

*Н.Ю. ИЛЬСОВА, А.В.КУПРИЯНОВ,
А.О. КОРЕПАНОВ*

**ОЦЕНИВАНИЕ ГЕОМЕТРИЧЕСКИХ
ПАРАМЕТРОВ БИМЕДИЦИНСКИХ
ДИАГНОСТИЧЕСКИХ ИЗОБРАЖЕНИЙ**

2007



САМАРА

ФЕДЕРАЛЬНОЕ АГЕНТСТВО ПО ОБРАЗОВАНИЮ
ГОСУДАРСТВЕННОЕ ОБРАЗОВАТЕЛЬНОЕ УЧРЕЖДЕНИЕ
ВЫСШЕГО ПРОФЕССИОНАЛЬНОГО ОБРАЗОВАНИЯ
«САМАРСКИЙ ГОСУДАРСТВЕННЫЙ АЭРОКОСМИЧЕСКИЙ
УНИВЕРСИТЕТ имени академика С.П. КОРОЛЕВА»

ОЦЕНИВАНИЕ ГЕОМЕТРИЧЕСКИХ ПАРАМЕТРОВ БИОМЕДИЦИНСКИХ ДИАГНОСТИЧЕСКИХ ИЗОБРАЖЕНИЙ

*Утверждено Редакционно-издательским советом университета
в качестве учебного пособия*

САМАРА
Издательство СГАУ
2007

УДК 681.3, 621.372.542
ББК 22.16



**Инновационная образовательная программа
"Развитие центра компетенции и подготовка
специалистов мирового уровня в области
аэрокосмических и геоинформационных технологий"**

Авторы: *Н.Ю. Ильясова, А.В. Куприянов, А.О. Корепанов*

Рецензенты: зав. кафедрой геоинформатики СГАУ д-р.техн.наук, проф.
Сергеев В.В.; доц. кафедры безопасности информационных
систем СамГУ канд.физ.-мат.наук Осипов М.Н.

М744 **Оценивание геометрических параметров биомедицинских диагностических изображений:** учеб. пособие / *Н.Ю. Ильясова, А.В. Куприянов, А.О. Корепанов* – Самара: Изд-во Самар. гос. аэрокосм. ун-та, 2007. – 142 с.

ISBN

Настоящее учебное пособие является новой разработкой, способствующей повышению познавательной активности студентов в условиях изучения новых форм и методов организации знаний; использования в процессе обучения новых информационных технологий, инструментальных методик и технических средств, ориентированных на решение прикладных задач анализа медико-диагностических изображений и прикладных задач биомедицинской диагностики.

Учебное пособие является инновационным образовательным модулем. Представляет собой самостоятельный раздел учебных дисциплин, связанных с изучением методов и алгоритмов выделения и математической формализации диагностических признаков на медицинских диагностических изображениях, а также различных методов обработки изображений, ориентированных на оценивание геометрических параметров. Учебное пособие позволит повысить уровень подготовки студентов по специальностям 190500 – Биотехнические и медицинские аппараты и системы, новый курс: Методы и средства обработки медицинских изображений; 010600 – Прикладные математика и физика; 010500 – Прикладная математика и информатика по следующим приоритетным направлениям: современные методы компьютерной диагностики; методы обработки биомедицинских изображений; математические модели объектов медицинской диагностики.

УДК 681.3, 621.372.542
ББК 22.16

ISBN

© Н.Ю. Ильясова, А.О. Корепанов,
А.В. Куприянов, 2007
© Самарский государственный
аэрокосмический университет, 2007

СОДЕРЖАНИЕ

ВВЕДЕНИЕ	5
1 БИОМЕДИЦИНСКИЕ ДИАГНОСТИЧЕСКИЕ ИЗОБРАЖЕНИЯ...	14
1.1 ДИАГНОСТИЧЕСКИЕ ИЗОБРАЖЕНИЯ ГЛАЗНОГО ДНА	14
1.2 ДИАГНОСТИЧЕСКИЕ ИЗОБРАЖЕНИЯ КОРОНАРНЫХ СОСУДОВ.....	18
2 ОЦЕНИВАНИЕ НАПРАВЛЕНИЙ ВЕТВИ ДРЕВОВИДНОЙ СТРУКТУРЫ МЕТОДОМ ЛОКАЛЬНОГО ВЕЕРНОГО ПРЕОБРАЗОВАНИЯ	28
2.1 ПРЕОБРАЗОВАНИЕ РАДОНА И ЛУЧЕВОЕ ПРЕОБРАЗОВАНИЕ	28
2.2 ЛОКАЛЬНОЕ ВЕЕРНОЕ ПРЕОБРАЗОВАНИЕ	31
2.3 ДИСКРЕТНОЕ ПРИБЛИЖЕНИЕ ПРЕОБРАЗОВАНИЯ.....	34
2.4 РЕАЛИЗАЦИЯ МЕТОДА ЛОКАЛЬНОГО ВЕЕРНОГО ПРЕОБРАЗОВАНИЯ.....	37
2.4.1 Формирование радиальной развертки	38
2.4.2 Обработка графиков радиальных разверток	39
2.4.3 Поиск локальных минимумов	41
2.4.4 Поиск направлений ветвления	44
2.4.5 Выделение центров ветвей сетчатых структур.....	45
3 ОЦЕНИВАНИЕ ГЕОМЕТРИЧЕСКИХ ПАРАМЕТРОВ ДРЕВОВИДНЫХ СТРУКТУР НА ОСНОВЕ ВЕЙВЛЕТ- АНАЛИЗА..	49
3.1 ОБЩАЯ ХАРАКТЕРИСТИКА МЕТОДА РЕШЕНИЯ ЗАДАЧИ	49
3.1.1 Выбор и анализ диагностических признаков.....	50
3.2 МАТЕМАТИЧЕСКОЕ ОПИСАНИЕ ЦЕНТРАЛЬНЫХ ЛИНИЙ СОСУДОВ.....	50
3.2.1 Непрерывное представление центральной линии	51
3.2.2 Дискретное представление центральной линии ветви.....	52
3.3 ФОРМИРОВАНИЕ ПЕРВИЧНОГО ПРИЗНАКОВОГО ПРОСТРАНСТВА	53
3.3.1 Определение кривизны	53
3.3.2 Сглаживание гладкой регулярной параметрической кривой	53
3.3.3 Нормирование диагностических признаков	59
3.3.4 Формирование вектора признаков	60
3.4 ФАКТОРНЫЙ АНАЛИЗ ПЕРВИЧНОГО ПРИЗНАКОВОГО ПРОСТРАНСТВА И ФОРМИРОВАНИЕ РЕЗУЛЬТИРУЮЩЕГО ПРИЗНАКОВОГО ПРОСТРАНСТВА	61
3.4.1 Применение дискретного разложения Карунена-Лоева для уменьшения количества признаков	61
3.4.2 Механизм расчета признаков и формирования признакового пространства	63

4 ОЦЕНИВАНИЕ НАПРАВЛЕНИЙ ДРЕВОВИДНЫХ СТРУКТУР В ПРОСТРАНСТВЕ	65
4.1 Задача восстановления пространственной интенсивности по изображениям проекций	65
4.2 Алгоритм восстановления пространственной интенсивности	66
4.3 3D локальное веерное преобразование Радона	71
4.4 Определение направления ветви в пространстве	74
4.5 Экспериментальное исследование метода	78
4.5.1 Искусственные модельные изображения	78
4.5.2 Изображения фантома	80
5 ОЦЕНИВАНИЕ ЛОКАЛЬНЫХ НАПРАВЛЕНИЙ ВЕТВИ СЕТЧАТОЙ СТРУКТУРЫ	83
5.1 Метод прямого поиска направлений	83
5.2 Алгоритм трассировки ветви сетчатой структуры	85
6 ОЦЕНИВАНИЕ ЛОКАЛЬНЫХ ДИАМЕТРОВ СЕЧЕНИЙ ВЕТВИ	91
6.1 Параметрические модели структурных элементов	91
6.2 Оценка локального диаметра с использованием метода моментов	95
6.3 Оценка параметров сечения с использованием метода МНК	99
6.4 Экспериментальные исследования алгоритмов оценивания локальных диаметров	101
7 ПРИМЕНЕНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ОЦЕНИВАНИЯ ДИАГНОСТИЧЕСКИХ ПАРАМЕТРОВ	104
7.1 Искусственные нейронные сети	105
7.1.1 Применение нейронных сетей в задачах обработки изображений	107
7.1.2 Основные черты нейронных сетей	108
7.1.3 Обучение нейронных сетей	109
7.1.4 Классификация базовых архитектур нейронных сетей	111
7.1.5 Многослойные нейронные сети (персептроны)	112
7.2 Применение многослойных нейронных сетей	117
7.3 Экспериментальное исследование алгоритмов	124
ПРЕДМЕТНЫЙ УКАЗАТЕЛЬ	133
БИБЛИОГРАФИЧЕСКИЙ СПИСОК	134

ВВЕДЕНИЕ

Учебное пособие посвящено описанию методов и алгоритмов оценивания геометрических параметров для анализа и интерпретации биомедицинских диагностических изображений.

Основой разрабатываемых методов и алгоритмов анализа диагностических изображений является оценивание их *геометрических параметров* и использование этих параметров для распознавания и классификации.

Традиционно задача распознавания и классификации изображений решается в два этапа. На первом этапе производится выбор и измерение классификационных признаков изображения. Второй этап заключается в построении системы распознавания (классификации) с использованием классической статистической теории.

Задача второго этапа к настоящему времени глубоко исследована в работах по статистической теории распознавания [1, 2, 3, 4, 5, 6, 7, 8, 9, 10]. Что касается первого этапа (отбор и математическая формализация признаков), то к настоящему времени широкое распространение получили методы, связанные с корреляционной теорией распознавания. Сюда относятся различного рода согласованные фильтры, корреляторы, анализаторы спектра [11, 12, 13, 17, 25, 14, 15, 16, 17]. С нашей точки зрения, основным недостатком такого подхода является излишнее абстрагирование получаемых признаков (энергетический спектр, корреляционная функция) от физических параметров реальных диагностируемых объектов (периметр, площадь и пространственное расположение частиц, диаметр и кривизна кровеносных сосудов, и т.п.), что затрудняет интерпретацию полученных результатов для конечного пользователя. Кроме того, размерность пространства признаков при таком подходе очень высока.

Для преодоления первого из указанных недостатков в настоящей работе предлагается использовать *геометрические* параметры диагностических изображений. Эти параметры должны быть физически

обоснованными, иметь ясный смысл для исследователя и быть понятными для конечного пользователя. Например, для врача-офтальмолога такими признаками являются неравномерность диаметра и кривизна кровеносных сосудов глазного дна, для испытателя двигателей внутреннего сгорания информация содержится в форме факела распыла топливной струи, для лаборанта, анализирующего препараты крови, представляет интерес количество кровяных частиц определенной геометрической формы.

Принятый в учебном пособии подход к построению систем распознавания (классификации) диагностических изображений на основе измерения геометрических параметров имеет ряд преимуществ. Во-первых, используется опыт исследователя в конкретной прикладной области для формирования диагностических признаков, что позволяет, в конечном счете, использовать экспертный подход к построению систем диагностики [18, 19]. Кроме того, имеется возможность использовать наработанные методики диагностики в конкретных прикладных задачах. Так исследования, связанные с разработкой систем медико-биологического направления проводились совместно с сотрудниками кафедры офтальмологии Самарского государственного медицинского университета (разработка экспертной системы ранней диагностики глазных заболеваний) и сотрудниками Волгоградской медицинской академии (разработка системы диагностики глазных заболеваний на основе анализа кристаллов слезной жидкости).


Аппарат геометрических признаков глубоко развит в машинной графике и геометрии, которые основаны на описании объектов при помощи графических примитивов [20, 21]. Задачей машинной графики является формирование изображений на основе графических примитивов с известными значениями геометрических параметров. Параметры этих графических примитивов как раз и являются признаками, которые могут использоваться для распознавания и классификации диагностических изображений. Таким образом, задача

оценивания геометрических параметров может считаться обратной к задаче машинной графики.


В качестве компромисса между указанными подходами (спектрально-корреляционным и геометрическим) к построению системы признаков часто используется метод поля направлений [22, 23]. В отличие от энергетического спектра, поле направлений, хотя и является некоторой абстракцией, позволяет сохранить пространственное описание и локальные свойства объекта исследования. Переход от функции яркости изображения к полю направлений снижает информационную избыточность исходного диагностического изображения и позволяет сократить размерность пространства признаков.

Диагностические изображения *сетчатых структур* представляют собой протяженные древовидные или сетчатые объекты, определяемые такими понятиями как узлы и ветви. Будем называть ветвью элемент сетчатой структуры, который характеризуется *трассой* (геометрическим местом серединных точек) и распределением диаметра вдоль нее. Геометрическими параметрами данной диагностической структуры являются усредненный и локальный диаметры ветви, его распределение вдоль трассы, извилистость и кривизна трассы, углы ветвления в узлах. Примерами изображений, характеризующих наличием сетчатых структур, могут служить изображения различного рода трещин, кристаллические структуры металлов, сеть дорог, русла рек, кровеносное русло глазного дна сетчатки глаза человека.


В учебном пособии в качестве диагностических изображений рассматривается кровеносная система человека, которую можно охарактеризовать как древовидную или сетчатую структуру. Примерами изображений подобных структур также могут служить изображения различного рода трещин, кристаллических структур металлов, сети дорог, русла рек, изображение электрического разряда, изображения глазного дна человека, снимки коронарных сосудов и изображения других биологических структур (рис. 1).



а)




б)




в)



г)



д)



е)

Рис. 1. Примеры изображений древовидных структур: а) коронарные сосуды; б) дельта реки; в) сосуды глазного дна; г) сеть дорог; д) электрический разряд; е) изображение фантома

Будем называть *ветвью* элемент сетчатой структуры, который характеризуется трассой (геометрическим местом серединных точек) и распределением диаметра вдоль нее.

Наибольший интерес с точки зрения медицинской диагностики представляют следующие геометрические параметры диагностической структуры:

- геометрические характеристики линии центров сосудов – трассы сосудов: длина, извилистость, кривизна и т.п.;
- распределение толщины сосудов вдоль трассы;
- углы ветвления сосудов.

Отметим, что в дальнейшем будем использовать термин «сосуд», подразумевая сосуды кровеносной системы человека.

Геометрические параметры толщины и направления являются диагностическими параметрами трассы, поскольку на их основе производится формирование диагностических признаков сосудов. Данные параметры являются локальными характеристиками, рассчитываемыми непосредственно по изображению древовидной структуры в процессе анализа изображений сосудов.

В настоящее время в офтальмологии сложились методы измерения диаметра сосудов сетчатки, большинство из них основаны на построении профиля яркости поперечного сечения сосуда в заданной оператором точке. К таким методам относятся "kick-point" метод [24], аппроксимация профиля к 95% кривой Гаусса [25]. Основным недостатком этих методов, несмотря на высокую точность, является высокая трудоемкость и вероятность ошибки из-за измерения диаметра на локальном сужении сосуда или месте изгиба. Wang Y., Cheasty J.E., Zuckerman R в [26] предлагают более динамичный метод измерения диаметра с процедурой трассирования и учетом статистических характеристик изображения. Richard S.B. Newsom для повышения точности измерения использует измерение диаметра на небольшом протяжении сосуда и вычисляет среднее значение трех измерений. Диаметр сосудов вычисляется как расстояние между интерполированными позициями половины высоты профиля с обеих сторон от его центра [27].

Существует несколько основных типов алгоритмов оценивания направлений древовидных структур: методы непосредственного и косвенного измерения параметров, методы, основанные на моделировании, методы, основанные на применении искусственного интеллекта и нейронных сетей, комбинированные методы. Проверка работы алгоритмов чаще всего осуществляется на синтезированных или на фантомных изображениях, т.е. на изображениях, где известны действительные значения диагностических параметров.

Алгоритмы непосредственного или косвенного измерения анализируют распределение точек, принадлежащих окрестности сосуда, уточняют форму сосуда, путем аппроксимации некоторой кривой (например, B-сплайном), либо формируют оценку параметра на основе минимизации специальной энергетической функции. При этом существует возможность либо непосредственного измерения параметра (например, толщина определяется количеством точек со значениями яркости, попавшими в определенный диапазон), либо измеряются некоторые вспомогательные характеристики (например, значения моментов), на основе которых формируется оценка интересующего параметра. Алгоритмы такого типа подходят для аккуратного выделения параметров в заданной точке, но из-за необходимости участия пользователя и большого объема вычислений не являются достаточно универсальными.

Алгоритмы, основанные на моделях, производят сравнение с эталонной моделью, либо производят аппроксимацию параметров модели. Измерения диагностических параметров производятся на построенных моделях. Эта группа алгоритмов также характеризуется большими вычислительными затратами, однако обходится без вмешательства пользователя и обладает достаточной устойчивостью к искажениям.

Суть метода, основанного на применении искусственного интеллекта, заключается в применении экспертной системы. Система содержит знания о форме кровеносных сосудов на изображениях в виде основных правил (например: центральная линия сосуда имеет высокую интенсивность, области средней интенсивности имеют параллельные границы, и т.д.). Эти правила представляются в иерар-

хическом виде, т.е. сначала определяется порядок и значимость соответствия правилам. Затем в результате применения правил определяется форма сосуда в анализируемой области и производится оценка параметров. Этот метод работает только на тех изображениях, для которых составлены сведения о структуре сосудов.

Метод, основанный на применении нейронной сети, связан с обучением на изображениях древовидных структур, параметры которых известны. Применяя нейронную сеть к анализируемому фрагменту изображения, на выходе сети получаем значение оценки необходимого параметра. Основные вычислительные затраты связаны с процессом обучения. Если известен тип анализируемого изображения, то, выбирая соответствующую сеть, можно с высокой точностью производить оценивание параметров. Однако при наличии искажений метод можно настроить только на конкретный тип искажений (аддитивный шум или расфокусировка), построить универсальную структуру сети в общем случае не удастся.

В работах [28, 29, 30, 31, 32, 33, 34] для оценивания геометрических параметров древовидных изображений на изображениях глазного дна авторами учебного пособия был предложен метод трассировки дерева сосудов при помощи круглой рамки. Суть метода заключается в следующем. Последовательно осуществляется анализ центральных точек выбранной ветви. На каждом шаге трассировки для оценивания направления анализируется распределение интенсивности на границе круглой рамки. Особенности этого метода являются необходимость явно указывать начальную и конечную точки ветви. Точность данного метода можно повысить, рассматривая рамки меняющегося радиуса. Кроме того, возможно производить усреднение отсчетов изображения в локальной области.

Авторами настоящего пособия также был предложен новый метод: метод локального всеерного преобразования. Он обобщает анализ изображений круглой рамкой, так как позволяет использовать информацию внутри области круглой рамки и не требует указывать направление ветви. Предложенный метод позволяет определять направления ветвей в произвольных точках на изображениях сетчатых структур.

В основу метода положено преобразование Радона, которое часто используется в качестве стандартного инструмента анализа изображений, позволяющего распознавать глобальные прямые линии на изображениях [35, 36, 37, 38, 39, 40]. Преобразование Радона и лучевое преобразование являются частным случаем преобразования Хоу, которое позволяет выделять на изображениях различные кривые, которые можно параметризовать (прямые, окружности фиксированного радиуса, и другие). Локальное веерное преобразование является специальным вариантом преобразования Радона, позволяющим хорошо работать в местах разветвлений и при наличии помех.

Различные математические модели, используемые для выявления геометрических характеристик кровеносных сосудов (как центральных линий, так и профиля) предложены, например, в работах [41, 42]. В работах [36, 37, 43, 44, 45] представлены методы формирования признаков пространств, позволяющих производить непосредственно классификацию кровеносных сосудов на нормальные и патологические. Указанные методы основаны на расчете оценки извилистости центральных линий сосудов, как правило, с использованием различных дифференциальных характеристик, и используют в качестве исходных данных уже вычисленные центральные линии кровеносных сосудов.

В учебном пособии предлагается оригинальный метод, являющийся развитием методов выявления патологических изменений структуры сосудистой системы глазного дна, основанных на анализе центральных линий кровеносных сосудов и использовании их дифференциальных характеристик для формирования признакового пространства с последующей классификацией. Предлагаемый метод основан на оценивании кривизны центральных линий сосудов изображений, предварительно обработанных с использованием сглаживающих фильтров с различной полосой пропускания (с различной степенью сглаживания), что при вычислении дифференциальных характеристик приводит к использованию вейвлет-преобразования. Отличительной особенностью предложенного метода является то, что он использует в качестве результирующего набора признаков оценку кривизны центральных линий кровеносных сосудов, полу-

ченную при различных значениях параметра масштаба вейвлет-преобразования.

Существует ряд работ, посвященных решению задачи восстановления трехмерной структуры объектов по проекциям. Например, в работе [46] предложен метод формирования пространственной структуры с использованием плоских древовидных структур, выделенных на проекциях. Недостатком такого подхода является необходимость указания пользователем опорных точек на плоских деревьях. Восстановление структуры осуществляется посегментно, и ошибки при расстановке опорных точек могут привести к невозможности восстановления трехмерного сегмента.

Авторами учебного пособия была разработана технология формирования структуры 3-D объекта на основе анализа пространственного распределения интенсивности.

Для этого задача разбивается на подзадачи: 1) восстановление пространственного распределения интенсивности по имеющимся ангиографическим проекциям; 2) оценивание направлений трассы сосуда в пространстве и обнаружение разветвлений; 3) формирование пространственной структуры коронарных сосудов.

Для оценивания направлений в пространстве предлагается использовать модифицированный метод ЛВП – метод трехмерного локального вейвлет-преобразования 3D-ЛВП.

Практическая значимость рассматриваемых в учебном пособии подходов к оцениванию геометрических параметров и диагностических признаков состоит в том, что предложенные методы и алгоритмы позволяют повысить точность оценивания геометрических параметров. Это позволяет использовать значения оценок, предлагаемых методом, для формирования на их основе диагностических признаков. Разработанные методы являются достаточно универсальными, что позволяет использовать их для анализа различных классов изображений, таких как изображения глазного дна и ангиографические изображения системы коронарных сосудов.

1 БИОМЕДИЦИНСКИЕ ДИАГНОСТИЧЕСКИЕ ИЗОБРАЖЕНИЯ

В учебном пособии описывается класс биомедицинских изображений, характеризующихся наличием древовидных структур. К таким изображениям можно отнести изображения глазного дна сетчатки глаза человека, снимки сосудов кровеносной системы человека и другие биологические структуры. Примеры таких изображений показаны на рис. 3. Оценивание диагностических параметров на таких изображениях сводится к количественному оцениванию параметров объектов, которыми являются сосуды кровеносной системы человека.

1.1 Диагностические изображения глазного дна

Рынок офтальмологического оборудования представляет большое число коммерчески доступных систем получения цифровых изображений сетчатки (Carl Zeiss, Rodenstock, Topcon et al) (рис. 2).

Технические требования к устройствам ввода, компьютеру, вопросы хранения изображений на диске и сжатия, общеупотребительные методы предобработки (улучшения качества) офтальмологических изображений в клинической практике подробно представлены в [47]. Michael H. Goldbaum описывает, как происходит оцифровка изображения, как осуществляется его хранение и поиск, как изображение может быть улучшено и каким образом выделить более содержательные его элементы.

Решены некоторые вопросы фильтрации и анализа. Примеры получаемых цифровых изображений глазного дна приведены на рис. 2.

Полутонное диагностическое изображение глазного дна представляет собой сеть каналов (вен и артерий), расположенных на фоне с плавно меняющейся яркостью (рис. 3).




Рис. 2. Фундус-камера и изображения глазного дна

Сосуды древовидно ветвятся, распространяясь по всему глазному дну. Артерии более тонкие, вены толще, темнее и извилистее. Соотношение калибра артерий и вен два к трем. Патологические изменения глазного дна обусловлены поражением зрительного нерва, сетчатки и сосудистой оболочки глаза. При патологиях артерии сужаются, вены расширены, извиты, отмечаются массовые кровоизлияния по ходу вен. Аномальными проявлениями на изображении глазного дна служат сгустки черных и белых пятен, сильная извилистость сосудов, обильное ответвление капилляров.

Большинство существующих методов автоматизированной диагностики заболеваний глазного дна связаны с выявлением и анализом патологических изменений кровеносных сосудов сетчатки [50, 51, 52, 53, 54].




Рис. 3. Примеры диагностических изображений

Это связано с тем, что наиболее распространенные виды заболеваний (такие как сахарный диабет, полицитемия, анемия, лейкоз, гипертоническая болезнь) нередко начинаются с патологии глаза и сопровождаются изменениями структуры сосудистого русла глазного дна. В работах [51, 53, 55, 56] представлены методы, позволяющие производить выделение центральных линий кровеносных сосудов глазного дна. Результатом работы данных методов является цифровое представление центральных линий, допускающее визуальное представление, которое может быть использовано для дальнейшего построения системы признаков с последующей классификацией больных и здоровых сосудов. В работах [57, 58, 59] в качестве исходных данных для формирования признакового пространства используется профиль сосуда (т.е. развертка значений оценки диа-

метра вдоль центральной линии сосуда). Такой вид диагностики позволяет осуществлять более качественную диагностику (так как нестабильность диаметра сосудистого русла является первичным проявлением большинства заболеваний), однако сопряжен с рядом трудностей, связанных с оцениванием диаметра сосудов на изображении глазного дна вследствие, во-первых, традиционно низкого качества диагностических изображений и, во-вторых, сложности выбора адекватной модели профиля сосуда, необходимой для корректного определения исследуемых характеристик.

В настоящее время в офтальмологии используется сложившийся подход на основе измерения диаметра сосудов, однако также клинически важными показателями, которые вносят существенный вклад в построение экспертной оценки степени патологии, вероятности развития глазных заболеваний, являются и другие статистические характеристики сосудов: соотношение диаметров артерий и вен, неравномерность диаметра (четкообразные изменения вен, локальный спазм артерий), извилистость сосудов, углы разветвления сосудов.

Изображения глазного дна, как отмечалось выше, характеризуются наличием древовидных структур – системы кровеносных сосудов, определяемых такими понятиями как узлы и ветви. Ветвью называется элемент сетчатой структуры, который характеризуется геометрическим местом срединных точек, распределением диаметра и угла вдоль нее. Узел структуры - это точка разветвления или пересечения ветвей.

