

МИНИСТЕРСТВО ОБРАЗОВАНИЯ И НАУКИ РОССИЙСКОЙ ФЕДЕРАЦИИ
ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ АВТОНОМНОЕ
ОБРАЗОВАТЕЛЬНОЕ УЧРЕЖДЕНИЕ
ВЫСШЕГО ПРОФЕССИОНАЛЬНОГО ОБРАЗОВАНИЯ
«ЮЖНЫЙ ФЕДЕРАЛЬНЫЙ УНИВЕРСИТЕТ»
ТЕХНОЛОГИЧЕСКИЙ ИНСТИТУТ г. ТАГАНРОГЕ

На правах рукописи



ПОЦЫКАЙЛО АЛЕКСАНДР АНАТОЛЬЕВИЧ

**ИССЛЕДОВАНИЕ И РАЗРАБОТКА МЕТОДОВ ФОРМИРОВАНИЯ
РЕШАЮЩИХ ПРАВИЛ ПРИ КЛАССИФИКАЦИИ ФРАГМЕНТОВ
НА ПОЛУТОНОВЫХ ИЗОБРАЖЕНИЯХ**

Специальность: 05.12.04 – «Радиотехника,
в том числе системы и устройства телевидения»

Диссертация на соискание ученой степени кандидата технических наук

Научный руководитель
доктор технических наук
профессор Галустов Г.Г.

Таганрог

2011

04201163755

19.10.2011

СОДЕРЖАНИЕ

| | |
|---|----|
| ВВЕДЕНИЕ..... | 5 |
| 1 ПОСТАНОВКА ЗАДАЧИ ИССЛЕДОВАНИЯ И АНАЛИЗ ИЗВЕСТНЫХ МЕТОДОВ..... | 19 |
| 1.1 Постановка задачи выбора математической модели сигнала полутонного изображения..... | 19 |
| 1.2 Анализ методов формирования решающих правил | 25 |
| 1.2.1 Формирование признаков по полутонному изображению..... | 25 |
| 1.2.2 Выбор критерия эффективности системы признаков..... | 32 |
| 1.2.3 Проблема распознавания..... | 35 |
| 1.3 Постановка задачи оптимизации признаковых пространств..... | 38 |
| 1.4 Методы распознавания, основанные на теории статистических решений...44 | |
| Выводы по материалам 1 главы..... | 52 |
| 2 ИССЛЕДОВАНИЕ ХАРАКТЕРИСТИК МОДЕЛИ СИГНАЛА ПОЛУТОНОВОГО ИЗОБРАЖЕНИЯ И ОПТИМИЗАЦИЯ ПАРАМЕТРОВ РАСПОЗНАЮЩЕЙ СИСТЕМЫ..... | 54 |
| 2.1 Преобразование модели сигнала полутонного изображения..... | 54 |
| 2.1.1 Нормализация сигнала полутонного изображения..... | 59 |
| 2.2 Синтез решающего правила классификатора сигналов при непараметрической априорной неопределенности..... | 62 |
| 2.3 Укрупнение описания сигналов полутонных изображений на основе обобщенного оператора преобразования..... | 68 |
| 2.4 Оптимизация параметров распознающих систем в случае параметрической априорной неопределенности..... | 76 |
| Выводы по материалам 2 главы..... | 84 |
| 3 АЛГОРИТМЫ ПРИНЯТИЯ РЕШЕНИЙ ПРИ НЕПАРАМЕТРИЧЕСКОМ РАСПОЗНАВАНИИ СИГНАЛОВ ПОЛУТОНОВЫХ ИЗОБРАЖЕНИЙ | 86 |
| 3.1 Формирование системы признаков при классификации случайных процессов с использованием метода стохастического кодирования сигналов полутонных изображений..... | 86 |

| | |
|--|-----|
| 3.1.1 Исследование связи статистических характеристик анализируемого процесса с опорным процессом..... | 92 |
| 3.2. Оптимизация разделяющих поверхностей и принятие решений..... | 96 |
| 3.3. Определение структурной схемы алгоритма распознавания..... | 100 |
| 3.4 Исследование влияния вида и количества опорных распределений на эффективность классификатора..... | 104 |
| 3.5 Исследование влияния времени обучения и распознавания на эффективность классификатора | 114 |
| Выводы по материалам 3 главы..... | 122 |
| 4 МОДЕЛИРОВАНИЕ И ЭКСПЕРИМЕНТАЛЬНАЯ ПРОВЕРКА ЭФФЕКТИВНОСТИ РАБОТЫ КЛАССИФИКАТОРА СИГНАЛОВ ПОЛУТОНОВЫХ ИЗОБРАЖЕНИЙ..... | 123 |
| 4.1 Постановка экспериментального исследования..... | 123 |
| 4.2 Методы моделирования устройств обработки сигналов, с использованием пакетов программ математического моделирования..... | 123 |
| 4.3 Реализация работы алгоритмов непараметрического распознавания в пакете математического моделирования..... | 128 |
| 4.4 Оценка вычислительной сложности алгоритма..... | 130 |
| 4.5 Сравнительный анализ показателей качества и сложности НК МСОК и алгоритма непараметрической классификации по методу k–ближайших соседей..... | 135 |
| 4.6 Оценка статистической погрешности результатов программного эксперимента..... | 144 |
| 4.7 Разработка структурной схемы экспериментальной установки..... | 147 |
| 4.8 Определение показателей качества работы непараметрического классификатора..... | 148 |
| Выводы по материалам 4 главы..... | 151 |
| ЗАКЛЮЧЕНИЕ..... | 152 |
| ЛИТЕРАТУРА..... | 154 |
| ПРИЛОЖЕНИЕ 1..... | 160 |

ПРИЛОЖЕНИЕ 2.....175

ВВЕДЕНИЕ

Проблема распознавания изображений стала актуальной с момента появления автоматизации как на производстве, так и в различных сферах жизни человека. Это обусловлено, во-первых, активной работой в области создания автоматизированных систем наблюдения и контроля, во-вторых, попытками создания систем искусственного интеллекта. Важной составляющей, способствующей разработке подобных сложных систем, является значительный прогресс в создании как специализированных, так и универсальных высокопроизводительных ЭВМ. Однако задача распознавания образов оказывается достаточно сложной и решить её простым наращиванием производительности ЭВМ невозможно. Это во многом обусловлено сложностью формализации процесса восприятия различной природы информации (визуальной, акустической и пр.) и соотнесение её с системой образов живыми организмами. Поэтому, несмотря на кажущуюся легкость, с которой человек, как и другие живые организмы, решает задачу распознавания окружающих его предметов, формального универсального математического или технологического подхода, позволяющего разрабатывать алгоритмы, методы и автоматизированные системы, эффективно осуществляющие процесс распознавания, на данный момент нет.

Анализ трудов в этой области за последнее десятилетие показал, что достигнуты значительные теоретические результаты и в задачах параметрического, и в задачах непараметрического распознавания. Но многие из разработанных методов при хорошем теоретическом обосновании дают неприемлемые результаты при решении прикладных практических задач. Связано это с условными ограничениями и допущениями, принимаемыми исследователями при разработке методов классификации. Как правило, априорно принимается гипотеза о принадлежности функции плотности вероятности признаков какому-либо параметрическому семейству. Также, в большей части оптимальных теоретических методах априорно принимается гипотеза о статистической независимости

выбранной системы признаков. В результате оценки вероятностей ошибок, получающихся при параметрическом распознавании, носят асимптотический характер, встречающийся на практике лишь в редких случаях при условно неограниченной длительности обучающих выборок. Однако для некоторых частных ситуаций, когда математические модели оказываются подходящими для той или иной практической задачи, удается получить приемлемые результаты [1]. Весомый вклад в развитие решения проблемы поиска устойчивых информативных признаков при решении задач распознавания внесли: Сойфер В.А., Омельченко В.А., Ту Дж., Гонсалес Р., Вудс Р., Ярославский Л.П., Ковалевский В.А., Фомин Я.А., Тарловский Г.Р., Сенин А.Г., Киселев Н.В. и др. В работах этих авторов отражено, что эффективными признаками при классификации (распознавании) изображений являются моментные функции, корреляционные, а также спектральные, обладающие инвариантностью к различного рода преобразованиям.

Весь спектр решаемых при распознавании изображений задач условно можно представить в виде двух групп:

1. классификация изображений,
2. поиск и распознавание объекта на изображении (специфических локальных областей).

Это разделение связано с особенностями реализации процесса распознавания. В первой группе задач распознавание или классификация производится для всего изображения целиком. То есть, все изображение целиком в процессе распознавания относят к одному из нескольких классов. Решением задачи распознавания в этой группе является реализация отображения: изображение — номер класса. Следуя разбиению процесса распознавания на два этапа, указанное отображение реализуется в виде следующих двух отображений: отображения изображение—признаки и отображения признаки—класс. Это позволяет представить процесс решения задачи классификации изображения в виде схемы, приведенной на рисунке В.1, которая является традиционной и стандартной для задач распознавания образов.




Рисунок В.1 – Структурная схема решения задачи распознавания

Примером задач первой группы являются задачи распознавания лиц по фотографиям, распознавания дактилоскопических отпечатков, диагностики заболеваний по снимку того или иного человеческого органа и т.д.

В задачах второй группы процесс распознавания оказывается включенным в более общую технологию обработки изображения, связанную с поиском распознаваемых геометрических объектов на всей области наблюдения. Объекты в данной ситуации представляют собой относительно небольшие локальные области, появление которых может произойти в любой точке изображения. Причем информация о том: имеются ли объекты на изображении, каково их количество, ориентация, размеры и т.д., чаще всего отсутствует.

Результатом решения задачи распознавания в этой ситуации является не только класс найденного объекта, но также и его характеристики: положение, возможно размер, цвет, ориентация объекта в плоскости изображения и т.д.

Примером задач второй группы являются задачи дешифрирования аэрокосмических снимков, автоматического чтения текстов, нахождения локальных патологий на медицинских снимках и многие другие. Неопределенность в целом ряде характеристик объектов делает задачу их поиска и распознавания на изображении в математическом и вычислительном плане более сложной по сравнению с задачами первой группы. Это приводит к тому, что процесс ее решения не укладывается в приведенную схему, а производится в соответствии со схемой, в упрощенном виде представленной на рисунке В.2, то есть включает в себя трудно формализуемую задачу выделения фрагментов («областей интереса»).

В соответствии с данной схемой анализу подвергается каждый фрагмент на изображении [64]. По текущему фрагменту, выделенному окном обработки, производится формирование признаков и классификация. В зависимости от результатов классификации происходит расчет дополнительных параметров объекта.

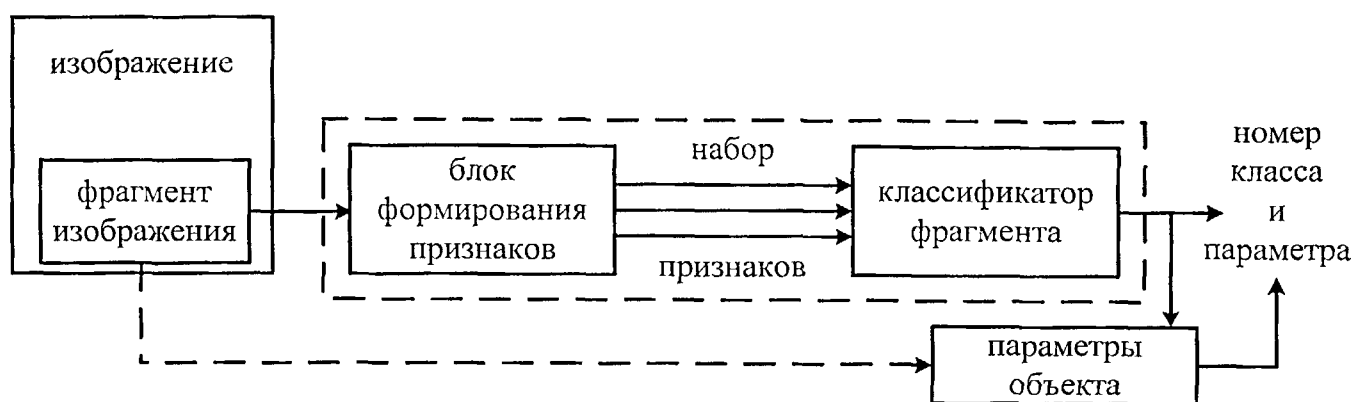


Рисунок В.2 – Структурная схема поиска и распознавания фрагментов на изображении

Легко заметить, что схема решения задачи классификации изображения входит как составной элемент в схему решения задачи поиска и распознавания. Действительно, в более широком понимании задачи второй группы относятся к группе задач высокого уровня — задачам анализа наблюдаемого изображения или сцены. Под анализом сцены в данном случае понимается составление полного описания изображенных на снимке предметов с указанием их местоположения и взаимного расположения. В то же время следует заметить, что нередко наблюдается и противоположная ситуация, когда методы и технологии решения задач второй группы выступают в качестве составных элементов решения задач первой группы. Так, например, один из методов решения задачи распознавания людей по фотографиям их лиц заключается в нахождении на изображении ярко выраженных областей интереса: глаз, носа, губ и т.д., и их последующего описания [2, 83].

Основой для решения такого круга задач является теория распознавания образов, которая особенно активно развивается в связи с созданием систем искусственного интеллекта.

В рассматриваемом нами случае, носящем с точки зрения теории распознавания образов прикладной характер, образом является изображение.

Принятый подход к распознаванию образов заключается в классификации на множестве признаков, вычисляемых по наблюдаемому изображению. Можно также сказать, что классификация образов заключается в отображении пространства признаков в пространство решений. При таком подходе распознавание образов включает две задачи:

- отбор и упорядочивание признаков;
- собственно классификация.

Задача отбора и упорядочивания признаков трудно формализуема. Критерием отбора и упорядочения является степень важности признаков для характеристики образов.

Задача классификации – принятия решения о принадлежности образа тому или иному классу на основе анализа вычисленных признаков – имеет целый ряд строгих математических решений в рамках детерминистического и вероятностного подходов.

Для того чтобы осуществить классификацию, необходимо отобрать признаки. Здесь возможны самые различные подходы [31]. Однако построение описания изображения на основе его представления с использованием признаков – едва ли не самая сложная задача в процессе построения любой системы распознавания. Все эти доводы и послужили предпосылками для появления настоящей работы.

Цель работы. Повышение эффективности решения задачи распознавания фрагментов на полутонных изображениях на основе сформированного набора инвариантных признаков в условиях непараметрической априорной неопределённости и ограниченного объема обучающих выборок.

Решение поставленной задачи проводится в несколько этапов.

1. Разработка и построение математических моделей сигналов полутонных изображений, позволяющих представить их в виде одномерных реализаций случайных процессов.

2. Синтез решающего правила при непараметрической априорной неопределенности, реализованного на основе аппроксимации функции правдоподобия.

3. Выбор системы признаков и разработка алгоритма формирования признаков с использованием метода стохастического кодирования сигналов. На основании системы признаков сформировать обучающие выборки фрагментов полутонных изображений различных классов.

4. Исследование зависимости эффективности классификатора от времени обучения и распознавания, и размерности признакового пространства.

5. Исследование показателей качества и сложности разработанных алгоритмов при решении задач распознавания изображений в составе распознающих систем.

6. Численный эксперимент на ЭВМ, для исследования показателей качества разработанных алгоритмов при классификации изображений.

Актуальность. Задача классификации (распознавания) фрагментов на полутонных изображениях является одной из основных при реализации систем автоматического распознавания, наблюдения и сопровождения, а также при создании различных систем технического зрения для автономных робототехнических систем, поэтому разработка алгоритмов классификации изображений является актуальной.

Научная новизна. В работе был получен ряд новых результатов:

1. Разработан алгоритм преобразования оцифрованных сигналов полутонных изображений объекта в одномерные реализации случайных процессов, подлежащих классификации.

2. Предложена методика синтеза решающего правила при непараметрической априорной неопределенности относительно закона распределения класси-

фицируемой выборки, позволяющего минимизировать использование априорных сведений о функции правдоподобия классифицируемых объектов.

3. Разработан алгоритм формирования системы эффективных признаков, использующий реализации преобразованных сигналов полутонных изображений.

4. Получены оценки зависимости эффективности предложенного алгоритма классификации реализованных сигналов полутонных изображений от времени обучения и распознавания, от вида опорных распределений и размерности признакового пространства, позволяющие свести ошибку классификации к минимуму.

5. Вычислены и произведены сравнения оценок показателей сложности для разработанного алгоритма с известным алгоритмом формирования систем признаков.

6. Сформулированы условия целесообразности использования в системах распознавания изображений разработанных алгоритмов.

Практическая значимость и внедрение результатов работы. Разработанный алгоритм нелинейного классификатора (НК) по методу собственных областей класса (МСОК) с использованием стохастического кодирования имеет преимущество в 10...20% по суммарной вероятности ошибки распознавания над известным методом алгоритмом по методу k-ближайших соседей при определённых условиях. Научные и практические результаты были использованы в рамках темы «Стенд функционального контроля оптико-электронной системы слежения (СФКОЭСС)» отделом 15 НКБ «МИУС» (г. Таганрог) по договору 315077. Результаты диссертации были использованы при выполнении НИОКР в ФГУП «ТНИИС» при разработке устройств машинного распознавания графических образов динамики развития излучения радиоэлектронных средств. Диссертационная работа выполнялась в рамках госбюджетной работы «Разработка методов моделирования радиоэлектронных средств для информационно-телекоммуникационных систем повышенной эффективности» (Г/б 11056/Г). Результаты работы представлены в виде программ непараметрической обработки

шумоподобных сигналов на ЭВМ. Отдельные результаты работы были использованы в учебном процессе кафедры Радиоприемных устройств и телевидения Государственного автономного образовательного учреждения высшего профессионального образования «Технологический институт Южного федерального университета в г. Таганроге», в курсах «Устройства приема и обработки сигналов» и «Основы компьютерного проектирования».

Достоверность изложенного подтверждается результатами экспериментальных исследований характеристик предлагаемых алгоритмов при классификации моделей сигналов фрагментов на полугонных изображениях в виде одномерных реализаций случайных процессов с заданными статистическими характеристиками, апробацией на научных семинарах, конференциях, актами внедрения.

Методы исследования базируются на использовании методов теории вероятности и математической статистики, численных методов, статистической теории распознавания образов и принятия решений.

Основные положения, выносимые на защиту, следующие:

- предложена методика преобразования оцифрованных сигналов полугонных изображений объекта в одномерные реализации случайных процессов, подлежащих классификации;
- разработана методика синтеза решающего правила при непараметрической априорной неопределенности относительно закона распределения классифицируемой выборки, реализованная на основе аппроксимации функции правдоподобия;
- предложена методика формирования системы эффективных признаков, использующая реализации преобразованных сигналов полугонных изображений для сокращения времени обучения и распознавания;
- установлено, что эффективность предложенного алгоритма классификации реализованных сигналов полугонных изображений зависит от времени обучения и распознавания, от вида опорных распределений и размерности при-

знакового пространства, позволяющие свести ошибку классификации к минимуму;

– сформулировано условие целесообразности использования в системах распознавания фрагментов на полутоновых изображениях разработанных алгоритмов, зависящее от объема выборок, используемых для обучения.

Апробация работы. Основные положения диссертационной работы обсуждались и докладывались: Международной научной конференции «Методы и алгоритмы принятия эффективных решений (МАПР-2009)» (Таганрог, 2009 г.); Всероссийской научной конференции «Современные исследовательские и образовательные технологии (СИОТ-2010)» (Таганрог, 2010 г.); X Всероссийской научной конференции студентов и аспирантов «Техническая кибернетика, радиоэлектроника и системы управления-2010 (КРЭС-2010)» (Таганрог, 2010 г.); Международной научной конференции «Информационное общество: идеи, технологии, системы-2010 (ИНФО-2010)» (Таганрог, 2010 г.); 56-й научно-технической конференции профессорско-преподавательского состава (Таганрог, 2011 г.); 13-й международной конференции «Цифровая Обработка Сигналов и её Применение» (DSPA-2011), (Москва, 2011 г.); Всероссийской научно-технической конференции с международным участием: «Компьютерные и информационные технологии в науке, инженерии и управлении» («КомТех-2011»), (Таганрог, 2011 г.).

Публикации. Основные научные результаты диссертации опубликованы в 9 печатных работах [23, 24, 25, 63, 64, 65, 66, 67, 68].

Структура и объем диссертации. Диссертационная работа состоит из введения, четырех глав, заключения и приложений.

Работа изложена на 178 стр. текста, 40 рисунках, 4 таблицах, а также содержит список литературы из 97 наименований и приложений.

Во введении сформулирована цель работы и обоснована актуальность решаемой задачи.

В первой главе проведен анализ подходов применяемых при разработке алгоритмов распознавания сигналов изображений, реализуемых на основе ме-

тодов статистической теории распознавания сигналов. Рассмотрены принципы формирования эффективных признаков по изображению, а также требования предъявляемые к ним.

Проведен анализ методов распознавания сигналов, при этом установлено, что большинство методов распознавания и способов оценки вероятностей ошибок распознавания разработаны для случаев неограниченного объема обучающих и контрольных выборок. Рассмотрены статистические методы распознавания, а также проанализированы основные этапы статистического распознавания:

- формирование признакового пространства;
- обучение системы распознавания;
- принятие решений.

Сформулирована постановка задачи формирования эффективных признаков пространств и решающих правил, для систем распознавания сигналов изображений, работающих в условиях априорной неопределенности относительно вида распределения плотности вероятности распознаваемых сигналов и ограниченных объемов обучающих и контрольных выборок.

Произведена постановка задачи исследования возможности оптимизации временных и пространственных параметров проектируемых систем распознавания, обеспечивающих заданный уровень достоверности распознавания, при заданных ограничениях.

Во второй главе произведено обоснование выбора в качестве объекта исследования сигналов изображений, преобразованных в одномерные реализации случайных процессов, статистические характеристики которых могут служить, как отмечено в литературе, эффективными признаками при решении задачи их классификации. Ввиду чрезвычайной сложности и высокой вариабельности характеристик сигналы изображений обладают свойством обобщения, т.е. результаты, полученные для систем распознавания сигналов изображения, могут быть перенесены и на другие, например технические системы диагностики.

Рассмотрены и предложена математическая модель изображения, представляющая изображение как случайный процесс функции яркости. Наиболее часто пользуются моделью изображения, являющейся аппликативно аддитивной смесью, предложенной Нахи. Эта модель, позволяет учитывать статистические свойства изображений объекта и фона, а также вероятности перехода элементов изображения «фон-объект» и «объект-фон». Однако, данная модель эффективна при решении задач определения координат центров изображений протяженных световых объектов и сопровождения динамических изображений объектов. В случае классификации статических изображений протяженных объектов может быть использована более простая модель изображений, где изображение представляется аддитивной смесью сигнала и шума.

Предложен новый подход к классификации сигналов полутонных изображений, основанный на переходе от двумерного представления изображения к системе одномерных реализаций. Суть подхода состоит в представлении изображения как системы выборочных строк в пределах одного кадра. Строки выбираются на изображении протяженного объекта через одинаковый интервал Δi , число строк на изображении может варьироваться. Для увеличения длины реализации формируемого процесса, выбираются эти же строки в последующих кадрах.

В качестве моделей сигналов изображений, предназначенных для исследования эффективности алгоритмов классификации, предлагается использовать стационарные процессы, получаемые с использованием стохастического кодирования одномерных реализаций из системы выборочных строк.

Выбраны методы нормализации анализируемых изображений, в частности яркостная нормализация и нормализация по площади протяженных объектов на изображениях. При нормализации протяженных объектов по площади предложено использование численного метода Монте-Карло.

Предложена методика синтеза решающего правила при непараметрической априорной неопределенности относительно закона распределения классифицируемой выборки.

Для формирования системы признаков выбран оператор неизоморфного преобразования исследуемых сигналов, обеспечивающий «сжатие» исходных сигналов при сохранении (в смысле заданного критерия) информации о разделении распознаваемых классов сигналов. Определены статические характеристики оператора преобразования, которые необходимы для построения разделяющих поверхностей в пространстве неизоморфных моделей сигналов и оценок вероятности правильной классификации.

Анализ существующих методов оптимизации систем распознавания показал, что в достаточной мере эти методы разработаны только для случая параметрической априорной неопределенности и статистической независимости выбранной системы признаков, что крайне редко встречается в практических задачах диагностики. Поэтому необходимо использовать методы непараметрической классификации и методы оптимизации временных и пространственных параметров классификатора.

В третьей главе выбран метод формирования классификационных признаков (метод стохастического кодирования сигналов), основанный на использовании функционала нелинейного преобразования первичных признаков пространств, выбранного во втором разделе. Данный метод строится на принципах измерения корреляционных моментов преобразованных сигналов (процессов) с помощью функций знаковой корреляции.

Предложен метод формирования классификационных признаков и построение на их основе решающих правил, основанный на использовании функционала нелинейного преобразования первичных признаков пространств.

Показано, что при использовании метода стохастического кодирования возрастает дисперсия оценок измеряемых моментов, однако при этом достигаются следующие положительные результаты: сокращается избыточность описания исходных процессов, подлежащих распознаванию; упрощается реализация алгоритма распознавания в микропроцессорных системах за счет применения одноразрядного квантования, дающего на выходе только знаки отсчетов.

Разработан алгоритм непараметрической классификации случайных процессов по методу собственных областей класса (МСОК), использующий в качестве признаков корреляционные моменты знаковых последовательностей, сформированных на основе метода стохастического кодирования. В качестве опорных сигналов используются случайные процессы с некоррелированными отсчетами.

Методами цифрового моделирования найдены зависимости математических ожиданий и среднеквадратических отклонений признаков от вида и количества опорных распределений и от времени обучения и классификации.

Разработана структурная схема предлагаемого непараметрического классификатора по МСОК, а также алгоритмы процедур обучения и классификации.

В четвертой главе рассмотрены вопросы моделирования алгоритма непараметрической классификации МСОК на ЭВМ. В результате моделирования работы классификатора МСОК при классификации случайных процессов с одинаковыми одномерными плотностями распределения вероятностей и различными корреляционными функциями, определены значения суммарных вероятностей ошибки классификации при различных объемах обучающих и контрольных выборок и различных размерах признакового пространства.

Установлено, что алгоритм классификации с формированием собственных областей распознаваемых классов эффективно работает при объемах обучающих наблюдений признаков, начиная от 10...20, при однократной процедуре предъявления контрольной выборки. Алгоритм целесообразно применять только при больших количествах распознаваемых классов, то есть в случае, когда построение разделяющих поверхностей на основе функций правдоподобия приводит к значительным вычислительным затратам.

Получена зависимость оценок суммарных вероятностей ошибки классификации от числа объектов обучения по классам.

Из приведенных зависимостей установлено, что при критически низком количестве объектов обучения (менее 8-10) алгоритм по методу k ближайших соседей значительно проигрывает разработанному алгоритму в показателях ве-

роятностей правильной классификации. Однако при увеличении количества объектов обучения (более 15-20) алгоритм по методу k ближайших соседей имеет преимущества, заключающихся в более высоких вероятностях правильной классификации по сравнению с разработанным алгоритмом по МСОК.

Определены также вероятности ошибки при классификации изображений принадлежащих четырем различным объектам. Получены матрицы перепутывания.

Результаты экспериментов показывают, что разработанные алгоритмы могут иметь область применения, выходящую за рамки исследования сигналов изображений. Они также могут быть использованы в любых системах диагностики, где объектом исследований являются шумоподобные сигналы.

Разработаны комплексы программ осуществляющих классификацию реальных изображений, а также случайных процессов, которые внедрены в учебный процесс.

В заключении сформулированы основные научные и практические результаты работы.

Приложение к диссертации содержат листинги программ расчета характеристик и алгоритмов работы устройств непараметрической обработки случайных процессов, а также результаты экспериментального определения характеристик работы непараметрических классификаторов при обработке изображений. Программы представляют собой рабочие документы пакета для математического моделирования Matlab. Данные программы легко могут быть использованы, например в учебно-методических целях. В приложении также содержатся копии актов внедрения результатов диссертации на ряде предприятий и использования результатов исследований в учебном процессе кафедры Радиоприемных устройств и телевидения Технологического института ЮФУ в г. Таганроге.

1 ПОСТАНОВКА ЗАДАЧИ ИССЛЕДОВАНИЯ И АНАЛИЗ ИЗВЕСТНЫХ МЕТОДОВ

1.1 Постановка задачи выбора математической модели сигнала лутонового изображения.

Под математическим моделированием понимают адекватную замену исследуемого объекта или явления (процесса) соответствующей математической моделью (ММ) и ее последующее изучение методами вычислительной математики с привлечением средств современной вычислительной техники. Изучение ММ можно рассматривать как проведение эксперимента на ЭВМ посредством вычислительно-логических алгоритмов. Поэтому в научно-технической литературе термин вычислительный эксперимент принято считать синонимом термина математическое моделирование.

Реализация на практике возможностей математического моделирования и вычислительного эксперимента значительно увеличивает эффективность и экономическую выгоду как в области теоретических, так и в области практических разработок.

В качестве примера можно привести, как одну из возможных, условную схему основных этапов математического моделирования [43] (рисунок 1.1):

I этап – неформальный переход от рассматриваемого исследуемого объекта (ИО) (или исследуемого явления – ИЯ) к его концептуальной модели (КМ). В зависимости от исследуемой области и конечной цели вычислительного эксперимента акцентируют те свойства и особенности ИО (ИЯ), с учётом характеризующих их параметров, которые должны отразиться в КМ. Или, наоборот, допускают упрощения, позволяющие не учитывать несущественные для КМ качества ИО (ИЯ) в конкретном случае. Проведение первого этапа в значительной мере зависит от профессионального уровня исследователя. Полнота и правильность учёта свойств ИО (ИЯ) в КМ, существенных с точки зрения поставленной цели исследования, являются основной предпосылкой для получе-

ния достоверных результатов математического моделирования. В другом случае, при значительной идеализации ИО (ИЯ) для получения более простой КМ, можно скомпрометировать все последующие этапы исследования.

II этап – формальное, математическое описание КМ, устанавливающее связь между параметрами, характеризующими КМ ИО (ИЯ). Это и называют ММ.

III этап – качественный и оценочный количественный анализ построенной ММ, в ходе которых выявляются противоречия, ликвидация которых потребует уточнения или пересмотра ИО (ИЯ) (штриховая линия на рис. 1.1). Итог анализа на рассматриваемом этапе – это обоснованный выбор рабочей ММ ИО (ИЯ), подлежащей в дальнейшем детальному количественному анализу. Успешность проведения этого этапа зависит, как правило, от глубины понимания связи отдельных составляющих ММ со свойствами ИО (ИЯ), нашедшими отражение в его КМ.

IV этап – обоснованный выбор метода количественного анализа ММ, в разработке эффективного алгоритма вычислительного эксперимента.

V этап – создание работоспособной программы, реализующей алгоритм, разработанный на предыдущем этапе, средствами вычислительной техники.

VI этап – получаемые в итоге работы программы результаты вычислений должны прежде всего пройти тестирование путем сопоставления с данными количественного анализа упрощенного варианта ММ рассматриваемого ИО (ИЯ). Тестирование может выявить недочеты как в программе, так и в алгоритме и потребовать доработки программы или же модификации и алгоритма и программы. Анализ результатов вычислений и их интерпретация могут вызвать необходимость в корректировке КМ и соответствующей ММ.

VII этап – после устранения всех выявленных недочетов триаду «модель – алгоритм – программа» можно использовать в качестве рабочего инструмента для проведения вычислительного эксперимента.

Из последовательности основных этапов математического моделирования (рис. 1.1) следует, что определяющую роль в нем ММ ИО (ИЯ). Поэтому

прежде всего следует уделить внимание основным свойствам ММ и требованиям к ней, а также классификации ММ.

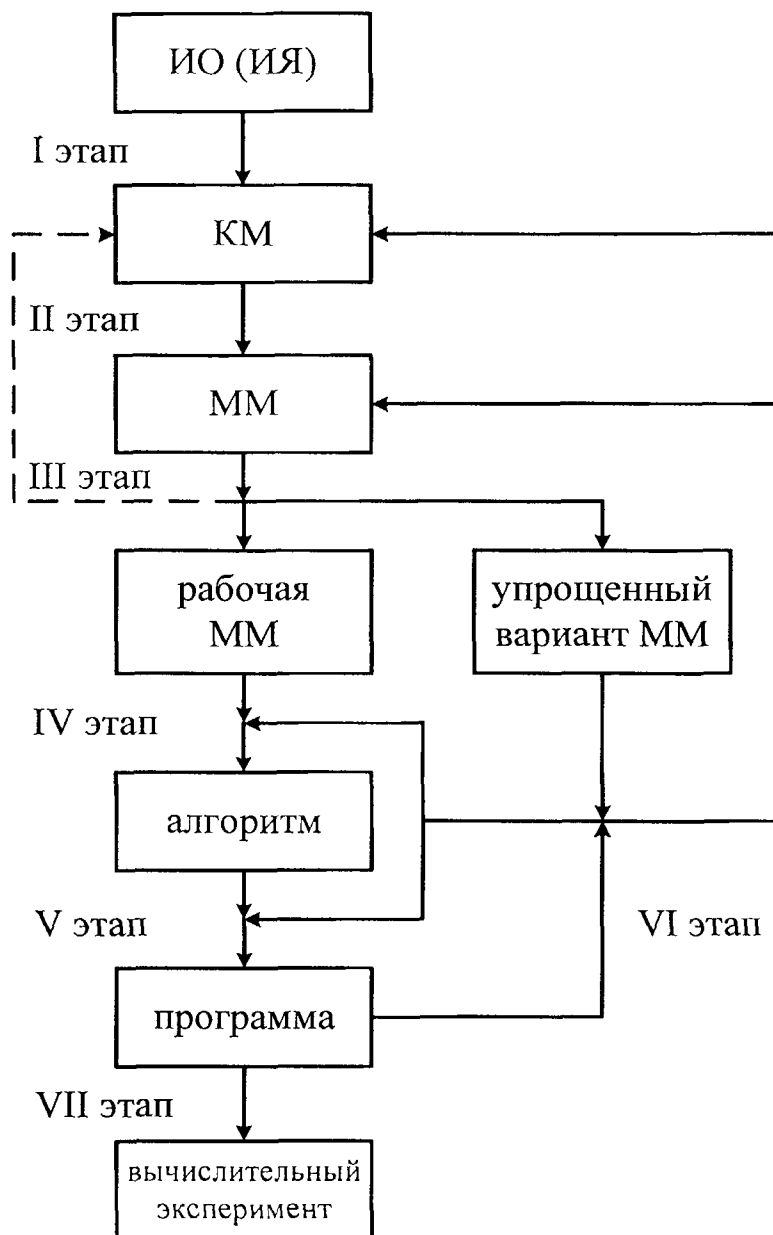


Рисунок 1.1. – условная схема основных этапов математического моделирования

В общем случае ИО (ИЯ) количественно можно охарактеризовать векторами внешних, внутренних и выходных параметров. При изучении реально существующего или мыслимого ИО (ИЯ) математические методы применяют к его ММ. Это применение будет эффективным, если свойства ММ удовлетворяют определенным требованиям. К основным свойствам ММ можно отнести:

полнота, точность, адекватность, экономичность, робастность, продуктивность и наглядность [12, 43, 50]. Конечно это далеко не полный перечень свойств для ММ. Но даже такому перечню полностью удовлетворить при создании ММ затруднительно, т.к. полнота какого-либо свойства зачастую противоречит остальным. Поэтому необходимо найти компромисс между всеми этими требованиями и вместе с тем построить оптимальную ММ для конкретной области исследования. В данной работе объектом исследования являются полутоновые двумерные изображения с 256-ю градациями яркости. Для формулировки задачи выбора ММ (в дальнейшем просто модели) ИО, прежде всего необходимо рассмотреть виды сигналов, получаемых при исследованиях, определить их качественные и количественные характеристики. Вместе с тем необходимо ограничить область рассмотрения сигналов полутоновых изображений. Совокупность сигналов, характерных для тех или иных методов распознавания, можно представить в виде разделения на две большие группы: детерминированные и стохастические [27]. С учётом доводов, приводимых в различных источниках [48, 56], можно сделать вывод, что исследуемые в данной работе сигналы как модели двумерных полутоновых изображений можно отнести к группе случайных процессов – случайные поля.

Под объектом распознавания будем понимать связанную область точек изображения, имеющую замкнутый контур и характеризующуюся некоторыми общими свойствами и закономерностями, такими как коррелированность яркости соседних пикселей, градиент температуры (для ИК систем), коэффициент отражения, закономерность движения и т. п. В общем случае, под объектом понимается множество точек, сгруппированных около условно принятого центра.

Модель объекта на полутоновом изображении может представляться двумя видами: в виде точки, т.е. представление объекта охватывает не более десятка элементов разложения, такой объект принято называть точечный световой объект, в другом случае если объект представлен более чем 12-15 элементами, то его следует трактовать как протяженный световой объект.

В данной работе будем рассматривать протяженный световой объект (ПСО), в отличие от точечного, обладающего индивидуальными информативными признаками, в том числе и произвольным выбором информативной точки. Существует довольно много математических моделей полутонных изображений, но как было сказано ранее, все они направлены на решение определенной поставленной задачи. Коротко рассмотрим наиболее часто используемые модели видеосигнала при решении задачи распознавания объекта. Если наблюдаемый объект расположен на переднем плане и составляющие фона не затемняют изображение объекта, наиболее адекватной является модель, предложенная Агарвалом (Aggarval) [53, 54].

В этом случае видеосигнал представляется аппликативной смесью сигналов от изображений объекта и фона, аддитивного шума и представляется в виде:

$$Z(i, j, t) = A \cdot S(i, j, \lambda(k)) + f_C(i, j, \lambda(k)) \cdot S_B(i, j) + n(t), \quad (1.1)$$

где A – максимальное значение яркости изображения объекта; $S(i, j, \lambda(k))$ – сигнальная функция изображения объекта $(i, j) \in (\Omega_C \subset \Omega)$; (i, j) – текущие координаты изображения; $\lambda(k) = [\lambda_1, \dots, \lambda_h]^T$ – h -мерный вектор информативных параметров объекта, определяющий полезное сообщение; $S_B(i, j)$ – сигнальная функция яркости фона, в общем случае случайная положительная функция с известным средним m_B и среднеквадратическим отклонением (СКО) σ_B ; Ω и Ω_C – соответственно размеры анализируемой сцены и изображения объекта; $f_C(i, j, \lambda(k))$ – весовая функция, осуществляющая затемнение фона в месте положения объекта $f_C(i, j, \lambda(k)) = \begin{cases} 0, & i, j \in \Omega_C \\ 1, & i, j \in \Omega - \Omega_C \end{cases}$; $n(t)$ – некоррелированный по пространству и времени гауссов белый шум с нулевым средним значением,

спектральной плотностью N_0 и дисперсией $\sigma_0^2 = N_0 \cdot \Delta f$, Δf – полоса частот видео усилителя.

Простота, наглядность и явный физический смысл этой модели очевидны. Однако она недостаточно адекватна для сложных сцен и малоконтрастных объектов. Так, если объект расположен на заднем плане, то отдельные части (элементы, пиксели) его полутонового изображения могут затеняться близко расположенными элементами фона. При малоконтрастных динамических сценах принадлежность каждой точки полутонового изображения объекту или фону является случайной, а их классификация носит статистический характер.

