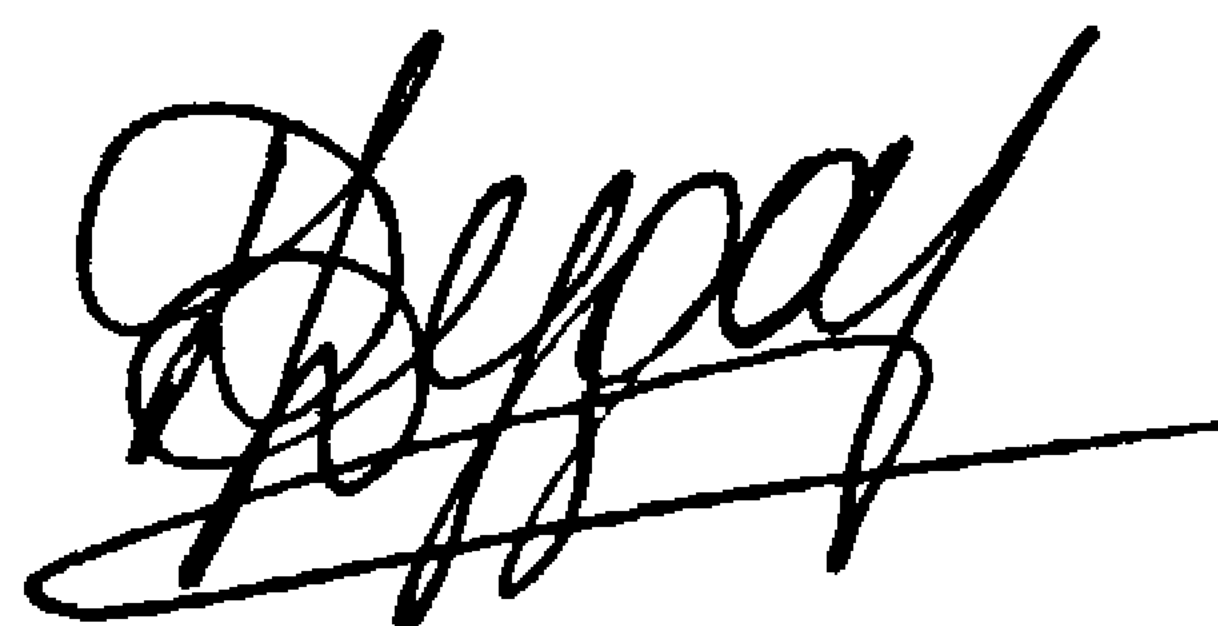


61:05-5/3707

Министерство образования и науки Российской Федерации
Федеральное агентство по образованию
Государственное образовательное учреждение высшего профессионального образования
Таганрогский государственный радиотехнический университет



На правах рукописи

Дударов Денис Александрович

Исследование и разработка методов формирования решающих правил при классификации сигналов изображений

Специальности 05.13.18 "Математическое моделирование, численные методы и комплексы программ"
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 Геннадий Григорьевич

Таганрог 2005

СОДЕРЖАНИЕ

	стр.
ВВЕДЕНИЕ.....	5
ГЛАВА 1: ПОСТАНОВКА ЗАДАЧИ ИССЛЕДОВАНИЯ И АНАЛИЗ	
ИЗВЕСТНЫХ МЕТОДОВ.....	18
1.1 Постановка задачи выбора моделей сигнала	18
1.2 Анализ методов формирования решающих правил, применяемых для решения задач классификации	25
1.2.1 Распознавание образов	25
1.2.1 Формирование признаков по изображению	28
1.3 Постановка задачи оптимизации признаковых пространств.....	31
1.4 Методы распознавания, основанные на теории статистических решений.....	37
1.5 Обзор методов оптимизации параметров распознающих систем в случае параметрической априорной неопределенности.....	46
1.5.1 Оптимизация временных характеристик системы распознавания одномерных нормальных совокупностей.....	49
1.5.2 Оптимизация временных характеристик системы распознавания многомерных нормальных совокупностей.....	54
1.5.3 Оптимизация размерности признакового пространства.....	60
Выводы по материалам 1 главы.....	65
ГЛАВА 2: ИССЛЕДОВАНИЕ ХАРАКТЕРИСТИК СИГНАЛОВ	
ИЗОБРАЖЕНИЙ В РАСПОЗНАЮЩИХ СИСТЕМАХ.....	66
2.1 Объекты исследования.....	66
2.2 Выбор математической модели сигналов изображений.....	67
2.3 Методика преобразования сигналов изображений.....	70
2.3.1 Нормализация сигналов изображений.....	74
2.4 Укрупнение описания сигналов изображений на основе обобщенного оператора преобразования.....	77
Выводы по материалам 2 главы.....	86

ГЛАВА 3: РАЗРАБОТКА МОДЕЛЕЙ ПРИНЯТИЯ РЕШЕНИЙ ПРИ НЕПАРАМЕТРИЧЕСКОМ РАСПОЗНАВАНИИ СИГНАЛОВ ИЗОБРАЖЕНИЙ.....	87
3.1 Формирование системы признаков на основе метода стохастического кодирования сигналов изображений.....	87
3.1.1 Исследование связи статистических характеристик анализируемого процесса с опорным процессом.....	97
3.2 Оптимизация разделяющих поверхностей и принятие решений...:	100
3.3 Определение структурной схемы алгоритма распознавания	104
3.4 Исследование влияния вида и количества опорных распределений на эффективность классификатора.....	107
3.5 Исследование влияния времени обучения и распознавания на эффективность классификатора.....	119
Выводы по материалам 3 главы.....	127
ГЛАВА 4: МОДЕЛИРОВАНИЕ И ЭКСПЕРИМЕНТАЛЬНАЯ ПРОВЕРКА ЭФФЕКТИВНОСТИ РАБОТЫ КЛАССИФИКАТОРА СИГНАЛОВ ИЗОБРАЖЕНИЙ.....	128
4.1 Задачи исследования.....	128
4.2 Методы моделирования устройств обработки сигналов, основанные на использовании современных пакетов программ для математического моделирования.....	128
4.3 Моделирование алгоритмов непараметрического распознавания...	134
4.4 Оценка вычислительной сложности программы моделирования...:	140

4.5 Сравнительный анализ показателей качества и сложности НК МСОК и алгоритма непараметрической классификации по методу k ближайших соседей	141
4.6 Оценка статистической погрешности результатов моделирования	149
4.7 Разработка структурной схемы экспериментальной установки.....	153
4.8 Определение показателей качества работы непараметрического классификатора.....	154
Выводы по материалам 4 главы.....	157
ЗАКЛЮЧЕНИЕ.....	158
ЛИТЕРАТУРА.....	160
ПРИЛОЖЕНИЯ.....	166
Приложение А.....	167
Приложение Б.....	175
Приложение В.....	184

ВВЕДЕНИЕ

Несмотря на высокий уровень развития современной компьютерной техники, до настоящего времени остается целый ряд практических задач, решение которых оказывается достаточно проблематичным. К числу подобных задач относится задача распознавания образов. Обусловлено это во многом определяется сложностью формализации процесса восприятия видимых образов. Поэтому, несмотря на очевидную легкость, с которой человек решает задачу распознавания окружающих его предметов, все еще нет "универсального" математического или технологического подхода, позволяющего конструктивно разрабатывать методы, алгоритмы и автоматические устройства, эффективно осуществляющие процесс распознавания. [57, 33, 34, 35] Однако для некоторых частных ситуаций, когда математические модели оказываются подходящими для той или иной практической задачи, удастся получить приемлемые результаты.

Весь спектр задач, которые приходится решать при распознавании на изображениях, можно подразделить на две группы:

- распознавание или классификация изображений;
- поиск и распознавание объектов (специфических локальных областей) на изображениях.

