

Министерство науки и высшего образования Российской Федерации
федеральное государственное бюджетное образовательное
учреждение высшего образования
«Казанский национальный исследовательский технический
университет им. А.Н. Туполева-КАИ»

На правах рукописи



Назаров Максим Андреевич

**МЕТОДЫ, АЛГОРИТМЫ И ПРОГРАММНЫЙ КОМПЛЕКС ОБРАБОТКИ
ИЗОБРАЖЕНИЙ НА ОСНОВЕ НЕЙРОНЕЧЕТКОГО И НЕЙРОСЕТЕВОГО
МОДЕЛИРОВАНИЯ**

Специальность:

1.2.2 – Математическое моделирование,
численные методы и комплексы программ

Диссертация на соискание ученой степени
кандидата технических наук

Научный руководитель:
доктор технических наук,
профессор Емалетдинова Л.Ю.

Казань – 2024

ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ.....	5
ГЛАВА 1. АНАЛИЗ МЕТОДОВ ВЫДЕЛЕНИЯ КОНТУРОВ НА ИЗОБРАЖЕНИИ.....	14
1.1. Определение и области применения контурного анализа	14
1.2. Градиентные методы выделения контуров на изображении	16
1.3. Методы выделения контуров на основе нечеткой логики	25
1.4. Обзор работ, описывающих нечеткие модели выделения контуров .	27
1.5. Постановка задачи выделения и распознавания контуров на изображении.....	40
1.6. Выводы	41
ГЛАВА 2. МЕТОДЫ И АЛГОРИТМЫ РАЗРАБОТКИ НЕЙРОНЕЧЕТКОЙ МОДЕЛИ ВЫДЕЛЕНИЯ КОНТУРНОГО ПИКСЕЛЯ.....	43
2.1. Математическая постановка задачи.....	43
2.2. Определение лингвистических переменных и вида нечетких продукционных правил	44
2.3. Алгоритмы определения состава нечетко-продукционных правил и принятия решения о контурности пикселя.....	48
2.4. Методы и алгоритмы оптимизации параметров нейронечеткой модели.....	49
2.4.1. Определение структуры нейронечеткой сети.....	49
2.4.2. Алгоритм обучения нейронечеткой сети.....	51
2.5. Выводы.....	54
ГЛАВА 3. МЕТОДЫ И АЛГОРИТМЫ РАЗРАБОТКИ НЕЙРОСЕТЕВОЙ МОДЕЛИ КЛАССИФИКАЦИИ КОНТУРА ОБЪЕКТА.....	57
3.1. Формирование признаков контура объекта на основе быстрого преобразования Фурье	58
3.2. Модифицированный алгоритм формирования признаков контура объекта.....	61

3.3. Алгоритм формирования набора данных для обучения нейросетевого классификатора	63
3.4. Нейросетевая модель классификатора контура, выделенного на изображении	65
3.5. Выводы	66
ГЛАВА 4. МЕТОДИЧЕСКОЕ И ПРОГРАМНОЕ ОБЕСПЕЧЕНИЕ РАСПОЗНАВАНИЯ ОБЪЕКТА С ЗАДАННЫМ КОНТУРОМ НА ИЗОБРАЖЕНИИ.....	68
4.1. Методика выделения и распознавания эталонного контура на изображении	68
4.2. Описание комплекса программ.....	71
4.3. Результаты экспериментальных исследований.....	73
4.3.1. Выделение эталонного контура лежащего на снегу человека на изображении	74
4.3.2. Разработка нейронечеткой модели выделения контурных точек на основе этого изображения.	75
4.3.3. Определение вектора признаков-дескрипторов эталонного контура человека.	76
4.3.4. Разработка нейросетевой модели классификатора эталонного контура человека	78
4.4. Показатели точности и качества применения комплекса построенных моделей	80
4.5. Сравнительный анализ работы нейронечеткой модели выделения контурных точек и метода Кэнни.....	83
4.6. Визуальная оценка обобщающих свойств нейронечеткой модели принятия решения о контурности пикселя изображения	86
4.7. Выводы	99
ЗАКЛЮЧЕНИЕ	101
СПИСОК ЛИТЕРАТУРЫ	103

ПРИЛОЖЕНИЕ 1. ПРИМЕРЫ ПРИМЕНЕНИЯ РАЗРАБОТАННОЙ НЕЙРОНЕЧЕТКОЙ МОДЕЛИ.....	116
ПРИЛОЖЕНИЕ 2. СВИДЕТЕЛЬСТВО О ГОСУДАРСТВЕННОЙ РЕГИСТРАЦИИ РАЗРАБОТАННОЙ ПРОГРАММЫ ДЛЯ ЭВМ	128
ПРИЛОЖЕНИЕ 3. АКТЫ О ВНЕДРЕНИИ И ИСПОЛЬЗОВАНИИ	129

ВВЕДЕНИЕ

Актуальность темы исследования. Во многих областях человеческой деятельности используются модели и методы компьютерного зрения, которое представляет собой область компьютерных наук, стремящаяся расширить возможности компьютеров по обнаружению и распознаванию объектов на изображениях [1].

При анализе изображений важной информацией для распознавания объектов являются их границы, так как они описывают форму, размер и расположение объектов. Одним из часто используемых средств поиска и распознавания объектов на изображениях является контурный анализ, цель которого - распознавание объектов разных масштабов и ориентаций. Задача поиска и распознавания объектов на основе контурного анализа состоит из трех подзадач: выделения контуров объектов, формирования признаков выделенных контуров и их классификации на основе этих признаков. На сегодняшний день существует большое количество методов и алгоритмов контурного анализа для распознавания объектов на изображениях, позволяющих получать требуемые результаты при выполнении определенных условий, отклонение от которых приводит к снижению результативности их практического использования. В частности, зашумленность изображений определяет нечеткий характер граничных значений перепадов яркости соседних пикселей, используемых в контурном анализе и, как следствие, приводит к сложности выделения контуров и определению их информативных признаков, используемых для автоматического распознавания объектов.

Контур представляет собой совокупность пикселей, поэтому целесообразно определить математическую зависимость степени принадлежности рассматриваемого пикселя к контуру от перепадов яркости соседних пикселей, а также дальнейшего принятия решения. Поскольку математическая зависимость неизвестна, а изображения искажены шумом, то возникает задача нахождения ее аппроксимирующей функции. Данную задачу можно решить с помощью нейронечеткого моделирования, позволяющего определить вид и параметры искомой аппроксимирующей функции многих переменных.

Нейронечеткая модель определяется структурой и составом правил соответствующей нечеткой модели. Значения параметров нейронечеткой модели определяются в результате их идентификации на основе набора исходных данных, который используется как обучающая выборка. Поэтому для решения задачи выделения контура искомого объекта на ряде изображений определенного класса необходимо определить структуру и состав нечетких правил, сформировать обучающую выборку на одном из представителей рассматриваемого класса и идентифицировать параметры функций принадлежности.

Непрерывные контуры объектов позволяют определять их информативные признаки, инвариантные относительно смещения, поворота и масштабирования рассматриваемых контуров. Зашумленность обрабатываемых изображений приводит к определенному искажению непрерывных контуров. Поэтому для решения задач классификации контуров целесообразно, в первую очередь, определить состав и значения их информативных признаков, а затем построить и использовать нейросетевые модели, каждая из которых аппроксимирует функциональную зависимость степени принадлежности соответствующего контура к классу в зависимости от его информативных признаков.

Однако задачи построения непрерывных контуров объектов на основе нейронечеткой модели, автоматизации распознавания объектов на основе формирования и классификации информативных признаков их контуров являются нетривиальными и требуют разработки специального математического и программного обеспечения. Следовательно, тема диссертационного исследования, связанная с разработкой и использованием нейронечетких моделей для выделения непрерывных контуров объектов на изображениях, а также разработкой методов формирования информативных признаков выделенных контуров и распознавания объектов на их основе, является актуальной.

Степень разработанности темы. Значительный вклад в разработку систем на основе технического зрения и разработку методов цифровой обработки изображений внесли: Б.А. Алпатов [2], П.В. Бабаян [3], О.Е. Балашов [4], К.К. Веремеенко [5], Н.В. Ким [6], Я.А. Фурман [7], И.Б. Гуревич [8], Ю.П. Пытьев [9], Ю.А. Журавлев, Л.М.

Шарнин [10], М.П. Шлеймович [11], Н.Н. Красильников [12], D.A. Forsyth [13], R.C. Gonzalez, W.K. Pratt, L.G. Shapiro и другие ученые и специалисты.

В настоящее время существует достаточное количество работ, в которых описывается использование нечетких моделей для выделения контуров и нейросетевых моделей для распознавания объектов. Исследованиям в этой области посвящены работы следующих ученых: В.В. Вершинина [14], И.В. Аникин [15], Н.С. Исупов [16], А.Е. Лепский [17], М.Д. Ершов [18], С.С. Георгиева [19], В.В. Борисов [20], В.В. Круглов [21], Л.Н. Ясницкий [22], С. Осовский, Н. Винер, С. Хайкин, Я. Лекун, А.М. Alawad [23], Е. Мoya-Albor, O.P. Verma [24], D.O. Aborisade [25], A. Khunteta [26] и др. Однако, в данных работах построение нечетких моделей принятия решения о контурности пикселя осуществляется при предположениях о возможных прохождениях контурных линий через фрейм пикселей 3x3 и как следствие теряются обобщающие свойства созданных моделей, ограничивается их практическое использование, что приводит к невозможности автоматизации дальнейшего процесса распознавания объекта.

Таким образом, научная задача, решаемая в диссертации, заключается в разработке методов и алгоритмов, а также комплекса программ нейронечеткого моделирования процесса выделения контуров объектов на изображениях, а также нейросетевого моделирования их классификации на основе вычисленных информативных признаков. Ее решение имеет научную и практическую ценность для построения нейронечетких и нейросетевых моделей, а также автоматизации обработки изображений для распознавания на них искомых объектов.

Объект исследования: процесс распознавания объектов на изображении на основе контурного анализа.

Предмет исследования: методы и алгоритмы построения нейронечетких моделей принятия решения о контурности пикселей изображения и формирования наборов данных для их обучения, а также методы и алгоритмы построения нейросетевых классификаторов контуров объектов и формирования наборов данных для их обучения.

Целью диссертационной работы является повышение результативности поиска и распознавания искомых объектов на изображениях на основе

нейронечеткого моделирования процесса выделения контуров объектов и нейросетевого моделирования их классификации. Результативность определяется показателями практического использования: долей правильно распознанных объектов на изображениях, а также возможностью автоматизации процесса выделения и классификации непрерывных контуров объектов.

Для достижения цели необходимо решить следующие задачи:

- 1) разработать метод и алгоритмы построения структуры и состава нейронечеткой модели выделения контурных точек изображения;
- 2) разработать метод и алгоритм идентификации значений параметров нейронечеткой модели;
- 3) разработать метод и алгоритмы построения нейросетевой модели классификатора выделенных контуров на основе их информативных признаков;
- 4) реализовать разработанные методы и алгоритмы в виде программного комплекса для выделения и распознавания контуров на изображении, а также проведения вычислительных экспериментов.

Научная новизна:

- 1) разработан метод построения структуры и состава нейронечеткой модели выделения контурных точек, отличающийся способом формирования нечетких правил, основанным на использовании бинарного эквивалента изображения и способом определения признака принадлежности пикселя контуру, что позволяет осуществлять процесс построения модели без участия эксперта (п. 2);
- 2) разработан метод идентификации значений параметров нейронечеткой модели, отличающийся способом формирования набора данных для обучения, а также этапом контроля создания исходной популяции и потомства используемого генетического алгоритма оптимизации, что позволяет обеспечить выполнение требований к значениям параметров функций принадлежности (п. 2);
- 3) разработан метод формирования набора данных для построения нейросетевой модели классификации выделенных контуров объектов, отличающийся использованием наборов признаков искомого контура двух противоположных

направлений, что позволяет распознавать объект независимо от его ориентации (п. 2);

4) разработан программный комплекс, реализующий предложенные методы и алгоритмы, отличающийся составом и взаимодействием программных модулей, что позволяет строить предложенные модели и использовать их для решения поставленных задачи, а также проведения вычислительных экспериментов (п. 3);

5) проведены численные эксперименты, а также статистический и визуальный анализ их результатов для оценки эффективности разработанных методов и алгоритмов с применением современных компьютерных технологий и метрик качества классификации, отличающиеся использованием требований к функциям принадлежности нейронечеткой модели и ошибкам классификации выделенных на изображении контуров, что позволяет сформировать требования к наборам данных для построения нейронечетких и нейросетевых моделей (п. 9).

Методы исследования. Для решения указанных задач использованы методы контурного анализа изображений, нейросетевого, нечеткого и нейронечеткого моделирования, генетической оптимизации, а также методы объектно-ориентированного программирования.

Достоверность полученных результатов. Предложенные в диссертационной работе методы, алгоритмы, модели теоретически обоснованы и не противоречат известным положениям других авторов. Достоверность научных положений, выводов и рекомендаций обусловлена математически строгим выполнением расчетов, подтверждена результатами проведенных исследований и практического использования.

На защиту выносятся следующие результаты:

1) метод и алгоритмы построения структуры и состава нейронечеткой модели выделения контурных точек, основанные на использовании бинарного изображения при формировании базы нечетких правил;

2) метод и алгоритм идентификации значений параметров нейронечеткой модели, обеспечивающие выполнение требований к параметрам функций принадлежности;

3) метод и алгоритмы построения нейросетевого классификатора контуров, выделенных с помощью нейронечеткой модели, на основе использования признаков-дескрипторов Фурье искомого контура двух направлений при формировании набора данных;

4) программный комплекс, реализующий предложенные методы и алгоритмы построения нейронечеткой модели выделения контурных точек изображения и нейросетевого классификатора выделенных контуров, а также использующий построенные модели для поиска и распознавания на изображении искомым объектов.

Теоретическая значимость диссертационного исследования заключается в разработке структуры и состава нейронечеткой модели выделения контурных точек на изображении, алгоритма формирования набора данных для ее построения, генетического алгоритма оптимизации значений параметров нейронечеткой модели, метода формирования набора данных для построения нейросетевой модели классификации выделенных контуров объектов.

Практическая значимость диссертации заключается в разработке программного комплекса, реализующего алгоритмы построения нейронечеткой модели выделения контурных точек изображения и нейросетевого классификатора выделенных контуров для поиска и распознавания искомым объектов на изображении.

Соответствие диссертации паспорту научной специальности.

Результаты диссертационного исследования соответствуют следующим пунктам паспорта научной специальности 1.2.2 «Математическое моделирование, численные методы и комплексы программ»:

П2. Разработка, обоснование и тестирование эффективных вычислительных методов с применением современных компьютерных технологий: разработаны методы построения нейронечеткой модели выделения контурных точек и формирования наборов данных для ее построения, а также метод генетической оптимизации значений параметров нейронечеткой модели и метод формирования набора данных для построения нейросетевой модели классификатора выделенных контуров объектов.

ПЗ. Реализация эффективных численных методов и алгоритмов в виде комплексов проблемно-ориентированных программ для проведения вычислительного эксперимента: предложенные методы и алгоритмы реализованы в виде комплекса программ, на базе которого проведены вычислительные эксперименты по построению нейронечеткой и нейросетевой моделей, выделению на их основе контуров на ряде изображений, а также поиску и распознаванию на изображениях искомого объекта на примере контура человека.

П9. Постановка и проведение численных экспериментов, статистический анализ их результатов, в том числе с применением современных компьютерных технологий: проведены численные эксперименты, а также статистический и визуальный анализ результатов обработки изображений, выделения и классификации контуров объектов на них с использованием метрик качества классификации.

По теме диссертационного исследования опубликованы 12 научных работ, в число которых входят 4 статьи в изданиях из перечня ВАК РФ, 1 статья из базы Scopus, 7 публикаций в других журналах и материалах научных конференций. Получено 1 свидетельство о регистрации разработанной программы для ЭВМ.

Основные результаты диссертации докладывались и обсуждались на следующих конференциях: XXIII - Международная научная конференция Математические Методы в Технике и Технологиях ММТТ (2020, 2021, 2023); Международная научная конференция «Кибер-физические системы: проектирование и моделирование» CYBERPHY – «Cyber-Physical Systems Design And Modelling» (2021, 2023); XVI Всероссийская научно-практической конференции. Пенза - МЦНС «Наука и Просвещение» (2022); Международный форум Kazan Digital Week (2023), XII Национальная научно – практическая конференция с международным участием «Моделирование энергоинформационных процессов» (2023).

Реализация результатов работы

- внедрены в ФГБОУ ВО «Казанский национальный исследовательский технический университет им. А.Н. Туполева-КАИ» и используются в учебном процессе при изучении дисциплин «Технологии интеллектуального анализа данных», «Нейросетевые модели и алгоритмы», «Глубокое машинное обучение»;

- используются в научных исследованиях обособленного подразделения №2 АО «УЗГА» при разработке системы интеллектуальной обработки изображений в рамках создания новых более точных методов обнаружения искомого объекта на изображениях, снятых с беспилотных летательных аппаратов.

Структура и объем диссертации. Диссертация изложена на 132 странице машинописного текста, содержит 68 рисунков, 8 таблиц, состоит из введения, четырех глав, заключения, списка использованной литературы из 127 наименований и 3 приложений.

Сведения о личном вкладе автора. Постановка научной задачи, содержание диссертации, проведение численных экспериментов получены лично автором. Подготовка к публикации некоторых научных статей, а также получение и регистрация результатов интеллектуальной деятельности проводились совместно с соавторами, причем вклад диссертанта определяющий.

Во введении обоснована актуальность темы диссертационного исследования, приведены основные научные положения и результаты.

В первой главе рассматриваются и анализируются методы выделения контуров на изображении: градиентные и методы на основе нечеткой логики. Описываются основные идеи выбранных методов, их достоинства и недостатки. Ставится задача разработки нейронечеткой модели выделения контурных точек, алгоритмов формирования набора данных для обучения и ее построения, метода и алгоритма формирования вектора признаков выделенного контура объекта на основе множества координат его точек, разработки нейросетевой модели классификации выделенного контура объекта на основе сформированных векторов признаков.

Во второй главе представлен разработанный метод построения базы знаний для выделения контурного пикселя, который состоит из трех этапов. На первом этапе вводятся лингвистические переменные, нечеткие множества их значений, определяется вид нечетких продукционных правил, описывается логический вывод Цукомото и правило, принимающее решение о контурности пикселя. Второй этап метода посвящен построению структуры и состава нейронечеткой сети для адаптивного подбора параметров функций принадлежности. Третьим этапом метода

является оптимизация параметров функций принадлежности. Приводится описание алгоритмов построения набора данных для обучения для нахождения параметров функций принадлежности и этапов самого генетического алгоритма.

Третья глава посвящена методу и алгоритму построения нейросетевой модели идентификации контура объекта на основе признаков (дескрипторов) его эталонного замкнутого контура. Для вычисления признаков используется быстрое преобразование Фурье и обосновывается необходимость модификации существующего метода. Предлагается алгоритм построения набора данных для обучения нейросетевой модели.

В четвертой главе описывается методика выделения и распознавания эталонного контура на изображении на основе разработанных методов и алгоритмов, а также разработанный комплекс программ по автоматизированной обработке изображения на основе нейронечеткого и нейросетевого моделирования, реализующий разработанную методику. Приведены результаты экспериментальных исследований.

ГЛАВА 1. АНАЛИЗ МЕТОДОВ ВЫДЕЛЕНИЯ КОНТУРОВ НА ИЗОБРАЖЕНИИ

В этой главе рассматриваются и анализируются методы выделения контуров на изображении: градиентные и методы на основе нечёткой логики. Описываются основные идеи выбранных методов, их достоинства и недостатки. Ставится задача разработки нейронечеткой модели выделения контурных точек, алгоритмов формирования набора данных для обучения и ее построения, метода и алгоритма формирования вектора признаков выделенного контура объекта на основе множества координат его точек, разработки нейросетевой модели классификации выделенного контура объекта на основе сформированных векторов признаков.

1.1. Определение и области применения контурного анализа

Контурный анализ представляет собой совокупность методов выделения и описания контуров объектов на изображениях, а также методов распознавания образов на основе признаков выделенных контуров [27–44]. При анализе изображения контуры объектов описывают форму, размер и используются для распознавания этих объектов, а также определения их местоположения на изображении.

Одним из важных факторов, позволяющих успешно распознавать объекты на основе выделенных контуров, является их непрерывность. Непрерывность контуров объектов также важна для автоматизации процесса распознавания объекта без участия эксперта на основании признаков, вычисленных тем или иным способом. При дальнейшем изложении будем считать, что непрерывность характеризует контур, представляющий собой границу некоторого объекта.

Контур объекта на изображении можно представить в виде упорядоченной последовательности координатных пар:

$$E = [e_1, e_2, \dots, e_n | e_i = P_i], P_i = (x_i, y_i);$$

где:

- E – сам контур объекта;
- e_1, e_2, \dots, e_n – упорядоченный набор пикселей контура;

- n – общее число точек, составляющих контур;
- P_i – координатная пара;
- x_i, y_i – координаты i -го пикселя.

В настоящее время контурный анализ применяется:

- при обработке рентгеновских и томографических снимков в медицинской области [45; 46];
- при обработке сигналов различных датчиков и камер роботов с целью управления его перемещением и/или его манипуляциями [47-49];
- при обработке снимков, сделанных с космических спутников [50];
- для распознавания номеров машин, нарушающих правила дорожного движения, или при различных криминалистических ситуациях [51-53];
- при распознавании лиц, отпечатков пальцев, голоса или при оценке состояние алкогольного опьянения в биометрических системах [54; 55];
- при распознавании жестов рук человека [56];
- и других областях.

Для выделения контурных точек в зависимости от решаемой задачи могут использоваться локальные методы, контекстные и глобальные методы, а также многомерные методы. В работе [57] предложена классификация методов выделения контурных точек. В таблице 1.1 представлены классы методов выделения контурных точек и их состав.

Таблица 1.1. – Классы методов выделения контурных точек и их состав

Класс методов	Состав класса
Локальные методы	Градиентные методы Статистические методы Методы фазовой конгруэнтности Методы статистики векторного порядка и Морфологические методы Комбинированные методы
Контекстные и глобальные методы	Методы значимости Методы Гештальт-группировки Методы активных контуров
Многомерные методы	Методы краевой фокусировки Методы локального управления масштабом

Одной из простых, достаточно эффективных и часто используемых групп методов выделения контурных точек являются градиентные методы.

1.2. Градиентные методы выделения контуров на изображении

Градиентные методы используют значения производных первого или второго порядка функции яркости каждого пикселя для нахождения пикселей, на которых значения производной яркости превышает заранее заданный порог. Для вычисления производных используют различные градиентные операторы: Робертса, Превитта, Собеля и других [58; 59].

Градиентные методы базируются на применении линейной пространственной фильтрации. В этом случае для поиска производной яркости на изображении используют фильтр, который еще называют «скользящей маской». Маска представляет собой квадратную матрицу с некоторыми числами, которая соотносится с пикселями обрабатываемого изображения. В дальнейшем элементы матрицы именуется коэффициентами. Процесс использования этой матрицы в тех или иных преобразованиях называется пространственной фильтрацией. На рисунке 1.1 продемонстрирована схема пространственной фильтрации.

В процессе фильтрации маска фильтра перемещается последовательно по горизонтали, затем по вертикали от точки к точке изображения. Для вычисления отклика фильтра в каждой точке (x, y) осуществляется свертка фильтра и соответствующей области обрабатываемого изображения. В случае линейной пространственной фильтрации свертка вычисляется суммой произведения чисел фильтра на соответствующие значения яркостей пикселей в соответствующей области. Для маски размера 3×3 , свертка вычисляется по следующей формуле:

$$R = w(-1, -1)f(x - 1, y - 1) + w(-1, 0)f(x - 1, y) + \dots + w(0, 0)f(x, y) + \dots + w(1, 0)f(x + 1, y) + w(1, 1)f(x + 1, y + 1) \quad (1.1)$$




Рис. 1.1 – Схема пространственной фильтрации

Дискретные аналоги производных первого и второго порядков используются при анализе перепадов яркостей соседних пикселей. Вычисление первой производной для каждого пикселя изображения использует дискретное приближение двумерного градиента. Градиентом $f(x, y)$ пикселя с координатами (x, y) на изображении является вектор:

$$\nabla f = \begin{pmatrix} G_x \\ G_y \end{pmatrix} = \begin{pmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{pmatrix} \quad (1.2)$$

Из математического анализа известно, что градиент функции f в точке (x, y) показывает направление наискорейшего возрастания функции. Модуль ∇f вычисляется по формуле (1.3) и используется при принятии решения о контурности рассматриваемого пикселя:

$$|\nabla f| = \sqrt{G_x^2 + G_y^2}. \quad (1.3)$$

Модуль $|\nabla f|$ определяет значение максимальной скорости изменения функции f для пикселя с координатами (x,y) .