В этом случае наиболее удобной является модель полутонового изображения в виде аппликативно аддитивной смеси, предложенной Нахи. Это более тонкая модель, так как она позволяет учитывать статистические свойства изображений объекта и фона, а также вероятности перехода элементов полутонового изображения «фон-объект» и «объект-фон».

В этом случае видеосигнал имеет вид:

$$Z(i, j, k) = A \cdot S(i, j, \lambda(k)) \cdot f_c(i, j, \lambda(k)) + [1 - f_c(i, j, \lambda(k))] \cdot S_B(i, j, k) + n(k), \quad (1.2)$$

где $Z(i, j, k)$ – значение видеосигнала в (i, j) точке изображения в k кадре; $S(i, j, \lambda(k))$ и $S_B(i, j, k)$ – соответственно видеосигнал точек изображений, принадлежащих объекту и фону; $n(k)$ – белый шум, не коррелированный по пространству и времени, с нулевым средним, среднеквадратическим отклонением σ_0 и спектральной плотностью N_0 ; $f_c(i, j, k)$ – случайная величина с дискретным распределением $P(f_c(i, j, k)) = P(f_c(i, j, k), 1 - f_c(i, j, k))$, где $f_c(i, j, k)$ – вероятность принадлежности точки изображения с координатами (i, j) объекту и, соответственно, $(1 - f_c(i, j, k))$ – фону [53, 54].

Однако, эти модели полутоновых изображений хороши в случае решения задачи сопровождения и определения координат динамического или стати-

ческого протяженного светового объекта. В нашем случае мы решаем задачу классификации сигналов полутоновых оцифрованных статических изображений и не затрагиваем вопросов связанных с сопровождением объекта и определения его координат, поэтому предлагается в качестве модели сигналов полутоновых изображений использовать аддитивную смесь сигнала и шума

$$Z(i, j) = A(i, j) + n(t), \quad (1.3)$$

где $A(i, j)$ – значение сигнала яркости в точке (i, j) ; $n(t)$ – белый шум, некоррелированный по пространству и времени, с нулевым средним $m_0 = 0$, среднеквадратическим отклонением σ_0 .

Такая модель является наиболее адекватна при решении задачи классификации сигналов полутоновых изображений, в виду того что анализу сразу подвергается вся фоно-целевая сцена анализируемого протяженного объекта [68].

1.2 Анализ методов формирования решающих правил

1.2.1 Формирование признаков по полутоновому изображению

Формирование признаков – первый этап в любой системе распознавания образов. На качество всей системы оказывает влияние то, насколько хорошо выбрана система признаков для описания объекта – в данном случае полутоновые изображения.

Задача формирования признаков достаточно сложна, потому что процесс описания полутонного изображения, или построения набора признаков, до настоящего времени остается процедурой эвристической, во многом зависимой от опыта и квалификации разработчика. В связи с этим при разработке каждой новой системы распознавания чаще всего даже специалистам в распознавании об-

разов приходится решать ее заново, ориентируясь на специфику обрабатываемых полутоновых изображений и изображенных на них объектов [56, 92].

Основным требованием к используемой системе признаков анализируемого полутонового изображения является требование эффективности процесса распознавания. Это требование часто имеет ряд противоречивых аспектов, на которые рассмотрим ниже.

Во-первых, оно предъявляет к признакам требования вычислительного характера. Они заключаются в том, чтобы существовал алгоритм расчета признаков, и этот алгоритм был вычислительно эффективен. Необходимость первого требования обусловлена тем, что разработка любой системой распознавания происходит, как правило, в рамках некоторого лимита «ценового» ресурса. Это ограничивает возможности использования ряда средств формирования признаков. Например, подобное ограничение в области распознавания полутоновых изображений может отразиться на возможности использования видеоаппаратуры, регистрирующей цветные изображения, либо обеспечивающей повышенную разрешающую способность. Второе требование вытекает из необходимости удовлетворения определенным временным ограничениям, накладываемым на процесс распознавания в целом. Это требование достаточно типично для систем распознавания в реальном времени, в частности, для бортовых систем дистанционного зондирования, систем оперативного контроля и других.

Во-вторых, требование эффективности распознавания накладывает определенные требования на значения признаков. А именно, для объектов различных классов значения признаков должны отличаться сильнее, чем для объектов одного класса. Это требование иногда интерпретируют как требование компактности описания класса в пространстве признаков, когда образы объектов одного класса в пространстве признаков образуют компактные области – кластеры или таксоны. Это не совсем корректно, так как на требование «различия» или «близости» значений признаков следует смотреть с точки зрения используемого при распознавании классификатора – решающего правила. В то же

время компактность образов, в случае ее достижимости, позволяет существенно упростить процедуру классификации и сделать ее более устойчивой.

В-третьих, требование эффективности распознавания приводит к необходимости удовлетворения требования устойчивости или инвариантности образа (изображения) к ряду возможных искажений объекта. Кроме того, процесс регистрации сцены приносит дополнительные искажения, связанные с неидеальностью приборов регистрации, изменением освещенности, шумами и т.д. На практике это приводит к изменению изображения объекта и, следовательно, изменению его образа в пространстве признаков [70, 71, 97]. Последнее в общем случае может повлиять на результаты классификации и, следовательно, эффективность системы в целом. Следует отметить, что, если характер требований эффективности признаков, существования методов их расчета и наличия быстрых алгоритмов их вычисления часто зависит от специфики решаемой задачи, то требование инвариантности для целого ряда практических задач распознавания на изображениях оказывается достаточно общим. В частности, оно подразумевает все или некоторые из следующих требований:

1. инвариантность к шумовым и динамическим искажениям;
2. инвариантность к яркостным искажениям (изменению яркости и контраста);
3. инвариантность к изменению местоположения объекта;
4. инвариантность к изменению масштаба объекта;
5. инвариантность к изменению ориентации объекта (к повороту объекта в плоскости изображения);
6. инвариантность к изменению ракурса съемки объекта (для трехмерных объектов).

Инвариантность к указанным искажениям в общем случае достигается за счет предварительного преобразования исходного полутонового изображения. В частности, первая группа искажений, связанная с шумовыми и динамическими изменениями изображения, устраняется за счет использования методов и алгоритмов восстановления. Яркостные искажения, относящиеся ко второй

группе, эффективно могут быть устранены за счет приведения изображения к «нормализованному» виду [56, 91, 32].

Рассматриваемые в п.1.1 модели основаны на принципе укрупнения описания сигналов, имеющих стохастическую природу. Согласно этому принципу исходный сигнал заменяется сигналом существенно меньшей размерности (при сохранении в заданных пределах эффективности систем классификации) на основе преобразования исходного многомерного пространства сигнала (пространства признаков) в пространство функционалов со значительно меньшей размерностью [22]. Это позволяет сформировать в пределах признакового пространства укрупненных координат новый сигнал с помощью динамической интерполяции, заключающейся в сравнении исходного сигнала и некоторым изменяющимся порогом и выборе из результата старшего (знакового) разряда в качестве значащего [30]. Выбор надлежащей модели производится на основе целей диагностической системы в соответствии с комплексным критерием эффективности модели, включающем значения мер адекватности, функциональной устойчивости к помехам и сложности модели [26].

Представление исследуемых сигналов в виде совокупности признаков или точек в признаковом пространстве позаимствовано из концепции геометрической модели описания сигналов. Эти типы моделей, наряду с другими (лингвистические, алгебраические), достаточно хорошо исследованы с точки зрения их применимости для решения широкого круга задач распознавания.

К настоящему моменту уже построено достаточно большое количество моделей, используемых при решении задач распознавания образов. Многие из этих моделей базируются на геометрическом представлении и интерпретации характеристик образов, подлежащих распознаванию, как координат в пространстве признаков [15, 41, 46, 78, 85]. Так или иначе все эти модели связаны с попыткой либо узнать вид геометрической структуры распределения объектов распознаваемых образов, либо зная эту структуру, попытаться максимально снизить размерность задачи до той степени, где начинает работать классическая теория статистических решений.

Согласно геометрической концепции представления сигналов каждое измерение признаков может быть представлено в r -мерном пространстве в виде точки A_i с координатами $(x_{1i}, x_{2i}, \dots, x_{pi})$ или направленного отрезка, соединяющего начало координат $(0, 0, \dots, 0)$ с точкой $A(x_{1i}, x_{2i}, \dots, x_{pi})$ этого пространства, как показано на рисунке 1.2.




Рисунок 1.2 – Геометрическое представление объекта (в виде точки) в r -мерном признаковом пространстве

Выбор пространства и действующей в нем метрики оказывает влияние на модель и постановку задачи. Если задана числовая функция, которая каждой паре точек пространства ставит в соответствие расстояние между ними (метрикой пространства), пространство называют метрическим [15]. Как правило, для геометрического представления объектов используют евклидово пространство, что не в последнюю очередь определяется возможностью интерпретации результатов по аналогии с трехмерным физическим пространством, воспринимаемым органами чувств человека и более привычно для образного восприятия.

В евклидовом пространстве расстояние между двумя точками этого пространства, вычисляется по формуле

$$d = \sqrt{(x_{1i} - x_{1j})^2 + (x_{2i} - x_{2j})^2 + \dots + (x_{pi} - x_{pj})^2}, \quad (1.4)$$

где x_i и x_j - различные объекты в признаковом пространстве.

Использование других пространств (Лобачевского, Банахова и пр.) является столь же правомерным, однако для перехода к модели явления в неевклидовом пространстве необходимо иметь достаточно высокий уровень априорной информации, оправдывающий необходимость такого перехода.




Рисунок 1.3 – Отображение множества объектов двух классов в p -мерном признаковом пространстве

Таким образом, каждый объект A может быть представлен точкой A в p -мерном евклидовом пространстве, либо вектором x , соединяющим начало координат с этой точкой. Декартовы координаты конца вектора (точка A) есть действительные числа x_1, x_2, \dots, x_p , являющиеся признаками объекта A . Любой совокупности объектов A_i ($i = 1 \dots n$) может быть однозначно поставлена в соответствие совокупность точек A_i в многомерном пространстве, которая описывается матрицей координат X .

Вся совокупность точек A_i может быть ограничена некоторой многомерной областью пространства. Если производится описание объектов нескольких классов (имеющих объективные различия), то каждому из классов соответствует некоторая область в выбранном пространстве признаков, как показано на рисунке 1.3.

Если многомерные фигуры, ограничивающие области Ω_m , не пересекаются друг с другом, то задача распознавания сводится к задаче различения или идентификации, т.к. попадание объекта в одну из областей Ω_m позволяет делать однозначный вывод о принадлежности исследуемого объекта.

При пересечении Ω_m образуются зоны неоднозначности решения задачи классификации. Точки A_i многомерного пространства, принадлежащие зонам пересечения могут порождаться различными классами объектов с отличной от нуля вероятностью. Наличие этих зон, обуславливающих ошибки классификации объектов, можно объяснить неполным описанием объектов и использованием конечного набора признаков. При этом часть информации, используемой для классификации исследователем не учитывается, некоторую часть не удается измерить либо описать формально, а часть информации отбрасывается при обработке.

Необходимо отметить, что при решении задач распознавания образов с использованием геометрических моделей опираются на основополагающую гипотезу о компактности образов [1, 11, 73]: простому образу соответствует компактное множество точек в признаковом пространстве. При этом предполагается, что: 1) всегда возможен непрерывный переход от одного объекта к другому внутри данного образа так, что и промежуточные объекты будут восприниматься как объекты этого же образа, и, наоборот, от объектов одного образа нельзя плавно перейти к объектам другого без того, чтобы не возникли объекты с неопределенной принадлежностью; 2) при малой деформации объектов в любом направлении они не выходят за пределы данного образа.

Компактное множество – множество точек, для которого: 1) число граничных точек мало по сравнению с общим их числом; 2) любые две внутренние точки множества могут быть соединены достаточно плавной линией, проходящей только через точки того же множества; 3) почти каждая внутренняя точка имеет в достаточно обширной окрестности только точки этого же множества [15].

1.2.2 Выбор критерия эффективности системы признаков

При наличии двух или большего числа классов цель выбора признаков состоит в определении таких признаков, которые являются наиболее эффективными с точки зрения делимости классов. Делимость классов зависит не только от распределений объектов в классах, но также и от используемого классификатора [5]. Для упрощения задачи необходимо отыскать оптимальный набор системы признаков для решающего правила, построенных на основе двух решающих правил (1.5) и (1.6), описанных ниже.

Решающая функция классификатора, построенного на принципе минимума расстояния для случая единственного эталона класса

$$d_i(x) = x'm_i - \frac{1}{2} m_i' m_i, \quad (1.5)$$

где m_i – матрица математического ожидания образов i -го класса; m_i' – транспонированная по отношению к m_i матрице. В роли эталона класса выступает вектор средних значений образов, входящих в соответствующий класс.

Пусть объем собственной области класса определяется минимальным радиусом $R_{i\min}$, тогда решающее правило может быть основано на попадании (или не попадании) распознаваемого сигнала внутрь собственной области класса, охваченной радиусом $R_{i\min}$, и выглядит следующим образом:

$$\begin{cases} \sum_{i=1}^n (\bar{L}_i^* - m_{ij}^*)^2 - (R_{j\min}^*)^2 \leq 0, & x(t) \in \omega_j; \\ \sum_{i=1}^n (\bar{L}_i^* - m_{ij}^*)^2 - (R_{j\min}^*)^2 > 0, & x(t) \notin \omega_j. \end{cases} \quad (1.6)$$

Здесь L_i^* – значение оценки признака при i -м опорном распределении, ($i = 1, 2, \dots, K$); m_{ij}^* – оценка математического ожидания признака при i -м опор-

ном распределении для j -го эталона, ($j = 1, 2, \dots, M$); $x(t)$ – распознаваемый сигнал.

С теоретической точки зрения достоверность классификации является наилучшим критерием эффективности признаков. Кроме того, на практике одним из наиболее распространенных критериев является вероятность ошибки, полученная экспериментально; а именно, интуитивно выбрав набор признаков, строят классификатор и экспериментально подсчитывают число ошибок классификаций. Эта процедура является гибкой, не зависит от вида распределения и теоретически позволяет найти оптимальное решение. Кроме того, с точки зрения машинного времени она может успешно конкурировать с процедурами минимизации многих других критериев, которые задаются явными математическими выражениями, но оказываются сложными для минимизации.

Главный недостаток критерия вероятности ошибки заключается в том, что, за исключением очень небольшого числа частных случаев, для него не существует явного математического выражения, даже для нормальных распределений вычисление вероятности ошибки требует численного интегрирования.

Будем строить критерий разделимости двух классов в виде [5]

$$c(\omega_i, \omega_j, y_1, \dots, y_N) = c(\omega_i, \omega_j, Y_N), \quad (1.7)$$

где N случайных величин y_1, \dots, y_N используются в качестве признаков. Кроме того, предположим, что лучшей разделимости классов соответствует большее значение критерия. Также желательно, чтобы критерии удовлетворяли следующим условиям [7, 67]:

1. Монотонная связь с вероятностью ошибки. Обычно трудно выполнимое условие.

2. Монотонная связь с нижней и верхней границами вероятности ошибки. Качество критерия при этом можно оценить в соответствии с тем, как близко эти границы находятся к вероятностям ошибки.

3. Инвариантность относительно взаимно однозначных отображений: вероятность ошибки байесовского классификатора инвариантна относительно любого преобразования, сохраняющего взаимно однозначное соответствие.

4. Аддитивность по отношению к независимым признакам: если y_N взаимно независимы, то

$$c(\omega_i, \omega_j, Y_N) = \sum_{k=1}^N c(\omega_i, \omega_j, Y_k). \quad (1.8)$$

5. Метрические свойства:

$$\text{а) } c(\omega_i, \omega_j, Y_N) > 0 \text{ при } i \neq j, \quad (1.9)$$

$$\text{б) } c(\omega_i, \omega_i, Y_N) = 0, \text{ при } i = j, \quad (1.10)$$

$$\text{в) } c(\omega_i, \omega_j, Y_N) = c(\omega_j, \omega_i, Y_N), \quad (1.11)$$

$$\text{г) } c(\omega_i, \omega_j, Y_N) = c(\omega_j, \omega_i, Y_{N+1}). \quad (1.12)$$

Следует отметить, что все эти условия являются не обязательными, а желательными.

В литературе предложено несколько критериев: на основе расстояния Бхатачария [5], на основе дивергенции [3, 5], матриц рассеяния [3, 5], на основе понятия внутреннего расстояния множеств [3], минимума энтропии [1, 3, 5].

Недостатком большинства из этих методов является их сложность и необходимость знания многомерной функции плотности вероятностей признаков.

В работе [5] предложено использование в качестве критерия эффективности k -го признака при классификации классов i и j критерия Фишера

$$\Psi_{k,ij} = \frac{(m_{ki} - m_{kj})^2}{\sigma_{ki}^2 + \sigma_{kj}^2}, \quad (1.13)$$

где m_{ki} , m_{kj} – математические ожидания k -го признака для i -го и j -го класса; σ_{ki} , σ_{kj} – среднеквадратические отклонения k -го признака для i -го и j -го класса.

При распознавании двух одномерных нормальных случайных процессов, критерий (1.13) удовлетворяет условиям (1.9), (1.10), (1.11), (1.12). Построим критерий разделимости на основе выражения (1.13) для многомерных нормальных совокупностей. Так как признаки получаемые на основе метода стохастического кодирования имеют слабую корреляционную связь, то в качестве критерия разделимости можно предложить

$$c(\omega_i, \omega_j, Y_N) = \sum_{n=1}^N \frac{(m_{ni} - m_{nj})^2}{\sigma_{ni}^2 + \sigma_{nj}^2}, \quad (1.14)$$

где N – число признаков.

Выражение (1.14) удовлетворяет (1.8-1.12).

При равных (или неизвестных) дисперсиях признаков можно использовать следующее выражение для оценки эффективности признака [66]

$$c(\omega_i, \omega_j, Y_N) = \sum_{n=1}^N |m_{ni} - m_{nj}|. \quad (1.15)$$

1.2.3 Проблема распознавания

Распознавание представляет собой отнесение исследуемого объекта, задаваемого в виде совокупности наблюдений, к одному из взаимоисключающих классов на основе сопоставления апостериорной информации относительно каждого поступившего на вход системы распознавания объекта (или изображения) с априорным описанием классов [41, 56, 74, 75]. КМ системы распознавания состоит в том, что существует однозначное отображение совокупности на-

блюдений, являющейся конечным числовым множеством $\{X\}$ на множество классов $\{s\} = \{s_1, s_2, \dots, s_k\}$, количество которых задано, $\{s\} \leftarrow \{x\}$. Буквенное обозначение классов заменим рядом натуральных чисел $\{1, 2, \dots, K\}$. В последнем случае распознавание это отображение наблюдений на конечное множество натуральных чисел, $\{1, 2, \dots, K\} \leftarrow \{X\}$. Ввиду числовой природы множеств последнее отображение отождествляется с обычной функцией $k = d(\{X\})$, принимающей целочисленные значения $k = 1, 2, \dots, K$ [41].

На практике множество наблюдений представляется в виде измеренных значений p характеристик (признаков) x_1, x_2, \dots, x_p , при этом количество наблюдений равно определенному числу n (рисунок 1.2). В этом случае распознавание сводится к pn -аргументной функции вида $k = d(x_{11}, x_{12}, \dots, x_{ij}, \dots, x_{pn})$, где x_{ij} – j -е измеренное значение i -го признака, $i = 1, 2, \dots, p$, $j = 1, 2, \dots, n$. Указанная функция, называемая решающей, существует и однозначна при заданных p и n .

Важной особенностью реальных задач распознавания является то, что наблюдения $\{x_{ij}\}_{p \times n}$ неизбежно подвержены случайным возмущениям, слабо прогнозируемый вероятностный характер которых оказывает влияние на всех стадиях, начиная с процесса получения результатов измерений и кончая вычислением значений функции $d(x_{11}, x_{12}, \dots, x_{ij}, \dots, x_{pn})$. Роль дестабилизирующих факторов в процессе измерения играют как погрешности преобразующих устройств, как шумы в каналах передачи данных изображений, аппаратные шумы, а также ошибки округления при вычислениях, связанные с ограниченностью разрядностью представления данных в цифровом виде. Взаимовлияния этих возмущений приводят к тому, что наблюдения x_{ij} неизбежно оказываются реализациями случайных величин, область значений функции $d(x_{11}, x_{12}, \dots, x_{ij}, \dots, x_{pn})$ приобретает случайной характер. В результате номер k класса также оказывается случайной величиной. В связи с этим разработка алгоритмов классификации изображений неизбежно связана с использованием

статистических методов, позволяющих выразить количественно достоверность распознавания через время обучения, время распознавания и размерность признакового пространства.

В опубликованных за последние несколько десятков лет работ в этой области достигнуты значительные теоретические результаты как для параметрического, так и непараметрического подходов к задаче распознавания [14, 32, 31, 36, 41, 48, 52, 64, 81, 84, 85, 90]. Несмотря на хорошее теоретическое обоснование многие из методов распознавания образов, дают неприемлемые результаты при решении практических задач. Это является следствием ограничений и допущений, выдвигаемых исследователями при разработке методов классификации. Зачастую априорно принимается гипотеза о принадлежности функции плотности вероятности какому-либо параметрическому семейству [41]. Многие из оптимальных теоретических методов предполагают, кроме того еще и статистическую независимость выбранной системы признаков [52]. Несмотря на то, что вопросы параметрического распознавания (процедуры обучения, принятия решения и понижения размерности признакового пространства) разработаны очень хорошо, оценки вероятностей ошибок, получающихся при параметрическом распознавании, являются асимптотическими, т.е. справедливыми лишь в редко встречающихся случаях неограниченного возрастания обучающих выборок [36, 48, 52].

Наряду с тем, что как и параметрические методы имеют ограничение на область их применения, непараметрические методы, например k -ближайших соседей, гистограммный, полигональный, Парзеновского ядра и др. также являются асимптотическими и обеспечивают достаточную точность оценивания только лишь при неограниченном увеличении объема обучающих выборок [36, 51, 64, 95].

В существующей литературе оказалась не исследованной важная проблема построения систем статистического распознавания из-за отсутствия оценок вероятностей ошибок или их асимптотического характера – оптимизация временных и пространственных параметров, базирующаяся на количественной

увязке достоверности распознавания с требуемыми для ее достижения временем обучения и принятия решения и размерностью признакового пространства. Последнее обстоятельство явилось, по всей вероятности, основной причиной малого уделения внимания авторами вопросам практических приложений статистического распознавания. Только в некоторых работах эти вопросы были рассмотрены в постановочном плане [32, 31, 48] и более подробно [84, 85].

В задачах применения теории распознавания образов (изображений) оптимизация временных и пространственных параметров диагностических систем имеет особенно важное значение, вследствие того, что эти параметры (вместе с заданной достоверностью распознавания) оказывают непосредственное и наибольшее влияние на результат работы систем различного назначения, связанных с распознаванием изображений.

Настоящая работа преследует дополнение и расширение существующих исследований в направлении решения проблем распознавания сигналов стационарных полутонных изображений, выбора эффективных алгоритмов классификации (расознавания) в условиях непараметрической априорной неопределенности, оптимизации временных и пространственных параметров распознающих систем при малых объемах обучающих выборок, характерных для телевизионных систем наблюдения и сопровождения.

1.3 Постановка задачи оптимизации признаковых пространств

При решении задач классификации сигналов изображений, которые были в п. 1.1 отождествлены со случайными процессами, целесообразно использовать основные результаты, полученные в теории статистических решений [52] и статистической теории распознавания образов [64, 81, 84, 85, 90].

В п. 1.2 было отмечено, что распознавание образов на основе статистических решений состоит из трёх основных этапов:

1. формирование признакового пространства;
2. обучение системы распознавания;

3. принятие решений.

Совокупность предъявляемых для распознавания наблюдений обычно записывают в виде матрицы

$$\mathbf{X}_n = \begin{pmatrix} X_{11} & X_{12} & \dots & X_{1n} \\ X_{21} & X_{22} & \dots & X_{2n} \\ \cdot & \cdot & \cdot & \cdot \\ X_{p1} & X_{p2} & \dots & X_{pn} \end{pmatrix}, \quad (1.16)$$

где n – количество наблюдений, используемых для распознавания. Каждый

столбец $\mathbf{x}_i = \begin{pmatrix} x_{1i} \\ x_{2i} \\ \vdots \\ x_{pi} \end{pmatrix} = (x_{1i}, x_{2i}, \dots, x_{pi})^T$, $i = 1, 2, \dots, n$ матрицы \mathbf{X}_n представ-

ляет собой p -мерный вектор наблюдаемых значений p признаков X_1, X_2, \dots, X_p , отражающих наиболее важные для распознавания свойства объекта. Вектор \mathbf{x}_i можно изобразить точкой p -мерного пространства с координатами X_1, X_2, \dots, X_p , или направленным отрезком, соединяющим начало координат $(0, 0, \dots, 0)$ с точкой $(x_{1i}, x_{2i}, \dots, x_{pi})$ этого пространства (рис. 1.2).

Набор признаков p , как правило, является одинаковым для всех распознаваемых классов s_1, s_2, \dots, s_K . Различие между классами состоит в том, что у разных объектов одни и те же признаки будут иметь различные характеристики (количественные, качественные и др.) и для любого набора признаков X_1, X_2, \dots, X_p можно задать правила, согласно которым любым двум классам s_i и s_j ставится в соответствие вектор

$$\mathbf{d}_{\ell r} = \begin{vmatrix} d_1^{\ell r} \\ \vdots \\ d_q^{\ell r} \end{vmatrix}, \quad (1.17)$$

представленный q скалярами, называемых межклассовыми расстояниями, и выражающих степень отличия у этих классов характеристик данных признаков [84].

Формирование признакового пространства X_1, X_2, \dots, X_p является первым этапом распознавания [41]. При этом условия, в которых выполняется это формирование, являются весьма противоречивыми. Во-первых, выбранная совокупность признаков X_1, X_2, \dots, X_p должна в наибольшей степени отражать все те свойства объектов, которые важны для их распознавания, т.е. быть наиболее полным. Во-вторых, с увеличением размерности p признакового пространства также возрастают вычислительная сложность процедур обучения и принятия решения, материальные и трудовые затраты на измерение необходимых характеристик объектов. Сокращение количества признаков уменьшает затраты на проведение измерений и вычислений, но может привести к снижению достоверности распознавания D , являющегося главным показателем качества распознавания [74, 84, 85, 90]. При ограничении времени на обучение и принятие решения повышение размерности признакового пространства может оказаться единственным средством увеличения достоверности. Следовательно одновременное достижение минимума общей размерности признакового пространства и максимума достоверности распознавания оказывается, как правило, невозможным. Поэтому одной из основных задач синтеза распознающих систем является выбор из заданного множества признаков Y_1, Y_2, \dots, Y_q оптимального набора X_1, X_2, \dots, X_p из p признаков для обеспечения требуемого по условиям решаемой задачи уровня достоверности распознавания и сокращения затрат на проведение измерений и вычислений [84].

Целью второго этапа, обучения, является восполнение недостатка априорных знаний о распознаваемых классах путем использования информации о них, содержащейся в обучающих наблюдениях:

$$\mathbf{X}_{m_k} = \begin{pmatrix} X_{11} & X_{12} & \dots & X_{1m_k} \\ X_{21} & X_{22} & \dots & X_{2m_k} \\ \cdot & \cdot & \cdot & \cdot \\ X_{p1} & X_{p2} & \dots & X_{pm_k} \end{pmatrix}, \quad (1.18)$$

где m_k - количество обучающих наблюдений, $k = 1, 2, \dots, K$.

Независимо от выбранных методов и подходов, применяемых при обучении, конечный результат их использования, как правило, неизменен – это эталонные описания $\hat{s}_1, \hat{s}_2, \dots, \hat{s}_K$, представляющих собой описание характеристик признаков X_1, X_2, \dots, X_p для всех распознаваемых классов s_1, s_2, \dots, s_K .

Увеличение продолжительности обучения [84]

$$T_{об} = \tau \sum_{k=1}^K m_k, \quad (1.19)$$

(где τ - время, необходимое для получения одного наблюдения) повышает, в принципе, достоверность распознавания за счет увеличения количества информации о распознаваемых классах, содержащейся в обучающих выборках и позволяющей уточнять эталонные описания классов $\hat{s}_1, \hat{s}_2, \dots, \hat{s}_K$. Увеличение $T_{об}$ также влечет за собой рост затрат на измерения и вычисления, и увеличение общего времени, требуемого для решения задачи распознавания. Сокращение $T_{об}$ может повлиять на качество эталонных описаний, что приведет к снижению достоверности распознавания. Определение минимального времени обучения, обеспечивающего заданный уровень достоверности распознавания, является одной из важных задач, возникающих при синтезе распознающих систем.

На заключительном этапе распознавания, принятие решений, осуществляется отображение наблюдений (1.16) на конечное множество натуральных чисел $1, 2, \dots, K$ с использованием информации о классах, содержащейся в обучающих наблюдениях и отражаемой в эталонных описаниях классов

$\hat{s}_1, \hat{s}_2, \dots, \hat{s}_K$ [84, 85]. Увеличение продолжительности процедуры принятия решения $T_{\text{реш}} = n\tau$ повышает достоверность распознавания за счет вовлечения в процесс принятия решения большего количества информации о предъявленном для распознавания объекте, содержащейся в описывающей его совокупности наблюдений (1.16) – контрольной выборке [85]. Однако для большинства распознающих систем рекомендуется минимизация $T_{\text{реш}}$ как для обеспечения сокращения времени решения стоящих перед распознающей системой задач, так и для минимизации затрат на измерения и вычисления. Таким образом, определение минимального времени принятия решения, обеспечивающего заданный уровень достоверности распознавания, является ещё одной из важных задач синтеза распознающих систем [84].

Основными параметрами распознающей системы, с учётом вышеизложенных рассуждений, являются: количество признаков p , объемы выборок (обучающих $m_i, i = \overline{1, K}$ и контрольной n) и достоверность распознавания D . На практике при синтезе распознающей системы, заключающемся в выборе величин p, m_i, n и D , обеспечивающем решение поставленной задачи распознавания наилучшим образом, на значения всех или некоторых из перечисленных параметров накладываются ограничения, обуславливаемые либо необходимостью достижения высокого уровня достоверности принимаемых решений, либо жесткими требованиями на время обучения и распознавания, либо ограниченными возможностями по затратам на получение наблюдений. Удовлетворить всем налагаемым на параметры распознающей системы ограничениям можно при различных соотношениях между ними. В этих условиях появляется возможность выбора таких значений параметров p, m_i, n и D , которые удовлетворяют всем налагаемым на них ограничениям и являются оптимальными с точки зрения некоторого критерия, т. е. появляется возможность оптимизации распознающей системы.

Общая постановка задачи оптимизации характеризуется вектором ее основных параметров $V(m_1, \dots, m_K, n, p, D) \in G$, где G - область допустимых зна-

чений параметров, и заключается в выборе из всех допустимых значений параметров таких, которые минимизировали бы некоторый критерий $H(\mathbf{V})$ [84]. Как правило, область допустимых значений параметров задается системой неравенств $h_i(\mathbf{V}) \leq \gamma_i$, $i = \overline{1, Q}$ и равенств $G_j(\mathbf{V}) = \theta_j$, $j = \overline{1, J}$, в качестве которых могут рассматриваться, например, неравенства $D \geq D_0$, $p \leq P_0$ и равенства $m_j = M$, $j = j_1, \dots, j_r$, $n = N$. В итоге задача оптимизации принимает следующий вид [8]:

$$\begin{aligned} H(\mathbf{V}) &\rightarrow \min; \\ h_i(\mathbf{V}) &\leq \gamma_i, i = \overline{1, Q}; \\ G_j(\mathbf{V}) &= \theta_j, j = \overline{1, J}. \end{aligned} \quad (1.20)$$

В задаче оптимизации распознающей системы (1.18) ограничения на затраты, достоверность распознавания, объемы выборок и размерность признакового пространства являются внешними условиями, задаваемыми потребителями. Внутренние зависимости между параметрами распознающей системы определяются, во-первых, тем, что, как было отмечено выше, размерность признакового пространства p и объемы выборок (обучающих m_i , $i = \overline{1, K}$ и контрольной n) непосредственно влияют на достоверность распознавания, а, во-вторых, тем, что, очевидно, достоверность распознавания определяется также степенью отличия характеристик признаков X_1, X_2, \dots, X_p у классов s_1, s_2, \dots, s_K , проявляющейся в обобщенном виде в межклассовых расстояниях $d_{\ell r}$, $\ell, r = \overline{1, K}$ [см. (1.4)].

Следовательно, центральное место в задаче оптимизации распознающих систем наряду с определением критерия оптимальности занимает получение в удобной для практического использования форме зависимости достоверности распознавания от других параметров распознающей системы и межклассовых расстояний.

1.4 Методы распознавания, основанные на теории статистических решений

Подробный анализ различных методов распознавания с позиций оптимизации был произведен в [84, 85]. Рассмотрены детерминистские методы распознавания, основанные на использовании потенциальных функций и перцептронных алгоритмов [81], методы синтаксического (структурного, лингвистического) распознавания [7, 74, 81, 89], логические распознающие системы [32, 31, 76], алгебраические методы [40, 42]. При этом сделан вывод о том, что статистические методы распознавания [14, 36, 64, 85, 90] позволяют в полной мере отразить тонкую структуру и все особенности проявления распознаваемых объектов через описывающие их признаки как при обучении, так и при принятии решений с учетом всех дестабилизирующих факторов (что особенно важно при исследовании стохастических и шумоподобных сигналов), а также количественно описать указанные процессы с использованием хорошо развитых методов математической статистики и теории статистических решений.

В п. 1.2 были выделены основные этапы процесса статистического распознавания. Рассмотрим подробнее эти этапы, а также формирование задачи оптимизации на основе ее общей постановки [8, 82, 85].

О большой важности проблемы первого этапа распознавания – формирования признакового пространства оптимальных размеров, уже упоминалось в п. 1.2. Способы формирования новых признаков X_1, X_2, \dots, X_p из первоначального набора признаков Y_1, Y_2, \dots, Y_q ($p < q$) в условиях полного априорного знания основаны на максимизации некоторой функции $J(Y_1, Y_2, \dots, Y_q)$, называемой критерием и обычно понимаемой как некоторое «расстояние» между классами в признаковом пространстве с координатами Y_1, Y_2, \dots, Y_q (например расстояние Махаланобиса [85]). Также критерий $J(Y_1, Y_2, \dots, Y_q)$ может выражать «диаметр» или «объем» области Ω_m (рис. 1.3), занимаемой классом в признаковом пространстве, и новые признаки X_1, X_2, \dots, X_p формируются путем

минимизации критерия [64, 81, 90]. Оба варианта критериев по своей сути равнозначны. Конкретно в качестве критерия $J(Y_1, Y_2, \dots, Y_q)$ выбирают среднеквадратическую ошибку аппроксимации признаков Y_1, Y_2, \dots, Y_q с помощью новых признаков X_1, X_2, \dots, X_p . Критерии, основанные на геометрической интерпретации расстояния между классами, устанавливают пропорциональность между этим расстоянием и достоверностью распознавания. Максимизация расстояния между классами повышает «разделяющую силу признаков» [74], что и должно обеспечить требуемую достоверность распознавания.

На следующем этапе, процедуре обучения распознающей системы, источником информации о распознаваемых образах является совокупность результатов независимых наблюдений (выборочных значений), составляющих обучающую (обучающие) $(x_i)_{i=1}^{m_k} = (x_1, x_2, \dots, x_{m_k})$ и контрольную (экзаменационную) $(x_i)_i^n = (x_1, x_2, \dots, x_n)$ выборки. Размерность x_i в зависимости от характера задачи распознавания (одномерной или многомерной). Основной целью обучения являются преодоление априорной неопределенности о распознаваемых классах путем использования информации о них, содержащейся в обучающих выборках, и построение эталонных описаний классов, вид которых определяется способом их использования в решающих правилах [85].

На заключительном этапе распознавания вид априорной неопределенности является решающим фактором при выборе метода распознавания. Априорная неопределенность относится только к параметрам закона распределения, если при предварительном анализе наблюдаемой совокупности выборочных значений (или на основе имеющейся априорной информации) оказывается возможным хотя бы с некоторым приближением лишь установить вид закона их распределения. Целью обучения в этом случае становится получение оценок параметров распределения. В этом случае априорная неопределенность носит название параметрической, а методы распознавания, применяемые в этих условиях, называются параметрическими. В общем случае, то есть при отсутствии априорных сведений не только о параметрах, но и о самом виде закона распре-

деления наблюдаемой совокупности выборочных значений априорная неопределенность носит название непараметрической, а методы распознавания соответственно непараметрическими [52].

При этом многими авторами, в том числе и в [84, 85], отмечается, что с формальной точки зрения закон распределения выборочных значений может быть любым, но на практике в параметрическом распознавании почти всегда используется нормальный закон. Основанием этого может служить достаточное большое количество наблюдений и объём выборок, что позволяет использовать центральную предельную теорему [55, 79]. Дело в том, что при распознавании многомерных совокупностей каждая компонента выборочных значений (т.е. наблюдаемые значения каждого признака) может иметь свой отличный от других компонент закон распределения. Но тогда многомерное совместное распределение совокупности выборочных значений должно описываться некоторым многомерным законом, включающим в себя компоненты с различными законами распределения. Однако для общего случая зависимых признаков в литературе аналитические выражения подобных «разнокомпонентных» законов отсутствуют. И в [84] сделан вывод о том, что параметрические методы распознавания, в сущности, являются методами распознавания нормально распределенных совокупностей, так что задачей параметрического обучения в этих условиях является оценивание параметров (средних, дисперсий, ковариационных матриц) нормальных плотностей вероятности, используемых в решающем правиле.

В [85] была предпринята попытка разработать метод оптимизации систем непараметрического распознавания, который основан на непараметрическом методе распознавания, базирующемся на использовании полученных в ходе обучения операторных оценок плотностей вероятности. Однако, как указывают авторы этого метода [84], практическое его применение крайне затруднено из-за требований наложения целого ряда жестких ограничений на функции распределения значений признаков. При этом был сделан вывод, что имеющиеся в настоящее время теоретические результаты по оптимизации многомерных систем непараметрического распознавания практически не могут

быть использованы для оптимизации реальных (в общем случае многомерных) систем распознавания произвольно распределенных образов, поскольку они не учитывают статистической зависимости признаков (имеющей большое влияние на достоверность распознавания), не обеспечивают выражения ограничений на достоверность и межклассовые расстояния через параметры оценок неизвестных плотностей вероятности, охватывают достаточно узкий класс распределений, и фактически не обеспечивают решения задачи оптимизации в наиболее важном для практических приложений случае многомерного распознавания.

Решение проблемы оптимизации систем распознавания произвольно распределенных образов авторам [84, 85] видится на пути нахождения преобразований, обеспечивающих нормализацию указанных распределений, что позволит эффективно использовать параметрические методы распознавания и оптимизации, при которых достоверность распознавания выражается в аналитическом виде через параметры распознаваемых классов и межклассовые расстояния и полностью обеспечивается учет статистической связи между признаками и группами признаков.

