

Восточно–Казахстанский технический университет им. Д. Серикбаева

УДК 004.932.2

на правах рукописи

**ТАНКИБАЕВА АКЕРКЕ КЫДЫРБЕКОВНА**

**Информационная технология выделения анатомических структур на изображениях магнитно–резонансной томографии**

8D06101 – Информационные системы (по отраслям)

Диссертация на соискание степени  
доктора философии (PhD)

Научный консультант  
к.т.н., профессор  
Кумаргажанова С.К.

Зарубежный научный консультант  
dr hab. inż, ассоц. профессор,  
Zbigniew Omiotek

Республика Казахстан  
Усть–Каменогорск, 2025

## СОДЕРЖАНИЕ

ВВЕДЕНИЕ.....	4
1 АНАЛИТИЧЕСКИЙ ОБЗОР МЕТОДОВ И МОДЕЛЕЙ АНАЛИЗА МЕДИЦИНСКИХ ИЗОБРАЖЕНИЙ .....	11
1.1 Медицинские аспекты диагностики повреждений мениска.....	11
1.2 Магнитно–резонансная диагностика повреждений мениска коленного сустава .....	15
1.3 Существующие информационные технологии и инструментальные средства обработки и распознавания медицинских изображений.....	18
1.4 Классические методы обработки и распознавания медицинских изображений .....	23
1.5 Современные модели и методы глубокого обучения в медицине .....	25
1.6 Сравнительный обзор свёрточных и трансформерных архитектур нейронных сетей в задачах анализа медицинских изображений.....	29
Выводы по первому разделу .....	31
2 МЕТОДЫ И МОДЕЛИ ДИАГНОСТИРОВАНИЯ ПОВРЕЖДЕНИЙ МЕНИСКОВ КОЛЕННОГО СУСТАВА .....	33
2.1 Описание исходных данных исследования .....	33
2.2 Общая методологическая концепция диагностирования повреждений менисков коленного сустава .....	34
2.3 Разработка метода текстурной диагностики повреждений менисков коленного сустава.....	35
2.4 Автоматическое распознавание повреждений менисков на основе методов глубокого обучения.....	51
2.4.1 Разработка методики предварительной обработки МРТ изображений .	56
2.4.2 Архитектуры моделей YOLO и RT–DETR.....	68
Выводы по второму разделу .....	71
3. ЭКСПЕРИМЕНТАЛЬНЫЕ ИССЛЕДОВАНИЯ И РЕЗУЛЬТАТЫ .....	73
3.1 Параметры обучения и метрики оценки производительности моделей ...	73
3.2 Сравнительный анализ моделей YOLOv8–x и RT–DETR–1 в задаче автоматического обнаружения разрыва мениска на МРТ–изображениях коленного сустава.....	75
3.3 Анализ ошибочной классификации и ложного обнаружения.....	81
3.4 Сравнение моделей по эффективности обнаружения и скорости обработки .....	82
3.5 Сравнение производительности моделей YOLOv8–x и RT–DETR–1.....	85
Выводы по третьему разделу .....	92

4. ПРОЕКТИРОВАНИЕ АРХИТЕКТУРЫ ИНТЕЛЛЕКТУАЛЬНОЙ СИСТЕМЫ ДИАГНОСТИКИ ПОВРЕЖДЕНИЙ МЕНИСКОВ КОЛЕННОГО СУСТАВА.....	93
4.1 Общее описание архитектурной структуры.....	93
4.2 Организация хранения данных и взаимодействие пользователей с интеллектуальной системой диагностики .....	97
4.3 Описание состава и схем диалога пользовательского интерфейса интеллектуальной системы .....	100
Выводу по четвертому разделу.....	107
ЗАКЛЮЧЕНИЕ .....	108
СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ .....	110
ПРИЛОЖЕНИЕ А – Свидетельство о государственной регистрации авторского права РК «Программное обеспечение магнитно–резонансной томографии патологий коленного сустава» .....	122
ПРИЛОЖЕНИЕ Б – Акт внедрения результатов исследования .....	123
ПРИЛОЖЕНИЕ В – Листинг программного кода приложения «XRAY Inspector» .....	124

## ВВЕДЕНИЕ

**Ключевые слова:** магнитно-резонансная томография (МРТ), разрыв мениска, текстурная диагностика, обнаружение объектов, глубокое обучение, обработка медицинских изображений, YOLOv8, RT-DETR, интеллектуальная диагностическая система.

**Актуальность работы.** В последние годы в Казахстане наблюдается активное развитие цифровой трансформации и технологий искусственного интеллекта, что подтверждается стратегическими инициативами на государственном уровне. В своем ежегодном послании народу от 8 сентября 2025 года Президент Республики Казахстан Касым-Жомарт Токаев обозначил задачу достижения полного перехода страны к цифровому формату в течение ближайших трёх лет, подчеркнув, что Казахстан вступает в новую эпоху — эпоху искусственного интеллекта (ИИ).

Дальнейшим шагом в реализации данного курса стало подписание 18 сентября 2025 года Указа Президента о реорганизации Министерства цифрового развития, инноваций и аэрокосмической промышленности в Министерство искусственного интеллекта и цифрового развития. Эта институциональная реформа отражает стремление государства вывести развитие искусственного интеллекта и цифровизации на уровень приоритетной государственной политики.

Создание специализированного государственного органа свидетельствует о системном подходе к управлению цифровыми преобразованиями и формированию национальной экосистемы ИИ. В то же время данный шаг направлен на усиление институциональной поддержки научных исследований и прикладных разработок в области искусственного интеллекта, а также на обеспечение эффективной интеграции научных достижений в практику цифровой трансформации различных отраслей экономики и социальной сферы.

В своем Послании Президент Республики Казахстан обозначил ряд приоритетных направлений развития, среди которых особое внимание уделено применению технологий искусственного интеллекта в сфере здравоохранения. Одной из ключевых задач определено создание условий для внедрения отечественных инновационных решений в деятельность медицинских учреждений. В частности, Глава государства подчеркнул важность разработки и внедрения системы «ИИ-ассистент врача», предназначеннной для оптимизации процессов медицинской диагностики, снижения вероятности диагностических ошибок и уменьшения нагрузки на медицинский персонал. Отдельное значение придается созданию интеллектуальных инструментов, обеспечивающих раннее выявление онкологических и других социально значимых заболеваний, что соответствует стратегическим задачам повышения качества и эффективности медицинской помощи населению.

В настоящее время заболевания и травмы опорно-двигательного аппарата остаются одной из наиболее значимых медико-социальных

проблем современного здравоохранения. Они оказывают существенное влияние на качество жизни населения, ограничивают физическую активность и являются одной из основных причин утраты трудоспособности у лиц активного возраста. Особое место в структуре таких патологий занимают травматические и дегенеративно-дистрофические поражения суставов, среди которых наибольшая доля приходится на коленный сустав. По данным клинических наблюдений, повреждения коленного сустава составляют до 70% всех травм опорно-двигательного аппарата, что обусловлено его анатомо-функциональными особенностями, высокой нагрузкой и частотой травмирующих воздействий в повседневной и профессиональной деятельности. К наиболее распространённым повреждениям мягкотканых структур коленного сустава относятся травмы менисков, связок, сухожилий и мышц [1]. При этом лидирующее положение занимают повреждения менисков, которые регистрируются в 55–85 % случаев всех травм коленного сустава и требуют своевременной и точной диагностики, а также обоснованного выбора тактики лечения [2–4].

В последние годы исследование внутрисуставных повреждений коленного сустава, в частности диагностика повреждений менисков, приобретает особую актуальность в области травматологии и ортопедии. Это обусловлено высокой частотой встречаемости данных патологий, их значительным влиянием на функциональную активность пациента и необходимостью разработки более эффективных методов визуализации и анализа структур мягких тканей.

Среди современных неинвазивных методов диагностики заболеваний коленного сустава особое место занимает магнитно-резонансная томография (МРТ), которая в последние годы получила широкое распространение в клинической практике. В ряде исследований МРТ определяется как «золотой стандарт» в неинвазивной визуализации патологий коленного сустава. Это обусловлено её высокими технологическими и диагностическими характеристиками, в частности чувствительностью и специфичностью, которые по ряду параметров превосходят возможности альтернативных методов визуализации, таких как рентгенография и ультразвуковое исследование.

Мышцы, связки, хрящи и другие суставные структуры обладают высокой степенью визуализации при использовании метода магнитно-резонансной томографии. Во многих случаях МРТ позволяет получать диагностически значимую информацию о внутренних структурах коленного сустава, недоступных для анализа при применении рентгенографии, ультразвукового исследования (УЗИ) или компьютерной томографии (КТ).

Магнитно-резонансная томография коленного сустава широко применяется для выявления причин необъяснимого болевого синдрома, диагностики артрита, опухолей костной ткани, инфекционных процессов, а также повреждений хрящей, менисков, связок и сухожилий. Использование МРТ позволяет определить необходимость проведения артроскопии коленного сустава и выявить скрытые переломы костей в случаях, когда

рентгенологические и иные методы исследования не дают однозначных результатов. В настоящее время МРТ является наиболее востребованным методом среди существующих инструментов неинвазивной диагностики патологий костно–суставной системы, обеспечивая высокую точность и информативность при оценке состояния как твёрдых, так и мягкотканых структур.

Несмотря на высокую диагностическую эффективность магнитно–резонансной томографии в выявлении разрывов менисков коленного сустава, остаётся нерешённой проблема точной и объективной интерпретации полученных изображений. Процесс анализа МРТ–снимков в значительной степени зависит от опыта и квалификации специалиста, что может приводить к вариативности диагностических заключений и снижению достоверности результатов.

В этой связи актуальной задачей является разработка и внедрение современных информационных технологий, способных повысить специфичность и чувствительность диагностики повреждений менисков коленного сустава на основе МРТ–изображений. Использование методов искусственного интеллекта и глубокого обучения открывает возможности для автоматизации процесса анализа медицинских изображений, повышения точности распознавания патологий и сокращения влияния субъективного фактора в диагностическом процессе.

В стратегических документах, определяющих направления развития Республики Казахстан, вопросам цифровизации и внедрения технологий искусственного интеллекта уделяется особое внимание. В частности, в Национальном плане развития Республики Казахстан до 2025 года и в Концепции цифровой трансформации, развития отрасли информационно–коммуникационных технологий и кибербезопасности на 2023–2029 годы обозначены задачи и мероприятия, направленные на развитие базовых направлений искусственного интеллекта. Важным шагом в этом направлении стало утверждение Постановлением Правительства Республики Казахстан от 24 июля 2024 года № 592 «Концепции развития искусственного интеллекта на 2024–2029 годы» [5]. Одной из ключевых задач, определённых в данном документе, является разработка и внедрение решений на основе технологий искусственного интеллекта в медицинской диагностике.

В этом контексте выполнение диссертационного исследования на тему «Информационная технология выделения анатомических структур на изображениях магнитно–резонансной томографии» представляется актуальным и практически значимым. Реализация поставленных в работе задач напрямую соответствует целям государственных программ по цифровизации здравоохранения и применению искусственного интеллекта в медицине.

Актуальность данного исследования также определяется применением технологий искусственного интеллекта для автоматизированного выделения анатомических структур на МРТ–изображениях, что способствует повышению точности и объективности диагностических заключений.

Использование интеллектуальных систем анализа медицинских изображений способствует снижению нагрузки на врачей, минимизации вероятности диагностических ошибок и повышению достоверности диагностики повреждений менисков коленного сустава, что, в конечном итоге, обеспечивает повышение качества и эффективности медицинской помощи.

Кроме того, в Республике Казахстан отмечается устойчивый рост интереса к развитию направлений, связанных с телемедициной, цифровой патологией и удалённым консультированием. В этих условиях особую значимость приобретают автоматизированные методы распознавания патологических изменений на основе анализа МРТ-изображений, которые могут способствовать внедрению подобных технологий, особенно в регионах, где наблюдается дефицит высококвалифицированных специалистов-рентгенологов. Таким образом, представленная тема диссертационного исследования обладает не только научной, но и выраженной социальной значимостью, поскольку её реализация направлена на повышение доступности качественной диагностики для населения, снижение экономической нагрузки на пациентов и систему здравоохранения, а также на улучшение общего качества и эффективности медицинской помощи в масштабах страны.

Диссертационное исследование выполнено в рамках грантового финансирования научных и (или) научно-технических проектов на 2024–2026 годы Министерства науки и высшего образования Республики Казахстан (ИРН проекта АР23486396 «Модели и методы распознавания анатомических структур на изображениях МРТ в задачах компьютерной диагностики»).

**Объектом исследования** является процесс распознавания разрывов менисков на МРТ изображениях коленного сустава.

**Предметом исследования** являются модели, методы обработки и анализа МРТ изображений для распознавания и локализации повреждений мениска коленного сустава.

**Целью исследования** является разработка информационной технологии анализа МРТ изображений, обеспечивающей выделение анатомических структур и повышение достоверности диагностики патологий на примере патологий коленного сустава.

Для достижения поставленной цели диссертационного исследования необходимо решить следующие научно-исследовательские задачи:

1. Провести анализ и систематизацию существующих подходов и методов, применяемых для автоматизации выделения и анализа анатомических структур на магнитно-резонансных изображениях.

2. Сформировать собственный датасет клинических МРТ-изображений коленного сустава, обеспечивающий репрезентативность данных для обучения и тестирования моделей.

3. Разработать метод информационно-текстурной диагностики повреждений менисков коленного сустава, основанный на анализе межпиксельных приращений яркости и плотности тканей.

4. Разработать методику предварительной обработки МРТ–изображений, включающую этапы фильтрации, улучшения контрастности и усиления резкости, с целью повышения качества данных для нейросетевого анализа.

5. Провести экспериментальные исследования, включающие обучение и тестирование моделей YOLOv8x и RT–DETR, а также выполнить сравнительный анализ их производительности и эффективности при решении задачи автоматического обнаружения разрывов менисков коленного сустава.

6. Спроектировать архитектуру интеллектуальной системы диагностики повреждений менисков коленного сустава, интегрирующую модули предварительной обработки, анализа и визуализации данных.

**Научная новизна** диссертационного исследования заключается в том, что впервые предлагается подход на основе архитектуры YOLOv8–x для автоматического распознавания разрывов мениска на МРТ изображениях коленного сустава, включающий собственный датасет и комбинированный метод предварительной обработки МРТ изображений.

**Основные научные положения, выносимые на защиту:**

– метод текстурной диагностики повреждений мениска коленного сустава, основанный на информационно–текстурной трансформации изображений, предполагающей переход от визуально–аналогового представления МРТ–срезов к их формализованной цифровой интерпретации;

– комбинированный метод предварительной обработки МРТ–изображений, включающий сравнительный анализ нескольких фильтрационных подходов и выбор оптимальной методики на основе объективных метрик качества визуализации;

– архитектура интеллектуальной системы диагностики разрывов мениска коленного сустава, интегрирующая модуль текстурной диагностики и модуль детекции патологии на основе моделей глубокого обучения.

**Практическая значимость** результатов исследований заключается в улучшении точности диагностики, в снижении ошибок и ложноположительных результатов в раннем выявлении патологий мениска коленного сустава на МРТ изображениях.

**Методы исследования.** Для решения задач, поставленных для проведения исследования, были использованы методы обработки и анализа изображений, распознавания образов и моделей глубокого обучения.

**Апробация работы.** Результаты диссертационного исследования обсуждались на следующих конференциях:

– IX Международная научно–техническая конференция студентов, магистрантов и молодых ученых «Творчество молодых инновационному развитию Казахстана», посвященная 65 – летию ВКТУ им Д. Серикбаева, Усть–Каменогорск, Казахстан, 3–14 апреля 2023.

– Международная конференция «Наука, образование и практики реализации BIM и ГИС технологий», Усть–Каменогорск, Казахстан, 20–21 июня 2023.

– Международная конференция в честь 65–летия образования ВКТУ имени Д.Серикбаева «Computational and Information Technologies in Science,

Engineering and Education (CITech–2023)», Усть–Каменогорск, Казахстан, 2–3 октября 2023.

– XIX Международной Азиатской школы–семинара «Проблемы оптимизации сложных систем», г. Новосибирск, Россия, 14–22 августа, 2023.

– XI Международная научно–техническая конференция студентов, магистрантов, докторантов и молодых ученых, Усть–Каменогорск, Казахстан, 10–15 апреля 2025.

**Публикации.** По теме диссертационного исследования опубликовано 11 научных работ. Из них 4 статьи в изданиях, рекомендованных Комитетом по обеспечению качества в сфере науки и высшего образования Министерства науки и высшего образования Республики Казахстан; 5 публикации в материалах международных конференций; 2 статьи в международных научных изданиях, входящих в базу данных Scopus.

**Структура и объем диссертации.** Диссертация состоит из введения, четырех разделов, заключения, списка литературы, содержащего 144 наименований, приложений. Диссертация включает 25 рисунков, 25 таблиц. Общий объем диссертации составляет 100 страниц.

**В первом разделе** был проведен аналитический обзор существующих методов и моделей анализа медицинских изображений. В результате проведённого анализа научной литературы было установлено, что МРТ остаётся наиболее информативным методом визуализации мягкотканых структур коленного сустава. Описаны медицинские аспекты менисков коленного сустава. Представлена классификация основных типов повреждений менисков и даны их описания. На основе проведенного анализа были выделены методы и средства обработки и визуализации МРТ данных. Был проведен сравнительный анализ инструментальных средств обработки и визуализации медицинских изображений. Также были выделены основные этапы и методы классического подхода обработки и распознавания медицинских изображений. Изучены и классифицированы современные модели и методы глубокого обучения. Проведен сравнительный обзор свёрточных и трансформерных архитектур нейронных сетей в задачах анализа медицинских изображений.

**Во втором разделе** диссертации представлено описание исходных данных исследования. Подробно описан специализированный размеченный датасет для обучения моделей обнаружения горизонтальных разрывов мениска, собранный в различных медицинских центрах и аннотированный совместно врачом–травматологом. Рассмотрена общая методологическая концепция диагностирования повреждений менисков коленного сустава. Описаны подходы, с помощью которых было реализовано диагностирование повреждений менисков коленного сустава. Первый подход был осуществлен при помощи метода информационно–текстурной диагностики повреждений менисков коленного сустава. Второй подход был реализован на основе методов глубокого обучения с применением современных моделей семейства YOLO и RT–DETR. Оба подхода направлены на решение одной задачи — повышение достоверности диагностики повреждений менисков на МРТ–

изображениях. Для улучшения качества изображений были определены основные этапы процесса обработки МРТ–изображений. В результате был предложен комбинированный метод обработки МРТ–изображений, который продемонстрировал высокую эффективность, обеспечивая оптимальное подавление шума при сохранении анатомических границ. Представлены и описаны архитектуры моделей YOLO и RT–DETR.

**В третьем разделе** был проведен сравнительный анализ моделей глубокого обучения YOLOv8–x и RT–DETR в задаче автоматического обнаружения разрыва мениска на МРТ–изображениях коленного сустава. Также было проведено сравнение моделей по эффективности обнаружения и скорости обработки, анализ ошибочной классификации и ложного обнаружения. Приведены результаты сравнения производительности моделей YOLOv8–x и RT–DETR–l.

**В четвертом разделе** диссертационной работы представлена разработанная архитектура интеллектуальной системы диагностики разрывов мениска коленного сустава, состоящая из двух подсистем. Первая подсистема позволяет провести автоматизированное обнаружение и локализацию повреждений менисков коленного сустава на основе моделей глубокого обучения. Функционирование второй подсистемы основано на предложенном методе информационно–текстурной диагностики повреждений менисков коленного сустава.

**В заключительном разделе диссертационной работы** приводятся основные результаты и выводы диссертационного исследования, исходя из которых положения, выносимые на защиту, были подтверждены, дается оценка научной новизны и практической значимости исследования.

**Приложения.** Свидетельство о государственной регистрации авторского права РК № 61988 от 9 сентября 2025 года (Приложение А), акт внедрения результатов исследования (Приложение Б), листинг программного кода приложения (Приложение В).

# 1 АНАЛИТИЧЕСКИЙ ОБЗОР МЕТОДОВ И МОДЕЛЕЙ АНАЛИЗА МЕДИЦИНСКИХ ИЗОБРАЖЕНИЙ

## 1.1 Медицинские аспекты диагностики повреждений мениска

Коленный сустав является одним из самых важных и сложных суставов в организме человека, играющий центральную роль в стабильности, движении и поддержании веса. Вследствие своего анатомического положения и функционального значения он наиболее часто подвержен травме в любом возрасте. На его долю, как уже было отмечено, приходится до 70% повреждений всех суставов. Коленный сустав является вторым по величине крупным суставом организма, в функциональном отношении играющим для человека исключительно важную роль, являясь залогом его физической активности [6, 7]. Он представляет собой сложную биологическую динамическую систему, включающую в себя капсульно-связочный аппарат, суставный хрящ, мениски и синовиальную жидкость. Эта система играет ключевую роль в обеспечении нормальной функции нижней конечности [8, 9]. Сложность анатомического строения и биомеханики, плохая защищённость мягкими тканями, большие нагрузки в статике и динамике являются характерными особенностями, которые обусловливают высокую частоту его повреждений [10–12]. К наиболее часто возникающим повреждениям мягкотканых структур коленного сустава относятся повреждения менисков, связок, сухожилий и мышц [8]. Среди них первое место занимают повреждения менисков, которые чаще всего встречаются в трудоспособном возрасте [13–15].

Мениски обеспечивают нормальное функционирование и долговечность коленного сустава. Патологии мениска являются причиной дальнейших внутрисуставных повреждений и сопровождаются выраженными нарушениями функций сустава, приводящими к возникновению боли, неустойчивости и нарушению движений. Разрушение и отсутствие менисков способствуют прогрессированию дегенеративно-дистрофических процессов в ранее неповреждённых элементах сустава, приводят к быстрому развитию деформирующего остеоартроза, ограничению в движениях и длительной нетрудоспособности [16–18].

Если изначально мениск представлялся как бесполезнаяrudиментарная структура, то сейчас известно, что это важный интегральный компонент сложного комплекса в функционирующем коленном суставе [19]. Ткань мениска — одна из мягких тканей в суставе человека, расположенная между бедренной и большеберцовой костями коленного сустава. Мениски состоят из фиброзно-хрящевой ткани С-образной формы и делятся на латеральный (внешний) и медиальный (внутренний) мениски. Они представляют собой гладкие и скользкие структуры, расположенные на медиальной и латеральной поверхностях колена [20]. Эти структуры выполняют важные функции: обеспечивают стабильность сустава, амортизацию, распределение суставной жидкости и передачу нагрузки [21, 22]. Повреждения мениска

приводят к изменениям в биомеханике сустава, которые влияют на распределение нагрузки и контактные напряжения [23].

В настоящее время существует множество исследований, подробно анализирующих повреждения мениска, уделяя особое внимание частоте, классификации, диагностике, лечению, результатам и частоте рецидивов. Согласно [24] повреждения мениска классифицируются по следующим признакам:

- по форме;
- по расположению и степени повреждения;
- по локализации;
- по причине возникновения.

Каждый из типов повреждений имеет свои особенности визуализации на МРТ и клинические особенности проявления. Так, горизонтальные разрывы чаще возникают при дегенеративных изменениях, тогда как вертикальные характерны для спортивных травм. В таблице 1.1 представлены основные типы повреждений мениска в разрезе каждого класса.

Таблица 1.1 – Классификация повреждений менисков коленного сустава

Тип повреждения	Характеристика	Клинические особенности
1	2	3
<b>По форме</b>		
Горизонтальный	Разрыв вдоль плоскости мениска, разделяет мениск на верхнюю и нижнюю части	Часто встречается при дегенерации, может приводить к накоплению жидкости между тканей
Радиальный	Разрыв поперёк мениска, от внутреннего края к наружному	Нарушает механическую стабильность и передачу нагрузки
Вертикальный (продольный)	Разрыв вдоль волокон мениска, при смещении оторванной части может образоваться так называемый разрыв по типу «ручки лейки»	Может трансформироваться в разрыв по типу «ручки лейки»
По типу "ручки лейки"	Вид продольного разрыва, при котором крупный фрагмент мениска отрывается и смещается в центр коленного сустава	Приводит к блокаде сустава
Лоскутный (ключ попугая)	Разрыв, при котором от мениска отрывается небольшой лоскут	Часто вызывает «защёлкивание» и механическую нестабильность
Комбинированный	Сочетание нескольких типов разрывов (например, продольного, радиального и горизонтального)	Наиболее сложный в диагностике и восстановлении
Отрыв корня мениска	Повреждение в зоне	Нарушает анкерный механизм и

	прикрепления мениска	биомеханику колена
<b>По расположению и степени повреждения</b>		
Неполный	Разрыв затрагивает только часть толщины хряща, сохраняя при этом его целостность	Умеренная боль при нагрузках и поворотах, отек сустава, ощущение щелчков или хруста при движениях, а также ограничение подвижности колена
Полный	Нарушается целостность всей толщины хряща, что может привести к образованию отломков	Интенсивная боль, значительный отек, ограничение подвижности вплоть до полной блокады сустава, а также ощущение нестабильности и щелчков при движении
В «красной зоне»	Разрыв в периферической части мениска, в которой хорошее кровоснабжение	Такие разрывы имеют более высокий потенциал к заживлению и восстановлению
В «белой зоне»	Разрыв во внутренней, неваскуляризированной части мениска	Повреждения в этой зоне хуже поддаются консервативному лечению, чаще требуется оперативное вмешательство
В «красно-белой зоне»	Разрыв частично затрагивает кровоснабжающую и бессосудистую части мениска	Усиление боли при наружных вращательных движениях колена, приседании и сгибании ноги
<b>По локализации</b>		
Разрыв медиального (внутреннего) мениска	Встречается чаще всего из-за меньшей подвижности мениска	Боль при движениях, отек в зоне сустава, «подкашивание» колена, либо возникновение «блокады» сустава, скопление жидкости в полости сустава, щелчки при сгибании/разгибании сустава
Разрыв латерального (наружного) мениска	Встречается реже, так как латеральный мениск более подвижен	Боль по внешнему краю колена, отечность в зоне повреждения, щелчки при разгибании ноги, ограниченность движений, при отрыве фрагмента хряща — блокада сустава
<b>По причине возникновения</b>		
Травматический	Возникает в результате резкого движения, чаще у молодых людей, занимающихся спортом	Сильные боли, ограниченность в движениях, воспалительный процесс внутренней оболочки сустава, блокада сустава
Дегенеративный	Развивается со временем из-за изнашивания хрящевой ткани, характерен для пожилых людей	Острая боль при движениях, ощущение инородного тела в суставе

Основные виды повреждений менисков коленного сустава приведены на рисунке 1.1.



Рисунок 1.1 – Основные типы повреждений менисков коленного сустава

Несмотря на то, что разрывы мениска являются распространённой ортопедической патологией, их лечение представляет собой сложную задачу. Способы лечения разрывов мениска бывают как неоперативными, так и хирургическими. Хирургические способы лечения включают менискэктомию и артроскопический шов мениска. В течение нескольких лет артроскопическое сшивание разрывов менисков и частичная менискэктомия стали двумя наиболее частыми ортопедическими операциями в мире [25]. Недавние исследования показывают, что у пациентов, перенесших менискэктомию, существенно более высокий риск возможности прогрессирования остеоартрита и последующей необходимости в тотальном эндопротезировании коленного сустава по сравнению с теми, кому было проведено восстановление мениска [26]. Это способствовало изменению концепции лечения в пользу сохранения мениска.

В настоящее время всё чаще рекомендуется проводить восстановление мениска при всех поддающихся восстановлению разрывах, особенно у молодых и физически активных пациентов. Восстановление мениска и сохранение менисковой ткани обеспечивает равномерное распределение биомеханической нагрузки в пораженном отделе сустава, снижая риск раннего износа и дегенерации хряща, тем самым сохраняя сустав. За последние годы сохранение мениска коленного сустава показало высокий уровень успеха с точки зрения времени восстановления сустава и функционального результата [25].

Возможность восстановления мениска и выбор наиболее эффективного способа лечения разрывов мениска определяется в зависимости от локализации и типа разрыва. Поэтому правильное распознавание и идентификация разрыва мениска имеет решающее значение для его последующего лечения и возможности восстановления [27]. Диагностика повреждений мениска зависит не только от тщательного сбора анамнеза и клинического обследования, но и практически неизбежно требует подтверждения с помощью МРТ [25].

## **1.2 Магнитно–резонансная диагностика повреждений мениска коленного сустава**

В последние годы исследование внутрисуставных повреждений, в частности повреждение менисков коленного сустава, является актуальной проблемой в травматологии и ортопедии. Даже для опытного хирурга поставить точный диагноз разрыва мениска бывает сложно. Эта проблема остается, несмотря на имеющееся большое количество описанных тестов и симптомов, характеризующих повреждение менисков.

По данным разных авторов, диагностические ошибки внутрисуставных повреждений составляют 3–30%, а эффективность «традиционных» методов обследования не превышает 70–75%, в остром периоде 55–60% [19, 28–30]. По данным О.П. Филиппова и соавторов [31], несмотря на большое количество работ, посвящённых проблеме выявления и лечения повреждений менисков, ошибки диагностики встречаются у 7,2–30,8% пострадавших.

Традиционно на протяжении нескольких десятилетий первичным диагностическим методом обследования пациентов с жалобами на боль в области коленного сустава являлась рентгенография. Рентгенография коленного сустава играет важную роль в диагностике костных структур. С помощью этого метода можно обнаруживать перелом, отрывной перелом, вывих, субхондральный склероз, сужение суставной щели, дегенеративные изменения и остеофиты. Однако он не может в достаточной степени обнаружить повреждения связок, менисков и других мягкотканых структур коленного сустава [32].

Магнитно–резонансная томография и клиническое обследование – два наиболее распространенных метода диагностики разрывов менисков коленного сустава. Считается, что стандартная МРТ перед лечебной артроскопией в случаях клинически диагностированного повреждения мениска уменьшит количество и стоимость ненужных инвазивных процедур. Предоперационная МРТ коленного сустава характеризуется высокой вариабельностью диагностической эффективности. С учетом высокой ценности МРТ как метода отбора пациентов на артроскопическую операцию, эта методика показана всем пациентам с симптомами повреждения внутренних структур коленного сустава. Основными условиями успешного применения МРТ является использование стандартизованных протоколов исследования и корректная интерпретация результатов [33]. С годами роль

МРТ стала незаменимой не только в диагностике травм мениска, но и почти во всех внутрисуставных патологий колена.

В настоящее время, по данным исследования [34] МРТ является «золотым стандартом» в неинвазивной диагностике патологии коленного сустава, так как показатели ее специфичности и чувствительности превосходят альтернативные методы исследования. К основным достоинствам МРТ относится возможность визуализации хрящевых тканей, поскольку одним из наиболее существенных его преимуществ перед другими методами лучевого исследования является высокая тканевая контрастность, которая позволяет получать изображения мягкотканых и хрящевых структур. Большим преимуществом являются также отсутствие лучевой нагрузки и возможность получения изображения в различных плоскостях без изменения положения пациента [1].

Основным показанием для МРТ обследования является подозрение на повреждение внутренних структур (хряща, связок, сухожилий, менисков) коленного сустава различной этиологии [35]. МРТ позволяет четко выявить наличие повреждения, дифференцировать разрывы и дегенеративные изменения этих структур. Кроме того, результаты МРТ дают возможность уточнить характер, локализацию и протяженность повреждения, а также выявить признаки травматического кровоизлияния в полость сустава [36]. Согласно данным, приведенным в статье [34] с началом применения МРТ точность выявления разрывов связок и менисков достигла более чем 90–95%. В целом, исследование коленного сустава занимает третье место по частоте применения метода МРТ, уступая только исследованиям головного мозга и позвоночника. МРТ обладает высокой информативностью при диагностике повреждений менисков. В то же время чувствительность и специфичность МРТ, по данным различных авторов, по сравнению с артроскопическим исследованием составляет от 84 до 98 %. Наряду с этим, МРТ обладает значительными возможностями для оценки эффективности артроскопического лечения травматических повреждений менисков. Благодаря большей чувствительности, неинвазивности и возможности амбулаторного проведения исследования для первичной оценки симптомов поражений коленного сустава чаще применяется МРТ, чем артроскопия.

По мнению Ф.М. Ахмеджанова и соавт. [37], чувствительность МРТ при диагностике внутрисуставных повреждений коленного сустава приближается к 100%. Сравнивая диагностические возможности методов МРТ и артроскопического исследования, автор делает выводы о преимуществах МРТ при диагностике повреждений внесуставных связок, переломах костей, оценке степени дегенеративных повреждений менисков. По данным Б.К. Бакиева [32], диагноз разрыва мениска по своей достоверности равнозначен возможности МРТ, но МРТ остаётся важным инструментом в тех случаях, когда необходима дополнительная информация для принятия решения о выполнении артроскопии. По данным А.В. Брюханова, М.А. Клыжина [35], при обнаружении повреждений менисков диагностическая ценность МРТ была выше, чем УЗИ: чувствительность методов составила соответственно

91,3 и 89,3%, специфичность – 98,2 и 81,5%, предсказуемость положительного теста – 97,3 и 75,3%, предсказуемость отрицательного теста – 94,1 и 92,4%, точность – 95,4 и 84,5%.

По результатам исследования, проведенного М.А. Абдушариповым и соавт. [38] чувствительность МРТ в диагностике разрывов менисков оказалась наиболее высокой и составила: 91,7% для латерального мениска и 95,4% для медиального мениска. В то же время при диагностике разрывов передней крестообразной связки МРТ-исследование не обладает столь высокой чувствительностью (88,2%).

Несмотря на эффективность МРТ в исследовании внутрисуставных повреждений коленного сустава, в настоящее время существуют значительные трудности в определении повреждений менисков коленного сустава. В исследовании [32] автор пишет о том, что основные сложности в оценке состояния менисков возникали при дифференциации дегенеративно-дистрофических и посттравматических изменений. На фоне этих изменений мениска участки повышенного МРТ-сигнала внутри ткани не доходили до суставной поверхности, хотя клинически подозревался разрыв. В таких случаях возможно затруднение при отличии II степени дегенерации мениска от III. Наряду с этим значительные трудности возникали в чёткой дифференциации периферического края мениска и прикрепления мениска к капсуле сустава.

Также одной из немаловажных причин затруднения диагностирования повреждений менисков с помощью МРТ является то, что объекты интереса исследователя на медицинских изображениях, используемых в ранней диагностике, обычно бывают небольшими и малоконтрастными по сравнению с окружающим фоном. При визуальном обнаружении этих объектов – выполнении первого шага на пути диагностики по медицинскому изображению – могут возникнуть проблемы. С одной стороны, они обусловлены указанными особенностями самих изображений, с другой – ограниченностью характеристик зрительной системы исследователя и искажениями, возникающими в изображениях при их получении и отображении [38]. Другими причинами недостаточной чувствительности и специфичности МРТ при определении повреждений менисков обычно рассматриваются напряженность магнитного поля и квалификация врача-рентгенолога. В самом процессе диагностики внутрисуставных повреждений коленного сустава наиболее сложным представляется интерпретация изображений. Как отмечают авторы работ [39–41], в этом отношении крайне важным является понимание характера интенсивности сигнала, создаваемого различными параметрами скана [42].

Необходимо отметить, что точность диагностики повреждений коленного сустава с помощью МРТ определяется как протоколом обследования, так и знаниями, квалификацией и опытом специалиста по лучевой диагностике. Обязательным условием точности обследования методом МРТ является наличие клинической информации о состоянии коленного сустава и предварительного диагноза, поставленного

травматологом–ортопедом. Только в этом случае специалист по лучевой диагностике может грамотно идентифицировать и интерпретировать патологические изменения коленного сустава. Ошибки интерпретации томограмм коленного сустава снижают точность МРТ, а также точность диагностирования и определения степени тяжести повреждений мениска, что может привести к повышению риска возникновения врачебных ошибок.

Таким образом, несмотря на эффективность МРТ в диагностировании повреждении мениска коленного сустава, существует проблема значительной неоднородности в интерпретации результатов томографии, что приводит к недооценке значения предоперационной МРТ травматологами–ортопедами и отсутствию согласованных показаний для МРТ у пациентов с травмой коленного сустава. В этой связи, возникает необходимость разработки и внедрения информационной технологии, которая позволит улучшить специфичность и чувствительность МРТ диагностики повреждений менисков коленного сустава.

### **1.3 Существующие информационные технологии и инструментальные средства обработки и распознавания медицинских изображений**

Информационные технологии наравне с ядерной медициной являются важнейшими составляющими прогресса в области высокотехнологичной медицины. Радионуклидная диагностика невозможна без высокопроизводительных вычислительных комплексов, математического, а также программного обеспечения своевременных задач принятия решений. В настоящее время для оперативных задач медицинской диагностики разработаны принципы компьютерного автоматизированного анализа медицинских изображений различных участков и органов тела [43].

В последнее время одним из актуальных направлений развития компьютерных технологий в медицине становится обработка цифровых изображений: улучшение качества изображения, восстановление поврежденных изображений, распознавание отдельных элементов.

Распознавание патологических процессов является одной из наиболее важных задач обработки и анализа медицинских изображений. При решении задач распознавания все чаще используются компьютерные системы диагностики – Computer Aided Diagnostic (CAD). Большинство из них являются инструментом для просмотра медицинских изображений стандарта DICOM (Digital Imaging and Communications in Medicine) – стандарт обработки, хранения, передачи, печати и визуализации медицинских изображений. DICOM определяет формат файлов радиологических исследований и сетевой протокол, который в качестве транспорта использует TCP/IP. DICOM разрабатывается с 80-х годов, ежегодно обновляется, став на сегодняшний день стандартом де-факто — поддерживается всеми современными цифровыми устройствами: томографами, УЗИ–аппаратами, маммографами, рентгеновскими аппаратами и т.д. [44].

Исследования в области обработки данных магнитно-резонансной томографии на сегодняшний день также являются быстро развивающимся научноемким направлением, характеризующимся созданием программного обеспечения и разработкой методов научной визуализации.

За последнее десятилетие в мире разработано большое количество компьютерных систем обработки и различных визуализаторов данных МРТ. В ходе выполнения исследования был проведен обзор современной научно-технической литературы, затрагивающей научную проблему обработки и когнитивной визуализации многомерных биомедицинских данных магнитно-резонансной томографии. Среди инструментальных средств можно отметить специализированную программу «BET» (Brain Extraction Tool) [45], которая предназначена для выделения области мозга, оценки внутренней и внешней поверхности черепа, а также наружной поверхности волосистой части головы. Программа «NiftySeg» [46] содержит набор алгоритмов для сегментации и анализа изображений, оценки толщины коры мозга и пр. Такие средства как «RadiAnt DICOM Viewer» [47] и «ImageJ» [48] используются в основном для визуализации. Программа «xjView» [49] позволяет просматривать МРТ-изображения в различных режимах («Glass View», «Section View», «3D Render View», «Slice View»). Визуализатор «Novo Spark» [50] является мощным приложением для просмотра и качественного анализа многомерных данных. Кроссплатформенная система «3D Slicer» [51] отличается широким функционалом за счет большого количества модулей. Следует отметить, что практически все вышеописанные программы имеют открытые исходные коды и распространяются без лицензионных ограничений.

В исследованиях [52, 53] представлена технология, которая позволяет измерять объемы внутричерепного пространства; ликворных субарахноидальных пространств и желудочков головного мозга; белого вещества; серого вещества; цереброспинальной жидкости и др. Данная технология позволяет провести количественную оценку атрофических и очаговых изменений головного мозга. В статье [54] рассмотрена задача автоматической сегментации изображений МРТ головного мозга человека на анатомические структуры, представлены средства для измерения веса областей, для которых известна экспертная разметка. В работе [55] представлено приложение «AW Oncoquant» предназначенное для упорядочивания и отображения данных онкологических исследований.

В последние годы наблюдается тенденция к созданию 3D-изображений в медицине. При достаточно плотных срезах их можно рассматривать в совокупности в 3D-пространстве. В работе [56] представлены нейроанатомические модели для анализа изображений головного мозга. В статье [57] рассмотрен подход к восстановлению изображения 3D-объекта и к поиску сопряженных точек между фрагментами изображений проекций объекта с применением алгоритмов контурного анализа. В исследовании [58] рассмотрен алгоритм, позволяющий построить трехмерную модель по координатам точек параллельных срезов, полученных на основе данных

МРТ. Автором предлагается метод визуализации модели, основанный на применении полигональных сеток. С помощью методов томографии удается с большой результативностью локализовать пораженные участки костных тканей с установлением точного геометрического положения, размера, повреждения или изменения положения окружающих костных тканей, удается представить трехмерную форму объекта в виде совокупности поставленных друг на друга многогранников, основания которых соответствуют срезам и параллельны между собой. После получения модели осуществляется ее визуализация методами машинной графики.

Программа «3D DOCTOR» (США) [59] предназначена для трехмерного моделирования, визуализации 3D-объектов в научных целях и в области высокоточных измерений. Интерфейс программы ориентирован на визуализацию, сегментирование и анимацию. Программа используется в ведущих больницах, медицинских учебных заведениях и научных организациях по всему миру. Программа «3D Slicer» (США) [51] может быть легко расширена для развития интерактивных и пакетных инструментов обработки в различных приложениях. Программа обеспечивает регистрацию изображений, интерфейс для внешних устройств, работу с графическими процессорами. Она позволяет легко добавлять новые интерактивные возможности визуализации произвольно ориентированных изображений, создавать поверхности. Программное обеспечение «Visualization Toolkit» (VTK, США) [60] предназначено для визуализации научной 2D- и 3D-графики, моделирования и обработки изображений. VTK включает вспомогательную поддержку параллельных вычислений и реализовано как инструментарий на языке C++, что позволяет легко интегрироваться в различные приложения. Программа «Drishti 2.0» (Австралия) [61] служит для визуализации данных томографии, электронно-микроскопических данных, позволяет пользователям применять функции передачи по «плотности» или «значению», а также «градиенту», удалять некоторые области пространства данных.

Система «OsiriX» может работать с файлами формата DICOM и поддерживает протокол передачи медицинской графической информации по сети, регламентируемый стандартом DICOM. Также поддерживаются стандарты Analyze, LSM, BioRadPIC и неспециализированные графические форматы TIFF, PNG, JPEG, PDF. «MRIcron» (Magnetic Resonance Image Conversion, viewing and analysis) – графический интерфейс визуализации и статистического анализа данных МРТ [62]. Визуализатор «MRIcron» [63] содержит утилиту «dcm2nii», конвертирующую DICOM-файлы в файлы формата «NIfTI», востребованного в средствах обработки данных МРТ. «MRIcron» позволяет эффективно просматривать и экспортировать изображения, а также идентифицировать участки, представляющие интерес [64–66].

Программный пакет «Gimias» (Graphical In-terface for Medical Image Analysis and Simulation) является бесплатным продуктом с открытым исходным кодом, распространяемым по лицензии BSD. «Gimias» имеет

модульную архитектуру и может использоваться как самостоятельно, так и для построения узкоспециализированных продуктов. «Gimias» поддерживает все распространенные форматы медицинских графических изображений, в том числе DICOM, Analyze, NIfTI и другие. В состав пакета входят разнообразные модули для обработки изображений, в том числе фильтры в пространственных и частотных областях, фильтры шумов и др. [64].