Направление вектора градиента ∇f определяется через вычисление угла между направлением вектора ∇f для пикселя с координатами (x,y) и осью x по следующей формуле:

$$\alpha(x, y) = \arctg\left(\frac{G_y}{G_x}\right) \quad (1.4)$$

Рассмотрим окрестность (рис. 1.2) некоторого пикселя изображения со значениями яркостей $\overline{z_1, z_8}$.

z_1	z_2	z_3
z_4	z_5	z_6
z_7	z_8	z_9

Рис. 1.2 – Окрестность 3x3 некоторого пикселя изображения

Оператора Робертса вычисляет первые частные производные в точке z_5 следующим образом [61; 62]:

$$G_x = (z_9 - z_5) \text{ и } G_y = (z_8 - z_6) \quad (1.5)$$

Обработка всего изображения при помощи оператора Робертса, базируется на использовании соответствующих масок, представленных на рисунке 1.3.

К достоинствам данного метода относится простота его реализации и низкая вычислительная сложность, однако в некоторых случаях качество фильтрации является неудовлетворительным.

-1	0	0	-1
0	1	1	0

Рис. 1.3 – Маски оператора Робертса

Оператор Превитт [41] вычисляет первые производные с помощью следующих формул:

$$\begin{aligned} G_x &= (z_7 + z_8 + z_9) - (z_1 + z_2 + z_3) \text{ и} \\ G_y &= (z_3 + z_6 + z_9) - (z_1 + z_4 + z_7) \end{aligned} \quad (1.6)$$

Обработка всего изображения при помощи оператора Превитт, базируется на использовании соответствующих масок:

-1	-1	-1
0	0	0
1	1	1

-1	0	1
-1	0	1
-1	0	1

Рис. 1.4 – Маски оператора Превитт

Достоинством оператора Превитт является лучшее качество фильтрации по сравнению с оператором Робертса, но при этом имеет большую вычислительная сложность.

Оператор Собеля вычисляет первые производные с помощью следующих формул:

$$G_x = (z_7 + 2z_8 + z_9) - (z_1 + 2z_2 + z_3) \text{ и}$$

$$G_y = (z_3 + 2z_6 + z_9) - (z_1 + 2z_4 + z_7) \quad (1.7)$$

Эти формулы позволяют увеличить эффект сглаживания за счет придания большего веса средним точкам. Маски оператора Собеля представлены на рисунке рисунке 1.5.

-1	-2	-1
0	0	0
1	2	1

-1	0	1
-2	0	2
-1	0	1

Рис. 1.5 – Маски оператора Собеля

Значения G_x и G_y вычисленные с помощью операторов Робертса, Превитт и Собеля для каждого пикселя изображения используются для вычисления модуля градиента яркости: $|\nabla f| = \sqrt{G_x^2 + G_y^2}$.

Позже было предложено множество методов, таких как: оператор Кирша, отличающимся использование масок для каждой стороны света (в общей сложности 8 масок), оператор Робинсона, Дойч и Фрам, Дэвис, Фрей-Чен, Неватия и Бабу, Икономопулос и др.

Метод Кэнни использует многоэтапный алгоритм для обнаружения контуров на изображениях [63–65]. Алгоритм состоит из следующих шагов:

1) Этап сглаживания. В качестве сглаживающего фильтра используется фильтр Гаусса:

$$Gs = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{x^2+y^2}{2\sigma^2}\right) \quad (1.8)$$

Сглаживание исходного изображения с помощью фильтра Гаусса вычисляется в виде свертки по следующей формуле:

$$g(x, y) = Gs(x, y) * f(x, y) \quad (1.9)$$

Вид матрицы Гаусса, используемой для свертки:

$$\frac{1}{159} * \begin{bmatrix} 2 & 4 & 5 & 4 & 2 \\ 4 & 9 & 12 & 9 & 4 \\ 5 & 12 & 15 & 12 & 5 \\ 4 & 9 & 12 & 9 & 4 \\ 2 & 4 & 5 & 4 & 2 \end{bmatrix}$$

2) Вычисление модулей градиента $G(x, y)$ пикселя с координатами (x, y) сглаженного изображения $g(x, y)$ вычисляется по формуле:

$$G(x, y) = \sqrt{g_x^2(x, y) + g_y^2(x, y)} \quad (1.10)$$

$$\alpha(x, y) = \arctg\left(\frac{g_y(x, y)}{g_x(x, y)}\right) \quad (1.11)$$

3) Сравнение значения градиента каждого пикселя изображения с двумя соседними пикселями в направлении вектора градиента. Если значение градиента рассматриваемого пикселя больше значений градиентов соседних пикселей, то рассматриваемый пиксель определяется как граничный, иначе значение градиента корректируется в меньшую сторону.

4) Осуществляется двойная пороговая фильтрация, в результате которой устанавливается является ли рассматриваемый пиксель изображения контурным. Для этого используются верхний и нижний пороги. Если значение градиента пикселя больше верхнего порога, то яркость рассматриваемого пикселя изменяется на максимальное значение. Если значение градиента пикселя меньше нижнего порога, то яркость рассматриваемого пикселя приравнивается минимальному значению. Для пикселей со значениями в диапазоне между верхним и нижним порогами

устанавливается фиксированное среднее значение.

5) В случае если пиксель со средним значением располагается рядом с пикселем, имеющим максимальное значение, то ему также присваивается максимальное значение. В противном случае значение его яркости уменьшается до минимального [66].

Детектор Кэнни, благодаря этапу сглаживания, обеспечивает наилучшее обнаружение контуров на зашумлённых изображениях по сравнению с вышеописанными методами. Также данный метод позволяет выделять контуры более точно и обеспечивает более тонкие контуры. К недостаткам метода относится высокая вычислительная сложность и большая ресурсоемкость [67].

Для устранения указанных недостатков детектора Кэнни разработаны его различные модификации. Например, в работах [68; 69] описан метод, который позволяет игнорировать короткие контурные линии (такие линии затрудняют распознавания объектов).

Одним из отличий предложенного метода от метода Кэнни является применение одномерных масок вида $(-k, -k + 1, \dots, -1, 0, 1, \dots, k - 1, k)$ и $(-k, -k + 1, \dots, -1, 0, 1, \dots, k - 1, k)^T$ для оценки частных производных $\partial_x I$ и $\partial_y I$. Для некоторого пикселя оценка частной производной осуществляется при помощи свертки предложенной маски и вектора яркостей пикселей длины $2k + 1$, влияющей на точность в условиях шума. Значение $l = 2k + 1$ задается следующим образом: если значение шума является низким, то значение l рекомендуется выбирать равным 5, для изображений с высоким уровнем шума - равным 7...9.

Для определения угла направления вектора градиента используется подход, основанный на анализе частных производных:

- если $\partial_x I > 0$, а $|\partial_y I| \leq 0,414 \cdot \partial_x I$, то $\alpha = 0^\circ$;
- если $\partial_x I > 0$, а $0,414 \cdot \partial_x I < |\partial_y I| \leq 2,414 \cdot \partial_x I$, то $\alpha = \text{sign}(\partial_y I) \cdot 45^\circ$;
- если $|\partial_y I| > 2,414 \cdot \partial_x I$, то $\alpha = \text{sign}(\partial_x I) \cdot 90^\circ$;
- если $\partial_x I < 0$ и $0,414 \cdot |\partial_x I| < |\partial_y I| \leq 2,414 \cdot |\partial_x I|$, то $\alpha = \text{sign}(\partial_y I) \cdot 135^\circ$.

Вводятся два порога Δ_1 и Δ_2 , которые позволяют разбить множество всех

найденных значений модуля градиента на три подмножества [68]: $D_1 = [|\nabla I|_{min}; \Delta_1]$, $D_2 = [\Delta_1; \Delta_2]$, $D_3 = [\Delta_2; |\nabla I|_{max}]$. Вычисленные значения модулей градиентов, попадающих в подмножество D_1 , на втором этапе алгоритма исключаются из рассмотрения, тем самым сокращая объем вычислений.

Второй шаг описанного метода связан с поиском экстремумов $locmax|\nabla I_{ij}|$ модулей градиентов, попадающих в подмножества D_2 и D_3 . Направление экстремума в каждом пикселе ищется в направлении, полученном на первом шаге. При выполнении неравенства $I_{t-1} < I_t > I_{t+1}$ по соответствующему направлению для пикселя (i, j) фиксируется локальный максимум модуля градиента. Если $locmax|\nabla I_{ij}|$ попадает в подмножество D_3 , то ячейке (i, j) присваивается значение 1, если $locmax|\nabla I_{ij}|$ попадает в подмножество D_2 , то ячейке (i, j) присваивается значение 2. Полученные линии, состоящие из единиц, называются «сильными», из двоек – «слабыми» [68].

Третий шаг посвящен присоединению или подавлению слабых линий. Одним из условий присоединения слабой линии к сильной является их связанность по схеме восьмисвязной области. Вторым условием присоединения слабой линии к сильной является совпадение направлений векторов градиентов: если направление вектора градиента в слабом пикселе отличается от направления в сильном менее чем на $\pm 45^\circ$, то слабый пиксель включается в состав формируемого контура. Если какое-либо из вышеописанных условий не выполняется, то слабый пиксель исключается из рассмотрения контурного изображения.

На рисунке 1.6а представлено контурное изображение, полученное при помощи предложенного метода, а на рис. 1.6б - при помощи метода Кэнни. На обоих изображениях были выделены границы водных объектов, однако контурное изображение, полученное при помощи предложенного метода, содержит существенно меньшее количество коротких линий.

Данный метод разработан для использования, прежде всего, в авиационных системах технического зрения. Однако также была продемонстрирована его эффективность для обработки других классов изображений: рентгеновский снимок, река, озёра, фотография человека и др. Метод показал результат с меньшим количеством

«лишних» пикселей и временем обработки по сравнению с методом Кэнни.

Другой группой методов, использующей вычисление производных, являются методы пересечения нулевого уровня, в основе которых лежит нахождение второй производной в каждом пикселе изображения. В этом случае для нахождения перепада яркости между двумя смежными используется оператор Лапласа. Вид масок оператора Лапласа:

$$L_1 = \begin{pmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{pmatrix}, \quad L_2 = \begin{pmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{pmatrix}$$




Рис. 1.6 – Контурное изображения, полученное при помощи предложенного метода (а), контурное изображения, полученное при помощи метода Кэнни (б)

Оператор Лапласа при прохождении через нулевое значение меняет свой знак, что свидетельствует о наличии границы в данной точке. Методы пересечения нулевого уровня обнаруживают все виды границ вне зависимости от их направления. Суть оператора заключается в вычислении свертки исходного изображения с LoG-фильтром:

$$g(x, y) = [\nabla^2 G(x, y)] * f(x, y),$$

$$\nabla^2 G(x, y) = \left(\frac{x^2 + y^2 - 2\sigma^2}{\sigma^4} \right) e^{-\frac{x^2 + y^2}{2\sigma^2}},$$

далее необходимо найти точки пересечения нулевого уровня, характеризующие контурные пиксели.

Общий алгоритм методов пересечения нулевого порядка состоит из

следующих шагов:

- 1) фильтрация изображения при помощи гауссова фильтра низких частот;
- 2) вычисление лапласиана фильтрованного изображения;
- 3) нахождение точки пересечения нулевого уровня.

Достоинствами методов пересечения нулевого порядка является способность выделения контурных линий любых направлений, а также низкая вычислительная сложность. К недостаткам относится высокая чувствительная к шуму.

Несмотря на недостатки детектора Кэнни и появления большого количества его модификаций, следует отметить следующее. Согласно множеству исследований, проводимых как в России, например институтом НИИСИ РАН [70, 71], так и за рубежом [72], сделан вывод о том, что метод Кэнни является одним из лучших алгоритмов построения контурных точек изображения, позволяющий при определенных значениях его параметров строить непрерывные контуры (границы) для дальнейшего распознавания объектов. Однако принятие решения о том, что подобранные параметры обеспечивают построение непрерывных контуров объектов, происходит на основе визуального анализа, что не позволяет автоматизировать процесс распознавания объектов.

Преодолеть указанные ограничения позволяют методы нечеткой логики. В настоящее время методы нечеткой логики активно используются при решении различного рода задач, в том числе и для решения задач обработки изображений вообще и контурного анализа в частности. Применение нечеткого подхода позволит смоделировать процесс анализа изображений, естественный для человека. Это дает возможность построить правила выделения контуров с точки зрения человеческого восприятия. Методы нечеткой логики, применяемые для обработки изображения, позволяют рассматривать пороговое значение как лингвистическую переменную с нечеткими множествами значений и использовать функции принадлежности для задания степени принадлежности или не принадлежности рассматриваемой точки изображения к контуру. Целесообразно исследовать методы нечеткого и нейронечеткого моделирования, позволяющие строить решающие правила и

оптимизировать параметры функций принадлежности с целью построения непрерывных контуров объектов.

1.3. Методы выделения контуров на основе нечеткой логики

В настоящее время активно исследуется применение нечеткой фильтрации изображения [73–82]. Выделение контурных точек при помощи нечеткого фильтра основывается на применении одной из моделей нечеткого вывода (Мамдани, Ларсена и тд.). В научной литературе [74] доказана универсальная способность нечеткой модели аппроксимировать нелинейную функцию. Преимущество модели нечеткой фильтрации заключается в обладании свойством обобщения решения и работоспособности в условиях зашумленности изображения. Другим классом методов являются методы на основе нечеткой логики, которые рассматривают перепады яркости соседних пикселей как лингвистические переменные с множеством нечетких значений [83; 84].

Основными этапами обработки изображения с помощью нечеткой логики являются (рис. 1.7):

Входное изображение последовательно просматривается фреймом и для пикселей каждого фрейма выполняются следующие этапы алгоритма:

1. Фаззификация позволяет перейти от числовых значений перепадов яркостей к нечетким значениями лингвистических переменных. Этап обработки нечетких значений предполагает использования функции принадлежности и базы знаний в виде совокупности нечетких правил.

2. Логический вывод. Вычисленное значение истинности для предпосылок каждого правила применяется к заключениям каждого правила. Это приводит к одному нечеткому подмножеству, которое будет назначено каждой переменной вывода для каждого правила.

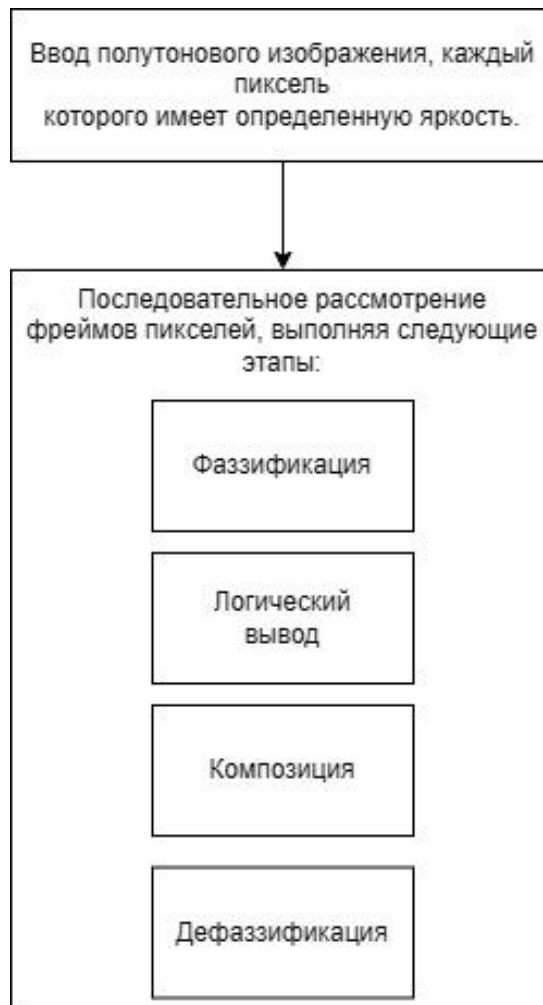


Рис. 1.7 – Основные этапы обработки

3. Композиция. Все нечеткие подмножества, назначенные к каждой переменной вывода (во всех правилах), объединяются вместе, чтобы формировать одно нечеткое подмножество для каждой переменной вывода.

4. Этап дефаззификации, приводящий нечеткий набор выводов в четкое число.

Нечеткие модели различаются:

1. Видом нечеткого вывода (Мамдани, Тагаки Сугено и др.), лингвистическими переменными (градиент яркости соседних пикселей/ яркость пикселей), различие заключается в разных способах задания значений выходной переменной в правилах, образующих базу знаний. От выбранной системы нечеткого вывода зависит значение выходной переменной, в системах нечеткого вывода Мамдани - нечеткие термы, а в случае Такаги-Сугено – линейная комбинация входных переменных [55].

2. Множеством используемых пикселей, описывающих прохождение контурной линии через рассматриваемый пиксель, в одних системах рассматривается фреймы размером 3x3, в других 5x5.
3. Множествами нечетких значений лингвистических переменных.
4. Методами определения параметров функций принадлежности.

1.4. Обзор работ, описывающих нечеткие модели выделения контуров

В работе [85] описывается применение нечеткой логики для обнаружения контуров на размытых и зашумленных медицинских снимках. Описанный подход включает в себе две нечеткие модели. Первая модель позволяет повысить контрастность, что позволяет уменьшить шум и понизить эффект размытия. Вторая модель применяется для выделения контурных точек.

После ввода полутонового изображения, в случае если необходимо повысить контрастность изображения осуществляется последовательная обработка фреймов 3x3 (рис. 1.8 (а)). В качестве входных данных нечетких модели выделения контурных пикселей выступает набор значений (рис. 1.8 (б)), полученные при помощи следующей формулы: $\Delta P_j = |P_j - P|, j = \overline{1,8}$.

P_1	P_2	P_3
P_4	P	P_5
P_6	P_7	P_8

а)

ΔP_1	ΔP_2	ΔP_3
ΔP_4	P	ΔP_5
ΔP_6	ΔP_7	ΔP_8

б)

Рис. 1.8 – Набор рассматриваемых пикселей (а), обработанный набор рассматриваемых пикселей (б)

В нечеткой модели для улучшения контрастности на этапе фаззификации используются трапециевидные функции принадлежности (рис. 1.9 (а)), а для функции принадлежности выходной переменной используется функция Гаусса (рис. 1.9 (б)). Вид нечетких правил представлен на рис. 1.10. В результате применения данной

модели значение каждого пикселя изображения попадает в один из трех диапазонов: более темный, серый и более светлый, при чем границы диапазонов сильно отличаются, тем самым повышается контрастность.

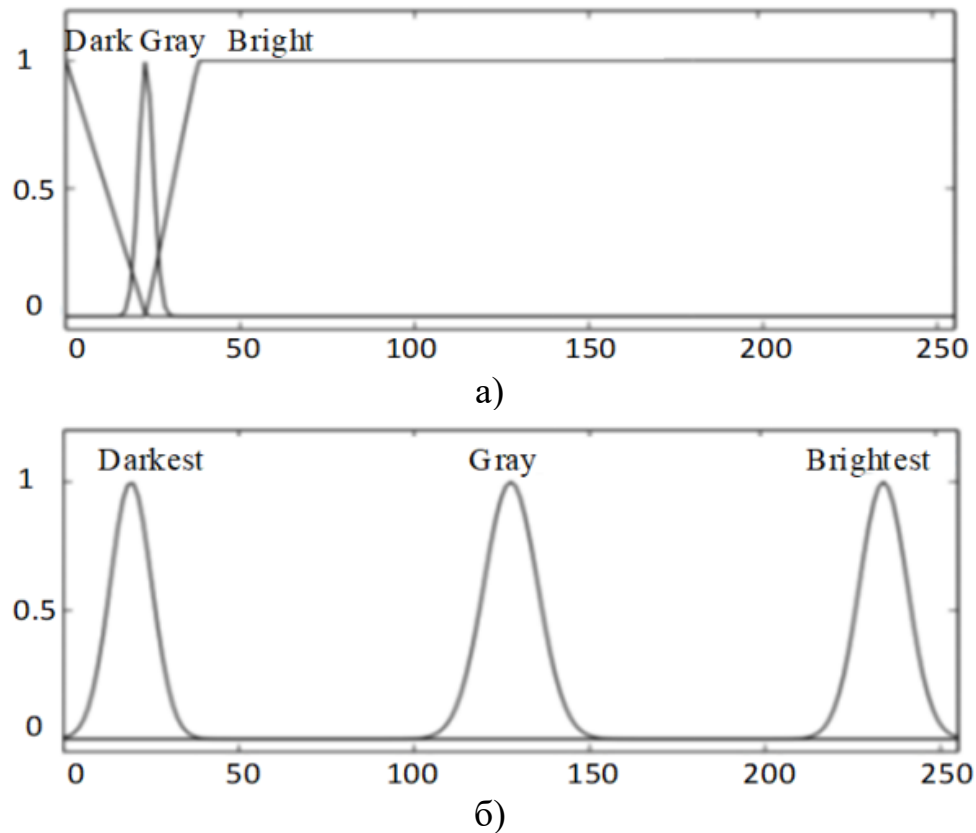



Рис. 1.9 – Вид функций принадлежности нечеткой модели повышения контрастности


Rules	Input Variable	Output Variable
1	Darker	Darkest
2	Grey	Grey
3	Brighter	Brightest

Рис. 1.10 – Вид нечетких правил нечеткой модели повышения контрастности

Нечеткая модель для выделения контурных пикселей для обработки входных значений также использует трапециевидные функции принадлежности (рис 1.11 (а)), а для выходной переменной функцию Гаусса (рис. 1.11 (б)). На рисунке 1.12 представлен набор используемых правил.



а)



б)

Рис. 1.11 – Вид функций принадлежности нечеткой модели выделения контурных точек

Rules	Input Variables								Output Variable
	ΔP_1	ΔP_2	ΔP_3	ΔP_4	ΔP_5	ΔP_6	ΔP_7	ΔP_8	
1	Higher	Higher	None	None	None	None	None	Lower	Edge
2	Higher	None	None	High	None	None	None	Lower	Edge
3	None	Higher	Higher	None	None	None	None	Lower	Edge
4	None	None	None	Higher	None	Higher	None	Lower	Edge
5	Higher	Higher	None	None	None	None	Lower	None	Edge
6	Higher	None	None	Higher	None	None	Lower	None	Edge
7	None	Higher	Higher	None	None	None	Lower	None	Edge
8	None	None	None	Higher	None	Higher	Lower	None	Edge
9	Higher	Higher	None	None	Lower	None	None	None	Edge
10	Higher	None	None	Higher	Lower	None	None	None	Edge
11	None	Higher	Higher	None	Lower	None	None	None	Edge
12	None	None	None	Higher	Lower	Higher	None	None	Edge

Рис. 1.12 – Набор используемых правил

На рисунке 1.13 представлены несколько изображений на которых представленный метод успешно выделил контуры. Для сравнения с представленным подходом были протестированы следующие методы: Sobel, Prewitt, LOG, Roberts, Canny

и др. Данные методы были применены к различным изображениям и их зашумленным версиям. Изображение, представленное на рис 1.14а, с разрешением 512x512 пикселей было зашумлено методом «соль и перец» с уровнем 25 дБ (рис. 1.14b). На рисунке 1.15 представлен график количества ложно выделенных контурных пикселей на изображении 1.14b. Как видно из графика, количество ложных контурных точек, выделенных при помощи предложенного подхода близко к результату метода Кэнни, имеющим лучший результат на данном изображении.

Далее предложенные методы были протестированы на размытом клиническом снимке (270x290 пикселей) с различным уровнем шума (24, 30, 35 дБ) типа «соль и перец». Количество выделенных ложных пикселей представлено на рис. 1.16. Представленный метод демонстрирует лучший результат среди всех протестированных методов, что говорит об его эффективности. Уровень чувствительности представленного метода составил 89%, а специфичности 96%.