Рассмотрим саму процедуру принятия решений с учётом характера априорной неопределенности. В рамках статистической теории принятия решений все виды решающих правил $K = 2$ основаны на формировании отношения правдоподобия L и сравнении его с определенным порогом c , значение которого определяется выбранным критерием качества [52]

$$L = \frac{\omega_n(x_1, x_2, \dots, x_n | s_2)}{\omega_n(x_1, x_2, \dots, x_n | s_1)} \quad c, \quad (1.21)$$

где $\omega_n(x_1, x_2, \dots, x_n | s_j)$ - условная совместная n -мерная плотность вероятности выборочных значений x_1, x_2, \dots, x_n при условии их принадлежности к классу s_j . Однако, если в теории статистических решений указанные плотности $\omega_n(x_1, x_2, \dots, x_n | s_j)$ являются априорно известными, то в статистическом рас-

познавании они, в принципе, не известны, вследствие чего в решающее правило (1.21) подставляются не сами плотности, $\omega_n(x_1, x_2, \dots, x_n | s_j)$, а их оценки $\hat{\omega}_n(x_1, x_2, \dots, x_n | s_j)$, получаемые в процессе обучения, поэтому в решающем правиле с порогом c сравнивается уже не само отношение правдоподобия L , а его оценка \hat{L} , полученная в ходе обучения:

$$\hat{L} = \frac{\hat{\omega}_n(x_1, x_2, \dots, x_n | s_2)}{\hat{\omega}_n(x_1, x_2, \dots, x_n | s_1)} \geq c. \quad (1.22)$$

При $\hat{L} \geq c$ принимается решение: контрольная выборка принадлежит классу s_2 , в противном случае (при $\hat{L} < c$) она считается принадлежащей классу s_1 .

На практике помимо обучающих выборок иногда имеется и другая, дополнительная информация о классах образов, могут выдвигаться различные требования к продолжительности, стоимости обучения и распознавания, достоверности решений и т.д. Эти сведения влияют на выбор порога и способ сравнения оценок отношений правдоподобия с порогом. Указанная дополнительная информация учитывается путем выбора наиболее подходящего решающего правила из имеющихся в теории статистических решений: байесовского, Неймана - Пирсона, минимаксного, Вальда, максимума апостериорной вероятности, максимального правдоподобия и др. [52].

При числе классов $K > 2$ задача распознавания называется многоальтернативной. Наиболее простым и естественным обобщением двухальтернативного решающего правила (1.22) на случай $K > 2$ является следующее [85]: контрольная выборка $\{x_i\}_1^n$ принадлежит классу s_c , если

$$\hat{L}_{cu} = \frac{\hat{\omega}_c(x_1, x_2, \dots, x_n)}{\hat{\omega}_u(x_1, x_2, \dots, x_n)} > c_{cu} \quad (1.23)$$

для всех ℓ , $u = \overline{1, K}$, $u \neq \ell$, при этом $\hat{\omega}_k(x_1, x_2, \dots, x_n)$ $k = \overline{1, K}$ – оценки плотностей вероятности для классов s_k , $k = \overline{1, K}$, полученные по классифицированным обучающим выборкам, а $c_{\ell u}$ – заданные положительные пороги сравнения.

Однако обобщение указанных выше правил принятия решений на многоальтернативный случай не всегда приводит к решающему правилу вида (1.23). Причем только для байесовского критерия при этом получают достаточно простые соотношения [52]. В других случаях соответствующие обобщения оказываются довольно сложными и громоздкими. Легко приводятся к виду (1.23) многоальтернативные критерии максимума апостериорной вероятности и максимального правдоподобия. Помимо этого правило (1.23) обладает одним существенным недостатком. Оно не всегда позволяет выбрать наиболее правдоподобный класс. Возможны ситуации, когда для данной контрольной выборки, заведомо принадлежащей к одному из альтернативных классов, оно вообще не дает никакого решения. Это происходит вследствие нарушения условия транзитивности правила принятия решений. В [84] рассмотрены возможные случаи нарушения данного условия. Для того, чтобы избежать подобных ситуаций необходимо накладывать некоторые ограничения на соотношения значений порогов $c_{\ell u}$. В частности для трехальтернативного случая достаточным условием транзитивности решающего правила (1.23), обеспечивающим существование решения для любой выборки X_n не приводящей к вырождению функции $\hat{\omega}_k(X_n)$, $k = \overline{1, K}$, является условие [84]

$$c_{k_1 k_2} c_{k_2 k_3} c_{k_3 k_1} = 1 \quad (1.24)$$

для любых классов s_{k_1} , s_{k_2} , s_{k_3} из множества $\{s_k\}$. Можно убедиться, что достаточному условию удовлетворяют критерии максимума апостериорной вероятности и максимального правдоподобия.

В п. 1.2 была сформулирована общая постановка задачи оптимизации распознающей системы. Сформулируем задачу оптимизации временных и пространственных параметров системы распознавания применительно к параметрическому случаю.

Как уже отмечалось, процесс распознавания содержит в себе формирование признакового пространства размерностью p , обучение распознающей системы с использованием обучающих выборок объемом m_k , и принятие решений о принадлежности контрольной выборки объемом n_k к одному из классов s_k . При этом возможны ошибки распознавания, возникающие с определенной вероятностью, зависящей от большого количества факторов.

Указанные вероятности определяются следующим образом [85]. Обозначим через α_k вероятность отнесения выборки из n контрольных наблюдений к какому-нибудь из классов $s_1, s_2, \dots, s_{k-1}, s_{k+1}, \dots, s_K$, отличному от класса s_k , когда на самом деле выборка относится именно к этому классу, а через β_k - вероятность отнесения выборки контрольных наблюдений к классу s_k , когда в действительности она ему не принадлежит. При двух классах, $K = 2$, выполняются очевидные равенства $\alpha_1 = \beta_2$ и $\alpha_2 = \beta_1$, и вероятности α_1 и β_2 совпадают с вероятностями ошибок 1-го и 2-го рода.

Вероятности ошибок распознавания $\alpha_k, \beta_k, r = \overline{1, K}$ определяют достоверность D , являющуюся одним из параметров задачи оптимизации (1.20), и получение для них аналитических выражений, позволяющих вычислять α_k и $\beta_k, k = \overline{1, K}$ при любых конкретных значениях $m_k, n, p, K, d_{lr}, \ell, r = \overline{1, K}, \ell \neq r$, дает возможность конкретизировать общую постановку задачи оптимизации в случае параметрической априорной неопределенности. Как уже было отмечено ранее, возможны различные подходы к выбору критерия оптимальности $H(\mathbf{V})$ и ограничений $h_i(\mathbf{V}) < \gamma_i, i = \overline{1, Q}, C_j(\mathbf{V}) = \theta_j, j = \overline{1, J}$ в (1.20). Однако, как правило, при синтезе распознающих систем основным является требование обеспечения гарантированного уровня достоверности принимаемых ре-

шений, состоящее в том, что вероятности ошибок распознавания α_k и β_k , $k = \overline{1, K}$ не должны превышать некоторых заданных значений α^* и β^* ни для одного из имеющихся классов s_1, \dots, s_K . При этом в качестве критерия оптимальности системы распознавания естественно принимать затраты на обеспечение заданного уровня достоверности (стоимостные, временные и т.д.). Так, если C_j - стоимость измерения j -го признака, как правило, одинаковая для всех классов, а b - количество актов распознавания, которые необходимо произвести за заданный промежуток времени, то стоимость распознавания [84]

$$H = \sum_{j=1}^p C_j \left(\sum_{k=1}^K m_k + b n \right). \quad (1.25)$$

При $b=1$ и $C_j = C$ для всех $j = \overline{1, p}$, опуская постоянный множитель в критерии (1.25), задачу оптимизации распознающей системы (1.20) можно записать в виде:

$$\begin{aligned} p \left(\sum_{k=1}^K m_k + n \right) &\rightarrow \min ; \\ \alpha_k &\leq \alpha^*, \beta_k \leq \beta^*, \quad k = \overline{1, K}. \end{aligned} \quad (1.26)$$

Фактически (1.26) означает минимизацию числа измерений признаков, необходимых для того, чтобы вероятностями ошибок распознавания α_k и β_k не превышали заданных значений α^* и β^* соответственно ни для одного из распознаваемых классов.

Выводы по материалам 1 главы

1. Анализ методов распознавания полутоновых изображений показал, что сигналы полутоновых изображений, могут быть представлены векторными случайными процессами (в общем случае представляющих собой нестационарные процессы). С учетом перспективности применения для классификации сигналов полутоновых изображений методов статистической теории распознавания образов, является актуальной задача разработки моделей сигналов полутоновых изображений, эффективных при использовании этих моделей для распознавания фрагментов на полутоновых изображениях. Необходимо также решить задачу преобразования исходных полутоновых изображений при переходе от двумерной модели полутонového изображения к системе одномерных реализаций сигналов изображения. Актуальны некоторые преобразования сводящиеся к устранению искажающих факторов: нормализация по площади, яркости, приведение сигналов полутоновых изображений к виду близкому к стационарному.

2. В результате анализа методов теории распознавания образов, применяемых для решения задач классификации, можно сделать вывод, что большинство методов распознавания и способов оценки их эффективности разработаны для случая неограниченно возрастающих объемов обучающих и контрольных выборок процессов. В связи с этим необходима разработка новых методов распознавания сигналов изображений, ориентированных на конечное (в том числе и малое) число обучающих и контрольных выборок.

3. В результате анализа распознающих систем можно сделать вывод о том, что оптимизацию таких систем необходимо проводить в направлении минимизации суммарного количества наблюдений (т.е. объем обучающих и контрольных выборок и размер признакового пространства), которое будет достаточным для обеспечения требуемого уровня достоверности распознавания при заданных ограничениях, например, время принятия решений.

4. Для оценки эффективности работы разработанного алгоритма в сравнении с известными необходимо выбрать средства и методы, обеспечивающие компромисс между достоверность получаемых оценок и обеспечением приемлемых времени и затрат на получение этих оценок. Также необходимо при реализации разработанных алгоритмов обеспечить возможность учитывать статистические погрешности результатов программного эксперимента для контроля адекватности получаемых результатов и возможности сравнительного анализа разработанных алгоритмов с известными.

2 ИССЛЕДОВАНИЕ ХАРАКТЕРИСТИК МОДЕЛИ СИГНАЛА ПОЛУТОНОВОГО ИЗОБРАЖЕНИЯ И ОПТИМИЗАЦИЯ ПАРАМЕТРОВ РАСПОЗНАЮЩЕЙ СИСТЕМЫ

2.1 Преобразование модели сигнала полутонного изображения

В п.1.2 приведен в качестве примера широкий круг задач, в которых полутонные изображения выступают в качестве источника информации, основываясь на которой необходимо вынести некоторое решение. Было отмечено отсутствие каких-либо общих формальных методов построения моделей сложных сигналов полутонных изображений. При создании распознающих систем перед разработчиком встает задача выбора и конструирования этих моделей. Эффективность построенных моделей зачастую зависит только от его опыта и интуиции.

В виду сложности объекта исследования и принципиальной невозможности создания всеобъемлющей адекватной модели изображения (не только полутонного), необходимо рассматривать только лишь частную прикладную задачу, решаемую при каком-либо из видов целевой функции.

В работах многих авторов по теории распознавания образов [15, 76, 19, 81, 85] говорится о том, что разработка абстрактной распознающей системы не имеет никакой практической значимости без приложения к какой-либо реальной задаче. При решении конкретной практической задачи необходимо идти от частного к общему: обобщение результатов, полученных при решении частной практической задачи, на группу задач, в какой-то мере близких к решаемой. Исходя из этого принципа в диссертационной работе рассматривается задача построения системы распознавания фрагментов на полутонных изображениях.

В качестве основного объекта исследования были выбраны оцифрованные полутонные изображения реальных объектов, что продиктовано несколькими причинами: во-первых, актуальностью задачи распознавания фрагментов

на полутоновых изображениях; во-вторых, создание классификационных обучающих выборок для экспериментальной оценки результатов работы.

В общем случае полутоновое изображение – случайная двумерная функция яркости. При этом если полутоновое изображение рассматривать в виде последовательности кадров, то в данном случае можно рассматривать еще и временную зависимость.

В диссертационной работе подразумевается анализ полутоновых изображений, на которых оператором, либо системой в автоматическом режиме, выбирается некоторый фрагмент на полутоновом изображении (область интереса) подлежащий распознаванию. Этот подход в какой-то степени позволяет сузить область и объем анализируемых данных.

Полутоновые изображения (п. 1.2) описывается рядом признаков, набор и количество которых зависит от конкретной решаемой задачи. Исходя из представления яркостного сигнала полутонового изображения в виде случайного процесса, возможен следующий подход к формированию процессов, отображающих полутоновое изображение объекта в последовательность кадров необходимых для формирования информационной системы признаков. Анализируются лишь выборочные строки изображения, число которых может варьироваться, но при этом выборочные строки равномерно отстоят друг от друга на протяженном объекте (рисунок 2.1). В результате анализа ограниченного количества строк получается ограниченный набор реализаций случайных процессов в пределах одного кадра $Z_1(j)$. Этот подход позволяет перейти от двумерной модели полутонового изображения к системе одномерных реализаций сигналов изображения [63]. Для удобства оперирования с яркостными сигналами полутоновых изображений произведем нормировку по максимальному уровню сигнала, как показано на рисунке 2.2. В нашем случае используются полутоновые статические изображения представленные 256 градациями (8 бит) яркостного сигнала.



Рисунок 2.1 – Формирование системы одномерных реализаций




Рисунок 2.2 – Выборочная реализация нормированного яркостного сигнала полутонового изображения

В большинстве случаев (п. 1.2) перед непосредственной обработкой полутоновых изображений необходимы некоторые преобразования сводящиеся к устранению искажающих факторов. Для этого эффективно использовать яркостную нормализация [56] – преобразование полутонового изображения, позволяющее привести его к виду, удобному для распознавания. Также необходимо выполнение нормализации по площади занимаемым объектом на изображении для достижения определенной степени достоверности результатов проводимой классификации объектов. Во-первых, необходимо добиться, чтобы площади классифицируемых протяженных объектов были практически одинаковы, при

расхождении порядка 3...5%. Во-вторых, классифицируемые объекты (фрагменты) должны занимать максимально возможную площадь апертуры, т.е. необходимо минимизировать «ненужный» фон. Вопросы нормализации рассматриваются в п. 2.1.1.

Проведенные исследования показали, что в ряде случаев сигналы яркости оцифрованных полутоновых изображений не являются стационарными процессами. Для приближения сигналов полутоновых изображений к виду близкому к стационарному применяется динамическая интерполяция сигнала – построение разностного сигнала изображения и опорного, в качестве которого используется равномерный случайный процесс. Динамическая интерполяция определяется выражением

$$X_i(j) = Z_{iH}(j) - \eta_i(j), \quad (2.1)$$

где $Z_{iH}(j)$ – нормализованный сигнал анализируемого полутонового изображения, определяемое выражением (1.1) в п. 1.1; $\eta_i(j)$ – дискретные отсчеты равномерного случайного процесса, некоррелированного с анализируемым, и определенным на интервале не меньшем интервала определения анализируемого сигнала.

В ряде источников [9, 29, 58, 59] операция (2.1) называется динамической интерполяцией анализируемого сигнала. Она служит, во-первых, для стационаризации процесса, во-вторых, при использовании в качестве опорного процесса равномерного процесса в операции свертки получается равномерное распределение значений анализируемого сигнала по интервалу квантования и, в-третьих, данная операция позволяет устранить плохую обусловленность корреляционных матриц. Примеры результатов данной операции приведены на рисунке 2.3. В качестве примера была сформирована система из пяти анализируемых строк распознаваемого полутонового изображения.

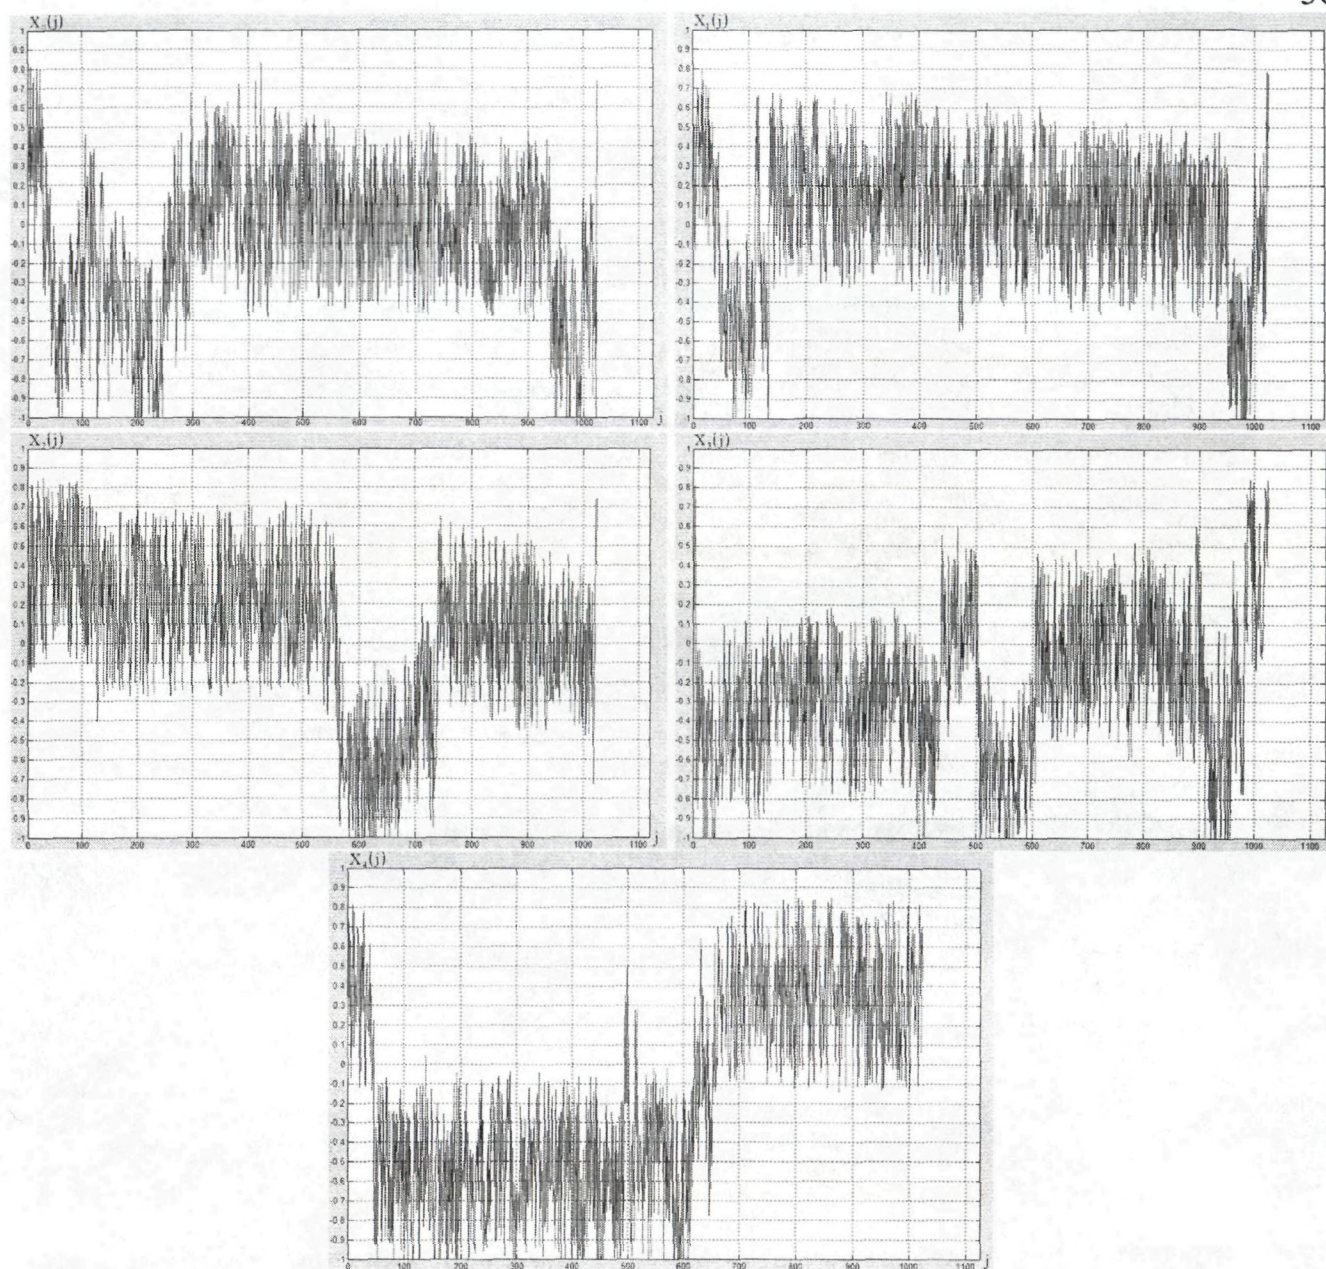


Рисунок 2.3 – Сформированная система одномерных реализаций сигналов изображения

В [30, 56, 61, 97] в качестве системы эффективных признаков рекомендуется использовать систему моментных функций. При использовании методов статистического распознавания использование моментных функций, в том числе и смешанных моментов, позволяет получить эффективную систему признаков и осуществить классификацию объектов.

2.1.1 Нормализация сигнала полутонового изображения

Необходимым этапом при решении задач обнаружения и распознавания объектов на цифровых полутоновых изображениях является нормализация яркостных искажений. Источниками подобных искажений в системах дистанционного формирования изображений выступают как природные, так и технические факторы (время экспозиции, условия наблюдений, освещенности и т.д.). Результатом действия этих факторов становится существенное изменение яркостных статистических характеристик фона и объектов на полутоновом изображении при сохранении неизменной формы объектов. Основную информацию об объектах несут их геометрические характеристики, поэтому необходимо осуществлять яркостную нормализацию – преобразование полутонового изображения к виду, независимому от случайного характера яркостных искажений.

Как правило априорная информации об искажениях отсутствует. Поэтому вид нормализующего яркостного преобразования задается по конкретному обрабатываемому полутоновому изображению, а параметры вычисляются на основе яркостных статистических характеристик (среднего, дисперсии, гистограммы) [56, 70, 71]. Однако параметры могут быть также определены и с помощью других признаков изображения (например, моментных инвариантов [56]).

Предположим, что имеем полутоновое изображение в математической модели которого значительную часть поля яркости $f(n_1, n_2)$ занимает пространственно-протяженный объект. Тогда область изображения можно разбить на две, соответствующие объекту D_0 и фону D_b : $D = D_0 \cup D_b$. Области D – эталонное изображение, каждый элемент которого определяется в зависимости от его принадлежности области D_0 или D_b :

$$\bar{f}(n_1, n_2) = \begin{cases} 0, & \text{при } (n_1, n_2) \in D_b; \\ 1, & \text{при } (n_1, n_2) \in D_0. \end{cases} \quad (2.2)$$

Используя данное представление, получаем модель нормализуемого полутонового изображения:

$$f(n_1, n_2) = (\bar{\zeta}_0(n_1, n_2) + A_0)\bar{f}(n_1, n_2) + \bar{\zeta}_b(n_1, n_2)(1 - \bar{f}(n_1, n_2)) + A + v(n_1, n_2). \quad (2.3)$$

Здесь $\bar{\zeta}_0(n_1, n_2)$, $\bar{\zeta}_b(n_1, n_2)$ – центрированные однородные случайные поля с заданными автоковариационными функциями, $v(n_1, n_2)$ – шумовая составляющая наблюдаемого полутонового изображения, A и A_0 – параметры яркостного преобразования полутонового изображения относительно эталона. Величина A_0 – контраст между объектом и фоном (разность между их средними значениями), а величина A – средняя яркостью фона.

Определим основные требования к искомому нормализующему преобразованию, которые естественным образом вытекают из самой постановки задачи.

Преобразование Θ устранения яркостных искажений полутонового изображения должно обеспечивать:

– минимизацию некоторого критерия сходства нормализованного полутонового изображения в окне с эталонным:

$$\|y(\Theta(f(n_1, n_2))) - y(\bar{f}(n_1, n_2))\| \rightarrow \min, (n_1, n_2) \in D, \quad (2.4)$$

где y – вектор признаков, вычисляемых на области изображения D (в качестве признаков можно использовать отсчеты полутонового изображения, тогда $y(f(n_1, n_2)) = f(n_1, n_2)$); $\|y\|$ – норма вектора y в заданном пространстве функций дискретного аргумента;

– инвариантность к линейному яркостному преобразованию полутонового изображения:

$$y(\Theta(Af(n_1, n_2) + B)) = y(\Theta(f(n_1, n_2))), \quad (2.5)$$

где A, B – параметры преобразования;

– для эталонного полутонового изображения (2.2) должно выполняться соотношение

$$y(\Theta(\tilde{f}(n_1, n_2))) = y(\tilde{f}(n_1, n_2)). \quad (2.6)$$

При построении преобразования могут задаваться и дополнительные требования, например, условие несмещенности математических ожиданий признаков на нормализованном полутоновом изображении относительно признаков, определяемых на эталонном изображении:

$$E\{y(\Theta(f(n_1, n_2)))\} = y(\tilde{f}(n_1, n_2)). \quad (2.7)$$

На основании выше изложенного, в нашем случае выражение для яркостной нормализации будет иметь вид

$$Z_H(j) = Z(j) - m[Z_N(j)], \quad (2.8)$$

где $m[Z_N(j)]$ – средняя яркость, усредненная по N анализируемым строкам изображения.

Рассмотрим теперь вопрос нормализации объекта по занимаемой им площади на полутоновом изображении, в основе которого лежит численный метод Монте-Карло [18]. При этом задача выделения контуров объекта в данной работе не рассматривалась, поэтому эта операция проводилась вручную.

Метод Монте-Карло предназначен для приближенного подсчета сложной подынтегральной функции, каким и является изображение протяженного объекта. Преимущество метода Монте-Карло, во-первых, в многомерном случае

число вычисляемых значений подинтегральной функции растет значительно медленнее, чем при квадратурных формулах, при заданной точности вычисления, а во-вторых, точность не зависит от гладкости подинтегральной функции. Недостатком метода – результат носит вероятностный характер, т.е. отсутствие строгих оценок погрешностей.

В нашем случае воспользуемся упрощенным выражением [18]

$$S_{об} \approx \frac{1}{N} \sum_{i=1}^N k_i, \quad (2.9)$$

где N – общее число испытаний; k_i – точка принадлежащая объекту.

2.2 Синтез решающего правила классификатора сигналов при непараметрической априорной неопределенности

Если при решении задачи распознавания сигналов у исследователя имеется в наличии лишь достаточно протяжённые кластеризованные выборки, то, как рекомендуется в [81], при построении решающего правила необходимо использовать один из аппроксимационных подходов.

Будем полагать, что выходные сигналы канала передачи информации – это реализации, представленные в пространстве информативных признаков, что задана кластеризованная обучающая выборка

$$\{\bar{y}_r, r=1,2, \dots, n_i; i=1,2, \dots, M\}.$$

Обозначим $p^i(\bar{y}) = p(\bar{y}/f^i)$ как неизвестную функцию правдоподобия входных сигналов f^i , заданных на вероятностном пространстве и принадлежащих пространству сигналов F .

Представим $p^i(\bar{y})$ разложением в ряд Фурье по ортонормированной системе $\{e_k(\bar{y})\}$ и ограничимся частичной суммой

$$\hat{p}^i(\bar{y}) = \sum_{k=1}^Q \bar{d}_k^i \cdot e_k(\bar{y}), \quad (2.10)$$

где $e_k(\bar{y})$ – выбираются априори и считаются известными, а коэффициенты разложения \bar{d}_k^i подлежат определению.

При этом можно функцию правдоподобия записать как известную функцию, зависящую от неизвестного векторного параметра \bar{d}^i , то есть

$$\hat{p}^i(\bar{y}) = \hat{p}(\bar{y} / f^i, \bar{d}^i). \quad (2.11)$$

Как показано в [61], оценки коэффициентов разложения d_k^{i*} при условии, что пространство \bar{y} задано обучающей выборкой, могут быть определены из выражения

$$d_k^{i*} = \frac{1}{n_i} \cdot \sum_{r=1}^{n_i} e_k(\bar{y}_r), \quad k=1,2,3, \dots, Q. \quad (2.12)$$

Алгоритм (2.12) позволяет найти оценку вектора \bar{d}^{i*} по классифицированной выборке $\{\bar{y}_r, r=1,2, \dots, n_i; \}$ для всех $i=1,2, \dots, M$. А это, в соответствии с адаптивным байесовским подходом, дает оценку функций правдоподобия в виде

$$\hat{p}^{i*}(\bar{y}) = \hat{p}(\bar{y} / f^i, \bar{d}^{i*}), \quad i=1,2,3, \dots, M. \quad (2.13)$$

В частном случае простой функции потерь, приводящей к требованию минимизации средней ошибки распознавания, решающее правило может быть записано в виде [90]

$$P_l \cdot p(\bar{x} / f^l, \bar{\alpha}^{*l}) \geq P_i \cdot p(\bar{x} / f^i, \bar{\alpha}^{*i}), \quad l=1,2, \dots, M; \quad l \neq i, \quad (2.14)$$

где $\bar{\alpha}^*$ - оценка максимального правдоподобия векторного случайного параметра \bar{y} .

Подставляя оценку функции правдоподобия из (2.13) в решающее правило (2.14), получим

$$P_l \cdot \hat{p}(\bar{y} / f^l, \bar{d}^{l*}) \geq P_i \cdot \hat{p}(\bar{y} / f^i, \bar{d}^{i*}). \quad (2.15)$$

Следует отметить, что качество аппроксимации функций $p^i(\bar{y})$ с помощью выбранной системы базисных функций зависит от числа членов разложения Q . Поскольку заранее вид $p^i(\bar{y})$ нам неизвестен, то точность аппроксима-

ции выясняется на «экзамене» при экспериментальной проверке работы классификатора.

Выбор базисных функций зависит от характера изменения плотности распределения процессов, подлежащих классификации. При отсутствии априорных сведений о характере плотности распределения исходят из условия простоты реализации базисной системы функций.

Метод аппроксимации функций правдоподобия принципиально можно применять для смеси сигнала и помехи. Однако значительное увеличение размерности сигнала \bar{y} резко увеличивает трудоемкость вычислительных операций. Приходится исследовать функции $e_k(\bar{y})$ от большого числа переменных. В распознавании сигналов этап сокращения размерности описания вводится для обеспечения реализуемости подобных алгоритмов. Но в такой ситуации можно пойти по двум направлениям:

1. Искать эффективные методы сокращения размерности исходного описания сигналов и тем самым упростить реализацию решающего правила.
2. Использовать простые алгоритмы сокращения размерности исходного описания классов, а на этапе принятия решения искать такую систему базисных функций $e_k(\bar{y})$, которая допускает для данной конкретной задачи, простую техническую реализацию.

Оставаясь в рамках второго направления можно аппроксимировать функцию правдоподобия системой моментных функций достаточно просто технически реализуемых стохастическим способом.

В работе [90] показано, что в случае аппроксимации плотности распределения $P(y/f^i)$ ортонормированными полиномами Эрмита с весовой функцией

$$k(y/f^i) = (2 \cdot \pi)^{-\frac{1}{2}} \cdot \sigma_i^{-1} \cdot \exp\left(-\frac{1}{2} \cdot y^2 / \sigma_i^2\right), \quad (2.16)$$

ее приближенное выражение может быть записано в виде

$$p(y/f^i) \cong \frac{1}{(2 \cdot \pi)^{1/2} \sigma_i} \exp\left(-\frac{y^2}{2\sigma_i^2}\right) \cdot \left[1 + \frac{m_3}{3! \cdot \sigma_i^3} \left\{ \left(\frac{y}{\sigma_i}\right)^3 - \left(\frac{3}{2}\right) \left(\frac{y}{\sigma_i}\right) \right\} + \right. \\ \left. + \frac{1}{4!} \left(\frac{m_4}{\sigma_i^4} - 3\right) \left\{ \left(\frac{y}{\sigma_i}\right)^4 - \left(\frac{4}{2}\right) \left(\frac{y}{\sigma_i}\right)^2 + 1 \cdot 3 \cdot \left(\frac{4}{4}\right) \right\} \right], \quad (2.17)$$

где m_i – i -й момент плотности вероятности $p(y/f^i)$, техническая реализация может быть осуществлена с помощью алгоритма [20]. Будем полагать, что кластеризованная обучающая выборка $\{\bar{y}\}$ взята из реализации процесса $\xi(t)$, имеющего плотность распределения $p_\xi(y)$.

Будем формировать процесс

$$\text{Sgn}Z = \begin{cases} 1, & \xi > \eta; \\ 0, & \xi \leq \eta, \end{cases} \quad (2.18)$$

где $\eta(t)$ – некоторый опорный процесс с одномерной плотностью $p_\eta(y)$ [21].

В этом случае вероятность

$$P(\xi \geq \eta) = P(\eta \leq \xi) = M\{P(\eta \leq \xi)\} = \int_{-\infty}^{\infty} \int_{-\infty}^y p_\eta(y_1) \cdot p_\xi(y) dy_1 dy.$$

Отсюда видно, что опорный процесс должен иметь интервал распределения не меньше области определения исследуемого процесса $\xi(t)$.

Если

$$p_\eta(y) = \begin{cases} 1.0, & y \in [0,1]; \\ 0, & y \notin [0,1], \end{cases} \quad (2.19)$$

и значения процесса $\xi(t)$ лежат в также в интервале $[0,1]$, то

$$P[\text{Sgn}Z=1] = M[\text{Sgn}Z] = \int_{-\infty}^{\infty} y \cdot p_\xi(y) dy \approx m_1^* = \frac{1}{N} \sum_{i=0}^N \text{Sgn}Z_i. \quad (2.20)$$

То есть получается оценка первого начального момента. Для получения начального момента k -го порядка плотность вероятности опорного процесса должна иметь вид

$$p_\eta(y) = \frac{dF_\eta(y)}{dy} = \frac{d(y^k)}{dy} = \begin{cases} k \cdot y^{k-1}, & y \in [0,1]; \\ 0, & y \notin [0,1]. \end{cases}$$

При этом

$$P[\xi \geq \eta] = M[\text{Sgn}Z] = \int_{-\infty}^{\infty} y^k \cdot p_{\xi}(y) dy \approx m_k^* = \frac{1}{N} \sum_{i=0}^N \text{Sgn}Z_i. \quad (2.21)$$

Таким образом, в зависимости от вида функции распределения опорного сигнала, не изменяя структуры измерителя, мы можем получать оценки моментов различных порядков. Используя эти оценки при аппроксимации функции правдоподобия, можно построить решающее правило в соответствии с адаптивным байесовским подходом.

Структурная схема распознающего устройства M сигналов при простой функции потерь, построенная по критерию минимума средней вероятности ошибки распознавания может быть представлена в виде (рисунок 2.4) [25]




Рисунок.2.4 Структурная схема распознающего устройства

По выходному сигналу \bar{y} канала передачи информации в M каналах параллельно измеряются функции $\hat{p}^{i*}(\bar{y})$. Они умножаются на числа P_i , равные вероятностям предъявления сигналов, и подаются на устройство выбора максимума, которое принимает решение в пользу максимума найденной величины. На практике удобнее вычислять не непосредственно условные вероятности, а монотонную функцию от этих вероятностей. Ею может быть логарифмическая функция. При этом, в случае, когда $\sigma_i = 1$, выражение (2.17) может быть преобразовано к виду

$$\begin{aligned} \varphi[p(y/f^1)] = & -\ln y + \ln \left[y + \frac{m_3}{3!} \cdot (y^4 - 3y^2) + \frac{1}{4!} (m_4 - 3) \cdot (y^5 - 6y^3 + 3y) \right] - \\ & - \ln(\sqrt{2\pi}) - \frac{1}{2} y^2. \end{aligned} \quad (2.22)$$

Практическая реализация (2.22) является достаточно сложной и может быть оправдана только тогда, когда допущение о нормальности распределений признаков классов не обеспечивает требуемой надежности распознавания.

Таким образом, в случае классификации сигналов, характеризующихся одним признаком с негауссовским одномерным распределением и при неизвестных вероятностях распознавания классов минимальная средняя ошибка распознавания обеспечивается использованием критерия идеального наблюдателя, предполагающего равенство априорных вероятностей классов P_i . При этом сигнал, представленный реализацией \bar{y} , может быть классифицирован в соответствии с решающим правилом

$$\varphi[p(y/f^1)] \geq \varphi[p(y/f^2)], \quad (2.23)$$

а структурная схема классификатора примет вид (рисунок 2.5)

Классификатор, построенный в соответствии со структурной схемой, изображенной на рисунке 2.5 вычисляет логарифмические функции условных вероятностей вида (2.22) и требует хранения в памяти классификатора начальных моментов третьего и четвертого порядков. Оценки этих моментов могут быть получены на этапе обучения предложенным выше методом.

Предложенный метод синтеза линейного классификатора негауссовских сигналов приводит к решениям, близким к оптимальным, только в случае малых дисперсий оценок функций правдоподобия. Так как истинные значения функций правдоподобия неизвестны, точность их представления может быть оценена на контрольных выборках при работе классификатора.




Рисунок.2.5. Структурная схема классификатора.

2.3 Укрупнение описания сигналов полугонных изображений на основе обобщенного оператора преобразования

Известные методы сокращения размерности описания сложных сигналов (на основе минимизации энтропии, с использованием ортогональных разложений, с использованием критерия разброса, с использованием статистических характеристик, на основе максимизации дивергенции) [61, 81, 82, 90] с целью улучшения их разделимости (повышения достоверности классификации) иногда приводят к противоречивым рекомендациям по выбору эффективных признаков. Так, например, при выборе признаков методом минимизации внутриклассового разброса наблюдений выбирается некоторое количество преобразованных признаков, соответствующих минимальным собственным числам, а при использовании критерия максимизации межклассового расстояния необходимо выбирать некоторое количество преобразованных признаков, соответствующих, в отличие от предыдущего метода, максимальным собственным числам [90].

Причина этого заключается в отсутствии явной связи критериев, основанных на понятии расстояния, с основными показателями качества распознавания, в частности, с главным из них – достоверностью. Поэтому на практике бывает трудно отдать предпочтение какому-то определенному критерию и сделать обоснованный выбор между противоречащими рекомендациями.

В [85] предлагается вариант усовершенствованного критерия, объединяющего два указанных выше, а также предложено преобразование исходного

признакового пространства, позволяющее заменить q первоначальных признаков Y_1, Y_2, \dots, Y_q одним единственным признаком и при этом обеспечить ту же вероятность правильного распознавания, которая получилась бы при использовании всех q первоначальных признаков. Однако использование этих методов возможно лишь при распознавании полностью известных гауссовых процессов использования декоррелирующего преобразования исходных признаков.

В [26] предложена методика поиска оператора преобразования исходного сигнала $x(t)$, с целью такого укрупнения его описания, которое в дальнейшем позволит связать заданный уровень достоверности классификации сигналов с эффективностью используемой модели сигнала. При этом в качестве базовой модели использованы неизоморфные модели сложных сигналов в виде класса случайных процессов.

Во многих прикладных задачах распознавания случайных сигналов [46, 76] имеется возможность нахождения эффективных признаков, которые являются существенно нелинейными функциями исходных признаков. В таких случаях основная задача, позволяющая в дальнейшем упростить алгоритмы решающего правила, состоит в нахождении подходящего нелинейного преобразования для рассматриваемых признаков. Рассмотрим один из подходов к решению таких задач, предложенный в [27].

Любая реализация случайного сигнала с ограниченным спектром определяется совокупностью своих мгновенных значений в дискретные моменты времени, определяемые теоремой Котельникова. С точки зрения распознавания реализацию случайного процесса $x(t)$ можно рассматривать как объект, характеризуемый вектором признаков $\{x(t_1), x(t_2), \dots, x(t_q)\}$, где $x(t_q)$ – выборки из реализации процесса $x(t)$.