«FreeSurfer» представляет собой набор инструментов для автоматической реконструкции и анализа поверхностных и внутренних структур головного мозга, который позволяет сегментировать белое вещество, кортикальное и субкортикальное серое вещество, вычислять такие параметры, как толщина и глубина извилин, выполнять межсубъектный анализ путем проекции индивидуальных изображений коры на сферическую поверхность стандартного размера [67–70].

В таблице 1.2 представлен сравнительный анализ современных инструментальных средств для обработки и распознавания медицинских изображений.

Таблица 1.2 – Сравнительный анализ инструментальных средств обработки и распознавания медицинских изображений

Критерии	Показатели	BET	NiftySeg	ImageJ	xView	Novo Spark	3D Slicer	FreeSurfer	Gimias	OsiriX	MRIcron	3D Doctor	Drishū	OncQuant	RadiAnt DICOM Viewer	Visualization Toolkit
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
I. Технологические характеристики	Кроссплатформенность	+	+	+	+	±	+	+	+	±	+	±	+	±	±	+
	Поддержка формата DICOM	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+
	Поддержка 3D-визуализации	–	+	+	±	+	+	+	+	+	+	+	+	+	±	+
	Наличие модульной архитектуры	–	+	+	–	±	+	+	+	±	±	±	+	±	–	+
	Поддержка параллельных вычислений	–	±	±	–	±	+	+	±	–	±	±	+	±	–	+
II. Функциональные возможности	Сегментация изображений	+	+	+	±	+	+	+	+	±	+	+	+	+	–	+
	Анализ морфологических структур	±	+	±	±	±	+	+	+	+	±	+	+	+	–	+
	Визуализация и анимация	–	±	+	+	+	+	+	+	+	+	+	+	+	+	+
	Автоматическая обработка данных	±	+	±	–	±	+	+	+	±	±	+	±	+	–	+
	Возможность 3D-реконструкции	–	±	+	±	+	+	+	+	+	+	+	+	+	±	+
Бес	Интуитивный интерфейс	±	±	±	±	+	+	±	+	+	+	+	+	+	+	±

<b>IV. Прикладное назначение</b>	Доступность (лицензия)	Свободная	Свободная	Свободная	Свободная	Коммерческая	Свободная	Свободная	Свободная	Коммерческая	Свободная	Коммерческая	Свободная	Коммерческая	Частично	Свободная
	Активность поддержки сообщества	+	+	+	±	±	+	+	+	±	+	±	+	±	±	+
	Документация и обучающие материалы	±	+	+	±	±	+	+	+	±	+	+	+	+	+	+
	Нейроанализ	+	+	±	+	-	+	+	+	±	+	±	±	+	-	±
	Онкологическая диагностика	±	±	±	±	±	+	±	±	+	±	+	±	+	±	+
	Ортопедическая визуализация (в т.ч. суставы)	±	±	+	±	+	+	±	+	+	+	+	+	+	+	+

Примечание – Составлено по источникам [45–70]

Классификация методов и средств обработки и визуализации данных МРТ в общем виде представлена ниже на рисунке 1.2.



Рисунок 1.2 – Классификация методов и средств обработки и визуализации данных МРТ

В Казахстане данное направление исследований находится лишь на начальной стадии развития. На данный момент пока нет отечественных систем распознавания медицинских МРТ изображений. По результатам проведенного обзора, также можно сделать вывод, что в настоящее время нет автоматизированного программного комплекса с соответствующим функционалом, который помог бы врачу-диагносту определить разрыв мениска коленного сустава на снимках МРТ. Проанализировав, разработанные и существующие на данный момент системы распознавания МР изображений, необходимо отметить, что известные в настоящее время программные средства в большинстве направлены на автоматическую сегментацию мозга и позвоночника. Для обработки МР изображений чаще всего используется метод ручной сегментации, при котором оператор в

ручном режиме обозначает границы каждого изображения. Это трудоемкий процесс, требующий значительных временных затрат. Такой подход используется для сегментирования наиболее важных частей изображения и может содержать ошибки, вызванные субъективными погрешностями [71].

Исследование функций и особенностей работы современных специализированных систем для анализа и обработки медицинских изображений в различных целях показало, что эти системы обладают рядом недостатков. Основным недостатком представляется то, что большинство из систем содержит лишь широкий набор методов анализа и обработки изображений, доступный исследователю, без указаний, какой именно метод должен быть применен для достижения поставленной цели преобразования. В связи с этим выявлены следующие проблемы:

- невозможно гарантированно осуществить оптимальный (в смысле достижения поставленной цели преобразования) выбор метода (или комбинации методов) для обработки изображений, поскольку этот выбор основывается лишь на знаниях и опыте пользователя;
- осуществить перебор всех имеющихся в распоряжении исследователя методов (и их сочетаний) для достижения наилучшего результата обработки невозможно, поскольку это будет слишком затратным по времени [43].

На основе анализа литературных источников, можно сделать заключение, что в настоящее время компьютерные программы количественной оценки для медицинской диагностики разработаны только для ряда частных случаев [72, 73]. Большинство из них были разработаны для диагностирования заболеваний головного мозга и позвоночника. В открытом доступе нет средств автоматической количественной оценки коленного сустава и построения трехмерных моделей ввиду сложности его анатомического строения и малых размеров структур. Аналитический обзор показал необходимость в разработке информационной технологии, для автоматической количественной оценки коленного сустава, которая позволит более точно диагностировать наличие его повреждений.

#### **1.4 Классические методы обработки и распознавания медицинских изображений**

Технологии распознавания и классификации изображений являются неотъемлемой частью многих отраслей экономики, таких как медицина, автомобилестроение, системы безопасности и развлечения. Методы распознавания позволяют автоматизировать такие процессы, как извлечение информации, распознавание объектов и лиц, сжатие изображений, медицинская визуализация, а также повышать их эффективность.

С развитием медицины и технологий обработки изображений задача автоматического распознавания патологий на медицинских изображениях, таких как МРТ, компьютерная томография (КТ), ультразвуковое исследование (УЗИ), на сегодняшний день стала одной из ключевых в биомедицинской информатике и цифровой диагностике.

В настоящее время известно достаточно много методов обработки и распознавания изображений. С их помощью становится возможным повысить точность диагностики, уменьшить влияние человеческого фактора при постановке диагноза и ускорить процесс интерпретации патологий. Особенно это актуально для распознавания внутрисуставных повреждений, таких как разрыв менисков. Это связано с тем, что объекты распознавания бывают малоконтрастными и очень маленьких размеров [43].

Медицинские изображения имеют ряд особенностей, которые следует учитывать при создании систем распознавания. Основными проблемами при работе с изображениями, полученными с помощью МРТ, являются низкое качество или плохой контраст, наличие артефактов, обусловленных техническими характеристиками и настройками оборудования. Точный анализ и правильная обработка результатов МР исследований позволяют эффективно выделять внутрисуставные патологические процессы и в частности, определять повреждения менисков коленного сустава [74].

Классический подход обработки и распознавания медицинских изображений включает следующие этапы: предобработка изображения; сегментация/выделение области интереса (ROI); извлечение признаков; классификация (рисунок 1.3).

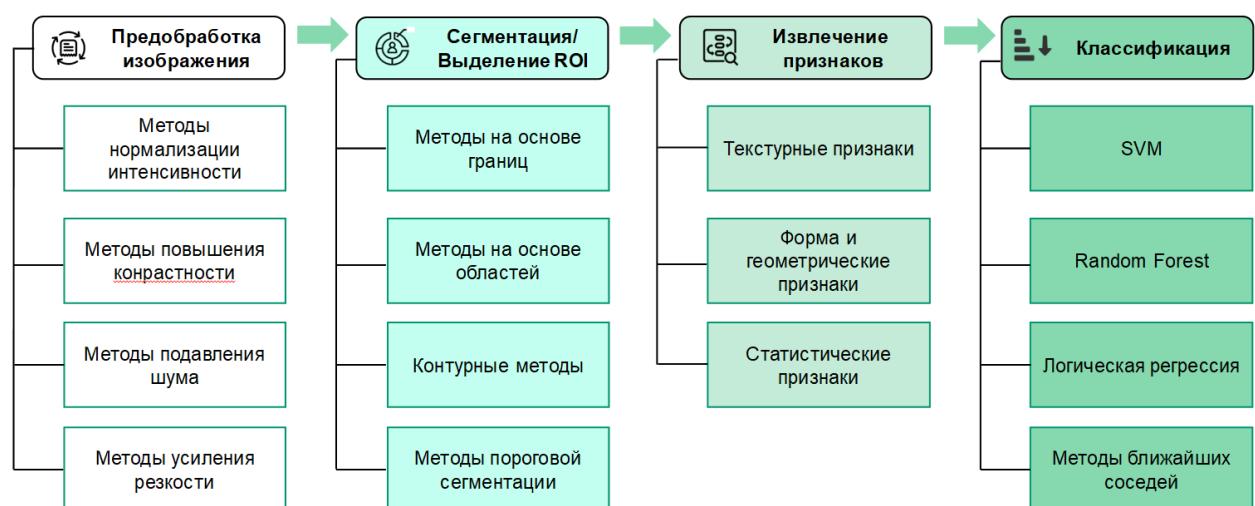


Рисунок 1.3 – Основные этапы и методы классического подхода обработки и распознавания медицинских изображений

Неоспоримое достоинство классических алгоритмов распознавания образов заключается в том, что они не требуют данных для обучения, обрабатывают изображения на высокой скорости и могут работать в реальном времени. Методы и алгоритмы на основе характеристических признаков эффективны без обучения на больших наборах данных. Это делает их полезными в ситуациях, где обучение невозможно или затруднительно. Кроме того, их легко интерпретировать, потому что они основаны на четких математических принципах.

К недостаткам можно отнести то, что настройка параметров классических методов может быть трудоемкой задачей и требует экспертных знаний для достижения хороших результатов. Классические методы чувствительны к изменениям в условиях съемки. Их производительность может снижаться в сложных сценариях. В связи с этим в последнее время приобретают популярность методы машинного и глубокого обучения.

## **1.5 Современные модели и методы глубокого обучения в медицине**

Глубокое обучение и нейронные сети произвели революцию в области распознавания изображений, обеспечивая значительные улучшения в точности и эффективности по сравнению с классическими методами [75].

Методы глубокого обучения продемонстрировали большой потенциал в повышении качества медицинской помощи и результативности лечения пациентов.

В сфере медицинской визуализации технологии глубокого обучения показали значительный потенциал для улучшения качества медицинского обслуживания и результативности лечения пациентов. Автоматизируя анализ медицинских изображений, такие алгоритмы могут способствовать раннему обнаружению заболеваний, оптимизации клинических процессов и снижению нагрузки на врачей. Кроме того, глубокое обучение также важно для проверки точности представленных медицинских данных. Например, оно может использоваться для выявления аномалий или несоответствий в данных, что обеспечивает надежность информации, которая применяется для диагностики или разработки плана лечения. Модели глубокого обучения также могут помочь в определении подлинности медицинских изображений, что особенно важно в условиях современного цифрового века, когда обработка данных становится все более сложной задачей [76].

Основные методы и архитектуры, используемые в этой области, приведены на рисунке 1.4.



Рисунок 1.4 – Методы глубокого обучения в распознавании изображений

Как видно из рисунка 1.4, существует множество подходов по распознаванию и классификации визуальной информации, однако основными являются сверточные нейронные сети (CNN), которые эффективно обрабатывают изображения благодаря своей архитектуре. Сверточная нейронная сеть является одним из наиболее широко используемых методов в области анализа и распознавания медицинских изображений.

Преимущество глубокого обучения, особенно глубоких сверточных сетей, заключается в том, что функция ручного сбора данных может быть заменена эффективными алгоритмами неконтролируемого или полуконтролируемого обучения признаков и иерархического извлечения признаков [75].

МРТ исследования в сочетании с моделями глубокого обучения показали достаточно высокую точность в правильном обнаружении разрыва мениска. Существует достаточное количество исследований, посвящённых автоматической диагностике разрывов мениска на основе МРТ-изображений, в которых применяются различные современные модели обнаружения объектов, а также их ансамбли.

В исследовании [77] авторы провели оценку эффективности современных моделей глубокого обучения, в частности YOLOv8 и EfficientNetV2, при обнаружении разрывов мениска с использованием относительно небольшого набора, 642 изображений МРТ. Для определения местоположения мениска использовался алгоритм глубокого обучения YOLO, а затем для обнаружения разрывов мениска использовалась архитектура глубокого обучения EfficientNetV2. Несмотря на относительно

небольшой набор исходных данных, модели, применяемые в данной работе, показали достаточно хорошие результаты.

В [78] для диагностики повреждений мениска предлагается использование каскадно-прогрессивной сверточной нейронной сети (C-PCNN), которая не только помогает в диагностике повреждений мениска, но и обеспечивает при этом визуализацию характеристик поражения. Для обучения и тестирования было использовано в общей сложности 1396 изображений МРТ. Метод, используемый для обучения и тестирования, представлял собой 5-кратную перекрестную проверку. C-PCNN показала точность 85,6% при диагностике и определении повреждения переднего рога и точность 92% при диагностике и определении повреждения заднего рога. Средняя точность C-PCNN составила 89,8%, AUC = 0,86.

Mangone и др. в своем исследовании [79] также представили модель машинного обучения на основе сверточных нейронных сетей (CNN). Данная модель используется не только для обнаружения разрывов мениска, но помимо этого также для обнаружения отека костного мозга и общих отклонений при обследованиях колена с помощью МРТ. Модель, предложенная в этой работе, была названа KNet и основана на CNN. Эффективность модели оценивается с точки зрения точности, чувствительности и специфичности. Исследуемые модели достигают максимальной точности 83,7%, максимальной чувствительности 82,2% и максимальной специфичности 87,99% для разрывов мениска.

Еще одна работа, в которой для обнаружения разрыва мениска применяется модель, разработанная на основе сверточной нейронной сети, представлена Shin и соавторами [80]. В этом исследовании модель, вместе с тем, что определяет наличие повреждения мениска, классифицирует их по типам. Также как и в [79,83] авторы использовали небольшой набор данных, который составил 1048 случаев МРТ исследований коленного сустава. Для оценки наличия разрывов мениска были использованы все собранные изображения МРТ колена. Для оценки типа разрыва мениска были использованы 538 случаев с разрывами мениска и 449 случаев без разрывов мениска.

Полностью автоматическую трехмерную глубокую сверточную нейронную сеть (DCNN) для сегментации мениска и обнаружения артроскопически подтвержденных разрывов мениска представили в своем исследовании Li и соавторы [81]. Набор данных в исследовании включал мениски, диагностированные артроскопически и просканированные с помощью МРТ. Результаты обнаружения разрыва мениска на изображениях МРТ, полученные при помощи разработанной модели, сравнивались с результатами артроскопии. Модель показала точность Dice 0,924, чувствительность 0,95, что является достаточно хорошим результатом.

В работе [82] описано создание прогрессивно работающих моделей глубокого обучения, обнаруживающих травмы мениска, разрывы передней крестообразной связки (ПКС) и аномалии колена при магнитно-резонансной томографии. Исследование проведено в три этапа. На первом этапе

выбирались изображения, подходящие для определения заболевания. Для этого использовалась модель 50-слойных остаточных сетей (ResNet50). Вторая часть исследования включает определение области, на которой следует сосредоточиться. На этом этапе была построена новая модель, построенная путем интеграции сверточных нейронных сетей (CNN). Третий этап исследования посвящен диагностике заболевания. В этой части исследования новая модель ResNet50 обучается определять диагнозы заболеваний или отклонения от нормы, независимо от модели ResNet50, используемой на первом этапе. Изображения, которые каждая модель выбирает в качестве выходных данных после обучения, называются прогрессивно действующими методами глубокого обучения, поскольку они предоставляются в качестве входных данных для следующей модели.

Обнаружение повреждений мениска коленного сустава с помощью магистральных сверточных сетей на изображениях МРТ предлагают в своем исследовании Hung и др. [83]. В этом исследовании было использовано в общей сложности 584 исследования МРТ колена. Открытый набор данных MRNet использовался в качестве набора данных для проверки и оценки производительности модели. Архитектура модели обнаружения разрыва мениска была основана на улучшенной модели YOLOv4 с Darknet-53 в качестве основы. Общая точность обнаружения разрывов мениска с использованием данной модели на наборах данных внутреннего тестирования, внутренней проверки и внешней проверки составила 95,4%, 95,8% и 78,8% соответственно.

Методы глубокого обучения часто обеспечивают высокую точность распознавания образов, особенно когда имеется доступ к большим объемам данных для обучения. Они могут быть адаптированы к различным задачам распознавания образов: сегментацию, классификацию, детекцию объектов. Сверточные нейронные сети способны автоматически извлекать сложные признаки из изображений. Это делает их эффективными в распознавании объектов с разнообразными текстурными и геометрическими характеристиками.

К недостаткам методов глубокого обучения можно отнести то, что для достижения высокой точности нейросети требуют большого количества данных для обучения, что может быть ограничивающим фактором в случае ограниченной доступности данных. Обучение и работа с нейросетями требует значительных вычислительных ресурсов и специализированных аппаратных ускорителей. Неправильно подобранные данные могут привести к переобучению или низкой производительности нейросетей.

В последние годы для обработки и анализа изображений все более активно применяются модели глубокого обучения на основе сверточных и трансформерных архитектур.

## 1.6 Сравнительный обзор свёрточных и трансформерных архитектур нейронных сетей в задачах анализа медицинских изображений

Диагностика повреждений мениска коленного сустава по данным магнитно-резонансной томографии (МРТ) остаётся сложной задачей, особенно при слабо выраженных признаках разрыва, схожих с нормальными анатомическими структурами. Несмотря на высокую информативность МРТ, интерпретация изображений требует опыта и значительных временных затрат, а межэкспертная вариативность может достигать существенных значений [84, 85]. Это обуславливает возрастающий интерес к внедрению алгоритмов глубокого обучения для автоматизации анализа МРТ-снимков.

Наиболее перспективными являются архитектуры, способные не только классифицировать наличие повреждений, но и точно локализовать их на изображении. Среди них особое внимание привлекают модели на основе свёрточных нейронных сетей (CNN), такие как YOLO, успешно применяющиеся в задачах диагностики ортопедических патологий, включая менисковые разрывы [86, 87]. Более современные трансформерные архитектуры, представленные семейством DETR, показывают высокий потенциал в обработке сложных и визуально неоднородных медицинских изображений [88–90]. Эти два подхода демонстрируют различия в стратегии извлечения признаков, что может влиять на точность и устойчивость в задачах с клиническим шумом и слабо выраженными изменениями.

Существующие исследования преимущественно сосредоточены либо на классификации изображений с использованием CNN [84–86], либо на экспериментальном применении трансформеров в задачах медицинской сегментации [87–89].

Применение глубокого обучения для анализа МРТ-изображений коленного сустава с целью выявления повреждений мениска, активно развивается. Первоначально доминировали методы на основе свёрточных нейронных сетей (CNN), направленные на классификацию наличия патологии без локализации. Например, использовались модели ResNet и EfficientNet, которые демонстрировали высокие показатели точности в задачах бинарной и трёхклассовой классификации [20, 91, 92]. Однако такие подходы зачастую не позволяли точно определить расположение повреждения и не обеспечивали интерпретируемости результатов.

С появлением моделей объектного детектирования в медицинской визуализации появились решения, позволяющие проводить как классификацию, так и локализацию. В частности, модели семейства YOLO, включая YOLOv3 и YOLOv4, успешно применялись для автоматического обнаружения разрывов мениска, обеспечивая более точную привязку к анатомической структуре [93, 94]. Однако многие из этих исследований использовали ограниченные датасеты, и редко проводилось сравнение разных архитектур при одинаковых условиях.

Более современные трансформерные модели, включая DETR и его производные, нашли применение в задачах медицинского анализа

изображений, особенно там, где требуется работа с разреженными или слабо выраженным структурами [95–97]. В таких работах трансформеры демонстрируют потенциал в обработке сложных визуальных паттернов и неоднородных данных. Однако их использование в контексте диагностики менисковых повреждений остаётся ограниченным, а сравнение с CNN–моделями на одном и том же датасете практически не встречается.

Проведение прямого сравнения семейств современных моделей, таких как YOLO и RT–DETR, в условиях реальных клинических МРТ–изображений остаётся актуальной исследовательской задачей. Настоящее исследование восполняет этот пробел, предлагая количественное и качественное сравнение моделей на едином датасете, аннотированном экспертами, и отражающем реальную клиническую вариативность МРТ–изображений. В рамках настоящего исследования была проведена сравнительная оценка эффективности моделей семейств YOLO и RT–DETR для автоматического распознавания и локализации разрывов мениска на МРТ–снимках коленного сустава.

Дадим краткую характеристику свёрточных и трансформерных архитектур. CNN–архитектуры основаны на локальных свёрточных фильтрах, иерархической агрегации признаков и сильных индуктивных предположениях о переводимой локальности структуры изображений. Это делает CNN устойчивыми при небольших наборах данных, эффективными в вычислениях и относительно простыми для внедрения [76]. Трансформерные архитектуры напрямую моделируют глобальные взаимосвязи пикселей/участков изображения, что позволяет улучшить работу с разреженными или контекстно распределенными признаками. DETR–архитектуры представляют задачу обнаружения, как множественное предсказание набора, тем самым исключая необходимость в сложных пост–обработках [98].

Далее в таблице 1.3 приведен сравнительный анализ свёрточных и трансформерных архитектур по ключевым критериям.

Таблица 1.3 – Сравнение свёрточных и трансформерных архитектур по ключевым критериям

Критерий	CNN	Трансформеры	Примечание
1	2	3	4
<b>Качество извлечения признаков и локализация</b>	Хорошо извлекают локальные текстурно–морфологические признаки, что особо важно при работе с МРТ изображениями, где важны края и локальные контрасты	Представляют преимущества при необходимости моделирования долгих диапазонов зависимостей (например, при обнаружении пространственно разнесённых признаков). На практике их способность точно локализовать мелкие	В ряде обзоров и прикладных работ отмечается, что гибридные конфигурации (CNN + attention / DETR с CNN–backbone) дают наилучший компромисс

		объекты улучшились только после включения свёрточных компонентов и многомасштабных блоков	
<b>Чувствительность к объёму и гетерогенности данных</b>	Благодаря индуктивным bias часто демонстрируют более быструю конвергенцию и лучшую общую производительность на умеренных выборках	Требуют значительно больших объёмов данных или тщательно подобранных схем регуляризации/ аугментации	В медицинских данных, собранных в многоцентровом режиме (разные МРТ-установки, протоколы), это ограничение трансформеров особенно заметно [99]
<b>Устойчивость к шуму и вариативности сканов</b>	Демонстрируют большую устойчивость к локальным артефактам и небольшим искажениям	Проявляют лучшую способность улавливать глобальные контекстуальные сигналы, что даёт преимущество при сложных, распределённых патологических картинах, но требует строгой нормализации и предобработки входных данных	Практические работы показывают, что комбинированные подходы (предобработка + CNN-фици + attention) повышают стабильность выводов [100]
<b>Вычислительные требования и время обработки</b>	Ориентированы на real-time применение и легче интегрируются в рабочие процессы	Требовательны к памяти и времени обучения; это критично для практических клинических систем, где необходим баланс между скоростью и качеством	Для задач, ориентированных на оперативную поддержку принятия решений, время отклика остаётся важным фактором
<b>Интерпретируемость и верифицируемость</b>	CNN-модели легче поддаются классическим методам интерпретации, что облегчает клиническую валидацию	Трансформеры также допускают интерпретацию через карты внимания, но практическая интерпретируемость attention-весов в клиническом контексте ещё требует стандартизации и доказательной валидации	Модель должна быть не только точной, но и объяснимой для врачей-диагностов

Примечание – Составлено по источникам [76, 99, 100, ]

## Выводы по первому разделу

В данном разделе были изучены медицинские аспекты диагностики повреждений менисков коленного сустава, были определены основные типы повреждений менисков.

В результате анализа современной научной литературы, клинических исследований и цифровых технологий было установлено, что МРТ является

наиболее информативным и безопасным методом диагностики мягкотканых структур коленного сустава. Преимуществами МРТ являются высокая пространственная и тканевая контрастность, неинвазивность, отсутствие лучевой нагрузки, а также возможность визуализации внутренних структур в различных плоскостях.

Однако результаты анализа литературы показали, что при всех своих достоинствах МРТ остаётся зависимой от человеческого фактора: опыт и квалификация врача-рентгенолога существенно влияют на достоверность диагностики. Отмечено, что интерпретация МРТ-снимков сопровождается высокой степенью субъективности, особенно в сложных случаях дегенеративно-дистрофических изменений и микроповреждений менисков. Кроме того, выявлены проблемы неоднородности изображений, возникающие из-за использования разных томографов, настроек и параметров сканирования. Это приводит к снижению качества данных и усложняет анализ изображений.

Проведённый анализ показал, что классические методы обработки и распознавания изображений, несмотря на их очевидные преимущества — такие как высокая скорость вычислений, отсутствие необходимости в обучающих выборках и прозрачность алгоритмической интерпретации — обладают ограниченной применимостью в условиях медицинской диагностики. Эти методы демонстрируют высокую эффективность при работе с простыми структурами и однородными текстурами, однако становятся менее надёжными при анализе сложных изображений, содержащих шумы, артефакты и вариативность интенсивностей, характерные для МРТ.

По результатам обзора современных технологий и средств обработки и анализа медицинских изображений установлено, что тенденция в мировой практике направлена на переход к автоматизированным и интеллектуальным системам анализа медицинских изображений. Ведущие направления исследований сосредоточены на применении искусственного интеллекта и глубокого обучения для поддержки принятия врачебных решений.

## 2 МЕТОДЫ И МОДЕЛИ ДИАГНОСТИРОВАНИЯ ПОВРЕЖДЕНИЙ МЕНИСКОВ КОЛЕННОГО СУСТАВА

### 2.1 Описание исходных данных исследования

Для проведения исследования были использованы данные в виде МРТ снимков коленного сустава, собранные у пациентов со всех регионов страны в период с 2022 по 2024 гг. в отделении артроскопии и спортивной травмы Национального научного центра травматологии и ортопедии имени академика Н.Д. Батпенова города Астана. Исходный набор содержал МРТ данные 2242 пациентов в формате DICOM. Возрастной диапазон пациентов составлял от 11 до 75 лет. МРТ-снимки были получены при прохождении пациентами обследований в 84 центрах МРТ диагностики с использованием МРТ систем 1,5 Т или 3,0 Т. МРТ-исследования были выполнены на томографах различных производителей с использованием разных настроек протоколов сканирования, что обусловило различия в качестве полученных изображений, наблюдаются различия в разрешении, контрастности и размерах изображений. Каждое МРТ-исследование представляет собой серию последовательных томографических срезов, полученных в трех взаимно перпендикулярных проекциях: аксиальной, коронарной, сагиттальной.

На рисунке 2.1 представлены томографические срезы коленного сустава, полученные в трех основных проекциях.

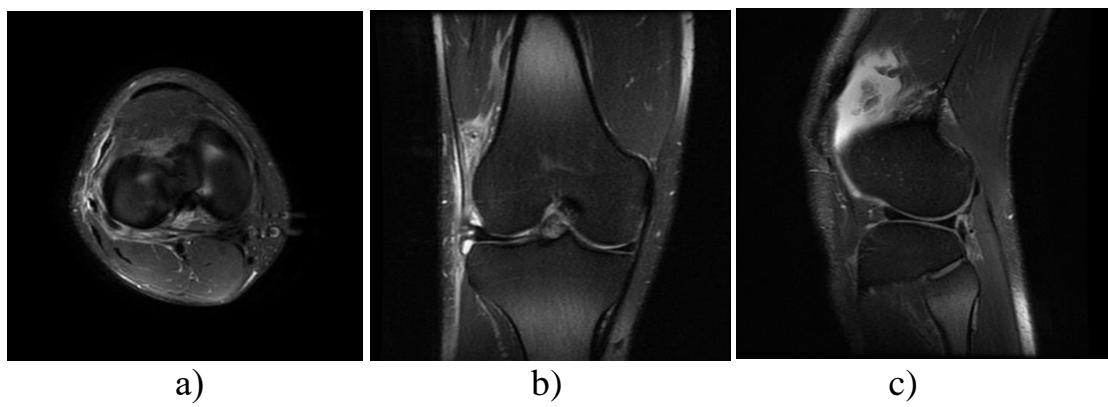


Рисунок 2.1 – Примеры МРТ изображений коленного сустава: а) в аксиальной проекции; б) в коронарной проекции; в) в сагиттальной проекции

Изображения, полученные в результате магнитно-резонансной томографии, отражают состояние связочного аппарата, капсулы, менисков, кровеносных сосудов и нервных волокон. МРТ дает возможность изучить все анатомические составляющие коленного сустава, но в рамках данного исследования интерес представляют мениски, в частности их повреждения и диагностика.

## 2.2 Общая методологическая концепция диагностирования повреждений менисков коленного сустава

В последние годы область медицины претерпевает значительные изменения благодаря внедрению новых технологий, среди которых особое место занимают магнитно-резонансная томография и искусственный интеллект. МРТ, как метод визуализации, предоставляет детальные изображения органов и тканей, что позволяет врачам ставить точные диагнозы и планировать лечение. В сочетании с ИИ, данный метод становится ещё более эффективным.

Как уже было отмечено ранее, МРТ технологии широко применяются в диагностике патологий коленного сустава, в частности повреждений мениска, благодаря высоким показателям чувствительности и специфичности. Также уже было отмечено, что главная проблема, состоит в недостаточной достоверности метода, которая в значительной мере зависит от компетентности врача-диагноста и сопутствующих операционных артефактов. Для повышения достоверности (точности) процесса диагностирования разрабатывается большое количество инструментальных средств, математических методов обработки изображений МРТ и соответствующих программных средств, об этом упоминалось в первом разделе работы.

В рамках данного исследования реализованы два подхода в диагностировании повреждений менисков коленного сустава с применением МРТ технологии (рисунок 2.2).



Рисунок 2.2 – Основные подходы в диагностировании повреждений менисков коленного сустава

Первый подход основан на методе текстурной диагностики, который заключается в информационно-текстурной трансформации изображений. Второй подход реализован на основе методов глубокого обучения, с

применением современных моделей семейства YOLO и RT-DETR. Оба подхода направлены на решение одной задачи — повышение достоверности диагностики повреждений менисков при МРТ, но основаны на принципиально разных концепциях обработки данных.

### **2.3 Разработка метода текстурной диагностики повреждений менисков коленного сустава**

В данном исследовании метод текстурной диагностики основан на информационно-текстурной трансформации медицинских изображений, предполагающей переход от визуально-аналогового представления МРТ-срезов к их формализованной цифровой интерпретации.

Основная идея метода заключается в том, что каждый МРТ-срез рассматривается как матрица интенсивностей пикселей, которая содержит скрытую структурную информацию о неоднородностях тканей. В рамках метода производится формирование векторов строк и столбцов и их графо-аналитическая обработка.

Текстурный анализ позволяет выделить скрытые статистические и структурные закономерности, которые не всегда доступны при визуальном осмотре МРТ-снимков, но имеют диагностическую значимость для дифференциации нормальных и патологических тканей. Текстура представляет собой пространственное распределение интенсивностей серого уровня в пределах изображения и описывает микроструктурные особенности тканей. При патологии мениска (например, при разрывах или дегенеративных изменениях) текстурные характеристики изображения изменяются — увеличивается энтропия, снижается однородность, появляются направленные или хаотичные градиенты интенсивности. Эти изменения могут быть количественно измерены и использованы для классификации состояния ткани.

На рисунке 2.3 представлены этапы реализации метода текстурной диагностики:

- 1) получение изображения;
- 2) представление изображения в виде двумерного массива;
- 3) нормализация;
- 4) представление векторной дисперсии в горизонтальном и вертикальном измерении (векторная интерпретация);
- 5) графо-аналитическая обработка.



Рисунок 2.3 – Схема метода текстурной диагностики патологий мениска

Данный подход можно рассматривать как детерминированно-аналитический, т.к. он опирается на явно вычисляемые признаки и не требует предварительного обучения на больших выборках данных. Он особенно полезен при малом объёме данных и предоставляет возможность интерпретации результатов, что очень важно в медицинских исследованиях.

После того, как получено изображение, оно преобразуется в двумерный массив. МРТ изображение, которое является рабочим диагностическим материалом в данном исследовании, представляет пиксельную матрицу в черно-белом формате. На рисунке 2.4 приведен пример подобного изображения. Данное изображение в количественном формате представляет двумерный массив (вектор) из  $n$  строк и  $m$  столбцов. Физически каждое число в массиве является пикселеем, в котором хранится число эквивалентное световой интенсивности («энергетическим всплеском») радио-частотного импульса. Компьютерная программа преобразует эти всплески в 2D черно-белое изображение. МРТ технология представляет монохромные снимки анатомической среды в аксиальной, сагиттальной и коронарной плоскостях.



Рисунок 2.4 – МРТ изображение – оригинал

Рисунок 2.4 представляет исходное цифровое изображение – информационный массив (оригинал) одного МРТ среза –  $X$  ( $n, m$ ):  $X$  – имя массива;  $n$  – количество строк в массиве;  $m$  – количество столбцов в массиве. Главное требование и проблема при расшифровке МРТ среза коленного сустава, состоит в компетенции врача, который должен – «в совершенстве владеть знаниями анатомии сочленения и хорошо разбираться в особенностях МР-картины различных заболеваний». Данный массив является двумерным вектором, который имеет следующий информационный формат (рис. 2.5). На рисунке:  $x_{n,m}$  – элемент  $n$  – й строки,  $m$  – го столбца массива  $X()$ .

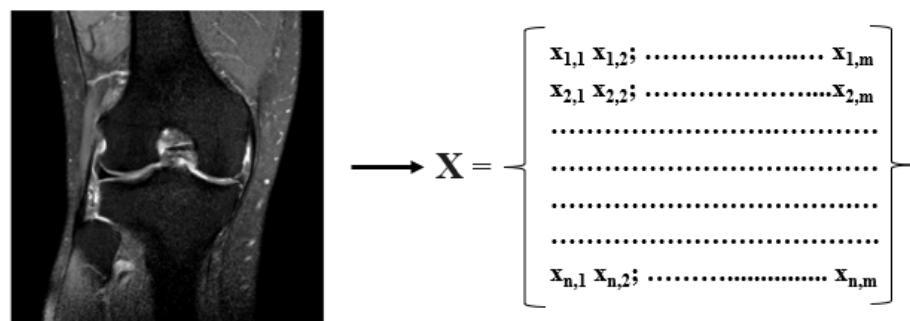


Рисунок 2.5 – Условный информационный срез МРТ изображения коленного сустава в формате двумерного массива

В массиве  $X$  элемент  $x_{n,m}$  является энергетической количественной оценкой пикселя  $n$  – строки  $m$  – го столбца. Как показывает практика, снимки должен читать опытный врач – рентгенолог, и он ставит окончательное решение. Главное условие состоит в том, что расшифровка МРТ изображения (текстурный анализ) – «не является диагнозом», а служит дополнительной информацией для лечащего врача. Негативным фактором в

данной ситуации является то, что отсутствует «эталон здорового» коленного сустава именно этого конкретного пациента в МРТ формате, так как человек обращается к врачу только после заболевания колена, с уже пораженной костно-биологической средой [101].

Практика показала, что интенсивность излучения, количественно зарегистрированного и исследуемого сигнала в пикселе, в значительной степени зависит от структуры, температуры окружающей атмосферы и качества текстурируемой ткани, содержания воды в мягких тканях коленного сустава, таких как хрящей, связок, мышц, суставных капсул. Для градации компьютерных изображений по степени плотности ткани используется шкала Хаунсфилда Г., которая графически иллюстрируется рисунком 2.6 [102].

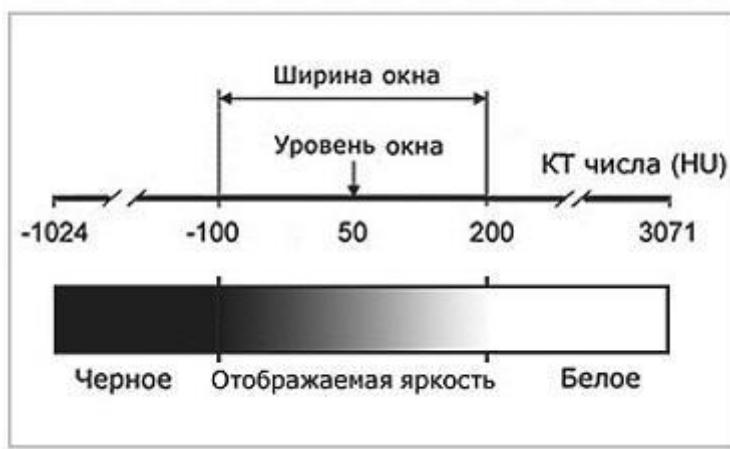


Рисунок 2.6 – Оценка окна визуализации МРТ по Хаунсфилду

Примечание – Составлено согласно источника [102]

В предлагаемом исследовании считается, что в случае повреждения или деструкции участков в структуре мягких тканей, происходят изменения в энергетической картине на срезах МРТ изображения, что можно визуально зарегистрировать и считать их диагностическими признаками. Задачами исследования на данном этапе являются выявление диагностических признаков, повышение качества их визуализации и информационно-аналитической устойчивости в контрольно-измерительной среде путем математической или операционной технологической обработки МРТ изображения [103].

В настоящее время работ по изучению и решению проблемы, под общим названием – текстурный анализ, опубликовано достаточно большое количество. Среди публикаций на эту тему, можно выделить следующие методологические направления: методы математического моделирования на базе разделов математической статистики; формальные методы принятия решений; нейросетевые подходы на базе прецедентного анализа. Нейросетевые диагностические системы находятся в настоящее время на начальной стадии своего изучения и практического применения, как и вся

МРТ предметная область, и требуют огромного статистического материала, как по объему, так и по прецедентной метрологической истории.

В данной работе предлагаются новые информационно–аналитические подходы и формально–технологические процедуры в текстурном анализе, имеющие не только формализованный формат, но и технологическое качественное содержание.

Реализация новых предлагаемых формально–методических подходов для решения задач, обозначенной предметной области, предусматривается в следующем поэтапном порядке.

После преобразования изображения в двумерный массив осуществляется «нормализация» (нормирование) массива  $\mathbf{X}$  (рисунок 2.5). Для нормирования по строкам находятся максимальные значения в каждой  $i$  исходной матрицы  $\mathbf{X}$ :

$$Max_i = \max_j(x_{i,j}) \quad (2.1)$$

После этого каждый элемент  $x_{i,j}$  делится на максимальное значение этой строки  $Max_i$ :

$$x_{1i,j} = \frac{x_{i,j}}{Max_i} \quad (2.2)$$

Получается массив построчного нормирования (2.3):

$$\mathbf{X}_1 = \begin{pmatrix} x_{11,1} & x_{11,2} & \dots & x_{11,m} \\ x_{12,1} & x_{12,2} & \dots & x_{12,m} \\ x_{13,1} & x_{13,2} & \dots & x_{13,m} \\ \vdots & \vdots & \ddots & \vdots \\ x_{1n,1} & x_{1n,2} & \dots & x_{1n,m} \end{pmatrix} \quad (2.3)$$

Аналогично находим максимальный элемент, для каждого столбца  $j$ :

$$Max_j = \max_i(x_{i,j}) \quad (2.4)$$

Каждый элемент  $x_{i,j}$  делится на максимальное значение соответствующего столбца  $Max_j$  (2.5):

$$x_{2i,j} = \frac{x_{i,j}}{Max_j} \quad (2.5)$$

Получается массив постолбцовного нормирования (2.6):

$$X_2 = \begin{pmatrix} x_{21,1} & x_{21,2} & \dots & x_{21,m} \\ x_{22,1} & x_{22,2} & \dots & x_{22,m} \\ x_{23,1} & x_{23,2} & \dots & x_{23,m} \\ \vdots & \vdots & \ddots & \vdots \\ x_{2n,1} & x_{2n,2} & \dots & x_{2n,m} \end{pmatrix} \quad (2.6)$$

После нормализации визуализируем полученные матрицы. На рисунках 2.7, 2.8 показаны результаты нормализации по строкам и столбцам.

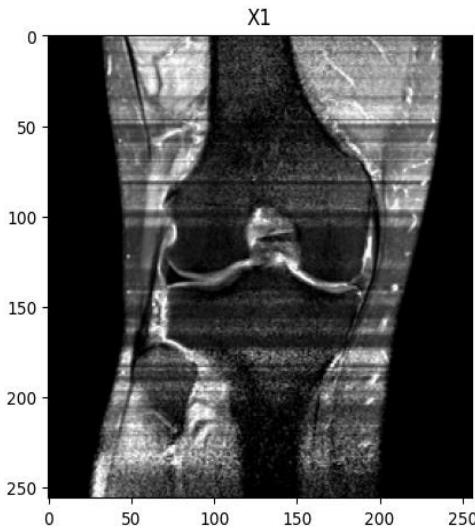


Рисунок 2.7 – Нормализация по строкам

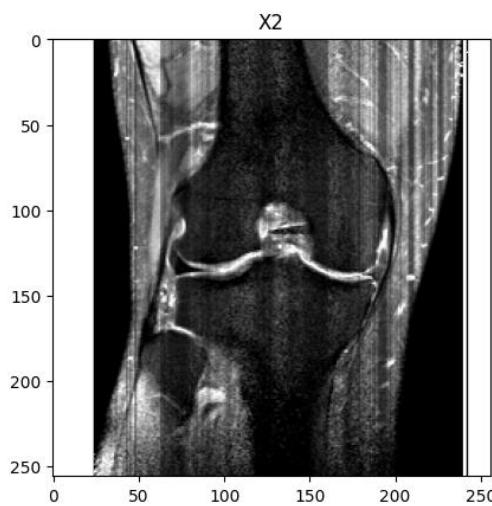


Рисунок 2.8 – Нормализация по столбцам

На следующем этапе исследования выдвигается рабочая гипотеза, состоящая в том, что если численные значения яркости пикселя являются точечным количественным эквивалентом энергии радиоизлучения и поглощения в мягких тканях колена в определенной 3D координате внесуставной среды, то сумма всех численных пиксельных оценок по всей

строке среза изображения будет являться условным диагностическим энергетическим количественным признаком, корреляционно связанным с состоянием материи коленного сустава по заданной строчной линейной траектории. Следуя данной гипотезе, находится сумма нормированных строк массива  $X_1$  и формируются следующие показатели (2.7):

Формируем одномерный вектор  $\mathbf{A}$  ( $n \times 1$ ), координатами которого являются построчные суммы пиксельной составляющей нормированных строк массива  $\mathbf{X}_1$  (2.8):

$$\mathbf{A} = \begin{pmatrix} A_1 \\ A_2 \\ \dots \\ A_n \end{pmatrix}. \quad (2.8)$$

Эта процедура осуществляется также с массивом  $X_2$  и формируются показатели  $B_i$  по столбцам массива  $X_2$  (2.9):

Формируем одномерный вектор  $\mathbf{B}$  ( $1 \times m$ ), координатами которого являются постолбцовые суммы пиксельной составляющей нормированных столбцов массива  $\mathbf{X}_2$  (2.10):

$$B = (B_1, B_2, \dots, B_m). \quad (2.10)$$

Векторы **А** и **В** гипотетически могут быть использованы в качестве визуальной диагностической информации. Для проверки выдвинутой гипотезы были построены эмпирические графики  $f(\mathbf{A})$  и  $f(\mathbf{B})$ , представленные на рисунках 2.9, 2.10. Из визуального анализа рисунков следует, что мягкая ткань коленного сустава по вертикальному вектору крайне неоднородна, врачу-диагносту следует сконцентрировать внимание в этом направлении. Детализировать процесс изучения выделенной области интереса в нижней области коленного сустава можно путем изучения пиксельной динамики по отдельно выбранным строкам. Эту неоднородность при информационно-энергетическом подходе можно представить векторной дисперсией в горизонтальном (строковом) измерении пиксельной энергии  $A()$ , и вертикальном столбцовом измерении  $B()$ . Динамику дисперсий векторов  $A()$ ,

В() рекомендуется изучать также при диагностировании в графическом 2D формате.

