

ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ БЮДЖЕТНОЕ УЧРЕЖДЕНИЕ
«НАЦИОНАЛЬНЫЙ МЕДИЦИНСКИЙ ИССЛЕДОВАТЕЛЬСКИЙ ЦЕНТР
ХИРУРГИИ ИМ. А.В. ВИШНЕВСКОГО» МИНИСТЕРСТВА
ЗДРАВООХРАНЕНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ

На правах рукописи

АРУТЮНОВА КСЕНИЯ АНДРЕЕВНА

**ВОЗМОЖНОСТИ АВТОМАТИЗИРОВАННОЙ ДИАГНОСТИКИ
ГИПОВАСКУЛЯРНЫХ И ГИПЕРВАСКУЛЯРНЫХ НОВООБРАЗОВАНИЙ
ПОДЖЕЛУДОЧНОЙ ЖЕЛЕЗЫ НА КОМПЬЮТЕРНЫХ ТОМОГРАММАХ**

3.1.25 – Лучевая диагностика
(медицинские науки)

ДИССЕРТАЦИЯ

на соискание учёной степени
кандидата медицинских наук

Научный руководитель:
доктор медицинских наук
профессор, академик РАН
Кармазановский Григорий Григорьевич

Москва – 2025

ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ	4
ГЛАВА 1. ОБЗОР ЛИТЕРАТУРЫ	11
1.1. Гиперваскулярные и гиповаскулярные опухоли поджелудочной железы и их диагностика.....	11
1.2. Алгоритмы компьютерного зрения в лучевой диагностике поджелудочной железы и ее патологических изменений.....	17
ГЛАВА 2. МАТЕРИАЛ И МЕТОДЫ.....	36
2.1. Дизайн исследования	36
2.2. Общая характеристика пациентов.....	37
2.3. Методика выполнения компьютерной томографии.....	40
2.4. Методика сегментации поджелудочной железы и ее гипо- и гиперваскулярных образований по данным компьютерной томографии.....	40
2.5. Оценка разницы ручной сегментации поджелудочной железы между разными врачами-рентгенологами с выявлением наиболее критических зон	42
2.5.1. Качественный анализ, сравнение с эталонной разметкой опытного врача-рентгенолога	42
2.5.2. Машинный анализ, сравнение объемов 3D-масок поджелудочной железы	43
2.6. Оценка возможностей системы компьютерного зрения по компьютерным томограммам с внутривенным контрастированием в сегментации паренхимы поджелудочной железы и ее образований.....	44
2.6.1. Качественный анализ компьютерных томограмм пациентов с гиповаскулярными и гиперваскулярными образованиями поджелудочной железы и без них	44
2.6.2. Машинный анализ	45
2.7. Оценка возможностей алгоритмов системы компьютерного зрения по компьютерным томограммам с внутривенным контрастированием в детекции образований поджелудочной железы.....	48

2.7.1. Методология оценки возможностей нейросети.....	48
2.8. Статистический анализ.....	49
ГЛАВА 3. ВОЗМОЖНОСТИ КОМПЬЮТЕРНОГО ЗРЕНИЯ В СЕГМЕНТАЦИИ И ДЕТЕКЦИИ ОБРАЗОВАНИЙ ПОДЖЕЛУДОЧНОЙ ЖЕЛЕЗЫ ПО КОМПЬЮТЕРНЫМ ТОМОГРАММАМ.....	53
3.1. Результаты определения зависимости точности сегментации врача- рентгенолога от внешних факторов и опыта.....	53
3.2. Результаты определения точности сегментации паренхимы поджелудочной железы системой компьютерного зрения по данным компьютерной томографии.....	62
3.3. Результаты определения точности сегментации образований поджелудочной железы системой компьютерного зрения по данным компьютерной томографии.....	63
3.4. Оценка функции детекции образований поджелудочной железы системой компьютерного зрения по данным компьютерной томографии.....	63
3.5. Обсуждение результатов валидации системы компьютерного зрения для сегментации поджелудочной железы и детекции ее образований по компьютерной томографии.....	69
ЗАКЛЮЧЕНИЕ	74
ВЫВОДЫ	83
ПРАКТИЧЕСКИЕ РЕКОМЕНДАЦИИ.....	84
СПИСОК СОКРАЩЕНИЙ И УСЛОВНЫХ ОБОЗНАЧЕНИЙ.....	86
СПИСОК ЛИТЕРАТУРЫ.....	87
ПРИЛОЖЕНИЕ А Абсолютные отклонения от значений эталона масштабированные на его абсолютные значения и направления отклонений.....	104

ВВЕДЕНИЕ

Актуальность темы и степень ее разработанности

Образования поджелудочной железы (ПЖ) обладают разным гистологическим строением, степенями злокачественности и особенностями контрастирования на компьютерной томографии (КТ).

По паттернам контрастирования опухоли ПЖ разделяют на 2 группы: гиповаскулярные и гипervasкулярные. Но, конечно, есть образования, контрастирование которых не соответствует привычным параметрам, и они изоденсны относительно нормальной паренхимы железы [3].

К наиболее часто встречающемуся гиповаскулярному образованию ПЖ относится протоковая аденокарцинома. Наиболее распространенное гипervasкулярное образование ПЖ – нейроэндокринная опухоль. Оно требует дифференциальной диагностики с интрапанкреатической долькой селезенки, метастазами в ПЖ, солидным вариантом серозной цистаденомы, опухолями близлежащих органов [3].

Рак поджелудочной железы (РПЖ), один из наиболее частых, имеет неблагоприятный прогноз и обычно приводит к летальному исходу [3, 8, 125]. Больные с этим диагнозом требуют неотложного лечения, в том числе хирургического, если это возможно на данной стадии. Риск рецидива и смертность увеличивается при задержке лечения, что делает раннюю диагностику опухоли ПЖ решающим фактором для успешного хирургического лечения [125].

В Российской Федерации РПЖ является четвертой причиной смертности от всех видов рака. А в США прогнозируется, что к 2030 г. этот рак станет второй по значимости причиной смертности от рака, а выживаемость, когда размер опухоли превосходит 2 см, становится крайне низкой. Также в Российской Федерации удельный вес морфологических верификаций ниже всего именно у РПЖ [8, 112].

КТ часто является первым исследованием, по которому впервые выявляют опухоль и затем оценивают его распространенность, но диагностическая

эффективность метода зависит от опыта рентгенологов. Кроме того, примерно 40% опухолей размером менее 2 см не поддаются обнаружению с помощью КТ [37], что подчеркивает острую потребность в новых методах, дополняющих интерпретацию рентгенологом для повышения чувствительности при обнаружении РПЖ.

Панкреатические нейроэндокринные опухоли (НЭО) достаточно редки и составляют около 2% от всех неоплазий ПЖ, однако являются потенциально злокачественными. Несмотря на улучшение качества диагностики и развитие методов лечения, прогноз у пациентов зависит от степени дифференцировки опухоли [16].

Согласно российским и международным рекомендациям КТ или магнитно-резонансная томография (МРТ) с внутривенным болюсным контрастированием являются обязательными процедурами при подозрении на аденокарциному или НЭО ПЖ и предоперационном обследовании. КТ позволяет определить локализацию опухоли и провести стадирование [99].

Искусственный интеллект (ИИ) и машинное обучение – быстро развивающиеся отрасли, которые не обошли стороной и здравоохранение. Области их применения расширяются с каждым годом, как и возможности внедрения в повседневный рабочий процесс.

Практическое применение ИИ актуально из-за образовавшегося кадрового дефицита и увеличившимся количеством исследований, заболеваний.

В статье Burnout in Radiology Michelle Chen [47] говорится о том, что выгорание является чрезвычайно распространенной проблемой среди медицинских работников. Врачи-рентгенологи не являются исключением, и у 46% из них в исследовании 2023 года определяются симптомы выгорания.

ИИ поможет улучшить качество диагностики / лечения, снизить нагрузку на врачей и число диагностических ошибок, сократить назначение ненужных исследований.

Машинное обучение продемонстрировало хорошую работу в выявлении заболеваний, таких как диабетическая ретинопатия, туберкулез, рак молочной

желез, нарушения ритма сердца [39]. Среди успешных алгоритмов ИИ наиболее высокой диагностической точностью отличается модель DL CADx, которая классифицирует доброкачественные и злокачественные опухоли молочной железы [53].

Все это дает основание полагать, что для выявления злокачественных поражений ПЖ можно разработать алгоритм машинного обучения, который сможет решить вышеперечисленные проблемы.

Уже с 2018 года стали появляться научные работы, посвященные применению алгоритмов машинного обучения при гипо- и гиперваскулярных образованиях ПЖ, однако результаты являются крайне разнообразными из-за использования различных видов нейросетей и наборов данных для разных целей.

В дальнейшем для внедрения в рутинную практику врача-рентгенолога систем ИИ необходимо автоматизировать точное определение местоположения органа и его поражения, то есть построение сегментационной маски, а затем объединить с функциями детекции и классификации.

Поэтому первым этапом для обучения нейросети следует рассматривать самую объемную часть работы – ручную сегментацию ПЖ и ее образований.

Таким образом, мало изучены возможности алгоритмов машинного обучения в сегментации ПЖ и ее образований, сопоставимость полученных результатов с результатами врачей-рентгенологов, применимость алгоритмов на разных наборах данных. Разработка алгоритмов глубокого машинного обучения является одной из актуальных клинических и научных задач и требует изучения точности в сравнении с врачами-рентгенологами с разным опытом и оценки воспроизводимости полученных результатов в рутинной практике.

Цель исследования

Повышение эффективности выявления образований ПЖ с помощью алгоритмов машинного обучения по данным КТ.

Задачи исследования

1. Разработать алгоритм создания и разметки набора данных компьютерных томограмм для обучения сверточных нейронных сетей с целью выполнения трехмерной сегментации и оценки ткани ПЖ, выявления патологических образований.

2. Провести анализ качества разметки данных КТ исследований ПЖ с гипо- и гиперваскулярными образованиями ПЖ. Выявить факторы, влияющие на качество разметки данных, оценить текстурные характеристики краев ПЖ на КТ-снимках.

3. Определить степень совпадения сегментационных масок ПЖ и патологических образований в ней, размеченных врачом и системой компьютерного зрения.

4. Оценить диагностическую ценность алгоритма ИИ в выявлении образований ПЖ.

Научная новизна исследования

Впервые проведена оценка точности врача-рентгенолога и ИИ в сегментации гиперваскулярных и гиповаскулярных образований ПЖ, оценена диагностическая и прогностическая точность и воспроизводимость результатов в условиях НМИЦ хирургии им. А.В. Вишневского. Впервые построен подробный алгоритм сегментации и обучения нейросетей.

Практическая и теоретическая значимость работы

Полученные результаты позволят: разработать методологию создания и разметки набора данных компьютерных томограмм для обучения сверточных нейронных сетей с целью выполнения трехмерной сегментации гиперваскулярных и гиповаскулярных образований ПЖ. Результаты диссертационного исследования использованы для разработки модели ИИ и внедрены в практическую работу отделения рентгенологии и магнитно-резонансных методов исследования ФГБУ «НМИЦ хирургии имени

А.В. Вишневого», а также опубликованы в центральной печати, представлены на съездах и конференциях.

Методология и методы исследования

На амбулаторном этапе пациентам будет выполняться мультиспиральная КТ органов брюшной полости с внутривенным контрастным усилением по модифицированному низкодозовому протоколу (100 kV) и по стандартному протоколу (120 kV). Пациенты с гиперваскулярными и гиповаскулярными образованиями ПЖ при КТ органов брюшной полости с внутривенным контрастным усилением и наличием морфологической верификации образования будут включены в исследование. Часть исследований будет размечаться врачами-рентгенологами для создания входного обучающего массива данных для глубокого машинного обучения. Затем будет сравниваться разметка ИИ и врачей-рентгенологов на валидационной выборке, врачей-рентгенологов между собой в зависимости от внешних факторов. Будет оценена воспроизводимость и диагностическая ценность разметчика компьютерных томограмм исследования при применении протокола сканирования (120 Kv и 100 Kv) в диагностике гиперваскулярных и гиповаскулярных образований ПЖ.

Основные положения, выносимые на защиту

1. Создание алгоритма для обучения нейросети построению сегментационных масок ПЖ и ее образований по компьютерным томограммам органов брюшной полости с контрастированием возможно с достаточно высоким результатом, что может помочь в дальнейшем использовать этот алгоритм обучения в создании продукта для предоперационного планирования лечения пациентов с образованиями ПЖ.

2. Использование алгоритмов машинного обучения может помочь в создании помощника врачу-рентгенологу в диагностике образований ПЖ, а также может обеспечить раннюю диагностику новообразований ПЖ.

3. Обучение нейросети в построении сегментационных масок образований в дальнейшем могут использоваться для классификации и разработки автоматического вычисления текстурных характеристик и дооперационной дифференциальной диагностики образований ПЖ.

Внедрение результатов работы в практику

Разработан алгоритм для обучения нейросети сегментации поджелудочной железы по КТ органов брюшной полости с внутривенным болюсным контрастированием для дальнейшего внедрения в диагностический процесс в отделе лучевых методов диагностики и лечения ФГБУ «Национальный медицинский исследовательский центр хирургии им. А.В. Вишневского» Министерства Здравоохранения России.

Апробация диссертационной работы

Основные положения диссертации были доложены и обсуждены на отечественных и международных научных конференциях и конгрессах: на всероссийском национальном конгрессе лучевых диагностов и терапевтов «Радиология» 2021, 2022 гг., г. Москва; на конгрессе Российского общества рентгенологов и радиологов 2021, 2022, 2023 гг., г. Москва; на всероссийском научно-образовательном конгрессе с международным участием «Онкорadiология, лучевая диагностика и терапия» 2021, 2022, 2023 и 2024 гг., г. Москва.

Личный вклад автора

Личный вклад автора состоит в наборе и составлении базы данных пациентов, сегментации ПЖ и выявленных образований ПЖ, аналитической и статистической обработке полученных данных. Автор проанализировал 96 источников отечественной и зарубежной литературы, самостоятельно систематизировал полученный в ходе исследования набор данных.

Соответствие диссертации паспорту научной специальности

Диссертация соответствует паспорту специальности 3.1.25 – Лучевая диагностика (Медицинские науки), а также области исследования, в диссертационной работе научно обоснованы возможности применения алгоритмов машинного обучения в обнаружении и дифференциальной диагностике опухолей ПЖ по компьютерным томограммам органов брюшной полости с внутривенным контрастированием.

Публикации

По материалам диссертационной работы опубликовано 4 работы в центральной печати и сборниках научных конференций. Из них 3 статьи – в журналах, входящих в перечень научных изданий, рекомендованных ВАК, 2 статьи – в журналах, входящих в перечень Scopus, 2 тезиса в материалах научных конгрессов.

Структура и объем диссертации

Диссертация изложена на 106 страницах машинописного текста, состоит из введения, трёх глав, заключения, выводов, практических рекомендаций, приложения и списка литературы, который включает 16 отечественных и 113 иностранных источников. Представленный материал иллюстрирован 13 рисунками, 17 таблицами.

ГЛАВА 1. ОБЗОР ЛИТЕРАТУРЫ

1.1. Гиперваскулярные и гиповаскулярные опухоли поджелудочной железы и их диагностика

Согласно международным и отечественным рекомендациям, КТ с внутривенным болюсным контрастированием является обязательным методом диагностики панкреатических новообразований, благодаря высокой чувствительности и возможности выполнения стадирования процесса [44, 65, 66]. КТ позволяет обнаружить опухоль ПЖ, сделать предположение о ее морфологии, оценить местную распространенность и инвазию сосудов и выявить отдаленные метастазы [10, 56, 112, 113].

Для повышения чувствительности и специфичности КТ при выявлении опухолей ПЖ применяется мультифазный протокол с внутривенным контрастированием. Наиболее эффективным признан двухфазный режим, включающий панкреатическую (позднюю артериальную) и портальную венозную фазы. В ряде работ сообщается, что при таком протоколе диагностическая точность достигает 89-92%, чувствительность – до 90%, а специфичность – около 87%, хотя это относится к достаточно крупным образованиям – не на ранней стадии [26]. Толщина срезов 0,625-1,25 мм и скорость сканирования 3-4 мл/с обеспечивают визуализацию сосудов, тканей опухоли и окружающих структур. Поздняя артериальная фаза особенно полезна при оценке гиповаскулярных образований, поскольку обеспечивает максимальную разницу плотности между опухолью и неизменённой паренхимой железы [6].

Несмотря на эффективность панкреатической и портальной фаз, в некоторых случаях, например при изоденсных образованиях, может потребоваться выполнение отсроченной фазы или дополнение другими методами визуализации, такими как МРТ или ПЭТ/КТ.

Среди панкреатических опухолей, выявляемых при КТ, по паттернам контрастирования выделяют гипervasкулярные и гиповаскулярные опухоли. К гипervasкулярным относятся опухоли, накапливающие контрастный препарат в артериальную или венозную фазы исследования интенсивнее, чем неизменённая паренхима ПЖ [107]. Гиповаскулярные опухоли, наоборот, накапливают контрастный препарат слабее, чем нормальная ткань ПЖ [63, 90]. К наиболее часто встречающимся гиповаскулярным панкреатическим опухолям относится протоковая аденокарцинома ПЖ [63, 90].

Заболеваемость РПЖ неуклонно растёт, при этом наиболее высокие цифры смертности наблюдаются в восточной и западной Европе [60]. По данным Global Cancer Observatory (GLOBOCAN) за 2022 год, во всём мире было зарегистрировано около 1,5 млн новых случаев злокачественных новообразований (ЗНО) предстательной железы. Это составляло 7,3% в общей структуре онкологической заболеваемости (четвёртое место) и 14,2% в структуре мужской онкологической заболеваемости (второе место после ЗНО трахеи, бронхов и легкого) [76]. Прогнозировалось, что к 2035 году количество новых случаев РПЖ вырастет до 2,1 млн, а смертность – на 51,8% и достигнет 603,2 тыс. случаев [76]. При этом среди пациентов с РПЖ отмечается наименьший процент морфологической верификации – 65% [63].

Также это онкологическое заболевание обладает одним из самых низких уровней пятилетней выживаемости, составляя около 30% [109]. Связано это преимущественно с диагностикой опухоли на поздних стадиях. Ранняя диагностика РПЖ остается крайне сложной задачей. Даже при выполнении стандартной КТ-диагностики небольшие или изоатентивные опухоли могут быть пропущены. Такие образования зачастую не вызывают обструкции протока, не сопровождаются дилатацией и сливаются с паренхимой, особенно в головке или хвосте железы. При этом использование панкреатической фазы, согласно данным литературы, повышает диагностическую точность на 15-20% по сравнению с классическими исследованиями [7].

Подобные трудности подчеркивают необходимость мультидисциплинарного подхода и дополнительного применения таких методов как МРТ с DWI-последовательностями, ПЕТ/СТ и эндоскопического УЗИ.

Тем не менее РПЖ все равно крайне редко диагностируется на ранней стадии, только около 2% всех случаев диагностируются на стадиях 0 и I. Однако, согласно отчету, составленному Регистром рака поджелудочной железы Японского общества по борьбе с РПЖ, пятилетний показатель общей выживаемости у пациентов со стадией 0 составил 85,8%, стадией Ia – 68,7% и стадией Ib – 59,7%, что превышает этот показатель на стадии II или выше. Это демонстрирует, что для улучшения прогноза пациентов с РПЖ необходима система эффективного выявления пациентов и облегчения ранней диагностики [100].

К наиболее часто встречающимся гиперваскулярным образованиям ПЖ можно отнести следующие:

- панкреатические нейроэндокринные опухоли (НЭО) [10, 107];
- интрапанкреатическая добавочная долька селезенки [12, 67, 96];
- метастазы светлоклеточного рака почки в ПЖ [73, 83, 96].

Нередко возникают трудности в дифференциальной диагностике упомянутых образований, особенно между интрапанкреатической долькой и НЭО хвоста ПЖ [73].

НЭО ПЖ – достаточно редкая патология, составляющая не более 2-3% [19, 75, 79] от всех панкреатических неоплазий, однако являющаяся второй по частоте встречаемости после протоковых аденокарцином. В Российской Федерации частота встречаемости – 0,7-1,1 случаев на 100 000 человек. Но за последние 20 лет частота выявления НЭО ПЖ увеличилась в 3-4 раза (до 1-2 случаев на 100 000 населения), что связано с улучшением диагностики (КТ, МРТ, эндоскопия) [88]. Панкреатические НЭО относятся к группе эпителиальных образований, происходящих из клеток с нейроэндокринным фенотипом, и составляют до 7% от всех НЭО.

Также они подразделяются морфологически и в зависимости от наличия симптомов секретирующие биологические активные вещества (функционирующие

НЭО) и не секреторные (не функционирующие НЭО). Функционирующие НЭО (инсулиномы, гастриномы) вызывают тяжелые эндокринные нарушения (гипогликемия, язвы желудка), но часто имеют малые размеры (<1 см), что затрудняет обнаружение на КТ (чувствительность для микроаденом – 30-50%). Нефункциональные НЭО (60-70% случаев) длительно протекают бессимптомно, но могут достигать 10 см до выявления [101].

Однако наиболее важным для определения прогноза и тактики лечения является степень дифференцировки опухоли. Согласно классификации ВОЗ от 2017 НЭО ПЖ подразделяются на 3 степени, или грейда, на основании количества митозов в поле зрения и индекса Ki-67 [13, 61]:

- высокая степень дифференцировки, или *low grade* (наименее агрессивная с пятилетней выживаемостью, достигающей 85-100%);
- умеренная степень дифференцировки, или *intermediate grade*;
- низкая степень дифференцировки, или *high grade* (наиболее агрессивная с пятилетней выживаемостью менее 9%) [16].

Из-за разного прогноза лечебная тактика варьирует в зависимости от агрессивности опухоли. 5-летняя выживаемость высокодифференцированных опухолей (G1) составляет 85-100%, низкодифференцированных – в среднем менее года, особенно на поздних стадиях, когда есть признаки метастазирования в другие органы. Единственным радикальным методом лечения является хирургический, который строго рекомендуется для опухолей низкой степени дифференцировки при локализованных формах (G3). Но, к сожалению, 40% НЭО ПЖ выявляются случайно при обследовании по поводу неспецифических симптомов (боли в животе, желтуха), а 20-30% – уже на стадии метастазов [111]. Опухоли высокой степени дифференцировки могут быть подвергнуты энуклеации или локальной резекции ввиду низкого риска метастатического поражения лимфатических узлов, при этом резекция низко- и умеренно дифференцированных опухолей должна сопровождаться регионарной лимфодиссекцией. В то же время клинический мониторинг может рассматриваться при высокодифференцированных опухолях ввиду травматичности и высокого риска осложнений после

оперативных вмешательств на поджелудочной железе, таких как панкреатодуоденальная резекция (ПДР) и панкреатэктомия. При этом ПДР – одна из самых сложных и дорогих операций. А таргетная терапия (препараты сандостатин, сунитиниб) требуют пожизненного приема и обходятся в \$5-10 тыс./мес. Это обуславливает значительную долю в расходах некоторых онкоцентрах, несмотря на редкую встречаемость. А пациенты с функционирующими НЭО страдают от депрессии из-за хронических симптомов (например, приступов гипогликемии), становятся инвалидами из-за проявлений карциноидного синдрома [55].

Как в международных, так и в российских клинических рекомендациях КТ или МРТ с внутривенным болюсным контрастированием является обязательной методом при подозрении на новообразование ПЖ и предоперационном обследовании. КТ позволяет определить локализацию опухоли и выполнить стадирование [66].

Несмотря на то, что КТ с внутривенным болюсным контрастированием является высокоточным методом диагностики и оценки распространенности образований ПЖ из-за перегруженности или низкого уровня насмотренности врачей-рентгенологов и существования некоторых образований, которые плохо визуализируются на КТ-изображениях, особенно размером менее 2 см для аденокарцином и менее 1 см для НЭН, иногда случаются пропуски патологии [2, 73, 77]. Остается открытым вопрос внедрения алгоритмов машинного обучения в рутинную практику врача [4].

Дифференциальный диагноз опухолей ПЖ также имеет решающее значение для определения тактики лечения. В дифференциальной диагностике различных образований ПЖ по данным КТ уже неплохо себя зарекомендовал метод радиомики [14], но для ее применения необходима сегментация всего объема опухоли на КТ-срезах. Ручная сегментация трудоемка и занимает до 15 минут времени врача, автоматизированная сегментация значительно ускоряет процесс и может помочь стандартизировать нечеткие границы образований [6].

В последние годы активно развиваются алгоритмы автоматизированной сегментации, основанные на методах глубокого обучения. Такие модели, как 3D nnU-Net, обученные на обширных базах данных КТ-исследований, демонстрируют высокую точность при сегментации ПЖ и её образований [49].

Это открывает новые возможности для стандартизации радиомического анализа и интеграции ИИ в клиническую практику. Автоматизация позволяет существенно сократить временные затраты, избежать субъективных ошибок, а также расширить доступность количественных методов анализа даже в учреждениях с ограниченным кадровым ресурсом. Но необходимо составить алгоритм обучения нейросетей с учетом особенностей контрастирования органа и образований, его сложной анатомии и расположенных рядом органов и структур.

Как уже упоминалось – для наилучшей визуализации ПЖ, ее патологии и ее образований используется специальный протокол – панкреатическая фаза исследования. Но рутинно ее делают не во всех медицинских учреждениях. Портальная и артериальная фазы исследования обеспечивают также хорошую визуализацию аденокарциномы ПЖ и других гиповаскулярных образований [33]. Хотя для некоторых видов аденокарцином, которые изоденсные в эти фазы имеет смысл анализировать дополнительно отсроченную фазу, на которой они могут быть лучше видны [125].

Артериальная фаза КТ исследования лучше всего подходит для визуализации гипervasкулярных образований ПЖ, таких как нейроэндокринная опухоль, метастазы светлоклеточного рака почки, интрапанкреатической спленулы и других [31].

Поэтому авторы большинства работ используют для обучения нейросетей именно артериальную и портальную фазы [26].

Современные технологии ИИ показали свою эффективность в медицинской визуализации, особенно в задачах компьютерного анализа изображений, которые схожи по сложности с диагностикой ПЖ. Вот некоторые примеры, демонстрирующие эффективность ИИ в анализе изображений других органов, подтверждая его потенциал в широком клиническом контексте: LiLNet (Liver

Lesion Network), разработанная для анализа мультифазных КТ печени, показала точность до 94,7% и AUC 97,2% при различении доброкачественных и злокачественных поражений на валидационной выборке в 4 медицинских центрах [71]; компьютеризированные системы обнаружения (CAD) помогают с высокой точностью распознавать лёгочные узлы на КТ, что существенно сокращает время интерпретации и повышает эффективность скрининга [34]; интегрированный алгоритм на базе Convolutional Neural Network (U-Net с residual-модулями) обучался на Dataset KiTS19 (~300 3D-изображений) и показал отличную производительность: Dice-коэффициент ~96% для почек и ~91% для опухолей, что позволяет использовать такой инструмент при предоперационном планировании и раннем скрининге [57] и еще много подобных примеров.

