

**МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ
РОССИЙСКОЙ ФЕДЕРАЦИИ**

Федеральное государственное автономное образовательное
учреждение высшего образования

ЮЖНЫЙ ФЕДЕРАЛЬНЫЙ УНИВЕРСИТЕТ

На правах рукописи



Михайличенко Алексей Андреевич

**Методы и алгоритмы автоматизированной
диагностики остеоартрита по
рентгенографическим изображениям**

Специальность 2.3.5 —
«Математическое и программное обеспечение вычислительных
систем, комплексов и компьютерных сетей»

Автореферат
диссертации на соискание учёной степени
кандидата технических наук

Ростов-на-Дону — 2023

Работа выполнена в Федеральном автономном образовательном учреждении высшего образования «Южный Федеральный университет» (ЮФУ) на кафедре прикладной математики и программирования (ПМП) Института математики, механики и компьютерных наук им. И.И. Воровича (ИММиКН).

Научный руководитель: кандидат технических наук, доцент
Демяненко Яна Михайловна

Официальные оппоненты: **Ковалёв Сергей Михайлович**,
доктор технических наук, профессор,
Ростовский филиал АО «Научно-исследовательский и проектно-конструкторский институт информатизации, автоматизации и связи на железнодорожном транспорте», г. Ростов-на-Дону,
директор Центра интеллектуальных и инновационных технологий

Дрюченко Михаил Анатольевич,
кандидат технических наук, доцент,
ФГБОУ ВО «Воронежский государственный университет», г. Воронеж,
доцент кафедры технологий обработки и защиты информации

Защита состоится «1» декабря 2023 г. в 14:00 на заседании диссертационного совета ЮФУ 801.02.06 Федерального государственного автономного образовательного учреждения высшего образования «Южный федеральный университет» по адресу: г. Таганрог, ул. Чехова, 2, корп. «И», комн. 347.

С диссертацией можно ознакомиться в Зональной научной библиотеке Южного федерального университета по адресу: г. Ростов-на-Дону, ул. Зорге, 21ж, и на сайте ФГБОУ ВО «Южный федеральный университет» по адресу: <https://hub.sfedu.ru/storage/1/1319040/e806f3b7-06b2-4297-b25a-d9921e05f2f3/>.

Автореферат разослан «___» _____ 2023 года.

Ученый секретарь
диссертационного совета
кандидат технических наук,
доцент



А.П. Кухаренко

Общая характеристика работы

Актуальность темы исследования. Цифровая обработка изображений и компьютерное зрение сегодня являются важными разделами прикладной математики и информатики. Методы и алгоритмы цифровой обработки изображений находят широкое применение в самых разнообразных областях: в системах контроля качества, робототехнике, системах автономного вождения, медицинской диагностике и других.

Обработка медицинских изображений, получаемых при помощи компьютерной и магнитно-резонансной томографии, рентгенографии и ультразвуковых исследований является одним из самых популярных современных направлений исследований в области цифровой обработки изображений.

В настоящее время в России для медицинской диагностики широко используются рентгенографические изображения, при этом практически вся обработка проводится вручную. Это требует высокой квалификации специалистов, а в случае массового потока изображений приводит к сильной загруженности рентгенологических кабинетов, что в свою очередь повышает вероятность ошибок диагностики из-за человеческого фактора. Использование методов автоматизированной диагностики позволяет избавиться от фактора субъективности и сократить количество изображений, требующих внимания специалиста.

Существующие методы обработки изображений для компьютерной диагностики остеоартрита (ОА) можно разделить на две группы.

Методы из первой группы обычно основаны на использовании комбинации классических алгоритмов обработки и анализа изображений (размытие, анализ текстурных характеристик, выделение контуров и др.), и позволяют получить некоторые количественные оценки рассматриваемых критериев (расстояние между объектами, углы, особенности расположения ключевых точек и т.п.). Подобные методы активно развивались научной школой В.С. Пилиди, а также подробно описаны в работах Х. Ока (H. Oka), Ш. Мураки (S. Muraki) и Т. Акунэ (T. Akune).

Вторая группа методов опирается на алгоритмы машинного обучения. Данные методы более универсальны и в меньшей степени зависят от качества исходных данных, источника этих данных и прочих варьирующихся характеристик, что представляет отдельную проблему для методов первой группы. В современном виде для решения задачи автоматической диагностики ОА они были предложены в работах Д. Энтони (J. Antony) и К. МакГиннеса (K. McGuinness), а затем получили развитие в исследованиях А. Тюльпина.

К недостаткам методов автоматизированной диагностики, опирающихся на классические алгоритмы обработки изображений, можно отнести некорректные результаты их работы в случае плохого качества данных и при нестандартной форме объектов, которая возникает из-за различных заболеваний. Классические методы машинного обучения, из-за своей специфики, обладают высокими требованиями к вычислительным ресурсам, что ограничивает их применение в медицинских учреждениях с недостаточно мощным оборудованием.

Поэтому, **актуальной** задачей является создание новых методов и алгоритмов обработки цифровых медицинских рентгенографических изображений для автоматизированной диагностики заболеваний, обладающих высокой точностью работы и способных работать в условиях ограниченных вычислительных ресурсов.

Объектом исследования являются системы автоматизированной диагностики остеоартрита по рентгенографическим изображениям.

Предметом исследования являются методы и алгоритмы компьютерного зрения, цифровой обработки изображений и глубокого обучения для автоматизированной диагностики остеоартрита.

Целью диссертации является повышение точности автоматизированной диагностики остеоартрита по цифровым рентгенограммам.

Общая научная задача: разработка методов и алгоритмов повышения точности автоматизированной диагностики остеоартрита по цифровым рентгенограммам без использования априорной информации о форме объектов в условиях ограниченных вычислительных ресурсов.

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

1. Провести анализ существующих методов обработки изображений для автоматизированной диагностики остеоартрита и алгоритмов выделения контуров объектов на медицинских рентгенограммах. Исследовать применимость известных архитектур сверточных нейронных сетей для решения задач автоматической локализации сустава и диагностики ОА на медицинских рентгенограммах, а также провести вычислительные эксперименты по оценке их эффективности.
2. Разработать метод автоматической локализации сустава на рентгенограмме, который обладает повышенной точностью в условиях ограниченных вычислительных ресурсов.

3. Разработать метод повышения точности автоматической диагностики остеоартрита сверточными нейронными сетями по цифровым медицинским изображениям.
4. Разработать новый алгоритм детектирования контуров костей на медицинских рентгенограммах, не требующий априорной информации о форме объектов.
5. Разработать программное обеспечение для реализации предложенных методов и алгоритмов, и провести анализ их эффективности.

Методология и методы исследования. В исследовании использовались методы теории вероятностей и компьютерного зрения, методы оптимизации, теория распознавания образов, машинное и глубокое обучение, статистические методы оценки результатов экспериментов и другие.

