

На правах рукописи



**Хамад Юсиф Ахмед**

**РАЗРАБОТКА И ИССЛЕДОВАНИЕ АЛГОРИТМОВ СЕГМЕНТАЦИИ И  
РАСПОЗНАВАНИЯ ОБЪЕКТОВ НА МЕДИЦИНСКИХ ИЗОБРАЖЕНИЯХ НА  
ОСНОВЕ ШИАРЛЕТ-ПРЕОБРАЗОВАНИЯ И НЕЙРОННЫХ СЕТЕЙ**

Специальность 05.13.17 – Теоретические основы информатики

**АВТОРЕФЕРАТ**

диссертации на соискание ученой степени  
кандидата технических наук

Красноярск – 2020

Работа выполнена в Федеральном государственном автономном образовательном учреждении высшего образования «Сибирский федеральный университет», г. Красноярск

Научный руководитель: доктор технических наук,  
**Симонов Константин Васильевич**

Официальные оппоненты: **Гергет Ольга Михайловна**, доктор технических наук, доцент, Федеральное государственное автономное образовательное учреждение высшего образования «Национальный исследовательский Томский политехнический университет», отделение информационных технологий, профессор

**Горнов Александр Юрьевич**, доктор технических наук, Федеральное государственное бюджетное учреждение науки Институт динамики систем и теории управления имени В.М. Матросова Сибирского отделения Российской академии наук, отделение эволюционных уравнений и управляемых динамических систем, главный научный сотрудник

Ведущая организация: Федеральное государственное автономное образовательное учреждение высшего образования «Новосибирский национальный исследовательский государственный университет»

Защита состоится «29» сентября 2020 года в 14.00 часов на заседании диссертационного совета Д 212.099.22, созданного на базе Сибирского федерального университета по адресу: 660074, г. Красноярск, ул. Киренского, 26, ауд. УЛК 112.

С диссертацией можно ознакомиться в библиотеке и на сайте Сибирского федерального университета по адресу <http://www.sfu-kras.ru/>

Автореферат разослан «\_\_» августа 2020 г.

Ученый секретарь  
диссертационного совета



Покидышева Людмила Ивановна

## ОБЩАЯ ХАРАКТЕРИСТИКА РАБОТЫ

**Актуальность работы.** В последнее десятилетие активно развивается аппаратное обеспечение в экспериментальных медицинских исследованиях, появляются все более совершенные и сложные приборные комплексы. В то же время известные алгоритмические средства не вполне соответствуют требованиям по быстродействию и качеству обработки сложных визуальных данных, регистрируемых вновь создаваемыми аппаратными средствами, а также возможностям для решения новых актуальных задач геометрического (морфологического, текстурного) анализа данных, основанного на вейвлет- и шпурлет-преобразованиях. В настоящее время делаются попытки комплексного использования искусственных систем обработки информации, структурно отражающих функционирование биосистем. Особое внимание при этом уделяется разработке моделей, методов и алгоритмов, всесторонне учитывающих специфику объекта исследования.

Для решения новых задач необходимо модифицировать и разработать вычислительную технологию геометрического (морфологического, текстурного) анализа визуальных данных за счет обеспечения выбора алгоритмов сегментации и машинного обучения в виде вероятностной нейронной сети (PNN), что позволит повысить точность выделения линейных структур, визуальное качество изображений изучаемых объектов и их контуров. Актуальными также являются теоретические и прикладные исследования по усовершенствованию алгоритмов, связанных с применением нейронных сетей в рамках единой вычислительной технологии для решения задач оценки состояния объекта (выявление и классификация патологий и новообразований) на медицинских изображениях: СХР-сканирование (рентгенография грудной клетки), КТ (компьютерная томография) и МРТ (магнитно-резонансная томография) снимки.

**Целью диссертационной работы** является повышение точности алгоритмов сегментации и распознавания объектов на изображениях для визуализации и интерпретации экспериментальных медицинских данных.

Для достижения цели поставлены следующие **задачи**:

1. Разработать и исследовать метод сегментации локальных областей (с патологией) на медицинских изображениях МРТ и КТ.
2. Разработать и исследовать быстрый алгоритм классификации локальных областей в комплексной диагностике (на примере злокачественных новообразований молочной железы и головного мозга).
3. Разработать и исследовать высокоточный метод обнаружения границ объектов на основе модифицированного метода сегментации.
4. Разработать вычислительную методику для выделения объектов и распознавания патологии на изображениях рентгенографии грудной клетки (СХР) и КТ.
5. Провести экспериментальные исследования по оценке результативности разработанных метода, алгоритмов в рамках комплексного медицинского эксперимента.

**Методы исследования.** Для решения поставленных в работе задач использовались методы теории цифровой обработки изображений, теории информации, методы теории распознавания образов и анализа данных, методы объектно-ориентированного программирования.

**Научная новизна.** При решении поставленных в диссертационной работе задач получены следующие новые научные результаты:

1. Разработан **новый метод** автоматической сегментации по отдельным объектам, отличающейся использованием комбинации порогового значения Оцу и нечеткой кластеризации, который позволяет улучшить точность выделения отдельных объектов и классификации (на примере опухолей головного мозга и молочной железы).

2. Разработаны **методика и алгоритмическое обеспечение** обработки и анализа изображений СХР и КТ, отличающиеся введением конкурентного уровня и дополнительных шагов для определения новых функций CPNN на основе метода машинного обучения, что позволяет повысить точность определения границ легких и уменьшить ошибки распознавания патологии на изображениях СХР и КТ.

3. Разработан **способ** обнаружения и визуализации контуров, отличающийся использованием модифицированного шварц-преобразования (алгоритм FFST), который позволяет анализировать геометрические (морфологические, текстурные) особенности изображений (на примере оценки скорости роста тканей на имплантатах в медицинском эксперименте).

**Практическая значимость.** Разработанные метод и алгоритмы сегментации и распознавания позволяют повысить эффективность обнаружения злокачественной опухоли на изображениях КТ и МРТ, а также повысить качество обнаружения патологий на рентгеновских снимках грудной клетки. Результаты обработки и анализа визуальных данных в экспериментальных исследованиях в герниопластике позволяют повысить качество поиска и описания соответствующих объектов, что вносит существенный вклад в обеспечение эффективности методов количественной гистологии.

#### **Положения, выносимые на защиту.**

1. Метод автоматической сегментации отдельных объектов на медицинских изображениях.

2. Алгоритм классификации локальных объектов (на примере опухолей головного мозга и молочной железы) на изображениях МРТ и КТ.

3. Методика и алгоритмическое обеспечение высокоточного выделения границ объектов (легких) и распознавания патологии на изображениях СХР и КТ.

4. Способ обнаружения и контрастирования контуров объектов на изображении на основе шварц-преобразования (модифицированный алгоритм FFST).

**Внедрение результатов диссертационной работы.** Результаты диссертационного исследования переданы на кафедры общей хирургии и урологии КрасГМУ, в Центр инновационной деятельности и грантовой поддержки СНКЦ ФМБА России. Также результаты диссертационного исследования внедрены в учебный процесс кафедры прикладной математики и компьютерной безопасности Института космических и информационных технологий СФУ. Оформлены документы для регистрации двух программ для ЭВМ в Роспатенте.