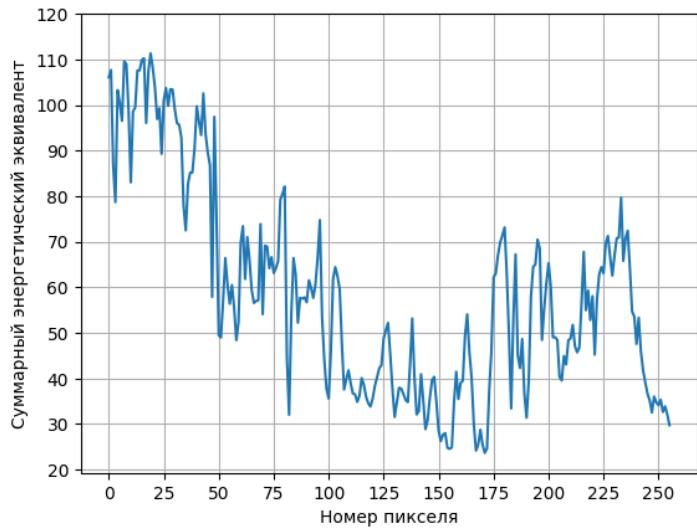


Рисунок 2.9 – Графическая иллюстрация численных значений пиксельных энергетических эквивалентов строк МРТ изображения

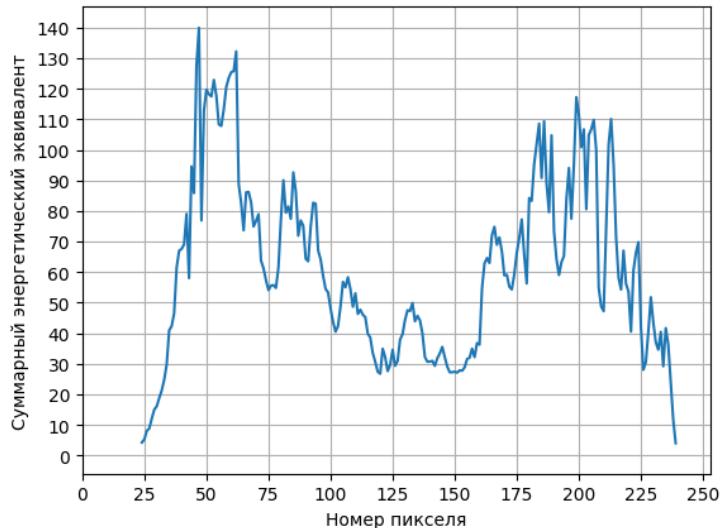


Рисунок 2.10 – Графическая иллюстрация численных значений пиксельных энергетических эквивалентов столбцов МРТ изображения

На рисунках 2.9 и 2.10 приведена графическая динамика пиксельных данных по отдельно выбранным строкам и столбцам. Согласно сделанным выводам, наибольший диагностический интерес представляет строковая информация. На этом основании предлагается – на ранней стадии диагностирования предоставить врачу возможность выделения отдельных

строк с целью анализа пиксельной динамики, что позволит сократить область визуального анализа 2D среза.

Дальнейшее повышение качества текстурной диагностики предлагается искать в графо-аналитических подходах, состоящих из трех версий.

Первая версия. Данная версия опирается на количественное представление пиксельного информационно-энергетического поля среза МРТ коленного сустава в строчно-столбцовой мультипликации. В данной версии используются мультипликативные свойства нелинейной динамики при их комбинациях в форме произведений  $A_i \cdot B_j$  [95].

Тогда информационная пиксельная матрица среза МРТ коленного сустава в количественном 2D формате может быть сформирована как внешнее произведение векторов  $\mathbf{A}$  и  $\mathbf{B}$  (2.11):

$$P_{i,j} = A_i \cdot B_j \quad (2.11)$$

или в матричном виде количественный формат пиксельного информационно-энергетического поля среза МРТ коленного сустава (2.12):

$$\mathbf{P} = \mathbf{A} \mathbf{B} = \begin{pmatrix} A_1 \cdot B_1 & A_1 \cdot B_2 & \dots & A_1 \cdot B_m \\ A_2 \cdot B_1 & A_2 \cdot B_2 & \dots & A_2 \cdot B_m \\ A_3 \cdot B_1 & A_3 \cdot B_2 & \dots & A_3 \cdot B_m \\ \vdots & \vdots & \ddots & \vdots \\ A_n \cdot B_1 & A_n \cdot B_2 & \dots & A_n \cdot B_m \end{pmatrix} \quad (2.12)$$

Вторая версия. Данная версия оформлена как численно – пиксельное представление информационно-энергетического поля в векторной интерпретации среза МРТ коленного сустава в строково-столбцовой мультипликации на основе Евклидовой нормы элементов векторов  $\mathbf{A}$  и  $\mathbf{B}$  вида (2.13).

$$W_{i,j} = \sqrt{A_i^2 + B_j^2} \quad (2.13)$$

Тогда информационная матрица среза МРТ коленного сустава в количественном 2D формате будет иметь следующий вид (2.14):

$$W = \begin{pmatrix} \sqrt{A_1^2 + B_1^2} & \sqrt{A_1^2 + B_2^2} & \dots & \sqrt{A_1^2 + B_m^2} \\ \sqrt{A_2^2 + B_1^2} & \sqrt{A_2^2 + B_2^2} & \dots & \sqrt{A_2^2 + B_m^2} \\ \sqrt{A_3^2 + B_1^2} & \sqrt{A_3^2 + B_2^2} & \dots & \sqrt{A_3^2 + B_m^2} \\ \vdots & \vdots & \ddots & \vdots \\ \sqrt{A_n^2 + B_1^2} & \sqrt{A_n^2 + B_2^2} & \dots & \sqrt{A_n^2 + B_m^2} \end{pmatrix} \quad (2.14)$$

или пиксельная информационно-энергетическая матрица, как геометрическая сумма векторов  $\mathbf{A}$  и  $\mathbf{B}$  равна (2.15).

$$\mathbf{W} = \begin{pmatrix} W_{1,1} & W_{1,2} & \dots & W_{1,m} \\ W_{2,1} & W_{2,2} & \dots & W_{2,m} \\ W_{3,1} & W_{3,2} & \dots & W_{3,m} \\ \vdots & \vdots & \ddots & \vdots \\ W_{n,1} & W_{n,2} & \dots & W_{n,m} \end{pmatrix} \quad (2.15)$$

Третья версия. Доказано, что в случае местного поражения мягкой ткани колена, физическое изменение плотности или иного параметра мягкой ткани суставной материи, регистрируемое в строке и каждом пикселе, будет изменяться с определенной динамикой от одной границы изображения (начало строки) до противоположной границы (конца строки) [104]. Тогда численные значения двух соседних пикселей (межпиксельная дифференциация уровней сигнала) будут отличаться на величину приращений, и МРТ изображение будет представлено не в абсолютных пиксельных форматах, а в межпиксельных разностях. Предлагаемая методическая процедура селекции информативной динамики решает одну из задач фильтрации аддитивных шумов и помех, присутствующих в каждом пикселе. Данная процедура представляет собой реализацию дифференциального фильтра (оператора конечных разностей) на матрице интенсивности  $\mathbf{X}$ . Целью является получение карты локальных градиентов интенсивности, что позволит подавить аддитивный фон и шум и выделить только резкие изменения, связанные с границами тканей и патологическими очагами ( $\Delta S$ ).

В любой точке изображения регистрируемое значение пикселя  $x_i$  состоит из полезного сигнала  $S_i$  и случайной аддитивной помехи  $Z_i$ . Если есть патология или граница ткани, то сигнал имеет приращение  $\Delta S$ . Математическая модель соседних пикселей (2.16):

$$\begin{aligned} X_i &= S_i + Z, \\ X_{i+1} &= S_i + \Delta S + Z, \end{aligned} \quad (2.16)$$

где  $X_i$  и  $X_{i+1}$  – соседние пиксели в строке или столбце;  $Z$  – некоррелированный аддитивный шум;  $\Delta S$  – информационно полезное приращение, связанное с патологией.

При вычитании значений между соседними пикселями ( $X_{i+1} - X_i$ ) шум  $Z$  взаимно компенсируется (2.17):

$$X_{i+1} - X_i = (S_i + \Delta S + Z) - (S_i + Z) = \Delta S \quad (2.17)$$

Таким образом, в пикселе строки останется только информационно полезное приращение  $\Delta S$  (градиент), что обеспечивает эффективное подавление фоновых и шумовых составляющих. Оно может нарастать по мере движения по строке до очага поражения в суставе, затем начнет опадать по мере движения до конца строки. Место изменения знака динамики приращения  $\Delta S$  может быть информацией о центре суставного очага деструкции.

Для определения горизонтального градиента интенсивности строим матрицу  $\mathbf{Y}$  (размерность  $n \times (m - 1)$ ). Каждый элемент  $y_{i,j}$  вычисляется как разность между соседним правым и текущим пикселям той же строки  $i$  (2.18):

$$y_{i,j} = x_{i,j+1} - x_{i,j} \quad (2.18)$$

Матрица  $\mathbf{Y}$  преобразованная из МРТ изображения оригинала  $\mathbf{X}$  по строковой межпиксельной динамике:

$$\mathbf{Y} = \begin{pmatrix} x_{1,2} - x_{1,1} & x_{1,3} - x_{1,2} & \dots & x_{1,m} - x_{1,m-1} \\ x_{2,2} - x_{2,1} & x_{2,3} - x_{2,2} & \dots & x_{2,m} - x_{2,m-1} \\ x_{3,2} - x_{3,1} & x_{3,3} - x_{3,2} & \dots & x_{3,m} - x_{3,m-1} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n,2} - x_{n,1} & x_{n,3} - x_{n,2} & \dots & x_{n,m} - x_{n,m-1} \end{pmatrix}, \quad (2.19)$$

или

$$\mathbf{Y} = \begin{pmatrix} y_{1,1} & y_{1,2} & \dots & y_{1,m-1} \\ y_{2,1} & y_{2,2} & \dots & y_{2,m-1} \\ y_{3,1} & y_{3,2} & \dots & y_{3,m-1} \\ \vdots & \vdots & \ddots & \vdots \\ y_{n,1} & y_{n,2} & \dots & y_{n,m-1} \end{pmatrix} \quad (2.20)$$

По аналогичному алгоритму строится  $\mathbf{V}$  – матрица «разность по столбцам». Матрица  $\mathbf{V}$  (размерность  $(n - 1) \times m$ ) отражает вертикальный градиент. Каждый элемент  $v_{i,j}$  вычисляется как разность между соседним нижним и текущим пикселям того же столбца  $j$ :

$$v_{i,j} = x_{i+1,j} - x_{i,j} \quad (2.21)$$

Матрица  $\mathbf{Y}$  преобразованная из МРТ изображения оригинала  $\mathbf{X}$  по строковой межпиксельной динамике (2.22):

$$V = \begin{pmatrix} x_{2,1} - x_{1,1} & x_{2,2} - x_{1,2} & \dots & x_{2,m} - x_{1,m} \\ x_{3,1} - x_{2,1} & x_{3,2} - x_{2,2} & \dots & x_{3,m} - x_{2,m} \\ x_{4,1} - x_{3,1} & x_{4,2} - x_{3,2} & \dots & x_{4,m} - x_{3,m} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n,1} - x_{n-1,1} & x_{n,2} - x_{n-1,2} & \dots & x_{n,m} - x_{n-1,m} \end{pmatrix}, \quad (2.22)$$

или

$$V = \begin{pmatrix} v_{1,1} & v_{1,2} & \dots & v_{1,m} \\ v_{2,1} & v_{2,2} & \dots & v_{2,m} \\ v_{3,1} & v_{3,2} & \dots & v_{3,m} \\ \vdots & \vdots & \ddots & \vdots \\ v_{n-1,1} & v_{n-1,2} & \dots & v_{n-1,m} \end{pmatrix} \quad (2.23)$$

После указанных операций динамического преобразования по строкам и столбцам, формируются три массива, представленных на рисунке 2.11, где матрица  $X$  – исходная матрица–оригинал; матрица  $Y$  – «разность по строкам»;  $V$  – матрица «разность по столбцам».

$$\begin{bmatrix} X \end{bmatrix} \quad \begin{bmatrix} Y \end{bmatrix} \quad \begin{bmatrix} V \end{bmatrix}$$

Рисунок 2.11 – Матрицы пиксельных динамических преобразований

Данные матрицы при сопоставлении с МРТ изображением по количественным отклонениям дают предварительную экспресс – информацию врачу о месте нахождении источника повреждения в мягкой среде колена.

Для реализации численного компьютерного эксперимента, предусматривается использовать существующие универсальные типовые программные средства и специально разработанные приложения.

Вопрос оценки информационной диагностической эффективности, предложенных версий, может быть решен в клинико–диагностической практике, по мере накопления больших объемов экспериментально – статистического материала.

Результаты обработки представлены на рисунке 2.12.

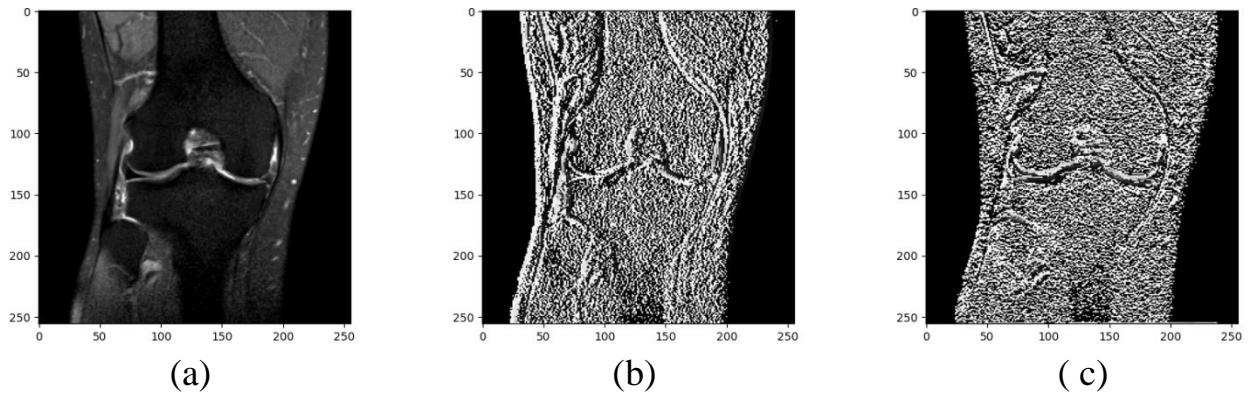


Рисунок 2.12 – Результаты обработки исходной информации: а) – исходная информация (оригинал); б) – разность по строкам; в) – разность по столбцам

Как следует из рисунка 2.12, изображение б (строковые разности), более четко обозначились в некоторых анатомических структурных границах коленного сустава по сравнению с оригиналом (а). Следует отметить, что шум на изображении или, как еще говорят, смещение в цифровом срезе уменьшилось.

Далее была проведена нормализация массивов  $Y$  и  $V$  по строкам и столбцам. В результате получили массивы  $Y_1$  и  $V_1$ , нормированные по строкам, а также массивы  $Y_2$  и  $V_2$ , нормированные по столбцам, которые представлены на рисунках 2.13 и 2.14.

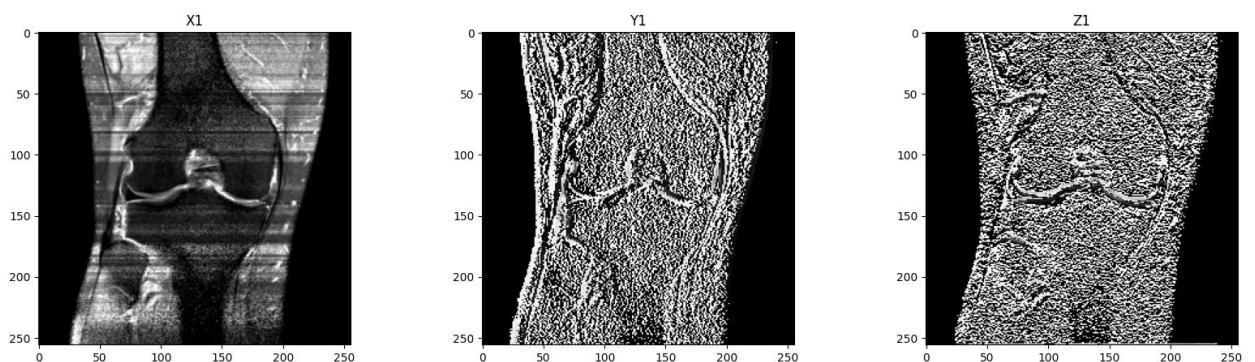


Рисунок 2.13 – Результаты нормализации по строкам

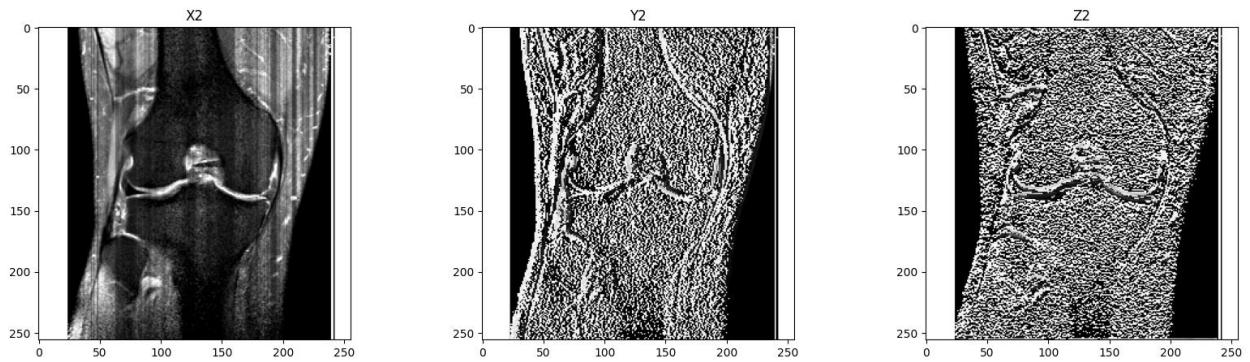


Рисунок 2.14 – Результаты нормализации по строкам

Рисунки 2.13 и 2.14 демонстрируют результаты нормализации массивов данных по строкам и по столбцам. Данная операция позволяет компенсировать неравномерность распределения яркости по изображению и усилить локальные особенности тканей. После нормализации становятся более выраженными границы менисков и прилегающих анатомических структур, что облегчает дальнейший анализ.

На рисунке 2.13 представлены результаты нормализации по строкам, в результате которой устраняется вертикальная неравномерность яркости и усиливаются горизонтально ориентированные элементы структуры.

На рисунке 2.14 представлены результаты нормализации по столбцам, позволяющие выявить вертикально ориентированные границы и повысить контраст в продольном направлении.

Сравнение нормализованных изображений показывает, что оба типа нормализации вносят важный вклад в выделение структур интереса:

- 1) нормализация по строкам подчёркивает продольные изменения интенсивности;
- 2) нормализация по столбцам делает более заметными поперечные вариации яркости.

В совокупности это обеспечивает более точное и информативное представление данных, подготавливая их к последующей корреляционной обработке и 3D-визуализации. Такое преобразование позволяет выявить динамику изменения плотностных характеристик по всей матрице изображения, что важно для интерпретации состояния мягкотканых структур коленного сустава.

Корреляционная обработка, при физической интерпретации результата, показала низкую корреляционную связь между суммами пиксельной строчной и столбцовой энергией, что наводит на идею представления количественных данных, представленных на МРТ срезе в 3D формате. Подобное представление позволит визуально оценить форму и динамику изменения данных по всей матрице (массиву). Результаты 3D изображений представлены на рисунке 2.15.

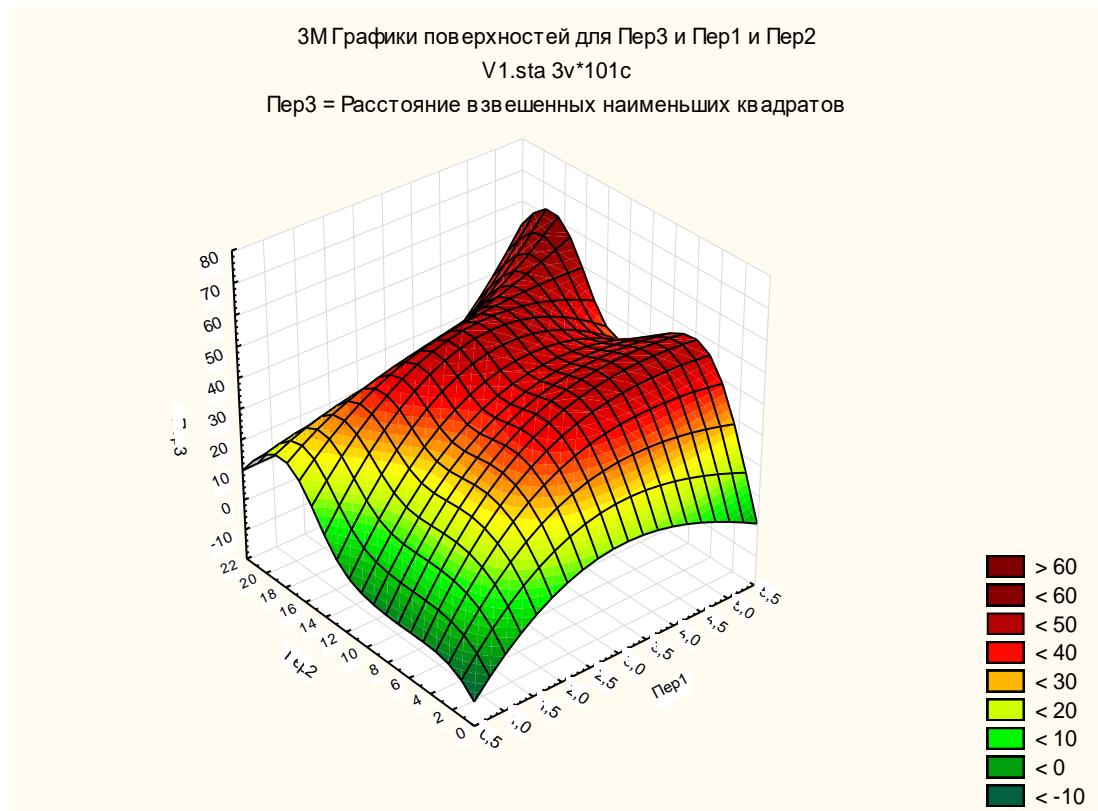


Рисунок 2.15 – Поверхность распределения пиксельной радиочастотной энергии на МРТ срезе.

Информация в 3D формате дает врачу объемное представление о динамике деструкции мягкой ткани коленного сустава.

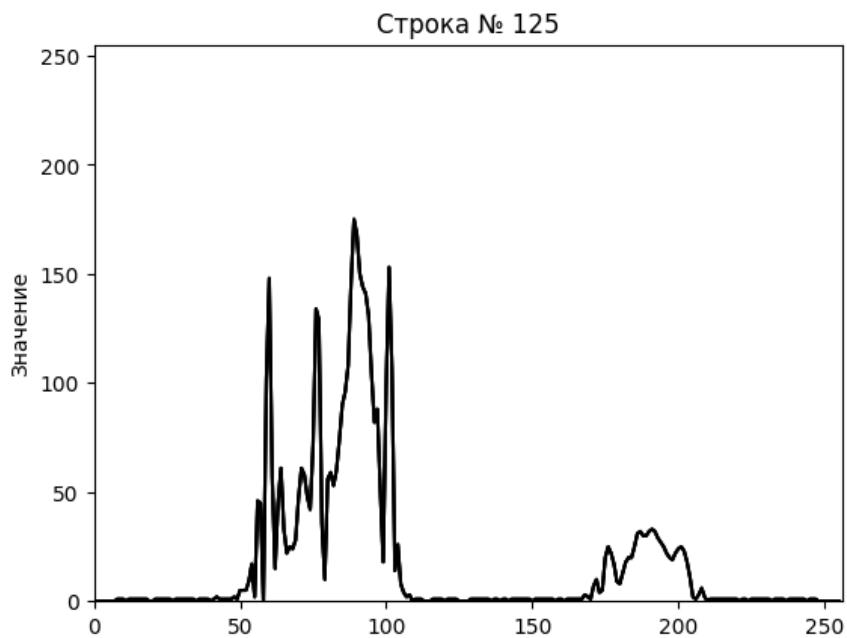


Рисунок 2.16 – Диаграмма численных значений пикселей в исследуемой строке на изображении одного исследуемого среза.

Диаграмма, представленная на рисунке 2.16, в физической интерпретации отражает распределение интенсивности сигнала, связанного с содержанием воды в тканях, в пределах одной исследуемой строки МРТ-среза. Локальные пики на графике соответствуют участкам повышенной плотности и энергетики пиксельной структуры, что позволяет визуально выделить зоны возможных патологических изменений. Данный тип анализа наглядно демонстрирует пространственную неоднородность яркостных характеристик и подчёркивает чувствительность МРТ-изображений к минимальным изменениям структуры мягких тканей.

Проведённый анализ текстурных характеристик МРТ-изображений коленного сустава показал, что изменения локальной плотности и энергетики пиксельной структуры позволяют выявлять зоны патологических процессов в мениске, отражающие нарушения водного баланса, дегенеративные изменения либо механические повреждения. Несмотря на высокую чувствительность метода к локальным вариациям интенсивности, его практическое применение оказывается ограничено значительными вычислительными затратами при обработке больших массивов изображений и необходимостью комплексной интерпретации данных специалистом.

В этой связи в рамках исследования предложен второй подход — интеллектуальная модель диагностики повреждений мениска, основанная на методах глубокого обучения. Такие модели позволяют автоматизировать выявление повреждений, повысить воспроизводимость результатов и минимизировать влияние субъективного фактора при интерпретации изображений. Кроме того, применение нейросетевых архитектур обеспечивает возможность учитывать сложные пространственно-текстурные зависимости, которые трудно формализовать классическими методами анализа.

Таким образом, переход от классического текстурного анализа к моделям глубокого обучения является логическим развитием предложенной информационной технологии и ключевым элементом концепции диагностирования повреждений менисков.

Предложенный метод информационно-текстурной диагностики повреждений менисков коленного сустава демонстрирует высокую эффективность при анализе МРТ-изображений, особенно в случаях низкого контраста и невыраженной визуальной структуры патологических областей. В отличие от традиционных подходов, ориентированных преимущественно на визуально-аналоговое восприятие врачом-рентгенологом, разработанный метод обеспечивает переход к формализованной цифровой интерпретации изображения за счёт анализа межпиксельных приращений яркости, локальной неоднородности и вариаций плотности тканей.

Методика позволяет количественно оценить текстурные характеристики мениска, выделить зоны скрытых патологических изменений, которые могут быть слабо заметны при стандартной визуализации, и тем самым повысить чувствительность раннего обнаружения повреждений. Проведённые исследования показали, что информационно-текстурные

признаки обладают высокой дискриминационной способностью и позволяют надёжно отделять нормальную структуру мениска от поверхностных и глубоких дегенеративных нарушений.

Практическая значимость метода заключается в возможности его интеграции в автоматизированные системы поддержки принятия врачебных решений. Использование информационно–текстурной диагностики в составе интеллектуальной системы позволяет снизить субъективный фактор при расшифровке МРТ, стандартизировать подход к оценке изображений и увеличить достоверность диагностических заключений. Таким образом, разработанный метод является важным инструментом повышения точности, объективности и воспроизводимости диагностики повреждений менисков коленного сустава.

## 2.4 Автоматическое распознавание повреждений менисков на основе методов глубокого обучения

Второй подход в диагностировании патологий менисков был реализован на основе глубокого обучения с применением моделей семейств YOLO и RT–DETR. Данный подход направлен на анализ МРТ изображений с целью автоматического обнаружения и классификации патологических изменений менисков.

На рисунке 2.17 представлены основные этапы автоматического распознавания повреждений менисков.



Рисунок 2.17 – Основные этапы автоматического обнаружения повреждений менисков

Развитие технологий распознавания изображений, основанных на глубоком обучении, даёт возможность существенно улучшить анализ

медицинских снимков. В отличие от традиционных подходов, требующих ручного выделения признаков, системы глубокого обучения самостоятельно изучают важные характеристики, используя большие наборы данных. Такой метод позволяет обнаруживать сложные и неочевидные связи в биомедицинских изображениях, например, незначительные текстурные особенности, указывающие на начальные стадии заболеваний менисков.

В диссертационном исследовании была использована методика контролируемого обучения: каждому изображению МРТ соответствует метка класса — наличие или отсутствие повреждения мениска. Таким образом, задача формулируется как бинарная классификация с элементами детекции объектов.

В исследовании использовались два современных семейства моделей обнаружения объектов: YOLO (версии YOLOv5, YOLOv8–YOLOv12), а также модели RT-DETR, позволяющие одновременно локализовать и классифицировать патологические изменения. Архитектура моделей была адаптирована к задаче анализа медицинских изображений, а в качестве входных данных использовались серии двумерных срезов МРТ в формате  $640 \times 640 \times 3$ . Комплексная методика автоматического распознавания разрывов менисков представлена на рисунке 2.18.

На первом этапе проведения исследования была проведена предварительная подготовка данных. Исходный набор данных, состоящий из МРТ исследований пациентов со всех регионов Казахстана, как уже было ранее отмечено, был получен на различном оборудовании с отличающимися техническими характеристиками, включая напряжённость магнитного поля, толщину среза и производителя.

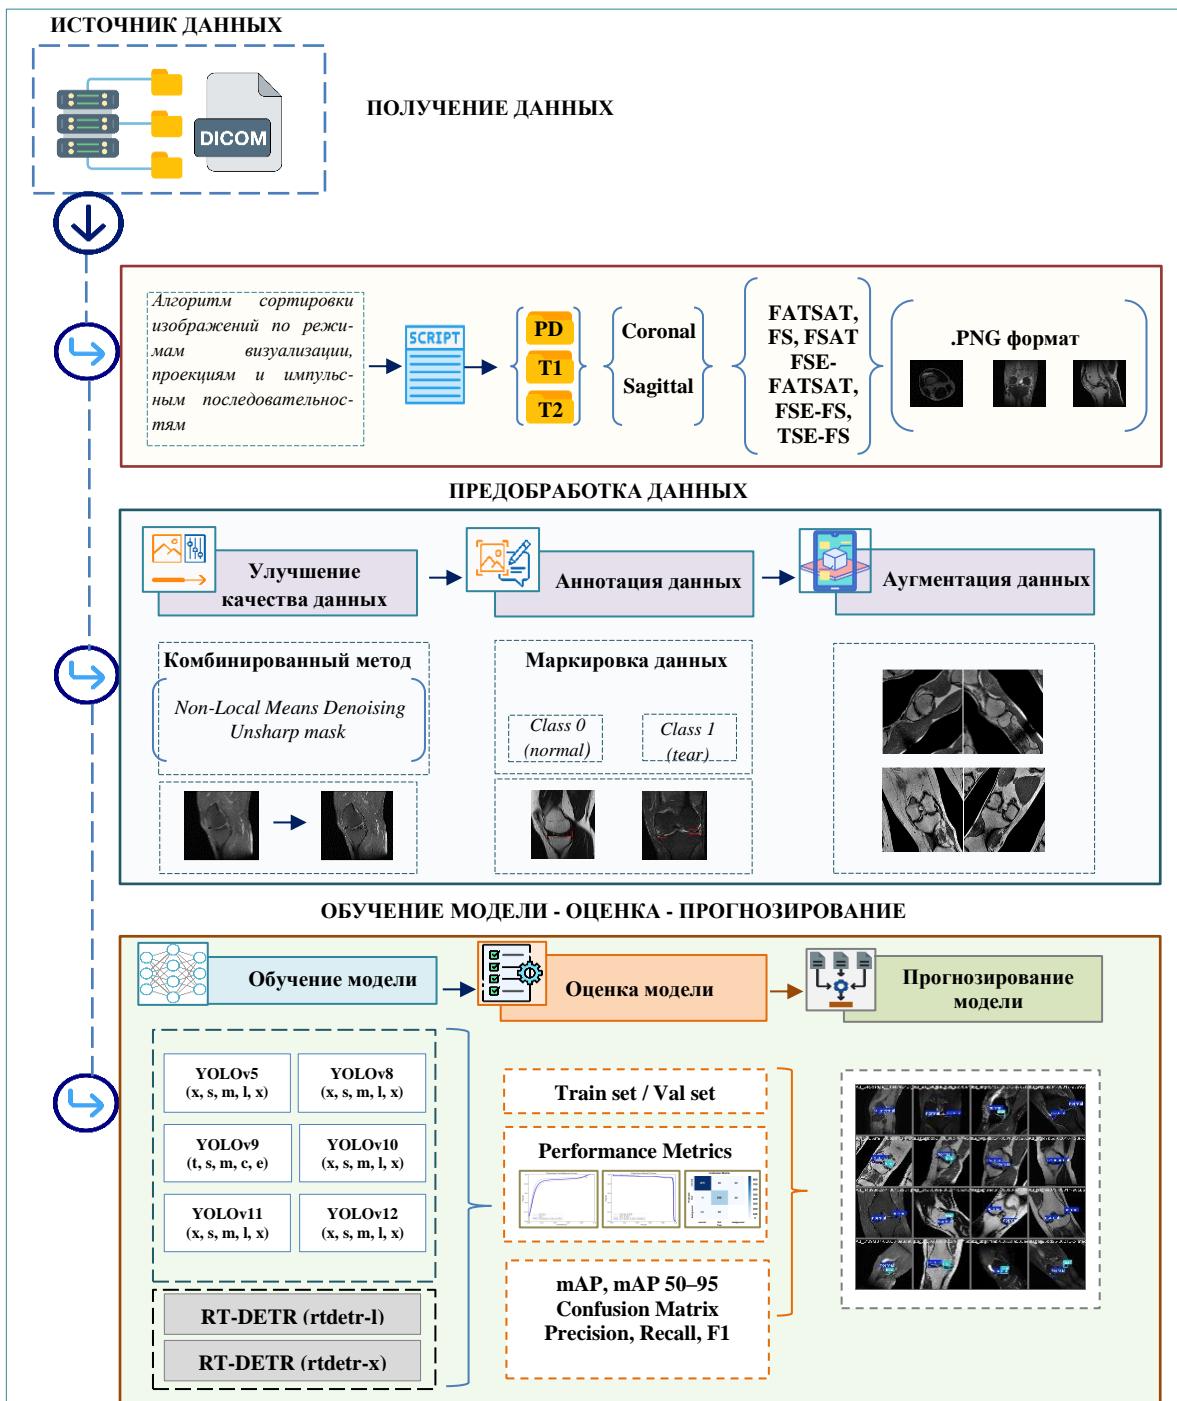


Рисунок 2.18 – Комплексная методика автоматического распознавания разрыва мениска

Исследования проводились с применением различных протоколов сканирования и параметров настройки. В связи с этим данные сильно различались по режимам визуализации и импульсным последовательностям, а также по качеству изображения.

Согласно данным научных статей и медицинских учебников [93, 94], для диагностики повреждений коленного сустава наиболее информативными являются:

- режимы визуализации – T1, T2, PD [17];

- импульсные последовательности – Spin–Echo (SE), Turbo Spin–Echo (TSE), Fast Spin–Echo (FSE), Fat Saturated (FATSAT, FSAT, FS) [18];
  - проекции – коронарная, сагиттальная [93].

В качестве репрезентативных изображений для обучения модели обнаружения объектов были выбраны коронарные и сагиттальные T1–, T2–, PD–взвешенные изображения, полученные при помощи импульсных последовательностей SE, TSE, FSE, FSat, FatSat, FS. При помощи программы Weasis МРТ снимки коленных суставов из файлов DICOM были экспортированы в формат PNG. Общее количество изображений составило 129 343. Из них 66 328 изображений PD–взвешенной визуализации, 38 421 изображений в T1 режиме и 24 594 изображения в T2 режиме. Однако не все изображения являются информативными для проведения исследования. Для целей настоящего исследования из общей серии изображений МРТ исследования каждого пациента отбирались только те срезы, на которых визуализируются мениски, поскольку именно они являются анатомическим объектом анализа.

Исходный набор данных содержал МРТ снимки с различными типами разрывов мениска, соответствующими клинической классификации: вертикальные, продольные, горизонтальные, радиальные, косые, комбинированные, а также разрывы по типу «ручки лейки» [94]. Данные типы повреждений мениска хорошо описаны в литературе и являются ключевыми с точки зрения диагностики. Также они были описаны в первом разделе диссертации. Анализ распределения типов повреждений в исходном наборе данных показал преобладание МРТ–снимков с горизонтальными разрывами мениска. В связи с этим, в данном исследовании в качестве повреждения мениска был выбран горизонтальный тип разрыва, что позволило оптимизировать обучение моделей и повысить статистическую достоверность результатов.

В соответствии с клиническими диагностическими рекомендациями мениски классифицировались на мениски без разрыва (здоровые) и с признаками разрыва. Классификация изображений с признаками разрыва мениска обусловливалась наличием аномального гиперинтенсивного сигнала внутри мениска, достигающего хотя бы одной из суставных поверхностей. Дополнительными признаками послужили деформация мениска, нарушение его контуров или смещение фрагмента [20]. Критериями включения изображений для анализа являлись наличие признаков разрыва мениска, визуализируемого на МРТ, при этом повреждение должно было ограничиваться одной стороной коленного сустава (медиальной или латеральной) без сопутствующего разрыва противоположного мениска.

В рамках предварительной подготовки все изображения были вручную размечены и разделены на два класса: 0 — изображения без разрыва мениска (normal), и 1 — изображения с подтвержденным разрывом мениска (tear). Примеры соответствующих изображений из набора данных приведены на рисунке 2.19.

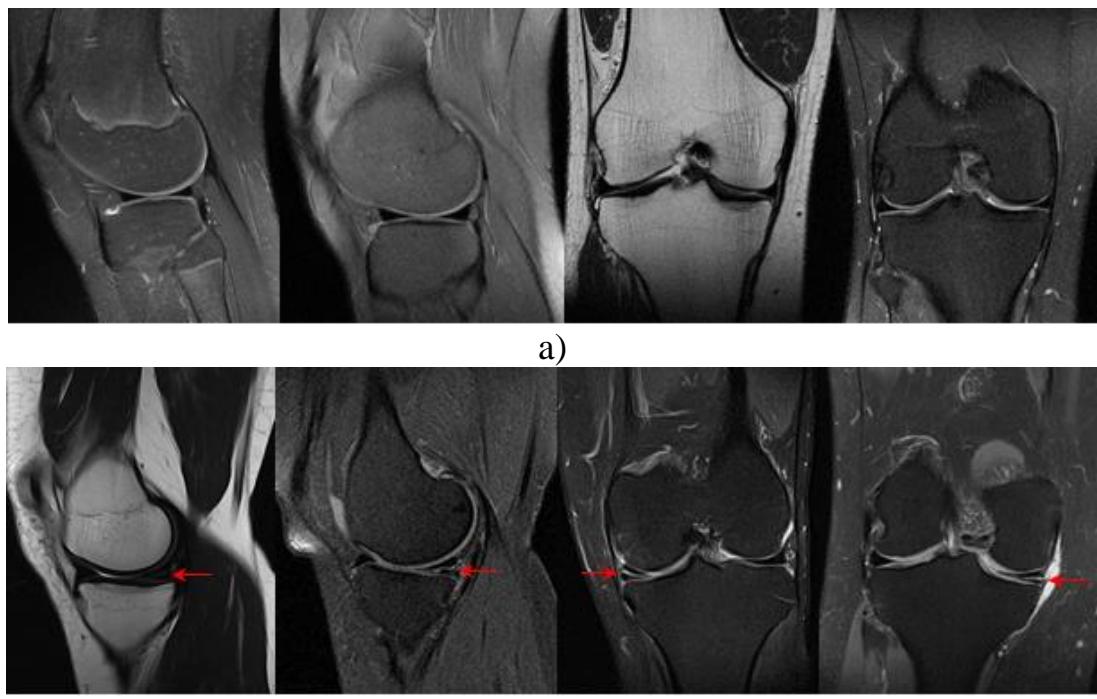


Рисунок 2.19 – (а) Изображения без разрыва мениска (класс 0);  
(б) изображения с подтвержденным разрывом мениска (класс 1)

Маркировка данных по классам проводилась пошагово. Общее количество распределенных изображений составило 4262. Отобранные на этапе маркировки изображения были проверены специалистом-экспертом. В результате верификации количество маркированных МРТ-изображений составило 2000 изображений, а общее количество объектов на изображениях – 7990. В таблице 2.1 представлено распределение изображений и объектов по классам.

Таблица 2.1 – Распределение изображений и объектов по классам

Классы	Режимы визуализации			Изображения	Объекты
	PD	T1	T2		
<b>Normal</b>	556	202	242	1000	5992
<b>Tear</b>	682	134	184	1000	1998

Для обучения нейронной сети задаче автоматического обнаружения разрывов менисков набор данных (2000 оригинальных и 2000 дополненных) был случайным образом разделен на три части (табл. 2.2): 70% составили обучающие данные (2800 изображений), по 15% – валидационные и тестовые данные (по 600 изображений соответственно).

Таблица 2.2 – Разделение данных

Категория	Обучающий набор	Тестовый набор	Проверочный набор	Всего
<b>Изображения(normal/tear)</b>	2800	600	600	4000

В результате подготовки и маркировки данных был сформирован собственный специализированный датасет клинических МРТ-изображений, с использованием которого проводились последующие этапы автоматического обнаружения повреждений менисков. После завершения этапа подготовки и маркировки данных была проведена предварительная обработка изображений, являющаяся одним из ключевых этапов анализа МРТ-изображений, направленная на улучшение качества визуальных данных, снижение влияния артефактов и обеспечение стабильности последующего анализа.

Для улучшения качества отобранных изображений была разработана методика предварительной обработки МРТ изображений с применением нескольких групп методов для обработки и анализа изображений с различными принципами работы.

#### 2.4.1 Разработка методики предварительной обработки МРТ изображений

Изображения, получаемые в сканере МРТ, подвержены шумам. Эти помехи необходимо убрать, поскольку они существенно затрудняют дальнейший процесс классификации, кластеризации и постановку диагноза. Помехи разделяются на два больших вида – случайные и систематические. Это деление довольно условное, присутствуют и другие специфические помехи, например, анатомические и возрастные особенности пациента, которые относят к специальным помехам, называемым шумом пациента.