Научная новизна. При решении поставленных задач в рамках исследовательской работы были получены следующие **новые научные результаты**:

1. предложен метод локализации коленного сустава на рентгенограмме, **отличающийся** от существующих методов применением нейросетевой архитектуры Single Shot Detector (SSD) в сочетании с разделимыми по глубине свертками, что позволило существенно снизить требования к вычислительным ресурсам и повысить точность локализации;
2. разработан метод повышения точности автоматической диагностики остеоартрита нейросетями, **отличающийся** от существующих методов использованием комплекса архитектурных решений (интеграция блоков сжатия и возбуждения, использование ансамблей, модификация шкалы оценки), что позволило повысить точность и стабильность работы;
3. разработан **новый** алгоритм выделения контуров костей на медицинских рентгенографических изображениях, **отличающийся** от существующих тем, что не использует информацию об априорной форме объекта, что позволяет работать с сильно искаженными объектами и нестандартными конфигурациями;
4. предложены **новый** алгоритм отслеживания контуров, использующий градиент изображения, что позволило повысить устойчивость к артефактам, и **новая** энергия для метода активных контуров, учитывающая направление градиента при изменении положения точек, что позволяет более аккуратно проводить уточнение контура.

Основные положения, выносимые на защиту:

1. разработанный метод локализации сустава на базе нейросетевой архитектуры Single Shot Detector (SSD) позволяет в условиях ограниченных вычислительных ресурсов ускорить обработку и повысить точность классификации остеоартрита;
2. разработанный метод повышения точности автоматической классификации остеоартрита, использующий комплекс архитектурных решений (интеграция блоков сжатия и возбуждения в структуру нейросети, использование ансамблей, модификация шкалы оценки), позволяет сократить количество рентгенограмм, требующих внимания специалиста;
3. разработанный алгоритм выделения контуров костей на рентгенограмме, не использующий априорную информацию о форме объекта, может работать с сильно искаженными объектами и позволяет повысить точность необходимых для диагностики измерений.

Теоретическая значимость. Результаты, полученные в диссертации, являются важными для развития методов автоматизированной диагностики остеоартрита по рентгенографическим изображениям.

Автором **показано**, что разработанный метод повышения точности автоматической классификации ОА, использующий предложенный комплекс архитектурных решений, может быть использован для улучшения качества алгоритмов классификации ОА, основанных на использовании сверточных нейронных сетей.

Автором **показано**, что разработанный алгоритм детектирования контуров, использующий новый метод отслеживания контуров и предложенную энергию для активных контуров, не требует априорной информации о форме объектов и может быть использован для работы с сильно искаженными объектами.

Практическая значимость. Разработанные методы, алгоритмы и их программная реализация могут быть использованы для анализа цифровых рентгенографических изображений как в интерактивном, так и в автоматическом режимах в условиях большой загруженности, показывая высокую точность диагностики и существенно уменьшая количество рентгенограмм, требующих внимания специалиста.

1. Предложенный метод локализации сустава на базе SSD может работать в условиях ограниченных вычислительных ресурсов и на тестовой выборке из датасета OAI для коэффициента перекрытия

искомого и найденного прямоугольников не менее 0,75 показал точность 94,1%, что на 1,9% превышает точность метода, основанного на использовании модели YOLOv2, на 4,9% — точность метода на базе полностью сверточных нейронных сетей и более чем в 11 раз превышает точность методов, основанных на сопоставлении с шаблоном.

2. Реализованный метод повышения точности классификации на основе комбинации архитектурных решений позволил существенно повысить точность классификации остеоартрита сверточными нейронными сетями: изменение шкалы оценки позволило повысить точность от 9,86% до 14,39% при сохранении информативности диагностики, интеграция блоков сжатия и возбуждения дала прирост до 3,85%, а использование ансамблей позволило повысить точность на более чем 2,4%. Финальная точность классификации составила 72,28% для случая 5 классов для ансамбля из трех SE-ResNeXt-50, 84,66% для 4 классов для ансамбля из трех SE-DenseNet-121 и 87,5% для бинарной классификации для ансамбля из трех SE-Xception, что превосходит существующие методы классификации для всех рассматриваемых случаев.
3. Разработанный алгоритм выделения контуров корректно выделил контуры для 84,96% объектов, и еще для 5,08% результат признан пригодным к использованию после небольшой корректировки спорных участков экспертом. Результаты работы алгоритма могут быть использованы для автоматизации измерений, необходимых для получения количественных оценок ОА: измерения сужения межсуставной щели, определения «параллельности» кромки сустава и др.
4. Созданный на базе предложенных методов программный комплекс может быть использован как для проведения стандартных медицинских измерений, так и для выполнения автоматической диагностики остеоартрита путем классификации по разным шкалам оценки (в том числе в режиме пакетной обработки) с целью обнаружения болезни на ранних стадиях. Использование автоматических методов анализа позволяет облегчить работу эксперта, устранить фактор субъективности и компенсировать недостаток опыта при принятии решения.

Помимо классификации, предложенные модели сверточных нейронных сетей могут быть использованы для получения распределения вероятностей

классов ОА и акцентирования внимания специалиста на определенных областях рентгенограммы [8].

Достоверность полученных результатов обеспечивается проведением серий экспериментов для каждой модели нейронной сети на разных наборах данных. В каждом из экспериментов исследуемые модели обучались с разным начальным значением генератора случайных чисел и на разных комбинациях подмножеств тренировочной и валидационной выборок, что позволяет обучать разные сети, не меняя при этом их структуры. Устойчивость результатов классификации обеспечивается усреднением результатов работы нескольких моделей. Кроме того, результаты находятся в соответствии с результатами, полученными другими авторами в данной области исследований.

Реализация и внедрение результатов работы. Результаты диссертации были внедрены в рабочие процессы ООО «Наука», акт от 2 декабря 2022, утвержден заместителем генерального директора ООО «Наука». Разработанное в ходе написания диссертации программное обеспечение было адаптировано под решение специальных задач и использовано при проведении медицинских исследований.

Также, полученные результаты исследования были внедрены при выполнении ряда работ в ООО «Изоскан», акт от 5 октября 2022 года, утвержден техническим директором ООО «Изоскан». Результаты диссертации были использованы при реализации программного комплекса, решающего задачу автоматической классификации объектов по графическим данным. Внедрение результатов исследования позволило реализовать эффективный алгоритм классификации, точность работы которого превышает 90%.

Кроме того, результаты диссертационного исследования были внедрены в учебном процессе кафедры прикладной математики и программирования (ПМП) Института математики, механики и компьютерных наук (ИММиКН) Южного федерального университета (ЮФУ), акт от 19 сентября 2022 года, утвержден директором ИММиКН. Материалы диссертации использовались в лекционном курсе по дисциплине «Компьютерное зрение», лекционном курсе по дисциплине «Машинное обучение» и лекционном курсе по дисциплине «Нейронные сети для мобильных приложений» для подготовки магистров направления подготовки 02.04.02 «Фундаментальная информатика и информационные технологии».

Апробация работы. Основные результаты работы докладывались и обсуждались на следующих конференциях:

- Первая международная научная конференция «Осенние математические чтения в Адыгее», г. Майкоп, 2015 [11].

- XXIII международная конференция «Математика. Компьютеры. Образование», г. Дубна, 2015.
- The 5th International Conference on Image Analysis, Social Networks and Texts (AIST 2016), г. Екатеринбург, 2016 [5].
- 26-я Международная конференция по компьютерной графике и обработке изображений (ГрафиКон 2016), г. Нижний Новгород, 2016 [10].
- Всероссийская конференция «Современные информационные технологии: тенденции и перспективы развития», г. Ростов-на-Дону, 2016.
- 27-я Международная конференция по компьютерной графике и обработке изображений (ГрафиКон 2017), г. Пермь, 2017.
- XXVII научная конференция «Современные информационные технологии: тенденции и перспективы развития» (СИТО 2020), г. Ростов-на-Дону, 2020 [9].
- The 9th International Conference on Image Analysis, Social Networks and Texts (AIST), г. Москва, 2020 [3].
- XXVIII научная конференция «Современные информационные технологии: тенденции и перспективы развития» (СИТО 2021), г. Ростов-на-Дону, 2021 [8].
- XXIX научная конференция «Современные информационные технологии: тенденции и перспективы развития» (СИТО 2022), г. Ростов-на-Дону, 2022 [7].
- 30-я международная конференция «Математика. Компьютер. Образование» (МКО 2023), г. Дубна, 2023.