При анализе изображений древовидных структур основной является задача выделения центров ветвей и определение направлений в каждой точке ветви. Это позволяет выделять ветви структуры на фоне изображения для дальнейшего анализа их геометрических характеристик, на основе которых может быть проведена оценка медико-диагностических параметров. Геометрические характеристики толщины и направления являются диагностическими параметрами трассы, поскольку на их основе производится формирование диаг-

ностических признаков сосудов. Данные параметры являются локальными характеристиками, рассчитываемыми непосредственно по изображению древовидной структуры в процессе трассировки ветви либо при указании точки, принадлежащей сосуду.

1.2 Диагностические изображения коронарных сосудов

Цифровая рентгенология сегодня - наиболее быстро развивающаяся отрасль медицины. Например, при рентгенологическом исследовании сердца при просвечивании на экране хорошо видна тень сердца на фоне прозрачных легких (рис. 4), поэтому можно оценить размеры и расположение тени сердца и сосудистого пучка, их форму. Таким образом, рентгенологические снимки позволяют изучать внутренние органы человека, а также диагностировать их состояние и своевременно определять различного рода патологии. Врач своевременно получает информацию о состоянии пациента, необходимую для принятия решения о методе лечения. С другой стороны, нельзя сказать, что получаемая информация является исчерпывающей и всегда однозначной, что связано с особенностями рентгенографии. Поэтому оценка врачом состояния больного носит субъективный характер.

Коронарная ангиография (коронарография) позволяет врачу увидеть двумерные проекции сосудов сердца пациента, в то время как реально они имеют трехмерную пространственную структуру.

Целью врача является определение пораженных сосудов, идентификация сужения сосудов (стеноз сосудистой стенки) и на основе этих данных вынесение решения о хирургическом вмешательстве. Проблема заключается в том, что зачастую количественное определение характера поражения сосудов по имеющимся ангиографическим снимкам затруднительно, так как стенозированный сосуд (рис. 5а) может выглядеть критическим на одной проекции, в то время как на другой проекции тот же сосуд может не обнаруживать *стенозы* (резкого сужения толщины сосуда). Дополнительно на изображении-

ях проекций возникают виртуальные наложения и пересечения сосудов, что затрудняет визуальное восприятие изображений.




Рис. 4. Изображение ангиографического снимка сердца

С медицинской точки зрения наиболее важными параметрами, влияющими на постановку диагноза и выбор тактики лечения, являются – локальное изменение диаметра сосуда и характер относительного изменения трассы сосудов в пространстве.




Рис. 5. Сосудистая система сердца: а) со стенозой, б) без стенозы

Коронарная ангиография выполняется на специальном дорогостоящем оборудовании, выпускаемом такими фирмами как Philips и Siemens (рис. 6). Под местным обезболиванием через одну из артерий пациента проводят специальный катетер и вводят рентгенконтрастное вещество. Последовательность рентгенологических снимков, регистрирующих попадание контрастного вещества в сосуды сердца, сохраняется в специальном цифровом формате DICOM (Digital Imaging and Communications in Medicine) на диске.



a)



б)

*Рис. 6. Специальное оборудование для проведения коронарографии:
а) AXIOM Multista; б) AXIOM Artis BC*

Таким образом, производится оцифровка рентгенологического пространственного изображения, поступившего на камеру-детектор, в ряд цифровых изображений, которые можно подвергнуть последующей обработке. Примеры изображений коронарных артерий приведены на рис. 7.



a)



б)

*Рис. 7. Иллюстрация двух типов артериальных стволов сердца:
а) примеры левой коронарной артерии; б) примеры правой коронарной артерии*

Наиболее полную информацию для диагностики состояния системы коронарных сосудов можно получить, восстановив пространственную структуру исследуемого объекта (рис. 8), на основе которой могут быть рассчитаны необходимые параметры и диагностические признаки: пространственная криволинейность и извилистость сосудов, амплитуда толщины и т.п. [48].

Существует ряд работ, посвященных решению задачи восстановления структуры объекта.




Рис. 8. Восстановление пространственной структуры коронарных сосудов по ангиографическим проекциям

Например, в работах Devetnau [46] предложен метод формирования пространственной структуры с использованием плоских древовидных структур, выделенных на проекциях. К особенностям такого подхода следует отнести необходимость указания пользователем опорных точек на плоских деревьях. Восстановление структуры осуществляется посегментно, и ошибки при расстановке опорных точек могут привести к невозможности восстановления трехмерного сегмента.

Коронарография – это последний этап обследования больного со стенокардией перед операцией, без которого вопрос этот не решается. Исследование выполняется путем черескожной пункции бедренной артерии, через которую под рентгеновским экраном в аорту, а затем – в обе (правую и левую) коронарные артерии (последовательно) вводится специальный катетер, с поступающим через него контрастным веществом. Снимается кинофильм в нескольких проекциях (обычно 5-6) правой артерии и в 2-3-х проекциях - левой. С помощью коронарографии определяется следующее: тип кровообращения сердца; сколько и какие венечные артерии поражены; степень стенозирования сосудов, которая имеет 4 градации: 1 – сужение умеренное – до 50% просвета сосуда, 2 – окклюзия на 50 – 75%, 3 – резкое стенозирование на 75 – 90% и 4 – полная непроходимость

(рис. 5). У человека имеются два основных артериальных ствола - правый и левый. Их съемка производится последовательно. Левая коронарная артерия имеет более сложную структуру, чем правая, что обуславливает более сложное ее диагностирование (рис. 7). Это является причиной того, что обычно снимается 5-6 проекций левой коронарной артерии и 2-3 - правой.




Рис. 9. Изображения проекций и результат восстановления структуры

В основе формирования рентгеновских изображений лежит использование эффекта неодинаковой рентгеновской плотности веществ. Одни вещества пропускают лучи лучше, другие хуже. Схема процесса такова: тонкий пучок рентгеновских лучей просвечивает тело, изменение интенсивности излучения фиксируется детектором,

и затем эти данные обрабатываются на компьютере или же на пути распространения лучей помещается фоточувствительная пленка, где лучи засвечивают участки пленки тем сильнее, чем меньше плотность вещества. В действительности изображение дает коэффициент “поглощения” рентгеновского излучения, но для большинства материалов эта величина приблизительно пропорциональна плотности, поэтому можно считать, что яркость получаемого изображения пропорциональна плотности исследуемого вещества [38].

Исходными данными для восстановления структуры коронарных артерий являются рентгеновские снимки (ангиографические проекции), полученные в результате коронарографии.




Рис. 10. Поворот: а) на первичный угол; б) на вторичный угол

Установка для проведения коронарографии состоит из источника рентгеновского излучения и приемника (или камеры), соединенных между собой дугообразным держателем. Держатель нежестко закреплен на подвижной опоре. Такая конструкция обеспечивает две степени свободы камеры в пространстве. Кроме этого камера может перемещаться относительно держателя в продольном направлении, обеспечивая масштабирование изображения. На рис. 10а стрелкой показан поворот камеры на *первичный* угол. Этот поворот обеспечивается поворотом держателя камеры вместе с опорой отно-

сительно балки крепления. Первичный угол поворота установки назовем углом α .

Вторичный угол поворота показан на рис. 10б. Такой поворот осуществляется путем скольжения дугообразного держателя по направляющей опоры. При этом камера и источник излучения перемещаются по дуге окружности. В дальнейшем вторичный угол обозначим β . Таким образом, ракурс проекции определяется двумя углами поворота: α и β . Съемка производится расходящимся пучком рентгеновского излучения, угол расхождения пучка примерно равен 12° .

Масштаб изображения определяется положением тела пациента в пространстве между источником и приемником, а также расстоянием от источника излучения до камеры. В процессе съемки одной проекции движение камеры не происходит. Однако может происходить изменение масштаба, а также движение кровати вместе с пациентом в горизонтальной плоскости. Съемка правой и левой коронарной артерий производится последовательно. Сначала формируются все проекции правого сердца (рис.11). Время съемки одной проекции составляет 3-5 секунд, после чего врач изменяет ракурс съемки и процесс повторяется.

Серия последовательных рентгенологических снимков, регистрирующих попадание этого вещества в сосуды сердца, сохраняется на магнитной ленте или кинофильме, или в специальном цифровом формате DICOM. [49] Таким образом, производится оцифровка объекта, то есть рентгеновское пространственное изображение, поступившее на камеру-детектор, преобразуется в ряд цифровых параметров, которые с помощью компьютерных цифровых систем можно подвергнуть последующей обработке. Как правило, в этом формате сохраняются фильмы проекций, кардиограммы, и все данные о геометрии съемки. Для анализа имеются геометрические характеристики плоскостей проекций, а также фильмы проекций, которые в свою очередь состоят из отдельных кадров. Кадры представляют собой

ангиографические снимки сосудов сердца в определенный момент времени, сделанные с некоторого ракурса - ран-фильм (последовательный набор кадров), снятый под определенным ракурсом.

Частота фиксации кадров (фреймов) составляет 25 кадров в секунду. Обычно в одном ране содержится от 80 до 130 фреймов, то есть съемка одного ракурса продолжается в среднем 3-5 секунд. Соответственно в пределах одного фильма можно наблюдать 3-4 полных цикла сокращения сердца. В каждом ране также хранится информация об условиях съемки (первичный и вторичный углы, расстояние от источника излучения до камеры). В каждом отдельном документе формата DICOM содержится в среднем 4-6 ранов с изображением левого сердца и 2-3 с изображением правого. Каждый фрейм представляет собой изображение в формате BMP(GrayScale) размером 512×512 пикселей. По получаемым снимкам очень трудно точно оценить взаимное расположение различных органов тела, их точную геометрическую форму. Основная причина заключается в том, что мы получаем двумерное изображение трехмерного объекта. Рентгеновское изображение представляет собой проекцию суммы изображений слоев тела, которые находятся на различных расстояниях от пленки.

При этом, если мы сканируем несколько тел, как это происходит с внутренними органами при получении рентгенологических снимков человека, то на конечном изображении эти объекты наслаиваются друг на друга, что значительно искажает информацию об их строении и взаимном расположении. Таким образом, в некоторой области пространства, где предположительно находится объект, для каждой точки с помощью конечного числа ангиографических проекций нужно восстановить исходное значение интенсивности, которое имела соответствующая точка сканируемого объекта.

Визуальное наблюдение медицинским экспертом изображений сердечно-сосудистой системы носит субъективный характер и по-

зволяет дать только качественные оценки патологических изменений. Методы цифрового компьютерного анализа изображений являются объективными и дают возможность количественного анализа изображений.

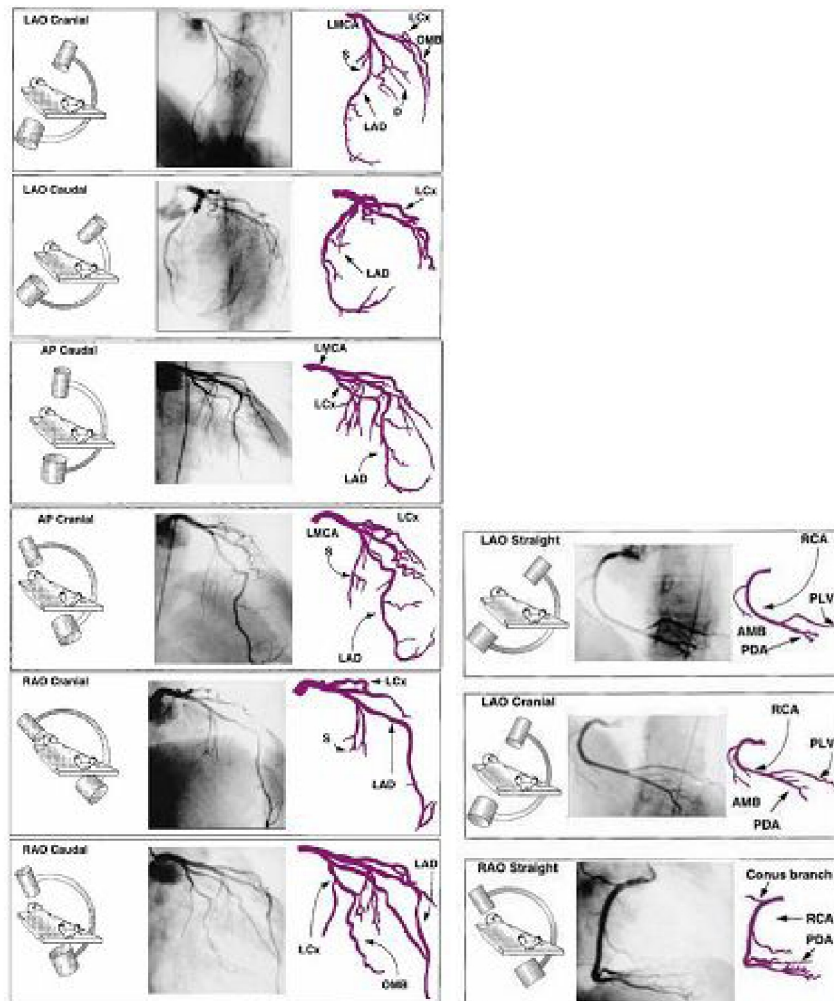


Рис. 11. Проекция левой и правой коронарных артерий

2 ОЦЕНИВАНИЕ НАПРАВЛЕНИЙ ВЕТВИ ДРЕВОВИДНОЙ СТРУКТУРЫ МЕТОДОМ ЛОКАЛЬНОГО ВЕЕРНОГО ПРЕОБРАЗОВАНИЯ

В данном разделе представлен метод оценивания направления ветви древовидной структуры - метод локального веерного преобразования. Он обобщает анализ изображений круглой рамкой, так как позволяет использовать информацию внутри области круглой рамки и не требует указывать направление ветви. Предложенный метод позволяет определять направления ветвей в произвольных точках на изображениях сетчатых структур. В основу метода положено преобразование Радона, которое модифицируется таким образом, чтобы эффективно работать в местах разветвлений и при наличии помех.

2.1 Преобразование Радона и лучевое преобразование

Преобразование Радона \mathfrak{R} (n -мерное) отображает функцию, определенную в \mathbf{R}^n , во множество её интегралов по гиперплоскостям в \mathbf{R}^n . Если $\theta \in S^{n-1}$ и $s \in \mathbf{R}^1$, то

$$\mathfrak{R} f(\theta, s) = \int_{x \cdot \theta = s} f(x) dx = \int_{\theta^\perp} f(s\theta + y) dy,$$

представляет собой интеграл функции f по гиперплоскости, перпендикулярной вектору θ и расположенной на расстоянии s (с учетом знака) от начала координат. Очевидно, что $\mathfrak{R} f$ – четная функция, т.е. $\mathfrak{R} f(-\theta, -s) = \mathfrak{R} f(\theta, s)$.

Лучевое преобразование P (n -мерное) отображает функцию, определенную в \mathbf{R}^n , во множество её линейных интегралов. Если $\theta \in S^{n-1}$ и $x \in \mathbf{R}^n$, то

$$P f(\theta, x) = \int_{-\infty}^{+\infty} f(x + t\theta) dt,$$

представляет собой интеграл функции f по прямой, проходящей через точку x в направлении θ [60]. Очевидно, что величина $P f(\theta, x)$ – не меняется при смещении точки x в направлении θ .

Всерное преобразование D (n -мерное):

$$D f(\theta, x) = \int_0^{\infty} f(x + t\theta) dt,$$

представляет собой интеграл функции f по лучу с началом в точке $x \in \mathbf{R}^n$ и направлением $\theta \in S^{n-1}$. Таким образом, лучевое преобразование можно представить как сумму двух всерных преобразований, вычисленных в точке для противоположных направлений.

Преобразование Радона является стандартным инструментом анализа изображений, который позволяет распознавать глобальные прямые линии на изображениях [35,36,37,38,39,40]. Он является частным случаем преобразования Хоу, которое позволяет выделять на изображениях различные кривые, которые можно параметризовать (прямые, окружности фиксированного радиуса и другие).

Преобразованием Радона на евклидовой плоскости называется интегральное преобразование, относящее функции f на плоскости ее интегралы по всевозможным прямым (относительно евклидовой длины).

Запишем преобразование Радона явной формулой. Будем задавать прямую на плоскости параметрическими уравнениями:

$$\begin{aligned} x_1 &= -t \sin \varphi + \rho \cos \varphi, \\ x_2 &= t \cos \varphi + \rho \sin \varphi. \end{aligned}$$

Тем самым вводятся параметры (φ, ρ) на многообразии прямых, причем параметрам (φ, ρ) и (φ', ρ') отвечает одна и та же прямая тогда и только тогда, когда $\varphi' = \varphi + \pi k$, $\rho' = (-1)^k \rho$, $k \in \mathbf{Z}$.

Преобразование Радона функции $f(x_1, x_2)$ задается следующим образом:

$$\Re f(\varphi, \rho) = \int_{-\infty}^{+\infty} f(-t \sin \varphi + \rho \cos \varphi, t \cos \varphi + \rho \sin \varphi) dt .$$

Интеграл зависит от параметров φ и ρ , однако, так как $\Re f(\varphi + \pi, -\rho) = \Re f(\varphi, \rho)$, функция $\Re f$ опускается на многообразии прямых. Преобразование Радона, вычисленное в точке (x, y) , совпадает с лучевым преобразованием, вычисленным при тех же условиях, и их можно переписать в следующем виде:

$$P f(x, y, \varphi) = \Re f(x, y, \varphi) = \int_{-\infty}^{+\infty} f(x + t \cos \varphi, y + t \sin \varphi) dt .$$

Оно представляет собой интеграл функции f по прямой, проходящей через точку $(x, y) \in R^2$ в направлении φ (рис. 12).

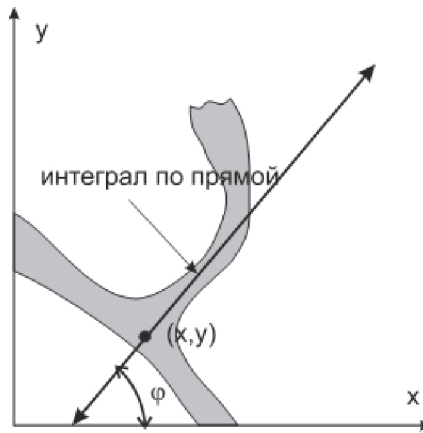


Рис. 12. Лучевое преобразование

Верное преобразование на плоскости представляет собой интеграл функции f по лучу с началом в точке $(x, y) \in R^2$ и направлением φ (рис. 13):

$$D f(x, y, \varphi) = \int_0^{+\infty} f(x + t \cos \varphi, y + t \sin \varphi) dt .$$

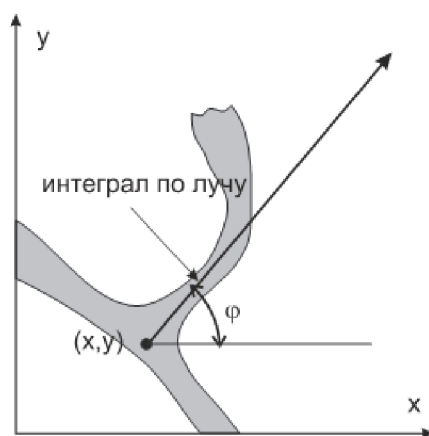


Рис. 13. Веерное преобразование

Ограничение области интегрирования только одним направлением позволяет повысить чувствительность метода в окрестности разветвления. В случае совпадения направления ветви в точке разветвления с направлением луча интегрирования получается более выраженный пик в результате преобразования, чем для классического Радона, так как интегрирование не будет проводиться по фону изображения.

2.2 Локальное веерное преобразование

Изображения сетчатых структур характеризуются тем, что их ветви могут изгибаться. При этом на изображении нет глобальных прямых линий или иных параметрических кривых, но для каждой точки ветви существует окрестность, в которой эта ветвь может быть аппроксимирована прямой.

Кроме этого, важными элементами сетчатых структур являются точки разветвления и окончания ветвей. В связи с этим веерное преобразование модифицируется таким образом, чтобы учитывать указанные особенности.

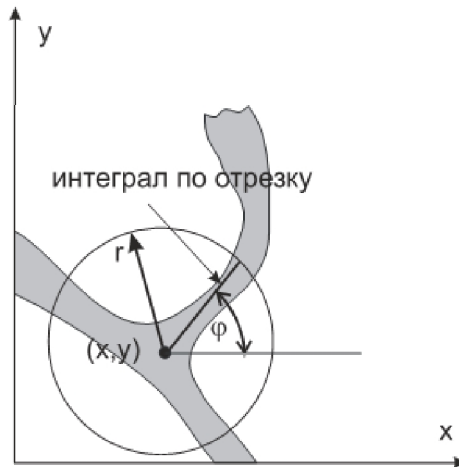


Рис. 14. Локальное веерное преобразование

Для анализа изображений сетчатых структур предлагается использовать локальное веерное преобразование, которое представляет собой интеграл функции f по отрезку длиной r с началом в точке $(x, y) \in R^2$ и направлением φ (рис. 14):

$$F(x, y, \varphi, r) = \int_0^r f(x + t \cos \varphi, y + t \sin \varphi) dt. \quad (1)$$

Таким образом, все множество отрезков, по которым производится интегрирование, образует окружность – локальная область веерного преобразования (рис. 14). Радиус локальной области необходимо выбирать с учетом кривизны ветвей. Чем больше локальная кривизна ветви, тем меньше становится радиус окружности, поскольку в случае совпадения направления интегрирования с направлением ветви локальный фрагмент трассы будет целиком лежать внутри области интегрирования. Следует заметить, что нет возможности измерить кривизну всего локального участка ветви, поскольку для этого необходимо знать как минимум точки трассы ветви. Поэтому значение радиуса ЛВП подбирается экспериментально.

Предлагается дополнительно ограничить область интегрирования относительно небольшой окрестностью, размеры которой выбираются в зависимости от кривизны ветвей так, чтобы внутри выбранной окрестности ветвь можно было достаточно хорошо аппроксимировать отрезком прямой. Это позволяет еще больше повысить чувствительность метода, так как в случае совпадения направления интегрирования с ветвью вся область интегрирования будет лежать целиком на ветви. Введенное преобразование позволяет выделять участки ветвей, даже если они изгибаются, а также точки разветвления, пересечения и окончания ветвей.




Рис. 15. Пример радиальной развертки изображения для конфигурации рис. 14

Если зафиксировать точку (x, y) и радиус локальной области r , то в результате преобразования получится функция от одной переменной φ : $F(x', y', \varphi, r')$ - радиальная развертка изображения. Для конфигурации, приведенной на рис. 14, вид графика этой функции приведен на рис. 15 (яркость ветвей ниже яркости фона).

Радиальная развертка имеет локальные минимумы для тех направлений, которые соответствуют ветвям. Преимущество преобразования (1) заключается в том, что оно позволяет однозначно определить направления ветвей в заданной точке, а в классическом преобразовании Радона и лучевом преобразовании два противополож-

ных направления неразличимы. Для конфигурации, приведенной на рис. 14, это означает, что мы не узнаем, была ли ветвь направлена под углом 135° или 315° .

2.3 Дискретное приближение преобразования

Для реализации предложенного преобразования необходимо учитывать, что входные данные (изображение) дискретны и значения преобразования могут быть вычислены лишь на некотором конечном множестве значений аргумента. Непрерывное локальное верное преобразование зависит от четырех переменных $F(x, y, \varphi, r)$. Радиус r определяется толщиной анализируемых ветвей сосудов.

Пространственные координаты точек на изображении определяются двумя переменными x и y . Так как исходное изображение уже дается в оцифрованном виде, то дискретизацию по пространству естественно выполнить таким же образом, как производится дискретизация изображения. То есть преобразование следует вычислять для каждого отсчета исходного изображения x_m, y_n .

Для изображения размером $M \times N$ отсчетов преобразование (1) запишется в следующем виде:

$$F(x_m, y_n, \varphi, r) = \int_0^r \hat{f}(x_m + t \cos \varphi, y_n + t \sin \varphi) dt,$$

где $\hat{f}(x, y) = f([x], [y])$, $m = \overline{1, M}$, $n = \overline{1, N}$.

Дискретизация по углу направления интегрирования φ осуществляется равномерным разбиением единичной окружности и определяется количеством возможных направлений K .

Например, при разбиении с шагом в один градус K равняется 360. Преобразование (1) переписывается в следующем виде:

$$F(x_m, y_n, \varphi_k, r) = \int_0^r \hat{f}(x_m + t \cos \varphi_k, y_n + t \sin \varphi_k) dt,$$

где $k = \overline{1, K}$, $\varphi_k = \frac{2\pi(k-1)}{K}$.

На изображениях древовидных структур высокого качества, где нет пятен рядом с ветвями и ветви не идут параллельно друг другу, достаточно для анализируемой точки формировать только одну радиальную развертку выбранного радиуса $r = R$.




Рис. 16. Локальное вверное преобразование ветвей с помехами

На реальных изображениях присутствуют и пятна, и параллельно идущие ветви. Если эти помехи расположены настолько близко к ветви, что захватываются локальной круглой областью (рис. 16), то в таких случаях радиальная развертка изображений будет иметь дополнительные локальные минимумы рис. 17.

Для изображений, где могут встречаться указанные конфигурации, предлагается анализировать в каждой точке изображения не одну круглую область, а концентрические круги уменьшающегося радиуса (рис.18). Преобразование (1) переписывается в виде:

$$F(x_m, y_n, \varphi_k, r) = \sum_{t=0}^r \hat{f}(x_m + t \cos \varphi_k, y_n + t \sin \varphi_k), \quad (2)$$

где $r = \overline{R_{\min}, R_{\max}}$.




Рис. 17. Радиальная развертка с ложными минимумами

Шаг изменения радиуса можно брать равным одному отсчету изображения, при этом R_{\min} , R_{\max} определяет минимальную толщину анализируемой ветви. Таким образом, получаем набор радиальных разверток для каждого значения радиуса r (рис. 19).

Примеры радиальных разверток приведены в табл. 1.




Рис. 18. Локальное веерное преобразование с последовательно увеличивающимся радиусом

Этот метод подходит для анализа реальных изображений и хорошо справляется с такими особенностями, как наличие пятен и близко расположенных ветвей. Он устойчив к различным помехам и лишен недостатков своих предшественников, таких как необходимость указывать начальную и конечную точки ветви.




