

ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ БЮДЖЕТНОЕ ОБРАЗОВАТЕЛЬНОЕ  
УЧРЕЖДЕНИЕ ВЫСШЕГО ОБРАЗОВАНИЯ  
«БАШКИРСКИЙ ГОСУДАРСТВЕННЫЙ МЕДИЦИНСКИЙ УНИВЕРСИТЕТ»  
МИНИСТЕРСТВА ЗДРАВООХРАНЕНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ

Институт развития образования  
Кафедра медицинской физики и информатики

*На правах рукописи*




Гильмиярова Маргарита Нурихановна

РАЗРАБОТКА АЛГОРИТМА ИНТЕЛЛЕКТУАЛЬНОГО АНАЛИЗА  
РАСПОЗНАВАНИЯ ПНЕВМОНИИ

Научный руководитель:

доктор физико-математических наук,  
профессор



А.А. Кудрейко

Уфа – 2024

## ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ.....	4
ГЛАВА 1. ИНТЕЛЛЕКТУАЛЬНЫЙ АНАЛИЗ МЕДИЦИНСКИХ ИЗОБРАЖЕНИЙ.....	8
1.1 Интеллектуальный анализ медицинских изображений: КТ и рентгеновских снимков легких.....	10
1.2 Шум в изображениях компьютерной томографии.....	11
1.3 Методы подавления шума.....	13
1.4 Выводы по главе 1.....	22
ГЛАВА 2. АЛГОРИТМЫ МАШИННОГО ОБУЧЕНИЯ.....	23
2.1 Краткое описание программы Orange Data Mining.....	23
2.2 Нейронная сеть Inception v3.....	25
2.3 Модуль аналитики изображений.....	29
2.4 Обучение без учителя.....	34
2.5 Модуль визуализации данных.....	40
2.6 Модуль оценки эффективности классификации изображений.....	43
2.7 Выводы по главе 2.....	47
ГЛАВА 3. ИНТЕЛЛЕКТУАЛЬНЫЙ АНАЛИЗ РАСПОЗНАВАНИЯ ПНЕВМОНИИ.....	48
3.1 Описание базы данных.....	48
3.2 Алгоритм распознавания медицинских изображений.....	50
3.3 Результаты анализа рентгеновских изображений.....	52
3.4 Выводы по главе 3.....	58

ЗАКЛЮЧЕНИЕ .....	58
СПИСОК ЛИТЕРАТУРЫ.....	59

## ВВЕДЕНИЕ

**Актуальность проблемы.** Среди наиболее применяемых методик ранней диагностики широкого спектра социально значимых заболеваний: пневмония, онкологические заболевания легких, рак молочной железы, нарушения целостности костных структур и т.д., наиболее точной является лучевая диагностика. Она позволяет установить диагноз на самой ранней стадии развития заболевания. Соответствующие изображения и их интерпретация являются превалирующими инструментами в постановке диагноза перечисленных групп заболеваний. Фундаментальный недостаток лучевой диагностики связан с интегральным характером получаемого изображения, что ведет к потере информации по ее глубине. Это вызывает необходимость в получении и анализе множества проекций [1]. Отсюда возникает следующая ситуация: совершенствование методов и средств диагностики не всегда приводит к улучшению показателей качества диагностики [2]. Следовательно, решение задач распознавания медицинских изображений, их классификация по категориям и внедрение в клинические методы позволит разрешить накопленные противоречия [3].

Учитывая изложенное, разработка и исследование методов и алгоритмов классификации медицинских изображений (их сегментов) в условиях априорной неопределенности координат патологических нарушений является актуальной задачей. Для решения подобного рода задач используются различные методы машинного обучения. Например, метод опорных векторов или случайный лес, могут быть применены для доступных признаков на изображениях, сверточные нейронные сети (англ. convolutional neural network, CNN) показывают превосходные результаты в решении задач распознавания медицинских изображений [4-7].

Важной частью распознавания медицинских изображений является подготовка данных и извлечение признаков [8, 9]. Данная процедура

включает предварительную обработку таких параметров изображений<sup>1</sup> как резкость, фильтрация шума или нормализация. Кроме того, изображения могут быть представлены в виде гистограммы направленных градиентов или карты активации.

Интеллектуальный анализ медицинских изображений в виде компьютерных томограмм (КТ) и рентгена легких, представляет собой важную область исследований [10]. Различные методы машинного обучения и глубокого обучения могут быть использованы для решения задачи распознавания фрагментов изображений. Целью интеллектуального анализа изображений КТ легких с диагнозом пневмония может быть выявление патологий и классификация заболевания по доли области поражения легких.

**Цель работы:** поиск новых подходов, методов и алгоритмов классификации КТ и рентген изображений с диагнозом пневмония в условиях априорной неопределенности координат патологии и относительных уровней яркости объектов на фоне пространственно-неоднородного изображения.

Для достижения данной цели были поставлены и решены следующие **задачи:**

- поиск и подготовка медицинских изображений, необходимых для обучения алгоритмов;
- анализ и подбор подходящих алгоритмов предобработки и классификации изображений;
- разработка, обучение и определение на тестовой выборке ее диагностической информативности;
- анализ результатов исследования.

---

<sup>1</sup> Диапазон значений интенсивности пикселей.

Решение поставленных задач выполнено в программе Orange Data Mining, которая визуально отображает данные машинного обучения и их интеллектуального анализа.

**Область исследования.** Выпускная квалификационная работа выполнена в рамках освоения компетенций ОПК-2 (способен творчески использовать в профессиональной деятельности знания фундаментальных и прикладных разделов дисциплин (модулей), определяющих направленность магистратуры), и ОПК-6 (способен творчески применять и модифицировать современные компьютерные технологии, работать с профессиональными базами данных, профессионально оформлять и представлять результаты новых разработок) ФГОС ВО – Магистратура по направлению подготовки 06.04.01. Биология. Кроме того, российский и международный опыт показывают, что недостаточно и нельзя говорить об успешном инновационном развитии без эффективного междисциплинарного взаимодействия искусственного интеллекта и медицинской визуализации. Приоритеты инновационного развития здравоохранения России и способы реализации технологического развития, в том числе и искусственного интеллекта, отражены в нормативных документах Министерств здравоохранения и экономического развития РФ (Указ Президента Российской Федерации от 9 мая 2017 г. № 203 «О Стратегии развития информационного общества в Российской Федерации на 2017–2030 годы») [11].

В данной работе будут рассмотрены методы предварительной обработки рентгеновских и КТ снимков и проведено сравнение качества классификации на наборах данных с разной степенью предобработки.

**Объектом исследования** является открытая база данных КТ снимков легких, загруженная с платформы Kaggle [12, 13]. В работе мы

проанализировали набор из 300 снимков, который содержит три типа изображений: норма, пневмония и туберкулез легких.

Данная выпускная квалификационная работа была представлена 18.04.2024 на Международной научно-практической конференции «Компьютерное моделирование физических процессов и новые цифровые технологии в медицине и фармации».

## **ГЛАВА 1. ИНТЕЛЛЕКТУАЛЬНЫЙ АНАЛИЗ МЕДИЦИНСКИХ ИЗОБРАЖЕНИЙ**

Интеллектуальный анализ медицинских данных — это процесс применения методов и алгоритмов искусственного интеллекта (ИИ), машинного обучения (МО) и глубокого обучения (ГО) для обработки, анализа и извлечения информации из медицинских данных. Основная цель этого процесса - получение ценных и полезных знаний из больших объемов данных, что позволяет понять вид заболевания на начальном его этапе, прогнозировать результаты лечения, оптимизировать процессы здравоохранения и помочь в принятии обоснованных решений в медицинских вопросах.

В последние годы область медицинской визуализации стала свидетелем значительных достижений в области технологий и методов, что позволило специалистам в области здравоохранения более точно диагностировать и лечить различные заболевания. Медицинские изображения играют решающую роль в диагностике и последующем лечении пациентов. Тем не менее, интерпретация и анализ изображений с едва заметными патологиями могут оказаться сложными для врачей. Таким образом, разработка интеллектуальных методов анализа и технологий для медицинских изображений стала областью, представляющей значительный интерес. Об этом ясно свидетельствует динамика роста публикаций по анализу медицинских изображений (см. Рисунок 1. Динамика роста публикаций с ключевыми словами "medical images" и "artificial intelligence", полученная с помощью базы данных Scopus (дата обращения: 22.01.2024).

). Примечательно, что резкий рост интереса исследователей к данной теме совпал с началом пандемии COVID-19, поскольку во всех странах наблюдался дефицит квалифицированного медицинского персонала. За это время разработаны модели с высокими показателями точности и



перспективой дальнейшего применения в клинической практике для помощи врачам-рентгенологам. Сегодня данное направление исследований меняет будущее медицины.

В области анализа медицинских изображений важность использования передовых методов ГО трудно переоценить. Возможность применения методов ГО достигла впечатляющих результатов в различных областях, что делает ее особенно привлекательной для анализа медицинских изображений в здравоохранении.




Рисунок 1. Динамика роста публикаций с ключевыми словами "medical images" и "artificial intelligence", полученная с помощью базы данных Scopus (дата обращения: 22.01.2024).

Интеграция ГО с анализом медицинских изображений позволяет в режиме реального времени анализировать обширные и сложные наборы данных, получая информацию, которая значительно улучшает результаты здравоохранения и операционную эффективность в отрасли.

## 1.1 Интеллектуальный анализ медицинских изображений: КТ и рентгеновских снимков легких

Медицинские изображения, как правило, формируются с помощью одного из специализированных – КТ- или ЯМР-сканеров, радиоизотопных камер, ультразвуковых или рентгеновских установок и т. п., – каждое из которых имеет свою специфику. В целом, последовательность этапов получения и восприятия медицинского изображения можно представить в виде биотехнической системы (БТС) медицинской визуализации [14], приведенной на Рисунок 2. Биотехнической она является, поскольку все технические и биологические звенья системы объединены в едином контуре управления для достижения цели – постановки диагноза на основе анализа изображения медицинского объекта.

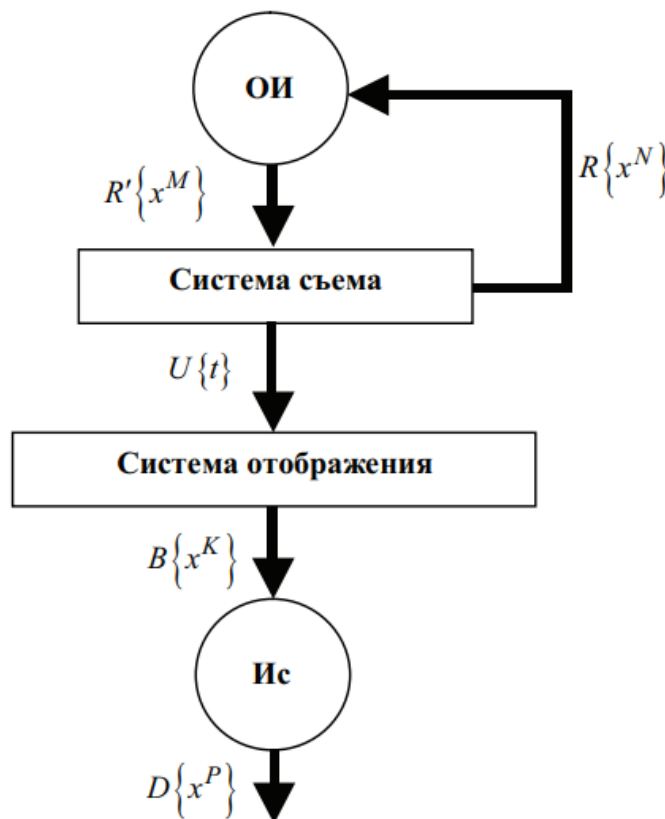


Рисунок 2. Биотехническая система медицинской визуализации.

В простейшем случае БТС медицинской визуализации состоит из следующих блоков: «Объект исследования» (ОИ), «Система съема», «Система отображения» и «Исследователь» (Ис).

При анализе КТ и рентген изображений легких, первым шагом является изучение структуры и анатомии органа, затем происходит поиск любых необычных форм, теней или аномалий, которые могут быть связаны с различными болезненными состояниями легких, такими как опухоли, инфекции или травмы. Для улучшения точности анализа, врачи используют различные программные средства и техники обработки изображений. Одна из таких техник — это использование программного обеспечения для выделения определенных областей интереса и улучшения контраста для более детального изучения обнаруженных аномалий. Кроме того, происходит сопоставление данных изучаемого пациента с нормативными данными для определения отклонений и распознавания патологических изменений. В процессе анализа медицинских изображений, врачу могут помочь специальные алгоритмы машинного обучения, которые были обучены на большом объеме данных [15]. Некоторые из алгоритмов описаны в данной ВКР (Глава 2) и применены к базам данных изображений.