Соответствие паспорту специальности. Содержание диссертации соответствует пункту 7 («Модели, методы, архитектуры, алгоритмы, форматы, протоколы и программные средства человеко-машинных интерфейсов, компьютерной графики, визуализации, обработки изображений и видеоданных, систем виртуальной реальности, многомодального взаимодействия в социобиберфизических системах») в части «методы и алгоритмы обработки изображений», а также пункту 4 («Интеллектуальные системы машинного обучения, управления базами данных и знаний, инструментальные средства разработки цифровых продуктов») в части «интеллектуальные системы машинного обучения» паспорта научной специальности 2.3.5 — «Математическое и программное обеспечение вычислительных систем, комплексов и компьютерных сетей».

Личный вклад. Автор самостоятельно провел теоретические изыскания и осуществил практическую реализация всех описанных в диссертации

алгоритмов и методов. Были проведены все необходимые эксперименты и выполнен анализ полученных результатов. По результатам работы разработан программный комплекс, пригодный для использования в медицинской практике.

Публикации. Основные результаты по теме работы изложены в 10 печатных изданиях, 1 из которых изданы в журналах, рекомендованных ВАК, 4 — в научных журналах и изданиях, индексируемых Scopus, 5 — в сборниках трудов конференций и тезисах докладов. Зарегистрирована 1 программа для ЭВМ.

Объем и структура работы. Диссертация состоит из введения, четырех глав и заключения. Полный объем диссертации составляет 222 страницы, включая 79 рисунков и 58 таблиц. Список литературы содержит 148 наименования.

Краткое содержание работы

Во **введении** приводится обоснование актуальности исследований, проводимых в рамках данной диссертационной работы, формулируется цель, ставятся задачи работы, излагается научная новизна и практическая значимость представленной работы. Кроме того, приводятся основные положения, которые выносятся на защиту.

В **первой главе** обсуждаются существующие архитектуры сверточных нейронных сетей и проводится анализ применимости той или иной архитектуры к решению задачи классификации остеоартрита в условиях ограниченного размера датасетов для обучения и тестирования. Для каждой из архитектур приводится подробное описание ее структуры и важные архитектурные особенности, отличающие ее от остальных архитектур.

Приведен обзор наборов данных, которые прямо или косвенно использовались в рамках данного исследования. В частности, к таким наборам данных можно отнести датасеты для обучения классификаторов стадии остеоартрита по рентгенограмме, а также датасеты, на которых были предобучены некоторые используемые в работе модели. Приводится подробное описание датасета **OAI** (the Osteoarthritis Initiative) — одного из основных датасетов для исследований в области диагностики остеоартрита.

В конце главы приводится описание существующих методов локализации области коленного сустава на рентгенограмме, методов автоматической классификации остеоартрита и алгоритмов детектирования контуров. Для каждого метода указаны результаты и описаны его слабые и сильные стороны.

Также описаны используемые методы оценки качества классификаторов [1; 7] и методы оценки качества локализации объектов на изображении в целом и коленного сустава на рентгенограмме в частности.

Вторая глава посвящена задаче автоматической локализации области коленного сустава на рентгенографическом изображении. Предлагается новый метод [9], основанный на использовании сверточной нейронной сети с архитектурой Single Shot Detector (SSD). Данная архитектура возвращает фиксированный набор ограничивающих прямоугольников и оценку вероятности наличия в них искомого объекта, и состоит из трех основных уровней (рис. 1).

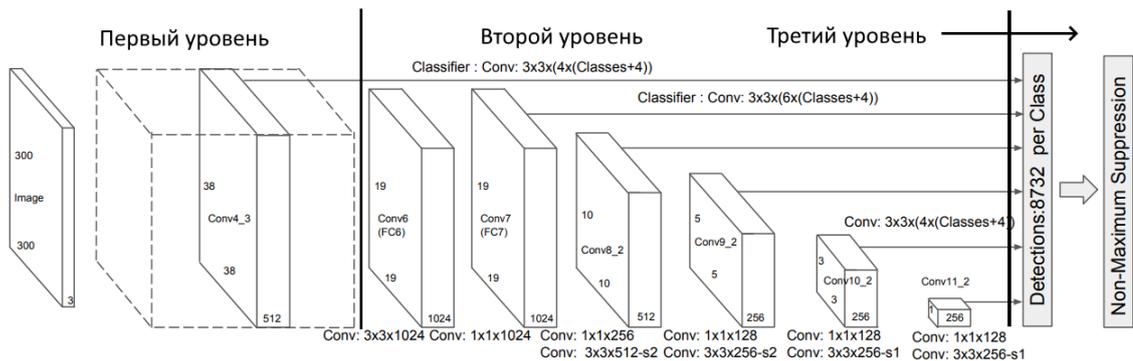


Рисунок 1 — Трехуровневая схема архитектуры SSD, последний уровень — полносвязный слой и подавление немаксимумов

Первый уровень сети состоит из предобученной модели какой-либо стандартной архитектуры (например, VGG или ResNet) и отвечает за извлечение низкоуровневых признаков из входного изображения. Для этого используются лишь несколько первых слоев выбранной модели. В работе для этих целей была использована сеть с архитектурой MobileNet, предварительно обученная на датасете COCO (Common Objects in Context) от Microsoft. Данная архитектура специально разрабатывалась для использования на мобильных устройствах в условиях ограниченных вычислительных ресурсов и памяти, и позволяет достигать точности, сравнимой с очень глубокими сетями, обладая при этом на порядок меньшим количеством весов.

Достичь производительности в таких условиях архитектуре MobileNet позволило использование разделимых по глубине сверток вместо традиционных сверточных слоев. Суть подобных сверток состоит в том, чтобы разделить обычную свертку, осуществляющую одновременно и пространственную, и межканальную фильтрацию для каждого пикселя, на два этапа — свертку каждого слоя отдельным одноканальным пространственным фильтром и межканальную свертку фильтрами 1×1 . Например, для сверточного фильтра

размером 3×3 с 32 входными и 64 выходными каналами этот подход позволяет более чем в 7 раз сократить количество параметров сверточного слоя.

Второй уровень SSD состоит из четырех блоков свертки, каждый из которых понижает пространственную размерность входных данных, что позволяет искать объекты различного масштаба. Это возможно благодаря тому, что выход каждого из таких блоков затем используется для локализации. Каждый блок состоит из пары сверточных слоев, первый из которых сначала понижает канальную размерность данных, а второй эту размерность снова повышает, но при этом уменьшает размерность пространственную.

Третий уровень предназначен для вычисления фиксированного множества предсказаний координат центров прямоугольников, вероятности наличия объекта того или иного класса и т.п. при помощи сверточных слоев для выхода каждого из блоков второго уровня и — опционально — выхода некоторых слоев из первого уровня SSD.