Рис. 19. Набор радиальных разверток для конфигурации рис. 18

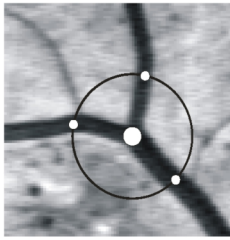
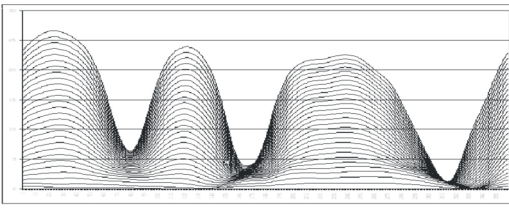
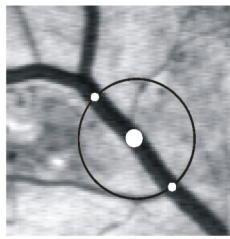
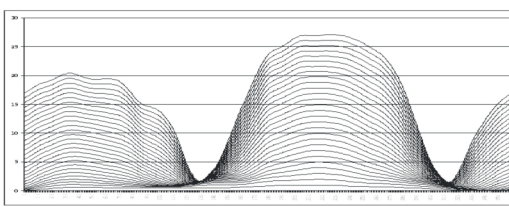
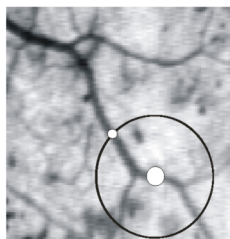
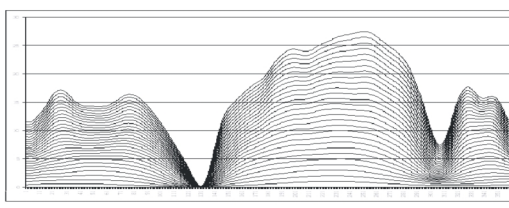
2.4 Реализация метода локального веерного преобразования

Для реализации алгоритма дискретного веерного преобразования необходимо для каждой точки исходного изображения выполнить следующие пункты:

1. Предварительная обработка изображений.
2. Построение радиальных разверток ЛВП для выбранного диапазона радиусов от r_{\min} до r_{\max} .
3. Фильтрация радиальных разверток.
4. Поиск локальных минимумов.
5. Определение направлений трассы, определение количества и углов ветвлений трассы.

Схема основных этапов алгоритма оценивания направлений и использования метода ЛВП приведена на рисунке 21.

Таблица 1
Примеры радиальных разверток

Фрагмент изображения	Радиальная развертка
	
	
	

2.4.1 Формирование радиальной развертки

Для решения основной задачи выделения центров ветвей необходимо сформировать радиальную развертку для каждой точки исходного изображения. Развертка представляет из себя набор функций (2) с радиусами от r_{\min} до r_{\max} . r_{\min} - минимальный радиус, для которого строится радиальная развертка. r_{\max} - длина отрезка прямой, которым аппроксимируются ветви сетчатой структуры.

Для каждого радиуса анализируемой точки рассматриваются направления с шагом в один градус. Получаем координаты некоторой новой точки, яркость которой прибавляется к значению функции (2) для предыдущего радиуса с тем же направлением. В результате, для каждого пикселя изображения, формируется матрица, строки которой соответствуют радиусам рамки, а столбцы – направлениям. Пример радиальной развертки точки полутонного изображения приведен на рис. 20 и таблице 1.




Рис. 20. Пример радиальной развертки для пяти значений радиуса:
 а) анализируемая точка, б) радиальные развертки

2.4.2 Обработка графиков радиальных разверток

На полученных радиальных развертках будут наблюдаться яркостные всплески из-за неравномерности распределения яркости на изображении. Поэтому необходимо провести фильтрацию этих всплесков. Для этого наиболее подходит *медианный фильтр*.

Это нелинейный метод обработки сигналов, позволяющий убирать резкие выбросы. Для фильтруемой точки берутся значения ее соседей и заносятся в таблицу. Эта таблица сортируется по возрастанию, и за новое значение точки принимается значение из средней ячейки таблицы. Таким образом, если в точке был выброс, то она оказывается на краю отсортированной таблицы и не попадает в отфильтрованный сигнал.

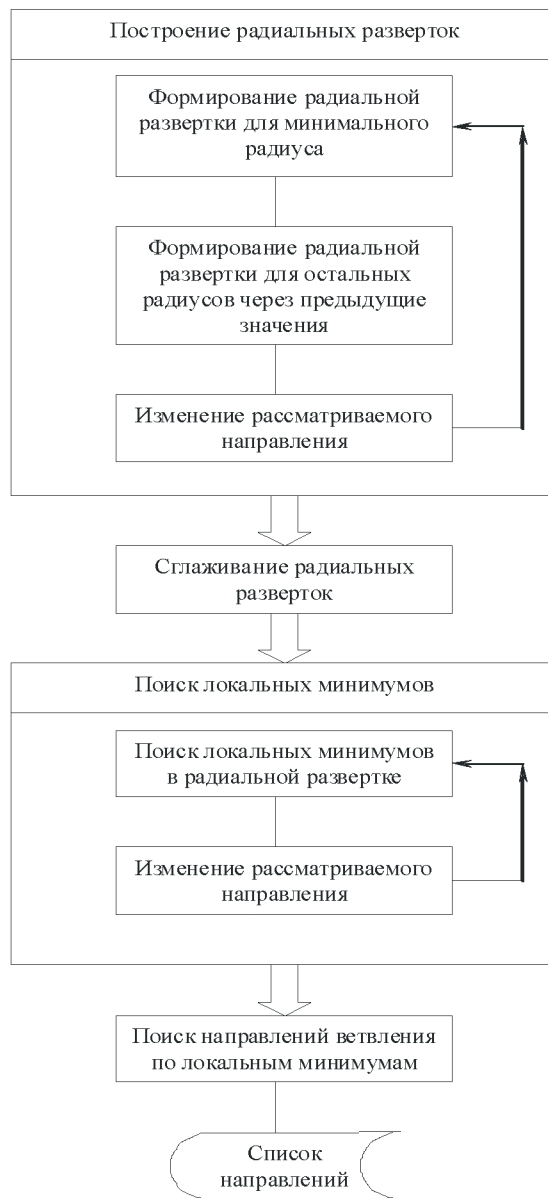
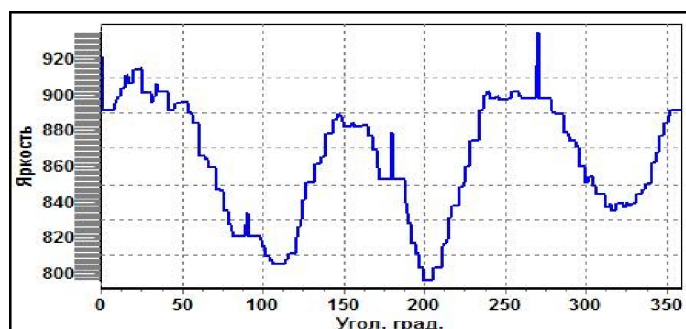



Рис. 21. Общий алгоритм поиска направлений



а)



б)

Рис. 22. Пример работы медианного фильтра: а) развертка до фильтрации, б) развертка после фильтрации

Размер окна медианного фильтра влияет на ширину фильтруемых всплесков. Чем больше окно, тем более широкие выбросы сглаживаются. Пример работы медианного фильтра с размером окна, равного трем пикселям, приведен над графиком радиальной развертки, рис. 22.

2.4.3 Поиск локальных минимумов

Для каждой полученной развертки, соответствующей какому-либо радиусу, необходимо обнаружить локальные минимумы, которые будут указывать на направления, в которых присутствует ветвь. Найденная ветвь будет иметь длину, равную размеру рассматриваемого радиуса рамки.

Алгоритм заключается в следующем. Заводится некоторая матрица направлений, размерность которой равна размерности матрицы разверток, и инициализируется нулями. Для каждой строки матрицы разверток (развертка, соответствующая текущему радиусу) ищется глобальное максимальное значение. Далее рассматриваются все значения в строке (направления) по порядку начиная с координаты глобального максимального значения. Оно помечается как локальный максимум. Если разница следующего и текущего значений отрицательна, то наблюдается спад значений функции. Последующее направление запоминается как первое минимальное направление. Если же разница следующего и текущего значений положительна, то наблюдается возрастание значений функции.

Текущее направление помечается как второе минимальное направление, при условии, что возрастание встречено первый раз после убывания. Далее ожидается спад. Как только он встречен, то все направления, начиная с первого минимального и заканчивая вторым минимальным, помечаются как локальные минимумы и на соответствующих местах матрицы направлений ставятся единицы, при условии, что глубина падения такого локального минимума не менее заданной глубины относительно локального максимума.

Текущее направление помечается как локальный максимум. Если в процессе перебора направлений встречено последнее направление, то перебор продолжается циклически (за последним направлением следует первое). Цикличность перебора обусловлена цикличностью направлений, заданных в градусах.

Структура описанного алгоритма представлена на рис. 23.

После работы описанного алгоритма будет получена матрица направлений, состоящая из нулей и единиц. Единицами будут отмечены направления, в которых обнаружены ветви.

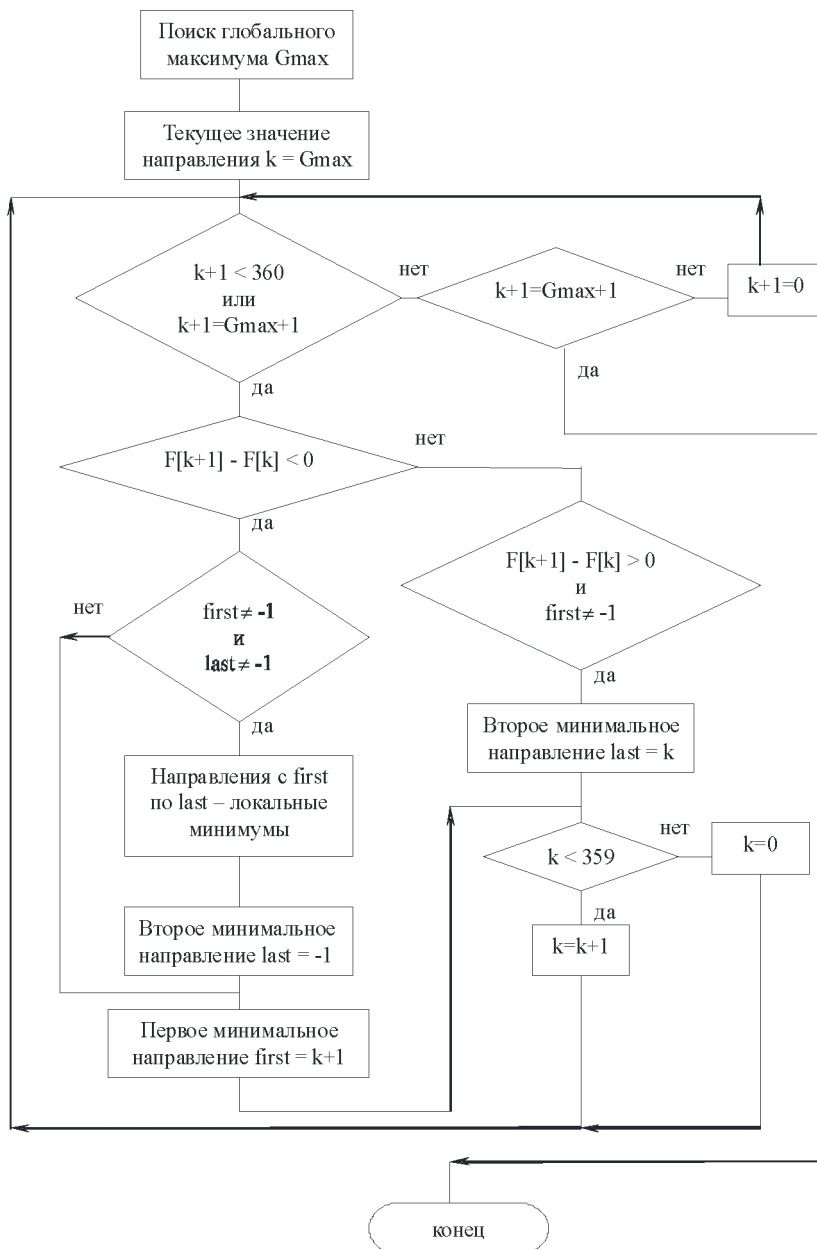


Рис. 23. Алгоритм поиска локальных минимумов

2.4.4 Поиск направлений ветвления

Рассматривается матрица направлений, строки которой соответствуют значениям радиуса рамки, а столбцы – направлениям. Для наибольшего радиуса (последняя строка) просматриваются все направления, в которых найдены локальные минимумы. Прослеживается, что найденный локальный минимум сохраняется при уменьшении радиуса для заданного направления.

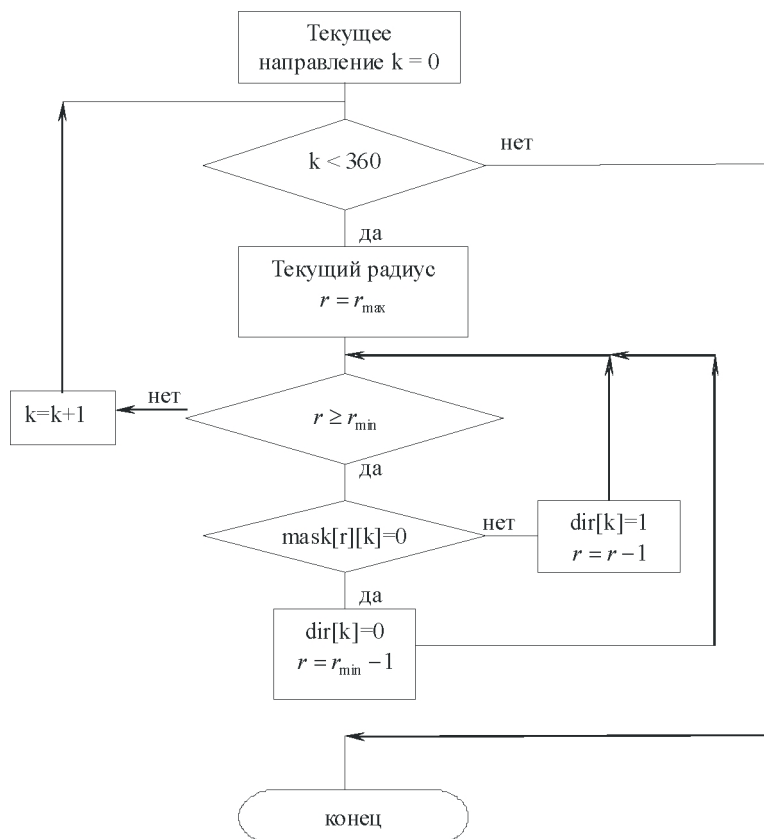


Рис. 24. Алгоритм поиска направлений

Если это выполняется, то направление заносится в список направлений анализируемой точки. Список направлений представляет

из себя вектор, длина которого равна числу направлений. На месте направлений, для которых найдена ветвь, стоят единицы, а на остальных местах нули. В списке направлений могут присутствовать области постоянных значений, равных единицам. Это означает, что ветвление обнаружено в соседних направлениях и указывает на то, что обнаруженная ветвь имеет толщину более одного пикселя. В этом случае единица оставляется только в центральном отсчете области, а остальные отсчеты обнуляются.

Структура алгоритма поиска направлений представлена на рис. 24.

2.4.5 Выделение центров ветвей сетчатых структур

После нахождения направлений ветвей в каждой точке исходного изображения можно выделить точки, принадлежащие центрам ветвей. В каждой точке изображения имеется список направлений. Используется тот факт, что в близлежащих точках, принадлежащих одной ветви, вычисленные направления близки, а в точках фона вычисленные направления случайны.

Заводится массив, совпадающий размерами с исходным изображением, и инициализируется нулями. Просматриваются все точки изображения и списки направлений. Если в точке (x_m, y_n) обнаружено направление под углом φ_k , то значения элементов массива, лежащие на отрезке $(x_m, y_n) - (x_m + R \cos \varphi_k, y_n + R \sin \varphi_k)$, $r = R_{\max}$, увеличиваются на единицу. Таким образом, направления, соответствующие ветвям, складываются и накапливаются, а случайные направления, найденные на фоне, располагаются хаотично. В результате наибольшие значения принимают те элементы массива, которые соответствуют протяженным ветвям.

Для проведения исследований генерировалось изображение, в точках которого можно теоретически оценить направление ветвления. Для этого используется график функции $f(x) = \sin(x)$ и ок-

ружность. Направления ветвления оценивается как угол наклона касательной в точке. Анализировалось среднее квадратичное отклонение обнаруженного направления от теоретически оцененного. Минимальный радиус рамки $r_{\min} = 3$, максимальный радиус рамки $r_{\max} = 10$. Точность оценивания направления на синтезированных изображениях представлена в табл. 2.

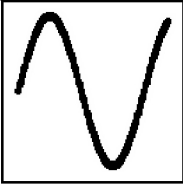
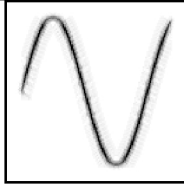
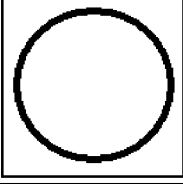
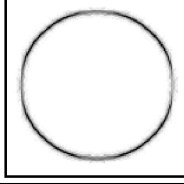
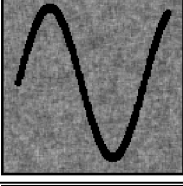
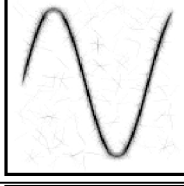
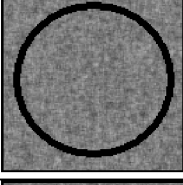
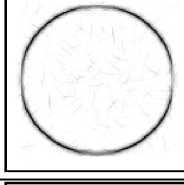
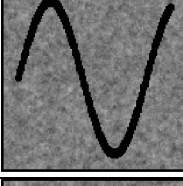
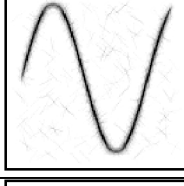
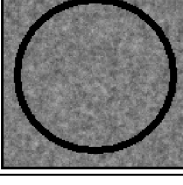
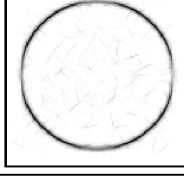
Исследования показали также, что яркость фона слабо влияет на качество обнаружения ветвей. Исследование качества обнаружения направлений ветвления в зависимости от наличия шума показали, что среднее квадратичное отклонение увеличивается при увеличении интенсивности шума, что указывает на ухудшение качества обнаружения ветвей при увеличении шумовой составляющей. Причем, если фон имеет постоянное значение яркости, то погрешность обнаружения меньше, чем при наличии фона с перепадами яркости.

Рассмотрим работу алгоритма при анализе натуральных изображений. Возьмем размер минимального радиуса рамки $r_{\min} = 3$, что указывает на то, что ветви длиной менее трех пикселей будут игнорироваться. Размер максимального радиуса рамки $r_{\max} = 10$, $r_{\max} = 20$, $r_{\max} = 30$, то есть найденные ветви будут аппроксимироваться отрезками соответствующей длины.

Результаты обработки представлены на рис. 25. Видно, что алгоритм успешно справляется с наличием разного рода пятен и близко расположенных ветвей. Найдены все ветви длиной, соответствующей значению r_{\max} .

Таблица 2

Точность оценивания направления на синтезированных изображениях

		Тестируемые изображения	Результирующие изображения	СКО
1	постоянная яркость фона			$\varepsilon^2 = 0,6\%$
2	постоянная яркость фона			$\varepsilon^2 = 0,61\%$
3	фон с биэкспоненциальной АКФ			$\varepsilon^2 = 0,87\%$
4	фон с биэкспоненциальной АКФ			$\varepsilon^2 = 0,9\%$
5	фон с изотропной АКФ			$\varepsilon^2 = 1,01\%$
6	фон с изотропной АКФ			$\varepsilon^2 = 1,03\%$




Рис. 25. Поиск направлений ветвления на натуральных изображениях:
 а) исходные изображения, б) результат обработки $r_{\max} = 10$, в) - $r_{\max} = 30$

3 ОЦЕНИВАНИЕ ГЕОМЕТРИЧЕСКИХ ПАРАМЕТРОВ ДРЕВОВИДНЫХ СТРУКТУР НА ОСНОВЕ ВЕЙВЛЕТ- АНАЛИЗА

3.1 Общая характеристика метода решения задачи

В данном подходе в качестве первичного признака анализируемого объекта используется характеристика извилистости ветвей [62, 63]. Основная идея предлагаемого метода формирования пространства диагностических признаков состоит в следующем: первоначально производится построение первичного признакового пространства – определяется дифференциальная характеристика кривой – кривизна, которая отражает степень изогнутости кривой в локальной окрестности каждой точки. Оценка кривизны для каждой кривой, представляющей собой центральную линию кровеносного сосуда, используется как первичные признаки. Для расчета кривизны используется *вейвлет-преобразование*.

Следует отметить, что при увеличении значений масштаба (при уменьшении полосы пропускания сглаживающего фильтра), используемого при расчете оценки кривизны, значение кривизны уменьшается, что приводит к неизотропности первичного признакового пространства. Для того чтобы этого избежать, производится нормировка первичного признакового пространства. Таким образом, получается первичное нормированное пространство признаков.

После формирования первичных диагностических признаков анализируется их информативность и значимость, то есть производится факторный анализ полученного признакового пространства, по результатам которого для формирования результирующего признакового пространства используется линейная комбинация признаков первичного нормированного признакового пространства.

Таким образом, задача формирования пространства диагностических признаков формально делится на три этапа: 1) выбор и анализ первичных диагностических признаков; 2) формирование пер-

вичного признакового пространства и его нормировка; 3) факторный анализ первичного признакового пространства и формирование результирующего признакового пространства.

3.1.1 Выбор и анализ диагностических признаков

В отличие от [62, 63], будем оценивать извилистость центральных линий сосудов предварительно обработанных с использованием сглаживающих фильтров с различной полосой пропускания (с различной степенью сглаживания), что при вычислении дифференциальных характеристик приводит к использованию вейвлет-преобразования. В качестве исходных данных используются центральные линии сосудов глазного дна человека, получаемые полуавтоматическим путем (эксперт ставит опорные точки на кровеносных сосудах на диагностических изображениях, по которым впоследствии проводится трассировка), которые представляют собой дискретные кривые. Используемый подход позволит как ограничить пагубное воздействие шумов, полученных в результате трассировки или при неточной постановке опорных точек, так и проанализировать «тренды» центральной линии, полученные при ее фильтрации Гауссовым фильтром с различной степенью сглаживания, что в дальнейшем позволит не только производить классификацию нормы и патологии, но и выявлять степень и вид патологии (различные виды патологий приводят к различным «видам» извилистости сосудов). Прежде чем перейти к рассмотрению признакового пространства, приведем математическое описание центральных линий сосудов глазного дна и определим характеристику извилистости.

3.2 Математическое описание центральных линий сосудов

Для того чтобы определить характеристику извилистости кровеносных сосудов глазного дна, необходимо определить понятие центральной линии сосуда.

3.2.1 Непрерывное представление центральной линии

Центральная линия сосуда представляет собой линию, составленную из точек равноудаленных от границ сосудов (центральных точек сосуда). Так как по своей природе сосуд не может быть прямым, то центральную линию кровеносного сосуда представим в виде параметрической кривой:

$$r(t) = (x(t), y(t)), t \in [0, L], \quad (3)$$

где L – длина центральной линии, а x, y – координаты точек кривой на плоскости, t – натуральный параметр.

Необходимо наложить ряд ограничений на значения кривой (3), чтобы добиться соответствия рассматриваемой модели физической природе кровеносных сосудов.

Во-первых, кривая (3) является регулярной кривой:

$$\left\| \frac{\partial r}{\partial t} \right\| \neq 0, \quad t \in (0, L). \quad (4)$$

Наличие «объемности» сегмента накладывает ограничение на множество допустимых значений центральной линии, связывающее кривизну центральной линии с функцией радиуса сегмента. Для любого $0 \leq l \leq L$

$$R(l) > d, \quad (5)$$

где d – радиус сосуда в исследуемой точке (так как диаметр сосуда в пределах одного сегмента практически не изменяется, то величину d можно считать постоянной), $R(l)$ – радиус кривизны (3) – величина обратно пропорциональная кривизне, определяемой в случае задания кривой через натуральный параметр следующим выражением [64]:

$$k(l) = \frac{d^2 r(l)}{dl^2}. \quad (6)$$

Использование второй производной в (6), а также необходимость расчета кривизны для формирования признакового пространства неизбежно накладывает условие существования второй производной в правой части (6), что, впрочем, согласуется с физической природой сосудов.

Далее, кривая (3) по своей физической природе не может иметь самопересечений. Для любых двух точек $r(l_1)$, $r(l_2)$, принадлежащих центральной линии, должно выполняться условие:

$$\|r(l_1) - r(l_2)\| > 2d, \quad \forall l_1, l_2 \in [0, L]. \quad (7)$$

3.2.2 Дискретное представление центральной линии ветви

Центральная линия сосуда в дискретном представлении получается в результате равномерной дискретизации с шагом $\Delta t = 1$ гладкой регулярной параметрической кривой (3) (чтобы при дальнейшем сглаживании дискретной кривой избежать перераспределения точек вдоль кривой, что может привести к «сгущению» точек в некоторых областях кривой) и описывается последовательностью точек плоскости:




Рис. 26. Пример кривой, представляющей центральную линию:
 а) кривая до равномерной дискретизации с шагом $\Delta t = 1$,
 б) кривая после равномерной дискретизации с шагом $\Delta t = 1$

$$r = \left\{ r^n \right\}_{n=0, N}. \quad (8)$$

Пример кривой, представляющей собой центральную линию кровеносного сосуда, до и после равномерной дискретизации с шагом $\Delta t = 1$ приведен на рис. 26.

3.3 Формирование первичного признакового пространства

Как было отмечено ранее, центральная линия сосуда представляется в виде гладкой регулярной параметрической кривой (3). Аналогично работам [62, 63] для описания степени извилистости кривой будем использовать оценку кривизны, которая представляет собой дифференциальную характеристику кривой, отражающую степень изогнутости кривой в локальной окрестности каждой точки.

3.3.1 Определение кривизны

Кривизна гладкой регулярной параметрической кривой в непрерывном случае определяется формулой [64]:

$$k(t) = \frac{x'(t)y''(t) - x''(t)y'(t)}{\left(x'(t)^2 + y'(t)^2\right)^{\frac{3}{2}}}, t \in [0, L], \quad (9)$$

где $x'(t), y'(t)$ – первые производные координат кривой (3) по параметру t , $x''(t), y''(t)$ – вторые производные координат кривой (3) по параметру t .

Величина кривизны в каждой точке определяется локальной изогнутостью кривой в малой окрестности данной точки, и некоторая ее интегральная величина отражает извилистость сосуда.

3.3.2 Сглаживание гладкой регулярной параметрической кривой

Для выявления геометрической информации о центральной линии ветви, соответствующей различным частотным диапазонам ко-

лебания центральной линии, используется низкочастотная фильтрация для различных значений ширины полосы пропускания.