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. Таким образом, 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 изображе-

ния в виде схемы, приведенной на рисунке В.1, которая является традиционной и стандартной для задач распознавания образов.



Рисунок В.1 – 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. [36] 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 соответствие со схемой, в упрощенном виде представленной на рисунке В.2, то есть включа-

ет в себя трудно формализуемую задачу выделения фрагментов ("областей интереса").

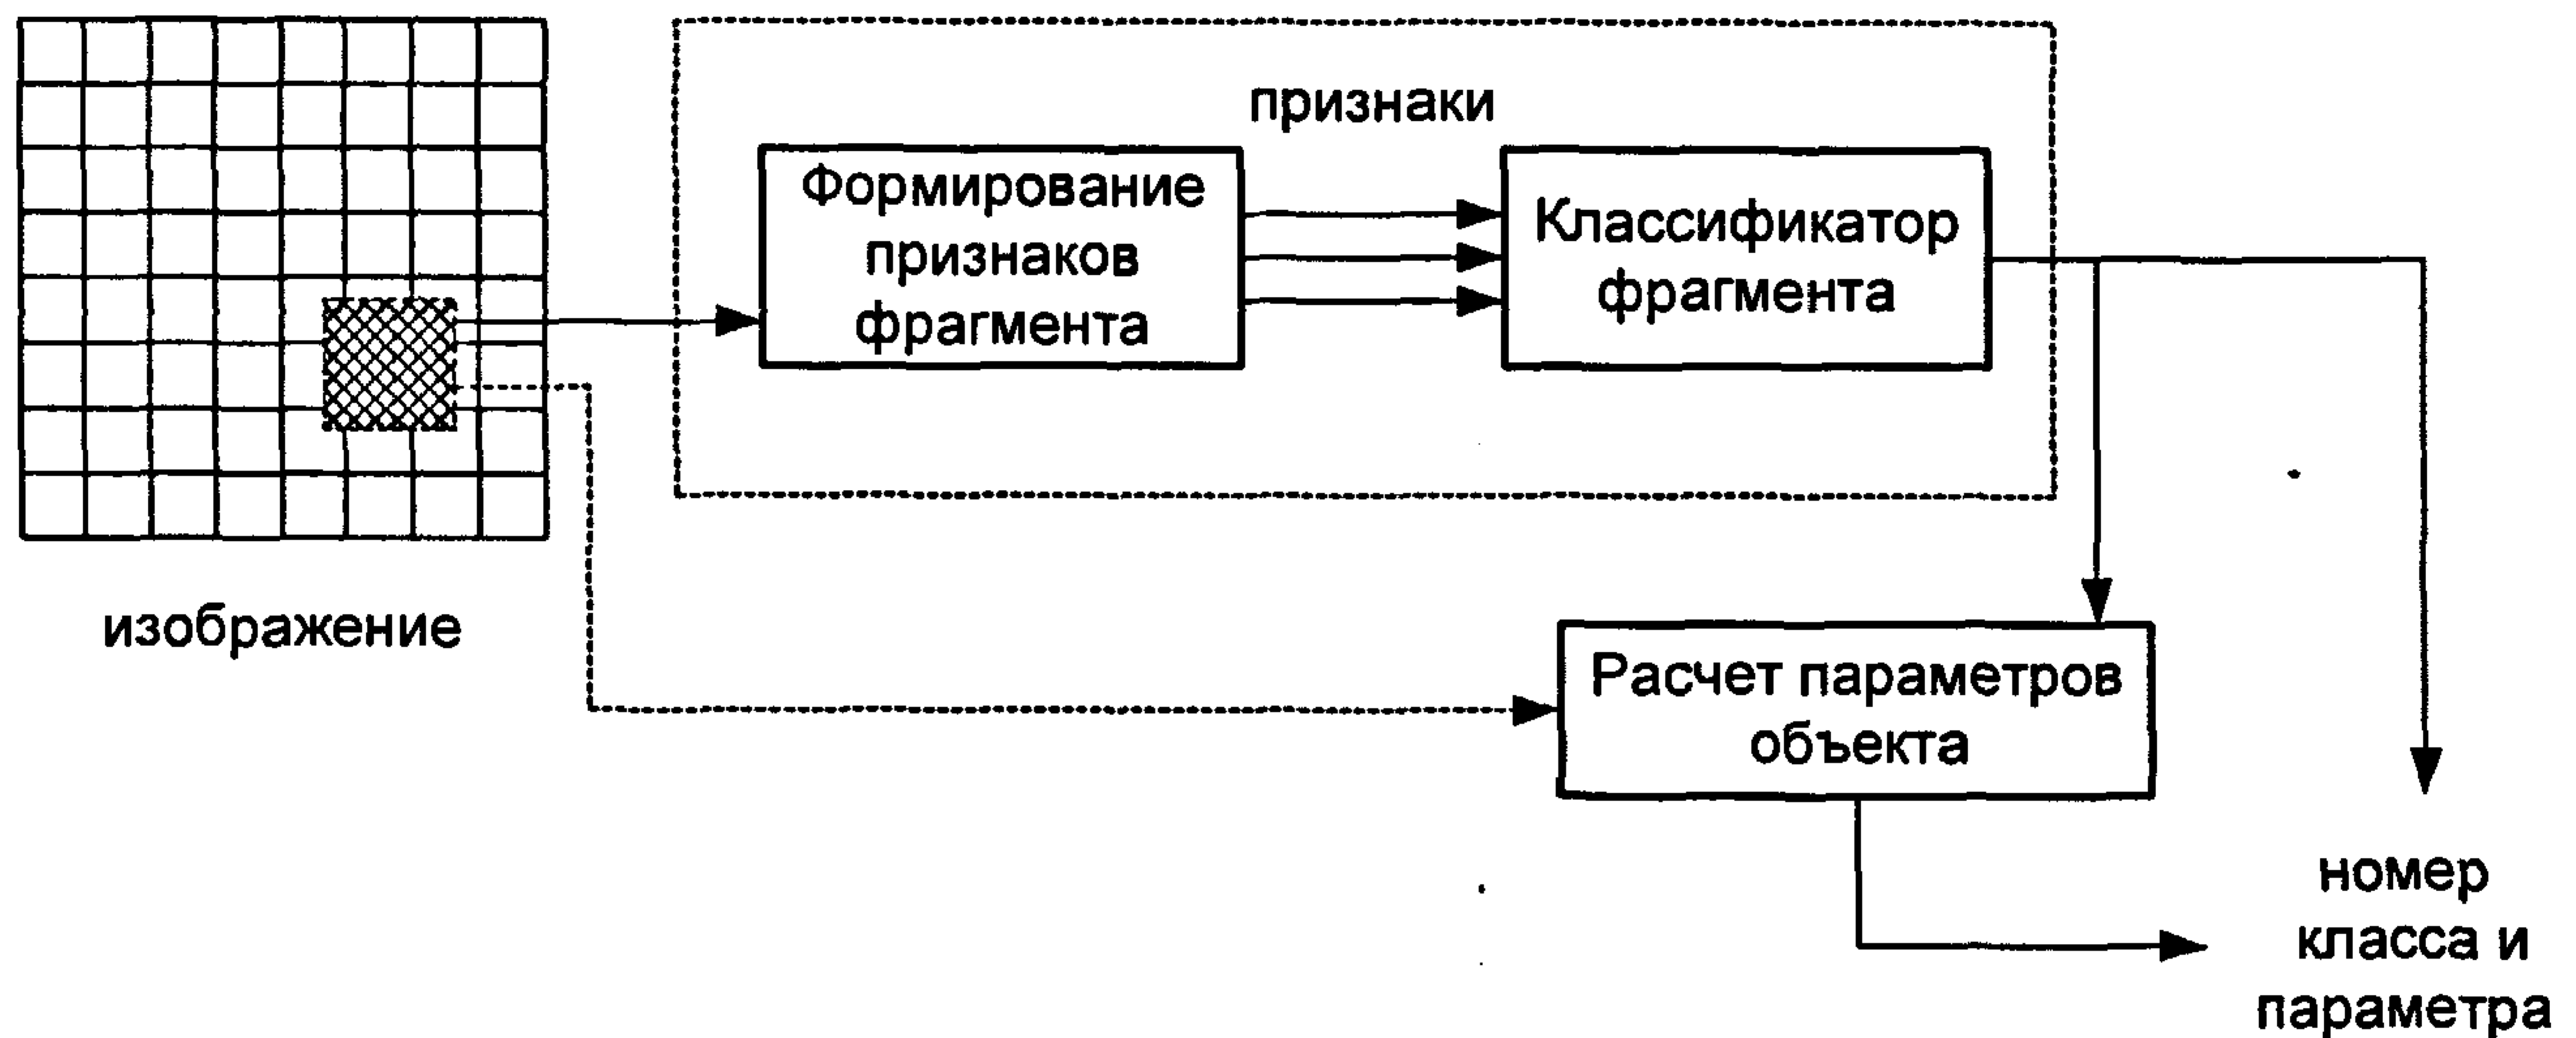


Рисунок В.2 – Схема поиска и распознавания объектов на изображении

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

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 распо-

знавания людей по фотографиям их лиц заключается в нахождении на изображении ярко выраженных областей интереса: глаз, носа, губ и т.д., и их последующего описания [89, 57, 25].

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 [15, 83, 25, 3]. 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. Разработать набор эффективных признаков используемых в устройствах классификации изображений. Исследовать возможности оптимизации временных и пространственных параметров классификаторов изображений, на основе разработанных признаков.

Решение поставленной задачи проводится в несколько этапов.

1. Разработка метода построения математических моделей сигналов изображения в виде реализации случайных процессов.

2. Выбор критерия эффективности признаков, используемых в классификаторах сигналов изображений.

3. Разработка алгоритма формирования классификационных признаков на основе метода стохастического кодирования сигналов.

4. Исследование влияния времени обучения и распознавания и размерности признакового пространства на показатели эффективности классификатора.

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

6. Экспериментальное исследование показателей качества разработанных алгоритмов при классификации изображений.

Актуальность. Задача классификации (распознавания) изображений 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 получен ряд новых результатов, которые сводятся к следующему:

1. Предложена методика преобразования оцифрованных сигналов изображений объекта в одномерные реализации случайных процессов, позволяющих реализовать алгоритм их классификации.

2. Разработан алгоритм формирования системы эффективных классификационных признаков использующих сформированные реализации на основе метода стохастического кодирования.

3. Получены зависимости показателей эффективности классификатора оцифрованных сигналов изображений от времени обучения и распознавания, от вида опорных распределений и размерности признакового пространства, позволяющие минимизировать ошибку классификации.

4. Вычислены оценки показателей качества и сложности для разработанного алгоритма формирования систем признаков.

5. Определены условия целесообразности использования в системах распознавания изображений, разработанных алгоритмов.

Практическая ценность. Результаты диссертации были использованы при выполнении НИР "Известность-Т" и "Миля-Т", в НИИ Многопроцессорных вычислительных систем Таганрогского государственного радиотехнического университета, при разработке устройств систем технического зрения дистанционно управляемых и автономных объектов. 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. Отдельные результаты работы были использованы в учебном процессе кафедры Радиоприемных устройств и телевидения Таганрогского государственного радиотехнического университета, в курсе "Основы цифрового телевидение", а также при выполнении хоздоговорных работ №11334, № 11337 и № 11338.

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

Методы исследования основаны на использовании методов теории вероятности и математической статистики, численных методах, статистической теории распознавания образов.

Основные положения, выносимые на защиту, следующие:

- методика преобразования оцифрованных сигналов изображений в одномерные реализации случайного процесса;
- математические и цифровые модели сигналов изображения и критерии эффективности признаков сформированных на основе нелинейного преобразования сигналов;
- алгоритм формирования признаков по методу стохастического кодирования;
- зависимости дисперсий оценок признаков и ошибки распознавания от времени обучения, вида опорных распределений, размерности признакового пространства;