Каждой ячейке карты признаков соответствует набор ограничивающих прямоугольников с одинаковым и фиксированным положением и различным масштабом и соотношением сторон (рис. 2). На выходе детектора каждый такой прямоугольник представлен набором (cx, cy, w, h, p) , где (cx, cy) — координаты смещения центра прямоугольника относительно базового положения, (w, h) — модификатор для базового размера прямоугольника, а p — вероятность наличия в прямоугольнике объекта соответствующего класса.

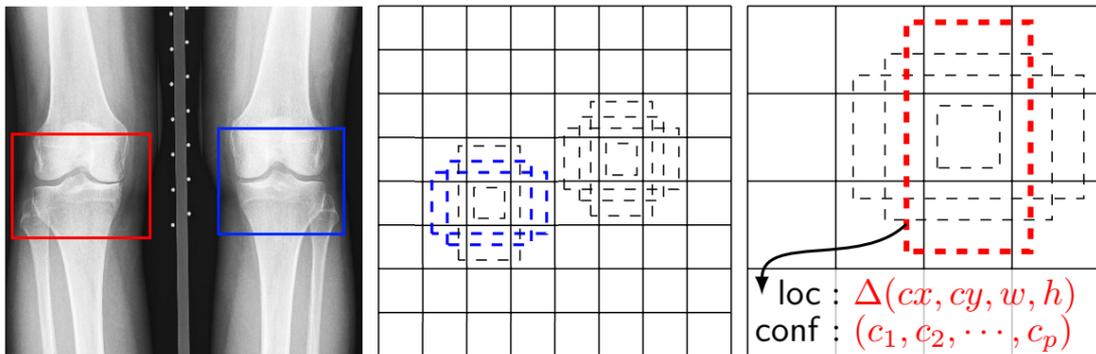


Рисунок 2 — Иллюстрация выбора положений для исследования наличия объектов на карте признаков. Слева — искомые ограничивающие прямоугольники, в середине — разбиение карты признаков сеткой 8×8 , справа — разбиение сеткой 4×4 и параметры искомого прямоугольника

В рамках исследования проводится реализация и обучение SSD на датасете, содержащем рентгенограммы коленей, и выполняется сравнение результатов работы обученной сети на тестовой выборке с методами из

ранее опубликованных работ при помощи коэффициента Жаккара (пересечение над объединением между искомым и найденным прямоугольниками). В таблице 1 представлены результаты оценки локализации для поиска по шаблону (template matching), линейный метод опорных векторов на базе предобработанного оператором Собеля изображения (Linear SVM + Sobel), полностью сверточная нейронная сеть (FCN) и еще один существующий детектор на базе сверточных сетей YOLOv2. Полученная точность превосходит точность существующих методов и составляет **94,1%** для коэффициента Жаккара, равного 0,75, и **100%** для меньших значений коэффициента (табл. 1).

Таблица 1 — Сравнение методов автоматического детектирования, основанное на коэффициенте Жаккарда (J)

Данные	$J \geq 0.25$	$J \geq 0.5$	$J \geq 0.75$
Template Matching	~54,4%	8,3%	-
Linear SVM + Sobel	~81,8%	38,6%	-
FCN	100%	99,9%	89,2%
YOLOv2	-	-	92,2%
SSD, наш метод	100%	100%	94,1%

В третьей главе описывается предложенный метод повышения точности автоматической классификации остеоартрита сверточными нейронными сетями при помощи комплекса архитектурных решений (использование функции потерь специального вида, модификация шкалы оценки ОА, интеграция блоков сжатия и возбуждения, использование ансамблей).

Сначала выполняется оценка точности классификации ОА при помощи классических архитектур сверточных нейронных сетей, таких как ResNet, Inception, Inception-ResNet, DenseNet [3] и других. В качестве базовой шкалы для классификации используется шкала Келлгрена-Лоуренса, состоящая из 5 классов (KL-5). Для получения более точных и стабильных результатов, для каждой модели выполняется обучение нескольких моделей на основе разных комбинаций данных внутри тренировочной и валидационной выборки путем задания разного начального значения для генератора случайных чисел. Рассматривались два вида основных функций потерь, используемых при обучении — перекрестная энтропия (cross-entropy loss) и порядковая функция потерь (ordinal loss), учитывающая «расстояние» между классами для штрафа ошибочных результатов классификации.

В медицинской практике, из-за слабых различий, стадии 0 и 1 часто диагностируют как отсутствие остеоартрита, поэтому в работе дополнительно рассмотрена *сокращенная* шкала Келлгрена-Лоуренса, которая содержит в

себе четыре класса вместо пяти, и представляет собой аналог полной шкалы оценки с объединенными первыми двумя классами (KL-4). Кроме того, рассматривается бинарная классификация (KL-2) с целью определить, есть на рентгенограмме признаки остеоартрита, или нет.

Для каждой из рассматриваемых архитектур проверяется гипотеза о возможности повышения точности ее работы на задаче классификации остеоартрита путем добавления *блоков сжатия и возбуждения*, или SE-блоков [2]. В теории, данные блоки позволяют усилить обобщающую способность нейронной сети или ее части путем явного моделирования зависимости между различными слоями сверточного блока. Достигается это путем рекалибровки выходных данных сверточного блока, т.е. каждому слою ставится в соответствие его вес (рис. 3). SE-блоки обучаются использовать глобальную информацию для акцентирования внимания сети на информативных признаках, в то же время подавляя признаки неинформативные.

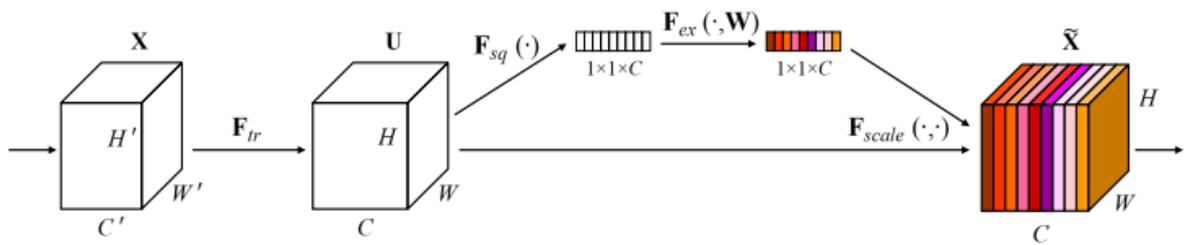


Рисунок 3 — Иллюстрация основных операций блока сжатия и возбуждения

Для этого сначала для карты признаков выполняется операция сжатия F_{sq} , которая позволяет получить дескрипторы каждого канала путем агрегирования содержимого каждого слоя в одно число при помощи операции глобального усредняющего пуллинга. Затем для полученного таким образом вектора дескрипторов выполняется процедура адаптивной рекалибровки, или *возбуждения* (F_{ex}). Этот механизм состоит из простейшей двухслойной нейронной сети, первый слой которой сначала понижает размерность входного вектора дескрипторов, а второй слой эту размерность восстанавливает до исходной, что добавляет нелинейность и позволяет гибко управлять сложностью и обобщающей способностью всего SE-блока. Выходной вектор коэффициентов используется для рекалибровки входящей карты признаков (F_{scale}).

Всего в работе рассмотрено 16 различных архитектур (10 оригинальных и 6 разновидностей архитектуры ResNet и SE-ResNet различной глубины), а для каждого случая при этом было проведено три независимых эксперимента. В общей сумме было получено 240 различных моделей сверточных сетей:

48 для бинарной классификации и по 96 моделей для полной и сокращенной шкал Келлгрена-Лоуренса для каждой из рассматриваемых функций потерь. В таблице 2 представлены результаты обучения для основных архитектур из этого списка.