Ограничиваясь стационарными процессами $x(t)$, нелинейное преобразование $\varphi(x)$ исходной реализации равносильно преобразованию компонент вектора признаков $\{\varphi[x(t_1)], \varphi[x(t_2)], \dots, \varphi[x(t_q)]\}$, при этом в качестве укрупненного

описания этого процесса возьмем оператор математического ожидания, то он будет определяться выражением

$$L = M[y] = \int_{-\infty}^{\infty} \varphi(x)p(x)dx, \quad (2.24)$$

где $y = \varphi(x)$; $p(x)$ – плотность распределения стационарного случайного процесса $x(t)$; $M[\cdot]$ – обозначает операцию математического ожидания над величиной, указанной в квадратных скобках.

Для процессов, обладающих свойством эргодичности, можно переписать выражение (2.24) на интервале в виде [58]

$$\frac{1}{T_p} \int_0^{T_p} \varphi[x(t)]dt = \lim_{q \rightarrow \infty} \frac{1}{q} \sum_{n=1}^q \varphi[x(t_n)]\Delta t_n, \quad (2.25)$$

где T_p – длительность анализируемой реализации процесса; $\Delta t_n = T_p/q$ – интервал дискретизации процесса $x(t)$.

При конечном значении q функционал L заменяется его оценкой \hat{L} .

Выражение

$$\hat{L} = \frac{1}{q} \sum_{n=1}^q \varphi[x(t_n)]\Delta t_n = 0 \quad (2.26)$$

определяет некоторую поверхность в пространстве признаков и если параметры этой поверхности выбраны так, что удовлетворяется система неравенств вида

$$\begin{cases} M[y] \geq 0, & \{x(t_k)\}_{k=1}^q \in \omega_1; \\ M[y] < 0, & \{x(t_k)\}_{k=1}^q \in \omega_2, \end{cases} \quad (2.27)$$

где ω_1, ω_2 – объект первого и второго класса, то эта поверхность может служить разделяющей [49].

Из определения оператора (2.24) можно сделать вывод, что функция нелинейного преобразования может быть детерминированной функцией без наложенных на нее ограничений. Однако интересный, с точки зрения практических приложений, результат может быть получен, если в качестве последней используется функция, отвечающая свойствам функции распределения вероятностей

$$\varphi(x) = F_{\eta}(x) = P_{\eta}[X \leq x], \quad (2.28)$$

символ $P[\cdot]$ означает вероятность события, указанного в квадратных скобках.

В этом случае результат преобразования может быть записан

$$L = \int_{-\infty}^{\infty} F_{\eta}(x) p(x) dx \quad (2.29)$$

или

$$L = \int_{-\infty}^{\infty} \int_{-\infty}^x p_{\eta}(y) p(x) dy dx, \quad (2.30)$$

где $p_{\eta}(t)$ – плотность распределения некоторого опорного процесса $\eta(t)$, некоррелированного с анализируемым процессом $x(t)$.

Из (2.30) следует, что интервал распределения опорного процесса должен быть не меньше интервала распределения анализируемого процесса. Можно видеть, что в частном случае, когда функция распределения опорного сигнала $\eta(t)$ $F_{\eta}(x) = x^k$, то результат (2.29) определяет моменты распределения k -го порядка ($k = 1, 2, \dots$).

Функции распределения опорного сигнала $F_{\eta}(x)$ выбираются на этапе обучения из условия получения максимальной достоверности классификации.

В общем случае вычисление значения функционала (2.29) предполагает знание плотности распределения процесса $x(t)$ и функции распределения (или плотности вероятности) опорного процесса $\eta(t)$. На первый взгляд такая форма преобразования может показаться абсурдной, так как для распознавания сигнала $x(t)$ достаточно знания плотности распределения $p(x)$, однако следует иметь в виду, что на практике эта плотность, как правило, не известна, а имеется в распоряжении кластеризованная выборка из реализации процесса $x(t)$, по которой можно сформировать оценку $\hat{p}(x)$ его плотности распределения, но и этого делать нет необходимости в силу специфики практической реализации оценок функционала (2.29).

Такой подход к определению системы эффективных признаков позволяет отобразить многомерное пространство исходных признаков в одномерное пространство функционалов, при этом убирается излишняя детализация описания процесса, присущая данному конкретному представителю распознаваемого класса процессов. "Обобщенная" информация о распознаваемых классах сигналов содержится в преобразованной системе признаков-функционалов в той мере, в какой она существенна для разделения сигналов.

Хотя исходная система признаков в общем случае нелинейно связана с редуцированной системой признаков-функционалов, однако построение решающего правила (разделяющей поверхности) в случае системы независимых признаков возможно в классе линейных классификаторов, где, как известно [49, 90], наилучшим является байесовский классификатор, минимизирующий ошибки классификации (диагностирования).

Для построения в дальнейшем разделяющих поверхностей и оценок вероятности правильной классификации необходимо знать статистические характеристики функционалов (2.24) и (2.29), при этом будем полагать, что исходная

система признаков является независимой и представляет собой мгновенные значения реализаций стационарных процессов, взятые через интервал Δt .

Подробный вывод выражений для статистических характеристик рассматриваемых функционалов можно найти в [26]. Ограничимся лишь окончательными результатами.

Приведем вначале статистические характеристики результата преобразования в случае детерминированной функции нелинейного преобразования без наложенных ограничений на ее свойства.

Так как L будет случайной величиной только в случае использования вместо плотности вероятности $p(x)$ ее оценки $\hat{p}(x)$, в этом случае

$$M[L] = \int_{-\infty}^{\infty} \varphi(x) M[\hat{p}(x)] dx. \quad (2.31)$$

Дисперсию преобразованного процесса можно определить из выражения

$$\sigma_L^2 = M[L^2] - \{M[L]\}^2.$$

Получаем

$$\begin{aligned} \sigma_L^2 &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \varphi(x_1) \varphi(x_2) \{M[\hat{p}(x_1)] M[\hat{p}(x_2)] - M[\hat{p}(x_1) \hat{p}(x_2)]\} dx_1 dx_2 = \\ &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \varphi(x_1) \varphi(x_2) \hat{K}(x_1, x_2) dx_1 dx_2, \end{aligned} \quad (2.32)$$

где $\hat{K}_p(x_1, x_2) = \frac{2}{T_p} \int_0^{T_p} (T_p - \tau) \hat{p}(x_1, x_2; \tau) d\tau - \hat{p}(x_1) \hat{p}(x_2)$; $\tau = t_2 - t_1$; $\hat{p}(x_1, x_2; \tau)$ –

двумерная плотность вероятности анализируемого процесса $x(t)$, при этом процесс $x(t)$ является стационарным эргодическим.

Таким образом, полученные в результате анализа выражения (2.24), реализуемого системой распознавания, статистические соотношения (2.31), (2.32) связывают входные и выходные сигналы блока преобразования, реализующего функцию введенного функционала L .

Приведем теперь статистические характеристики результата преобразования в случае, когда функция нелинейного преобразования является функцией распределения случайной величины, т.е.

$$\varphi(x) = F_{\eta}(x) = P_{\eta}[X \leq x].$$

Из выражения (2.29) следует, что если $p(x)$ представлена своей оценкой $\hat{p}(x)$, то

$$M[L] = \int_{-\infty}^{\infty} M[F_{\eta}(x)\hat{p}(x)]dx = \int_{-\infty}^{\infty} M[F_{\eta}(x)]\hat{p}(x)dx. \quad (2.33)$$

В выражении (2.33) использовано то положение, что процессы $\eta(t)$, имеющий функцию распределения $F(x)$, и $x(t)$, имеющий плотность вероятности $p(x)$, являются независимыми, а также то, что

$$M[F_{\eta}(x)] = F_{\eta}(x).$$

Так как (2.33) записано в той же форме, что и (2.31), то выражение для дисперсии результата преобразования может быть записано в виде, аналогичном (2.32)

$$\sigma_L^2 = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} F_{\eta}(x_1)F_{\eta}(x_2)\hat{K}_p(x_1, x_2)dx_1dx_2. \quad (2.34)$$

В практических приложениях в распоряжении исследователя часто имеются лишь оценки плотностей распределения и корреляционных функций, поэтому выражения (2.31), (2.32), (2.33) и (2.34) можно приближенно определить следующим образом:

для функции преобразования $\varphi(x)$

$$M[L] \approx \Delta x \sum_{k=1}^n \varphi(x_k) M[\hat{p}(x_k)]; \quad (2.35)$$

$$\sigma_L^2 \approx (\Delta x)^2 \sum_{k=1}^n \varphi^2(x_k) \hat{\sigma}_p^2(x_k); \quad (2.36)$$

для функции распределения $F_\eta(x)$

$$M[L] \approx \Delta x \sum_{k=1}^n F_\eta(x_k) M[\hat{p}(x_k)]; \quad (2.37)$$

$$\sigma_L^2 \approx (\Delta x)^2 \sum_{k=1}^n [F_\eta(x_k)]^2 \hat{\sigma}_p^2(x_k); \quad (2.38)$$

здесь Δx – интервал квантования анализируемого процесса $x(t)$; n – количество уровней квантования процесса $x(t)$; $M[\hat{p}(x_k)] = M\left[\frac{1}{\Delta x} \int_{x_{k-1}}^k \hat{p}(x) dx\right]$ – математическое ожидание оценки плотности вероятности процесса $x(t)$ в точках интерполяции; $\hat{\sigma}_p^2(x_k)$ – дисперсия оценок $M[\hat{p}(x_k)]$.

Таким образом, в обоих рассмотренных случаях могут быть определены оценки статистических характеристик результата преобразования исходного сложного сигнала, необходимые для построения разделяющих поверхностей в пространстве неизоморфных моделей сигналов [23].

2.4 Оптимизация параметров распознающих систем в случае параметрической априорной неопределенности

Рассмотрим основные результаты по оптимизации временных и пространственных параметров систем распознавания, полученные в рамках развития статистической теории распознавания образов [84, 85]. Основой решения этой задачи является увязка значений вероятностей ошибок распознавания α_k и β_k с временными и пространственными параметрами распознающей системы.

Известно [52], что оптимальные решающие правила и методы оценки достоверности распознавания хорошо разработаны лишь для случая исследования нормально распределенных независимых признаков при полной априорной определенности относительно параметров их распределения, что никогда не встречается в реальной практике. Для решения задач распознавания в реальных условиях авторы предлагают ряд мер, которые позволяют свести поставленную задачу к известной.

Так для выполнения условия независимости признаков предлагается на этапе формирования признакового пространства подвергать исходное пространство признаков $Y = (Y_1, Y_2, \dots, Y_q)$ линейному преобразованию A в новое пространство $X = (X_1, X_2, \dots, X_p)$

$$X = AY. \quad (2.39)$$

При этом преобразование (2.39) является декоррелирующим, для чего в качестве столбцов матрицы преобразования выбирают собственные векторы общей ковариационной матрицы M распознаваемых совокупностей (которая при полном априорном знании точно известна). Сама ковариационная матрица M^* в этом случае становится диагональной с собственными числами λ_i на диагонали [90]

$$\mathbf{M}^* = \mathbf{A}^T \mathbf{M} \mathbf{A} = \Lambda = \begin{pmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & \\ \cdot & \cdot & \cdot & \cdot \\ 0 & 0 & \dots & \lambda_p \end{pmatrix}. \quad (2.40)$$

После указанного преобразования отбирают p ($p < q$) новых признаков, соответствующих тем собственным числам λ_i матрицы \mathbf{M}^* , которые оказывают наибольшее влияние на значение выбранного критерия $J(\mathbf{Y})$.

Для удовлетворения требования нормальности признаков предлагается использовать универсальный и простой способ нормализации признаков, основанный на нормализации распределений случайных величин в условиях центральной предельной теоремы, и известный в радиотехнике под названием метода накопления [80, 83]. Метод накопления обобщается также и на многомерный случай. Основным вопросом практического применения метода накопления для нормализации распределений признаков является вопрос скорости сходимости функции распределения случайной величины к нормальной. Достаточно подробно он рассмотрен в [84].

Для случая оптимизации систем распознавания одномерных образов, различающихся средними и дисперсиями, в [84] на основе полученных выражений для ошибок распознавания [84] и при использовании критерия максимального правдоподобия приведены результаты расчетов объема обучающих и контрольной выборок для заданных достоверностей распознавания $1 - \alpha^* = 0,9; 0,95; 0,99$ при изменении параметров, характеризующих межклассовое расстояние, d_0 и r_0

$$d^2 = \frac{(a_2 - a_1)^2}{\sigma_1} \quad \text{и} \quad r = \frac{\sigma_2^2}{\sigma_1^2}. \quad (2.41)$$

При этом отмечен незначительный рост оптимальных объемов выборок m^* , n^* при значениях r_0 , близких к 1, и существенное их убывание в широком диапазоне остальных значений r_0 и всех значений d_0 , что является подтверждением возможности использования приведенных в [84] таблиц для выбора оптимальных объемов выборок m^* и n^* , требуемых для достижения заданной достоверности $1 - \alpha^*$ ориентируясь на наихудший случай $d^2 = d_0$, $r = r_0$.

При распознавании многомерных нормальных совокупностей к основным характеристикам - расстоянию между классами d , объемам обучающих m и контрольной n выборок - добавляется и пространственная характеристика - число признаков p .

Рассмотрим оптимизацию временных характеристик систем распознавания многомерных совокупностей с неизвестными векторами средних \mathbf{a}_1 и \mathbf{a}_2 и общей ковариационной матрицей \mathbf{M} при фиксированном числе признаков p .

Важным моментом при проведении оптимизации является определение расстояния между классами d и задание его минимального значения $d_\epsilon > 0$, используемого при решении задачи оптимизации [85]. При рассмотрении одномерного случая в качестве расстояния d между классами использовалась скалярная величина - нормированная разность $|a_2 - a_1| / \sigma$ между средними значениями. В многомерном случае расстояние между двумя многомерными нормальными совокупностями s_1 и s_2 с векторами средних \mathbf{a}_1 и \mathbf{a}_2 и общей ковариационной матрицей \mathbf{M} выражается также скалярной величиной - расстоянием Махаланобиса [81]

$$d^2 = (\mathbf{a}_2 - \mathbf{a}_1)^T \mathbf{M}^{-1} (\mathbf{a}_2 - \mathbf{a}_1). \quad (2.42)$$

Задача оптимизации временных характеристик системы может быть сформулирована как задача минимизации суммарного объема $\rho = p \cdot (2m + n)$ обучающих и контрольной выборок, необходимых для достижения заданного

уровня достоверности при заданном ограничении, заключающемся в том, что расстояние между совокупностями s_1 и s_2 должно быть не меньше некоторого минимального значения $d_\epsilon > 0$, в качестве которого, как и в одномерном случае, где мы имеем дело со скаляром, целесообразно выбирать точность измерения этого расстояния в реальных системах.

Найденное в [85] выражение вероятности ошибок распознавания через объемы контрольной и обучающих выборок и расстояние Махаланобиса d между классами составляет основу для оптимизации характеристик распознающей системы, заключающейся в отыскании вектора параметров системы \mathbf{V} , минимизирующего некоторый критерий $H(\mathbf{V})$ и удовлетворяющего ограничениям $h_i(\mathbf{V}, \alpha, \beta) \geq b_i$, $i = \overline{1, Q}$ на допустимые значения параметров и вероятности ошибок.

Анализ результатов расчетов значений оптимальных объемов обучающих и контрольной выборок, приведенных в [27, 88] показывает, что при сравнительно невысоких требованиях к точности измерения расстояния между классами $d_\epsilon^2 = 0,01$ и размерности признакового пространства $p = 10$ удовлетворительный уровень достоверности распознавания 0,9 достигается при значениях $m^* = 1917$ и $n^* = 2300$. Повышение уровня требуемой достоверности распознавания до значений 0,99; 0,999; 0,9999 при тех же значениях d_ϵ^2 и p достигается путем достаточно умеренного увеличения оптимальных объемов обучающих и контрольной выборок. Наблюдается эффект возрастания значений объемов m^* и n^* , требуемых для обеспечения заданной достоверности $1 - \alpha^* = 1 - \beta^*$ при неизменном значении расстояния d_ϵ^2 и при увеличении размерности признакового пространства p . Физически он объясняется возрастанием с ростом p числа оцениваемых параметров, что увеличивает общую дисперсию их оценок и, следовательно, уменьшает результирующую достоверность распознавания [85]. Для доведения последней до требуемого по условиям задачи уровня

$1 - \alpha^* = 1 - \beta^*$ необходимо несколько увеличить значения оптимальных объемов выборок m^* и n^* [85].

Возможность повышения достоверности распознавания путем наращивания числа p признаков открывает дополнительный путь формирования признакового пространства без применения линейного преобразования пространства исходных признаков.

В общем виде задачу формирования признакового пространства необходимо ставить, исходя из реальной обстановки, из требований к распознающей системе в целом [81]. В реальных условиях обычно требуется, чтобы принимаемые системой решения имели гарантированную достоверность, которая достигалась бы при минимуме стоимости используемого оборудования, энергетических затрат, времени обучения системы, времени принятия решения и т.д. В связи с этим характеристики достоверности неизбежно должны быть увязаны с количеством обучающих наблюдений, используемых для задания классов, объемом контрольных выборок, необходимых для принятия решений, а также со свойствами выбираемых признаков, их количеством.

Каждое обучающее и контрольное наблюдение требует, очевидно, проведения p актов измерения значений признаков. Поэтому задача формирования признакового пространства является составной частью проблемы минимизации общей размерности задачи распознавания [84], а в общей формулировке задачи оптимизации распознающей системы (1.26) минимизации подлежит общее количество измерений [84]

$$\rho = p \left(\sum_{k=1}^K m_k + nb \right), \quad p \leq q, \quad (2.43)$$

где m_k – объем обучающей выборки для определения характеристик класса s_k ; n – объем контрольной выборки; b – общее количество актов принятия решений в процессе распознавания; q – число первоначальных признаков.

Задача оптимизации размерности признакового пространства при $K = 2$, $m_1 = m_2 = m$, $b = 1$ должна включать в себя как составную часть задачи оптимизации суммарного объема $\rho = (2m + n)$ обучающих и контрольной выборок, то есть представлять собой обобщение этой задачи на случай минимизации суммарного количества измерений по всем p признакам $\rho = p \cdot (2m + n)$, требуемого для достижения заданного уровня достоверности распознавания $\alpha^* = \beta^*$. Во многих практических задачах оказывается возможным в первом приближении положить общую ковариационную матрицу \mathbf{M} распознаваемых совокупностей s_1 и s_2 диагональной с дисперсиями на диагонали [41, 84]. В этом случае расстояние Махаланобиса [84]

$$d^2 = \sum_{i=1}^p \left[(a_{i2} - a_{i1}) / \sigma_i \right]^2 = \sum_{i=1}^p \delta_i, \quad (2.44)$$

где $\delta_i = \left[(a_{i2} - a_{i1}) / \sigma_i \right]^2$.

Ограниченные возможности реальных распознающих систем по обработке результатов измерений по каждому из p признаков позволяют всегда считать число признаков p ограниченным некоторой величиной P ($p \leq P$), откуда следует, что существует некоторое общее значение $\delta > 0$, что $\delta_i \geq \delta$ для всех $i = 1, \dots, p$. В качестве δ , в частности, можно выбрать точность измерения признаков в реальных системах.

Очевидно, задача оптимизации признакового пространства (включающая в себя и оптимизацию суммарного объема обучающих и контрольных наблюдений) записывается следующим образом [84]:

$$(2m + n)p \rightarrow \min, \quad \alpha(m, n, p) \leq \alpha^*. \quad (2.45)$$

При заданном δ , учитывая инвариантность решения задачи (2.45) относительно умножения критерия на положительное число, задача переписывается в следующем виде:

$$\delta(2m + n)p \rightarrow \min, \quad \alpha(m, n, p) \leq \alpha^*. \quad (2.46)$$

В реальных системах распознавания максимально возможные значения объемов обучающих m и контрольной n выборок, как правило, ограничены некоторыми предельными значениями M и N ($m \leq M, n \leq N$), причем здесь помимо соображений, связанных с ограниченностью сил и средств на проведение необходимых обучающих и контрольных наблюдений (в общем, аналогичных тем, которые ограничивают размерность p признакового пространства), на первый план выступают жесткие требования по ограниченности времени обучения и принятия решения, которые во многих случаях наряду с требуемой достоверностью распознавания являются определяющими факторами при построении распознающей системы.

При фиксированном значении p с увеличением объема обучающих m и контрольной n выборок вероятность ошибки распознавания $\alpha = \beta$ уменьшается. Следовательно, с учетом ограничений ее минимально возможное значение достигается при фиксированном значении p , когда m и n , увеличиваясь, оказываются равными своим предельным значениям $m = M$ и $n = N$. Если при этом достигнутое значение вероятности ошибки $\alpha(M, N, p)$ остается больше заданного по условиям задачи значения α^* , то единственным путем ее дальнейшего уменьшения остается увеличение размерности признакового пространства p . Вычисляется значение вероятности ошибки распознавания $\alpha(M, N, p)$ при $p = 1, 2, \dots, p_0$, до тех пор, пока не окажется, что

$$\alpha(M, N, p_0) \leq \alpha^*. \quad (2.47)$$

Зависимость $\alpha(M, N, p)$ от размерности признакового пространства при $\delta = 0,1$ приведена в [84]. Значения $p_{\text{опт}}$, $n_{\text{опт}}$, $m_{\text{опт}}$ при $\delta = 0,1$, $1 - \alpha^* = 0,9$ и различных значениях N и M приведены в [84]. Анализ представленных результатов расчетов показывает, что с уменьшением предельных значений объемов обучающих M и контрольной N выборок оптимальное значение размерности признакового пространства $p_{\text{опт}}$, обеспечивающее заданный уровень достоверности распознавания $1 - \alpha^* = 1 - \beta^*$ увеличивается. Аналогичный характер носит взаимосвязь оптимальной размерности признакового пространства $p_{\text{опт}}$ с оптимальными объемами обучающих $m_{\text{опт}}$ и контрольной $n_{\text{опт}}$ выборок: увеличение последних приводит к уменьшению $p_{\text{опт}}$ и наоборот.

Следовательно, в тех случаях, когда по условиям функционирования системы распознавания увеличение с целью обеспечения требуемой достоверности значения какого-либо из ее параметров (например, времени обучения или/и распознавания) оказывается невозможным, заданный уровень может быть достигнут увеличением другого параметра (например, размерности признакового пространства).

Выводы по материалам 2 главы

1. Сигналы изображений ввиду их чрезвычайной сложности и высокой вариабельности характеристик составляют широкий класс процессов. При этом результаты, полученные для систем распознавания сигналов изображений, могут быть перенесены и на другие технические системы диагностики.

2. Предложена методика преобразования изображения протяженного объекта в систему одномерных реализаций случайного процесса, позволяющие формировать систему эффективных признаков при классификации сигналов изображений.

3. Выбрана система нормализующих первичных преобразований сигналов изображений, состоящая из нормализации по яркости, а также нормализацией по площади занимаемой объектом на изображении. При этом последнее преобразование основано на численном методе Монте-Карло.

4. Предложена методика синтеза решающего правила при непараметрической априорной неопределенности относительно закона распределения классифицируемой выборки.

5. Выбран оператор неизоморфного преобразования исследуемых сложных сигналов с целью сокращения размерности их описания обеспечивающий сохранение (в смысле заданного критерия) информации о делимости распознаваемых классов сигналов. Определены статистические характеристики результата преобразования, что позволит реализовать в дальнейшем оптимальное решающее правило в пространстве отображений исходных сигналов.

6. Анализ существующих методов оптимизации систем распознавания показал, что в достаточной мере эти методы разработаны лишь для случая параметрической априорной неопределенности относительно закона распределения признаков. При этом, необходимо выполнение требования статистической независимости исследуемых признаков. Все эти условия редко встречаются в практических приложениях. Поэтому весьма актуальна задача разработки методов оптимизации временных и пространственных параметров распознающих

систем, инвариантных как к закону распределения признаков, так и к виду их статистической взаимосвязи.

3 АЛГОРИТМЫ ПРИНЯТИЯ РЕШЕНИЙ ПРИ НЕПАРАМЕТРИЧЕСКОМ РАСПОЗНАВАНИИ СИГНАЛОВ ПОЛУТОНОВЫХ ИЗОБРАЖЕНИЙ

3.1 Формирование системы признаков при классификации случайных процессов с использованием метода стохастического кодирования сигналов полутоновых изображений

При решении задач классификации случайных процессов, как отмечено в [27], в качестве эффективных признаков можно использовать оценки моментных характеристик, получаемых в результате обработки кластеризованных реализаций случайных процессов, при обучении. Однако в ряде случаев в качестве системы классификационных признаков целесообразно использовать отсчётные значения оценок второго смешанного момента процессов, подлежащих классификации и подвергнутых процедуре стохастического кодирования.

Использование нелинейного преобразования первичных признаков позволяет с одной стороны укрупнить описание классифицируемых сигналов, отобразив исходное многомерное пространство признаков в одномерное пространство функционалов, с другой стороны – с применением в качестве функции преобразования функции распределения некоторого вспомогательного процесса – позволяет представить более компактно свойства всех сигналов, принадлежащих одному классу [22].

Рассмотрим один из методов реализации алгоритма стохастического кодирования сигналов [21, 27], ориентированного на классификацию сложных сигналов с непараметрической априорной неопределенностью.

Предположим, что анализируется с целью выделения признаков некоторый стационарный сигнал (процесс) $X(t)$, имеющий одномерную плотность вероятности $p_x(x)$ и обладающий свойством эргодичности.

Сформируем знаковый процесс

$$\operatorname{sgn} Z = \begin{cases} 1, & X > H; \\ 0, & X \leq H, \end{cases} \quad (3.1)$$

где $Z = X - H$; $H(t)$ – некоторый опорный процесс с плотностью вероятности $p_H(H)$.

Для упрощения математических выкладок при $X \leq H$ значение знаковой функции принято равным $\operatorname{sgn} Z = 0$.

При назначенных X и H , то есть когда $X = x$ и $H = \eta$, выражение (3.1) можно записать

$$\operatorname{sgn} Z = z(t) = \begin{cases} 1, & X(t) > \eta(t); \\ 0, & X(t) \leq \eta(t). \end{cases} \quad (3.2)$$

Запишем выражение для математического ожидания знаковой функции $\operatorname{sgn} Z$

$$M[\operatorname{sgn} Z] = +1 \cdot P(X > H) + 0 \cdot P(X \leq H) = P(H < X). \quad (3.3)$$

При фиксированном значении x , т.е. когда $X = x$, условное математическое ожидание

$$M[\operatorname{sgn} Z|x] = P(H < X), \quad (3.4)$$

в то время как $P(H < X) = F_\eta(x)$

$$P(\eta < x) = F_\eta(x) = \int_{-\infty}^x p_\eta(\eta) d\eta, \quad (3.5)$$

где $F_\eta(x)$ – интегральный закон распределения случайной величины η .

$F_\eta(x)$ является функцией аргумента распределения сигнала и, следовательно, можно сделать вывод, что интервал распределения опорного сигнала должен быть, по крайней мере, не меньше, чем интервал распределения анализируемого сигнала $X(t)$.

Отсюда выражение для условного математического ожидания

$$M[\text{sgn } Z|x] = P[\eta < x]. \quad (3.6)$$

Из теории вероятностей известно [16, 49], что математическое ожидание условного математического ожидания некоторой случайной функции равно математическому ожиданию этой случайной функции. В данном случае

$$M\{M[\text{sgn } Z|x]\} = M[\text{sgn } Z]$$

или

$$M[\text{sgn } Z] = \int_a^b M[\text{sgn } Z|x] p_x(x) dx. \quad (3.7)$$

Подставляя в уравнение (3.7) значение $M[\text{sgn } Z|x]$ из формулы (3.6) с учетом (3.5), будем иметь:

$$M[\text{sgn } Z] = M[z(t)] = \int_{a-\infty}^b \int_a^x p_\eta(\eta) p_x(x) d\eta dx = \int_a^b F_\eta(x) p_x(x) dx, \quad (3.8)$$

где $[a, b]$ – интервал распределения анализируемого сигнала $X(t)$.

Нетрудно заметить, что выражение (3.8) совпадает с выражением (2.30), определяющим оператор преобразования в случае использования функции преобразования $\varphi(x) = F_\eta(x)$.

Рассмотрим частный случай [90], когда значения опорного процесса равномерно распределены на интервале, причем выберем интервал, равный $[0, 1]$

$$p_\eta(x) = \begin{cases} 1, & x \in [0, 1]; \\ 0, & x \notin [0, 1]. \end{cases} \quad (3.9)$$

Если значения процесса $X(t)$ лежат также в интервале $[0, 1]$, то $F_\eta(x) = x$, а значение математического ожидания знаковой функции

$$M[z(t)] = \int_0^1 F_\eta(x) p_x(x) dx = \int_0^1 x p_x(x) dx = M[x(t)]. \quad (3.10)$$

Из формулы (3.10) видна возможность определения среднего значения случайной функции $X(t)$ по среднему значению знаковой функции

$$\hat{M}[X] = \hat{M}[\text{sgn } Z]. \quad (3.11)$$

Если в качестве оценки $M[\text{sgn } Z]$ принять оценку вида

$$\frac{1}{N} \sum_{i=1}^N \text{sgn } Z,$$

то получим

$$\hat{m}_{X,1} \approx \frac{1}{N} \sum_{i=1}^N z(iT_0), \quad (3.12)$$

где T_0 – интервал дискретизации процесса $z(t)$.

Для получения начального момента k -го порядка, как это видно из (3.10), функция распределения опорного процесса должна быть $F_\eta(x) = x^k$, при этом

$$M[z(t)] = \int_0^1 x^k p_x(x) dx \approx m_{X,k}, \quad (3.13)$$

$$\hat{m}_{X,k} \approx \frac{1}{N} \sum_{i=1}^N z(iT_0).$$

Таким образом, в зависимости от вида функции распределения опорного сигнала, не изменяя структуры измерителя, мы можем получать оценки моментов различных порядков.

Можно видеть, что использование оценок вида (3.13) в качестве аргумента векторов признаков диагностируемых процессов эффективно в случае диагностирования процессов с отличающимися одномерными плотностями вероятностей. Однако в случае одинаковых одномерных распределений, например у сигналов изображений, эффективность таких признаков стремится к нулю [84].

В случае одинаковых одномерных распределений диагностируемых классов процессов можно поступить следующим образом.

Будем формировать два процесса:

$$z_1(t) = \begin{cases} 1, & X(t) > U(t); \\ 0, & X(t) \leq U(t); \end{cases} \text{ и } z_2(t) = \begin{cases} 1, & X(t) > V(t); \\ 0, & X(t) \leq V(t), \end{cases} \quad (3.14)$$

где $U(t)$ и $V(t)$ – опорные случайные процессы, некоррелированные между собой и со случайным процессом $X(t)$, имеющие интервал распределения $[a,b]$, равный интервалу распределения сигнала $X(t)$.

В [58] показано, что знаковая функция

$$R_H(\tau) = M[\operatorname{sgn} Z_1 \operatorname{sgn} Z_2], \quad (3.15)$$

где $Z_1 = \dot{X}(t) - U(t)$; $Z_2 = \dot{X}(t + \tau) - U(t + \tau)$, (при условии равномерности распределений опорных процессов в пределах заданного интервала) связана с корреляционной функцией процесса $X(t)$ соотношением

$$K_X(\tau) = c \cdot R_H(\tau),$$

где c – коэффициент пропорциональности.

Используя методику нахождения выражения знаковой корреляционной функции, найдем $M[\operatorname{sgn} Z_1 \operatorname{sgn} Z_2] = M[z_1 z_2]$. Обозначим через X_t и X_{t+nT_0} случайные величины, соответствующие значениям анализируемой реализации сигнала $x(t)$ в моменты времени t и $t + nT_0$ ($n = 1, 2, 3, \dots$) (T_0 – интервал дискретизации), определим выражение для подсчета второго смешанного момента

$$M[z_1 z_2] = \int_a^b \int_a^b F_U(x_t) F_V(x_{t+nT_0}) \times p_2(x_t, x_{t+nT_0}; \tau = nT_0) dx_t dx_{t+nT_0}, \quad (3.16)$$

где $p_2(x_t, x_{t+nT_0}; \tau = nT_0)$ – двумерный закон распределения анализируемого процесса $X(t)$.

Следует заметить, что (3.16) будет определять второй смешанный момент только в случае, когда процессы $U(t)$ и $V(t)$ будут распределены равномерно в интервале, не меньшем чем $[a, b]$. В случае, когда опорные распределения $U(t)$ и $V(t)$ имеют распределения, отличающиеся от равномерных, (3.16) будет определять функцию дискретного аргумента (nT_0), значения которой в точках $\tau = nT_0$ будут зависеть как от параметров формы распределения процесса $X(t)$, так и от его энергетических характеристик (корреляционной функции процесса

$X(t)$). Последовательность этих значений может быть использована в качестве эффективных признаков при диагностировании. Как и выражение (3.15), (3.16) можно приближенно определять достаточно простыми техническими средствами, так как

$$m^*[z_1 z_2] \approx \Theta(nT_0) = \frac{1}{N-n} \sum_{i=1}^{N-n} z_1(iT_0) z_2[(i+n)T_0], \quad (3.17)$$

где N – количество выборочных значений из реализации $z(t)$.

Следует отметить, что эффективность алгоритма с использованием стохастического кодирования особенно проявляется при классификации процессов с непараметрической априорной неопределённостью, когда в распоряжении исследователя имеются кластеризованные реализации процессов малой протяжённости [68].

Получение системы эффективных признаков на основе метода стохастического кодирования связано с синтезом системы опорных распределений, на основе заданных или выбранных критериев эффективности, тем или иным образом связанных с достоверностью классификации, так как эта достоверность является глобальным и самым мощным критерием при ограничениях, наложенных на время обучения, принятие решения и размерность признакового пространства. Подходы при этом могут быть различные. Некоторые из таких подходов будут рассмотрены ниже

3.1.1 Исследование связи статистических характеристик анализируемого процесса с опорным процессом

Исследуем связь статистических характеристик анализируемого процесса $X(t)$ с процессом $z(t)$, полученным в результате сравнения с опорным распределением [24]. При этом наибольший интерес представляет случай равномерно-

го распределения опорного сигнала $\eta(t)$, так как в этом случае, в соответствии с (3.13) и (3.16), статистические характеристики процесса $z(t)$ будут совпадать с начальными моментами его распределения.

Будем исходить из того, что анализируемый процесс $X(t)$ является стационарным эргодическим и распределен в интервале $[0,1]$. Тогда, полагая, что опорный процесс $\eta(t)$ распределен равномерно в интервале $[0,1]$, выражение (3.2) перепишем в виде

$$z_i(t) = z_i = \begin{cases} 1, \eta < X; \\ 0, \eta \geq X. \end{cases}$$

Составим ряд для дискретной случайной величины z_i :

| | | |
|-------|----------------|-----------|
| z_i | 0 | 1 |
| P | $(1 - x_i)P_i$ | $x_i P_i$ |

Переходя к непрерывной случайной величине X , можно сразу записать:

$$M[z] = \int_0^1 x p(x) dx = m_X, \quad (3.18)$$

$$D[z] = \int_0^1 x^2 p(x) dx - m_X^2 = m_X(1 - m_X). \quad (3.19)$$

Для ошибки представления случайной величины z_i в результате ее одно-разрядного квантования $\delta_i = z_i - x_i$ также запишем ряд распределения, который будет иметь вид

| | | |
|------------|----------------|-----------|
| δ_i | $-x_i$ | $1 - x_i$ |
| P | $(1 - x_i)P_i$ | $x_i P_i$ |

Откуда при переходе к непрерывным случайным величинам имеем

$$M[\delta] = \int_0^1 [(-x)(1-x) + (1-x)x] p(x) dx = 0. \quad (3.20)$$

Таким образом, математическое ожидание ошибки в результате одноуровневого квантования независимо от вида распределения анализируемого процесса $p(x)$ равно нулю.

Теперь определим дисперсию ошибки δ :

$$\begin{aligned} D[\delta] &= \int_0^1 (1-x)^2 x p(x) dx + \int_0^1 (1-x)x^2 p(x) dx = \int_0^1 x p(x) dx - \int_0^1 x^2 p(x) dx = \\ &= m_X - [\sigma_X^2 + m_X^2] = m_X(1 - m_X) - \sigma_X^2 = D[z] - D[X]. \end{aligned} \quad (3.21)$$

Среднеквадратическое отклонение ошибки δ запишется как

$$\sigma(\delta) = \sqrt{m_X(1 - m_X) - \sigma_X^2}. \quad (3.22)$$

В соответствии с (3.13), математическое ожидание

$$M[z] \approx m_{X,1}^* = \frac{1}{N} \sum_{i=1}^N z(iT_0),$$

$$\begin{aligned} D[z] &= D[X] + D[\delta] \approx m_X^* (1 - m_X^*) = \\ &= \frac{1}{N} \sum_{i=1}^N z(iT_0) \left[1 - \frac{1}{N} \sum_{i=1}^N z(iT_0) \right]. \end{aligned} \quad (3.23)$$

Таким образом, дисперсия случайной величины z может быть определена на основе выражения (3.23).

Дисперсия оценки (3.13) может быть определена следующим образом [57]:

$$\begin{aligned}
 D[M[z]] &= \frac{1}{N} D[z] \approx D[m^*] = \frac{m_x^*(1-m_x^*)}{N} = \\
 &= \frac{1}{N^2} \sum_{i=1}^N z(iT_0) \left[1 - \frac{1}{N} \sum_{i=1}^N z(iT_0) \right].
 \end{aligned}
 \tag{3.24}$$

Оценим теперь погрешности, вносимые стохастическим кодированием, для случая равномерного распределения опорного сигнала $\eta(t)$.

Оценка m_x по стохастическому отображению $z(iT_0)$ представляет собой оценку вероятности P события $z(iT_0)=1$, ($i=1,2,\dots,N$) по его частоте

$$P^* = \frac{1}{N} \sum_{i=1}^N z(iT_0) \text{ в } N \text{ независимых опытах.}$$

Дисперсия оценки P^* равна $\sigma^2(P^*) = m_x(1-m_x)/N - \sigma_X^2/N$.

Тогда с вероятностью β можно утверждать, что величина погрешности $\delta_m = |P^* - P|$ определения m_x по стохастическому отображению $z(iT_0)$ определяется выражением

$$\bar{\Delta} = t_\beta \sqrt{\frac{m_x(1-m_x) - \sigma_X^2}{N}}. \tag{3.25}$$

Суммарная погрешность вычисления математического ожидания случайной функции по его стохастическому отображению равна [29]

$$\bar{\Delta}_\Sigma = \bar{\Delta} + \Delta_{\text{ст}} = \frac{t_\beta}{\sqrt{N}} \left[\sqrt{m_x(1-m_x) - \sigma_X^2} + \sqrt{\sigma_X^2} \right], \tag{3.26}$$

где N – количество некоррелированных выборок из функции $z(iT_0)$;

$t_\beta = \Phi^{-1}\left(\frac{1+\beta}{2}\right)$ – функция, обратная нормальной функции распределения [29].