Для того чтобы убрать или ограничить действия шумов, проявляющихся вследствие целочисленности трассировки или сдвига опорной точки, на значение кривизны, необходимо провести сглаживание кривой после равномерной дискретизации.

Сначала рассмотрим случай непрерывной гладкой регулярной параметрической кривой.

В качестве фильтра при сглаживании используется функция Гаусса с параметром S :

$$g_s(t) = \frac{1}{\sqrt{2\pi s^2}} \exp\left(-\frac{t^2}{2s^2}\right). \quad (10)$$

Сглаживание кривой (3) проводится при помощи свертки с функцией Гаусса (9):

$$\begin{cases} u_s(t) = x * g_s(t), \\ v_s(t) = y * g_s(t). \end{cases} \quad (11)$$

После сглаживания получается новая непрерывная кривая, имеющая вид:

$$r_s(t) = (u_s(t), v_s(t)). \quad (12)$$

Для фиксированного значения масштаба s для сглаженной кривой (12) производится расчет значений кривизны по формуле (9). Для этого необходимо вычислить значения первых и вторых производных кривой после ее сглаживания функцией Гаусса.

Для нахождения производных воспользуемся следующей формулой:

$$\frac{d}{dt}(f * h(t)) = f * \frac{d}{dt}h(t). \quad (13)$$

Тогда применив к (10) формулу (12), получаем:

$$\begin{cases} \frac{d}{dt}u_s(t) = \frac{d}{dt}(x * g_s(t)) = x * \frac{d}{dt}g_s(t); \\ \frac{d}{dt}v_s(t) = \frac{d}{dt}(y * g_s(t)) = y * \frac{d}{dt}g_s(t). \end{cases} \quad (14)$$

Следует отметить, что функция $\frac{d}{dt}g_s(t)$ с точностью до нормирующего множителя является Гауссовым вейвлетом первого порядка.

Аналогично определим вторые производные сглаженной кривой (12):

$$\begin{cases} \frac{d^2}{dt^2}u_s(t) = \frac{d^2}{dt^2}(x * g_s(t)) = x * \frac{d^2}{dt^2}g_s(t); \\ \frac{d^2}{dt^2}v_s(t) = \frac{d^2}{dt^2}(y * g_s(t)) = y * \frac{d^2}{dt^2}g_s(t). \end{cases} \quad (15)$$

Следует отметить, что функция $\frac{d^2}{dt^2}g_s(t)$ с точностью до нормирующего множителя является Гауссовым вейвлетом второго порядка.

Вейвлет, являющийся производной первого порядка функции Гаусса, называется WAVE-вейвлетом и имеет вид:

$$g'_s(t) = -\frac{1}{\sqrt{2\pi}s^3}t \exp\left(-\frac{t^2}{2s^2}\right). \quad (16)$$

Вейвлет, являющийся производной второго порядка функции Гаусса, называется МНАТ-вейвлетом и имеет вид:

$$g''_s(t) = \frac{1}{\sqrt{2\pi}s^3}\left(1 - \frac{t^2}{s^2}\right) \exp\left(-\frac{t^2}{2s^2}\right). \quad (17)$$

Пример этих вейвлетов приведен на рис. 27.




Рис. 27. Примеры базисных функций вейвлет: а) WAVE-вейвлет, б) MHAT-вейвлет

После расчета производных производится расчет кривизн по формуле [64] для различных значений параметра масштаба.

Рассмотрим случай дискретной кривой.

Функция Гаусса в дискретном случае имеет вид:

$$g_s(n) = \frac{1}{\sqrt{2\pi s^2}} \exp\left(-\frac{n^2}{2s^2}\right), n = \overline{0, N}. \quad (18)$$

Сглаживание дискретной кривой (8) проводится при помощи свертки с дискретной функцией Гаусса (18):

$$\begin{cases} u_s(n) = x * g_s(n), \\ v_s(n) = y * g_s(n). \end{cases} \quad (19)$$

После сглаживания получается новая дискретная кривая, имеющая вид:

$$r_s(n) = (u_s(n), v_s(n)). \quad (20)$$

Расчет кривизн для различных значений масштаба производится с помощью вейвлет преобразования по формуле:

$$k_s(n) = \frac{u'_s(n)v''_s(n) - u''_s(n)v'_s(n)}{\left(u'_s(n)^2 + v'_s(n)^2\right)^{\frac{3}{2}}}, n = \overline{0, N}. \quad (21)$$

Пример расчета кривизны для дискретных кривых приведен на рис. 28 и рис. 29.




Рис. 28. Пример расчета кривизны для дискретной кривой, представляющей собой центральную линию кровеносного сосуда в норме

Далее рассмотрим алгоритм вейвлет-преобразования дискретной кривой. В результате вейвлет-преобразования для каждой точки кривой (4) необходимо получить набор вейвлет-коэффициентов для различных значений масштаба $s = \overline{1, S}$. Дискретизация вейвлета будет проводиться в частотной области, при этом будет проводиться отсечение спектра вейвлета по размерам кривой. Тогда погрешность дискретизации определяется энергией отсеченной части вейвлета (в частотной и пространственной области).




Рис. 29. Пример расчета кривизны для дискретной кривой, представляющей собой центральную линию кровеносного сосуда с патологией

Будем считать, что значения масштаба выбраны так, что эффективный носитель вейвлета как в пространственной, так и в частотной области лежит в пределах исследуемой области (очевидно выбор других значений масштабной переменной является нецелесообразным). Тогда погрешность дискретизации можно считать пренебрежимо малой. В этом случае, алгоритм вейвлет-преобразования дискретной кривой состоит в следующем:

- 1) нахождение спектра кривой при помощи БПФ,
- 2) аналитическое представление дискретного спектра вейвлета,
- 3) перемножение спектра кривой и спектра вейвлета,
- 4) нахождение вейвлет образа при помощи обратного БПФ.

После расчета кривизны по формуле (16) с использованием вейвлет-преобразования дискретной кривой получаем матрицу диагностических признаков K размерности $S \times N$, где S - это количество используемых масштабов, а N - количество точек дискретной кривой.

3.3.3 Нормирование диагностических признаков

Следует отметить, что при увеличении значения масштаба рассчитанные по формуле (21) значения кривизны становятся не изотропными. При наличии сильных изломов на дискретной кривой, таких как на рис. 30а, значения кривизны стремятся к максимуму на первых масштабах, что показано на рис. 30б. Эти максимумы являются ложными, так как на реальных кровеносных сосудах не бывает изломов такого вида. Рассматривая значения кривизны в месте излома кривой (рис. 30), заметим, что эти значения близки к значениям, обратно пропорциональных к масштабу s (рис.31).




Рис. 30. Значения кривизны для модельной кривой, имеющей излом

Для того чтобы избежать ложных максимумов, необходимо нормировать значения кривизны на значение обратно пропорциональное масштабу $1/s$, то есть применить формулу:

$$\tilde{k}_s(t) = s \cdot k_s(t). \quad (22)$$

Следует отметить, что такое преобразование сделает пространство радиусов кривизны более удобным для анализа, хотя признаки утратят очевидный физический смысл.




Рис. 31. Значения кривизны в точке излома кривой

3.3.4 Формирование вектора признаков

Сформируем общий вектор признаков для каждой дискретной кривой. Для этого аналогично работе [63] используем взвешенную сумму кривизн, рассчитанных по формуле (20) для фиксированного значения масштаба. Этот вектор признаков будет иметь вид:

$$k(s) = \frac{1}{N} \frac{\sum_{i=1}^N [\tilde{k}_s(i)]^2}{\sum_{i=1}^N \tilde{k}_s^i}. \quad (23)$$

Вектор признаков, сформированный таким образом, используется для того, чтобы усилить влияние максимальных (пиковых) значений на результирующее значение кривизны. Таким образом, вектор признаков характеризует не только глобальное искривление кровеносного сосуда, но также отражает все локальные всплески.

3.4 Факторный анализ первичного признакового пространства и формирование результирующего признакового пространства

Проведем факторный анализ для уменьшения количества признаков. Для этого необходимо найти линейное преобразование, переводящее признаки в пространство меньшей размерности. Для нахождения этого преобразования воспользуемся разложением Карунена-Лоева.

3.4.1 Применение дискретного разложения Карунена-Лоева для уменьшения количества признаков

Пусть X - n -мерный случайный вектор. Введем обозначения:

Σ_x - корреляционная матрица случайного вектора X , которая находится по формуле:

$$\Sigma_x = \left[M(x^i, x^j) \right]_{ij} = \left[\frac{1}{N} \sum_{k=1}^N x_k^i x_k^j \right]_{ij}, \quad (24)$$

где (x^i, x^j) - элементы случайного векторы X , ϕ_i - собственные векторы корреляционной матрицы Σ_x , λ_i - собственные значения корреляционной матрицы Σ_x . Дискретное разложение Карунена-Лоева имеет вид:

$$X = Y\Phi, \quad (25)$$

где Φ - матрица собственных векторов корреляционной матрицы Σ_x , Y - новый вектор признаков. Используя разложение Карунена-Лоева, получаем, что оптимальные базисные векторы нового пространства – это собственные векторы корреляционной матрицы Σ_x .

При этом среднеквадратичная ошибка равна: $\hat{\varepsilon}_{opt}^2(m) = \sum_{i=m+1}^n \lambda_i$.

Заметим, что:

1) эффективность каждого признака, то есть его полезность с точки зрения представления X , определяется соответственным соб-

ственным значением; если некоторый признак y_i исключается из разложения, то среднеквадратичная ошибка увеличивается на λ_i , поэтому, если хотим уменьшить число признаков, признак с наименьшим собственным значением следует исключить в первую очередь и т.д.;

2) рассматриваемые признаки взаимно некоррелированы, то есть корреляционная матрица случайного вектора Y диагональная.

3) собственные векторы корреляционной матрицы Σ_x дают наименьшее значение среднеквадратической ошибки $\bar{\varepsilon}^2(m)$ среди всех ортонормированных базисных векторов.

Применим дискретное разложение Карунена-Лоева для уменьшения числа признаков. Рассмотрим выборку из 50 элементов, которые представляют собой реализации случайного вектора X . Каждый элемент из этой выборки представляет собой вектор признаков, состоящий из 20 значений масштаба, дальнейшее увеличение масштаба не приводит к большей информативности векторов признаков и разделению классов в признаковом пространстве. Уменьшим объем векторов признаков. Для этого воспользуемся дискретным разложением Карунена-Лоева (25). После вычисления корреляционной матрицы по формуле (24) можно заметить, что только пять собственных значений наиболее существенны, притом последнее превосходит все остальные более чем в 40 раз. Значит, с погрешностью $\bar{\varepsilon}^2 = 0,058$ можно исключить 19 координат в векторе признаков и оставить один. Преобразуем вектора признаки в менее объемные. Для этого используем формулу:

$$x'_k = x_k \cdot V, k = \overline{1, N}, \quad (26)$$

где V - матрица перехода.

Таким образом, из 20 первоначально выбранных масштабов получили один. Это не должно пугать, так как был рассмотрен всего один класс диагностических признаков.

3.4.2 Механизм расчета признаков и формирования признакового пространства

Общий механизм расчета признаков состоит в следующем:

- 1) кривизна рассчитываются по формуле (21);
- 2) полученные значения нормируются с помощью формулы (22);
- 3) формируются векторы признаков по формуле (23);
- 4) рассчитывается корреляционная матрица по формуле (24) для случайного вектора X , реализациями которого являются векторы признаки (для обучающей выборки);
- 5) вычисляются матрица собственных значений и матрица собственных векторов корреляционной матрицы случайного вектора X с помощью разложения Карунена-Лоева (для обучающей выборки);
- 6) с помощью матрицы преобразования, которая является матрицей собственных векторов корреляционной матрицы случайного вектора X , формируются новые вектора признаков, состоящие из одного значения.

С помощью данного механизма получают некоррелированные, информативные и эффективные вектора признаков, которые легко и удобно используются для классификации. Рассмотрим механизм расчета признаков на примере двух центральных линий кровеносных сосудов, одна из которых относится к нормальным, а другая к патологичным. Пример этих центральных линий приведен на рис. 32. Рассчитаем кривизны для каждой из этих центральных линий по формуле (21). Полученные матрицы кривизны приведены на рис. 33.

Нормируем полученные значения по формуле (22) и формируем вектор признаков по формуле (23). Далее рассчитывается корреляционная матрица векторов признаков по формуле (23), находятся ее собственные числа и собственные вектора. После чего формируются новые вектора признаков в признаковом пространстве.

Метод формирования признакового пространства на основе анализа дифференциальных характеристик центральных линий кровеносных сосудов глазного дна в дальнейшем позволит автоматизиро-

вать и повысить качество процесса диагностики возможных патологий глаза человека. Основой для выработанного подхода послужил метод оценки извилистости кровеносных сосудов на основе анализа кривизны их центральных линий. В рамках описанного метода используются сглаживание кривой, представляющей собой центральную линию сосуда, и нахождение ее кривизны с использованием вейвлет-преобразований. Такой способ сглаживания кривой и расчета ее кривизны позволяет наиболее полно учесть основные характеристики и индивидуальные особенности каждого кровеносного сосуда, а также варьировать точность определения извилистости центральной линии кровеносного сосуда глазного дна в зависимости от поставленных задач.




Рис. 32. Пример центральных линий кровеносных сосудов: а) нормальная, б) патологичная




Рис. 33. Матрицы кривизны: а) для нормального кровеносного сосуда, б) для патологичного кровеносного сосуда

4 ОЦЕНИВАНИЕ НАПРАВЛЕНИЙ ДРЕВОВИДНЫХ СТРУКТУР В ПРОСТРАНСТВЕ

4.1 Задача восстановления пространственной интенсивности по изображениям проекций

Запишем вид лучевого преобразования для трехмерного случая. Исследуемый объект (система коронарных сосудов) просвечивается параллельным пучком хорошо сфокусированных рентгеновских лучей (рис. 34). С противоположной стороны объекта располагается устройство, регистрирующее интенсивность каждого луча, которая ослабляется веществом, находящимся внутри объекта, пропорционально его плотности. Коэффициент поглощения рентгеновского излучения или интенсивность объекта в каждой точке задается функцией $f(\bar{x})$.




Рис. 34. Схема получения проекций

Направление лучей задается вектором $\bar{\theta} = (\theta_1, \theta_2, \theta_3)$, а точка, в которой считается лучевое преобразование, координатами (x_1, x_2, x_3) . Тогда интенсивность рентгеновского луча на выходе из объекта, задаваемая формулой (1), переписется в виде:

$$Pf(\bar{\theta}, \bar{x}) = \int_{-\infty}^{+\infty} f(x_1 + t\theta_1, x_2 + t\theta_2, x_3 + t\theta_3) dt. \quad (27)$$

Преобразование (27) называется *лучевым преобразованием для трехмерного случая*. Преобразование, вычисленное для зафиксированного направления, называется *проекцией*. Проекция трехмерного объекта представляет собой плоское изображение.

Проекция $P_{\bar{\theta}}f(\bar{x})$ вычисляются для всевозможных направлений $\bar{\theta}$ и для тех точек $\bar{x} \in \bar{\theta}^\perp$, при которых трехмерная функция $f(\bar{x})$ отлична от нуля. На практике размеры гиперплоскости ограничиваются физическими размерами исследуемого объекта.

Удобно ввести в рассмотрение сферу радиусом a , охватывающую исследуемый объект. В этом случае интеграл (27) равен:

$$Pf(\bar{\theta}, \bar{x}) = \int_{-a}^{+a} f(x_1 + t\theta_1, x_2 + t\theta_2, x_3 + t\theta_3) dt. \quad (28)$$

В ангиографических устройствах проекции вычисляются для конечного числа точек по гиперплоскости и конечного числа направлений, так как в реальных устройствах технически невозможно получить бесконечное число проекций и измерять интенсивность излучения для всех возможных значений \bar{x} . Поэтому проекционные данные $Pf(\bar{\theta}, \bar{x})$ в практических приложениях являются дискретными величинами.

4.2 Алгоритм восстановления пространственной интенсивности

Простейшим алгоритмом реконструкции является алгоритм, аналогом которого для преобразования Радона является алгоритм обратного проецирования. Его идея состоит в том, что оценку плотности в любой точке находят путем суммирования лучей, проходящих через эту точку. Фактически, для того чтобы восстановить интенсивность в любой точке, необходимо найти на каждой имеющейся проекции координаты, куда была спроецирована эта точка, взять

ее яркость и просуммировать все полученные значения. Для того чтобы это сделать, необходимо знать механику движения камеры.

Рассмотрим, каким образом происходит проецирование. Как уже упоминалось, входными данными являются ангиографические проекции с указанием для каждой первичного и вторичного угла поворота камеры. Ориентация этих углов показана на рис. 35. Любое положение камеры достигается двумя последовательными поворотами: сначала вокруг оси OX на угол α , затем вокруг новой оси OY' на угол β (рис. 35).




Рис. 35. Углы поворота камеры: а) первичный угол; б) вторичный угол

Следует отметить, что все повороты производятся по правилу правой тройки векторов, то есть против часовой стрелки. Таким образом, повороты на первичный и вторичный угол можно описать следующими преобразованиями.

Поворот вокруг оси OX :

$$M_1 = \begin{pmatrix} 1 & 0 & 0 \\ 0 & \cos \alpha & \sin \alpha \\ 0 & -\sin \alpha & \cos \alpha \end{pmatrix},$$

где α - первичный угол поворота.

Результатом данного преобразования является фактически переход к новой системе координат $OXY'Z'$.

Поворот вокруг новой оси OY' :

$$M_2 = \begin{pmatrix} \cos \beta & 0 & -\sin \beta \\ 0 & 1 & 0 \\ \sin \beta & 0 & \cos \beta \end{pmatrix},$$

где β - вторичный угол поворота камеры.

Зададим мировую систему координат $OXYZ$, связав ее с положением тела пациента во время проведения процедуры коронарографии. Пусть ось OX будет направлена в сторону ног, OY - в сторону левой руки и OZ - вертикально вверх (рис. 36). Поместим точку O , начало системы координат, в начальную точку сосуда, туда, где в сосуд входит катетер. В мировой системе координат орт оси OX $\vec{u}_0 = (1, 0, 0)$, орт оси OY $\vec{v}_0 = (0, 1, 0)$, нормаль к плоскости OXY $\vec{n}_0 = (0, 0, 1)$.




Рис. 36. Мировая система координат

Получение проекции представляет собой вычисление лучевого преобразования по формуле (28), то есть интегрирование в каждой точке излучающей поверхности камеры вдоль лучей, перпендикулярных этой поверхности. Зная углы поворота камеры, можно определить ориентацию получаемой проекции. Направление плоскости в пространстве можно задать, зная три единичных вектора

$\bar{u}(u_x, u_y, u_z)$ - орт оси OX , $\bar{v}(v_x, v_y, v_z)$ - орт оси OY , $\bar{n}(n_x, n_y, n_z)$ - нормаль к плоскости. Все вектора заданы своими координатами в мировой системе координат. Тогда эти вектора для проекции при любом положении камеры находятся следующим образом:

$$\bar{u} = M_1 \cdot M_2 \cdot \bar{u}_0,$$

$$\bar{v} = M_1 \cdot M_2 \cdot \bar{v}_0,$$

$$\bar{n} = M_1 \cdot M_2 \cdot \bar{n}_0.$$

Ориентация плоскости в пространстве определяется матрицей M :

$$M = \begin{pmatrix} u_x & v_x & n_x \\ u_y & v_y & n_y \\ u_z & v_z & n_z \end{pmatrix}.$$

Выразим M в явном виде:

$$M = \begin{pmatrix} \cos \beta & 0 & -\sin \beta \\ \sin \alpha \sin \beta & \cos \alpha & \sin \alpha \cos \beta \\ \cos \alpha \sin \beta & -\sin \alpha & \cos \alpha \cos \beta \end{pmatrix}.$$

Необходимо также учесть, что после поворотов камеры получаемые проекции смещаются относительно начала мировой системы координат. Чтобы совместить проекции, нужно указать на каждой проекции координаты точки, в которую была спроецирована какая-либо выбранная точка в пространстве. Назовем такие точки на проекциях базовыми и будем считать, что они являются проекциями начала мировой системы координат. Началом выбрана точка вхождения катетера в сосуд потому, что ее проекции легко идентифицируются на других.

Пусть на некоторой проекции базовая точка имеет координаты $b(b_x, b_y)$. Предположим, что начало системы координат плоскости пространственно совпадает с началом мировой системы координат, и выразим координаты базовой точки в мировой системе координат:

$b' = M \cdot b | 0$, где $b | 0$ - точка, имеющая координаты $(b_x, b_y, 0)$; b' - пространственная точка, имеющая координаты (b'_x, b'_y, b'_z) . Очевидно, чтобы совместить базовую точку на проекции с началом мировой системы координат, необходимо задать сдвиг плоскости на вектор $\bar{d}(-b'_x, -b'_y, -b'_z)$. Теперь преобразование координат любой выбранной точки пространства $p(p_x, p_y, p_z)$ в координаты плоскости запишется в виде:

$$p' = M^{-1} \cdot (p - \bar{d}). \quad (29)$$

При этом третья координата точки p' обычно не используется. Преобразование произвольной точки плоскости $p'(p'_u, p'_v)$ в координаты мировой системы координат записываются в следующем виде: $p = M \cdot p' | 0 + d$, где $p' | 0$ - точка, имеющая координаты $(p'_u, p'_v, 0)$. Таким образом, чтобы восстановить значение интенсивности в произвольной пространственной точке $p(p_x, p_y, p_z)$, вычисляются ее координаты $p'(p'_u, p'_v)$ на плоскости по формуле (29), а затем суммируются значения яркости точек в получаемых координатах по всем имеющимся проекциям:

$$I(p_x, p_y, p_z) = \frac{1}{N_{\text{проекций}}} \sum_{n=1}^{N_{\text{проекций}}} I_n(p'_u, p'_v),$$

где $I_n(p'_u, p'_v)$ - яркость точки $p'(p'_u, p'_v)$ на проекции.

Недостатком рассмотренного метода можно назвать то, что восстановление из-за дискретности данных происходит по конечному числу проекций, что приводит к погрешностям и появлению так называемых “артефактов” (ложных объектов и линий).

Пример восстановления пространственной интенсивности для двух круглых цилиндров приведен на рис. 37.

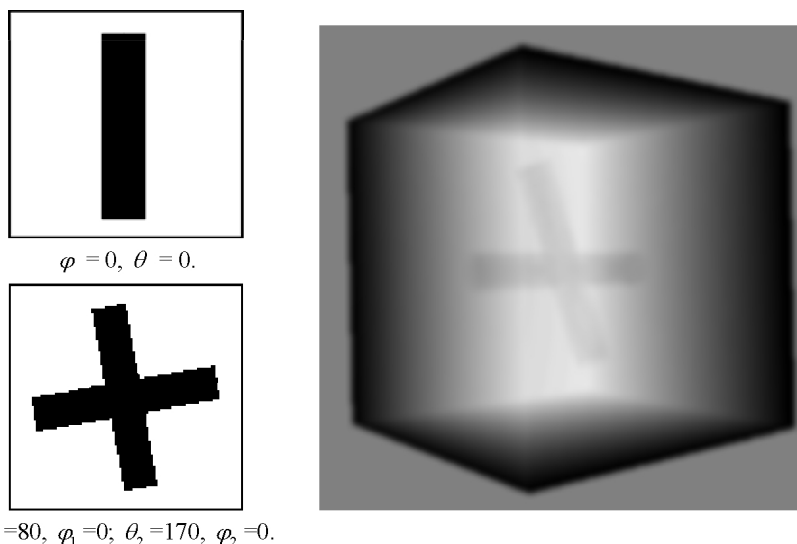


Рис. 37. Изображения проекций и восстановление пространственной интенсивности

4.3 3D локальное веерное преобразование Радона

Для анализа пространственных древовидных структур строится метод по аналогии с 2D случаем (см. гл. 2). Особенностью древовидных структур является наличие изгибающихся ветвей, поэтому ни одна ветвь не может быть приближена глобальной прямой линией, но для каждой точки ветви существует окрестность, в которой эта ветвь может быть аппроксимирована прямой. Кроме того, ветви могут проходить близко друг к другу, что является помехой при определении направления в одной из таких ветвей. Поэтому используется та же модификация метода, что описана в главе 2.

После проведения этапа восстановления интенсивности исходного объекта по изображениям его ангиографических проекций, описанного выше, имеется пространственное распределение интенсивности $I(x, y, z)$, где (x, y, z) - координаты точки в пространстве.

Используем дискретные координаты: x_m, y_n, z_l , где $m = \overline{1, M}$, $n = \overline{1, N}$, $l = \overline{1, L}$; M, N, L – размеры области, ограничивающей сосуд. Значения M, N, L можно оценить по размерам области, которая была просканирована для получения рентгеновских снимков исследуемого объекта.

Направление, в котором проводится интегрирование, задается вектором единичной сферы. Суммирование значений интенсивности происходит по этому направлению с увеличением расстояния от точки, для которой производится ЛВП, то есть по лучу. Таким образом, естественно будет перейти к сферической системе координат. Тогда положение любой точки в пространстве будет определяться сферическими координатами (θ, φ, r) , где θ задает угол поворота оси z относительно y , φ – оси x относительно z , а r – радиус, то есть расстояние, на которое точка (θ, φ, r) удалена от центра координат. В нашем случае пространственное распределение интенсивности было восстановлено для координат в декартовой системе. Поэтому, при интегрировании, когда определяются сферические координаты точки, в которой нужно найти интенсивность, необходимо перейти от сферических координат к декартовым. Формулы перехода:

$$\begin{cases} x = x_0 + r \cos \varphi \sin \theta, \\ y = y_0 + r \sin \varphi \sin \theta, \\ z = z_0 + r \cos \theta, \end{cases} \quad (30)$$

где (x_0, y_0, z_0) – координаты точки, в которой проводится ЛВП.

При вышеуказанном переходе получаемые координаты не всегда являются целочисленными, а значения интенсивности есть только для целых значений координат. На данном этапе необходимо провести интерполяцию.

В простейшем случае проводится интерполяция по ближайшему соседу, тогда (30) переписывается так:

$$\begin{cases} x_m = [x_0 + r \cos \varphi \sin \theta], \\ y_n = [y_0 + r \sin \varphi \sin \theta], \\ z_l = [z_0 + r \cos \theta], \end{cases} \quad (31)$$

где $[\]$ означает взятие целой части.

Можно также попытаться повысить точность алгоритма путем применения сложной схемы пространственной интерполяции, к примеру, используя значения интенсивности в 8 (куб размером 2x2) или в 27 (куб размеров 3x3) соседних точках.