Рис. 1.13 – Тестируемые изображения: Радуга (а), Цветок 1 (b), Цветок 2 (c), Контурное изображение радуги (d), Контурное изображение цветок 1 (e), Контурное изображение цветок 2 (f)




Рис. 1.14 – Исходное изображение (a), зашумленное изображение (b)




Рис. 1.15 – Количество ложных выделенных пикселей на изображении 1.14 (b)




Рис. 1.16 – Количество выделенных ложных пикселей

В работе [25] вначале, для каждого пикселя изображения вычисляется значение силы границы при помощи трех (3) линейных пространственных фильтров 3×3 : нижних частот, верхних частот и Собеля для улучшения границ (Рис. 1.17), посредством процесса пространственной свертки. На рисунке 1.18 представлены обозначения и последовательность, в которой обрабатываются пиксели из окрестности 3×3 . Пространственная свертка осуществляется при помощи следующей формулы:

$$\begin{aligned}
 O(x, y) = & aI(x - 1, y - 1) + bI(x - 1, y) + cI(x - 1, y + 1) + dI(x, y - 1) \\
 & + eI(x, y) + fI(x, y + 1) + gI(x + 1, y - 1) + hI(x + 1, y) + iI(x \\
 & + 1, y + 1)
 \end{aligned}$$

$$h_{LP} = \begin{bmatrix} \frac{1}{9} & \frac{1}{9} & \frac{1}{9} \\ \frac{1}{9} & \frac{1}{9} & \frac{1}{9} \\ \frac{1}{9} & \frac{1}{9} & \frac{1}{9} \end{bmatrix}, \quad h_{HP} = \begin{bmatrix} -1 & -1 & -1 \\ -1 & 9 & -1 \\ -1 & -1 & -1 \end{bmatrix}$$

$$h_x = \begin{bmatrix} -1 & 0 & +1 \\ -2 & 0 & +2 \\ -1 & 0 & +1 \end{bmatrix}, \quad h_y = \begin{bmatrix} +1 & +2 & +1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix}$$

Рис. 1.17 – Маски фильтров: нижних частот, верхних частот и Собеля

<i>a</i>	<i>b</i>	<i>c</i>
<i>d</i>	<i>e</i>	<i>f</i>
<i>g</i>	<i>h</i>	<i>i</i>

Рис. 1.18 – Обозначения пикселей из рассматриваемой окрестности

Полученные значения силы границ служат входными значениями нечеткой модели. В качестве функций принадлежности используются функции Гаусса, представленные на рис. 1.19. На рисунке 1.20 представлен фрагмент базы нечетких правил. В качестве алгоритма нечеткого вывода используется метод Мамдани.




Рис. 1.19 – Функции принадлежности

If $edginess_{Lp}$ is LO and $edginess_{So}$ is LO and $edginess_{Hp}$ is LO then p_{edge} is E_L
 If $edginess_{Lp}$ is LO and $edginess_{So}$ is LO and $edginess_{Hp}$ is MD then p_{edge} is E_L
 If $edginess_{Lp}$ is LO and $edginess_{So}$ is LO and $edginess_{Hp}$ is HI then p_{edge} is E_L
 If $edginess_{Lp}$ is LO and $edginess_{So}$ is MD and $edginess_{Hp}$ is LO then p_{edge} is E_L
 If $edginess_{Lp}$ is LO and $edginess_{So}$ is MD and $edginess_{Hp}$ is MD then p_{edge} is E_L
 If $edginess_{Lp}$ is LO and $edginess_{So}$ is MD and $edginess_{Hp}$ is HI then p_{edge} is E_M
 If $edginess_{Lp}$ is LO and $edginess_{So}$ is HI and $edginess_{Hp}$ is LO then p_{edge} is E_L
 If $edginess_{Lp}$ is LO and $edginess_{So}$ is HI and $edginess_{Hp}$ is MD then p_{edge} is E_H
 If $edginess_{Lp}$ is LO and $edginess_{So}$ is HI and $edginess_{Hp}$ is HI then p_{edge} is E_H

Рис. 1.20 – Фрагмент базы нечетких правил

В экспериментальной части продемонстрирована работа предложенного алгоритма и операторов Собеля и Кирша на нескольких изображениях (рис. 1.21). В данной статье не приводятся результатов экспериментальных исследований, однако авторы утверждают, что контурное изображение, полученное при помощи предложенного метода, является более гладким и содержит меньше шума. Также авторы утверждают, что их подход гораздо менее затратен в вычислительном отношении, а его применение к изображению улучшает качество границ по сравнению с методами, основанными на использовании операторов Собеля и Кирша.

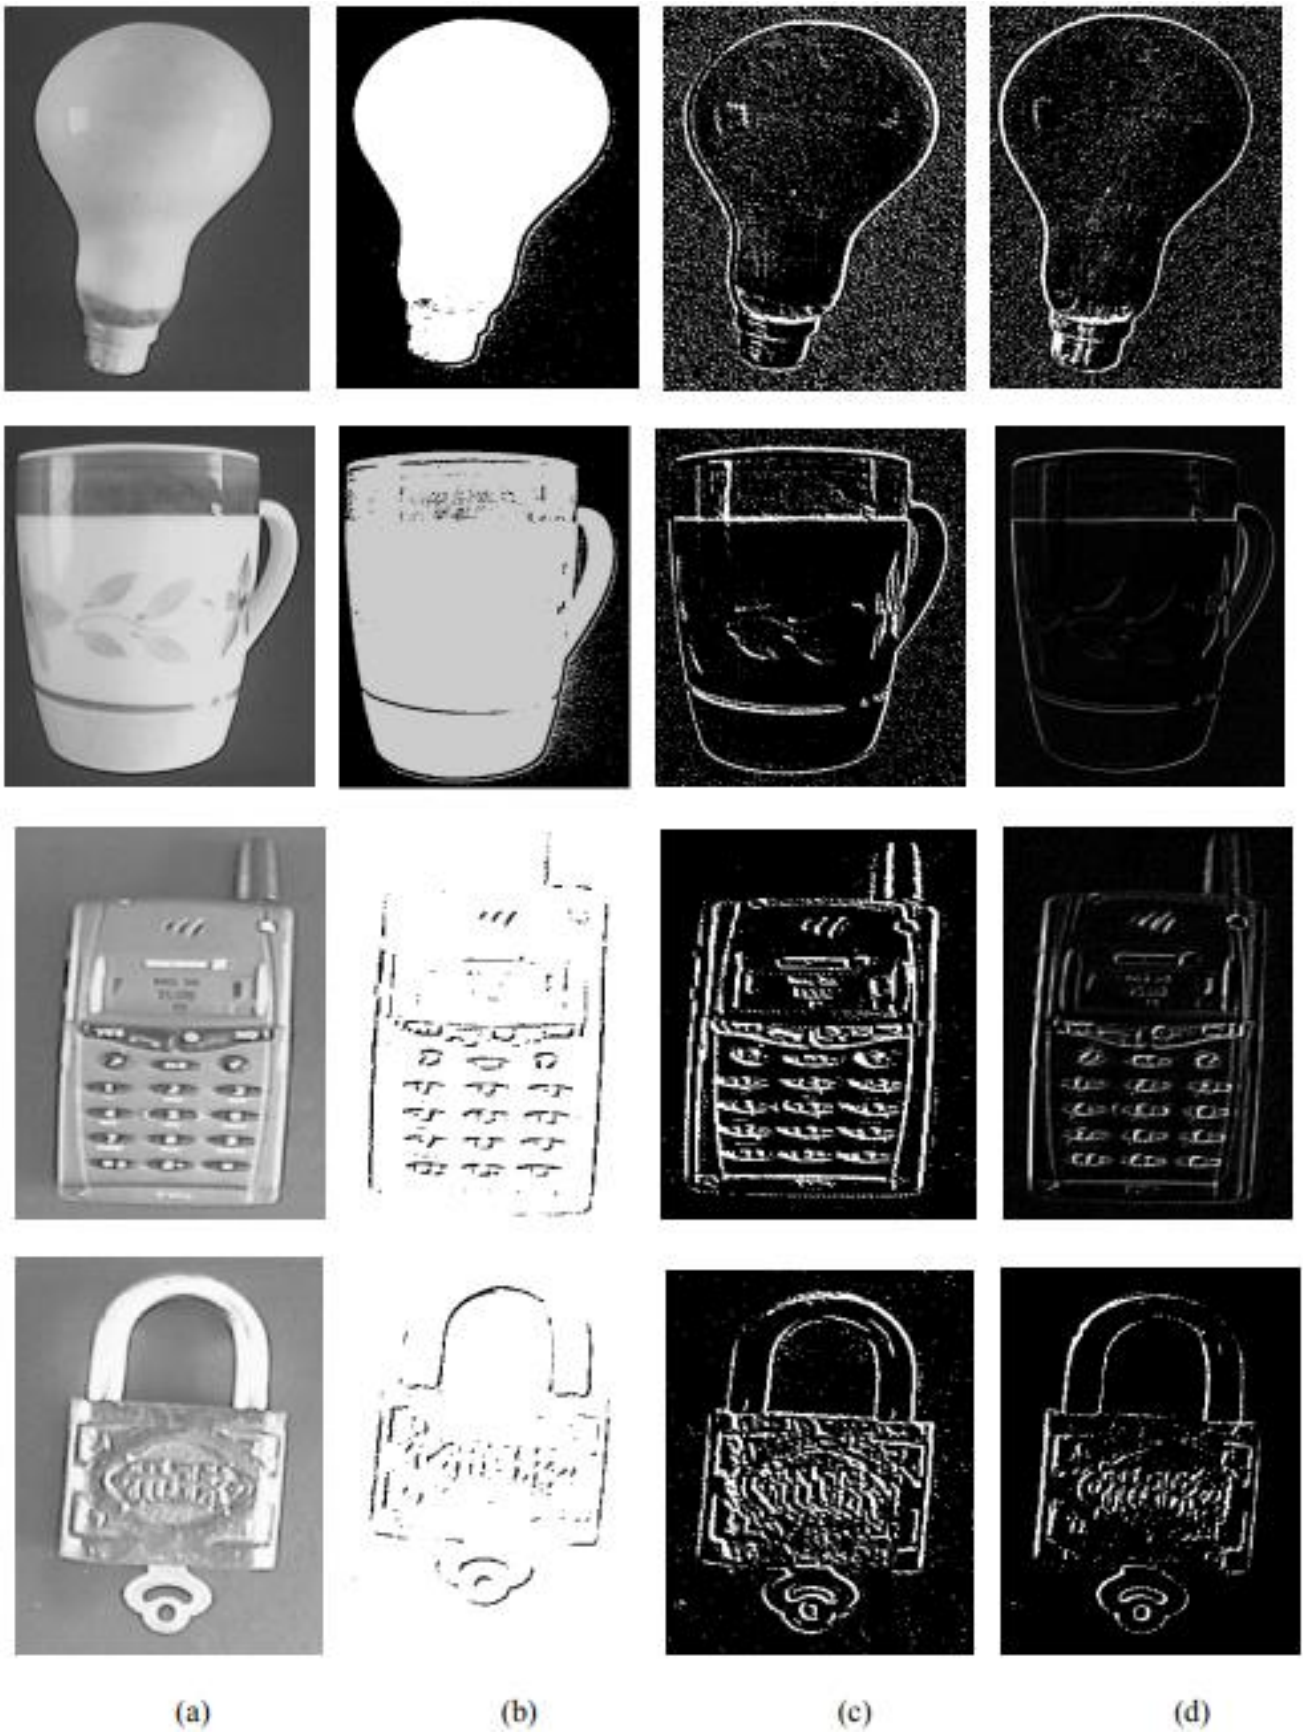


Рис. 1.21 – Исходные изображения (a), Результат работы оператора Собеля (b), Результат работы оператора Кирша (c), Результат работы предложенного метода (d)

В работе [86] описывается нечеткая модель, входными значениями которой являются результаты применения: фильтра верхних частот (HP), оператор Собеля (DV) и фильтра нижних частот (M). Для описания интенсивности полученных значений используются три лингвистические переменные «низкая», «средняя» и «высокая». Для лингвистических переменных «низкая» и «высокая» используется сигмовидная функция, для переменной «средняя» используется функция Гаусса со средним значением 127,5 (рис. 1.22). На рисунке 1.23 представлен вид нечетких правил.




Рис. 1.22 – Вид функций принадлежности

1. IF (M is low) and (h_{DV} is low) and (HP is low) THEN ("Edge" is low).
2. IF (M is low) and (h_{DV} is low) and (HP is medium) THEN ("Edge" is low).
3. IF (M is low) and (h_{DV} is low) and (HP is high) THEN ("Edge" is low).
4. IF (M is low) and (h_{DV} is medium) and (HP is low) THEN ("Edge" is low).
5. IF (M is low) and (h_{DV} is medium) and (HP is medium) THEN ("Edge" is low).
6. IF (M is low) and (h_{DV} is medium) and (HP is high) THEN ("Edge" is medium).
7. IF (M is low) and (h_{DV} is high) and (HP is low) THEN ("Edge" is low).
8. IF (M is low) and (h_{DV} is high) and (HP is medium) THEN ("Edge" is high).
9. IF (M is low) and (h_{DV} is high) and (HP is high) THEN ("Edge" is high).

Рис. 1.23 – Вид нечетких правил

В качестве алгоритма логического вывода (дефаззификатора) используется метод Мамдани. По результатам моделирования приводятся следующие выводы: метод имеет большую точность обнаружении границ и четко удаляет шум, однако требует больших вычислительных затрат.

В работе [23] описывается нечеткий подход, в котором используется 16 нечетких правил, описывающих прохождение контурной линии через рассматриваемый пиксель. Для лингвистических переменных вводятся нечеткие множества значений: «близкий к 0», «близкий к 0,3», «близкий к 0,8». Данные значения были выбраны на основе экспериментальных исследований и являются постоянными для всех изображений.

Сравнивая результат применения предложенного метода с градиентными методами, авторы утверждают, что полученные контуры лучше видно и легче обозначить границы отдельных объектов.

В работе [24] описывается нечеткий подход, в котором применяется 30 нечетких правил, в каждом из которых рассматривается яркость соседних с рассматриваемым пикселем. Лингвистическими переменными являются яркости этих пикселей, для них вводятся нечеткие множества значений: «близкий к 0» (черный пиксель), «близкий к 1» (белый пиксель). Используются треугольные функции принадлежности, представленные на рисунке 1.24. Множество нечетких правил (фрагмент представлен на рисунке 1.25) условно делят на 5 классов:

1. Правила с 3 черными и 5 белыми пикселями в окрестности рассматриваемого пикселя;
2. Правила с 4 черными и 4 белыми пикселями в окрестности рассматриваемого пикселя;
3. Правила с 5 черными и 3 белыми пикселями в окрестности рассматриваемого пикселя;
4. Правила с 6 черными и 2 белыми пикселями в окрестности рассматриваемого пикселя;
5. Правила со всеми черными или белыми пикселями в окрестности рассматриваемого пикселя (для устранения шума).

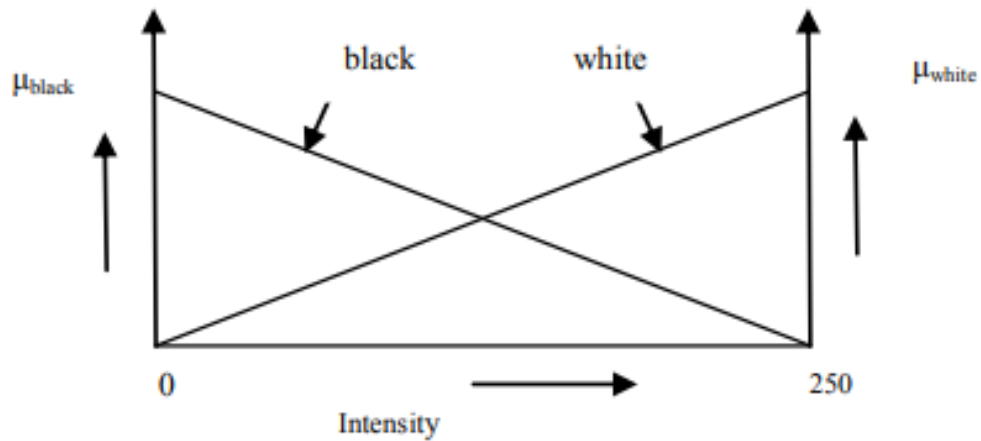


Рис. 1.24 – Вид функций принадлежности

Rule 1: If $I(i-1,j-1)$ AND $I(i-1,j)$ AND $I(i-1,j+1)$ AND $I(i,j-1)$ AND $I(i,j+1)$ are white and $I(i+1,j-1)$ AND $I(i+1,j)$ AND $I(i+1,j+1)$ are black then (i,j) is the edge pixel

Rule 2: If $I(i-1,j-1)$ AND $I(i-1,j)$ AND $I(i-1,j+1)$ are black and $I(i,j-1)$ AND $I(i,j+1)$ AND $I(i+1,j-1)$ AND $I(i+1,j)$ AND $I(i+1,j+1)$ are white then (i,j) is the edge pixel

Rule 3: If $I(i-1,j-1)$ AND $I(i-1,j)$ AND $I(i-1,j+1)$ are black and $I(i,j-1)$ AND $I(i,j+1)$ AND $I(i+1,j-1)$ AND $I(i+1,j)$ AND $I(i+1,j+1)$ are black then (i,j) is the edge pixel

Rule 4: If $I(i-1,j-1)$ AND $I(i,j-1)$ AND $I(i+1,j-1)$ are black and $I(i-1,j)$ AND $I(i-1,j+1)$ AND $I(i,j+1)$ AND $I(i+1,j)$ AND $I(i+1,j+1)$ are white then (i,j) is the edge pixel

Рис. 1.25 – Фрагмент базы правил

Также в работе описывается способ избавления от ложных срабатываний метода. Для этого авторы удаляют ложные границы при условии, если шесть или более шести пикселей в его окрестностях находятся в промежуточном диапазоне интенсивности. Выбранный промежуточный диапазон — [117...137]. Этот диапазон был определен путем проведения экспериментов и дает наилучшие результаты.

При сравнении описанного подхода с градиентными методами, был получен следующий результат: границы, полученные при помощи нечеткого подхода – лучше, а вычислительная сложность сопоставима.

В работе [26] для каждого пикселя изображения вычисляются градиенты в вертикальном и горизонтальном направлениях. Полученные значения градиентов подаются на вход нечеткой модели. В качестве лингвистических переменных используются «градиент яркости» с нечеткими значениями «высокий» и «низкий», и треугольными функциями принадлежности, представленными на рисунке 1.26, а также «степень контурности» рассматриваемого пикселя - с нечеткими значениями «низкая»,

«средняя» и «высокая», треугольные функции которых продемонстрированы на рисунке 1.27. Количество используемых нечетких правил равно 4 (рис. 1.38).

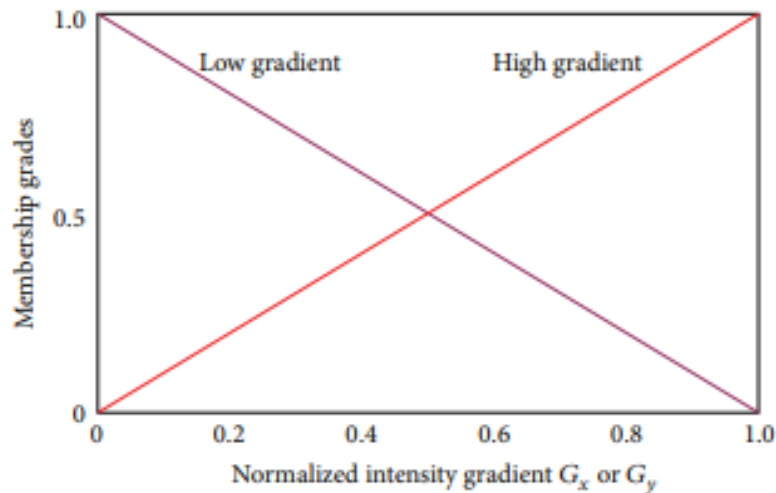


Рис. 1.26 – Вид функций принадлежности для переменной «градиент яркости»

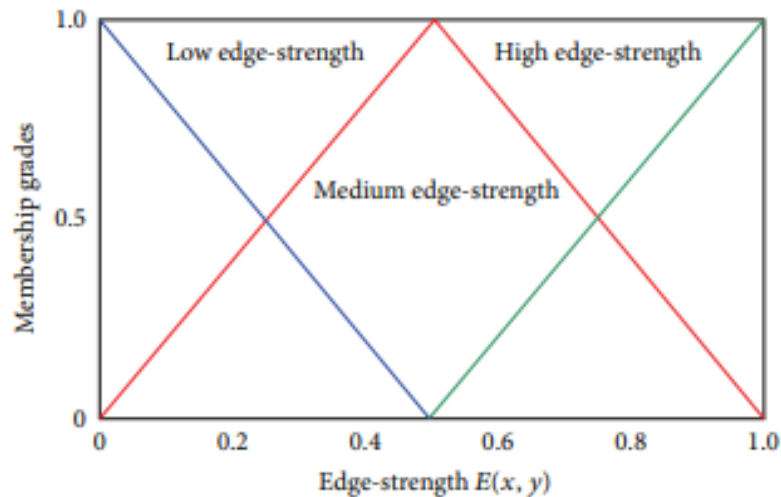


Рис. 1.27 – Вид функций принадлежности для переменной «степень контурности»

- (i) *Rule 1.* IF G_x is low AND G_y is low THEN edge-strength $E(x, y)$ is low.
- (ii) *Rule 2.* IF G_x is low AND G_y is high THEN edge-strength $E(x, y)$ is medium.
- (iii) *Rule 3.* IF G_x is high AND G_y is low THEN edge-strength $E(x, y)$ is medium.
- (iv) *Rule 4.* IF G_x is high AND G_y is high THEN edge-strength $E(x, y)$ is high.

Рис. 1.28 – Вид нечетких правил

Таким образом применение нечеткого подхода к выделению контуров имеет ряд преимуществ по сравнению с градиентными методами, а именно меньшая

восприимчивость к шуму и лучшее выделение контуров. К недостаткам следует отнести сложность реализации и вычислительную сложность.

Из вышеописанного можно сделать вывод, что использование нечеткого подхода позволяет автоматизировать процесс выделения контурных точек.

1.5. Постановка задачи выделения и распознавания контуров на изображении

Множество используемых пикселей, описывающих прохождение контурной линии через рассматриваемый пиксель, зависит от контура объекта, имеет ли он участки прямых линий, угловых и так далее. Рассматриваемое множество пикселей, а также множество лингвистических переменных и их нечеткие значения определяют вид и число нечетких правил. Поэтому необходимо разработать метод, позволяющий строить нечеткие правила для контуров, состоящих из любых видов участков. Далее необходимо сформировать алгоритм формирования набора данных для обучения и алгоритм построения нечеткой модели.

В работах [87–89] предложен метод и алгоритм классификации контура объекта, основанный на построении их признаков с помощью преобразования Фурье. Преимуществом такого подхода является инвариантность к размеру и смещению объекта на изображении. Однако особенности использования произведения комплексных чисел приводит к тому, что нормализация данных не обеспечивает инвариантность признаков контура относительно его угла поворота, что приводит к значительным ошибкам классификации. Поэтому возникает задача модификации данного алгоритма с целью обеспечения инвариантности.

Для сокращения времени построения и поиска контура искомого объекта на изображении необходимо разработать математическое, алгоритмическое, методическое и программное обеспечения, позволяющие автоматизировать этот процесс, а именно:

1. Разработать метод и алгоритмы построения нечеткой модели принятия решения о контурности точек изображения, а именно: структуры и состава нечетких правил, формирования набора данных для обучения, подбора параметров функций активации.

2. Модифицировать алгоритм формирования и распознавания вектора признаков непрерывного контура объекта на основе преобразования Фурье и нейросетевого моделирования.

3. Разработать методику построения контуров объектов на изображении и его классификации на основе нейронечеткой модели выделения контурных точек объектов на изображениях и нейросетевой модели принятия решения о соответствии выделенного контура эталонному.

4. Разработать программный комплекс, реализующий предложенную методику, а также методы и алгоритмы.

Решение указанных задач отражено в следующих главах диссертации.

1.6. Выводы

Метод Кэнни является одним из лучших алгоритмов построения контурных точек изображения, позволяющий при заданных значениях порогов фильтрации строить непрерывные контуры (границы) для дальнейшего распознавания объектов. Однако принятие решения о том, что выбранные значения порогов обеспечивают построение непрерывных контуров объектов, происходит на основе визуального анализа, что не позволяет на его основе автоматизировать процесс распознавания объектов.