Борьба со случайными помехами имеет давнюю историю в теории и практике обработки сигналов, начиная с изобретения радио в начале двадцатого века и затем с появлением систем передачи и обнаружения аудио, визуальной и многоспектральной информации. В настоящее время разработаны и широко применяются статистические методы подавления случайных помех. Теория случайных шумов богата математическими моделями и хорошо разработана. В рамках этой теории и практики нашли применение методы и алгоритмы реконструкции изображений вычислительной томографии, стабилизация и оптимизация помехоустойчивых подходов теории слабо-обусловленных и некорректных задач математической физики.

Обычно шум на МР-изображениях обусловлен флуктуациями магнитного поля в катушке [107]. Различные неоднородности, связанные с МР-изображениями, включают шум, артефакт затенения и эффект частичного объема. Неоднородность интенсивности возникает из-за неравномерности радиочастот во время сбора данных, что приводит к артефакту затенения [108]. Когда несколько типов тканей или классов занимают один и тот жеvoxель или пиксель, это называется эффектом частичного объема. Высокая контрастность и высокое пространственное разрешение являются обязательными в зависимости от типа диагностических задач. Высокое отношение сигнал-шум является обязательным условием для

приложений обработки изображений, поскольку большинство алгоритмов чувствительны к шуму. Это подчеркивает необходимость применения фильтрации шумов на МРТ-изображениях для сохранения мелких деталей изображения.

Значение интенсивности (от черного до белого) может варьироваться в пределах одной и той же ткани. Это называется полем смещения. Это низкочастотный, гладкий, нежелательный сигнал, который значительно затемняет или освещает какие-то области МРТ-изображения. Поле смещения вызывается неоднородностью магнитного поля аппарата МРТ. Если не исправить поле смещения, алгоритмы обработки изображений (например, сегментация и классификация) будут давать неверные результаты. Перед сегментацией или классификацией необходим этап предварительной обработки, чтобы скорректировать влияние поля смещения [109].

В данном исследовании рассматривается задача улучшения визуального качества снимков, получаемых в сканерах МРТ и подверженных систематическим помехам, в частности, смещению поля, или неоднородностям яркости на снимках. Изменение визуальной яркости снимка МРТ, вызванное полем смещения, может иногда достигать 30% искажения нормальной плотности изображения, что вызывает большие затруднения у врачей при оценке изображений при постановке клинического диагноза, и оказывает неблагоприятное влияние на возможности цифровой обработки медицинских изображений [110].

Практически все исследователи в своих работах используют похожую постановку задачи и модель формирования помех МРТ-изображений [109]. Два основных артефакта искажают МРТ-изображение: радиочастотная (РЧ)-неоднородность и импульсный шум. В частотной области, (РЧ)-неоднородность изменяет низкочастотные гармоники, а случайный импульсный шум искажает высокие частоты. В пространственной области РЧ-неоднородность — это мультиплектическое искажение, а импульсный шум — аддитивный. На основании признаков, описанных выше, мы можем написать следующую модель помех:

$$g = f \times b + N \quad (2.24)$$

Искаженное изображение ( $g$ ) получается суммой шума ( $N$ ) и исходного изображения ( $f$ ), умноженного на искажение (смещение) RF-неоднородности ( $b$ ). Шум может быть подавлен с помощью известных фильтров для удаления шума.

В последние годы было предложено множество подходов к предобработке МРТ-изображений с целью улучшения их качества. Например, в работе [111] проведён сравнительный анализ различных фильтров, включая средний, гауссовский, Калмана и альфа-усечённый средний фильтр, для удаления шума из МРТ-изображений мозга. Результаты показали, что альфа-усечённый фильтр обеспечивает наилучшие показатели

по метрикам PSNR, SSIM и MSE. В другом исследовании [112] предложена комбинация анизотропной фильтрации и нейронных сетей для денойзинга и выделения аномалий.

Однако, несмотря на достигнутые успехи, всё ещё необходимы исследования, направленные на повышение устойчивости методов фильтрации в условиях реальной клинической вариативности, когда изображения получены из различных источников, выполнены на МРТ-сканерах разных моделей, с разными протоколами съёмки и параметрами. Методика предварительной обработки МРТ изображений, разрабатываемая в рамках настоящего диссертационного исследования, как раз фокусируется на обработке именно таких неоднородных и разнородных данных.

Новизна данной методики заключается в применении комплексного подхода, включающего как численные метрики (MSE, PSNR, SSIM), так и субъективную визуальную экспертизу, а также в построении комбинированной схемы фильтрации, объединяющей преимущества методов Лапласа, Non-Local Means и Unsharp Mask. Такой подход позволяет достичь баланса между визуальной чёткостью и эффективным шумоподавлением, что особенно важно в контексте подготовки изображений к последующему машинному анализу и автоматической диагностике.

Последние достижения в области методов обработки и визуализации изображений в значительной степени способствовало улучшению качества МРТ изображений, а именно снижению шума, устранению артефактов и повышению разрешения. Применение различных подходов, начиная от традиционных метрик по улучшению качества изображений, так и глубокого обучения, в целом имеет большой потенциал для точной диагностики и оценки заболеваний, связанные с различными видами травм мениска. Так, к примеру, в работе [113], авторы анализирует степень применимости и эффективности различных метрик оценки качества изображения (IQA) для случая магнитно-резонансной томографии, а именно МРТ-изображений. В исследовании использован набор данных FastMRI с реалистичными сканами МРТ для установления эталонного стандарта для оценки качества изображений. В ходе исследования определены три основных критерия оценки качества МРТ, как SNR (соотношение сигнал/шум), CNR (соотношение контрастность/шум) и наличие артефактов. Методы, которые повышают воспринимаемый уровень шума (SNR), могут привести к получению более четких изображений. Авторы утверждают о необходимости в метриках, которые могут эффективно измерять улучшения в SNR. Значимость CNR и идентификация артефактов указывают на необходимость разработки улучшенных алгоритмов для баланса между шумоподавлением и контрастным усилением, тем самым гарантируя, что важные особенности не будут скрыты. Кроме этого, авторы подчеркивают ограничения существующих методов оценки качества изображения (IQA) при применении к МРТ. Таким образом, предлагается разработка и проверка специфичных для МРТ метрик, которые могут более точно отражать уникальные характеристики данных МРТ. Также, авторы отмечают применение методов

глубокого обучения в оценке качества изображений, которые показывают хорошие результаты в повышении качества МРТ изображений.

В работе [114], исследованы этапы предварительной обработки МРТ изображений колена, которые необходимы для повышения качества и эффективности МРТ изображений в приложениях глубокого обучения, направленные на диагностику повреждений мениска. В статье использован набор данных МРТ-сканов колена за период с 2016 по 2019 год. В реализации предварительной обработки для улучшения качества МРТ изображений рассматриваются несколько этапов. Такими этапами выступают модально-специфические корректировки, пространственная повторная выборка и изменение размера, нормализация и стандартизация интенсивности, а также для шумоподавления фильтрация Гаусса. Данный метод повышают четкость и улучшают извлечение признаков из данных МРТ. Авторы утверждают, что применение методов предварительной обработки значительно повышает эффективность моделей глубокого обучения для диагностики разрывов мениска. В следующей работе [115], были проанализированы способности алгоритмов шумоподавления на основе матриц низкого ранга для МРТ изображений в диагностике перелома плато большеберцовой кости (TPF) с повреждением мениска. В качестве набора данных были отобраны 60 случаев пациентов с TPF, диагностированных с марта 2018 года по октябрь 2019 года. Авторы исследования предложили новый алгоритм Гауссовой смеси на основе факторизации матриц низкого ранга (GLRMF), который улучшен для подавления шума в МРТ-изображениях. В реализации анализа качества изображений использовались и сравнивались метрики RMSE и SSIM для оценки качества при разных уровнях шума. В результате экспериментальных работ новый алгоритм GLRMF продемонстрировал лучшую структурную сохранность (SSIM) по сравнению с алгоритмами ADF и NLM, особенно при  $K=100$  (параметр модели). Таким образом, результаты классификации пациентов были подсчитаны по диагностике Шатцкера, а результаты артроскопии использовались в качестве стандарта для анализа точности МРТ в диагностике TPF с повреждениями мениска. Оценка модели показала высокие показатели, а именно чувствительность составила 94,76%, точность 93,33% и специфичность 89%.

В работе [116], представлены исследования, где были рассмотрены взаимосвязь между качеством реконструкции изображений с использованием глубокого обучения (DL) и эффективностью обнаружения аномалий. Кроме этого, была проведена оценка эффективности помощника на основе ИИ для улучшения интерпретации рентгенологами аномалий мениска на реконструированных изображениях. В методологии для обнаружения аномалий использовались наборы данных из 896 пациентов. В качестве оценочных метрик для оценки качества изображений применялись стандартные метрики, а именно nRMSE, PSNR и SSIM. Тем самым, сравнительный анализ между применением стандартных метрик и разработанными авторами новыми box-based метриками есть разница. Новый

подход авторов по оценке качества реконструированных изображений в контексте обнаружения аномалий обеспечивает более точную оценку качества по сравнению с традиционными метриками, такими как SSIM.

В целом, на сегодняшний день большинство работ по исследованию улучшения качества МРТ изображений прибегают к применению стандартных метрик с целью оценки и улучшения качества МРТ изображений. Также, многие научные работы предлагают новые технологии и методы, которые позволяют улучшить качество изображений и ускорить процесс получения МРТ. Такими технологиями и методами можно привести параллельное изображение, методы сжатия и алгоритмы глубокого обучения, которые подробно описаны в работе [117]. Авторы отмечают, что 3D МРТ обеспечивает более высокое пространственное разрешение, что в свою очередь снижает эффект размытия и позволяет выполнять многоплоскостные реконструкции без значительной потери качества изображения. Это хорошо подходит для количественной оценки состояния хрящей, менисков и других структур колена.

Современная медицинская визуализация требует высокой точности и надёжности в диагностике. Одним из ключевых этапов анализа МРТ–изображений является их предобработка, целью которой является устранение шумов и улучшение визуального восприятия. В данном исследовании рассматриваются различные методы обработки изображений, а также проводится их сравнительный анализ на основе метрик и визуального анализа. На основе анализа предложен комбинированный метод, обеспечивающий оптимальное соотношение между метриками оценки и визуальной чёткостью изображения.

Изображения, получаемые при помощи МРТ, как уже было отмечено ранее, часто содержат шумы, артефакты и другие искажения, снижающие качество диагностики. Предобработка изображений позволяет устранить эти дефекты, однако выбор наиболее подходящего метода зависит от множества факторов, включая режим визуализации и используемую импульсную последовательность. Настоящее исследование направлено на тестирование и сравнение нескольких фильтрационных подходов и выбор оптимального метода на основе метрик качества изображения.

В ходе проведённого исследования были сформированы и структурированы основные этапы процесса обработки МРТ–изображений, представленные на рисунке 2.20:

1. Изучение, анализ и тестирование методов обработки изображения: применялись методы улучшения контрастности, методы шумоподавления, методы для усиления резкости и выделения краёв.
2. Определение и расчёт критериев оценки качества: использовались метрики MSE, PSNR и SSIM.
3. Сравнительный анализ: результаты оценивались как количественно (по метрикам), так и визуально.
4. Выбор оптимального метода: проводился для каждого режима визуализации и импульсной последовательности.

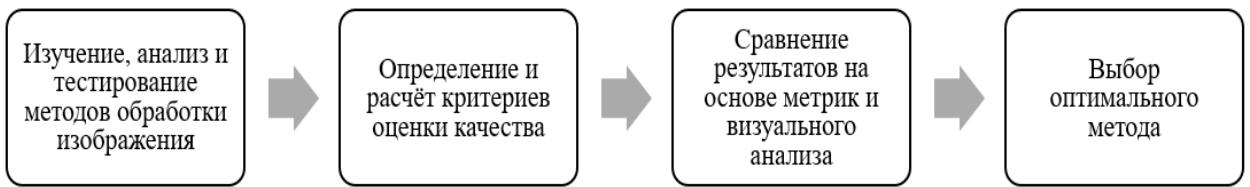


Рисунок 2.20 – Этапы процесса предобработки МРТ–изображений

Изучение, анализ и тестирование методов обработки изображения. В исследовании были использованы несколько групп методов с различными принципами работы [119–122].

Методы улучшения контрастности. CLAHE (Contrast Limited Adaptive Histogram Equalization) представляет собой усовершенствованный вариант адаптивного выравнивания гистограммы, при котором изображение разбивается на небольшие блоки (тайлы), и для каждого из них выполняется локальная коррекция распределения яркости. Такой подход позволяет улучшать контраст в отдельных участках изображения, делая более заметными детали как в светлых, так и в тёмных зонах. Важной особенностью метода является ограничение усиления контраста с помощью параметра *clip limit*, что предотвращает чрезмерное выделение шума и артефактов, особенно в областях с однородной структурой. После локальной обработки всех блоков их значения плавно интерполируются, обеспечивая плавный переход между соседними областями и сохраняя визуальную целостность изображения. Благодаря этим свойствам CLAHE широко применяется в медицинской визуализации, аэрофотосъёмке и других областях, где требуется корректировка локального контраста при неоднородном освещении.

Equalize Hist (глобальное выравнивание гистограммы) основан на построении гистограммы яркости для всего изображения и её перераспределении с использованием кумулятивной функции распределения (CDF), что обеспечивает более равномерное распределение тонов по всему диапазону. Этот подход эффективно повышает общий контраст, позволяя сделать изображение более чётким и выразительным, однако он не учитывает локальные особенности освещённости. В результате в областях с однородным тоном или низким уровнем яркости возможно усиление шума и появление нежелательных артефактов. Equalize Hist наиболее эффективно применять к изображениям с относительно равномерным освещением, где требуется глобальное улучшение детализации и визуальной выразительности, например, при обработке цифровых фотографий или в предварительной подготовке данных для алгоритмов распознавания изображений.

Методы шумоподавления. Gaussian Blur основан на применении гауссова ядра для равномерного сглаживания изображения, при котором каждый пиксель заменяется взвешенным средним значений соседних пикселей с коэффициентами, заданными двумерной гауссовой функцией.

Такой подход позволяет эффективно уменьшать высокочастотные составляющие изображения, что приводит к снижению мелких шумов и смягчению резких переходов между цветами и яркостями. Однако наряду с шумом происходит и частичная потеря деталей, поэтому метод чаще применяют там, где важно общее визуальное сглаживание, например, в подготовке изображений перед сегментацией или выделением крупных структур.

Median Blur заменяет значение каждого пикселя медианой значений в его локальном окружении, что делает его особенно эффективным для подавления импульсного шума типа «соль и перец». В отличие от линейных фильтров, медианная фильтрация сохраняет резкие границы и линии, так как медиана не размывает края столь сильно, как усреднение. Данный метод широко применяется в случаях, когда изображение содержит отдельные выбросы яркости, особенно в медицинских и технических снимках, где важно сохранить чёткость границ объектов.

Bilateral Filter сочетает пространственное сглаживание с учётом различий в интенсивности пикселей, благодаря чему позволяет одновременно уменьшать шум и сохранять чёткие края. Вес соседнего пикселя определяется не только расстоянием до центрального пикселя (как в гауссовом фильтре), но и сходством по яркости или цвету, что препятствует смешиванию различных областей изображения. Такой подход особенно полезен при обработке фотографий и изображений с важными мелкими деталями.

Метод Non-Local Means Denoising (NLM) усредняет значение пикселя, опираясь на сходные по цвету и текстуре области изображения, даже если они находятся на значительном расстоянии друг от друга. В отличие от локальных фильтров, NLM анализирует большие области и находит похожие фрагменты, что позволяет эффективно удалять шум при сохранении тонких деталей и текстур. Этот метод особенно эффективен для фотографий и медицинских изображений, где важно сохранить точную структуру объектов, но он требует значительных вычислительных ресурсов и может быть медленнее других способов шумоподавления.

Методы для усиления резкости и выделения краёв. Sharpening (Unsharp Mask) предназначен для усиления резкости изображения путём выделения и подчёркивания его контуров. Принцип работы заключается в том, что из исходного изображения вычитается его размытая копия, полученная, например, с помощью гауссова фильтра. Разница между оригиналом и размытым вариантом содержит в основном высокочастотные компоненты, то есть детали и края, которые затем добавляются обратно к исходному изображению с определённым коэффициентом усиления. Такой подход позволяет сделать изображение более чётким и детализированным, однако при слишком сильном усиении возможно появление артефактов и усиление шума. Unsharp Mask широко используется в цифровой фотографии, полиграфии и медицинской визуализации, где важно подчеркнуть границы объектов.

Laplacian Filter основан на применении дискретного лапласиана — второй производной по пространственным координатам, которая позволяет обнаруживать области с резкими изменениями интенсивности яркости. Поскольку такие изменения обычно соответствуют границам объектов, фильтр эффективно выделяет контуры независимо от их ориентации. Laplacian Filter чувствителен к шуму, поэтому часто применяется в сочетании с предварительным сглаживанием изображения, чтобы избежать ложных срабатываний на случайных колебаниях яркости. Он используется как в задачах выделения краёв для последующей сегментации, так и в алгоритмах анализа структуры изображения.

Sobel Filter применяет свёртку с двумя ортогональными ядрами, которые вычисляют приближённые значения градиентов яркости в горизонтальном и вертикальном направлениях. На основе этих данных можно выделить участки, где происходит значительное изменение интенсивности, что соответствует краям объектов. Преимущество фильтра Собеля заключается в одновременном выделении краёв и сглаживании изображения, что снижает чувствительность к шуму по сравнению с простыми операторами разности. Этот метод широко используется в компьютерном зрении и обработке изображений для выделения контуров, направления градиентов и формирования карт границ.

Для тестирования методов и расчета критериев оценки качества были использованы МРТ снимки с режимами визуализации PD, T1 и T2 с импульсными последовательностями FS, SE, FSE и TSE.

Для улучшения качества изображения, выбранные методы были протестиированы на МР-изображениях с различными режимами визуализации PD и T2 и импульсными последовательностями SE, FSE и TSE.

На рисунке 2.21 показана обработка качества изображения с режимом визуализации PD и импульсной последовательностью FS с использованием выбранных методов.

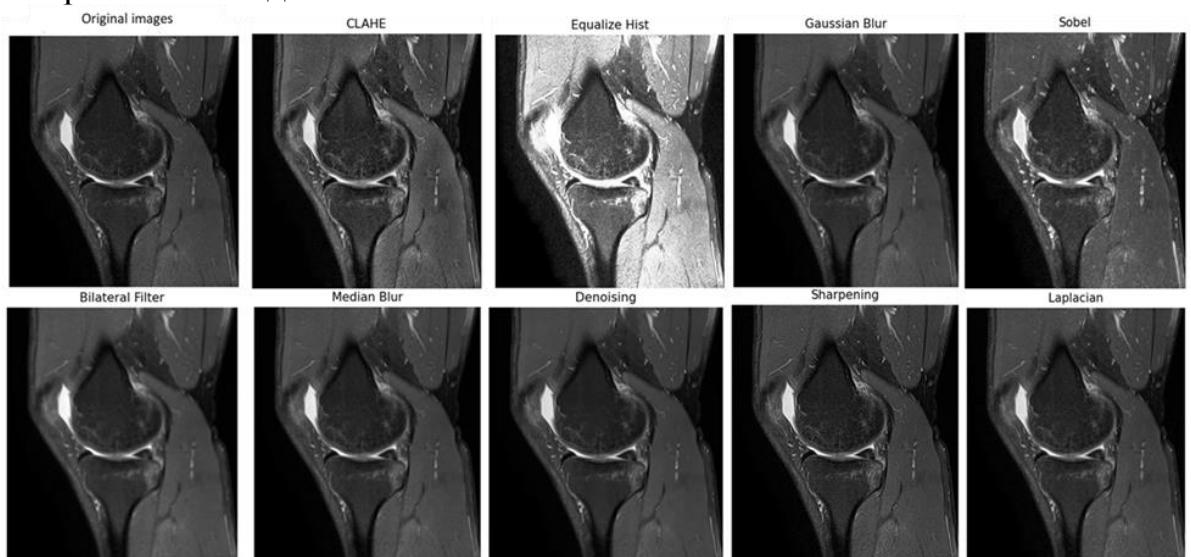


Рисунок 2.21 – Результаты обработки изображения различными методами

Для оценки качества изображения использовались такие метрики, как MSE (среднеквадратичная ошибка), PSNR (пиковое отношение сигнал/шум) и SSIM (индекс структурного сходства).

Среднеквадратическая ошибка (MSE). Измеряет среднее квадратичное отклонение между исходным и обработанным изображением (2.25).

$$MSE = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n [I(i, j) - K(i, j)]^2 \quad (2.25)$$

Диапазон значений от 0 до 65025 для 8-битных изображений. Чем меньше значение MSE, тем меньше различий между изображениями. Данная метрика чувствительна к яркостным изменениям, но не отражает структурные отличия, соответственно не может выровняться хорошо с человеческим восприятием качества.

Пиковое отношение сигнал–шум (PSNR). Представляет собой отношение пикового сигнала к среднеквадратичному уровню шума, определяемое при последовательной оценке разницы между всеми пикселями исходного и обработанного изображения (2.26). Диапазон принимаемых значений от 0 до 100, измеряется в логарифмической шкале в децибелах. Более высокие значения PSNR указывают на лучшее качество (меньше шума и искажений). Данная метрика удобна для оценки общего уровня шума, но не учитывает визуальное восприятие.

$$PSNR = 10 * \log_{10} \left( \frac{MAX_I^2}{MSE} \right) \quad (2.26)$$

Методы, основанные на этих оценках, хороши для изображений, имеющих белый шум. Однако эти меры некорректно отражают структурные искажения изображения.

Мера структурного подобия (SSIM). Оценивает структурное сходство между изображениями, включая яркость, контраст и текстуру (2.27). Значения SSIM лежат в диапазоне от 0 до 1 (1 означает полное сходство). Поскольку зрительная система человека способна чувствовать структуру, метрика качества SSIM соглашается более тесно с субъективным качественным счетом.

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (2.27)$$

По результатам сравнения методов на основе метрик было установлено, что лучшими являются фильтры Гаусса, Лапласа и Билатеральный (Таблица 2.3). Но визуально, если разобраться, эти методы показывают не самые лучшие результаты.

Таблица 2.3 – Сравнение методов по метрикам оценки качества.

Method	MSE	PSNR	SSIM
Combined method	32.55	41.37	0.92
Gaussian Blur	39.47	39.36	0.90
Laplacian Filter	39.80	38.21	0.90
Bilateral Filter	35.45	39.76	0.86
Non-Local Means Denoising (NLM)	35.69	39.57	0.86
Sharpening (Unsharp Mask)	47.10	35.80	0.85
Median Blur	42.20	32.26	0.82
CLAHE	132.33	24.47	0.74
Sobel Filter	190.83	21.22	0.68
Equalize Hist	232.28	9.30	0.44

На рисунке 2.22 представлены результаты обработки данными фильтрами. В результате сравнения было решено учитывать как метрики оценки качества, так и результаты визуального анализа при выборе метода.

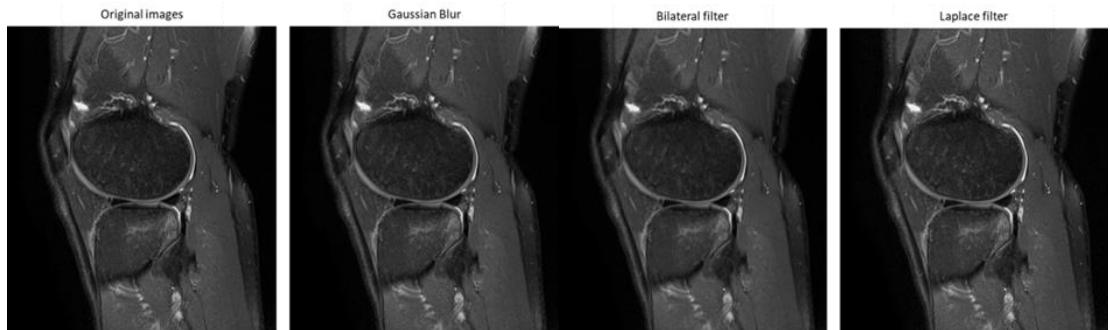


Рисунок 2.22 – Результаты применения Билатерального фильтра, Гаусса и Лапласа

Визуальный анализ показал, что, несмотря на высокие метрики у фильтров Гаусса и Лапласа, они не обеспечивают наилучшее визуальное качество. Оптимальным признан комбинированный метод. Количественная оценка эффективности которого представлена в таблице 2.3, где приведены значения метрик MSE, PSNR и SSIM. По результатам сравнительного анализа был выбран комбинированный подход, включающий методы Non-Local Means Denoising и Unsharp Mask, который продемонстрировал наилучшие значения количественных показателей ( $MSE = 32.55$ ;  $PSNR = 41.37$ ;  $SSIM = 0.92$ ), что свидетельствует о его высокой эффективности на этапе обработки МРТ-изображений. При этом, данный подход обеспечил наилучшие визуальные результаты, обеспечивая оптимальное подавление шума при сохранении анатомических границ (Рисунок 2.23).

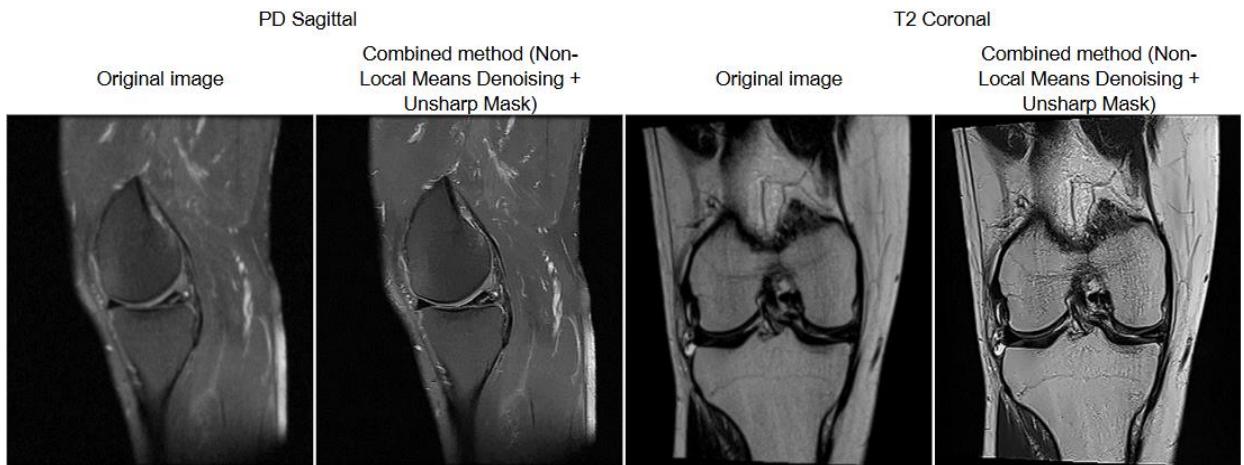


Рисунок 2.23 – Результаты обработки комбинированным методом

Предложенный комбинированный метод обработки МРТ–изображений демонстрирует высокую эффективность и может быть рекомендован для широкого применения при работе с медицинскими изображениями. Полученные данные обладают высокой однородностью и качеством, что создаёт основу для разработки и обучения математических моделей распознавания анатомических структур.

Ниже на графиках представлены значения метрик 997 изображений, обработанных комбинированным методом (Рисунок 2.24).

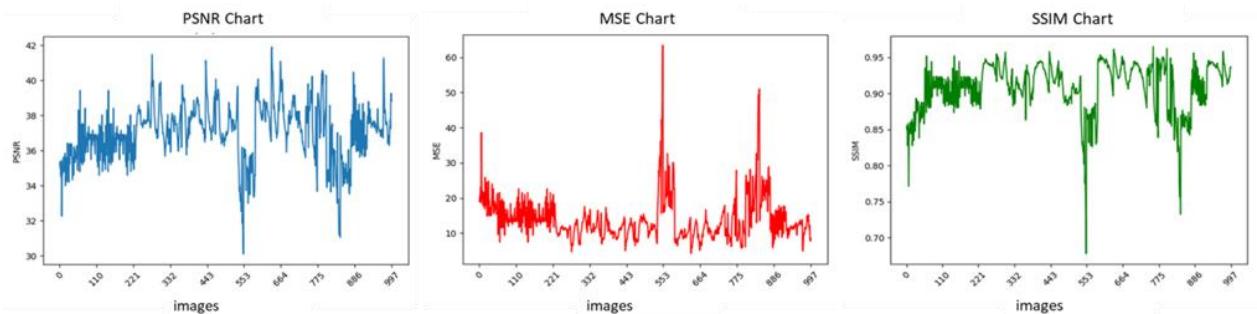


Рисунок 2.24 – Метрики оценки качества изображений, обработанных комбинированным методом

Проведённый анализ показал, что выбор метода фильтрации должен учитывать как численные показатели, так и субъективное восприятие изображения. Метрики PSNR и MSE не всегда коррелируют с визуальным качеством, в то время как SSIM демонстрирует наибольшее соответствие. В итоге, комбинация методов позволяет достичь наилучшего результата в различных клинических сценариях.

Предложенный комбинированный метод обработки МРТ–изображений демонстрирует высокую эффективность и может быть рекомендован для широкого применения при работе с медицинскими изображениями. Будущие исследования могут быть направлены на адаптацию методов к изображениям других модальностей и внедрение нейросетевых подходов для автоматизации процесса оценки качества.

Следует отметить, что предлагаемый подход был протестирован только на наборе данных, использованном в данном исследовании. Его применимость к внешним наборам данных требует дальнейшей проверки.

Для повышения обобщающей способности модели и компенсации ограниченности обучающей выборки была применена пространственная аугментация изображений. Использовались устойчивые к потере информации методы, обеспечивающие сохранение анатомических структур и контекстных признаков: Safe Rotate, ShiftScaleRotate, Random Sized BBox Safe Crop, Perspective. Из каждого класса было отобрано по 500 изображений, которые подвергались аугментации по четырём указанным признакам, в результате чего был сформирован итоговый набор из 2000 изображений. Результаты применения пространственных преобразований представлены на рисунке 2.25.

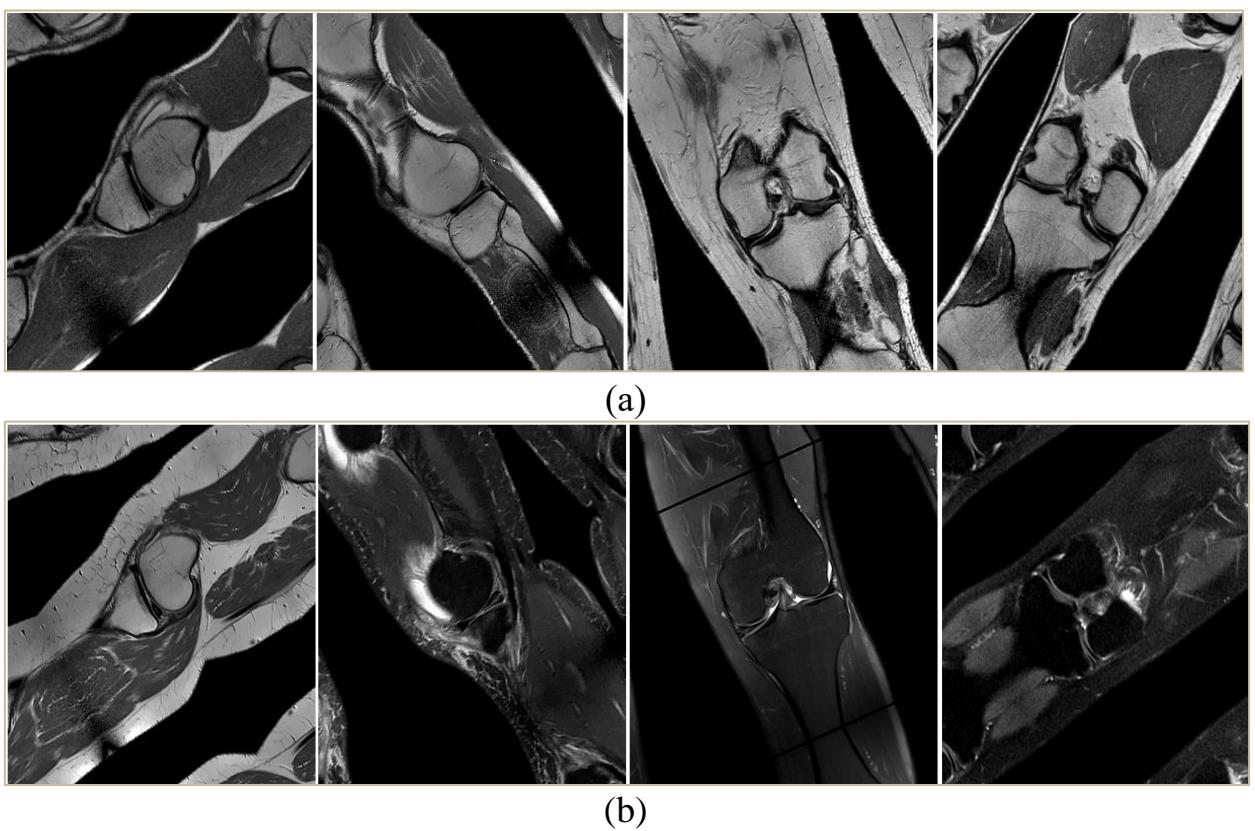


Рисунок 2.25 – Результаты аугментации: (а) изображения без разрыва мениска (класс 0); (б) изображения с подтвержденным разрывом мениска (класс 1)

Таким образом, на основании разработанной методики предварительной обработки МРТ-изображений коленного сустава обеспечивается повышение качества входных данных для последующего этапа автоматического анализа с применением моделей глубокого обучения семейства YOLO и RT DETR, описание архитектур которых представлено в следующем разделе диссертации.

#### 2.4.2 Архитектуры моделей YOLO и RT-DETR

Методы и модели глубокого обучения в настоящее время демонстрируют высокую эффективность в задачах сегментации, классификации и обнаружения объектов. Использование таких моделей для обнаружения разрывов мениска в интеграции с компьютерными системами позволяет автоматически обнаруживать и распознавать патологические изменения мениска на МРТ-изображениях. В частности, алгоритмы обнаружения объектов показали высокую производительность при решении подобных задач. Среди таких алгоритмов архитектура YOLO (You Only Look Once) является наиболее эффективной и точной. Быстрая эволюция семейства моделей YOLO показывает, что мы постоянно совершенствуем архитектуру, тем самым повышая точность и производительность моделей. Структура первых моделей YOLO состояла из простых конволюционных сетей и ограниченного числа якорных блоков. В дальнейшем, по мере развития моделей YOLO, в их основу были положены более глубокие модели с остаточными слоями, многоуровневый подход к обучению и безъякорный подход. В настоящее время последние модели YOLO, например YOLOv8 и выше, характеризуются тем, что в них используются новые блоки Backbone и Head, в которых реализованы лучшие блоки извлечения признаков, механизмы внимания и методы без NMS. Кроме того, расширены возможности обучения и регуляризации. Такие архитектурные возможности повышают качество оценки модели и сохраняют ее высокую скорость. Сравнительный обзор основных версий модели YOLO и их архитектурных компонентов представлен в таблице 2.4.

Таблица 2.4 – Сравнение YOLO-моделей по структуре сети

	Backbone	Neck	Activation	Loss	Models
YOLOv5 [121,122]	CSPDarknet53 (Focus)	PANet + SPPF	LeakyReLU	BCE + CIoU	YOLOv5-nu, YOLOv5-su, YOLOv5-mu, YOLOv5-lu, YOLOv5-xu
YOLOv8 [123]	C2f + CBS	PANet + SPPF	SiLU	BCE + DFL (v2)	YOLOv8-n, YOLOv8-s, YOLOv8-m, YOLOv8-l, YOLOv8-x
YOLOv9 [124]	ELAN-V2 + DFL v3	BiFPN or PAN++	SiLU	vFL (v3) + improved DFL	YOLOv9-t, YOLOv9-s, YOLOv9-m, YOLOv9-c, YOLOv9-e
YOLOv10 [125]	improved C2f / Transformer	RT-DETR- like neck	GELU	DFL + Adaptive Matching	YOLOv10-n, YOLOv10-s, YOLOv10-m, YOLOv10-l, YOLOv10-x
YOLOv11 [126]	RTMDet-style backbone	CBAM + PAN	SiLU / GELU	Varifocal Loss + DFL	YOLOv11-n, YOLOv11-s, YOLOv11-m,

					YOLOv11-l, YOLOv11-x
YOLOv12 [127]	R-ELAN	Multi-scale fusion: Upsample- Concat – A2C2F + C3k2 + Area Attention	SiLU	Hybrid: DFL+ GIoU	YOLOv12-n, YOLOv12-s, YOLOv12-m, YOLOv12-l, YOLOv12-x

Представленная на рисунке 2.26 архитектура YOLOv8-x реализует улучшенную сверточную структуру нейросети. Структура архитектуры включает в себя функциональные блоки: Backbone, Neck, Head. Такая структура архитектуры обеспечивает эффективное извлечение признаков, их агрегацию и многомасштабную детекцию объектов. Модель версии YOLOv8 определяется тремя параметрами: `depth_multiple`, `width_multiple`, `max_channels`, где `depth_multiple` определяет сколько блоков узкого места находится в блоке C2f, а параметры `width_multiple` и `max_channels` определяют выходные каналы [130]. Stem компонент модели YOLOv8 состоит из двух блоков свертки с шагом 2 и размером ядра 3. Эти блоки преобразуют данные в исходные признаки и уменьшают входное разрешение [130].

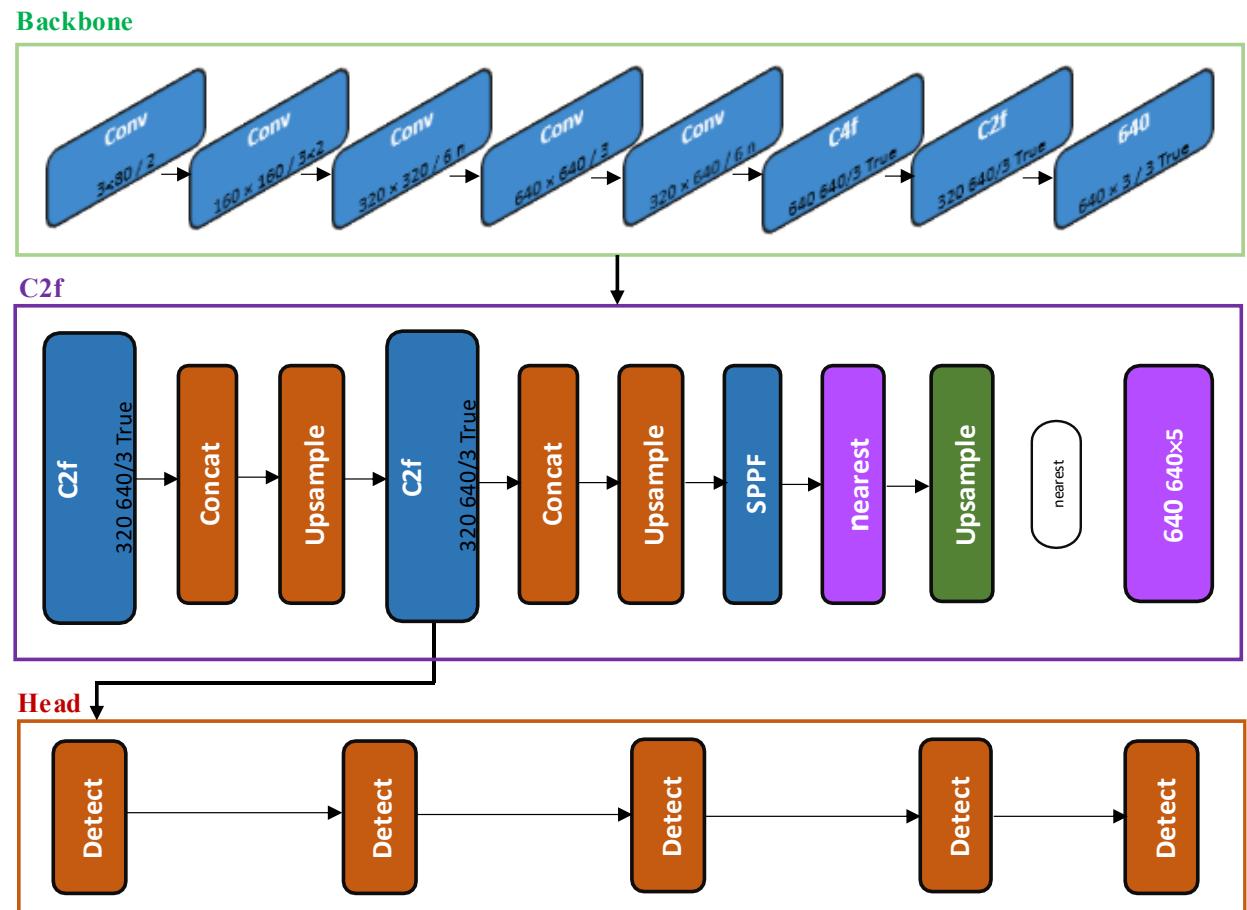


Рисунок 2.26 – Структурная схема сети YOLOv8-x

В модели YOLOv8 компонент *stage* использует блок *C2f*. В такой структуре модели YOLOv8 есть 8 этапов. *C2f* выполняет глубокую обработку признаков с сохранением пространственных признаков. Данная структура реализует поэтапное снижение пространственного разрешения и увеличение глубины признаков. Также имеющиеся этапы в магистрали используют сокращения, тогда как шейка не использует сокращения [130]. Такое использование или неиспользование сокращений определяется эмпирическими результатами экспериментов методом проб и ошибок для поиска наилучшего варианта [131]. Реализация процедуры понижения дискретизации в модели YOLOv8 использует блок свертки с шагом 2 и размером ядра 3. При шаге 2 выходное пространственное разрешение будет уменьшено вдвое.

На выходном слое *Backbone* сразу следует следующий блок *SPPF* (*Spatial Pyramid Pooling Fast*), находящийся на шее. Блок *SPPF* предназначен для предоставления многомасштабного представления карты признаков. Блок *SPPF* позволяет модели захватывать признаки на различных уровнях абстракции путем объединения в различных масштабах [131]. Также на шее имеются несколько блоков, таких как *concat* и *upsample*. В модели YOLOv8 разрешение карты признаков увеличивается на основе повышения дискретизации, где в дискретизации применяется техника по ближайшему соседу. При увеличении карты признаков ближайшие пиксели повторяются, а объединение через *concat* увеличивает число каналов без изменения размера. Кроме этого, в модели YOLOv8 есть три головки для мелких, средних и крупных объектов, которые подключены к разным уровням и размерам объекта определяется относительно изображения.

Таким образом, модель YOLOv8 поддерживает многоуровневую агрегацию признаков с использованием операций *concat* и *upsample*. Также модель YOLOv8 эффективно использует блок *C2f*, который способствует обучению глубоких слоев с обеспечением компактности и эффективности обучения.