## **1.2 Шум в изображениях компьютерной томографии**

Наиболее часто используемым и легко определяемым на практике параметром качества изображения является шум. Шум в КТ характеризует зернистость изображения и оказывает в первую очередь влияние на визуализацию низкоконтрастных объектов [16]. В то же время, проблема шумоподавления является одной из актуальных в области обработки изображений [17, 18]. Аналогично исследованию, приведенному на Рисунок 1. Динамика роста публикаций с ключевыми словами "medical images" и "artificial intelligence", полученная с помощью базы данных Scopus (дата обращения: 22.01.2024).

, число публикаций с ключевыми словами «medical images» и «denoising» увеличилось с 7 в 2000 г. до 179 в 2023 г. (данные получены с помощью базы данных Scopus). Чаще всего шумоподавление служит для улучшения визуального восприятия, но может также использоваться для специализированных целей, например, для увеличения четкости изображения на рентгеновских снимках, в качестве предобработки для последующего распознавания и т.п. [19, 20] .

Прежде чем рассматривать методы снижения шума на КТ-изображениях, важно получить общее представление об источнике шума. Однако на шум компьютерного изображения влияют многие источники. В своей статье Manoj Diwakar и Manoj Kumar выделяют следующие основные факторы [21]:

*Случайный шум.* Он может возникнуть в результате обнаружения конечного числа рентгеновских квантов в данной проекции. Это выглядит как колебание линейного коэффициента ослабления, отнесенного к плотности вещества. Данное явление происходит случайным образом и известно как случайный шум.

*Статистический шум.* Энергия рентгеновских лучей передается в виде квантов - отдельных порций энергии. Детектор рентгеновского излучения регистрирует конечное число рентгеновских квантов. Количество обнаруженных квантов может отличаться при другом измерении в силу статистических флуктуаций. Статистический шум в изображениях компьютерной томографии возникает из-за флуктуаций в обнаружении конечного числа рентгеновских квантов. По мере того, как при каждом измерении обнаруживается больше квантов, относительная точность каждого измерения повышается. Единственный способ уменьшить влияние статистического шума — это увеличить количество обнаруженных квантов.

Это достигается за счет увеличения количества пропускаемых рентгеновских лучей, то есть за счет увеличения дозы рентгеновского излучения.

*Электронный шум.* Существуют электрические схемы для приема аналоговых сигналов, которые также известны как аналоговые схемы. На процесс приема аналоговых сигналов электронными схемами может влиять некоторый шум, который называется электронным шумом. Новейшие компьютерные сканеры хорошо спроектированы для снижения электронного шума.

*Ошибки округления.* Аналоговые сигналы преобразуются в цифровые сигналы с использованием этапов обработки сигналов и затем отправляются в цифровой компьютер для реконструкции изображений компьютерной томографии. В цифровых компьютерах существуют цифровые схемы для обработки дискретных сигналов. Из-за ограниченного количества битов для хранения дискретных сигналов в компьютерной системе математические вычисления невозможны без округления. Это ограничение называется ошибкой округления.

### **1.3 Методы подавления шума**

*Целью шумоподавления изображения является удаление его шумовых компонент при сохранении полезной информации*

(Рисунок 3 Рисунок 3. КТ-изображение как совокупность четкого изображения и шумовой компоненты.

). Подавление шума в КТ-изображении может быть лучше выполнено при наличии предварительных знаний о КТ-изображениях и шуме [18, 22, 23].



Рисунок 3. КТ-изображение как совокупность четкого изображения и шумовой компоненты.

Цифровая обработка изображений играет ключевую роль в подавлении шума на снимках компьютерной томографии [21, 24, 25]. Известно несколько методов подавления шума в изображениях:

- Ресамплинг изображений и суперразрешение.
- Артефакты ложного оконтуривания.
- Повышение резкости методом деформирования сетки.
- Многомасштабное обнаружение хребтовых структур изображения.
- Совмещение изображений.

К методам повышения разрешения изображений относятся однокадровое и многокадровое суперразрешение [26] .

*Однокадровое суперразрешение или ресамплинг* заключается в восстановлении изображения высокого разрешения из одного изображения низкого разрешения [23, 26]. Для этого можно использовать классические методы, основанные на математической модели уменьшения разрешения изображения, или методы машинного обучения, в частности сверточные нейронные сети.

Классические методы предполагают, что изображение высокого разрешения можно получить путем интерполяции пикселей изображения

низкого разрешения. Однако, такой подход приводит к потере информации и ухудшению качества изображения. Для компенсации потери информации используются различные априорные сведения об изображении, например, информация о полной вариации.

Методы машинного обучения позволяют избежать использования априорной информации. Они основаны на том, что для каждого изображения низкого разрешения существует изображение высокого разрешения. Эта информация может быть использована для обучения нейронной сети, которая будет восстанавливать изображения высокого разрешения из изображений низкого разрешения.

*Многокадровое суперразрешение* заключается в восстановлении изображения высокого разрешения из нескольких изображений низкого разрешения. В этом случае объем доступных данных гораздо более информативный, и нет необходимости использовать априорную информацию для реконструкции изображения высокого разрешения [26-28].

Многокадровое суперразрешение может быть выполнено с помощью классических методов, основанных на математической модели уменьшения разрешения изображения. В этом случае необходимо решить обратную задачу, которая может быть некорректно поставленной. Для решения этой задачи используются методы регуляризации.

В статьях Крылова А.С., Саввина С.В. и Сироты А.А. предложены несколько алгоритмов многокадрового суперразрешения, основанных на классических методах [26-28]. Эти алгоритмы позволяют достичь хороших результатов для различных типов изображений.

Искажение изображения, которое выглядит в виде волн или колебаний вблизи сильных контуров на изображениях, представляет собой подавление *артефактов ложного оконтуривания (рингинга)*. Появление рингинга в изображениях МРТ, при сжатии алгоритмом JPEG2000, а также при

выполнении различных операций обработки изображений, таких как устранение размытия, повышение резкости и повышение разрешения, являются его наиболее известными случаями [26, 29-33]. Методы подавления рингинга являются одной из важных задач обработки изображений.

Основные подходы к улучшению качества изображения (подавлению рингинга) [26]:

1. Регуляризация полной вариации. Она позволяет восстановить изображение, минимизируя его полную вариацию. При этом высокочастотные детали изображения, которые наиболее подвержены рингину, подавляются сильнее, чем низкочастотные детали [34-37].
2. Методы дерингинга, основанные на разреженных представлениях [38-40]. Они рассматривают изображение как сумму разреженного набора базисных функций [33]. Рингинг может быть выглядеть в виде отдельной колебательной компоненты, которая подавляется путем удаления или ослабления соответствующей компоненты разреженного представления.
3. Гибридный метод дерингинга [41, 42]. Он основан на совместном использовании описанных выше методов и глубоком обучении.

Методы *повышения резкости изображений, основанные на деформации сетки пикселей*, не требуют знания ядра размытия или информации о типе и уровне шума [43-45]. Вместо этого, они используют только приблизительный уровень размытия изображения. Используемый нами метод повышения резкости контуров работает следующим образом:

1. Сначала определяется приблизительный уровень размытия изображения.



2. Затем, используя этот уровень размытия, вычисляется деформация сетки пикселей.

3. Наконец, изображение пересчитывается на деформированной сетке.

Деформация сетки пикселей приводит к тому, что пиксели, расположенные вблизи контуров, перемещаются ближе к этим контурам и это приводит к тому, что переходные участки контуров становятся тоньше без их искажения (Рисунок 4) [46].



Рисунок 4. Идея повышения резкости контуров изображения методом деформации сетки.

Преимуществами метода повышения резкости контуров методом деформации сетки являются то, что он не требует знания ядра размытия или информации о типе и уровне шума, а также не вводит артефакт рингинга и не изменяет уровень шума [26].

В статье также [47] рассматриваются различные аспекты реализации метода повышения резкости контуров методом деформации сетки. В частности, выбор параметров алгоритма, вычислительная эффективность алгоритма, применение алгоритма к объемным изображениям, усовершенствование алгоритма в угловых областях.

Экспериментальные исследования, представленные в статье [47], показывают, что метод повышения резкости контуров методом деформации

сетки обеспечивает хорошие результаты для различных типов изображений и используется после других алгоритмов улучшения изображения [48, 49].

*Детектирование хребтовых структур* решает задачу шумоподавления, сегментации и выделения контуров в анализе изображений [50-52].

Алгоритм обнаружения хребтовых структур строится на основе лапласиана (оператор Лапласа). Поскольку оператор Лапласа представляет собой сумму его вторых производных, его применение подчеркивает разрывы уровней яркостей на изображении и подавляет области со слабыми изменениями яркостей. Это приводит к получению изображения, содержащего сероватые линии на месте контуров и других разрывов, наложенные на темный фон без особенностей. Но фон можно «восстановить», сохранив при этом эффект повышения резкости, достигаемой лапласианом. Для этого достаточно сложить исходное изображение и лапласиан, при этом необходимо помнить, какое из определений лапласиана было использовано. Если использовалось определение, использующее отрицательные центральные коэффициенты, тогда для получения эффекта повышения резкости, изображение-лапласиан следует вычитать, а не прибавлять [53].

Алгоритм обнаружения хребтовых структур на основе лапласиана выглядит следующим образом [54]:

1. Изображение фильтруется лапласианом с помощью гауссова фильтра.
2. Модуль лапласиана вычисляется для каждой точки изображения.
3. Точки, где модуль лапласиана достигает максимума, считаются хребтовыми структурами.

Направление хребтовой структуры можно определить, используя матрицу Гессе [26, 52]. Матрица Гессе содержит информацию о том, как вторая производная изображения меняется в зависимости от переменных.

Там, где модуль лапласиана достигает максимального значения для каждой точки изображения, собственный вектор матрицы Гессе, соответствующий наименьшему собственному значению, будет направлен вдоль хребтовой структуры.

Обычно изображение содержит множество хребтовых структур разного размера. Для их обнаружения можно использовать многомасштабный подход [54].

В данном методе используется несколько значений масштаба для фильтрации лапласиана: для каждой точки изображения вычисляется модуль лапласиана на каждом масштабе. Точка считается хребтовой структурой, если модуль лапласиана достигает максимума для одного из данных масштабов.

Обнаружение хребтовых структур может быть использовано в различных программах обработки изображений:

- шумоподавление: хребтовые структуры обычно менее подвержены шуму, чем другие области изображения, что позволяет использовать их для подавления шума.
- сегментация: хребтовые структуры часто совпадают с границами между различными объектами в изображении, поэтому их можно использовать для сегментации изображения на отдельные объекты [55].
- выделение контуров: хребтовые структуры могут использоваться для выделения контуров объектов в изображении.

Кроме алгоритма на основе лапласиана, существуют и другие методы обнаружения хребтовых структур. Например, можно использовать метод на основе диффузии [46, 54, 56, 57], в основе которого лежит метод распространения информации от пикселей с высокой интенсивностью к пикселям с низкой интенсивностью. В том числе для сегментации изображений можно использовать методы на основе сверточных нейронных сетей и многомасштабном детектировании хребтовых структур [58-60].

*Совмещение изображений* позволяет объединить информацию из двух разных методов визуализации. Это позволяет улучшить качество диагностики и лечения [61-64].

Алгоритмы совмещения изображений могут быть разделены на две основные категории:

- алгоритмы на основе опорных точек - используют соответствия между опорными точками на двух изображениях для определения параметров совмещения [65].
- алгоритмы на основе признаков - используют признаки, которые характеризуют изображение, для определения параметров совмещения [63].

Алгоритмы на основе опорных точек (SIFT, SURF, FAST) работают так: на изображениях выделяются опорные точки и их дескрипторы, затем по совпадению дескрипторов выделяются соответствующие друг другу опорные точки и рассчитываются параметры их сопоставления [65]. Опорные точки могут быть, например, анатомическими ориентирами, такими как края сосудов или костей.

Способом ускорения алгоритма на основе опорных точек является поиск опорных точек изображения и создание их дескрипторов, инвариантных к масштабу и вращению. Это значит, что описание опорной точки будет одинаково, даже если образец изменит размер и/или будет

повернут. Сам поиск опорных точек тоже должен обладать инвариантностью [66]. Алгоритм находит опорные точки с быстрым изменением яркости и отбрасывает неустойчивые опорные точки.

Алгоритмы на основе признаков (HOG, LBP, CNN) более сложные, чем алгоритмы на основе опорных точек, они обеспечивают более высокую точность совмещения. Такие алгоритмы выглядят следующим образом: для каждого изображения выявляются признаки, характеризующие его; соответствия между изображениями определяются с использованием этих признаков; параметры совмещения рассчитываются с использованием этих соответствий [63]. Такими признаками могут быть, например, форма, градиенты, текстура, цвет или яркость.