Другим классом методов выделения контурных точек являются методы на основе нечеткой логики, которые рассматривают пороговые значения перепадов яркости соседних пикселей как лингвистические переменные с множеством нечетких значений. Каждая лингвистическая переменная описывается функцией принадлежности. Выделение контурных точек при помощи нечеткого фильтра основывается на применении одной из моделей нечеткого вывода (Мамдани, Ларсена и тд.), использующей определенный набор нечетких правил. В настоящее время модели нечеткой фильтрации строятся для определенных видов контурных линий на основе экспертной оценки. Для построения нечеткой модели для произвольных видов контурных линий необходимо разработать методы и алгоритмы определения множества нечетких правил и параметров функций принадлежности.

В настоящее время в технической литературе описан метод и алгоритм классификации контура объекта, основанный на построении их признаков с помощью преобразования Фурье. Преимуществом описанного подхода является преобразование контура: его сдвиг, масштабирование. Эти преобразования позволяют привести контур к одному и тому же виду и положению в новой системе координат вне зависимости от его первоначального размера и положения на изображении. Таким образом, преобразования сдвига и масштабирования обеспечивают инвариантность вычисляемых признаков контура вне зависимости от размера и расположения объекта на изображении. Однако особенности использования произведения комплексных чисел при вычислении угла, на который следует повернуть контур, не обеспечивает инвариантность признаков контура относительно его угла поворота, что приводит к значительным ошибкам классификации. Поэтому возникает задача модификации данного алгоритма с целью обеспечения инвариантности признаков контура относительно угла поворота.

Для построения нейросетевого классификатора необходимо разработать структуру нейронной сети и разработать метод построения набора данных для обучения.

ГЛАВА 2. МЕТОДЫ И АЛГОРИТМЫ РАЗРАБОТКИ НЕЙРОНЕЧЕТКОЙ МОДЕЛИ ВЫДЕЛЕНИЯ КОНТУРНОГО ПИКСЕЛЯ

В данной главе представлен разработанный метод построения базы знаний для выделения контурного пикселя, который состоит из трех этапов. На первом этапе вводятся лингвистические переменные, нечеткие множества их значений, определяется вид нечетких продукционных правил, описывается логический вывод Цукомото и правило, принимающее решение о контурности пикселя. Вторым этапом метода посвящен построению структуры и состава нейронечеткой сети для адаптивного подбора параметров функций принадлежности. Третьим этапом метода является оптимизация параметров функций принадлежности. Приводится описание алгоритмов построения набора данных для обучения для нахождения параметров функций принадлежности и этапов самого генетического алгоритма.

2.1. Математическая постановка задачи

Пусть:

Задано полноцветное изображение I , описываемое отображением:

$$\beta: X \times Y \rightarrow R \times G \times B \quad (2.1)$$

Здесь $X \times Y$ – множество координат пикселей изображения на плоскости;

$R \times G \times B$ – множество цветовых составляющих пикселей полноцветного изображения.

Требуется построить нейронечеткую модель выделения контурных точек изображения, для чего необходимо:

1. Определить структуру и состав слоев нейронечеткой сети.
2. Обучить нейронечеткую сеть и оптимизировать её параметры.

В основе построения структуры и состава нейронечеткой сети лежат нечеткие продукционные правила и логический вывод. Для построения нечетких продукционных правил требуется:

1. Определить совокупность лингвистических переменных и множество ее нечетких значений.
2. Определить вид нечетко-продукционных правил и алгоритм логического вывода.
3. Определить состав нечетко-продукционных правил и алгоритм принятия решения о контурности пикселя.

2.2. Определение лингвистических переменных и вида нечетких продукционных правил

Как известно из курса нечеткой логики, лингвистическая переменная характеризуется следующими параметрами:

- наименованием лингвистической переменной;
- множеством ее значений
- областью определения.

Для сокращения сложности состава предпосылок нечетких правил осуществляется переход от полноцветного изображения к полутоновому с помощью преобразования:

$$L(x_i, y_i) = 0.2989 * r(x_i, y_i) + 0.5870 * g(x_i, y_i) + 0.1140 * b(x_i, y_i), \quad (2.2)$$

где $r(x_i, y_i)$, $g(x_i, y_i)$, $b(x_i, y_i)$ - красная, зеленая и синяя составляющая i -го пикселя; $L(x_i, y_i)$ – значение яркости i -го пикселя полутонового изображения.

В дальнейшем рассматриваются нормализованные значения яркости в интервале $[0, 1]$, для чего яркость L_i делится на 256.

Рассмотрим некоторый пиксель изображения. Обозначим его яркость L и значения яркостей $L_i, i = \overline{1, 8}$ соседних пикселей (рис. 2.1). Так как значение яркости пикселя лежит в диапазоне $[0, 1]$, то значения разности яркостей $s_k = L - L_k, k = \overline{1, 8}$, будут лежать в диапазоне $[-1, 1]$.

L ₁	L ₂	L ₃
L ₈	L	L ₄
L ₇	L ₆	L ₅

Рис. 2.1 – Окружность пикселя с яркостью L

Введем восемь лингвистических переменных

< Разность яркостей $s_k, \{A, B, C\}, S$ >,

где терм-множество для всех лингвистических переменных состоит из следующих нечетких множеств:

- A - «Яркость пикселя из окрестности значительно меньше яркости L центрального пикселя»: $A = \{(s, \mu_A(s)); s \in [-1, 1]\}$;
- B - «Яркость пикселя из окрестности близка к яркости L центрального пикселя»: $B = \{(s, \mu_B(s)); s \in [-1, 1]\}$;
- C - «Яркость пикселя из окрестности значительно больше яркости L центрального пикселя»: $C = \{(s, \mu_C(s)); s \in [-1, 1]\}$.

Здесь $S = [-1, 1]$ – область определения лингвистических переменных, а $\mu_A(s)$, $\mu_B(s)$, $\mu_C(s)$ - трапециевидные функции принадлежности, график которых представлен на рисунке 2.2 (а):

$$\mu_A(s; a, b) = \begin{cases} 1, & \text{для } s \leq a \\ \frac{b-s}{b-a}, & \text{для } a < s \leq b \\ 0, & \text{для } s > b \end{cases} \quad (2.3)$$

$$\mu_B(s; c, d, e, f) = \begin{cases} 0, & \text{для } s \leq c \\ \frac{s-c}{d-c}, & \text{для } c < s \leq d \\ 1, & \text{для } d < s < e \\ \frac{f-s}{e-f}, & \text{для } e \leq s \leq f \\ 0, & \text{для } s > f \end{cases} \quad (2.4)$$

$$\mu_C(s; g, h) = \begin{cases} 0, & \text{для } s \leq g \\ \frac{s-g}{h-g}, & \text{для } g < s \leq h \\ 1, & \text{для } s > h \end{cases} \quad (2.5)$$

Введем следующую лингвистическую переменную

< Признак контурности пикселя, $\{E, F\}, Z$ >

где терм-множество состоит из следующих нечетких множеств:


- E – «Пиксель контурный»: $E = \{(z, \mu_E(z)); z \in [0,1]\}$,
- F – «Пиксель не контурный»: $F = \{(z, \mu_F(z)); z \in [0,1]\}$,

Здесь $Z = [0,1]$ – область определения лингвистической переменной, а $\mu_E(z)$, $\mu_F(z)$ – усеченные гауссовские функции принадлежности, представленные на рисунке 2.2 (б):


$$\mu_F(z) = \exp\left(-\left(\frac{z}{\sigma}\right)^2\right), \quad \mu_E(x) = \exp\left(-\left(\frac{x-1}{\sigma}\right)^2\right), \quad \text{где } \sigma = 0,05 \quad (2.6)$$

Поскольку принятие решения о контурности рассматриваемого пикселя зависит от разности яркостей между ним и восьмью пикселями, окружающих его, то база нечетких продукционных правил для выделения контурного пикселя примет следующий вид:

Если $s_1 = G_1$ & $s_2 = G_2$ & $s_3 = G_3$ & $s_4 = G_4$ & $s_5 = G_5$ & $s_6 = G_6$ & $s_7 = G_7$ & $s_8 = G_8$, тогда $z = R$, где $G_i \in \{A, B, C\}$, $i = \overline{1,8}$, $R \in \{E, F\}$ (2.7)



а)



б)

Рис. 2.2 – Вид функций принадлежности нечетких множеств

Механизм нечетких выводов, имеющий в своей основе нечеткие продукционные правила, состоит из трех этапов:

1. Введение нечеткости. Функции принадлежности применяются к фактическим значениям разности яркости для определения степени истинности каждой предпосылки каждого правила.

2. Логический вывод. Вычисленное значение истинности предпосылок каждого правила применяется к заключениям каждого правила о контурности пикселя. Это приводит к одному нечеткому подмножеству, которое будет назначено переменной «признак контурности пикселя» для каждого правила. В качестве правил логического вывода используется операция МИНИМУМ, когда функция принадлежности переменной «признак контурности пикселя» отсекается по высоте, соответствующей степени истинности предпосылок правила в соответствии с нечеткой логикой «И».

3. Приведение нечеткого множества для лингвистической переменной вывода к четкости.

Монотонный характер функций принадлежности для термов-множеств лингвистической переменной «Признак контурности пикселя» позволяет использовать алгоритм Цукомото и после этапа логического вывода определить четкое значение

«Признака контурности пикселя».

2.3. Алгоритмы определения состава нечетко-продукционных правил и принятия решения о контурности пикселя

Формирование базы правил является достаточно важным шагом, так как от качества правил будет зависеть результат правильности выделения контурного пикселя.

При формировании базы нечетких правил можно использовать алгоритм полного перебора нечетких значений. В этом случае будет получена база, состоящая из $2 * 3^8 = 13122$ правил, что очевидно является избыточным, которую необходимо будет редуцировать.

Для формирования базы правил без этапа полного перебора предлагается:

Алгоритм построения множества нечетких продукционных правил (Алгоритм 2.1):

1. Формирование бинарного изображения одним из известных методов.
2. Последовательное рассмотрение фреймов из пикселей бинарного изображения размером 3×3 (двигаясь слева направо и сверху вниз) и формирование множества $S_q = \{(s_1^j, s_2^j, s_3^j, s_4^j, s_5^j, s_6^j, s_7^j, s_8^j, r^j), j = \overline{1, M}\}$, где j - номер рассматриваемого пикселя, $s_i^j \in \{-1, 0, 1\}, i = \overline{1, 8}$ - разности яркостей на бинарном изображении между j пикселем и соседними с ним, $r^j \in \{0, 1\}$ - признак контурности рассматриваемого пикселя; M - количество фреймов.
3. Удаление повторяющихся векторов значений из S_q .
4. Для каждого вектора $(s_1^j, s_2^j, s_3^j, s_4^j, s_5^j, s_6^j, s_7^j, s_8^j, r^j)$ формируется нечеткое правило вида (2.7),

$$\text{в котором } G_i = \begin{cases} A, & \text{если } s_i^j = -1 \\ B, & \text{если } s_i^j = 0 \text{ и } z = \begin{cases} E, & \text{если пиксель контурный и } r^j = 1 \\ F, & \text{если пиксель не контурный и } r^j = 0 \end{cases} \\ C, & \text{если } s_i^j = 1 \end{cases}$$

Алгоритм принятия решения о контурности пикселя состоит из двух этапов:

1. В соответствии с логическим выводом Цукамото четкое значение переменной вывода z_0 для каждого j пикселя определяется как взвешенное среднее:

$$z_0 = \frac{\sum_{k=1}^M \alpha_k z^k}{\sum_{k=1}^M \alpha_k}, \quad (2.8)$$

где $\alpha_k = \min(\mu_{G_1^k}(s_1), \mu_{G_2^k}(s_2) \dots \mu_{G_8^k}(s_8))$, k – номер правила; z^k определяется как решение уравнения $\alpha_k = \mu_R(z^k)$, M – общее число правил.

2. Для каждого j пикселя применяется решающее правило, позволяющее получить однозначное значение принадлежности рассматриваемого пикселя контурному:

$$\begin{cases} \text{Если } z_0 \geq \varepsilon, \text{ то } j \text{ пиксель – контурный,} \\ \text{Если } z_0 < \varepsilon, \text{ то } j \text{ пиксель – не является контурным,} \end{cases} \quad (2.9)$$

где ε – заданное граничное значение.

2.4. Метод и алгоритмы идентификации значений параметров нейронечеткой модели

2.4.1. Определение структуры нейронечеткой сети

Нечеткие модели вывода позволяют описать выходной сигнал многомерного процесса как нелинейную функцию входных переменных и параметров функций принадлежности. В работах [90; 91] отмечено, что модели нечеткого вывода позволяют аппроксимировать с произвольной точностью любую нелинейную функцию многих переменных суммой функций одной переменной.

Существует класс нечетких нейронных сетей, соответствующих нечетким моделям [87]. В отличие от классических нечетких моделей в нечетких нейронных сетях выполняется адаптивный подбор параметров функций принадлежности в процессе работы алгоритмов обучения.

При M правилах вывода агрегирование выходного результата производится по формуле логического вывода Цукамото (2.8) для каждого j пикселя, которую можно представить в виде функции:

$$z_0 = \frac{\sum_{k=1}^M \min\left(\mu_{G_1^k}(s_1), \mu_{G_2^k}(s_2), \dots, \mu_{G_8^k}(s_8)\right) z^k}{\sum_{k=1}^M \min\left(\mu_{G_1^k}(s_1), \mu_{G_2^k}(s_2), \dots, \mu_{G_8^k}(s_8)\right)}, \quad (2.10)$$

где M – общее число правил, k – номер правила; $z_0(s_1, s_2 \dots s_8)$ – значение переменной вывода z_0 при известных значениях входных переменных $s_1, s_2 \dots s_8$, z^k определяется как решение уравнения:

$$\min\left(\mu_{G_1^k}(s_1), \mu_{G_2^k}(s_2) \dots \mu_{G_8^k}(s_8)\right) = \mu_R(z^k),$$

Формуле (2.10) можно сопоставить многослойную структуру сети, изображенную на рисунке 2.3. В такой сети выделяется 6 слоев.

- Первый слой нейросети выполняет фаззификацию каждого значения $s_i, i = \overline{1,8}$ и определяет для каждого k правила значения предпосылок $\mu_A^k(s_i), \mu_B^k(s_i), \mu_C^k(s_i)$. Это параметрический слой с параметрами a, b, c, d, e, f, g, h , которые подлежат адаптации в процессе обучения.

- Второй слой отвечает за агрегирование значений $s_i, i = \overline{1,8}$, определение результирующего значения $\alpha_k = \min\left(\mu_{G_1^k}(s_1), \mu_{G_2^k}(s_2) \dots \mu_{G_8^k}(s_8)\right)$, $k = \overline{1, N}$, который является уровнем активации k -го правила вывода. Это слой не является параметрическим.

- Третий слой определяет четкое значение выходной переменной z^k для каждого k -го правила по формуле $\alpha_k = \mu_R(z^k), R \in \{E, F\}$. Слой непараметрический.

- Четвертый слой реализует умножение значений z^k вывода k -го правила на значение α_k , сформированное в предыдущем слое: $\alpha_k z^k$. Слой непараметрический.

- Пятый слой состоит из двух нейронов – сумматоров, один из которых рассчитывает взвешенную сумму $\gamma_1 = \sum_{k=1}^M \alpha_k z^k$, а другой определяет сумму весов $\gamma_2 = \sum_{k=1}^M \alpha_k$. Слой непараметрический.

- Шестой слой является нормализующим слоем и состоит из единственного выходного нейрона, вычисляющего результат вывода z_0 по формуле: $z_0 = \frac{\gamma_1}{\gamma_2}$.

Слой непараметрический.

Количество нейронов в первом, втором, третьем и четвертом слоях равно количеству правил в базе. Из описания видно, что только первый слой является параметрическим и его параметры уточняются в процессе обучения.

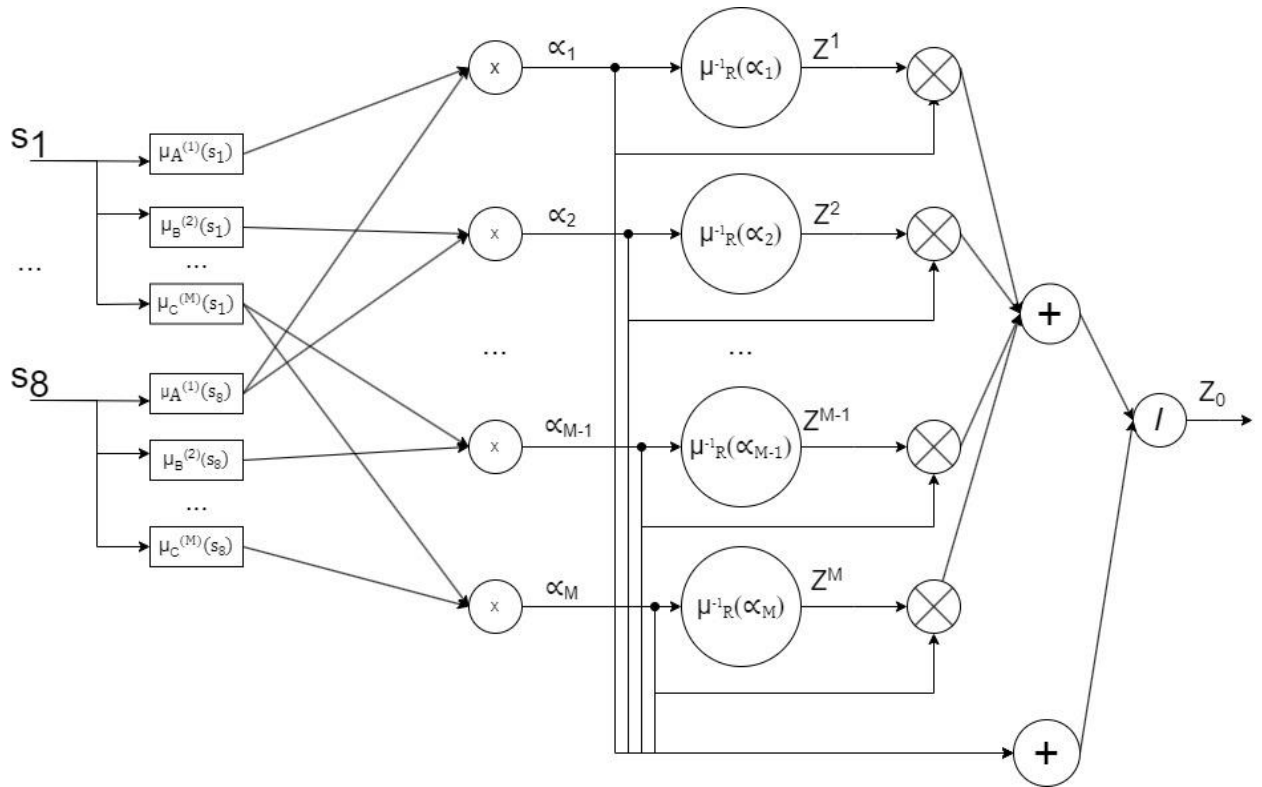


Рис. 2.3 – Структура нейронечеткой модели

2.4.2. Алгоритм обучения нейронечеткой сети

Для обучения нейронечеткой сети целесообразно использовать полутоновое изображение с визуально определяемыми четкими контурами и на его основе построить обучающую выборку для нейронечеткой сети, строящей зависимость значения признака контурности рассматриваемого пикселя от значений разностей яркости окружающих пикселей.

Предлагается следующий алгоритм построения набора данных для обучения (*Алгоритм 2.2*), состоящий из следующих шагов:

1. Формирование полутонового изображения из полноцветного.
2. Нанесение контуров на полутоновом изображении, которые

определяются визуально.

3. Последовательное рассмотрение фреймов из пикселей размером 3×3 (двигаясь по изображению слева направо и сверху вниз) и формирование множества: $\{(s_1^j, s_2^j, s_3^j, s_4^j, s_5^j, s_6^j, s_7^j, s_8^j, z^j), j = \overline{1, N}\}$, где j – номер рассматриваемого пикселя, $s_i^j, i = \overline{1, 8}$ – разности яркостей между i -ми пикселями, окружающими j – пиксель фрейма, и самого j – пикселя; $z^j = 1$, если пиксель является контурным; $z^j = 0$, в противном случае; N – количество фреймов.

Сформированная выборка данных будет использована при обучении и тестировании (контроле переобучения) нейронечеткой сети.

Задача определения оптимальных значений параметров нейронечеткой сети относится к сложной неформализованной задаче, поэтому для ее решения целесообразно использовать генетический алгоритм [92].

Генетический алгоритм для решения задачи оптимизации должен содержать следующие компоненты:

1. Генетическое представление потенциальных решений задачи.
2. Способ создания начальной популяции потенциальных решений.
3. Оценочную фитнес-функцию (функцию пригодности), которая ранжирует решения по степени их пригодности.
4. Генетические операторы, изменяющие генетический состав потомства (отбор, скрещивание, мутация).
5. Значения параметров генетического алгоритма (вероятности скрещивания и мутации, размер популяции, количество поколений).

В качестве критериев остановки выполнения алгоритма могут использоваться:

- Сформировано заданное число поколений.
- Популяция достигла заданного качества, которое оценивается с помощью фитнес-функции.
- Достигнут определенный уровень сходимости, что оценивается по

сходству строк в популяции.

Схема работы генетического алгоритма представлена на следующем рисунке:

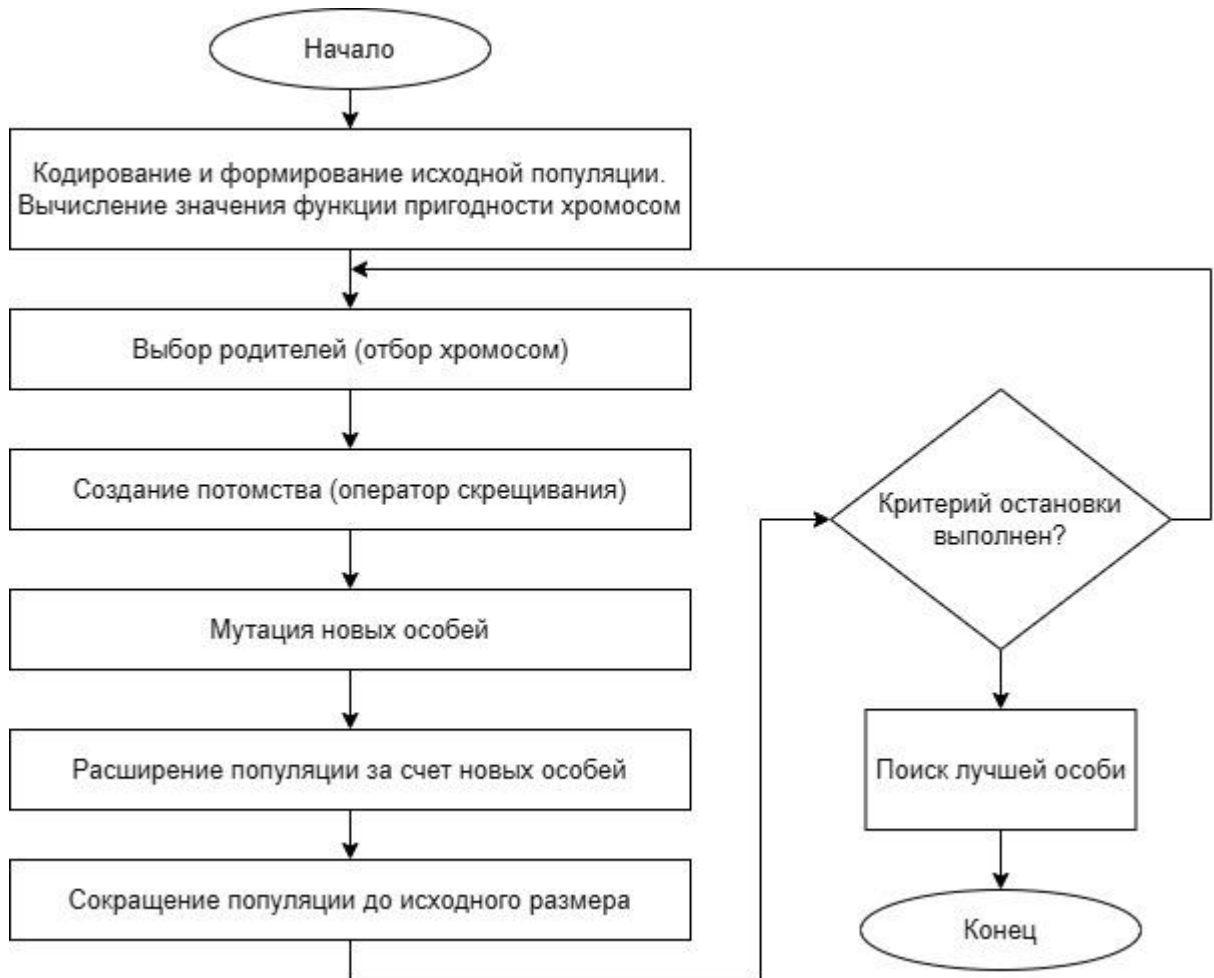


Рис. 2.4 – Схема работы генетического алгоритма

Основополагающим моментом генетического алгоритма является способ вычисления фитнес функции. Предлагается для ее вычисления использовать построенную ранее обучающую выборку.