Определим координаты соседей в случае 8 соседей:

$$\begin{cases} x_{m1} = [x_0 + r \cos \varphi \sin \theta], & x_{m2} = [x_0 + r \cos \varphi \sin \theta] + 1, \\ y_{n1} = [y_0 + r \sin \varphi \sin \theta], & y_{n2} = [y_0 + r \sin \varphi \sin \theta] + 1, \\ z_{l1} = [z_0 + r \cos \theta], & z_{l2} = [z_0 + r \cos \theta] + 1. \end{cases} \quad (32)$$

Значение интенсивности можно найти следующим образом:

$$\begin{aligned} I(x, y, z) = & \frac{1}{8} (I(x_{m1}, y_{n1}, z_{l1}) + I(x_{m1}, y_{n1}, z_{l2}) + \\ & + I(x_{m1}, y_{n2}, z_{l1}) + I(x_{m1}, y_{n2}, z_{l2}) + I(x_{m2}, y_{n1}, z_{l1}) + \\ & + I(x_{m2}, y_{n1}, z_{l2}) + I(x_{m2}, y_{n2}, z_{l1}) + I(x_{m2}, y_{n2}, z_{l2})), \end{aligned} \quad (33)$$

где значения x, y, z определяются по формуле (30), а координаты соседних точек по формулам (32).

Теперь перепишем преобразование:

$$F(\bar{x}; \theta, \varphi, r) = \sum_{t=0}^r f^*(x_0 + t \cos \varphi \sin \theta, y_0 + t \sin \varphi \sin \theta, z_0 + t \cos \theta), \quad (34)$$

где $f^*(x, y, z)$ - значение интенсивности, найденное в результате интерполяции (33). Преобразование проводится в точке $\bar{x} = (x_0, y_0, z_0)$ в направлении, определяемом углами (θ, φ) . Зададим шаги изменения Δ_1 и Δ_2 соответственно для углов θ и φ . Эти шаги

зависят от требуемой точности алгоритма и выбираются либо априорно, исходя из соображений об исследуемом объекте, либо определяются адаптивно в процессе работы.

Пусть для определенности число направлений по углу θ будет K_1 , а по φ - K_2 . Тогда преобразование (34) примет вид:

$$F(\bar{x}; \theta_i, \varphi_j; r) = \sum_{t=0}^r f^*(x_0 + t \cos \varphi_j \sin \theta_i, y_0 + t \sin \varphi_j \sin \theta_i, z_0 + t \cos \theta_i) \quad (35)$$

где $i = \overline{1, K_1}$, $j = \overline{1, K_2}$, $\bar{x} = (x_0, y_0, z_0)$. Преобразование, приведенное в формуле (35), представляет собой 3D локальное веерное преобразование.

4.4 Определение направления ветви в пространстве

Предлагается применить разработанный метод 3D ЛВП для каждой точки ветви, чтобы определить направления трассы в пространстве, то есть направления, вдоль которых происходит ветвление или ветвь продолжается. Легко видеть, что особым свойством такого подхода является большой объем вычислений, однако в результате работы алгоритма формируются все необходимые данные о структуре исследуемого объекта.

Определим радиус ограничивающей области r , исходя из априорных соображений о пространственных размерах сосуда. Оптимальное значение радиуса подбирается в процессе работы, когда можно сравнить результаты, полученные для разных значений. Возьмем точку $\bar{x} = (x_0, y_0, z_0)$. Зададим шаги интегрирования по углам: $\Delta_1 = 1^\circ$, $\Delta_2 = 1^\circ$.

Теперь посчитаем ЛВП по формуле (35). В результате получится набор значений ЛВП для заданного радиуса и разных направлений. Известно, что на ангиографических изображениях точки сосуда

имеют меньшую яркость, чем точки фона, поэтому восстановленная интенсивность также темнее там, где находится объект.

Чтобы выделить направления, в которых проходит сосуд, необходимо найти минимумы в полученном наборе. Для этого набор посчитанных значений ЛВП представляется в виде 2D матрицы (рис. 38): $M(\theta_i, \varphi_j)$, где $i = \overline{1, K_1}$, $j = \overline{1, K_2}$; K_1 – количество направлений по углу θ , K_2 – количество направлений по углу φ .




Рис. 38. Изображения а) значений ЛВП, б) матрицы возможных направлений

Любой отсчет $M(\theta_i, \varphi_j)$ есть значение локального веерного преобразования, посчитанного в точке $\bar{x} = (x_0, y_0, z_0)$ в направлении, заданном углами (θ, φ) . Для того чтобы найти минимумы, предлагается использовать пиковый фильтр:

$$M(\theta_i, \varphi_j) = \begin{cases} 0, & M(\theta_i, \varphi_j) \leq p, (\theta_i, \varphi_j) \in D; \\ 255, & M(\theta_i, \varphi_j) > p, (\theta_i, \varphi_j) \notin D, \end{cases}$$

где D – локальная область; p – пороговое значение.

Оптимальное значение порога находится при тестировании алгоритма. В результате получается матрица (рис. 38), в которой нулевое

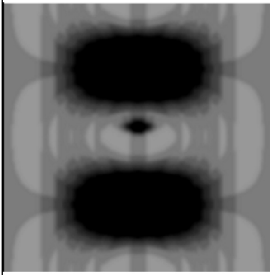
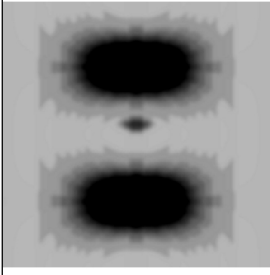
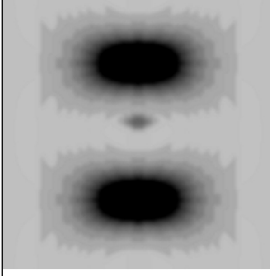
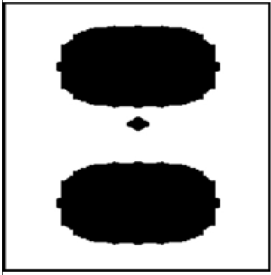
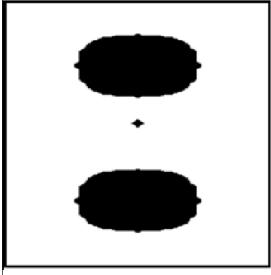
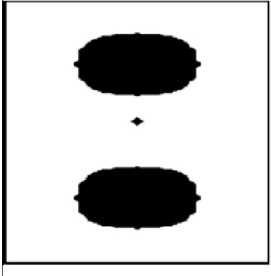
значение имеют элементы, соответствующие направлениям, по которым происходит ветвление. Так как ширина сосуда не равна одному пикселу, то можно выделить области, точки в которых имеют близкие направления. Необходимо произвести сегментацию и найти центральные точки этих областей.

Сегментация проводится по следующему алгоритму: находится первая точка, яркость которой равна нулю, заносится в некий список. Далее перебираются все соседние точки текущей: если какая-либо из них также имеет яркость равную, то она также заносится в список и затем алгоритм перебора соседей проводится рекурсивно. Таким образом, после окончания перебора имеется список точек. Находим центр, это направление запоминаем, а затем всем точкам из списка присваиваем значение яркости 255. Тогда при повторе последовательности действий уже выделенное направление не определяется. Когда значения отсчетов матрицы $M(\theta_i, \varphi_j)$ станут равными 255, тогда найдены все направления ветвления в заданной точке.

Далее предлагается считать 3ДЛВП в каждой точке не один раз, а несколько с разными радиусами области, в которой проводится преобразование. Возьмем точку внутри сосуда. Если отсутствуют помехи в виде пятен и проходящих рядом сосудов, то для заданного направления значение ЛВП с увеличением радиуса будет только повышаться. Действительно, при расширении области, в которой вычисляется преобразование, суммирование происходит уже не только по точкам сосуда, но и по фону.

Таким образом, если в этой точке находится локальный минимум, то он останется при всех значениях радиуса. В случае, когда рядом с сосудом присутствуют помехи, локальный минимум будет присутствовать в данном направлении не при всех значениях размера ограничивающей области, что позволит не выделить “ложное” направление (рис. 38).

Таблица 3
Сферические развертки 3ДЛВП в случае древовидного объекта с помехами

<i>Изображения матриц значений 3ДЛВП при разных радиусах</i>		
		
$R = 15$	$R = 18$	$R = 23$
<i>Бинарное изображение матриц</i>		
		
<i>Обнаруженные направления сосулов в пространстве</i>		
$\theta_1 = 90^\circ, \varphi_1 = 90^\circ; \theta_2 = 90^\circ, \varphi_2 = 270^\circ;$ $\theta_3 = 90^\circ, \varphi_3 = 195^\circ.$	$\theta_1 = 90^\circ, \varphi_1 = 90^\circ; \theta_2 = 90^\circ, \varphi_2 = 270^\circ;$ $\theta_3 = 90^\circ, \varphi_3 = 193^\circ.$	$\theta_1 = 90^\circ, \varphi_1 = 90^\circ; \theta_2 = 90^\circ, \varphi_2 = 270^\circ.$

4.5 Экспериментальное исследование метода

Экспериментальные исследования проводились на тестовых объектах и на двух видах изображений: искусственные модельные изображения и изображения фантома. Ниже приведено краткое описание процесса тестирования и его результатов, а также определены цели и задачи, которые мы преследовали.

4.5.1 Искусственные модельные изображения

Искусственные модельные изображения представляют собой искусственно сгенерированные изображения проекций. Требуется восстановить по заданным проекциям пространственную структуру объекта, а затем применить алгоритм нахождения направлений ветвления. В процессе такого тестирования производится проверка корректности работы алгоритма определения направлений для восстановленного объекта. Следует сказать, что в данном случае основной акцент делается не на результаты восстановления, а на алгоритм нахождения направлений ветвления. Поэтому, для того чтобы проверить работу этого алгоритма, будем восстанавливать достаточно простой объект, имеющий древовидную структуру. Будем генерировать проекции цилиндра с заданной ориентацией. Ниже приведены результаты тестирования. Проекции, по которым восстанавливается объект, приведены в таблице 4 вместе с первичным и вторичным углами поворота (рис. 39), $0^\circ \leq \theta < 180^\circ$, $-180^\circ \leq \varphi < 180^\circ$.


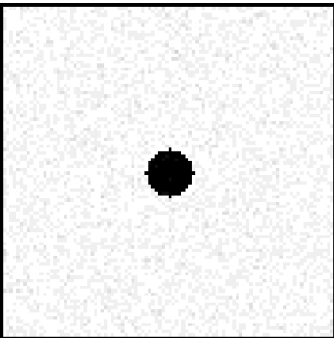
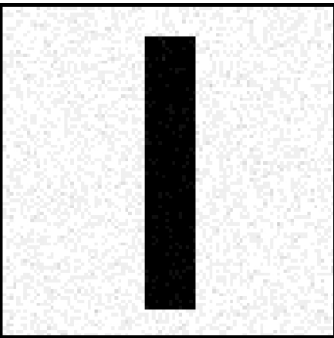
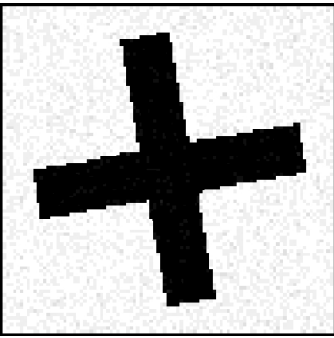


Рис. 39. Углы, задающие направление в пространстве

Таблица 4

Примеры работы алгоритма нахождения направлений ветвления для тестовых объектов с наложенным гауссовским шумом

Изображение сечения	Ориентация цилиндра (град)	Погрешность
	$\theta = 90, \varphi = 90$	$\varepsilon = 0,00349$
	$\theta = 0, \varphi = 0$	$\varepsilon = 0,00315$
	$\theta_1 = 80, \varphi_1 = 0$ $\theta_2 = 170, \varphi_2 = 0$	$\varepsilon = 0,00412$

Можно видеть, что для всех тестовых объектов графики весьма похожи. Это легко можно понять, если учесть, что сами объекты почти одинаковы и отличаются только ориентацией в пространстве. Также при увеличении дисперсии шума, то есть при уменьшении отношения сигнал/шум, погрешность работы алгоритма нахождения направлений ветвления увеличивается, что можно было ожидать. Однако ухудшение незначительно, то есть алгоритм является устойчивым к шуму.

4.5.2 Изображения фантома

Фантом представляет собой некоторый пространственный объект, сделанный из непрозрачного для рентгеновского излучения материала. По своей структуре он приближен к сосудам сердца. Фантом имеет два разветвления и, соответственно, три ветви, различные по диаметру. Съемка проекций фантома производится аналогично съемке реального сердца.

По полученным проекциям необходимо восстановить пространственную структуру исходного объекта. Производится тестирование алгоритма восстановления по ангиографическим проекциям.

Проверяется правильность геометрических преобразований, оценка качества восстановления пространственной структуры производится визуально. Входные данные, результат восстановления пространственной интенсивности и параметры восстановленного объекта приведены в табл. 5 и табл. 6. Таким образом, можно сделать вывод, что алгоритм восстановления пространственного распределения интенсивности и оценивания направлений в пространстве работает корректно.

Таблица 5
Обработка изображений проекций фантома №1

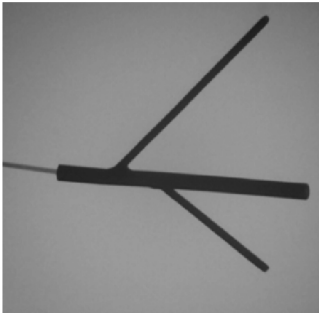
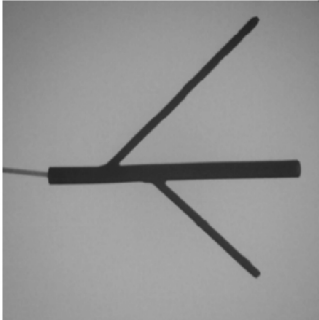
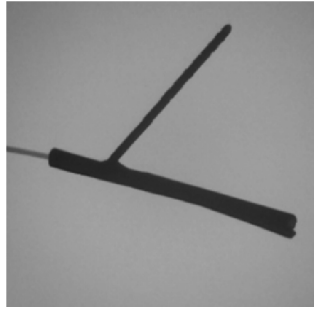
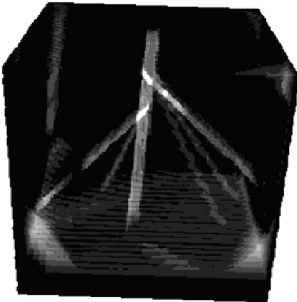
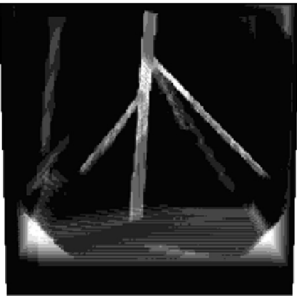
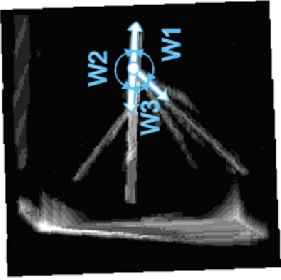


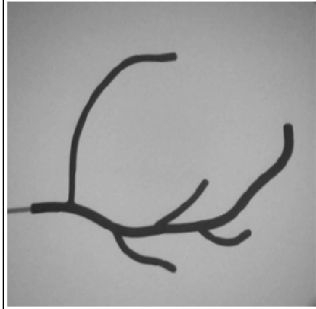
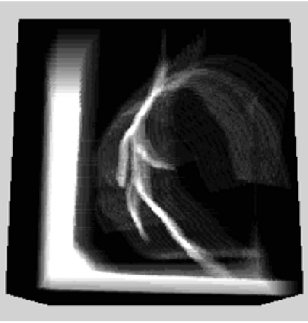
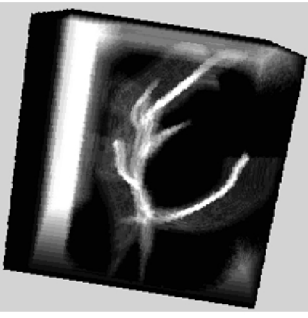
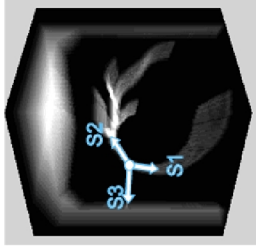
 <p>$\alpha = 0, \beta = 0.3$</p>	 <p>$\alpha = -19.9, \beta = 1$</p>	 <p>$\alpha = 40.1, \beta = -20$</p>
<p>Восстановление пространственной интенсивности. Восстановленные объекты: $W1 = 134^\circ, W2 = 180^\circ, W3 = 46^\circ$.</p>		
		

Таблица 6
Обработка изображений проекций фантома №2

 <p>$\alpha = 4.8, \beta = -14.7$</p>	 <p>$\alpha = 20.9, \beta = -5.1$</p>	 <p>$\alpha = -5.1, \beta = 15.1$</p>
<p>Восстановление пространственной интенсивности. Восстановленные объекты: $S1 = (161^\circ, 56^\circ), S2 = (72^\circ, 79^\circ), S3 = (89^\circ, 179^\circ)$.</p>		
		

5 ОЦЕНИВАНИЕ ЛОКАЛЬНЫХ НАПРАВЛЕНИЙ ВЕТВИ СЕТЧАТОЙ СТРУКТУРЫ

Как отмечалось выше, ветвь сетчатой структуры характеризуется распределением диаметра и угла вдоль нее, задающим базовый набор её признаков. Оценка локальных диаметров будет рассмотрена ниже. В данном параграфе будут предложены методы оценивания локальных направлений трассы, построенные на основе алгоритма трассировки ветвей с использованием метода прямого поиска направлений [28, 29, 30, 31, 32, 33, 34, 61].

5.1 Метод прямого поиска направлений

Основная идея алгоритма заключается в анализе выборки отсчетов поля изображения, попавших на границу круглого, сканирующего вдоль ветви структуры, окна радиуса R (полярной рамки). Радиус рамки можно брать примерно равным или немного большим средней толщины трассы. Скорость работы алгоритма прямо пропорциональна числу отсчетов, взятых на окружности. Допустимо использование не всех точек, а некоторой части из них, взятых с одинаковым шагом. На практике является допустимым использование πR точек с минимальной потерей точности определяемого угла в силу того, что яркость изображения в двух соседних точках расположенных на полярной рамке при развертке 360 отсчетов являются одинаковой (некоторые точки изображения, попавшие на полярную рамку, повторяются).

После выборки отсчетов задача сводится к одномерному случаю. Это существенно упрощает и, следовательно, ускоряет дальнейшую обработку. Для уменьшения влияния помех на исходном изображении (являющихся следствием таких факторов, как случайные локальные всплески и спады фона, погрешность ввода изображения) производится фильтрация отсчетов рекурсивным усреднением по

окну малого размера. Процедура фильтрации является рекурсивной, поэтому время работы алгоритма не зависит от размеров окна.




Рис. 40. Распределение функции яркости вдоль полярной рамки: а) фрагмент изображения, охватываемый рамкой, б) развертка функции яркости в зависимости от угла направлений, в) сглаженная функция яркости

После усреднения имеется функция распределения яркости по направлениям (рис. 40). Для нахождения углов, соответствующих направлениям входа ветви в полярную рамку и выхода из нее, накапливаются глобальные минимумы функции распределения яркости. Используя алгоритм быстрой рекурсивной сортировки значений, находим углы, соответствующие расположениям отсчетов с минимальными яркостями рамки в полярных координатах. Найденные углы являются направлениями трассы (если в данной окрестности она не разветвляется - направления входа и выхода).

Таким образом, в отсортированной по возрастанию значений яркости выборке определяются два или более (в случае раздваивания или пересечения с другой линией) значений направлений, первое из которых равно первому в выборке, а остальные определяются линейным поиском при условии отклонения направления от уже най-

денных не менее чем на заданный угол. Достоинствами рассмотренного метода являются высокая помехоустойчивость и быстрое действие.




Рис. 41. Иллюстрация алгоритма: а) изображение полярной рамки, пересекающей ветвь; б) функция яркости изображения, взятая в отсчетах круглой рамки

Профиль на рис. 41б после сглаживания и пороговой обработки позволяет найти углы ξ , ζ и φ после чего по формуле (36) находим искомую оценку параметров толщины.

$$D = 2R \sin \frac{\alpha}{2} \cdot \sin \frac{\varphi}{2}, \quad (36)$$

где D – искомая оценка; $\alpha = \frac{\xi + \zeta}{2}$ – средний угловой размер дуги;

φ – центральный угол между двумя центрами линий пересечений.

К недостаткам этого метода можно отнести слабую помехоустойчивость к аддитивному шуму и сильную зависимость результата от относительного положения объекта относительно рамки.

Достоинство этого метода легкость реализации и малое время получения оценки толщины.

5.2 Алгоритм трассировки ветви сетчатой структуры.

Автоматическая трассировка отдельного элемента структуры производится с учетом найденного направления в текущей точке.

Следует отметить, что метод прямого поиска сразу дает два направления возможного обхода ветви, в общем случае не точно противоположных (в случае изгиба), что позволяет находить дальнейшее направление с большей точностью. На каждом шаге трассировки производится оценка локального диаметра ветви. В качестве данного параметра можно принять число ненулевых отсчетов, лежащих на сечении, перпендикулярном к направлению движения трассы. При этом используется локальная пороговая обработка отсчетов изображения, попавших в сканирующее окно (рис. 42). Недостатком данного подхода является сильная зависимость от дискретизации изображения. Для более точного определения диаметра был разработан метод косвенного определения локального диаметра, а также класс методов, основанных на параметрической аппроксимации сечения ветви.




Рис. 42. Трассировка ветви с локальной предобработкой изображения в окне сканирования (фильтрация, пороговая обработка).

После оценки локальных геометрических характеристик ветви (диаметр, направление входа, выхода) исходная точка смещается на некоторый заданный шаг трассировки в направлении, которое выбирается из вычисленных ранее как наиболее близкое к конечной точке ветви. На основе дальнейшего анализа полученной последовательности локальных параметров производится оценка основных геометрических характеристик сетчатой структуры, которые в дальнейшем могут служить базовым набором для распознавания диагностических изображений. На рис. 43 показана работа процедуры трассировки сетчатой структуры и оценивания локальных диаметров на примере анализа диагностического изображения глазного дна.

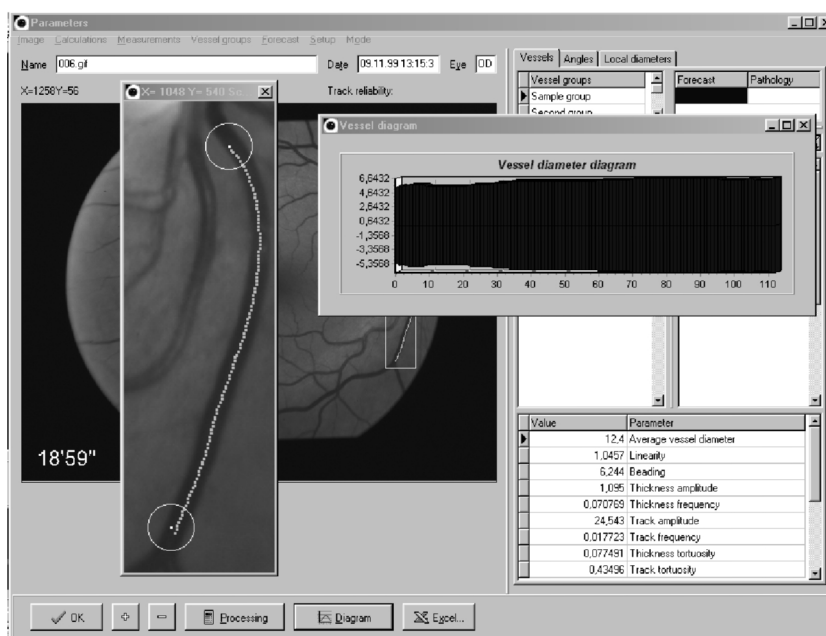


Рис. 43. Иллюстрация работы процедуры трассировки сосудов глазного дна и оценивания локальных диаметров

Алгоритм трассировки ветви сетчатой структуры состоит из следующих шагов:

1. Выделение фрагмента сосуда с помощью задания двух точек - начальной и конечной точек трассировки. При этом диаметр рамки сканирования должен быть больше диаметра сосуда примерно в 1.5-2 раза, во избежание попадания в рамку соседних сосудов или крупных шумовых фрагментов. Для изображения 512x512 размер рамки приблизительно равен 14 пикселям.

2. Формирование одномерного массива чисел, пропорциональных яркости точек изображения, которые лежат на окружности круглой рамки (рис. 40).

3. Применение к сформированному массиву чисел цифрового сглаживающего фильтра для уменьшения уровня шума. Размер окна сглаживающего фильтра устанавливается равным $TtR15$ (R - радиус рамки сканирования), и подобран экспериментальными исследованиями на серии натуральных изображений глазного дна для стабильности работы алгоритма и повышения точности расчётов.

4. Формирование массива чисел, пропорциональных угловым координатам всех локальных минимумов сглаженного массива чисел (пункт 3 алгоритма) с помощью определения смены знаков производной.

5. Пороговая обработка сглаженного массива чисел (пункт 3 алгоритма) с целью получения бинарного массива чисел, состоящего из нулей и единиц, для выделения отсчётов изображения, принадлежащих сосуду, а не фону, окружающему сосуд. Для повышения точности нахождения порога используем отсчёты не только принадлежащие окружности круглой рамки, но и области описанного вокруг рамки квадрата. Нахождение порога осуществляется автоматически путём анализа гистограммы функции яркости рассматриваемой области изображения.

6. Применение к сформированному массиву чисел (пункт 5 алгоритма) цифрового рангового фильтра окном размера 5 с рангом 3 для усреднения точечных локальных минимумов, связанных с импульсным шумом фона изображения.

7. Формирование упорядоченного по убыванию угловых длин отрезков нулевых значений сглаженного бинарного одномерного массива чисел (пункт 6 алгоритма) с отбором четырёх наибольших по длине отрезков нулевых отсчётов (условно «угловых дуг»), выбранных по правилу: если число «угловых дуг» меньше четырёх, то все «дуги» сохраняются, если больше четырёх, то вычисляется суммарная угловая длина «дуг» до тех пор, пока она не превысит 80% от угловой длины всех «дуг» или пока их число не будет равно четырём.

8. Сравнение угловых координат локальных минимумов, полученных по пунктам 2.3 с угловыми координатами «дуг» (отрезков нулевых отсчётов массива по пункту 7: если минимум не принадлежит одной из четырёх «дуг», то он удаляется из массива минимумов, если несколько минимумов принадлежат одной «дуге», то оставляется один из них.