**Апробация работы.** Основные положения и результаты диссертационной работы представлялись на международных и всероссийских конференциях: Всероссийской научно-технической конференции студентов, аспирантов и молодых учёных (Красноярск, 2018-2019); XXI Всероссийском семинаре «Моделирование неравновесных систем» (Красноярск, 2018); XXVI Всероссийском семинаре «Нейроинформатика, её приложения и анализ данных» (Красноярск, 2019); XIX Всероссийском симпозиуме с международным участием «Сложные системы в экстремальных условиях» (Красноярск, 2018); Марчуковские чтения: Международной конференции «Актуальные проблемы вычислительной и прикладной математики»

(Новосибирск, 2019); 22rd International Conference on Knowledge-Based and Intelligent Information & Engineering Systems (Белград, Сербия, сентябрь 2018); 23rd International Conference on Knowledge-Based and Intelligent Information & Engineering Systems (Будапешт, Венгрия, сентябрь 2019); 1st International Conference on Information and Sciences (AiCIS, Ирак, 2018); 9th International Conference on Information Systems and Technologies (АСМ, Египет, 2019); International Conference on Applied Computing to Support Industry: Innovation and Technology (ACRIT, Ирак, 2019), а также на научных семинарах в ИКИТ СФУ (2018–2020).

**Соответствие диссертации паспорту специальности.** Диссертационное исследование соответствует области исследований специальности 05.13.17 – Теоретические основы информатики по п. 5. «Разработка и исследование моделей и алгоритмов анализа данных, обнаружения закономерностей в данных и их извлечениях, разработка и исследование методов и алгоритмов анализа текста, устной речи и изображений» и п. 7. «Разработка методов распознавания образов, фильтрации, распознавания и синтеза изображений, решающих правил».

**Публикации.** Результаты диссертационного исследования опубликованы в 23 печатных работах, из них 10 статей в журналах, рекомендованных ВАК, 7 публикаций в изданиях, индексируемых в базе SCOPUS и WoS, 6 статей опубликованы в научно-технических журналах и сборниках, в трудах научных конференций. Вклад автора в статьи 1-4 составляет 75%, в статьи 5-10 составляет 70%; в статьи 11-17 составляет 85 %; в статьи 18-23 составляет 65%.

**Структура и объем диссертации.** Диссертация состоит из введения, четырех глав, заключения и приложений. Полный объем диссертации – 171 страницы текста, включая 39 рисунков и 21 таблицу. Список использованных источников содержит 186 позиции.

**Благодарности.** Автор глубоко признателен профессору д.ф.-м.н. Носкову М.В. и профессору, д.т.н. Симонову К.В., которые оказали большое влияние на формирование научных взглядов соискателя, за поддержку и внимание к диссертационной работе. Также автор выражает благодарность коллегам и участникам совместных исследований: доценту к.т.н. А.Г. Зотину, М.А. Курако и специалистам медикам: д.м.н. Ф.П. Капсаргину, Е.М. Кабаеву, А.С. Кенц, Т.В. Черепановой.

## СОДЕРЖАНИЕ РАБОТЫ

Во **Введении** обоснована актуальность работы, сформулирована цель и поставлены задачи исследования, показана научная новизна и практическая ценность выполненных исследований, представлены основные положения, выносимые на защиту.

**В первой главе** рассмотрены современные математические модели и методы обработки медицинских изображений для мониторинга и прогнозирования на основе компьютерных диагностических систем и распознавания образов. Приводятся краткие описания методов систем компьютерной диагностики и некоторые общие подходы к оценке алгоритмов классификации патологий на рентгенограммах грудной клетки (СХР) и компьютерной томографии (КТ). Демонстрируется идея, лежащая в основе применения матрицы когерентности серого (GLCM) и дискретного вейвлет-преобразования (DWT), для извлечения признаков. Принцип компонентного анализа (РСА) описан как один из эффективных методов извлечения и восстановления характеристик. Представлен обзор различных подходов к применению алгоритмов машинного обучения и шварлет-преобразования для решения задач обработки и

анализа визуальных медицинских данных. Результаты первой главы опубликованы в [1-4, 6-7, 11, 18], а также использовались в работах [5, 12-13, 19, 22] для выделения контуров объектов, сегментации и классификации их на изображениях.

**Вторая глава** посвящена разработке метода сегментации объектов и алгоритма классификации (на примере опухолей) МРТ-изображений на основе использования дополнительных разработанных вычислительных процедур.

Рассмотрим пороговую итеративную сегментацию объектов на изображении МРТ. Известно, что сложно выбрать подходящий глобальный порог для получения идеального начального контура из-за различий в уровнях серого в области патологии (на примере опухоли мозга и молочной железы), а также для неинфицированной области.

Разработан **метод пороговой итерации** для выполнения сегментации объектов (опухолей) и не инфицированных областей (головного мозга и молочной железы) на изображениях МРТ и КТ на основе улучшенных алгоритмов Оцу и нечеткой кластеризации С-средних, как показано на рисунке 1.

Пусть интенсивность изображения выражается в  $L$  уровнях серого  $[1, 2, \dots, L]$ . оличество точек с уровнем серого  $p(i)$  обозначается через  $x_i$ , а все количество точек может быть выражено как  $X = x_1 + x_2 + \dots + x_L$ , гистограмма этого изображения уровня серого рассматривается как распределение вероятности возникновения:

$$p(i) = \frac{x_i}{X}, x_i \geq 0, \sum_{i=1}^L x_i = 1. \quad (1)$$

Пиксели изображения делятся на две части  $C_0$  и  $C_1$ , передний план и задний фон с пороговым значением  $t$ , где  $C_0$  повторно представляет пиксели в пределах уровней  $[1, 2, \dots, t]$ , а  $C_1$  – обозначает пиксели в пределах уровней  $[t + 1, \dots, L]$ . Вероятности возникновения этого класса и среднего могут быть выражены, соответственно:

$$w_0 = w(t) = \sum_{i=1}^t p(i), \quad (2)$$

$$w_1 = 1 - w(t) = \sum_{i=t+1}^L p(i), \quad (3)$$

$$\mu_0 = \sum_{i=1}^t \frac{i \cdot p(i)}{w_0} = \frac{1}{w(t)}, \quad (4)$$

$$\mu_1 = \sum_{i=t+1}^L \frac{i \cdot p(i)}{w_1} = \frac{1}{1-w(t)} \sum_{i=t+1}^L i \cdot p(i). \quad (5)$$

Общее среднее можно записать в виде:

$$\mu_T = \sum_{i=1}^L i \cdot p(i). \quad (6)$$

и далее можем найти:

$$\mu_T = w_0 \mu_0 + w_1 \mu_1, \quad (7)$$

где  $w_0$  и  $w_1$  – обозначают вероятности переднего и фонового участков. Кроме того,  $\mu_0$ ,  $\mu_1$  и  $\mu_T$  относятся к среднему уровню серых уровней переднего плана серого изображения, фонового изображения серого изображения и всего изображения уровня серого.

Вариант между классами  $\sigma_B^2$  из двух частей  $C_0$  и  $C_1$  может быть перезаписан как:

$$\sigma_B^2 = w_0 (\mu_0 - \mu_T)^2 + w_1 (\mu_1 - \mu_T)^2, \quad (8)$$

а порог качества  $t^*$  выбирается по максимизации  $\sigma_B^2$ :

$$t^* = \arg \max \sigma_B^2, 1 \leq t \leq L. \quad (9)$$

Когда распределение для класса  $C_k$  ( $k = 0$  или  $1$ ) находится между областями с различными характеристиками, известно, что медианное значение является надежным оценочным значением по сравнению со средним уровнем серого. Тогда находим, что медианное значение замещения среднего может получить как  $t^*$ , что достаточно

обоснованно с учетом наличия распределения  $C_K$  по сравнению с этими порогами, выбранным алгоритмом Оцу. Следовательно, можем заменить общее среднее значение  $\mu_T$  суммарным медианным уровнем  $m_T$  всех точек на всем изображении уровня серого. Аналогично среднему значению  $\mu_T$  всего изображения, средние значения  $\mu_0$  и  $\mu_1$  также могут быть заменены срединными уровнями серого  $m_0$  и  $m_1$  передней части  $C_0$  и задней части  $C_1$ , соответственно.