- результаты анализа показателей качества и сложности предлагаемых алгоритмов формирования признаков;
- результаты экспериментальных исследований предложенных алгоритмов в распознающих системах изображений.

Апробация работы. Основные положения диссертационной работы обсуждались и докладывались:

- на XIII Международной научно-технической конференции студентов и аспирантов "Радиоэлектроника, электротехника и энергетика" (Москва, 2002г.);
- VI Всероссийской научной конференции студентов и аспирантов "Техническая кибернетика, радиоэлектроника и системы управления" (Таганрог, 2002г.);
- Международной научной конференции "Информационный подход в естественных, гуманитарных и технических науках" (Таганрог, 2004г.);
- Международной научной конференции "Искусственный интеллект. Интеллектуальные и многопроцессорные системы 2004" (Таганрог, 2004г.);

– Международной научной конференции "Оптимальные методы решения научных и практических задач" (Таганрог, 2005г.).

Публикации. Основные научные результаты диссертации опубликованы в 10 печатных работах.

СТРУКТУРА ДИССЕРТАЦИИ. Диссертационная работа состоит из введения, четырех глав, заключения и приложений.

Работа содержит 165 стр. текста, 41 рисунок, 4 таблицы, список литературы из 95 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 методов 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.

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.

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 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.

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

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 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 вероятностей правильной классификации. Однако при увеличении количества объектов обучения (более 20-30) 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. Для проведения эксперимента была разработана экспериментальная установка, включающая в себя цифровую ПЗС камеру и персональная ЭВМ.

В заключении сформулированы основные научные и практические результаты работы.

Приложения к диссертации содержат программы расчета характеристик и моделирования алгоритмов работы устройств непараметрической обработки случайных процессов, а также результаты экспериментального определения ха-

ра характеристик работы непараметрических классификаторов при обработке изображений.

Программы представляют собой рабочие документы пакета для математического моделирования Mathcad Professional 2003. Данные программы легко могут быть использованы непосредственно на любом компьютере, содержащем указанный пакет, например в учебно-методических целях.

В приложениях, также приложены акты внедрения результатов работы.

1 ПОСТАНОВКА ЗАДАЧИ ИССЛЕДОВАНИЯ И АНАЛИЗ ИЗВЕСТНЫХ МЕТОДОВ

1.1 Постановка задачи выбора моделей сигнала

При любых теоретических исследованиях используются модели реальных объектов и явлений, содержательность и результативность этих исследований в значительной степени зависит от соответствия модели реальным объектам, от конструктивности и простоты модели. При этом каких-либо общих формальных методов или процедур построения моделей не существует [53, 10]. Выбор и конструирование моделей осуществляется на интуитивном уровне, и успех зависит во многом от квалификации и опыта разработчика. Иначе говоря, наиболее ответственный этап проектирования диагностических систем, определяющий основные решения, – выбор моделей исходных сигналов – в настоящее время не допускает какой-либо оптимизации.

Требования, предъявляемые к используемым моделям, находятся в жестком противоречии. С одной стороны, модель должна быть адекватна исследуемому объекту или явлению, а с другой – сложность этой модели не должна превышать определенный уровень. Используемый в традиционной теории сигналов подход, основанный на требовании изоморфизма сигналов и моделей не позволяет разрешить это противоречие, которое для сложных сигналов принципиально не разрешимо на основе данного требования.

Поэтому основными требованиями к модели должны быть ее адекватность анализируемой сцене в широком диапазоне параметров, удобство и простота в использовании.

Для того, чтобы сформулировать задачу выбора моделей исследуемых сигналов, прежде всего необходимо рассмотреть виды сигналов, получаемых при исследованиях, определить их качественные и количественные характери-

стики. А также необходимо ограничить область рассмотрения сигналов изображений.