Таким образом, можно заключить, что при использовании метода стохастического кодирования возрастает дисперсия оценок измеряемых моментов, однако к положительным моментам можно отнести сокращение избыточности описания исходного процесса $X(t)$ в $\alpha = k/S$ раз [29], где k – разрядность представления $X(t)$ двоичным кодом; S – порядок определяемой моментной функции процесса $z(t)$.

Кроме того, при математической обработке процессов $z(t)$, полученных в результате применения метода стохастического кодирования, операции сложения и умножения сводятся к простейшим операциям – конъюнкции и счету импульсов. Это позволяет строить относительно простые вероятностные процессоры для статистической обработки данных с целью выделения эффективных признаков.

3.2. Оптимизация разделяющих поверхностей и принятие решений

В [26, 93] уже обсуждался вопрос выбора критерия оптимизации, и был предложен следующий подход к рассмотрению задачи построения разделяющей поверхности.

Как уже отмечалось в п.1.3 в теории распознавания сигналов в отношении процессов (сигналов), принадлежащих одному классу, высказывается гипотеза компактности, т.е. включение всех объектов каждого класса в одно подмножество, состоящее из конечного числа связанных областей. Другими словами, гипотеза компактности предполагает адекватность понятий "сходства" процессов одного класса и их геометрической "близости", проявляющейся в объединении их в одно связанное подмножество в пространстве признаков.

Поскольку распознаваемый класс сигналов является случайным процессом, N -мерный вектор его признаков \vec{y} заключен в некоторой области G , причем эта область может быть бесконечной. Так для нормального процесса вероятность попадания его значений в любую произвольную область отлична от ну-

ля. Однако практически удается выделить такую ограниченную область признакового пространства, вероятность попадания в которую признаков данного класса весьма высока, в то же время для других ничтожно мала.

Разделяющая поверхность в нашем случае задается выражением

$$\Omega(\bar{y}) = 0; \quad (3.27)$$

она охватывает замкнутую область фиксированного объема, вероятность попадания в которую признаков данного класса максимальна. Необходимо найти эту поверхность. При этом, если собственную область G пространства признаков определенного класса (например, класса A) задавать исходя из условия максимума вероятности правильной классификации

$$P(A) = \int_G \omega(\bar{y}|A) d\bar{x}, \quad (3.28)$$

при фиксированном объеме выделенного пространства

$$V_A = \int_G d\bar{y}, \quad (3.29)$$

то максимизируемый функционал I принимает вид [76]

$$I = \int_G p(\bar{y}|A) d\bar{y} - \lambda \int_G d\bar{y}, \quad (3.30)$$

где λ – множитель Лагранжа.

В [76] показано, что искомая граница Γ выделенной области G должна удовлетворять условию

$$p(\bar{y}|A) = \lambda, \bar{y} \in \Gamma, \quad (3.31)$$

а поверхность (3.38) будет представлять собой контур равновероятной плотности. Если эта поверхность определена, процедура распознавания сводится к вычислению функции плотности вероятности $p(\bar{y}|A)$ при наблюдаемом значении \bar{y} и сравнению ее с порогом λ . Решающее правило в этом случае будет иметь вид

$$\begin{cases} \bar{y} \in A, & \text{если } p(\bar{y}|A) \geq \lambda; \\ \bar{y} \notin A, & \text{если } p(\bar{y}|A) < \lambda. \end{cases} \quad (3.32)$$

Умение достаточно точно и сравнительно просто восстановить функцию плотности вероятности или выделить контур, на котором она постоянна, в значительной степени определяет практическую возможность решения задачи распознавания.

Если контур равновероятной плотности является разделяющей поверхностью, то сформировать его можно используя алгоритмы обучения, описанные в [94]. Использование алгоритмов обучения предполагает, что контур равновероятной плотности или разделяющая поверхность аппроксимируются рядом

$$\sum_{j=1}^n c_j \varphi_j(\bar{y}) = 0. \quad (3.33)$$

Во многих практических ситуациях более предпочтительно формировать разделяющую поверхность как огибающую элементарных фигур – гиперсфер, гиперкубов [41]. Уравнение каждой такой поверхности

$$\sum (y_i - m_i)^2 = R_j^2 \quad (3.34)$$

или

$$\sum |y_i - m_i| = R_j. \quad (3.35)$$

Центр фигуры естественно совмещается с математическим ожиданием m распределения вектора признаков \bar{y} . При этом для сферически симметричного распределения уравнение (3.34) является также контуром равновероятной плотности и достаточно компактно выделяет собственную область каждого класса. В качестве критерия оптимальности можно использовать функционал, минимизирующий объем собственной области при фиксированной вероятности правильного распознавания P_G [76]

$$I = V_G + \lambda \left(\int_G p(\bar{y}) d\bar{y} - P_G \right), \quad (3.36)$$

где λ – множитель Лагранжа.

Если область G замыкается единственной сферой, то функционал можно представить в виде

$$I = \frac{2\pi^{n/2}}{\Gamma(n/2) \cdot n} R^n + \lambda \left(\int_G p(\bar{y}) d\bar{y} - P_G \right), \quad (3.37)$$

где $\Gamma(n/2)$ – гамма-функция.

Необходимыми параметрами для формирования области G являются здесь координаты центра сферы \bar{m}_G и величина радиуса R . Исходя из выше сказанного, данный метод формирования областей можно назвать методом собственных областей класса (МСОК).

3.3. Определение структурной схемы алгоритма распознавания

В соответствии с изложенными материалами в предыдущем пункте разделяющая поверхность формируется как огибающая элементарных фигур вида (3.34) в пространстве вторичных (эффективных) признаков, в качестве которых используются оценки вида (3.17) $L^* = m^*[z_1 z_2]$ (здесь и далее для удобства будем использовать символ a^* для обозначения оценок параметров вместо ранее употреблявшегося символа \hat{a}). Поверхности элементарных фигур в виде гиперсфер запишутся в виде [76]

$$\sum_{i=1}^n (L_i^* - m_{ij}^*)^2 - (R_j^*)^2 = 0, \quad (3.38)$$

где L_i^* – значение оценки признака при i -м опорном распределении ($i = 1, 2, \dots, K$); m_{ij}^* – оценка математического ожидания признака при i -м опорном распределении для j -го эталона ($j = 1, 2, \dots, M$); R_j^* – оценка радиуса гиперсферы.

Так как оценки вектора \bar{L}_i^* распределены по сферически симметричному нормальному закону, то центр фигуры может быть совмещен с математическим ожиданием вектора признаков \bar{L}_i , а уравнение (3.38) при этом является контуром равновероятной плотности и достаточно компактно выделяет собственную область каждого класса.

Необходимыми параметрами для описания собственной области G здесь являются координаты центра сферы m_G и величина радиуса R . Эти величины получают при обучении устройства распознавания. Объем собственной области класса определяется минимальным радиусом $R_{i \min}$, при этом решающее правило может быть основано на попадании (или не попадании) распознаваемого

сигнала внутрь собственной области класса, охваченной радиусом $R_{i \min}$, и выглядит следующим образом

$$\begin{cases} \sum_{i=1}^n (\bar{L}_i^* - m_{ij}^*)^2 - (R_{j \min}^*)^2 \leq 0, & x(t) \in \omega_j; \\ \sum_{i=1}^n (\bar{L}_i^* - m_{ij}^*)^2 - (R_{j \min}^*)^2 > 0, & x(t) \notin \omega_j. \end{cases} \quad (3.39)$$

Формирование вектора оценок L_i^* может быть осуществлено в соответствии со структурной схемой, изображенной на рисунке 3.1.

На рисунке 3.1 реализация процесса подается одновременно на $2K$ компараторов, с другой стороны на входы компараторов подаются опорные процессы $\eta_i(t)$ с различными распределениями. В парах $\eta_i(t)$ имеют одинаковые распределения и также не зависимы друг от друга. В результате сравнения на выходе компараторов имеем K пар знаковых функций $z_i(t)$. В каждой паре один из процессов задерживается на величину τ , и затем оба процесса $z_i(t)$ и $z_i(t + \tau)$ подаются на интегратор. В результате усреднения на выходе каждого i -го интегратора формируется оценка случайной величины (3.16), статистические характеристики которой зависят как от статистических характеристик распознаваемого процесса $x(t)$, так и от статистических характеристик опорного процесса $\eta_i(t)$, имеющего функцию распределения $F_{\eta_i}(x)$.

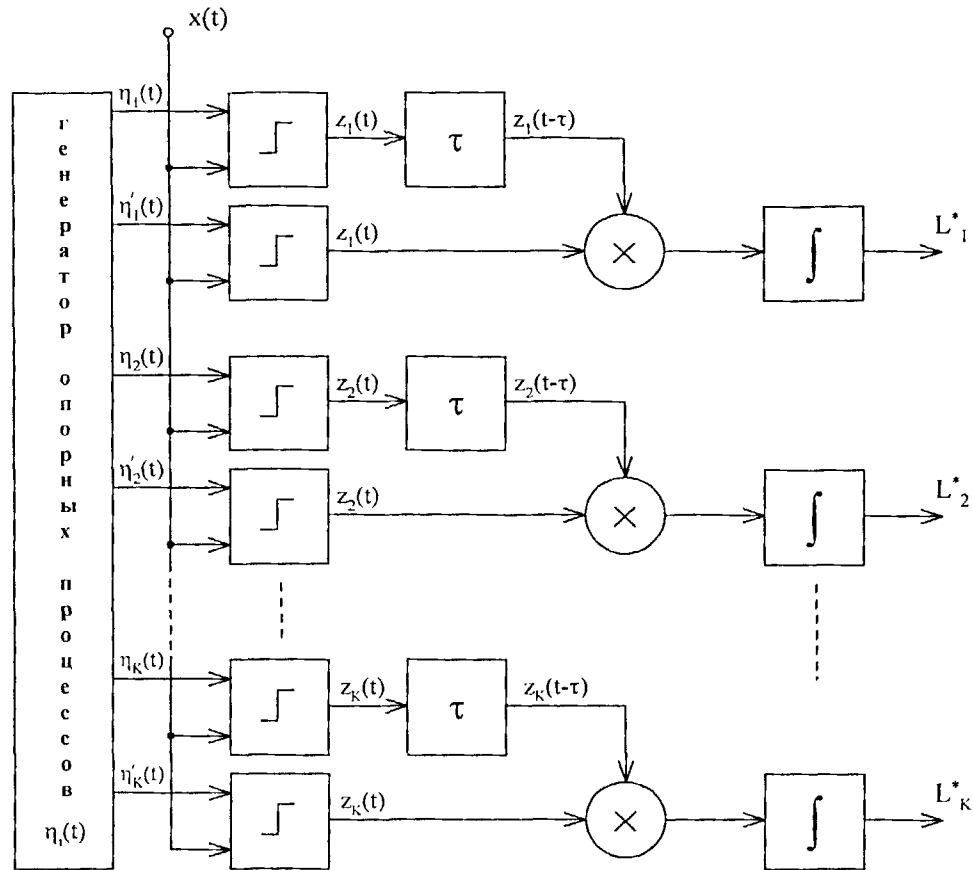


Рисунок 3.1 – Структурная схема формирователя вектора признаков \bar{L}_i^*

На структурной схеме формирователя вектора признаков использованы обозначения для случая, когда исследуемый процесс $x(t)$ представлен в виде непрерывного аналогового сигнала. Для дискретного случая обозначения на рисунке 3.1 заменяются следующим образом: t на n , τ на nT_0 , а интеграл заменяется знаком суммы.

При обучении величины m_{ij} определяются как среднестатистические значения векторов L_i^* , получаемых при подаче на вход обучающих реализаций.

Величины R_j получаются на этапе обучения после получения значений оценок m_{ij}^* . В [76] предлагается рекуррентная процедура определения радиуса гиперсферы, основанная на алгоритмах обучения, изложенных в [94]

$$R[n] = \begin{cases} R[n-1], & \bar{r} \in G; \\ R[n-1] + \gamma, & \bar{r} \notin G, \end{cases} \quad (3.40)$$

где γ – коэффициент, определяющий скорость сходимости процедуры.

Несмотря на простоту вычисления радиуса с помощью процедуры (3.40), использовать ее в любых случаях затруднительно, так как возникает задача нахождения значения коэффициента γ , подходящего с точки зрения скорости завершения работы алгоритма и точности оценок R_j^* .

Можно воспользоваться более простым методом нахождения R_j^* , естественно вытекающим из структуры решающего правила (3.39). В результате усреднения оценок R^* (величина R_j является случайной и распределена нормально), получаем

$$\left(r_j^*\right)^2 = \frac{1}{N} \sum_{k=1}^N \left[\sum_{i=1}^K \left(L_i^* - m_{ij}^*\right)^2 \right], \quad (3.41)$$

где K – размерность признакового пространства (количество опорных распределений); N – количество оценок r_i^* , полученных при обучении.

Приближенно (с ошибкой $\alpha \approx 2,5\%$) можно определить

$$R_j \approx r_j^* + 2 \cdot \sigma_{r,j}, \quad (3.42)$$

где $\sigma_{r,j}$ – среднееквадратическое значение оценки r_j^* .

Таким образом, структурная схема непараметрического классификатора (НК) моделей сигналов изображений имеет вид, представленный на рисунке 3.2. Схема алгоритма НК моделей сигналов изображений представлена на рисунке 3.3 (режим «Обучение») и рисунке 3.4 (режим «Классификация»).

3.4 Исследование влияния вида и количества опорных распределений на эффективность классификатора

Известно [85], что с повышением размерности признакового пространства (при условии использования эффективных признаков, с точки зрения заданного критерия) качество работы классификатора улучшается. Однако значительное увеличение количества признаков ведет к необоснованному усложнению аппаратуры распознавания и, в конечном счете, потере рентабельности разрабатываемого оборудования. Поэтому остается открытым вопрос, какое количество и, самое главное, какие признаки должны использоваться при классификации процессов, то есть стоит задача оптимизации размерности признакового пространства.

Рассмотренные в п. 2.3 методы оптимизации количества используемых признаков применимы только в случаях, когда известны хотя бы оценочные зависимости ошибок первого и второго рода от времени обучения и распознавания. Однако для случая использования признаков, сформированных с применением метода стохастического кодирования, такие зависимости не получены.

Так как методика получения признаков для распознавания уже определена, то, говоря о виде признаков, имеем в виду вид плотности распределения вероятности опорного процесса. Решение задачи выбора опорного распределения (или опорных распределений) в данном случае не может быть формализовано. Здесь многое зависит от опыта и интуиции разработчика.

Говоря об эффективных признаках, имеют в виду признаки, использование которых максимизирует некоторый заданный критерий. В нашем случае таким критерием является, как уже указывалось, достоверность распознавания. Однако найти аналитическую зависимость между достоверностью и количеством опорных распределений, а также их параметрами, не представляется возможным. Но, если рассмотреть критерий (3.37), то можно видеть, что параметром, влияющим на достоверность распознавания, является радиус собственной области распознаваемых классов процессов, который, в свою очередь, напря-

мую зависит от дисперсий оценок признаков классов. Поэтому можно сказать, что минимизация дисперсий оценок признаков (минимизация радиусов собственных областей классов) ведет к максимизации достоверности распознавания.

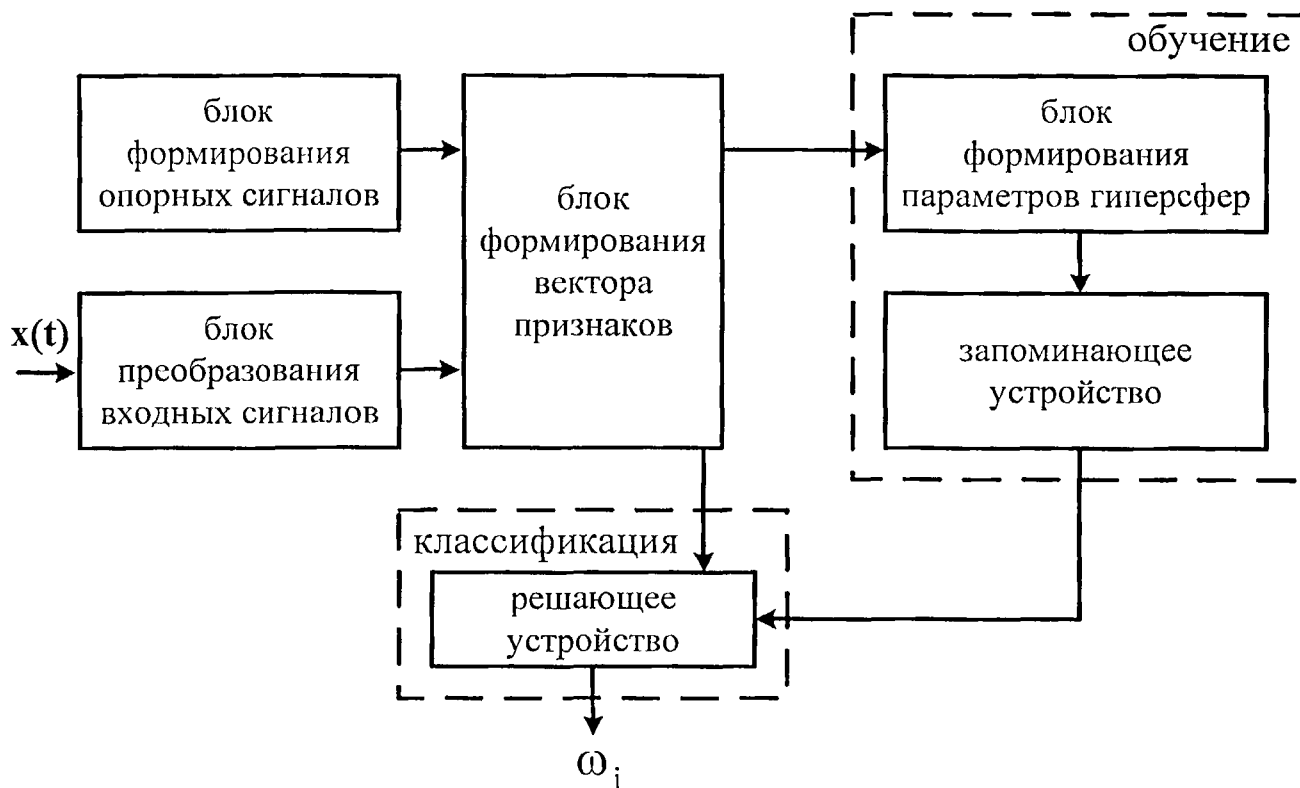


Рисунок 3.2 – Структурная схема НК

С целью определения влияния на дисперсии оценок признаков (главная цель состоит в её минимизации) видов закона опорных распределений были проведены статистические испытания с использованием программной реализации приведённых алгоритмов в пакете математического моделирования Matlab фирмы MathWorks Inc. [6, 37, 45]. Программная реализация позволяет строить графики для $m_r(k)$ и $\sigma_r(k)$ – зависимостей оценок математического ожидания (МО) оценок и среднеквадратического отклонения (СКО) оценок признаков от вида закона распределения использованных опорных [93]. Структурная схема численного эксперимента может быть представлена в виде, приведенном на рисунке 3.5, а определение погрешности результатов моделирования проведено в п.4.6. На рисунке 3.8, рисунке 3.12, рисунке 3.14 показаны виды опорных рас-

пределений, входных сигналов и зависимости изменения $\text{tr}(k)$ и $\sigma_r(k)$ от номера опорного распределения для значения интервала наблюдения $T = 10^3 \Delta t$, где Δt – интервал дискретизации исследуемых сигналов.

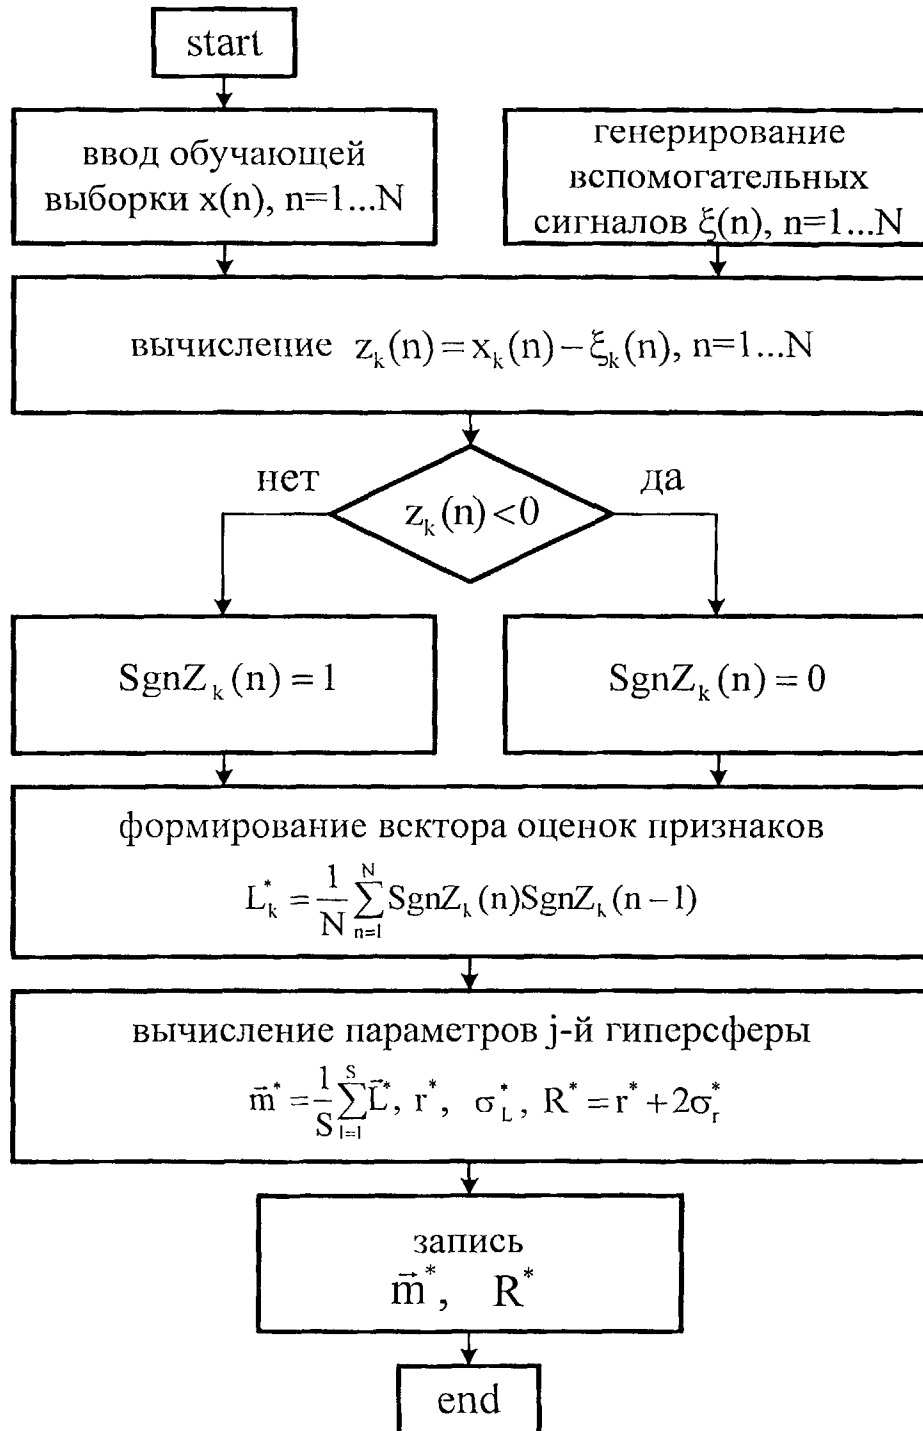


Рисунок 3.3 – Схема алгоритма работы НК в режиме «Обучение»

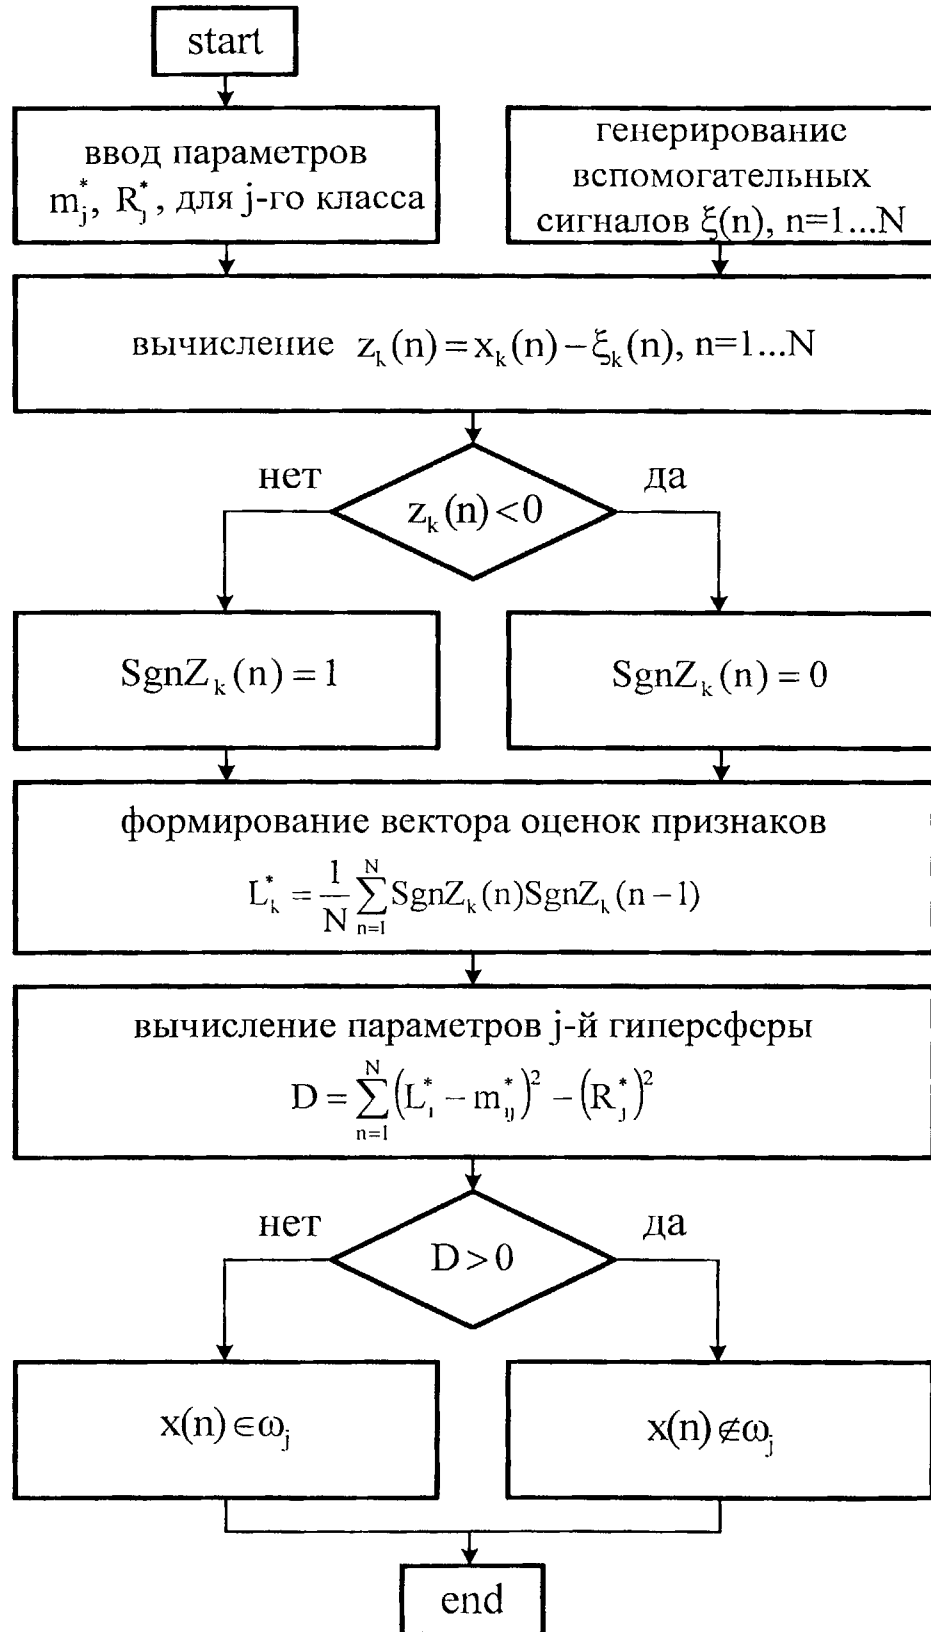


Рисунок 3.4 – Схема алгоритма работы НК в режиме «Классификация»

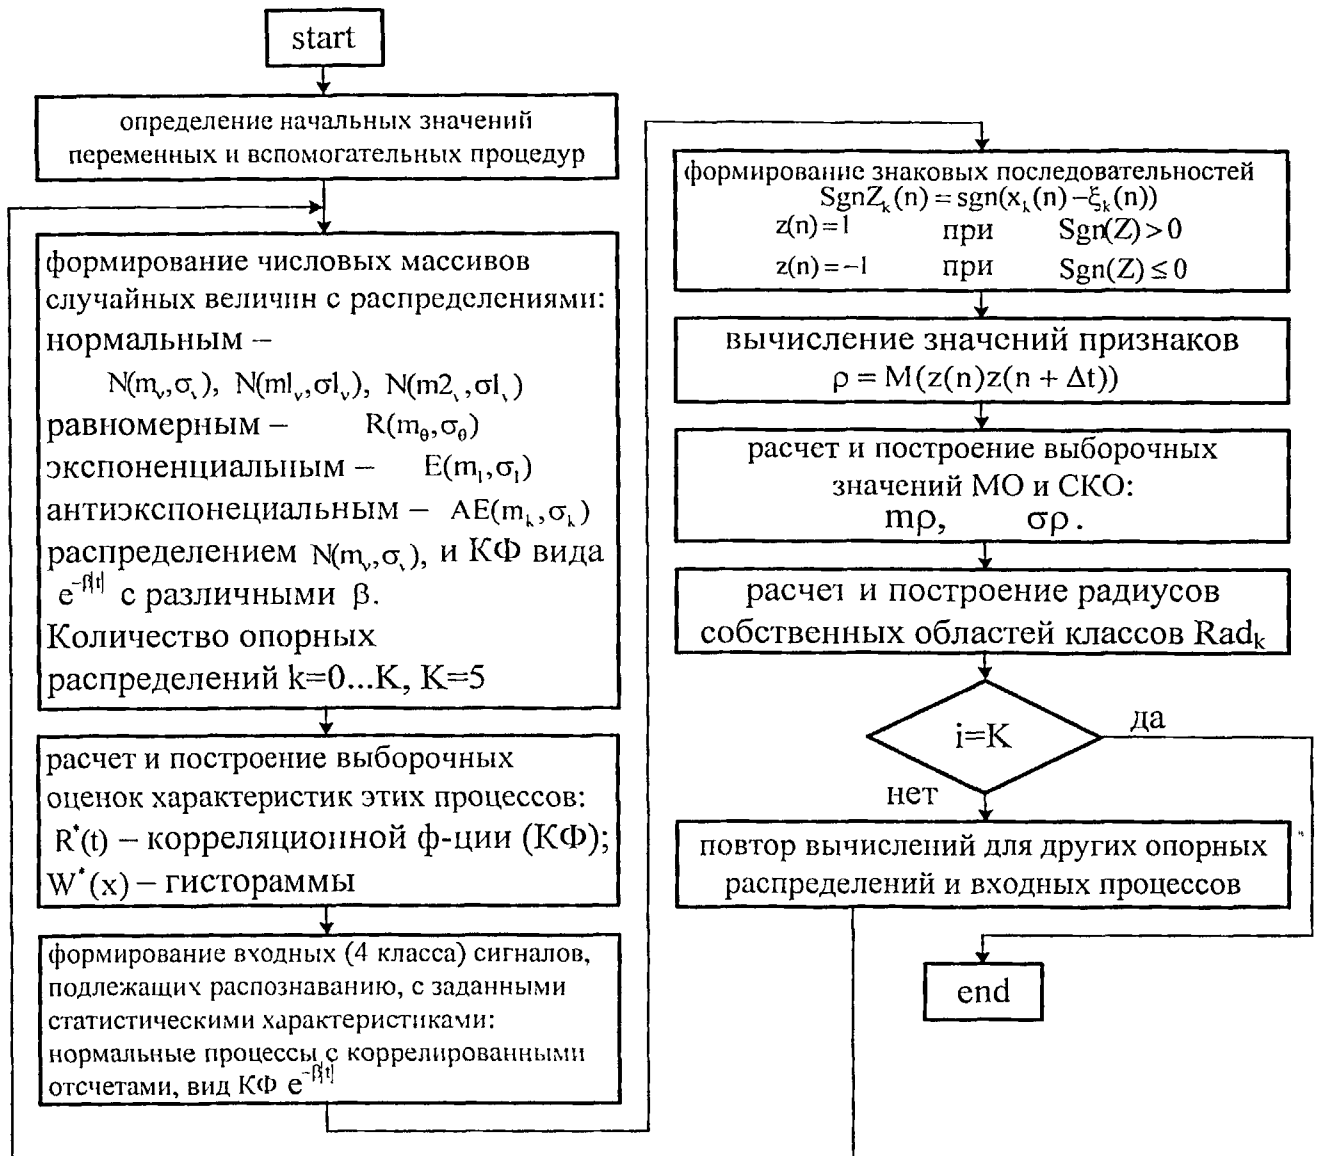


Рисунок 3.5 – Структурная схема алгоритма работы НК (формирование классификационных признаков в режиме обучения).

На рисунке 3.6 показан вид процессов, подлежащих распознаванию.

Исследуемые реализации процессов – нормальные процессы с одинаковым одномерным законом распределения и различным видом корреляционных функций (КФ). Здесь под различными КФ понимаются функции, имеющие одинаковый, вид но различные интервалы корреляции процессов. На рисунке 3.6 представлены примеры временных диаграмм процессов с различными видом КФ, оценочные значения которых представлены на рисунке 3.7. Вид корреляционных функций – убывающий экспоненциальный ($R(\tau) = e^{-\beta|\tau|}$). Вход-

ные процессы генерировались в соответствии с алгоритмом, изложенным в [10, 13, 21], основанным на обработке с помощью рекуррентных процедур отсчетов нормального некоррелированного процесса. Физической моделью данных рекуррентных процедур является пропускание широкополосного нормального шума через фильтр низких частот (ФНЧ), при этом коэффициент β функции корреляции определяется значением граничной частоты ФНЧ f_c . В данном случае четыре класса случайных процессов были сгенерированы для значений f_c , равных $f_0 = 100$ Гц, $f_1 = 200$ Гц, $f_2 = 400$ Гц, $f_3 = 600$ Гц.

По сгенерированным входным процессам были сформированы наборы признаков для каждого из четырех классов. При этом использовался набор из шести опорных процессов с некоррелированными отсчетами и различными плотностями распределения вероятностей, вид которых представлен на рисунке 3.8, а выборочная КФ для одного из процессов – на рисунке 3.9.

На рисунках 3.10 и 3.13 представлены графики зависимости значений МО, СКО и относительного среднеквадратического значения дисперсии сформированных признаков от номера опорного распределения k ($k=0, \dots, 5$). Приведено по три графика упомянутых зависимостей, соответствующих процессам, приведенных на рисунке 3.6. На указанном рисунке цифрами от 0 до 3 обозначается принадлежность линии к одному из четырех классов входных процессов данного вида.

В таблице 3.1 представлены значения радиусов собственных областей четырех классов для данного вида классифицируемых процессов.

Анализируя полученные результаты, можно отметить следующее.

1. Для каждого из видов сигналов существует опорное распределение, которое обеспечивает наибольшее различие признаков классифицируемых процессов.

2. Из графиков на рис.3.10 видно, что в случае классификации процессов с одинаковыми одномерными плотностями распределений и различными КФ (рисунок 3.7) наибольшей разделяющей способностью обладают те опорные сигналы, плотность вероятности которых имеют больший процент перекрытия

с плотностью вероятности входного процесса, подлежащего классификации. Так, максимальное различие между МО признаков (рисунки 3.10.а) обеспечивается опорным процессом с порядковым номером 3 ($k=3$), площадь под кривой плотности вероятности которого практически полностью перекрывается с площадью под кривой плотности вероятности классифицируемых процессов; при этом относительные значения среднеквадратических дисперсий оценок признаков минимальны (рисунки 3.10.в).




Рисунок 3.6 – временные диаграммы исследуемых процессов



Рисунок 3.7 – Оценки корреляционных функций исследуемых процессов

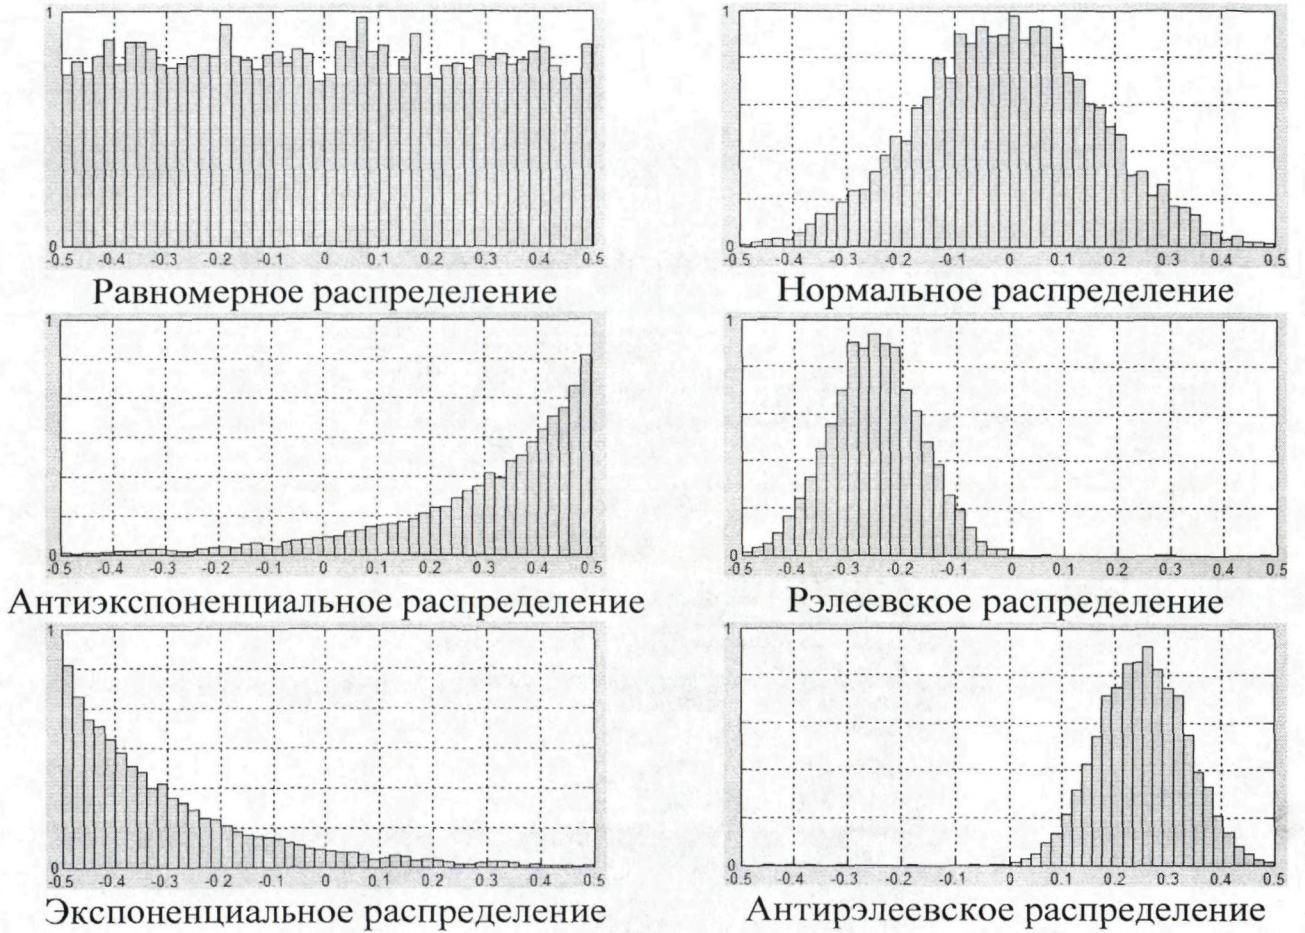


Рисунок 3.8 – Гистограммы оценок плотностей распределения вероятностей опорных процессов
Отсчеты оценки КФ процесса




Рисунок 3.9. Выборочные оценки корреляционной функции одного из опорных процессов

Таблица 3.1 – Радиусы собственных областей классов для различных классов исследуемых процессов

| | класс 0 | класс 1 | класс 2 | класс 3 |
|--------|---------|---------|---------|---------|
| радиус | 0.159 | 0.113 | 0.095 | 0.088 |




Рисунок 3.10 – Графики изменения значений а – МО, б – СКО и в – относительного СКО оценок признаков в зависимости от вида опорного распределения

Из представленных результатов можно сделать следующие выводы.