Выбор конкретного алгоритма совмещения изображений зависит от конкретной задачи, от характеристик изображений и доступных ресурсов.

Основные проблемы фильтрации шума на КТ-изображениях [67]:

- потеря информации (чрезмерное сглаживание изображения с потерей важных деталей);
- размытие границ (затрудняет их сегментацию и распознавание);
- неправильный подбор параметров (может привести к чрезмерному сглаживанию и/или появлению артефактов);
- вычислительная сложность алгоритмов (затрудняет применение в определенных задачах, связанных с обработкой больших объемов данных);
- не существует универсального метода шумоподавления (для каждого типа шума используется определенный метод шумоподавления);
- появление артефактов.

## 1.4 Выводы по главе 1

Интеллектуальный анализ медицинских изображений КТ и рентгена легких имеет несколько преимуществ перед традиционными методами анализа: он повышает точность и надежность результатов, способствует автоматизации процесса диагностики и уменьшению человеческого фактора, что позволяет быстро анализировать большие объемы данных и проводить быструю комплексную оценку состояния пациентов.

Однако, интеллектуальный анализ медицинских изображений КТ и рентгена легких имеет свои ограничения:

- Разработка и обучение моделей требует больших объемов размеченных данных, где каждый снимок содержит описание анатомических структур, патологий и других характеристик. Сбор таких данных процесс трудоемкий, требующий участие высококвалифицированных врачей-рентгенологов. Недостаток данных, а также их низкое качество, может привести к неточному анализу искусственным интеллектом.
- Необходимость в высокопроизводительных компьютерах. Алгоритмы искусственного интеллекта для обработки медицинских изображений требуют значительных вычислительных ресурсов. Работа с изображениями, сложные алгоритмы сегментации и машинного обучения обуславливают высокую загрузку компьютерного оборудования, что имеется не во всех медицинских учреждениях.
- Переобучение. Модели искусственного интеллекта могут «запоминать» особенности данных из обучающего набора, что приводит к переобучению. Например, модель хорошо работает с изображениями из обучающего набора, но плохо справляется с

изображениями из других источников, даже если они содержат один и тот же механизм.

- Ошибки в интерпретации (недообучение). Модели искусственного интеллекта не всегда могут объяснить почему они получили тот или иной результат, что снижает доверие врачей к этим результатам.
- Учет этических норм и стандартов.

## **ГЛАВА 2. АЛГОРИТМЫ МАШИННОГО ОБУЧЕНИЯ**

### **2.1. Краткое описание программы Orange Data Mining**

Orange Data Mining (ODM) – это интерактивная среда для визуального программирования и визуализации данных, интеллектуального анализа данных и решения задач машинного обучения [68]. Orange Data Mining имеет удобный интуитивно понятный визуальный интерфейс программирования.

Orange Data Mining использует визуальную платформу, в которой его функциональность разделена на самостоятельные программные модули (виджеты). Виджеты — это стандартные элементы пользовательского интерфейса, которые выполняют различные задачи, начиная от простых операций визуализации и фильтрации данных до сложных алгоритмов решения задач машинного обучения и прогнозирования. Каждый виджет имеет графический интерфейс, позволяющий пользователю взаимодействовать с ним. Также виджеты могут быть соединены друг с другом, определяя порядок выполнения операций для создания сложных рабочих процессов.

Orange Data Mining предоставляет широкий спектр функций:

- создание алгоритмов с помощью различных методов и моделей машинного обучения: логистической регрессии, случайного леса, глубоких нейронных сетей и другие;
- предобработка, очистка и преобразование данных (например, замена отсутствующего значения средним, медианой, модой, либо удалением всей записи, удаление выбросов, либо их ограничение, либо замена);
- визуализация данных и моделей машинного обучения (предоставляет собой инструменты, с помощью которых можно создавать различные виды графиков, диаграмм, позволяет визуализировать данные в трехмерном пространстве и в наиболее понятной для человека форме).
- поддержка различных типов данных, включая категориальные, числовые, текстовые данные и изображения;
- экспорт/импорт данных и моделей машинного обучения с последующей интеграцией с другими системами.

Одно из преимуществ Orange — это возможность расширения программы, то есть ее открытая архитектура, что позволяет адаптировать платформу к конкретным задачам анализа данных и увеличить ее функциональность. В качестве дополнений могут выступать следующие инструменты, например, Orange BioWidgets: предоставляет виджеты для общих задач в биоинформатике, таких как анализ геномных данных, анализ экспрессии генов и анализ метаболизма; Orange3D: позволяет визуализировать 3D-медицинские изображения - молекулы и структуры; Biomedical Text Mining: позволяет извлекать информацию из биомедицинских текстов.



Структура Orange основана на интерфейсе Canvas, который представляет собой основное пространство, где пользователи могут создавать и редактировать свои рабочие процессы для анализа данных. Виджеты добавляются на Canvas и связываются друг с другом с помощью линий, которые определяют направление данных и порядок выполнения операций. Данные передаются от одного виджета к другому, пока не достигнут финального этапа анализа. Каждый виджет выполняет определенную задачу, например, загрузку данных, очистку данных, визуализацию или машинное обучение. Orange использует обычные библиотеки Python с открытым исходным кодом для научных вычислений. Это открывает дополнительные возможности для манипулирования данными и настройки виджетов, позволяя создавать более сложные и индивидуальные рабочие процессы.

Далее приводится описание только тех виджетов, которые были заложены в построение алгоритма интеллектуального анализа распознавания пневмонии.

## **2.2. Нейронная сеть Inception v3**

Основным элементом анализа изображений ODM является Inception v3 — это сверточная нейронная сеть, состоящая из 42 слоев. Она использует архитектуру Inception, которая была разработана для повышения эффективности и точности сверточной нейронной сети и выполняет вычисления на графическом процессоре, что делает их быстрее. Модуль Inception v3 содержит несколько модулей Inception, каждый из которых состоит из сверточных слоев разного размера, которые объединяются в один слой. Это позволяет сверточной нейронной сети эффективно обрабатывать изображения с различными характеристиками, например, размер, цвет или текстура.

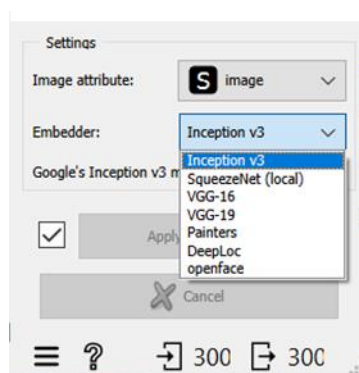


Рисунок 5. Расположение Inception v3.

Inception v3 была обучена на наборе данных ImageNet, содержащем более миллиона изображений и 1000 категорий объектов. Она показала высокую эффективность в различных задачах, связанных с анализом изображений, включая классификацию изображений, сегментацию изображений и извлечение признаков. Точность достигла 78,1%, что является более качественным по сравнению с предыдущими моделями.

Окончательная модель Inception v3 выглядит следующим образом (Рисунок 6):

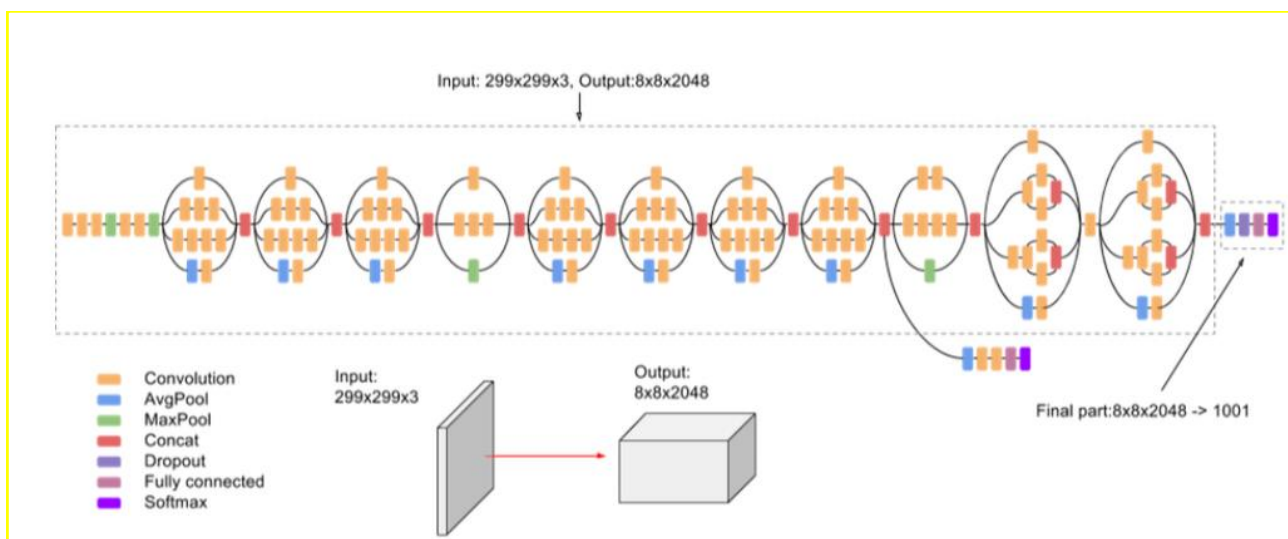


Рисунок 6. Модель Inception v3.

Inception v3 работает следующим образом: в виджет для встраивания изображений загружается таблица с метаданными изображений, такими как название, местоположение и размер изображения, но они не готовы для анализа. Изображения отправляются на сервер для встраивания в формате, понятном алгоритмам машинного обучения (**Ошибка! Источник ссылки не найден.**). Сервер пропускает изображения через предварительно обученную глубокую нейронную сеть и возвращает числовые векторы в виджет.

Возможности Inception v3:

- Классификация изображений (может быть использована для классификации медицинских изображений по категориям, таким как "нормальный", "аномальный" или "с признаками заболевания").
- Сегментация изображений (может быть использована для сегментации медицинских изображений, например, для выделения «конкретных областей интереса», таких как опухоли или органы).
- Извлечение признаков (может быть использована для извлечения признаков из медицинских изображений).

Основные преимущества использования нейронной сети Inception v3:

- показала высокую точность в решении задач, связанных с анализом изображений, в некоторых случаях достигая результатов сопоставимых с экспертами. Данная нейронная сеть превосходит традиционные алгоритмы машинного обучения, такие как SVM (Метод опорных векторов) и KNN (Метод k-ближайших соседей), в классификации и сегментации медицинских изображений;
- может относительно быстро и качественно обрабатывать изображения в настоящем времени, что делает ее подходящей для клинических программ, и имеет небольшой размер, что позволяет использовать ее на устройствах с ограниченными возможностями;

- анализирует большой спектр медицинских изображений: рентгеновские снимки, МРТ, КТ, УЗИ и т.д. и используется для решения разнообразных задач;
- доступна для бесплатного использования, включена в Orange Data Mining и поддерживается многими разработчиками;
- постоянно развивается, улучшается, получает обновления с новыми функциями и дополнениями, совместима с лучшими достижениями в области глубокого обучения.

При применении Inception v3 в ODM для анализа медицинских изображений следует учитывать следующие ограничения:

1. требуются навыки программирования на Python.
2. нейросеть, будучи обученной изображениями общего медицинского назначения, в вопросах медицинской диагностики не подходит для применения «мгновенно». Для настройки достижения заданных результатов требуется произвести дообучение набора данных изображений, что может повысить общую трудоемкость и потребовать большого количества вычислительных ресурсов.
3. нейросеть очень чувствительна к составу и качеству обучающих данных. Несбалансированные или нерепрезентативные наборы данных могут привести к смещению модели и снижению ее точности.

Inception v3 сложна в интерпретации данных: объяснение того, как сеть принимает решения для определенного изображения, бывает затруднительным, а непрозрачность - ограничивает ее применение в ситуациях, где нужно понимание, как модель делает свои выводы.

Нейронная сеть Inception v3, входящая в ODM, мощный инструмент для решения задач, связанных с анализом изображений.

### 2.3. Модуль аналитики изображений

Модуль аналитики изображений (Image Analytics) в программе ODM предназначен для анализа изображений. Для решения наших задач анализа медицинских изображений мы будем использовать следующие виджеты из данного модуля: Import Images (Импорт изображений), Image Viewer (Программа просмотра изображений), Image Embedding (Встраивание изображений), Image Grid (Сетка изображений).

Виджет **Import Images** (Импорт изображений) является первым виджетом, который мы используем для анализа изображений. Он выполняет импорт изображений из файлов или папок. Импорт происходит по каталогу и при формировании таблицы определяет одну строку для каждого изображения. Столбцы содержат название изображения, полный путь к нему, его ширину, высоту и размер. Столбец, содержащий путь к изображению, используется как атрибут для визуализации и встраивания изображения.