Рисунок 1 – Блок-схема разработанного метода пороговых нечетких С-средних

Вариант между классами  $\sigma_B^2$  из двух частей  $C_0$  и  $C_1$  может быть перезаписан как:

$$\sigma_B^2 = w_0 (m_0 - m_T)^2 + w_1 (m_1 - m_T)^2, \quad (10)$$

а порог качества  $t^*$  выбирается по максимизации  $\sigma_B^2$ :

$$t^* = \arg \max \sigma_B^2, \quad 1 \leq t \leq L. \quad (11)$$

При этом точность классификации объектов зависит от качества сегментации и извлеченных признаков.

Предложен **алгоритм классификации** объектов (опухолей мозга и молочной железы) с использованием разработанного метода сегментации, дискретного вейвлет-преобразования (DWT) и матрицы взаимодействия уровня серого (GLCM). Вейвлет используется для анализа различных частот изображения в разных масштабах. Вейвлет локализует частотную информацию о функции, что важно для классификации. Применено дискретное вейвлет-преобразование, которое привело к четырем поддиапазонам LL (низкая), HL (высокая-низкая), LH (низкая-высокая), HH (высокая), с двухуровневым вейвлет-разложением области интереса (ROI). При разложении изображения на 2D-уровень отображается аппроксимация с подробными тремя изображениями, представляющими низкочастотное и высокочастотное

содержимое изображения, соответственно. Различные частотные компоненты и каждый компонент изучены с разрешением, соответствующим его масштабу, и выражены следующим образом:

$$DWT_{p(s)} = \begin{cases} di, j = \sum p(s)h * i(s - 2ij) \\ di, j = \sum p(s)g * i(s - 2ij) \end{cases} \quad (12)$$

Коэффициенты  $d_{i,j}$  относятся к атрибуту компонента в сигнале  $p(s)$ , соответствующему функции вейвлета, в то время как  $d_{i,j}$  относятся к приближенным компонентам в сигнале. Функции  $h(s)$  и  $g(s)$  в уравнении представляют собой коэффициенты фильтра высоких и низких частот, соответственно, а параметры  $i$  и  $j$  относятся к шкале вейвлетов и коэффициентам перевода.

Матрица кооперации уровня серого (GLCM) является надежным способом статистического анализа изображений. Используется для оценки характеристик изображений по статистике второго порядка. Матрица GLCM определяется как двумерная матрица совместной вероятности между парами пикселей над изображением ( $I$ ) как распределение совместно встречающихся значений при заданном смещении ( $dx, dy$ ) для изображения размером  $N \times M$ :

$$C_{dx,dy}(i, j) = \sum_{p=1}^N \sum_{q=1}^M \begin{cases} 1, & \text{if } I(p, q) = i \text{ and } I(p + dx, q + dy) = j \\ 0, & \text{otherwise} \end{cases} \quad (13)$$

Извлеченные особенности: Энергия (F1), Контраст (F2), Корреляция (F3), Автокорреляция (F4), Энтропия (F5), Гомогенность (F6), Несоответствие (F7), Кластерный оттенок (F8), Протуберанец кластера (F9), Максимальная вероятность (F10), Сумма квадрата (F11), Момент обратной разности (F12), Суммарное среднее (F13), Суммарное отклонение (F14), Суммарная энтропия (F15), Различное отклонение (F16), Различная энтропия (F17) и Информационное измерение корреляции (F18).

Для получения лучших результатов классификации сгенерированы матрицы GLCM для различных смещений (от 2 до 4 пикселей) и углов ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  и  $135^\circ$ ). Выделенные признаки (на основе области объекта – опухоли) и выбранные из сегментированных изображений, а затем классифицированы с использованием методов нейронной сети для диагностики наличия у пациента доброкачественной опухоли или злокачественной опухоли. Реализация комбинации методов повышает точность результатов расчета. В результате разработанный метод сегментации и извлеченные признаки дают хорошие оценки, которые обеспечивают высококачественные изображения для анализа медицинским специалистом. Выполнена верификация метода сегментации и предложенного алгоритма классификации в рамках медицинского эксперимента (в случаях патологии).

Показано, что метод сегментации позволяет повысить скорость, а также точность сегментации объектов – на 2-3%, по сравнению с современными методами сегментации (2016-2019 гг.) Алгоритм классификации позволяет повысить точность диагностики на МРТ и КТ изображениях: опухоли головного мозга (в течение 120 с., точность 99%); опухоли молочной железы (в течение 200 с., точность до 98%). Результаты исследований во второй главе опубликованы в [1, 5, 10, 12-14, 19-20, 22], а также использовались в работах [8, 16] для анализа медицинских изображений.

**Третья глава** содержит описание разработанного вычислительной методики и алгоритмического обеспечения для извлечения данных из взаимодействующих информационных процессов обработки и анализа визуальных данных в рентгенологии. Если невозможно получить данные, непосредственно описывающие

состояние поврежденного легкого, необходимо изолировать сигнал от не инвазивно полученных источников. Решение этой задачи выполнено с помощью машинного обучения, а разработанное алгоритмическое обеспечение позволило увеличить точность диагностики границы легкого, выделения опухоли и распознавания патологий в случае неоднозначности на изображениях КТ и СХР. В этой главе также излагается методика глубокого обучения нейронных сетей и способы ее применения для распознавания патологии на СХР-изображениях.

Разработан **метод определения границ объекта**, содержащий три этапа:

- Использование дискретного вейвлет-преобразования для создания автоматического кластера вместо использования статического кластера:

- двухмерное вейвлет-разложение с использованием B-Spline;
- Оцу порог на каждом из 4 выходов вейвлета;
- вычисление нового порога из суммы 4 порогов Оцу и деления на 2,  $k = (\text{thresh1} + \text{thresh2} + \text{thresh3} + \text{thresh4})/2$ ;
- одноуровневое обратное дискретное двумерное вейвлет-преобразование,  $X = \text{idwt2}(cA, cH, cV, cD, \text{'bior1.1'})$ ,

где  $k$  – новый кластер,  $X$  – новые входные данные.

- Нечеткая кластеризация выполняет кластеризацию путем итеративного поиска набора нечетких кластеров и связанных с ними центров кластеров, которые наилучшим образом представляют структуру данных. Но в этом методе, который мы использовали, получен из DWT, он позволяет разделить существующий набор степеней  $n$  на заданное количество нечетких множеств.

Особенностью метода является использование нечеткой матрицы принадлежности  $W = \{w_{ik}\}$ . Эти элементы определяют степень принадлежности  $k_{th}$  элемента начального набора векторов  $i_{th}$  кластеру. Учитывая количество кластеров  $c$ , кластеризация разделяет данные  $x = \{x_1, x_2, \dots, x_n\}$  в  $c$  нечетких кластеров с центрами кластеров  $V = (v_1, v_2, \dots, v_c)$  путем минимизации целевой функции:

$$F(W, V) = \sum_{i=1}^c \sum_{k=1}^n (w_{ik})^m \cdot \|x_k - v_i\|^2, \quad w_{ik} \in [0, 1], \quad i = \overline{1, c}, \quad k = \overline{1, n}, \quad 1 \leq m < \infty, \quad (14)$$

где  $m$  – индекс нечеткости,  $w_{ik}$  – степень членства  $x_k$  в  $i_{th}$  кластере,  $v_i$  является центром  $i_{th}$  кластера, а  $\|x_k - v_i\|^2$  представляет расстояние между данными  $x_k$  и центром кластера  $v_i$ :

$$w_{ik} = \left( \sum_{j=1}^c \left( \frac{\|x_k - v_i\|}{\|x_k - v_j\|} \right)^{2/(m-1)} \right)^{-1}, \quad \sum_{i=1}^c w_{ik} = 1, \quad (15)$$

$$v_i = \frac{\sum_{k=1}^n (w_{ik})^m \cdot x_k}{\sum_{k=1}^n (w_{ik})^m}. \quad (16)$$

На каждом итерационном шаге метода нечеткой кластеризации  $C$ -средних матрица  $W$  вычисляется по формуле (15), а соответствующие центры кластеров – по формуле (16). Критерием остановки алгоритма является следующее условие: ошибка, вычисленная по (14) ниже заданного порогового значения, или модуль разности ошибок, полученных на настоящей и предыдущей итерациях, ниже заданного порога. Экспоненциальный вес  $m$  влияет на матрицу степеней принадлежности  $W$ . Чем больше  $m$ , тем конечная матрица  $c$ -разбиения становится более «размазанной», а при

$m \rightarrow \infty$  все объекты принадлежат всем кластерам с одинаковой степенью принадлежности. Экспоненциальный вес позволяет также при формировании координат центров кластеров усилить влияние объектов с большими значениями степеней принадлежности и уменьшить влияние объектов с малыми значениями степеней принадлежности.