Генетический алгоритм определения параметров функций принадлежности (*Алгоритм 2.3*) имеет следующий вид:

1. Этап кодирования.

Десятичные значения оптимизируемых параметров a, b, c, d, e, f, g, h кодируется бинарной строкой (хромосомой) длиной $\Omega = 8 \cdot 18 = 144$.

2. Формирование исходной популяции из 30 хромосом $\vartheta_i, i = \overline{1,30}$:

2.1. Создание хромосомы на основе генерации случайных чисел (0 или 1).

2.2. Получение десятичных значений параметров путем преобразования генотипа (кодированное значение) в фенотип (раскодированное значение).

2.3. Проверка одновременного выполнения условий, обеспечивающих взаимное расположение функций принадлежности нечетких множеств лингвистической переменной «Разность яркостей»: если $(a < b)$ и $(b > c)$ и $(c < d)$ и $(e < f)$ и $(f > g)$ и $(g < h)$ и $(d < 0)$ и $(e > 0)$, то соответствующая хромосома используется в популяции. В противном случае выполняется п.2.1.

3. Вычисление значения функции пригодности хромосом популяции.

3.1. Преобразование генотипа хромосомы ϑ_i в его фенотип.

3.2. Определение значения выходной переменной z_i^j с помощью нейронечеткой сети для каждого примера набора данных для обучения, полученного *Алгоритмом 2.2*.

3.3. Вычисление функции пригодности: $P(\vartheta_i) = -\sum_{j=1}^N (z_i^j - \tilde{z}_i^j)^2$, где z_i^j , \tilde{z}_i^j – значения выходной переменной, соответственно заданные в обучающем примере и вычисленные нейронечеткой моделью.

4. Формирование новой популяции на основе отбора, скрещивания и мутации хромосом с проверкой условия п.2.3.

5. Итерационное выполнение пунктов 3,4 до достижения сформированной популяции заданного качества.

2.5. Выводы

1. Для построения нейронечеткой модели выделения контурных точек изображения необходимо определить структуру, состав слоев нейронечеткой сети и обучить нейронечеткую сеть, оптимизировав ее параметры. В основе построения структуры и состава нейронечеткой сети лежат нечеткие продукционные правила и логический вывод, для построения которых требуется:

1.1. Определить совокупность лингвистических переменных и множество ее нечетких значений.

1.2. Определить вид нечетко-продукционных правил и алгоритм логического вывода.

1.3. Определить состав нечетко-продукционных правил и алгоритм принятия решения о контурности пикселя.

2. Входными лингвистическими переменными являются восемь переменных $\langle \text{Разность яркостей } s_k, \{A, B, C\}, S \rangle$, которые описывают разности яркостей в окрестностях пикселя, где терм-множество для всех лингвистических переменных состоит из следующих нечетких множеств:

- А - «Яркость пикселя из окрестности значительно меньше яркости L центрального пикселя»: $A = \{(s, \mu_A(s)); s \in [-1, 1]\}$;

- В - «Яркость пикселя из окрестности близка к яркости L центрального пикселя»: $B = \{(s, \mu_B(s)); s \in [-1, 1]\}$;

- С - «Яркость пикселя из окрестности значительно больше яркости L центрального пикселя»: $C = \{(s, \mu_C(s)); s \in [-1, 1]\}$.

Здесь $S = [-1, 1]$ – область определения лингвистических переменных, а $\mu_A(s), \mu_B(s), \mu_C(s)$ - трапециевидные функции принадлежности.

Выходной лингвистической переменной является переменная

$\langle \text{Признак контурности пикселя}, \{E, F\}, Z \rangle$, где терм-множество состоит из следующих нечетких множеств:

- Е – «Пиксель контурный»: $E = \{(z, \mu_E(z)); z \in [0, 1]\}$,

- F – «Пиксель не контурный»: $F = \{(z, \mu_F(z)); z \in [0, 1]\}$,

Здесь $Z = [0, 1]$ – область определения лингвистической переменной, а $\mu_E(z), \mu_F(z)$ – усеченные гауссовские функции принадлежности,

3. Поскольку принятие решения о контурности рассматриваемого пикселя зависит от разности яркостей между ним и восьмью пикселями, окружающими его, то база нечетких продукционных правил для выделения контурного пикселя примет следующий вид:

Если $s_1 = G_1 \& s_2 = G_2 \& s_3 = G_3 \& s_4 = G_4 \& s_5 = G_5 \& s_6 = G_6 \& s_7 = G_7 \& s_8 = G_8$, тогда $z = R$, где $G_i \in \{A, B, C\}$, $i = \overline{1, 8}$, $R \in \{E, F\}$.

4. Монотонный характер функций принадлежности для термов-множеств лингвистической переменной «Признак контурности пикселя» позволяет использовать алгоритм Цукомото и после этапа логического вывода определить четкое значение «Признака контурности пикселя».

5. Алгоритм построения множества нечетких продукционных правил основан на формировании и приведении в соответствие контуров объекта на бинарном и плутоновом изображениях, что позволяет избежать избыточности правил и необходимости дальнейшей редукции.

6. Структура нейронечеткой сети, аппроксимирующей зависимость значения признака принадлежности пикселя к контуру от 8 разностей яркостей между ним и его окружением, состоит из 6 слоев.

7. Для обучения нейронечеткой сети целесообразно использовать плутоновое изображение с визуально определяемыми четкими контурами и на его основе построить обучающую выборку для нейронечеткой сети.

8. Задача определения оптимальных значений параметров нейронечеткой сети относится к сложной неформализованной задаче, поэтому для ее решения целесообразно использовать генетический алгоритм.

9. Основопологающим моментом генетического алгоритма является способ вычисления фитнес функции. Для ее вычисления целесообразно использовать построенную ранее обучающую выборку.

ГЛАВА 3. МЕТОДЫ И АЛГОРИТМЫ РАЗРАБОТКИ НЕЙРОСЕТЕВОЙ МОДЕЛИ КЛАССИФИКАЦИИ КОНТУРА ОБЪЕКТА

Данная глава посвящена методу и алгоритму построения нейросетевой модели идентификации контура объекта на основе признаков (дескрипторов) его эталонного замкнутого контура. Для вычисления признаков используется быстрое преобразование Фурье и обосновывается необходимость модификации существующего метода. Предлагается алгоритм построения набора данных для обучения нейросетевой модели.

Под распознаванием и классификацией контура объекта понимается его идентификация и отнесение к соответствующему классу данных [67]. При решении данной задачи необходимо, прежде всего, выбрать метод определения наиболее характерных признаков, описывающих контур, а затем метод, позволяющий на основе этих признаков отнести контур к некоторому классу [27].

Для определения наиболее характерных признаков двумерного контура объекта на изображении целесообразно применять метод обработки данных на основе быстрого преобразования Фурье [93]. Данный метод позволяет трансформировать контур и привести его описание к виду, обеспечивающему независимость от первоначального расположения контура, его масштаба и угла разворота. В результате преобразования Фурье вычисляются наиболее характерные признаки контура, которые являются инвариантными относительно перемещения, поворота и масштабирования [87].

Нейронные сети прямого распространения с сигмоидальной функцией активации активно используются при решении задач классификации на основании тех или иных входных данных [94–113]. Поэтому рассматриваемую нейронную сеть можно использовать для классификации контуров объектов изображения, на вход которой подается вектор признаков, вычисленных с помощью быстрого преобразования Фурье.

3.1. Формирование признаков контура объекта на основе быстрого преобразования Фурье

В работах [87; 89] рассматривается применение быстрого преобразования Фурье для вычисления признаков (дескрипторов) контура объекта. Суть подхода заключается в следующем.

Пусть контур задан своими координатами контурных пикселей в двумерном пространстве. Координаты пикселей представляются комплексным числом: $z_i = x_i + jy_i, i = \overline{1, M}, j = \sqrt{-1}$, где M – число контурных пикселей.

Для обработки полученных данных применяется дискретное преобразование Фурье в виде [114]:

$$F_t = \sum_{i=0}^{n-1} z_{i+1} \exp\left(-j \frac{2\pi}{M} ti\right), t = \overline{0, M-1}. \quad (3.1)$$

Вектор $F = (F_0, F_1 \dots F_{M-1})$ определяет структуру контура в комплексном пространстве. По известным значениям вектора F можно восстановить координаты контура с помощью обратного преобразования Фурье:

$$z(i) = \frac{1}{M} \sum_{t=0}^{M-1} F_t \exp\left(j \frac{2\pi}{M} ti\right), i = \overline{0, M-1}. \quad (3.2)$$

Компонент F_0/M преобразования Фурье представляет собой среднее значение («центр тяжести») координат всех пикселей контура. Если приравнять $F_0 = 0$, то контур, соответствующий вектору F , переместится на некоторую стандартную позицию относительно системы координат, которая не зависит от его первоначального расположения. После этого преобразования вектор F имеет вид: $(0, F_1 \dots F_{M-1})$, который является инвариантным относительно смещения. $(0, F_1 \dots F_{M-1})$

Известно, что шумы носят высокочастотный характер. Отсечение компонент высшего порядка в векторе F вызывает уменьшение шума в контуре образа после его воспроизведения с помощью обратного преобразования Фурье. Согласно теории преобразования Фурье [114] наиболее значимыми при отображении структуры контура являются пары компонент F_1 и F_{M-1} , затем F_2 и F_{M-2} , затем F_3 и F_{M-3} и

так далее. В дальнейшем рассматривается вектор из K значимых пар:

$$(0, F_1, F_2 \dots F_K, F_{M-K}, \dots F_{M-2}, F_{M-1}).$$

Инвариантность относительно масштаба контура обеспечивается вычислением коэффициента масштабирования K_s [93; 115]:

$$K_s = \sqrt{|F_1|^2 + |F_{M-1}|^2} \quad (3.3)$$

А затем нормализацией всех компонент вектора $(0, F_1, F_2 \dots F_K, F_{M-K}, \dots F_{M-2}, F_{M-1})$: $F_{ks} = \frac{F_k}{K_s}$. После данного преобразования значения компонент вектора не зависят от размера контура.

Из теории известно, что пара F_1 и F_{M-1} при обратном преобразовании Фурье задает главный эллипс с наиболее длинной осью, пара F_2 и F_{M-2} и следующий по величине и так далее. Поворот контура относительно начальной позиции вызывает поворот оси главного эллипса. Поэтому для обеспечения инвариантности вектора признаков относительно угла поворота контура необходимо нормализовать положение оси главного эллипса. Коэффициент нормализации угла поворота определяется выражением [93; 115]:

$$K_r = \exp\left(-j \frac{\psi_{F_{1s}} + \psi_{F_{(M-1)s}}}{2}\right), \quad (3.4)$$

где $\psi_{F_{1s}}$ и $\psi_{F_{(M-1)s}}$ – аргументы комплексных чисел F_{1s} и $F_{(M-1)s}$.

Для обеспечения поворота контура относительно начальной позиции каждый компонент вектора $(0, F_{1s}, F_{2s} \dots F_{Ks}, F_{(M-K)s}, \dots F_{(M-2)s}, F_{(M-1)s})$ умножается на коэффициент:

$$K_r: F_{ksr} = F_{ks} K_r. \quad (3.5)$$

Следует отметить, что в соответствии с формулой (3.1) для вычисления каждого признака F_k используются координаты всех контурных пикселей. При умножении комплексных чисел аргументы складываются, тем самым осуществляется изменение аргументов вектора признаков на одну и ту же величину. Положение наибольшей оси главного эллипса нормализуется, контур, полученный с использованием обратного преобразования Фурье (3.2), повернется против часовой стрелки.

Очевидно, что если контур объекта имеет линию симметрии, то после трех последовательных нормализаций и обратного преобразования Фурье будем получать один и тот же контур. Тем самым для подобных контуров обеспечивается инвариантность признаков относительно поворота. Для произвольных несимметричных контуров после нормализации (3.3) положение наибольшей оси главного эллипса нормализуется, контур также повернется против часовой стрелки, но ввиду его несимметричности он будет приведен к одному из двух положений (рис. 3.1 – 3.4). Причем каждый контур двух нормализованных положений будет иметь свой вектор признаков.




Рис. 3.1 – Контур первого человека до поворота и его главный эллипс




Рис. 3.2 – Контур первого человека после поворота и его главный эллипс




Рис. 3.3 – Контур второго человека до поворота и его главный эллипс




Рис. 3.4 – Контур второго человека после поворота и его главный эллипс

3.2. Модифицированный алгоритм формирования признаков контура объекта

Модифицированный алгоритм формирования нормализованных дескрипторов эталонного контура, расположенного на изображении произвольно, на основе преобразования Фурье (*Алгоритм 3.1*) состоит из следующих шагов:

1. Представить координаты контурных точек замкнутого эталонного контура объекта в комплексном виде: $z_i = x_i + jy_i$, $i = \overline{1, M}$, $j = \sqrt{-1}$, где M – количество точек, описывающих контур. За первую контурную точку взять самую левую верхнюю точку контура.

2. Определить множество признаков-дескрипторов контура объекта $\tilde{F} = (\tilde{F}_0, \dots, \tilde{F}_{M-1})$, используя дискретное преобразование Фурье: $\tilde{F}_t = \sum_{i=0}^{M-1} z_{i+1} \exp(-j \frac{2\pi}{M} ti)$, $t = \overline{0, M-1}$. (3.6)

3. Приравнять значение компоненты $\tilde{F}_0 = 0$, тем самым перенося центр масс контура в начало координат.

4. Нормализовать вектор \tilde{F} , обеспечивая инвариантность признаков относительно размера контура: $\tilde{F} = \frac{\tilde{F}}{\sqrt{|\tilde{F}_1|^2 + |\tilde{F}_{M-1}|^2}}$. (3.7)

5. Умножить вектор \tilde{F} на коэффициент $K = \exp(-j \frac{\psi_{\tilde{F}_1} + \psi_{\tilde{F}_{M-1}}}{2})$, где $\psi_{\tilde{F}_1}$ и $\psi_{\tilde{F}_{M-1}}$ – аргументы комплексных чисел \tilde{F}_1 и \tilde{F}_{M-1} : $F = K\tilde{F}$, обеспечивая поворот

исходного контура в одно из двух базовых направлений в зависимости от ориентации контура.

6. Произвести обратное преобразование Фурье для вектора F и получить множество координат последовательно связанных точек контура:

$$z_t = \frac{1}{M} \sum_{i=0}^{n-1} F_t \exp\left(j \frac{2\pi}{M} ti\right), t = \overline{0, M-1}. \quad (3.8)$$

7. Среди полученного множества координат найти координаты самой верхней левой точки контура z^* и упорядочить множество координат так, чтобы координаты точки z^* оказались первыми, тем самым получить множество координат A_1 .

8. Сформировать вектор дескрипторов F для множества координат A_1 в соответствии с этапами 1-5 алгоритма.

9. Сформировать вектор информативных признаков эталонного контура

$$B_1 = \{F_{1a}, F_{1b}, \dots, F_{Kb}, F_{M-Ka}, \dots, F_{M-1a}, F_{M-1b}\}$$

для множества координат A_1 , где F_{ia}, F_{ib} - действительная и мнимая часть дескриптора F_i

10. На основании множества A_1 координат точек эталонного контура сформировать множество A_2 с помощью преобразования координат, обеспечивающих поворот эталонного контура на угол $\varphi = 180^\circ$: $x' = x \cos \varphi + y \sin \varphi$, $y' = -x \sin \varphi + y \cos \varphi$ или $x' = -x$, $y' = -y$.

11. Сформировать вектор дескрипторов F' для множества координат A_2 в соответствии с этапами 1-5 алгоритма.

12. Сформировать вектор информативных признаков эталонного контура $B_2 = \{F_{1a}, F_{1b}, \dots, F_{Kb}, F_{M-Ka}, \dots, F_{M-1a}, F_{M-1b}\}$ для множества координат A_2 .

В результате работы вышеописанного алгоритма будут получены вектор признаков B_1 и B_2 , которые используются при формировании набора данных для обучения нейросетевого классификатора, и обеспечивают способность нейросети распознавать эталонный контур независимо от смещения, угла поворота или масштаба.

Количество значимых дескрипторов K выбирается таким образом, чтобы

близость контура, описываемого полным набором дескрипторов и контура, описываемого количеством $2 \times K$ дескрипторов соответствовала заданному значению:

$$\delta = \frac{\sum_{i=0}^{M-1} \sqrt{(\tilde{x}_i - x_i)^2 + (\tilde{y}_i - y_i)^2}}{M} \quad (3.9)$$

где \tilde{x}_i, \tilde{y}_i - координаты i -го пикселя контура, полученного после обратного преобразования Фурье с использованием ограниченного множества $2 \times K$ нормализованных дескрипторов,

x_i, y_i - координаты i -го пикселя эталонного контура, полученного после обратного преобразования Фурье с использованием всех нормализованных дескрипторов.

3.3. Алгоритм формирования набора данных для обучения нейросетевого классификатора

При вычислении признаков контура с помощью преобразования Фурье используются все его координаты. Пропуск даже одного пикселя в разных местах контура приведет к отклонению результирующих нормализованных признаков и, как следствие, к снижению качества распознавания и классификации. Поэтому будем строить нейросетевую модель классификации контура объекта, не имеющего разрывы и имеющего инвариантные признаки относительно перемещения, масштабирования и поворота [116–123].

Непрерывный нормализованный контур, для распознавания которого будем строить нейросетевую модель, в дальнейшем будем называть эталонным контуром. Поскольку нейронная сеть должна распознавать класс «эталонный контур», то на ее вход должны подаваться действительные и мнимые части $2 \times K$ дескрипторов, а выход состоит из одного нейрона, вычисляющего степень близости выделенного контура на изображении к эталонному. Поэтому каждый пример набора данных для обучения состоит из $4 \times K + 1$ элемента. Поскольку в связи с зашумленностью изображений сложно выделить на нем контур, соответствующий в точности эталонному, то набор данных для обучения должен содержать кроме признаков дескрипторов эталонного контура и развернутого на 180 градусов, дополнительно

признаки зашумленных контуров.

Алгоритм формирования обучающего множества для построения нейросетевой модели распознавания эталонного контура (**Алгоритм 3.2**) заключается в следующем:

1. Сформировать множество S контуров, похожих на эталонный двух направлений. Для этого на координаты каждой точки $(x_i, y_i), i = \overline{1, M}$ из A_1 и A_2 , соответствующих эталонным контурам противоположных направлений, наложить случайное отклонение из интервала $[-q, q]$:

$$(x_i^j, y_i^j) = (x_i + (-q + 2 * rand(q)), y_i + (-q + 2 * rand(q))), \quad (3.10)$$

где $rand(q)$ – функция, возвращающее случайное целое число в диапазоне $[0, q]$, j -номер контура в множестве S . Значение q задается в зависимости от размера контура.

2. Добавить в получившееся множество S контуры, не похожие на эталон, для формирования класса «не эталонный контур». В качестве контуров могут быть рассмотрены контуры, не совпадающие с контурами входящими во множество S .

3. Сформировать множество векторов признаков C_f для каждого контура из множества S , используя п.1-5 модифицированного алгоритма формирования нормализованных дескрипторов контура (Алгоритма 4).

4. Сформировать обучающее множество $D = \{(D_f, Y)\}$, где $D_f \in B_1 \cup B_2 \cup C_f$, а значение $Y = \{0, 1\}$, описывает непринадлежность (0) или принадлежность (1) контура, описываемого соответствующим вектором признаков D_f к классу “эталонный контур”.

В результате каждый элемент из обучающего множества D будет иметь следующий вид:

$$(D_f^j, Y^j) = \{F_{1a}^j, F_{1b}^j, \dots, F_{Kb}^j, F_{M-Ka}^j, \dots, F_{M-1a}^j, F_{M-1b}^j, Y^j\}, \quad (3.11)$$

где F_{ia}^j, F_{ib}^j - действительная и мнимая части i -го признака дескриптора, описывающего j -ый контур множеств S, B_1, B_2 .

3.4. Нейросетевая модель классификатора контура, выделенного на изображении

Одной из важных задач, возникающих при построении нейросетевой модели классификатора, является определение структуры сети, обеспечивающей наилучшие обобщающие (аппроксимирующие) способности [115]. Для этого обычно применяются два подхода – конструктивный и деструктивный. При конструктивном подходе подбор структуры начинается с минимального размера и затем увеличивается до достижения необходимой точности. При деструктивном подходе наоборот, изначально берут структуру завышенного размера, а затем удаляют нейроны и связи, имеющие наименьшее влияние. Для простой аппроксимирующей зависимости целесообразно использовать один или два скрытых слоя.

На входной слой классификатора подаются признаки выделенных на изображении контуров, в качестве которых используются действительные и мнимые части признаков этих контуров, полученных при помощи выражения (3.11). Выход нейронной сети состоит из одного нейрона, вычисляющего значение от 0 до 1 в качестве степени близости выделенного на изображении контура к эталонному.

В результате нейросетевая модель классификатора состоит из следующих слоев:

- Входными переменными нейронной сети являются признаки $\{F_{1a}, F_{1b}, \dots, F_{Ka}, F_{M-Ka}, \dots, F_{M-1a}, F_{M-1b}\}$, их количество равняется значению $K*4$.
- Выходная переменная Y нейронной сети описывает степень соответствия контура, описываемого входным вектором признаков, эталонному.
- Число скрытых слоев и нейронов в скрытых слоях таково, что количество образованных ими связей меньше числа обучающих примеров в три раза.

Для обучения предложенной нейросетевой модели предлагается использовать метод обратного распространения ошибки [124; 125]. Данный метод используется для обновления весов с целью минимизации ошибки работы нейронной сети и получения желаемого выхода.

3.5. Выводы

1. Для обработки координат пикселей, представленных в комплексном виде, применяется дискретное преобразование Фурье: $F_t = \sum_{i=0}^{n-1} z_{i+1} \exp\left(-j \frac{2\pi}{M} ti\right)$, $t = \overline{0, M-1}$.

2. Компонент F_0/M преобразования Фурье представляет собой среднее значение («центр тяжести») координат всех пикселей контура, и если приравнять значение $F_0 = 0$, то контур, описываемый данным вектором, переместится в начало координат.

3. В работе [87] показано, что отсечение компонент высшего порядка в векторе F вызывает уменьшение шума в контуре, воспроизведенном при помощи обратного преобразования Фурье. Рекомендация по подбору порога отсечения компонент вектора основана на визуальном анализе контура, полученного при помощи обратного преобразования Фурье с урезанным набором компонент.

4. Нормализация $F_{ks} = \frac{F_k}{K_s}$ при помощи коэффициента $K_s = \sqrt{|F_1|^2 + |F_{M-1}|^2}$ обеспечивает инвариантность признаков контура относительно размера.

Пара признаков F_1 и F_{M-1} при обратном преобразовании Фурье задает главный эллипс, а его поворот вызывает поворот контура относительно начальной позиции. Нормализация признаков $F_{ksr} = F_{ks} K_r$ при помощи коэффициента $K_r = \exp\left(-j \frac{\psi_{F_{1s}} + \psi_{F_{(M-1)s}}}{2}\right)$ обеспечивает поворот контура.

Для произвольных несимметричных контуров после нормализации относительно угла поворота положение наибольшей оси главного эллипса нормализуется, контур также повернется против часовой стрелки к одному из двух возможных направлений.

5. Модификация алгоритма формирования признаков, представленного в [87], заключается в формировании вектора признаков для самого

нормализованного контура, называемого эталоном, и его зеркального отражения, то есть для эталонного контура, повернутого на 180 градусов.

6. Нейросетевая модель классификации строится для распознавания контура объекта, не имеющего разрывов. Предложена структура нейросетевой модели и метод формирования набора данных для обучения.

ГЛАВА 4. МЕТОДИЧЕСКОЕ И ПРОГРАММНОЕ ОБЕСПЕЧЕНИЕ РАСПОЗНАВАНИЯ ОБЪЕКТА С ЗАДАНЫМ КОНТУРОМ НА ИЗОБРАЖЕНИИ

В данной главе описывается методика выделения и распознавания эталонного контура на изображении на основе разработанных методов и алгоритмов, а также разработанный комплекс программ по автоматизированной обработке изображения на основе нейронечеткого и нейросетевого моделирования, реализующий разработанную методику. Приведены результаты экспериментальных исследований.