Таблица 2 — Среднеклассовые метрики качества работы различных классификаторов для разных функций потерь для основных архитектур, усредненные по трем экспериментам

Архитектура	Cross-Entropy Loss			Ordinal Loss	
	Бинарн.	4 класса	5 классов	4 класса	5 классов
ResNet-50	85,00	80,35	66,43	80,39	66,20
ResNeXt-50	84,60	80,48	67,33	78,78	66,34
Inception3	85,57	82,47	69,93	80,09	69,08
Inception-ResnetV2	86,23	80,76	70,43	81,32	67,39
Xception	85,61	81,50	69,24	80,94	69,18
DenseNet-121	84,76	80,86	66,73	80,56	66,69
SE-Inception3	85,99	81,30	69,59	81,86	68,18
SE-ResNet-50	85,18	80,29	67,47	80,37	66,65
SE-ResNeXt-50	86,33	81,04	71,18	81,54	69,83
SE-Xception	86,59	81,46	69,14	81,32	68,84
SE-DenseNet-121	86,27	82,51	69,99	82,21	69,22

Наилучшая точность классификации в экспериментах с *полной* шкалой Келлгрена-Лоуренса была получена для архитектур SE-ResNeXt-50 и Inception-ResnetV2, и составила **71,18%** и **70,43%** соответственно. Также достаточно высокий (по сравнению с другими архитектурами) результат был получен для сетей SE-DenseNet-121 и Inception3 с точностью на тестовой выборке, равной 69,99% и 69,93%.

В эксперименте с *сокращенной* шкалой Келлгрена-Лоуренса наилучшие результаты были показаны сверточными сетями с архитектурами Inception3 (**82,47%**) и SE-DenseNet-121 (**82,51%**). Добавление блоков сжатия и возбуждения к архитектуре DenseNet позволило повысить точность работы более чем на 2%. Результат, превышающий средний результат по качеству работы, также показан архитектурами SE-ResNeXt-50 и Inception-ResNet с точностью **81,54%** и **81,32%**.

Наилучшая усредненная по трем экспериментам точность классификации для *бинарной* классификации была получена при помощи архитектур SE-Xception и SE-ResNeXt-50 после добавления к ним блоков сжатия и возбуждения, и составила **86,59%** и **86,33%** соответственно. Сопоставимую

точность в 86,27% и 86,23% можно наблюдать у моделей SE-DenseNet-121 и Inception-ResNet. Модели, показавшие наилучшие результаты, и используются в разработанном программном обеспечении для автоматической диагностики остеоартрита.

На рис. 4 в виде диаграммы показано влияние изменения способов оценки остеоартрита путем сокращения шкалы Келлгрена-Лоуренса на финальную точность классификации. Видно, что объединение нулевого и первого классов в один (отсутствие остеоартрита) позволило более чем на 10% повысить эффективность работы исследуемых классификаторов, а переход к бинарной классификации повышает точность почти на 20%. Это подтверждает гипотезу о неоднозначности шкалы Келлгрена-Лоуренса, которая неоднократно озвучивалась в предыдущих исследованиях.

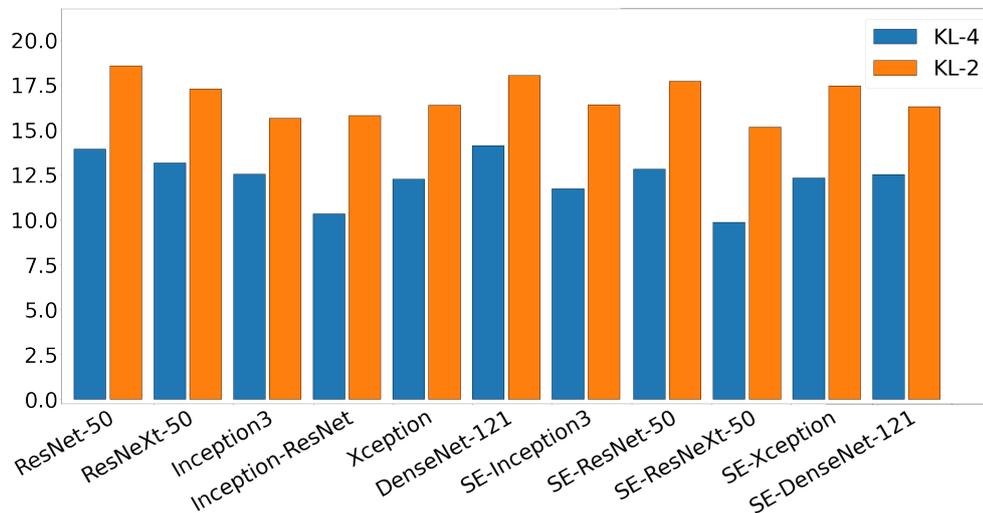


Рисунок 4 — Изменение точности классификации ОА коленного сустава при помощи известных архитектур сверточных нейронных сетей при сокращении шкалы Келлгрена-Лоуренса до четырехклассовой (KL-4) и двухклассовой (KL-2)

Во второй части главы проводится анализ возможности улучшения точности полученных ранее моделей путем объединения нескольких классификаторов в ансамбли [3]. В данной работе использовалось объединение при помощи невзвешенного среднего трех моделей, обученных на одном и том же датасете, но с разными начальными значениями для генератора случайных чисел. Это позволило тренировать одну и ту же модель на разных комбинациях исходных данных. При этом, для каждого случая использовались модели, показавшие наилучший результат на валидационной выборке.

На рис. 5 представлена диаграмма, показывающая улучшение точности работы описанных в работе классификаторов на базе сверточных нейронных сетей при использовании ансамбля вместо одиночных моделей. В качестве функции потерь для всех моделей, упомянутых на диаграмме, была использована перекрестная энтропия (как показавшая наилучшие результаты).

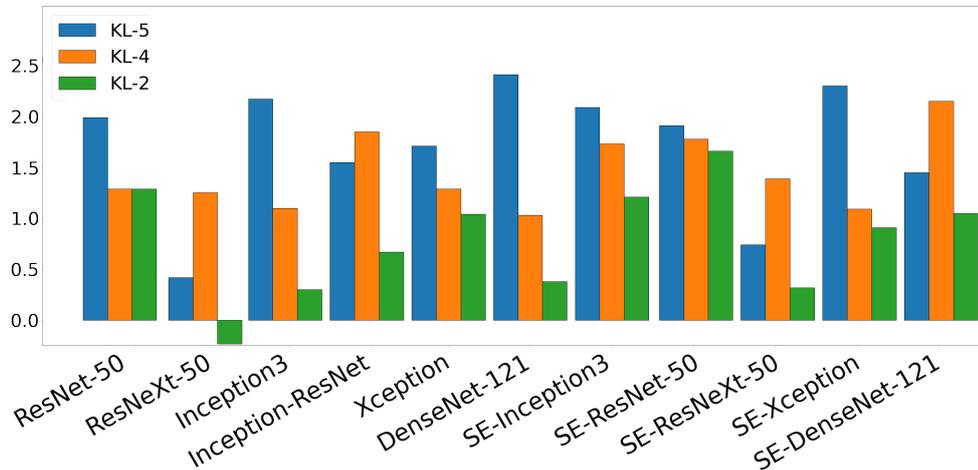


Рисунок 5 — Улучшение точности классификации для различных архитектур при использовании ансамблей для разных шкал оценки

В большинстве случаев при использовании ансамблей удалось повысить точность более чем на 1%. Наибольшее повышение при этом зафиксировано для случая полной шкалы Келлгрена-Лоуренса, и составило 2,41% для архитектуры DenseNet-121, а наименьшее — для бинарной классификации (0,91% для архитектуры SE-Xception).