- Алгоритмы для вычисления шпурлет-преобразования «FFST» и «ShearLab» – при этом данная реализация основана на дискретном быстром преобразовании Фурье (также как в FFST), однако интерпретируется частотный диапазон несколько иначе. Изучение алгоритма FFST показывает, что контуры объекта могут быть получены как сумма коэффициентов шпурлет-преобразования для фиксированного масштаба и всех возможных значений параметров сдвига и смещения. В связи с этим предлагается использовать эту особенность при решении задачи построения контуров.

Контуры объектов можно получить как сумму коэффициентов преобразования фиксированных значений параметров для последнего сдвига шкалы и различных значений параметров, как показано в уравнение (17), где  $sh_{\psi}$  – коэффициент сдвига для шкалы  $j^*$  поворота (ориентации)  $k$  и смещения  $m$ , где  $k_{\max}$  – максимальное число поворотов,  $m_{\max}$  – максимальная величина смещения:

$$f_{cont} = \sum_{k=0}^{k_{\max}} \sum_{m=0}^{m_{\max}} sh_{\psi}(f(j^*, k, m)) . \quad (17)$$

В качестве количественного параметра для оценки эффективности работы алгоритма выбрано среднее время при решении задач обработки медицинских изображений.

Для распознавания объектов (патологии) на CXR изображениях разработаны **вычислительная методика и алгоритмическое обеспечение**, которые позволяют автоматически распознавать объект – легкие (как с патологией, так и без патологии). В рамках методики алгоритм CPNN имеет другой уровень (уровень конкуренции), который возникает между вычислением гауссовых ядер и условных вероятностей. На рисунке 2 подробно описана структура и поток данных в алгоритмической схеме CPNN.

Конкурентный уровень вводит два дополнительных шага, которые включают новые функции для алгоритма CPNN. На первом этапе значения сортируются и ранжируются в порядке убывания. Все ядра конкурируют за включение в расчет условной вероятности, но используется только часть. Аппроксимация может быть достигнута путем усреднения многомерных нормальных гауссовых ядер, которые являются произведением их собственных одномерных ядер и центрированы в каждом из известных образцов:

$$W_{ij} = \frac{1}{(2\pi)^{\frac{d}{2}} \sigma^d} * \exp\left(-\frac{(X_{new}-X_{Ci,j})^T \cdot (X_{new}-X_{Ci,j})}{2\sigma^2}\right), \quad (18)$$

в котором  $|C|_i$  – мощность подмножества  $C_i$ ,  $W_{i,j}$  – многомерное нормальное (не особое) ядро и  $\sigma$  (разброс) – является регулируемым параметром, который определяется экспериментально и для нормализованных входных векторов может принимать значение в диапазоне от 0 до 1;  $X_{C_{i,j}}$  – является входом классификации например,  $j$ -е данные, которые принадлежат классу  $C_i$ . Однако показано, что оцененный отклик функция плотности вероятности (PDF) не очень чувствителен к изменениям  $\sigma$ . Если  $S$  включает входные данные для классов NC, то его можно

разделить на подмножества  $NC$   $C_i$ , которые содержат входные данные, т.е.  $C_i = \{X_{C_i,1}, X_{C_i,2}, \dots, X_{C_i,|C_i|}\}$ .

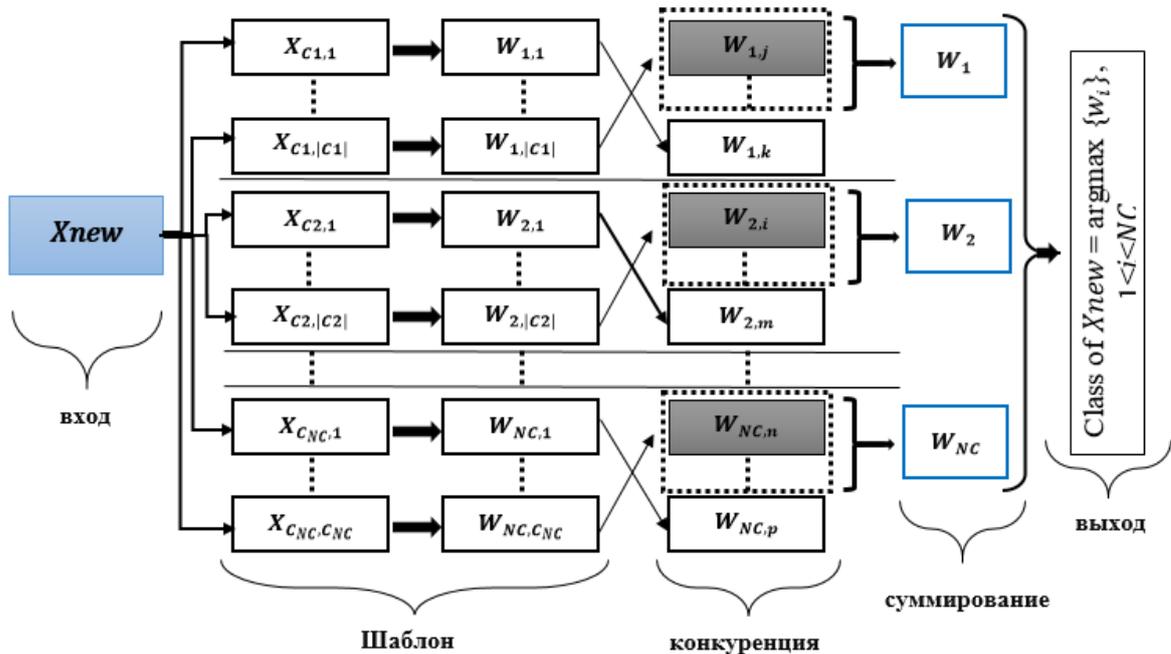


Рисунок 2 – Архитектура CPNN

Количество выбранных ядер в классе  $i$  указывается как количество победителей ( $NW_i$ ). Отношение  $\gamma_i$  определяется как отношение  $NW_i$  к общему количеству ядер в каждом классе  $i$ :

$$\gamma_i = \frac{NW_i}{|C_i|} \rightarrow NW_i = [\gamma_i |C_i|]. \quad (19)$$

Это соотношение  $\gamma_i$  нормализовано и ограничено:

$$\gamma_i \min = \frac{1}{|C_i|} \leq \gamma_i \leq 1. \quad (20)$$

Отношение  $\gamma_i$  не является непрерывной переменной и может иметь конечное число значений. Используя это обозначение, условно-вероятная вероятность каждого класса в CPNN рассчитывается по формуле:

$$P_i = \frac{1}{NW_i} \sum_{i=1}^{NW_i} w_{ij} = \frac{1}{[\gamma_i |C_i|]} \sum_{j=1}^{[\gamma_i |C_i|]} w_{ij}. \quad (21)$$

Традиционный метод PNN можно рассматривать как особую форму алгоритма CPNN с  $\gamma_i = 1$  для всех классов. Параметры усовершенствованной PNN:  $\sigma$ , а также параметры  $\gamma_i$  – являются функцией обучающих наборов данных и их величины следует оптимизировать для достижения максимальной производительности. Следовательно, есть параметры  $NC+1$  для оптимизации в CPNN. Используем двухуровневую оптимизацию, при которой оптимизация  $\sigma$  рассматривается как задача верхнего уровня, а оптимизация параметров  $\gamma_i$  рассматривается как задача нижнего уровня. При оптимизации верхнего уровня предполагаем, что все  $\gamma_i$  остаются постоянными и равными единице.