Всю совокупность различного рода сигналов, характерных для тех или иных методов распознаваний, можно разделить на две большие группы, рисунок 1.1: детерминированные и стохастические [22].



Рисунок 1.1 – Классификация типовых сигналов используемых при диагностических исследованиях

Детерминированные сигналы представляют собой некоторые функции времени, вид которых задан, а конкретные параметры, определяющие однозначно форму этих сигналов, неизвестны. Например $x(t) = A \sin(\omega_0 t + \varphi)$. Амплитуда A , фаза φ и частота ω_0 априори неизвестны.

Стохастическими называются процессы, развитие которых во времени или пространстве подчиняются вероятностным законам. Из большого числа различных классификаций стохастических сигналов целесообразно выделить классификацию, в которой содержатся лишь те разновидности сигналов, представители которых встречаются в функционально-диагностических исследованиях или полезны как достаточно удобная математическая модель, с необходимой точностью адекватная реальным процессам.

С этих позиций все стохастические сигналы разделяют на три группы [22]:

- случайные (скалярные) процессы;
- векторные случайные процессы;
- случайные поля.

Случайный (скалярный) процесс $X(t)$ есть функция одного аргумента t (обычно функция времени), причем для каждого фиксированного t значение $X(t)$ является некоторой случайной величиной. В зависимости от конкретных особенностей из всей совокупности процессов $X(t)$ выделяют:

- чисто случайный процесс (процесс типа "белого" шума);
- линейный случайный процесс, который можно интерпретировать как результат прохождения чисто случайного процесса через линейную динамическую систему;
- импульсный случайный процесс, для которого показательно то обстоятельство, что информативными являются форма и расположение составляющих этот процесс импульсов;
- точечные процессы (импульсные потоки), определенные на дискретном множестве точек, которые, как и в предыдущем случае, представляют собой последовательности импульсов, разделенных случайными интервалами времени, однако здесь форма импульсов уже не играет никакой роли, а информативным является сам факт появления импульсов в те или иные моменты времени.

Векторный случайный процесс – это совокупность нескольких скалярных процессов:

$$\bar{X}(t) = \{X_1(t), X_2(t), \dots, X_n(t)\} \quad (1.1)$$

Случайное поле $X(l_1, l_2, \dots, l_k, t)$ является функцией не одного, а нескольких аргументов l_1, l_2, \dots, l_k , интерпретируемых обычно как координаты k -мерного пространства и, быть может, времени t .

Анализ сигналов изображений, характерных для различных методов их получения, показывает, что для большинства методов эти сигналы относятся к классу случайных процессов той или иной разновидности.

Анализируя доводы приводимые в различных источниках, можно сделать вывод, что исследуемые в данной работе сигналы изображений заключены в группе случайных процессов – случайные поля.

Рассматриваемые модели основаны на принципе укрупнения описания сигналов, имеющих стохастическую природу. Принцип укрупнения сигналов состоит в замене исходного сигнала сигналом существенно меньшей размерности (при условии сохранения в заданных пределах эффективности систем классификации) на основе преобразования исходного многомерного пространства сигнала (пространства признаков) в пространство функционалов, обладающее значительно меньшей размерностью [21]. При этом происходит формирование в пределах признакового пространства укрупненных координат нового сигнала с помощью так называемой динамической интерполяции [25], заключающейся в сравнении исходного сигнала и некоторым изменяющимся порогом и выборе из результата старшего (знакового) разряда в качестве значащего. 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 [20].

Выше уже упоминалось о представлении исследуемых сигналов в виде совокупности признаков или точек в признаковом пространстве. Такое представление 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.

В настоящее время известно большое количество моделей, пригодных для решения задач распознавания образов, опирающихся на геометрическое представление и истолкование характеристик образов, подлежащих распозна-

ванию, как координат в пространстве признаков [45, 74, 12, 49, 80]. 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. Пространство называют метричным, если задана числовая функция, которая каждой паре точек пространства ставит в соответствие расстояние между ними [12]. Эту функцию называют метрикой пространства. Предполагается, что метрика пространства должна удовлетворять некоторым естественным условиям. Расстояние между двумя точками должно быть всегда положительным и обладать свойством симметрии. Кроме того, расстоя-

ние между двумя точками не должно превышать суммы их расстояний до любой третьей.

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 подвластным его образу мышления.

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

$$d = \sqrt{(x_{1i} - x_{1j})^2 + (x_{2i} - x_{2j})^2 + \dots + (x_{pi} - x_{pj})^2}, \quad (1.2)$$

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.

Таким образом, каждый объект A может быть представлен точкой A в r -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.

Если же зоны Ω_m пересекаются, то образуются зоны неоднозначности решения задачи классификации. Точки A_i многомерного пространства, попавшие в эти зоны 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 удастся измерить либо описать формально, а часть информации отбрасывается при обработке.




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

Необходимо отметить, что при решении задач распознавания образов с использованием геометрических моделей опираются на основополагающую гипотезу о компактности образов [9. 70, 1]: простому образу соответствует ком-

компактное множество точек в признаковом пространстве. При этом предполагается, что

- 1) всегда возможен плавный 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.

Уточним понятие компактного множества [12]. Компактным множеством называется такое 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.

1.2 Анализ методов формирования решающих правил, применяемых для решения задач классификации

1.2.1 Распознавание образов

Распознавание образов заключается в классификации изображений на основе определенных требований, причем изображения, относящиеся к одному классу образов, обладают относительно высокой степенью близости. Следовательно, процесс распознавания состоит в том, что система распознавания на основе сопоставления апостериорной информации относительно каждого поступившего на вход системы объекта (или изображения) с априорным описанием классов принимает решения о принадлежности этого объекта (изображения) к

одному из классов. Подобный принцип распознавания был заимствован у человека, который обладает удивительной способностью к обучению и умением разделять предоставляемые объекты на классы по всевозможным признакам (таксономия) [45, 57].

Распознавание представляет собой отнесение исследуемого объекта, задаваемого в виде совокупности наблюдений, к одному из взаимоисключающих классов [71, 72]. Это означает, что существует однозначное отображение совокупности наблюдений, являющейся конечным числовым множеством $\{X\}$ на множество классов $\{s\} = \{s_1, s_2, \dots, s_k\}$, количество которых задано, $\{s\} \leftarrow \{x\}$. Без потери общности классы можно заменить их номерами $\{1, 2, \dots, K\}$, и, рассматривая последние как натуральные числа, представлять себе распознавание как 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 $k = 1, 2, \dots, K$ [45].

На практике множество наблюдений, как правило, может быть представлено в виде измеренных значений p характеристик (признаков) x_1, x_2, \dots, x_p , при этом количество наблюдений равно определенному числу n , приведенному на рисунке 1.2. Тогда распознавание сводится к rp – аргументной функции вида $k = d(x_{11}, x_{12}, \dots, x_{ij}, \dots, x_{pn})$, где x_{ij} – j -ое измеренное значение i -го признака, $i = 1, 2, \dots, p$, $j = 1, 2, \dots, n$, причем указанная функция, называемая решающей функцией, 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, непредсказуемый вероятностный характер которых сказывается на всех стадиях, начиная с процесса получения самих измерений и кончая вычислением значений функции $d(x_{11}, x_{12}, \dots, x_{ij}, \dots, x_{pn})$. Дестабилизирующие факторы выступают в диагностике как погрешности преобразующих устройств, как шумы в каналах передачи данных изображений, аппаратные шумы, а также, как ошибки округления при вычислениях, связанные с ограниченностью разрядной сетки

ЭВМ. Взаимодействуя между собой, указанные возмущения приводят к тому, что наблюдения x_{ij} неизбежно оказываются реализациями случайных величин, функция $d(x_{11}, x_{12}, \dots, x_{ij}, \dots, x_{pn})$ становится случайной функцией, в результате номер k класса также оказывается случайной величиной. Отсюда видно, что разработка алгоритмов классификации изображений неизбежно связана с использованием статистических методов.