Несмотря на всё ещё ограниченное внедрение в повседневную клиническую практику, интенсивное развитие технологий ИИ позволяет с уверенностью предполагать, что в обозримом будущем они станут неотъемлемым инструментом поддержки принятия решений для врача-рентгенолога при интерпретации КТ-исследований ПЖ. В настоящей работе был проведён анализ наиболее значимых и перспективных научных публикаций, доступных на момент подготовки диссертации, с целью обоснования актуальности применения ИИ в данной области.

1.2. Алгоритмы компьютерного зрения в лучевой диагностике поджелудочной железы и ее патологических изменений

ИИ на сегодняшний день является одной из самых перспективных областей исследований в области медицинской визуализации. С помощью специальных алгоритмов его можно использовать, чтобы помочь рентгенологам в их рутинном рабочем процессе. Есть множество статей, в которых описываются подходы ИИ к решению различных задач в визуализации различных органов, в том числе печени и ПЖ. Эти задачи можно свести к четырем различным направлениям:

сегментация, количественная оценка, характеристика и улучшение качества изображения. Сегментация обычно является первым шагом последовательных разработок. Если делать это вручную, то это долгий и трудоемкий процесс. Поэтому полуавтоматическое и автоматическое создание маски органа может сэкономить время для других оценок, таких как количественная оценка различных параметров, от объема органов до их текстурных особенностей. Изменения нормальной структуры поджелудочной железы могут указывать на наличие диффузной или очаговой патологии. ИИ можно научить распознавать эти изменения и предлагать диагноз, который затем может быть подтвержден или нет радиологами. Также ИИ может применяться при реконструкции медицинских изображений, чтобы повысить качество изображения, уменьшить дозу облучения и сократить время сканирования [79].

На сегодняшний момент у ИИ существует достаточно большое количество различных функций и возможностей, среди них основные – детекция, классификация и сегментация. Их следует различать между собой, хотя все они в той или иной мере способны решить ряд упомянутых диагностических проблем и повысить уровень оказываемой помощи пациентам.

Детекция в первую очередь позволяет обнаружить патологию (ответить на вопрос есть опухоль или нет), в данном случае опухоль ПЖ, в том числе слабовидимый и небольших размеров. Как показывает анализ зарубежных работ намного выше точность выявления исследований с опухолями при использовании вместе с радиомикой – математическим анализом текстуры в зоне интереса [106].

Классификация обычно обозначает дифференциальную диагностику образований между доброкачественными и злокачественными, например, панкреатит фокального типа и внутрипротоковую аденокарциному, или даже различает grade НЭН. Большинство работ с классификаторами активно используют текстурные характеристики, то есть тоже используют радиомику [98].

Сегментация самого органа и образований в большинстве случаев выполняется рентгенологом вручную или автоматически. Ручная сегментация требует до 15 минут на каждое исследование у врача, а для обучения нейросети

делать это автоматически требуется очень большой объем работы, так как нужно огромное количество исследований построенными сегментационными масками органа и образований на многочисленных изображениях, чтобы нейросеть научилась автоматически «находить» орган и затем в нем патологию. В некоторых работах для повышения точности нахождения границ масок использовали радиомические характеристики [33]. Существует 2D-сегментация и 3D-сегментация, в первом случае разметка и анализ органа и/или образования происходят по срезам и независимо от других срезов, во втором анализируется весь массив данных КТ как единый 3D-массив с учетом пространственных связей и построением целостной модели органа. У 3D-сегментации больше преимуществ: она точнее в случае сосудистой инвазии и малых образований, позволяет строить 3D-модели для подготовки к резекции и воспроизводит объемные текстурные признаки в радиомике. Но есть и минусы: требования к разрешению КТ-исследований (толщина среза не менее 2 мм) и минимальными артефактами, более долгое и сложное обучение 3D-нейросетей [50].

Перспективы применения алгоритмов компьютерного зрения в классификации, детекции и сегментации образований – помощь рентгенологу в диагностике образований ПЖ, «обнаружение» плохо визуализируемых образований, которые не различимы глазом врача, помощь в планировании хирургического лечения, в оценке ответа на химиотерапию, в проведении биопсии и эндоскопических исследований под контролем КТ [20].

Но для внедрения алгоритмов глубокого машинного обучения для рутинного использования в медицинской практике необходимо преодолеть ряд трудностей и учесть опыт зарубежных коллег. Например, многие работы, посвященные детекции или сегментации образований ПЖ и других органов, наглядно продемонстрировали более высокую точность алгоритма при первоначальном поиске паренхимы органа и последующей в этой области или на томограммах данного уровня сегментации образований [118].

Сегментировать органы по КТ-томограммам пытались еще в 2007 г., но так как еще не было такого разнообразия сетей и опыта, результаты были очень

низкие. С появлением машинного обучения точность сегментации выросла до ~65% [25, 42, 89], с 2015-2020 гг. активно внедрялась U-Net и её модификации (75-85%) [81]. Сегодня появились Transformer-архитектуры (Swin UNETR) [128] + 3D-анализ – точность сегментации печени, легких, почек, селезенки превышают 90%, а ПЖ остается несколько ниже [20, 128]. Это из-за того, что ПЖ достаточно сложный для сегментации орган из-за ее анатомических особенностей (например, в области крючковидного отростка, головки и протоков) и дольчатого строения, близкого расположения органов верхнего этажа [115], также разметку паренхимы усложняет выраженный липоматоз органа у пациентов с ожирением и его эндокринной недостаточностью. Bagheri M. и соавт. [40] в своей работе выявили пять параметров, связанных с жиром (таких как индекс массы тела и объем висцерального жира), которые лучше очерчивают профили органов. Хорошо развитый висцеральный жир, особенно парапанкреатическая клетчатка (переднее почечное пространство) улучшает визуализацию органа от кишечника и других структур и повышает точность сегментации органа. Размер ПЖ также имеет значение, чем больше жировой ткани, тем выше точность нейросетей. Количество контрастного препарата (КП), сердечный выброс а также скорость болюсного введения КП имели меньшее значение. При выраженном липоматозе, вариантной анатомии и возрастных изменениях нейросеть выдавала больше ошибок сегментации. По сравнению с другими органами (такими как почки, печень, селезенка) ПЖ – более сложный орган для сегментации как для нейросети, так и для рентгенолога [40].

Поэтому точная ручная сегментация ПЖ требует много времени – в среднем до 30 минут на одно исследование, если несколько фаз контрастирования. Но после обучения алгоритм ИИ может превзойти ручную сегментацию по времени [1, 30]. Однако некоторые работы показывают что важно, чтобы обучение проводилось на разных базах данных, тогда понадобится меньший объем данных и меньше время для ручной разметки [74].

Для обучения нейросетей разных типов чаще используются артериальные и венозные фазы [115] либо только венозные фазы КТ-исследований [40], на КТ-

изображениях панкреатической и портальной фаз исследования лучше всего дифференцируется паренхима ПЖ от окружающих органов и сосудов по сравнению с остальными фазами [40, 115], но панкреатическая фаза есть далеко не во всех протоколах. При включении и артериальной, и венозной фаз в обучающую выборку, разметка производится на них отдельно, так как из-за дыхания и сердцебиения пациента положение органов брюшной полости во время исследования может несколько отличаться [115].

Wang X.H. и др. выявили «критические» зоны сегментации в ПЖ, то есть те, которые были по разному размечены врачами в артериальную и венозную фазу, следует добавить что врачи размечали эти фазы одного и того же исследования с промежутком в две недели. Эти же зоны были сложными для сегментации нейросетью – области прилегания к двенадцатиперстной кишке, дуоденоюнональному изгибу, левому надпочечнику, а также к воротной вене, верхней брыжеечной вене, селезеночной артерии и селезеночной вены. То есть самыми сложными отделами были головка и крючковидный отросток железы [115].

Boers T.G.W. и соавт. [30] также отмечают сложной зоной для сегментации – крючковидный отросток, и что между опытными рентгенологами существуют расхождения в разметке органа (в среднем до 80%). Большинство исследований и авторов используют для своих работ нейросети на основе U-net либо модифицированные на ее основе, так как этот тип нейросетей превосходит по точности другие нейросети и применима на разных датасетах [30, 73].

Перспективным направлением считается обучение с помощью нахождения контуров органа, нередко в таких работах дополнительно используется радиомика [116].

Некоторые авторы используют специальную модель для сегментации 3D-объектов необходимую, чтобы иметь возможность достраивать объемы между срезами. Это дополнительная подсеть, которая восстанавливает недостающие части сегментации и выводит более надежные карты вероятностей, чем исходная 2D-подсеть сверточной нейросети [23, 85]. Как показала одна из работ 2D сеть для

сегментации может быть достаточной для крупных органов, таких как печень, но для более тонких структур или сложных для визуализации органов лучше 3D [23].

Получают результаты количественной сегментации с использованием коэффициента совпадения сегментационных масок (Dice) в процентах, и индекс Жаккара (JI) – они отражают точность по количеству совпадения пикселей. Кроме того, используется усредненное расстояние Хаусдорфа (AVD) для оценки результата моделирования непрерывности и формы между срезами [85]. Для 3D-сегментации актуально еще использовать Hausdorff Distance (HD) для оценки границ. Это метрика, используемая для количественной оценки точности совпадения границ между двумя множествами точек (например, между ручной разметкой эксперта и автоматической сегментацией). Она особенно полезна для оценки качества контуров в задачах сегментации опухолей, органов или других структур на медицинских изображениях (КТ, МРТ). Чем меньше HD, тем лучше совпадение границ, в отличие от Dice (который оценивает объемное перекрытие), HD фокусируется на худшем случае несоответствия границ [62]. В этой обзорной главе преимущественно будет сравниваться Dice как результат работы различных нейросетей, так как он самый используемый и самый «понятный» показатель.

Точность нейросети в некоторых работах в сегментации ПЖ достигает 95% и более [73]. Значительная часть этих сетей обучались только лишь на одной базе исследований, и немногие на двух и более, это важно, так как нейросеть должна быть применимой для исследований с разных томографов, разными особенностями проведения исследования и с разной постобработкой. Сами исследования должны быть с различными анатомическими особенностями (вариантная анатомия, патологические изменения), простыми словами данные должны быть более разнообразными для повышения точности и возможности применения нейросети повсеместно [33]. Например, важно включать в обучающие выборки исследования помимо здоровых пациентов также с РПЖ, хроническим панкреатитом или со стеатозом (чаще на фоне сахарного диабета), чтобы нейросеть обучалась сегментировать паренхиму с измененной анатомией [59, 72, 93].

Нередко использовали для обучения и тестирования наборы данных, опубликованные в свободном доступе. Основные из них National Institutes of Health-Pancreas CT (NIH) [31], TCIA-PDA (TCIA) [82] и Medical Segmentation Decathlon (MSD) [119], в большинстве этих наборов данных есть и патологически измененные органы (с образованиями, стеатозом или хроническим панкреатитом). Suman G. и соавт. [86] оценили их по качеству и пригодности для обучения, используя шкалу качества медицинских изображений – “*a four-point medical imaging data readiness (MIDaR) scale*” [77]. NIH с нормальными КТ-изображениями ПЖ ($n = 80$ КТ) имел оптимальное качество изображения и соответствовал критериям MIDAR A [77], но небольшая часть была исключена из предоставленных сегментаций. Набор данных TCIA-PDA ($n = 60$ КТ; 6 МРТ) и MSD ($n = 420$ КТ) отнесены к категории MIDAR B из-за неполноценной разметки, ограниченных метаданных и недостаточной документации. Значительная часть КТ из наборов данных TCIA-PDA и MSD оказалась непригодной для обучения ИИ из-за билиарных стентов [TCIA-PDA: 10 (17%); MSD: 112 (27%)], которые создают артефакты, а также из-за других факторов (слишком поздняя венозная фаза, субоптимальное качество изображения, этиология, не связанная с ОАП, или состояние после лечения) [TCIA-PDA: 5 (8,5%); СКО: 156 (37,1%)]. Эти нюансы в качестве не учитывались ни в одном из 25 исследований, в которых использовались эти PPID (NIH-PCST: 20; MSD: 1; оба: 4).

Kumar Naribalan и соавторы [84] в 2019 г. проанализировали ранее более поздние статьи (20 штук) по сегментации ПЖ по КТ и МРТ изображениям с помощью различных нейросетей и алгоритмов и сделали вывод о среднем Dice – 74,4%.

Один из лучших результатов сегментации ПЖ на КТ-томограммах показала работа Meixiang Huang и соавт. [48], которые разработали деформируемую U-Net (сокращенно DU-Net) в качестве уточняющей модели, Dice – 87,25%. Ключевым компонентом DU-Net является деформируемая свертка, которая может адаптивно увеличивать сетку выборки, изучая двумерные смещения от каждого пикселя изображения в соответствии с предыдущими картами признаков. Включение

деформируемой свертки в базовую сеть U-Net может улучшить возможности U-Net.

Перспективная работа Peijun Hu [56] с тоже достаточно хорошим результатом сети DSD-ASPP-Net, обученной для получения «грубой» карты поджелудочной железы, которая используется для обрезки исходного изображения, чтобы из него затем получить более точную сегментационную маску поджелудочной железы.

Потом, на этапе мелкомасштабной сегментации, в базовую сеть DenseASPP вводится новый модуль с учетом текстуры, характерной для поджелудочной железы. В результате «грубая» сегментация и текстура объединяются вместе для улучшения модели и получения более точного результата – до $85,49 \pm 4,77\%$ [56].

В этом методе также рассчитывается карта геодезических расстояний, на которой учитывается не только расстояние между пикселями, но и текстура изображения (например, сходство интенсивности), это помогает лучше различать соседние пиксели от, например, пикселей сосудов или парапанкреатической жировой клетчатки [56].

Если обратиться к самым последним работам с 2024 по 2025 гг. (таблица 1), то самый высокий результат 93,7% с небольшим набором данных для обучения ($n = 229$) показала работа Gaofeng Zhang [43], где использовалась трансферная нейросеть nnTransfer net.

Таблица 1 – Результаты сегментации поджелудочной железы по данным КТ в различных исследованиях (Dice)

Авторы, год	Количество кейсов; фазы исследования	Результаты, Dice (%)	Тип нейросети; дата сети
Surenth Nalliah, 2025 [59]	550 исследований (нормальные ПЖ и с признаками хронического панкреатита) + 80 из базы NIH; венозная фаза	85% (Aalborg) и 79% (Bergen Hospitals, NIH Pancreas-CT dataset)	nnU-Net; Aalborg и Bergen Hospitals, NIH Pancreas-CT dataset
Ehwa Yang, 2024 [93]	851 исследований (с РПЖ); венозная фаза	76,4%	3D-архитектура nnU-net;
Gaofeng Zhang, 2024 [43]	229 исследований (нормальные ПЖ); венозная фаза	93,7%	nnTransfer net

Продолжение таблицы 1

Авторы, год	Количество кейсов; фазы исследования	Результаты, Dice (%)	Тип нейросети; дата сети
Hima Tallam, 2022 [72]	471 исследования (пациенты с сахарным диабетом и без); контрастные и бесконтрастные	69%	Больница и клиники Университета Висконсина, Medical Data Decathlon, The Cancer Imaging Archive, Beyond the Cranial Vault challenge, Национальный военно-морской медицинский центр, Бетесда, Мэриленд; 3D U-net
Sovanlal Mukherjee, 2025 [97]	3031 исследование пациентов без образований ПЖ для обучения. Для тестирования – 585 исследований; венозная фаза	94-96%	3D-архитектура nnU-net; клиника Мэйо США и AbdomenCT-1K dataset
Sehrish Javed, 2022 [126]	82 исследования с нормальной ПЖ + тестовые наборы данных – 30 штук; венозная фаза	94,5%	3D-архитектура U-Net+ Bayesian Model; Национальный институт здравоохранения, Медицинский центр Сидарс-Синай

Трансформеры успешно справляются с анализом изображений, но им требуется большой объём данных, чтобы превзойти свёрточные нейронные сети. Это серьёзное препятствие для широкого использования трансформеров, особенно в области медицинской визуализации, где ограниченная доступность больших наборов данных препятствует их применению в обучении. Эту проблему можно решить, используя немаркированные данные 3D-изображений в медицинских целях для самоконтролируемого предварительного обучения, чтобы выявить сходство между КТ-изображениями. Простыми словами в отличие от стандартных генеративных моделей, nnTransfer фокусируется на общих параметрах ПЖ, таких как внешний вид и текстура на КТ, и использует их для задач сегментации. Данные 227 КТ-исследований из набора данных этой работы были выполнены у пациентов без образований искомого органа.

Также стоит отметить работы Hima Tallam [72], Ehwa Yang [93] и Surenth Nalliah [59], где обучали свёрточные нейросети сегментировать ПЖ на

исследованиях у пациентов с сахарным диабетом (до 69%), РПЖ и хроническим панкреатитом (до 85%) соответственно с весьма достойными результатами.

Самый крупный обучающий набор данных был в работе Sovanlal Mukherjee [97] ($n = 3031$) с высокой точностью до 94% и сверточной нейросетью nnU-Net. В набор данных вошли КТ-исследования с поджелудочными без образований, но были со стеатозом, кальцинатами и мелкими кистами.

Точность сегментации ПЖ зависит от объема обучающей выборки: чем больше, тем точнее результат, хотя при достижении определенного размера выборки точность увеличивается незначительно, согласно работе Matteo Cavicchioli [87] это около 440 КТ-исследований. Особенно чувствительны к размеру набора данных сложные и вариабельные участки ПЖ по данным КТ (крючковидный отросток, головка) [87].

Поэтому очень актуальным кажется исследование Sehrish Javed [126] с отдельной разметкой частей ПЖ: головки, тела и хвоста. Нейросеть обучалась находить между ними границы и отдельно сегментировать. Причем тестировали ее на наборах данных как с нормальными поджелудочными так и с образованиями. Она учитывала расположение частей относительно друг друга, соотношение длины каждой части и всей ПЖ и соотношение объема и всей ПЖ. В перспективе это может сильно улучшить точность сегментации всей железы.

Если говорить про детекцию образований, то раньше в большинстве исследований выполнялась только бинарная классификация входного изображения как «с опухолью» или «без опухоли» как в работе Ma Han [92], без одновременной локализации поражения, но за последние 5 лет появились исследования с нейросетями, обученными строить сегментационные маски не только ПЖ, но и образований, причем сегментация органа чаще является первым этапом таких работ. Но работы с простой классификацией исследований на «есть патология» или «нет патологии» не могут использоваться для построения 3D-моделей, планирования хирургических операций, оценки распространенности, а также одновременного использования в дальнейшем автоматического расчета радиомических показателей [33].

После детекции или сегментации паренхимы ПЖ для более точной сегментации образований ПЖ и создания сегментационных масок, подходящих под обучение нейросетей, важна хорошая видимость самих опухолей и их границ. Для наилучшей визуализации ПЖ, ее патологии и ее образований используется специальный протокол – панкреатическая фаза исследования. Но рутинно ее делают не во всех медицинских учреждениях. Портальная и артериальная фазы исследования обеспечивают также хорошую визуализацию аденокарциномы ПЖ [119]. Хотя для некоторых видов аденокарцином, которые изоденсные в эти фазы имеет смысл анализировать дополнительно отсроченную фазу, на которой они могут быть лучше видны [104].

Артериальная фаза КТ исследования лучше всего подходит для визуализации гиперваскулярных образований ПЖ, таких как НЭО, метастазы светлоклеточного рака почки, интрапанкреатической спленулы и других. Хотя и в некоторых случаях визуализируется лучше в портальную фазу исследования, так как нередко имеет весьма нетипичный паттерн контрастирования [35].

Поэтому авторы большинства работ использовали для обучения нейросетей именно артериальную и портальную фазы, результаты последних самых крупных работ по разметке гипо- и гиперваскулярных образований. Данные представлены в таблицах 2 и 3.

Таблица 2 – Результаты сегментации гиповаскулярных опухолей (преимущественно аденокарцином) по данным КТ в различных исследованиях (Dice)

Авторы, год	Количество кейсов; фазы исследования	Результаты, Dice (%)	Тип нейросети; дата сети
Yan Wang, 2021 [21]*	ЖНМІ - 800 (400 нормальные и 400 с аденокарциномами), портальная фаза	60,29%	IAG-Net (на основе VGG-Net и 2D U-Net); MSD - обучение, ЖНМІ - тестирование
Si Ke, 2021 [74]*	319 (нормальные ПЖ, аденокарциномы, IPMN, серозные цистаденомы); артериальная, венозная и отсроченная фазы	81,7% (83%*)	ResNet18, U-Net32*, ResNet34; Медицинская школа Чжэцзянского университета (Чжэцзян, Китай), 2 больницы с разными томографами

Продолжение таблицы 2

Авторы, год	Количество кейсов; фазы исследования	Результаты, Dice (%)	Тип нейросети; дата сети
Tahereh Mahmoudi, 2022 [111]*	138 19; артериальная и портальная фазы	74,6% (60,4%*) + сегментация сосудов (ВБА, ВБВ)	3D CNN и 3D LBP, 2D U-Net*, TAU-Net; MSD, 19 из университетской больницы
Alves Natália, 2022 [73]*	119 (с аденокарциномой), 123 (без аденокарциномы) 281 из MSD, 80 из TCIA (без аденокарциномы). портальная фаза	с разметкой окружающих структур – 99,1%	3D U-Net (nnUnet_T, nnUnet_TP*, nnUnet_MS*+ сегментация структур панкреатодуоденальной области); Медицинский центр Университета Р адбауд (5 разных КТ-сканеров), MSD, TCIA
Mukherjee Sovanlal, 2023 [46]*	1151 (230 - тест) 152 - MSD 41 - TCIA	69% (MSD - 82%, 84% - TCIA)	nnUNet; больница, MSD и TCIA
Liu Kao-Lang, 2020 [106]*	295 - обучение 176 - тест	карта вероятности в пределах сегментационной маски органа-точность 87,4%, специфичность - 86,7%	VGG; больница Национального Тайваньского университета, MSD, TCIA.
Yingda Xia, 2022 [119]*	690 с аденокарциномой ПЖ, 546 здоровых пациентов, 450 с НЭН, 458 с кистозными образованиями; большинство с артериальной и венозной фазами	более 90% в разных когортах	FELIX (на базе 3D U-Net), Johns Hopkins Hospital, Heidelberg Medical School, NIH Pancreas-CT dataset
Jieneng Chen, 2023 [125]*	1365 с аденокарциномами, 777 здоровые пациенты; артериальная и портальная фазы	70,2%	CancerUniT, 5 разных госпиталей
Bo Zhou, 2023 [90]	1371 с аденокарциномами, 707 нормальные ПЖ и другие образования (IPMN, кистозные образования); Бесконтрастная, артериальная и портальная фазы исследования	95,8% сегментация нормальных поджелудочных, 86,9% - аденокарцином	MDPFormer, институт рака поджелудочной железы
Shilai Wen, 2025 [126]*	3265 исследования, из которых 569 были отобраны для тестовой выборки	92,4% для образований	Swin-UNet; 6 клиник в Китае
* – работы с предварительной сегментацией ПЖ			

Таблица 3 – Результаты сегментации гиперваскулярных опухолей (преимущественно нейроэндокринных опухолей) по данным КТ в различных исследованиях (Dice)

Авторы, год	Количество кейсов; фазы исследования	Результаты, Dice	Тип нейросети; дата сети
Bingsheng Huang, 2021 [26]	НЭН 98 - 1 датасет 50 - 2 датасет, артериальная фаза	98 - 81,8% 50 - 74,8%	2 разных центра
Yingda Xia, 2022 [119]*	546 здоровых пациентов, 450 НЭН, с артериальной и венозной фазами	94%	FELIX (на базе 3D U-Net); Johns Hopkins Hospital, Heidelberg Medical School, NIH Pancreas-CT dataset
Bo Zhou, 2023 [90]	144 с НЭН поджелудочной железы, 707 нормальные поджелудочные железы и другие образования (PDAC, IPMN, кистозные образования); бесконтрастная, артериальная и портальная фазы исследования	95,8% сегментация нормальных поджелудочных, 47,1% - с НЭН	MDPFormer; институт рака поджелудочной железы
Felipe Lopez-Ramirez, 2024 [105]*	270 исследований (135 с НЭН, 135 - неизменные поджелудочные железы); артериальная и венозная фазы	90% чувствительность, 76% специфичность в детекции НЭН с помощью радиомики	Radiomics, 3D U-net, Университета Джонса Хопкинса, Балтимор, Мэриленд
* – работы с предварительной сегментацией ПЖ			

Еще одна сложность в ручной сегментации и обучении нейросети автоматической – это нахождение границ гиповаскулярных образований ПЖ. Оно затрудняется тем, что межэкспертная вариабельность в определении границ опухоли достигает 20-25%, что может снижать точность распространенности процесса, а также классификации. Поэтому ведутся работы по определению допустимых отклонений от истинной границы и влияния на результаты анализа радиомических характеристик образований [118].

Интересно, что добавление разметки окружающей анатомии в панкреатодуоденальной зоне (панкреатический проток, сосуды) улучшает способность модели оценить степень распространенности внутрипротоковой аденокарциномы. Особенно это полезно в случае изоденсных образований,

которые обтурируют панкреатический проток, вызывая его расширение или образований меньше 2 см. Модели, сегментирующие только паренхиму и образование, не могут идентифицировать такие поражения, поскольку часто нет видимых различий между опухолью и паренхимой здоровой ПЖ. Однако при дополнительной разметке окружающих структур модель может намного точнее определить его местоположение в шейке-теле поджелудочной железы в месте обрыва расширенного протока. Обеспечивая контролируемое обучение сегментации протока и других структур, нейронная модель может лучше сосредоточиться на оставшихся областях паренхимы ПЖ, это может объяснить ее способность обнаруживать опухоли, слабо накапливающие контрастный препарат. Также такая сегментация предоставляет рентгенологу полезную информацию, которая может помочь в интерпретации исследований [44]. А в одном исследовании [45] наоборот – части, которые не были ни ПЖ, ни опухолью, были исключены из дальнейшего анализа изображения нейросетью, так как авторы считают, что фон и прилежащие органы сильно снижают точность нейросети в поиске образований, хотя по сути чтобы их исключить нейросети нужно все равно научиться прежде их находить. И при предварительном выделении только ткани железы могут с более высокой точностью находить аденокарциному, даже в сравнении с опытными рентгенологами.

Еще важно отметить, что большинство публикаций не фокусируется на небольших поражениях на ранних стадиях, и только в этом исследовании сообщается о работе модели для опухолей размером < 2 см [45].