4.1. Методика выделения и распознавания эталонного контура на изображении

Для поиска объекта на изображении с эталонным (заданным) контуром предлагается методика, состоящая из двух этапов.

На первом этапе (рис. 4.1) осуществляется разработка нейронечеткой модели принятия решения о контурности пикселя изображения, нейросетевого классификатора на основе построения и использования признаков – дескрипторов Фурье. Целью и результатом работы данного этапа является формирование и пополнение баз данных эталонных контуров, нейронечетких моделей выделения контурных пикселей, а также нейросетевых классификаторов [116].

Использование разработанного математического и алгоритмического обеспечения для разных эталонных контуров позволит сформировать базы данных эталонных контуров, нечетких нейронных моделей и нейросетевых классификаторов.

База изображений содержит изображения, слабо зашумленные с определенным распределением яркостей пикселей, позволяющим выделить контуры объектов, используемые для построения нейронечеткой модели. Выбор подобных изображений осуществляется на основе визуального анализа.

После выбора изображения из базы данных осуществляется перевод яркости изображения из цветного в нормализованные оттенки серого с целью сокращения сложности нейронечеткой модели с использованием формулы (2.2).

На сформированном изображении выделяется непрерывный контур объекта, используемого в дальнейшем для наполнения баз данных нейронечетких моделей и нейросетевых классификаторов. При этом выделение контура осуществляется следующим образом. Для сформированного изображения в оттенках серого строится тем или иным методом бинарное изображение, на котором выделяются пиксели, являющиеся контурными для заданного объекта. Если контур не является замкнутым, то пропущенные пиксели доопределяются как контурные вручную. Сформированный непрерывный контур в виде совокупности координат пикселей сохраняется в Базе эталонных контуров.

На основе нормализованных яркостей пикселей изображения в оттенках серого и информации о контурных пикселях с помощью *Алгоритма 2.1-2.3* строится нейронечеткая модель принятия решения о принадлежности пикселя к контуру, которая сохраняется в Базе данных нечетких нейронных (НН) моделей.

Для формирования и пополнения Базы нейросетевых классификаторов данных осуществляется построение вектора признаков-дескрипторов для необходимого эталонного контура из Базы эталонных контуров. Построение вектора признаков-дескрипторов выполняется с помощью *Алгоритма 3.1* на основе быстрого преобразования Фурье.

Разработка нейросетевой модели распознавания эталонного контура на изображении выполняется с использованием *Алгоритма 3.2*. Результат построения сохраняется в Базе нейросетевых классификаторов.

На втором этапе (рис. 4.2) осуществляется выделение контуров на изображении и распознавание необходимого эталонного контура с использованием Базы нечетких нейронных моделей и Базы нейросетевых классификаторов, сформированных на первом этапе. Целью и результатом работы данного этапа является выделение и распознавание заданного объекта на произвольном изображении.



Рис. 4.1 – Схема последовательности формирования Баз: эталонных контуров, нейронечетких (НН) моделей, нейросетевых классификаторов

Получив произвольное изображение, осуществляется его перевод в нормализованные оттенки серого с использованием формулы (2.2) и дальнейшей нормализацией.

Подключая модель из Базы нечетких нейронных моделей, осуществляется выделение контурных точек рассматриваемого изображения, тем самым формируется его бинарный вид.

Использование алгоритма трассировки окрестностей Мура позволяет выделять отдельные контуры без разрывов на бинарном изображении. Алгоритм состоит из следующих шагов:

- Поиск первой контурной точки;
- Обход окрестности найденной контурной точки в поиске новой;
- Повторение предыдущего пункта до достижения стартовой точки.

Для каждого выделенного контура формируется вектор признаков-дескрипторов с помощью *Алгоритма 3.1*, который подается на вход моделей из Базы нейросетевых классификаторов, позволяющих отнести вектор признаков к признакам того или иного контура. Выбор вида контура позволяет распознать объект на изображении.



Рис. 4.2 – Схема последовательности использования Баз: нейронечетких моделей и нейросетевых классификаторов для распознавания объекта на изображении

4.2. Описание комплекса программ

Для разработки программного комплекса использовался Matlab [114]. Комплекс состоит из следующих модулей:

- Модуль построения базы нечетких правил;
- Модуль формирования набора данных для обучения нейронечеткой модели выделения контурных точек;
- Модуль генетической оптимизации параметров нейронечеткой модели выделения контурных точек;

- Модуль формирования признаков-дескрипторов выделенных контуров;
- Модуль построения набора данных для обучения нейросетевой модели классификатора;
- Модуль обучения нейросетевой модели классификатора;
- Модуль выделения контуров на изображении и их классификации.

Рассмотрим программные модули и соответствующие им функциональные задачи (см. табл. 4.1) [126].

Таблица 4.1 – Модули программного комплекса и соответствующие им функциональные задачи

Название программного модуля	Функциональные задачи программного модуля
Модуль построения структуры нейронечеткой модели	-загрузка изображения -бинаризация введённого изображения -формирование базы нечетких правил, определяющих состав и взаимосвязь слоев нейронечеткой модели
Модуль формирования набора данных для обучения нейронечеткой модели выделения контурных точек	-загрузка изображения -формирование полутонового изображения из исходного -формирование/загрузка контурного изображения -формирование состава набора данных
Модуль генетической оптимизации параметров нейронечеткой модели выделения контурных точек	-формирование исходной популяции -оптимизация значений параметров функций принадлежности нейронечеткой модели -тестирование значений параметров функций принадлежности, полученных в результате оптимизации
Модуль формирования признаков-дескрипторов выделенных контуров;	-загрузка координат контуров -вычисление и нормализация признаков контуров на основе быстрого преобразования Фурье
Модуль построения набора данных для обучения нейросетевой модели классификатора	-загрузка координат контуров -формирование контуров, похожих на контур искомого объекта путем наложения шумовой составляющей

	-формирования набора контуров отличающихся от искомого -вычисление и нормализация признаков контуров на основе быстрого преобразования Фурье
Модуль обучения нейросетевой модели классификатора	-загрузка выборки данных для обучения -обучение и тестирование нейросетевой модели
Модуль выделения и классификации контуров на изображении	-загрузка изображения -выделение контуров с использованием нейронечеткой модели -формирование векторов признаков выделенных контуров -нейросетевая классификация признаков выделенных контуров

Все расчеты проводились на компьютере с 6-ядерным процессором AMD Ryzen 5 3600 с частотой 3.60 ГГц, оперативной памятью 32 Гб, 64-разрядной MS Windows 10.

4.3. Результаты экспериментальных исследований

Разработанные методы и алгоритмы были применены для:

1. Выделения эталонного контура лежащего на снегу человека на изображении (рис. 4.3).
2. Разработки нейронечеткой модели выделения контурных точек на основе этого изображения.
3. Определения вектора признаков-дескрипторов эталонного контура человека.
4. Разработки нейросетевой модели классификатора эталонного контура человека.

4.3.1. Выделение эталонного контура лежащего на снегу человека на изображении

На рис. 4.3 представлен фрагмент изображения (461x343 пикселей) с лежащим на снегу человеком для выделения контура человека, его нормализации и дальнейшего использования в качестве эталонного. Изображение, которое использовалось для построения множества нечетких правил, содержит 1600x1194 пикселей.

На рис. 4.4.а) представлен увеличенный фрагмент изображения (237x175 пикселей) в оттенках серого, содержащий образ лежащего на снегу человека. На рис.4.4б) представлен замкнутый, без пропуска пикселей эталонный контур, лежащего на снегу человек в бинарном отображении.



Рис. 4.3 – Фрагмент изображения, использованное для формирования базы правил



Рис. 4.4 – Увеличенный фрагмент изображения в оттенках серого (а), содержащий образ лежащего на снегу человека, выделенный эталонный контур на бинарном изображении (b), замкнутый, без пропуска пикселей.

4.3.2. Разработка нейронечеткой модели выделения контурных точек на основе этого изображения.

Применив *Алгоритм 2.1* к изображению, представленному на рис. 4.3 была получена база правил, состоящая из 511 правил. В таблице 4.2 представлен фрагмент базы знаний. В таблице использовались следующие обозначения:

1. s_1, \dots, s_8 – лингвистические переменные «Разность яркостей пикселя и окружающих его», со значением 1, если яркость окружающего пикселя больше яркости самого пикселя, 0 если яркости приблизительно равны и -1 если яркость окружающего пикселя меньше яркости самого пикселя.

2. z - признак принадлежности рассматриваемого пикселя к контуру

Таблица 4.2 – Фрагмент базы правил

№ правила	s_1	s_2	s_3	s_4	s_5	s_6	s_7	s_8	z
1	0	0	0	0	0	0	0	0	1
2	0	0	0	0	0	1	0	0	1
3	-1	-1	-1	-1	-1	-1	-1	-1	0
...									
510	0	-1	0	-1	0	-1	-1	0	0
511	0	-1	0	-1	0	-1	0	-1	0

В результате применения *Алгоритмов 2.2 и 2.3* была сформирована нейро-нечеткая модель (рис. 4.5) с параметрами функций принадлежности: $a = -0.559$, $b = -0.431$, $c = -0.487$, $d = -0.019$, $e = 0.165$, $f = 0.949$, $g = 0.173$, $h = 0.956$:

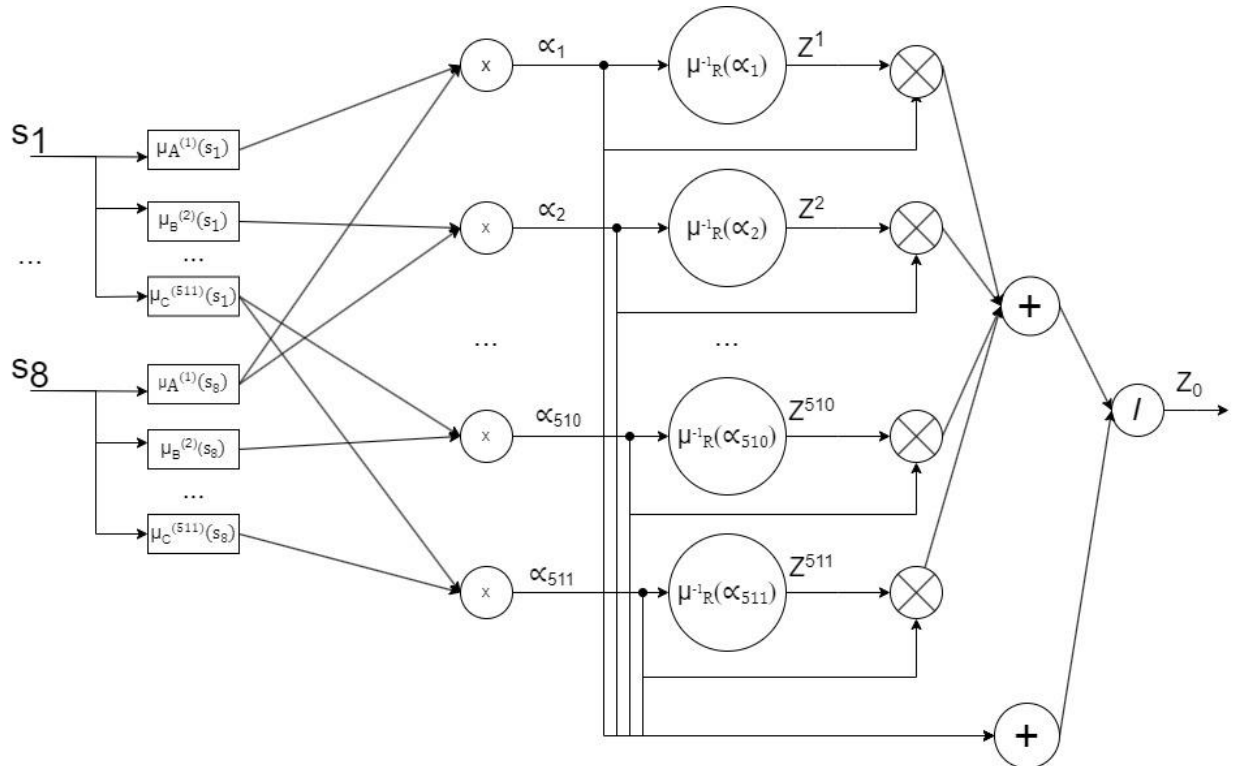


Рис. 4.5 – Структура нейро-нечеткой модели

4.3.3. Определение вектора признаков-дескрипторов эталонного контура человека.

Контур лежащего на снегу человека состоит из 77 связанных пикселей. В таблице 4.3 приведены результаты влияния состава множества нормализованных признаков на среднее отклонение δ контура, полученного после обратного преобразования Фурье, от эталонного, которое вычисляется по следующей формуле:

$$\delta = \frac{\sum_{i=0}^{M-1} \sqrt{(\tilde{x}_i - x_i)^2 + (\tilde{y}_i - y_i)^2}}{M}, \quad (4.1)$$

где \tilde{x}_i, \tilde{y}_i - координаты i -го пикселя контура, полученного после обратного преобразования Фурье с использованием ограниченного множества нормализованных признаков, x_i, y_i - координаты i -го пикселя эталонного контура, полученного после обратного преобразования Фурье с использованием всех 77 нормализованных дескрипторов [116].

Задав величину 0,5 в качестве граничного значения для δ , видно, что среднее отклонение $\delta < 0.5$ достигается уже на множестве $F_1, \dots, F_8, F_{70}, \dots, F_{77}$, поэтому достаточно 16 дескрипторов для получения контура, близкого к эталонному. На рисунке 4.7 продемонстрирован результат воспроизведения контура человека с использованием только 16 нормализованных дескрипторов [116]. Как видно на изображении, полученный контур нормализовался и имеет сглаженный вид. Таким образом использование в качестве признаков усеченного набора дескрипторов позволяет сгладить шумовые отклонения.

Таблица 4.3 – Результаты влияния состава множества нормализованных дескрипторов

Состав множества нормализованных дескрипторов	Среднее отклонение δ контура, полученного после обратного преобразования Фурье, от эталонного
F_1, F_{77}	2.7226
F_1, F_2, F_{76}, F_{77}	2.5458
$F_1, F_2, F_3, F_{75}, F_{76}, F_{77}$	1.9105
...	...
$F_1, \dots, F_7, F_{71}, \dots, F_{77}$	0.5054
$F_1, \dots, F_8, F_{70}, \dots, F_{77}$	0.4947
$F_1, \dots, F_9, F_{69}, \dots, F_{77}$	0.3304

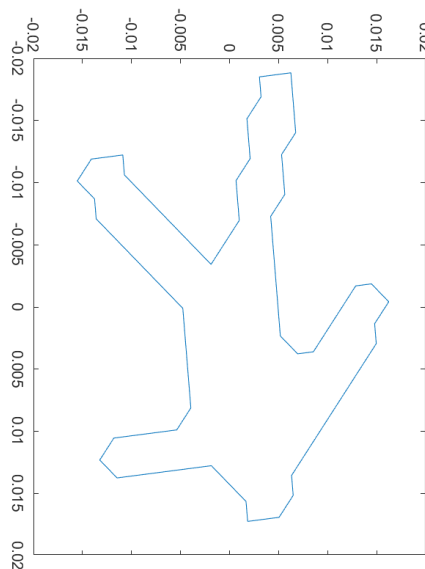


Рис. 4.6 – Вид контура человека, воспроизведенного с использованием всех нормализованных дескрипторов.




Рис. 4.7 – Вид контура человека, воспроизведенного с использованием 16 нормализованных дескрипторов.

4.3.4. Разработка нейросетевой модели классификатора эталонного контура человека

Для построения нейросетевого классификатора в соответствии с *Алгоритмами 3.1 и 3.2* был сформирован набор данных для обучения, состоящий из 902 векторов. Каждый вектор содержит 32 признака либо:

- эталонного контура;
- 200 контуров, близких к эталону;
- эталонного контура, повернутого на 180 градусов;
- 200 контуров, близких к повернутому эталонному контуру;

Для отнесения вектора признаков контура к не эталонному в набор данных для обучения были добавлены признаки 500 контуров, отличающихся от эталонного и повернутого эталонного контуров. Признаки были добавлены следующим образом: на изображении, представленном на рис. 4.3 были выделены контуры, среди всех контуров, кроме контура человека было случайным образом выбрано 500 контур, из которых в дальнейшем были получены признаки [127].

Кроме 32 признаков вектор набора данных для обучения содержит признак Y близости рассматриваемого контура к эталонному 0 (не эталонный контур) или 1 (эталонный контур).

Обучение проводилось с помощью метода Левенберга — Марквардта. Для обучения использовалось 80% выборки, для тестирования 20%, точность обучения составила около 0.1%, точность тестирования составила 1,06%.

Разработанный нейросетевой классификатор (рис. 4.8, 4.9) состоит из:

- 32 входных нейронов, которые являются действительными и мнимыми частями 16 дескрипторов;
- Одного скрытого слоя из 10 нейронов
- Одного выходного нейрона, отражающего степень близости рассматриваемого контура к эталонному.




Рис. 4.8 – Структура нейросетевой модели




Рис. 4.9 – Архитектура нейросетевого классификатора, полученная в среде Matlab

4.4. Показатели точности и качества применения комплекса построенных моделей

Для оценки адекватности разработанных моделей они были применены для выделения и распознавания контуров на изображении 4.3. В результате выделения нейронечеткой моделью контурных точек и работы алгоритма отслеживания замкнутых контуров было получено 2634 контура. После формирования векторов признаков-дескрипторов Фурье и их классификации было классифицировано 103 контура как эталонный контур. Результаты проведенных исследований приведены в таблице 4.3.

Таблица 4.3 – Результаты проведенных исследований на изображении 4.3

Количество выделенных на изображении контуров	Количество правильно распознанных эталонных контуров	Количество не эталонных контуров, распознанных как эталон (ошибка 2 рода)	Количество эталонных контуров, распознанных как не эталон (ошибка 1 рода)	Количество правильно распознанных не эталонных контуров
2634	1(100%)	102(3,9%)	0(0%)	2531(96,1%)

Из таблицы видно, что ошибка второго рода составила 3,9%, ошибка первого рода составила 0%.

Для оценки точности разработанных моделей традиционно рассматриваются общие показатели успеха и ошибки. Общий показатель успеха (overall success rate) – это отношение числа правильно классифицированных контуров к общему количеству контуров:

$$OSR = \frac{2532}{2634} = 0,96 \text{ (96\%).}$$

Общий показатель ошибки (overall error rate) – это отношение числа неправильно классифицированных контуров к общему количеству контуров:

$$OER = \frac{102}{2634} = 0,039 \text{ (3,9\%).}$$

Для оценки эффективности моделей рассматриваются показатели чувствительности и специфичности. Чувствительность S_e - число правильно распознанных эталонных контуров, отнесенных к общему числу таких контуров:

$$S_e = \frac{1}{1} = 1(100\%).$$

Специфичность определяется как отношение число не эталонных контуров, распознанных как не эталон, к общему числу не эталонных контуров:

$$S_p = \frac{2531}{2633} = 0,961(96,1\%).$$

Также модель была применена для распознавания контуров на изображении 4.10. В результате выделения нейронечеткой моделью контурных точек и работы алгоритма отслеживания замкнутых контуров было получено 875 контура. После формирования векторов признаков-дескрипторов Фурье и их классификации было классифицировано 19 контура как эталонный контур. Результаты проведенных исследований приведены в таблице 4.3. Для изображения были получены следующие показатели (Общий показатель успеха, Общий показатель ошибки, Чувствительность, Специфичность):

$$OSR = \frac{858}{875} = 0,98 \text{ (98\%)}.$$

$$OER = \frac{17}{875} = 0,02 \text{ (2\%)}.$$

$$S_e = \frac{2}{2} = 1 \text{ (100\%)}.$$

$$S_p = \frac{856}{873} = 0,98 \text{ (98\%)}.$$



Рис. 4.10 – Фрагмент тестируемого изображения.

Таблица 4.3 – Результаты проведенных исследований на изображении 4.10

Количество выделенных на изображении контуров	Количество правильно распознанных эталонных контуров	Количество не эталонных контуров, распознанных как эталон (ошибка 2 рода)	Количество эталонных контуров, распознанных как не эталон (ошибка 1 рода)	Количество правильно распознанных не эталонных контуров
875	2(100%)	17(1,9%)	0(0%)	856(97,8%)

4.5. Сравнительный анализ работы нейронечеткой модели выделения контурных точек и метода Кэнни

Для сравнения эффективности нейронечеткой модели выделения контурного пикселя был выбран наиболее часто используемый исследователями метод Кэнни. Для применения метода Кэнни необходимо задать параметр – порог фильтрации, который существенно влияет на результат выделения контуров на изображении. Для получения замкнутого контура возникает задача подбора порога фильтрации.

В таблице 4.4 приведены результаты выделения контуров на изображении (рис. 4.3) и распознавания эталонного контура с помощью этапа 2 разработанной в диссертации методики, в которой контурные точки определяются не нейронечеткой моделью, а методом Кэнни при различных значениях параметров (от 0.01 до 0.5).

Таблица 4.4 – Результаты выделения и распознавания с использованием фильтра Кэнни

Порог фильтра Кэнни	Количество выделенных на изображении контуров	Количество правильно распознанных эталонных контуров	Количество не эталонных контуров, распознанных как эталон	Количество эталонных контуров, распознанных как не эталон	Количество правильно распознанных не эталонных контуров

			(ошибка 2 рода)	(ошибка 1 рода)	
0,01	6917	1(100%)	470(6,8%)	0(0%)	6446(93,2%)
0,02	6931	1(100%)	471(6,8%)	0(0%)	6459(93,2%)
0,03	6913	1(100%)	472(6,8%)	0(0%)	6440(93,2%)
...	
0,29	3602	1(100%)	217(6,0%)	0(0%)	3384(94,0%)
0,30	3488	0(0%)	237(6,8%)	1(100%)	3251(93,2%)
0,31	3312	0(0%)	218(6,6%)	1(100%)	3094(93,4%)
0,32	3226	0(0%)	222(6,9%)	1(100%)	3004(93,1%)
0,33	3090	0(0%)	233(7,5%)	1(100%)	2857(92,5%)
0,34	2941	0(0%)	203(6,9%)	1(100%)	2738(93,1%)
0,35	2865	0(0%)	185(6,5%)	1(100%)	2680(93,6%)
0,36	2804	0(0%)	211(7,5%)	1(100%)	2593(92,5%)
0,37	2698	1(100%)	176(6,5%)	0(0%)	2521(93,5%)
...
0,48	1667	1(100%)	88(5,3%)	0(0%)	1578(94,7%)
0,49	1604	1(100%)	82(5,1%)	0(0%)	1521(94,9%)
0,50	1498	1(100%)	85(5,7%)	0(0%)	1412(94,3%)

Из таблицы видно, что ошибка второго рода составила от 5 до 7%, при этом при параметрах от 0.3 до 0.36 эталонный контур (контур человека) не был распознан, а значит при данных значениях параметра ошибка первого рода составила 100%. По полученным данным были рассчитаны: общий показатель успеха, общий показатель ошибки, чувствительность и специфичность, представленные в таблице 4.5. Средний показатель успеха составил 93,2%, а ошибки 6,8% соответственно. При этом лучший результат был получен при значении порога равном 0,49: Общий показатель успеха (OSR) = 0,949 (94,9%). Общий показатель ошибки (OER) = 0,051 (5,1%).