При классификации процессов, когда отсутствуют сведения не только о параметрах их распределений, но и об их виде, необходимо формировать опорные процессы с учетом следующих соображений:

- моды плотностей вероятности опорных процессов распределены равномерно по интервалу $[a, b]$, для обеспечения максимальное перекрытие плотностей вероятности хотя бы для одного из признаков классифицируемых и опорных процессов;

- для того, чтобы избежать генерирования «лишних» опорных процессов, можно применять методы разведочного анализа данных (РАД) [3, 4], позволяющие быстро оценить вид и основные параметры распределения исследуемых входных процессов (в данном случае низкая точность оценок при использовании РАД не играет роли). Это позволит генерировать только опорные процессы, максимально перекрывающиеся своими распределениями с входными сигналами.

Возвращаясь к вопросу о количестве используемых признаков, то есть о размерности признакового пространства, можно сказать следующее.

Задача оптимизации размерности признакового пространства должна, очевидно, включать в себя как составную часть, рассмотренную в п. 2.4, задачу оптимизации суммарного объема $\rho=(2m+n)$ (при количестве классов, равном 2)

обучающих и контрольной выборок, то есть представлять собой обобщение этой задачи на случай минимизации суммарного количества измерений по всем p признакам $p=p(2m+n)$, обеспечивающего достоверность распознавания не хуже заданного значения $\alpha^*=\alpha_{\max}$, $\beta^*=\beta_{\max}$.

Ограниченные возможности реальных распознающих систем по обработке результатов измерений по каждому из p признаков позволяют всегда считать число признаков p ограниченным некоторой величиной P ($p \leq P$). Кроме того, максимально возможные значения объемов обучающих m и контрольной n выборок, как правило, ограничены некоторыми предельными значениями M и N ($m \leq M$, $n \leq N$), причем здесь помимо соображений, связанных с ограниченностью сил и средств на проведение необходимых обучающих и контрольных наблюдений (в общем, аналогичных тем, которые ограничивают размерность p признакового пространства), на первый план выступают жесткие требования по ограниченности времени обучения и принятия решения, которые часто с требуемой достоверностью распознавания являются определяющими факторами при построении распознающей системы.

При фиксированном значении p с увеличением объема обучающих m и контрольной n выборок вероятность ошибки распознавания α , β , очевидно, уменьшается. Следовательно, с учетом ограничений ее минимально возможное значение достигается при фиксированном значении p , когда m и n , увеличиваясь, оказываются равными своим предельным значениям $m=M$ и $n=N$. Если при этом достигнутое значение вероятности ошибки $\alpha^*(M,N,p)$ остается больше заданного по условиям задачи значения α_{\max} , то единственным путем ее дальнейшего уменьшения остается увеличение размерности признакового пространства p . Находим оценку вероятности ошибки распознавания $\alpha^*(M,N,p)$ при $p=1, 2, \dots, p_0$, до тех пор, пока не окажется, что

$$\alpha^*(M,N,p) \leq \alpha_{\max}. \quad (3.43)$$

Зафиксировав найденное значение $p=p_0$, необходимо решить задачу оптимизации $(2m+n) \rightarrow \min$, $\alpha^* \leq \alpha_{\max}$, то есть найти такие значения количества обучающих m и контрольной n выборок, при которых достигался бы заданный предел ошибки распознавания α_{\max} .

3.5 Исследование влияния времени обучения и распознавания на эффективность классификатора

Под временем обучения и распознавания принято понимать объемы обучающих m и контрольной n выборок [85]. Задача минимизации общего числа выборок уже рассматривалась в предыдущих пунктах и основные ее аспекты уже сформулированы. Необходимо только добавить, что, как уже указывалось, прямая аналитическая зависимость между достоверностью распознавания (основным параметром эффективности системы) и объемами обучающих, и контрольных выборок для данного непараметрического случая до сих пор не найдены. Поэтому в качестве параметра, влияющего на достоверность распознавания, будем использовать дисперсии оценок признаков, определяющие значения радиусов собственных областей классов в признаковом пространстве.

Прежде чем рассматривать вопрос о том, какие объемы обучающих и контрольных выборок обеспечивают заданную достоверность распознавания, необходимо определить достаточные размеры статистик для формирования одного отсчета признаков или одного элемента в признаковом пространстве для заданного класса исследуемых сигналов.

Можно показать [27], что количество отсчетов классифицируемого процесса, необходимое для формирования одного признака и объем выборки, по которой формируется собственная область класса, имеют прямо пропорциональную зависимость. То есть, например, если для формирования собственной области G_j класса ω_j с минимальным радиусом $R_{j\min}$ необходима выборка из 100 значений признака, сформированного на основе 100 отсчетов входного сигнала

каждое, то эту же область можно получить используя 10 значений признака с 1000 отсчетами.

Однако необходимо знание объема выборки классифицируемых процессов, требуемого для формирования одного признака, обладающего минимальной дисперсией, с целью дальнейшего изучения влияния размеров выборки признаков на достоверность распознавания.

С целью нахождения объемов статистик для заданных классов, обеспечивающих минимизацию дисперсий оценок признаков, было проведено статистические испытания с использованием программ, листинги которых приведены в приложении. Программная реализация позволяет получать графики для $m_r(k)$ и $\sigma_r(k)$ – зависимостей математического ожидания (МО) и среднеквадратического отклонения (СКО) оценок признаков от количества отсчетов процессов, используемых для их получения, а также зависимости $Rad(i)$ для радиусов собственных областей заданных классов классифицируемых процессов, получаемых при обучении классификатора. Структурная схема численного эксперимента может быть представлена на рисунке 3.11. На рисунках 3.12 – 3.19 показаны виды опорных распределений, входных процессов и зависимости изменения $m_r(i)$, $\sigma_r(i)$ и $Rad(i)$ от количества отсчетов входного процесса (от интервала времени обучения $T = \Delta t i$).

Рассматриваются процессы, подлежащие распознаванию, имеют одинаковы вида закона распределения отсчётных значений. Это нормальные процессы с одинаковыми одномерными плотностями распределений (рисунок 3.12) и различными корреляционными функциями. Вид КФ – убывающий экспоненциальный. Оценочные значения КФ сгенерированных входных процессов представлены на графиках на рисунке 3.13. Множество входных процессов разбито на 4 класса, соответствующие корреляционным функциям на рисунке 3.13.

По сгенерированным входным процессам были сформированы наборы признаков для каждого из четырех классов. При этом использовался набор опорных сигналов из шести опорных процессов с некоррелированными отсчетами и различными плотностями распределения вероятностей, вид которых

представлен на рисунке 3.14, а выборочная КФ для одного из процессов – на рисунке 3.15.

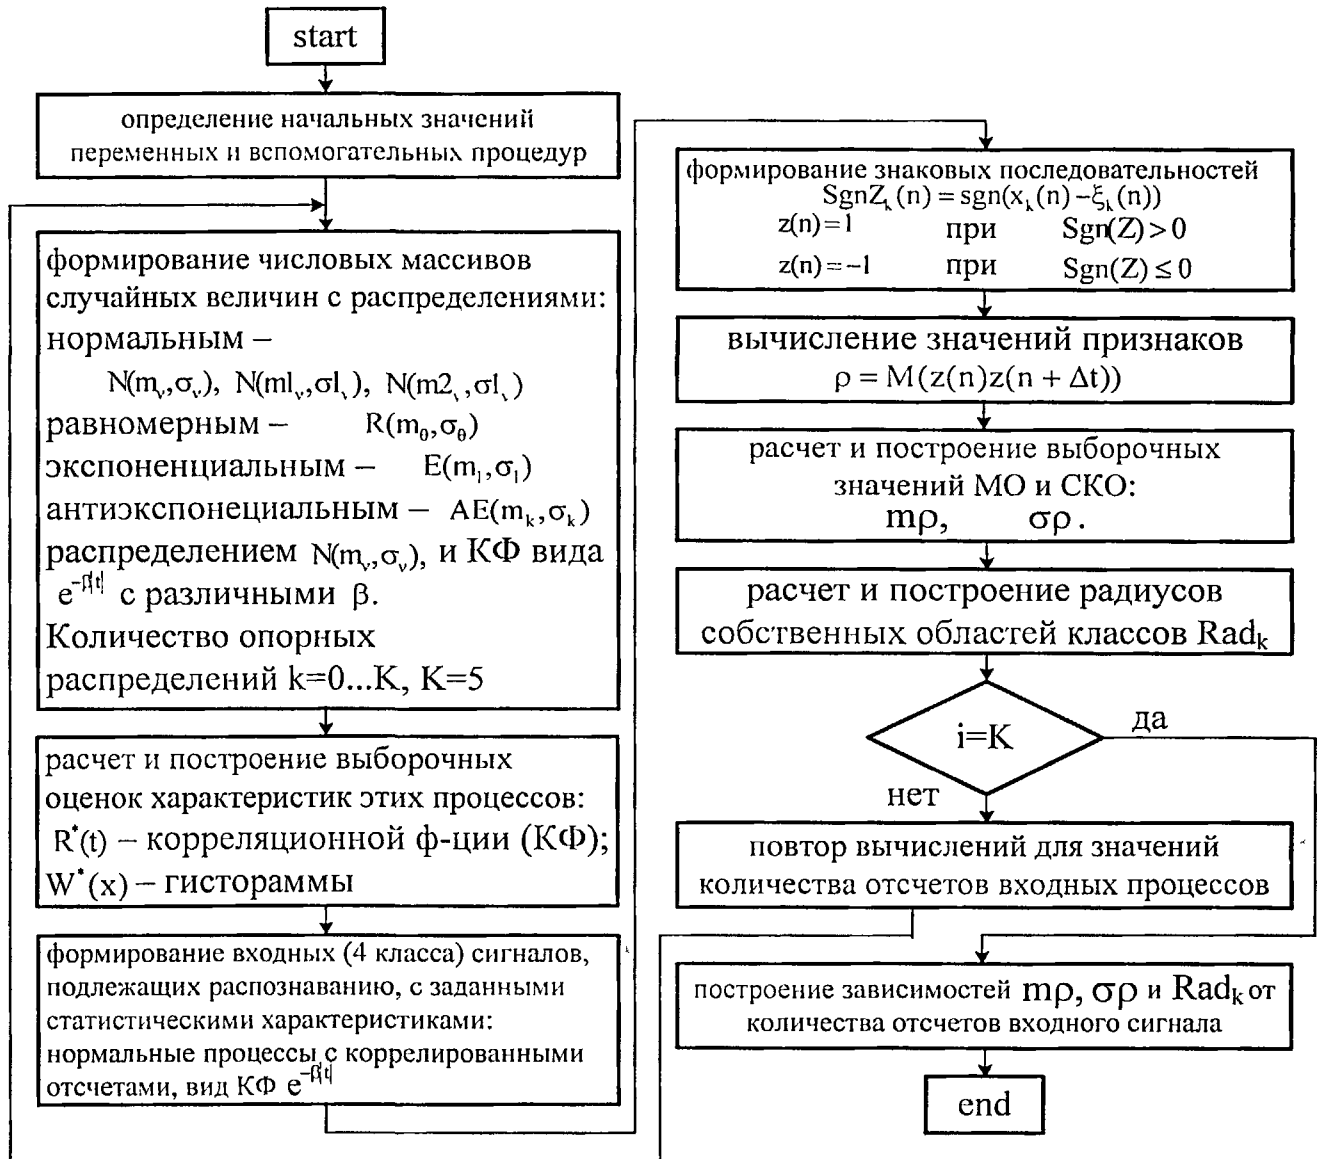


Рисунок 3.11 – Структурная схема алгоритма работы НК (формирование классификационных признаков при различных интервалах обучения)

На рисунках 3.16 и 3.17 представлены графики зависимостей значений МО оценок, СКО оценок признаков и оценок радиусов собственных областей классов, полученных при обучении, от количества отсчетов классифицируемого процесса, для формирования одного значения признака. Опорные процессы – некоррелированные, с модами плотностей вероятности, распределенными в диапазоне значений сигналов. Оценки радиусов найдены исходя из количества

отсчетов признаков каждого класса, равного 10. На данных графиках представлены зависимости при изменении числа отсчетов классифицируемых процессов от 100 до 3000. На рисунках 3.18 и 3.19 представлены те же зависимости, но при изменении числа отсчетов классифицируемых процессов от 10^3 до 10^4 . Графики для МО и СКО оценок признаков приведены только для одного из четырех исследуемых классов.




Рисунок 3.12 – Плотность распределения вероятностей входных процессов




Рисунок 3.13 – Оценки КФ четырех классов входных процессов




Рисунок 3.14 – Плотности распределения вероятностей опорных процессов



Рисунок 3.15 – Оценка КФ одного из опорных процессов




Рисунок 3.16 – Графики изменения а – МО и б – СКО оценок признаков класса при увеличении количества отсчетов в обучающей выборке




Рисунок 3.17 – График изменения оценок радиусов собственных областей классов при увеличении количества отсчетов в обучающей выборке

Анализируя полученные результаты можно отметить следующее.

1. Из рисунков 3.16 – 3.19 видно, что увеличение количества отсчетов входного процесса для формирования одного признака приводит к «стабилизации» МО оценок признаков и уменьшению СКО оценок признаков. Однако, как видно из графиков, увеличивать количество отсчетов больше 1000 нецелесообразно, так как при этом значения СКО уменьшаются незначительно.

2. Сравнивая зависимости СКО от времени обучения для различных классов, можно сделать вывод, что скорость убывания оценок СКО, с увеличением времени обучения, зависит от интервала корреляции (τ_k) классифицируемых процессов. Чем больше τ_k , тем выше скорость убывания. Можно дать примерную оценку: для классифицируемых процессов с экспоненциальной КФ, при вычислении признака, достаточно времени наблюдения, равном $20\tau_{м.к.}$, где $\tau_{м.к.}$ – максимальный интервал корреляции входного процесса.

3. Как видно из графиков зависимости МО оценок признаков от времени обучения, при симметричных распределениях классифицируемых процессов эффект использования опорных сигналов с равномерно распределенными по

интервалу $[a, b]$ модами симметричен (на рис.3.16.а, 3.18.а оценки МО признаков класса 0 и 3, 1 и 2 практически совпадают). То есть в данном случае можно использовать опорные процессы с модами, равномерно распределенными только в половине интервала $[a, b]$.




Рисунок 3.18 – Графики изменения а – МО и б – СКО оценок признаков класса при увеличении количества отсчетов в обучающей выборке




Рисунок 3.19 – График изменения оценок радиусов собственных областей классов при увеличении количества отсчетов в обучающей выборке

Из представленных результатов можно сделать следующие выводы.

При формировании классификационных признаков методом стохастического кодирования число отсчетов сигналов не должно превышать значение, соответствующее времени измерения, равному $20\tau_{\text{м.к.}}$; в противном случае это ведет к необоснованному увеличению суммарного времени обучения системы распознавания.

Выводы по материалам 3 главы

1. Выбран метод формирования классификационных признаков, основанный на принципах измерения корреляционных моментов преобразованных сигналов изображений с помощью функций знаковой корреляции. Установлено, что в случае распознавания случайных процессов с одинаковыми одномерными плотностями распределения вероятностей и различными корреляционными функциями, высокие показатели эффективности имеют признаки, сформированные на основе корреляционных моментов знаковых функций, получаемых при сравнении входных процессов с опорными.

2. При использовании метода стохастического кодирования возрастает дисперсия оценок измеряемых моментов, однако при этом достигаются следующие положительные результаты: сокращается избыточность описания процессов, подлежащих распознаванию; упрощается реализация алгоритма распознавания в микропроцессорных системах за счет применения одноразрядного квантования, дающего на выходе только знаки отсчетов.

3. Разработан алгоритм непараметрической классификации моделей сигналов изображений, использующий в качестве признаков корреляционные моменты знаковых последовательностей, сформированных на основе метода стохастического кодирования.

4. Исследованные зависимости показателей качества разработанного алгоритма от вида и количества опорных распределений и от времени обучения и классификации позволяют обоснованно с точки зрения аппаратных и временных затрат подходить к выбору опорных распределений, количества отсчетов сигнала для формирования одного признака и объемов обучающих выборок, необходимых для классификации процессов с заданной достоверностью.

4 МОДЕЛИРОВАНИЕ И ЭКСПЕРИМЕНТАЛЬНАЯ ПРОВЕРКА ЭФФЕКТИВНОСТИ РАБОТЫ КЛАССИФИКАТОРА СИГНАЛОВ ПОЛУТОНОВЫХ ИЗОБРАЖЕНИЙ

4.1 Постановка экспериментального исследования

Основная задача данной главы – проведение программного эксперимента на ЭВМ и оценка эффективности работы разработанного непараметрического классификатора в сравнении с известным непараметрическим классификатором по методу k -ближайших соседей. Сравнительный эксперимент будет проводиться на предложенных моделях сигналов полутоновых изображений. Основным показателем эффективности будет определение вида зависимостей вероятности классификации от количества объектов.

В качестве исходных данными будут использованы оцифрованные полутоновые изображения реальных объектов, искусственно разделённых на четыре класса по определенным признакам.

4.2 Методы моделирования устройств обработки сигналов, с использованием пакетов программ математического моделирования

Этапы построения математической модели какого-либо объекта, в том числе и физического, было обсуждено в п 1.1. Можно уточнить, что построение модели сопровождается решением следующих задач [39, 91]:

- 1) выбор структурной схемы модели из физических соображений;
- 2) математическое описание элементов выбранной структурной модели;
- 3) построение цифровой модели и подгонка ее параметров к имеющимся данным (оценивание);
- 4) проверка и подтверждение модели (диагностическая проверка);
- 5) использование модели по назначению.

Выбор структурной схемы и математическое описание структурных звеньев устройств непараметрической классификации было проведено в п.3.3. Здесь основное внимание уделяется решению третьей задачи с учетом возможностей, предоставляемых современными пакетами для математического моделирования. Структура цифрового представления математической модели определяется видом математического описания структурных компонент классификатора. Возможные методы, с помощью которых осуществляется построение цифрового представления математической модели [39, 91]:

- 1) метод конечных разностных уравнений;
- 2) метод несущей;
- 3) метод комплексной огибающей;
- 4) формульный метод;
- 5) метод статистических испытаний;
- 6) метод статистических эквивалентов;
- 7) метод структурных схем;
- 8) метод информационного параметра.

Наиболее адекватным из представленных методов моделирования устройств обработки сигналов для случая, рассматриваемого в данной диссертационной работе, является метод статистических испытаний (МСИ) [39]. В основе метода лежат предельные соотношения теории вероятностей – центральная предельная теорема и закон больших чисел. Основное достоинство МСИ: при точном знании математических моделей системы и случайных внешних воздействий позволяет получить результаты, не отличающиеся от натурального эксперимента. Перечисленные достоинства МСИ, а также особенности решаемой задачи, позволяют использовать его для определения показателей качества НК.

Использование МСИ для анализа устройств обработки сигналов предполагает следующие этапы:

- 1) задание вида функционального преобразования исходного сигнала. Для такого задания можно использовать любой из методов 1) - 4) предыдущей клас-

сификации. Результатом данного этапа является дискретная модель системы, представляемая в виде:

$$\Theta[\Delta \cdot i + \Delta] = F[\Theta(i \cdot \Delta), i, z(i \cdot \Delta)], \quad i = 1, \dots, N, \quad (4.1)$$

где $\Theta(i \cdot \Delta)$ – искомая функция, описывающая реакцию системы; $F[\cdot]$ – функция (или функционал), определяющая вид преобразования входного случайного процесса $z(i \cdot \Delta)$, заданного в N точках; Δ – продолжительность интервала дискретизации по времени.

Основные требования на данном этапе: адекватность математического описания физической модели системы и минимизация вычислительных затрат для получения последующего значения $\Theta(i \cdot \Delta)$;

2) Генерация случайных значений процесса $z(i \cdot \Delta)$ и начального состояния системы $\Theta(0) = \Theta_0$. Требования к числовой последовательности $z(i \cdot \Delta)$ заключаются в выполнении равенства статистических характеристик числовой последовательности (моментов, закона распределения) заданным значениям. При моделировании простых одномерных систем обработки сигналов (имеющих один вход и выход), как правило, полагают достаточным выполнение требования одновременного равенства одномерного закона распределения и корреляционной функции генерируемой числовой последовательности заданным значениям;

3) Используя выражение (4.1) определение выходного случайного процесса $\Theta(i \cdot \Delta)$ для многократных испытаний, т. е. для различных реализации $z(i \cdot \Delta)$.

Для каждой реализации рассчитывается значение показателя качества системы, подлежащего оценке (критерий качества, среднеквадратическая ошибка и т.п.). Окончательное среднее значение показателя обычно определяется как среднее арифметическое всех показателей [54]. Точность получаемых

результатов с использованием МСИ определяется СКО оценок m_{Θ}^* и D_{Θ}^* , а именно, значениями

$$\sigma_{m^*} = \sqrt{D[m_{\Theta}^*]} \text{ и } \sigma_{D^*} = \sqrt{D[D_{\Theta}^*]}.$$

Точность МСИ [54, 92] относительно медленно возрастает с увеличением числа испытаний. К примеру увеличение количества испытаний на два порядка приводит к уменьшению значений σ_{m^*} и σ_{D^*} только на порядок.

Одной из целей диссертационной работы является определение характеристик устойчивости и эффективности предлагаемых алгоритмов с последующим сравнительным анализом, поэтому важны потенциальные значения этих характеристик. В статистической радиотехнике под такими характеристиками понимают показатели качества идеальных устройств обработки (заданных своей математической моделью) сигналов.

В качестве средств для проведения программного эксперимента используются пакеты программ математического моделирования Matlab, что предоставляет исследователю большие возможности. Основные из этих возможностей следующие [37]:

- 1) удобная и гибкая система представления результатов в графическом виде;
- 2) гибкий и адаптированный для удобного использования собственный язык программирования с интуитивно понятным синтаксисом и системой отладки листингов программ. Ориентирован на неспециалистов в области программирования;
- 3) большое количество встроенных функций, ориентированных на работу со статистическими данными и представленными в виде массивов;
- 4) алгоритмы, используемые во встроенных функциях, являются общепринятыми и хорошей изученностью. Вычисление дифференциалов, интегра-

лов, операции с матрицами, численные методы решения системы уравнений осуществляется отлаженными стандартными методами.

Благодаря простому и интуитивному программному интерфейсу достаточно просто пользоваться различными программными модулями.

Современные программные пакеты математического моделирования значительно упрощают подготовку, отладку и проведение программного и числового моделирования и эксперимента. Во-первых, отпадает надобность рассчитывать число итераций программы с целью ее оптимизации, поскольку при выполнении стандартных вычислений используются оптимизированные по этому критерию процедуры. Также имеются гибкие и удобные в использовании встроенные инструменты представления вводимой и выводимой информации, писать тексты программ известных алгоритмов стандартных математических вычислений, используемых при расчетах (например, операции с матрицами, БПФ и т.п.).

Во-вторых, производительность современных настольных рабочих станций в сочетании с невысокой ценой (а значит и высокой доступностью), позволяет значительно сократить время проведения эксперимента очень громоздких алгоритмов до величин, имеющих порядок десятков секунд или минут.

Вместе с тем множество частных задач не позволяет использовать универсальные пакеты с универсальными алгоритмами. В силу их универсальности, вычисления определенных выражений, с высокой степенью вложенности циклов, использование этих пакетов занимают значительно больше времени, чем написание и использование программ на языках высокого уровня (например Java, C++ и пр.). Благодаря гибкости системы Matlab имеется возможность производить вычисления с помощью функций пользователя, в том числе написанные на любом из поддерживаемых этой системой языке высокого уровня (к примеру C или C++), и поддерживающие протокол обмена данными между программами, входящими в состав пакета.

Важной проблемой при проведении программного эксперимента с использованием специальных пакетов является обеспечение требуемой точности

и адекватности результатов моделирования. При решении некорректных задач необходимо так строить вычисления, чтобы уровень ошибки, получаемый на каждом этапе, была минимален или компенсировался на последующих итерациях. Настоятельно рекомендуется придерживаться определенной последовательности блоков вычислительных операций, обеспечивающей наибольшую устойчивость результатов при проведении эксперимента к вариации входных данных и начальных условий. При использовании математических пакетов, предусматривающих проведение вычислений в порядке расположения формул, приводит к необходимости преобразованию формул и структуры алгоритма для обеспечения передачи результатов вычислений в нужном порядке. Многочисленные примеры в пакете Matlab, подтверждающие данные выводы, приведены в [45]. Также необходимо обеспечить простоту исполнения самих программ, позволяющую не только быстро разобраться в написанном коде, но и легко его преобразовать для конкретной частной задачи.

4.3 Реализация работы алгоритмов непараметрического распознавания в пакете математического моделирования

Из представленного в п. 3.3 описания алгоритмов работы НК следует, что их показатели качества – вероятности суммарных ошибок по классам $P_{ош i}$, $i = \overline{1, K}$ зависят от многих параметров [68]:

- 1) длительности интервала наблюдения или количества отсчетов входного сигнала, необходимых для формирования одного признака;
- 2) размерности вектора признаков p ;
- 3) продолжительности процедур обучения и распознавания или объемов обучающих и контрольной выборок n и m ;
- 4) вида опорных распределений процессов, используемых при формировании вектора признаков.

Реализация работы алгоритмов непараметрической обработки с целью получения зависимостей показателей качества от этих параметров представляет

сложную задачу как в отношении вычислительной сложности алгоритмов моделирования, так и в отношении интерпретации результатов моделирования и оценки погрешностей полученных результатов. Поэтому в данной работе представлены результаты анализа поведения оценок $P_{\text{ош1}}$ в зависимости от объемов обучающих выборок (количество объектов обучения), размерности вектора признаков, при постоянных значениях длительности интервала наблюдения, продолжительности процедуры классификации и для определенных опорных распределений. Данные зависимости вычислены с использованием алгоритма НК с некоррелированными отсчетами опорных случайных процессов.

Случай с различными видами опорных распределениями и интервалами наблюдения рассматривался в п. 3.4-3.5, где определялись зависимости МО и СКО признаков от этих параметров.

Таким образом, в результате моделирования определяются значения параметров системы распознавания, при которых использование разработанного алгоритма практически целесообразно.

В соответствии со структурной схемой устройства НК, представленным на рисунке 3.1, моделирование его работы проводится в два этапа: 1) моделирование в режиме обучения; 2) моделирование в режиме классификации. Структурные схемы алгоритмов программ моделирования, соответствующих этим этапам, представлены на рисунке 4.1 и рисунке 4.2. Листинг программ представлен в приложении 1, на основе которых были получены результаты моделирования.

Программный эксперимент проводился с использованием четырех классов случайных процессов, имеющих одинаковые одномерные плотности распределения вероятностей и корреляционные функции экспоненциального вида с различными интервалами корреляции. Примеры реализаций исследуемых случайных процессов представлены на рисунке 4.3. На основе полученных результатов были построены графики на рисунке 4.4.

Анализ полученных результатов позволяет прийти к выводам.

1) Минимизация вероятности ошибки классификации наблюдается в случае роста объема обучающих выборок;

2) Коэффициент сжатия информации о процессе для графика на рисунке 4.4, равен $k = 1000$, количеству точек, по которым строится оценка признака.

4.4 Оценка вычислительной сложности алгоритма

Оценку вычислительной сложности алгоритма работы НК МСОК произведем в соответствии с методикой, предложенной в [72]. Основной задачей будет являться определение порядка сложности алгоритма. Порядок сложности - мажоранта функции, определяющей количество арифметических и логических операций, при выполнении программы.

Для структурной схемы на рисунке 4.1 расчет порядка сложности начинаем с внутренних циклов. Порядок сложности внутреннего цикла по n составляет:

$$O(2 \cdot N), \quad (4.2)$$

где $O(f(x))$ – обозначает мажоранту функции $f(x)$ (читается O – большое); N – длительность обучающей реализации.

Порядок сложности второго цикла (по L):

$$O(M \cdot Z^2 \cdot L), \quad (4.3)$$

где M – длительность интервала, на котором вычисляются оценки признаков; L – количество обучающих последовательностей; Z – размерность вектора z .

Порядок сложности цикла по I

$$O((2 \cdot N + M \cdot Z^2 \cdot L) \cdot I^2), \quad (4.4)$$

где I – размер вектора признаков.

Порядок сложности цикла по J

$$O((2 \cdot N + M \cdot Z^2 \cdot L) \cdot I^2 \cdot J), \quad (4.5)$$

где J – количество сигналов в системе.

Таким образом, порядок сложности программы моделирования в режиме обучения равен

$$\Sigma_{об} = O((2 \cdot N + M \cdot Z^2 \cdot L) \cdot I^2 \cdot J). \quad (4.6)$$

Аналогично определяем порядок сложности программы моделирования в режиме классификации:

$$\Sigma_{кл} = O((2 \cdot NK + NK \cdot Z^2) \cdot I^2 \cdot J), \quad (4.7)$$

где NK – длина контрольной выборки, предъявляемой для классификации.

Численные значения порядков сложности $\Sigma_{об}$ и $\Sigma_{кл}$ для исходных данных одного из экспериментов, представленного в приложении 1 будут иметь следующие значения:

$$I = 2, \quad J = 2, \quad N = 10^4, \quad M = 10^3, \quad L = 10, \quad NK = 10^3, \quad Z = 2, \quad \Sigma_{об} \cong 0.96 \cdot 10^6,$$

$$\Sigma_{кл} \cong 0.096 \cdot 10^6, \quad \Sigma = 1.056 \cdot 10^6.$$




Рисунок 4.1 – Структурная схема алгоритма непараметрического классификатора в режиме обучения

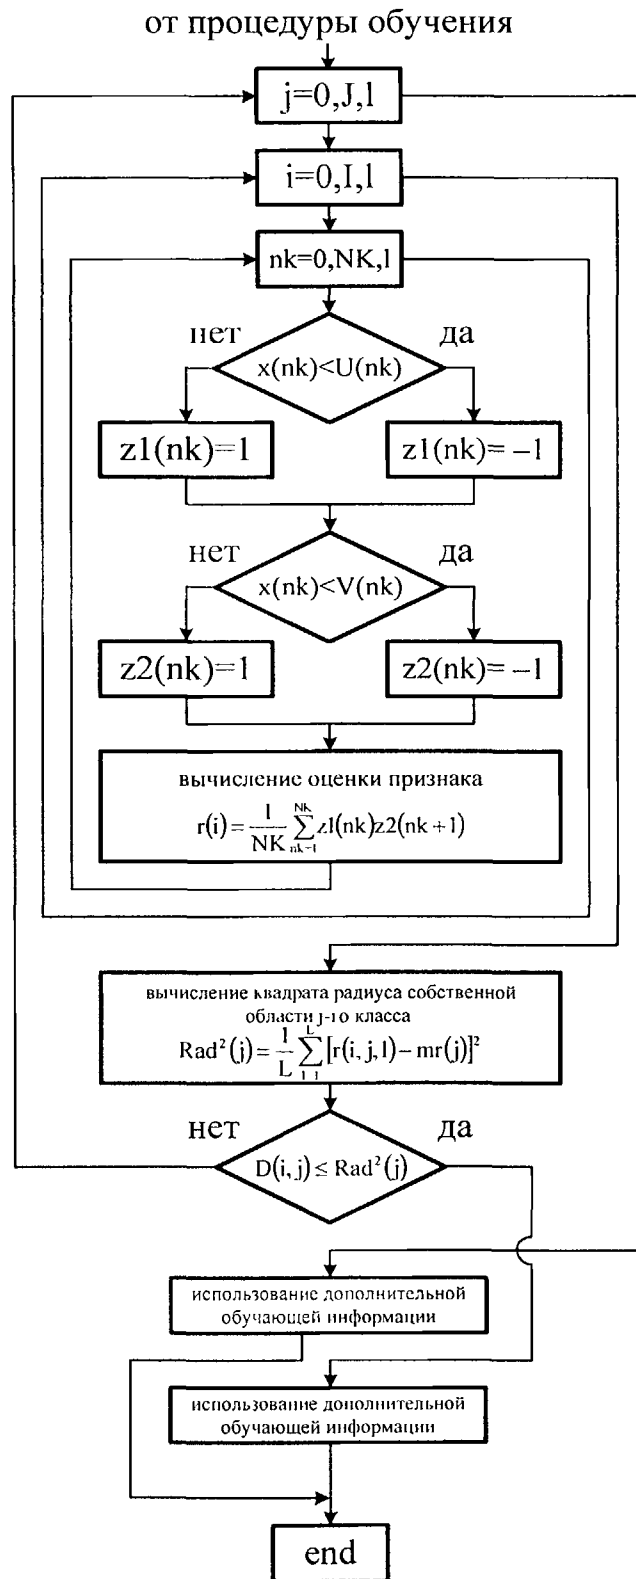


Рисунок 4.2 – Структурная схема алгоритма непараметрического классификатора в режиме классификации

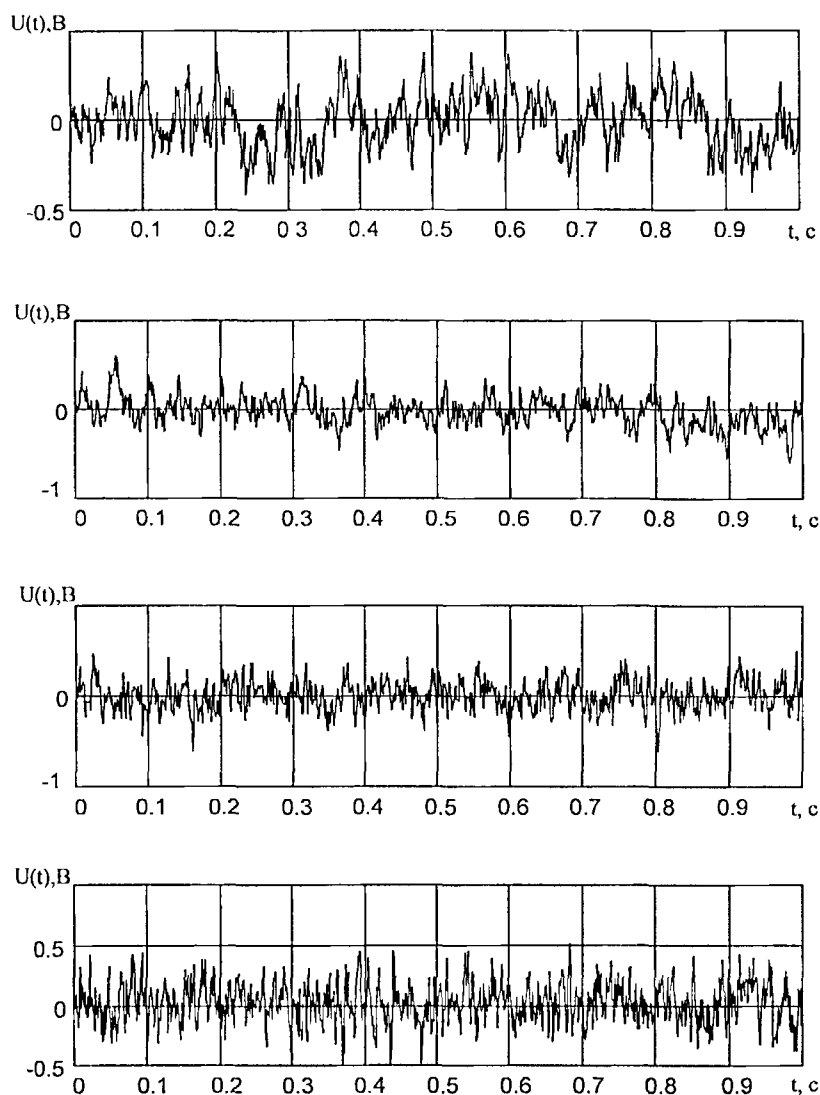


Рисунок 4.3 – Временные диаграммы реализаций входных процессов




Рисунок 4.4 – Зависимость оценок суммарных вероятностей ошибки классификации непараметрического классификатора от числа объектов обучения по классам

4.5 Сравнительный анализ показателей качества и сложности НК МСОК и алгоритма непараметрической классификации по методу k -ближайших соседей

Цель данного подраздела – объективное сравнение характеристик предлагаемых алгоритмов и известными алгоритмами непараметрической классификации. Оставляя за рамками данной работы анализ известных алгоритмов непараметрического распознавания, остановимся на методах непараметрической оценки плотности вероятности, то есть методах, позволяющих аппроксимировать неизвестную функцию плотности вероятности с целью ее дальнейшего использования для построения оптимальных решающих правил [95].

В литературе [90] достаточно подробно описаны методы оценивания плотности вероятности и их использования для построения оптимальных решающих правил. Среди них: методы оценки Парзена, метод k -ближайших соседей [65], метод гистограмм, методы разложения по базисным функциям. Часто предпочтение отдают методам ядерных оценок Парзена за их высокую точность восстановления функций плотности, однако вычисление ядра для каждого объекта требует значительного времени.

Остановимся на модификации оценки Парзена, которая гораздо проще с вычислительной точки зрения. Такая простота вычислений достигается за счет того, что мы ищем не оценки плотностей вероятности сами по себе, а их локальную оценку, то есть нас интересует классификация объектов, порождаемых двумя распределениями, и нам достаточно решить лишь вопрос о том, какая из двух плотностей вероятности больше в данной точке.

В методе Парзена каждый объект является центром, вокруг которого строится некоторое фиксированное ядро. Похожую оценку можно получить иначе, следующим образом. Используя выборку, состоящую из N объектов, находят расстояние r от точки X до k -го ближайшего к X объекта (k -го ближайшего соседа). Для измерения «близости» можно воспользоваться любой подходя-

щей метрикой. Тогда в качестве оценки плотности вероятности в точке X можно принять [90]

$$\hat{p}_N(X) = \frac{k-1}{N} \frac{1}{A(k, N, X)}, \quad (4.8)$$

где $A(k, N, X)$ – объем множества всех точек, расстояния которых до X меньше, чем r . Когда в качестве расстояния используется евклидово расстояние, это множество представляет собой гипершар радиуса r , объем которого

$$A(k, N, X) = \frac{2r^n \pi^{n/2}}{n\Gamma(n/2)}. \quad (4.9)$$

Величина A является случайной величиной, зависящей от выбранного множества N объектов.