Самый лучший результат был достигнут коллегами из Китая, Shilai Wen и соавторы [126] – 92,4%, причем обучались разные нейросети на огромной выборке пациентов с РПЖ ($n = 3265$) из шести разных медицинских учреждений. Самой точной оказалась трансферная сеть Swin-UNet, что подтверждает перспективность использования этого типа нейросетей для обучения и дальнейшего внедрения в рутинную практику врача-рентгенолога.

Существуют также работы, где нейросеть училась детекции образований, а не сегментации. Такие работы классифицируют изображения – есть или нет

опухоль и помечают приблизительное местоположение опухоли без точной маски, что может вероятно ограничивать в дальнейшем возможности такой нейросети. Одна из таких работ, например Liu S.L. и соавторов, но значительным минусом ее является то, что обучение и тестирование проводится только на одной базе, где все или большинство исследований с образованиями ПЖ, что может переобучить сеть [70]. Есть еще подобная работа Zhang, Zhengdong и соавт., где рентгенологи помечали образования в рамки вместо сегментационных масок на достаточно большом датасете – 2890 КТ-исследований, но только из одной базы данных [22]. Из-за отсутствия сравнения на нормальных железах или с другой патологией, оценить преимущества такого метода и сравнить с сегментацией затруднительно.

Следует отметить исследование с двойным метаобучением, суть которого заключается в двойном обучении нейросети и на МРТ, и на КТ сегментировать РПЖ с помощью генеративной сети [46].

Есть интересная работа Li Siqi по сегментации аденокарциномы по ПЭТ-КТ исследованиям с учетом накопления радиофармпрепарата, оказывается что это значительно повышает работу нейросети до 96,47% (правда с тестированием на исследованиях из той же больницы). Следует отметить, что в этой работе также выполнялось предварительное обучение сети сегментировать паренхиму ПЖ (Dice – 78,9%) с тестированием уже на двух датасетах [30].

Нейроэндокринные новообразования ПЖ в большинстве случаев визуализируются лучше, чем аденокарциномы, границы таких опухолей видны четче за счет хорошей васкуляризации и яркого контрастирования в артериальную и портальную фазы. Хотя могут быть ошибки в сегментации из-за сходства гиперваскулярной опухоли с близлежащими сосудами или при размерах опухоли менее 1 см [26, 41]. Но для решения этой проблемы Felipe Lopez-Ramirez и соавт. [105] в их работе предложили использовать после автоматической сегментации ПЖ метод радиомики именно для небольших гиперваскулярных опухолей (НЭН). И получили достаточно высокие точность и специфичность, это

говорит о том, что радиомика может помочь в более точной сегментации образований малых размеров.

Объединенная система классификации ВОЗ 2010 и 2017 годов делит НЭН ПЖ на три класса: G1, G2 и G3. Клинически хорошо дифференцированная локальная группа G1/G2, особенно локальные заболевания, может лечиться хирургической резекцией, тогда как низкодифференцированная группа G3 может подвергаться комплексному лечению. Однако точная патологическая классификация обычно определяется инвазивными методами, такими как резекция. Поэтому определение патологической степени предоперационных панкреатических НЭН имеет решающее значение для того, чтобы клиницисты могли разработать соответствующие планы лечения – в этом может помочь автоматическая сегментация образований и радиомика. В сравнении с сегментацией аденокарцином в вышеупомянутых исследованиях среднее значение Dice сегментации НЭН выше в работе Huang W. составило 74,8% для одного набора данных и 81,8% для другого [26], что подтверждает лучшую визуализацию этого типа образований. Хотя в работе Bo Zhou [90] точность оказалась низкой, значительно ниже точности сегментации аденокарцином, вероятно это связано с очень малой обучающей выборкой в сравнении с остальным массивом данных.

Работ, посвященных только сегментации нейроэндокринных опухолей поджелудочной железы по данным КТ в базе PubMed немного. В основном те данные, которые приведены в таблице 3 являются результатами крупных исследований, в которых нейросеть обучалась «находить» самые разные образования, в том числе гиповаскулярные (аденокарциномы, кистозные образования и СППО). Обращает на себя внимание работа по детекции нейроэндокринных образований по данным ПЭТ-КТ, но там включено только 32 нейроэндокринные опухоли ПЖ, остальные 126 образований были в других органах, но КТ-часть согласно материалам и методам не использовалась [58].

Поэтому были проанализированы и работы с применением радиомики с целью сегментации или детекции гиперваскулярных образований. Особый

интерес представляет уже упомянутая выше работа с 270 исследованиями здоровых пациентов и с панкреатическими НЕО, в ней использовали анализ радиомических показателей сегментированной ПЖ по данным КТ, чтобы найти небольшие гиперваскулярные образования от 5 мм до 19 мм. Модель-классификатор LightGBM артериальной фазы КТ показала наилучшие результаты в тестовом наборе с чувствительностью 90% (95% доверительный интервал [ДИ]: 80-98), специфичностью 76% (95% ДИ: 62-88) и AUC 0,87 (95% ДИ: 0,79-0,94) [105].

Актуальным является также применение радиомики в области сегментационной маски ПЖ с целью получения карт вероятности развития РПЖ по данным текстурного анализа, подобная работа была опубликована в 2022 также Sovanlal Mukherjee [106], и его коллегами. В ней показано, что основанные на радиомике модели глубокого машинного обучения позволяют обнаруживать РПЖ в визуальном по данным КТ нормальной ПЖ, т.е. когда это выходит за рамки возможностей человека, за значительное время до постановки клинического диагноза.

Таким образом нет рекомендованных программ/методов для раннего выявления или скрининга образований ПЖ, в отличие от рака молочной железы или толстой кишки.

А образования ПЖ, представляют собой значимую медико-социальную проблему из-за высокой стоимости лечения, диагностических сложностей и риска инвалидизации. Автоматическая сегментация на основе ИИ может стать ключевым инструментом для ранней диагностики и оптимизации терапии, сокращая экономическое бремя и улучшая качество жизни пациентов.

Обученная строить сегментационные маски ПЖ и ее образований нейросеть может быть хорошим помощником в ранней диагностике небольших и плохо визуализируемых образований в условиях высокой загрузки врача. Кроме того построение с помощью нее 3D моделей ПЖ может быть полезным для планирования хирургического лечения образований, а также в оценке уменьшения объема опухоли на фоне химиотерапевтического лечения.

Перспективным также является дальнейшее использование автоматической сегментации для автоматического расчета текстурных показателей и дифференциальной диагностики образований со схожими рентгенологическими признаками. Комбинация сегментации и радиомики позволяет предсказать степень дифференцировки (точность 85-90% для G3) [26].

Однако, несмотря на многообещающие результаты, представленное в научных публикациях, масштабное клиническое внедрение нейросетевых технологий остается ограниченным – преимущественно потому, что большинство моделей требует значительного объема аннотированных изображений для обучения. Врачам и исследователям редко удаётся собрать тысячи тщательно размеченных исследований, что особенно критично для редких органов, таких как ПЖ. В ответ на эту проблему активно развиваются подходы, требующие значительно меньшего количества данных. Среди наиболее перспективных – *few-shot learning*, когда модели обучаются на очень небольших выборках, либо *deep generative models* (например, GAN, VAE, diffusion models), которые на основе искусственно синтезированных изображений создают расширенные тренировочные выборки [28, 95]. Кроме того, применяется *meta-learning*, позволяющий адаптировать модели к новой задаче с минимальным количеством примеров. Например, *Model-Agnostic Meta-Learning* (MAML) уже доказал свою эффективность в медицинской сегментации при ограниченных данных [69].

Также до настоящего времени возможности совместного применения сегментации и текстурного анализа (радиомика) в дифференциальной диагностике гиперваскулярных и гиповаскулярных образований поджелудочной железы остаются недостаточно изученными. В частности, пока не предложен практико-ориентированный подход, позволяющий внедрять такие методы в клиническую работу. Несмотря на это, существуют предварительные публикации, подтверждающие информационный потенциал комбинированного анализа, однако они редко выходят за рамки обзорных или ретроспективных исследований. Следующим логичным шагом станет разработка полноценного цифрового продукта: клинически валидированной платформы, интегрированной в

рабочий процесс радиолога, с унифицированным алгоритмом применения, стандартизацией процедуры и возможностью масштабного внедрения. Такие решения позволят перейти от теоретических разработок к устойчивым цифровым инструментам, поддерживающим принятие решений в условиях рутинной диагностики.

ГЛАВА 2. МАТЕРИАЛ И МЕТОДЫ

2.1. Дизайн исследования

Данное исследование выполнено ретроспективно.

Данная работа разделена на 4 этапа (рисунок 1):

1. Разработка алгоритма разметки ПЖ и ее образований по данным КТ-исследований.
2. Оценка влияний внешних факторов на разметку врача-рентгенолога.
3. Оценка соответствия сегментации ткани ПЖ и ее образований между врачом и системой компьютерного зрения.
4. Выявление ложноотрицательной детекции образований ПЖ системой компьютерного зрения по КТ исследованиям.

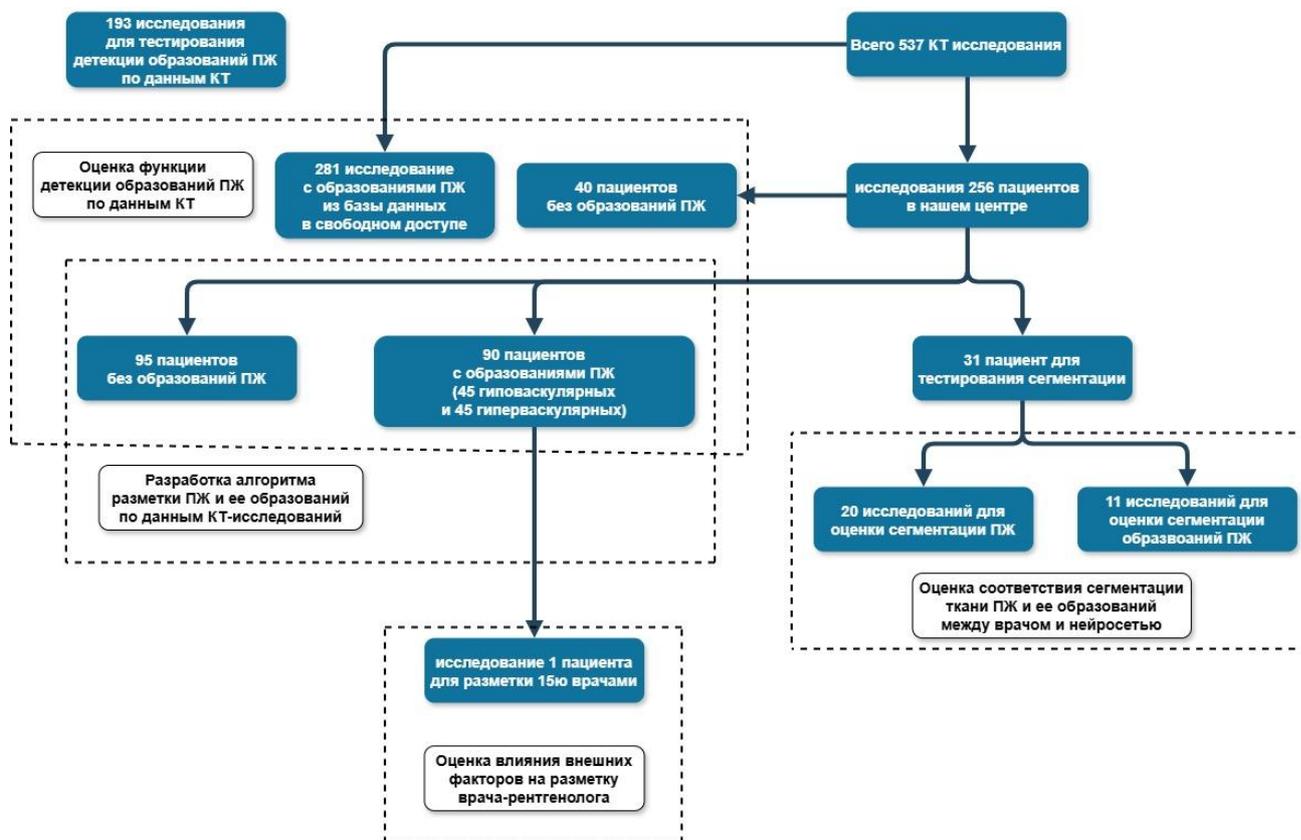


Рисунок 1 – Дизайн исследования

В схеме указаны пути формирования групп пациентов. В рамках с пунктирной линией выделены группы пациентов с соответствующими этапами исследования, для которых они отобраны.

Для выполнения данных этапов было необходимо следующее:

- определить зависимость разметки врача-рентгенолога от внешних факторов и опыта;
- разработать критерии «правильной» разметки ПЖ на КТ-исследованиях для создания обучающей и тестовой выборок;
- разработать критерии «правильной» разметки образований ПЖ на КТ-исследованиях для создания обучающей и тестовой выборок;
- сравнить точность разметки системы компьютерного зрения и врача-рентгенолога ПЖ и ее образований на тестовых выборках;
- определить точность детекции образований ПЖ обученной нами нейросетью.

2.2. Общая характеристика пациентов

В исследование были включены пациенты, наблюдавшиеся в Национальном медицинском исследовательском центре хирургии имени А.В. Вишневского (далее – Центр), которые в последующем либо перенесли хирургическое вмешательство на ПЖ, либо получили специализированную консультацию профильных специалистов в период с сентября 2011 года по июнь 2023 года. Всем пациентам в рамках предоперационного обследования или при обращении в сторонние лечебно-профилактические учреждения (ЛПУ) была выполнена мультиспиральная компьютерная томография (МСКТ) органов брюшной полости с внутривенным болюсным контрастированием. Перед проведением исследования каждый пациент подписывал информированное согласие на выполнение КТ-исследования в соответствии с этическими требованиями и стандартами оказания медицинской помощи.

Отбор случаев в исследование проводился ретроспективно и включал только те КТ-исследования, которые были выполнены до проведения хирургического лечения. Это позволило исключить влияние постоперационных изменений на визуализацию ПЖ и её патологических образований.

Критерии включения в исследование:

- наличие гиперваскулярного образования ПЖ, определяемого по паттернам контрастного накопления на КТ-изображениях;
- наличие гиповаскулярного образования ПЖ по данным КТ-исследования;
- наличие предоперационного КТ органов брюшной полости и забрюшинного пространства, выполненного с внутривенным контрастированием в полном объёме, включающем как минимум артериальную и венозную фазы.

Критерии исключения:

- отсутствие артериальной и венозной фаз исследования;
- наличие в анамнезе хирургического вмешательства на ПЖ, что могло бы повлиять на анатомию и структуру органа.

Возраст пациентов, включённых в анализ, варьировал от 34 до 89 лет, что отражает широкий возрастной диапазон встречаемости опухолей ПЖ.

По итогам анализа базы данных в исследование вошло 256 пациентов, из них:

- 60 пациентов с гиперваскулярными образованиями (в том числе 15 исследований были отобраны для тестирования алгоритмов сегментации);
- 54 пациента с гиповаскулярными образованиями (9 исследований использовались для тестирования сегментации);
- 142 пациента с ПЖ без выявленных образований, служившие контрольной группой.

В подгруппе пациентов с гиповаскулярными образованиями насчитывалось 32 мужчины и 22 женщины, средний возраст составил 64 года. В группе с гиперваскулярными образованиями было 28 мужчин и 32 женщины, при этом средний возраст оказался существенно ниже и составил 42 года.

Локализация патологических образований распределялась следующим образом:

- при гиповаскулярных опухолях у 32 из 54 пациентов поражение локализовалось в головке ПЖ, у остальных – в теле или хвосте органа;
- при гипervasкулярных образованиях у 29 пациентов опухоль располагалась в головке, у 12 – в хвосте, у 17 – в теле. У одного пациента выявлено тотальное поражение ПЖ, а у ещё одного – распространение процесса как на тело, так и на хвост.

Дополнительно у 51 пациента (из 150 включённых в анализ) по данным КТ отмечались признаки стеатоза поджелудочной железы – частичного замещения нормальной паренхимы жировой тканью различной степени выраженности. Случаи с тяжёлым стеатозом, при котором паренхима органа сохранялась лишь в виде отдельных фрагментов, были исключены из исследования ввиду невозможности корректной сегментации.

Тестовые выборки для алгоритмов сегментации распределились следующим образом:

- без патологических образований – 7 исследований;
- с гиповаскулярными образованиями – 9 исследований (3 случая в хвосте, 1 в теле, 5 в головке поджелудочной железы);
- с гипervasкулярными образованиями – 15 исследований (13 в головке, 2 в теле).

Во всех случаях пациенты, перенёсшие хирургическое вмешательство на поджелудочной железе до момента исследования, были исключены как из обучающих, так и из тестовых датасетов, чтобы избежать искажений данных.

Для расширения выборки и повышения устойчивости алгоритмов сегментации дополнительно использовался открытый набор данных Medical Segmentation Decathlon, включающий 281 КТ-исследование, из которых 38 вошли в тестовую выборку [119].

2.3. Методика выполнения компьютерной томографии

В работу были включены данные пациентов с выполненными КТ-исследованиями как в Центре, так и в других медицинских учреждениях по протоколу КТ-исследования органов брюшной полости и получивших описание от врачей-рентгенологов нашего Центра (консультация диска, второе мнение).

КТ-исследования в НМИЦ хирургии Вишневого выполнялись по стандартному протоколу с использованием КТ-томографа Philips Ingenuity 64 – толщина среза 1,5 мм, напряжение на рентгеновской трубке (кильвольтаж) – 100 кВ, реконструкционный интервал 0,75 мм. Контрастное вещество с концентрацией йода 350 мг/мл вводилось с помощью автоматического инжектора из предзаряженного шприца со скоростью 3,5 мл/с и сопровождалось введением 25 мл физиологического раствора. Для расчёта необходимого объема КП использовалась формула 1 мл/кг массы тела пациента, но не более 100 мл (максимальный объем КП в предзаряженном шприце). Исследование с контрастированием выполнялось по методике «*bolus tracking*» с установкой трекера на уровне диафрагмы с порогом плотности 150 HU на нисходящей грудной аорте со стартом сканирования артериальной фазы на 10 с, венозной фазы на 38 с, отсроченной фазы исследования на 300 с. КТ в других центрах были выполнены на томографах четырех основных производителей: GE, Philips (модель сканера отличалась от используемой в центре), Siemens и Toshiba (Canon). Толщина среза составляла от 1 до 5 мм, напряжение на рентгеновской трубке составляло от 100 до 140 кВ.

2.4. Методика сегментации поджелудочной железы и ее гипо- и гиперваскулярных образований по данным компьютерной томографии

Сегментацию полученных изображений производили в модуле просмотра DICOM-изображений Philips IntelliSpace Portal (Philips Medical Systems, Cleveland), для сегментации использовали инструмент, определяющий контуры

органа по типу «магнитного лассо», выгружались маски в формате Stl. В дальнейшем производили корректировку масок и экспорт в подходящий формат с помощью другого программного обеспечения 3D Slicer (Рисунок 2) [111]. С помощью него же проводили выгрузку сегментационных масок в файловый формат NIfTI.

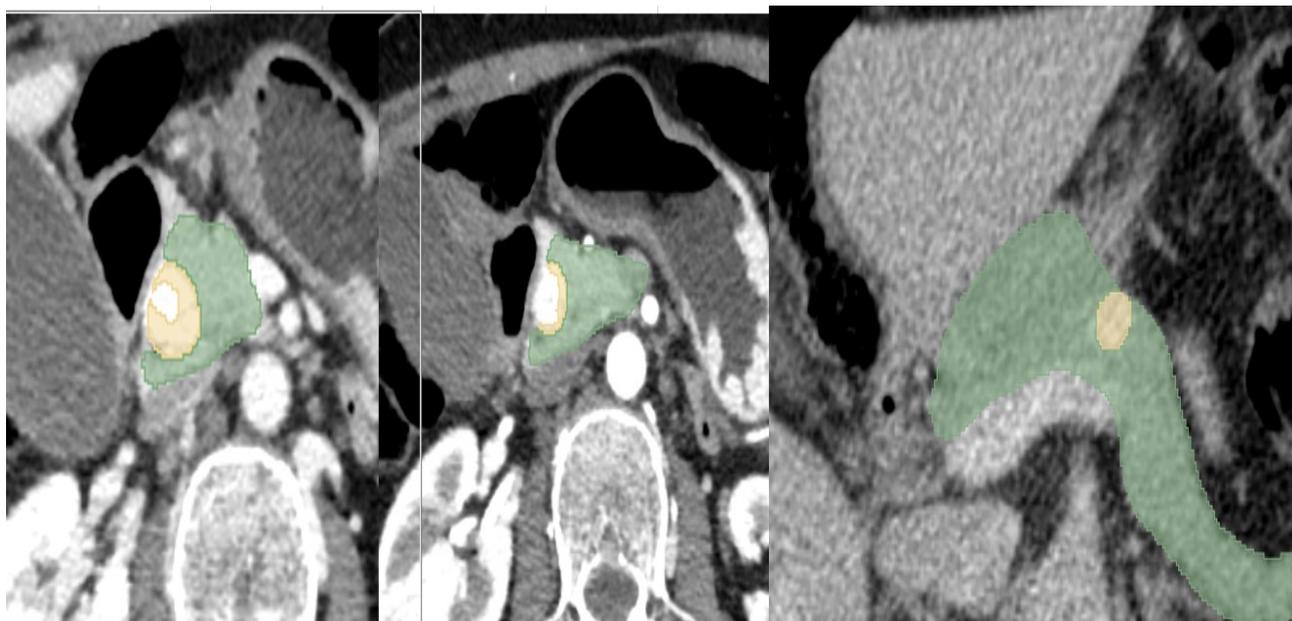


Рисунок 2 – Примеры сегментационных масок образований ПЖ на КТ, которые с помощью программного обеспечения 3D Slicer пришлось корректировать и доразмечать

Чтобы уменьшить влияние субъективного фактора разметки и облегчить большой объем работы сегментацию проводили 2 врача-рентгенолога (опыт работы более 5 лет) с выделением границ ПЖ на артериальной и венозной фазах каждого исследования в вышеописанном программном пакете Intellispace Portal V. компании Philips. Выделяли всю паренхиму ПЖ, если в ней было образование, его включали в общую разметку, но исключали общий желчный проток, видимые кровеносные сосуды и жировое пространство вокруг ПЖ. Затем проводили сегментацию образований ПЖ на КТ изображениях, использовались портальная фаза – для гиповаскулярных образований, артериальная фаза – для гиперваскулярных.

2.5. Оценка разницы ручной сегментации поджелудочной железы между разными врачами-рентгенологами с выявлением наиболее критических зон

2.5.1. Качественный анализ, сравнение с эталонной разметкой опытного врача-рентгенолога

В исследование были привлечены шестнадцать врачей-рентгенологов, специализирующихся на абдоминальной визуализации, с опытом работы в данной области от 1 до 7 лет. Каждый специалист, независимо от стажа, проводил анализ результатов по одному и тому же КТ-исследованию одного пациента. Для оценки использовались изображения в двух ключевых фазах контрастного усиления – артериальной и венозной, что обеспечивало полноту визуализации сосудистых структур и паренхимы ПЖ.

Задача рентгенологов заключалась в оценке построенных трёхмерных моделей сегментационных масок ПЖ в трёх взаимно перпендикулярных проекциях: аксиальной, фронтальной и сагиттальной. Такой подход позволял комплексно оценить форму и контуры органа, исключить искажения, возникающие при анализе только в одной плоскости, и повысить объективность заключений.

Для генерации и последующего просмотра 3D-моделей сегментационных масок применялось специализированное медицинское программное обеспечение 3D Slicer (версия XXX), широко используемое в исследовательской и клинической практике для обработки медицинских изображений. Сегментационные маски, полученные алгоритмом, были дополнительно разделены на анатомические отделы ПЖ в соответствии с хирургическими ориентирами.

В качестве границы между головкой и телом органа была принята верхняя брыжеечная вена:

– головкой считался весь объём ПЖ, расположенный справа от верхней брыжеечной вены;

- перешейком называли отдел, расположенный кпереди от верхней брыжеечной вены;
- телом считалась часть ПЖ, находящаяся слева от вены.

Поскольку чёткой анатомической границы между телом и хвостом органа не существует, оставшуюся часть условно разделяли на две равные зоны: ближнюю к верхней брыжеечной вене относили к телу, а более удалённую – к хвосту ПЖ.

После выполнения анатомического разделения выполнялась новая 3D-реконструкция сегментационных масок с использованием различных режимов прозрачности и цветовой маркировки отдельных отделов. Такой метод позволял наглядно визуализировать пространственные взаимосвязи между анатомическими структурами, облегчал оценку полноты и точности сегментации, а также способствовал выявлению возможных ошибок алгоритма на стыках отделов.

Данный этап работы был направлен на комплексную визуальную валидацию результатов сегментации, что является важным компонентом оценки эффективности автоматизированных систем в клинических условиях.

2.5.2. Машинный анализ, сравнение объемов 3D-масок поджелудочной железы

Было проведено сравнение масок сегментации по точности совпадения с эталоном с помощью индекса Дайса и вычисления разницы в объемах, как в целом для всего объема органа, так и для его отделов. Для этого был использован специальный код, написанный на языке программирования Python. Индекс Дайса (*DSC*) был рассчитан по формуле:

$$DSC = \frac{2|X \cap Y|}{|X| + |Y|}, \quad (1)$$

где $|X|$ и $|Y|$ – мощности двух множеств (т.е. количество элементов в каждом множестве).

Разница в объемах была посчитана после вычисления количества вокселей каждой маски сегментации. Затем зоны сегментации всех 5 масок были проанализированы с помощью радиомики. Для текстурного анализа было использовано расширение Radiomics¹, таким образом, были получены характеристики 1-го порядка наиболее переменных участков разметок.

2.6. Оценка возможностей системы компьютерного зрения по компьютерным томограммам с внутривенным контрастированием в сегментации паренхимы поджелудочной железы и ее образований

2.6.1. Качественный анализ компьютерных томограмм пациентов с гиповаскулярными и гиперваскулярными образованиями поджелудочной железы и без них

Два врача-рентгенолога, специализирующиеся на абдоминальной визуализации и имеющие стаж работы в данной области 5 и 12 лет соответственно, осуществляли тщательный отбор КТ исследований, включённых в данное исследование. На этапе первичной экспертизы из базы исключались исследования, качество которых не соответствовало установленным требованиям. В первую очередь это касалось случаев, содержащих выраженные артефакты движения, существенно ухудшающие визуализацию и препятствующие точной интерпретации данных. Также исключались исследования с выраженной жировой дегенерацией ПЖ (стеатозом), при которой ткань железы была представлена лишь отдельными фрагментами (островками) паренхимы, что делало невозможным адекватное формирование сплошной сегментационной маски.