Таким образом можно сделать вывод, что методы, использующие ансамбли моделей, являются мощным инструментом, позволяющим получить более качественные результаты по сравнению с использованием отдельных классификаторов. Достигается это за счет того, что методы усредняют ошибки каждого базового классификатора и уменьшают влияние случайностей. Также, использование нескольких моделей позволяет уменьшить дисперсию, поскольку несколько разных моделей, исходящих из разных гипотез, имеют больше шансов прийти к правильному результату, чем одна отдельно взятая.

В таблице 3 представлена сводная информация о качестве работы классификации остеоартрита коленного сустава по всем упомянутым шкалам оценки для основных существующих методов, в сравнении с полученными в диссертации результатами. В таблице указаны методы, работающие с набором данных ОАИ.

Таблица 3 — Эффективность основных известных методов классификации остеоартрита

Метод	KL-5	KL-4	KL-2
WND-CHARM	38%	-	-
Сверточная нейронная сеть.	64,6%	-	-
DenseNet + данные о весе, возрасте	-	77,2%	-
VGG-16 + Attention + GAP	64,3%	-	-
VGG-19 + Ordinal Loss	67,7%	-	-
Сиамская CNN	66,71%	-	-
Усреднение двух ResNet	66,68%	-	-
SE-ResNeXt-50 + град. бустинг	70,0%	-	-
VGG-16 + U-Net + случ. лес	64,48%	-	-
3 × SE-ResNeXt-50 (наш метод)	72,28%	82,43%	86,71%
3 × SE-DenseNet-121 (наш метод)	71,44%	84,66%	87,32%
3 × SE-Xception (наш метод)	71,44%	82,55%	87,50%

В качестве отправной точки выбран метод WND-CHARM, основанный на применении модифицированного метода ближайших соседей, который является универсальным методом классификации, разработанным специально для задач в области медицины. Сверточная нейронная сеть принимает на вход изображение и сама занимается извлечением необходимых для классификации признаков.

Также в таблице перечислены различные модификации известных архитектур или предложенные специфические архитектурные решения, такие как дополнительное использование известных данных о пациенте (вес, возраст и др.), использование глобального усредняющего пуллинга (GAP) для уменьшения объемов информации, специальная функция потерь (Ordinal Loss), адаптированная специально для классификации по шкале Келлгрена-Лоуренса, использование вместо одной сверточной сети двух моделей, каждая из которых обрабатывает свою половину рентгенограммы (сиамская сверточная сеть), а также комбинация глубокого обучения с такими методами машинного обучения, как случайный лес или градиентный бустинг.

В открытом доступе отсутствуют прямые исследования, направленные на сравнение результатов работы автоматических алгоритмов и результатов диагностики специалистом-человеком. Однако, в литературе встречается средняя численная оценка эффективности диагностики ОА по шкале Келлгрена-Лоуренса (т.е. для случая 5 классов ОА) несколькими экспертами на датасете MOST при помощи коэффициента *взвешенная каппа Коэна*, которая равна **0,748**. Данную численную оценку эффективности диагностики можно

сравнивать со значением подобного коэффициента для ансамбля из 3-х моделей SE-ResNeXt-50, где его значение составляет **0,849**. Таким образом можно сделать вывод, что эффективность диагностики остеоартрита предложенным в диссертации алгоритмом на 10,1% превосходит эффективность диагностики человеком на схожем по структуре и количеству примеров наборе данных.

В четвертой главе приводится описание нового метода выделения контуров костей коленного сустава на рентгенограмме, который использует в своей работе комбинацию различных алгоритмов обработки изображений [4; 5; 10; 11], таких как размытие, пороговое разделения, вычисление краев, метод активных контуров и др. Кроме того, предлагаются новые алгоритмы для этапов отслеживания и уточнения контуров, позволяющие повысить точность основного метода.

Первым этапом решения задачи обработки изображений является предварительная обработка входных данных при помощи сглаживающего фильтра для избавления от разного рода шумов (рис. 6, а). Традиционно для этого используется фильтр Гаусса, однако в работе предлагается использовать билатеральную фильтрацию, которая, в отличие от фильтра Гаусса, сохраняет границы, что особенно важно в данном случае. Это достигается за счет специально подобранных коэффициентов при вычислении взвешенного среднего пикселя, которые помимо расстояния между пикселями учитывают разность интенсивностей между этими пикселями.



а)

б)

в)

г)

Рисунок 6 — Иллюстрация к этапам предложенного метода выделения контуров: результат размытия исходного изображения билатеральным фильтром (а), выделение границ (б), бинаризация изображения (в) и результат устранения разрывов на бинарном изображении (г)

Следующий этап — вычисление краев на изображении. Для этого используется комбинация фильтра Собеля и векторного поля потока градиента (GVF) в виде их поэлементного перемножения (рис. 6, б). К полученному изображению (G_1) применяется операция утончения краев (подавления немаксимумов) с использованием карты направлений градиента, которая получается при вычислении GVF. Аналогичная операция подавления немаксимумов используется на одном из этапов детектора границ Кэнни. Далее полученное изображение будет обозначено как G_2 .

В работе описан алгоритм поиска порога для бинаризации G_2 . На базе изображения G_1 вычисляется верхнее значение диапазона для поиска порога бинаризации для G_2 :

$$\bar{T} = \frac{\sum_{y=1}^N \sum_{x=1}^M G_1(x, y) \cdot \hat{G}(x, y)}{\sum_{y=1}^N \sum_{x=1}^M \hat{G}(x, y)},$$

где \hat{G} — градиент изображения G_1 , а M, N — размерности изображения. Полученный интервал $(0, \bar{T}]$ используется для получения некоторого набора потенциальных значений порога бинаризации. В простейшем случае это обычное равномерное разбиение интервала с некоторым шагом, величина которого зависит от задачи исследователя и доступных вычислительных ресурсов. Затем для каждого из порогов выполняется бинаризация (рис. 6, в), проводится нормализация изображения (приведения его к виду, пригодному для выделения контуров), поиск контуров и оценка качества этих контуров, критерии которой также были предложены в ходе исследования. На основе данной оценки выбирается финальный порог бинаризации и финальный набор контуров костей (рис. 6, г). Опишем более подробно процесс нормализации бинарного изображения и оценки качества выделения контуров.

Для того, чтобы на бинарной версии G_2 можно было выделить контуры костей, необходимо устранить разрывы в границах, которые появляются из-за особенностей содержимого изображений, неверно подобранных порогов предыдущих этапов и др. Для этого в работе предложен *алгоритм устранения разрывов*, который позволяет объединить фрагменты границы объектов в замкнутые области. Предварительно выполняется классификация пикселей, которые по определенным критериям относятся к точкам разрыва границы.

На базе полученного набора выполняется итерационный алгоритм поиска соответствующих пар точек разрыва и выполняется процесс связывания

фрагментов границы при помощи модифицированного алгоритма поиска пути A^* , который опирается на градиент исходного изображения, направление градиента в пикселях и другую доступную информацию. Если полученный с помощью A^* набор точек не пересекает существующую границу объектов на изображении, то разрыв считается устраненным и происходит переход к следующей потенциальной паре точек (рис. 7).