Виджет **Image Viewer** (Программа просмотра изображений) представляет собой инструмент для визуализации изображений. Он позволяет просматривать, сравнивать и анализировать изображения из набора данных, используя масштабирование, фильтрацию, панорамирование и сохранение. Предварительный просмотр данных играет основную роль в анализе данных, помогает получить более глубокое понимание своего набора данных.

Виджет **Image Embeddings** (Встраивание изображений) преобразует изображения в векторные представления. Этот виджет загружает изображения на удаленный сервер или оценивает их локально. Модели глубокого обучения используются для расчета вектора признаков для каждого изображения.

Виджет имеет следующие входные данные:

- изображения, которые мы хотим внедрить;
- метод преобразования изображений в векторном виде.

Векторное представление данных имеет фиксированную длину. Она генерируется с использованием алгоритмов глубокого обучения, таких как сверточные нейронные сети (Рисунок 7).

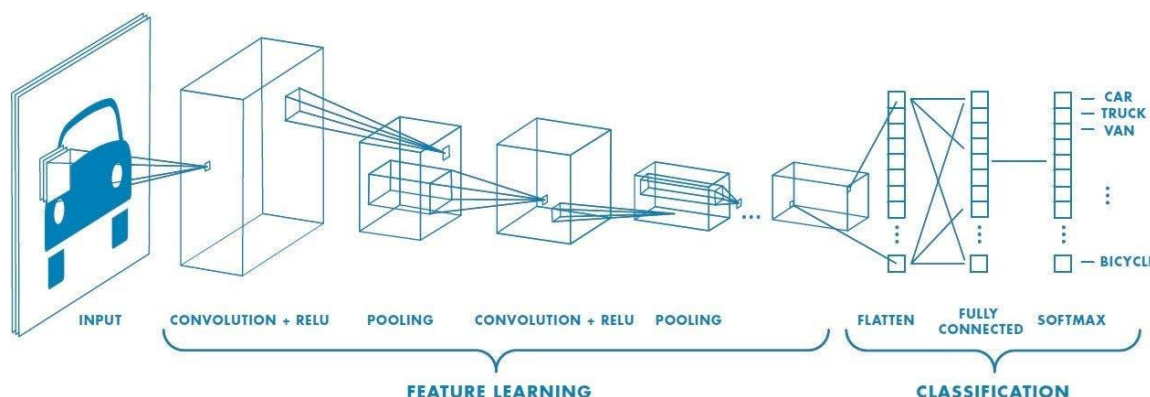


Рисунок 7. Схема работы сверточной нейронной сети.

Виджет предлагает следующие методы для встраивания изображений:

- SqueezeNet: небольшая и очень быстрая модель для распознавания изображений.
- Inception v3, разработан Google.
- VGG-16: имеет 16 слоев распознавания изображений.
- VGG-19: имеет 19 слоев распознавания изображений.
- Painters: модель, обученная предсказывать художников по художественным изображениям.
- DeepLoc: модель, обученная анализировать изображения дрожжевых клеток.

Каждый из этих методов обучен для решения определенных задач. Большинству из них, за исключением SqueezeNet, для работы нужно подключение к интернету.

Результат вычислений представляет собой таблицу данных (Рисунок 8).

<b>Info</b> 300 instances (no missing data) 2048 features Target with 3 values 5 meta attributes		category	image name	image	size	width	height	n0	True
1	1. Туберкулез	Tuberculosis-1	1. Туберкулез/...	217451	512	512	0.0660995		
2	1. Туберкулез	Tuberculosis-10	1. Туберкулез/...	65932	512	512	0.276602		
3	1. Туберкулез	Tuberculosis-100	1. Туберкулез/...	69392	512	512	0.643106		
4	1. Туберкулез	Tuberculosis-11	1. Туберкулез/...	76980	512	512	0.186294		
5	1. Туберкулез	Tuberculosis-12	1. Туберкулез/...	73539	512	512	0.0689426		
6	1. Туберкулез	Tuberculosis-13	1. Туберкулез/...	67899	512	512	0.321401		
7	1. Туберкулез	Tuberculosis-14	1. Туберкулез/...	63062	512	512	0.580383		
8	1. Туберкулез	Tuberculosis-15	1. Туберкулез/...	71378	512	512	0.708286		
9	1. Туберкулез	Tuberculosis-16	1. Туберкулез/...	82379	512	512	0.530093		
10	1. Туберкулез	Tuberculosis-17	1. Туберкулез/...	69484	512	512	0.543751		
11	1. Туберкулез	Tuberculosis-18	1. Туберкулез/...	71613	512	512	0.501804		
12	1. Туберкулез	Tuberculosis-19	1. Туберкулез/...	64575	512	512	0.463397		
13	1. Туберкулез	Tuberculosis-2	1. Туберкулез/...	198946	512	512	0.449929		
14	1. Туберкулез	Tuberculosis-20	1. Туберкулез/...	69496	512	512	0.389497		
15	1. Туберкулез	Tuberculosis-21	1. Туберкулез/...	62182	512	512	0.306915		

Рисунок 8. Таблица данных.

Виджет **Image Grid** (Сетка изображений) применяется для отображения изображений в виде сетки, где наиболее близкие изображения размещаются рядом на основе их сходства. Виджет имеет следующие параметры:

- подключается входной набор данных, который необходимо отобразить в сетке;
- путь к изображениям;
- размер ячейки влияет на масштаб изображения на сетке, а обрезка - до квадратов.
- определение размера сетки, где указывается количество строк и столбцов, либо фиксируется автоматически.
- информация о входных данных, например, о количестве изображений.

Алгоритм работы виджета выглядит следующим образом:

1. Вычисление количества изображений.
2. Исходя из количества изображений, виджет вычисляет количество столбцов и строк в сетке.

3. Используя метод интерполяции, указанный в параметрах виджета, изображения размещает на сетке.

Виджет Image Grid может использоваться для визуализации следующих типов изображений:

- цифровые изображения: например, для визуализации изображений, полученных с помощью камеры или сканера;
- категориальные изображения: например, для визуализации изображений, полученных с помощью медицинских или научных приборов;
- текстовые изображения: например, для визуализации изображений, полученных с помощью компьютерных программ.

Группа виджетов модуля анализа изображений (Image Analytics) работает следующим образом: задача автоматизированной классификации изображений сводится к выделению области интереса сегментов, принадлежащих к классу «патология» и включающий:

- многослойный морфологический оператор, отличающийся использованием множества структурообразующих элементов в комплекте с кортежем морфологических операторов. При этом один из них увеличивает яркость пикселя в структурообразующем элементе, а другой уменьшает яркость пикселя, а окончательная яркость пикселя устанавливается посредством использования третьего морфологического оператора, позволяющего управлять показателями однородности сегментов изображения;
- алгоритм сегментации изображений рентгеновского снимка, отличающийся тем, что каждому вновь полученному сегменту присваивается статус сегмента-потомка или материнского сегмента, в зависимости от которого формируется его уникальный код, определяющий его место в иерархии сегментов изображения;



- алгоритм модификации границ сегмента путем оптимизации критерия однородности у сегментов-потомков одного материнского сегмента, отличающийся итерационным процессом увеличения или уменьшения горизонтальных и вертикальных координат границ смежных сегментов-потомков таким образом, чтобы оптимизировать критерии однородности в сегментах с новыми границами, позволяющий снизить количество материнских сегментов изображения и тем самым повысить скорость обработки изображения [69].

Классификаторы выделенных сегментов строятся на методах попиксельной классификации или на методах анализа границ сегмента. Формирование каскадного окна происходит следующим образом: растровое изображение декомпозируется на некоторое количество уровней. Каждый уровень содержит множество потомков - изображений. Изображение верхнего уровня является «материнским» изображением для множества изображений-потомков нижнего уровня, как и изображение нижнего уровня является «материнским» для изображений следующего (нижнего по отношению к этому изображению) уровня [69].

Критерии однородности носят эмпирический характер и выбираются на основе яркостных характеристик или текстурных характеристик:

$$\max_{P \in R} |f(P) - m| < T,$$

где  $m$  – среднее значение яркостей пикселей  $f(P)$  в каскадном окне  $R$ , которое вычисляется по формуле

$$m = \frac{1}{N} \sum_{P \in R} f(P),$$

где  $N$  – число пикселей в каскадном окне. При текстурном подходе к критерию однородности каскадное окно описывается вектором информативных признаков, например, спектральные коэффициенты,

гистограммы и т.п. Тогда критерий однородности каскадных окон определяется как эвклидово расстояние между векторами признаков, характеризующих текстуры каскадных окон [70].

## 2.4. Обучение без учителя

Модуль виджетов обучения без учителя (Unsupervised) в программе ODM используется для решения задач машинного обучения. При построении алгоритма нами будут использованы следующие виджеты этого модуля: Distancer (Расстояния), Distance Map (Карта расстояний), Hierarchical Clustering (Иерархическая кластеризация), MDS (Multidimensional scaling) (Многомерное масштабирование).

Виджет **Distancer** (Расстояния) определяет расстояния между строками и/или столбцами в датасете. По умолчанию данные для обеспечения единообразия при применении определенных функций приводятся к одному виду. Оптимизация всегда выполняется по столбцам.

Виджет использует следующие параметры: подключается входной набор данных, для которых необходимо вычислить расстояния, и определяется метрика расстояния, которая будет использована для вычисления расстояний между объектами.

Виджет Distancer поддерживает следующие метрики расстояния:

- Эвклидово расстояние - измеряет кратчайшее расстояние между двумя точками и является наиболее универсальным в применении.

Вычисляется по формуле:

$$d(x_i, y_j) = \sqrt{\sum_{r=1}^n (x_{ir} - y_{jr})^2},$$

где  $(x_{ir}, y_{jr})$  – координаты векторов.

- Манхэттенское расстояние - определяет сумму абсолютной разницы между координатами двух точек. Вычисляется по формуле:

$$d(x, y) = |x_1 - y_1| + |x_2 - y_2| + \dots + |x_n - y_n|,$$

где  $x_n$  и  $y_n$  — точки в двумерном пространстве.

- Косинусное расстояние — это мера сходства между двумя ненулевыми векторами пространства скалярного произведения, которая измеряет косинус угла между ними. Косинусное расстояние находится в диапазоне от -1 до 1, при этом значения, близкие к 1, указывают на сходство, а значения, близкие к -1, указывают на различие [71]. Вычисляется по формуле:

$$d(x, y) = 1 - \cos \theta = 1 - \frac{x \cdot y}{|x||y|}$$

- Расстояние Жаккара — это показатель сходства между двумя наборами данных. Разработан Полом Жаккаром. Индекс варьируется от 0 до 1. Чем ближе к 1, тем более похожи два набора данных. Индекс сходства Жаккара рассчитывается так:

$$d(x, y) = 1 - \frac{|x \cap y|}{|x \cup y|}$$

- Расстояние Хемминга между двумя векторами — это сумма соответствующих элементов, которые различаются между векторами. Вычисляется по формуле:

$$d(x, y) = \sum_{i=1}^n \delta(x_i, y_i)$$

где  $\delta(x_i, y_i)$  равно 0, если  $x_i = y_i$ , и 1 в противном случае.

Виджет **Distance Map** (Карта расстояний) применяется для визуализации матрицы расстояний. Это график, где каждому пикселю, представляющим его расстояние до конкретного объекта (или набора

объектов) на исходном изображении, присваивается значение и выделяется цветом ячейки. Чем ближе расстояние, тем более темным цветом отображается ячейка. Расстояние между двумя объектами вычисляется с помощью виджета Distancer.

Виджет Distance Map имеет следующие параметры:

- подключается входной набор данных, для которых нужно визуализировать матрицу расстояний;
- выбирается метрика расстояния для вычисления расстояний между объектами;
- выбирается цветовая палитра для отображения расстояний;
- указывается размер графика.

Виджет **Hierarchical Clustering** (Иерархическая кластеризация) – это метод машинного обучения, который используется для группировки объектов в наборе данных на основе их сходства.

Алгоритм иерархической кластеризации выглядит следующим образом:

1. Каждый объект — это отдельный кластер.
2. На каждом шаге алгоритма, два наиболее похожих кластера объединяются в один.
3. Алгоритм повторяет этот шаг, пока не останется только один кластер, содержащий все объекты.

В итоге, на основе матрицы расстояний создается древовидная структура, визуализирующая процесс объединения кластеров, которая называется дендрограммой. Дендрограмма показывает иерархию кластеров и позволяет пользователю выбирать уровень кластеризации, который лучше всего подходит для его задачи.