9. Определение направления сосуда в данной точке: если число дуг, полученных в пункте 7, меньше трёх, то направлением сосуда считается угловая величина того минимума массива чисел, который получен в пункте 4, с учётом пункта 8, и который ближе всего к направлению, полученному на предыдущем шаге сканирования сосуда круглой рамкой; если число «дуг», полученных в пункте 7, три или четыре, то направлением сосуда считается угловая величина того минимума массива чисел, который получен в пункте 4, с учётом пункта 8, который ближе к направлению на конечную точку выбранного участка сосуда. Если выбранное направление отклоняется от направления на конечную точку участка сосуда на угол, больший допустимого (90°), то за направление сосуда в данной точке принимается направление на конечную точку.

10. Определение координат следующей точки трассы, в которую смещается круглая рамка по формуле:

$$x_{n+1} = x_n + \Delta \cos \alpha, \quad (37)$$

$$y_{n+1} = y_n + \Delta \cos \alpha,$$

где (x_n, y_n) и (x_{n+1}, y_{n+1}) - координаты текущей и последующих точек трассы сосуда, в которые помещается центр круглой рамки, Δ - шаг трассировки (шаг сканирования круглой рамки вдоль сосуда), α - угол локального направления сосуда, найденный в пункте 9.

11. Метод по пунктам 1, 2, состоящий в определении локального диаметра (толщины) сосуда в заданной точке по правилу: если число «дуг», найденных в пункте 7, равно двум, что соответствует участку трассы без пересечений и без ветвлений, то диаметр сосуда определяется по формуле:

$$D = 2R \sin \frac{\beta}{2} \sin \frac{\gamma}{2}, \quad (38)$$

где R - радиус круглой рамки, β - среднеарифметическое угловых размеров двух «дуг», образованных при пересечении сосуда круглой рамкой и определённых в пункте 7 с учётом пункта 8, γ - центральный угол, образованный двумя радиусами круглой рамки, направленными на центры двух «дуг»; если число «дуг», определённых по пункту 7, более двух, то диаметр сосуда не вычисляется, а данная точка сосуда относится к списку недостоверных точек и круглая рамка смещается ещё на один шаг.

6 ОЦЕНИВАНИЕ ЛОКАЛЬНЫХ ДИАМЕТРОВ СЕЧЕНИЙ ВЕТВИ

6.1 Параметрические модели структурных элементов

Рассмотрим класс методов, основанных на использовании различных параметрических моделей представления элемента сетчатой структуры. Измеренную функцию яркости вдоль сечения ветви аппроксимируем некоторой параметрической функцией. При этом наша задача сведется к оценке неизвестных параметров данной функции.

Опишем несколько моделей представления ветви. Одна из них основана на анализе реальных диагностических объектов изображений (на примере реального устройства кровеносного сосуда глазного дна), назовем их «физическими» моделями. Аналог данной модели представлен в работе [24]. Остальные на чисто внешнем сходстве графиков функций сечения ветвей.

Первая модель представляет собой так называемую коаксиальную модель, где каждый элемент структуры представляет собой в разрезе два кольца (рис. 44). Внешнее кольцо назовем стенкой, внутреннее - объектом заполнения.

Данная модель описывается следующей функцией яркости:

$$\hat{I}(x) = \begin{cases} \left(2\rho_2\sqrt{R_2^2 - x^2} + 2(\rho_1 - \rho_2)\sqrt{R_1^2 - x^2} \right), & |x| \leq R_1; \\ 2\rho_2\sqrt{R_2^2 - x^2}, & R_1 \leq |x| \leq R_2; \\ 0, & |x| > R_2, \end{cases}$$

где R_1, R_2 - соответственно внутренний и внешний радиусы ветви (искомые величины), а ρ_1, ρ_2 - плотность заполнения и плотность стенок.

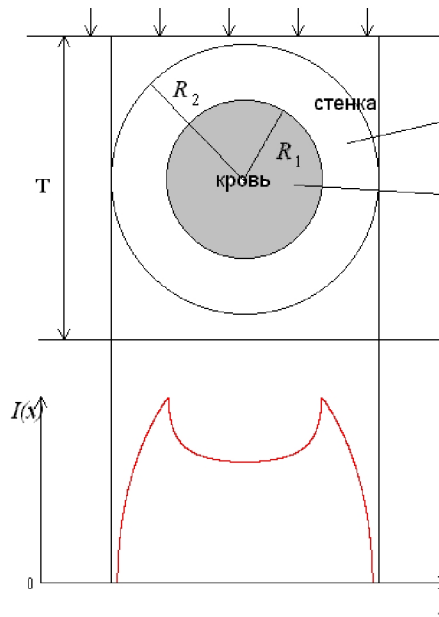


Рис. 44. Коаксиальная двухрадиусная модель

Более простой вариант модели получаем в случае отсутствия стенки ($R_1 = R_2$) или одинаковых оптических свойств стенки и заполнения ($\rho_1 = \rho_2$) (рис. 45). Для такой модели функция яркости имеет вид:

$$\hat{I}(x) = \begin{cases} 2\rho\sqrt{R^2 - x^2}, & |x| \leq R; \\ 0, & |x| > R, \end{cases}$$

где ρ - плотность заполнения, R радиус ветви.

На рис. 46 представлена вторая наиболее часто встречающаяся модель сечений ветви реальных диагностических изображений.

Она описывается функцией, график которой наиболее точно соответствует реальному сечению:

$$\hat{I}(x) = A + Be^{-\frac{|x-x_0|^p}{\sigma}},$$

где параметр A является подставкой, характеризующей фон изображения, B - амплитуда функции яркости, x_0 - смещение относительно начала координат при развертке профиля, характеризующее центр трассы, а σ - искомая ширина сечения.

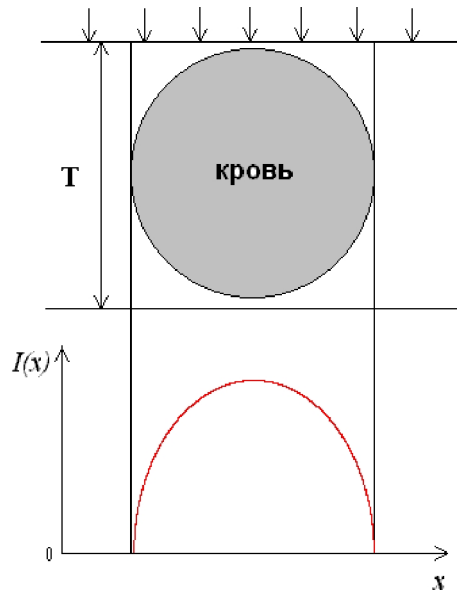


Рис. 45. Коаксиальная модель с бесконечно тонкой стенкой

Опишем третью дробно-рациональную модель сечения.

Достоинством такой модели по сравнению с экспоненциально - степенной является возможность оценки (как и в физических моделях) внутреннего радиуса трассы (рис. 47). Это объясняется тем, что дробно-рациональная функция может иметь более одного экстремума. Для формирования профиля с “ямкой”, необходимо существование трех экстремумов. Таким образом, чтобы смоделировать реальный профиль (на примере кровеносного сосуда), наложим определенные условия на вид дробно-рациональной функции.




Рис. 46. Экспоненциально-степенная модель сечения ветви

Функция должна стремиться к нулю на бесконечности, быть четной (симметричность профиля), положительной, ограниченной сверху (степень числителя меньше знаменателя и знаменатель не равен нулю) и сумма степеней числителя и знаменателя равна четырём. Функция, удовлетворяющая данным условиям имеет следующий вид:

$$\hat{I}(x) = \frac{A}{(x-x_0)^4 + a(x-x_0)^2 + b^2} + C.$$




Рис. 47. Дробно-рациональная модель сечения

Чтобы функция была ограниченной и положительной, должно выполняться следующее неравенство: $a^2 < 4b^2$ или совокупность неравенств: $a^2 \geq 4b^2$ и $a > 0$. При положительном значении пара-

метра a данная функция имеет один экстремум, при отрицательном - три экстремума.

При использовании данной модели в качестве внутреннего радиуса рассмотрим следующую величину, соответствующую (в случае существования “ямки”) экстремуму дробно-рациональной функции: $R_1 = \sqrt{a/2}$. Для определения внешнего радиуса используем вторую точку перегиба, лежащую на убывающем участке кривой (рис. 47): $R_2 = \sqrt{y}$, где y - положительный корень (большой из двух при $a < 0$) уравнения: $10y^3 + 9ay^2 + 3(a^2 - 2b^2)y - ab^2 = 0$, полученного при поиске точки перегиба приравнением второй производной дробно-рациональной функции нулю. Оценку параметров данной модели легко получить, сводя данную нелинейную модель к линейному виду заменой переменных.

6.2 Оценка локального диаметра с использованием метода моментов

При большом числе наблюдений выборочные и теоретические моменты близки друг к другу. Если теоретическая функция зависит от каких-либо параметров, то для определения параметров можно воспользоваться выборочными обобщёнными моментами [65, 66]. Таким образом, оценивание параметров $\vec{\Theta} = (\Theta_1, \Theta_2, \dots, \Theta_m)$ аппроксимирующих функций моделей произведем приравнением теоретических обобщенных моментов к эмпирическим:

$$\frac{1}{|D|} \int_D W_k(x) \hat{I}(x, \vec{\Theta}) dx = \frac{1}{n} \sum_{i=1}^n W_k(x_i) I(x_i), \quad k = 1, 2, \dots, m,$$

где $W_k(x) = x^{k-1}$, $k = 1, 2, \dots, m$. Применяя метод моментов для экспоненциально - степенной модели получим следующую систему нелинейных уравнений:

$$\left\{ \begin{array}{l} \hat{\mu}_0 = \frac{1}{(b-a)} \int_a^b I(x) dx = A + 2B\sigma \frac{1}{(b-a)n} \Gamma\left(\frac{1}{n}\right), \\ \hat{\mu}_1 = \frac{1}{(b-a)} \int_a^b xI(x) dx = \frac{1}{2} A(b-a) + 2Bx_0\sigma \frac{1}{(b-a)n} \Gamma\left(\frac{1}{n}\right), \\ \hat{\mu}_2 = \frac{1}{(b-a)} \int_a^b x^2 I(x) dx = \frac{1}{3} A(b^2 - a^2) + 2Bx_0^2\sigma \frac{1}{(b-a)n} \Gamma\left(\frac{1}{n}\right) + \\ \quad + 2B\sigma^3 \frac{1}{(b-a)n} \Gamma\left(\frac{3}{n}\right), \\ \hat{\mu}_3 = \frac{1}{(b-a)} \int_a^b x^3 I(x) dx = \frac{1}{4} A(b^3 - a^3) + 2Bx_0^3\sigma \frac{1}{(b-a)n} \Gamma\left(\frac{1}{n}\right) + \\ \quad + 6Bx_0\sigma^3 \frac{1}{(b-a)n} \Gamma\left(\frac{3}{n}\right), \\ \hat{\mu}_4 = \frac{1}{(b-a)} \int_a^b x^4 I(x) dx = \frac{1}{5} A(b^4 - a^4) + 2Bx_0^4\sigma \frac{1}{(b-a)n} \Gamma\left(\frac{1}{n}\right) + \\ \quad + 12Bx_0^2\sigma^3 \frac{1}{(b-a)n} \Gamma\left(\frac{3}{n}\right) + 2B\sigma^5 \frac{1}{(b-a)n} \Gamma\left(\frac{5}{n}\right). \end{array} \right.$$

Воспользуемся одним из методов решения данной системы [67] - методом Ньютона-Рафсона. Предположим, что необходимо решить систему из двух нелинейных уравнений: $f_1(x, y) = 0$, $f_2(x, y) = 0$. Неизвестное решение обозначим через (x_∞, y_∞) . Начинаем процесс решения с исходной точки (x_0, y_0) , которую можно отыскать методом проб и ошибок. Если нам удастся найти поправки h_0 и r_0 , такие, что $x_0 + h_0 = x_\infty$ и $y_0 + r_0 = y_\infty$, то получим решение системы нелинейных уравнений. В общем случае на n -й итерации найдена точка (x_n, y_n) , и мы ищем поправки h_n, r_n , такие, что $x_n + h_n = x_\infty$ и $y_n + r_n = y_\infty$. Используя двумерный ряд Тейлора, который имеет вид:

$$f(x+h, y+r) = f(x, y) + \left(h \frac{\delta}{\delta x} f(x, y) + r \frac{\delta}{\delta y} f(x, y) \right) + \frac{1}{2!} \left(h^2 \frac{\delta^2}{\delta x^2} f(x, y) + 2hr \frac{\delta^2}{\delta x \delta y} f(x, y) + r^2 \frac{\delta^2}{\delta y^2} f(x, y) \right) + \dots$$

и приравнявая к нулю разложение функций f_1, f_2 в точке $(x_n + h_n, y_n + r_n)$:

$$\begin{cases} -f_1(x_n, y_n) = \left(\frac{\delta}{\delta x} f_1(x_n, y_n) \right) h_n + \left(\frac{\delta}{\delta y} f_1(x_n, y_n) \right) r_n; \\ -f_2(x_n, y_n) = \left(\frac{\delta}{\delta x} f_2(x_n, y_n) \right) h_n + \left(\frac{\delta}{\delta y} f_2(x_n, y_n) \right) r_n. \end{cases}$$

Далее ищем решение полученной системы из двух линейных уравнений с неизвестными h_n, r_n и получаем упрощенный вариант решения системы нелинейных уравнений: $x_n + h_n = x_{n+1}$, $y_n + r_n = y_{n+1}$. Этот процесс продолжается до тех пор, пока не будет достигнута желаемая степень точности. Аналогично производится обобщение метода на случай трех и более переменных.

Представленную выше систему нелинейных уравнений можно значительно упростить, уменьшая существенно время выполнения процедуры оценивания. Для этого необходимо провести предварительное оценивание параметров: A, B . Оценка производится на основе анализа гистограммы функции яркости анализируемого профиля ветви. Для оценки параметра x_0 , определяющего смещение развертки профиля относительно начала координат, можно воспользоваться координатами трассы ветви, полученными алгоритмом трассировки. В качестве начального приближения параметра σ в методе Ньютона-Рафсона используем оценку ширины трассы, получаемую методом косвенного вычисления диаметра трассы, который будет описан ниже.

Рассмотрим *коаксиальную модель* с двумя радиусами:

$$f(x) = \begin{cases} A + \left(2\rho_2 \sqrt{R_2^2 - (x - x_0)^2} + 2(\rho_1 - \rho_2) \sqrt{R_1^2 - (x - x_0)^2} \right), \\ \quad |x - x_0| \leq R_1; \\ A + \left(2\rho_2 \sqrt{R_2^2 - (x - x_0)^2} \right), \quad R_1 \leq |x - x_0| \leq R_2; \\ A, \quad |x - x_0| > R_2. \end{cases}$$

Применяя метод моментов для данной модели получим следующую систему нелинейных уравнений:

$$\left\{ \begin{aligned} \hat{\mu}_0 &= \int_a^b f(x) dx = A(b - a) + \rho_2 \pi R_2^2 + (\rho_1 - \rho_2) \pi R_1^2; \\ \hat{\mu}_1 &= \int_a^b x f(x) dx = \frac{1}{2} A(b^2 - a^2) + \rho_2 \pi x_0 R_2^2 + (\rho_2 - \rho_1) \pi x_0 R_1^2; \\ \hat{\mu}_2 &= \int_a^b x^2 f(x) dx = \frac{1}{3} A(b^3 - a^3) + \rho_2 \pi x_0^2 R_2^2 + \frac{1}{4} \rho_2 \pi R_2^4 + \\ &\quad + (\rho_2 - \rho_1) \pi x_0^2 R_1^2 + \frac{1}{4} (\rho_1 - \rho_2) \pi R_1^4; \\ \hat{\mu}_3 &= \int_a^b x^3 f(x) dx = \frac{1}{4} A(b^4 - a^4) + \rho_2 \frac{3}{4} \pi x_0^2 R_2^4 + \rho_2 \pi x_0^3 R_2^2 + \\ &\quad + (\rho_1 - \rho_2) \frac{3}{4} \pi x_0 R_1^4 + (\rho_1 - \rho_2) \pi x_0^3 R_1^2; \\ \hat{\mu}_4 &= \int_a^b x^4 f(x) dx = \frac{1}{5} A(b^5 - a^5) + \rho_2 \frac{1}{8} \pi R_2^6 + \rho_2 \frac{3}{2} \pi x_0^2 R_2^4 + \rho_2 \pi x_0^4 R_2^2 + \\ &\quad + (\rho_1 - \rho_2) \frac{1}{8} \pi R_1^6 + (\rho_1 - \rho_2) \frac{3}{2} \pi x_0^2 R_1^4 + (\rho_1 - \rho_2) \pi x_0^4 R_1^2; \\ \hat{\mu}_5 &= \int_a^b x^5 f(x) dx = \frac{1}{6} A(b^6 - a^6) + \rho_2 \frac{5}{8} \pi x_0 R_2^6 + \rho_2 \frac{5}{2} \pi x_0^3 R_2^4 + \\ &\quad + \rho_2 \pi x_0^5 R_2^2 + (\rho_1 - \rho_2) \frac{5}{8} \pi x_0 R_1^6 + (\rho_1 - \rho_2) \frac{5}{2} \pi x_0^3 R_1^4 + \\ &\quad + (\rho_1 - \rho_2) \pi x_0^5 R_1^2. \end{aligned} \right.$$

Рассмотрим коаксиальную модель с бесконечно малой стенкой:

$$f(x) = \begin{cases} A + 2\rho\sqrt{R^2 - (x - x_0)^2}, & |x - x_0| \leq R; \\ A, & |x - x_0| > R. \end{cases}$$

Для данной модели система нелинейных уравнений будет иметь следующий вид:

$$\begin{cases} \hat{\mu}_0 = \int_a^b f(x)dx = A(b - a) + \pi\rho R^2; \\ \hat{\mu}_1 = \int_a^b xf(x)dx = \frac{1}{2}A(b^2 - a^2) + \pi x_0 \rho R^2; \\ \hat{\mu}_2 = \int_a^b x^2 f(x)dx = \frac{1}{3}A(b^3 - a^3) + \pi x_0^2 \rho R^2 + \frac{1}{4}\pi\rho R^4; \\ \hat{\mu}_3 = \int_a^b x^3 f(x)dx = \frac{1}{4}A(b^4 - a^4) + \frac{3}{4}\pi x_0^2 \rho R^4 + \pi x_0^3 \rho R^2. \end{cases}$$

Решая систему методом Ньютона-Рафсона находим неизвестные параметры аппроксимирующей функции, одним из которых и является искомый диаметр трассы.

6.3 Оценка параметров сечения с использованием метода МНК

Метод основан на минимизации следующего функционала:

$$J = \sum_{i=1}^n (\hat{I}_i - I_i)^2 \rightarrow \min,$$

где \hat{I}_i - эмпирическое значение функции яркости.

Приравнявая частные производные по параметрам нулю, получаем систему уравнений, решение которой и является оценкой неизвестных параметров рассматриваемой модели. Для экспоненциально-степенной модели такая система уравнений будет иметь вид:

$$\left\{ \begin{array}{l} \frac{\partial J}{\partial A} = -2 \sum_{i=1}^N \left(\hat{I}_i - A - B e^{-\left(\frac{|x_i - x_0|}{\sigma}\right)^n} \right) = 0; \\ \frac{\partial J}{\partial B} = -2 \sum_{i=1}^N \left(\hat{I}_i - A - B e^{-\left(\frac{|x_i - x_0|}{\sigma}\right)^n} \right) e^{-\left(\frac{|x_i - x_0|}{\sigma}\right)^n} = 0; \\ \frac{\partial J}{\partial \sigma} = -2 \sum_{i=1}^N \left(\hat{I}_i - A - B e^{-\left(\frac{|x_i - x_0|}{\sigma}\right)^n} \right) B \left(\frac{|x_i - x_0|}{\sigma} \right)^n \frac{n}{\sigma} e^{-\left(\frac{|x_i - x_0|}{\sigma}\right)^n} = 0; \\ \frac{\partial J}{\partial x_0} = -2 \sum_{i=1}^N \left(\hat{I}_i - A - B e^{-\left(\frac{|x_i - x_0|}{\sigma}\right)^n} \right) B \left(\frac{|x_i - x_0|}{\sigma} \right)^n \frac{n}{x_i - x_0} e^{-\left(\frac{|x_i - x_0|}{\sigma}\right)^n} = 0; \\ \frac{\partial J}{\partial n} = 2 \sum_{i=1}^N \left(\hat{I}_i - A - B e^{-\left(\frac{|x_i - x_0|}{\sigma}\right)^n} \right) B \left(\frac{|x_i - x_0|}{\sigma} \right)^n \ln \left(\frac{|x_i - x_0|}{\sigma} \right) e^{-\left(\frac{|x_i - x_0|}{\sigma}\right)^n} = 0. \end{array} \right.$$

Решение системы находим с помощью метода Ньютона-Рафсона.

Данный метод неприменим для коаксиальных моделей сетчатых структур. Это объясняется тем, что функции, описывающие данные модели, заданы различными выражениями на разных участках изменения аргумента. Границы этих участков зависят от некоторых из неизвестных параметров. Именно по этим параметрам нельзя взять аналитически частные производные.

Для двухрадиусной коаксиальной модели:

$$I(x) = \begin{cases} f_1(x) = A + 2\rho_2 \sqrt{R_2^2 - (x - x_0)^2} + 2(\rho_1 - \rho_2) \sqrt{R_1^2 - (x - x_0)^2}, \\ \quad |x - x_0| \leq R_1; \\ f_2(x) = A + 2\rho_2 \sqrt{R_2^2 - (x - x_0)^2}, \quad R_1 \leq |x - x_0| \leq R_2; \\ A, \quad |x - x_0| \geq R_2, \end{cases}$$

функционал имеет вид:

$$J = \sum_{|x_i - x_0| > R_2} (\hat{I}_i - 0)^2 + \sum_{|x_i - x_0| < R_1} (\hat{I}_i - f_1(x_i))^2 + \sum_{R_1 \leq |x_i - x_0| \leq R_2} (\hat{I}_i - f_2(x_i))^2.$$

Для коаксиальной модели с бесконечно малой стенкой функционал имеет вид:

$$J = \sum_{|x_i - x_0| \leq R} (\hat{I}_i - A - 2\rho\sqrt{R^2 - (x_i - x_0)^2})^2 + \sum_{|x_i - x_0| > R} (\hat{I}_i - A)^2 \rightarrow \min.$$

Для минимизации полученных функционалов используется один из методов покоординатного спуска [68].

6.4 Экспериментальные исследования алгоритмов оценивания локальных диаметров

Экспериментальные исследования проводились на диагностических изображениях сосудистой системы глазного дна.

В данных исследованиях большую сложность представляет отсутствие информации о реальных распределениях диаметра кровеносного сосуда вдоль трассы. Поэтому на первом этапе используем тестовые изображения сечений сосуда, полученные моделированием функции яркости профиля. Наложим на исходное изображение белый шум и проведем исследования устойчивости представленных методов.

Рассмотрим тестовое изображение (рис. 48) для экспоненциально-степенной модели:

$$I(x) = A + Be^{\left|\frac{x-x_0}{\sigma}\right|^p} + V(x),$$

где $V(x)$ - белый шум. Рассмотрим несколько вариантов отношения шум/сигнал: $h^2 = \sigma_v^2 / \sigma_i^2$, где σ_i^2 - дисперсия функции яркости, σ_v^2 - дисперсия шума. Погрешность выразим следующим образом:

$$\bar{\delta} = \frac{|\hat{\sigma} - \sigma|}{\sigma} 100\%,$$

где σ - радиус сосуда, использованный при моделировании тестового изображения, а $\hat{\sigma}$ - оценка радиуса одним из рассмотренных методов аппроксимации.




Рис. 48. Моделирование профиля сосуда

В табл. 7 и табл. 8 приведены зависимости погрешности методов оценивания от дисперсии шума для различных моделей аппроксимации.

Таблица 7

Точность оценивания диаметра (экспоненциально-степенная модель)

Шум/сигнал	Метод моментов	МНК
1%	2.01%	2.3%
2%	2.1%	2.5%
3%	2.2%	2.6%
5%	2.4%	2.8%
7%	4.08%	6.31%
10%	10.81	12.48%
15%	20.53%	24.11%

Точность оценивания диаметра (коаксиальная модель с бесконечно тонкой стенкой)

Шум/сигнал	Метод моментов	МНК
1%	6.12%	6.55%
2%	7.00%	7.23%
3%	7.91%	8.31%
5%	9.15%	9.76%
7%	10.08%	10.99%
10%	16.5%	17.04%
15%	25.72%	27.02%

Экспериментальные исследования также проведем на натуральных изображениях сосудистой системы глазного дна. На рис. 46 приведен профиль натурального изображения сечения сосуда (пунктиром) и функции яркости экспоненциально-степенной модели (сплошная линия). Для данного изображения получены следующие оценки параметров профиля: $\sigma = 8.5$, $A = 80$, $B = 145$, $x_0 = 20$, $n = 6$.

При использовании первой модели аппроксимации рассмотренные методы оценивания параметров приводят к громоздкости систем нелинейных уравнений. Сама модель в силу физичности является более точной, но погрешность нахождения параметров данной модели (в силу грубого усечения ряда Тейлора в методе Ньютона Рафсона) превышает погрешность, получаемую при замене физической модели на феноменологическую (2-3 модели). Это затрудняет клиническое применение данной модели. Экспоненциально-степенная модель даёт по сравнению с другими моделями более точный результат и является наиболее устойчивой к шумам. Но данная модель имеет один экстремум и поэтому позволяет найти только внешний радиус сосуда.

7 ПРИМЕНЕНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ОЦЕНИВАНИЯ ДИАГНОСТИЧЕСКИХ ПАРАМЕТРОВ

В настоящей главе представлен метод оценивания диагностических параметров на биомедицинских изображениях с помощью искусственных нейронных сетей [44, 45, 69]. Метод позволяет оценивать протяженность объектов на изображениях в заданных точках с заданными направлениями (рис. 49), что дает возможность определения важных параметров объектов (характеристики трассы, толщины сосудистого русла, и т.д.) [70, 71, 72].




Рис. 49. Результат оценки расстояний до стенок сосуда позволяет выделить границы сосуда и трассу, проходящую по центру сосудистого русла

В основе метода лежит анализ изображений сосудов посредством искусственных нейронных сетей с целью получения более точных результатов по отношению к другим методам.