После окончательного отбора каждый случай подвергался ручной сегментации. ПЖ размечалась в артериальной и портальной фазах контрастного

¹ <https://www.slicer.org/wiki/Documentation/Nightly/Extensions/Radiomics>

усиления, что позволяло максимально чётко отобразить как паренхиму органа, так и особенности её васкуляризации. В случаях наличия опухолевого образования сегментация патологического очага выполнялась в фазе, на которой визуализация была наиболее информативной – артериальной или портальной. При этом учитывались характеристики накопления контрастного препарата и дифференциация границ опухоли с окружающей паренхимой.

Разметка выполнялась в трёх взаимно перпендикулярных плоскостях (аксиальной, фронтальной и сагиттальной), что обеспечивало максимальную точность пространственного воспроизведения формы и объёма как ПЖ, так и её новообразований. Для построения сегментационных масок использовалась рабочая станция «Philips Brilliance Portal», оснащённая специализированным программным обеспечением для медицинской визуализации.

Перед передачей данных на этап машинного обучения или тестирования модели проводилась многоступенчатая верификация. Сначала осуществлялась проверка соответствия сегментационных масок исходным DICOM-изображениям с помощью пакета «3D Slicer», что позволяло выявить и устранить любые пространственные несоответствия или артефакты, возникшие на этапе разметки. В случае обнаружения неточностей выполнялась корректировка масок с последующим повторным контролем. Такой подход обеспечивал высокую точность исходных данных, что является критически важным фактором для обучения и валидации алгоритмов ИИ в задачах медицинской сегментации.

2.6.2. Машинный анализ

Для получения сегментационных масок ПЖ и образований использовалась рабочая станция «Philips Brilliance Portal». 2 врача-рентгенолога независимо друг от друга с опытом работы 3 и 12 лет проводили сегментацию всего объёма ПЖ и опухоли с помощью трехмерной области интереса (3D ROI) в артериальную и портальную фазы исследования (рисунок 3).

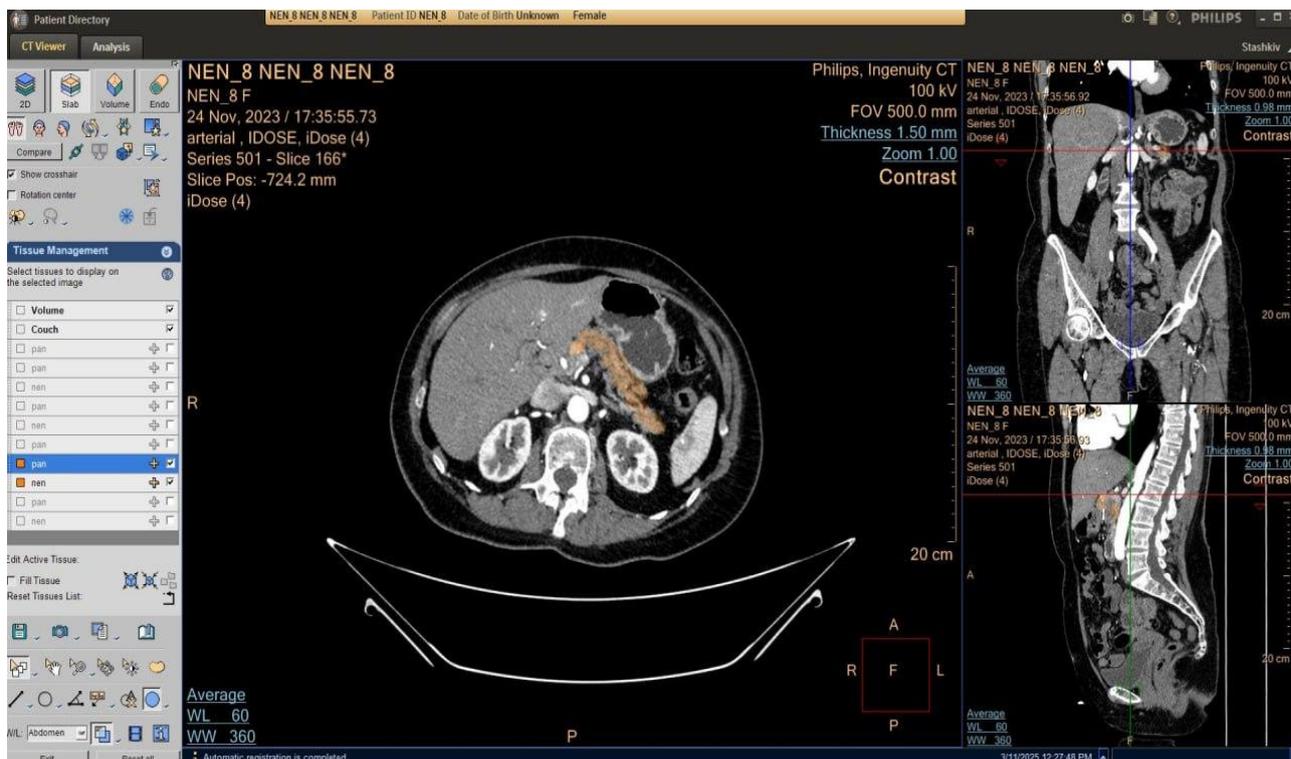


Рисунок 3 – Процесс сегментации паренхимы поджелудочной железы в артериальную фазу исследования КТ на рабочей станции «Philips Brilliance Portal»

Для обучения использовалась современная архитектура нейросети U-Net++ (см. рисунок 4), разработанная специально для задач точной и структурно согласованной сегментации медицинских изображений. Эта нейросетевая модель является улучшенной модификацией классической архитектуры U-Net, зарекомендовавшей себя как «золотой стандарт» в задачах сегментации в биомедицинской визуализации [122].

Входными данными для обучения являлись пары трёхмерных массивов (воксельных объёмов), полученных с КТ-исследований. Первый элемент каждой пары представлял собой объемные изображения с численными значениями плотности (в единицах Хаунсфилда), а второй – бинарную маску-истину (ground truth), в которой каждому вокселю соответствовало одно из двух значений:

- 0 – фоновая ткань (вне ПЖ);
- 1 – ПЖ (или патологическая зона при обучении на масках опухолей).

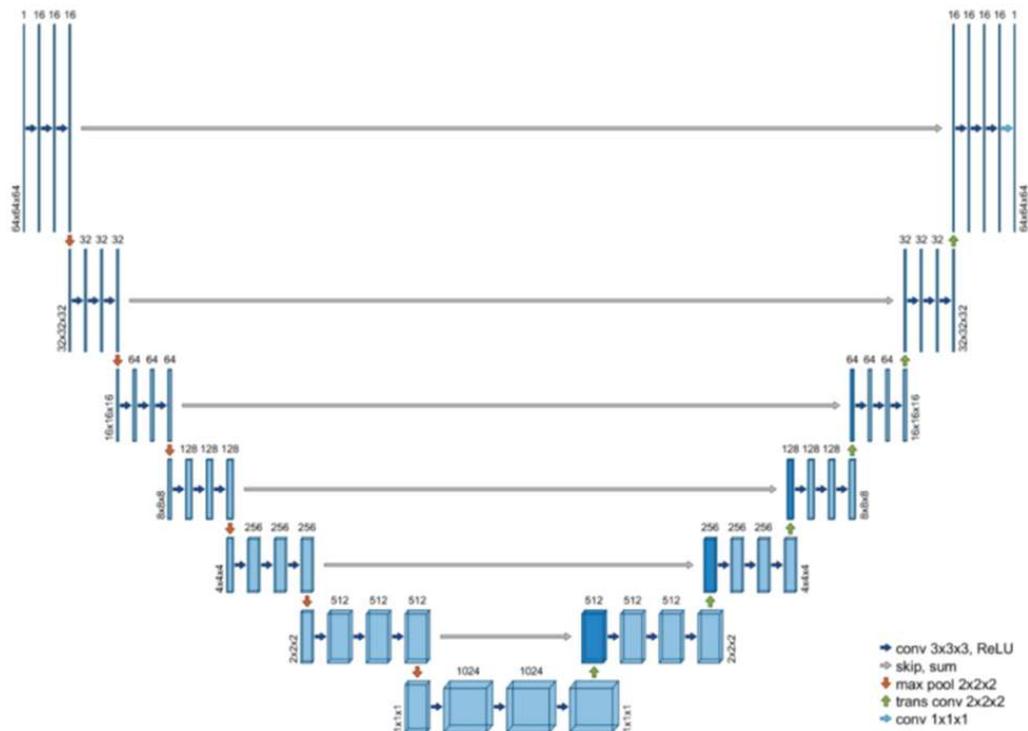


Рисунок 4 – Архитектура сети U-net

U-Net++ построена на основе архитектуры с симметричным энкодером и декодером (U-образной формы), но содержит дополнительные *сквозные соединения* (nested skip pathways), которые обеспечивают улучшенный обмен информацией между слоями. Это особенно важно при сегментации анатомических структур, обладающих высокой вариабельностью формы и плотности, как, например, поджелудочная железа.

Основные особенности архитектуры U-Net++:

- глубокая каскадная структура декодера;
- использование глубокого супервайзинга на нескольких уровнях декодера, что позволяет улучшить устойчивость и ускорить сходимость;
- эффективное устранение избыточных переходов между энкодером и декодером, характерных для классической U-Net, что повышает согласованность и точность границ сегментации;
- поддержка работы с ограниченными размеченными данными – важное преимущество в клинической практике, где ручная разметка зачастую требует значительных временных затрат [108].

Семантическая сегментация, выполняемая U-Net++, заключается в отнесении каждого вокселя изображения к определённому классу (например, ПЖ, опухоль, фон). За счёт серии операций свёртки (convolution), активации и нормализации, нейросеть обучается распознавать сложные пространственные паттерны, соответствующие границам органа или патологического образования.

При этом сеть формирует на выходе сегментационную маску – изображение такого же размера, как и входное, но в каждом вокселе которого содержится вероятность принадлежности к целевому классу. После пороговой классификации эта карта преобразуется в бинарную маску, готовую для анализа и визуализации.

Выбор U-Net++ обусловлен её высокой эффективностью в задачах медицинской сегментации, особенно в условиях ограниченного набора размеченных данных и при наличии сложной анатомии, как в случае с ПЖ и её опухолями. Согласно ряду исследований, данная архитектура демонстрирует лучшие показатели по сравнению с классической U-Net и другими сверточными сетями при сегментации абдоминальных органов и опухолей [80,123].

Производительность моделей глубокого обучения сильно зависит от наличия больших, точных и аннотированных наборов данных для облегчения содержательного обучения.

2.7. Оценка возможностей алгоритмов системы компьютерного зрения по компьютерным томограммам с внутривенным контрастированием в детекции образований поджелудочной железы

2.7.1. Методология оценки возможностей нейросети

Для обучения и проверки системы компьютерного зрения (КЗ) в детекции образований ПЖ по данным КТ были загружены исследования 95 пациентов без образований ПЖ и 90 – с образованиями, из выборки для обучения сегментации нейросети U-Net++, а также исследования 40 пациентов со здоровой железой и 281

исследование из открытой базы данных The Medical Decathlon [119] с образованиями ПЖ. КТ-срезы, на которых была сегментационная маска ПЖ, были загружены в другую нейросеть DenseNet121 – всего было обработано 29252 КТ-среза, из них 24980 с нормальной паренхимой ПЖ и 4272 с признаками образования в ней.

В результате система КЗ выдала результат в виде классификации (1 – есть образование, 0 – нет образования). Были подсчитаны общая точность и количество ложноположительных и ложноотрицательных разметок нейросетью.

2.8. Статистический анализ

Для количественной оценки точности автоматической сегментации ПЖ и её патологических образований, выполненной системой КЗ, был применён коэффициент Дайса–Сёренсена (Dice Similarity Coefficient, DSC) – один из наиболее распространённых метрик оценки схожести бинарных масок в задачах медицинской сегментации. Он позволяет объективно сравнить степень совпадения между двумя наборами данных, в данном случае – между сегментацией, выполненной автоматически с помощью нейросетевого алгоритма, и эталонной (референтной) разметкой, выполненной врачом-рентгенологом вручную [114].

Данный коэффициент широко используется в современной литературе по медицинской визуализации, включая статьи по сегментации анатомических структур, опухолей, сосудов и других объектов на КТ и МРТ изображениях. В зависимости от контекста, его также называют индексом Сёренсена–Дайса, коэффициентом подобия, коэффициентом сходства, а в англоязычной литературе он может встречаться под аббревиатурой *DSC*. Математически индекс рассчитывается по формуле:

$$DSC = \frac{2 \cdot |A \cap B|}{|A| + |B|} \quad (2)$$

где A – множество вокселей, принадлежащих автоматической маске, B – множество вокселей, входящих в референтную (ручную) маску, а $|A \cap B|$ – их пересечение. Значение коэффициента варьирует от 0 до 1 (или от 0% до 100%), где 1 (или 100%) означает полное совпадение двух масок, а 0 – полное отсутствие общих вокселей между ними. Таким образом, DSC является не только показателем точности, но и важным критерием воспроизводимости сегментации.

В настоящем исследовании коэффициент Дайса применялся для количественного сравнения масок, построенных системой КЗ, с эталонными масками, созданными опытным врачом-рентгенологом. Сравнение проводилось по каждому отдельному исследованию, входящему в валидационную выборку, которая включала 20 компьютерных томографий с размеченной паренхимой поджелудочной железы и 11 исследований с размеченными опухолевыми образованиями. Для получения обобщенной оценки точности, индивидуальные значения DSC усреднялись по каждому из двух наборов данных, что позволило определить среднюю степень совпадения автоматических и экспертных масок для каждой анатомической и патологической структуры. Этот подход обеспечил объективную оценку эффективности алгоритма в реальных условиях клинической визуализации.

В качестве метрик оценки качества разметки нейросети использовались диагностическая точность и чувствительность.

Для количественной оценки эффективности модели, предназначенной для автоматического выявления образований поджелудочной железы на КТ-изображениях, были использованы стандартные метрики качества классификации, а также графические методы анализа динамики обучения модели (таблица 4).

Таблица 4 – Характеристики основных метрик качества модели и графического анализа

Метрика	Назначение
Accuracy	Общая корректность классификации
Precision	Точность определения «опухоли» среди всех помеченных случаев

Продолжение таблицы 4

Метрика	Назначение
Recall	Способность обнаружить все истинные опухоли
AUC	Неспецифический показатель качества классификации
ROC-кривая	Визуальное представление TPR vs FPR
Графики	Анализ динамики обучения: точность, полнота, потери

Метрики качества модели

– *Accuracy* (точность) – определяет обобщенную долю случаев (как опухолей, так и нормальных), классифицированных правильно. Рассчитывается как доля верных предсказаний от всех случаев:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$

где TP , TN – истинно положительные и отрицательные случаи, FP , FN – ложноположительные и ложноотрицательные;

– *Precision* (точность положительных предсказаний) – показывает, какую долю из помеченных моделью как «опухоль» действительно составляют опухоли, то есть минимизирует вероятность ложноположительных срабатываний;

– *Recall* (полнота, чувствительность) – оценивает, какую долю истинных опухолевых случаев модель смогла обнаружить, что критично в медицинских применениях, где важно минимизировать пропуски;

– *AUC* (*Area Under the Curve*) – характеризует способность модели разделять классы (опухоль vs. без опухоли) независимо от порога классификации. *AUC* включает отображение *TPR* (чувствительности) и *FPR* (ошибок ложноположительных) и, как правило, значения $AUC > 0.80$ рассматриваются как клинически полезные.

Графический анализ динамики обучения

- *ROC*-кривая позволяет визуализировать зависимость между *TPR* и *FPR* при различных порогах классификации, что помогает выбрать оптимальный рабочий точек и оценить различающую способность модели;
- график *Accuracy* отражает, как меняется общая точность модели по мере увеличения числа эпох обучения, что помогает выявить моменты схождения и переобучения;
- графики *Precision* и *Recall* демонстрируют, как сбалансированы ложноположительные и ложноотрицательные ошибки в ходе обучения, что важно для понимания компромисса между точностью диагностики и пропуском патологии;
- график функции потерь (*Loss*) отображает динамику снижения ошибки модели и позволяет оценить стабильность процесса обучения.

ГЛАВА 3. ВОЗМОЖНОСТИ КОМПЬЮТЕРНОГО ЗРЕНИЯ В СЕГМЕНТАЦИИ И ДЕТЕКЦИИ ОБРАЗОВАНИЙ ПОДЖЕЛУДОЧНОЙ ЖЕЛЕЗЫ ПО КОМПЬЮТЕРНЫМ ТОМОГРАММАМ

3.1. Результаты определения зависимости точности сегментации врача-рентгенолога от внешних факторов и опыта

В рамках данного раздела диссертационной работы нами проведена оценка зависимости точности разметки паренхимы ПЖ врачом-рентгенологом в зависимости от внешних факторов.

Оценка влияния внешних факторов на разметку врача рентгенолога представлена в таблицах 5-14.

Таблица 5 – Результаты корреляционного анализа значений исследуемых показателей с возрастом рентгенолога

Показатель	ρ [95% ДИ]	p
Артериальная фаза		
DICE (сравнение с эталоном)	-0,02 [95% ДИ: -0,53; 0,5]	0,938
Разница с эталонным значением	0,01 [95% ДИ: -0,5; 0,52]	0,964
Венозная фаза		
DICE (сравнение с эталоном)	-0,05 [95% ДИ: -0,55; 0,47]	0,86
Разница с эталонным значением	-0,08 [95% ДИ: -0,57; 0,45]	0,764

Таблица 6 – Значения исследуемых показателей в зависимости от наличия опыта разметки

Показатель	Опыт разметки		p
	Нет	Есть	
Артериальная фаза			
DICE (сравнение с эталоном)	84,7 (83,7; 87)	86,6 (84,2; 86,8)	0,768
Разница с эталонным значением	-11462,5 (-16886; -8380,5)	-11472 (-20480; -3888)	0,953

Продолжение таблицы 6

Показатель	Опыт разметки		p
	Нет	Есть	
Венозная фаза			
DICE (сравнение с эталоном)	86 (84,3; 86,4)	87,4 (86,7; 88,3)	0,04
Разница с эталонным значением	-6632,5 (-12002; -1405,5)	3693 (1800; 5139)	0,129

Таблица 7 – Значения исследуемых показателей в зависимости от возраста рентгенолога

Показатель	Возраст рентгенолога		p
	23-28 лет	28-40 лет	
Артериальная фаза			
DICE (сравнение с эталоном)	86,5 (84,3; 87,1)	84,3 (83,2; 84,7)	0,371
Разница с эталонным значением	-10014 (-16883; -4891)	-16297 (-17082; -12716)	0,513
Венозная фаза			
DICE (сравнение с эталоном)	86,4 (86,2; 87,2)	85,8 (83,9; 86,8)	0,44
Разница с эталонным значением	-27 (-7828; 4777,5)	-6049 (-21891; -1256)	0,254

Таблица 8 – Значения исследуемых показателей в зависимости от пола рентгенолога

Показатель	Пол рентгенолога		p
	Женский	Мужской	
Артериальная фаза			
DICE (сравнение с эталоном)	84,7 (83,4; 86,6)	86,9 (86; 87,6)	0,28
Разница с эталонным значением	-12716 (-17884,5; -5894,5)	-10840,5 (-13724; -6779,5)	0,851
Венозная фаза			
DICE (сравнение с эталоном)	86,1 (84,8; 86,5)	88,3 (87,8; 88,5)	0,026
Разница с эталонным значением	-6049 (-13250,5; 1941,5)	2575,5 (-454; 3436,5)	0,412

Таблица 9 – Значения исследуемых показателей в зависимости от занятости рентгенолога

Показатель	Занятость		р
	Женский	Мужской	
Артериальная фаза			
DICE (сравнение с эталоном)	84,3 (83,2; 84,7)	86,7 (86,5; 87,8)	0,113
Разница с эталонным значением	-16297 (-18687; -10209)	-8860 (-11058,8; 656,5)	0,145
Венозная фаза			
DICE (сравнение с эталоном)	86,3 (83,9; 86,7)	87,3 (86,2; 88,3)	0,145
Разница с эталонным значением	-7216 (-13176; -1256)	2575,5 (-940,5; 3607,5)	0,328

Таблица 10 – Значения исследуемых показателей в зависимости от удовлетворенности местом работы

Показатель	Удовлетворенность		р
	Удовлетворен	Не удовлетворен	
Артериальная фаза			
DICE (сравнение с эталоном)	84,7 (84,3; 87)	84,9 (82,1; 87,1)	0,571
Разница с эталонным значением	-11472 (-17884,5; -5894,5)	-11267,5 (-16669; -6487)	0,949
Венозная фаза			
DICE (сравнение с эталоном)	86,3 (85,7; 87)	86,6 (85,8; 87,2)	0,661
Разница с эталонным значением	-6049 (-10604; 4416)	-1555 (-6863,2; -104,2)	0,851

Таблица 11 – Значения исследуемых показателей в зависимости от продолжительности свободного времени

Показатель	Свободное время		р
	До 2 часов	От 2 часов и более	
Артериальная фаза			
DICE (сравнение с эталоном)	86,5 (83,8; 86,7)	84,7 (84; 87,6)	0,779
Разница с эталонным значением	-12716 (-18781; -8860)	-10840,5 (-16894,5; -3627,5)	0,779
Венозная фаза			
DICE (сравнение с эталоном)	86,1 (84,8; 86,6)	86,5 (86,2; 87,6)	0,463
Разница с эталонным значением	-1854 (-17608; 272)	-1349 (-7420; 4716)	0,281

Таблица 12 – Результаты корреляционного анализа значений исследуемых показателей с продолжительностью свободного времени

Показатель	τ_B [95% ДИ]	p
Артериальная фаза		
DICE (сравнение с эталоном)	0,09 [95% ДИ: -0,33; 0,5]	0,674
Разница с эталонным значением	0,09 [95% ДИ: -0,37; 0,55]	0,674
Венозная фаза		
DICE (сравнение с эталоном)	0,24 [95% ДИ: -0,15; 0,64]	0,247
Разница с эталонным значением	0,22 [95% ДИ: -0,26; 0,7]	0,293

Таблица 13 – Значения исследуемых показателей в зависимости от наличия долговых обязательств

Показатель	Долговые обязательства		p
	Нет	Есть	
Артериальная фаза			
DICE (сравнение с эталоном)	85,6 (84,2; 86,7)	84,7 (83,2; 89)	0,953
Разница с эталонным значением	-10840,5 (-15402; -8380,5)	-18687 (-28528; -3888)	0,44
Венозная фаза			
DICE (сравнение с эталоном)	86,2 (85,6; 86,7)	86,7 (86,3; 87,4)	0,513
Разница с эталонным значением	-1555 (-6924; 3220)	-8032 (-13176; 3351)	0,679

Таблица 14 – Результаты корреляционного анализа значений исследуемых показателей с оценкой стоимости проведения разметки

Показатель	τ_B [95% ДИ]	p
Артериальная фаза		
DICE (сравнение с эталоном)	0,18 [95% ДИ: -0,24; 0,6]	0,377
Разница с эталонным значением	0,03 [95% ДИ: -0,25; 0,32]	0,876
Венозная фаза		
DICE (сравнение с эталоном)	-0,12 [95% ДИ: -0,53; 0,29]	0,568
Разница с эталонным значением	-0,18 [95% ДИ: -0,55; 0,19]	0,377

Статистически значимых зависимостей выявлено не было, кроме опыта работы врача рентгенолога и пола для венозной фазы исследования. Можно предположить, что в венозную фазу визуализация точной границы паренхимы поджелудочной может быть затруднена из-за близкого расположения петель тонкого кишечника и желудка и требуется больший опыт работы для нахождения ее, в то время как в артериальную фазу паренхима поджелудочной визуализируется лучше.

Оценка зон гипер- и гипоразметки паренхимы поджелудочной железы в отличие от эталона.

Произведено сравнение 15 сегментационных масок 15 врачей-рентгенологов в артериальную и в портальную фазы КТ-исследования одного пациента. Для наглядности и выделения «критичных» зон были построены 3D-модели гипо- и гиперразметки. Гипоразметка включает в себя воксели, которые включил в маску при разметке каждый из 15 врачей, гиперразметка включает в себе все воксели, которые хотя бы единожды были размечены врачом-разметчиком (рисунки 5 и 6).

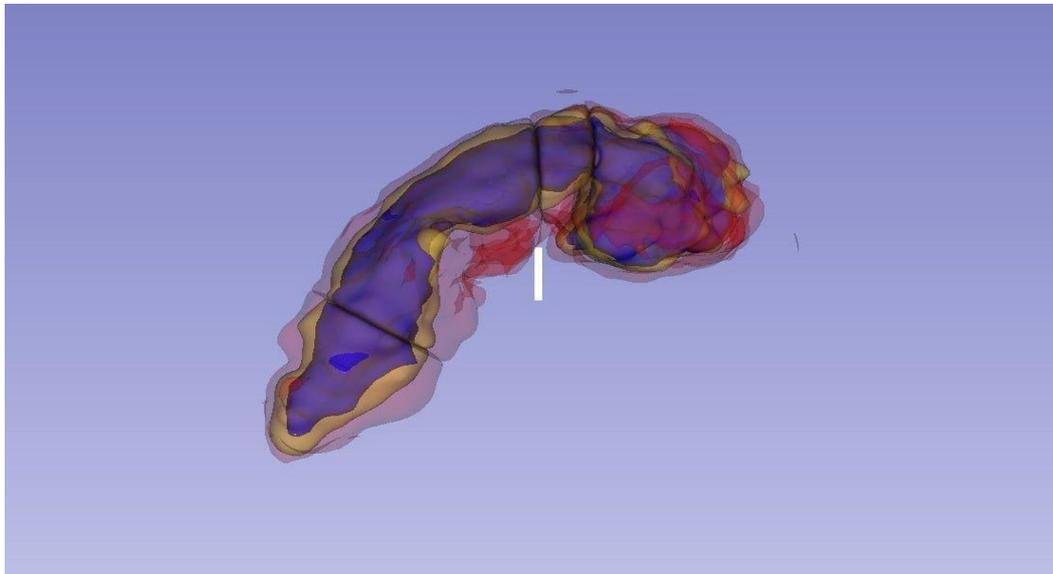


Рисунок 5 – 3D-модель сегментационных масок поджелудочной железы, размеченных по КТ-изображениям в артериальную фазу исследования врачами-рентгенологами

Примечание: Синим цветом обозначена модель гипоразметки ПЖ, желтым – эталонная модель, красным – гиперразметка ПЖ.