Основные методы объединения кластеров:

Метод	Описание	Преимущества	Недостатки
-------	----------	--------------	------------

объединения кластеров	метода		
Одинарная связь (метод ближайшего соседа)	вычисляет расстояние между ближайшими элементами двух кластеров	простой и быстрый алгоритм, хорошо работает для данных с кластерами, которые имеют вытянутую форму	может создавать "цепочки" кластеров, которые не являются компактными, чувствителен к выбросам
Полная связь (метод дальнего соседа)	вычисляет расстояние между самыми удаленными элементами кластеров	создает компактные кластеры, устойчив к выбросам.	может быть медленным для больших наборов данных, чувствителен к шуму.
Средняя связь (метод среднего расстояния)	вычисляет среднее расстояние между всеми парами точек в двух кластерах.	простой и быстрый алгоритм, выравнивает преимущества и недостатки одинарной и полной связей	не всегда хорошо работает для данных с кластерами, которые имеют разную форму.
Привязка Уорда	объединяет кластеры, которые минимизируют дисперсию	создает компактные кластеры, устойчив к шуму	может быть медленным для больших наборов данных, не всегда хорошо

	внутри кластеров		работает для данных с кластерами, которые имеют разную форму
Взвешенная связь	использует метод WPGMA (weighted pair- group method with arithmetic mean)	учитывает количество объектов в кластерах	может быть медленным для больших наборов данных

Выбор метода объединения кластеров зависит от типа данных, цели кластеризации и доступных вычислительных ресурсов.

Виджет Hierarchical Clustering имеет следующие параметры:

- подключается входной набор данных, для которых необходимо выполнить кластеризацию.
- выбирается метрика расстояния, которая будет использоваться для вычисления расстояний между объектами.
- выбирается метод объединения кластеров.
- указывается порог, который будет использоваться для объединения кластеров методом слияния.
- указывается порог, который будет использоваться для объединения кластеров методом объединения.

Виджет предоставляет возможности, которые позволяют получить более полное представление о результатах кластеризации:

- отображает дендрограмму, которая представляет иерархическое дерево кластеров.
- отображает метки кластеров для всех объектов.
- отображает центры кластеров.
- отображает статистику для каждого кластера, такую как количество объектов в кластере и среднее значение признаков в кластере.

Виджет **MDS (Multidimensional Scaling)** (Многомерное масштабирование) применяется для визуализации данных в многомерном пространстве. Он работает путем поиска проекции данных в двухмерное или трехмерное пространство таким образом, чтобы сохранить расстояния между объектами в исходном пространстве.

Алгоритм MDS итеративно перемещает точки в своего рода имитации физической модели: если две точки находятся слишком близко друг к другу (или слишком далеко), существует сила, удаляющая их (или соединяющая). Изменение положения точки на каждом временном интервале соответствует сумме действующих на нее сил.

Виджет MDS имеет следующие параметры:

- подключается входной набор данных, которые необходимо визуализировать.
- выбирается метрика расстояния для вычисления расстояний между объектами в исходном пространстве.
- указываются: количество измерений, в которые необходимо проецировать данные; начальная проекция данных; значение для определения того, когда алгоритм минимизации квадратов достиг совпадения.

Виджет MDS используется для визуализации различных типов данных:

- числовые данные: например, для визуализации данных о температуре, скорости или весе;
- категориальные данные: например, для визуализации данных о людях, животных или растениях;
- текстовые данные: например, для визуализации данных о документах или веб-сайтах.

Группа виджетов обучения без учителя имеет ряд дополнительных возможностей, которые позволяют настроить ее поведение:

- цветовая кодировка для обозначения различных объектов или групп объектов.
- символы для обозначения различных объектов или групп объектов.
- дополнительные параметры, которые позволяют настроить их поведение.

Описанные метрики расстояния являются исходными данными для многомерного шкалирования (см. раздел 3.2).

## 2.5. Модуль визуализации данных

Группа виджетов Visualize в пакете ODM используется для визуализации данных. В разработке алгоритма мы применим набор следующих виджетов: Scatter Plot (Точечная диаграмма), Box Plot (Диаграмма размаха) и Distributions (Распределения).

Виджет **Scatter Plot** (Диаграмма рассеивания) применяется для визуализации взаимосвязи между двумя переменными. Данные отображаются в виде набора точек, каждый из которых имеет значение атрибута, определяющего положение на горизонтальной оси (X), и значение атрибута, определяющего положение на вертикальной оси (Y).

Виджет Scatter Plot имеет следующие параметры:



- подключается входной набор данных, для построения графика рассеяния.
- указываются: признак для построения осей X; признак для построения осей Y; признак для цветовой кодировки данных; признак для изменения размера данных.

С помощью виджета можно исследовать расположение точек на графике рассеяния и визуально оценить взаимосвязь между двумя переменными. Например, точки, расположенные по диагонали с положительным наклоном, отражают положительную корреляцию; точки, расположены по диагонали с отрицательным наклоном - отрицательную корреляцию; точки, рассеянные случайным образом, демонстрируют отсутствие корреляции.

Виджет **Box Plot** (Диаграмма размаха) предназначен для визуализации распределения данных в виде «ящика с усами». «Ящик с усами» является диаграммой, которая отражает следующие статистические характеристики данных:

- медиану - центральное значение в наборе данных;
- квартили (первый и третий) - значения, которые делят упорядоченный набор данных на четыре равные части;
- выбросы - точки, которые находятся далеко от основного распределения данных.

Box Plot используется для сравнения распределения двух или более наборов данных на одном графике, позволяет легко обнаружить выбросы, которые указывают на ошибки в данных или на интересные особенности.

Box Plot состоит из «ящика», вертикальной линией внутри «ящика» - медианой, «усов», которые простираются от минимального и до максимального значений и не являются выбросами, и выбросов (точек, которые находятся за пределами усов и отображаются индивидуально).

Виджет **Distributions** (Распределения) используется для визуализации распределения данных в виде графиков, таких как: гистограмма, кривая плотности вероятности, кривая распределения. Он дает возможность понять, как часто встречаются разные значения этой переменной.

Гистограмма — это столбчатая диаграмма, где каждый столбец показывает количество объектов данных, попадающих в определенный диапазон значений. Если набор данных имеет переменную класса, виджет может отобразить отдельные гистограммы для каждого класса. Это позволяет сравнить, как распределены значения переменной в разных группах. По форме гистограммы можно судить о том, как распределены данные:

- симметричное распределение: столбцы гистограммы отображаются симметрично относительно центра.
- правостороннее смещение: большинство столбцов слева, а хвост гистограммы направлен вправо.
- левостороннее смещение: большинство столбцов расположены справа, а хвост гистограммы направлен влево.

Виджеты Box Plot и Distributions имеют как общие черты, так и различия.

Общие черты: оба виджета демонстрируют распределение данных и имеют параметры, позволяющие настроить их поведение.

Различия: виджет Box Plot показывает основные статистические характеристики распределения данных: медиану, межквартильный размах и границы выбросов; виджет Distributions отображает более полную информацию о распределении данных - частоту появления значений в каждом интервале значений и плотности их распределения.

## 2.6. Модуль оценки эффективности классификации изображений

Набор виджетов Evaluate в программе ODM применяется для оценки моделей машинного обучения. Из данного набора мы будем использовать в алгоритме следующие виджеты: Test and Score (Тест и оценка), Confusion Matrix (Матрица путаницы) и ROC Analysis (ROC-анализ).

Виджет **Test and Score** (Тест и оценка) применяется для оценки эффективности алгоритмов машинного обучения на текущих данных. Он обучает модель на входных данных, оценивает ее и выводит результаты оценки модели.

Параметры виджета Test and Score:

- подключается входная таблица данных, на которой будет обучаться и оцениваться модель.
- виджеты, используемые для обучения и для оценки модели.
- количество фолдов для кросс-валидации модели.
- есть возможность перекрестной проверки модели на основе одного из признаков данных.

Виджет Test and Score работает следующим образом:

1. Обучает модель на определенном наборе данных.
2. Имеется возможность оценки модели либо на тестовых данных, либо на обучающем наборе данных.
3. Выводит результаты оценки модели.

Результаты оценки модели включают в себя:

- Матрицу ошибок.
- ROC-кривую.
- Площадь под ROC-кривой (AUC).
- Точность.
- Полноту.

- F-меру.

Виджет Test and Score позволяет оценить точность модели и сравнить производительность различных моделей.

Примеры использования виджета Test and Score:

- оценка модели, которая была обучена на наших данных.
- сравнение производительности различных моделей, обученных на одних и тех же данных.
- оценка обобщающей способности модели, используя перекрестную проверку.

Виджет **Confusion Matrix** (Матрица путаницы) предназначен для визуализации матрицы ошибок, которая показывает, сколько объектов были правильно и неправильно классифицированы моделью. Матрица ошибок имеет следующий формат:

	Прогнозируемый класс	Фактический класс
Положительный	Положительный $n_{tp}$	Положительный $n_{fp}$
Отрицательный	Отрицательный $n_{fn}$	Отрицательный $n_{tn}$

где:  $n_{tp}$  - количество объектов положительного класса, которые были правильно классифицированы моделью;

$n_{fp}$  - количество объектов положительного класса, которые были неправильно классифицированы моделью как отрицательные;

$n_{fn}$  - количество объектов отрицательного класса, которые были неправильно классифицированы моделью как положительные;

$n_{tn}$  - количество объектов отрицательного класса, которые были правильно классифицированы моделью.

Виджет Confusion Matrix отображает матрицу ошибок в виде таблицы. Столбцы таблицы соответствуют фактическим классам, а строки - прогнозируемым классам. Количество объектов, правильно классифицированных моделью, указано в ячейках пересечения строк и столбцов. Количество объектов, неправильно классифицированных моделью, указано в остальных ячейках.

Виджет Confusion Matrix может использоваться для следующих целей:

- оценка точности модели;
- анализ ошибок, допущенных моделью;
- сравнение производительности различных моделей.

Интерпретации матрицы ошибок:

Точность (Accuracy) — это доля объектов, которые были правильно классифицированы моделью. Она рассчитывается по формуле:

$$\text{Accuracy} = (n_{tp} + n_{tn}) / (n_{tp} + n_{fp} + n_{fn} + n_{tn})$$

Полнота (Recall) — это доля объектов положительного класса, которые были правильно классифицированы моделью. Она рассчитывается по формуле:

$$\text{Recall} = n_{tp} / (n_{tp} + n_{fn})$$

Специфичность (Specificity) — это доля объектов отрицательного класса, которые были правильно классифицированы моделью или вероятность того, что тест окажется негативным при отсутствии признака. Она рассчитывается по формуле:

$$\text{Specificity} = n_{tn} / (n_{tn} + n_{fp})$$

F-мера (F-score) — это взвешенная комбинация точности и полноты. Она рассчитывается по формуле:

$$\text{F-score} = 2 * (\text{precision} * \text{recall}) / (\text{precision} + \text{recall})$$

Выбор меры оценки зависит от конкретной задачи. Например, для задачи классификации изображений важна точность, а для задачи обнаружения ошибок важна полнота.

Виджет **ROC Analysis** (ROC-анализ) предназначен для визуализации ROC-кривой, которая показывает, как модель классифицирует объекты в зависимости от порога классификации.

ROC-кривая обычно используется для сравнения производительности различных моделей машинного обучения. Модель с более высокой ROC-кривой считается более точной. Виджет ROC Analysis отображает ROC-кривую в виде графика. На оси абсцисс отложена отрицательная вероятность, а на оси ординат - положительная вероятность. Точка на ROC-кривой соответствует одному порогу классификации.

Виджет ROC Analysis может использоваться для следующих целей:

- оценка точности модели;
- сравнение производительности различных моделей;
- выбор порога классификации, который обеспечивает наилучшее соотношение между точностью и полнотой модели.

Интерпретация ROC-кривой:

Точность (Accuracy) — это площадь под ROC-кривой. Чем больше площадь, тем точнее модель.

Полнота (Recall) — это максимальное значение положительной вероятности на ROC-кривой.

Специфичность (Specificity) — это минимальное значение отрицательной вероятности на ROC-кривой.

Выбор порога классификации:

Для задачи классификации изображений можно выбрать порог классификации, который обеспечивает максимальную точность.

Для задачи обнаружения мошенничества можно выбрать порог классификации, который обеспечивает максимальную полноту.

Виджет ROC Analysis является инструментом для оценки моделей машинного обучения, он позволяет визуально оценить точность модели и сравнить производительность различных моделей.

## **2.7. Выводы по главе 2**

Orange Data Mining мощный инструмент для работы с данными, который сочетает в себе простой визуальный интерфейс, гибкость настройки и широкий выбор функциональности.

Анализ и экспериментальные исследования известных методов сегментации полутоновых растровых изображений компьютерных томограмм показал, что они имеют определенные недостатки и не могут быть использованы непосредственно для сегментации рентгенограмм. Поэтому алгоритм сегментации должен быть построен по иерархическому принципу. На нижней иерархии должны находиться интеллектуальные агенты, обеспечивающие повышение качества сегментации за счет сокращения переходной области между сегментами и увеличение яркости пограничных пикселей.