Рассматриваем множественные значения  $\sigma$ , а его оптимальное значение выбираем таким образом, чтобы производительность метода CPNN была максимальной. Это идентично подходу оптимизации параметра в расширенном методе PNN. На нижнем уровне, используя полученный оптимум  $\sigma$ , параметры  $\gamma_i$  также оптимизируются. В алгоритме CPNN каждый класс имеет свой собственный

параметр  $\gamma$ , а каждый параметр класса  $\gamma$  оптимизируется отдельно от  $\gamma$  в других классах.

В этом алгоритме для каждого нового входного значения ядра данных в каждом классе вычисляются и ранжируются от наибольшего к наименьшему значению; эти ранжирования составляют соревнование между ядрами за возможность быть включенным в расчет величины условной вероятности класса. Для классификации с использованием алгоритма CPNN, после определения размера всех ядер, они сортируются в порядке убывания. Данные обучения представлены в виде звездочек и квадратов для пациента с патологией или без нее как класс 1 и класс 2, соответственно. Результаты моделирования данных и решения указанных задач приведены в таблице 1.

Таблица 1 – Точность классификатора CPNN изображений CXR из наборов данных MC и SH.

Изображения	MC Набор данных			SH Набор данных		
	Количество изображений	Классифицировано %		Количество изображений	Классифицировано %	
		Правильно	Неправильно		Правильно	Неправильно
Изображения без патологии	75	96.94	3.06	99	97.89	2.11
Изображения с патологией	50	96.58	3.42	80	95.77	4.23
Общее количество	125	96.76	3.24	179	96.83	3.17

Результаты указывают на высокую вариабельность по отношению к выбранному разделению набора данных. Особенно для «скрытой патологии», которая является классом с наименьшим количеством положительных выборок. Оценка существующих подходов и сравнение их эффективности затруднительны, так как прошлые исследования фокусируются в основном на одном (случайном) разбиении.

В данной работе представлена разработанная архитектура нейронной сети, которая оптимизирована для диагностики патологии. Эта специализированная нейронная сеть обучалась с нуля и достигала хороших результатов по сравнению с другими подходами. В то же время здесь достигнуто значительное снижение требований к вычислительным ресурсам, памяти и энергопотреблению. Блок-схема алгоритма для обнаружения границы объекта (легкого) и распознавания патологии показана на рисунке 3.

Представлен алгоритм CPNN относительно базовой версии (метод PNN) и модифицированный алгоритм FFST для определения границ легких и классификации патологий на рентгенограмме грудной клетки, включая обнаружение опухолей на КТ и МРТ изображениях. В итоге, в таблице 2 приведены данные сравнительного анализа обработки некоторых указанных выше медицинских изображений различными методами и с помощью разработанной вычислительной методики.

Таблица 2 – Сравнительный анализ данных обработки медицинских изображений различными методами и с помощью вычислительной методики.

Методы	Метрика PSNR (db)
Алгоритм Превитта (Prewitt)	24.68
Алгоритм Собела (Sobel)	26.25
Алгоритм Fast Finite Shearlet Transform (FFST) – Hauser s., 2013	27.05
Модифицированный алгоритм FFST– Luis Cadena, 2016	33.50
<b>Вычислительная методика – (DWT-FFST-FCM)</b>	<b>34.36</b>