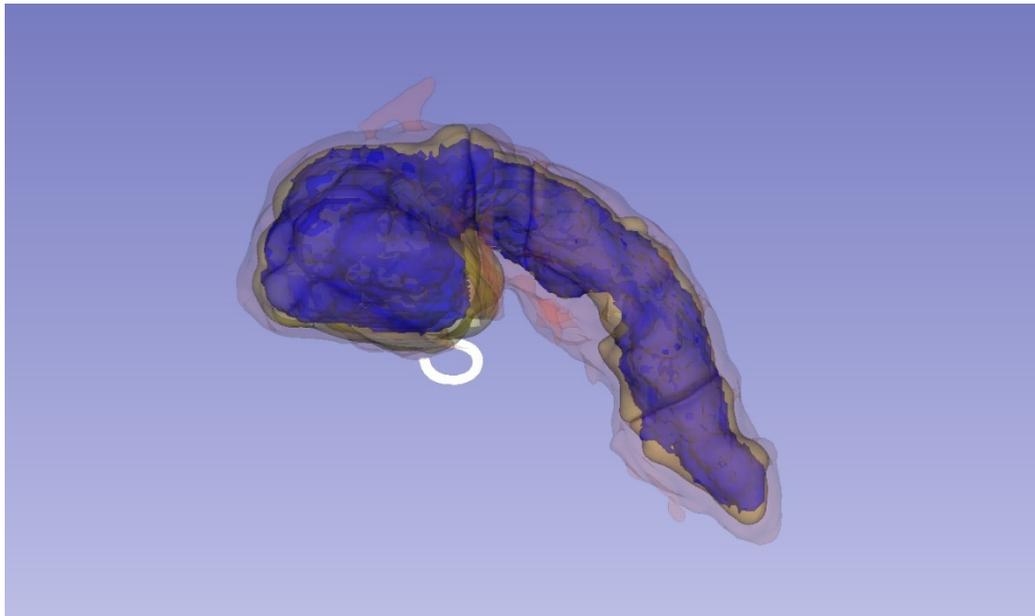


Рисунок 6 – 3D-модель сегментационных масок поджелудочной железы, размеченных по КТ-изображениям в портальную фазу исследования врачами-рентгенологами

Примечание: Синим цветом обозначена модель гипоразметки ПЖ, желтым – эталонная модель, красным – гиперразметка ПЖ.

Так как обучение нейросети сегментации ПЖ и ее образований подразумевает в дальнейшем совместное использование модели вместе с методологией текстурного анализа мы провели анализ зон различий гипер- и гипоразметки с эталоном.

В качестве меры выраженности отклонений текстурных параметров в зонах гипо- и гиперразметки от эталонных значений использовалось абсолютное отклонение от эталонного значения масштабированное на его абсолютное значение:

$$\frac{|\text{значение в зоне гипо / гиперразметки} - \text{значение эталона}|}{|\text{значение эталона}|} \quad (4)$$

В Приложении А и на рисунках 7 и 8 представлены результаты оценки особенностей зон гипо- и гиперразметки по сравнению с эталоном в отношении текстурных параметров. В артериальную фазу наиболее выраженными особенностями гиперразметки были параметры glcm: ClusterShade и

ClusterProminence, которые характеризовались более чем 100 раз увеличенными по значению с эталонными значениями, HighGrayLevelEmphasis, Autocorrelation, ClusterTendency, SumSquares, DifferenceVariance и Contrast, которые были выше эталонных значение более чем в 5 раз, параметры gldm: SmallDependenceHighGrayLevelEmphasis и GrayLevelVariance, которые имели абсолютные отклонения от эталона в большую сторону 28 и 6,1, соответственно, параметры firstorder: Skewness и Variance которые имели абсолютные отклонения от эталона в большую сторону 28 и 6,6. В артериальную фазу для зон гипоразметки было характерно увеличение более чем в 10 раз значений параметра ClusterShade (glcm) и Skewness (firstorder), а также абсолютное отклонение в большую сторону параметра SurfaceVolumeRatio, составившее 3,77.

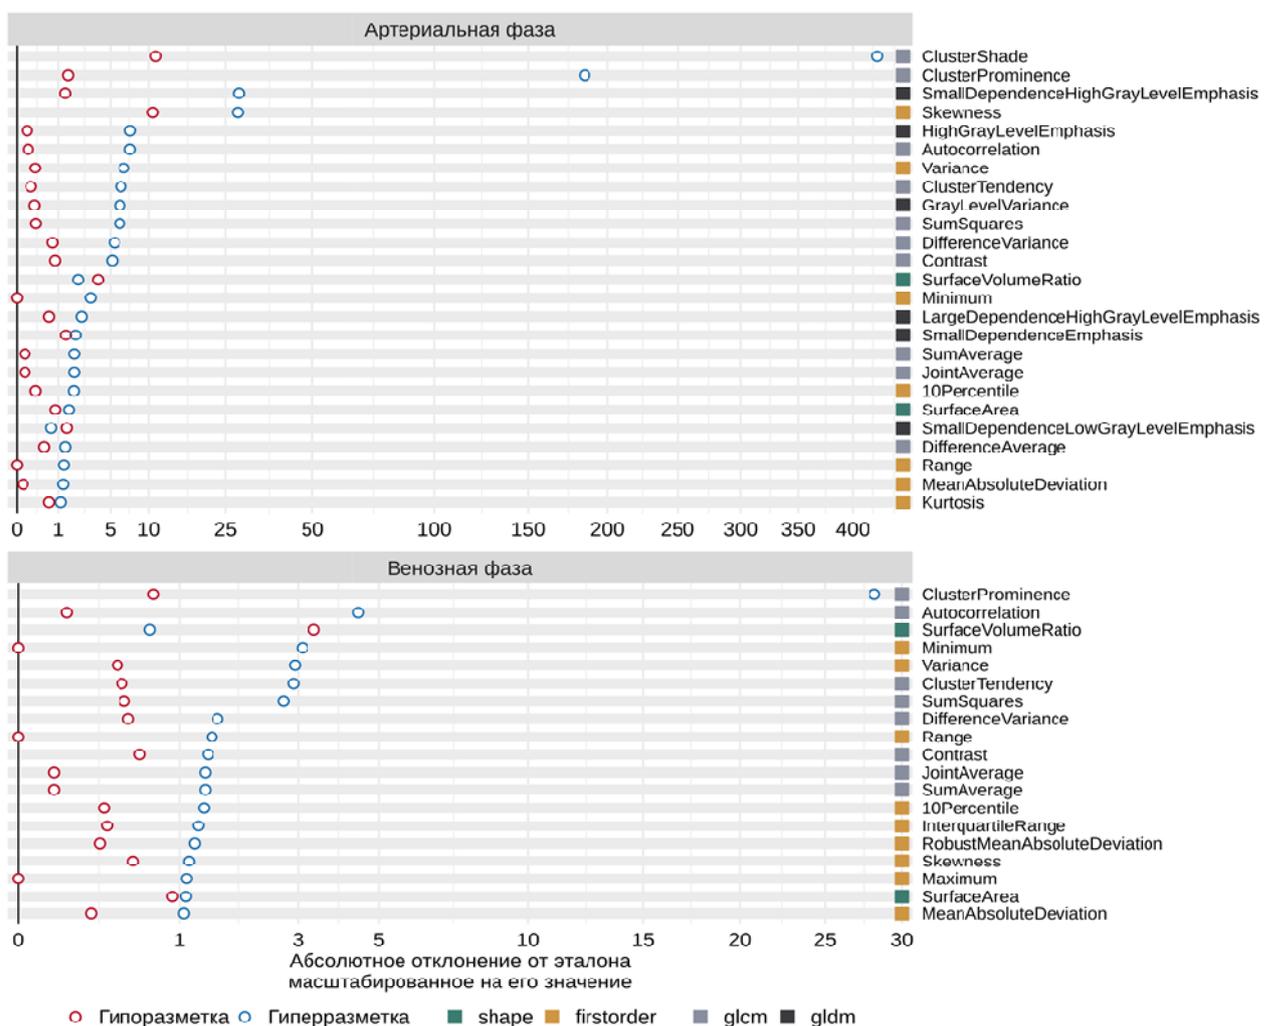


Рисунок 7 – Абсолютные отклонения от эталонных значений текстурных параметров масштабированные на их значения

Артериальная фаза		Венозная фаза		
Гипоразметка	Гиперразметка	Гипоразметка	Гиперразметка	
▲ 11.1	▲ 424			ClusterShade
▲ 1.52	▲ 185	▲ 0.71	▲ 28	ClusterProminence
▲ 1.35	▲ 28			SmallDependenceHighGrayLevelEmphasis
▲ 10.6	▲ 28	▲ 0.51	▲ 1.12	Skewness
	▲ 7.4			HighGrayLevelEmphasis
	▲ 7.4		▲ 4.45	Autocorrelation
	▲ 6.6		▲ 2.93	Variance
	▲ 6.2		▲ 2.9	ClusterTendency
	▲ 6.1			GrayLevelVariance
	▲ 6.1		▲ 2.7	SumSquares
▲ 0.75	▲ 5.5		▲ 1.53	DifferenceVariance
▲ 0.85	▲ 5.2	▲ 0.57	▲ 1.38	Contrast
▲ 3.77	▲ 2.16	▲ 3.36	▲ 0.67	SurfaceVolumeRatio
	▼ 3.12		▼ 3.1	Minimum
▼ 0.61	▲ 2.41			LargeDependenceHighGrayLevelEmphasis
▲ 1.39	▲ 1.98			SmallDependenceEmphasis
	▲ 1.9		▲ 1.34	SumAverage
	▲ 1.9		▲ 1.34	JointAverage
	▼ 1.87		▼ 1.32	10Percentile
▲ 0.86	▲ 1.57	▲ 0.91	▲ 1.08	SurfaceArea
	▲ 1.28		▲ 1.44	Range
▲ 1.44	▼ 0.69			SmallDependenceLowGrayLevelEmphasis
	▲ 1.36			DifferenceAverage
	▲ 1.25		▲ 1.05	MeanAbsoluteDeviation
	▲ 0.78		▲ 1.24	InterquartileRange
	▲ 0.9		▲ 1.19	RobustMeanAbsoluteDeviation
▲ 0.61	▲ 1.12		▲ 0.79	Kurtosis
	▲ 0.69		▲ 1.09	Maximum

■ shape
■ firstorder
■ glcm
■ gldm

Рисунок 8 – Абсолютные отклонения от эталонных значений текстурных параметров масштабированные на их значения

Наиболее высокие отклонения от эталонных значений в зонах гиперразметки в венозную фазу имели параметры такие glcm как ClusterProminence и Autocorrelation, абсолютные значения отклонений которых составили 28 и 4,45, соответственно, также в зонах гиперразметки было отмечено снижение значений параметра Minimum (firstorder) на 310% и увеличение параметра Variance (firstorder) на 293%. Наиболее выраженной особенностью зон гипоразметки в венозную фазу было увеличение SurfaceVolumeRatio (shape) на 336% по сравнению с эталоном.

Вышеупомянутые текстурные характеристики (Приложение А) с высоким отклонением могут коррелировать с большим количеством ошибок в разметке, то есть большим отклонением от эталона в большую или меньшую сторону.

Оценка значимости отступа от границы эталона для извлечения текстурных характеристик.

Для этого с помощью ПО “3D slicer” мы строили сегментационные маски с прибавлением по границе по 1 мм до 5 мм и убавлением по 1 мм до 5 мм, а затем сравнивали соответствие текстурных характеристик с эталоном с помощью коэффициента внутриклассовой корреляции (ИСС).

Вот как интерпретировать значение коэффициента внутриклассовой корреляции согласно Ку и Ли:

- менее 0,50: низкая надежность;
- от 0,5 до 0,75: умеренная надежность;
- между 0,75 и 0,9: хорошая надежность;
- более 0,9: превосходная надежность.

Результаты представлены в Таблице 15.

Таблица 15 – Значения коэффициента внутриклассовой корреляции для каждого отступа от границы

Фаза исследования	Отступ от границы, мм									
	-5	-4	-3	-2	-1	+1	+2	+3	+4	+5
Артериальная	0,451	0,766	0,766	0,874	0,931	0,859	0,761	0,773	0,744	0,631
Венозная	0,581	0,767	0,869	0,962	0,993	0,994	0,969	0,698	0,725	0,648

Если условно взять порог в 0,9 (превосходная надежность), то согласно значениям коэффициента внутриклассовой корреляции: для артериальной фазы КТ-исследования нежелательна недоразметка границы ПЖ более чем на 2 мм и гиперразметка более чем на 1 мм; для портальной фазы КТ-исследования нежелательна недоразметка границы ПЖ более чем 3 мм и гиперразметка более чем на 2 мм.

3.2. Результаты определения точности сегментации паренхимы поджелудочной железы системой компьютерного зрения по данным компьютерной томографии

В данном разделе диссертационной работы мы получали сегментационные маски первой тестовой выборки из 20 исследований, предсказанные нейросетью и сравнивали их с размеченными двумя врачами-рентгенологами. Точность сегментационных масок отражена с помощью коэффициента сходства Соренса-Дайса в таблице 16.

Таблица 16 – Точность сегментационных масок валидационной выборки в артериальную и портальную фазы КТ-исследований

Артериальная фаза		Венозная фаза	
Код исследования	Dice	Код исследования	Dice
AC_6_arterial_0000	0.888404	AC_3_portal_0000	0.85250807
NE1004B_arterial_0000	0.89127517	NE2001B_portal_0000	0.8021831
NE2002B_arterial_0000	0.9144513	NE2003B_portal_0000	0.71730375
NE2007B_arterial_0000	0.77658075	NE2007B_portal_0000	0.80178666
NEN_12_arterial_0000	0.8162483	PAN_24P	0.75077814
NEN_3_arterial_0000	0.85119045	PAN_25P	0.8327945
NEN_4_arterial_0000	0.8861745	ac_11 p	0.85354805
PAN_24A	0.75725454	nen_24 p	0.80727273
PAN_33A	0.86548376	pan_15 p	0.78777623
PAN_36A	0.77671176	pan_3 p	0.82777375

Средняя точность сегментации нейросетью в сравнении с врачом-рентгенологом ПЖ в артериальную фазу исследования составила 0.8467, в портальную фазу исследования – 0.8033.

Точность достаточно высокая, чтобы использовать данную нейросеть для дообучения сегментации образований ПЖ по КТ-томограммам. Однако при постепенном увеличении обучающей базы данных возможно повышение точности сегментации нейросетью.

3.3. Результаты определения точности сегментации образований поджелудочной железы системой компьютерного зрения по данным компьютерной томографии

В данном разделе диссертационной работы мы получали сегментационные маски второй тестовой выборки из 11 исследований, предсказанные нейросетью и сравнивали их с размеченными двумя врачами-рентгенологами. Точность сегментационных масок отражена с помощью коэффициента сходства Соренса-Дайса в таблице 17.

Таблица 17 – Точность сегментационных масок валидационной выборки в артериальную и портальную фазы КТ-исследований

Артериальная фаза		Венозная фаза	
Код исследования	Dice	Код исследования	Dice
NE1006B_arterial_0000	0.49127534	AC_4_portal_0000	0.4021831
NE2001B_arterial_0000	0.7146713	ac_5 p	0.41730375
NE2006B_arterial_0000	0.77611275	ac_8 p	0.70178666
NEN_11_arterial_0000	0.4159433	AC_2_portal_0000	0.45077814
NEN_2_arterial_0000	0.55309045	ac_9 p	0.5327945
		ac_1 p	0.55354805

Средняя точность сегментации нейросетью в сравнении с врачом-рентгенологом ПЖ в артериальную фазу исследования гиперваскулярных образований – 0.6467, гиповаскулярных в портальную фазу исследования – 0.6143.

3.4. Оценка функции детекции образований поджелудочной железы системой компьютерного зрения по данным компьютерной томографии

Для оценки функции детекции нейросети мы использовали третий тестовый набор данных из 193 КТ-исследований, среди них было 38 случаев с образованием ПЖ и 155 – без образований. Были представлены результаты

предсказаний модели (**predicted_label**) и истинные значения (**true_label**), а также метрики качества модели:

- **AUC (Area Under Curve)** = 0.8896.
- **Accuracy** = 0.9255.
- **Recall** = 0.7222.
- **Precision** = 0.8378.

Указанные метрики проиллюстрированы рисунками 9-13.

На рисунке 9 представлен график ROC-кривой (Receiver Operating Characteristic curve), которая иллюстрирует качество работы нейронной сети в задаче бинарной классификации (детекция опухолей ПЖ на КТ-исследованиях). ROC-кривая показывает зависимость True Positive Rate (TPR) от False Positive Rate (FPR) при изменении порога классификации.

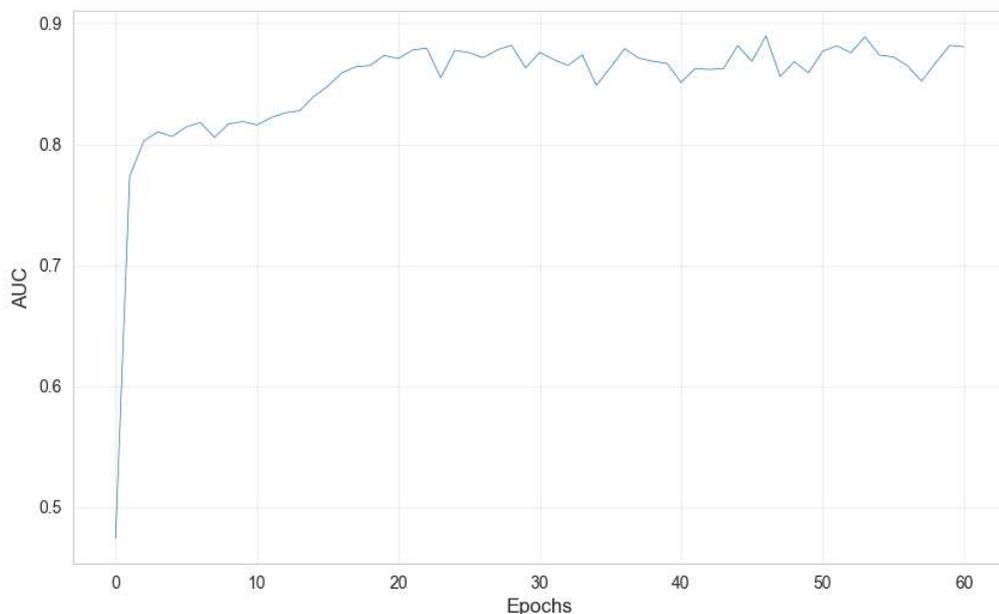


Рисунок 9 – ROC-кривая (Receiver Operating Characteristic curve)

На рисунке 10 представлен график зависимости **общей точности (Accuracy)** модели от количества эпох (**Epochs**) обучения. Общая точность – это метрика, которая показывает долю правильно классифицированных случаев (как с опухолью, так и без неё) среди всех предсказаний модели.

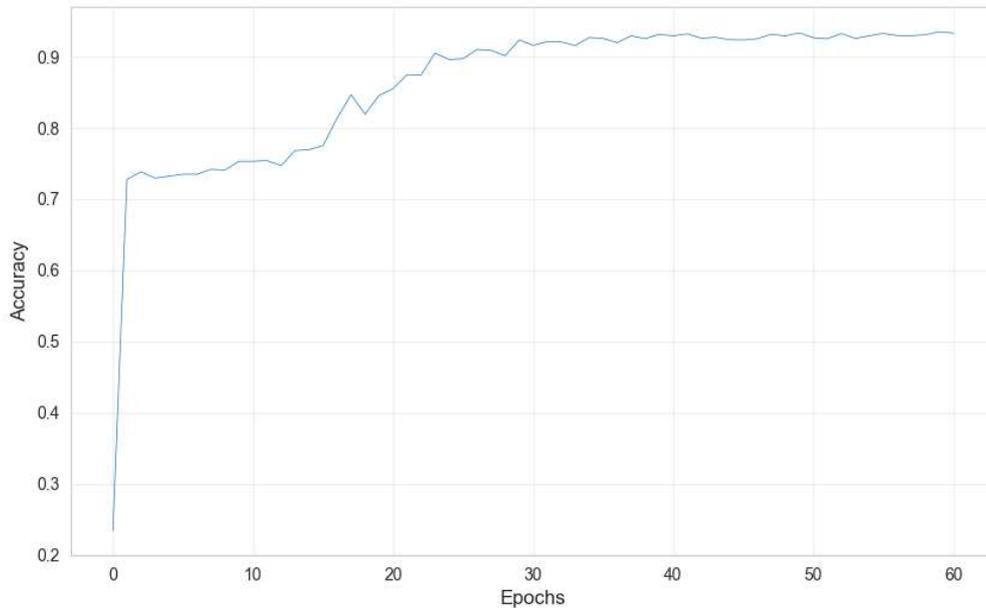


Рисунок 10 – Зависимость общей точности (Accuracy) модели от количества эпох (Epochs) обучения

На рисунке 11 представлен график зависимости **точности (Precision)** модели от количества эпох (**Epochs**) обучения. **Precision (Точность)** – это метрика, которая показывает, какую долю предсказанных положительных случаев (опухолей) модель правильно идентифицировала.

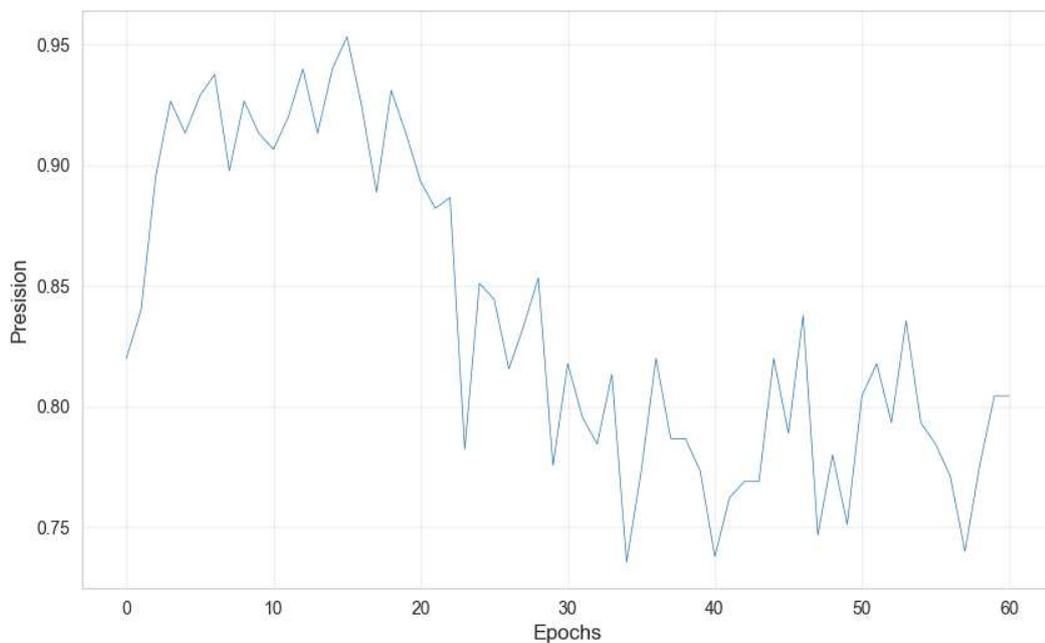


Рисунок 11 – Зависимость **точности (Precision)** модели от количества эпох (**Epochs**) обучения

Анализ графика Precision:

- **начальный рост:** в первые 10-20 эпох Precision быстро увеличивается с 0.75 до 0.9, что свидетельствует о том, что модель быстро учится минимизировать ложноположительные предсказания;
- **стабилизация:** после 20-30 эпох Precision стабилизируется на уровне около 0.85-0.9;
- **максимальное значение:** максимальное значение Precision составляет около 0.9 (90%). Это означает, что 90% предсказанных моделью опухолей действительно являются опухолями.

На рисунке 12 представлен график зависимости **полноты (Recall)** модели от количества **эпох (Epochs)** обучения. Полнота – это метрика, которая показывает, какую долю истинных положительных случаев (опухолей) модель правильно идентифицировала.

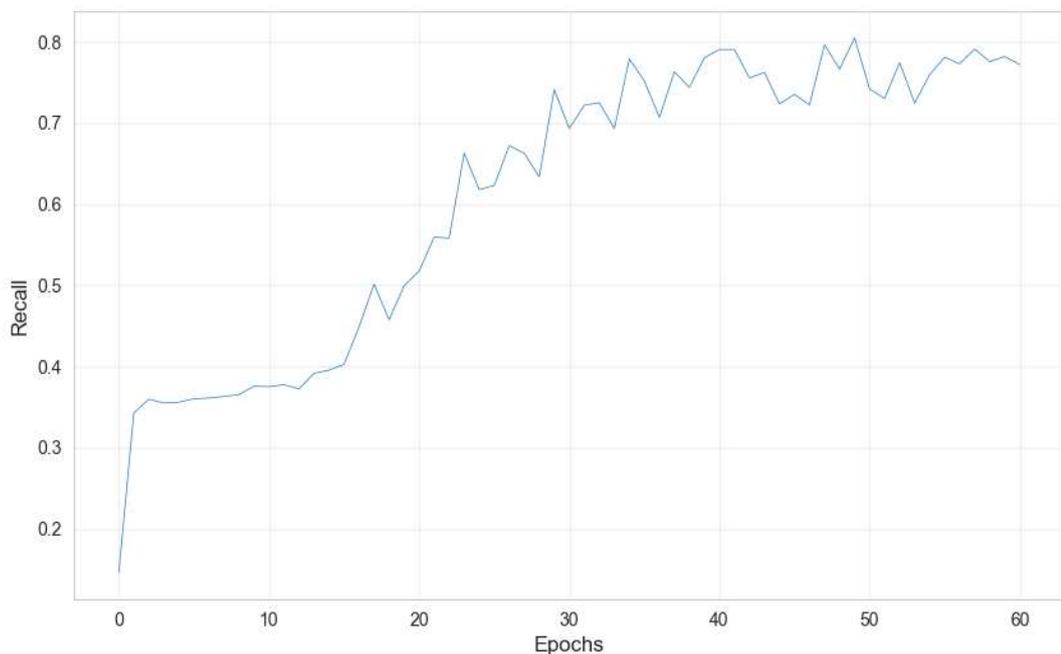


Рисунок 12 – Зависимость **полноты (Recall)** модели от количества **эпох (Epochs)** обучения

Анализ графика Recall:

- **начальный рост:** в первые 10-20 эпох Recall быстро увеличивается с 0.2 до 0.6, что свидетельствует о том, что модель быстро учится правильно идентифицировать опухоли;
- **стабилизация:** после 20-30 эпох рост Recall замедляется, и кривая выходит на плато. К 60 эпохам Recall стабилизируется на уровне около 0.7;
- **максимальное значение:** максимальное значение Recall составляет около 0.7 (70%). Это означает, что модель правильно идентифицирует 70% всех случаев с опухолью.