**Архитектура RT-DETR.** В рамках данного исследования также было проведено обучение моделей RT-DETR (RTDETR-1 и RTDETR-x) на том же самом наборе данных изображений, с целью последующего сравнения производительности и эффективности данных моделей с представителями семейства моделей YOLOv8-12. RT-DETR является передовым комплексным детектором объектов, который демонстрирует производительность в реальном времени с сохранением высокой точности. Сетевая структура архитектуры модели RT-DETR основана на *Transformer* и представлена на рисунке 2.32. Архитектура модели RT-DETR включает в себя три основных модуля, такие как магистрали извлечения признаков, гибридный кодер улучшения признаков, декодер *Transformer* со вспомогательным механизмом прогнозирования [133]. Принцип работы такой сетевой структуры модели RT-DETR основано на иерархическом механизме обработки многомасштабных признаков, т.е., модель сначала улучшает признаки в каждом масштабе, а потом выполняет кросс-

масштабную интеграцию признаков. В своей архитектуре RT-DETR в качестве магистральной сети использует эффективную архитектуру CNN (либо может быть серией ResNet [135]) или же специально оптимизированной HGNet [135].

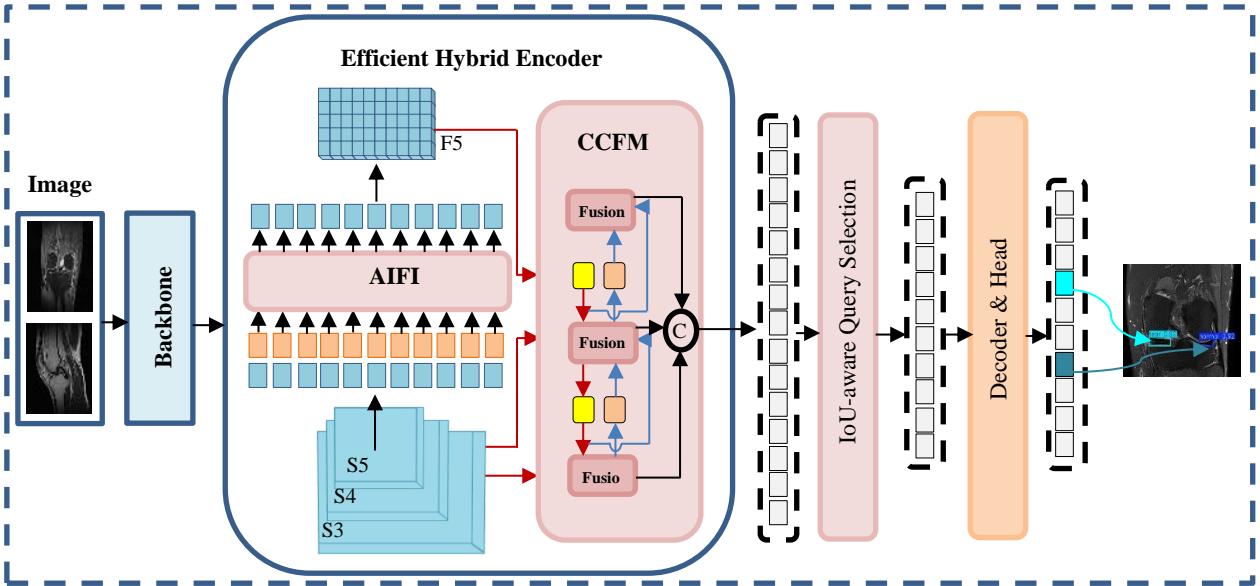


Рисунок 2.27 – Схема архитектуры сети RT-DETR

В процессе обработки признаков модель RT-DETR в своей структуре использует инновационных два модуля. Это модуль AIFI (Attention-Enhanced Intra-Scale Feature Interaction) и второй модуль CCFM (Convolution-Driven Cross-Scale Feature Fusion). Модуль AIFI выполняет векторизацию глубинных признаков на основе использования облегченного кодировщика Transformer и после этого проводится реконструкция признаков с помощью сети прямых связей. На завершающем этапе работы модели RT-DETR используется модуль CCFM, который выполняет интеллектуальную агрегацию многоуровневых признаков, тем самым показывая полноценное представление признаков. В блоке детекции RT-DETR применяет стратегию подавления шума, основанную на подходе DINO [136]. Данный подход позволяет модели RT-DETR значительно повысить качество сопоставления запросов с объектами, а также ускорить сходимость процесса обучения.

## Выводы по второму разделу

В результате проведённого анализа и экспериментальных исследований разработан комплекс методических решений, обеспечивающий повышение точности и достоверности автоматизированного диагностирования повреждений менисков коленного сустава по данным магнитно-резонансной томографии. В ходе работы были сформированы и аннотированы исходные данные, включающие клинические МРТ-изображения коленных суставов. Разработаны критерии включения и исключения, обеспечивающие репрезентативность выборки.

Проведённое исследование показало, что выбор метода фильтрации МРТ-изображений должен учитывать как количественные метрики качества (MSE, PSNR, SSIM), так и субъективное восприятие визуального результата. На основе сравнительного анализа был предложен комбинированный метод, включающий фильтры Лапласа, Non-Local Means и Unsharp Mask, обеспечивающий оптимальный баланс между структурной чёткостью и шумоподавлением. Полученные результаты подтверждают, что использование комплексного подхода позволяет существенно повысить диагностическую ценность МРТ-снимков. В дальнейшем планируется адаптация предложенных методов к другим режимам визуализации и расширение исследования с применением нейросетевых алгоритмов оценки качества изображений.

На основе анализа существующих архитектур глубоких нейронных сетей выбран гибридный подход, сочетающий возможности свёрточных и трансформерных моделей. В качестве исследуемых архитектур использованы модели YOLO и RT-DETR, обладающие высокой эффективностью в задачах детекции и классификации медицинских изображений.

Таким образом, в данном разделе определены основные материалы и методы, обеспечивающие реализацию последующих этапов исследования. Разработанная методика формирует основу для экспериментального сравнения нейросетевых архитектур и дальнейшей интеграции интеллектуальных технологий в процесс диагностики суставных патологий.

### 3. ЭКСПЕРИМЕНТАЛЬНЫЕ ИССЛЕДОВАНИЯ И РЕЗУЛЬТАТЫ

#### 3.1 Параметры обучения и метрики оценки производительности моделей

Построение моделей осуществлялось на вычислительной платформе NVIDIA DGX A100, основными компонентами которой были: Центральный процессор – Dual AMD Rome 7742, 256 ядер, 1 ТБ; Видеокарта – 8 x NVIDIA A100 SXM4 80 ГБ Tensor Core; Операционная система: Ubuntu 22.04.5 LTS. Для построения моделей использовались платформа Torch 2.3.0 и язык программирования Python 3.10.12.

Для обучения моделей в данном исследовании были использованы следующие гиперпараметры: количество эпох – 200, размер пакета – 16, размер изображения – 640×640 пикселей. Порог IoU установлен на уровне 0,7 для более строгого сопоставления предсказаний с разметкой. Начальная скорость обучения составляла 0,01, с использованием момента 0,937 и коэффициента затухания весов 0,0005, что обеспечивало стабильную сходимость и предотвращение переобучения. Оптимизатор был выбран автоматически, а параметр `patience` = 100 позволил контролировать процесс ранней остановки, обеспечивая достаточное время для достижения оптимальной производительности моделей.

Для комплексной оценки производительности модели в задаче автоматического обнаружения разрыва мениска на МРТ-изображениях коленного сустава были использованы стандартные метрики классификации и обнаружения: Precision (P), Recall (R), F1-measure, mAP (mean Average Precision) при порогах IoU (Intersection over Union) 0,5 и 0,5–0,95, а также матрица ошибок. Пересечение по объединению (IoU) – используется для оценки точности локализации моделей обнаружения объектов. Оценка проводится на основе степени совпадения предсказанного ограничивающего прямоугольника с истинным ограничивающим прямоугольником, соответствующим данному объекту. Пусть  $B_{gt}$  – истинный ограничивающий прямоугольник,  $B_p$  – предсказанный ограничивающий прямоугольник. В области обнаружения объектов IoU равен площади перекрытия (пересечения) между прогнозируемым ограничивающим прямоугольником  $B_p$  и истинным ограничивающим прямоугольником  $B_{gt}$ , деленной на площадь их объединения, то есть [136]:

$$IoU = \frac{area(B_p \cap B_{gt})}{area(B_p \cup B_{gt})}. \quad (3.1)$$

Схематическое изображение метрики представлено на рисунке 3.1.

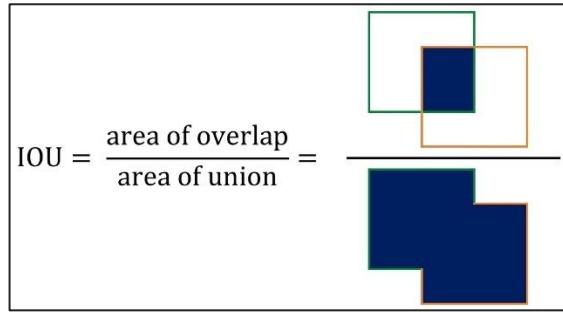


Рисунок 3.1 – Схематическое изображение метрики IoU

Значение метрики IoU находится в диапазоне от 0 до 1. Если значение IoU равно 1, это означает полное совпадение предсказанной и истинной ограничивающих рамок. При IoU, равном 0, рамки не пересекаются вовсе. Таким образом, чем выше значение IoU, тем точнее локализация объекта моделью; напротив, низкие значения отражают значительное расхождение между предсказанным и фактическим положением объекта.

Пусть:

TP (True Positives) — количество верно классифицированных случаев разрыва,

FP (False Positives) — количество ложно положительных предсказаний,

FN (False Negatives) — количество пропущенных (ложно отрицательных) разрывов,

TN (True Negatives) — количество верно распознанных случаев без разрыва.

Метрики, применяемые для оценки эффективности модели, приведены в уравнениях (2)–(4).

$$Precision(P) = \frac{TP}{TP+FP}, \quad (3.2)$$

$$Recall(R) = \frac{TP}{TP+FN}, \quad (3.3)$$

$$F1 = 2 \frac{P \times R}{P+R}. \quad (3.4)$$

Метрика F1-score применяется для оценки баланса между полнотой и точностью.

Для оценки моделей детектирования объектов использовалась метрика mean Average Precision (mAP) [137]:

- mAP@0.5: средняя точность при фиксированном пороге пересечения предсказанной и истинной областей ( $IoU \geq 0.5$ );

- mAP@0.5:0.95: средняя точность, усреднённая по 10 порогам IoU от 0.5 до 0.95 с шагом 0.05, что соответствует официальной методике оценки COCO.

Дополнительно была построена матрица ошибок, визуализирующая распределение истинных положительных, ложноположительных, истинных отрицательных и ложноотрицательных предсказаний, что позволяет провести качественный анализ ошибок модели.

Использование набора указанных метрик обеспечивает объективную и всестороннюю оценку качества работы модели как с точки зрения точности предсказаний, так и устойчивости к ложным срабатываниям и пропускам.

### 3.2 Сравнительный анализ моделей YOLOv8–x и RT–DETR–l в задаче автоматического обнаружения разрыва мениска на МРТ–изображениях коленного сустава

В рамках исследования была проведена комплексная сравнительная оценка моделей обнаружения объектов семейства YOLO, включая версии YOLOv5 (конфигурации n, s, m, lu, xu), YOLOv9 (конфигурации t, s, m, c, e) и YOLOv8, YOLOv10–YOLOv12 (конфигурации n, s, m, l, x). В качестве альтернативного подхода были рассмотрены и протестированы модели RT–DETR в вариантах Large и Extra–Large. Обе архитектуры использовались для решения задачи бинарной классификации наличия разрыва мениска на МРТ–изображениях с последующей локализацией патологической зоны. Сравнение проводилось на одних и тех же исходных данных.

Показатели производительности моделей семейств YOLO и RT–DETR по основным метрикам Precision, Recall, mAP@50 и mAP@50–95 приведены в таблице 3.1.

Таблица 3.1 – Производительность моделей YOLO и RT–DETR

Architecture	Version	Precision	Recall	mAP50	mAP50–95
YOLOv5	n	0.964	0.945	0.977	0.587
	s	0.956	0.939	0.964	0.583
	m	0.956	0.948	0.972	0.6
	l	0.965	0.948	0.975	0.605
	x	0.958	0.941	0.975	0.604
YOLOv8	n	0.973	0.947	0.978	0.594
	s	0.965	0.951	0.977	0.6
	m	0.968	0.95	0.974	0.601
	l	0.945	0.953	0.97	0.612
	x	0.958	0.961	0.975	0.616
YOLOv9	t	0.961	0.947	0.975	0.589
	s	0.968	0.953	0.975	0.604
	m	0.959	0.955	0.974	0.601
	c	0.96	0.942	0.971	0.601
	e	0.966	0.962	0.976	0.605
YOLOv10	n	0.948	0.941	0.964	0.571
	s	0.954	0.95	0.974	0.595
	m	0.953	0.95	0.978	0.582
	l	0.95	0.946	0.969	0.6
	x	0.965	0.931	0.972	0.612

YOLOv11	n	0.96	0.937	0.974	0.596
	s	0.959	0.954	0.977	0.59
	m	0.949	0.963	0.977	0.587
	l	0.974	0.948	0.975	0.597
	x	0.962	0.942	0.978	0.606
YOLOv12	n	0.957	0.946	0.973	0.592
	s	0.96	0.951	0.978	0.59
	m	0.97	0.945	0.979	0.584
	l	0.955	0.956	0.972	0.591
	x	0.956	0.956	0.973	0.595
RT-DETR	l	0.919	0.952	0.929	0.531
	x	0.898	0.889	0.906	0.434

В медицинской диагностике, особенно при анализе МРТ-изображений, важно не только правильно найти патологические объекты, но и точно определить их границы. Метрика  $mAP@50-95$  является признанным международным стандартом для оценки качества детекции [140, 141]. В отличие от  $mAP@0.5$ , рассчитываемой при одном пороге перекрытия ( $IoU = 0.5$ ), метрика  $mAP@50-95$  учитывает диапазон  $IoU$  от 0.5 до 0.95 с шагом 0.05. Это позволяет более точно оценить, насколько хорошо модель определяет форму и местоположение объектов, что особенно важно в медицине, где даже небольшие ошибки могут привести к неправильной интерпретации и диагностике. Вместе с тем, не менее важна метрика  $Recall$ , которая показывает, насколько полно модель обнаруживает все объекты на изображении. В медицинской практике пропуск даже одного патологического участка может иметь серьёзные последствия, поэтому высокая чувствительность ( $Recall$ ) имеет большое значение. В свою очередь, часто существует компромисс между точностью и полнотой: улучшение точности может снизить полноту, и наоборот. Поэтому, чтобы достичь оптимальной производительности обнаружения, необходимо сбалансировать эти две метрики [140]. Также в случае несбалансированных наборов данных, где один класс значительно превосходит другие, точность может вводить в заблуждение. В таких случаях  $Recall$  для меньшинства классов часто является более информативной метрикой [124]. Таким образом, использование обеих метрик –  $mAP@50-95$  и  $Recall$  – позволяет всесторонне оценить работу модели: как по точности локализации, так и по полноте обнаружения, что особенно важно для задач медицинской визуализации. На рисунке 3.2 представлены результаты моделей, показавших наилучшие значения по метрикам  $mAP@50-95$  и  $Recall$ , как по семейству YOLO, так и по RT-DETR.

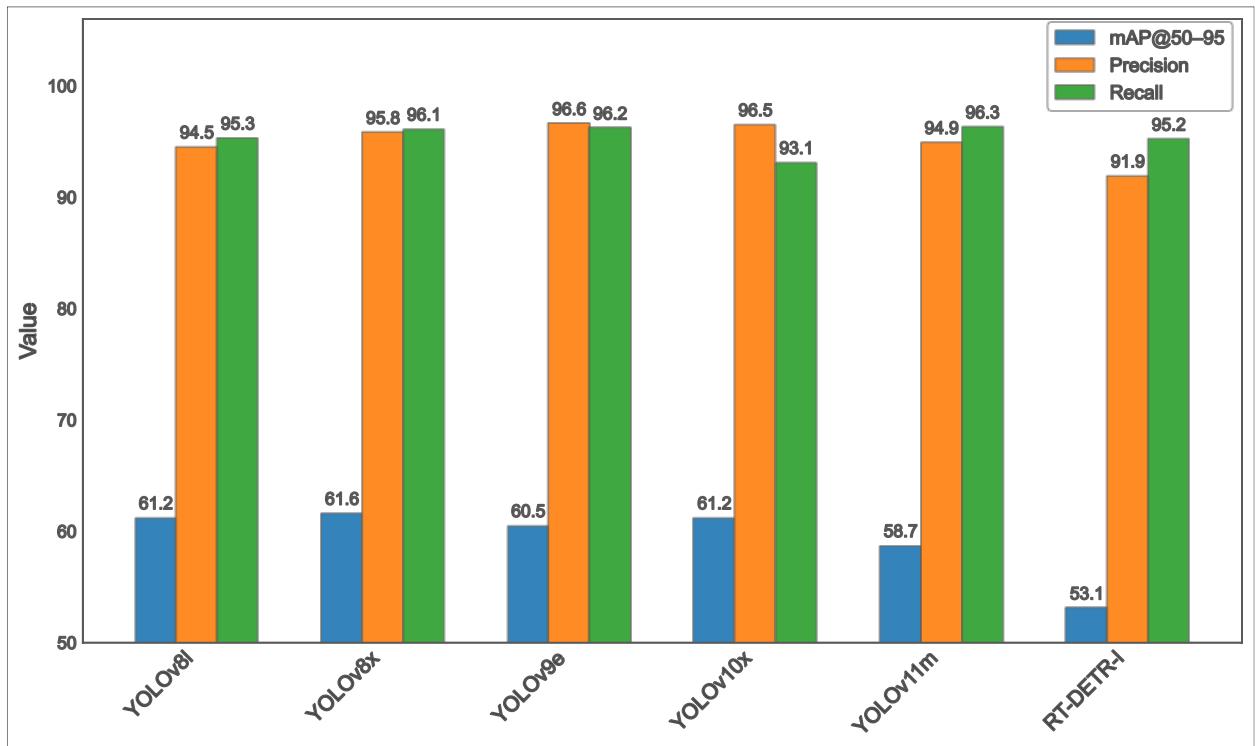


Рисунок 3.2 – Значения ключевых метрик качества (mAP@50–95, Precision, Recall) для наиболее эффективных моделей по семействам YOLO и RT-DETR

В результате сравнения моделей семейств YOLO и RT-DETR были определены модели, продемонстрировавшие наивысшие значения ключевых метрик. Как видно из рисунка, модели семейства YOLO достигают более высоких значений по метрике mAP@50–95, что свидетельствует об их лучшей общей точности распознавания объектов. В то же время модель RT-DETR-1 показывает достойные результаты по метрикам Precision и особенно Recall (95,2), что говорит о её высокой способности обнаруживать большинство объектов. Таким образом, наиболее эффективной моделью среди YOLO является YOLOv8x, а среди моделей RT-DETR – RT-DETR-1.

Рисунок 3.3 показывает, как менялась функция потерь на протяжении обучения, что отражает эффективность работы данных моделей по эпохам.

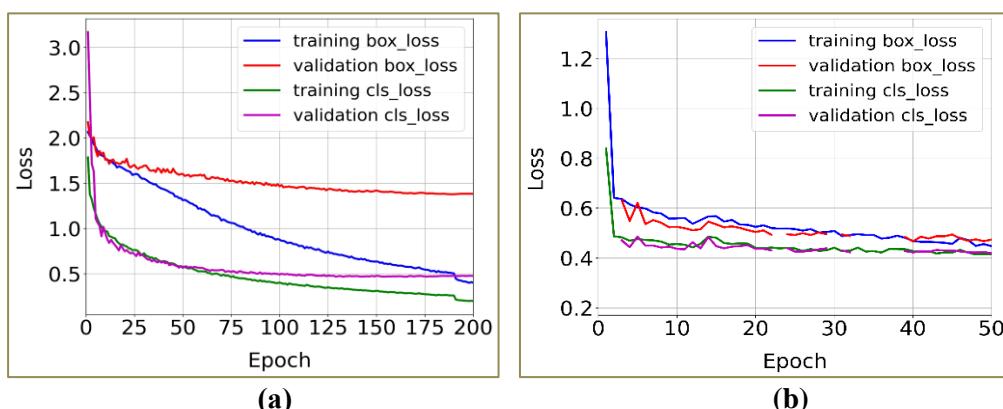


Рисунок 3.3 – Кривые потерь за эпоху для моделей (a) YOLOv8-x и (b) RT-DETR-1

Рисунок 3.4 демонстрирует изменение метрик производительности (mAP@50–95, Precision, Recall), позволяющее отследить поведение моделей по мере обучения.

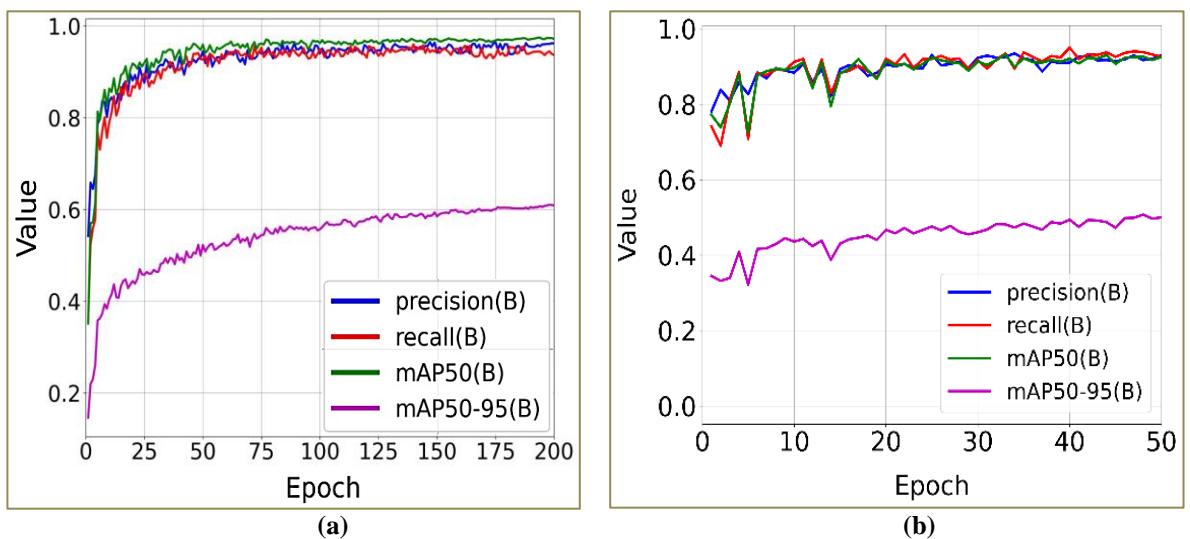


Рисунок 3.4 – Показатели производительности за эпохи для моделей (а) YOLOv8-x и (б) RT-DETR-1

Как показано на рисунке 3.4, все четыре метрики – Precision, Recall, mAP@50 и mAP@50–95 в целом показывают схожее поведение: в начале обучения значения немного колеблются, а затем постепенно улучшаются и стабилизируются.

У модели YOLOv8-x ближе к 10-й эпохе все значения значительно повышаются, особенно точность и полнота, которые почти сразу выходят на уровень выше 0.9. Метрика mAP@50–95 растёт более плавно, но стабильно до самого конца обучения, что говорит о хорошем качестве распознавания сложных объектов. RT-DETR-1 достигла стабильных показателей точности и полноты уже в первые 10 эпох, однако значения mAP@50–95 оставались на более низком уровне и росли медленнее, что может указывать на ограниченную способность модели к точной локализации объектов различного масштаба в рамках заданного количества эпох.

Поведение моделей на тестовой выборке было дополнительном проанализировано с помощью кривых зависимости Precision, Recall и F1-score от confidence threshold (Рисунки 3.5–3.8), а также с использованием матриц ошибок (Рисунок 3.9). Эти оценки позволили выявить, как изменяется точность и полнота предсказаний при различных уровнях уверенности, а также какие типичные ошибки классификации совершают модели.

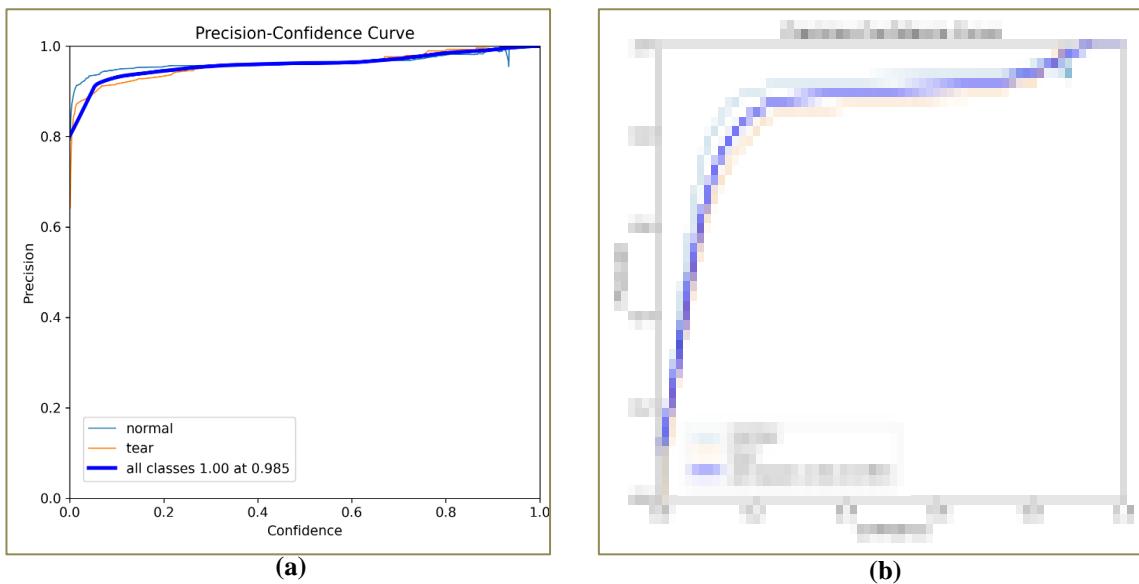


Рисунок 3.5 – Кривые зависимости точности и уверенности для моделей  
 (a) YOLOv8-x и (b) RT-DETR-1

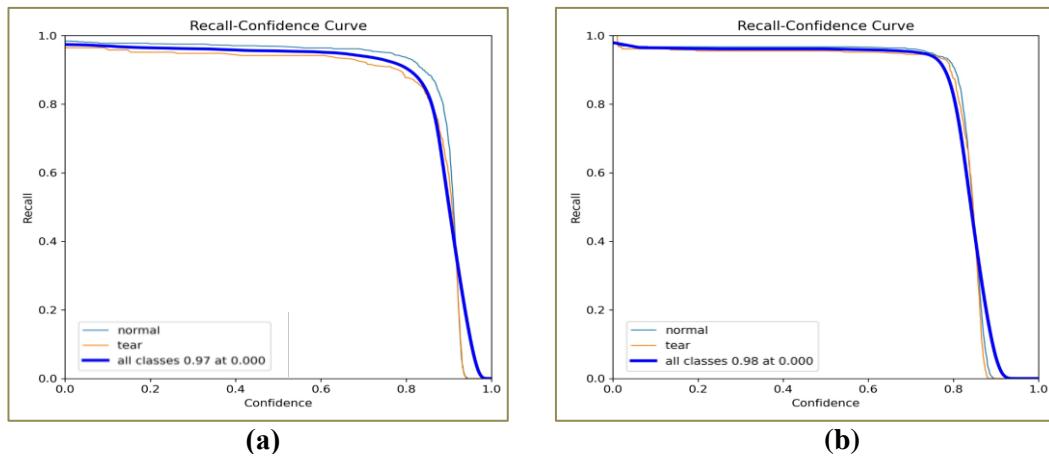


Рисунок 3.6 – Кривые зависимости полноты и уверенности для моделей  
 (a) YOLOv8-x и (b) RT-DETR-1

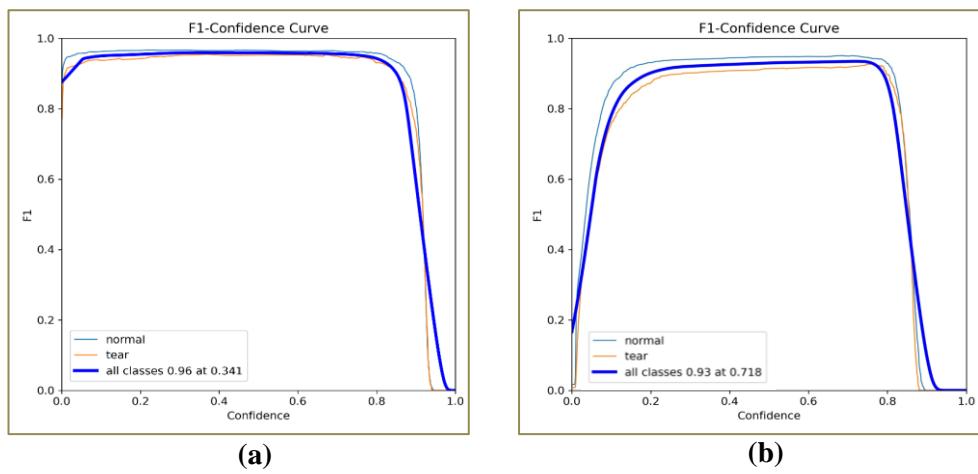


Рисунок 3.7 – Кривые зависимости достоверности F1-score для моделей  
 (a) YOLOv8-x и (b) RT-DETR-1

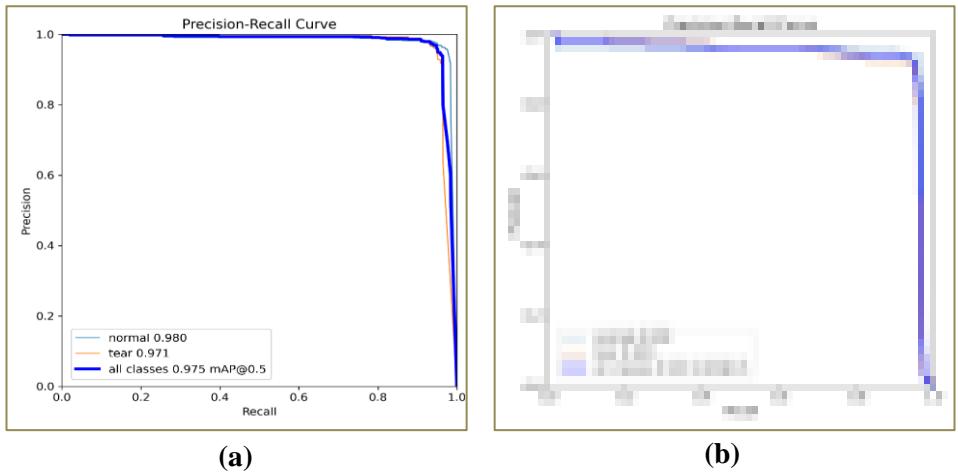


Рисунок 3.8 – Кривые зависимости точности и полноты для моделей  
(a) YOLOv8–x и (b) RT–DETR–1

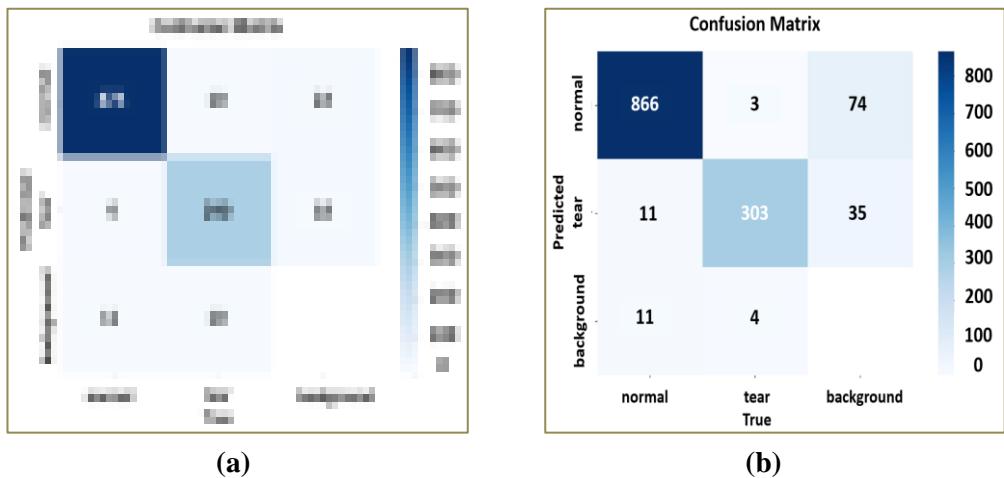


Рисунок 3.9 – Матрицы ошибок моделей (a) YOLOv8–x и (b) RT–DETR–1

Как показано на рисунках 3.5–3.8, кривые зависимости точности (Precision), полноты (Recall) и F1–оценки от порога confidence позволяют оценить, как изменяется поведение моделей при различной степени уверенности в предсказаниях.

Модель YOLOv8–x достигает 100% точности для всех классов при уровне confidence 0.985, в то время как RT–DETR–1 — при уровне 0.935. На рисунке 3.5 (а) кривые модели YOLOv8–x демонстрируют более крутой подъем в начальной части графика, отражая достижение высокой точности уже при низких значениях confidence. На графике Recall–Confidence модель YOLOv8–x показывает более стабильные и высокие значения recall при увеличении confidence. У RT–DETR–1 наблюдается более раннее снижение полноты, особенно по классу «tear». На рисунке 3.7 модель YOLOv8–x достигает максимальной F1–оценки 0.96 при confidence 0.341, в то время как RT–DETR–1 — значения 0.938 при confidence 0.72. Кривые точность–полнота (PR) на рисунке 3.8 для модели YOLOv8–x располагаются ближе к верхнему правому углу для обоих классов («normal» и «tear»), при этом значения AP приближаются к 1.0. У модели RT–DETR–1 PR–кривые также демонстрируют высокие значения, но имеют менее выраженную выпуклость, особенно по

классу «tear». Наконец матрицы ошибок (Рисунок 3.9), отражают распределение корректных и ошибочных классификаций по каждому из классов, предоставляя дополнительную информацию о надежности модели и природе ошибок классификации.

Как видно из матриц ошибок, модель YOLOv8-x продемонстрировала меньшее количество ошибок по сравнению с RT-DETR-1. Класс «normal» был ошибочно отнесен к «background» в 22 случаях, тогда как у RT-DETR-1 таких ошибок было 74, что свидетельствует о более высокой чувствительности YOLOv8-x к нормальным структурам. Аналогично, для класса «tear» YOLOv8-x допустила 4 ошибки, перепутав его с классом «normal», и 18 ошибок — с «background», в то время как RT-DETR-1 ошиблась в 11 и 35 случаях соответственно. Наибольшее количество корректных классификаций в обеих моделях также приходится на класс «normal», что скорее всего связано с его численным преобладанием в выборке.

### **3.3 Анализ ошибочной классификации и ложного обнаружения**

В процессе обучения и тестирования моделей YOLOv8-x и RT-DETR-1 были зафиксированы случаи ошибочной классификации и ложного обнаружения, характерные для задач медицинской визуализации, в частности, при анализе МРТ-снимков коленного сустава. Выявленные ошибки обусловлены как ограничениями моделей, так и особенностями входных данных.

МРТ-снимки, использованные в данном исследовании, поступали, как правило, в Национальный научный центр травматологии и ортопедии им. Батченова из различных регионов страны, где обследования проводились на оборудовании разных производителей и с использованием разнообразных протоколов сканирования. Это обусловило значительную неоднородность качества изображений: наблюдались различия в разрешении, контрастности, размере и чёткости визуализации анатомических структур. Несмотря на выполнение предварительной обработки для повышения качества снимков, вариативность технических параметров сохранялась и оказывала влияние на стабильность и точность автоматического распознавания.

Ошибки моделей можно сгруппировать по следующим основным причинам:

- разнородность качества изображений: отличия в характеристиках сканирования (магнитное поле, матрица, срезы, настройки усиления сигнала и т.д.) приводили к вариациям визуального представления мениска, что осложняло единообразное извлечение признаков;

- использование различных режимов визуализации (PD, T1, T2). В исследовании были использованы МРТ-снимки, полученные в разных режимах визуализации, таких как PD, T1 и T2. Каждый из этих режимов имеет свои особенности контрастирования и по-разному отображает тканевые структуры. В результате признаки разрыва могли визуализироваться с разной степенью выраженности в зависимости от

режима, что создавало дополнительную нагрузку на модель и снижало стабильность классификации между случаями, полученными в различных параметрах съёмки;

– слабо выраженные признаки разрыва: некоторые патологические изменения проявляются слабо или частично. Это соответственно усложняло процесс автоматического распознавания и в некоторых случаях приводило к ошибочной классификации;

– артефакты и шумы: механические или программные помехи, присутствующие на отдельных снимках, а также тени, перегревы и перекрытие костными структурами, увеличивают вероятность ложного срабатывания модели;

– многомасштабность и различия в анатомии: значительное разнообразие размеров, форм и расположения менисков у разных пациентов создаёт дополнительную нагрузку на модель в плане обобщающей способности, особенно при ограниченном числе обучающих примеров таких вариаций.

Следует отметить, что фокус исследования на горизонтальных разрывах мениска, обусловленный критериями отбора данных, мог повлиять на характер и частоту ошибок классификации. Отсутствие обучения на других морфологиях разрывов (например, радиальных и по типу «ручка лейки») ограничивает способность модели корректно обрабатывать такие случаи. Для повышения универсальности и клинической применимости методологии необходимо расширить исходный набор данных и провести дополнительное обучение на изображениях с различными типами разрывов.

Полученные результаты обозначают ряд аспектов, которые могут быть учтены при дальнейшем совершенствовании моделей, включая повышение чувствительности к слабо выраженным признакам, а также повышение устойчивости к различиям в режимах визуализации и качеству изображений.

### **3.4 Сравнение моделей по эффективности обнаружения и скорости обработки**

Ключевым вопросом при выборе оптимальной модели является определение требований, которым она должна соответствовать. Модель, рекомендуемая на основе данного исследования, должна, с одной стороны, обнаруживать как можно больше объектов интереса на изображении (обладать высокой полнотой), а с другой стороны, выполнять процесс обнаружения объектов с максимально возможной точностью (обладать высоким mAP). График на рисунке 3.10 даёт хорошее представление о заданных критериях. Точки, видимые на этом графике, представляют пары значений (полнота, mAP50–95) для отдельных моделей. Модели, соответствующие заданным требованиям, отмечены на рисунке 3.10 серой пунктирной линией, а нижняя часть графика показывает увеличенную область диапазона значений интереса (полнота, mAP50–95). Исходя из этого, можно сделать вывод о целесообразности более подробного анализа свойств следующих моделей: YOLOv11-m, YOLOv8-x и YOLOv9-e. Модель

YOLOv8–x имеет полноту, сопоставимую с моделями YOLOv9–e и YOLOv11–m, но достигла наибольшего значения параметра mAP50–95 (61,6%). Следует отметить, что значения анализируемых метрик производительности моделей RT–DETR–l и RT–DETR–x значительно хуже значений метрик остальных моделей семейства YOLO.

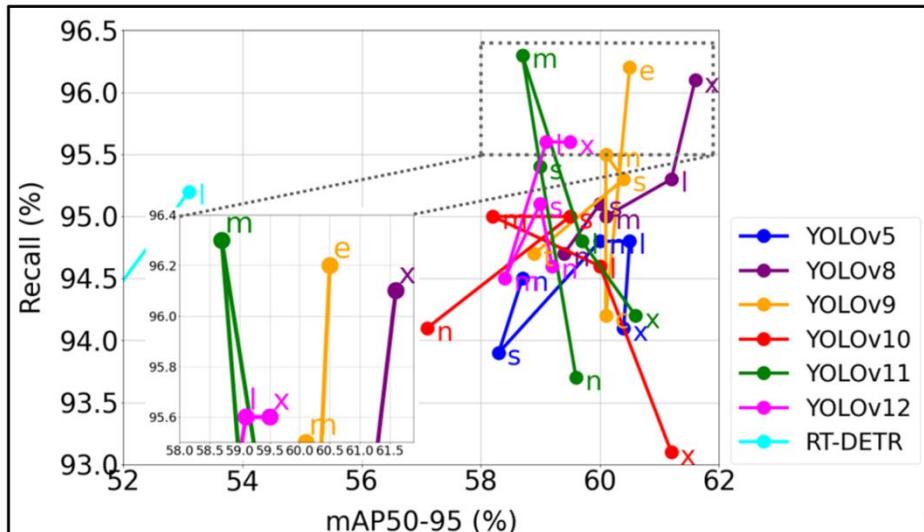


Рисунок 3.10 – Значения показателей полноты и mAP@50–95 построенных моделей

Вторым критерием выбора модели является то, что она должна выполнять процесс обнаружения в кратчайшие возможные сроки (иметь короткое время вывода). На рисунке 3.11 серая пунктирная линия отмечает область пар значений (полнота, время вывода), которые удовлетворяют требованию возможно высокого значения полноты и низкого или среднего времени вывода. Среднее время вывода предполагалось равным половине самого длительного времени вывода, принадлежащего модели YOLOv12–x (16,9 мс). Выбранная область показана в нижней части рисунка 19 в увеличенном виде. Все ранее выбранные модели соответствовали второму критерию. Модели YOLOv8–x и YOLOv9–e имеют среднее время вывода (7,7 мс). Модель YOLOv11–m, в свою очередь, достигла наименьшего времени вывода (2,7 мс), однако её значение параметра mAP50–95 (58,7%) значительно ниже, чем mAP50–95 двух других моделей — 60,5% (YOLOv9–e) и 61,6% (YOLOv8–x). Модели архитектуры RT–DETR достигли среднего времени вывода (от 6 до 8 мс), но их полнота оказалась ниже, чем у лучших моделей семейства YOLO.