Применяя этот метод к медицинским изображениям, медицинские работники могут повысить точность диагностики, оптимизировать планы лечения и в конечном итоге улучшить результаты пациентов. Кроме того, понимание, полученное в результате этого анализа, может способствовать разработке новых технологий медицинской визуализации и достижений в области радиологии.

Оценку вероятности диагностической ошибки при распознавании изображения пневмонии выполняется с помощью Confusion Matrix (Матрицы путаницы), где столбцы матрицы — прогнозируемые значения целевой

переменной, то есть диагноз, поставленный по результатам распознавания изображения; строки — фактические (результатирующие) показатели, то есть морфологическая верификация процесса.

Процесс деятельности врача в условиях разработки, внедрения и использования искусственного интеллекта не должен быть линейным, то есть конечным. Это означает следующее: постоянно пополняемая база данных и увеличение количества информации в обучающей выборке сделает возможным дообучение системы для улучшения результатов; с другой стороны — отслеживая результаты верификации и формируя базу данных, врач получает дополнительный опыт, углубляет знания, особенно в случаях с нетипичной визуализационной картины. Данный подход является предпосылкой реструктуризации деятельности отделения и перехода к научно-практической ориентации специалистов лучевой диагностики в медицинских учреждениях.

## **ГЛАВА 3. ИНТЕЛЛЕКТУАЛЬНЫЙ АНАЛИЗ РАСПОЗНАВАНИЯ ПНЕВМОНИИ**

### **3.1. Описание базы данных**

Для тестирования алгоритма мы использовали изображения из следующих баз данных: Chest X-Ray Images (Pneumonia) и Tuberculosis (TB) Chest X-ray Database [12, 13]. Общее количество снимков — 300: 100 снимков пневмонии и 100 снимков с нормальным изображением из базы Chest X-Ray Images (Pneumonia) (Рентгенограммы грудной клетки (пневмония)) и 100 снимков из базы Tuberculosis (TB) Chest X-ray Database (База данных рентгенографии органов грудной клетки по туберкулезу (ТБ)).

**Chest X-Ray Images (Pneumonia)** - эта база данных была создана исследователями из Университета штата Пенсильвания в 2020 году [12]. Она



содержит 4273 изображения легких, полученных с помощью рентгенографии грудной клетки. Изображения разделены на три класса:

- бактериальная пневмония (1084 изображения);
- вирусная пневмония (2189 изображений);
- нормальные изображения (1000 изображений).

**Tuberculosis (TB) Chest X-ray Database** - данная база данных была создана исследователями из Национального института аллергии и инфекционных заболеваний США в 2019 году [13]. Она содержит 6892 изображения легких, полученных с помощью рентгенографии грудной клетки. Изображения разделены на три класса:

- туберкулез (1036 изображений)
- изображения без патологии (1583 изображения)
- другие заболевания (4273 изображения)

Все изображения в базах данных Chest X-Ray Images (Pneumonia) и Tuberculosis (TB) Chest X-ray Database имеют следующие характеристики: размер: 1024x1024 пикселей, формат: PNG, глубина цвета: 12 бит на пиксель, т.е. 4096 оттенков серого цвета [12, 13]. Все они были получены от пациентов, проходивших обследование в различных медицинских учреждениях, и проверены на качество и пригодность для использования в исследованиях машинного обучения.

Обе базы данных являются ценными ресурсами для исследований машинного обучения в области диагностики заболеваний легких. Они могут быть использованы для разработки алгоритмов автоматической диагностики пневмонии и туберкулеза, что позволит улучшить качество диагностики и снизить риск ошибок. Однако следует отметить, что эти базы данных имеют некоторые ограничения. Во-первых, они содержат относительно небольшое количество изображений. Во-вторых, изображения были получены в

различных медицинских учреждениях с использованием различных методов рентгенографии грудной клетки. Все это может привести к различиям в качестве изображений и в характере патологических изменений. Перед загрузкой совокупности всех изображений в наш алгоритм, они были обработаны на подавление шума (раздел 1.2).

### **3.2. Алгоритм распознавания медицинских изображений**

Виджеты обучения, представленные в главе 2 являются важными ресурсами для исследований машинного обучения в области диагностики заболеваний. Модульный алгоритм распознавания изображений представлен на рисунке 9.

Ключевым виджетом алгоритма является «Image Embeddings». По сути, это математическое представление набора точек данных в пространстве более низкой размерности, которое фиксирует их основные отношения и закономерности. Данный виджет необходим для создания вектора признаков каждого изображения таким образом, чтобы алгоритмы машинного обучения могли вычислять расстояния между векторами (см. раздел 2.3).

Другим ключевым виджетом алгоритма является «Distances». Его назначение состоит в вычислении расстояний между строками или столбцами в наборе данных. По умолчанию данные являются нормализованными, поскольку это обеспечивает равное рассмотрение отдельных функций. Нормализация всегда выполняется по столбцам. Разреженные данные можно использовать только с евклидовой, манхэттенской и косинусной метрикой (раздел 2.4). Полученная матрица расстояний может быть передана далее в иерархическую кластеризацию для обнаружения групп в данных, в карту расстояний или матрицу расстояний для визуализации расстояний (матрица расстояний может работать довольно медленно для больших наборов данных). Матрица расстояний может быть передана в виджет многомерного

шкалирования MDS (англ.: multidimensional scaling) для сопоставления экземпляров данных с помощью матрицы расстояний (см. разделы 2.3 и 2.4).

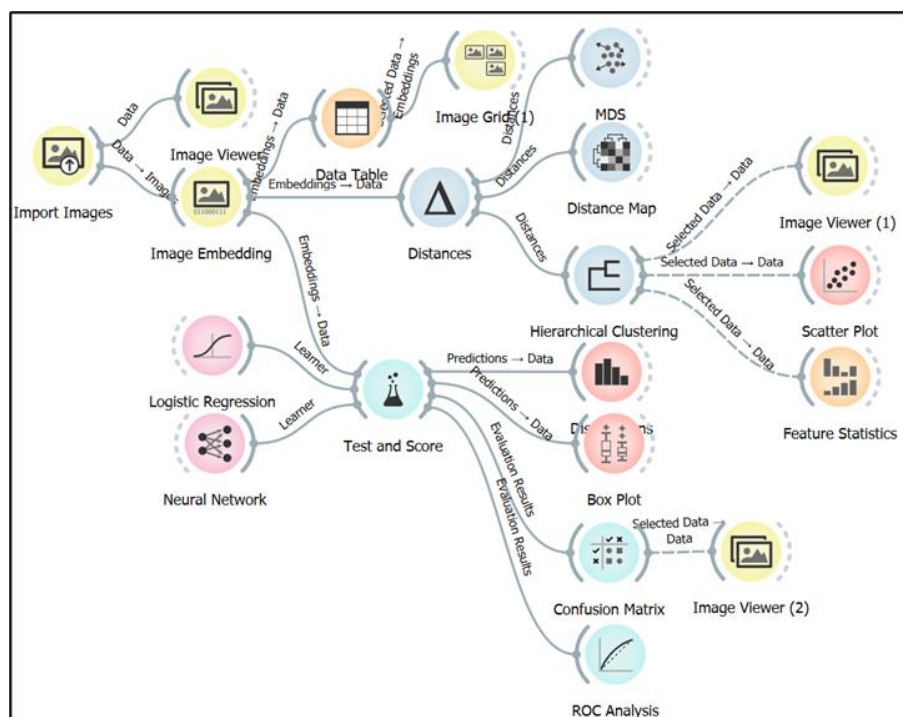


Рисунок 9. Алгоритм интеллектуального анализа изображений.

В качестве функции активации ГО была использована функция ReLu при числе нейронных слоев равным 280. Для сегментации легочной ткани применили алгоритм, использующий метод каскадных окон. После выделения всех объектов, соответствующих диапазону плотностей, результатом сегментации было множество выделенных объектов – кандидатов в патологию. Поскольку сегментация основана на показателях шкалы Хаунсфилда, в поле зрения могли попадать объекты, совпадающие по рентгеновской плотности с признаком «пневмония», но являющиеся при этом анатомическими объектами (например, участками сосудов). Для выделения сосудов и других плотных объектов в массиве сегментированной легочной ткани использовался так называемый алгоритм заливки (flood fill): многоуровневая процедура порогового определения на каждом слайсе [72].

Совокупность вычисленных метрических расстояний позволяет представить результаты анализа в том или ином виде. В нашем алгоритме это реализовано в виджетах «Image grid», «Distance map» и «Hierarchical clustering».

### 3.3. Результаты анализа рентгеновских изображений

Для визуализации диапазона расстояний (см. раздел 2.4), представленных в матрице, обычно используется цветовая палитра. Ниже мы визуализировали наиболее коррелирующие атрибуты (расстояния по столбцам) в наборе данных о легочных заболеваниях (Рисунок 10). Можно заметить, что в нашей выборке изображений существует три кластера данных: пневмония, туберкулез и норма каждый из которых разбивается на дополнительные кластеры.



Рисунок 10. Визуализация кластерного анализа изображений с двумя разными диагнозами и нормой.

*Image Grid (Сетка изображений).*




Рисунок 11. Фрагмент результата работы алгоритма сравнения изображений при поиске сходств и различий.

На сетке изображений - Image Grid (Рисунок 11) четко и отдельно выделяется кластер изображений с туберкулезом.

### *Confusion Matrix (Матрица ошибок)*

Для тестирования классификаторов изображения с диагнозами туберкулез и пневмония. В качестве показателей качества, характеризующих статистическую достоверность полученных критериев оценки, выбраны следующие показатели диагностическая чувствительность (ДЧ), диагностическая специфичность (ДС), диагностическая эффективность (ДЭ), прогностическая значимость положительных результатов (ПЗ+) и прогностическая значимость отрицательных результатов (ПЗ-)

		Predicted			
		1. Туберкулез	2. Пневмония	NORM	$\Sigma$
Actual	1. Туберкулез	99	1	0	100
	2. Пневмония	1	88	11	100
	NORM	2	11	87	100
$\Sigma$		102	100	98	300

Рисунок 12. Матрица ошибок.

Матрица ошибок - Confusion Matrix (Рисунок 12) показывает следующее: 99 снимков в отношении пациентов с туберкулезом определены точно. Это означает, что из 100 пациентов, которые были классифицированы как имеющие заболевание туберкулез, 99 действительно имеют это заболевание. Из 100 снимков пациентов с пневмонией, которые были классифицированы как имеющие это заболевание, 88 действительно имеют это заболевание. Из 100 снимков без патологии 87 определены точно. Исходя из того факта, что врач тоже может ошибаться, основными причинами его ошибок чаще всего бывают малые размеры патологий, в то время как причинами ошибок искусственного интеллекта являются иные причины: прилегание к средостению сосуда или плевры, слияние с ателектазированной легочной тканью, расположение узелков на фоне диффузного уплотнения легочной ткани. Таким образом, обучение алгоритма на большем количестве данных, включающем атипичные случаи, сможет сделать его диагностическую способность сопоставимой с группой врачей. Однако отсутствие статистически значимого различия не позволяет говорить об использовании алгоритма без врача [72].

Однако, стоит отметить, что модель ошибочно классифицировала одного пациента с туберкулёзом как имеющего другое заболевание, хотя он на самом деле не имел его; из больных с пневмонией одного пациента определила как больного с туберкулезом и 11 без заболевания. И среди снимков с нормой - 11 как пневмония и 1 как туберкулез.

Таким образом, развитие алгоритмов искусственного интеллекта в области диагностики легочных заболеваний достигло высоких результатов. Некоторые алгоритмы не уступают показателям врачей и могут использоваться для первичного прочтения, однако для этого требуется соответствующая нормативно-правовая основа [73]. Такие высокие показатели достигнуты благодаря тому, что мы намеренно выделили 3 класса изображений. Если бы мы выделили различные виды туберкулеза, пневмонии и добавили другие патологии, то искусственный интеллект проявил бы себя по-разному. Например, в диагностике пневмоний искусственный интеллект сталкивается с рядом сложностей и ограничений, связанных с рентгенологическими симптомами пневмонии, необходимостью доступности клинической картины, боковых проекций и широким диапазоном заболеваний для дифференциальной диагностики.

*Box Plot (Доля верных классификаций)*




Рисунок 13. Доли верных классификаций изображений.