На рисунке 13 представлен график зависимости **потерь (Loss)** модели от количества **эпох (Epochs)** обучения. Loss (Функция потерь) – это метрика, которая показывает, насколько предсказания модели отличаются от истинных значений. Чем ниже значение Loss, тем лучше модель справляется с задачей.

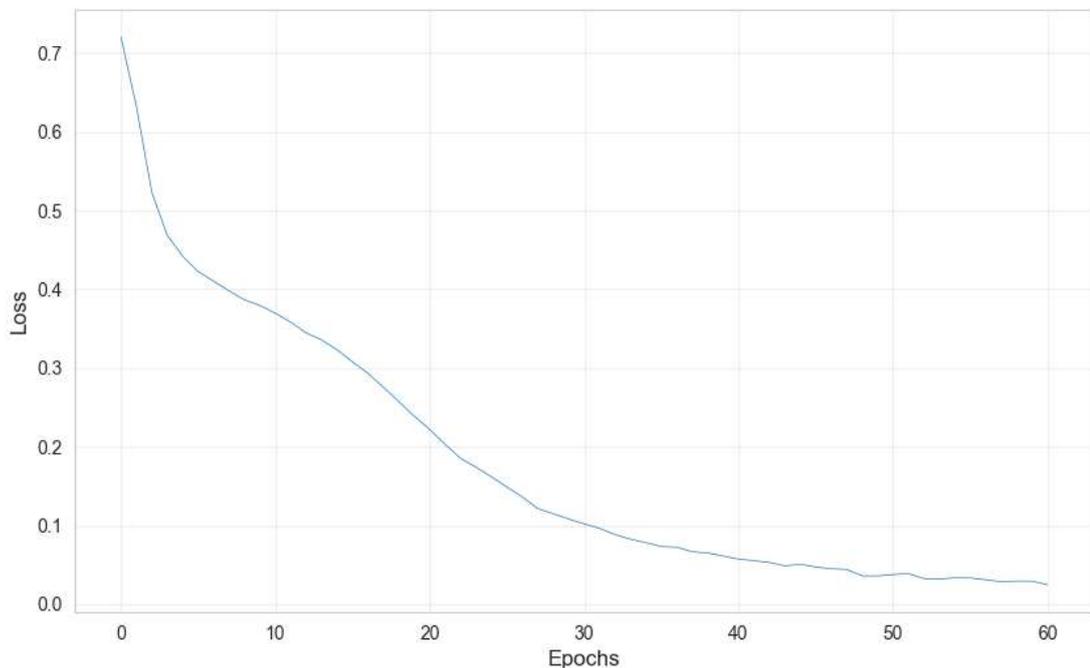


Рисунок 13 – Зависимость **потерь (Loss)** модели от количества **эпох (Epochs)** обучения

Анализ графика Loss:

- **начальное снижение:** в первые 10-20 эпох Loss быстро уменьшается с 0.7 до 0.2, что свидетельствует о быстром обучении модели.
- **стабилизация:** после 20-30 эпох Loss продолжает уменьшаться, но более медленно. К 60 эпохам Loss стабилизируется на уровне около 0.1.
- **минимальное значение:** минимальное значение Loss составляет около 0.1, что указывает на хорошую сходимость модели.

Анализ предсказаний:

1. **Общая точность (Accuracy = 0.9255)** – модель правильно классифицировала 92,55% всех случаев. Это высокий показатель, который говорит о том, что модель в целом хорошо справляется с задачей детекции опухолей.

2. **Полнота (Recall = 0.7222)** – модель правильно идентифицировала 72,22% всех случаев с опухолью. Это означает, что около 27,78% случаев с опухолью были пропущены (ложноотрицательные случаи). В диагностике это критично, так как пропуск опухоли может иметь серьезные последствия для пациента.

3. **Точность положительных предсказаний (Precision = 0.8378)** – из всех случаев, которые модель предсказала как опухоль, 83,78% действительно были опухолями. Остальные 16,22% – это ложноположительные случаи, когда модель ошибочно определила опухоль там, где её не было.

4. **AUC (Area Under Curve = 0.8896)** – AUC близко к 1, что говорит о хорошей способности модели различать случаи с опухолью и без неё. Это важный показатель, особенно в задачах бинарной классификации.

Таким образом, модель демонстрирует высокую точность (Accuracy = 0.9) и хорошую способность различать случаи с опухолью и без неё (AUC = 0.8896) по данным КТ. Однако значение Recall = 0.7 указывает на то, что модель пропускает около 30% опухолей, что критично в первичной диагностике и на данном этапе требует пересмотра исследований врачом-рентгенологом.

Рекомендации

Для улучшения Recall можно рассмотреть:

- увеличение количества данных для обучения, особенно сложных случаев (например, с артефактами или аномалиями);
- использование методов балансировки классов (например, oversampling для класса с опухолями);
- настройку гиперпараметров модели для улучшения Recall.

Для дальнейшего улучшения модели можно также рассмотреть использование более сложных архитектур нейронных сетей или ансамблей моделей.

3.5. Обсуждение результатов валидации системы компьютерного зрения для сегментации поджелудочной железы и детекции ее образований по компьютерной томографии

В сравнении с упомянутыми выше исследованиями [84], в которых использовались аналогичные по объему и составу наборы данных, алгоритм машинного обучения, примененный в данной работе для сегментации паренхимы ПЖ, продемонстрировал сопоставимую точность по коэффициенту Dice. Это свидетельствует о его высокой эффективности и потенциале применения в повседневной клинической практике врача-рентгенолога. Более того, стабильные результаты, полученные на различных фазах контрастирования, подтверждают универсальность предложенного подхода, что особенно важно при интеграции автоматических методов анализа в рутинный диагностический процесс.

Достигнутая точность сегментации открывает широкие перспективы не только для непосредственного выделения паренхимы органа, но и для последующего анализа патологических изменений, включая выявление новообразований различной этиологии. Система КЗ, представленная в данной работе, обладает потенциалом стать вспомогательным инструментом в

диагностике как выраженных, так и субклинических изменений ПЖ. В частности, в будущем её применение может оказаться полезным при диагностике диффузных изменений паренхимы, таких как стеатоз, фиброз или хронический панкреатит, а также для обнаружения малых очаговых образований: гипervasкулярных (менее 1 см) и гиповаскулярных (менее 2 см), диагностика которых традиционно вызывает затруднения даже у опытных специалистов.

Интеграция текстурного анализа с автоматической сегментацией открывает новые горизонты в сфере радиомики, обеспечивая более глубокую количественную оценку тканей на основе КТ-данных. Совмещение этих технологий особенно перспективно в задачах раннего выявления и дифференциальной диагностики злокачественных и доброкачественных процессов. Кроме того, построение трехмерных моделей ПЖ на основе автоматической сегментации значительно упрощает предоперационное планирование, позволяя визуализировать анатомо-топографические особенности расположения опухоли, её отношения к сосудам, протокам и другим критически важным структурам.

Одним из ключевых преимуществ предложенной системы КЗ является автоматический режим обработки данных, исключая необходимость ручной разметки паренхимы. Это не только существенно ускоряет процесс анализа, но и способствует стандартизации данных, что особенно актуально при проведении научных исследований с участием больших массивов КТ-изображений. Автоматизация повышает воспроизводимость результатов и делает возможным проведение масштабных мультицентровых исследований с минимальными затратами временных и человеческих ресурсов.

Несмотря на наличие публикаций, демонстрирующих более высокие показатели точности сегментации [97], важно отметить, что во многих из них разметка проводилась исключительно на КТ-исследованиях пациентов без образований ПЖ. В то же время в данной работе использовались более сложные в интерпретации данные с патологическими изменениями, включая объемные образования и выраженные деформации органа. Эти особенности усложняют

процесс обучения, так как анатомические ориентиры становятся менее выраженными, однако именно такой подход наиболее приближен к реальным клиническим условиям. Таким образом, несмотря на потенциальное снижение точности, обучение на таких выборках обеспечивает лучшую адаптацию модели к сложным случаям, что особенно важно для задач ранней онкологической диагностики.

В отдельных работах [43] рассматривалась возможность использования современных трансферных нейросетей, таких как трансформерные архитектуры, показавших высокую эффективность при ограниченных объемах данных. Представляется целесообразным рассмотреть использование таких подходов в будущих исследованиях, особенно с учетом их способности захватывать глобальные зависимости в изображениях. Однако на текущий момент остаётся недостаточно информации об их обучении на наборах с реальными опухолевыми изменениями, что ограничивает их применение в данной конкретной задаче.

Отдельного внимания заслуживает вопрос точности сегментации самих образований ПЖ. В данной работе она оказалась существенно ниже, что, вероятно, связано с ограниченным числом соответствующих исследований в обучающей выборке, а также с морфологическими особенностями самих образований. Так, гиповаскулярные опухоли часто имеют размытые контуры и слабо дифференцируются на фоне неизменной ткани, что затрудняет даже субъективную визуальную оценку опытными специалистами. Анализ различий в сегментационных масках, размеченных разными врачами-рентгенологами, подтвердил наличие выраженного субъективного фактора, влияющего на процесс разметки. Это дополнительно осложняет задачу обучения модели и объясняет наличие расхождений между предсказаниями нейросети и экспертной разметкой.

С учётом этих факторов, возможно, стоит пересмотреть стратегию сегментации образований в сторону использования методов радиомики на автоматически сегментированной железе. Подобный подход предложен в ряде публикаций [105, 106], где показана его эффективность в задачах оценки рисков и прогнозирования течения заболевания. Альтернативной стратегией может быть

отказ от точной сегментации в пользу детекции с последующей классификацией и оценкой распространенности процесса на окружающие структуры. В настоящее время активно ведутся разработки по автоматической оценке инвазии опухоли в сосудистые структуры, протоки и соседние органы, и уже достигнуты обнадеживающие результаты [36, 52].

Таким образом, реализованная в данной работе система КЗ продемонстрировала высокую эффективность в автоматической сегментации как нормальной паренхимы ПЖ, так и патологических зон с образованиями. При оценке функции детекции образований системой КЗ, несмотря на отдельные случаи ложных срабатываний и пропущенных изменений, система показала способность обнаруживать подозрительные участки, требующие внимания врача, тем самым снижая риск упущенной патологии. Однако на данном этапе модель не может полностью заменить специалиста и должна рассматриваться как вспомогательный инструмент, поддерживающий принятие клинических решений и обеспечивающий двойной контроль.

Также важной частью работы стала оценка воспроизводимости текстурных показателей ПЖ на КТ-изображениях в зависимости от точности её разметки в различных фазах контрастного усиления (артериальной и портальной) [25]. Это исследование позволило определить допустимые границы погрешности при формировании сегментационных масок и установить расстояние, на котором отступ от края органа начинает влиять на достоверность результатов радиомического анализа. Полученные данные крайне важны при разработке протоколов автоматической разметки, обеспечивающих стандартизированные условия для последующего количественного анализа.

Совмещение автоматической сегментации, детекции (или классификации), текстурного анализа и методов радиомики на единой клинической платформе представляет собой перспективное направление развития диагностических систем, особенно в свете постоянно возрастающей цифровизации здравоохранения. Согласно ряду отечественных и международных исследований [6, 14], такая

интеграция может значительно повысить точность и своевременность диагностики, особенно на ранних стадиях злокачественных процессов.

На основании проведенного анализа можно заключить, что применение автоматизированных систем для анализа КТ-изображений ПЖ действительно может способствовать повышению эффективности работы врачей-рентгенологов, улучшению воспроизводимости диагностики и снижению вероятности пропуска клинически значимых изменений. В долгосрочной перспективе это способно привести к более раннему выявлению новообразований, повышению выживаемости пациентов и оптимизации использования ресурсов здравоохранения.

ЗАКЛЮЧЕНИЕ

За последние десять лет в научной литературе опубликовано значительное количество работ, посвященных возможностям современной лучевой диагностики опухолей ПЖ. Актуальность данной темы обусловлена не только ростом числа выявляемых случаев, но и высоким уровнем летальности при поздней диагностике злокачественных образований. Особое внимание в этих исследованиях уделяется совершенствованию визуализационных методик, повышению их точности, а также внедрению алгоритмов количественного анализа изображений, включая радиомику и ИИ.

На сегодняшний день КТ и МРТ с внутривенным контрастированием признаны основными методами визуализации ПЖ. Они являются неотъемлемыми компонентами диагностического алгоритма как на этапе установления диагноза, так и при предоперационной оценке распространенности патологического процесса. Использование контрастных препаратов позволяет улучшить визуализацию сосудистых структур, оценить васкуляризацию опухоли, а также определить степень инвазии в окружающие органы и ткани. Ввиду высокой чувствительности и специфичности эти методы играют ключевую роль в планировании тактики лечения, включая вопрос резектабельности опухоли.

На ранних этапах развития лучевой диагностики основное внимание специалистов было сосредоточено на задаче непосредственного выявления новообразований в структуре ПЖ. Особенно актуально это было в случаях опухолей малых размеров, протекающих бессимптомно. В данном контексте КТ с внутривенным контрастированием заняло центральное место как первый и до сих пор основной метод выявления объемных образований в ПЖ. Его широкая доступность, относительная простота выполнения методики, высокая скорость сканирования, а также высокое пространственное разрешение обеспечивают значительные диагностические преимущества.

Важнейшим фактором, определяющим эффективность КТ, является применение специализированного панкреатического протокола, включающего

двухфазное контрастное сканирование: позднюю артериальную (так называемую «панкреатическую») фазу и портальную венозную фазу. Именно этот протокол позволяет достичь максимальной контрастности между опухолевой тканью и нормальной паренхимой железы, что особенно важно при визуализации гиповаскулярных образований, таких как аденокарцинома ПЖ [32]. Гиповаскулярные опухоли становятся наиболее отчетливо видимыми именно в позднюю артериальную фазу, когда усиление нормальной ткани максимальное, а опухоль остаётся менее контрастной.

Дополнительную ценность КТ-диагностике придает использование таких современных методик, как КТ-перфузия. Она позволяет количественно оценить параметры кровотока в опухоли и окружающих тканях, что может служить дополнительным критерием злокачественности и помочь в дифференциальной диагностике. Кроме того, КТ-перфузия открывает возможности для ранней оценки ответа на терапию и мониторинга динамики заболевания.

Таким образом, на данном этапе развития медицины КТ с внутривенным контрастированием, выполненная по специализированному панкреатическому протоколу, остаётся основным инструментом визуализации ПЖ и её патологических изменений.

Следующим этапом развития лучевой диагностики заболеваний ПЖ стало не только выявление опухоли как таковой, но и извлечение максимального объема диагностически значимой информации из медицинских изображений. Современные подходы к интерпретации КТ- и МРТ-данных направлены на детальный анализ морфологических и функциональных характеристик как самой опухоли, так и окружающих тканей. На смену исключительно визуальной оценке пришли методы количественного анализа, позволяющие получать более точную, воспроизводимую и стандартизированную информацию.

Одним из наиболее значимых направлений стало формирование и внедрение комплекса критериев, позволяющих судить о локальной и регионарной распространенности опухолевого процесса. В частности, в клиническую практику были интегрированы многочисленные радиологические признаки, описывающие

вовлечение магистральных сосудов (артерий и вен), лимфатических узлов, периневральной ткани и близлежащих органов. Всего, согласно ряду международных рекомендаций, выделяется до 69 отдельных критериев, определяющих степень инвазии и тем самым оказывающих ключевое влияние на выбор лечебной тактики – будь то резекция, неoadьювантная терапия или паллиативное ведение. Эти критерии стали неотъемлемой частью стадирования по системам TNM и NCCN, в частности, при дифференциации гранично-резектабельных и нерезектабельных опухолей.

Параллельно с этим, большое внимание стало уделяться возможностям неинвазивного прогнозирования степени дифференцировки опухоли (грейда). Это особенно актуально в ситуациях, когда проведение биопсии затруднено или рискованно, либо не даёт достаточной информации для верификации степени злокачественности. Радиомика – направление, основанное на извлечении и анализе большого числа количественных признаков из изображений (таких как гомогенность, энтропия, плотность, форма и др.) – открыла новые перспективы в этой области. Исследования последних лет показывают, что модели, обученные на радиомических данных, позволяют предсказывать гистологическую градацию опухолей с высокой степенью достоверности, приближающейся к инвазивным методам.

С развитием технологий обработки изображений и ростом вычислительных мощностей в медицинской визуализации всё более активно внедряются методы глубокого машинного обучения (deep learning). Эта технология представляет собой одну из наиболее перспективных и стремительно развивающихся областей ИИ, основанную на работе многослойных нейросетей, способных обучаться на больших объёмах данных без жёстко заданных правил. За последние годы её применение стало практически повсеместным в таких сферах, как компьютерное зрение, речевая аналитика, прогнозирование и, конечно, медицинская диагностика.

Количество публикаций, посвящённых использованию ИИ в клинической практике, стремительно увеличивается. Особенно это заметно в области анализа

медицинских изображений, таких как КТ, МРТ, ПЭТ и УЗИ. Однако, несмотря на активное внедрение ИИ в диагностику заболеваний органов грудной клетки, головного мозга, печени и молочной железы, работ, касающихся применения нейросетей в диагностике новообразований ПЖ, существенно меньше. Ещё более ограниченным является число исследований, направленных именно на автоматическую сегментацию ПЖ и её патологических очагов. Тем не менее, даже в этих немногочисленных публикациях продемонстрированы впечатляющие результаты: точность сегментации органа по КТ-данным достигает до 90 % по метрике Dice, а чувствительность и специфичность в задаче детекции опухолей в ряде случаев оказались на уровне, сопоставимом с опытными врачами-рентгенологами [26, 43, 60, 90, 106, 126].

Несмотря на столь обнадеживающие цифры, большинство из этих алгоритмов остаются на стадии прототипов. Они либо не прошли валидацию на независимых тестовых выборках, либо не были адаптированы под различные клинические базы данных, что ограничивает возможность их масштабного применения. Кроме того, существенная проблема заключается в отсутствии унифицированных рекомендаций по построению алгоритма обучения нейросетей в задачах, связанных с ПЖ. До сих пор не существует стандартизированного подхода к построению сегментационных масок органа, выбору фаз контрастирования, предобработке изображений и аугментации данных, что затрудняет повторяемость и воспроизводимость результатов между разными исследовательскими группами.

Следует отметить, что в других анатомических зонах нейросетевые алгоритмы уже зарекомендовали себя как эффективные инструменты. В частности, они успешно применяются для сегментации опухолей головного мозга (например, глиом), печени, лёгких, органов малого таза и молочных желез. В некоторых медицинских учреждениях эти модели уже официально интегрированы в системы поддержки принятия врачебных решений и используются в повседневной работе врачей-рентгенологов, особенно в условиях высоких нагрузок и большого объёма диагностических исследований. Их задача

заключается в том, чтобы минимизировать риск пропуска патологий и повысить скорость анализа изображений, особенно при рутинном скрининге [1].

Что касается ПЖ, малое количество исследований может быть объяснено рядом факторов. Прежде всего, это высокая анатомическая вариабельность и сложность ее топографического положения. ПЖ отличается изогнутой, часто S-образной формой, располагается ретроперитонеально, прилежит к крупным сосудам и органам (двенадцатиперстная кишка, селезенка, желудок), а её структура нередко изменяется с возрастом, включая стеатоз, фиброз или атрофию. Дополнительную сложность представляет собой неоднородность фазы контрастного усиления и различия между венозной и артериальной перфузией тканей. Все эти особенности снижают воспроизводимость ручной разметки и затрудняют обучение моделей.

Отдельную проблему представляет сегментация самих образований, особенно злокачественных. Гиповаскулярные аденокарциномы, особенно малых размеров, как правило, имеют размытые, нечеткие контуры, сливаются с паренхимой железы и не контрастируются должным образом. Даже опытному врачу-рентгенологу бывает затруднительно с уверенностью выделить такие очаги, особенно если они расположены в протоках или головке железы на фоне хронических изменений. Именно это объясняет высокий процент пропуска таких образований при визуальной интерпретации и крайне важную роль автоматизации в их выявлении.

Все вышеперечисленные ограничения, а также потребность в создании воспроизводимых и точных инструментов анализа медицинских изображений и послужили основанием для проведения настоящего исследования. Целью нашей работы стало изучение возможностей алгоритмов машинного обучения в автоматической сегментации и детекции образований ПЖ по данным КТ с внутривенным контрастным усилением в различных фазах сканирования. Особое внимание было уделено устойчивости моделей при работе с реальными клиническими данными, наличию сопутствующих изменений и вариативности анатомических структур.

Для достижения поставленной цели мы сформулировали и решили ряд задач:

1. Разработка алгоритма создания и разметки набора данных компьютерных томограмм для обучения сверточных нейронных сетей с целью выполнения трехмерной сегментации и оценки ткани ПЖ, выявления патологических образований.

2. Провести анализ качества разметки данных КТ исследований ПЖ с гипо- и гиперваскулярными образованиями поджелудочной железы. Выявить факторы, влияющие на качество разметки данных, оценить текстурные характеристики краев ПЖ на КТ-снимках.

3. Определить степень совпадения сегментационных масок ПЖ и патологических образований в ней, размеченных врачом и системой компьютерного зрения.

4. Оценить диагностическую ценность алгоритма ИИ в выявлении образований ПЖ.

Для решения поставленных задач мы отобрали 256 пациентов с выполненными КТ с внутривенным контрастированием, прошедших лечение или получивших консультацию в НМИЦ хирургии им. А. В. Вишневского с 2011 по 2024 год. Часть пациентов была с гипо- и гиперваскулярными образованиями ПЖ по данным КТ, часть – без образований. Критериями включения были выполненная КТ с внутривенным контрастированием с наличием артериальной и венозной фаз исследования. В случае если была выполнена хирургическая операция на ПЖ, пациент исключался.

Для решения первой задачи мы проанализировали литературу, отобрали 185 пациентов с образованиями ПЖ, у которых были выполнены КТ-исследования с внутривенным контрастированием до проведения хирургического лечения (если оно требовалось). Два врача-рентгенолога вручную размечали артериальные и портальные фазы этих КТ-исследований, чтобы в результате получились максимально точные сегментационные маски ПЖ без включения сосудов и желчных протоков. Перед загрузкой в нейросеть все маски проверялись на

совместимость с соответствующим DICOM-файлом исследования и на наличие ошибок разметки с их корректировкой. Этап загрузки и получения результатов повторялся 3 раза, в первый раз в артериальную фазу участка, соответствующие венам, были включены в разметку, так как иногда плохо отличимы от паренхимы, во второй раз в портальную фазу на отдельных исследованиях в разметку были включены участки соответствующие другим структурам и органам, при сопоставлении с артериальной фазой разметка была скорректирована и маски загружены в третий раз. Это позволило поднять точность нейросети и сформировать алгоритм создания и разметки паренхимы ПЖ и ее образований.

Для решения второй задачи мы дали разметить паренхиму ПЖ одного пациента в артериальную и портальную фазы одного КТ-исследования 15 врачам-рентгенологам с разным опытом работы. В результате получили 30 разных сегментационных масок (15 в артериальную фазу и 15 в портальную фазу исследования), которые мы проанализировали и сравнили с эталонной маской. Все участники исследования прошли анкетирования на момент ручной разметки. В результате статистически значимых зависимостей точности разметки от внешних факторов выявлено не было, кроме опыта разметки и мужского пола. В портальную фазу исследования у мужчин и у тех, кто имеет опыт разметки сопоставимость с эталоном была выше.

Затем мы оценивали текстурные характеристики зон, которые разметило 100% врачей и зон гиперразметки, то есть выходящих за эталон.

В артериальную фазу наиболее выраженными особенностями гиперразметки были параметры glcm: ClusterShade и ClusterProminence, которые характеризовались более чем 100 раз увеличенными по значению с эталонными значениями, HighGrayLevelEmphasis, Autocorrelation, ClusterTendency, SumSquares, DifferenceVariance и Contrast, которые были выше эталонных значение более чем в 5 раз, и в меньшей степени параметры gldm: SmallDependenceHighGrayLevelEmphasis и GrayLevelVariance, которые имели абсолютные отклонения от эталона в большую сторону 28 и 6,1, соответственно, параметры firstorder: Skewness и Variance которые имели абсолютные отклонения

от эталона в большую сторону 28 и 6,6. Наиболее высокие отклонения от эталонных значений в зонах гиперразметки в венозную фазу имели параметры такие как ClusterProminence и Autocorrelation, абсолютные значения отклонений которых составили 28 и 4,45, соответственно, также в зонах гиперразметки было отмечено снижение значений параметра Minimum (firstorder) на 310% и увеличение параметра Variance (firstorder) на 293%.

В артериальную фазу для зон гипоразметки было характерно увеличение более чем в 10 раз значений параметра ClusterShade (glcm) и Skewness (firstorder), а также абсолютное отклонение в большую сторону параметра SurfaceVolumeRatio, составившее 3,77. Наиболее выраженной особенностью зон гипоразметки в венозную фазу было увеличение SurfaceVolumeRatio (shape) на 336% по сравнению с эталоном. Соответственно их можно отнести к характеристикам более специфичным для истинной структуры паренхимы ПЖ.

Для решения третьей задачи мы брали те же 185 пациентов, их КТ-исследования и сегментационные маски ПЖ. После окончательного обучения нейросети тестировали ее в сегментации органа (как первый этап для поиска в нем патологий) на тестовой выборке из 20 КТ-исследований с образованиями и без. Сравнивали предсказанные 20 сегментационных масок модели с масками врачей-рентгенологов с помощью DSC, средняя точность сегментации ПЖ в артериальную фазу исследования составила 0.8467, в портальную фазу исследования – 0.8033.

Затем дообучали нейросеть, загружая из этих же 185 исследований 90 исследований с образованиями и их маски. Тестовая выборка была из 11 человек, в ней было 5 гиповаскулярных (портальные фазы КТ-исследований) и 6 гиперваскулярных образований (артериальные фазы КТ-исследований). Средняя точность предсказанных масок образований была 0,61.

Это является достаточно хорошим результатом, учитывая, что во всех случаях маска образования была сегментирована в том же отделе органа с точностью не менее 0,41 (без ложноположительной разметки в другой области органа). Мы считаем, что при увеличении количества обучающих исследований, а

также дальнейшего модифицирования нейросети U-net можно добиться еще большей точности.

Затем 506 исследований мы использовали для обучения третьей нейросети DenseNet121 (среди них были упомянутые выше и 281 исследование из открытой базы данных) в детекции образований, то есть ответа на вопрос – есть или нет образование в органе. Каждый срез исследования был классифицирован как:

- 1 – наличие опухоли;
- 0 – отсутствие опухоли.

Всего было обработано 29252 КТ-срезы, из них 24980 с нормальной паренхимой ПЖ и 4272 с признаками образования в ней.

В тестовую выборку вошли 193 исследования.