Оценка (4.8) может использоваться для классификации следующим образом. Когда требуется классифицировать неизвестный объект X , среди имеющихся N объектов, из которых N_1 объектов принадлежит классу ω_1 , а N_2 объектов – классу ω_2 , находят k ближайших к точке X объектов.

Пусть k_1 и k_2 – соответственно числа объектов из класса ω_1 и ω_2 среди этих k -ближайших соседей. Тогда оценка (4.8) принимает вид

$$\hat{p}_{N_i}(X/\omega_i) = \frac{k_i - 1}{N} \cdot \frac{1}{A}, \quad i = 1, 2. \quad (4.10)$$

Так как k_1 и k_2 объектов извлечены из одного и того же гипершара, то объем A – один и тот же как для класса ω_1 , так и для класса ω_2 . Следовательно, байесовский критерий, минимизирующий ошибку, будет иметь вид

$$(N_1/N_2)\hat{p}(X/\omega_1) \stackrel{\leq}{>} (N_1/N_2)\hat{p}(X/\omega_2) \rightarrow X \in \begin{cases} \omega_1; \\ \omega_2. \end{cases} \quad (4.11)$$

или, подставляя (4.9) в (4.10) получим

$$k_1 \stackrel{\leq}{>} k_2 \rightarrow X \in \begin{cases} \omega_1; \\ \omega_2. \end{cases} \quad (4.12)$$

Таким образом, решение о принадлежности объекта X к тому или другому классу можно принять непосредственно после нахождения k -ближайших соседей и сравнения k_1 и k_2 .

Данное решающее правило легко обобщается для задачи классификации M классов. Аналогично, как и для двух классов, выбираются из обучающих выборок k -ближайших к точке X точек. Пусть k_1, k_2, \dots, k_M – число наблюдений из $\omega_1, \omega_2, \dots, \omega_M$ соответственно. Наблюдение X относится к тому классу i , из которого в числе k -ближайших точек присутствует больше точек, чем из любого другого класса $j \neq i$ ($j = 1, 2, \dots, M$). Решающее правило для классификации M совокупностей имеет вид [95]

$$k_i = \max\{k_1, k_2, \dots, k_M\} \rightarrow X \in \omega_i. \quad (4.13)$$

Процедура классификации по правилу k -ближайших соседей не требует знания плотностей вероятности и является достаточно простой. Недостатком данного метода классификации является необходимость хранить в памяти машины все объекты и сравнивать каждый из них с неизвестным объектом. В общем случае непараметрические методы классификации требуют большего объема вычислений при классификации новых наблюдений, чем параметрические методы при наличии обучения.

В упомянутой литературе приводятся алгоритмы работы непараметрических классификаторов по методу k -ближайших соседей. Однако производить сравнение показателей эффективности и сложности этих алгоритмов и разработанных алгоритмов нельзя, так как в структуру алгоритмов, представленных на рисунке 4.1 и 4.2 заложены процедуры формирования классификационных признаков, разработанные в главе 3. Поэтому необходимо сравнивать алгоритмы работы НК в целом, то есть, включая модули формирования признаков пространств, обучения и принятия решений.

С целью получения количественных соотношений, устанавливающих зависимость эффективности непараметрического классификатора, работающего по методу k -ближайших соседей, от временных параметров системы было проведено цифровое моделирование. Методом статистических испытаний были получены зависимости вероятности ошибки классификации от количества объектов обучения при фиксированном общем объеме обучающей выборки и с использованием тех же обучающих и контрольных статистик, которые были задействованы в статистическом эксперименте с разработанной моделью НК. Структурная схема алгоритма классификации представлена на рисунках 4.5, 4.6, графики зависимости $P_{\text{ош}}(n)$ – на рисунке 4.7 [26].

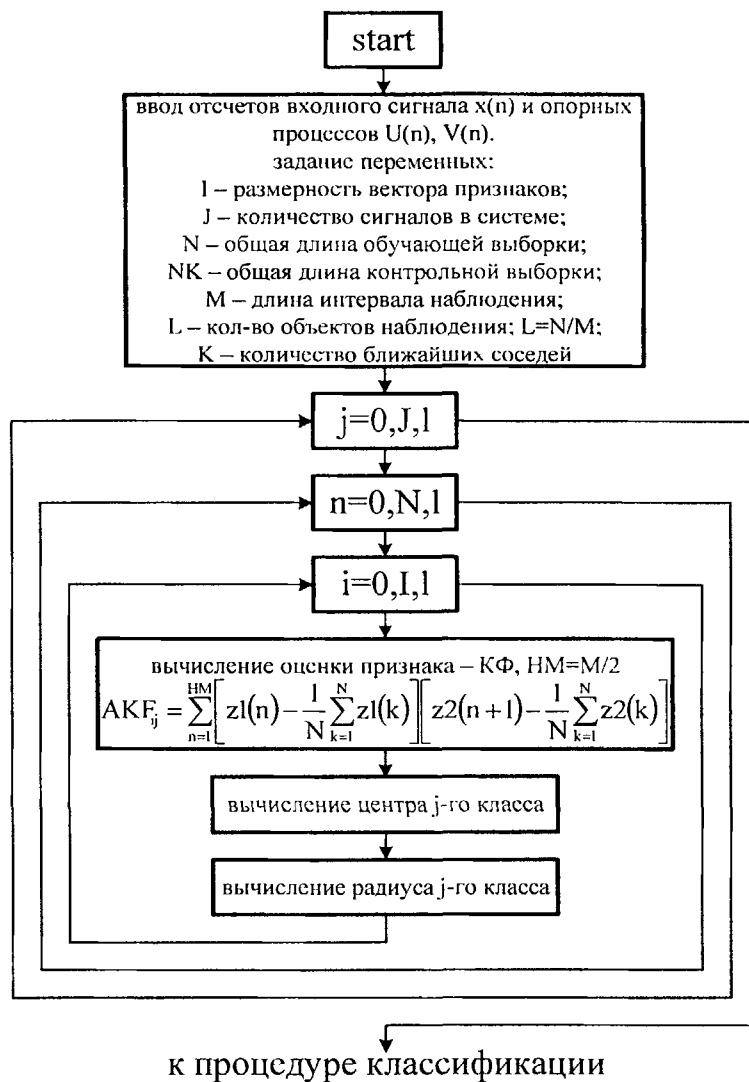


Рисунок 4.5 – Структурная схема алгоритма работы классификатора по методу k-ближайших соседей в режиме обучения

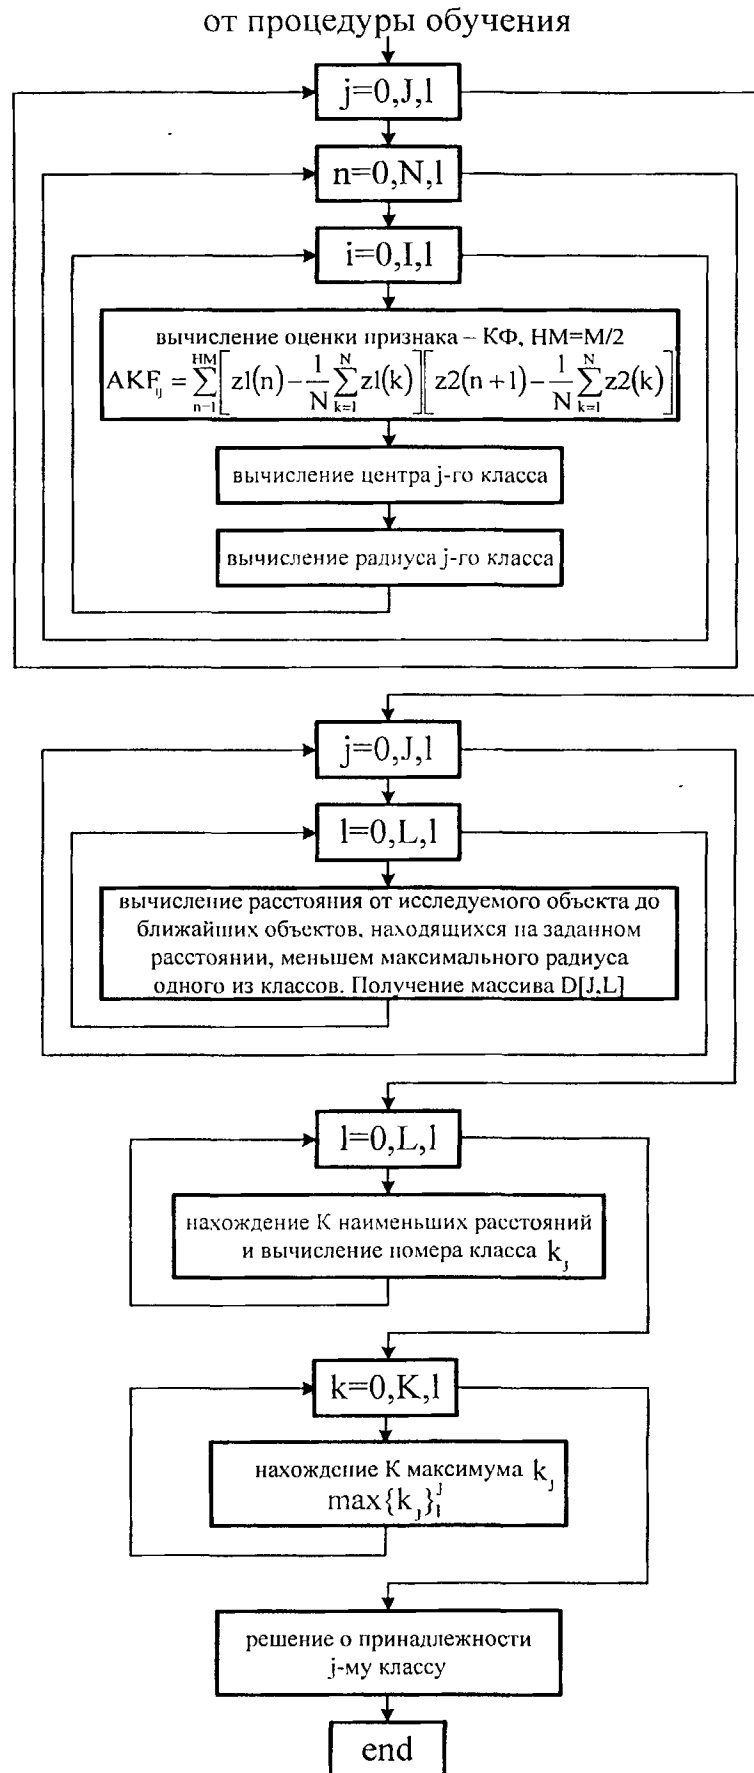


Рисунок 4.6 – Структурная схема алгоритма работы классификатора по методу k-ближайших соседей в режиме классификации




Рисунок 4.7 – Зависимость оценок суммарных вероятностей ошибки классификации от числа объектов обучения по классам по методу k-ближайших соседей

Произведем оценку вычислительной сложности программы моделирования работы классификатора по методу k ближайших соседей в соответствии с методикой, использованной в п. 4.4. Определим порядок сложности алгоритма.

Для структурной схемы на рисунке 4.5 расчет порядка сложности начинаем с внутренних циклов. Порядок сложности внутреннего цикла по I составляет:

$$O(I \cdot NM^2), \quad (4.14)$$

где $NM = M/2$ – половина длины интервала наблюдения. Порядок сложности второго цикла (по L):

$$O(I \cdot NM^2 \cdot L + N \cdot \log_2 N), \quad (4.15)$$

где N – общая длина обучающей выборки.

Порядок сложности цикла по J

$$O(I \cdot NM^2 \cdot L + N \cdot \log_2 N) \cdot J, \quad (4.16)$$

где J – количество сигналов в системе.




Рисунок 4.8 – Сравнение для различных классификаторов зависимости оценок суммарных вероятностей ошибок классификации от числа объектов обучения по классам (а – класс 0, б – класс 1, в – класс 2, г – класс 3)

Таким образом, порядок сложности программы моделирования в режиме обучения равен

$$\Sigma_{об} = O(I \cdot NM^2 \cdot L + N \cdot \log_2 N) \cdot J, \quad (4.17)$$

Аналогично определяем порядок сложности программы моделирования в режиме классификации:

$$\Sigma_{кл} = O(I \cdot NM^2 + NK \cdot \log_2 NK) \cdot J, \quad (4.18)$$

где NK – длина контрольной выборки, предъявляемой для классификации.

Численные значения порядков сложности $\Sigma_{об}$ и $\Sigma_{кл}$ для исходных данных одного из экспериментов, представленного в приложении 1 будут иметь следующие значения:

$$I=5, \quad J=4, \quad N=10^4, \quad M=10^3, \quad L=10, \quad NK=10^3, \quad \Sigma_{об} \cong 50.05 \cdot 10^6, \\ \Sigma_{кл} \cong 5.04 \cdot 10^6, \quad \Sigma = 55.09 \cdot 10^6.$$

На рисунке 4.8 представлены сравнительные графики зависимости суммарных вероятностей ошибок от количества объектов обучения для каждого из четырех классов для разных классификаторов.

Таким образом, сравнивая основные показатели эффективности (представленные на рисунке 4.4 и рисунке 4.7) и сложности (представленные в виде оценок порядков сложности алгоритмов) разработанных алгоритмов и алгоритма классификации по методу k -ближайших соседей с использованием спектральных признаков, можно сделать следующие выводы.

1. При увеличении количества объектов обучения (более 12-15) алгоритм по методу k -ближайших соседей имеет преимущества, заключающиеся в более высоких вероятностях правильной классификации по сравнению с разработанными алгоритмами, что обусловлено, очевидно, использованием оптимальной

байесовской стратегии принятия решений. Особенно сильно эти преимущества проявляются при двухальтернативном распознавании.

2. Как видно из графиков зависимостей суммарных вероятностей ошибок классификации от числа объектов обучения, при критически низком количестве объектов обучения (менее 8-10) алгоритм классификации по методу к ближайших соседей значительно проигрывает разработанному алгоритму в показателях вероятностей правильной классификации. В ходе моделирования установлено, что в случае многоальтернативного распознавания при увеличении количества классов (выше 5-10) эффективность «эталонного» классификатора начинает резко падать, по сравнению с показателями эффективности разработанного алгоритма непараметрического классификатора.

3. Анализ вычислительной сложности алгоритмов показывает, что сложность алгоритма классификации по методу k-ближайших соседей более чем на порядок выше вычислительной сложности разработанных алгоритмов. Особенно это важно при выполнении процедуры принятия решений (режим классификации), где порядок сложности разработанных алгоритмов ниже порядка сложности алгоритма классификации по методу k-ближайших соседей приблизительно в 50 раз.

4.6 Оценка статистической погрешности результатов программного эксперимента

Показателем качества алгоритма непараметрического классификатора является суммарная вероятность ошибки классификации одного объекта исследования $P_{ош}$. Так как имеется случайная погрешность в определении $P_{ош}$, под ошибкой моделирования будем понимать эту случайную погрешность.

Осуществление оценки ошибок статистического моделирования в общем виде затруднительна ввиду отсутствия общих аналитических выражений для ошибок моделирования систем случайных величин с произвольными законами распределения [5, 4, 47]. Используем методику оценивания вероятности ошиб-

ки для заданного классификатора, приведенной в [90]. При неизвестных априорных вероятностях классов $P(\omega_i)$, $i = 1, 2$, можно случайно извлечь N объектов и произвести проверку правильности решения данного классификатора для этих объектов, представляющих собой случайную выборку.

Пусть τ – число объектов, неправильно классифицированных в результате этого эксперимента. Величина τ является дискретной случайной величиной. Обозначим истинную вероятность ошибки через ε . Вследствие дискретности τ при фиксированном ε рассмотрим вероятность $\Pr\{\tau = \tau/\varepsilon\}$, которая задается биномиальным распределением:

$$\Pr\{\tau = \tau/\varepsilon\} = \binom{N}{\tau} \varepsilon^\tau (1 - \varepsilon)^{N-\tau}. \quad (4.19)$$

Оценка максимального правдоподобия $\hat{\varepsilon}$ величины ε есть решение следующего уравнения правдоподобия:

$$\left. \frac{\partial \ln \Pr\{\tau = \tau/\varepsilon\}}{\partial \varepsilon} \right|_{\varepsilon=\hat{\varepsilon}} = \left(\frac{\tau}{\varepsilon} - \frac{N-\tau}{1-\varepsilon} \right) \Big|_{\varepsilon=\hat{\varepsilon}}. \quad (4.20)$$

Следовательно,

$$\hat{\varepsilon} = \frac{\tau}{N}. \quad (4.21)$$

Другими словами, оценка максимального правдоподобия равна отношению числа неправильно классифицированных объектов к общему числу объектов.

Свойства биномиального распределения хорошо известны. Характеристическая функция, математическое ожидание и дисперсия определяются следующим образом:

$$\varphi(\varepsilon) = \{\varepsilon \exp(j\omega) + (1 - \varepsilon)\}^N, \quad (4.22)$$

$$M(\tau) = N\varepsilon, \quad (4.23)$$

$$D(\tau) = N\varepsilon(1 - \varepsilon). \quad (4.24)$$

Поэтому

$$M(\hat{\varepsilon}) = \frac{M(\tau)}{N} = \varepsilon, \quad (4.25)$$

$$D(\varepsilon) = \frac{D(\tau)}{N^2} = \frac{\varepsilon(1 - \varepsilon)}{N}. \quad (4.26)$$

Таким образом, оценка $\hat{\varepsilon}$ является несмещенной.

Поскольку плотность вероятности оценки $\hat{\varepsilon}$ известна, то можно вычислить доверительные интервалы по формуле:

$$\Pr\{a < \hat{\varepsilon} < b\} = \sum_{a < \hat{\varepsilon} < b} \Pr\{\hat{\varepsilon} = \hat{\varepsilon}/\varepsilon\} = \gamma. \quad (4.27)$$

Стоит отметить, явный вид для суммы слагаемых в выражении (4.27) не найден. Но соотношения между величинами ε , $\hat{\varepsilon}$, N и γ затабулированы с помощью численных методов, и на рисунке 4.9 [90] показано соотношение между истинной вероятностью ошибки ε и ее оценки $\hat{\varepsilon}$ для коэффициента доверия $\gamma = 0,95$.

Для некоторых, полученных в приложении 1 значений $\hat{P}_{\text{ош}}$ и n значения доверительных интервалов приведены в таблице 4.1.

Таблица 4.1 – Значения доверительных интервалов

| N | n | некорр. ОП $\min[\hat{P}]$ | некорр. ОП \hat{P} | некорр. ОП $\max[\hat{P}]$ |
|-----|----|-------------------------------|-------------------------|-------------------------------|
| 100 | 2 | 0,24 | 0,39 | 0,45 |
| 100 | 4 | 0,25 | 0,37 | 0,46 |
| 100 | 6 | 0,19 | 0,22 | 0,39 |
| 100 | 8 | 0,06 | 0,15 | 0,27 |
| 100 | 10 | 0,05 | 0,12 | 0,19 |




Рисунок 4.9 – Доверительные интервалы для $P_{ош}$ при коэффициенте доверия $\gamma = 0,95$

4.7 Разработка структурной схемы экспериментальной установки

В связи с тем, что целью работы является экспериментальное исследование разработанного непараметрического классификатора на реальных объектах, приведем структурную схему экспериментальной установки.

Структурная схема экспериментальной установки имеет довольно простой вид, состоящая из цифровой видеокамеры и персональной ЭВМ. Полутонные изображения протяженных световых объектов в оцифрованном виде поступают на ЭВМ, через USB порт. Оцифрованные данные не претерпевают никакого сжатия, в результате они в персональной ЭВМ представляются в виде

записи видефрагмента статического изображения, в формате MPEG. Далее в персональной ЭВМ происходит раскадровка видефрагмента и анализу уже подвергается последовательность кадров, представляющая собой файлы в формате JPEG.




Рисунок 4.10 – Структурная схема экспериментальной установки

Листинги программ работы классификаторов приведены в приложении 1.

4.8 Определение показателей качества работы непараметрического классификатора

Экспериментальной проверкой эффективности работы предлагаемого алгоритма будет являться построение матрицы вероятностей перепутывания реальных при классификации реальных объектов. При этом соблюдены все выше предложенные преобразования: нормализация по средней яркости и нормализация по площади, занимаемой объектом на изображении.

Для проведения программного эксперимента использовались изображения микроавтобусов, имеющие схожие геометрические параметры кузова, приведенных на рисунке 4.11. Условно примем следующие обозначения изображений «WV T5» присвоим «Класс0», «WV T4» – «Класс1», «Ford Transit» – «Класс2», «Gazelle» – «Класс3».

Поскольку работа велась с оценкой стохастических параметров, то для повышения точности оценивания параметров, все результаты были получены по статистике $N=1000$. В результате экспериментального исследования были получены следующие результаты, приведенные в таблицах 4.2, 4.3.



класс 0
WV T5



класс 1
WV T4



класс 2
Ford Transit



класс 3
Gazelle

Рисунок 4.11 – Изображения протяженных статичных объектов

Таблица 4.2 – Изменения радиусов собственных областей от размерности признакового пространства

| Размерность признакового пространства, К | Класс 0 | Класс 1 | Класс 2 | Класс 3 |
|--|---------|---------|---------|---------|
| 4 | 0,048 | 0,053 | 0,052 | 0,049 |
| 8 | 0,06 | 0,063 | 0,058 | 0,058 |
| 12 | 0,068 | 0,069 | 0,07 | 0,062 |

Таблица 4.3 – Изменения СКО радиусов собственных областей от размерности признакового пространства

| Размерность признакового пространства, К | Класс 0 | Класс 1 | Класс 2 | Класс 3 |
|--|----------------------|----------------------|----------------------|----------------------|
| 4 | $3,5 \cdot 10^{-3}$ | $3,88 \cdot 10^{-3}$ | $3,88 \cdot 10^{-3}$ | $4,2 \cdot 10^{-3}$ |
| 8 | $3,66 \cdot 10^{-3}$ | $3,58 \cdot 10^{-3}$ | $3,39 \cdot 10^{-3}$ | $3,7 \cdot 10^{-3}$ |
| 12 | $3,28 \cdot 10^{-3}$ | $3,38 \cdot 10^{-3}$ | $3,15 \cdot 10^{-3}$ | $3,54 \cdot 10^{-3}$ |

Далее приведем матрицы вероятностей перепутывания при классификации этих классов объектов:

а) при размерности признакового пространства $K = 4$

$$\begin{bmatrix} 0.85 & 0.15 & 0 & 0 \\ 0.31 & 0.69 & 0 & 0 \\ 0 & 0 & 0.95 & 0.05 \\ 0 & 0 & 0.04 & 0.96 \end{bmatrix};$$

б) при размерности признакового пространства $K = 8$

$$\begin{bmatrix} 0.89 & 0.11 & 0 & 0 \\ 0.24 & 0.76 & 0 & 0 \\ 0 & 0 & 0.97 & 0.03 \\ 0 & 0 & 0.1 & 0.9 \end{bmatrix};$$

в) при размерности признакового пространства $K = 12$

$$\begin{bmatrix} 0.93 & 0.07 & 0 & 0 \\ 0.15 & 0.85 & 0 & 0 \\ 0 & 0 & 0.98 & 0.02 \\ 0 & 0 & 0.03 & 0.97 \end{bmatrix}.$$

Анализируя полученные результаты можно сделать следующие выводы:

1. Увеличение размерности признакового пространства приводит, с одной стороны, к увеличению радиуса собственных областей, что может привести к пересечению собственных областей класса, и тем самым повлиять на вероятность правильной классификации, а с другой стороны, это приводит к разнесению в пространстве центров собственных областей класса.

2. Увеличение размерности признакового пространства повышает вероятность правильной классификации, в виду того, что размерность признакового пространства напрямую зависит от количества выбранных строк.

Выводы по материалам 4 главы

1. В результате моделирования работы классификатора при классификации случайных процессов с одинаковыми одномерными плотностями распределения вероятностей и различными корреляционными функциями определены значения суммарных вероятностей ошибки классификации при различных объемах обучающих и контрольных выборок и различных размерах признакового пространства.

2. Определены оценки вычислительной сложности использованных алгоритмов моделирования работы непараметрических классификаторов. Установлено, что при классификации показатели сложности реализация этого алгоритма на микропроцессорных системах имеет меньшее значение, по сравнению с непараметрическими алгоритмами распознавания на основе оценивания плотностей вероятности по методу k -ближайших соседей.

3. Определены понятие и численные значения статистической погрешности моделирования работы непараметрического классификатора при решении задачи классификации изображений объектов.

4. Разработана и описана структурная схема экспериментальной установки, позволяющая изучить непараметрические методы классификации сигналов изображений.

5. При исследовании работы разработанного классификатора были получены матрицы вероятностей перепутывания при классификации реальных объектов, от размерности признакового пространства, позволяющие оценить эффективность предложенного алгоритма.

ЗАКЛЮЧЕНИЕ

В диссертационной работе рассмотрен комплекс теоретических и практических вопросов, связанных с построением признаковых пространств в автоматизированных системах распознавания изображений. Основную научную и практическую значимость имеют результаты исследования возможности оптимизации временных и пространственных параметров распознающих систем изображений. При этом получены следующие основные результаты:

1. Предложен алгоритм преобразования оцифрованных сигналов изображений объекта в реализации случайных процессов, подлежащих классификации.

2. На основе анализа существующих методов формирования признаковых пространств при классификации сигналов моделей изображений показана, возможность улучшения качества работы автоматизированных распознающих систем за счет нелинейного преобразования исходных пространств сигналов, которое обеспечивает сокращение избыточности описания исходных сигналов и сокращение временных и аппаратных затрат при решении задач классификации изображений.

3. Разработан алгоритм непараметрической классификации сигналов изображений на основе формирования признаковых пространств по методу стохастического кодирования. Разработаны математические модели алгоритмов. Определены показатели качества и сложности разработанного алгоритма МСОК при их реализации на микропроцессорных системах для решения задачи классификации сигналов изображений.

4. Получены зависимости основных показателей качества разработанного алгоритма по МСОК от времени обучения и распознавания, и размерности признакового пространства, позволяющие оптимизировать временные и пространственные параметры аппаратуры классификации.

5. Проведено экспериментальное исследование показателей качества разработанного алгоритма МСОК. Использование разработанного метода для классификации изображений позволило достоверно различать классы наблюдаемых протяженных объектов, соответствующих различным классам объектов.

6. Научные и практические результаты, полученные в диссертации, внедрены на ряде предприятий при создании устройств сопровождения и наблюдения за объектами при решении задачи классификации изображений.

ЛИТЕРАТУРА

1. Автоматический анализ сложных изображений. Сборник переводов / Под ред. Э.М. Бравермана – М.: Мир, 1969. – 310с.
2. Айвазян и др. Прикладная статистика: Классификация и снижение размерности. – М.: Финансы и статистика. 1989. – 607 с.
3. Айвазян С.А., Енюков И.С., Мешалкин Л.Д. Прикладная статистика: Основы моделирования и первичная обработка данных: Справ изд. М.: Финансы и статистика, 1983. – 471 с.
4. Лкимов П.С. и др. Сигналы и их обработка в информационных системах. Учебн. пособие для вузов. М.: Радио и связь, 1994. – 256с.
5. Акимов П.С. Непараметрическое обнаружение сигналов. // Радиотехника. 1972. Т.32. №11. – С.17-30.
6. Ануфриев И.Е., Смирнов А.Б., Смирнова Е.Н. МАТЛАВ 7. СПб.: БХВ-Петербург, 2005. – 1104 с.
7. Астанин С.В. Методы и системы распознавания образов – Таганрог: Изд-во ТРТУ, 2003. – 160 с.
8. Банди Б. Методы оптимизации. Вводный курс: Пер. с англ. М.: Радио и связь, 1988. – 128с.
9. Бендат Дж., Пирсол А. Прикладной анализ случайных данных. М.: Мир 1989. – 540 с.
10. Бобнев М.П. Генерирование случайных сигналов. М.: Энергия, 1971. – 240 с.
11. Браверман Э.М., Дорофеток А.А., Лумельский В.Я. Применение методов обучения машин распознаванию образов. М.: Наука, 1971. – 254 с.
12. Бусленко Н.П., Калашников В.В., Коваленко И.Н. Лекции по теории сложных систем. М.: Советское радио, 1971. – 328 с.
13. Быков В.В. Цифровое моделирование в статистической радиотехнике. М.: Советское радио, 1971. – 328 с.
14. Вапник В.Н., Червоненкис А.Я. Теория распознавания образов (статистические проблемы обучения) М.: Наука, 1974. – 416 с.
15. Васильев В.И. Распознающие системы: Справочник. Киев.: Наукова думка, 1983. – 423 с.
16. Вентцель Е.С. Теория вероятностей. М.: Наука, 1969. – 576 с.
17. Витих В.А., Сергеев В.В., Сойфер В.А. Обработка изображений в автоматизированных системах научных исследований. – М.: Наука, 1982. – 311 с.
18. Волков Е.А. Численные методы / Учебное пособие – М.: Наука, 1982. – 256 с.

19. Вопросы статистической теории распознавания / Под ред. Б.В. Варского М.: Сов. радио, 1967. – 400с.
20. Галустов Г.Г. Классификатор случайных сигналов // Известия СКНЦ ВШ. Новочеркасск, 1984. Серия «Технические науки». № 3. – С. 54-57.
21. Галустов Г.Г. Моделирование случайных процессов и оценивание их статистических характеристик. М.: Радио и связь, 1999. – 120 с.
22. Галустов Г.Г. Укрупнение описания случайных процессов с целью их классификации // Межведомственный тематический сборник "Вопросы медицинской электроники". Таганрог, 1986. Вып. 6. – С. 57-62.
23. Галустов Г.Г., Краснобаев Д.А., **Поцькайло А.А.** О построении статистических систем распознавания по кластеризованным выборкам // Материалы Всероссийской научной конференции «Современные исследовательские и образовательные технологии (СИОТ-2010)», часть 2. 2010. Стр.17-21.
24. Галустов Г.Г., Краснобаев Д.А., **Поцькайло А.А.** Оценка погрешности при стохастическом кодировании сигналов // Материалы Всероссийской научной конференции «Современные исследовательские и образовательные технологии (СИОТ-2010)», часть 2. 2010. Стр. 13-17.
25. Галустов Г.Г., Краснобаев Д.А., **Поцькайло А.А.** Синтез решающего правила классификатора сигналов при непараметрической априорной неопределённости // 56-я научно-техническая конференция профессорско-преподавательского состава, журнал «Известия ЮФУ. Технические науки». №1(114) январь, 2011 г. Раздел II. Стр. 78-84.
26. Галустов Г.Г., Теоретические и аппаратные основы, анализа и синтез сложных сигналов диагностических систем. / диссертация на соискание ученой степени доктора технических наук. Таганрог. 1991.
27. Галустов Г.Г., Цымбал В.Г., Михалев М.В. Принятие решений в условиях неопределенности. М.: Радио и связь, 2001. – 196 с.
28. Гастев Ю.А. Гомоморфизмы и модели: Логико-алгебраические аспекты моделирования. – М.: Наука, 1975. – 150 с.
29. Гладкий В.С. Вероятностные вычислительные модели. М.: Наука, 1973. – 298 с.
30. Гонсалес Р., Вудс Р. Цифровая обработка изображений М.: Техносфера, 2005. – 1072 с.
31. Горелик А.Л., Гуревич И.Б., Скрипкин В.А. Современное состояние проблемы распознавания. М.: Радио и связь, 1985. – 160 с.
32. Горелик А.Л., Скрипкин В.А. Построение систем распознавания. М.: Сов. радио, 1974. – 224 с.
33. Градштейн И.С., Рыжик И.М. Таблицы интегралов, сумм, рядов и произведений. М.: Наука, 1971. – 184 с.

34. Денисенко А.Н. Сигналы. Теоретическая радиотехника. Справочное пособие. М: Горячая линия-Телеком, 2005. – 704 с.
35. Драган Я.П. Структура и представления моделей стохастических сигналов. Киев: Наукова думка, 1980. – 384 с
36. Дуда Р., Харт П. Распознавание сигналов и анализ сцен. М.: Мир, 1976. – 511 с.
37. Дьяконов В.П. MATLAB 7.*/R2006/R2007: Самоучитель. М: ДМК Пресс, 2008. – 768 с..
38. Евсиков Ю.А., Чапурский В.В. Преобразование случайных процессов в радиотехнических устройства. Учеб. пособ. для радиотехн. специальностей вузов. М.: Высш. школа, 1977. – 264 с.
39. Ермаков С.М., Михайлов Г.А.. Курс статистического моделирования. М.: Наука, 1976. – 168 с.
40. Журавлев Ю.И. Непараметрические задачи распознавания образов // Кибернетика, 1986. №6 – с. 83-103.
41. Загоруйко Н.Г. Методы распознавания и их применение. М.: Сов. радио, 1972. – 206 с.
42. Заде Л. Размытые множества и их применение в распознавании образов и кластер-анализе. В кн.: "Классификация и кластер" / Под ред. Ю.И. Журавлева. М.: Мир, 1980. – С. 208-243.
43. Зарубин В.С. Математическое моделирование в технике: учеб. для вузов / Под ред. В.С. Зарубина, А.П. Крищенко. (Сер. Математика в техническом университете; Вып. XXI, заключительный). М.: Изд-во МГТУ им. Баумана, 2003. – 496 с
44. Казанцев Г.Д., Курячий М.И., Пустынский И.Н. Измерительное телевидение: Учебное пособие для вузов – М.: Высш. шк., 1994. – 288с.
45. Кетков Ю.Л., Кетков А.Ю., Шульц М.М. MATLAB 7: программирование, численные методы. СПб.: БХВ-Петербург, 2005. – 752 с.
46. Киселев Н.В. Методы построения систем распознавания и классификации негауссовых сигналов. Л.: ЛГУ, 1986. – 186 с.
47. Киселев Н.В., Сечкин В.А. Техническая диагностика методами нелинейного преобразования. Л.: Энергия, 1980. – 108 с.
48. Ковалевский В.А. Методы оптимальных решений в распознавании изображений. – М.: Наука, 1976. – 328 с.
49. Коваленко И.Н., Филипова А.А. Теория вероятностей и математическая статистика. М., Высшая школа, 1973. – 368 с.
50. Коган И.М. Прикладная теория информации. М.: Радио и связь, 1981. – 216 с.
51. Лапко А.В. Непараметрические методы классификации и их применение. Новосибирск: Наука, 1993 с.

52. Левин Б.Р. Теоретические основы статистической радиотехники. М.: Радио и связь, 1989. – 656 с.
53. Мартышевский Ю.В. Выделение искусственных объектов на сложном фоне // IV Международная научно техническая конференция «Актуальные вопросы электронного приборостроения» (АПЭП-98). – Новосибирск: НГТУ, 1998. – Том 2. – с. 239-241.
54. Мартышевский Ю.В. Телевизионные средства определения координат объектов, расположенных на сложном фоне / диссертация на соискание ученой степени доктора технических наук. Томск 2002.
55. Математическая статистика: учеб. для вузов / В.Б. Горяинов, И.В. Павлов, Г.М. Цветкова и др.; Под ред. В.С. Зарубина, А.П. Крищенко. (Сер. Математика в техническом университете; Вып. XVII). М.: Изд-во МГТУ им. Баумана, 2001. – 424 с.
56. Методы компьютерной обработки изображений / Под ред. В.А. Сойфера. – М.: Физматлит, 2001. – 784 с.
57. Миленский А.В. Классификация сигналов в условиях неопределенности. М.: Сов. радио, 1975. 328 с.
58. Мирский Г.Я. Аппаратурное определение характеристик случайных процессов. М.: Энергия, 1972. 456 с.
59. Мирский Г.Я. Характеристики стохастической взаимосвязи и их измерения. М.: Энергия, 1982. – 320 с.
60. Ольховский Ю.Б., Новоселов О.Н., Мановцев А.П. Сжатие данных при телеизмерениях. М.: Сов. радио, 1971. – 304 с.
61. Омельченко В.А. Основы спектральной теории распознавания сигналов. Харьков: Вища школа, 1983. – 159 с.
62. Патрик Э. Основы теории распознавания образов. Пер. с англ. / Под ред. Б.Р. Левина. М.: Сов. радио, 1980. – 408 с.
63. **Поцькайло А.А.** Детерминистский и статистический подход в итеративных алгоритмах с использованием решающих функций // Международная научная конференция «Методы и алгоритмы принятия эффективных решений» (МАПР-2009), часть 2 – математические методы принятия решений и оптимизации. 2009. Стр. 63-69.
64. **Поцькайло А.А.** Задача распознавания фрагментов на изображении // X Всероссийская научная конференция студентов и аспирантов «Техническая кибернетика, радиоэлектроника и системы управления-2010 (КРЭС-2010)», секция радиотехники, подсекция моделирование и цифровая обработка сигналов. 2010. Стр. 31-32.
65. **Поцькайло А.А.** Использование метода k-ближайших соседей при распознавании полутоновых изображений. // Всероссийская научно-техническая конференция с международным участием: «Компьютерные и

информационные технологии в науке, инженерии и управлении» («КомТех-2011»), журнал «Известия ЮФУ. Технические науки». №5(118) май, 2011 г. Стр. 258-260..

66. **Поцыйкайло А.А.** Методика выбора критерия эффективности системы признаков при решении задачи классификации // Материалы Международной научной конференции «Информационное общество: идеи, технологии, системы-2010 (ИНФО-2010)», часть 3. 2010. Стр. 53-56.
67. **Поцыйкайло А.А.** Формирование признаков по изображению при классификации // Сборник материалов докладов 8-й Всероссийской научно-практической конференции студентов, аспирантов и молодых ученых «Молодежь XXI века – будущее российской науки». В двух томах. Т1. – Ростов-на-Дону: Изд-во ЮФУ, 2010, стр. 143-144.
68. **Поцыйкайло А.А.** Формирование системы признаков при классификации случайных процессов с использованием стохастического кодирования // 13-я международная конференция «Цифровая Обработка Сигналов и её Применение» (DSPA-2011). Секция №1 «Теория сигналов и систем». Т1. – Стр.67-69.
69. Применение цифровой обработки сигналов. Пер. с англ. / Под ред. А. Оппенгейма. М.: Мир, 1980. – 552 с.
70. Прэрт У.К. Цифровая обработка изображений. Т.1. – М.: Мир, 1982. – 312 с.
71. Прэрт У.К. Цифровая обработка изображений. Т.2. – М.: Мир, 1982. – 480 с.
72. Райли Д. Абстракция и структуры данных: Вводный курс / Пер. с англ. М.: Мир, 1973. – 752 с.
73. Распознавание образов при помощи цифровых вычислительных машин / Под ред. Л. Хармон. М.: Мир, 1974. – 287 с.
74. Распознавание образов. Состояние и перспективы / Пер. с англ. К. Верхаген, Р. Дейн, Ф. Грун и др. М.: Радио и связь, 1985. – 104 с.
75. Распознавание образов: Теория и приложения. М.: Наука, 1977. – 128 с.
76. Сенин А.Г. К анализу критериев оптимальности, используемых при обучении распознаванию образов // Автометрия, 1971. № 5. С. 20-25.
77. Сенин А.Г. Распознавание случайных сигналов. Новосибирск: Наука. Сибирское отделение. 1974. – 76 с.
78. Сергиенко А.Б. Цифровая обработка сигналов /– СПб.: Питер, 2002. – 608 с.
79. Теория вероятностей: учеб. для вузов / А.В. Печинкин, О.И. Тескин, Г.М. Цветкова и др.; Под ред. В.С. Зарубина, А.П. Крищенко. (Сер. Математика в техническом университете; Вып. XVI). М.: Изд-во МГТУ им. Баумана, 2004. – 456 с.