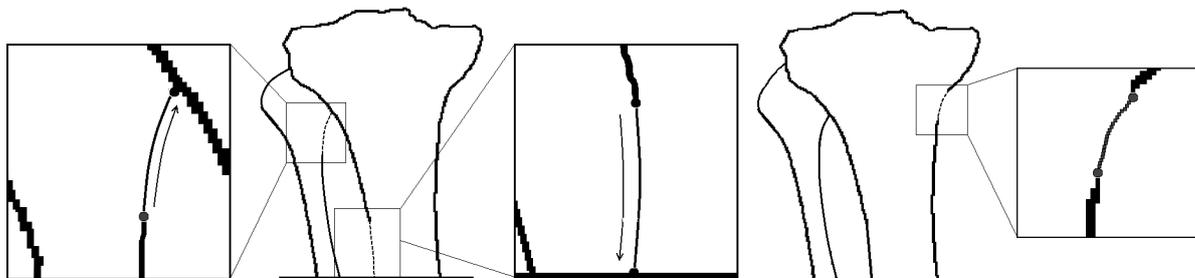


Рисунок 7 — Иллюстрация к устранению разрывов

Для отслеживания контуров в замкнутой области разработан алгоритм, использующий в своей работе градиент изображения. Сначала специальным образом формируется упорядоченный набор ключевых точек контура объекта. Затем точки последовательно соединяются между собой при помощи алгоритма A^* , используя в качестве дополнительных эвристик отмасштабированный градиент и бинарное представление изображения, при этом проходимой считается только область границы (рис. 8, а).

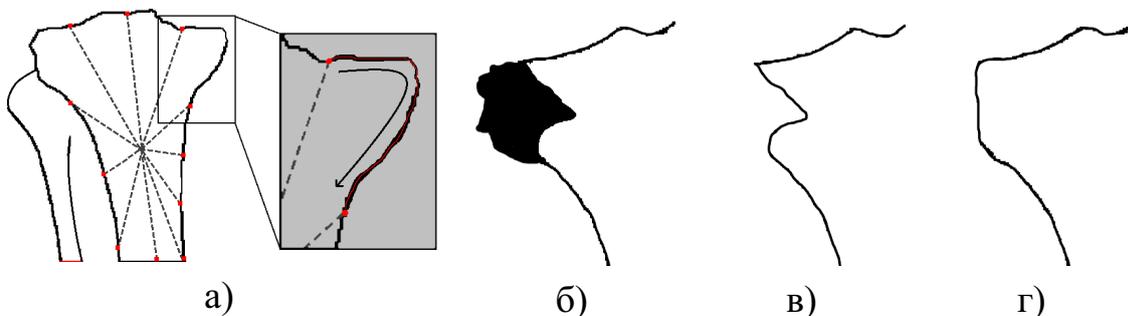


Рисунок 8 — Схема предложенного метода отслеживания контуров (а) и иллюстрация работы на участке с неоднозначной трактовкой границы: пример проблемного участка бинарного изображения (б), фрагмент контура, найденный одним из стандартных алгоритмов отслеживания — «алгоритмом жука» (в) и фрагмент контура, найденный предложенным методом (г)

В такой конфигурации расстояние между оказывает на формирование пути гораздо меньше влияния, и путь более точно описывает участок контура объекта между двумя последовательными ключевыми точками. Данный

подход позволяет корректно обрабатывать участки бинарного изображения, которые лишь приблизительно указывают границу объекта. Стандартные методы, не учитывающие значения градиента изображения и работающие только с бинарной его версией, не способны правильно обработать подобные проблемные участки (рис. 8, б-г).

Для коррекции формы применяется модифицированный метод активных контуров, который помимо стандартного набора энергий учитывает направление градиента в точках, что позволяет проводить уточнение более аккуратно.

Тестирование метода осуществлялось на наборе из 266 тестовых изображений (содержащих 532 объекта интереса), часть из которых была взята из датасета ОАИ, а часть предоставлена Ростовским государственным медицинским университетом. В итоге, **84,96%** контуров были выделены корректно, результат для 5,08% был признан удовлетворительным и пригодным для использования в интерактивном режиме работы. На оставшихся 9,96% основной проблемой детектирования было объединение контуров большеберцовой и бедренной костей в один контур из-за нечеткой границы сустава. На рис. 9 продемонстрированы возможности предложенного метода при работе с объектами нестандартной формы или с непредсказуемыми изменениями формы (переломы), что показывает его универсальность и гибкость.

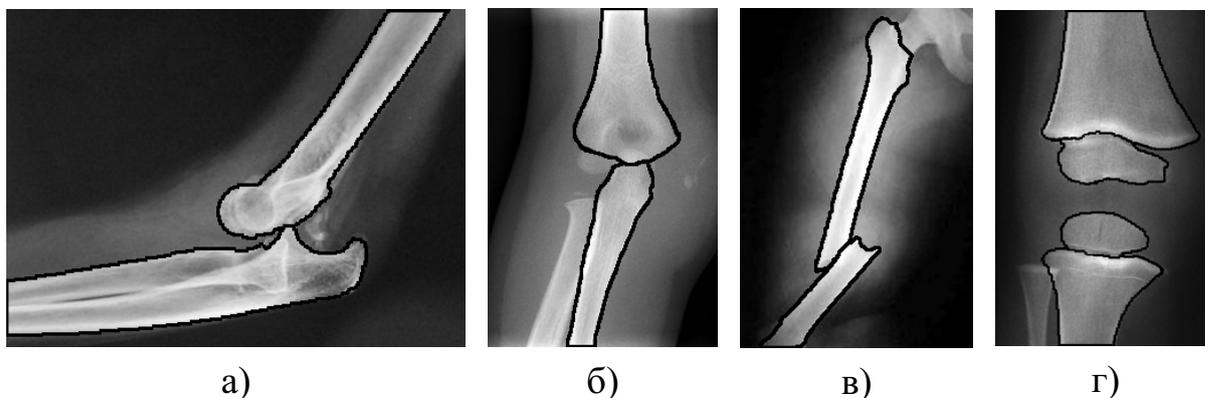


Рисунок 9 — Пример работы предложенного метода на рентгенограммах с вывихом (а, б), переломом (в) и детским суставом (г)

Для демонстрации полученных результатов было реализовано программное обеспечение, позволяющее проводить полноценные медицинские измерения как в ручном, так и в автоматическом режимах с применением описанных в работе методов автоматизированной диагностики остеоартрита.

В **заключении** приведены основные результаты диссертационной работы.

Основные результаты и выводы

Основной научный результат диссертационной работы заключается в решении **актуальной научной задачи**: *разработке методов и алгоритмов повышения точности автоматизированной диагностики остеоартрита по цифровым рентгенограммам без использования априорной информации о форме объектов в условиях ограниченных вычислительных ресурсов.*

При проведении исследований по теме представленной работы получены следующие результаты, обладающие научной новизной:

1. метод локализации суставов на рентгенограмме, **отличающийся** от существующих методов использованием сверточной нейронной сети специальной архитектуры в сочетании с разделимыми по глубине свертками, что позволило повысить точность работы (до 11 раз) и снизить требования к вычислительным ресурсам (вычислительная сложность меньше аналогичных методов в 5-7 раз);
2. метод повышения точности автоматической диагностики остеоартрита нейросетями, **отличающийся** от существующих методов использованием комплекса архитектурных решений, что позволило повысить точность (до 14,39% для модификации шкалы оценки при сохранении информативности диагностики, до 3,85% для интеграции блоков сжатия и возбуждения и до 2,41% при использовании ансамблей) и стабильностью работы;
3. **новый** алгоритм выделения контуров костей на медицинских рентгенографических изображениях, не использующий информацию об априорной форме объекта, что позволяет работать в случаях с сильным искажением формы;
4. **новый** алгоритм отслеживания контуров, использующий градиент изображения, что позволяет повысить устойчивость к артефактам, а также **новая** энергия для метода активных контуров, учитывающая направление градиента при изменении положения точек, что позволяет более аккуратно проводить уточнение контура.