В результате была получена высокая точность модели (**Accuracy**) = 0.9255, она отражает, что в большинстве случаев нейросеть справилась и дала верный ответ. Но Полнота указывает на достаточно высокий процент (27,78%) ложноотрицательных случаев, то есть когда модель не указала, что опухоль есть на КТ-срезе, там где она была. Это говорит нам о том, что нейросеть должен контролировать врач-рентгенолог и пересматривать КТ-исследования сам.

По итогам нашей работы поставленная цель исследования, состоящая в изучении возможности сегментации компьютерных томограмм при динамическом контрастном усилении для детекции образований ПЖ, была достигнута. Положения, вынесенные нами на защиту, подтвердились результатами выполненного исследования.

ВЫВОДЫ

1. Разработанный алгоритм создания и разметки набора данных компьютерных томограмм показал высокую эффективность и может быть рекомендован для обучения сверточных нейронных сетей с целью выполнения трехмерной сегментации и оценки ткани ПЖ, выявления патологических образований.

2. Качество разметки данных для подготовки к обучению нейронных сетей зависит от ряда факторов, основным из которых является опыт работы врача-рентгенолога. Соблюдение алгоритма сегментации позволяет снизить различие в разметке между врачами.

3. Точность внедренного автоматизированного алгоритма сегментации паренхимы поджелудочной и ее образований по данным КТ органов брюшной полости с контрастным усилением сопоставима с точностью ручной сегментации врача-рентгенолога.

4. Автоматизированный поиск патологических образований ПЖ на основе искусственной нейронной сети показал высокую эффективность: точность 92,55%, чувствительность 72,22%, специфичность 96,97%. Система КЗ может в большинстве случаев находить патологию в органе, что позволяет снизить число пропусков образований ПЖ.

ПРАКТИЧЕСКИЕ РЕКОМЕНДАЦИИ

1. Оценку исследований компьютерных томограмм с последующей разметкой образований и паренхимы ПЖ следует выполнять врачам-рентгенологам со стажем не менее 3х лет и с опытом работы в абдоминальной радиологии. При разметке ткани ПЖ по данным КТ для сохранения точности радиомических показателей при анализе структуры паренхимы железы не следует отступать от края ПЖ в артериальную фазу КТ-исследования внутрь более чем на 2 мм и наружу более чем на 1 мм, в портальную фазу – внутрь более чем 3 мм и наружу более чем на 2 мм.

2. Артериальная и венозная фазы КТ исследований являются наиболее оптимальными для оценки изменений ПЖ и соответствующей разметки. Также следует не вовлекать в разметку желчный проток и прилежащие сосуды, но зону патологии ПЖ включить в сегментационную маску паренхимы.

3. Гиповаскулярное образование ПЖ имеет наилучшую визуализацию в портальную фазу исследования, гипervasкулярное образование – в артериальную. Использование соответствующих фаз обязательно при разметке данных образований на компьютерных томограммах. Следует производить оценку DICOM-изображений и масок перед обучением нейросети врачами-специалистами.

4. Для повышения точности диагностики образований ПЖ по данным КТ следует использовать систему КЗ.

Алгоритм

Разработан алгоритм создания и разметки набора данных компьютерных томограмм для обучения сверточных нейронных сетей с целью выполнения трехмерной сегментации и оценки ткани ПЖ, выявления патологических образований:

а) рекомендуется сначала отобрать набор КТ-исследований здоровых пациентов и с образованиями ПЖ для обучения сегментировать ПЖ, затем второй

набор КТ-исследований с патологией для дообучения сегментировать образования ПЖ;

б) разметку рекомендуется перед обучением нейросети корректировать через ПО 3D Slicer;

в) в разметку паренхимы ПЖ не рекомендовано включать сосудистые структуры, прилежащие органы, но имеет смысл включать образование;

г) допустима погрешность отступа от края ПЖ в артериальную фазу КТ-исследования внутрь более чем на 2 мм и снаружи более чем на 1 мм, в портальную фазу – внутрь более чем 3 мм и снаружи более чем на 2 мм.

СПИСОК СОКРАЩЕНИЙ И УСЛОВНЫХ ОБОЗНАЧЕНИЙ

ВОЗ	Всемирная организация здравоохранения
ЗНО	злокачественные новообразования
ИИ	искусственный интеллект
КЗ	компьютерное зрение
КП	контрастный препарат
КТ	компьютерная томография
ЛПУ	лечебно-профилактическое учреждение
МРТ	магнитно-резонансная томография
МСКТ	мультиспиральная компьютерная томография
НЭН	нейроэндокринные новообразования
НЭО	нейроэндокринные опухоли
ПДР	панкреатодуоденальная резекция
ПЖ	поджелудочная железа
ПЭТ	позитронно-эмиссионная томография
РПЖ	рак поджелудочной железы
СППО	солидно-псевдопапиллярная опухоль
УЗИ	ультразвуковое исследование

СПИСОК ЛИТЕРАТУРЫ

1. Автоматическое определение плотности печени по данным компьютерной томографии и ультранизкодозной компьютерной томографии / А. П. Гончар, А. Б. Елизаров, Н. С. Кульберг [и др.] // Новости хирургии. – 2020. – Т. 28, № 6. – С. 636–647. – DOI: 10.18484/2305-0047.2020.6.636.
2. Алиев, И. И. Опухоли поджелудочной железы: диагностика и лечение (литературный обзор) / И. И. Алиев, Д. А. Ивлев, А. Ю. Бердинских // Практическая онкология. – 2020. – Т. 21, № 3. – С. 153–165. – DOI: 10.31917/2103153.
3. Амосова, Е. Л. Дифференциальная диагностика негиперваскулярных нейроэндокринных опухолей поджелудочной железы и протоковой аденокарциномы по данным МСКТ с внутривенным болюсным контрастированием / Е. Л. Амосова, Г. Г. Кармазановский // Вестник Российского научного центра рентгенорадиологии Минздрава России. – 2018. – Т. 18, № 4. – С. 148–166.
4. Быкова, Е. А. Рак поджелудочной железы, современные терапевтические подходы и возможные перспективы / Е. А. Быкова, Н. А. Фалалеева, Л. Ю. Гривцова // Российский биотерапевтический журнал. – 2020. – Т. 4, № 19. – С. 18–28. – DOI: 10.17650/1726-9784-2020-19-4-18-28.
5. Возможности применения мини-инвазивных технологий при осложнениях панкреатодуоденальной резекции / М. Ю. Кабанов, Д. М. Яковлева, К. В. Семенцов [и др.] // Анналы хирургической гепатологии. – 2021. – Т. 26, № 3. – С. 89–96. – DOI: 10.16931/1995-5464.2021-3-89-96.
6. Глубокое машинное обучение в сегментации гипо- и гиперваскулярных образований поджелудочной железы по КТ-изображениям (обзор литературы) / К. А. Замятина, Е. В. Кондратьев, А. В. Жарикова [и др.] // Диагностическая и интервенционная радиология. – 2023. – Т. 17, № S3.1. – С. 79–91. – DOI: 10.25512/DIR.2023.17.3(1).11.
7. Гуревич, Л. Е. Современные подходы к морфологической диагностике нейроэндокринных опухолей поджелудочной железы и прогнозированию их клинического течения на основе анализа собственной базы данных /

Л. Е. Гуревич, И. А. Казанцева // Альманах клинической медицины. – 2018. – Т. 46, № 4. – С. 298–313. – DOI: 10.18786/2072-0505-201846-4-298-313.

8. Злокачественные новообразования в России в 2020 году (заболеваемость и смертность) / под ред. А. Д. Каприна, В. В. Старинского, А. О. Шахзадовой. – М.: МНИОИ им. П.А. Герцена – филиал ФГБУ НМИЦ радиологии Минздрава России, 2021. – 252с.

9. Искусственный интеллект в скрининге рака легкого: оценка диагностической точности алгоритма для анализа низкодозовых компьютерных томографий / С. П. Морозов, А. В. Владзимирский, В. А. Гомболевский [и др.] // Туберкулез и болезни легких. – 2020. – Т. 98, № 8. – С. 24–31. – DOI: 10.21292/2075-1230-2020-98-8-24-31.

10. Коханенко, Н. Ю. Нейроэндокринные опухоли поджелудочной железы: этиология, патогенез, диагностика, современные аспекты лечения / Н. Ю. Коханенко, Т. Ш. Моргошия // Анналы хирургической гепатологии. – 2018. – Т. 23, № 2. – С. 100–110. – DOI: 10.16931/1995-5464.20182100-110.

11. Москва первая в стране включит анализ снимков искусственным интеллектом в тариф ОМС [Электронный ресурс] // Официальный портал Мэра и Правительства Москвы: [официальный сайт]. – 2022. – 16 дек. – Режим доступа: <https://www.mos.ru/news/item/117555073/> (дата обращения: 13.01.2026).

12. Ошибки в диагностике новообразований поджелудочной железы: интрапанкреатическая долька селезенки / А. И. Тюнибабян, И. А. Блохин, В. Ю. Чернина [и др.] // Медицинская визуализация. – 2018. – Т. 22, № 3. – С. 70–80. – DOI: 10.24835/1607-0763-2018-3-70-80.

13. Практические рекомендации по лекарственному лечению нейроэндокринных неоплазий желудочно-кишечного тракта и поджелудочной железы / Н. Ф. Орел, Е. В. Артамонова, В. А. Горбунова [и др.] // Злокачественные опухоли. – 2022. – Т. 12, № 3s2–1. – С. 562–578. – DOI: 10.18027/2224-5057-2022-12-3s2-562-578.

14. Радиомика при заболеваниях печени и поджелудочной железы. Обзор литературы / К. А. Замятина, М. В. Годзенко, Г. Г. Кармазановский, А. Ш. Ревивили

// *Анналы хирургической гепатологии*. – 2022. – Т. 27, № 1. – С. 40–47. – DOI: 10.16931/1995-5464.2022-1-40-47.

15. Современная лучевая диагностика и интеллектуальные персонализированные технологии в гепатопанкреатологии / Г. Г. Кармазановский, Е. В. Кондратьев, И. С. Груздев [и др.] // *Вестник Российской академии медицинских наук*. – 2022. – Т. 77, № 4. – С. 245–253. – DOI: 10.15690/vramn2053.

16. Факторы, влияющие на общую выживаемость при протоковой аденокарциноме головки поджелудочной железы. Опыт одного центра / Д. М. Кучин, Я. И. Колесник, Г. Г. Торгомян, В. Е. Загайнов // *Злокачественные опухоли*. – 2021. – Т. 11, № 1. – С. 20–28. – DOI: 10.18027/2224-5057-2021-11-1-20-28.

17. A Bottom-Up Approach for Pancreas Segmentation Using Cascaded Superpixels and (Deep) Image Patch Labeling / A. Farag, L. Le, H. R. Roth [et al.] // *IEEE Transactions on Image Processing*. – 2017. – Vol. 26, № 1. – P. 386–399. – DOI: 10.1109/TIP.2016.2624198.

18. A convolutional neural network for total tumor segmentation in Cu-DOTATATE PET/CT of patients with neuroendocrine neoplasms / E. A. Carlsen, K. Lindholm, A. Hindsholm [et al.] // *EJNMMI Research*. – 2022. – Vol. 12, № 1. – Art. 30. – DOI: 10.1186/s13550-022-00901-2.

19. A dual meta-learning framework based on idle data for enhancing segmentation of pancreatic cancer / J. Li, L. Qi, Q. Chen [et al.] // *Medical Image Analysis*. – 2022. – Vol. 78. – Art. 102342. – DOI: 10.1016/j.media.2021.102342.

20. A generic approach to pathological lung segmentation / A. Mansoor, U. Bagci, Z. Xu [et al.] // *IEEE Transactions on Medical Imaging*. – 2014. – Vol. 33, № 12. – P. 2293–2310. – DOI: 10.1109/TMI.2014.2337057.

21. A large annotated medical image dataset for the development and evaluation of segmentation algorithms / A. L. Simpson, M. Antonelli, S. Bakas [et al.] // *arXiv*. – 2019. – DOI: 10.48550/arXiv.1902.09063.

22. A Novel and Efficient Tumor Detection Framework for Pancreatic Cancer via CT Images / Z. Zhang, S. Li, Z. Wang, Y. A. Lu // *Annual International Conference of*

the IEEE Engineering in Medicine and Biology Society. – 2020. – Vol. 2020. – P. 1160–1164. – DOI: 10.1109/EMBC44109.2020.9176172.

23. A novel multi-atlas strategy with dense deformation field reconstruction for abdominal and thoracic multi-organ segmentation from computed tomography / B. Oliveira, S. Queirós, P. Morais [et al.] // *Medical Image Analysis*. – 2018. – Vol. 45. – P. 108–120. – DOI: 10.1016/j.media.2018.02.001.

24. A Semiautomated Deep Learning Approach for Pancreas Segmentation / M. Huang, C. Huang, J. Yuan, D. Kong // *Journal of Healthcare Engineering*. – 2021. – Vol. 2021. – Art. 3284493. – DOI: 10.1155/2021/3284493.

25. Abdominal multi-organ segmentation from CT images using conditional shape-location and unsupervised intensity priors / T. Okada, M. G. Linguraru, M. Hori [et al.] // *Medical Image Analysis*. – 2015. – Vol. 26, № 1. – P. 1–18. – DOI: 10.1016/j.media.2015.06.009.

26. Accurate and Feasible Deep Learning Based Semi-Automatic Segmentation in CT for Radiomics Analysis in Pancreatic Neuroendocrine Neoplasms / B. Huang, X. Lin, J. Shen [et al.] // *IEEE Journal of Biomedical and Health Informatics*. – 2021. – Vol. 25, № 9. – P. 3498–3506. – DOI: 10.1109/JBHI.2021.3070708.

27. Adding Delayed Phase Images to Dual-Phase Contrast-Enhanced CT Increases Sensitivity for Small Pancreatic Ductal Adenocarcinoma / Y. Fukukura, Y. Kumagae, Y. Fujisaki [et al.] // *American Journal of Roentgenology*. – 2021. – Vol. 217, № 4. – P. 888–897. – DOI: 10.2214/AJR.20.25430.

28. Alsaleh, A. M. Few-Shot Learning for Medical Image Segmentation Using 3D U-Net and Model-Agnostic Meta-Learning (MAML) / A. M. Alsaleh, E. Albalawi, A. Algozaibi // *Diagnostics (Basel)*. – 2024. – Vol. 14, № 12. – Art. 1213. – DOI: 10.3390/diagnostics14121213.

29. An application of cascaded 3D fully convolutional networks for medical image segmentation / H. R. Roth, H. Oda, X. Zhou [et al.] // *Computerized Medical Imaging and Graphics*. – 2018. – Vol. 66. – P. 90–99. – DOI: 10.1016/j.compmedimag.2018.03.001.

30. An effective computer aided diagnosis model for pancreas cancer on PET/CT images / S. Li, H. Jiang, Z. Wang [et al.] // *Computer Methods and Programs in Biomedicine*. – 2018. – Vol. 165. – P. 205–214. – DOI: 10.1016/j.cmpb.2018.09.001.

31. An Overview of Artificial Intelligence Applications in Liver and Pancreatic Imaging / N. Cardobi, A. Dal Palù, F. Pedrini [et al.] // *Cancers (Basel)*. – 2021. – Vol. 13, № 9. – Art. 2162. – DOI: 10.3390/cancers13092162.

32. An update on pancreatic cancer imaging, staging, and use of the PACT-UK radiology template pre- and post-neoadjuvant treatment / C. Corallo, A. S. Al-Adhami, N. Jamieson [et al.] // *British Journal of Radiology*. – 2025. – Vol. 98, № 1165. – P. 13–26. – DOI: 10.1093/bjr/tqae217.

33. Analysis of pancreatic segmentation algorithm based on deep learning to improve pancreatic critical region segmentation ability on dual-phase CT / X. H. Wang, H. D. Xue, T. P. Qu [et al.] // *Zhonghua Yi Xue Za Zhi*. – 2021. – Vol. 101, № 7. – P. 470–475. – DOI: 10.3760/cma.j.cn112137-20200930-02756.

34. Artificial Intelligence in Lung Cancer Screening: The Future Is Now / M. Cellina, L. M. Cacioppa, M. Cè [et al.] // *Cancers (Basel)*. – 2023. – Vol. 15, № 17. – Art. 4344. – DOI: 10.3390/cancers15174344.

35. Artificial Intelligence in Medical Imaging: Opportunities, Applications and Risks / ed. E. R. Ranschaert, S. Morozov, P. R. Algra. – Cham: Springer, 2019. – 373 p.

36. Artificial Intelligence in Pancreatic Imaging: A Systematic Review / N. Podină, E. C. Gheorghe, A. Constantin [et al.] // *United European Gastroenterology Journal*. – 2025. – Vol. 13, № 1. – P. 55–77. – DOI: 10.1002/ueg2.12723.

37. Artificial intelligence in radiology / A. Hosny, C. Parmar, J. Quackenbush [et al.] // *Nature Reviews Cancer*. – 2018. – Vol. 18, № 8. – P. 500–510. – DOI: 10.1038/s41568-018-0016-5.

38. Attention U-Net: Learning Where to Look for the Pancreas / O. Oktay, J. Schlemper, L. L. Folgoc [et al.] // *arXiv*. – 2018. – DOI: 10.48550/arXiv.1804.03999.

39. Aung, Y. Y. M. The promise of artificial intelligence: a review of the opportunities and challenges of artificial intelligence in healthcare / Y. Y. M. Aung,

D. C. S. Wong, D. S. W. Ting // *British Medical Bulletin*. – 2021. – Vol. 139, № 1. – P. 4–15. – DOI: 10.1093/bmb/ldab016.

40. Automated abdominal multi-organ segmentation with subject-specific atlas generation / R. Wolz, C. Chu, K. Misawa [et al.] // *IEEE Transactions on Medical Imaging*. – 2013. – Vol. 32, № 9. – P. 1723–1730. – DOI: 10.1109/TMI.2013.2265805.

41. Automated full body tumor segmentation in DOTATATE PET/CT for neuroendocrine cancer patients / A. Santilli, P. Panyam, A. Autz [et al.] // *International Journal of Computer Assisted Radiology and Surgery*. – 2023. – Vol. 18, № 11. – P. 2083–2090. – DOI: 10.1007/s11548-023-02968-1.

42. Automated pancreas segmentation from three-dimensional contrast-enhanced computed tomography / A. Shimizu, T. Kimoto, H. Kobatake [et al.] // *International Journal of Computer Assisted Radiology and Surgery*. – 2010. – Vol. 5, № 1. – P. 85–98. – DOI: 10.1007/s11548-009-0384-0.

43. Automated pancreatic segmentation and fat fraction evaluation based on a self-supervised transfer learning network / G. Zhang, Q. Zhan, Q. Gao [et al.] // *Computers in Biology and Medicine*. – 2024. – Vol. 170. – Art. 107989. – DOI: 10.1016/j.compbimed.2024.107989.

44. Automatic Multi-Organ Segmentation on Abdominal CT With Dense V-Networks / E. Gibson, F. Giganti, Y. Hu [et al.] // *IEEE Transactions on Medical Imaging*. – 2018. – Vol. 37, № 8. – P. 1822–1834. – DOI: 10.1109/TMI.2018.2806309.

45. Automatic Pancreas Segmentation in CT Images With Distance-Based Saliency-Aware DenseASPP Network / P. Hu, X. Li, Y. Tian [et al.] // *IEEE Journal of Biomedical and Health Informatics*. – 2021. – Vol. 25, № 5. – P. 1601–1611. – DOI: 10.1109/JBHI.2020.3023462.

46. Bounding box-based 3D AI model for user-guided volumetric segmentation of pancreatic ductal adenocarcinoma on standard-of-care CTs / S. Mukherjee, P. Korfiatis, H. Khasawneh [et al.] // *Pancreatology*. – 2023. – Vol. 23, № 5. – P. 522–529. – DOI: 10.1016/j.pan.2023.05.008.

47. Chen, M. Burnout in Radiology / M. Chen, A. Gholamrezanezhad // *Academic Radiology*. – 2023. – Vol. 30, № 6. – P. 1031–1032. – DOI: 10.1016/j.acra.2023.03.025.

48. Clinical impact of artificial intelligence-based solutions on imaging of the pancreas and liver / M. A. Berbís, F. P. Godino, J. R. Del Val [et al.] // *World Journal of Gastroenterology*. – 2023. – Vol. 29, № 9. – P. 1427–1445. – DOI: 10.3748/wjg.v29.i9.1427.

49. Combining radiomic features with a miRNA classifier may improve prediction of malignant pathology for pancreatic intraductal papillary mucinous neoplasms / J. B. Permuth, J. Choi, Y. Balarunathan [et al.] // *Oncotarget*. – 2016. – Vol. 7, № 52. – P. 85785–85797. – DOI: 10.18632/oncotarget.11768.

50. Comparing 3D, 2.5D, and 2D Approaches to Brain Image Auto-Segmentation / A. Avesta, S. Hossain, M. Lin [et al.] // *Bioengineering (Basel)*. – 2023. – Vol. 10, № 2. – Art. 181. – DOI: 10.3390/bioengineering10020181.

51. Complementary role of computed tomography texture analysis for differentiation of pancreatic ductal adenocarcinoma from pancreatic neuroendocrine tumors in the portal-venous enhancement phase / C. P. Reinert, K. Baumgartner, T. Hepp [et al.] // *Abdominal Radiology*. – 2020. – Vol. 45, № 3. – P. 750–758. – DOI: 10.1007/s00261-020-02406-9.

52. Computed Tomography-Based Radiomics Using Tumor and Vessel Features to Assess Resectability in Cancer of the Pancreatic Head / G. Litjens, J. P. E. A. Broekmans, T. Boers [et al.] // *Diagnostics*. – 2023. – Vol. 13. – Art. 3198. – DOI: 10.3390/diagnostics13203198.

53. Computer-Aided Diagnosis with Deep Learning Architecture: Applications to Breast Lesions in US Images and Pulmonary Nodules in CT Scans / J. Z. Cheng, D. Ni, Y. H. Chou [et al.] // *Scientific Reports*. – 2016. – № 6. – Art. 24454. – DOI: 10.1038/srep24454.

54. Construction of a convolutional neural network classifier developed by computed tomography images for pancreatic cancer diagnosis / H. Ma, Z. X. Liu, J. J. Zhang [et al.] // *World Journal of Gastroenterology*. – 2020. – Vol. 26, № 34. – P. 5156–5168. – DOI: 10.3748/wjg.v26.i34.5156.

55. C-reactive protein is superior to white blood cell count for early detection of complications after pancreatoduodenectomy: a retrospective multicenter cohort study /

J. C. van Dongen, F. J. Smits, H. C. van Santvoort [et al.] // *Hepato-Pancreato-Biliary (Oxford)*. – 2020. – Vol. 22, № 10. – P. 1504–1512. – DOI: 10.1016/j.hpb.2020.02.005.

56. Data from pancreas-CT (Version 2) [Электронный ресурс] / R. R. Holger, F. Amal, E. B. Turkbey [et al.] // *The cancer imaging archive: [сайт]*. – 2016. – Режим доступа: <https://www.cancerimagingarchive.net/collection/pancreas-ct/> (дата обращения: 03.03.2025).

57. Deep learning for end-to-end kidney cancer diagnosis on multi-phase abdominal computed tomography / K. H. Uhm, S. W. Jung, M. H. Choi [et al.] // *NPJ Precision Oncology*. – 2021. – Vol. 5, № 1. – Art. 54. – DOI: 10.1038/s41698-021-00195-y.

58. Deep learning to distinguish pancreatic cancer tissue from non-cancerous pancreatic tissue: a retrospective study with cross-racial external validation / K. L. Liu, T. Wu, P. T. Chen [et al.] // *Lancet Digital Health*. – 2020. – Vol. 2, № 6. – P. 303–313. – DOI: 10.1016/S2589-7500(20)30078-9.

59. Deep-learning based automated pancreas segmentation on CT scans of chronic pancreatitis patients / S. Nalliah, E. B. Mark, M. H. Liedenbaum [et al.] // *European Journal of Radiology*. – 2025. – Vol. 189. – Art. 112175. – DOI: 10.1016/j.ejrad.2025.112175.

60. Deshpande, S. S. Pancreatic Neoplasms: CT Evaluation of the Uncommon Presentations of Common Lesions and Common Presentations of the Uncommon Lesions! / S. S. Deshpande, A. R. Joshi, D. Mankar // *Indian Journal of Radiology and Imaging*. – 2022. – Vol. 32, № 4. – P. 531–539. – DOI: 10.1055/s-0042-1754359.

61. Design of experiment (DoE)-driven in vitro and in vivo uptake studies of exosomes for pancreatic cancer delivery enabled by copper-free click chemistry-based labelling / L. Xu, F. N. Faruqu, R. Liam-Or [et al.] // *Journal of Extracellular Vesicles*. – 2020. – Vol. 9, № 1. – Art. 1779458. – DOI: 10.1080/20013078.2020.1779458.

62. Development of a Hausdorff distance based 3D quantification technique to evaluate the CT imaging system impact on depiction of lesion morphology / P. Sahbaee, M. Robins, J. Solomon, E. Samei // *Proc. SPIE 9783, Medical Imaging 2016: Physics of Medical Imaging, 97835V (4 April 2016)*. – DOI: 10.1117/12.2216503.

63. Differential diagnosis of nonhypervascular pancreatic neuroendocrine neoplasms from pancreatic ductal adenocarcinomas, based on computed tomography radiological features and texture analysis / H. Yu, Z. Huang, M. Li [et al.] // *Academic Radiology*. – 2020. – Vol. 27, № 3. – P. 332–341. – DOI: 10.1016/j.acra.2019.06.012.

64. Differentiating autoimmune pancreatitis from pancreatic ductal adenocarcinoma with CT radiomics features / S. Park, S. Park, R. H. Hruban [et al.] // *Diagnostic and interventional imaging*. – 2020. – Vol. 101, № 9. – P. 555–564. – DOI: 10.1016/j.diii.2020.03.002.

65. Differentiation between non-hypervascular pancreatic neuroendocrine tumors and mass-forming pancreatitis using contrast-enhanced computed tomography / Y. Wang, X. Chen, J. Wang [et al.] // *Acta Radiologica*. – 2021. – Vol. 62, № 2. – P. 190–197. – DOI: 10.1177/0284185120921503.

66. Differentiation between pancreatic metastases from clear cell renal cell carcinoma and pancreatic neuroendocrine tumor using double-echo chemical shift imaging / H. L. Lyu, J. X. Cao, H. Y. Wang [et al.] // *Abdominal Radiology*. – 2018. – Vol. 43, № 10. – P. 2712–2720. – DOI: 10.1007/s00261-018-1539-7.

67. Differentiation of intrapancreatic accessory spleen from small hypervascular neuroendocrine tumor of the pancreas: textural analysis on contrast-enhanced computed tomography / X. Lin, L. Xu, A. Wu [et al.] // *Acta Radiologica*. – 2019. – Vol. 60, № 5. – P. 553–560. – DOI: 10.1177/0284185118788895.