### *Distributions (Распределение результатов прогнозирования)*

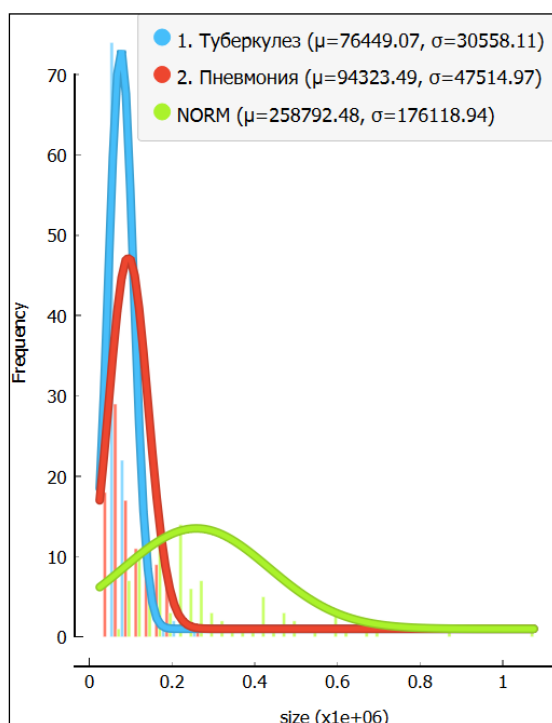


Рисунок 14. Графики нормальных распределений изображений с метками "пневмония", "туберкулез" и "норма".

### *MDS (Многомерное шкалирование)*

Исследуя отношение совокупности изображений к некоторым диагнозам (объектам), исходными данными для «классического» варианта



многомерного шкалирования служат меры близости между объектами, которые были ранее вычислены с помощью различных метрик (см. разделы 2.3 и 2.4). Алгоритм многомерного шкалирования решает задачу поиска и интерпретации латентных переменных общих факторов.

Совокупность вычисленных расстояний позволяет найти близости и различия между векторами. Близости и различия – величины обратные друг другу: чем больше близости, тем меньше различия. На Рисунок 15 мы видим, что изображения с диагнозом туберкулез образуют отдельный кластер. Изображения с признаками пневмонии и нормой образуют другой кластер, но разделены в нем по субкластерам.

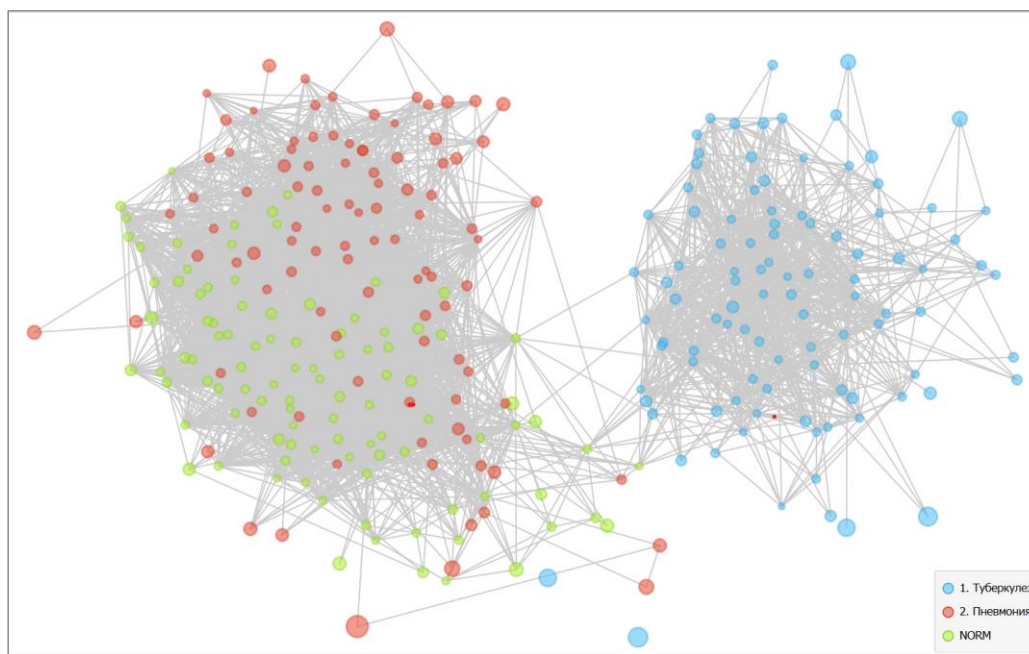


Рисунок 15. Результат работы алгоритма многомерного шкалирования MDS (Multidimensional scaling).

Результат использования алгоритма многомерного шкалирования какому классу относится объект (например, туберкулез, пневмония, норма). Отметим, что данный способ визуализации напоминает точечную диаграмму сходств.

### **3.4. Выводы по главе 3**

Разработана модульная структура алгоритма, которая включает интерфейсные элементы, сервис ввода-вывода, модуль сегментации, контроллер задач, модуль формирования окон, модуль нейросетевого моделирования. Предложенный алгоритм позволяет осуществлять классификацию изображений в условиях неопределенности координат патологии.

Сформированы обучающие и контрольные выборки для классификаторов интеллектуальной системы обработки и анализа КТ-изображений.

Проведена экспериментальная апробация программного обеспечения интеллектуальной системы по классификации заболеваний по классам «пневмония» и «туберкулез». Матрица ошибок показала, что 99 изображений из 100 с меткой «туберкулез» определены точно. Из 100 снимков пациентов с пневмонией, правильно классифицированы 88.

Объем, обширность и актуальность представляемой работы, новые подходы и методы, освещенные в ней, позволяют обоснованно считать дальнейшую разработку алгоритмов интеллектуального анализа медицинских изображений перспективным направлением. Работа отражает вектор развития мировой и российской науки в направлении развития и внедрения автоматизированных интеллектуальных систем в практику медицинских учреждений.

### **ЗАКЛЮЧЕНИЕ**

1. Разработана интеллектуальная система поддержки принятия решений по классификации КТ и рентгеновских снимков, экспериментальная апробация которой проведена на контрольных выборках по

классификации медицинских изображений по классам «пневмония», «туберкулез» и «норма» показали высокую диагностическую эффективность: около 90%.

2. Разработан метод автоматической классификации КТ-изображений с использованием сверточных нейронных сетей, получаемых путем предварительной сегментации изображения, позволяющей формировать дескрипторы только по тем пикселям, которые не маскированы маской прозрачности.
3. Научно-технические результаты могут быть использованы при клинической диагностике различных заболеваний, формировании атласов эталонных изображений анатомических объектов в процессе терапевтических воздействий. Возможность работы с удаленными пользователями, позволяет алгоритму получать для своей базы данных информацию о влиянии терапевтического воздействия на легкие.

## **СПИСОК ЛИТЕРАТУРЫ**

1. Т. Г. Авачева, М.К.А., Ю. В. Зубцова. Применение искусственного интеллекта в радиологии. in Всероссийская научно-практическая конференция с международным участием «Информационный обмен в междисциплинарных исследованиях». 2022 года. Рязанский государственный радиотехнический университет им. В.Ф. Уткина.

2. Дабагов, А.Р. Методы и алгоритмы синтеза систем искусственного интеллекта с гетерогенными интеллектуальными агентами для рентгенологических исследований в цифровой медицине. 2020.
3. Kaur, C. and U. Garg, Artificial intelligence techniques for cancer detection in medical image processing: A review. Materials Today: Proceedings, 2021.
4. Singh, M., et al., Transfer learning-based ensemble support vector machine model for automated COVID-19 detection using lung computerized tomography scan data. Med Biol Eng Comput, 2021. 59(4): p. 825-839.
5. Bi, L. and Y. Guo, Development and Validation of the Random Forest Model via Combining CT-PET Image Features and Demographic Data for Distant Metastases among Lung Cancer Patients. J Healthc Eng, 2022. 2022: p. 7793533.
6. Печников, А.А. and Н.А. Богданов. Два подхода к распознаванию пневмонии по рентгеновским снимкам: описание, реализация и сравнение. 2022. ; Available from: <https://cyberleninka.ru/article/n/dva-podhoda-k-raspoznavaniyu-pnevmonii-po-rentgenovskim-snimkam-opisanie-realizatsiya-i-sravnenie> (дата обращения: 26.02.2024).
7. Heidari, M., et al., Improving the performance of CNN to predict the likelihood of COVID-19 using chest X-ray images with preprocessing algorithms. Int J Med Inform, 2020. 144: p. 104284.
8. Косарева, А., Алгоритм подготовки набора данных для обучения нейронных сетей на примере задачи анализа радиологических изображений лёгких. Доклады Белорусского государственного университета информатики и радиоэлектроники, 2023. 21(1): p. 66-73.
9. Sailunaz, K., et al., A survey of machine learning-based methods for COVID-19 medical image analysis. Med Biol Eng Comput, 2023. 61(6): p. 1257-1297.

10. Zhang, Z. and E. Seeram, The use of artificial intelligence in computed tomography image reconstruction-a literature review. Journal of medical imaging and radiation sciences, 2020. 51(4): p. 671-677.
11. Указ Президента Российской Федерации от 09.05.2017 г. № 203 "О Стратегии развития информационного общества в Российской Федерации на 2017 – 2030 годы". 2017.
12. MOONEY, P. Chest X-Ray Images (Pneumonia). Available from: <https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia>.
13. RAHMAN, T. Tuberculosis (TB) Chest X-ray Database. Available from: <https://www.kaggle.com/datasets/tawsifurrahman/tuberculosis-tb-chest-xray-dataset>.
14. Виллевальде, А., О системном подходе к медицинской визуализации. Известия СПбГЭТУ «ЛЭТИ», 2006: p. 37.
15. Guo, K., et al., Diagnosis and detection of pneumonia using weak-label based on X-ray images: a multi-center study. BMC Medical Imaging, 2023. 23(1): p. 209.
16. Беркович, Г., et al., Сравнение различных подходов к оценке диагностического качества компьютерной томографии органов грудной клетки. Лучевая диагностика и терапия, 2020. 11(3): p. 44-55.
17. Авшаров, Е., М. Абгарян, and С. Сафарянц, Обработка медицинских изображений как необходимый инструментарий медицинского диагностического процесса. [(In Russ.)]. URL: [http://www.courseas.ru/download/pdf/Processing\\_of\\_medical\\_images.pdf](http://www.courseas.ru/download/pdf/Processing_of_medical_images.pdf). (Data obrashcheniya: 18.12. 2018), 2010.
18. Сторожилова, М.В., А.С. Лукин, and Д.В. Юрин. Методы анализа качества фильтрации шума на изображениях компьютерной томографии. Available from:

[https://imaging.cs.msu.ru/pub/2013.DSPA.Lukin\\_Storozhilova\\_Yurin.Analysis.ru.pdf](https://imaging.cs.msu.ru/pub/2013.DSPA.Lukin_Storozhilova_Yurin.Analysis.ru.pdf) (Дата обращения: 26.02.2024).

19. Калинин, Д. and Д. Ватолин, Проблема подавления шума на изображениях и видео и различные подходы к ее решению. Компьютерная графика и мультимедиа, 2005. 9(2).
20. Блюштейн Е. А. and М.А. О. Применение нерезкого маскирования для повышения резкости изображения в компьютерной томографии. Вестник СГТУ, 2012; Available from: <https://cyberleninka.ru/article/n/primeneniye-nerezskogo-maskirovaniya-dlya-povysheniya-rezkosti-izobrazheniya-v-kompyuternoy-tomografii> (дата обращения: 26.02.2024).
21. Diwakar, M. and M. Kumar, A review on CT image noise and its denoising. Biomedical Signal Processing and Control, 2018. 42: p. 73-88.
22. Казначеева, А.О. Разработка методов и средств шумоподавления в томографии. 2006; Available from: <https://www.dissercat.com/content/razrabotka-metodov-i-sredstv-shumopodavleniya-v-tomografii> (дата обращения: 26.02.2024).
23. Hu, J., et al., Super-Resolution Swin Transformer and Attention Network for Medical CT Imaging. Biomed Res Int, 2022. 2022: p. 4431536.
24. Гонсалес, Р. and Р. Вудс, Цифровая обработка изображений. 2022: Litres.
25. Ласьков, В.В. and Е.Н. Симонов. Методы фильтрации изображений в рентгеновской компьютерной томографии. Вестник ЮУрГУ. Серия: Компьютерные технологии, управление, радиоэлектроника. 2014. ; Available from: <https://cyberleninka.ru/article/n/metody-filtratsii-izobrazheniy-v-rentgenovskoy-kompyuternoy-tomografii> (дата обращения: 26.02.2024).