Из анализа работ, опубликованных за последние несколько десятков лет [13, 26, 27, 30, 45, 51, 54, 64, 78, 80, 87], можно сказать, что достигнуты значительные теоретические результаты в области как параметрического, так и непараметрического распознавания. Однако, многие из методов распознавания образов, несмотря на хорошее теоретическое обоснование, дают неприемлемые результаты при решении практических задач. Причиной этого являются те ограничения и допущения, которые выдвигаются исследователями при разработке методов классификации. Так, зачастую, априорно принимается гипотеза о принадлежности функции плотности вероятности какому-либо параметрическому семейству [45]. Многие из оптимальных теоретических методов предполагают, кроме того еще и статистическую независимость выбранной системы признаков [54]. Несмотря на то, что вопросы параметрического распознавания разработаны очень хорошо (разработаны процедуры обучения, принятия решения и понижения размерности признакового пространства), оценки вероятностей ошибок, получающихся при параметрическом распознавании, являются асимптотическими, т.е. справедливыми лишь в редко встречающихся случаях неограниченного возрастания обучающих выборок [30, 54, 51].

Непараметрические методы, например k -ближайших соседей, гистограммный, полигональный, Парзеневского ядра и др. также являются асимптотическими, т.е. обеспечивают достаточную точность оценивания только лишь при неограниченном увеличении объема обучающих выборок [30, 64, 92, 61].

Из-за отсутствия оценок вероятностей ошибок или их асимптотического характера в существующей литературе оказалась не исследованной важная проблема построения систем статистического распознавания – 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 [26, 27, 51] и более подробно [80, 82].

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 ставит своей основной целью дополнение 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.

1.2.2 Формирование признаков по изображению

Формирование признаков – первый этап в любой системе распознавания образов. И качество всей системы оказывается жестко зависимо от того, насколько хорошо подобраны признаки для описания объекта – в данном случае изображения.

Задача формирования признаков достаточно сложна, потому что процесс описания 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 образов приходится решать ее заново, ориентируясь на специфику обрабатываемых изображений и изображенных на них объектов. [57, 89]

Основным требованием к используемой системе признаков анализируемого 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 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 исполь-

зуемого 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. [94, 67, 68] 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:

- инвариантность к шумовым и динамическим искажениям;
- инвариантность к яркостным искажениям (изменению яркости и контраста);
- инвариантность к изменению местоположения объекта;
- инвариантность к изменению масштаба объекта;
- инвариантность к изменению ориентации объекта (к повороту объекта в плоскости изображения);
- инвариантность к произвольным аффинным преобразованиям;
- инвариантность к изменению ракурса съемки объекта (для трехмерных объектов).

Инвариантность к указанным искажениям в общем случае достигается за счет предварительного преобразования исходного изображения. В частности, первая группа искажений, связанная с шумовыми и динамическими измене-

ниями 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.[57, 88, 26]

1.3 Постановка задачи оптимизации признаков пространств

При решении задач классификации, из выше сказанного следует, что для сигналов изображений, являющихся случайными процессами, целесообразно использовать основные результаты, полученные в теории статистических решений [54] и статистической теории распознавания образов [87, 78, 64, 80].

Из анализа, проведенного в п. 1.2 следует, что процесс статистического распознавания образов разделяется на три основных этапа

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

Совокупность предъявляемых для распознавания наблюдений обычно записывают в виде матрицы

$$X_n = \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \cdot & \cdot & \cdot & \cdot \\ x_{p1} & x_{p2} & \dots & x_{pn} \end{pmatrix}, \quad (1.3)$$

где n - количество наблюдений, используемых для распознавания. Каждый

столбец $x_i = \begin{pmatrix} x_{1i} \\ x_{2i} \\ \vdots \\ x_{pi} \end{pmatrix} = (x_{1i}, x_{2i}, \dots, x_{pi})^T$, $i = 1, 2, \dots, n$ матрицы X_n представ-

ляет собой r -мерный вектор наблюдаемых значений r признаков

X_1, X_2, \dots, X_p , отражающих наиболее важные для распознавания свойства объекта. Вектор 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.

Набор признаков p , как правило, является одинаковым для всех распознаваемых классов s_1, s_2, \dots, s_k . При этом различие между классами проявляется только 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

$$d_{lr} = \begin{vmatrix} d_1^{lr} \\ \vdots \\ d_q^{lr} \end{vmatrix}, \quad (1.4)$$

состоящий из q скаляров, называемых межклассовыми расстояниями, и выражающих степень отличия у этих классов характеристик данных признаков [82].

Формирование признакового пространства, т.е. определение набора признаков X_1, X_2, \dots, X_p , пространства является неотъемлемой составной частью процесса распознавания [45]. При этом условия, в которых выполняется это формирование являются весьма противоречивыми. С одной стороны, выбранная совокупность признаков должна в наибольшей степени отражать все те свойства объектов, которые важны для их распознавания, т.е. набор признаков X_1, X_2, \dots, X_p должен быть наиболее полным. С другой стороны, с увеличением размерности p признакового пространства очень быстро возрастают вычислительная сложность процедур обучения и принятия решения, материальные и трудовые затраты на измерение необходимых характеристик объектов, т.е. на получение наблюдений на этапе обучения и принятия решений.

Сокращение количества признаков уменьшает затраты на проведение измерений и вычислений, но может привести к снижению достоверности распо-

знавания D , которая является основным показателем качества распознавания [71, 80, 87]. Если время на обучение и принятие решения жестко ограничено, то повышение размерности признакового пространства может оказаться единственным средством увеличения достоверности. Таким образом, одновременное достижение минимума общей размерности признакового пространства и максимума достоверности распознавания оказывается, как правило, невозможным, и, следовательно, 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, обеспечивающего требуемый по условиям решаемой задачи уровень достоверности распознавания и минимизирующего затраты на проведение измерений и вычислений [82].

Другой важной составной частью распознающего процесса является обучение, целью которого является восполнение недостатка априорных знаний о распознаваемых классах путем использования информации о них, содержащейся в обучающих наблюдениях:

$$X_{m_k} = \begin{pmatrix} X_{11} & X_{12} & \dots & X_{1m_k} \\ X_{21} & X_{22} & \dots & X_{2m_k} \\ \cdot & \cdot & \cdot & \cdot \\ X_{p1} & X_{p2} & \dots & X_{pm_k} \end{pmatrix}, \quad (1.5)$$

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

Хотя методы и подходы, используемые при обучении, отличаются большим разнообразием (статистические [13, 80], структурные [86], перцептронные, с использованием потенциальных функций [78], логические [26, 27] и др.), конечный результат их использования, как правило, неизменен - это эталонные описания $\hat{s}_1, \hat{s}_2, \dots, \hat{s}_K$, представляющие собой описания характеристик признаков X_1, X_2, \dots, X_p для всех распознаваемых классов s_1, s_2, \dots, s_K .

Увеличение продолжительности обучения $T_{об}$, которая во многих случаях вычисляется по формуле [82]

$$T_{об} = \tau \sum_{k=1}^K m_k, \quad (1.6)$$

(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 $\hat{s}_1, \hat{s}_2, \dots, \hat{s}_K$. В то же время увеличение $T_{об}$ влечет за собой рост затрат на измерения и вычисления и, что самое главное, увеличение общего времени, требуемого для решения задачи распознавания. Сокращение же времени обучения может повлиять на качество эталонных описаний и в конечном итоге привести к снижению достоверности распознавания. Следовательно, определение минимального времени обучения, обеспечивающего заданный уровень достоверности распознавания, является одной из важных задач, возникающих при синтезе распознающих систем.