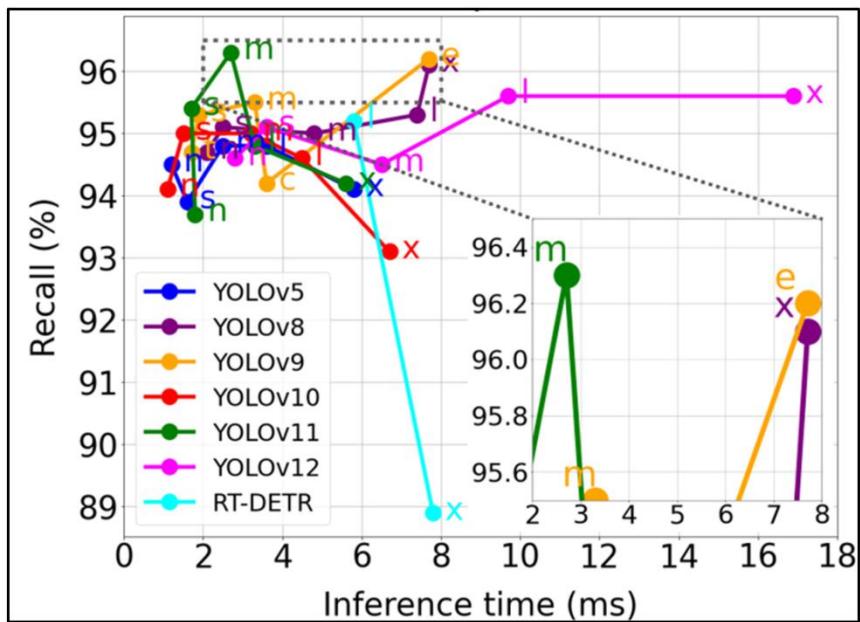


Рисунок 3.11 – Значения времени припоминания и вывода построенных моделей

На основании предыдущего анализа можно сделать вывод, что модель YOLOv8–x может быть рекомендована для обнаружения разрывов мениска. Время вывода этой модели составляет 7,7 мс. Следует отметить, что общее время обработки кадра изображения ( $t_{proc}$ ) состоит из трёх компонентов: времени предварительной обработки ( $t_{pre}$ ), времени вывода ( $t_{infer}$ ) и времени постобработки ( $t_{post}$ ). Для модели YOLOv8–x эти времена были следующими:  $t_{proc} = t_{pre} + t_{infer} + t_{post} = 0,5 \text{ мс} + 7,7 \text{ мс} + 2,7 \text{ мс} = 10,9 \text{ мс}$ . Это значение даёт теоретическую скорость обработки 92 кадра в секунду ( $1000 \text{ мс}/10,9 \text{ мс} \approx 92$  кадра в секунду). Фактическая скорость обработки ниже, поскольку существуют дополнительные задержки, связанные с такими операциями, как захват изображения, отображение результатов на экране и т. д. В результате FPS зависит от архитектуры модели и аппаратно-программной платформы, на которой работает модель. Скорость обработки модели была протестирована с использованием персонального компьютера со следующей конфигурацией: операционная система Windows 10 64-bit, процессор Intel Core i7-4770 3.4 GHz, 32 GB RAM, графический процессор NVIDIA GeForce GTX 1660 Ti, 6 GB GDDR6, платформа PyTorch 2.1.2 и язык программирования Python 3.10. Средняя скорость обработки составила 13 FPS. Этого значения достаточно для использования модели на типичных компьютерных системах со средней вычислительной производительностью. Также следует отметить, что FPS более важен для обработки видео, но в контексте представленного исследования более важны полнота и средняя средняя точность обнаружения разрыва мениска.

### 3.5 Сравнение производительности моделей YOLOv8-x и RT-DETR-1

На основании данных, представленных в разделе 3.2, модель YOLOv8-x демонстрирует значительные преимущества перед RT-DETR-1, подтверждая её превосходную производительность в задачах медицинской диагностики и классификации на МРТ-изображениях коленного сустава. Эти улучшения обусловлены как архитектурными преимуществами YOLOv8-x, так и более эффективными стратегиями обучения, которые позволяют модели надёжно работать даже с ограниченным количеством визуальных признаков. В частности, YOLOv8-x более эффективно обрабатывает слабо выраженные структуры благодаря своей способности интегрировать признаки на нескольких уровнях. В отличие от этого, было обнаружено, что RT-DETR-1 более чувствительна к качеству изображения, что снижает её надёжность при изменении контрастности и резкости.

YOLOv8-x демонстрирует превосходную производительность по сравнению с RT-DETR-1 по всем ключевым метрикам оценки, что свидетельствует о его более высокой эффективности в задачах обнаружения объектов на медицинских изображениях. Улучшения касаются как точности обнаружения, так и способности модели надёжно идентифицировать и классифицировать объекты в различных условиях. Точность YOLOv8-x составляет 0,958 по сравнению с 0,919 у RT-DETR-1, а полнота достигает 0,961 против 0,952 соответственно. Эти метрики отражают более высокую надёжность YOLOv8-x в снижении как ложноположительных, так и пропущенных обнаружений.

Оценка mAP@50 для YOLOv8-x составляет 0,975, что превышает показатель 0,929, достигнутый RT-DETR-1. Преимущество становится еще более выраженным при более строгом критерии mAP@50-95, где оценка YOLOv8-x составляет 0,616 по сравнению с 0,531 для RT-DETR-1. Эти различия подтверждают большую надежность YOLOv8-x в точной локализации и классификации объектов даже в сложных сценариях. Анализ кривых «точность–достоверность» показывает, что YOLOv8-x достигает максимальной точности при пороге достоверности 0,985, в то время как RT-DETR-1 требуется всего 0,935 для достижения аналогичного уровня. Это указывает на более надежную стратегию прогнозирования в YOLOv8-x.

Кривые для YOLOv8-x демонстрируют более крутой начальный подъём и более стабильное поведение по мере повышения порога доверия, особенно для класса «tear». Напротив, RT-DETR-1 теряет память гораздо быстрее. Такая стабильность критически важна в клинических условиях, где минимизация количества пропущенных детектирований имеет первостепенное значение.

Аналогичные выводы подтверждаются анализом кривых достоверности F1. YOLOv8-x достигает максимального значения F1-оценки (0,96) уже при доверительной вероятности 0,341, тогда как RT-DETR-1 показывает максимум (0,93) только при значительно более высоком пороге (0,718). Это указывает на более надёжный баланс между точностью и полнотой работы

YOLOv8–x, что критически важно при анализе медицинских изображений, содержащих малозаметные патологические признаки.

Подробный анализ матрицы ошибок также подтверждает преимущество модели YOLOv8–x. Модель RT–DETR–l ошибочно классифицировала изображения с нормальным мениском как фон в 74 случаях, тогда как YOLOv8–x допустила такие ошибки только 22 раза. Для изображений с разрывами мениска RT–DETR–l классифицировала их как нормальные в 11 случаях и как фон в 35 случаях, тогда как YOLOv8–x допустила только 4 ошибочные классификации как нормальные и 18 как фоновые. Эти различия указывают на то, что RT–DETR–l менее устойчива к визуальной изменчивости, включая едва заметные признаки повреждения и фоновый шум. Это особенно важно в клинических условиях, где разрывы мениска часто проявляются незначительными изменениями сигнала или частично маскируются анатомическими структурами. Модель YOLOv8–x продемонстрировала более высокую точность и стабильность в таких случаях, о чем свидетельствует значительно меньшее количество ложноотрицательных результатов и ошибочных классификаций.

Дополнительным фактором, влияющим на результаты, является структурный дисбаланс классов в обучающей выборке. Несмотря на наличие изображений как с нормальными, так и с поврежденными менисками, количественно преобладали объекты класса «норма». Это обусловлено особенностями аннотации: в случае «нормы» оба мениска были отмечены как отдельные объекты, тогда как в случае разрыва была аннотирована только одна патологическая структура. В результате доля объектов класса «норма» составила 5992 против 1998 объектов класса «разрыв». Такой дисбаланс не отражает реальной распространенности патологий, но влияет на поведение модели, смещаая акцент в сторону «нормы». Наибольшее количество ошибок в обеих моделях зафиксировано именно между классами «разрыв» и «фон», что может быть связано с низкой контрастностью отдельных изображений, на которых разрыв был плохо визуализирован, что затрудняло его локализацию как для модели, так и для человека.

В целом, YOLOv8–x демонстрирует более высокую адаптивность, устойчивость к изменению порога доверия, лучшую локализацию и классификацию объектов, а также меньшую чувствительность к дисбалансу классов по сравнению с RT–DETR–l. Повышенная точность распознавания даже в условиях лёгких патологий и визуального шума делает её предпочтительной моделью для автоматизированного анализа МРТ–изображений коленного сустава в клинической практике.

Для оценки эффективности предлагаемого подхода были собраны результаты нескольких других исследований в той же области [85, 142-145]. Сводные показатели представлены в таблице 3.2 и указывают на сопоставимый уровень точности.

Таблица 3.2 – Сравнение с другими исследованиями

№	Цель исследования	Исходные данные	Метод	Показатели производительности
Наше исследование	Применение моделей семейства YOLO и RT-DETR в распознавании разрывов мениска	MPT снимки коленного сустава (1000 normal, 1000 tear)	Модели YOLOv5, YOLOv8–YOLOv12 со всеми доступными подмоделями (n, s, m, l, x)	mAP@0.5–0.95 = 0.616 ACC = 95.8% TPR = 96.1%
[140]	Создание и оценка алгоритма для обнаружения и характеристики наличия разрыва мениска	1123 МРТ изображений колена	Сверточная нейронная сеть (CNN), CNN на быстрых регионах (RCNN)	AUC = 92% для определения положения двух рогов мениска AUC = 94% для наличия разрыва мениска AUC = 83% для определения ориентации разрыва
[85]	Извлечение областей интереса мениска из изображений МРТ колена	Наборы данных: 1)FastMRI –10 012 DICOM изображений колена; 2)MRNet – 1370 МРТ колена	Модели YOLOv8–x–seg, YOLOv8–x–seg–рб, YOLOv9c–seg, YOLOv9e–seg, YOLOv11–seg	ACC = 94% TPR = 93% F1 = 93%
[141]	Оценка подхода глубокого обучения для обнаружения разрывов мениска и их характеристика	11 353 МРТ обследований коленного сустава	Нейронная сверточная сеть CNN	AUC = 93% TPR = 82% TNR = 95%
[142]	Диагностика разрыва мениска коленного сустава	Стандартные изображения МРТ колена 924 пациентов	Маскированная региональная сверточная нейронная сеть (R–CNN), ResNet50	AP = 68–80 % TPR = 74–95%
[143]	Систематический обзор моделей DL для МРТ колена	Более 20 исследований по автоматическому выявлению разрывов мениска	Обзор моделей CNN, ResNet, DenseNet и др.	ACC = 77–100%, TPR = 56.9–71.1%, TNR = 67–93%

В исследовании [142] был описан алгоритм на основе CNN, способный обнаруживать разрывы мениска. Основная задача исследования была разделена на три подзадачи: определение положения обоих рогов мениска, обнаружение наличия разрыва и определение ориентации разрыва. Метрика производительности основывалась на анализе площади под кривой (AUC) для каждой подзадачи. Результаты алгоритма были следующими: AUC = 92% для определения положения двух рогов мениска, AUC = 94% для наличия разрыва мениска и AUC = 83% для определения ориентации разрыва. В исследовании [85], аналогично нашему исследованию, была выполнена бинарная классификация разрывов мениска на изображениях МРТ коленного сустава, где модель обучалась на клинических данных с использованием многоуровневой архитектуры CNN, оптимизированной для обнаружения как

наличия разрывов, так и их морфологического типа. Модель продемонстрировала высокую производительность для бинарной классификации (AUC до 0,924) и удовлетворительные результаты для распространенных типов разрывов. Однако ее точность снижалась для редких морфологий из-за их низкой представленности в обучающем наборе. Таким образом, обученная модель использовала относительно простую архитектуру AlexNet для классификации без указания локализации или типа разрыва и без включения современных модулей, таких как остаточные связи или механизмы внимания. Напротив, в нашем исследовании обнаружение реализуется с использованием ограничивающих рамок, используются современные модели, такие как YOLOv8 и RT-DETR, и применяется более строгая метрика mAP@50–95, что обеспечивает улучшенную точность, большую клиническую интерпретацию и расширенную практическую применимость нашей модели. Исследование [141], аналогичное нашему, было проведено для обнаружения травм мениска, но с использованием сверточной нейронной сети CNN. Как и в нашем исследовании, была создана аннотированная база данных коронарных и сагиттальных МРТ-изображений коленного сустава. Алгоритм глубокого обучения продемонстрировал высокую эффективность в обнаружении травм мениска коленного сустава и показал результаты, близкие к полученным нами, но все же не превышающие их. В [144] маскированная региональная сверточная нейронная сеть (R-CNN) была использована для построения структуры сети глубокого обучения для обнаружения и диагностики разрывов мениска коленного сустава, а ResNet50 был принят для разработки магистральной сети. Маскированный R-CNN показал довольно хорошие результаты: средняя точность для трех типов мениска (здоровый, разорванный и дегенерированный мениск) составила от 68% до 80%; чувствительность составила от 74% до 95%. Авторы [145] представили систематический обзор методов глубокого обучения на МРТ для разрывов мениска, где ACC составила от 77 до 100%, чувствительность от 57 до 71% и специфичность от 67 до 93%, что указывает на значительную вариабельность и нестабильность в ряде решений в литературе.

По сравнению с вышеупомянутыми исследованиями, модель YOLOv8-x, предложенная в настоящем исследовании, демонстрирует превосходные результаты: ACC = 96,0, TPR = 96,1, F1 = 96,0 и mAP@0,5:0,95 = 0,616. Особого внимания заслуживает достигнутое значение чувствительности, TPR = 96,1, которое является самым высоким среди всех рассмотренных исследований. Это подтверждает высокую способность модели выявлять даже незначительные разрывы мениска, минимизируя риск пропуска патологии.

Полученные результаты подтверждают высокую точность, стабильность и надежность модели YOLOv8-x при работе с клиническими МРТ-изображениями. Это отражено как в основных метриках качества (mAP, точность, полнота, F1), так и в анализе матрицы ошибок, который демонстрирует низкое количество ложных классификаций и высокую чувствительность (TPR = 96,1). Особое значение имеет способность модели

правильно различать нормальные и поврежденные структуры в пределах одного изображения, что соответствует реальным диагностическим условиям. В отличие от предыдущих исследований (таблица 3.2), в нашем исследовании используется более крупный и разнообразный собственный клинический набор данных, применяется более строгая метрика  $mAP@50-95$  вместо одной  $mAP@50$ , включает сравнение двух современных архитектур (YOLOv8-x и RT-DETR) и фокусируется на практической клинической задаче бинарной классификации, тем самым повышая прикладную ценность и объективность результатов.

Помимо стандартных метрик, была проведена дополнительная количественная оценка надежности прогнозов модели на основе анализа распределения значений уверенности среди правильно классифицированных объектов. Такой подход позволил оценить уверенность модели в своих прогнозах и подтвердить её устойчивость при различных порогах уверенности. Для корректной интерпретации полученных значений важно понимать, что представляет собой уверенность и как она вычисляется в модели.

Метрика  $confidence$  в задачах обнаружения объектов отражает степень уверенности модели в том, что в заданной области изображения действительно присутствует объект определённого класса. Как определено в уравнении, уверенность определяется двумя основными факторами:

$$Confidence = P(Object) \times IoU(pred, truth), \quad (3.5)$$

где  $P(Object)$  – предсказанная вероятность наличия объекта в ограничивающем прямоугольнике, а  $IoU$  – мера перекрытия между предсказанной и истинной рамкой. Таким образом,  $confidence$  одновременно учитывает вероятностную достоверность классификации и качество локализации, выступая в роли комплексного индикатора точности. Более высокие значения  $confidence$  (например,  $\geq 0.9$ ) свидетельствуют о высокой уверенности модели в корректности предсказания, тогда как низкие значения ( $\leq 0.5$ ) могут указывать на ненадёжные или ошибочные детекции. На этапе постобработки значения уверенности используются для фильтрации прогнозов и управления подавлением немаксимума (non-maximum suppression, NMS), которое напрямую влияет на точность и полноту модели [146].

После применения модели YOLOv8-x к тестовому набору данных надёжность её предсказаний оценивалась по следующей схеме:

1. Сопоставление с эталонными разметками (ground truth): предсказания модели сопоставлялись с истинными ограничивающими рамками. Предсказание считалось корректным (true positive, TP), если значение  $IoU$  превышало заданный порог ( $IoU = 0.7$ ) и класс совпадал.

2. Фильтрация по порогам  $confidence$ : среди TP-предсказаний выделялись те, у которых  $confidence$  превышал установленные значения (например, 0.80, 0.85, 0.90). Для каждого порога рассчитывалась доля

надёжных предсказаний; соответствующие результаты представлены в таблице 3.3

Таблица 3.3 – Надёжность модели при разных порогах confidence

Confidence	Test samples	Reliable TPs (%)
$\geq 0.80$	79 %	95.67%
$\geq 0.85$	77,1%	93.05%
$\geq 0.90$	63,8%	77.04%

Обученная модель YOLOv8-x успешно идентифицировала все тестовые изображения, при этом более 77% образцов были распознаны с показателем достоверности выше 85%, а в 79% случаев – выше 80%, что свидетельствует о высокой устойчивости модели при различных уровнях confidence.

На рисунке 3.12 представлена общая схема системы обнаружения и классификации повреждений мениска на МРТ изображениях коленного сустава с использованием модели YOLOv8-x, которая показала наивысшие показатели качества (Precision – 0,958, Recall – 0,961, mAP@50 – 0,975, mAP@50–95 – 0,616). После улучшения качества данных изображения подаются на вход модели YOLOv8-x. Модель YOLOv8-x обнаруживает объекты на данных и определяет их принадлежности к одному из классов (normal, tear). После успешной локализации модель анализирует вероятности принадлежности объекта к одному из возможных классов. Таким образом, на основе этих предсказаний объекту присваивается метка того класса, где для которого вероятность оказалась наибольшей – «tear» (при наличии признаков повреждения) или же «normal» (при отсутствии признаков повреждения).

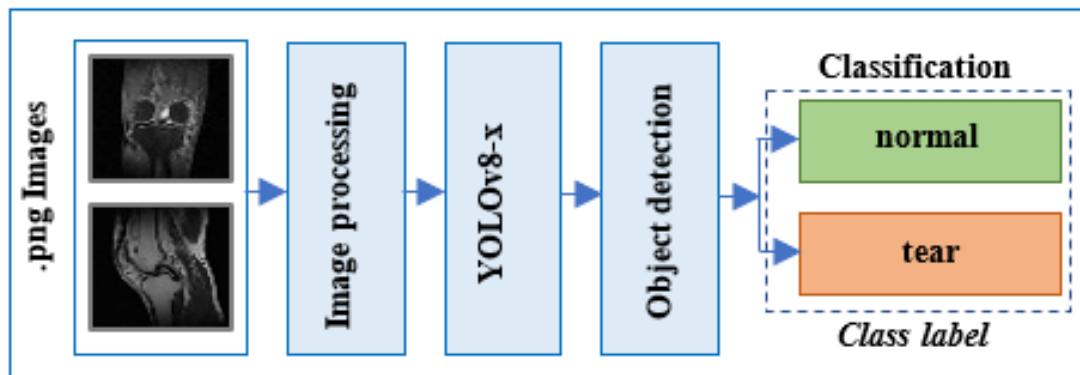


Рисунок 3.12 – Общая схема системы обнаружения и классификации повреждений мениска

Для качественной оценки работы моделей были визуализированы примеры как корректных, так и ошибочных предсказаний. В большинстве случаев успешной классификации, представленных на рисунке 3.13 (а), модели точно локализовали и распознавали разрывы мениска при различной

форме и расположении патологий. Ошибочные предсказания, показанные на рисунке 3.13 (b), как правило, возникали в условиях выраженной визуальной вариативности – при слабо выраженных признаках повреждений или наличии фоновых структур, затрудняющих интерпретацию. В отдельных случаях мениск визуально выглядел существенно уменьшенным, что затрудняло извлечение устойчивых признаков и становилось фактором, влияющим на снижение точности классификации.

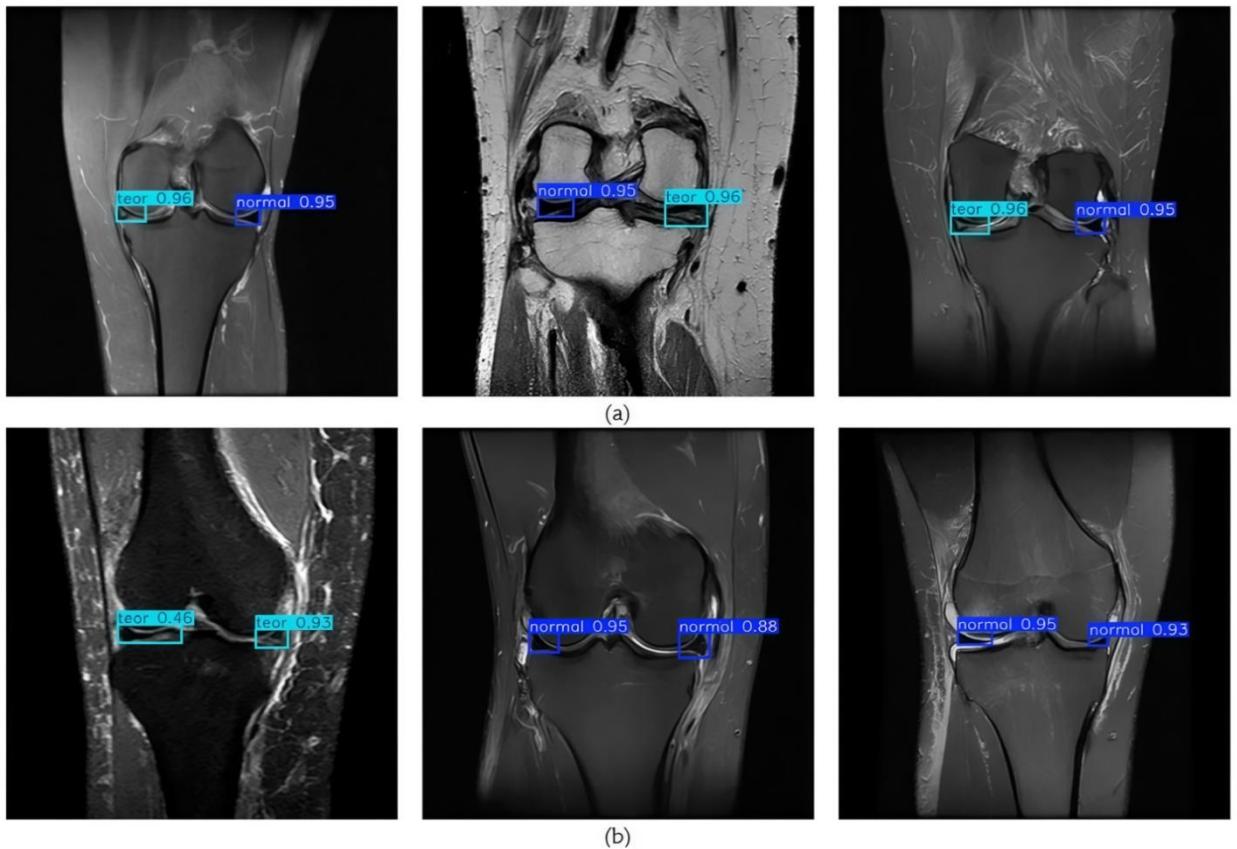


Рисунок 3.13 – Примеры работы модели YOLOv8-x на тестовой выборке:  
 (а) корректные предсказания; (б) ошибочные предсказания

В целом результаты тестирования показывают, что модель хорошо справляется с распознаванием разрывов мениска в разных клинических ситуациях. Она точно выделяет важные признаки, устойчиво работает при различиях в анатомии пациентов и справляется с помехами на изображениях. Модель уверенно распознаёт даже слабо выраженные повреждения и сохраняет точность при различном качестве изображений.

Предложенный подход имеет потенциал для практического применения в качестве вспомогательного инструмента для врачей при интерпретации МРТ-сканов и может быть интегрирован в компьютерные диагностические системы для повышения точности и скорости выявления патологий коленного сустава.

## **Выводы по третьему разделу**

В проведенном исследовании использовались модели семейств YOLO и RT-DETR для детектирования повреждений мениска на МРТ изображениях коленного сустава. В задаче участвовали два целевых класса, общее количество размеченных объектов составило 7990. После завершения этапов обучения на основе ключевых метрик  $mAP@50-95$  и Recall были отобраны наиболее эффективные модели из каждого семейства. По итогам анализа наивысшие результаты показали модели YOLOv8-x и RT-DETR-l.

Сравнительный анализ моделей на основе динамики обучения, ключевых метрик качества и поведения на тестовой выборке показал, что YOLOv8-x демонстрирует более стабильные и точные результаты по сравнению с RT-DETR-l. Она лучше справляется с определением повреждений мениска даже при ограниченном объеме данных и наличии визуальных искажений на МРТ. Такая эффективность объясняется архитектурными преимуществами YOLOv8-x – в частности, использованием усовершенствованных механизмов извлечения признаков и внимания к контексту, что особенно важно при анализе неструктурированных медицинских изображений. По итоговым метрикам YOLOv8-x достигла Precision – 0,958, Recall – 0,961,  $mAP@50$  – 0,975,  $mAP@50-95$  – 0,616. Эти показатели подтверждают высокую способность модели выявлять и классифицировать разрывы мениска при разных уровнях перекрытия (IoU).

Несмотря на отдельные случаи ложноположительных предсказаний, особенно в областях с выраженными структурными изменениями, модель в целом сохраняла стабильность и высокую избирательность. В условиях диагностической неопределенности она может эффективно дополнять традиционные методы, поддерживая принятие врачебных решений. Таким образом, YOLOv8-x зарекомендовала себя как точный, надежный и эффективный инструмент для автоматического распознавания разрывов мениска на МРТ изображениях. Хотя остаются области для доработки – такие как снижение ложных срабатываний и повышение чувствительности к слабо выраженным повреждениям, полученные результаты подтверждают высокий потенциал этой модели для применения в клинической практике. В дальнейшем планируется расширение обучающей выборки и добавление других типов повреждений для решения задач многоклассовой классификации, что позволит повысить универсальность модели и расширить возможности её применения в медицинской диагностике.

## **4. ПРОЕКТИРОВАНИЕ АРХИТЕКТУРЫ ИНТЕЛЛЕКТУАЛЬНОЙ СИСТЕМЫ ДИАГНОСТИКИ ПОВРЕЖДЕНИЙ МЕНИСКОВ КОЛЕННОГО СУСТАВА**

### **4.1 Общее описание архитектурной структуры**

В рамках диссертационного исследования разработана архитектура интеллектуальной системы диагностики разрывов мениска коленного сустава на основе анализа МРТ изображений. Разрабатываемая система объединяет методы предобработки изображений, текстурной диагностики и глубокого обучения, формируя комплексный подход к распознаванию патологий.

Основная цель проектируемой системы — повышение достоверности и воспроизводимости результатов МРТ-диагностики патологий менисков за счёт минимизации влияния субъективных факторов и вариативности интерпретации снимков специалистом.

Система предназначена для поддержки принятия диагностических решений в условиях клинической неопределённости, а также для оптимизации процесса анализа МРТ-снимков.

Архитектура системы разработана по модульному принципу и включает пять основных функциональных блоков:

1. Пользовательский интерфейс (UI):

- загрузка пользователем снимков в формате DICOM;
- отображает данные пациента (ФИО, возраст, пол и т.д.);
- позволяет редактировать или добавлять недостающую информацию;
- показывает результаты анализа и сохраняет их в истории пациента.

2. Модуль текстурной диагностики реализует информационно-текстурную трансформацию изображений, которая включает:

- преобразование изображения в двумерный массив;
- нормализация, полученного двумерного массива;
- формирование строково-столбцовых векторов изображения;
- выполнение графо-аналитической обработки;
- вывод полученных результатов.

3. Модуль обработки данных (Data Processing):

- принимает DICOM-файлы и извлекает метаданные (данные пациента, параметры снимка, режим, плоскость и т.д.);
- производит конвертацию DICOM данных в формат PNG;
- выполняет предобработку изображений комбинированным методом на основе методов Non-Local Means и Unsharp Masking для подавления шума и повышения резкости.

4. Модуль классификации (Model Inference):

- загружает заранее обученную модель классификации;
- принимает на вход изображения, полученные в результате предобработки изображения;
- определяет наличие или отсутствие разрыва;
- возвращает результат анализа (например, `tear_detected = True/False`, а также вероятность).

## 5. Модуль результатов и хранилище (Result & Storage):

- сохраняет результаты диагностики в базе данных;
- формирует историю пациента, включая предыдущие обследования;
- отображает динамику состояния пациента во времени.

На рисунке 4.1 представлена общая архитектура приложения с модулями текстурного анализа и детекции разрывов.

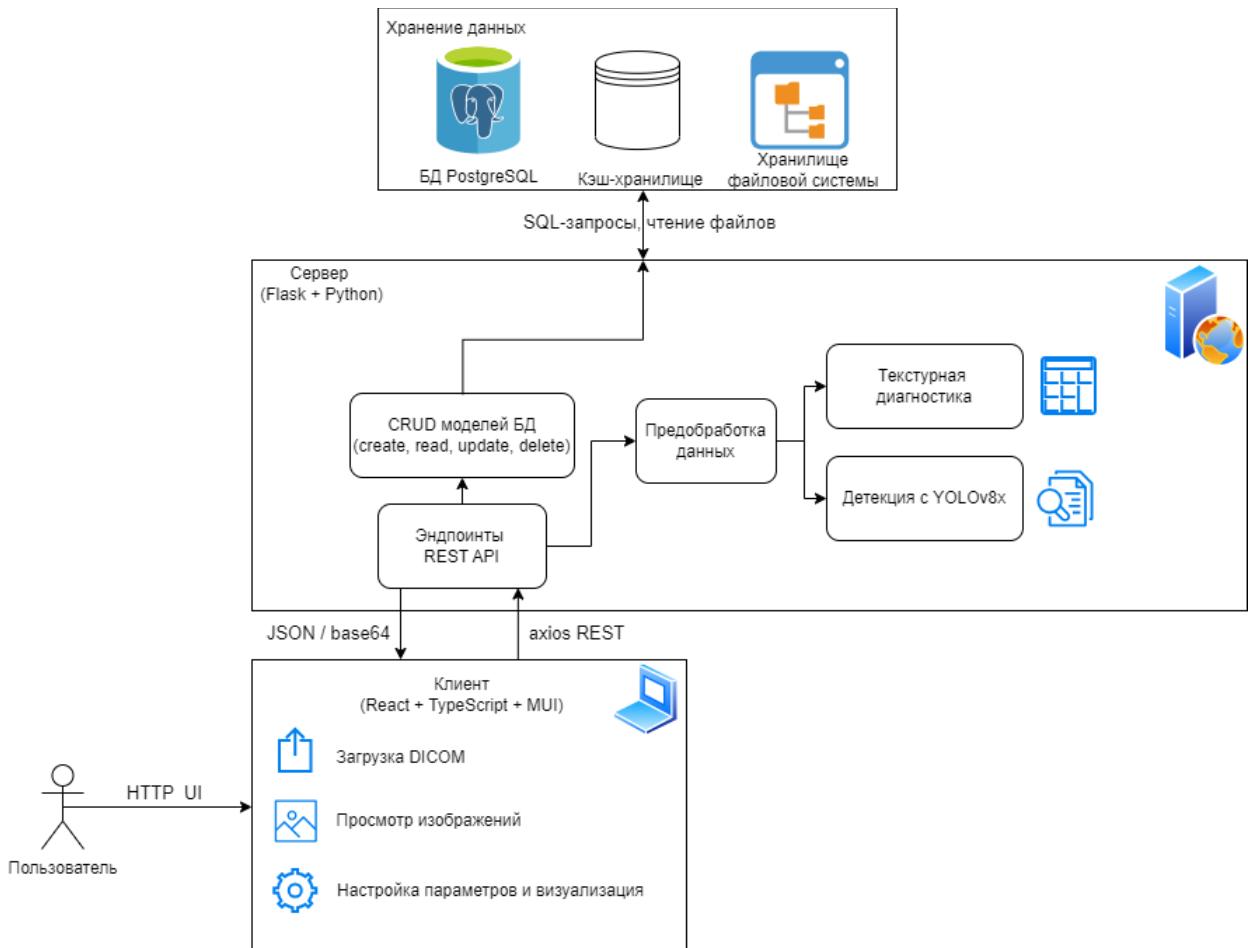


Рисунок 4.1 – Общая архитектура приложения с модулями текстурного анализа и детекции разрывов

Представленная архитектура отражает интегрированную структуру программного комплекса для автоматизированного анализа медицинских изображений, включающего загрузку, предобработку и детекцию патологических изменений менисков коленного сустава с использованием нейронных сетей семейства YOLO. Система состоит из трёх логических уровней: пользовательского, клиентского и серверного, а также включает централизованную базу данных PostgreSQL для хранения всей информации о пациентах, исследованиях и результатах диагностики.

На верхнем уровне взаимодействие осуществляется через пользователя, работающего с веб-интерфейсом. Клиентская часть реализована как одностраничное приложение (Single Page Application, SPA) на React с использованием TypeScript и библиотеки Material UI. Интерфейс

обеспечивает функции загрузки DICOM-файлов, просмотра и навигации по изображениям, редактирования метаданных пациента, выбора режима анализа и отображения результатов работы нейронной сети. Обмен между клиентом и сервером осуществляется через REST API по протоколу HTTP, используя библиотеку axios.

Серверная часть реализована на фреймворке Flask (Python) и объединяет несколько ключевых модулей: REST-интерфейс, модуль предобработки изображений и аналитический блок. REST-компонент отвечает за маршрутизацию запросов и координацию внутренних операций. Модуль предобработки выполняет извлечение и нормализацию пиксельных данных с использованием библиотек pydicom, numpy и Pillow, а также подавление шумов и повышение резкости. Аналитический блок включает два метода анализа: текстурный анализ для оценки однородности тканей и YOLO-модуль для детекции патологий, таких как разрывы менисков. Эти методы могут применяться как отдельно, так и совместно, в зависимости от выбранного режима анализа.

Сервер также взаимодействует с файловым хранилищем uploads, где сохраняются изображения, и с системой кэширования, ускоряющей повторную обработку. Все структурированные данные — сведения о пользователях, пациентах, исследованиях, снимках и результатах детекции сохраняются в базе данных PostgreSQL. База данных служит центральным элементом долговременного хранения, обеспечивая ведение истории обследований, управление правами пользователей и возможность отслеживания динамики состояния пациентов во времени.

Такое построение архитектуры обеспечивает логическое разделение функциональных уровней:

- Клиент - отвечает за визуализацию и взаимодействие с пользователем.
- Сервер - за обработку, анализ и формирование диагностических отчётов.
- База данных - за долговременное хранение и консистентность информации.

Интеграция аналитических модулей в состав серверной части позволяет системе работать как единое целое, выполняя полный цикл обработки — от загрузки DICOM-файлов до формирования визуализированного отчёта о детекции. Подобная архитектура поддерживает масштабирование, модульное обновление отдельных компонентов и интеграцию с медицинскими системами PACS или внешними клиническими хранилищами.

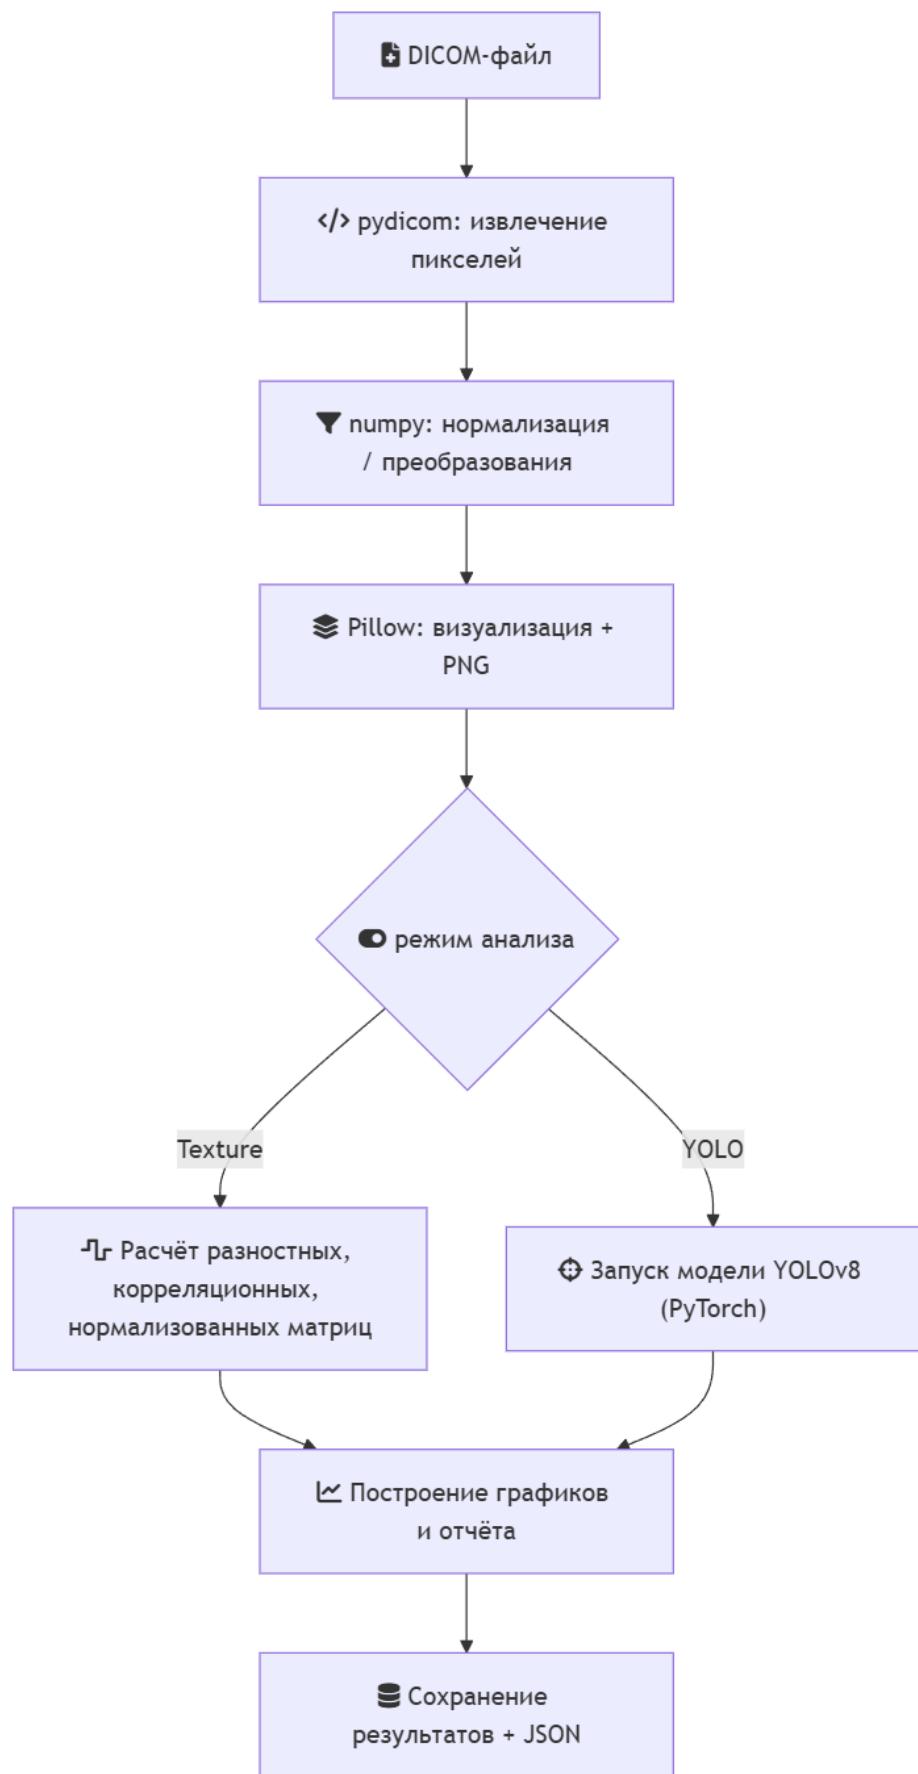


Рисунок 4.2 – Пайплайн обработки изображений на сервере

На рисунке 4.2 представлен пайплайн обработки изображений на сервере, который представляет последовательность этапов, выполняемых сервером для анализа медицинских снимков. Первым шагом осуществляется загрузка DICOM-файлов, поступающих от клиента. Далее происходит извлечение метаданных, включающих сведения о пациенте, параметрах исследования, типе последовательности и плоскости сканирования. После этого выполняется конвертация в формат PNG и формирование структуры каталогов по пациентам, режимам и плоскостям.

Следующим этапом является предобработка изображений, включающая нормализацию интенсивности, подавление шумов методом нелокальных средних (NLM), коррекцию контраста и повышение резкости (Unsharp Masking). Подготовленные изображения поступают на вход нейросетевой модели YOLO, которая выполняет детекцию объектов интереса, в данном случае повреждения менисков. Результаты детекции представлены в виде масок и координат областей, сопровождаемых вероятностной оценкой. Параллельно может выполняться текстурный анализ изображений для оценки структурной однородности тканей и подтверждения выводов модели. На заключительном этапе формируется JSON-отчёт с результатами анализа и сохраняется в базу данных.

## 4.2 Организация хранения данных и взаимодействие пользователей с интеллектуальной системой диагностики

В рамках разработки интеллектуальной системы диагностики повреждений менисков коленного сустава особое внимание было уделено вопросам хранения данных и организации взаимодействия пользователей с системой. Эффективная структура хранения информации обеспечивает целостность, доступность и безопасность данных, а также поддерживает интеграцию между компонентами программного комплекса и внешними пользователями — врачами, исследователями и системными администраторами.

Модель базы данных (БД) реализует реляционную схему, обеспечивающую хранение данных о пользователях, пациентах, исследованиях, изображениях и результатах анализа. Entity Relation (ER) — модель БД для YOLO-детекции представлена на рисунке 4.3.

Таблица USERS содержит информацию о пользователях системы (идентификатор, имя, роль, адрес электронной почты, хэш пароля) и отвечает за управление доступом. Таблица PATIENTS хранит сведения о пациентах: полное имя, возраст, пол и дату создания записи. Связь между пользователями и пациентами задаётся отношением «пользователь создаёт/наблюдает пациента».

Каждый пациент связан с множеством исследований, представленных таблицей STUDIES. Исследование включает атрибуты modality (режим сканирования), plane (плоскость), method (метод исследования) и дату выполнения. Каждое исследование может содержать несколько изображений, хранящихся в таблице IMAGES. Для каждого изображения сохраняются пути

к исходным и обработанным файлам, а также статус обработки. Результаты анализа фиксируются в таблице RESULTS, где указываются идентификатор изображения, флаг `tear_detected`, вероятность (`confidence`), путь к отчёту и дата анализа. Такая структура обеспечивает прослеживаемость всех этапов обработки — от загрузки исходных данных до формирования диагностического заключения, а также возможность ведения истории по каждому пациенту и исследованию.

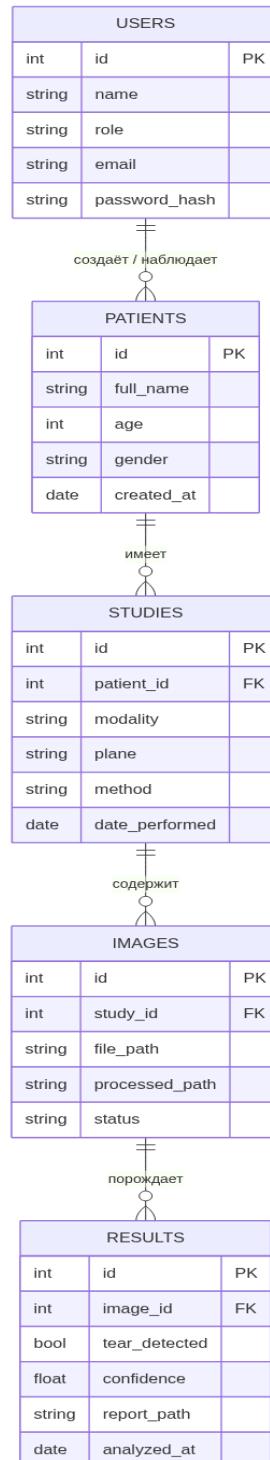


Рисунок 4.3 – Entity Relation (ER) – модель БД для YOLO–детекции

Диаграмма последовательности (Рисунок 4.4) описывает взаимодействие основных участников системы в процессе диагностики на основе детекции с использованием нейросетевой модели YOLO. В роли инициатора выступает пользователь, взаимодействующий с пользовательским интерфейсом приложения.