Таблица 4.5 – Результаты выделения и распознавания с использованием фильтра Кэнни

Порог фильтра Кэнни	Общий показатель успеха (OSR)	Общий показатель ошибки (OER)	Чувствительность (S_e)	Специфичность (S_p)
0,01	0,932 (93,2%)	0,068 (6,8%)	1 (100%)	0,932 (93,2%)
0,02	0,932 (93,2%)	0,068 (6,8%)	1 (100%)	0,932 (93,2%)
0,03	0,932 (93,2%)	0,068 (6,8%)	1 (100%)	0,932 (93,2%)
...
0,29	0,940 (94%)	0,060 (6%)	1 (100%)	0,940 (94%)
0,30	0,932 (93,2%)	0,068 (6,8%)	0 (0%)	0,932 (93,2%)
0,31	0,934 (93,4%)	0,066 (6,6%)	0 (0%)	0,934 (93,4%)
0,32	0,931 (93,1%)	0,069 (6,9%)	0 (0%)	0,931 (93,1%)
0,33	0,925 (92,5%)	0,076 (7,6%)	0 (0%)	0,925 (92,5%)
0,34	0,931 (93,1%)	0,069 (6,9%)	0 (0%)	0,931 (93,1%)
0,35	0,935 (93,5%)	0,065 (6,5%)	0 (0%)	0,935 (93,5%)
0,36	0,925 (92,5%)	0,076 (7,6%)	0 (0%)	0,925 (92,5%)
0,37	0,935 (93,5%)	0,065 (6,5%)	1 (100%)	0,935 (93,5%)
...
0,48	0,947 (94,7%)	0,053 (5,3%)	1 (100%)	0,947 (94,7%)
0,49	0,949 (94,9%)	0,051 (5,1%)	1 (100%)	0,949 (94,9%)
0,50	0,943 (94,3%)	0,057 (5,7%)	1 (100%)	0,943 (94,3%)

Таким образом сравнительный анализ показал преимущество использования нейронечеткой модели для выделения контурных точек при автоматизации процесса выделения контуров и распознавания объектов на их основе.

4.6. Визуальная оценка обобщающих свойств нейронечеткой модели принятия решения о контурности пикселя изображения


Очевидно, что результаты применения разработанной нейронечеткой модели для построения контурных точек на других изображениях зависят от распределения градиента яркости контурных пикселей объектов.

Для оценки обобщающих свойств разработанной модели необходимо применить ее к другим изображениям. В качестве таких изображений были использованы изображения, представленные на рис. 4.11 и 4.12.


На рисунке 4.11 представлены изображение катера на воде (а) и бинарный вид изображения (b). Из рисунка видно, что применение разработанной нейронечеткой модели позволило получить замкнутый контур катера, что обеспечит в дальнейшем выделение признаков дескрипторов контура и построение нейросетевого классификатора. Положительный результат применения модели позволяет утверждать, что распределение градиента яркости контурных пикселей катера (рис. 4.11) и человека (рис. 4.3) являются близкими.

На рисунке 4.12 представлены изображение беспилотного летательного аппарата (БПЛА) в воздухе и бинарный вид изображения. Из рисунка видно, что применение разработанной нейронечеткой модели не позволило получить замкнутый контур летательного аппарата. Отрицательный результат применения модели позволяет утверждать, что распределение градиента яркости контурных пикселей БПЛА (рис. 4.12) и человека (рис. 4.3) не являются близкими.

В настоящее время существует различные методы изменения градиента яркости [66], позволяющие увеличить контрастность изображения. Применение метода гамма-коррекции imadjust позволили улучшить контрастность изображения (рис. 4.13 (а)). Применение нейронечеткой модели выделения контурных точек позволило получить бинарное изображение (рис. 4.13 (b)) с большим количеством контурных точек БПЛА, однако его замкнутый контур не был получен.




a)




b)

Рис. 4.10 – Исходное изображение лодки (a) и его контурное изображение (b), полученное при помощи нейронечеткой модели



a)



b)


Рис. 4.11. Исходное изображение БПЛА (a) и его контурное изображение (b), полученное при помощи нейронечеткой модели



Рис. 4.13 – Изображение БПЛА с измененной контрастностью (а) и его контурное изображение (b), полученное при помощи нейронечеткой модели

Для сравнения на рис. 4.14 продемонстрирован результат выделения контуров на исходных изображениях 4.12 (а) и 4.13 (а) методом Кэнни. Для формирования бинарного изображения 4.14 (а) и (b) в результате перебора параметров было подобрано значение 0.25. Из рисунков видно, что контурных точек БПЛА по сравнению с рис. 4.13 (b) стало больше, но его контур не является замкнутым и в дальнейшем не позволит сформировать признаки – дескрипторы и построить нейросетевой классификатор.

В приложении представлены результаты применения нейронечеткой модели как к снимкам, сделанными с дронов, так и к рентгеновским снимкам. Из результатов видно, что в большинстве случаев контуры выделяются достаточно четко.



a)



б)

Рис. 4.14 – Результат выделения контуров методом Кэнни

Таким образом, нейронечеткая модель принятия решения о контурности пикселя может быть применена к другим изображениям со схожим распределением разностей яркостей на контурных границах объекта. Для применения разработанной модели к изображениям, которые отличаются значением градиента на контурной границе объекта, необходимо:

- Расширить набор данных для обучения, пополнив его необходимыми векторами со значениями разности яркости и признаком контурности рассматриваемого пикселя;
- переобучить нейронечеткую сеть принятия решения о контурности пикселя.

4.7. Исследование применимости нейронечеткой модели выделения контурного пикселя к зашумленным изображениям

Исходное изображение, использованное для построения контурного изображения, представлено на рисунке 4.15. Рассмотрим фрагменты исходного изображения и его контурного изображения, полученного при помощи разработанной нейронечеткой модели (рис. 4.16). Значения яркостей пикселей лежат в диапазоне $[0, 1]$.



Рис. 4.15 – Исходное изображение




Рис. 4.16 – Фрагмент исходного изображение и его контур, полученный при помощи разработанной нейронечеткой модели выделения контурного пикселя

Исследуется применение нейронечеткой модели выделения контурного пикселя для зашумленного изображения [123]. На исходное изображение накладывается гауссовый шум с математическим ожиданием равным 0 и различным среднеквадратичным отклонением яркости (σ).

На рисунке 4.17 представлено зашумленное изображение с PSNR=26.1171dB, а на рисунке 4.18 фрагмент соответствующего контурного изображения, полученного с помощью разработанной нейронечеткой модели.



Рис. 4.17 – Зашумленное изображение с PSNR= 26.1171dB



Рис. 4.18 – Фрагмент контурного изображения

Для каждого значения среднеквадратического отклонения было проведено по 10 попыток зашумления и последующего выделения непрерывного контура. Результаты проведенных исследований приведены на рис. 4.19-4.30, визуализирующие фрагменты полученных контурных изображений. В таблице 4.7 представлены среднее значение PSNR, а также количество попыток, в результате которых были получены замкнутые контуры искомого объекта. Из результатов видно, что увеличение среднеквадратического отклонения при наложении шума снижает вероятность выделения замкнутого контура и начиная со значения 0,06 вероятность составляет меньше 50%.

Таблица 4.7 – Результаты проведенных исследований

Среднеквадратические отклонения (σ)	Среднее значение PSNR (dB)	Количество попыток, в результате которых были получены замкнутые контуры искомого объекта
0,01	40.1503	10
0,02	34.3051	10
0,03	30.9899	8
0,04	28.6396	9
0,05	26.9047	6
0,06	25.3282	4
0,07	24.1982	3
0,08	23.2060	4
0,09	22.3439	2
0,1	21.5226	2
0,12	20.1046	1
0,15	18.3451	0

Также разработанная нейронечеткая модель была применена к изображению, представленному на рис. 4.31, а также его зашумленным, результаты работы разработанной нейронечеткой модели выделения контурного пикселя представлены на рисунке 4.31 (б) и 4.32 [118].




Рис. 4.19 – Фрагмент зашумленного изображения со значениями $\sigma=0.01$ и PSNR=40.2060




Рис. 4.20 – Фрагмент зашумленного изображения со значениями $\sigma=0.02$ и PSNR=34.3278




Рис. 4.21 – Фрагмент зашумленного изображения со значениями $\sigma=0.03$ и PSNR=31.0548




Рис. 4.22 – Фрагмент зашумленного изображения со значениями $\sigma=0.04$ и PSNR=28.5414




Рис. 4.23 – Фрагмент зашумленного изображения со значениями $\sigma=0.05$ и PSNR=26.1171




Рис. 4.24 – Фрагмент зашумленного изображения со значениями $\sigma=0.06$ и PSNR=25.7651




Рис. 4.25 – Фрагмент зашумленного изображения со значениями $\sigma=0.07$ и PSNR=24.5010




Рис. 4.26 – Фрагмент зашумленного изображения со значениями $\sigma=0.08$ и PSNR=22.1883




Рис. 4.27 – Фрагмент зашумленного изображения со значениями $\sigma=0.09$ и PSNR=22.4227




Рис. 4.28 – Фрагмент зашумленного изображения со значениями $\sigma=0.1$ и PSNR=21.8921




Рис. 4.29 – Фрагмент зашумленного изображения со значениями $\sigma=0.12$ и PSNR=20.2020




Рис. 4.30 – Фрагмент зашумленного изображения со значениями $\sigma=0.15$ и PSNR=18.1574




Рис. 4.31 – Исходный рисунок лодки и контурное изображение, полученное при помощи нейронечеткой модели выделения контурного пикселя




Рис. 4.32 – Контурные изображения, полученные на зашумленных изображениях с $\sigma=0.04$ (PSNR=28.2412), 0.06 (PSNR=24.8517) и 0.08 (PSNR=22.5329)

4.7. Выводы

1. Для поиска объекта с эталонным (заданным) контуром на изображении необходимо выполнить следующие этапы методики, реализующие разработанные в диссертации методы и алгоритмы:

1.1. Формирование Базы нечетких нейронных моделей и Базы нейросетевых классификаторов на основе разработки нейронечеткой модели принятия решения о контурности пикселя изображения, а также нейросетевого классификатора на основе построения и использования признаков – дескрипторов Фурье [117].

1.2. Выделение контуров на изображении и распознавание необходимого эталонного контура с использованием Базы нечетких нейронных моделей и Базы нейросетевых классификаторов.

2. Экспериментальные исследования разработанных в диссертации методов и алгоритмов для выделения и распознавания на изображении контура лежащего на снегу человека показало следующие результаты:

2.1. База знаний для выделения контурных точек, построенная на основе изображения, представленная на рис. 4.3., состоит из 511 правил.

2.2. Восемь пар нормализованных признаков-дескрипторов эталонного контура человека с одной стороны отражают структуру контура, а с другой стороны не содержат шумовую составляющую.

2.3. Набор данных для обучения нейросетевого классификатора эталонного контура человека состоит из 902 контуров, а нейронная сеть состоит из 32 входных нейронов, соответствующих действительной и мнимой части 8 пар дескрипторов, один скрытый слой из 10 нейронов и выходной слой из одного нейрона.

3. Сравнение результатов применения метода Кэнни для выделения контуров и дальнейшего распознавания показало преимущество использования нейронечеткой модели для выделения контурных точек при автоматизации процесса выделения контуров и распознавания объектов на их основе.

4. Нейронечеткая модель принятия решения о контурности пикселя может быть применена для изображений со схожим распределением разностей яркостей на контурных границах объекта.

5. Проведенные исследования применимости нейронечеткой модели выделения контурного пикселя к зашумленным изображениям показали, что увеличение среднеквадратического отклонения при наложении шума снижает вероятность выделения замкнутого контура.

ЗАКЛЮЧЕНИЕ

В диссертационной работе на основе выполненных исследований решена актуальная научная задача, имеющая значение с точки зрения развития и применения средств математического моделирования, численных методов и комплексов программ для нейронечеткого выделения контурных точек на изображении и нейросетевого распознавания контуров. Обоснована необходимость разработки нового математического обеспечения по построению нейронечеткой модели выделения контурных точек, а также нейросетевого классификатора на основе признаков-дескрипторов Фурье контура искомого объекта.

Математическое обеспечение, разработанное в диссертации, состоит из следующих основных компонентов:

- 1) метода и алгоритмов построения структуры и состава нейронечеткой модели выделения контурных точек изображения;
- 2) метода и алгоритма идентификации значений параметров нейронечеткой модели;
- 3) метода и алгоритмов построения нейросетевого классификатора выделенных контуров.

На основе предложенных методов и алгоритмов реализован программный комплекс, позволяющий автоматизировать процессы построения нейронечетких и нейросетевых моделей для выделения и классификации контуров на изображении, а также проводить вычислительные эксперименты.

Проведенные исследования с применением современных компьютерных технологий и метрик качества классификации позволили сформировать требования к наборам данных для построения нейронечетких и нейросетевых моделей и оценить эффективность разработанных методов и алгоритмов.

Для оценки эффективности разработанных нейронечеткой и нейросетевой моделей определялось количество правильно распознанных объектов на двух изображениях (рис. 4.3, 4.10) на примере поиска и распознавания человека, лежащего на земле. Общий показатель успеха на первом изображении (точность классификации, OSR)

составил 96,1%, а общий показатель ошибки (суммарная ошибка первого и второго рода, OER) – 3,9%. Общий показатель успеха на втором изображении OSR составил 98%, а общий показатель ошибки OER– 2%.

Применение метода Кэнни для выделения контуров на изображении (рис. 4.3) и дальнейшего их распознавания показало, что лучший результат достигается при значении порога фильтрации, равном 0,49. При этом общий показатель успеха составил 94,9%, а общий показатель ошибки – 5,1%. Сравнение показателей успеха и ошибки указывают на преимущество применения нейронечеткой модели выделения контурных точек, что позволяет повысить долю правильно распознанных объектов на изображении.

Разработанная нейронечеткая модель выделения контурных точек была применена к различным изображениям, снятым с беспилотных летающих аппаратов, и к рентгеновским снимкам. Результаты обработки изображений показали адекватность модели и возможность ее использования в различных прикладных областях.

Проведенные исследования применимости нейронечеткой модели выделения контурного пикселя к зашумленным изображениям показали, что увеличение среднеквадратического отклонения при наложении шума снижает вероятность выделения замкнутого контура.

Таким образом, в диссертации решены все поставленные задачи, а ее цель, заключающаяся в повышении результативности поиска и распознавания искомых объектов на изображениях на основе нейронечеткого моделирования процесса выделения контуров объектов и нейросетевого моделирования их классификации, достигнута.

Перспективы дальнейшей разработки темы. Перспективы диссертационного исследования связаны с определением критериев выделения классов изображений, для которых нейронечеткие модели позволят выделять непрерывные контуры для дальнейшей классификации, а также адаптацией предложенного подхода к полноцветному изображению.

СПИСОК ЛИТЕРАТУРЫ

1. Форсайт, А. Д. Компьютерное зрение. Современный подход / А.Д. Форсайт, Ж. Понс // Пер. с англ. – М.: ИД «Вильямс». – 2004. – 928 с.
2. Алпатов, Б. А. Исследование эффективности алгоритма межкадровой фильтрации бинарного изображения в системах видеослежения / Б. А. Алпатов, А. А. Катаев // Вестник Рязанской государственной радиотехнической академии. – 2006. – № 19. – С. 3-5.
3. Бабаян, П. В. Распознавание объектов на изображениях при наблюдении из космоса / П. В. Бабаян, А. Б. Фельдман // Вестник Рязанского государственного радиотехнического университета. – 2008. – № 26. – С. 3-10.
4. Балашов, О. Е. Исследование алгоритма выделения движущихся объектов / О. Е. Балашов, П. В. Скрябина // Новые информационные технологии в научных исследованиях и в образовании "НИТ 2014" : материалы XIX Всероссийской научно-технической конференции студентов, молодых ученых и специалистов, Рязань, 12–14 ноября 2014 года. – Рязань: Рязанский государственный радиотехнический университет, 2014. – С. 215-217.
5. Веремеенко, К. К. Комплексная отказоустойчивая навигационная система беспилотного аппарата, использующая информацию от системы технического зрения / К. К. Веремеенко, Д. А. Антонов, М. В. Жарков [и др.] // Новости навигации. – 2016. – № 2. – С. 8-13.
6. Ким, Н. В. Анализ дорожной ситуации с использованием систем технического зрения / Н. В. Ким, А. Г. Кузнецов, С. Ю. Косоруков // Известия ЮФУ. Технические науки. – 2010. – № 3(104). – С. 107-111.
7. Фурман, Я. А. Распознавание образов как задача разложения вектора в базисе эталонных векторов алфавита / Я. А. Фурман // Вестник Марийского государственного технического университета. Серия: Радиотехнические и инфокоммуникационные системы. – 2008. – № 1(2). – С. 53-60.

8. Гуревич, И. Б. Схема синтеза логических моделей изображений, допускаемых эффективными распознающими операторами / И. Б. Гуревич // Компьютерная оптика. – 1995. – № 14-15-1. – С. 133-147.
9. Пытьев, Ю. П. Методы морфологического анализа изображений / Ю. П. Пытьев, А. И. Чуличков. – Moscow : ООО Издательская фирма "Физико-математическая литература", 2010. – 336 с.
10. Мокшин, В. В. Отслеживание объектов в видеопотоке по значимым признакам на основе фильтрации частиц / В. В. Мокшин, А. П. Кирпичников, Л. М. Шарнин // Вестник Казанского технологического университета. – 2013. – Т. 16, № 18. – С. 297-303.
11. Шлеймович, М. П. Распознавание изображений лиц в интеллектуальных системах / М. П. Шлеймович, Ю. И. Кербичков // Вестник Казанского государственного технического университета им. А.Н. Туполева. – 2014. – № 2. – С. 209-213.
12. Красильников, Н. Н. Реставрация изображений с учетом их структуры / Н. Н. Красильников // Оптический журнал. – 2009. – Т. 76, № 2. – С. 7-12.
13. Forsyth, D. A. Automatic Detection of Human Nudes / D. A. Forsyth, M. M. Fleck // International Journal of Computer Vision. – 1999. – Vol. 32, No. 1. – P. 63-77.
14. Вершинина, В. В. Метод и алгоритмы анализа контурных изображений в визуальных информационных системах на основе неоднородной нечеткой семантической сети : специальность 05.13.01 "Системный анализ, управление и обработка информации (по отраслям)" : диссертация на соискание ученой степени кандидата технических наук / Вершинина Валентина Владимировна. – Рыбинск, 2004. – 176 с.
15. Глова, В. И. Нечеткая модель распознавания размытых двумерных форм / В. И. Глова, И. В. Аникин, М. А. Аджели // Вестник Казанского государственного технического университета им. А.Н. Туполева. – 2001. – № 3. – С. 32-36.
16. Исупов, Н. С. Распознавание слитных рукописных текстов с использованием аппарата нечеткой логики / Н. С. Исупов, А. В. Кучуганов // Вестник ИЖГТУ имени М.Т. Калашникова. – 2012. – № 1(53). – С. 104-107.

17. Лепский, А. Е. Стохастическое и нечеткое упорядочивание методом минимальных преобразований / А. Е. Лепский // Автоматика и телемеханика. – 2017. – № 1. – С. 59-79.
18. Ершов, М. Д. Обнаружение линий электропередач на изображениях / М. Д. Ершов, Н. Ю. Шубин // Новые информационные технологии в научных исследованиях: материалы XXI Всероссийской научно-технической конференции студентов, молодых ученых и специалистов, Рязань, 16–18 ноября 2016 года / Рязанский государственный радиотехнический университет. – Рязань: Рязанский государственный радиотехнический университет, 2016. – С. 248.
19. Ершов, М. Д. Исследование подходов к выделению контуров объектов на изображении на основе предварительной фильтрации и нечеткой логики / М. Д. Ершов, С. С. Георгиева // Цифровая обработка сигналов. – 2019. – № 3. – С. 46-53.
20. Борисов, В. В. Способы интеграции нечетких и нейронных сетей / В. В. Борисов, А. С. Федулов // Нейрокомпьютеры: разработка, применение. – 2007. – № 1. – С. 5-11.
21. Круглов, В. В. Сравнение алгоритмов Мамдани и Сугэно в задаче аппроксимации функции / В. В. Круглов // Математическая морфология: электронный математический и медико-биологический журнал. – 2001. – Т. 3, № 4. – С. 69-76.
22. Ясницкий, Л. Н. Программный комплекс для распознавания рукописных и старопечатных текстов / С. И. Корниенко, Ю. Р. Айдаров, Д. А. Гагарина [и др.] // Информационные ресурсы России. – 2011. – № 1(119). – С. 35-37.
23. Alawad, A.M. Fuzzy Logic based Edge Detection Method for Image Processing / A.M. Alawad, F.D. Abdul Rahman, O.O. Khalifa, N.A. Malek // International Journal of Electrical and Computer Engineering - Vol. 8, No. 3. - 2018. - p. 1863-1869.
24. Verma, O.P. Simple Fuzzy Rule Based Edge Detection / O.P. Verma, Veni Jain, R. Gumber // J Inf Process Syst, - Vol.9, No.4, - 2013. - pp.575-591.

25. Aborisade, D.O. Fuzzy Logic Based Digital Image Edge Detection / D.O. Aborisade // Global Journal of Computer Science and Technology - Vol. 10 Issue 14. – 2010. – p. 78-83.
26. Khunteta, A. Edge Detection via Edge-Strength Estimation Using Fuzzy Reasoning and Optimal Threshold Selection Using Particle Swarm Optimization / A. Khunteta, D. Ghosh // Advances in Fuzzy Systems, -Vol. 2014. -2014. -p. 17.
27. Фурман, Я.А. Введение в контурный анализ. Приложения к обработке изображений и сигналов / Я.А. Фурман, А.В. Кревецкий, А.К. Передреев, А.А. Роженцов, Р.Г. Хафизов, И.Л. Егошина, А.Н. Леухин // 2-е изд., испр. – М.: Физматлит. – 2003. – 592 с.
28. Сойфер, В.А. Методы компьютерной обработки изображений / В.А. Сойфер// М.: ФИЗМАТЛИТ. – 2003. – 192 с.
29. Фурман, Я. А. Цифровые методы обработки и распознавания бинарных изображений / Я.А. Фурман, А.Н. Юрьев, В.В. Яншин // Красноярск: Изд-во Краснояр. ун-та. – 1992. – 248 с.
30. Gong Xin-Yi. An Overview of Contour Detection Approaches / Xin-Yi Gong, Hu Su, De Xu, Zheng-Tao Zhang, Fei Shen, Hua-Bin Yang // International Journal of Automation and Computing. – 2018. – Vol. 15, No 6. – P. 656-672.
31. Senthilkumaran, N. A Study on Edge Detection Methods for Image Segmentation/ N. Senthilkumaran, R. Rajesh // Proceedings of the International Conference on Mathematics and Computer Science. – 2009. – Vol. I. – P. 255-259.
32. Senthilkumaran, N. Edge Detection Techniques for Image Segmentation – A Survey / N. Senthilkumaran, R. Rajesh // Proceedings of the International Conference on Managing Next Generation Software Applications. – 2008. – P.749-760.
33. Lakshmi, S. A study of Edge Detection Techniques for Segmentation Computing Approaches / S. Lakshmi, Dr.V. Sankaranarayanan // IJCA, Special Issue on CASCT. – 2010. – Vol. 1. – P. 35-41.
34. Ziou, Djemel. Edge Detection Techniques – An Overview / Djemel Ziou, Salvatore Tabbone // Pattern Recognition & Image Analysis. – 1998. – Vol. 8, No 4. – P.537-559.

35. Sharifi, M. A classified and comparative study of edge detection algorithms / M. Sharifi, M. Fathy, M.T. Mahmoudi // International Conference on Information Technology: Coding and Computing, Proceedings. – 2002. – P. 117-120.
36. Сакович, И.О. Обзор основных методов контурного анализа для выделения контуров движущихся объектов / И.О. Сакович, Ю.С. Белов // Инженерный журнал: наука и инновации. – вып. 12. – 2014.
37. Rao Elisala, Mr. Srinivasa. A Novel Edge Detection Technique for Image Classification and Analysis / Mr. Srinivasa Rao Elisala, Y. Smruthi, B. Lavanya, E. Nageswara Rao // Journal of Computer Engineering. – Vol. 15, Issue 5. – 2013. – P. 90-97.
38. Баранник, В.В. Анализ методов обнаружения границ объектов на изображениях и их классификация / В.В. Баранник, А.В. Яковенко, А.В. Власов // Сучасна спеціальна техніка. – 2012. – № 3. – С. 20-27.
39. Kumar Katiyar, Sunil. Comparative analysis of common edge detection techniques in context of object extraction / Sunil Kumar Katiyar, P.V. Arun // IEEE Transactions on Geoscience and Remote Sensing. – Vol. 50. – 2012. – P. 68-78.
40. Shrivakshan, G.T. A Comparison of various Edge Detection Techniques used in Image Processing / G.T. Shrivakshan, Dr.C. Chandrasekar // IJCSI International Journal of Computer Science Issues. – Vol. 9, Issue 5, No 1. – 2012.
41. Reshma, P. Comparison of various Edge Detection Algorithms / P. Reshma // International Journal of Scientific & Engineering Research. – Vol. 10, Issue 3. – 2019.
42. Singh, Simranjit. Comparison of various edge detection techniques / Simranjit Singh, Rakesh Singh // Computing for Sustainable Global Development (INDIA-Com), 2nd International Conference. – 2015. – P. 393-396.
43. Kumar, Sanjay. Comparative Analysis of Various Edge Detection Techniques in Biometric Application / Sanjay Kumar, Mahatim Singh, D.K. Shaw // International Journal of Engineering and Technology. – Vol. 8, No 6. – 2016. – P. 2452-2459.