Решаемая задача разбивается на несколько подзадач: 1) выбор структуры нейронной сети, наиболее подходящей для решения данной задачи; 2) выбор подходящего представления входных данных; 3) выбор алгоритма обучения нейронной сети; 4) определение оптимальных параметров нейронной сети; 5) сравнительный анализ точности предложенного метода. Приведенные выше подзадачи и составляют предмет исследований, представленных в учебном пособии.

В общем случае задача формулируется следующим образом. Требуется построить алгоритм, вычисляющий расстояние между заданной точкой внутри сосуда и границей сосуда на биомедицинском изображении. Алгоритм должен обладать способностью адаптации к различным видам изображений, посредством обучения на фрагментах этих изображений. Разработанный алгоритм необходимо применить для оценки диаметров сосудов на натуральных биомедицинских изображениях с целью получить точные оценочные данные.

7.1 Искусственные нейронные сети

Сеть нейронов, образующая человеческий головной мозг, представляет собой высокоэффективную комплексную, существенно параллельную систему обработки информации. Она способна организовывать свои нейроны таким образом, чтобы реализовывать восприятие образа, его распознавание во много раз быстрее, чем эти задачи могут быть решены самыми современными компьютерами. Так распознавание знакомого лица происходит в мозге человека за 100-120 мс, в то время как компьютеру для этого необходимы минуты и даже часы.

Несомненно то, что мозг работает более эффективно и принципиально другим образом, чем любая вычислительная машина, созданная человеком.

Нервная система человека, построенная из элементов, называемых нейронами, имеет достаточную сложность. Около 10^{11} нейронов участвуют в примерно 10^{15} передающих связях, имеющих длину метр и более. Каждый нейрон обладает многими качествами, общими с другими элементами тела, но его уникальной способностью является прием, обработка и передача электрохимических сигналов по нервным путям, которые образуют коммуникационную систему мозга.




Рис. 50. Биологический нейрон

На рис. 50 показана структура пары типичных биологических нейронов. Дендриты идут от тела нервной клетки к другим нейронам, где они принимают сигналы в точках соединения, называемых синапсами. Принятые синапсом входные сигналы подводятся к телу нейрона. Здесь они суммируются, причем одни входы стремятся возбудить нейрон, другие – воспрепятствовать его возбуждению. Когда суммарное возбуждение в теле нейрона превышает некоторый порог, нейрон возбуждается, посылая по аксону сигнал другим нейронам. У этой основной функциональной схемы много усложнений и исключений, тем не менее большинство искусственных нейронных сетей моделируют лишь эти простые свойства.

7.1.1 Применение нейронных сетей в задачах обработки изображений

Нейронные сети наиболее приспособлены к решению широкого круга задач, так или иначе связанных с обработкой изображений.

Список типичных постановок задач для нейронных сетей:

- 1) аппроксимация функций по набору точек (регрессия);
- 2) классификация данных по заданному набору классов;
- 3) кластеризация данных с выявлением заранее неизвестных классов-прототипов;
- 4) сжатие информации;
- 5) восстановление утраченных данных;
- 6) ассоциативная память;
- 7) оптимизация, оптимальное управление.

Этот список можно было бы продолжить и дальше. Однако, между всеми этими внешне различными постановками задач существует глубокое родство. За ними просматривается некий единый прототип, позволяющий сводить их друг к другу.

Возьмем, например, задачу аппроксимации функции по набору точек. Это типичный пример некорректной задачи, т.е. задачи не имеющей единственного решения. Чтобы добиться единственности, такие задачи надо регуляризовать, то есть дополнить требованием минимизации некоторого регуляризирующего функционала. Минимизация такого функционала и является целью обучения нейронной сети. Задачи оптимизации также сводятся к минимизации целевых функций при заданном наборе ограничений. С другой стороны, классификация - это не что иное, как аппроксимация функции с дискретными значениями (идентификаторами классов), хотя ее можно рассматривать и как частный случай заполнения пропусков в базах данных, в данном случае - в колонке идентификаторов класса. Задача восстановления утраченных данных, в свою очередь, - это ассоциативная память, восстанавливающая прообраз по его части. Таки-

ми прообразами в задаче кластеризации выступают центры кластеров. Наконец, если информацию удастся восстановить по какой-нибудь ее части, значит мы добились сжатия этой информации, и т.д.




Рис. 51. Глобальность связей в искусственных нейросетях

7.1.2 Основные черты нейронных сетей

Отличительной чертой нейронных сетей является глобальность связей. Базовые элементы искусственных нейронных сетей - формальные нейроны - изначально нацелены на работу с широкополосной информацией. Каждый нейрон сети, как правило, связан со всеми нейронами предыдущего слоя обработки данных (рис. 51), иллюстрирующего наиболее широко распространенную в современных приложениях архитектуру многослойного персептрона. В этом основное отличие формальных нейронов от базовых элементов последовательных ЭВМ - логических вентилях, имеющих лишь два входа. Архитектура нейронных сетей проста и универсальна. Специализация связей возникает на этапе их обучения под влиянием конкретных данных.

Формальный нейрон производит простейшую операцию (рис. 52) - взвешивает значения своих входов со своими же локально хранимыми весами и производит над их суммой нелинейное преобразование:

$$y = f(u), \quad u = w_0 + \sum w_i x_i. \quad (39)$$




Рис. 52. Нейрон производит нелинейную операцию над линейной комбинацией входов

Нелинейность выходной функции активации $f(\cdot)$ принципиальна. Если бы нейроны были линейными элементами, то любая последовательность нейронов также производила бы линейное преобразование, и вся нейронная сеть была бы эквивалентна одному нейрону (или одному слою нейронов - в случае нескольких выходов). Нелинейность разрушает линейную суперпозицию и приводит к тому, что возможности нейронной сети существенно выше возможностей отдельных нейронов.

7.1.3 Обучение нейронных сетей

Массовый параллелизм нейронных вычислений, необходимый для эффективной обработки изображений, обеспечивается локальностью обработки информации в нейронных сетях. Каждый нейрон реагирует лишь на локальную информацию, поступающую к нему в данный момент от связанных с ним таких же нейронов, без обращений к общему плану вычислений. Таким образом, нейросетевые ал-

горитмы локальны, и нейроны способны функционировать параллельно.

Отсутствие глобального плана вычислений в нейронных сетях предполагает и особый характер их программирования. Оно носит локальный характер: каждый нейрон изменяет свои "подгоночные параметры" - синаптические веса - в соответствии с поступающей к нему локальной информацией об эффективности работы всей сети как целого. Режим распространения такой информации по сети и соответствующей ей адаптации нейронов носит характер обучения. Такой способ программирования позволяет эффективно учесть специфику требуемого от сети способа обработки данных, так как алгоритм не задается заранее, а порождается самими данными - примерами, на которых сеть обучается. Именно таким образом в процессе самообучения биологические нейронные сети выработали столь эффективные алгоритмы обработки сенсорной информации.

Характерной особенностью нейронных сетей является их способность к обобщению, позволяющая обучать сеть на ничтожной доле всех возможных ситуаций, с которыми ей, может быть, придется столкнуться в процессе функционирования.

Привлекательной чертой нейронных сетей является единый принцип обучения нейронных сетей - минимизация эмпирической ошибки. Функция ошибки, оценивающая данную конфигурацию сети, задается извне - в зависимости от того, какую цель преследует обучение. Но далее сеть начинает постепенно модифицировать свою конфигурацию - состояние всех своих синаптических весов - таким образом, чтобы минимизировать эту ошибку. В итоге, в процессе обучения сеть все лучше справляется с возложенной на нее задачей. Образно этот процесс можно представить себе как поиск минимума функции ошибки $E(w)$, зависящей от набора всех синаптических весов сети w .

7.1.4 Классификация базовых архитектур нейронных сетей

Типы обучения нейронных сетей. Ошибка сети зависит, как уже говорилось, от конфигурации сети - совокупности всех ее синаптических весов. Но эта зависимость не прямая, а опосредованная. Так как непосредственные значения весов скрыты от внешнего наблюдателя, оценивать ее работу можно, лишь основываясь на ее поведении, т.е. на том, каковы значения выходов сети при данных входах. В общем виде функция ошибки имеет вид $E(w) = \{x^\alpha, y^\alpha, y(x^\alpha, w)\}$, где $\{x^\alpha, y^\alpha\}$ - набор примеров (т.е. пар входо-выходов), на которых обучается нейросеть; $\{y(x^\alpha, w)\}$ - реальные значения выходов нейросети. Такой способ обучения, когда действительный выход нейросети сравнивают с эталонным, называют обучением с учителем. В данной работе в роли "учителя" выступает человек - эксперт.

Архитектура связей. На способ обработки информации решающим образом сказывается наличие или отсутствие в сети петель обратных связей. Если обратные связи между нейронами отсутствуют (т.е. сеть имеет структуру последовательных слоев, где каждый нейрон получает информацию только с предыдущих слоев), обработка информации в сети однонаправленна. Входной сигнал обрабатывается последовательностью слоев и ответ гарантированно получается через число тактов равное числу слоев. Наличие же обратных связей может сделать динамику нейронной сети (называемой в этом случае *рекуррентной*) непредсказуемой. Но в этом случае нейроны в рекуррентных сетях много раз принимают участие в обработке информации, позволяя таким сетям производить более разнообразную и глубокую обработку информации.

Классификация по типу связей и типу обучения. Ограничившись лишь двумя описанными выше факторами, разделяющими сети по типу обучения (программирования) и функционирования, можно

получить полезную классификацию базовых архитектур нейронных сетей.

В табл. 9 различные архитектуры сетей распределены по ячейкам в зависимости от способа обработки ими информации и способа их обучения. В скобках указаны основные типы задач, обычно решаемых данным классом нейронных сетей. На основе этой классификации для решения данной задачи была выбрана многослойная нейронная сеть без обратных связей.

Таблица 9
Классификация нейронных сетей

Тип связей	Тип обучения	
	С "учителем"	Без "учителя"
Без обратных связей	Многослойные перцептроны (аппроксимация функций, классификация)	Соревновательные сети, карты Кохонена (сжатие данных, выделение признаков)
С обратными связями	Рекуррентные аппроксиматоры (предсказание временных рядов, обучение в режиме on-line)	Сеть Хопфилда (ассоциативная память, кластеризация данных, оптимизация)

7.1.5 Многослойные нейронные сети (перцептроны)

Описываемые алгоритмы основаны на использовании многослойных перцептронов или для краткости просто перцептронов – нейронных сетей, состоящих из последовательных слоев нейронов. Хотя любую сеть без обратных связей можно представить в виде последовательных слоев, именно наличие многих нейронов в каждом слое позволяет существенно ускорить вычисления.

Выбор перцептронов обусловлен широким кругом решаемых ими задач. В общем виде они решают задачу аппроксимации многомерных функций, т.е. построения многомерного отображения $F: x \Rightarrow y$, обобщающего заданный набор примеров $\{x^\alpha, y^\alpha\}$. В нашем случае, в качестве выходных значений, мы имеем дискретный

набор, поэтому аппроксимация функций принимает вид классификации.

Нейрон – классификатор. Простейшим устройством распознавания образов, принадлежащим к рассматриваемому классу сетей, является одиночный нейрон, превращающий входной вектор признаков в скалярный ответ, зависящий от линейной комбинации входных переменных: $y = f\left(\sum_{j=1}^d w_j x_j + w_0\right) \equiv f\left(\sum_{j=0}^d w_j x_j\right)$. Здесь и далее предполагается наличие у каждого нейрона дополнительного единичного входа с нулевым индексом, значение которого постоянно: $x_0 \equiv 1$. Это позволит упростить выражения, трактуя все синаптические веса w_j , включая порог w_0 , единым образом. Скалярный выход нейрона можно использовать в качестве индикатора принадлежности входного вектора к одному из заданных классов. Так, если входные векторы могут принадлежать одному из двух классов, нейрон способен различить тип входа, например, следующим образом: если $f(x) \geq 0$, входной вектор принадлежит первому классу, в противном случае - второму.

Выбор функции активации. Монотонные функции активации $f(\cdot)$ не влияют на классификацию. Но их значимость повышается, если трактовать выходы нейронов как вероятности принадлежности к соответствующему классу, что дает дополнительную информацию при классификации. Так, *сигмоидная функция активации* нейрона: $f(a) = 1/(1 + \exp(-a))$ дает вероятность принадлежности к соответствующему классу.

Метод обратного распространения ошибки. Согласно методу наименьших квадратов, минимизируемой целевой функцией ошибки нейронной сети является величина $E(w) = \frac{1}{2} \sum_{j,p} (y_{j,p}^{(N)} - d_{j,p})^2$, где $y_{j,p}^{(N)}$ – реальное выходное состояние нейрона j выходного слоя N

нейронной сети при подаче на ее входы p -го образа; $d_{j,p}$ – идеальное (желаемое) выходное состояние этого нейрона.

Суммирование ведется по всем нейронам выходного слоя и по всем обрабатываемым сетью образам. Минимизация ведется методом градиентного спуска, что означает подстройку весовых коэффициентов следующим образом: $\Delta w_{ij}^{(n)} = -\eta \cdot \partial E / \partial w_{ij}$, где w_{ij} – весовой коэффициент синаптической связи, соединяющей i -й нейрон слоя $n-1$ с j -м нейроном слоя n ; η – коэффициент скорости обучения, $0 < \eta < 1$.

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial y_j} \cdot \frac{dy_j}{ds_j} \cdot \frac{\partial s_j}{\partial w_{ij}}.$$

Здесь под y_j , как и раньше, подразумевается выход нейрона j , а под s_j – взвешенная сумма его входных сигналов, то есть аргумент активационной функции. Так как множитель dy_j/ds_j является производной этой функции по ее аргументу, из этого следует, что производная активационной функции должна быть определена на всей оси абсцисс. В связи с этим функции единичного скачка и прочие активационные функции с неоднородностями не подходят для рассматриваемых нейронных сетей. В них применяются такие гладкие функции, как гиперболический тангенс или классическая сигмоидальная функция с экспонентой. В случае гиперболического тангенса: $\frac{dy}{ds} = 1 - s^2$. Третий множитель $\partial s_j / \partial w_{ij}$, очевидно, равен выходу нейрона предыдущего слоя $y_i^{(n-1)}$.

Что касается первого множителя, он легко раскладывается следующим образом:

$$\frac{\partial E}{\partial y_j} = \sum_k \frac{\partial E}{\partial y_k} \cdot \frac{dy_k}{ds_k} \cdot \frac{\partial s_k}{\partial y_j} = \sum_k \frac{\partial E}{\partial y_k} \cdot \frac{dy_k}{ds_k} \cdot w_{jk}^{(n+1)}.$$

Здесь суммирование по k выполняется среди нейронов слоя $n+1$.

Введя новую переменную

$$\delta_j^{(n)} = \frac{\partial E}{\partial y_j} \cdot \frac{dy_j}{ds_j},$$

мы получим рекурсивную формулу для расчетов величин $\delta_j^{(n)}$ слоя n из величин $\delta_k^{(n+1)}$ более старшего слоя $n+1$:

$$\delta_j^{(n)} = \left[\sum_k \delta_k^{(n+1)} \cdot w_{jk}^{(n+1)} \right] \cdot \frac{dy_j}{ds_j}.$$

Для выходного же слоя

$$\delta_i^{(N)} = (y_i^{(N)} - d_i) \cdot \frac{dy_i}{ds_i}.$$

Теперь мы можем записать в раскрытом виде:

$$\Delta w_{ij}^{(n)} = -\eta \cdot \delta_j^{(n)} \cdot y_i^{(n-1)}.$$

Для придания процессу коррекции весов некоторой инерционности, сглаживающей резкие скачки при перемещении по поверхности целевой функции, данная формула дополняется значением изменения веса на предыдущей итерации:

$$\Delta w_{ij}^{(n)}(t) = -\eta \cdot \left(\mu \cdot \Delta w_{ij}^{(n)}(t-1) + (1-\mu) \cdot \delta_j^{(n)} \cdot y_i^{(n-1)} \right),$$

где μ – коэффициент инерционности; t – номер текущей итерации.

Таким образом, полный алгоритм обучения нейронной сети с помощью процедуры обратного распространения строится так:

1) подать на входы сети один из возможных образов и в режиме обычного функционирования нейронной сети, когда сигналы распространяются от входов к выходам, рассчитать значения последних;

2) рассчитать $\delta(N)$ для выходного слоя;

3) рассчитать изменения весов $\Delta w(N)$ слоя N ;

4) рассчитать $\delta(n)$ и $\Delta w(n)$ для всех остальных слоев, $n = N-1, N-2, \dots, 1$;

5) скорректировать все веса в нейронной сети:

$$w_{ij}^{(n)}(t) = w_{ij}^{(n)}(t-1) + \Delta w_{ij}^{(n)}(t).$$

6) если ошибка сети существенна, перейти на шаг 1. В противном случае – конец.

Сети на шаге 1 попеременно в случайном порядке предъявляются все тренировочные образы, чтобы сеть, образно говоря, не забывала одни по мере запоминания других. Алгоритм иллюстрирует рис. 53.

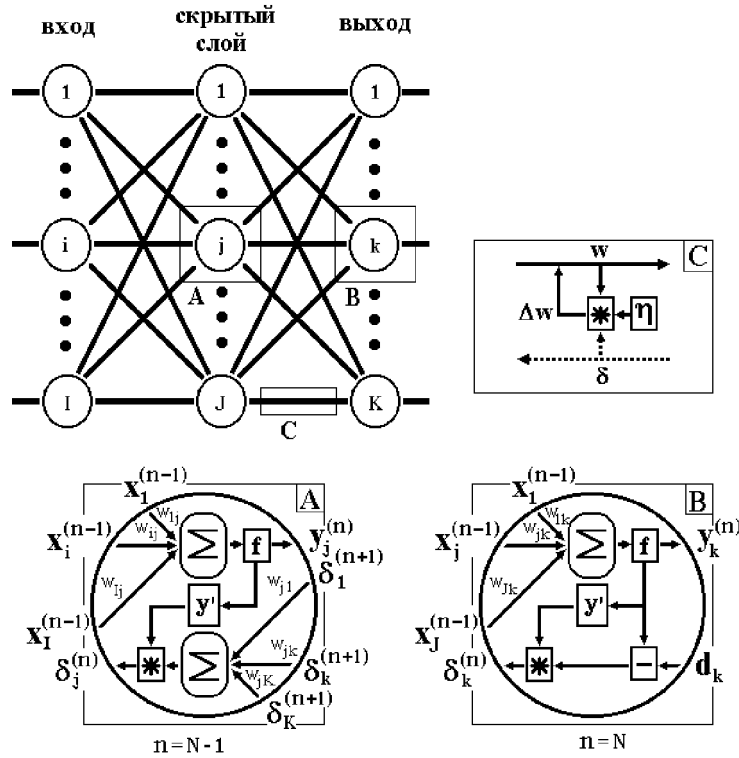


Рис. 53. Диаграмма сигналов в сети при обучении по алгоритму обратного распространения

Когда выходное значение $y_i(n-1)$ стремится к нулю, эффективность обучения заметно снижается. При двоичных входных векторах в среднем половина весовых коэффициентов не будет корректироваться, поэтому область возможных значений выходов нейронов $[0,1]$ желательно сдвинуть в пределы $[-0,5;+0,5]$, что достигается преобразованием сигмоида с экспонентой к виду $f(x) = \frac{1}{1+e^{-\alpha x}} - \frac{1}{2}$.

7.2 Применение многослойных нейронных сетей

Концепция. Как следует из постановки задачи, основой алгоритма является использование нейронной сети как инструмента оценки параметров объектов на биомедицинских изображениях. В нашем случае объектами являются русла сосудов на рентгеновских снимках сосудистых систем сердца и глазного дна. Параметрами для оценки являются расстояния между внутренней точкой и границами сосуда в направлениях, перпендикулярных трассе сосуда (рис. 54).

Входом нейронной сети является вектор фиксированной размерности, компонентами которого являются интенсивности точек изображения, лежащих на прямой, перпендикулярной трассе сосуда. Компоненты вектора набираются последовательно, начиная с заданной точки внутри сосуда, в направлении границы сосуда (рис. 55). Размерность векторов выбирается исходя из максимальной толщины сосудов на изображениях.

Формирование обучающей базы образцов. Обучающая база нейронной сети формируется человеком - экспертом. Его задача заключается в выборе подходящих для обучения изображений и последующем выборе фрагментов на этих изображениях. На рис. 56 представлены два изображения с выбранными фрагментами для обучения.




Рис. 54. Оцениваемые параметры объектов

Затем каждый фрагмент сосуда трассируется с помощью простейших вспомогательных алгоритмов. В результате трассировки каждый фрагмент разделяется на определенное количество векторов интенсивностей в соответствии с точками трассы. Каждому вектору ставится в соответствие значение толщины сосуда в данной точке трассы.

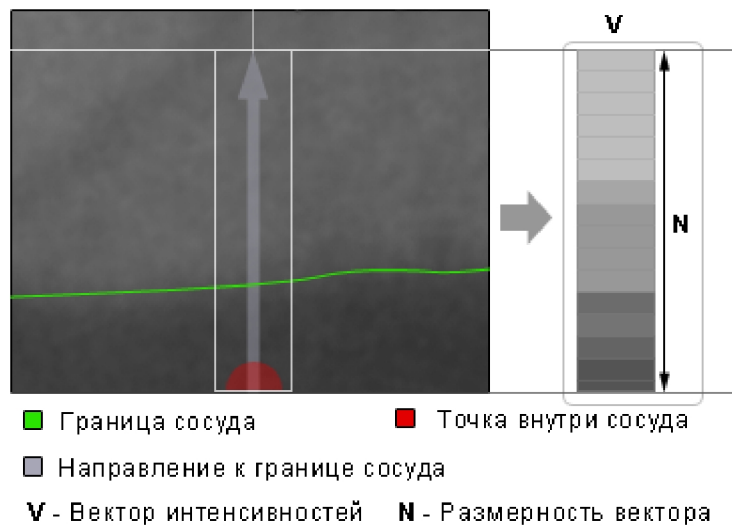


Рис. 55. Формирование входного вектора нейронной сети




Рис. 56. Обучающие фрагменты изображений

На следующем этапе производится визуальная оценка диаметров сосудов для каждого образца (рис. 57).




Рис. 57. Пример визуальной оценки диаметров сосудов

Таким образом, с каждого фрагмента изображения собирается набор данных – образцов, для обучения нейронной сети. На рис. 58 представлен процесс трассировки фрагмента сосуда.

Совокупность образцов, собранных со всех фрагментов всех изображений, участвующих в обучении, образуют обучающую базу для нейронной сети. Следует отметить, что прежде чем собранные данные смогут принять участие в обучении, необходимо провести процедуру предобработки.




Рис. 58. Трассировка фрагмента сосуда

Предобработка данных является наиболее трудоемким элементом данного метода. Она не связана непосредственно с нейронными сетями, но при этом является одним из ключевых элементов. Успех обучения нейронной сети решающим образом зависит от того, в каком виде представлена информация для ее обучения.

Нормировка данных. Так как входами и выходами нейронной сети являются совершенно разнородные величины, результаты не должны зависеть от единиц измерения этих величин. А именно, чтобы сеть трактовала их значения единообразно, все входные и выходные величины были приведены к единому - единичному - масштабу. Кроме того, для повышения скорости и качества обучения была проведена дополнительная предобработка данных, выравнивающая распределение значений еще до этапа обучения. Приведение данных к единичному масштабу обеспечивается нормировкой каждой переменной на диапазон разброса ее значений. В простейшем варианте это - линейное преобразование:

$$\tilde{x}_i = \frac{x_i - x_{i,\min}}{x_{i,\max} - x_{i,\min}},$$

в единичный отрезок: $\tilde{x}_i \in [0, 1]$. Рекомендуемое для входных данных обобщение для отображения данных в интервал $[-1, 1]$ тривиально. Линейная нормировка оптимальна, когда значения переменной x_i плотно заполняют определенный интервал. Но в случае, когда в

данных имеются относительно редкие выбросы (это характерно для обучающих образцов, полученных с реальных биомедицинских изображений), намного превышающие типичный разброс, именно эти выбросы определяют согласно предыдущей формуле масштаб нормировки. Это приводит к тому, что основная масса значений нормированной переменной \tilde{x}_i сосредоточится вблизи нуля (рис. 59).

Поэтому надежнее ориентироваться при нормировке не на экстремальные значения, а на типичные, т.е. статистические характеристики данных, такие как среднее и дисперсия:

$$\tilde{x}_i = \frac{x_i - \bar{x}_i}{\sigma_i}, \quad \bar{x}_i = \frac{1}{p} \sum_{a=1}^p x_i^a, \quad \sigma_i^2 = \frac{1}{p-1} \sum_{a=1}^p (x_i^a - \bar{x}_i)^2.$$

В этом случае основная масса данных будет иметь единичный масштаб, т.е. типичные значения всех переменных будут сравнимы (рис. 60). Однако в этом случае нормированные величины не принадлежат гарантированно единичному интервалу, более того, максимальный разброс значений \tilde{x}_i заранее не известен.




Рис. 59. Гистограмма значений переменной при наличии редких, но больших по амплитуде отклонений от среднего




Рис. 60. Нелинейная нормировка, использующая функцию активации $f(a) = \frac{1}{1+e^{-a}}$

Для входных данных это не важно, но выходные переменные используются в качестве эталонов для выходных нейронов. Так как выходные нейроны - сигмоидные, они могут принимать значения лишь в единичном диапазоне. Чтобы установить соответствие между обучающей выборкой и нейронной сетью необходимо ограничить диапазон изменения переменных.

Поэтому для предобработки данных была использована функция активации тех же нейронов: $\tilde{x}_i = \left(\frac{x_i - \bar{x}_i}{\sigma_i} \right)$, $f(a) = \frac{1}{1+e^{-a}}$.

Эта функция нормирует основную массу данных, гарантируя, что $\tilde{x}_i \in [0,1]$. Как видно из приведенного выше рисунка, распределение значений после такого нелинейного преобразования гораздо ближе к равномерному.

Процесс обучения нейронной сети.

В качестве обучающего алгоритма для нейронной сети был выбран алгоритм обратного распространения ошибки. Данный алгоритм подразумевает такой тип обучения, как обучение с учителем, то есть для каждого входа нейронной сети необходимо иметь требуемый выход. Цель обучения заключается в том, чтобы за конечное

число тактов обучения каждому входному образцу из обучающей выборки нейронная сеть ставила в соответствие выход, представленный ей на этапе обучения. В нашем случае входом нейронной сети является вектор интенсивностей размерности N . В качестве выходных данных используются вектора такой же размерности. Для каждого входного вектора из обучающей выборки нам известно расстояние до границы сосуда от заданной точки. В качестве выхода будем требовать от сети вектор, все компоненты которого равны нулю, кроме компоненты, номер которой совпадает с известным значением толщины. Рис. 61 иллюстрирует один шаг из процесса обучения нейронной сети.