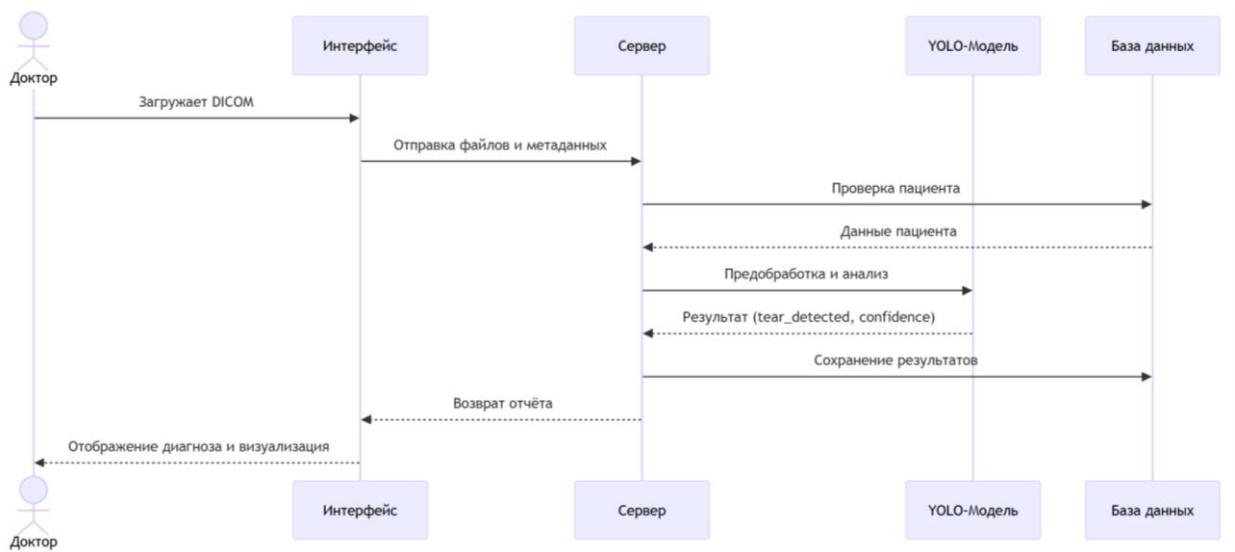


Рисунок 4.4 – Диаграмма последовательности для процесса формирования диагноза на основе детекции YOLO

Первым шагом пользователь через интерфейс загружает медицинские изображения в формате DICOM. Клиентская часть (UI) формирует запрос к серверу Flask, передавая файлы и сопутствующие метаданные пациента. Сервер принимает данные, проверяет наличие соответствующей записи в базе данных и при необходимости создаёт новую. Затем осуществляется вызов модели YOLO, которой передаются предварительно обработанные изображения для анализа.

YOLO-модель выполняет инференс — процесс распознавания и классификации объектов на изображениях. В результате возвращаются значения признаков `tear_detected` (наличие разрыва) и `confidence` (достоверность предсказания). После получения результата сервер сохраняет диагностическую информацию в базе данных, связывая её с соответствующим пациентом и исследованием.

Затем сервер формирует ответ, включающий диагностический отчёт, визуализированные результаты (например, выделенные области на изображениях) и метаданные анализа. Этот отчёт передаётся обратно пользовательскому интерфейсу, где пользователь получает итоговую информацию в наглядном виде: статус пациента, вероятность наличия патологии, а также графическое отображение зон, отмеченных моделью.

Таким образом, диаграмма отражает логическую последовательность взаимодействия между пользователем, клиентской частью, сервером,

нейросетевой моделью и базой данных. Система функционирует в режиме полной автоматизации: от загрузки и обработки снимков до формирования итогового диагноза и сохранения данных для последующего мониторинга динамики состояния пациента.

#### **4.3 Описание состава и схем диалога пользовательского интерфейса интеллектуальной системы**

Разработанная интеллектуальная система диагностики повреждений менисков коленного сустава включает специализированный графический интерфейс XRAY Inspector, обеспечивающий взаимодействие пользователя с вычислительными модулями, описанными в предыдущих подразделах. Приложение XRAY Inspector представляет собой современный инструмент для анализа медицинских изображений в формате DICOM. Оно предназначено для обработки МРТ снимков, включая исследование яркости, классификацию и выгрузку результатов для последующего использования в профессиональной деятельности. Структура интерфейса и логика взаимодействия пользователя с системой реализованы с учётом требований клинической практики и особенностей анализа МРТ-изображений.

При запуске приложение открывается в браузере, после загрузки отображается главный экран, представленный на рисунке 4.5.

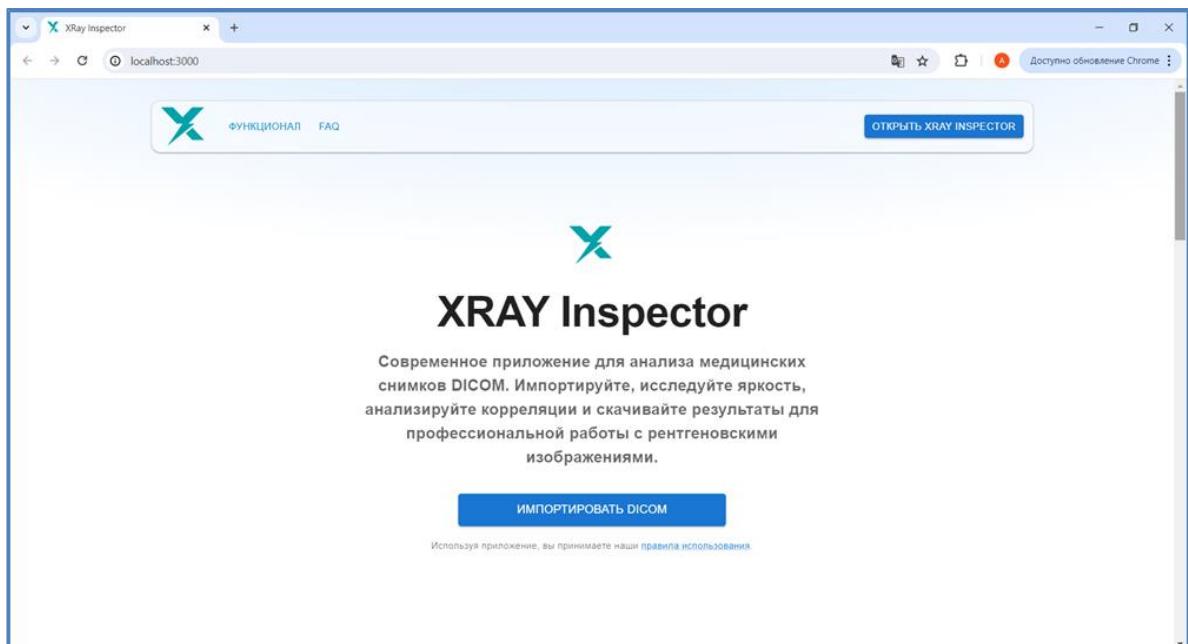


Рисунок 4.5 – Главный экран приложения

На главном экране расположены следующие элементы:

- Заголовок "XRAY Inspector" — указывает название приложения.
- Информационный блок — краткое описание функций приложения: импорт данных, анализ данных и экспорт результатов.

- Кнопка "Импортировать DICOM" — основной элемент для загрузки медицинских изображений в систему. Нажатие на кнопку открывает диалоговое окно выбора файлов в формате DICOM.
- Меню навигации (верхняя панель):
- вкладка Функционал — содержит описание возможностей программы;
- вкладка FAQ — справочный раздел;
- кнопка «Открыть XRAY Inspector» — переход к основному рабочему пространству приложения.

Таким образом, главный экран выполняет роль стартовой страницы, обеспечивая доступ к ключевым функциям системы и предоставляя пользователю возможность начать работу с медицинскими изображениями.

При переходе на вкладку «Функционал» отображается список основных функций, предоставляемых приложением (рисунок 4.6).

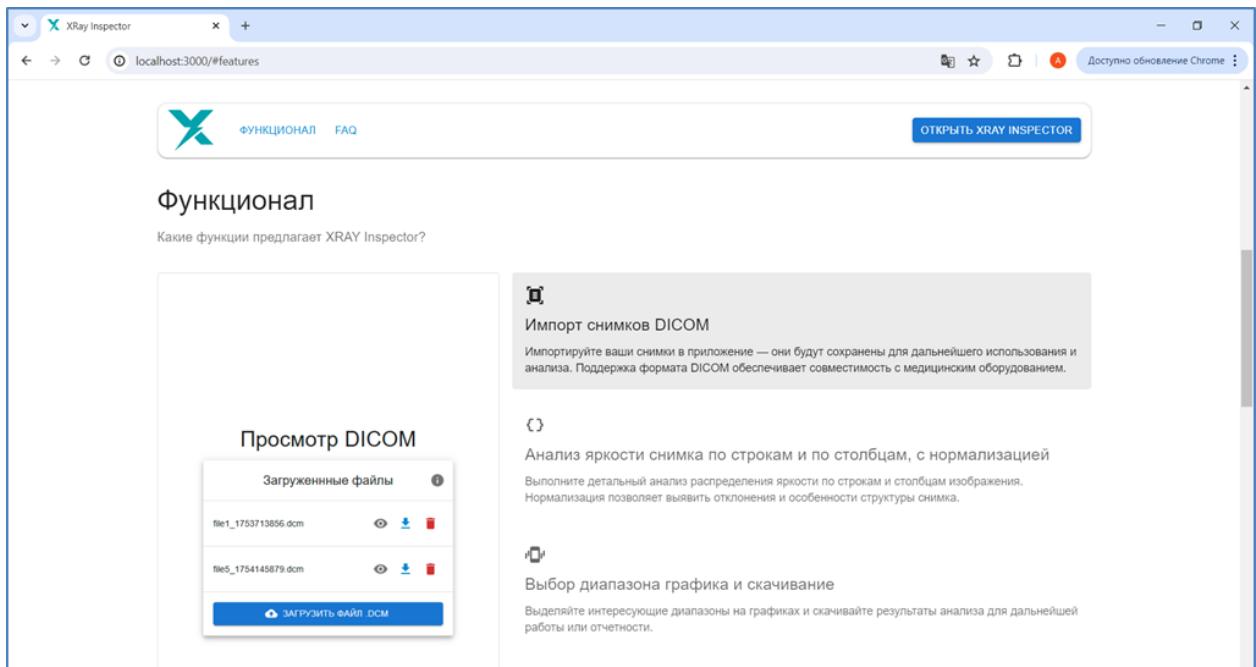


Рисунок 4.6 – Основные функциональные возможности приложения

Для начала работы в приложении необходимо нажать на кнопки «Открыть XRAY Inspector» в меню навигации, либо на кнопку «Импортировать DICOM» на главном экране приложения. В открывшемся окне для просмотра и импортирования снимков (рисунок 4.7) можно просмотреть, выгрузить, либо удалить уже ранее импортированные файлы, а также загрузить новые снимки при помощи кнопки «Загрузить файл .DCM». Откроется стандартное диалоговое окно операционной системы для выбора файлов. Пользователь выбирает один или несколько файлов в формате DICOM (\*.dcm). После подтверждения выбора изображения загружаются в приложение и становятся доступны для анализа.

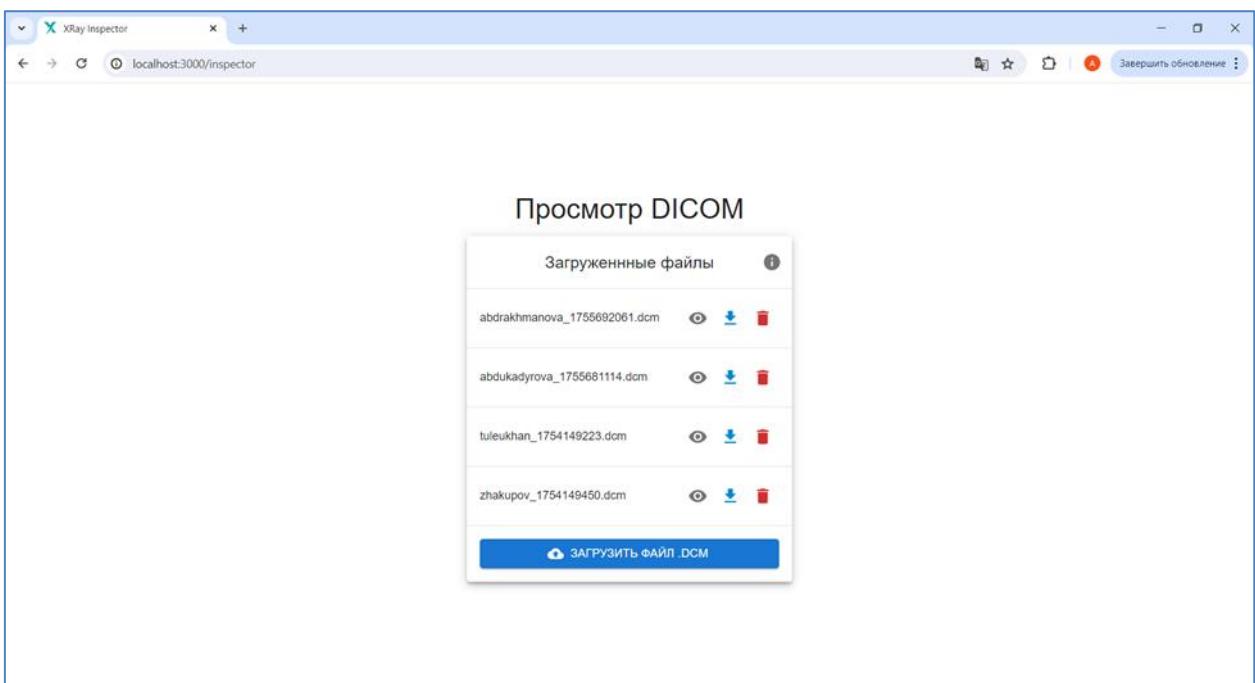


Рисунок 4.7 – Импортирование и просмотр DICOM файлов

После загрузки медицинских изображений система осуществляет переход к основному рабочему пространству, функционирующему в трех режимах – «Инспектор», «Нормализация» и «Классификация». Режим задается при помощи переключателей на панели меню. При выборе режима «Инспектор» (рисунок 4.8) в правой части экрана отображаются загруженные МРТ снимки, которые можно просматривать последовательно с помощью элементов навигации «Предыдущий снимок/Следующий снимок», также можно указать номер конкретного среза для просмотра.

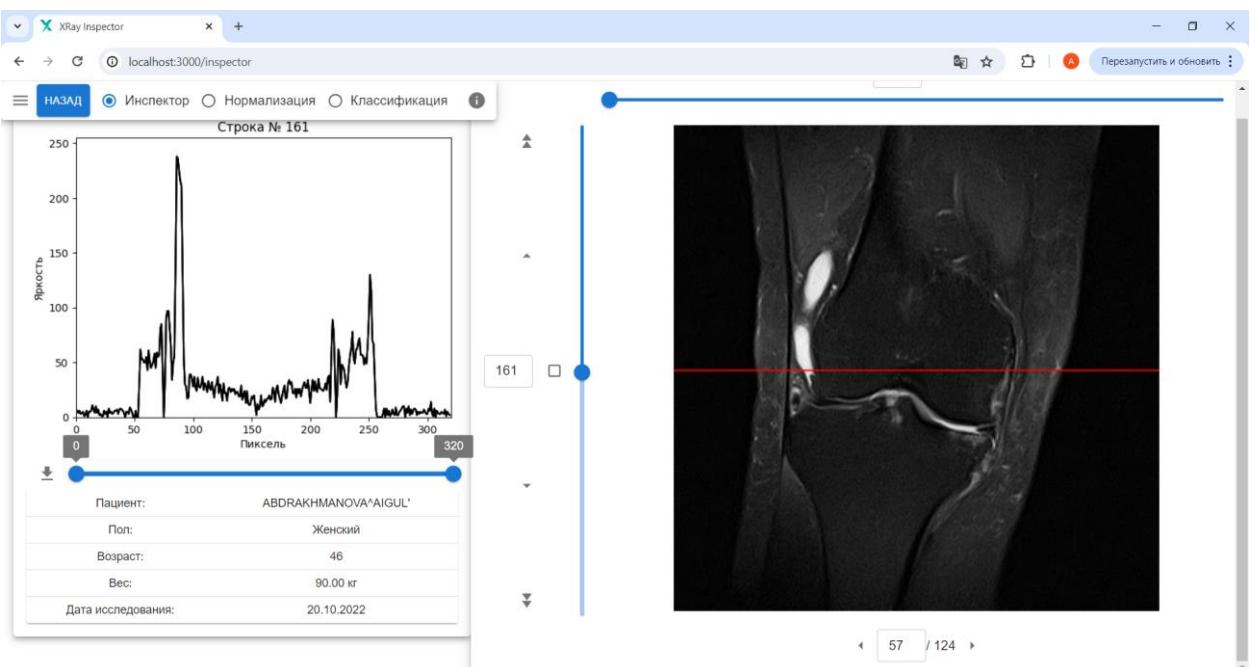


Рисунок 4.8 – Рабочее окно приложения в режиме «Инспектор»

Во время просмотра МРТ среза в левой части рабочего окна отображается диаграмма численных значений пикселей отображаемого среза. Под диаграммой отображаются основные данные пациента, которые были внесены в DICOM файл при проведении исследования. Пользователь может выбирать конкретную строку или столбец на просматриваемом срезе, по которым необходимо вывести диаграмму численных значений пикселей. Для этого можно использовать элементы навигации, перемещаясь последовательно по срезу, либо задать конкретный номер строки или столбца. При этом по срезу перемещается указатель в виде красной линии, показывающий на местоположение строки/столбца на срезе. Также указатель перемещается по срезу при помощи ползунка навигации, который можно перемещать указателем мыши.

Диаграмма, представленная на рисунке 4.8, в физической интерпретации показывает изменение содержания воды в пикселях различных строк на исследуемом срезе. Пользователь может загрузить диаграммы в формате .png и сохранить их для дальнейшей работы. Также пользователь может выбирать на диаграмме определенный диапазон значений пикселей для отображения. Сделать это можно при помощи ползунка навигации, расположенного под диаграммой как показано на рисунке 4.9.

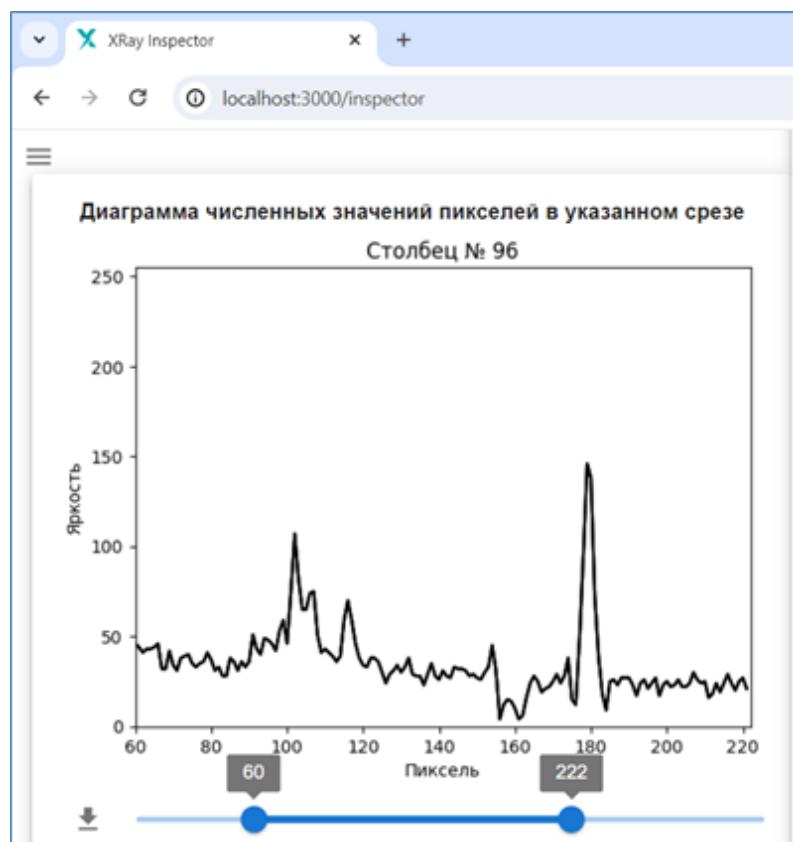


Рисунок 4.9 – Выбор диапазона численных значений пикселей на срезе

Для повышения удобства освоения системы реализован режим «Помощь», включающий интерактивные всплывающие подсказки (рисунок 4.10). Этот механизм объясняет назначение элементов интерфейса, позволяя пользователю безопасно и эффективно взаимодействовать с системой без необходимости предварительного обучения.

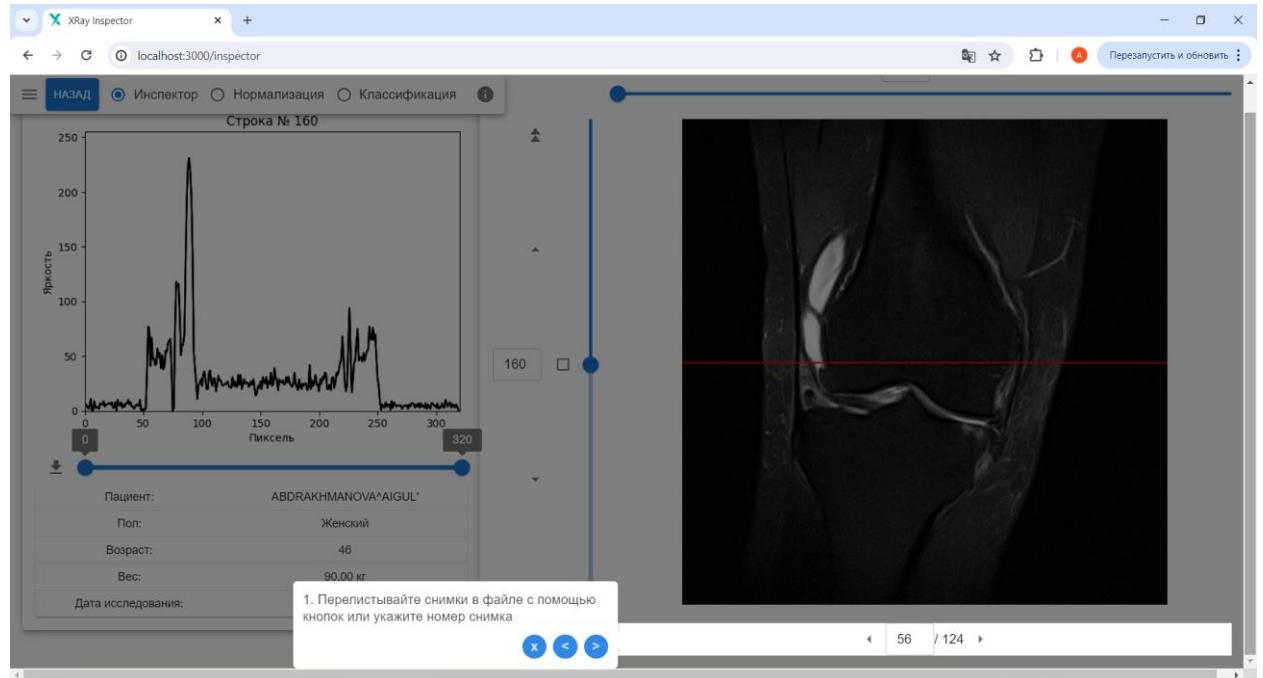


Рисунок 4.10 – Рабочее окно приложения в режиме «Помощь»

Следующий режим — «Нормализация» — обеспечивает отображение результатов преобразования МРТ-изображения, включая нормализацию по строкам и столбцам. Этот функциональный блок ориентирован на проведение текстурного анализа, описанного ранее в подразделе 2.3, и позволяет выявлять скрытые паттерны распределения яркости, характерные для дегенеративных или травматических изменений тканей менисков.

При переходе в режим «Нормализация» загружается окно с отображением результатов нормализации отображаемого среза по строкам и столбцам (рисунок 4.11).

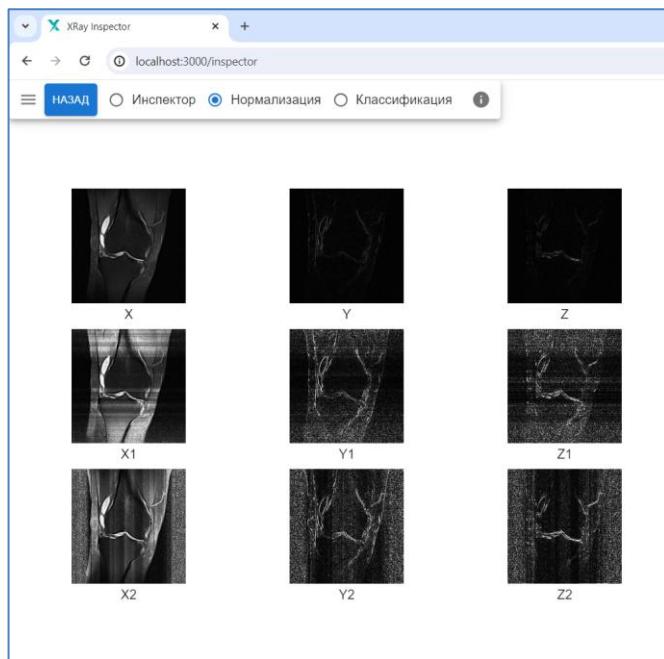


Рисунок 4.11 – Рабочее окно приложения в режиме «Нормализация»

В данном окне представлены исходные изображения, а также результаты их нормализации по строкам и столбцам. Каждое изображение можно просмотреть в отдельном окне, кликнув на него мышью. При наведении курсора мыши на изображение появляется всплывающая подсказка с названием изображения.

Особое значение в интеллектуальной системе имеет режим «Классификация», реализующий результаты работы обученной модели YOLOv8-x. Интерфейс данного режима представлен на рисунке 4.12.

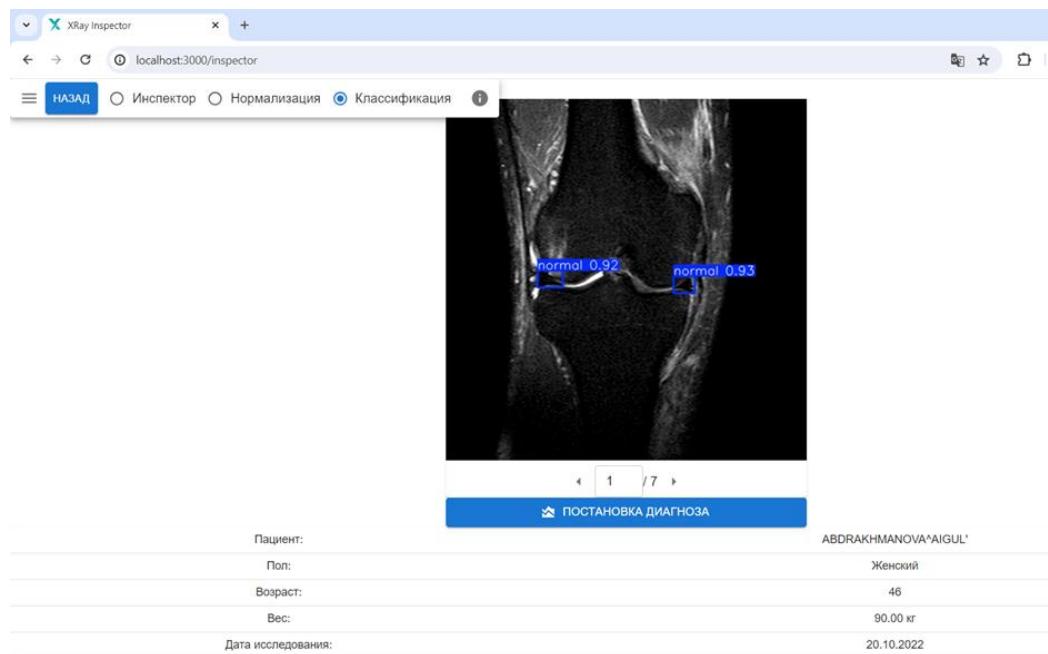


Рисунок 4.12 – Рабочее окно приложения в режиме «Классификация»

На изображении демонстрируется автоматическое обнаружение медиального и латерального менисков с указанием вероятностных оценок классов (normal 0.92, normal 0.93), что свидетельствует о высокой уверенности модели в отсутствии повреждений. Пользователь может последовательно просматривать все срезы исследования, на которых изображены мениски. На каждом из таких срезов модель обозначает локализацию менисков и присваивает им метки классов. Таким образом, система обеспечивает возможность визуальной верификации локализации патологий.

В нижней части окна режимов «Инспектор» и «Классификация» размещён блок персональных данных пациента, автоматически импортируемый из DICOM-файла: ФИО, возраст, пол, масса тела, дата исследования. Использование встроенного механизма DICOM-парсинга обеспечивает строгую привязку диагностических выводов к конкретному пациенту и исключает риск ошибок, связанных с ручным вводом.

Логика взаимодействия пользователя с системой построена по принципу диалоговой последовательности «команда → визуальный отклик → аналитическое действие». В процессе работы пользователь проходит следующие этапы:

- загрузка DICOM-файлов;
- предварительный визуальный анализ в режиме «Инспектор»;
- проведение текстурной диагностики в режиме «Нормализация»;
- получение результатов детекции и классификации в режиме «Классификация»;
- формирование итогового заключения;
- экспорт диагностических изображений и графиков в формате .png.

Интерфейс XRAY Inspector реализует принципы клинической прозрачности, высокой наглядности и интуитивной доступности, что позволяет пользователю эффективно сочетать автоматизированные компьютерные методы с собственным экспертным опытом. Наличие взаимосвязанных режимов работы обеспечивает комплексный подход к диагностике.

Отдельно следует отметить, что функционирование пользовательского интерфейса тесно интегрировано с архитектурными компонентами системы, описанными в подразделах 4.1 и 4.2. Источники логики отображения данных, параметры маршрутизации запросов, взаимодействие клиентской части с серверным API, а также механизмы построения графических компонентов отражены в программном коде приложения (см. Приложение А).

Таким образом, разработанный интерфейс интеллектуальной системы обеспечивает полнофункциональную, клинически ориентированную среду для визуального анализа, текстурной диагностики и автоматизированного обнаружения повреждений менисков коленного сустава. Он объединяет алгоритмы глубокого обучения, методы обработки изображений и средства визуализации в единый инструмент поддержки принятия врачебных решений.

Получено свидетельство о государственной регистрации на объект авторского права №61988 от 09 сентября 2025 г. «Программное обеспечение магнитно–резонансной томографии патологий коленного сустава» (Приложение Б).

### **Выводу по четвертому разделу**

В рамках диссертационного исследования была спроектирована и реализована архитектура интеллектуальной системы диагностики повреждений менисков коленного сустава на основе интеграции методов глубокого обучения и информационно–текстурного анализа. Разработанная архитектура представляет собой многоуровневую модульную систему, включающую подсистемы автоматизированного анализа медицинских изображений, модуль текстурной диагностики, а также пользовательский интерфейс, обеспечивающий взаимодействие пользователя с системой.

В результате проектирования установлено, что совмещение двух подходов — детектирования патологий при помощи архитектуры YOLOv8x и аналитической визуализации текстурных признаков — позволяет достичь синергетического эффекта. Такое объединение обеспечивает как высокую точность автоматического распознавания, так и повышение интерпретируемости результатов, что особенно важно при медицинской диагностике.

Представлено описание логической и функциональной структуры интеллектуальной системы, а также разработанного графического интерфейса пользователя, обеспечивающего интуитивный диалог между системой и специалистом. Пользовательский интерфейс реализован в виде веб–приложения XRAY Inspector, включающего инструменты для импорта, анализа и визуализации данных в формате DICOM. Разработаны схемы диалога и интерфейсные сценарии, которые обеспечивают логическую последовательность действий пользователя при проведении анализа и повышают удобство работы специалиста.

Разработанная интеллектуальная система имеет универсальную архитектуру и может быть адаптирована для анализа других видов МРТ–исследований мягкотканых структур, что свидетельствует о её масштабируемости и практической ценности для медицинской диагностики. Таким образом, проектирование архитектуры и интерфейса интеллектуальной системы решает задачу интеграции методов ИИ в клиническую практику и повышает достоверность диагностики повреждений менисков коленного сустава.

## ЗАКЛЮЧЕНИЕ

В ходе выполнения диссертационного исследования выполнен ряд задач, позволяющих сделать следующие выводы. Проведен аналитический обзор существующих методов обработки и распознавания медицинских изображений. Установлено, что методы глубокого обучения, в частности свёрточные и трансформерные архитектуры, демонстрируют высокую эффективность при анализе МРТ-изображений мягкотканых структур.

Для решения задачи классификации сформирован собственный аннотированный набор данных, включающий 2000 изображений от 2242 пациентов, собранных в различных медицинских центрах. Набор данных включает сканы, полученные с разных аппаратов МРТ с использованием нескольких последовательностей изображений (PD, T1, T2) и анатомических плоскостей (сагиттальной и коронарной). Это разнообразие обеспечило репрезентативность обучающей выборки и повысило достоверность последующих экспериментов.

Для представления МРТ срезов в формализованном цифровом виде предложен метод информационно-текстурной диагностики повреждений менисков, основанный на межпиксельном анализе яркости и плотности тканей. Реализация метода состоит из этапов: преобразование изображения в двумерный массив, нормализация, формирование строково-столбцовых векторов и графо-аналитическая обработка. Этот метод позволяет выявлять скрытые статистические и структурные закономерности, значимые для диагностики, которые не всегда доступны при визуальном осмотре. Метод позволяет перейти от визуально-аналогового восприятия изображения к его цифровой параметрической интерпретации.

Для улучшения качества изображений разработана методика предварительной обработки МРТ-изображений, включающая фильтрацию, нормализацию и контрастное усиление, что позволило улучшить качество данных для обучения нейросетевых моделей. Полученный комбинированный подход, включающий методы Non-Local Means Denoising и Unsharp Mask, продемонстрировал значения количественных показателей как MSE – 32.55; PSNR – 41.37; SSIM – 0.92, что свидетельствует о его высокой эффективности на этапе обработки МРТ-изображений.

По результатам экспериментов проведен сравнительный анализ двух современных архитектур глубокого обучения YOLOv8x и RT-DETR применительно к задаче обнаружения повреждений менисков на МРТ-изображениях. Оценка эффективности моделей осуществлялась по метрикам Precision, Recall, mAP@50 и mAP@50–95. Для YOLOv8x значения метрик составили 95,8%; 96,15; 97,5%; 61,6% соответственно. YOLOv8x показала наилучшее соотношение скорости и точности. RT-DETR продемонстрировала несколько более высокие показатели локализационной точности, однако уступала в скорости детекции. Значения метрик для RT-DETR-1 составили Precision – 91,9%; Recall – 95,2%; mAP@50 – 92,9%; mAP@50–95 – 53,1%. По совокупности параметров модель YOLOv8x была

выбрана для практической реализации интеллектуальной системы как более сбалансированная по точности, скорости и стабильности результатов.

Предлагаемые методы интегрированы в разработанную интеллектуальную систему диагностики повреждений менисков коленного сустава. Спроектирована и реализована архитектура системы, включающая модули глубокого обучения и текстурной диагностики. Разработан веб-интерфейс XRAY Inspector, обеспечивающий удобный диалог пользователя с системой, визуализацию результатов анализа и возможность экспорта данных.

На основе результатов диссертационного исследования можно заключить, что предлагаемые в диссертации методы и модели могут стать возможными решениями для диагностирования повреждений менисков коленного сустава. Предложенная информационная технология позволяет повысить точность, воспроизводимость и объективность диагностики повреждений менисков, снизить нагрузку на врача-диагноста и вероятность субъективных ошибок при интерпретации МРТ-изображений.

Внедрение разработанной системы в клиническую практику способствует цифровизации здравоохранения и отвечает современным тенденциям применения технологий искусственного интеллекта в медицине, что соответствует стратегическим приоритетам Республики Казахстан в области цифрового развития и медицинской инновации.

## СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Забавская О., Агабалаева А., Ахмеджанова Ф., Сахарова О., Малыгина М., Клюквин И. Возможности МРТ в диагностике повреждений хряща и мягких тканей коленного сустава.
2. Азизов М.Ж., Ступина Н.В., Ирисметов М.Э. Тизза бўғими касалликларининг клиник-артроскопик кўриниши ва даволаш: Метод. рекомендации. – Ташкент, 2005. – 12 с.
3. Бабуркина Е.П. Методологические аспекты менискэктомии // Сборник материалов 7-го Конгресса Российского артроскопического общества. – М., 2007. – С. 29.
4. Kalniev M. Initial Ultrastructural Changes of the Menisci in the Knee Joint after Rupture of the Collateral Ligaments – Experimental Study // Med. Health Sci. J. – 2011. – Vol. 8. – P. 59–63.
5. Концепции развития искусственного интеллекта. Постановление Правительства Республики Казахстан от 24 июля 2024 года № 592.
6. Ashraf S., Wibberley H., Mapp P.I. et al. Increased Vascular Penetration and Nerve Growth in the Meniscus: A Potential Source of Pain in Osteoarthritis // Ann. Rheum. Dis. – 2011. – Vol. 70. – P. 523–529.
7. Shetty A.A., Tindall A.J., James K.D. et al. Accuracy of Hand-Held Ultrasound Scanning in Detecting Meniscal Tears // J. Bone Joint Surg. Brit. – 2008. – Vol. 90, № 8. – P. 1045–1048.
8. Рыбалко Д.Ю., Самоходова О.В., Вагапова В.Ш. Прочностные свойства менисков коленного сустава человека в возрастном и половом аспектах // Морфология. – 2009. – Т. 13. – С. 122–127.
9. Verdonk P., Depaepe Y., Desmyter S. et al. Normal and Transplanted Lateral Knee Menisci: Evaluation of Extrusion Using Magnetic Resonance Imaging and Ultrasound // Knee Surg. Sports Traumatol. Arthrosc. – 2004. – Vol. 12, № 5. – P. 411–419.
10. Богатов В.Б., Матвеева О.В., Петров А.Б. Влияние холодно-плазменной абляции на хрящ коленного сустава человека и экспериментального животного // Травматол. и ортопед. России. – 2011. – № 1 (59). – С. 61–66.
11. Волошина И.С. Морфофункциональные особенности строения менисков коленного сустава человека // Морфология. – 2009. – № 4 (136). – С. 32–33.
12. Laurell L., Court-Payen M., Nielsen S. et al. Ultrasonography and Color Doppler of Proximal Gluteal Enthesitis in Juvenile Idiopathic Arthritis: A Descriptive Study // Pediatr. Rheumatol. – 2011. – Vol. 9. – P. 22.
13. Азизов М.Ж., Ступина Н.В., Ирисметов М.Э. Тизза бўғими касалликларининг клиник-артроскопик кўриниши ва даволаш: Метод. рекомендации. – Ташкент, 2005. – 12 с.
14. Бабуркина Е.П. Методологические аспекты менискэктомии // Сборник материалов 7-го Конгресса Российского артроскопического общества. – М., 2007. – С. 29.

15. Kalniev M. Initial Ultrastructural Changes of the Menisci in the Knee Joint after Rupture of the Collateral Ligaments – Experimental Study // Med. Health Sci. J. – 2011. – Vol. 8. – P. 59–63.
16. Долгова И.В. Новые ультразвуковые технологии в диагностике повреждений коленного сустава: Автореф. дис. ... канд. мед. наук. – М., 2002. – 20 с.
17. Хитров Н.А. Заболеваемость остеоартрозом и сопутствующая патология в условиях поликлиники // Клин. геронтол. – 2008. – № 2. – С. 20–24.
18. Park G.Y., Kim J.M., Lee S.M., Lee M.Y. The Value of Ultrasonography in the Detection of Meniscal Tears Diagnosed by Magnetic Resonance Imaging // Amer. J. Phys. Med. Rehabil. – 2008. – Vol. 87, № 1. – P. 14–20.
19. Богатов В.Б. Роль магнитно-резонансной томографии и клинического обследования в диагностике повреждений менисков коленного сустава // Медицинская визуализация. – 2009. – № 6.
20. Kuczyński N., Boś J., Białyńska K., Aleksandrowicz Z., Turoń B., Zabrzyska M., Bonowicz K., Gagat M. The Meniscus: Basic Science and Therapeutic Approaches // Journal of Clinical Medicine. – 2025. – Vol. 14. – P. 2020. DOI:10.3390/jcm14062020.
21. Pawar R.S., Yadav S.K., Kalyanasundaram D. Evaluation of the Stresses on the Knee Meniscus Tissue under Various Loading Conditions and Correlation with Resulting Meniscal Tears Observed Clinically: A Finite Element Study // J. Braz. Soc. Mech. Sci. Eng. – 2024. – Vol. 46. – P. 304.
22. Zhang J., Chen B., Chen B., Wang H., Han Q., Tang X., Qin Y. Clinical Application of Finite Element Analysis in Meniscus Diseases: A Comprehensive Review // Archives of Computational Methods in Engineering. – 2025. – P. 1–28. DOI:10.1007/s11831-025-10265-0.
23. Bandyopadhyay A., Ghibhela B., Mandal B.B. Current Advances in Engineering Meniscal Tissues: Insights into 3D Printing, Injectable Hydrogels and Physical Stimulation Based Strategies // Biofabrication. – 2024. – Vol. 16. – P. 022006.
24. Screpis D., Qordja F., De Berardinis L., Piovan G., Magnanelli S., Amarossi A., Gigante A.P., Zorzi C. Saving the Meniscus: A Retrospective Observational Study of the Incidence, Treatment, and Failure Rate of the Main Meniscal Tear Types at 24-Month Follow-Up // Journal of Clinical Medicine. – 2025. – Vol. 14. – P. 3350. DOI:10.3390/jcm14103350.
25. Bhan K. Meniscal Tears: Current Understanding, Diagnosis, and Management // Cureus. – 2020. – e8590. DOI:10.7759/cureus.8590.
26. Krivich L.M., Kunze K.N., Parvaresh K.C., Jan K., DeVinney A., Vadhera A., LaPrade R.F., Chahla J. Comparison of Long-Term Radiographic Outcomes and Rate and Time for Conversion to Total Knee Arthroplasty between Repair and Meniscectomy for Medial Meniscus Posterior Root Tears: A Systematic Review and Meta-Analysis // The American Journal of Sports Medicine. – 2021. – Vol. 50. – P. 2023–2031. DOI:10.1177/03635465211017514.