68. Discrimination of pancreatic serous cystadenomas from mucinous cystadenomas with CT textural features: based on machine learning / J. Yang, X. Guo, X. Ou [et al.] // *Frontiers in Oncology*. – 2019. – Vol. 9. – Art. 494. – DOI: 10.3389/fonc.2019.00494.

69. Domain Adaptation for Medical Image Segmentation: A Meta-Learning Method / P. Zhang, J. Li, Y. Wang, J. Pan // *Journal of Imaging*. – 2021. – Vol. 7. – Art. 31. – DOI: 10.3390/jimaging7020031.

70. Establishment and application of an artificial intelligence diagnosis system for pancreatic cancer with a faster region-based convolutional neural network / S. L. Liu,

S. Li, Y. T. Guo [et al.] // Chinese Medical Journal (Engl). – 2019. – Vol. 132, № 23. – P. 2795–2803. – DOI: 10.1097/CM9.0000000000000544.

71. Focal liver lesion diagnosis with deep learning and multistage CT imaging / Y. Wei, M. Yang, M. Zhang [et al.] // Nature Communications. – 2024. – Vol. 15. – Art. 7040. – DOI: 10.1038/s41467-024-51260-6.

72. Fully automated abdominal CT biomarkers for type 2 diabetes using deep learning / H. Tallam, D. C. Elton, S. Lee [et al.] // Radiology. – 2022. – Vol. 304. – P. 85–95. – DOI: 10.1148/radiol.211914.

73. Fully Automatic Deep Learning Framework for Pancreatic Ductal Adenocarcinoma Detection on Computed Tomography / N. Alves, M. Schuurmans, G. Litjens [et al.] // Cancers (Basel). – 2022. – Vol. 14, № 2. – Art. 376. – DOI: 10.3390/cancers14020376.

74. Fully end-to-end deep-learning-based diagnosis of pancreatic tumors / K. Si, Y. Xue, X. Yu [et al.] // Theranostics. – 2021. – Vol. 11, № 4. – P. 1982–1990. – DOI: 10.7150/thno.52508.

75. Gastroenteropancreatic neuroendocrine neoplasms: ESMO Clinical Practice Guidelines for diagnosis, treatment and follow-up / M. Pavel, K. Öberg, M. Falconi [et al.] // Annals of Oncology. – 2020. – Vol. 31, № 7. – P. 844–860. – DOI: 10.1016/j.annonc.2020.03.304.

76. GLOBOCAN 2022: estimates cancer incidence, mortality and prevalence worldwide in 2022 [Электронный ресурс] // GLOBOCAN: [сайт]. – 2023. – Режим доступа: <http://globocan.iarc.fr> (дата обращения: 20.12.2025).

77. Hierarchical combinatorial deep learning architecture for pancreas segmentation of medical computed tomography cancer images / M. Fu, W. Wu, X. Hong [et al.] // BMC Systems Biology. – 2018. – Vol. 12, № S4. – Art. 56. – DOI: 10.1186/s12918-018-0572-z.

78. Hyper-Pairing Network for Multi-phase Pancreatic Ductal Adenocarcinoma Segmentation / Y. Zhou, Y. Li, Z. Zhang [et al.] // Medical Image Computing and Computer Assisted Intervention – MICCAI 2019: 22nd International Conference

(Shenzhen, China, 13–17 October 2019). – Shenzhen, 2019. – P. 155–163. – DOI: 10.48550/arXiv.1909.00906.

79. Hypervascular pancreatic “lesions”: a pattern-based approach to differentiation / P. R. Shankar, A. P. Wasnik, M. M. Al-Hawary [et al.] // *Abdominal Radiology*. – 2018. – Vol. 43, № 4. – P. 1013–1028. – DOI: 10.1007/s00261-017-1363-5.

80. Iglovikov, V. TerausNet: U-Net with VGG11 Encoder Pre-trained on ImageNet for Image Segmentation / V. Iglovikov, A. Shvets // arXiv:1801.05746. – 2018. – DOI: 10.48550/arXiv.1801.05746.

81. Interactive 3D U-net for the segmentation of the pancreas in computed tomography scans / T. G. W. Boers, Y. Hu, E. Gibson [et al.] // *Physics in Medicine and Biology*. – 2020. – Vol. 65, № 6. – Art. 065002. – DOI: 10.1088/1361-6560/ab6f99.

82. Intrapancreatic accessory spleen mimicking pancreatic NET: can unnecessary surgery be avoided? / E. Vandekerckhove, E. Ameloot, A. Hoorens [et al.] // *Acta Clinica Belgica*. – 2021. – Vol. 76, № 6. – P. 492–495. – DOI: 10.1080/17843286.2020.1762351.

83. Intrapancreatic accessory spleen: An imaging enigma / S. P. Yadav, S. D. Kotak, S. Kumar [et al.] // *Indian Journal of Radiology and Imaging*. – 2020. – Vol. 30, № 3. – P. 392–394. – DOI: 10.4103/ijri.IJRI_407_20.

84. Kumar, H. Automated pancreas segmentation from computed tomography and magnetic resonance images: A systematic review / H. Kumar, S. V. DeSouza, M. S. Petrov // *Computer Methods and Programs in Biomedicine*. – 2019. – Vol. 178. – P. 319–328. – DOI: 10.1016/j.cmpb.2019.07.002.

85. Kurnaz, E. Pancreas Segmentation in Abdominal CT Images with U-Net Model / E. Kurnaz, R. Ceylan // 28th Signal Processing and Communications Applications Conference (Gaziantep, Turkey, 5–7 October 2020). – Gaziantep, 2020. – P. 955–958. – DOI: 10.1109/SIU49456.2020.9302180.

86. Learning Inductive Attention Guidance for Partially Supervised Pancreatic Ductal Adenocarcinoma Prediction / Y. Wang, P. Tang, Y. Zhou [et al.] // *IEEE Transactions on Medical Imaging*. – 2021. – Vol. 40, № 10. – P. 2723–2735. – DOI: 10.1109/TMI.2021.3060066.

87. Main challenges on the curation of large scale datasets for pancreas segmentation using deep learning in multi-phase CT scans: Focus on cardinality, manual refinement, and annotation quality / M. Cavicchioli, A. Moglia, L. Pierelli [et al.] // *Computerized Medical Imaging and Graphics*. – 2024. – Vol. 117. – Art. 102434. – DOI: 10.1016/j.compmedimag.2024.102434.

88. Meta-information-Aware Dual-path Transformer for Differential Diagnosis of Multi-type Pancreatic Lesions in Multi-phase CT / B. Zhou, Y. Xia, J. Yao [et al.] // *Information Processing in Medical Imaging: 28th International Conference (San Carlos de Bariloche, Argentina, 18–23 June 2023)*. – Springer Cham, 2023. – P. 119–131. – DOI: 10.1007/978-3-031-34048-2_10.

89. Model-based pancreas segmentation in portal venous phase contrast-enhanced CT images / M. Hammon, A. Cavallaro, M. Erdt [et al.] // *Journal of Digital Imaging*. – 2013. – Vol. 26, № 6. – P. 1082–1090. – DOI: 10.1007/s10278-013-9586-7.

90. MRI-based radiomics approach for differentiation of hypovascular nonfunctional pancreatic neuroendocrine tumors and solid pseudopapillary neoplasms of the pancreas / T. Song, Q. W. Zhang, S. F. Duan [et al.] // *BMC Medical Imaging*. – 2021. – Vol. 21, № 1. – Art. 36. – DOI: 10.1186/s12880-021-00563-x.

91. Multi-organ segmentation based on spatially-divided probabilistic atlas from 3D abdominal CT images / C. Chu, M. Oda, T. Kitasaka [et al.] // *Medical Image Computing and Computer-Assisted Intervention*. – 2013. – Vol. 16, Pt. 2. – P. 165–172. – DOI: 10.1007/978-3-642-40763-5_21.

92. Neuroendocrine and adrenal tumors, version 2.2021, NCCN clinical practice guidelines in oncology / M. H. Shah, W. S. Goldner, A. B. Benson [et al.] // *Journal of the National Comprehensive Cancer Network*. – 2021. – Vol. 19, № 7. – P. 839–868. – DOI: 10.6004/jnccn.2021.0032.

93. nnU-Net-based pancreas segmentation and volume measurement on CT imaging in patients with pancreatic cancer / E. Yang, J. H. Kim, J. H. Min [et al.] // *Academic Radiology*. – 2024. – Vol. 31. – P. 2784–2794. – DOI: 10.1016/j.acra.2024.01.004.

94. Ohmoto, A. Pancreatic neuroendocrine neoplasms: basic biology, current treatment strategies and prospects for the future / A. Ohmoto, H. Rokutan, S. Yachida // *International Journal of Molecular Sciences*. – 2017. – Vol. 18, № 1. – Art. 143. – DOI: 10.3390/ijms18010143.

95. Pachetti, E. A systematic review of few-shot learning in medical imaging / E. Pachetti, S. Colantonio // *Artificial intelligence in medicine*. – 2024. – Vol. 156. – Art. 102949. – DOI: 10.1016/j.artmed.2024.102949.

96. Pancreas segmentation in CT and MRI images via domain specific network designing and recurrent neural contextual learning / J. Cai, L. Lu, F. Xing, L. Yang // *arXiv*. – 2018. – DOI: 10.48550/arXiv.1803.11303.

97. Pancreas segmentation using AI developed on the largest CT dataset with multi-institutional validation and implications for early cancer detection / S. Mukherjee, A. Antony, N. G. Patnam [et al.] // *Scientific Reports*. – 2025. – Vol. 15, № 1. – Art. 17096. – DOI: 10.1038/s41598-025-01802-9.

98. Pancreatic Adenocarcinoma: Imaging Modalities and the Role of Artificial Intelligence in Analyzing CT and MRI Images / C. Anghel, M. C. Grasu, D. A. Anghel [et al.] // *Diagnostics (Basel)*. – 2024. – Vol. 14, № 4. – Art. 438. – DOI: 10.3390/diagnostics14040438.

99. Pancreatic cancer: ESMO Clinical Practice Guideline for diagnosis, treatment and follow-up / T. Conroy, P. Pfeiffer, V. Vilgrain [et al.] // *Annals of Oncology*. – 2023. – Vol. 34, № 11. – P. 987–1002. – DOI: 10.1016/j.annonc.2023.08.009.

100. Pancreatic Ductal Adenocarcinoma: Epidemiology and Risk Factors / J. Ushio, A. Kanno, E. Ikeda [et al.] // *Diagnostics (Basel)*. – 2021. – Vol. 11, № 3. – Art. 562. – DOI: 10.3390/diagnostics11030562.

101. Pancreatic neuroendocrine tumours: spectrum of imaging findings / E. Biccì, D. Cozzi, R. Ferrari [et al.] // *Gland Surgery*. – 2020. – Vol. 9, № 6. – P. 2215–2224. – DOI: 10.21037/gs-20-537.

102. Quality gaps in public pancreas imaging datasets: Implications & challenges for AI applications / G. Suman, A. Patra, P. Korfiatis [et al.] //

Pancreatology. – 2021. – Vol. 21, № 5. – P. 1001–1008. – DOI: 10.1016/j.pan.2021.03.016.

103. Radiology data from the clinical proteomic tumor analysis consortium pancreatic ductal adenocarcinoma collection [Электронный ресурс] / National Cancer Institute Clinical Proteomic Tumor Analysis Consortium // The cancer imaging archive: [сайт]. – 2018. – Режим доступа: <https://www.cancerimagingarchive.net/collection/crtac-pda/> (дата обращения: 03.03.2025).

104. Radiomics analysis based on diffusion kurtosis imaging and T2 weighted imaging for differentiation of pancreatic neuroendocrine tumors from solid pseudopapillary tumors / Y. J. Shi, H. T. Zhu, Y. L. Liu [et al.] // *Frontiers in Oncology*. – 2020. – Vol. 10. – Art. 1624. – DOI: 10.3389/fonc.2020.01624.

105. Radiomics machine learning algorithm facilitates detection of small pancreatic neuroendocrine tumors on CT / F. Lopez-Ramirez, S. Soleimani, J. R. Azadi [et al.] // *Diagnostic and Interventional Radiology*. – 2025. – Vol. 106, № 1. – P. 28–40. – DOI: 10.1016/j.diii.2024.08.003.

106. Radiomics-Based Machine-Learning Models Can Detect Pancreatic Cancer on Prediagnostic Computed Tomography Scans at a Substantial Lead Time before Clinical Diagnosis / S. Mukherjee, A. Patra, H. Khasawneh [et al.] // *Gastroenterology*. – 2022. – Vol. 163, № 5. – P. 1435–1446. – DOI: 10.1053/j.gastro.2022.06.066.

107. Recent epidemiology of patients with gastro-entero-pancreatic neuroendocrine neoplasms (GEP-NEN) in Japan: a population-based study / T. Masui, T. Ito, I. Komoto, S. Uemoto // *BMC Cancer*. – 2020. – Vol. 20, № 1. – Art. 1104. – DOI: 10.1186/s12885-020-07581-y.

108. Ren, J. Few-shot Medical Image Segmentation: Meta-learning and Consistency Learning / J. Ren, Q. Zhang // *Medical Image Analysis*. – 2021. – Vol. 73. – Art. 102194. – DOI: 10.1016/j.media.2021.102194.

109. Reproducibility of CT radiomic features within the same patient: influence of radiation dose and CT reconstruction settings / M. Meyer, J. Ronald, F. Vernuccio [et al.] // *Radiology*. – 2019. – Vol. 293, № 3. – P. 583–591. – DOI: 10.1148/radiol.2019190928.

110. Segmentation of pancreatic ductal adenocarcinoma (PDAC) and surrounding vessels in CT images using deep convolutional neural networks and texture descriptors / T. Mahmoudi, Z. M. Kouzahkanan, A. R. Radmard [et al.] // *Scientific Reports*. – 2022. – Vol. 12, № 1. – Art. 3092. – DOI: 10.1038/s41598-022-07111-9.

111. Sharzehi, K. AGA Clinical Practice Update on Management of Subepithelial Lesions Encountered During Routine Endoscopy: Expert Review / K. Sharzehi, A. Sethi, T. Savides // *Clinical Gastroenterology and Hepatology*. – 2022. – Vol. 20, № 11. – P. 2435–2443. – DOI: 10.1016/j.cgh.2022.05.054.

112. Siegel, R.L. Cancer statistics, 2018 / R. L. Siegel, K. D. Miller, A. Jemal // *CA: A Cancer Journal for Clinicians*. – 2018. – Vol. 68, № 1. – P. 7–30. – DOI: 10.3322/caac.21442.

113. Supervoxel-based segmentation of mitochondria in em image stacks with learned shape features // A. Lucchi, K. Smith, R. Achanta [et al.] // *IEEE Transactions on Medical Imaging*. – 2012. – Vol. 31, № 2. – P. 474–486. – DOI: 10.1109/TMI.2011.2171705.

114. Taha, A. A. Metrics for evaluating 3D medical image segmentation: analysis, selection, and tool / A. A. Taha, A. Hanbury // *BMC Medical Imaging*. – 2015. – Vol. 15. – Art. 29. – DOI: 10.1186/s12880-015-0068-x.

115. Technical and Clinical Factors Affecting Success Rate of a Deep Learning Method for Pancreas Segmentation on CT / M. H. Bagheri, H. Roth, W. Kovacs [et al.] // *Academic Radiology*. – 2020. – Vol. 27, № 5. – P. 689–695. – DOI: 10.1016/j.acra.2019.08.014.

116. Test–retest reproducibility analysis of lung CT image features / Y. Balagurunathan, V. Kumar, Y. Gu [et al.] // *Journal of Digital Imaging*. – 2014. – Vol. 27, № 6. – P. 805–823. – DOI: 10.1007/s10278-014-9716-x.

117. The FELIX Project: Deep Networks To Detect Pancreatic Neoplasms / Y. Xia, Q. Yu, L. Chu [et al.] // *medRxiv*. – 2022. – DOI: 10.1101/2022.09.24.22280071.

118. The impact of segmentation variability on texture analysis of the pancreas / I. Gruzdev, K. Zamyatina, A. Ustalov [et al.] // *European Congress of Radiology*. – 2025. – DOI: 10.26044/ecr2025/C-28431.

119. The Medical Segmentation Decathlon / M. Antonelli, A. Reinke, S. Bakas [et al.] // Nature Communications. – 2022. – Vol. 13, № 1. – Art. 4128. – DOI: 10.1038/s41467-022-30695-9.

120. Towards a Single Unified Model for Effective Detection, Segmentation, and Diagnosis of Eight Major Cancers Using a Large Collection of CT Scans / J. Chen, Y. Xia, J. Yao [et al.] // arXiv. – 2023. – DOI: 10.48550/arXiv.2301.12291.

121. Tumor heterogeneity of pancreas head cancer assessed by CT texture analysis: association with survival outcomes after curative resection / G. Yun, Y. H. Kim, Y. J. Lee [et al.] // Scientific Reports. – 2018. – Vol. 8, № 1. – Art. 7226. – DOI: 10.1038/s41598-018-25627-x.

122. UNet++: A Nested U-Net Architecture for Medical Image Segmentation / Z. Zhou, M. M. R. Siddiquee, N. Tajbakhsh, J. Liang // Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support. – 2020. – P. 3–11. – DOI: 10.1007/978-3-030-00889-5_1.

123. Unveiling COVID-19 from Chest X-Ray with deep learning: a hurdles approach by instructor-forced meta learning / E. Tartaglione, C. A. Barbano, G. Di Leo, M. Grimaldi // IEEE Journal of Biomedical and Health Informatics. – 2020. – Vol. 24, № 10. – P. 2718–2730. – DOI: 10.1109/JBHI.2020.3006376.

124. Usefulness of texture analysis for grading pancreatic neuroendocrine tumors on contrast-enhanced computed tomography and apparent diffusion coefficient maps / K. Ohki, T. Igarashi, H. Ashida [et al.] // Japanese Journal of Radiology. – 2021. – Vol. 39, № 1. – P. 66–75. – DOI: 10.1007/s11604-020-01038-9.

125. Variable generalization performance of a deep learning model to detect pneumonia in chest radiographs: A cross-sectional study / J. R. Zech, M. A. Badgeley, M. Liu [et al.] // PLOS Medicine. – 2018. – Vol. 15, № 11. – Art. e1002683. – DOI: 10.1371/journal.pmed.1002683.

126. Wen, S. Multi-class transformer-based segmentation of pancreatic ductal adenocarcinoma and surrounding structures in CT imaging: a multi-center evaluation / S. Wen, X. Xiao // Abdominal Radiology (NY). – 2025. – DOI: 10.1007/s00261-025-05061-0.

127. Xuan, W. Detection and diagnosis of pancreatic tumor using deep learningbased hierarchical convolutional neural network on the internet of medical things platform / W. Xuan, G. You // *Future Generation Computer Systems*. – 2020. – Vol. 111, № 22. – P. 132–142. – DOI: 10.1016/j.future.2020.04.037.

128. Zhang, Z. Dynamic Linear Transformer for 3D Biomedical Image Segmentation / Z. Zhang, U. Bagci // *Machine Learning Sharpens Medical Imaging*. – 2022. – Vol. 13583. – P. 171–180. – DOI: 10.1007/978-3-031-21014-3_18.

129. Zins, M. Pancreatic Adenocarcinoma Staging in the Era of Preoperative Chemotherapy and Radiation Therapy / M. Zins, C. Matos, C. Cassinotto // *Radiology*. – 2018. – Vol. 287, № 2. – P. 374–390. – DOI: 10.1148/radiol.2018171670.

ПРИЛОЖЕНИЕ А

(обязательное)

Абсолютные отклонения от значений эталона масштабированные на его абсолютные значения и направления отклонений

Таблица А.1 – Абсолютные отклонения от значений эталона масштабированные на его абсолютные значения и направления отклонений

Feature Class	FeatureName	Артериальная фаза		Венозная фаза	
		Гипоразметка	Гиперразметка	Гипоразметка	Гиперразметка
1	2	3	4	5	6
glcm	ClusterShade	▲ 11.1	▲ 424	▲ 0.25	▲ 0.25
glcm	ClusterProminence	▲ 1.52	▲ 185	▲ 0.71	▲ 28
gldm	SmallDependenceHighGrayLevelEmphasis	▲ 1.35	▲ 28	–	–
firstorder	Skewness	▲ 10.6	▲ 28	▲ 0.51	▲ 1.12
gldm	HighGrayLevelEmphasis	▼ 0.06	▲ 7.4	–	–
glcm	Autocorrelation	▼ 0.08	▲ 7.4	▼ 0.09	▲ 4.45
firstorder	Variance	▲ 0.21	▲ 6.6	▲ 0.38	▲ 2.93
glcm	ClusterTendency	▲ 0.12	▲ 6.2	▲ 0.41	▲ 2.9
gldm	GrayLevelVariance	▲ 0.19	▲ 6.1	–	–
glcm	SumSquares	▲ 0.22	▲ 6.1	▲ 0.44	▲ 2.7
glcm	DifferenceVariance	▲ 0.75	▲ 5.5	▲ 0.47	▲ 1.53
glcm	Contrast	▲ 0.85	▲ 5.2	▲ 0.57	▲ 1.38
shape	SurfaceVolumeRatio	▲ 3.77	▲ 2.16	▲ 3.36	▲ 0.67
firstorder	Minimum	0	▼ 3.12	0	▼ 3.10
gldm	LargeDependenceHighGrayLevelEmphasis	▼ 0.61	▲ 2.41	–	–
gldm	SmallDependenceEmphasis	▲ 1.39	▲ 1.98	–	–

Продолжение таблицы А.1

1	2	3		4		5		6	
glcm	SumAverage	▼	0.04	▲	1.9	▼	0.05	▲	1.34
glcm	JointAverage	▼	0.04	▲	1.9	▼	0.05	▲	1.34
firstorder	10Percentile	▼	0.21	▼	1.87	▼	0.28	▼	1.32
shape	SurfaceArea	▲	0.86	▲	1.57	▲	0.91	▲	1.08
firstorder	Range		0	▲	1.28		0	▲	1.44
gldm	SmallDependenceLowGrayLevelEmphasis	▲	1.44	▼	0.69	–	–	–	–
glcm	DifferenceAverage	▲	0.44	▲	1.36	▲	0.32	▲	0.46
firstorder	MeanAbsoluteDeviation	▲	0.02	▲	1.25	▲	0.21	▲	1.05
firstorder	InterquartileRange	▼	0.11	▲	0.78	▲	0.3	▲	1.24
firstorder	RobustMeanAbsoluteDeviation	▼	0.05	▲	0.9	▲	0.26	▲	1.19
firstorder	Kurtosis	▲	0.61	▲	1.12	▼	0.13	▲	0.79
firstorder	Maximum	–	0	▲	0.69	–	0	▲	1.09
gldm	LargeDependenceLowGrayLevelEmphasis	▼	0.5	▼	0.95	–	–	–	–
gldm	LowGrayLevelEmphasis	▲	0.08	▼	0.88	–	–	–	–
shape	Sphericity	▼	0.71	▼	0.66	▼	0.7	▼	0.44
firstorder	TotalEnergy	▼	0.68	▼	0.18	▼	0.62	▲	0.14
firstorder	Energy	▼	0.68	▼	0.18	▼	0.62	▲	0.14
glcm	DifferenceEntropy	▲	0.24	▲	0.62	▲	0.18	▲	0.26
gldm	GrayLevelNonUniformity	▼	0.62	▼	0.54	–	–	–	–
shape	VoxelVolume	▼	0.61	▼	0.19	▼	0.56	▲	0.24
shape	MeshVolume	▼	0.61	▼	0.19	▼	0.56	▲	0.24
glcm	JointEnergy	▼	0.19	▼	0.59	▼	0.39	▼	0.53
gldm	LargeDependenceEmphasis	▼	0.56	▼	0.58	–	–	–	–
shape	Maximum2DDiameterSlice	–	0	▲	0.57	–	0	▲	0.25
glcm	JointEntropy	▲	0.13	▲	0.54	▲	0.17	▲	0.34
gldm	DependenceNonUniformity	▼	0.51	▲	0.03	–	–	–	–
firstorder	Entropy	▲	0.05	▲	0.49	▲	0.13	▲	0.39
firstorder	Mean	▼	0.11	▼	0.49	▼	0.10	▼	0.22
firstorder	Uniformity	▼	0.01	▼	0.42	▼	0.20	▼	0.46

Окончание таблицы А.1

1	2	3		4		5		6	
firstorder	Median	▼	0.1	▼	0.43	▼	0.09	▼	0.13
shape	LeastAxisLength	▲	0.2	▲	0.39	▲	0.15	▲	0.25
glcm	SumEntropy	▲	0.05	▲	0.39	▲	0.12	▲	0.3
glcm	Imc1	▲	0.39	▲	0.18	▲	0.12	▼	0.21
glcm	MaximumProbability	▲	0.08	▼	0.2	▼	0.39	▼	0.39
shape	Flatness	▲	0.17	▲	0.38	▲	0.17	▲	0.34
gldm	DependenceVariance	▼	0.35	▼	0.27	–	–	–	–
shape	Maximum2DDiameterRow	–	0	▲	0.32	–	0	▲	0.25
shape	Maximum2DDiameterColumn	–	0	▲	0.11	–	0	▲	0.30
gldm	DependenceNonUniformityNormalized	▲	0.26	▲	0.27	–	–	–	–
shape	Maximum3DDiameter	–	0	▲	0.26	–	0	▲	0.14
shape	Elongation	▲	0.03	▲	0.16	▲	0.12	▲	0.22
glcm	Idm	▼	0.09	▼	0.20	▼	0.08	▼	0.09
firstorder	90Percentile	▼	0.05	▼	0.19	▼	0.01	▲	0.02
glcm	Correlation	▼	0.19	▲	0.05	▼	0.03	▲	0.13
glcm	MCC	▼	0.18	▲	0.02	▼	0.03	▲	0.14
shape	MinorAxisLength	▲	0.06	▲	0.17	▲	0.1	▲	0.14
glcm	Id	▼	0.08	▼	0.17	▼	0.07	▼	0.08
glcm	InverseVariance	▲	0.17	▲	0.17	▲	0.07	▲	0.04
glcm	Imc2	▼	0.13	▲	0.04	▼	0	▲	0.12
gldm	DependenceEntropy	▼	0.01	▲	0.12	–	–	–	–
firstorder	RootMeanSquared	▼	0.09	▲	0.01	▼	0.07	▼	0.04
shape	MajorAxisLength	▲	0.03	▲	0.01	▼	0.02	▼	0.07
glcm	Idn	▼	0.01	▼	0	▼	0.01	▲	0.01
glcm	Idmn	▼	0	▼	0	▼	0	▲	0