80. Тихонов В.И. Выбросы случайных процессов. М.: Наука, 1970. – 392 с.
81. Ту Дж., Гонсалес Р. Принципы распознавания образов. М.: Мир, 1978. – 432 с.
82. Фомин В.Н. Математическая теория обучаемых опознающих систем. Л.: Изд-во ЛГУ, 1976. – 235 с.
83. Фомин Я.А. Теория выбросов случайных процессов. М.: Связь, 1980. – 216 с.
84. Фомин Я.А., Савич А.В. Оптимизация распознающих систем. М.: Машиностроение, 1993. – 288 с.
85. Фомин Я.А., Тарловский Г.Р. Статистическая теория распознавания образов. М.: Радио и связь, 1986. – 264 с.
86. Форсайт Д.А., Понс А. Компьютерное зрение. Современный подход.: Пер. с англ. – М.: Издательский дом «Вильямс», 2004. – 928 с.
87. Френкс Л. Теория сигналов. М.: Сов. радио, 1974. – 344 с.
88. Фу К. Последовательные методы в распознавании образов и обучении машин. М.: Наука, 1979. – 287 с.
89. Фу К. Структурные методов распознавания образов / Пер с англ. Под ред. М.А. Айзермана. М.: Наука, 1977. – 319 с.
90. Фукунага К. Введение в статистическую теорию распознавания образов. М.: Наука, 1979. – 367 с.
91. Цветнов В.В., Борисов Ю.П. Математическое моделирование радиотехнических систем и устройств. М.: Радио и связь, 1985. – 176 с.
92. Цифровая обработка изображений в информационных системах: Учебное пособие / Грузман И.С., Киричук В.С. и др. – Новосибирск, НГТУ, 2002. – 587 с.
93. Цымбал В.Г. Разработка и исследование методов формирования признаков пространств в медицинских диагностических системах / диссертация на соискание ученой степени кандидата технических наук. Таганрог 1999.
94. Цыпкин Я.З. Основы теории обучающихся систем. М.: Наука, 1970. – 252 с.
95. Шапиро Е.И. Непараметрические оценки плотности вероятности в задачах обработки результатов наблюдений: обзор // Зарубежная радиоэлектроника. №2, 1976 – с. 3-33.
96. Шибанов Г.П. Распознавание в системах автоконтроля. М.: Машиностроение, 1973: – 424 с.
97. Ярославский Л.П. Введение в цифровую обработку изображений. – М.: Сов. Радио, 1979. – 312с.

ПРИЛОЖЕНИЕ 1

Листинг программы обучения с использованием стохастического кодирования

```

close all; clear all; clc; clf; %format long e;
%БЛОК ОБУЧЕНИЯ С ИСПОЛЬЗОВАНИЕМ МЕТОДА СТОХАСТИЧЕСКОГО
КОДИРОВАНИЯ

%С ПРЕДВАРИТЕЛЬНОЙ НОРМИРОВКОЙ МАССИВА ИЗОБРАЖЕНИЯ И
ДИНАМИЧЕСКОЙ ИНТЕРПОЛЯЦИЕЙ СИГНАЛА

%БЛОК ПОСЛЕДОВАТЕЛЬНОГО СЧИТЫВАНИЯ ФАЙЛОВ ИЗОБРАЖЕНИЙ

%повторяется столько раз, сколько имеется изображений для обучения в конкретном классе

%-----%

korpor=6; %какое кол-во опорных распределений будет использовано
s=1; %с какого опорного начинается отсчёт

tau=2^0; %задание смещения Sgn для вычисления второго смешанного момента

mn=(2^0)*(5^0); %множитель, определяющий шаг прореживания по строкам. должен нацело
делить общее кол-во строк изображения
%фактически является разложением на простые множители числа строк
% 640 = 2^7 * 5
res_str=640/mn; %константа для задания резервного массива с необходимым количеством
строк

Picn0=zeros(res_str,1024); %резервирование массива для уменьшенного изображения

Moc=zeros(res_str,korpor); %массив для построения признаков класса, кол-во столбцов опре-ся
кол-м опор
%Moc=zeros(1,korpor); %массив для оценки центра гипершара, номер столбца - номер
опорного распределения

kolobj=20; %кол-во объектов в классе

for i=1:kolobj
    imf1='kl1_'; imf2=int2str(i); imf3='.jpg'; %преобразование i в строковый тип
    imf=strcat(imf1,imf2,imf3); %получение очередного имени файла для обучения
    Pic=imread(imf); %считывание изображения
    Picn=im2double(Pic); %преобразование массива изображения uint8 в double
    (яркость в интервале [0,1])
    %imshow(imf) %контроль правильности считывания изображения

%-----%

str1=size(Picn,1); %количество строк в массиве изображения
strl1=size(Picn,2); %количество столбцов в массиве изображения

```


%БЛОК НАХОЖДЕНИЯ СРЕДНЕЙ ЯРКОСТИ ИЗОБРАЖЕНИЯ И ЦЕНТРИРОВАНИЕ ПО ЯРКОСТИ (СРЕДНЕМУ ЗНАЧЕНИЮ)

%ПРОРЕЖИВАНИЕ (СЕГМЕНТАЦИЯ) ПО СТРОКАМ

%-----%

```
moPicn=mean(Picn(:)); %нахождение средней яркости всего изображения
Picn01=Picn-moPicn; %центрирование по средней яркости
for j=1:res_str
    Picn0(j,1:stl1)=Picn01(j*mn,1:stl1);
end
```

%-----%

```
str=size(Picn0,1); %количество строк в массиве сегментированного по строкам изображения
stl=size(Picn0,2); %количество столбцов в массиве сегментированного по строкам изображения
```

%БЛОК ГЕНЕРАЦИИ ОПОРНЫХ СП С ЗАДАННЫМ ВИДОМ РАСПРЕДЕЛЕНИЯ И ВЫЧИТАНИЯ ИХ ИЗ ИЗОБРАЖЕНИЯ

%.....

%-----%

```
opora=zeros(str,stl);
Xiz=zeros(str,stl); %массив для хранения разницы между строками изображения и опорой
Sgn=Xiz; %массив для хранения кодовой последовательности
Liz=zeros(str,kopor); %массив для построения признаков изображения, кол-во столбцов опор
% кол-м опор
```

%генерирование опор

%-----

```
for k=s:kopor
    if k==1 %опора с РАВНОМЕРНЫМ распределением
        a1=-0.5; a2=0.5;
        opora=a1+(a2-a1).*rand(str,stl,'double');

    elseif k==2 %опора с НОРМАЛЬНЫМ распределением m=0
        sigma=0.5; %параметр сигма для нормального распределения
        opora=0+sigma.*randn(str,stl,'double');

    elseif k==3 %опора с НОРМАЛЬНЫМ распределением m=-0.25
        sigma=0.25; %параметр сигма для нормального распределения
        opora=-0.25+sigma.*randn(str,stl,'double');

    elseif k==4 %опора с НОРМАЛЬНЫМ распределением m=0.25
        sigma=0.25; %параметр сигма для нормального распределения
        opora=0.25+sigma.*randn(str,stl,'double');

    elseif k==5 %опора с антиЭКСПОНЕНЦИАЛЬНЫМ распределением
```

```

my=0.2; a1=0; a2=1; z=a1+(a2-a1).*rand(str,stl,'double');
opora=zeros(str,stl);
for ii=1:str
    for jj=1:stl
        opora(ii,j)=my*(log(z(ii,jj))-log(a2))+0.5;
        if opora(ii,jj)<-0.5
            opora(ii,jj)=-0.5+(0.5+0.5).*rand(1,1,'double');
        end
    end
end

else %опора с ЭКСПОНЕНЦИАЛЬНЫМ распределением
my=0.2; a1=0; a2=1; z=a1+(a2-a1).*rand(str,stl,'double');
opora=zeros(str,stl);
for ii=1:str
    for jj=1:stl
        opora(ii,j)=my*(-log(z(ii,jj))+log(a2))-0.5;
        if opora(ii,jj)>0.5
            opora(ii,jj)=-0.5+(0.5+0.5).*rand(1,1,'double');
        end
    end
end
end
%-----
for j=1:str
    Xiz(j,1:stl)=Picn0(j,1:stl)-opora(j,1:stl); %нахождение разницы между изображением и
опорным распределением
end

%БЛОК ПОСТРОЕНИЯ КОДОВОЙ ПОСЛЕДОВАТЕЛЬНОСТИ

%-----
for r=1:str
    for c=1:stl
        if Xiz(r,c)>=0
            Sgn(r,c)=1;
        elseif Xiz(r,c)<0
            Sgn(r,c)=-1;
        end
    end
end
%-----

%вычисление второго смешанного момента для отдельного изображения

%-----
Sgnn=[Sgn,zeros(size(Sgn,1),tau)];
Sgnn_1=[zeros(size(Sgn,1),tau),Sgn];
for l=1:str
    Liz(l,k)=(sum(Sgnn(l,1:stl).*Sgnn_1(l,1:stl),2))./size(Sgn,2); %суммирование всех
столбцов и присвоение %результата столбцу с номером k = номер опоры
end

```

```

%-----

end

Liz1='Liz'; Liz2=int2str(i); Liz3='.txt'; %преобразование i в строковый тип
Lizimf=strcat(Liz1,Liz2,Liz3); %получение очередного имени файла для обучения
save(Lizimf, 'Liz', '-ASCII') %запись признака изображения

Moc=Moc+Liz; %предварительное вычисление второго смешанного момента для всего
класса
%-----%
end
Moc=Moc./kolobj; %получение признаков класса - второго смешанного момента,
%номер столбца = номер опоры

%БЛОК ОЦЕНИВАНИЯ ПОЛОЖЕНИЯ ЦЕНТРОВ ГИПЕРСФЕР В ПРИЗНАКОВОМ
ПРОСТРАНСТВЕ
%И ПОЛУЧЕНИЯ ОЦЕНКИ РАДИУСА ГИПЕРСФЕРЫ КЛАССА

%-----%

rr=0;
for num=1:kolobj
    Liz1='Liz'; Liz2=int2str(i); Liz3='.txt'; %преобразование i в строковый тип
    Lizimf=strcat(Liz1,Liz2,Liz3); %получение очередного имени файла для обучения
    Liz=load(Lizimf); %загрузка признака изображения

%rr = (sum ( ((sum (((Lkl-M).^2), 2) )./kopor), 1) )./size(Lkl,1);
    rr = rr + (sum ( (sum (((Liz-Moc).^2), 2) ), 1) )./size(Liz,1); %вычисление радиуса гиперсферы
    класса

%1 - вычисление разницы между признаками класса и центрами гиперсфер для
соответствующих опор

%2 - возведение в квадрат этой разницы

%3 - суммирование столбцов, т.е. суммирование оценок центров для разных опор

%4 - суммирование по строкам, т.е. суммирование всех строк изображения

%5 - деление суммы на количество строк из изображения, используемых при обучении
end

rr = rr./kolobj;

%6 - вычисления корня квадратного из rr для нахождения значения радиуса гиперсферы
класса

R=(rr)^0.5;

%-----%

```

```
save('Moc1.txt', 'Moc', '-ascii'); %оценка центра гиперсферы  
save('R1.txt', 'R', '-ascii'); %оценка радиуса гиперсферы
```

```
who, whos
```

Листинг программы распознавания с использованием стохастического кодирования

```

close all; clear all; clc; clf; %format long e;
%БЛОК РАСПОЗНАВАНИЯ С ИСПОЛЬЗОВАНИЕМ МЕТОДА СТОХАСТИЧЕСКОГО
КОДИРОВАНИЯ
%С ПРЕДВАРИТЕЛЬНОЙ НОРМИРОВКОЙ МАССИВА ИЗОБРАЖЕНИЯ И
ДИНАМИЧЕСКОЙ ИНТЕРПОЛЯЦИЕЙ СИГНАЛА

korpor=6; %какое кол-во опорных распределений будет использовано

tau=2^0; %задание смещения Sgn для вычисления второго смешанного момента

mn=(2^0)*(5^0); %множитель, определяющий шаг прореживания по строкам. должен нацело
делить общее кол-во строк изображения
    %фактически является разложением на простые множители числа строк
    % 640 = 2^7 * 5
res_str=640/mn; %константа для задания резервного массива с необходимым количеством
строк

Lkl=zeros(res_str,korpor); %массив для построения признаков класса, кол-во столбцов опор-ся
кол-м опор

Picn0=zeros(res_str,1024); %резервирование массива для уменьшенного изображения

isp=10; %количество повторных испытаний
whichKL_stC=zeros(isp,4); %разервирование массива для матрицы перепутывания при
статистических испытаниях

%БЛОК СЧИТЫВАНИЯ ФАЙЛА РАСПОЗНАВАЕМОГО ИЗОБРАЖЕНИЯ
%ПРОВОДИТСЯ isp ИСПЫТАНИЙ С ОДНИМ И ТЕМ ЖЕ РАСПОЗНАВАЕМОМ
ИЗОБРАЖЕНИЕМ
%-----%
for i=1:isp
    imf='kl4_12.jpg';
    %imf='unknown1.jpg'; %получение имени файла неизвестного изображения
    Pic=imread(imf); %считывание изображения
    Picn=im2double(Pic); %преобразование массива изображения uint8 в double
(яркость в интервале [0,1])
    %imshow(imf) %контроль правильности считывания изображения
%-----%

strl=size(Picn,1); %количество строк в массиве изображения
stl1=size(Picn,2); %количество столбцов в массиве изображения

%БЛОК НАХОЖДЕНИЯ СРЕДНЕЙ ЯРКОСТИ ИЗОБРАЖЕНИЯ И ЦЕНТРИРОВАНИЕ ПО
ЯРКОСТИ (СРЕДНЕМУ ЗНАЧЕНИЮ)
%ПРОРЕЖИВАНИЕ (СЕГМЕНТАЦИЯ) ПО СТРОКАМ
%-----%
moPicn=mean(Picn(:)); %нахождение средней яркости всего изображения
Picn01=Picn-moPicn; %центрирование по средней яркости
for j=1:res_str
    Picn0(j,1:stl1)=Picn01(j*mn,1:stl1);

```

```

end
%-----%

str=size(Picn0,1); %количество строк в массиве сегментированного по строкам изображения
stl=size(Picn0,2); %количество столбцов в массиве сегментированного по строкам
изображения

%БЛОК ГЕНЕРАЦИИ ОПОРНЫХ СП С ЗАДАННЫМ ВИДОМ РАСПРЕДЕЛЕНИЯ И
ВЫЧИТАНИЯ ИХ ИЗ ИЗОБРАЖЕНИЯ
%.....
%-----%
opora=zeros(str,stl);
Xiz=zeros(str,stl); %массив для хранения разницы между строками изображения и опорой
Sgn=Xiz; %массив для хранения кодовой последовательности
Liz=zeros(str,kopor); %массив для построения признаков изображения, кол-во столбцов опор
ся кол-м опор

%генерирование опор
%-----%
for k=1:kopor
    if k==1 %опора с РАВНОМЕРНЫМ распределением
        a1=-0.5; a2=0.5;
        opora=a1+(a2-a1).*rand(str,stl,'double');

    elseif k==2 %опора с НОРМАЛЬНЫМ распределением m=0
        sigma=0.5; %параметр сигма для нормального распределения
        opora=0+sigma.*randn(str,stl,'double');

    elseif k==3 %опора с НОРМАЛЬНЫМ распределением m=-0.25
        sigma=0.25; %параметр сигма для нормального распределения
        opora=-0.25+sigma.*randn(str,stl,'double');

    elseif k==4 %опора с НОРМАЛЬНЫМ распределением m=0.25
        sigma=0.25; %параметр сигма для нормального распределения
        opora=0.25+sigma.*randn(str,stl,'double');

    elseif k==5 %опора с антиЭКСПОНЕНЦИАЛЬНЫМ распределением
        my=0.2; a1=0; a2=1; z=a1+(a2-a1).*rand(str,stl,'double');
        opora=zeros(str,stl);
        for ii=1:str
            for jj=1:stl
                opora(ii,j)=my*(log(z(ii,jj))-log(a2))+0.5;
                if opora(ii,jj)<-0.5
                    opora(ii,jj)=-0.5+(0.5+0.5).*rand(1,1,'double');
                end
            end
        end
    end

else %опора с ЭКСПОНЕНЦИАЛЬНЫМ распределением
    my=0.2; a1=0; a2=1; z=a1+(a2-a1).*rand(str,stl,'double');
    opora=zeros(str,stl);
    for ii=1:str

```

```

for jj=1:stl
    opora(ii,j)=my*(-log(z(ii,jj))+log(a2))-0.5;
    if opora(ii,jj)>0.5
        opora(ii,jj)=-0.5+(0.5+0.5).*rand(1,1,'double');
    end
end
end
end
end
%-----
for j=1:str
    Xiz(j,1:stl)=Picn0(j,1:stl)-opora(j,1:stl); %нахождение разницы между изображением и
опорным распределением
end
%БЛОК ПОСТРОЕНИЯ КОДОВОЙ ПОСЛЕДОВАТЕЛЬНОСТИ "-1/1"
%-----
for r=1:str
    for c=1:stl
        if Xiz(r,c)>=0
            Sgn(r,c)=1;
        elseif Xiz(r,c)<0
            Sgn(r,c)=-1;
        end
    end
end
end
%-----

%вычисление второго смешанного момента для отдельного изображения
%-----
Sgnn=[Sgn,zeros(size(Sgn,1),tau)];
Sgnn_1=[zeros(size(Sgn,1),tau),Sgn];
Liz(1:str,k)=(sum(Sgnn.*Sgnn_1,2))./size(Sgn,2); %суммирование всех столбцов и
присвоение
%результата столбцу с номером k = номер опоры
%-----
end
%-----%

%НИЖЕ НАХОДИТСЯ ОБЛАСТЬ РАСПОЗНАВАНИЯ
%=====

%БЛОК СЧИТЫВАНИЯ ДАННЫХ ПАРАМЕТРОВ КЛАССОВ
%-----%
kR=1; %принудительное разделение классов
kdist=1; %принудительное разделение классов
Liz=Liz.*kdist;

Moc1=load('Moc1.txt').*kdist; R1=load('R1.txt'); %R1=R1/3;
Moc2=load('Moc2.txt').*kdist; R2=load('R2.txt');
Moc3=load('Moc3.txt').*kdist; R3=load('R3.txt');
Moc4=load('Moc4.txt').*kdist; R4=load('R4.txt'); %R4=R4*1.1

%БЛОК РЕШАЮЩЕГО ПРАВИЛА

```

```

%-----%
d1 = (sum ( (sum (((Liz-Moc1).^2), 2) ), 1) ./size(Liz,1) - (1*R1*kR)^2; %сравнение с 1-м
классом
d2 = (sum ( (sum (((Liz-Moc2).^2), 2) ), 1) ./size(Liz,1) - (1*R2*kR)^2; %сравнение со 2-м
классом
d3 = (sum ( (sum (((Liz-Moc3).^2), 2) ), 1) ./size(Liz,1) - (1*R3*kR)^2; %сравнение с 3-м
классом
d4 = (sum ( (sum (((Liz-Moc4).^2), 2) ), 1) ./size(Liz,1) - (1*R4*kR)^2; %сравнение с 4-м
классом

D = [d1, d2, d3, d4]
[ming,idx]=min(D); %определяется какое из расстояний меньше
whichKL_stC(i,idx)=1;
%-----%

end
%-----%

verojatn=zeros(1,4);
for k=1:4
    verojatn(1,k)=sum(whichKL_stC(:,k));
end
bar(verojatn)

save 'whichKL_stC.txt' whichKL_stC -ascii; %запись массива с результатами голосования за
класс

who, whos

```


Листинг программы обучения по методу k-ближайших соседей

```

close all; clear all; clc; clf; %format long e;
%БЛОК ОБУЧЕНИЯ
%С ПРЕДВАРИТЕЛЬНОЙ НОРМИРОВКОЙ МАССИВА ИЗОБРАЖЕНИЯ И
ДИНАМИЧЕСКОЙ ИНТЕРПОЛЯЦИЕЙ СИГНАЛА

mn=(2^3)*(5^1); %множитель, определяющий шаг прореживания по строкам. должен нацело
делить общее кол-во строк изображения
    %фактически является разложением на простые множители числа строк
    % 640 = 2^7 * 5
res_str=640/mn; %константа для задания резервного массива с необходимым количеством
строк

%tau=;
AKF=zeros(res_str,1024); %резервирование для АКФ последовательно строк изображения-
опора
    %|АКФ строки изобр-1|
    %|.....|
    %|АКФ строки изобр-n|

AKFk1=zeros(res_str,1024); %резервирование для среднеарифметического значения всех
строк
    %АКФ отдельного изображения и построения из них массива для класса
    %|АКФ изобр-1|
    %|.....|
    %|АКФ изобр-n|

Picn0=zeros(res_str,1024); %резервирование массива для уменьшенного изображения

priznKL=zeros(3,1024); %разервирование для признаков класса: средняя АКФ класса и
диапазон
    %разброса значений от средней АКФ класса
    %|max АКФ в классе|
    %|avg АКФ в классе|
    %|min АКФ в классе|

kolobj=20; %кол-во объектов в классе

%БЛОК ПОСЛЕДОВАТЕЛЬНОГО СЧИТЫВАНИЯ ФАЙЛОВ ИЗОБРАЖЕНИЙ
%повторяется столько раз, сколько имеется изображений для обучения в конкретном классе
%-----%
for i=1:kolobj
    imf1='kl1_'; imf2=int2str(i); imf3='.jpg'; %преобразование i в строковый тип
    imf=strcat(imf1,imf2,imf3); %получение очередного имени файла для обучения
    Pic=imread(imf); %считывание изображения
    Picn=im2double(Pic); %преобразование массива изображения uint8 в double
(яркость в интервале [0,1])
    %imshow(imf) %контроль правильности считывания изображения
%-----%

```

```

str1=size(Picn,1); %количество строк в массиве изображения
stl1=size(Picn,2); %количество столбцов в массиве изображения

%БЛОК НАХОЖДЕНИЯ СРЕДНЕЙ ЯРКОСТИ ИЗОБРАЖЕНИЯ И ЦЕНТРИРОВАНИЕ ПО
ЯРКОСТИ (СРЕДНЕМУ ЗНАЧЕНИЮ)
%ПРОРЕЖИВАНИЕ (СЕГМЕНТАЦИЯ) ПО СТРОКАМ
%-----%
moPicn=mean(Picn(:)); %нахождение средней яркости всего изображения
Picn01=Picn-moPicn; %центрирование по средней яркости
for j=1:res_str
    Picn0(j,1:stl1)=Picn01(j*mn,1:stl1);
end
%-----%

str=size(Picn0,1); %количество строк в массиве сегментированного по строкам изображения
stl=size(Picn0,2); %количество столбцов в массиве сегментированного по строкам
изображения

%БЛОК ГЕНЕРАЦИИ ОПОРНОГО СП С ЗАДАННЫМ ВИДОМ РАСПРЕДЕЛЕНИЯ И
ВЫЧИТАНИЯ ЕГО ИЗ ИЗОБРАЖЕНИЯ x20
%ПОСТРОЕНИЕ МАССИВА АКФ ДЛЯ КАЖДОЙ ИЗ СТРОК
%-----%
picopora=zeros(1,stl);
%a1=min(Picn0(:)); a2=max(Picn0(:)); %задание пределов, в которых генерируется
псевдслучайный процесс
%opora=a1+(a2-a1).*rand(str,stl,'double');
sigma=0.5;
opora=0+sigma.*randn(str,stl,'double');
for j=1:str
    picopora=Picn0(j,1:stl)-opora(j,1:stl);
    akfstr=xcorr(picopora,picopora);
    АКФ(j,:)=akfstr(1,stl:stl+(stl-1)); %построение семейства АКФ для одного изображения
end
АКФ1='АКФ1_'; АКФ2=int2str(i); АКФ3='.1xt'; %преобразование i в строковый тип
АКФимf=strcat(АКФ1,АКФ2,АКФ3); %получение очередного имени файла для
обучения
save(АКФимf, 'АКФ', '-ASCII') %запись массива АКФ изображения
%-----%

%БЛОК ПОСТРОЕНИЯ ПРИЗНАКОВ КЛАССА
%-----%
АКФk1=АКФk1+АКФ; %предварительное вычисление АКФ для всего класса
end
АКФk1=АКФk1./kolobj; %получение признаков класса - АКФ,
%-----%

%БЛОК НАХОЖДЕНИЯ ЦЕНТРА И РАДИУСА КЛАССА
%-----%
srАКФk1=АКФk1(1,:);
for j=2:size(АКФk1,1)
    srАКФk1=srАКФk1+АКФk1(j,:);
end

```

```
priznKL(2,:)=srAKFkl./size(AKFkl,1); %средняя АКФ класса и его запись в 2-ю строку
массива признаков класса
```

```
%ВЫЧИСЛЕНИЕ НИЖНЕЙ (3-я строка) И ВЕРХНЕЙ (1-я строка) ГРАНИЦЫ РАЗБРОСА
ПРИЗНАКОВ КЛАССА
```

```
for j=1:size(AKFkl,2)
    priznKL(1,j)=max(AKFkl(:,j));
    priznKL(3,j)=min(AKFkl(:,j));
end
```

```
D1=pdist2((priznKL(1,:)),(priznKL(2,:)));
```

```
D2=pdist2((priznKL(3,:)),(priznKL(2,:)));
```

```
RADkl=(D1+D2)./2;
```

```
%-----%
```

```
save('AKFkl1.txt', 'AKFkl', '-ascii'); %запись АКФ класса
```

```
save('RADkl1.txt', 'RADkl', '-ascii'); %запись радиуса класса
```

```
who, whos
```

Листинг программы распознавания по методу k-ближайших соседей

```

close all; clear all; clc; clf; %format long e;
%БЛОК РАСПОЗНАВАНИЯ
%С ПРЕДВАРИТЕЛЬНОЙ НОРМИРОВКОЙ МАССИВА ИЗОБРАЖЕНИЯ И
ДИНАМИЧЕСКОЙ ИНТЕРПОЛЯЦИЕЙ СИГНАЛА

mn=(2^3)*(5^1); %множитель, определяющий шаг прореживания по строкам. должен нацело
делить общее кол-во строк изображения
    %фактически является разложением на простые множители числа строк
    % 640 = 2^7 * 5
res_str=640/mn; %константа для задания резервного массива с необходимым количеством
строк

AKF=zeros(res_str,1024); %резервирование для АКФ последовательно строк
изображения(распознаваемого)-опора
    %|АКФ стр.1 изобр|
    %|.....|
    %|АКФ стр.n изобр|

AKFiz=AKF; %резервирование для АКФ отдельного изображения одного из классов
    %|АКФ стр.1 изобр|
    %|.....|
    %|АКФ стр.n изобр|

Picn0=AKF; %резервирование массива для уменьшенного изображения

isp=10; %количество повторных испытаний
whichKL=zeros(isp,4); %разервирование массива для матрицы перепутывания при
статистических испытаниях

%БЛОК СЧИТЫВАНИЯ ФАЙЛА РАСПОЗНАВАЕМОГО ИЗОБРАЖЕНИЯ
%ПРОВОДИТСЯ isp ИСПЫТАНИЙ С ОДНИМ И ТЕМ ЖЕ РАСПОЗНАВАЕМОМ
ИЗОБРАЖЕНИЕМ
%-----%
for i=1:isp
    Kmn=0.4; %регулирование размера области голосования
    imf='k11_1.jpg'; %получение имени файла неизвестного изображения
    Pic=imread(imf); %считывание изображения
    Picn=im2double(Pic); %преобразование массива изображения uint8 в double
(яркость в интервале [0,1])
    %imshow(imf) %контроль правильности считывания изображения
%-----%

str1=size(Picn,1); %количество строк в массиве изображения
stl1=size(Picn,2); %количество столбцов в массиве изображения

%БЛОК НАХОЖДЕНИЯ СРЕДНЕЙ ЯРКОСТИ ИЗОБРАЖЕНИЯ И ЦЕНТРИРОВАНИЕ ПО
ЯРКОСТИ (СРЕДНЕМУ ЗНАЧЕНИЮ)
%ПРОРЕЖИВАНИЕ (СЕГМЕНТАЦИЯ) ПО СТРОКАМ
%-----%

```

```

moPicn=mean(Picn(:)); %нахождение средней яркости всего изображения
Picn01=Picn-moPicn; %центрирование по средней яркости
for j=1:res_str
    Picn0(j,1:stl1)=Picn01(j*mn,1:stl1);
end
%-----%

str=size(Picn0,1); %количество строк в массиве сегментированного по строкам изображения
stl=size(Picn0,2); %количество столбцов в массиве сегментированного по строкам
изображения

%БЛОК ГЕНЕРАЦИИ ОПОРНОГО СП С ЗАДАННЫМ ВИДОМ РАСПРЕДЕЛЕНИЯ И
ВЫЧИТАНИЯ ЕГО ИЗ ИЗОБРАЖЕНИЯ
%ПОСТРОЕНИЕ МАССИВА АКФ ДЛЯ КАЖДОЙ ИЗ СТРОК
%-----%
picopora=zeros(1,stl);
%a1=min(Picn0(:)); a2=max(Picn0(:)); %задание пределов, в которых генерируется
псеводслучайный процесс
%opora=a1+(a2-a1).*rand(str,stl,'double');
sigma=0.5;
opora=0+sigma.*randn(str,stl,'double');
for j=1:str
    picopora=Picn0(j,1:stl)-opora(j,1:stl);
    akfstr=xcorr(picopora,picopora);
    АКФ(j,:)=akfstr(1,stl:stl+(stl-1)); %построение семейства АКФ для одного изображения
end
%-----%

%НИЖЕ НАХОДИТСЯ ОБЛАСТЬ РАСПОЗНАВАНИЯ
%=====

%БЛОК ВЫЧИСЛЕНИЯ ОБЛАСТИ ГОЛОСОВАНИЯ ЗА КЛАСС - МИНИМАЛЬНОГО
РАДИУСА СРЕДИ КЛАССОВ
%-----%

R1=load('RADk1.txt'); R2=load('RADk12.txt'); R3=load('RADk13.txt'); R4=load('RADk14.txt');
RADk1=[R1, R2, R3, R4]; %резервирование под значения радиусов для каждого класса
[minRAD,ind]=min(RADk1); %минимальный радиус среди всех классов
minRAD=minRAD*Kmn;
%-----%

%БЛОК СЧИТЫВАНИЯ ДАННЫХ ПАРАМЕТРОВ КЛАССОВ
%-----%
rezgolos=zeros(1,4); %резервирования для подсчёта голосов по классам
for kl=1:4
    golos=0;
    for j=1:20 %цикл считывания параметров объекта конкретного класса
        klf1='AKF'; klf2=int2str(kl); klf3='_'; klf4=int2str(j); klf5='.txt';
        klf=strcat(klf1,klf2,klf3,klf4,klf5);
        АКФiz=load(klf);
    end
end

```

%БЛОК ВЫЧИСЛЕНИЯ РАССТОЯНИЙ МЕЖДУ НЕИЗВЕСТНЫМ ИЗОБРАЖЕНИЕМ И ВСЕМИ ОБЪЕКТАМИ В КЛАССЕ

```
%-----%
    dist=pdist2(AKFiz(1,:),AKF(1,:));
    for k=2:size(AKFiz,1)
        dist=dist+pdist2(AKFiz(k,:),AKF(k,:));
    end
    dist=dist./size(AKF,1);


    if dist < minRAD
        golos=golos+1;
    elseif dist >= minRAD
        golos=golos+0;
    end
%-----%
    end
    kl
    rezgolos(1,kl)=golos %подсчитывает голоса за каждый класс, кол-во голосов за класс
    %записывается в строки, номер столбца = номер класса
end
[ming,idx]=max(rezgolos); %определяется за какой класс отдано большее количество
голосов
    whichKL(i,idx)=1 %строка i определяется номером испытания, а в столбец с номером
    %idx, равному номеру класса, записывается 1

end
%-----%

verojatn=zeros(1,4);
for k=1:4
    verojatn(1,k)=sum(whichKL(:,k));
end
bar(verojatn)
save 'whichKL.txt' whichKL -ascii; %запись массива с результатами голосования за класс

who, whos
```

ПРИЛОЖЕНИЕ 2



внедрения результатов, полученных в диссертационной работе Поцыкайло Александра Анатольевича «Исследование и разработка методов формирования решающих правил при классификации фрагментов на полутоновых изображениях», представленной на соискание учёной степени кандидата технических наук.

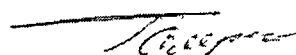
Комиссия в составе профессора Галустова Г.Г. (председатель), профессора Плаксиенко В.С., доцента Бровченко С.П. рассмотрела диссертационную работу Поцыкайло Александра Анатольевича «Исследование и разработка методов формирования решающих правил при классификации фрагментов на полутоновых изображениях» и составила настоящий акт о том, что результаты, полученные в представленной диссертации, внедрены в Государственном автономном образовательном учреждении высшего профессионального образования «Технологический институт Южного федерального университета в г. Таганроге» при выполнении учебно-методических работ.

Диссертационная работа выполнена по направлениям приоритетного национального проекта «Образование», реализуемого в Технологическом институте Южного федерального университета в г. Таганроге, и её результаты способствуют развитию инноваций в учебном процессе кафедры РПрУ и ТВ.

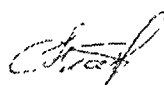

Предметом внедрения является комплекс программ для математического моделирования в пакете MATLAB 7.5 (R2008a). Данный комплекс программ используется при проведении лабораторных работ и курсовом проектировании предусмотренных программами дисциплин «Устройства приёма и преобразования сигналов» и «Основы компьютерного проектирования».

Внедрённые в учебный процесс материалы диссертационной работы Поцыкайло Александра Анатольевича позволили повысить уровень подготовки студентов по направлению «Радиотехника», а также были использованы при выполнении бакалаврских выпускных квалификационных работ, дипломных проектов и магистерских диссертаций.


Председатель комиссии:
д.т.н., профессор

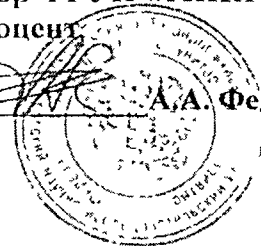
 Г.Г. Галустов

Члены комиссии:
д.т.н., профессор
к.т.н., с.н.с., доцент

 В.С. Плаксиенко
 С.П. Бровченко

Утверждаю
 Директор ФГУП «ТНИИС»
 д.т.н., доцент


 А.А. Федотов



А К Т

**Научно-технической комиссии о реализации
 научных положений и выводов кандидатской диссертации
 Поцыкайло Александра Анатольевича**

Комиссия в составе председателя, заместителя директора по науке Кулакова А.А., главного инженера, к.т.н., доцента Гришкова А.Ф., начальника сектора, к.т.н. Шпака В.Ф. и начальника ПЭО Рыбаковой Т.И. констатирует, что диссертационная работа Поцыкайло А.А. на тему "Исследование и разработка методов формирования решающих правил при классификации фрагментов на полутоновых изображениях", посвященная повышению качества классификации полутоновых изображений, по своему содержанию рассматривает вопросы производственного характера, свойственные ФГУП «ТНИИС» и решаемых в рамках выполняемых НИОКР. Автор развил и научно обосновал новые методы построения математических моделей сигналов изображений, разработал алгоритмы формирования классификационных признаков изображений, исследовал их эффективность в условиях высокой вариабельности характеристик сигнала изображений. Он проанализировал современные варианты моделей изображений и предложил новый подход к классификации сигналов изображений, основанный на переходе от двумерного представления изображения к системе одномерных реализаций. В качестве моделей сигналов изображений, предназначенных для исследования эффективности алгоритмов классификации, предложил использовать стационарные процессы, получаемые с использованием стохастического кодирования одномерных реализаций из системы выборочных строк изображения протяженного объекта.

Результаты диссертационной работы:

- разработана методика преобразования оцифрованных сигналов изображений объекта в одномерные реализации случайных объектов, позволяющая перейти от двумерного представления сигналов изображений к одномерным;

- на основе анализа существующих методов формирования признаков пространств при классификации сигналов моделей изображений показана, возможность улучшения качества работы автомагизированных распознающих систем за счет нелинейного преобразования исходных пространств сигналов, которое обеспечивает сокращение избыточности описания исходных сигналов и сокращение временных и аппаратурных затрат при решении задач классификации изображений;

- разработан алгоритм непараметрической классификации сигналов изображений на основе формирования признаков пространств по методу стохастического кодирования. Разработаны математические модели алгоритмов. Определены показатели качества и сложности разработанного алгоритма МСОК при их реализации на микропроцессорных системах для решения задачи классификации сигналов изображений;


-проведено экспериментальное исследование показателей качества разработанного алгоритма МСОК.

Полученные результаты использованы при классификации графических образов радиотехнических сигналов. Разработанные алгоритмы отличаются высокой универсальностью и могут быть использованы для машинного распознавания графических образов динамики развития излучения радиоэлектронных средств.

Внедрение результатов кандидатской диссертации Поцкайло А.А. способствует решению важной научно-технической проблеме повышения машинного интеллекта при решении задачи автоматической идентификации излучающих объектов по графическим характеристикам их радиотехнических сигналов.


Результаты работы могут найти применение при выполнении новых опытно-конструкторских работ ФГУП «ТНИИС».

Председатель комиссии,
Заместитель директора



А.А. Кулаков

Члены комиссии:

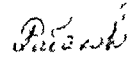
Главный инженер, к.т.н., доцент


А.Ф. Гришков

Начальник сектора,
к.т.н., доцент


В.Ф. Шчаков

Начальник ПЭО


Т.П. Рыбакова

УТВЕРЖДАЮ
 Директор-главный конструктор
 НКБ "МИУС" ЮФУ
 И.Ф. Сурженко
 "___" _____ 2011 г.


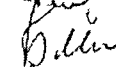
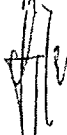
АКТ
 внедрения результатов диссертационной работы
 на соискание учёной степени кандидата технических наук
 Александра Анатольевича Поцькайло

Результаты, полученные в кандидатской диссертации А. А Поцькайло "Исследование и разработка методов формирования решающих правил при классификации фрагментов на полутоновых изображениях" использовались в разработках отдела 15 НКБ "МИУС" ЮФУ в рамках темы "Степль функционального контроля оптико-электронной системы слежения (СФКОЭСС)".

Основными результатами внедрения являются:

- метод формирования системы признаков на основе метода стохастического кодирования сигналов изображений;
- алгоритм непараметрической классификации моделей сигналов изображений;
- методика построения решающих правил в условиях априорной неопределенности при классификации изображений.

Разработанные алгоритмы могут быть использованы в ряде приборов для автоматизированной классификации изображений. Полученные в диссертации научные и практические результаты реализованы при разработке СФКОЭСС по договору 315077.

| | | |
|-----------------------------|---|----------------|
| Начальник отдела 15 |  | В. Н. Сапрунов |
| Начальник сектора отдела 15 |  | Л. М. Блинова |
| Начальник отдела 24 |  | В. А. Буряк |