27. Kim S.H., Lee H.-J., Jang Y.-H., Chun K.-J., Park Y.-B. Diagnostic Accuracy of Magnetic Resonance Imaging in the Detection of Type and Location of Meniscus Tears: Comparison with Arthroscopic Findings // Journal of Clinical Medicine. – 2021. – Vol. 10. – P. 606. DOI:10.3390/jcm10040606.
28. Абдуразаков А.У. Магнитно-резонансная томография в диагностике повреждений менисков и крестообразных связок коленного сустава // Вестн. травматол. и ортопед. им. Н.Н. Приорова. – 2007. – № 1. – С. 34–36.
29. Авраменко В.В., Кузнецов И.А. Артроскопия при внутренних повреждениях коленного сустава у детей и подростков // Травматол. и ортопед. России. – 2011. – № 4 (62). – С. 131–139.
30. Бакарджиева А.Н. Лучевая диагностика заболеваний и повреждений коленного сустава до и после артроскопии: Автореф. дис. ... канд. мед. наук. – Обнинск, 2010. – 17 с.
31. Филиппов О.П., Чураянц В.В., Божко О.В. Роль магнитно-резонансной томографии в диагностике и оценке изолированных и сочетанных повреждений менисков коленного сустава // Мед. визуализация. – 2004. – № 2. – С. 108–117.
32. Бакиев Б.К., Азизов М.Ж., Нуралиева Х.О. Клинико-инструментальные методы исследования повреждений менисков коленного сустава // Травматология.
33. Морозов С.П., Терновой С.К., Насникова И.Ю., Королев А.В., Филистееев П.А., Ильин Д.О. Исследование возможностей МРТ в диагностике повреждений коленного сустава // Вестник рентгенологии и радиологии. – 2008. – № 4–6.
34. Стулов А.С., Трасов А.Н. «Ловушки» магнитно-резонансной томографии в диагностике повреждений менисков коленного сустава // Гений ортопедии. – 2017. – Т. 23, № 4.
35. Брюханов А.В., Васильев А.Ю. Магнитно-резонансная томография в диагностике повреждений менисков и связок коленного сустава // Медицинская визуализация. – 2005. – № 2.
36. McCauley T.R., Moses M., Kier R., Lynch J.K., Barton J.W., Jokl P. MR Diagnosis of Tears of Anterior Cruciate Ligament of the Knee: Importance of Ancillary Findings // AJR. – 1994. – Vol. 162. – January.
37. Ахмеджанов Ф.М. Магнитно-резонансная томография при травматических повреждениях коленного сустава, сопоставления с данными артроскопии // Сборник материалов зимнего Всероссийского симпозиума «Коленный и плечевой сустав – XXI век». – 2000. – С. 14–15.
38. Абдушарипов М.А., Матризаева Г.Д., Абдуллаева Д.К., Худайберганов Д.Г. Магнитно-резонансная томография в диагностике травматических повреждений коленного сустава // Радиология. – 2017. – DOI:10.24835/1607-0763-2017-2-114-119.
39. Buckwalter K.A., Pennes D.R. Anterior Cruciate Ligament: Oblique Sagittal MR Imaging // Radiology. – 1990. – Vol. 175. – P. 276–277.

40. Grover J.S., Basset I.W. et al. Posterior Cruciate Ligament: Oblique Sagittal MR Imaging // Radiology. – 1990. – Vol. 174. – P. 527–530.
41. Reis N.D., Lanir A., Benmair J. Magnetic Resonance Imaging in Orthopaedic Surgery (A Glimpse into the Future) // J. Bone Joint Surg. – 1985. – Vol. 67-B, № 5. – P. 659–664.
42. Футрык А.Б., Головатенко-Абрамов К.В., Корочкина И.И., Сергеев С.В., Загородний Н.В., Абдулхабиров М.А. Диагностика внутрисуставных повреждений коленного сустава в остром периоде травмы при помощи магнитно-резонансной томографии // Вестник РУДН. Серия «Медицина». – 2002. – № 4.
43. Дороничева А.В., Савин С.З. Методы распознавания медицинских изображений для задач компьютерной автоматизированной диагностики.
44. Никитин О.Р., Пасечник А.С. Оконтуривание и сегментация в задачах автоматизированной диагностики патологий // Методы и устройства передачи и обработки информации. – 2009. – № 11. – С. 300–309.
45. BET – FslWiki. URL: <http://fsl.fmrib.ox.ac.uk/fsl/fslwiki/BET>
46. Nifty Seg. URL: <https://sourceforge.net/projects/niftyseg>
47. RadiAnt DICOM Viewer. URL: <http://www.radiantviewer.com>
48. ImageJ. URL: <http://imagej.net/>
49. xjView – viewing program for SPM. URL: <http://www.alivelearn.net/xjview>
50. Novo SparkVisualizer: Обзор. URL: <http://www.novospark.com/ru/Products/Visualizer/Overview.aspx>
51. 3D Slicer. URL: <https://www.slicer.org/>
52. Магонов Е.П. Комплексная магнитно-резонансная морфометрия очаговых и атрофических изменений головного мозга (на примере рассеянного склероза и ранних стадий ВИЧ-инфекции): Дисс. на соиск. учен. степени канд. мед. наук. – Санкт-Петербург, 2015. – 167 с.
53. Магонов Е.П., Катаева Г.В., Трофимова Т.Н. Современные методы автоматического вычисления объёма внутричерепного пространства при МРТ-морфометрии головного мозга // Вестник Новгородского государственного университета. – 2015. – № 2. – С. 98–104.
54. Зубов А.Ю., Сенюкова О.В. Сегментация изображений МРТ головного мозга с помощью сопоставления с несколькими атласами // GraphiCon 2015, Россия, Протвино (Парк Дракино), 22–25 сентября 2015 г. URL: <http://www.graphicon.ru/html/2015/papers/11.pdf>
55. Расширенные возможности визуализации в МРТ. URL: [http://www3.gehealthcare.ru/ru-products/categories/advanced\\_visualization/mri\\_imaging\\_software](http://www3.gehealthcare.ru/ru-products/categories/advanced_visualization/mri_imaging_software)
56. Вахрамеева О.А., Фокин В.А., Лебедев А.В., Хараузов А.К., Соколов А.В., Шелепин Ю.Е. Статистический параметрический анализ активности мозга человека при пассивном наблюдении стимула и в задаче активного выбора. – 2014.

57. Гайсин Р.Р., Закиров Р.Х., Зарипов Р.А., Никифорова А.В., Саченков О.А. Трёхмерная реконструкция внутренних органов с одним характерным размером на основе компьютерной томографии. URL: <http://mfvt.ru/trekhmernaya-rekonstrukciya-vnutrenixorganov-s-odnim-xarakternym-razmerom-na-osnovekompyuternoj-tomografii/>
58. Серегин П.С. Сравнительный анализ и усовершенствование методов параллельной реконструкции изображений магнитно-резонансной томографии // Вестник новых медицинских технологий. – 2012. – № 2. – С. 74–76.
59. 3D-DOCTOR 4.0.20110710 – Графика, 3D, моделирование. URL: <http://cwer.ws/node/238193/>
60. Visualization Toolkit – Freecode. URL: <http://freecode.com/projects/vtk>
61. Drishti: Volume Exploration and Presentation Tool. URL: <https://sf.anu.edu.au/Vizlab/drishti/>
62. Сойфер В.А. Компьютерная обработка изображений. Часть 2. Методы и алгоритмы // Соросовский образовательный журнал. – 1996. – № 3.
63. Mricon – Magnetic Resonance Image Conversion, Viewing and Analysis. Debian Neuroscience Package Repository. URL: <http://neuro.debian.net/pkgs/mricon.html>
64. Толкович Д.В., Суворов Н.Б., Марусина М.Я., Козаченко А.В. Многофункциональная биотехническая система для изучения физиологических сигналов при интеллектуальной деятельности // Научно-технические ведомости СПбГПУ. Информатика. Телекоммуникации. Управление. – СПб.: Изд-во Политехнического университета, 2013. – № 5 (181). – С. 73–78.
65. Marusina M.Y., Mochalina A.P., Frolova E.P., Satikov V.I., Barchuk A.A., Kuznetcov V.I., Gaidukov V.S., Tarakanov S.A. MRI Image Processing Based on Fractal Analysis // Asian Pacific Journal of Cancer Prevention. – 2017. – Vol. 18, № 1. – P. 51–55. DOI:10.22034/APJCP.2017.18.1.51.
66. Магонов Е.П., Трофимова Т.Н. Автоматическая сегментация МРТ-изображений головного мозга: методы и программное обеспечение // Лучевая диагностика и терапия. – 2012. – Т. 3, № 3. – С. 35–40.
67. Зубов А., Сенюкова О. Сегментация изображений магнитно-резонансной томографии головного мозга с помощью сопоставления с несколькими атласами // Труды 25-й Международной конференции по компьютерной графике и зрению Графикон'2015. – Протвино: Институт физико-технической информатики, 2015. – С. 56–61.
68. Marusina M.Y., Sizikov V.S., Volgareva A.P. Noise Suppression in the Task of Distinguishing the Contours and Segmentation of Tomographic Images // Journal of Optical Technology. – 2015. – Vol. 82, № 10. – P. 673–677.
69. Марусина М.Я., Волгарева А.П. Подходы к разработке автоматической сегментации томографических изображений // Фундаментальные и прикладные проблемы техники и технологий. – 2015. – № 5 (313). – С. 136–141.

70. Марусина М.Я., Волгарева А.П., Толкович Д.В. Анализ принципов разработки системы популяционного скрининга онкологических заболеваний лёгких на основе использования рентгеновской компьютерной томографии // Прикаспийский журнал: управление и высокие технологии. – 2015. – № 2. – С. 79–92.
71. Прэйт У.К. Цифровая обработка изображений. – М.: Мир, 1982. – Т. 2. – 792 с.
72. Вичевская Ю.А., Мурынов А.И. Структурный анализ изображений на основе использования функции информативности // Альманах современной науки и образования. – 2010. – № 4. – С. 53–55.
73. Саенко А.П., Мусалимов В.М., Лерм Ш., Линц Г. Применение методов машинного обучения для обнаружения бактерий в продуктах питания // Научно-технический вестник информационных технологий, механики и оптики. – 2014. – № 1 (89). – С. 93–98.
74. 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).
75. Пшенокова И.А., Киясов М.Р. Модели и методы глубокого обучения в задачах распознавания и классификации медицинских изображений // Известия Кабардино-Балкарского научного центра РАН. – 2025. – Т. 27, № 2. – DOI:10.35330/1991-6639-2025-27-2-103-112.
76. Zhang H., Qie Y. Applying Deep Learning to Medical Imaging: A Review // Applied Sciences. – 2023. – Vol. 13. – P. 10521. DOI:10.3390/app131810521.
77. Güngör E., Vehbi H., Cansin A., Ertan M.B. Achieving High Accuracy in Meniscus Tear Detection Using Advanced Deep Learning Models with a Relatively Small Data Set // Knee Surg. Sports Traumatol. Arthrosc. – 2025. – Vol. 33. – P. 450–456.
78. Ma Y., Qin Y., Liang C., Li X., Li M., Wang R., Yu J., Xu X., Lv S., Luo H. et al. Visual Cascaded-Progressive Convolutional Neural Network (C-PCNN) for Diagnosis of Meniscus Injury // Diagnostics. – 2023. – Vol. 13. – P. 2049. DOI:10.3390/diagnostics13122049.
79. Mangone M., Diko A., Giuliani L., Agostini F., Paoloni M., Bernetti A., Santilli G., Conti M., Savina A., Iudicelli G. et al. A Machine Learning Approach for Knee Injury Detection from Magnetic Resonance Imaging // International Journal of Environmental Research and Public Health. – 2023. – Vol. 20. – P. 6059. DOI:10.3390/ijerph20126059.
80. Shin H., Choi G.S., Shon O.-J., Kim G.B., Chang M.C. Development of Convolutional Neural Network Model for Diagnosing Meniscus Tear Using Magnetic Resonance Image // BMC Musculoskeletal Disorders. – 2022. – Vol. 23. – P. 1–10. DOI:10.1186/s12891-022-05468-6.
81. Li Y.-Z., Wang Y., Fang K.-B., Zheng H.-Z., Lai Q.-Q., Xia Y.-F., Chen J.-Y., Dai Z.-S. Automated Meniscus Segmentation and Tear Detection of

Knee MRI with a 3D Mask-RCNN // European Journal of Medical Research. – 2022. – Vol. 27. – P. 1–13. DOI:10.1186/s40001-022-00883-w.

82. Kara A.C., Hardalaç F. Detection and Classification of Knee Injuries from MR Images Using the MRNet Dataset with Progressively Operating Deep Learning Methods // Machine Learning and Knowledge Extraction. – 2021. – Vol. 3. – P. 1009–1029. DOI:10.3390/make3040050.

83. Hung T.N.K., Vy V.P.T., Tri N.M., Hoang L.N., Van Tuan L., Ho Q.T., Le N.Q.K., Kang J. Automatic Detection of Meniscus Tears Using Backbone Convolutional Neural Networks on Knee MRI // Journal of Magnetic Resonance Imaging. – 2022. – Vol. 57. – P. 740–749. DOI:10.1002/jmri.28284.

84. Hoover K.B., Vossen J.A., Hayes C.W., Riddle D.L. Reliability of Meniscus Tear Description: A Study Using MRI from the Osteoarthritis Initiative // Rheumatology International. – 2020. – Vol. 40. – P. 635–641.

85. Grasso D., Gnesutta A., Calvi M., Duvia M., Atria M.G., Celentano A., Callegari L., Genovese E.A. MRI Evaluation of Meniscal Anatomy: Which Parameters Reach the Best Inter-Observer Concordance? // Radiologia Medica. – 2022. – Vol. 127. – P. 991–997.

86. Bien N., Rajpurkar P., Ball R.L., Irvin J., Park A., Jones E., Bereket M., Patel B.N., Yeom K.W., Shpanskaya K. et al. Deep-Learning-Assisted Diagnosis for Knee Magnetic Resonance Imaging: Development and Retrospective Validation of MRNet // PLoS Medicine. – 2018. – Vol. 15. – e1002699.

87. Güngör E., Vehbi H., Cansın A., Ertan M.B. Achieving High Accuracy in Meniscus Tear Detection Using Advanced Deep Learning Models with a Relatively Small Data Set // Knee Surg. Sports Traumatol. Arthrosc. – 2025. – Vol. 33. – P. 450–456.

88. Carion N., Massa F., Synnaeve G., Usunier N., Kirillov A., Zagoruyko S. End-to-End Object Detection with Transformers // Proc. European Conference on Computer Vision (ECCV). – Glasgow, UK, 23–28 August 2020.

89. Hatamizadeh A., Tang Y., Nath V., Yang D., Myronenko A., Landman B., Roth H.R., Xu D. UNETR: Transformers for 3D Medical Image Segmentation // Proc. IEEE/CVF Winter Conference on Applications of Computer Vision (WACV). – Waikoloa, HI, USA, 3–8 January 2022.

90. Chen J., Lu Y., Yu Q., Luo X., Adeli E., Wang Y., Zhou Y. TransUNet: Transformers Make Strong Encoders for Medical Image Segmentation // arXiv. – 2021. – arXiv:2102.04306.

91. Liu F., Zhou Z., Jang H., Samsonov A., Zhao G., Kijowski R., Li F. Deep Convolutional Neural Network and 3D Deformable Approach for Tissue Segmentation in Musculoskeletal Magnetic Resonance Imaging // Magnetic Resonance in Medicine. – 2018. – Vol. 79. – P. 2379–2391.

92. Couteaux V., Si-Mohamed S., Nempong O., Lefevre T., Popoff A., Pizaine G., Villain N., Bloch I., Cotton A., Boussel L. Automatic Knee Meniscus Tear Detection and Orientation Classification with Mask-RCNN // Diagnostic and Interventional Imaging. – 2019. – Vol. 100. – P. 235–242.

93. Parkar A.P., Adriaensen M.E.A.P.M. ESR Essentials: MRI of the Knee – Practice Recommendations by ESSR // European Radiology. – 2024. – Vol. 34. – P. 6590–6599.
94. Смирнов В.В., Саввова М.В., Смирнов В.В. Магнитно-резонансная томография в диагностике заболеваний суставов. – Обнинск: Артифекс, 2022. – 170 с., ил. ISBN 978-5-6045614-9-2.
95. Jiang C., Ren H., Ye X., Zhu J., Zeng H., Nan Y., Sun M., Ren X., Huo H. Object Detection from UAV Thermal Infrared Images and Videos Using YOLO Models // International Journal of Applied Earth Observation and Geoinformation. – 2022. – Vol. 112. – P. 102912.
96. Ultralytics. YOLOv5. – 2020. – Available online: <https://github.com/ultralytics/yolov5> (accessed on 1 June 2025).
97. Terven J., Córdova-Esparza D.-M., Romero-González J.-A. A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS // Machine Learning and Knowledge Extraction. – 2023. – Vol. 5. – P. 1680–1716.
98. Yu L., Tang L., Mu L. A Review of DEtection TRansformer: From Basic Architecture to Advanced Developments and Visual Perception Applications // Sensors. – 2025. – Vol. 25, № 13. – P. 3952. DOI:10.3390/s25133952.
99. Siouras A., Moustakidis S., Giannakidis A., Chalatsis G., Liampas I., Vlychou M., Hantes M., Tasoulis S., Tsaopoulos D. Knee Injury Detection Using Deep Learning on MRI Studies: A Systematic Review // Diagnostics. – 2022. – Vol. 12, № 2. – P. 537. DOI:10.3390/diagnostics12020537.
100. Şimşek M.A., Sertbaş A., Sasani H., Dinçel Y.M. Automatic Meniscus Segmentation Using YOLO-Based Deep Learning Models with Ensemble Methods in Knee MRI Images // Applied Sciences. – 2025. – Vol. 15. – P. 2752. DOI:10.3390/app15052752.
101. Picot P., Braun G. Telemonitoring in Gesundheits- und Sozialsystemen. – Heidelberg–Dordrecht–London–New York: Springer, 2011. – 218 p.
102. Шкала Хаунсфилда – количественное отображение способности различных объектов (тканей, органов, воды, газа, металла и т. д.). URL: <https://secondopinions.ru/poleznye-materialy/kt/terminy-i>
103. Lux T. E-Health – Begriff und Abgrenzung // In: Müller-Mielitz S., Lux T. (eds.) E-Health Ökonomie. – Wiesbaden: Springer Gabler, 2017. – P. 39–57.
104. Кумарканова А.С., Тлебалдинова А.С., Танкибаева А.К., Карменова М.А., Кумаргажанова С.К. Комплексный подход к предобработке МРТ-изображений на основе фильтрации и оценке качества // Вестник ВКТУ им. Д. Серикбаева. – 2025. – № 2. – С. 153–162. DOI:10.51885/1561-4212\_2025\_2\_153.
105. А.К.Танкибаева, Кумаргажанова, Б.Н. Азаматов, Ж.К. Азаматова. Цифровая трансформация процессов управления рисками контроля в системе магнитно-резонансной диагностики //Вестник Академии гражданской

авиации. - № 2(37), 2025. C.194-203.  
[https://doi.org/10.53364/24138614\\_2025\\_37\\_2\\_17](https://doi.org/10.53364/24138614_2025_37_2_17).

106. Kazantsev, I.G.; Tankibayeva, A.K.; Kumargazhanova, S.K.; Azamatov, B.N. Correction of Intensity Inhomogeneity in Magnetic Resonance Images Using Ramp Filter. *Siberian Electronic Mathematical Reports* 2024, 21, 307–314, doi:10.33048/semi.2024.21.023

107. Mohan G., Subashini M.M. MRI Based Medical Image Analysis: Survey on Brain Tumor Grade Classification // *Biomedical Signal Processing and Control*. – 2018. – Vol. 39. – P. 139–161.

108. Kumar P.C.C., Dharun V.S. A Study of MRI Segmentation Methods in Automatic Brain Tumor Detection // *International Journal of Engineering and Technology*. – 2016. – Vol. 8. – P. 609–614.

109. Vovk U., Pernus F., Likar B. A Review of Methods for Correction of Intensity Inhomogeneity in MRI // *IEEE Transactions on Medical Imaging*. – 2007. – Vol. 26, № 3. – P. 405–4216.

110. Танкибаева А.К., Кумаргажанова С.К., Казанцев И.Г., Азаматов Б.Н. Коррекция неоднородности яркостей магнитно-резонансных изображений // Сборник трудов XIX Международной Азиатской школы-семинара «Проблемы оптимизации сложных систем». – Новосибирск, РФ, 14–24 августа 2023 г.

111. Selvakumar K., Thangaraju G. Comparative Study of Filters for Noise Removal in Brain MRI Images // *International Journal of Intelligent Engineering Informatics*. – 2023. – Vol. 11, № 1. – P. 1–15. DOI:10.1504/IJIEI.2023.132703.

112. Doãn T.B. Enhancing Quality and Detecting Anomalies in Brain MRI Images Using Anisotropic Filtering and Neural Networks // *Đại học Đà Lạt Journal of Science*. – 2022. – Vol. 12, № 2. – P. 27–42.

113. Kastrulyin S., Zakirov J., Pezzotti N., Dylov D.V. Image Quality Assessment for Magnetic Resonance Imaging // *IEEE Access*. – 2023. – Vol. 11. – P. 14154–14168. DOI:10.1109/ACCESS.2023.3243466.

114. Botnari A., Kadar M., Patrascu J.M. Considerations on Image Preprocessing Techniques Required by Deep Learning Models. The Case of the Knee MRIs // *Maedica (Bucur)*. – 2024. – Vol. 19, № 3. – P. 526–535. DOI:10.26574/maedica.2024.19.3.526.

115. Ji K., Wang S., Qiu Z., Liu Q. Diagnostic Evaluation of Low-Rank Matrix Denoising Algorithm-Based Magnetic Resonance Imaging on Tibial Plateau Fracture Complicated with Meniscus Injury // *Expert Systems*. – 2023. – Vol. 40, № 4. – e12858. <https://doi.org/10.1111/exsy.12858>.

116. Konovalova N., Tolpadi A., Liu F., Akkaya Z., Gassert F., Giesler P., Luitjens J., Han M., Bahroos E., Majumdar Sh., Pedoia V. The Object Detection Method Aids in Image Reconstruction Evaluation and Clinical Interpretation of Meniscal Abnormalities // *arXiv:2407.12184 [eess.IV]*. – 2024. – <https://doi.org/10.48550/arXiv.2407.12184>.

117. Altahawi F., Aro G., Li X. 3D MRI of the Knee // Seminars in Musculoskeletal Radiology. – 2021. – Vol. 25, № 3. – P. 455–464. DOI:10.1055/s-0041-1730400.
118. Roy S., Bhalla K., Patel R. Mathematical Analysis of Histogram Equalization Techniques for Medical Image Enhancement: A Tutorial from the Perspective of Data Loss // Multimedia Tools and Applications. – 2023. – <https://doi.org/10.1007/s11042-023-15799-8>.
119. Dyke R.M., Hormann K. Histogram Equalization Using a Selective Filter // The Visual Computer. – 2023. – Vol. 39. – P. 6221–6235. <https://doi.org/10.1007/s00371-022-02723-8>.
120. Shah A., Bangash J.I., Khan A.W., Ahmed I., Khan A., Khan A., Khan A. Comparative Analysis of Median Filter and Its Variants for Removal of Impulse Noise from Gray Scale Images // Journal of King Saud University – Computer and Information Sciences. – 2022. – Vol. 34, № 3. – P. 505–519. <https://doi.org/10.1016/j.jksuci.2020.03.007>.
121. Suryanarayana G. et al. Accurate MR Image SR Using Deep Networks and Gaussian Filtering // IEEE Access. – 2021. – Vol. 9. – DOI:10.1109/ACCESS.2021.3077611.
122. Spagnolo F. et al. Design of Approximate Bilateral Filters for Image Denoising on FPGAs // IEEE Access. – 2023. – Vol. 11. – DOI:10.1109/ACCESS.2022.3233921.
123. Jiang C., Ren H., Ye X., Zhu J., Zeng H., Nan Y., Sun M., Ren X., Huo H. Object Detection from UAV Thermal Infrared Images and Videos Using YOLO Models // International Journal of Applied Earth Observation and Geoinformation. – 2022. – Vol. 112. – P. 102912.
124. Ultralytics. YOLOv5. – 2020. – Available online: <https://github.com/ultralytics/yolov5> (accessed on 1 June 2025).
125. Terven J., Córdova-Esparza D.-M., Romero-González J.-A. A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS // Machine Learning and Knowledge Extraction. – 2023. – Vol. 5. – P. 1680–1716.
126. Hidayatullah P., Tubagus R. YOLOv9 Architecture Explained | Stunning Vision AI. – Available online: <https://article.stunningvisionai.com/yolov9-architecture> (accessed on 1 June 2025).
127. Wang Y., Li K., Zhang Y., Han J., Wang C. YOLOv10: Real-Time End-to-End Object Detection // arXiv. – 2024. – arXiv:2405.14458.
128. Khanam R., Hussain M. YOLOv11: An Overview of the Key Architectural Enhancements // arXiv. – 2024. – arXiv:2410.17725.
129. Tian Y., Ye Q., Doermann D. YOLOv12: Attention-Centric Real-Time Object Detectors // arXiv. – 2025. – arXiv:2502.12524. Available online: <https://github.com/sunsmarterje/yolov12> (accessed on 1 June 2025).
130. Hidayatullah P., Syakrani N., Sholahuddin M.R., Gelar T., Tubagus R. YOLOv8 to YOLOv11: A Comprehensive Architecture In-Depth Comparative Review // arXiv. – 2024. – arXiv:2501.13400.

131. Glenn J. Shortcut in Backbone and Neck // Ultralytics/ultralytics, GitHub Issues #1200. – Available online: <https://github.com/ultralytics/ultralytics/issues/1200#issuecomment-1454873251> (accessed on 15 June 2025).
132. Glenn J. Understanding SPP and SPPF Implementation // Ultralytics/yolov5, GitHub Issues #8785. – Available online: <https://github.com/ultralytics/yolov5/issues/8785> (accessed on 15 June 2025).
133. Hu J., Zheng J., Wan W., Zhou Y., Huang Z. RT-DETR-EVD: An Emergency Vehicle Detection Method Based on Improved RT-DETR // Sensors. – 2025. – Vol. 25. – P. 3327.
134. He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition // Proc. IEEE Conference on Computer Vision and Pattern Recognition. – Las Vegas, NV, USA, 27–30 June 2016. – P. 770–778.
135. Chen J., Lei B., Song Q., Ying H., Chen D.Z., Wu J. A Hierarchical Graph Network for 3D Object Detection on Point Clouds // Proc. IEEE/CVF Conference on Computer Vision and Pattern Recognition. – Seattle, WA, USA, 13–19 June 2020. – P. 392–401.
136. Caron M., Touvron H., Misra I., Jégou H., Mairal J., Bojanowski P., Joulin A. Emerging Properties in Self-Supervised Vision Transformers // Proc. IEEE/CVF International Conference on Computer Vision. – Montreal, QC, Canada, 10–17 October 2021. – P. 9650–9660.
137. Tlebaldinova A., Omiotek Z., Karmenova M., Kumargazhanova S., Smailova S., Tankibayeva A., Kumarkanova A., Glinskiy I. Comparison of Modern Convolution and Transformer Architectures: YOLO and RT-DETR in Meniscus Diagnosis // Computers. – 2025.- 14, 333, DOI:10.3390/computers14080333.
138. Tian J., Jin Q., Wang Y., Yang J., Zhang S. Performance Analysis of Deep Learning-Based Object Detection Algorithms on COCO Benchmark: A Comparative Study // Journal of Engineering and Applied Science. – 2024. – Vol. 71. – P. 76.
139. Padilla R., Passos W.L., Dias T.L.B., Netto S.L., da Silva E.A.B. A Comparative Analysis of Object Detection Metrics with a Companion Open-Source Toolkit // Electronics. – 2021. – Vol. 10. – P. 279.
140. Zhao B., Chang L., Liu Z. Fast-YOLO Network Model for X-Ray Image Detection of Pneumonia // Electronics. – 2025. – Vol. 14. – P. 903.
141. Mercaldo F., Brunese L., Martinelli F., Santone A., Cesarelli M. Object Detection for Brain Cancer Detection and Localization // Applied Sciences. – 2023. – Vol. 13. – P. 9158.
142. Wang Q., Yan N., Qin Y., Zhang X., Li X. BED-YOLO: An Enhanced YOLOv10n-Based Tomato Leaf Disease Detection Algorithm // Sensors. – 2025. – Vol. 25. – P. 2882.
143. Roblot V., Giret Y., Antoun M.B., Morillot C., Chassin X., Cotten A., Zerbib J., Fournier L. Artificial Intelligence to Diagnose Meniscus Tears on MRI // Diagnostic and Interventional Imaging. – 2019. – Vol. 100. – P. 243–249.

144. Rizk B., Brat H., Zille P., Guillin R., Pouchy C., Adam C., Ardon R., D'Assignies G. Meniscal Lesion Detection and Characterization in Adult Knee MRI: A Deep Learning Model Approach with External Validation // *Physica Medica*. – 2021. – Vol. 83. – P. 64–71.
145. Li J., Qian K., Liu J., Huang Z., Zhang Y., Zhao G., Wang H., Li M., Liang X., Zhou F. et al. Identification and Diagnosis of Meniscus Tear by Magnetic Resonance Imaging Using a Deep Learning Model // *Journal of Orthopaedic Translation*. – 2022. – Vol. 34. – P. 91–101.
146. Botnari A., Kadar M., Patrascu J.M. A Comprehensive Evaluation of Deep Learning Models on Knee MRIs for the Diagnosis and Classification of Meniscal Tears: A Systematic Review and Meta-Analysis // *Diagnostics*. – 2024. – Vol. 14. – P. 1090.
147. He L.-H., Zhou Y.-Z., Liu L., Cao W., Ma J.-H. Research on Object Detection and Recognition in Remote Sensing Images Based on YOLOv11 // *Scientific Reports*. – 2025. – Vol. 15. – P. 14032.

ПРИЛОЖЕНИЕ А – Свидетельство о государственной регистрации  
авторского права РК «Программное обеспечение магнитно-резонансной  
томографии патологий коленного сустава»



## ПРИЛОЖЕНИЕ Б – Акт внедрения результатов исследования

### Акт внедрения результатов научно-исследовательской работы

**Наименование предложения:** Программное обеспечение магнитно-резонансной томографии патологий коленного сустава.

**Работа включена** из грантового финансирования научных и (или) научно-технических проектов на 2024–2026 годы Министерства науки и высшего образования Республики Казахстан (ИРН проекта АР23486396 «Модели и методы распознавания анатомических структур на изображениях МРТ в задачах компьютерной диагностики»).

**Краткая аннотация:** Разработка определяется применением технологий искусственного интеллекта для автоматизированного выделения анатомических структур на МРТ-изображениях, что способствует повышению точности и объективности диагностических заключений. Разработанные технологии улучшают процесс принятия врачебных решений, связанных с определением необходимости хирургического вмешательства и выбором оптимальной тактики лечения. Использование интеллектуальных систем анализа медицинских изображений снижает нагрузку на врачей, уменьшает вероятность диагностических ошибок и повышает достоверность диагностики повреждений менисков коленного сустава, что обеспечивает повышение качества и эффективности медицинской помощи. Объектом исследования является процесс автоматизированного распознавания разрывов менисков на МРТ-изображениях коленного сустава. Предметом исследования являются модели и методы обработки и анализа МРТ-изображений для распознавания и локализации повреждений мениска.

**Эффект от внедрения (социальный, экономический):** Применение программного обеспечения позволит повысить точность диагностики, снизить трудозатраты врачей-рентгенологов, минимизировать диагностические ошибки и улучшить качество медицинской помощи. Внедрение способствует повышению эффективности диагностического процесса и снижению экономической нагрузки на систему здравоохранения.

**Предложения, замечания учреждения, осуществляющего внедрение:** Принять программное обеспечение для автоматизированного анализа МРТ-изображений коленного сустава в практику работы отделений рентгенологии, травматологии и ортопедии медицинских учреждений Республики Казахстан.

**Место и время внедрения:** ННЦТО им. академика Батпенова Н.Д., отделение артроскопии и спортивной травмы, г. Астана, ноябрь 2025 года.

**Форма внедрения:** программное обеспечение для автоматизированного распознавания патологий коленного сустава на МРТ-изображениях, основанное на технологиях искусственного интеллекта.

**Председатель комиссии:**

**Заместитель директора по научной работе и образованию**  
РГП на ПХВ «ННЦТО имени акад. Батпенова Н.Д.»  
PhD, асс. профессор Сагинова Д.А.



**Члены (ответственные за внедрение) и исполнители:**

1. зав. отделением АСТ Асанов Н. М.
2. врач отделения АСТ Мейірбек Н.Е.
3. врач отделения Уразаев М.Н.
4. врач отделения Махметова М.Н.

## ПРИЛОЖЕНИЕ В – Листинг программного кода приложения «XRAY Inspector»

```
import os
from flask import Flask, request, jsonify, send_file
from flask_cors import CORS
import pydicom
from werkzeug.utils import secure_filename
import time
import numpy as np
from functools import lru_cache
import io
import base64
import matplotlib
matplotlib.use('Agg')
import matplotlib.pyplot as plt
import seaborn as sns
from PIL import Image, ImageDraw
from collections import defaultdict

UPLOAD_FOLDER = 'uploads'
ALLOWED_EXTENSIONS = {'dcm'}

app = Flask(__name__)
CORS(app)
app.config['UPLOAD_FOLDER'] = UPLOAD_FOLDER

os.makedirs(UPLOAD_FOLDER, exist_ok=True)

def allowed_file(filename):
    return '.' in filename and filename.rsplit('.', 1)[1].lower() in ALLOWED_EXTENSIONS

image_store = {}

def get_image(filename, layer):
    key = f'{filename}-{layer}'
    stored = image_store.get(key)
    if (stored is not None):
        img = stored
    else:
        arr, ds = load_dicom(filename)
        if arr.ndim == 2:
            img = arr
        elif arr.ndim >= 3:
            img = arr[layer]
        else:
            return jsonify({"error": "Unsupported image shape"}), 400
        image_store[key] = img
    return img

@lru_cache(maxsize=128)
def load_dicom(filename):
    filepath = os.path.join(app.config['UPLOAD_FOLDER'], filename)
    if not os.path.exists(filepath):
        return jsonify({"error": "File not found"}), 404
    ds = pydicom.dcmread(filepath)
    return ds.pixel_array, ds

@app.route('/')
def home():
    return jsonify({"message": "Flask server is running"})
```

```

@app.route('/upload', methods=['POST'])
def upload_dicom():
    file = request.files.get('file')
    filename_from_client = request.form.get('filename') or request.json.get('filename') if request.is_json else None

    if not file and not filename_from_client:
        return jsonify({"error": "No file or filename provided"}), 400

    if file:
        filename = secure_filename(file.filename)
        name, ext = os.path.splitext(filename)
        timestamp = int(time.time())
        new_filename = f"{name}_{timestamp}{ext}"
        filepath = os.path.join(app.config['UPLOAD_FOLDER'], new_filename)
        file.save(filepath)
        return jsonify({
            "filename": new_filename,
        })

@app.route('/view_file', methods=['GET'])
def view_file():
    filename = request.args.get('filename')
    new_filename = secure_filename(filename)

    try:
        arr, ds = load_dicom(new_filename)

        metadata = {
            elem.keyword: str(elem.value)
            for elem in ds
            if elem.keyword and elem.keyword != "PixelData"
        }

        images = []

        if arr.ndim == 2:
            images.append(arr)
        elif arr.ndim == 3:
            for i in range(arr.shape[0]):
                images.append(arr[i])
        elif arr.ndim == 4:
            for i in range(arr.shape[0]):
                gray = np.dot(arr[i][..., :3], [0.299, 0.587, 0.114]).astype(np.uint8)
                images.append(gray)

        series_dict = defaultdict(list)
        if hasattr(ds, "SeriesInstanceUID"):
            series_dict[ds.SeriesInstanceUID].append(ds.SOPInstanceUID)

        if hasattr(ds, "NumberOfFrames") and "PerFrameFunctionalGroupsSequence" in ds:
            for i, frame in enumerate(ds.PerFrameFunctionalGroupsSequence):
                try:
                    uid = frame.FrameContentSequence[0].SeriesInstanceUID
                except Exception:
                    uid = ds.SeriesInstanceUID
                series_dict[uid].append(i)

        series_info = {
            uid: len(images)
            for uid, images in series_dict.items()
        }
    
```

```

return jsonify({
    "metadata": metadata,
    "shape": np.shape(images),
    "study_uid": str(ds.StudyInstanceUID),
    "series_info": series_info,
    "total_series": len(series_info)
})

except Exception as e:
    return jsonify({"error": f"Failed to read DICOM: {str(e)}"}), 500

@app.route('/list_images', methods=['POST'])
def list_imgs():
    try:
        files = os.listdir(app.config['UPLOAD_FOLDER'])
        dicom_files = [f for f in files if f.lower().endswith('.dcm')]
        return jsonify({
            "files": dicom_files
        })
    except Exception as e:
        return jsonify({"error": f"Failed to list files: {str(e)}"}), 500

@app.route('/state', methods=['POST'])
def get_state():
    data = request.get_json()

    filename = data.get('image')
    layer = data.get('layer', 0)
    sel = data.get('sel')
    sel_type = data.get('type')
    limits = data.get('limits', None)
    normalize = data.get('normalize', None)

    # try:
    img = get_image(filename, layer)

    h = img.shape[0]
    w = img.shape[1]
    size = {"width": w, "height": h}

    X = (img - img.min()) / (np.ptp(img))

    if normalize == 'row':
        X = X / np.max(X, axis=1, keepdims=True)
    elif normalize == 'col':
        X = X / np.max(X, axis=0, keepdims=True)

    X = (X * 255).clip(0, 255).astype(np.uint8)

    pil_img = Image.fromarray(X).convert("RGB")
    draw = ImageDraw.Draw(pil_img)
    if sel is not None and sel_type in ['row', 'col']:
        sel = int(sel)
        if sel_type == 'row' and 0 <= sel < h:
            draw.line([(0, sel), (w, sel)], fill="red", width=1)
            profile = X[sel, :]
        elif sel_type == 'col' and 0 <= sel < w:
            draw.line([(sel, 0), (sel, h)], fill="red", width=1)
            profile = X[:, sel]
        else:
            profile = None
    else:
        profile = None

```

```

else:
    profile = None
img_io = io.BytesIO()
pil_img.save(img_io, format='PNG')
img_io.seek(0)
img_b64 = base64.b64encode(img_io.read()).decode()
chart_b64 = ""
if profile is not None:
    y_max = max(255, int(profile.max()))
    x_start, x_end = (limits if limits and len(limits) == 2 else (0, len(profile)))
    x_vals = list(range(len(profile)))[x_start:x_end]
    y_vals = profile[x_start:x_end]

    fig, ax = plt.subplots()
    ax.plot(x_vals, y_vals, color='black')
    # ax.set_xlabel('Index')
    ax.set_ylabel('Яркость')
    ax.set_xlabel('Пиксель')
    ax.set_xlim(0, y_max)
    ax.set_ylim(0, y_max)
    ax.set_xlim(x_start, x_end)
    ax.set_title(f'{ "Строка" if sel_type == "row" else "Столбец" } № {sel}')

    buf = io.BytesIO()
    plt.savefig(buf, format='png', bbox_inches='tight')
    plt.close(fig)
    buf.seek(0)
    chart_b64 = base64.b64encode(buf.read()).decode()

return jsonify({
    "image": f"data:image/png;base64,{img_b64}",
    "chart": f"data:image/png;base64,{chart_b64}" if chart_b64 else "",
    "size": size
})

# except Exception as e:
#     return jsonify({ "error": str(e)}), 500

@app.route('/norm', methods=['POST'])
def get_norm():
    data = request.get_json()
    filename = data.get('image')
    layer = data.get('layer', 0)

    img = get_image(filename, layer)

    if img.ndim == 3 and img.shape[-1] == 3:
        img = np.mean(img, axis=2)
    elif img.ndim == 3:
        img = img[..., 0]

    X = (img - img.min()) / (np.ptp(img) + 1e-8)
    # X = (X * 255).astype(np.uint8)

    mat_r = np.roll(X, -1)
    mat_c = np.roll(X, -1, axis=0)

    Y = abs(X - mat_r)
    Z = abs(X - mat_c)

    X1 = X / (np.max(X, axis=1, keepdims=True) + 1e-8)
    Y1 = Y / (np.max(Y, axis=1, keepdims=True) + 1e-8)
    Z1 = Z / (np.max(Z, axis=1, keepdims=True) + 1e-8)

```

```

X2 = X / (np.max(X, axis=0, keepdims=True) + 1e-8)
Y2 = Y / (np.max(Y, axis=0, keepdims=True) + 1e-8)
Z2 = Z / (np.max(Z, axis=0, keepdims=True) + 1e-8)

A = np.sum(X1, axis=1)
B = np.sum(X2, axis=0)

C = np.sum(Y1, axis=1)
D = np.sum(Y2, axis=0)

E = np.sum(Z1, axis=1)
F = np.sum(Z2, axis=0)

Q = np.stack([A, B, C, D, E, F], axis=1)

R = np.corrcoef(Q, rowvar=False)
l = ['X1', 'X2', 'Y1', 'Y2', 'Z1', 'Z2']

fig, ax = plt.subplots(figsize=(8, 6))
sns.heatmap(R, annot=True, cbar=True, xticklabels=l, yticklabels=l, ax=ax)
buf = io.BytesIO()
plt.savefig(buf, format='png', bbox_inches='tight')
plt.close(fig)
buf.seek(0)
chart_b64 = base64.b64encode(buf.read()).decode()
corr = f"data:image/png;base64,{chart_b64}" if chart_b64 else ""

images = []
for i in [X, Y, Z, X1, Y1, Z1, X2, Y2, Z2]:
    arr = (i * 255).clip(0, 255).astype(np.uint8) if i.dtype != np.uint8 else i
    pil_img = Image.fromarray(arr).convert("L")
    img_io = io.BytesIO()
    pil_img.save(img_io, format='PNG')
    img_io.seek(0)
    img_b64 = base64.b64encode(img_io.read()).decode()
    images.append(f"data:image/png;base64,{img_b64}")

return jsonify({
    "images": images,
    "corr": corr,
})
}

@app.route('/download', methods=['GET'])
def download_file():
    filename = request.args.get('file')
    if '..' in filename or filename.startswith('/'):
        return jsonify({"error": "Invalid filename"}), 400
    if not filename:
        return jsonify({"error": "No file specified"}), 400

    filepath = os.path.join(app.config['UPLOAD_FOLDER'], secure_filename(filename))
    if not os.path.exists(filepath):
        return jsonify({"error": "File not found"}), 404

    return send_file(filepath, as_attachment=True)

@app.route('/delete', methods=['DELETE'])
def delete_file():
    filename = request.args.get('file')
    if '..' in filename or filename.startswith('/'):
        return jsonify({"error": "Invalid filename"}), 400

```

```
if not filename:
    return jsonify({"error": "No file specified"}), 400

filepath = os.path.join(app.config['UPLOAD_FOLDER'], secure_filename(filename))
if not os.path.exists(filepath):
    return jsonify({"error": "File not found"}), 404

try:
    os.remove(filepath)
    return jsonify({"message": "File deleted successfully"}), 200
except Exception as e:
    return jsonify({"error": f"Failed to delete file: {str(e)}"}), 500

if __name__ == '__main__':
    app.run(host='0.0.0.0', port=5000, debug=True)
```