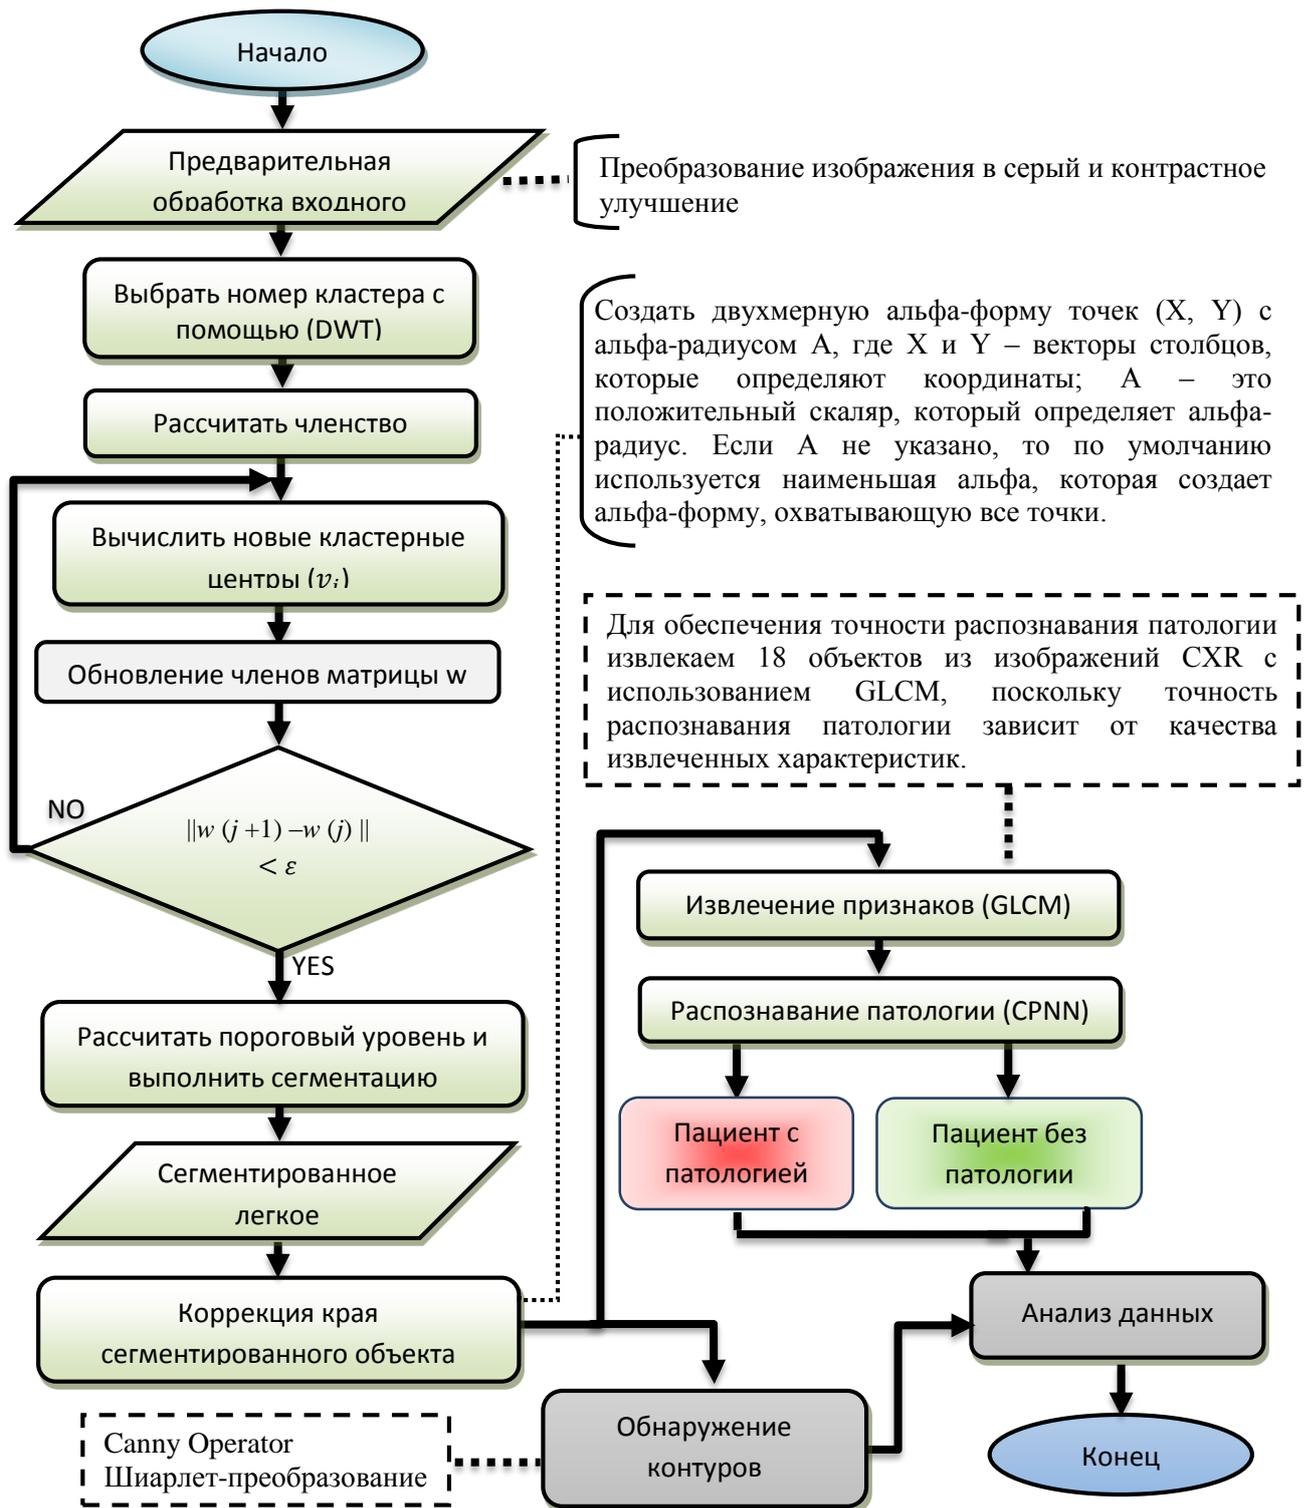


Рисунок 3 – Блок-схема алгоритма компьютерной диагностики для анализа CXR

Таким образом, **метод** обнаружения границ позволяет повысить точность сегментации и обнаружения границ объектов интереса (легких) на 1-2% для базы данных CXR и для баз данных SH и MS по сравнению с современными методами определения границы легких на изображениях CXR (2014-2019 гг.). Средняя точность распознавания для исследуемых баз данных достигает 96 %. Результаты

исследований по третьей главе опубликованы в [2, 9, 15, 17, 22], а также использовались в работах [8, 16, 21, 23] для анализа медицинских изображений.

**В четвертой главе** на основе разработанных алгоритмов в главах 2 и 3, которые используются для визуализации и интерпретации данных электронно-сканирующей микроскопии в рамках комплексного медицинского эксперимента, решается актуальная задача количественной гистологии – оценка показателей регенерации тканей (размеры зоны прорастания и скорости роста) на имплантатах различного типа. Целью численных экспериментов является повышение точности анализа экспериментальных визуальных данных (относительно классических подходов) путем модификации современного алгоритмического обеспечения для решения задач количественного морфологического (геометрического) анализа.

В результате этого, в частности, можно снизить сложность и трудоемкость экспериментов при анализе динамики роста тканей на имплантатах. Это также позволяет более четко визуально различать внутренние геометрические особенности объектов, представляющих интерес, на экспериментальных изображениях, тем самым повышая точность количественных оценок исследуемых параметров и качество их интерпретации. Рассмотрим детально особенности предложенного **способа** на основе разработанных алгоритмов в главах 2 и 3. Первый этап – устранение шума. Пиксели, включенные в операцию усреднения (фильтрации), определяются маской (ядром). Размер ядра может быть разным и зависит от поставленной задачи. Исследуются несколько вариантов фильтрации исходных изображений.

Второй этап – усиление контраста. Функция MSR – Мультимасштабный Ретинекс ( $R_{MSR}$ ) обычно принимает как отрицательные, так и положительные значения, а полученные пределы диапазона будут произвольными. Принимая это во внимание, необходимо преобразовать полученные значения в отображаемую область, то есть в диапазон интенсивности  $[0, 255]$ . В зависимости от исходного изображения в распределении выходных значений функции MSR среднее значение может быть смещено относительно нуля. Поэтому для формирования выходного изображения решено использовать диапазон растяжения с учетом адаптивной регулировки степени растяжения. Регулировка основана на пороговых значениях границы с учетом требуемого размера диапазона ( $Pr$ ) и смещения центра распределения (выравнивание по нулю). Следовательно, расчет выходного значения яркости изображения ( $I_{MSR}$ ) с желаемым диапазоном визуализации ( $I_{TR}$ ) проводится с помощью:

$$I_{MSR}(x, y, \sigma) = Cl \left( \frac{R_{MSR}(x, y, \sigma) - \text{avg}(R_{MSR}(\sigma))}{(\max(R_{MSR}(\sigma)) - \min(R_{MSR}(\sigma))) \cdot Pr} \cdot I_{TR} + k_{offset} \right) \quad (22)$$

где  $k_{offset}$  – коэффициент смещения яркости (по умолчанию,  $k_{offset}=127$ );  $Cl()$  – является функцией отключения для значений за пределами желаемого диапазона.

Примеры улучшения качества изображения из наборов растровых микроскопических изображений и гистологического анализа с использованием модифицированного алгоритма Multi-Scale Retinex показаны на рисунке 4.

На обработанном изображении можно наблюдать более четкое визуальное разделение никелид титанового имплантата и тканей (коллагеновых волокон, эритроцитов и т.д.). Данные характеристик яркости, такие как среднее значение и стандартное отклонение (SD), медицинских изображений до и после коррекции яркости с помощью алгоритма Retinex представлены в таблице 3, где приведены

статистические данные характеристик яркости для всего набор изображений, полученных в клинических экспериментах.

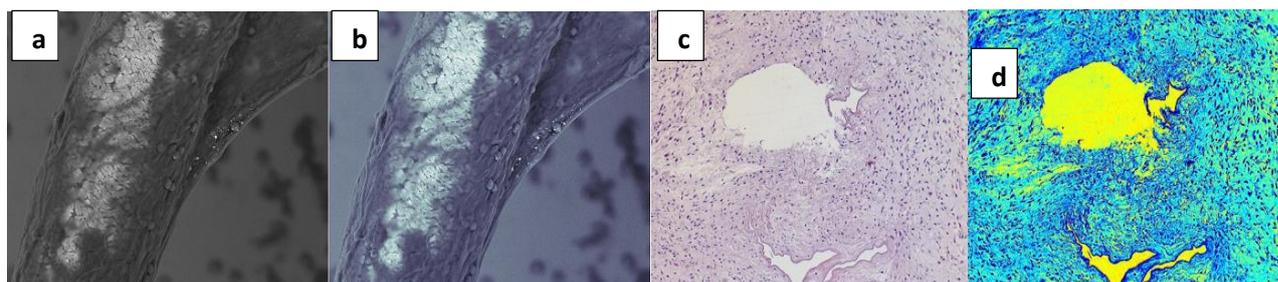


Рисунок 4 – Пример обработки изображения алгоритмом Retinex: а) гистологические изображения; с) изображение сканирующего электронного микроскопа; б) и d) изображения, обработанное модифицированным алгоритмом Retinex

Таблица 3 – Учет яркости изображений.

Изображение	До коррекции яркости		После коррекции яркости	
	Mean	SD	Mean	SD
Гистологические изображения				
Изображение	204.22	15.73	190.03	12.43
Изображения сканирующего электронного микроскопа				
Изображение	83.26	12.57	127.48	22.14

Третий этап – сегментация. На рисунках 5 и 6 можно видеть карты с цветовой кодировкой для не растущей области (выделены красным), с использованием метода сегментации для изображений из второй главы, полученных с помощью сканирующего микроскопа для различных периодов времени. На основании этих карт рассчитывались морфологические показатели и оценивались степень и скорость роста тканей для различных периодов времени наблюдения (7, 14, 21 и 45 дней).