Под процедурой принятия решения подразумевается реализация информации о распознаваемых классах, содержащейся в эталонных описаниях $\hat{s}_1, \hat{s}_2, \dots, \hat{s}_K$ и в совокупности предъявляемых для распознавания наблюдений (1.3). Процедура сводится к сопоставлению указанных неклассифицированных наблюдений или функций от них с эталонными описаниями и указанием номера класса k из множества $1, 2, \dots, K$ номеров классов, к которому принадлежит рассматриваемая совокупность наблюдений. Таким образом, решающая процедура осуществляет отображение наблюдений на конечное множество натуральных чисел $1, 2, \dots, K$ с использованием информации о классах, содержащейся в обучающих наблюдениях и отражаемой в эталонных описаниях классов $\hat{s}_1, \hat{s}_2, \dots, \hat{s}_K$ [80].

Увеличение продолжительности процедуры принятия решения $T_{реш} = n\tau$ в принципе повышает достоверность распознавания за счет вовлечения в процесс принятия решения большего количества информации о предъявленном для распознавания объекте, содержащейся в описывающей его совокупности на-

блюдений (1.3), которую [80] именуют контрольной выборкой. Однако для подавляющего большинства распознающих систем естественным является требование минимальной продолжительности $T_{\text{реш}}$ процедуры принятия решения как с точки зрения обеспечения быстроты решения стоящих перед распознающей системой задач, так и с позиций минимизации затрат на измерения и вычисления. Таким образом, определение минимального времени принятия решения, обеспечивающего заданный уровень достоверности распознавания, также является одной из важных задач синтеза распознающих систем [82].

Итак, основными параметрами распознающей системы 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, обусловливаемые либо необходимостью достижения высокого уровня достоверности принимаемых решений, либо жесткими требованиями на время обучения и распознавания, либо ограниченными возможностями по затратам на получение наблюдений, либо и тем, и другим, и третьим. В то же время отмеченный выше сложный характер взаимосвязей между параметрами распознающей системы приводит к тому, что нередко удовлетворить всем налагаемым на них ограничениям можно при различных соотношениях между этими параметрами. В этих условиях появляется возможность выбора таких значений параметров p , m_i , n и D , которые удовлетворяют всем налагаемым на них ограничениям и являются наилучшими (оптимальными) с точки зрения некоторого критерия, т. е. появляется возможность оптимизации распознающей системы.

Как указывается в [82], сложная взаимосвязь между параметрами распознающей системы принципиально не позволяет одновременно минимизировать объемы выборок и число признаков и максимизировать достоверность. Поэтому в принципе возможны разные постановки задачи оптимизации: минимизация вероятностей ошибок распознавания при заданных ограничениях на объе-

мы и размерность признакового пространства, минимизация затрат на проведение измерений и вычислений при заданных ограничениях на достоверность распознавания, минимизация времени обучения при заданных ограничениях на размерность признакового пространства, достоверность и время распознавания, минимизация времени распознавания при заданных ограничениях на размерность признакового пространства, время обучения и достоверность распознавания, минимизация размерности признакового пространства при заданных ограничениях на время обучения и распознавания и достоверность решений и т.п.

Сформулируем общую постановку задачи оптимизации, заимствованную в [82], которая характеризуется вектором ее основных параметров $V(m_1, \dots, m_k, n, p, D) \in G$, где G - область допустимых значений параметров, и заключается в выборе из всех допустимых значений параметров таких, которые минимизировали бы некоторый критерий $H(V)$. Как правило, область допустимых значений параметров задается системой неравенств $h_i(V) \leq \gamma_i$, $i = \overline{1, Q}$ и равенств $G_j(V) = \theta_j$, $j = \overline{1, J}$, 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:

$$\begin{aligned} H(V) &\rightarrow \min; \\ h_i(V) &\leq \gamma_i, \quad i = \overline{1, Q}; \\ G_j(V) &= \theta_j, \quad j = \overline{1, J}. \end{aligned} \quad (1.7)$$

Постановка задачи оптимизации распознающей системы совпадает с классической постановкой задачи оптимизации систем [6] и для ее решения применимы стандартные методы оптимизации. При этом в классической постановке задачи ограничения могут описывать как внешние условия, налагаемые на систему, так и функциональные связи между переменными, существующие внутри нее.

В задаче оптимизации распознающей системы (1.7) 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_{lr} , $l, r = \overline{1, K}$ [см. (1.4)].

Отсюда следует, что 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

В [80, 82] произведен подробный анализ различных методов распознавания с позиций оптимизации. Рассмотрены детерминистские методы распознавания, основанные на использовании потенциальных функций и перцептронных алгоритмов [78], методы синтаксического (структурного, лингвистического) распознавания [71, 78, 86, 5], логические распознающие системы [26, 27] и алгоритмы логического распознавания, основанные на вычислении оценок [44, 74], алгебраические методы [44, 46]. При этом сделан вывод о том, что статистические методы распознавания [13, 30, 64, 80, 87] 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 шумоподобных сигналов), а также количественно описать указанные процессы с использованием хорошо развитых методов математической статистики.

В некоторых случаях это может создавать основу для количественного выражения основных параметров распознающего процесса: размерности признакового пространства p , времени обучения и принятия решения через главный показатель качества системы - достоверность распознавания. Это, в свою очередь, позволяет реализовать в системах статистического распознавания общую постановку задачи оптимизации.

В [82] рассматриваются следующие возможности постановки задачи оптимизации. Для определения размерности p признакового пространства в системах статистического распознавания можно использовать: верхнюю границу Чернова ошибки классификации [87]; общее выражение вероятности ошибки классификации через размерность признакового пространства p , объем контрольной выборки n и межклассовые расстояния (например расстояние Махаланобиса [80]); обобщенную асимптотику Колмогорова, позволяющую выразить вероятности ошибок распознавания через асимптотически возрастающие объемы обучающих и контрольных выборок и размерность признакового пространства [82]. Для определения времени обучения и принятия решения в системах статистического распознавания могут быть использованы полученные в [82] выражения вероятностей ошибок распознавания через объемы обучающих и контрольных выборок и межклассовое расстояние d^2 (расстояние Махаланобиса), а также могут быть привлечены известные из теории статистических решений [54, 77, 18, 81] оценки вероятностей ошибок классификации через объемы контрольных выборок.

Однако далеко не всегда удастся воспользоваться перечисленными возможностями, так как их применение во всех случаях ограничено теми или иными условиями, связанными с функционированием разрабатываемых систем в реальных обстоятельствах. Эти ограничения будут рассмотрены позднее. Тем не менее представляется целесообразным рассмотреть основные результаты,

полученные при решении задачи оптимизации с применением статистического метода.

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 [6, 79, 80].

Формирование признакового пространства. Первоначальный набор признаков Y_1, Y_2, \dots, Y_q формируется из числа доступных измерению характеристик распознаваемых объектов таким образом, чтобы полно и всесторонне отразить все наиболее существенные для распознавания свойства. Однако увеличение размерности признакового пространства повышает вычислительную сложность распознающей процедуры и общие затраты на измерение характеристик объектов, т. е. на получение необходимого числа наблюдений. Поскольку время обучения и в особенности принятия решения, как правило, ограничено, повышение размерности признакового пространства может оказаться единственным способом увеличения достоверности до требуемого уровня. Следовательно, требования к размерности признакового пространства с точки зрения повышения достоверности распознавания и минимизации затрат на получение наблюдений (измерений) являются, как уже подчеркивалось, противоречивыми. Отсюда вытекает большая важность проблемы формирования признакового пространства оптимальных размеров.