44. Ziou, D. Edge detection techniques-an overview / D. Ziou, S. Tabbone // Pattern Recognition & Image Analysis. – Vol. 8, No 4. – 1998. – P. 537-559.
45. Huang, G. Real-time automated detection of older adults hand gestures in home and clinical settings/ G. Huang, S.N. Tran, Q. Bai // Neural Comput & Applic. 2023. №35. pp. 8143–8156.
46. Домрачева, А.Б. Применение контурного анализа в задаче прямого контроля позвоночного столба/ А.Б. Домрачева // НиКа. - 2016.
47. Рыбаков, А.В. Проектирование робототехнических манипуляторов с системой компьютерного зрения для сбора томатов/ А.В. Рыбаков, А.М. Лихтер, А.Б. Погожева, А.В. Михайлова, А.Б. Дусалиев // Прикаспийский журнал: управление и высокие технологии. – №3 (51). – 2020.
48. Аунг, Ч.Х. Разработка алгоритмов обработки изображений интеллектуальными мобильными роботами на основе нечёткой логики и нейронных сетей/ Ч.Х. Аунг, З.П. Танг, А.Р. Федоров, П.А. Федоров // Современные проблемы науки и образования. – № 6. – 2014.
49. Леонов, С.Н. Распознавание неупорядоченных деталей на видеоряде с помощью интеллектуальных систем технического зрения / С.Н. Леонов, В.В. Головков, И.И. Яковлев // Евразийский Союз Ученых. - 2016. - №5-2.
50. Домрачева, А.Б. Об одном подходе к сравнению разновременных космоснимков/ А.Б. Домрачева, М.А. Басараб // Инженерный журнал: наука и инновации. - 2013. - №2 (14).
51. Франц, В.А. Алгоритм построения траектории движения объектов в видеопотоке на основе оптического потока/ В.А. Франц, В.В. Воронин, В.И. Марчук, А.В. Фисунов // Инженерный вестник Дона. - 2013. - №3.
52. Гильманов, Т.А. Система распознавания дорожных знаков/ Т.А. Гильманов // Science Time. - 2014. - №8 (8).
53. Титов, И. О. Выделение контуров изображения движущегося объекта/ И.О. Титов, Г.М. Емельянов // Вестник НовГУ. - 2010. - №55.

54. Shah, N. Crime forecasting: a machine learning and computer vision approach to crime prediction and prevention/ N. Shah, N. Bhagat, M. Shah // *Visual Computing Industry, Biomedicine, and Art.* - 2021. - №4.
55. Сиволобов, С.В. Автоматизированный программный комплекс для оперативного отождествления человека по походке / С.В. Сиволобов, В.Г. Булгаков, В.В. Бумагин // *Информационная безопасность регионов.* - 2013. - №2 (13).
56. Чудновский, М.М. Алгоритм распознавания жестов руки человека на видеопоследовательности в режиме реального времени для реализации интерфейсов человеко-машинного взаимодействия/ М.М. Чудновский // *Сибирский аэрокосмический журнал.* - 2014. - №3 (55).
57. Papari, G. Edge and line-oriented contour detection: State of the art / G. Papari, N. Petkov // *Image and Vision Computing.* – 2011. – Vol. 29, No. 2-3. – P. 79-103.
58. Mlsna, P.A. Gradient and Laplacian Edge Detection. In *The Essential Guide to Image Processing* / P.A. Mlsna, J.J. Rodriguez // 2009. – P. 495-524.
59. Новиков, А.И. Детектор границ градиентного типа / А.И. Новиков, А.В. Пронькин // *Вестник РГРТУ.* – №68. – 2019. – с. 68-76.
60. Анисимов, Б.В. Распознавание и цифровая обработка изображений – М.: Высш. Школа. - 1983 – 295с.
61. Гонсалес, Р. Цифровая обработка изображений: Издание 3-е, исправленное и дополненное / Р. Гонсалес, Р. Вудс // Москва: Техносфера, 2012. – 1104 с.
62. Umbaugh, Scott. *Computer Imaging: Digital Image Analysis and Processing* / Scott Umbaugh // CRC Press. – Technology & Engineering. – 2005. – 688 p.
63. Canny, J. A Computational Approach for Edge Detection / J.A. Canny // *IEEE Trans. Pattern Analysis Machine Intelligence.* – Vol. PAMI-8, No 6. – 1986. – P. 679-698.
64. Ding, Lijun. On the Canny edge detector. *Pattern Recognition* / Lijun Ding, Ardeshir Goshtasby // Vol. 34, Issue 3. – 2001. – P. 721-725.
65. Liu, Ruiyuan. Research on Improved Canny Edge Detection Algorithm / Ruiyuan Liu, Jian Mao // *MATEC Web of Conferences.* – Vol. 232, No 14. – 2018. – P. 1-4.

66. McReynolds, T. *Advanced Graphics Programming Using OpenGL* / T. McReynolds, D. Blythe// - 2005. - p. 35-56
67. Фисенко, В.Т. Компьютерная обработка и распознавание изображений. Учебное пособие / В.Т. Фисенко, Т.Ю. Фисенко // Электрон. дан. – СПб.: НИУ ИТМО. – 2008. – 192 с.
68. Новиков, А. И. Детектор границ градиентного типа для изображений подстилающей поверхности / А. И. Новиков, А. В. Пронькин // Вестник Рязанского государственного радиотехнического университета. – 2019. – № 68. – С. 68-76.,
69. Новиков, А. И. Метод и программа детектирования границ перепада яркости / А. И. Новиков, А. В. Пронькин // Информационные технологии и нанотехнологии (ИТНТ-2020): Сборник трудов по материалам VI Международной конференции и молодежной школы. В 4-х томах, Самара, 26–29 мая 2020 года / Под редакцией В.В. Мясникова. Том 2. – Самара: Самарский национальный исследовательский университет имени академика С.П. Королева, 2020. – С. 111-119.
70. Кольцов, П. П. О количественной оценке эффективности алгоритмов анализа изображений/ П.П. Кольцов, А.С. Осипов, А.С. Куцаев, А.А. Кравченко, Н.В. Котович, А.В. Захаров // Компьютерная оптика. – 2015. – т. 39, № 4. – С. 542-556.
71. Кольцов, П. П. Эмпирический подход к оценке алгоритмов выделения границ // Информационные технологии и вычислительные системы. 2/2011. - С. 50-57.
72. R. Maini, H. Aggarwal. Study and comparison of various image edge detection techniques // *International Journal of Image Processing*, Vol. 3, No 1, 2009. - Pp. 1-11.
73. Shaout, A. Fuzzy logic image processing / A. Shaout, D. Murray, A. Motwakel // *International Journal of Knowledge Engineering and Data Mining*. - vol 6:3 - 2019, - p. 207-233.

74. Шведов, А. С. Аппроксимация функций с помощью нейронных сетей и нечетких систем / А. С. Шведов // Проблемы управления. - 2018. №1.
75. Ершов, М.Д. Исследование подходов к выделению контуров объектов на изображении на основе предварительной фильтрации и нечеткой логики/ М.Д. Ершов, С.С. Георгиева // Цифровая обработка сигналов. - 2019. - №3. - С. 46-53.
76. Петренко, Т.Г. Выделение границ на изображении с использованием нечетких множеств второго типа / Т.Г. Петренко, И.Г. Сальков, О.С. Тимчук, А.А. Адамец // Проблеми інформаційних технологій. – № 2. – 2012. – С. 116-122.
77. Pham T., Chen G. Introduction to Fuzzy Sets, Fuzzy Logic and Fuzzy Control Systems. Lewis Publishers, 2000.
78. Successful Applications of Fuzzy Logic and Fuzzy Control (Part 1) / В.М. Pfeiffer, J.Jakel, A. Kroll et al. // Automatisierungstechnik. 2002. N 10 (50). – P. 461-471.
79. Successful Applications of Fuzzy Logic and Fuzzy Control (Part 2) / В.М. Pfeiffer, J.Jakel, A. Kroll et al. // Automatisierungstechnik. 2002. N 11 (50). P. 511-521.
80. Ярушкина, Н.Г. Нечеткие нейронные сети (часть 1) / Н.Г. Ярушкина // Новости искусственного интеллекта. – 2001. – № 2-3. – С. 47-52.
81. Ярушкина, Н.Г. Нечеткие нейронные сети (часть 2) / Н.Г. Ярушкина // Новости искусственного интеллекта. – 2001. – № 4. – С. 23-29.
82. Abdulghafour, M. Image segmentation using Fuzzy logic and genetic algorithms/ M. Abdulghafour // Journal of WSCG. – Vol. 11, No 1. – 2003.
83. Abdallah, A. Edge Detection in Digital Images Using Fuzzy Logic Technique / A. Alshennawy Abdallah, A. Aly Ayman // World Academy of Science, Engineering and Technology International Journal of Computer and Information Engineering. – Vol. 3, No 3. – 2009.
84. Alshennawy, A.A. Edge Detection in Digital Images Using Fuzzy Logic Technique / A.A. Alshennawy, A.A. Aly // World Academy of Science, Engineering and Technology. – No 51. – 2009.
85. Haq, I. Fuzzy Logic Based Edge Detection in Smooth and Noisy Clinical Images / I. Haq, S. Anwar, K. Shah, MT. Khan, SA. Shah // PLoS ONE - Vol. 10(9) – 2015.

86. Shuliang, S. Edge Detection Based on Fuzzy Logic and Expert System / S. Shuliang, L. Chenglian, C. Sisheng // Fuzzy Inference System - Theory and Applications – 2012 – p. 271-278.
87. Осовский С. Нейронные сети для обработки информации // Пер. с польского. И.Д. Рудинского. – М.: Финансы и статистика, 2002. - 344 с.
88. Назаров, М. А. Использование преобразования Фурье для нормализации исходных данных и дальнейшей классификации образов / М. А. Назаров // Вестник современных исследований. – 2018. – № 5.3(20). – С. 491-493.
89. Свидетельство о государственной регистрации программы для ЭВМ № 2023680763 Российская Федерация. Программа обработки изображения на основе нейронечеткого и нейросетевого моделирования: № 2023668574: заявл. 05.09.2023: опубл. 04.10.2023 / М. А. Назаров, Л. Ю. Емалетдинова.
90. Kasabov, N. Foundations of neural networks, fuzzy systems and knowledge engineering/ N. Kasabov // London: Bradford Book, 1996.
91. Verbruggen, H.V. Constructing fuzzy models by product space clustering / H.V. Verbruggen, R. Babushka // Fuzzy model identification. – Berlin: Springer. – 1998. – p. 53-90.
92. Глушенко, С.А. Обучение нейро-нечеткой сети с помощью генетического алгоритма / С.А. Глушенко, А.И. Долженко // Кибернетика и программирование. – 2017. – № 5. – С. 79-88.
93. Dinh, N.D. Shape recognition using FFT preprocessing and neural network / N.D. Dinh, S. Osowski // Compel, - Vol. 17, No 5/6. – 1998. – p. 658-666.
94. Архангельский В.И., Богаенко И.Н., Грабовский Г.Г., Рюмшин Н.А. Нейронные сети в системах автоматизации. – К.: Техника, 1999. – 234 с.
95. Барский А.Б. Нейронные сети: распознавание, управление, принятие решений. – М.: Финансы и статистика, 2004. – 176с: - (Прикладные информационные технологии).
96. Галушкин А.И. Нейронные сети: основы теории. – М.: Горячая линия-Телеком, 2010. – 480 с.

97. Головкин В.А. Нейронные сети: обучение, организация и применение. Кн. 4: Учебное пособие для вузов / Общая ред. А.И. Галушкина. М.: ИПРЖР, 2001. – 256 с.: ил.
98. Заенцев И.В. Нейронные сети: основные модели. – Воронеж, 1999. – 76 с.
99. Каллан Р. Основные концепции нейронных сетей.: Пер. с англ. – М.: Издательский дом «Вильямс», 2001. – 287 с.
100. Круглов В.В., Борисов В.В. Искусственные нейронные сети. Теория и практика. – 2-е изд., стереотип. – М.: Горячая линия – Телеком, 2002. – 382 с.: ил.
101. Круглов В.В., Дли М.И., Голунов Р.Ю. Нечеткая логика и искусственные нейронные сети. – М.: Физматлит, 2001. – 224 с.
102. Медведев В.С., Потемкин В.Г. Нейронные сети. MATLAB 6. – М.: ДИАЛОГ – МИФИ, 2002. – 496 с.
103. Рутковская Д., Пилиньский М., Рутковский Л. Нейронные сети, генетические алгоритмы и нечеткие системы. М.: Горячая линия – Телеком, 2007. – 452 с.
104. Рутковский Л. Методы и технологии искусственного интеллекта / пер. с польского И.Д. Рудинского. – М.: Горячая линия-Телеком, 2010. – 520 с.
105. Тархов Д.А. Нейронные сети. Модели и алгоритмы. М.: Радиотехника, 2005. – 256 с.
106. Хайкин С. Нейронные сети: полный курс, 2-е издание.: Пер. с англ. - М.: Издательский дом "Вильямс", 2006. – 1104 с.
107. Катасёв, А.С. Нейронечеткая модель формирования правил классификации, как эффективный аппроксиматор объектов с дискретным выходом/ А.С. Катасёв // Кибернетика и программирование. - 2018. - № 6.
108. Прукс, В.Э. Пример системы технического зрения на основе нейросетевого классификатора/ В.Э. Прукс // Вестник Балтийского федерального университета им. И. Канта. Серия: Физико-математические и технические науки. - 2012. - №10.
109. Жабин, И.П. Применение нейросетевых технологий для автоматизации распознавания воздушных объектов/ И.П. Жабин, В.Н. Гордеев, А.В. Емельянов // Известия ТулГУ. Технические науки. - 2015. - №2.

110. Иванов, И.А. Проектирование нейросетевого классификатора для решения задачи распознавания эмоций/ И.А. Иванов // Решетневские чтения. - 2015. - №19.
111. Мешкова, Е.В. Методика построения классификатора текста на основе гибридной нейросетевой модели / Е.В. Мешкова // Известия ЮФУ. Технические науки. - 2008. - №4.
112. Буковшин, В.А. Анализ зашифрованного сетевого трафика на основе вычисления энтропии и применения нейросетевых классификаторов/ В.А. Буковшин, П.А. Чуб, Д.А. Короченцев, Л.В. Черкесова, Н.В. Болдырихин, О.А. Сафарьян // Известия юфу. Технические науки. - 2020. - №6 (216).
113. Абу-абед, Ф. Н. Построение нейросетевого классификатора для обнаружения нештатных ситуаций в процессе промышленного бурения нефтяных скважин/ Ф.Н. Абу-абед // Территория Нефтегаз. - 2012. - №6.
114. Kamen, E. Fundamentals of signals and systems using Matlab / E. Kamen, V. Heck // N.Y.:Prentice Hall, - 1997.
115. Svarer, C. Neural networks for signal processing / C. Svarer // Ph.D. dissertation. – Lyngby, Electronics Institute, -1994.
116. Назаров, М.А. Особенности поиска и нейросетевого распознавания эталонного контура объекта на изображении / М.А. Назаров, Л.Ю. Емалетдинова // Вестник технологического университета. – 2022. – Т.25, №3. – С. 62-66.
117. Назаров М.А. Методика распознавания эталонного контура на изображении с использованием нейросетевого и нечеткого моделирования / М.А. Назаров // Вестник технологического университета. – 2023. – Т.26, №9. – С. 78-83.
118. Назаров, М.А. Нейронечеткая модель построения контуров на изображении // Л.Ю. Емалетдинова, А.С. Катасёв, М.А. Назаров / Инженерный вестник Дона. – 2023. - №7.
119. Nazarov, M. Construction of a Fuzzy Model for Contour Selection / L. Emaletdinova, M. Nazarov // Studies in Systems, Decision and Control. – 2022. – 417. – P. 245-254


120. Назаров, М.А. Нейросетевой алгоритм распознавания объекта на изображении на основе эталонного контура / Л.Ю. Емалетдинова, М.А. Назаров // Математические методы в технике и технологиях: сб. тр. междунар. науч. Конф. - СПб.: Изд-во Политехн. ун-та, – 2020. – 137-141 с.
121. Назаров, М.А. Построение нечеткой модели выделения контуров / Л.Ю. Емалетдинова, М.А. Назаров // Математические методы в технике и технологиях: сб. тр. междунар. науч. Конф. – СПб.: Изд-во Политехн. ун-та, –2021. – 99-102 с.
122. Назаров, М.А. Модель нейросетевого распознавания контура объекта с использованием Фурье преобразования / Л.Ю. Емалетдинова, М.А. Назаров // Результаты современных научных исследований и разработок: сборник статей XVI Всероссийской научно-практической конференции. Пенза: МЦНС «Наука и Просвещение». – 2022. – С. 59-62.
123. Назаров, М.А. Технология распознавания эталонного контура на изображении с использованием нейросетевого и нейронечеткого моделирования/ Л.Ю. Емалетдинова, М.А. Назаров, А.Н. Кабирова // Математические методы в технике и технологиях: сб. тр. междунар. науч. Конф. – СПб.: Изд-во Политехн. ун-та, – 2023. – С. 92-95.
124. Werbos P. Backpropagation through time: what it does and how to do it // Proceedings of the IEEE. – October 1990. – Vol. 78, N. 10. – P. 1550 – 1560.
125. Горелова, А.В. Алгоритм обратного распространения ошибки / А.В. Горелова, Т.В. Любимова // Наука и современность. – 2015. – № 38. – С. 151-156.
126. Назаров, М. А. Разработка и использование программного комплекса выделения и распознавания контуров на изображении с использованием нейронечеткого и нейросетевого моделирования / М. А. Назаров // Вестник технологического университета. – 2024. – Т.27, №2. – С. 83-87.
127. Назаров, М. А. Метод распознавания контура объекта на изображении / М. А. Назаров // Моделирование энергоинформационных процессов: XII национальная научно-практическая конференция с международным участием. – Воронеж, 2024.

Приложение 1. ПРИМЕРЫ ПРИМЕНЕНИЯ РАЗРАБОТАННОЙ НЕЙРОНЕЧЕТКОЙ МОДЕЛИ

Таблица П.1 - Примеры применения разработанной нейронечеткой модели выделения контурных точек к различным изображениям, снятым с беспилотных летательных аппаратов

Первое изображение (полноцветное)	 A full-color photograph of a grey unmanned aerial vehicle (UAV) in flight against a clear blue sky. The aircraft is viewed from a low angle, showing its wings, tail, and various sensors. The number '331' is visible on the tail fin.
Первое изображение (в оттенках серого)	 A grayscale version of the same UAV image shown above. The aircraft and its features are rendered in shades of gray, highlighting the structural details and the number '331' on the tail.

Первое изображение (контурное)




Второе изображение (полноцветное)



Второе изображение (в оттенках серого)



Второе изображение (контурное)




Третье изображение (полноцветное)



Третье изображение (в оттенках серого)




Третье изображение (контурное)




Четвертое изображение (полноцветное)



Четвертое изображение (в оттенках серого)



Четвертое
изображение
(контурное)




Пятое изобра-
жение (полно-
цветное)



Пятое изображение (в оттенках серого)



Пятое изображение (контурное)




Шестое изображение (полноцветное)



Шестое изображение (в оттенках серого)





Примеры применения разработанной нейронечеткой модели выделения контурных точек к рентгеновским снимкам.




Первое изображение (в оттенках серого)




Первое изображение (контурное)




Второе изображение (полноцветное)




Второе изображение (в оттенках серого)



Второе изображение (контурное)




Третье изображение (полноцветное)



Третье изображение (в оттенках серого)



Третье изображение (контурное)



Приложение 2. Свидетельство о государственной регистрации разработанной программы для ЭВМ

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО
о государственной регистрации программы для ЭВМ
№ 2023680763

**Программа обработки изображения на основе
нейронечеткого и нейросетевого моделирования**

Правообладатели: **Назаров Максим Андреевич (RU),
Емалетдинова Лилия Юнеровна (RU)**

Авторы: **Назаров Максим Андреевич (RU), Емалетдинова
Лилия Юнеровна (RU)**

Заявка № **2023668574**
Дата поступления **05 сентября 2023 г.**
Дата государственной регистрации
в Реестре программ для ЭВМ **04 октября 2023 г.**

*Руководитель Федеральной службы
по интеллектуальной собственности*



ДОКУМЕНТ ПОДПИСАН ЭЛЕКТРОННОЙ ПОДПИСЬЮ
Сертификат: 4291650191951164b9795f83073b4aa7
Владелец: **Зубов Юрий Сергеевич**
Действителен с 18.08.2023 по 02.08.2024

Ю. С. Зубов

Приложение 3. Акты о внедрении и использовании

«УТВЕРЖДАЮ»

Проректор по образовательной
деятельности КНИТУ-КАИ

Р.Е. Моисеев

« 29 » 01 2024 г.



АКТ

о внедрении в учебный процесс университета
результатов кандидатской диссертации
Назарова Максима Андреевича

Мы, нижеподписавшиеся, заведующий кафедрой прикладной математики и информатики, к.т.н., доцент Зайдуллин С.С. и директор института компьютерных технологий и защиты информации, к.т.н., доцент Трегубов В.М. составили настоящий акт о том, что полученные аспирантом кафедры прикладной математики и информатики Назаровым М.А. результаты кандидатской диссертации внедрены в учебный процесс университета.

Предложенное в диссертации математическое и программное обеспечения в виде

- метода и алгоритма построения структуры и состава нейронечеткой модели выделения контурных точек на изображениях;
- метода и алгоритма формирования набора данных для построения нейронечеткой модели;
- метода и генетического алгоритма оптимизации значений параметров нейронечеткой модели;
- метода и алгоритма формирования набора данных для построения нейросетевого классификатора выделенных контуров;
- программного комплекса обработки изображений

используются на кафедре прикладной математики и информатики для подготовки магистров по направлениям «Прикладная математика и информатика» и «Информатика и вычислительная техника» при проведении лекционных занятий и выполнении лабораторных работ по дисциплинам «Технологии интеллектуального анализа данных», «Нейросетевые модели и алгоритмы», «Глубокое машинное обучение».

Кроме того, результаты диссертационного исследования Назарова М.А. используются на кафедре при выполнении обучающимися выпускных квалификационных, курсовых и научно-исследовательских работ.

Директор института
компьютерных технологий
и защиты информации,
к.т.н., доцент


В.М. Трегубов

Заведующий кафедрой
прикладной математики и
информатики,
к.т.н., доцент


С.С. Зайдуллин

«УТВЕРЖДАЮ»
 Директор
 обособленного подразделения
 №2 АО «УЗГА»

Р.Н. Ахмадеев

02 _____ 2024 г.

АКТ

об использовании результатов диссертационной работы
 Назарова Максима Андреевича

Комиссия в составе:

Председатель: Матвеев И.В., к.т.н., начальник ОКБ – главный конструктор

Члены комиссии:

Покровский Виталий Сергеевич, начальник отдела РПО

Хайруллин Рудель Ринатович, зам. начальника отдела РПО

составила настоящий акт о том, что результаты диссертационной работы аспиранта кафедры прикладной математики и информатики Назарова М.А. на соискание ученой степени кандидата технических наук, включающие методическое и алгоритмическое обеспечение построения и использования:

- нейронечеткой модели, позволяющей выделять контуры объектов на изображениях, снятых с беспилотного летательного аппарата;
- нейросетевого классификатора, позволяющего распознавать на изображении искомый объект;
- комплекса программ, реализующего разработанные алгоритмы

используются в научных исследованиях отдела разработки программного обеспечения обособленного подразделения №2 АО «УЗГА».

Полученные результаты диссертационной работы используются при разработке системы интеллектуальной обработки изображений в рамках создания новых более точных методов обнаружения искомого объекта на изображениях, полученных с помощью целевой аппаратуры беспилотных летательных аппаратов.

Считаем целесообразным рекомендовать полученные в диссертации Назарова М.А. результаты к использованию в других организациях, занимающихся в различных прикладных областях задачами интеллектуальной обработки изображений.

Председатель комиссии:

Главный конструктор, к.т.н.

Члены комиссии:

Начальник отдела РПО

Зам. начальника отдела РПО

 /Матвеев И.В.
 /Покровский В.С.
 /Хайруллин Р.Р.