Результаты диссертации были внедрены и использовались в ООО «Наука» (г. Ростов-на-Дону), ООО «Изоскан» (г. Ростов-на-Дону) и в учебном

процессе кафедры прикладной математики и программирования (ПМП) Института математики, механики и компьютерных наук (ИММиКН) ЮФУ (г. Ростов-на-Дону).

Предложенный в диссертации комплекс архитектурных решений для повышения точности автоматической диагностики остеоартрита может быть адаптирован и использован для решения задачи повышения точности классификации сверточными нейронными сетями в различных областях. Разработанные методы и алгоритмы могут быть использованы для построения систем интерактивной диагностики и автоматизации действий оператора при проведении измерений на рентгенограммах.

Разработанный программный комплекс может быть использован в медицинских учреждениях, осуществляющих работу с большим потоком данных или учреждениях с недостатком высококвалифицированных кадров, для автоматизации и упрощения процесса диагностики, а также для проведения вручную всех необходимых измерений (измерения углов, расстояний и т.п.).

Все научные результаты диссертации получены автором лично.

Публикации автора по теме научно-квалификационной работы

В изданиях из списка ВАК РФ

1. *Михайличенко, А. А.* Аналитический обзор методов оценки качества алгоритмов классификации в задачах машинного обучения / А. А. Михайличенко // Вестник Адыгейского государственного университета. Серия 4: Естественно-математические и технические науки. — 2022. — Т. 311, № 4. — С. 52—59. — DOI: [10.53598/2410-3225-2022-4-311-52-59](https://doi.org/10.53598/2410-3225-2022-4-311-52-59).

В изданиях, входящих в международную базу цитирования Scopus

2. *Михайличенко, А. А.* Использование блоков сжатия и возбуждения для повышения точности автоматической классификации остеоартрита коленного сустава при помощи сверточных нейронных сетей / А. А. Михайличенко, Я. М. Демяненко // Компьютерная оптика. — 2022. — Т. 46, № 2. — С. 317—325. — DOI: [10.18287/2412-6179-CO-897](https://doi.org/10.18287/2412-6179-CO-897).

3. *Mikhaylichenko, A.* Automatic Grading of Knee Osteoarthritis from Plain Radiographs Using Densely Connected Convolutional Networks / A. Mikhaylichenko, Y. Demyanenko // *Recent Trends in Analysis of Images, Social Networks and Texts. AIST 2020. Communications in Computer and Information Science.* — 2021. — Vol. 1357. — P. 149–161. — DOI: [10.1007/978-3-030-71214-3_13](https://doi.org/10.1007/978-3-030-71214-3_13).
4. *Михайличенко, А. А.* Выделение контуров костей коленного сустава на медицинских рентгенограммах / А. А. Михайличенко, Я. М. Демяненко // *Компьютерная оптика.* — 2019. — Т. 43, № 3. — С. 455–463. — DOI: [10.18287/2412-6179-2019-43-3-455-463](https://doi.org/10.18287/2412-6179-2019-43-3-455-463).
5. *Mikhaylichenko, A.* Automatic Detection of Bone Contours in X-Ray Images / A. Mikhaylichenko, Y. Demyanenko, E. Grushko // *CEUR Workshop Proceedings. Proceedings on 5th International Conference on Image Analysis, Social Networks and Texts.* — 2016. — Vol. 1710. — P. 212–223. — Access mode: <https://ceur-ws.org/Vol-1710/paper21.pdf> (access mode 30.06.2023).

Зарегистрированные программы для ЭВМ

6. *Свидетельство о государственной регистрации программы для ЭВМ № 2022665581, Российская Федерация.* Программа для автоматической диагностики остеоартрита коленного сустава по рентгенографическому изображению / А. А. Михайличенко. — Заявл. 04.08.2022 ; опубл. 18.08.2022, № 2022664895. — Бюл. № 8.

В сборниках трудов конференций

7. *Михайличенко, А. А.* Методы оценки качества работы бинарных и мультякласовых классификаторов / А. А. Михайличенко // *Современные информационные технологии: тенденции и перспективы развития : материалы ХХІХ научной конференции (Южный федеральный университет, Ростов-на-Дону, 21–23 апреля 2022 г.).* — Ростов-на-Дону; Таганрог: Издательство Южного федерального университета, 2022. — С. 198–203.

8. *Михайличенко, А. А.* Визуализация мотивов сверточной нейронной сети при принятии решения на примере автоматической классификации стадии остеоартрита / А. А. Михайличенко, Я. М. Демяненко // Современные информационные технологии: тенденции и перспективы развития. Материалы XXVIII научной конференции (Южный федеральный университет, Ростов-на-Дону, 13–15 мая 2021 г.) — Ростов-на-Дону; Таганрог: Издательство Южного федерального университета, 2021. — С. 257–259.
9. *Михайличенко, А. А.* Автоматическая локализация коленного сустава на рентгенограмме для оценки развития остеоартрита / А. А. Михайличенко // Современные информационные технологии: тенденции и перспективы развития. Материалы XXVII научной конференции (Южный федеральный университет, Ростов-на-Дону, 24–26 сентября 2020 г.) — Ростов-на-Дону; Таганрог: Издательство Южного федерального университета, 2020. — С. 189–191.
10. *Михайличенко, А. А.* Метод точного выделения контуров медицинских объектов на рентгенограммах / А. А. Михайличенко, Я. М. Демяненко // Графикон 2016 : труды 26-й Международной научной конференции, Россия, Нижний Новгород, 19–23 сентября 2016 г. — Нижний Новгород: Институт физико-технической информатики, 2016. — С. 193–198.
11. *Михайличенко, А. А.* Метод автоматического детектирования объектов на медицинских рентгенографических изображениях / А. А. Михайличенко, Я. М. Демяненко // Осенние математические чтения в Адыгее: материалы I Международной научной конференции, посвященной памяти профессора Казбека Сагидовича Мамия, 8–10 октября 2015 г. — Майкоп: АГУ, 2015. — С. 147–149.

Личный вклад автора в работы, выполненные в соавторстве: в [2] осуществлена интеграция блоков сжатия и возбуждения в существующие архитектуры сверточных нейронных сетей, а также выполнена проверка их эффективности; в [3] проведено исследование применимости сверточных нейронных сетей с плотно связанными блоками для задачи автоматической классификации ОА; в [5] разработан новый метод выделения контуров костей на рентгенограммах, в [4] дополнительно предложен алгоритм постобработки контуров для решения проблемы детектирования ложных границ.

Михайличенко Алексей Андреевич

Методы и алгоритмы автоматизированной диагностики остеоартрита по
рентгенографическим изображениям

Автореф. дис. на соискание ученой степени канд. техн. наук

Подписано в печать ____ . ____ . ____ . Заказ № _____

Формат 60×90/16. Усл. печ. л. 1. Тираж 100 экз.

Типография _____