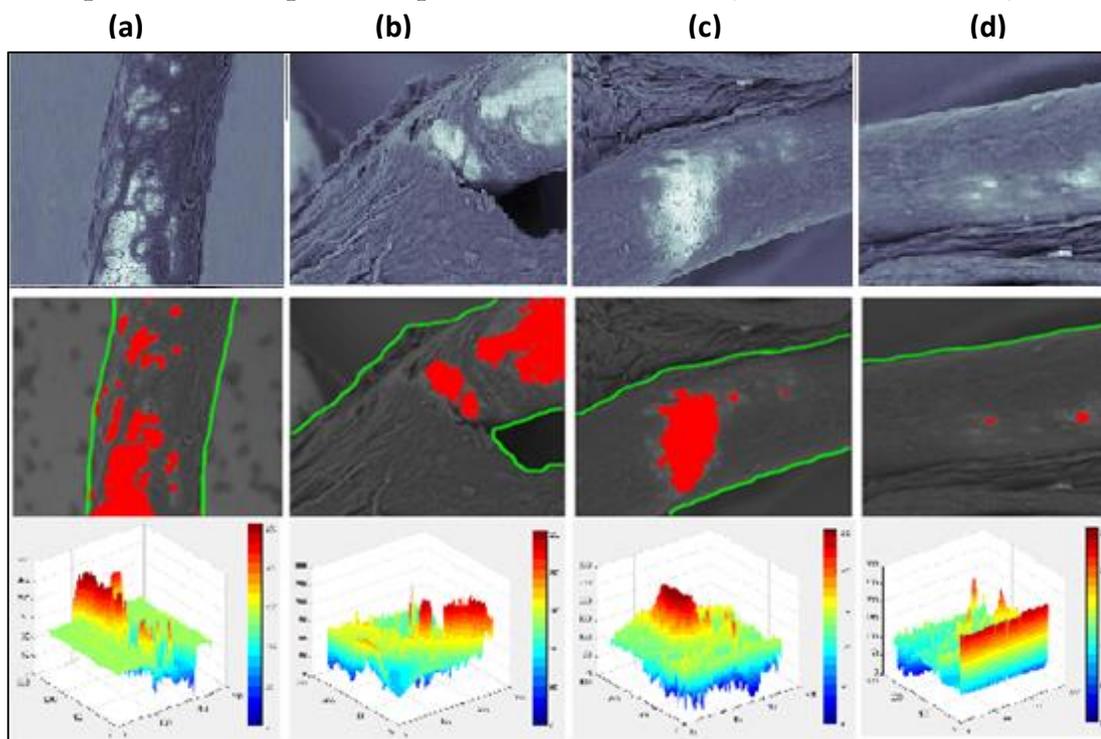


Рисунок 5 – Примеры карт с цветовой кодировкой растровых изображений для различных периодов времени: а) – 7 дней; б) – 14 дней; с) – 21 день; d) – 45 дней

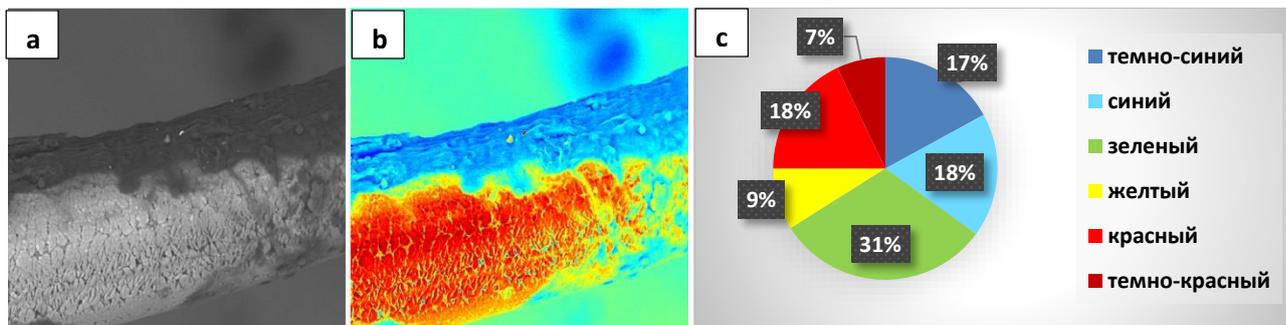


Рисунок 6 – а) исходное изображение; б) семантическая сегментация области имплантата; в) количество цветов имплантатов (клеток) для определения характеристик прорастания тканей

Результаты количественного гистологического анализа, полученные с использованием разработанного **способа**, приведены на рисунке 7. Достигнутое за счет предложенного способа повышение точности для указанных гистологических показателей в среднем составляет 3-7% относительно оценок, полученных при классическом способе анализа исходных изображений. Расчетные процедуры вычисления объектов сегментации реализованы в программном приложении (разработана программа matlab: 1 – преобразование изображения в набор пикселей; 2 – деление набора пикселей на 2, 4 или 6 групп; 3 – суммирование для каждой группы; 4 – оценка процента для каждой группы).

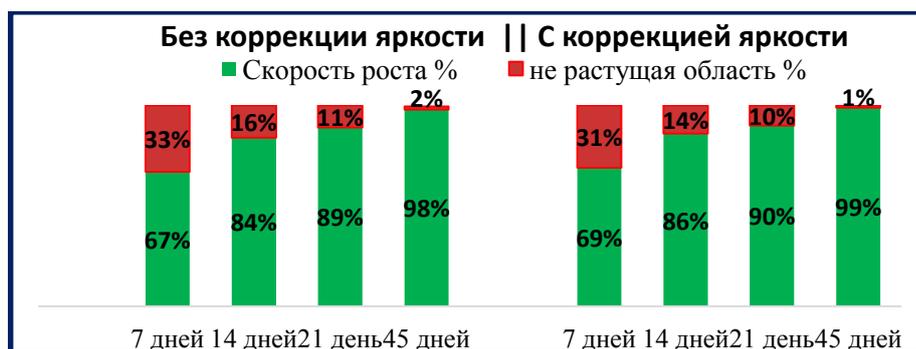


Рисунок 7 – Результаты экспериментальных и численных исследований: оценка скорости роста тканей в различные периоды времени для имплантата на основе никелид титана

Предложенный **способ** позволяет получить карту краев интересующего объекта с большей точностью, в среднем на 3-7%. Кроме того, **способ** (методика) демонстрирует меньший процент пикселей, ошибочно обнаруженных как края для не растущей области. Алгоритмические и экспериментальные результаты четвертой главы опубликованы в [8, 16, 21, 23].

В **Приложении** представлены программные коды разработанного алгоритмического обеспечения, а также результаты экспериментальных исследований распознавания патологии и определения границ легких.

### Основные результаты и выводы

1. Разработан **метод сегментации** по группам объектов, который характеризуется созданием нового порога для сегментации объектов с использованием комбинации порогового значения Оцу и нечеткой кластеризации, что позволяет значительно увеличить скорость и улучшить точность сегментации и

классификации объектов на 2-3% по сравнению с современными методами медицинской сегментации (2016-2019 гг.).

2. Предложен **алгоритм классификации** объектов интереса (опухолей доброкачественных или злокачественных) с использованием разработанного метода сегментации, извлеченных признаков и алгоритма на основе нейронной сети, который позволяет повысить точность диагностики на МРТ и КТ изображениях: опухолей головного мозга (в течение 120 сек. с точностью 99%); опухолей молочной железы (в течение 200 сек. с точностью 98%).