26. Крылов, А., et al. Анализ и повышение качества изображений: общие методы и биомедицинские приложения. Available from: <https://imaging.cs.msu.ru/pub/2022.PRIA.Lab.School.ru.pdf> (дата обращения 26.02.2024).
27. С.В. Саввин, А.А.С. Алгоритмы построения многокадрового сверхразрешения изображений в условиях аппликативных помех на основе глубоких нейронных сетей. Компьютерная оптика. 2022.; Available from: <https://cyberleninka.ru/article/n/algoritmy-postroeniya-mnogokadrovogo-sverhrazresheniya-izobrazheniy-v-usloviyah-applikativnyh-pomeh-na-osnove-glubokih-neyronnyh> (дата обращения: 26.02.2024).
28. Maiseli, B.J., O.A. Elisha, and H. Gao, A multi-frame super-resolution method based on the variable-exponent nonlinear diffusion regularizer. EURASIP Journal on Image and Video Processing, 2015. 2015(1): p. 22.
29. Никитин, О.Р. and А.С. Пасечник, Оконтуривание и сегментация в задачах автоматизированной диагностики патологий. Методы и устройства передачи и обработки информации, 2009(11): p. 300-309.
30. Дороничева, А. and С. Савин, Метод сегментации медицинских изображений. Фундаментальные исследования, 2015(5-2): p. 294-298.
31. Кокорев, П.А. Анализ артефактов изображений в компьютерной томографии. Научно-технический вестник информационных технологий, механики и оптики. 2008.; Available from: <https://cyberleninka.ru/article/n/analiz-artefaktov-izobrazheniy-v-kompyuternoy-tomografii> (дата обращения: 26.02.2024).
32. Alzain, A.F., et al., Common computed tomography artifact: source and avoidance. Egyptian Journal of Radiology and Nuclear Medicine, 2021. 52(1): p. 151.

33. Умнов А. В., К.А.С., Исследование метода разреженных представлений для подавления эффекта ложного оконтуривания. Компьютерная оптика, 2016.
34. Krylov, A. and A. Nasonov. Adaptive total variation deringing method for image interpolation. in 2008 15th IEEE International Conference on Image Processing. 2008. IEEE.
35. Nasonov, A.V. and A.S. Krylov. Adaptive image deringing. in Proceedings of GraphiCon. 2009.
36. Nasonov, A.V. and A.S. Krylov. Scale-space method of image ringing estimation. in 2009 16th IEEE International Conference on Image Processing (ICIP). 2009. IEEE.
37. Sitdikov, I. and A. Krylov, Variational image deringing using varying regularization parameter. Pattern Recognition and Image Analysis, 2015. 25: p. 96-100.
38. Umnov, A. and A. Krylov, Sparse approach to image ringing detection and suppression. Pattern Recognition and Image Analysis, 2017. 27: p. 754-762.
39. Umnov, A.V., A.S. Krylov, and A.V. Nasonov. Ringing artifact suppression using sparse representation. in Advanced Concepts for Intelligent Vision Systems: 16th International Conference, ACIVS 2015, Catania, Italy, October 26-29, 2015. Proceedings 16. 2015. Springer.
40. Umnov, A.V., et al. Sparse method for ringing artifact detection. in 2014 12th International Conference on Signal Processing (ICSP). 2014. IEEE.
41. Penkin, M., A. Krylov, and A. Khvostikov. Attention-based convolutional neural network for MRI Gibbs-ringing artifact suppression. in CEUR Workshop Proceedings. 2020.
42. Penkin, M.A., A.S. Krylov, and A.V. Khvostikov, Hybrid method for Gibbs-ringing artifact suppression in magnetic resonance images. Programming and Computer Software, 2021. 47(3): p. 207-214.



43. Насонова, А.А. Деформационный метод повышения разрешения изображений с сохранением резкости границ. Available from: <https://imaging.cs.msu.ru/pub/2014.DSPA.Nasonova.IntWarping.ru.pdf> (дата обращения: 26.02.2024).
44. Беззубик В. В., Б.Н.Р., Вдовин Г. В., Кармановский Н. С., Соловьев О. А. , Метод повышения резкости цифровых изображений. Научно-технический вестник информационных технологий, механики и оптики. , 2014.
45. Насонова, А.А. Методы повышения качества изображений путем деформации координатной сетки окрестностей границ. 2015; Available from: <https://www.dissercat.com/content/metody-povysheniya-kachestva-izobrazhenii-putem-deformatsii-koordinatnoi-setki-okrestnostei?ysclid=lt1of5a28e700046193>.
46. Nasonova, A. and A. Krylov, Deblurred images post-processing by Poisson warping. IEEE Signal Processing Letters, 2014. 22(4): p. 417-420.
47. Nasonov, A., A. Nasonova, and A. Krylov. Edge width estimation for defocus map from a single image. in Advanced Concepts for Intelligent Vision Systems: 16th International Conference, ACIVS 2015, Catania, Italy, October 26-29, 2015. Proceedings 16. 2015. Springer.
48. Krylov, A., A. Nasonov, and Y. Pchelintsev. Single parameter post-processing method for image deblurring. in 2017 Seventh International Conference on Image Processing Theory, Tools and Applications (IPTA). 2017. IEEE.
49. Krylov, A., A. Nasonova, and A. Nasonov, Image enhancement by non-iterative grid warping. Pattern Recognition and Image Analysis, 2016. 26: p. 161-164.
50. Довганич, А.А. Адаптивные методы обработки медицинских изображений. 2022; Available from:

<https://www.dissercat.com/content/adaptivnye-metody-obrabotki-meditsinskikh-izobrazhenii>.

51. Крылов, А.С., Методы выделения хребтовых структур на изображениях. . 2016.
52. Мамаев, Н., Д. Юрин, and А. Крылов. Нахождение параметров метода шумоподавления с использованием вейвлет-преобразования на медицинских изображениях на основе анализа хребтовых структур. in Труды Международной конференции по компьютерной графике и зрению" Графикон".-Федеральное государственное учреждение" Федеральный исследовательский центр Институт прикладной математики им. МВ Келдыша Российской академии наук". 2018.
53. Круглов, В.Н. Цифровая обработка изображений. 2007; Available from: <https://studfile.net/preview/1874427/page:4/>.
54. Н.В. Мамаев, Д.В. Юрин, and А.С. Крылов, Нахождение параметров метода нелинейного диффузионного подавления шума на изображениях на основе анализа хребтовых структур.
55. Фаридоддин, Ш., et al., Применение модели внешнего вида текстуры для сегментации легочных узлов при компьютерной томографии грудной клетки. Известия высших учебных заведений России. Радиоэлектроника, 2022. 25(3): p. 96-117.
56. Mamaev, N. and A. Krylov, Using anisotropic diffusion in the multiscale ridge detection method. Computational Mathematics and Modeling, 2019. 30: p. 191-197.
57. Perona, P. and J. Malik, Scale-space and edge detection using anisotropic diffusion. IEEE Transactions on pattern analysis and machine intelligence, 1990. 12(7): p. 629-639.
58. Safronova, E. and E. Pavelyeva. Unsupervised palm vein image segmentation. in CEUR Workshop Proceedings. 2020.

59. Tikhonova, V. and E. Pavelyeva. Hybrid iris segmentation method based on CNN and principal curvatures. in CEUR Workshop Proceedings. 2020.
60. Sagindykov, T.B. and E.A. Pavelyeva, Human image matting based on convolutional neural network and principal curvatures. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2021. 44: p. 183-187.
61. Ковалев, В., Анализ текстуры трехмерных медицинских изображений. 2022: Litres.
62. Ветров, А. and Ч. Мутумбиша. Совмещение рентгеновских и фрагментированных инфракрасных изображений в медицинской диагностике. in Современные технологии в науке и образовании-СТНО-2017. 2017. 2017.
63. Сергеев, А.М., О совмещении изображений и способах их реализации. Инженерный вестник Дона, 2022.
64. Юрин Д. В., К.А.С., Волегов Д. Б., Насонов А. В., and С.Н. В. Методы и алгоритмы совмещения изображений и их применение в задачах восстановления трехмерных сцен и панорам, анализе медицинских изображений in Труды 13-я Всероссийской конференции Математические методы распознавания образов. Ленинградская обл., г. Зеленогорск. 2007.
65. Г. В. Сыроежкин, А. Б. Савинецкий, and А.М. Маурер, Методы создания обобщенного изображения по опорным точкам. Вестник РГРТУ, 2017.
66. Evans, С., Обнаружение устойчивых признаков изображения: метод SURF 2012.
67. Engines, S. Шум в компьютерной томографии: правда ли он нам мешает? 2023 Available from: <https://habr.com/ru/companies/smartengines/articles/741796/>.

68. Юсупов, Н., А. Савельева, and О. Леонова, Исследование методов классификации в программе Orange. Молодежная школа-семинар по проблемам управления в технических системах имени АА Вавилова, 2020. 1: p. 27-30.
69. Дюдин, М., С. Филист, and П. Кудрявцев, Способ выделения и классификации контуров легких на изображениях флюорограмм грудной клетки. Научные технологии, 2014. 15(12): p. 25-30.
70. Филист, С.А., et al., Многослойные морфологические операторы для сегментации сложноструктурируемых растровых полутоновых изображений. Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение, 2019. 9(3): p. 44-63.
71. Метрики расстояния для машинного обучения — 15 примеров с кодом. 2023.
72. Мелдо, А.А. Разработка и внедрение системы искусственного интеллекта в лучевой диагностике очаговых образований в легких. 2021; Available from: <https://search.rsl.ru/ru/search#q=%D0%BC%D0%B5%D0%BB%D0%B4%D0%BE>.
73. Морозов, С., et al., Клинические аспекты применения искусственного интеллекта для интерпретации рентгенограмм органов грудной клетки. Туберкулез и болезни легких, 2021. 99(4): p. 58-64.



АНТИПЛАГИАТ  
ОБНАРУЖЕНИЕ ЗАИМСТВОВАНИЙ

## СПРАВКА

о результатах проверки текстового документа  
на наличие заимствований

Башкирский государственный медицинский  
университет

ПРОВЕРКА ВЫПОЛНЕНА В СИСТЕМЕ АНТИПЛАГИАТ.ВУЗ

Автор работы: Гильмиярова М. Н.  
Самоцитирование  
рассчитано для: Гильмиярова М. Н.  
Название работы: РАЗРАБОТКА АЛГОРИТМА ИНТЕЛЛЕКТУАЛЬНОГО АНАЛИЗА РАСПОЗНАВАНИЯ ПНЕВМОНИИ  
Тип работы: Выпускная квалификационная работа  
Подразделение: Башкирский Государственный Медицинский Университет

### РЕЗУЛЬТАТЫ

■ ОТЧЕТ О ПРОВЕРКЕ КОРРЕКТИРОВАЛСЯ: НИЖЕ ПРЕДСТАВЛЕНЫ РЕЗУЛЬТАТЫ ПРОВЕРКИ ДО КОРРЕКТИРОВКИ

СОВПАДЕНИЯ	18.58%	СОВПАДЕНИЯ	15.23%
ОРИГИНАЛЬНОСТЬ	64.59%	ОРИГИНАЛЬНОСТЬ	80.96%
ЦИТИРОВАНИЯ	16.84%	ЦИТИРОВАНИЯ	3.82%
САМОЦИТИРОВАНИЯ	0%	САМОЦИТИРОВАНИЯ	0%

ДАТА ПОСЛЕДНЕЙ ПРОВЕРКИ: 19.06.2024

ДАТА И ВРЕМЯ КОРРЕКТИРОВКИ: 09.07.2024 12:07

Структура  
документа:  
Модули поиска:

Проверенные разделы: библиография с.59-67, титульный лист с.1, содержание с.2-3, раздел не определен с.4-58  
Интернет Плюс\*; Шаблонные фразы; Переводные заимствования\*; Цитирование; ИПС Адилет; Библиография; Медицина; Коллекция НБУ; Публикации eLIBRARY; Перефразированные заимствования по коллекции Интернет в английском сегменте; Диссертации НББ; Патенты СССР, РФ, СНГ; СМИ России и СНГ; Переводные заимствования по коллекции Интернет в английском сегменте; Переводные заимствования (RuEn); Переводные заимствования по Интернету (EnRu); Переводные заимствования IEEE; Перефразирования по коллекции IEEE; СПС ГАРАНТ: перефразирования по Интернету; Перефразирования по коллекции IEEE; СПС ГАРАНТ: нормативно-правовая документация; Издательство Wiley; СПС ГАРАНТ: аналитика; Публикации РГБ; Перефразированные заимствования по коллекции Интернет в русском сегменте;

Работу проверил: Банникова Ольга Сергеевна

ФИО проверяющего

Дата подписи:

10.07.2024

ФГБОУ ВО БГМУ  
Минздрава России  
НАУЧНАЯ БИБЛИОТЕКА

Подпись проверяющего



Чтобы убедиться  
в подлинности справки, используйте QR-код,  
который содержит ссылку на отчет.

Ответ на вопрос, является ли обнаруженное заимствование  
корректным, система оставляет на усмотрение проверяющего.  
Предоставленная информация не подлежит использованию  
в коммерческих целях.