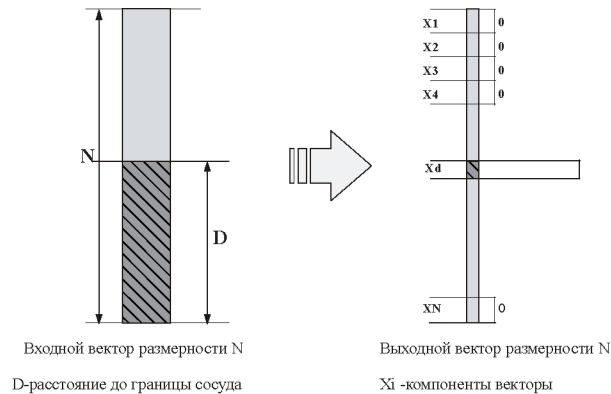


Рис. 61. Один шаг из процесса обучения нейронной сети

По окончании процесса обучения нейронная сеть используется для оценки параметров на изображениях, фрагменты которых не входили в обучающую базу. Функционирование алгоритма оценки заключается в следующем: 1) на вход нейронной сети подается вектор, содержащий интенсивности точек изображения, набранные вдоль направления к границе сосуда; 2) сигналы распространяются по всем нейронам сети, в результате из сигналов нейронов выходного слоя формируется результирующий вектор (рис. 62); 3) в качестве оценки толщины берется номер компоненты результирующего вектора, имеющей максимальное значение.




Рис. 62. Результат оценивания толщины

7.3 Экспериментальное исследование алгоритмов

В процессе тестирования исследовалась возможность применения нейронных сетей для оценивания параметров объектов, с целью получить точные оценочные данные. Большой акцент также сделан на сравнении результатов работы различных алгоритмов оценки параметров объектов. Экспериментальная часть включает в себя исследования работы алгоритма применительно к реальным изображениям двух типов: 1) изображения сосудов сердца; 2) изображения сосудов глазного дна. В данных условиях получить истинные значения толщины сосудов невозможно. Поэтому единственным способом определения этих параметров является их визуальная оценка экспертом. Например, в реальной жизни таким экспертом является врач, на глаз определяющий патологию сосудов. Ниже представлен результат визуальной оценки толщин сосудов на примере сосудов сердца.

В данном случае обучение нейронной сети производится на фрагментах изображения, содержащих сосуды с различными толщинами. Необходимо отметить, что выбор обучающих фрагментов

имеет немаловажное значение. Поскольку точность оценки напрямую зависит от качества обучающих образцов.

Входными данными для нейронной сети являются образцы, полученные из выборки обучающих фрагментов изображения. Истинными значениями толщины в данном случае будут являться результаты визуальной оценки сосудов экспертом. В данном случае обучение нейронной сети производится на фрагментах изображения, содержащих сосуды с различными толщинами. Необходимо отметить, что выбор обучающих фрагментов имеет немаловажное значение. Поскольку точность оценки напрямую зависит от качества обучающих образцов. Входными данными для нейронной сети являются образцы, полученные из выборки обучающих фрагментов изображения. Истинными значениями толщины в данном случае будут являться результаты визуальной оценки сосудов экспертом.

В ходе эксперимента алгоритм тестируется на фрагментах сосудов, не вошедших в обучающую выборку. Фрагменты изображения, вошедшие как в тестовую, так и в обучающую выборку представлены на рис. 63 и рис. 64.





Рис. 63. Фрагменты, вошедшие в обучающую выборку



а)

б)

Рис. 64. Фрагменты, вошедшие в тестовую выборку

Погрешность оценки определим как и в случае модельных изображений, следующим образом:

$$\bar{\delta} = \left(\sum_{x=l}^m \frac{|\hat{\sigma}(x) - \sigma(x)|^2}{\sigma(x)^2} \right) 100\%,$$

где $\sigma(x)$ - радиус сосуда в точке трассы, использованный при экспертной оценке тестового изображения, $\hat{\sigma}(x)$ - оценка радиуса, полученная с помощью разработанного алгоритма.

Максимальное отклонение определим как:

$$d = \max |\hat{\sigma}(x) - \sigma(x)|, \quad x \in [l, m].$$

Погрешности оценки толщины, полученные в результате тестирования, приведены в таблице 10.

Таблица 10
Погрешность оценки толщины

Номер образца	Рис. 63а		Рис. 63б	
	Погрешность оценки	Максимальное отклонение	Погрешность оценки	Максимальное отклонение
1	1,74 %	4	0,01 %	1
2	0,25 %	2	0,03 %	1
3	0,27 %	2	0,55 %	3
4	0,07 %	1	0,03 %	1
5	0,22 %	2	0,79 %	3
6	0,26 %	2	0,02 %	1
7	1,31 %	3	0,08 %	1
8	0,07 %	1	0,01 %	1
9	0,04 %	1	0,01 %	1
10	0,09 %	1	0,03 %	1
11	0,74 %	3	0,02 %	1
12	0,98 %	3	0,33 %	2
13	2,12 %	4	0,01 %	1

Из результатов тестов видно, что алгоритм дает высокую точность оценки толщины при сравнительно малом количестве обучающих данных и низком качестве тестовых изображений.

В следующем эксперименте алгоритм тестировался на серии снимков, представляющих собой различные проекции сосудов сердца. При этом, для обучения использовалось только одно изображение из серии. Рис. 65а содержит изображение, фрагменты которого использовались для обучения нейронной сети. На рис. 65б, рис. 65в и рис. 65г представлены три изображения из серии, на которых алгоритм тестировался. В табл. 11, приведены результаты оценки толщин сосудов.




Рис. 65. Изображение, фрагменты которого использовались для обучения нейронной сети

По результатам последнего теста можно сделать вывод, что разработанный алгоритм, будучи обученным на фрагментах одного изображения, с достаточной точностью работает на фрагментах, не вошедших в обучающую выборку, то есть, в данном случае, проявляются свойства алгоритма к адаптации. Однако следует отметить и тот факт, что подобные свойства алгоритма имеют место не во всех случаях. Например, экспериментально было установлено, что применение алгоритма к изображениям сосудов глазного дна в случае, когда обучение производилось на фрагментах, взятых с изображений сосудов сердца, не дало достаточной точности оценки параметров.

Таблица 11
Погрешность оценки толщины

Номер изображения	Номер образца	Погрешность оценки	Максимальное отклонение
рис. 65б	1	0,27 %	2
	2	0,09 %	1
	3	0,39 %	2
	4	0,94 %	3
	5	1,87 %	4
рис. 65в	1	0,01 %	1
	2	0,92 %	3
	3	1,01 %	3
	4	2,11 %	4
	5	0,26%	2
рис. 65г	1	0,94%	3
	2	3,27 %	5
	3	1,96 %	4
	4	0,25 %	2
	5	0,88 %	3

Таким образом, можно сделать вывод, что разработанный алгоритм может эффективно применяться к оцениванию биомедицинских изображений одного типа, например последовательность снимков сосудов сердца. В случае, когда требуется оценивание параметров на разнотипных изображениях, необходимо дополнительное обучение нейронной сети на образцах, взятых с различных изображений. Такое обучение может стать достаточно трудоемким в связи с необходимой подготовкой обучающей выборки большого объема.

Сравнительный анализ эффективности метода.

Целью проведения сравнительного анализа эффективности разработанного метода было определение алгоритма, дающего наиболее точную оценку параметров для натуральных изображений. В экспериментах использовались натурные изображения сосудов сердца. На выбранных изображениях экспертом производилась визуальная оценка параметров сосудов. Были проведены две серии тестов, в каждой из которых производилась оценка толщины сосудов на выбранных фрагментах изображений, с помощью трех рассмотренных алгоритмов: 1) алгоритма градиентного выделения контуров 2) Алгоритма Diadel; 3) разработанного алгоритма.

В тестах первой серии нейронная сеть обучалась на фрагментах изображений использовавшихся при тестировании. В тестах второй серии, обучение нейронной сети производилось на фрагментах изображений не входящих в группу изображений, на которых производилось тестирование. Для каждого из трех алгоритмов была рассчитана погрешность оценивания параметров сосудов. На рис. 66 приведено тестовое изображение, на участках сосудов которого производилось оценивание параметров.

В табл. 12 приведены результаты оценки толщины сосудов различными алгоритмами для случая, когда обучение нейронной сети производилось на фрагментах взятых с самих тестовых изображений. В табл. 13 приведены результаты оценки толщины сосудов разработанным алгоритмом, в случае когда обучение нейронной сети производилось на фрагментах взятых с других изображений.




Рис. 66. Тестовое изображение для оценивания параметров сосудов

Таблица 12

Погрешность оценки толщины сосудов различными алгоритмами оценивания

Номер фрагмента	Используемый алгоритм оценивания	Погрешность оценки толщины
1	Градиент	3,66 %
	Diadel	1,83 %
	Нейронные сети	1,37 %
2	Градиент	5,42 %
	Diadel	6,28 %
	Нейронные сети	3,21 %
3	Градиент	8,19 %
	Diadel	2,29 %
	Нейронные сети	2,59 %
4	Градиент	4,31 %
	Diadel	4,51 %
	Нейронные сети	1,93 %
5	Градиент	9,2 %
	Diadel	4,42 %
	Нейронные сети	2,11 %

Таблица 13

Погрешность оценки толщины сосудов в случае обучения на фрагментах, не присутствующих на тестовых изображениях

Номер фрагмента	Погрешность оценки толщины
1	3,13 %
2	1,01 %
3	4,02 %
4	2,17 %
5	2,98 %

Проведенные тесты показали правильность выбранной нейросетевой модели и ее высокую способность к адаптации к различным типам изображений. В результате сравнительного анализа существующих методов оценивания параметров на изображениях было установлено, что данный алгоритм более всего применим к сериям изображений одного типа, например последовательности снимков сосудов сердца. В этом случае данный алгоритм превосходит, по точности полученных результатов, существующие алгоритмы оценивания параметров. Однако следует отметить то, что недостатком данного алгоритма является трудоемкость процесса обучения в случае, когда необходимо одновременно производить оценивание параметров на изображениях разного типа.

ПРЕДМЕТНЫЙ УКАЗАТЕЛЬ

МНАТ-вейвлет	3.3.2
WAVE-вейвлет	3.3.2
Алгоритм обратного проецирования	4.2
Всерное преобразование	2.1
Гауссовый вейвлет	3.3.2
Изображение фантома	4.5.2
Коаксиальная модель	6.2
Корреляционная матрица	3.4.1
Кривизна	3.1; 3.3.1
Локальное всерное преобразование	2.2
Лучевое преобразование	2.1; 4.1
Преобразование Радона	2.1
Разложение Карунена-Лоева	3.4.1

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Горелик, А. Л. Современное состояние проблемы распознавания / А. Л. Горелик, И. Б. Гуревич, В. А. Скрипкин. - М.: Высшая школа, 1985. - 160 с.
2. Фу, К. Последовательные методы в распознавании образов и обучении машин / К. Фу. - М.: Наука, 1971. - 256 с.
3. Фукунага, К. Введение в статистическую теорию распознавания образов / К. Фукунага. - М.: Наука, 1979. - 368 с.
4. Горелик, А. Л. Методы распознавания / А. Л. Горелик, В. А. Скрипкин. - М.: Высшая школа, 1984. - 208 с.
5. Ту, Дж. Принцип распознавания образов / Дж. Ту, Р. Гонсалес. - М.: Наука, 1986.
6. Дуда, Р. Распознавание образов и анализ сцен / Р. Дуда, П. Харт. - М.: Мир, 1976.
7. Фор, А. Восприятие и распознавание образов / А. Фор. - М.: Машиностроение, 1989.
8. Анисимов, Б. В. Распознавание и цифровая обработка изображений / Б. В. Анисимов, В. Д. Курганов, В. К. Злобин. - М.: Высш. шк., 1983.
9. Патрик, Э. Основы теории распознавания образов / Э. Патрик. - М.: Советское радио, 1980.
10. Журавлёв, Ю. И. Распознавание, классификация, прогноз / Ю. И. Журавлёв. - М.: Наука, 1992.
11. Сергеев, В.В. Некоторые модификации цифрового коррелятора для обнаружения объектов на изображении / В.В. Сергеев, М.А. Чичева // Компьютерная оптика. – М., 1989. - Вып. 5. - С.78-84.
12. Краковский, В. Я. Особенности скользящего анализа спектра / В. Я. Краковский, В. Н. Чайковский // Автометрия. - 1984. - № 6. - С.34-37.

13. Баклицкий, В.К. Корреляционно-экстремальные методы навигации / В.К. Баклицкий, А.Н. Юрьев. - М.: Радио и связь, 1982. - 256 с.

14. Круглов, В.Н. Распознавание образов при помощи модульных инвариантов моментов / В.Н. Круглов, В.Г. Лабунец // Уральский политехнический институт. - Свердловск, 1985. 10 с. Деп. в ВИНТИ, № 5105-85.

15. Глумов, Н.И. Быстрый алгоритм вычисления моментных характеристик изображения в скользящем окне / Н.И. Глумов // Статистические методы обработки изображений. – Новосибирск, 1993.

16. Hozman, J. Biomedical Image Processing Applications / J. Hozman, M. Bernas, R. Kubinec [et al.] // Biomedical Engineering & Biotechnology, (A.Strejc, ed.), (Praha), p.22, Publishing House of the Czech Technical University, 1994.

17. Hozman, J. Automatic computer evaluation of blood serum crystallograms / J. Hozman, R. Kubinec, J. Trnka [et al.] // “Biomedical Image Processing Applications”, in Biomedical Engineering & Biotechnology, (A.Strejc, ed.), (Praha), Publishing House of the Czech Technical University, 1995.

18. Уотермен, Д. Руководство по экспертным системам / Д. Уотермен. - М.: Мир, 1989.

19. Левин, Р. Практическое введение в технологию искусственного интеллекта и экспертных систем / Р. Левин, Д. Дранг, Б. Эделсон. - М.: Финансы и статистика, 1990.

20. Фоли, Дж. Основы интерактивной машинной графики / Дж. Фоли, А. вэн Дэм. - М.: Мир, 1985.

21. Александров, О.П. Геометрическое моделирование: учеб. пособие / О.П. Александров. - Куйбышев, 1988.

22. Ильясова, Н.Ю. Методы анализа дактилоскопических изображений на основе поля направлений / Н.Ю. Ильясова, А.В. Усти-

нов, А.Г. Храмов // Научное приборостроение. - Т.3. - С.89-101. СПб., 1993.

23. Soifer, V.A. The Method of the Directional Field in the Interpretation and Recognition of Images with Structure Redundancy / V.A. Soifer, V.V. Kotlyar, S.N. Khonina [et al.] // Pattern Recognition and Image Analysis, v.6, No.4, pp.710-724 (1996).

24. Rassam, S.M.B. Accurate vessel width measurement from fundus photographs: a new concept / S.M.B. Rassam, V. Patel, E.M. Kohner [et al.] // British Journal of Ophthalmology, 1994, 78, pp. 24-29.

25. Zhou, L. High precision retinal vessel diameter measurement in angiography / L. Zhou, J.M. Chokreff, L.J. Singerman // Invest.Ophthalmol.Vis.Sci., 1992, 33, 840.

26. Wang, Y. Objective computer-controlled measurement of retinal vessel caliber and its correlation with optical maps of tissue PO₂ / Y. Wang, J.E. Cheasty, R. Zuckerman // Invest.Ophthalmol.Vis.Sci. 33, 1992, 840.

27. Richard, S. B. Newsom Retinal vessel measurement: comparison between observer and computer driven methods / S. B. Newsom Richard, Paul M. Sullivan, Sal M.B. Rassam [et al.] // Graefe's Arch. Clin. Exp. Ophthalmol, 1992, 230, pp. 221-225.

28. Бранчевский, С. Л. Применение новых методов распознавания и обработки изображений для оценки патологии сосудистой системы сетчатки / С.Л. Бранчевский, А.Б. Дурасов, Н.Ю. Ильясова [и др.] // Тез. докл. на 2-й междунар. конф. "Распознавание-95". - Курск, 1995. - С.231-233.

29. Бранчевский, С. Л. Автоматизированный комплекс анализа сосудистого русла сетчатки / С.Л. Бранчевский, Ю.В. Васильев, А.Б. Дурасов [и др.] // Матер. междунар. конф. офтальмологов, посвящ. 75-летию проф. А.М. Водовозова. - Т. 50. Вып.1. - С.99-101. - Волгоград, 1995.

30. Ильясова, Н.Ю. Методы и алгоритмы оценивания геометрических параметров диагностических изображений: дис. канд. техн. наук / Н.Ю. Ильясова. - Самара, 1997. - 155 с.

31. Ильясова, Н.Ю. Система цифрового анализа для диагностики сосудистой патологии глазного дна / Н.Ю. Ильясова, С.Л. Бранчевский, Н.А. Гаврилова [и др.] // Вестник офтальмологии. - №5. - 2003. - С. 37-40.

32. Ильясова, Н.Ю. Экспертная компьютерная система диагностики глазных заболеваний по изображениям глазного дна / Н.Ю. Ильясова, А.В. Устинов, В.Г. Баранов // Компьютерная оптика. - 1999. - № 19.

33. Branchevsky, S.L. Methods for estimating geometric parameters of retinal vessels using diagnostic images of fundus / S.L. Branchevsky, A.V. Durasov, N.Yu. Iliasova [et al.] // Proceeding SPIE. 1998. Vol. 3348. pp. 316 - 325.

34. Brantchevsky, S.L. Method for the distinguishing and quantitative evaluation of the elements of pathological patterns in the retina (pathology of microcirculation) / S.L. Brantchevsky, Yu.V. Vasiliev, A. V. Durasov [et al.] // Proceedings SPIE, vol 2363, pp. 236-242.

35. Бейтс Р. Восстановление и реконструкция изображений / Р. Бейтс, М. Мак-Доннел. - М.: Мир, 1989. - 336 с.

36. Грузман, И.С. Математические задачи компьютерной томографии / И.С. Грузман // Соросовский образовательный журнал. 2001. - Т. 7. - № 5. - С. 117 - 121

37. Грузман, И.С. Цифровая обработка изображений в информационных системах / И.С. Грузман, В.С. Киричук, В.П. Косых. - Новосибирск: Изд-во НГТУ, 2002. - 352 с.

38. Хармен, Г. Восстановление изображений по проекциям: Основы реконструктивной томографии / Г. Хармен - пер. с англ. - М.: Мир, 1983. - 352 с.

39. Allan, V. Oppenheim Applications of Digital Signal Processing: Massachusetts Institute of Technology Cambridge / V. Allan // Mass, 1978. - 550 с.
40. Gonzales, R.C. Digital Image Processing / R.C. Gonzales, R.E. Woods // Massachusetts: Addison-Wesley, 1992.
41. Богнер, Р. Введение в цифровую фильтрацию / Р. Богнер, А. Константи́нидис // пер. с англ. - М.: Мир, 1976. - 216 с.
42. Гольденберг, Л. Цифровая обработка сигналов / Л. Гольденберг, Б. Матюшкин, М. Поляк. - М.: Радио и связь, 1985. - 312 с.
43. Гончаровский, В. Реконструктивная обработка и анализ изображений в задачах вычислительной диагностики // В. Гончаровский, И.В. Кочин, А.Н. Матвиенко. - М.: МГУ, 1993. - 140 с.
44. Горбань, А.Н. Обучение нейронных сетей / А.Н. Горбань - М.: ParaGraph, 1990. - 160с.
45. Горбань, А.Н. Нейронные сети на персональном компьютере / А.Н. Горбань, Д.А. Россиев. - Новосибирск: Наука, 1996. - 276с.
46. Devernay, F. Towards Endoscopic Augmented Reality for Robotically Assisted Minimally Invasive Cardiac Surgery / F. Devernay, F. Mourgues, et È. Coste-Manière. – devernay.free.fr/publis
47. Goldbaum, M. Automated diagnosis and image understanding with object extraction, object classification, and inferencing in retinal images / M. Goldbaum, Moezzi Saied, Taylor Adam // Department of Ophthalmology and Department of Engineering and Computer Science University of California 1996 IEEE International Conference on Image Processing, Proceedings 3: 695-698.
48. Ильясова, Н.Ю. Оценивание геометрических параметров ветвей трёхмерных древовидных и сетчатых структур на примере изображения сосудистой системы сердца / Н.Ю. Ильясова, А.В. Куприянов, А.В. Устинов [и др.] // Компьютерная оптика. - 2002. - № 23. - С. 48-52.

49. Официальный сайт организации NEMA, разрабатывающей стандарт, <http://medical.nema.org/>

50. Jomier, J. Quantification of Retinopathy of Prematurity via Vessel Segmentation / J. Jomier, D.K. Wallace, S.R. Aylward // Proceedings of MICCAI 2003, LNCS 2879, pp. 620-626.

51. Ching-Wen, Yang Computer-aided diagnostic detection system of venous beading in retinal images / Yang Ching-Wen, Ma Dye-Jyun, Chao Shuenn-Ching [et al.] // Optical Engineering, Vol.39, No.5, 2000, pp. 1293-1303.

52. Mendels, F. Identification of the Optic Disk Boundary in Retinal Images Using Active Contours / F. Mendels, C. Heneghan, J.P. Thiran // Proceedings of the Irish Machine Vision and Image Processing Conference (1999) 103-115.

53. Chanwimaluang, T. An Efficient Algorithm for Extraction of Anatomical Structures in Retinal Images / T. Chanwimaluang, G. Fan // Proc. IEEE International Conference on Image Processing, Barcelona, Spain, September 2003.

54. Baranov, V.G. Discrete fan-shaped Radon transform for net-like structures' centerlines detection / V.G. Baranov, A.G. Khramov // Journal "Computer Optics", Vol. 23 (2002), 44-47.

55. Ильясова, Н.Ю. Восстановление связности линий на бинарных изображениях древовидных структур / Н.Ю. Ильясова, А.А. Ковалёв, А.В. Куприянов [и др.] // Компьютерная оптика. - 2002. - № 23. - С. 58-61.

56. Ильясова, Н.Ю. Оценивание геометрических параметров ветвей трехмерных древовидных и сетчатых структур на примере изображения сосудистой системы сердца / Н.Ю. Ильясова, А.В. Куприянов, А.В. Устинов [и др.] // Компьютерная оптика. - 2002. - № 23. - С. 48 - 52.

57. Chutatape, O. Retinal blood vessels detection and tracking by matched Gaussian and Kalman filters / O. Chutatape, L. Zheng, M.S. Krishnan // Proceedings of the 20th International Conference of the IEEE Engineering in Medicine and Biology Society, Vol.20, No.6, 1998.

58. Chwialkowski, M.P. A method for fully automated quantitative analysis of arterial flow using flow-sensitized MR-images / M.P. Chwialkowski, Y.M. Ibrahim, F.L. Hong [и др.] // Comp. Med. Imaging and Graphics, vol.20, 1996, pp. 365-378.

59. Davidov, A.N. Aviation turbine blades' strain state computing using holographic interferometry / A.N. Davidov, D.S. Elenevsky, A.G. Khramov [et al.] // 5th International Workshop on Digital Image Processing and Computer Graphics «Image Processing and Computer Optics», 1994, p.56-57.

60. Ярославский, Л.П. Введение в цифровую обработку изображений / Л. П. Ярославский. - М.: Советское радио, 1979.

61. Ильясова, Н.Ю. Биомеханические характеристики сосудов для цифрового анализа изображений глазного дна / Н.Ю. Ильясова, А.В. Куприянов., Н.А. Гаврилова [и др.] // Биомеханика глаза, Сб. трудов III семинара. – М., 2002. - С. 18-20.

62. Hart, William E. Measurement and classification of retinal vascular tortuosity / William E. Hart // Applied Numerical Mathematics Dept, Sandia National Laboratories, wehart@cs.sandia.gov.

63. Grisan, Enrico A novel method for the automatic evaluation of retinal vessel tortuosity / Enrico Grisan, Marco Foracchia, and Alfredo Ruggeri // Department of Information Engineering, University of Padova, Italy.

64. Дубровин, Б.А. Современная геометрия: Методы и приложения / Б.А. Дубровин, С.П. Новиков, А.Т. Фоменко. – М.: Эдиториал УРСС, 1998. - Т.1. – 334 с.

65. Элти, Дж. ЭС: концепции и примеры / Дж. Элти, М. Кумбе. - М.: Финансы и статистика, 1986.
66. Шульпин, Г. Подсчитаем число изомеров или рассказ о том, сколь плодотворным оказывается союз математики и химии / Г. Шульпин // Наука и жизнь, 1984. - №8. - С. 76-81.
67. Самарский, А.А. Введение в численные методы / А.А. Самарский // Наука, 1987.
68. Бахвалов, Н. С. Численные методы / Н. С. Бахвалов. - М.: Наука, 1973.
69. Ильясова, Н.Ю. Применение искусственных нейронных сетей для оценивания диагностических параметров на биомедицинских изображениях / Н.Ю. Ильясова, Д.Е. Липка, А.В. Куприянов // Компьютерная оптика. - 2003. - №25. - С. 151-153.
70. Рабинер, Л. Теория и применение цифровой обработки сигналов / Л. Рабинер, Гоулд. Пер. с англ. - М.: Мир, 1978. - 848с.
71. Дорогов, А.Ю. Структурные модели и топологическое проектирование быстрых нейронных сетей / А.Ю. Дорогов // Доклады международной конференции "Информационные средства и технологии" г. Москва, 21-23 октября 1997г., Т.1.- М., 1977. - 269 с.
72. Еремин, Д.И. Контрастирование и нейропрограммы / Д.И. Еремин // Под. ред. А.Н. Горбаня.- Красноярск: Изд-во КГТУ, 1994. - 108 с.

Учебное издание

Ильясова Наталья Юрьевна
Куприянов Александр Викторович
Куприянов Александр Викторович

**Оценивание геометрических параметров биомедицинских
диагностических изображений**

Учебное пособие

Редакторская обработка
Компьютерная верстка
Доверстка

Подписано в печать _____ г. Формат 60x84 1/16.
Бумага офсетная. Печать офсетная.
Печ.л. 9.
Тираж 120 экз. Заказ _____ . ИП – Ж79/2007.

Самарский государственный
аэрокосмический университет.
443086 Самара, Московское шоссе, 34.

Изд-во Самарского государственного
аэрокосмического университета.
443086 Самара, Московское шоссе, 34.