Традиционные 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 . В других случаях критерий $J(Y_1, Y_2, \dots, Y_q)$ выражает "диаметр" или "объем" области Ω_m (см. рис. 1.3), занимаемой классом в признаковом пространстве, и новые признаки X_1, X_2, \dots, X_p формируются путем минимизации критерия [64, 78, 87]. Оба варианта критериев по своей сути равнозначны. Конкретно в качестве критерия $J(Y_1, Y_2, \dots, Y_q)$ выбирают среднеквадратиче-

скую ошибку аппроксимации признаков Y_1, Y_2, \dots, Y_q с помощью новых признаков X_1, X_2, \dots, X_p , среднее межклассовое расстояние, внутриклассовый разброс наблюдений, энтропию одного класса относительно другого и т.д.

Традиционные критерии, основанные на геометрических понятиях расстояния между классами, исходят из того, что значение указанного расстояния пропорционально достоверности расстояния. Считают, что чем больше расстояние между классами в признаковом пространстве, тем больше различие между классами, тем легче его обнаружить и, следовательно, тем выше будет достоверность различения классов. Максимизация расстояния между классами повышает "разделяющую силу признаков" [71], которая, как ожидается, обеспечивает требуемую достоверность различения, особенно если само правило различения основано на том же самом критерии, что и выбор признаков.

Рассмотрим процедуру обучения диагностической системы. Источником информации о распознаваемых образах является совокупность результатов независимых наблюдений (выборочных значений), составляющих обучающую (обучающие) $(x_i)_{1}^{m_k} = (x_1, x_2, \dots, x_{m_k})$ и контрольную (экзаменационную) $(x_i)_{1}^n = (x_1, x_2, \dots, x_n)$ выборки, причем в зависимости от характера задачи распознавания (одномерной или многомерной) x_i может быть либо одномерной, либо p -мерной случайной величиной. 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 [80].

Решающее значение для выбора метода распознавания имеет вид априорной неопределенности. Если в результате предварительного анализа наблюдаемой совокупности выборочных значений (или на основе имеющейся априорной информации) оказывается возможным хотя бы с некоторым приближением установить вид закона их распределения, то априорная неопределенность относится лишь к параметрам этого распределения, так что целью обучения в этом случае становится получение оценок этих параметров. Подобная априорная не-

определенность носит название параметрической [54], а методы распознавания, применяемые в этих условиях, именуются параметрическими.

При этом многими авторами, в том числе и в [80, 82], отмечается, что хотя с формальной точки зрения закон распределения выборочных значений может быть любым, на практике в параметрическом распознавании почти всегда используется нормальный закон. 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 [82] делается вывод о том, что на сегодня 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 наиболее общем случае отсутствия априорных сведений не только о параметрах, но и о самом виде закона распределения наблюдаемой совокупности выборочных значений априорная неопределенность носит название непараметрической [54], а методы распознавания соответственно непараметрические.

В [80] 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 [82], практическое его применение крайне затруднено из-за требований наложения целого ряда жестких ограничений на функции рас-

пределения 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 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 процедуру принятия решений. Выбор решающего правила, позволяющего относить контрольную выборку наблюдений к одному из взаимоисключающих классов, производится в соответствии с теорией статистических решений с учетом априорной информации и характеристик, полученных в процессе обучения. В рамках этой теории 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 [54]

$$L = \frac{\omega_n(x_1, x_2, \dots, x_n | s_2)}{\omega_n(x_1, x_2, \dots, x_n | s_1)} \geq c, \quad (1.8)$$

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 распознавании они, в принципе, не известны, вследствие чего в решающее правило (1.3) 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:

$$\hat{L} = \frac{\hat{\omega}_n(x_1, x_2, \dots, x_n | s_2)}{\hat{\omega}_n(x_1, x_2, \dots, x_n | s_1)} \geq c. \quad (1.9)$$

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. Дополнительные 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. [54].

При числе классов $K > 2$ задача распознавания называется многоальтернативной. Наиболее простым и естественным обобщением двухальтернативного решающего правила (1.9) на случай $K > 2$ является следующее [80]: контрольная выборка $\{x_i\}_1^n$ принадлежит классу s_i , если

$$\hat{L}_{\ell u} = \frac{\hat{\omega}_{\ell}(x_1, x_2, \dots, x_n)}{\hat{\omega}_u(x_1, x_2, \dots, x_n)} > c_{\ell u} \quad (1.10)$$

для всех $\ell, u = \overline{1, K}, u \neq \ell$, 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 (1.10). Причем только для байесовского критерия при этом получаются достаточно простые соотношения [54]. В других случаях соответствующие обобщения оказываются довольно сложными и громоздкими. Легко приводятся к виду (1.10) многоальтернативные критерии максимума апостериорной вероятности и максимального правдоподобия. Кроме того, правило (1.10) обладает одним существенным недостатком. Оно не всегда позволяет выбрать наиболее правдоподобный класс, иначе говоря, 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 [82] 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 (1.10), обеспечивающим существование решения для любой выборки X_n не приводящей к вырождению функции $\hat{\omega}_k(X_n)$, $k = \overline{1, K}$, является условие [82]

$$c_{k_1 k_2} c_{k_2 k_3} c_{k_3 k_1} = 1 \quad (1.11)$$

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 [80]. 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 (1.3), и получение для них аналитических формул, позволяющих вычислять α_k и $\beta_k, k = \overline{1, K}$ при любых конкретных значениях $m_k, n, p, K, d_{\ell r}, \ell, r = \overline{1, K}, \ell \neq r$, дает возможность конкретизировать общую постановку задачи оптимизации в случае параметрической априорной неопределенности. Как уже было отмечено ранее, возможны различные подходы к выбору критерия оптимальности $H(V)$ и ограничений $h_i(V) < \gamma_i, i = \overline{1, Q}, C_j(V) = \theta_j, j = \overline{1, J}$ в (1.7). Однако, как правило, при синтезе распознающих систем основным является требование обес-

печения гарантированного уровня достоверности принимаемых решений, 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 [82]

$$H = \sum_{j=1}^p C_j \left(\sum_{k=1}^K m_k + b n \right). \quad (1.12)$$

При $b=1$ и $C_j = C$ для всех $j = \overline{1, p}$, опуская постоянный множитель в критерии (1.12), задачу оптимизации распознающей системы (1.3) можно записать в виде:

$$\begin{aligned} p \left(\sum_{k=1}^K m_k + n \right) &\rightarrow \min; \\ \alpha_k &\leq \alpha^*, \beta_k \leq \beta^*, \quad k = \overline{1, K}. \end{aligned} \quad (1.13)$$

Фактически (1.13) означает минимизацию числа измерений признаков, необходимых для того, чтобы обеспечить непревышение вероятностями ошибок распознавания α_k и β_k заданных значений α^* и β^* соответственно ни для одного из распознаваемых классов.

1.5 Обзор методов оптимизации параметров распознающих систем в случае параметрической априорной неопределенности

Рассмотрим основные результаты по оптимизации временных и пространственных параметров систем распознавания, полученные в рамках разви-

тия статистической теории распознавания образов [80, 82]. В указанной литературе рассматривается подход к оптимизации на основе постановки задачи, сформулированной в предыдущем пункте. Основой решения этой задачи является увязка значений вероятностей ошибок распознавания α_k и β_k с временными и пространственными параметрами распознающей системы.

Известно [54], 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 $X = (X_1, X_2, \dots, X_p)$

$$X = AY. \quad (1.14)$$

При этом преобразование (1.14) 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 [87]

$$M^* = A^T M A = \Lambda = \begin{pmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & \\ \cdot & \cdot & \cdot & \cdot \\ 0 & 0 & \dots & \lambda_p \end{pmatrix}. \quad (1.15)$$

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

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 [77, 81]. Применительно к проблеме нормализации распределений признаков в задачах распознавания этот метод формулируют следующим образом [82].