3. Разработан **метод определения параметров** (порогового значения), которые важны для автоматической сегментации с использованием дискретного вейвлет-преобразования, что позволяет повысить точность сегментации и обнаружения границ объектов интереса (легких) на 1-2%, по сравнению с современными методами определения границ легких на снимках СХР (2014-2019 гг.).

4. Разработаны **методика и алгоритмическое обеспечение** обработки и анализа изображений СХР и КТ на основе усовершенствованного алгоритма CPNN и модифицированного алгоритма шиарлет-преобразования (FFST) для определения границ легких и распознавания патологий на рентгенограммах грудной клетки, включая обнаружение опухолей на изображениях КТ, которые позволяют повысить точность диагностики патологий. Средняя точность распознавания объектов (патологий) на исследуемых базах данных достигает 96 %.

5. Предложен **способ** геометрического анализа и визуализации объектов интереса на основе модификации алгоритмического обеспечения шиарлет-преобразования и контрастирования изображений цветовым кодированием. Выполнены численные исследования экспериментальных данных сканирующей электронной микроскопии для оценки показателей регенерации тканей (размеры зоны прорастания и скорости роста) на имплантатах различного типа в рамках комплексного медицинского эксперимента. Результаты экспериментов показали быстрое действие и высокую точность разработанного способа (на 3-7 %), относительно классического подхода в гистологии при решении прикладных задач.

## СПИСОК ПУБЛИКАЦИЙ ПО ТЕМЕ РАБОТЫ

### Журналы из списка ВАК

1. **Хамад Ю.А.,** Капсаргин Ф.П., Симонов К.В. Алгоритмы обнаружения и распознавания локальных областей на изображениях // Информатизация и Связь. – 2020. – № 2. – С. 25-34.
2. **Хамад Ю.А.,** Симонов К.В., Кенц А.С. Алгоритмы сегментации и распознавания объектов на медицинских изображениях на основе шиарлет-преобразования и нейронных сетей // Информатизация и Связь. – 2020. – № 2. – С. 35-45.
3. Симонов К.В., Зотин А.Г., **Хамад Ю.А.,** Курако М.А., Кенц А.С. Алгоритмы обнаружения и классификации визуальных данных // Информатизация и связь. – 2019. – №. 4. – С. 55-63.
4. Симонов К.В., Зотин А.Г., **Хамад Ю.А.,** Курако М.А., Кенц А.С. Алгоритмы геометрического анализа медицинских изображений // Информатизация и Связь. – 2019. – № 4. – С. 95-101.
5. Зотин А.Г., **Хамад Ю.А.,** Кириллова С.В., Курако М.А., Симонов К.В. Обнаружение опухоли мозга на основе МРТ с применением метода нечеткой кластеризации с-средних // Медицина и высокие технологии.– 2018. – № 1. – С. 20-28.

6. Кириллова С.В., **Хамад Ю.А.**, Курако М.А., Симонов К.В. Вычислительная методика обработки медицинских изображений: выделение границ // Медицина и высокие технологии. – 2018. – № 1. – С. 14-19.
7. **Хамад Ю.А.**, Кириллова С.В., Курако М.А., Симонов К.В. Вычислительная методика обработки медицинских изображений, используя вейвлет и нейросети // Медицина и высокие технологии. – 2018. – № 3. – С. 5-13.
8. Симонов К.В., Зотин А.Г., **Хамад Ю.А.**, Черепанова Т.В. Алгоритмы обработки и анализа экспериментальных медицинских изображений // Медицина и высокие технологии. – 2019. – № 2. – С. 54-60.
9. Симонов К.В., Зотин А.Г., **Хамад Ю.А.** Алгоритмы обнаружения и классификация патологии легких на рентгеновских снимках // Медицина и высокие технологии. – 2019. – № 2. – С. 46-53.
10. Кенц А.С., Симонов К.В., **Хамад Ю.А.** Визуализация и контрастирование медицинских изображений // Медицина и высокие технологии.– 2019.– № 4.–С. 26-33.

#### **Труды международных конференций (SCOPUS)**

11. **Hamad Y.A.**, Simonov K., Naeem M.B. Brain's tumor edge detection on low contrast medical images // 2018 1st Annual International Conference on Information and Sciences (AiCIS). – IEEE, 2018. – P. 45-50.
12. Zotin A., Simonov K., Kurako M., **Hamad Y.A.**, Kirillova S. Edge detection in MRI brain tumor images based on fuzzy C-means clustering // Procedia Computer Science. – 2018. – Т. 126. – P. 1261-1270.
13. **Hamad Y.**, Simonov K., Naeem M.B. Breast Cancer Detection and Classification Using Artificial Neural Networks // 2018 1st Annual International Conference on Information and Sciences (AiCIS). – IEEE, 2018. – P. 51-57.
14. **Hamad Y.A.**, Simonov K.V., Naeem M.B. Detection of Brain Tumor in MRI Images, Using a Combination of Fuzzy C-Means and Thresholding //International Journal of Advanced Pervasive and Ubiquitous Computing (IJAPUC). – 2019. – Vol. 11. – №. 1. – P. 45-60.
15. Zotin A., **Hamad Y.**, Simonov K., Kurako M. Lung boundary detection for chest X-ray images classification based on GLCM and probabilistic neural networks // Procedia Computer Science. – 2019. – Vol. 159. – P. 1439-1448.
16. **Hamad Y.**, Mohammed O.K.J., Simonov K. Evaluating of Tissue Germination and Growth Rate of ROI on Implants of Electron Scanning Microscopy Images // Proceedings of the 9th International Conference on Information Systems and Technologies.– 2019.– P. 1-7.
17. **Hamad Y.A.**, Simonov K., Naeem M.B. Lung Boundary Detection and Classification in Chest X-Rays Images Based on Neural Network // International Conference on Applied Computing to Support Industry: Innovation and Technology. – Springer, Cham, 2019. – P. 3-16.

#### **Журналы и труды научных конференций (РИНЦ)**

18. Кириллова С.В., Курако М.А., **Хамад Ю.А.**, Симонов К.В. Вычислительная технология обработки медицинских изображений: выделение границ // Информационные и математические технологии в науке и управлении. – 2018. – № 4. – С. 79-87.
19. **Хамад Ю.А.**, Кириллова С.В., Курако М.А., Симонов К.В., Черепанова Т.В. Алгоритмы обнаружения границ на низко-контрастных изображениях компьютерной томографии // Материалы XXI Всероссийского семинара: Моделирование неравновесных систем-2018. – Красноярск: ИВМ СО РАН, 2018. – С. 100-104.

- 20.** Зотин А.Г., Кириллова С.В., Курако М.А., **Хамад Ю.А.**, Симонов К.В., Черепанова Т.В. Обработка и анализ медицинских изображений: обнаружение опухоли на основе МРТ // Сложные системы в экстремальных условиях. Материалы XIX Всероссийского симпозиума с международным участием. – Красноярск: ФИЦ КНЦ СО РАН, 2018. – С. 88-91.
- 21.** Зотин А.Г., Симонов К.В., **Хамад Ю.А.**, Курако М.А., Черепанова Т.В. Алгоритмы анализа экспериментальных медицинских данных // Тезисы Международной конференции АПВПМ-2019. – Новосибирск. ИВМиМГ СО РАН, 2018. – С. 152.
- 22.** Симонов К.В., **Хамад Ю.А.**, Кенц А.С. Нейросетевые алгоритмы классификации патологии легких на рентгеновских снимках // Нейроинформатика, ее приложения и анализ данных: Материалы XXVI Всероссийского семинара. – Красноярск: ИВМ СО РАН, 2019. – С. 104-109.
- 23.** Симонов К.В., Зотин А.Г., **Хамад Ю.А.**, Курако М.А., Черепанова Т.В. Алгоритмы анализа экспериментальных медицинских данных // Труды Международной конференции «АПВПМ»-2019. – Новосибирск: ИВМиМГ СО РАН, 2019. – С. 448-453.