Пусть случайная характеристика ξ , присущая распознаваемым классам s_1, s_2, \dots, s_K , имеет распределение, отличное от нормального. В качестве нормально распределенного признака, используемого при распознавании, используют случайную величину

$$x = \sum_{i=1}^q \xi_i, \quad (1.16)$$

где $\xi_i, i = \overline{1, q}$ - измерения случайной характеристики ξ . Метод накопления (1.16) обобщается также и на многомерный случай. Основным вопросом практического применения метода накопления для нормализации распределений признаков является вопрос выбора параметра q с точки зрения скорости сходимости функции распределения случайной величины x к нормальной. Достаточно подробно он рассмотрен в [82].

1.5.1 Оптимизация временных характеристик системы распознавания одномерных нормальных совокупностей

Рассмотрим оптимизацию характеристик системы распознавания одномерных нормальных совокупностей s_1 и s_2 с неизвестными средними значениями a_1 и a_2 и общей известной дисперсией σ^2 , основываясь на теоретических результатах, полученных в [80] для ошибок распознавания первого и второго рода α и β .

Поскольку в рассматриваемом случае размерность признакового пространства $p = 1$, в процессе оптимизации минимизируется суммарный объем ρ обучающих и контрольных выборок (то есть общее количество ρ требуемых для распознавания наблюдений), необходимый для достижения заданного уровня достоверности (непревышения вероятностями ошибок α и β их верхних границ α^* и β^*) при заданном ограничении, заключающемся в том, что нормированная разность между средними значениями совокупностей $(a_2 - a_1)/\sigma$ должна быть не меньше некоторого минимального значения $a_\epsilon > 0$, в качестве которого, как было сказано ранее, целесообразно взять точность измерения этой разности в реальных системах. Выражение для суммарного объема обучающих и контрольной выборок ρ , получающееся из (1.13) при $K = 2$, $m_1 = m_2 = m$, $b = 1$ и, поскольку рассматривается одномерный случай, $p = 1$, имеет вид $\rho = 2m + n$

Для наиболее часто применяемого на практике критерия максимального правдоподобия и одинаковых размерах обучающих выборок вероятности ошибок распознавания равны между друг другом и выражаются через табулированную функцию ошибок $\Phi(x)$ в соответствии с формулой [82]

$$\begin{aligned} \alpha = \beta &= F(-a/\sigma_2) \cdot F(a/\sigma_1) + F(a/\sigma_2) \cdot F(-a/\sigma_1) = \\ &= \frac{1}{2} - \frac{1}{2} \Phi\left[|a|/(\sigma_1\sqrt{2})\right] \Phi\left[|a|/(\sigma_2\sqrt{2})\right], \end{aligned} \quad (1.17)$$

где $a = (a_2 - a_1) / \sigma$, $\sigma_1 = \sqrt{4/n + 1/m_1 + 1/m_2}$, $\sigma_2 = \sqrt{1/m_1 + 1/m_2}$,

и известны соотношения

$$F(x) = \left[\Phi(x/\sqrt{2}) / 2 \right] + 1/2, \quad F(-x) = \left[1/2 - \Phi(x/\sqrt{2}) / 2 \right],$$

$$\Phi(x) = \frac{2}{\sqrt{\pi}} \int_0^x \exp(-z^2) dz,$$

которая может быть использована для оптимизации характеристик распознающей системы, заключающейся в отыскании объемов m^* и n^* обучающих и контрольной выборок, минимизирующих критерий и удовлетворяющих ограничениям $h_i(n, m, \alpha, \beta)$ на допустимые объемы выборок и вероятности ошибок [82]:

$$\rho = 2m + n \rightarrow \min;$$

$$\alpha = \beta = \frac{1}{2} - \frac{1}{2} \Phi(a_\varepsilon \sqrt{m} / 2) \Phi \left[a_\varepsilon / \left(2\sqrt{1/m + 2/n} \right) \right] \leq \alpha^* = \beta^* \quad (1.18)$$

Объемы m^* и n^* , являющиеся решением задачи (1.18), называют оптимальными.

При каждом выбранном a_ε оптимальные значения объемов m^* и n^* могут быть найдены стандартными методами целочисленного программирования [2, 43].

В [82] предлагается более простая методика решения данной задачи оптимизации. Используя инвариантность решения (m^*, n^*) задачи (1.18) относительно умножения критерия на положительное число, задача оптимизации переписывается в следующем виде:

$$a_\varepsilon^2 (2m + n) \rightarrow \min$$

$$\Phi(a_\varepsilon \sqrt{m} / 2) \cdot \Phi \left[a_\varepsilon / 2 \cdot \sqrt{(1/m) + 2/n} \right] \geq 1 - 2\alpha^*. \quad (1.19)$$

Разрешая уравнение

$$\Phi(\sqrt{x}/2) \cdot \Phi\left[1/2 \cdot \sqrt{(1/x) + 2/y}\right] = 1 - 2\alpha^* \quad (1.20)$$

относительно y

$$y = \frac{8x^2 f^2\left[(1 - 2\alpha^*) / \Phi(\sqrt{x}/2)\right]}{x - 4f^2\left[(1 - 2\alpha^*) / \Phi(\sqrt{x}/2)\right]}, \quad (1.21)$$

где $f[t] = \Phi^{-1}(t)$, и выясняя следующие свойства функции (1.21):

- 1) область определения G : $4f^2(\sqrt{1 - 2\alpha^*}) < x < \infty$,
- 2) $\lim_{x \rightarrow 4f^2(\sqrt{1 - 2\alpha^*})+0} y = \infty$,
- 3) $(\partial y / \partial x) < 0$, $x \in G$,
- 4) $(\partial^2 y / \partial x^2) > 0$, $x \in G$,

и учитывая монотонность и непрерывность функций $\Phi(x)$ и $\Phi^{-1}(x)$, показано, что если x_0 и y_0 являются решениями нижеследующей задачи оптимизации в классе непрерывных функций:

$$2x + y \rightarrow \min_{x,y},$$

$$y = \frac{8x^2 f^2\left[(1 - 2\alpha^*) / \Phi(\sqrt{x}/2)\right]}{x - 4f^2\left[(1 - 2\alpha^*) / \Phi(\sqrt{x}/2)\right]}, \quad (1.22)$$

то с достаточной для практических приложений точностью в качестве решения (m^*, n^*) задачи (1.19) можно принять

$$m^* = \left[x_0 / \mu_\varepsilon^2 \right] + 1, \quad n^* = \left[y_0 / \mu_\varepsilon^2 \right] + 1, \quad (1.23)$$

где $[t]$ – целая часть t .

Задача (1.22) сводится к задаче минимизации функции одной переменной

$$\min_{x,y} (2x + y) = \min_x \left\{ 2x^2 / \left[x - 4f^2 \left((1 - 2\alpha^*) / \Phi(\sqrt{x}/2) \right) \right] \right\}, \quad (1.24)$$

решаемой стандартными методами оптимизации [6].

Анализ результатов расчетов, приведенных в [80, 22] показывает, что при сравнительно невысоких требованиях к точности измерения разности средних a_ε ($a_\varepsilon = 0,1$) совокупностей (и, следовательно, при минимально допустимом расстоянии между указанными средними, равном $0,1\sigma$) и при необходимости обеспечения удовлетворительного уровня достоверности распознавания 0,9 оптимальные значения объемов указанных выборок составляют $m^* = 886$ и $n^* = 1302$. Повышение уровня требуемой достоверности распознавания до значений 0,99; 0,999; 0,9999 при том же значении a_ε достигается путем достаточно умеренного увеличения оптимальных объемов обучающих $m^* = 2334; 4050$ и 5868 и контрольных $n^* = 4140; 7860$ и 11734 выборок. Однако, дальнейшее повышение требований к точности измерения разности средних вплоть до 0,01 (и, следовательно, сокращение минимально допустимого расстояния между средними значениями совокупностей до $0,01\sigma$) при необходимости обеспечения высокой достоверности распознавания $1 - \alpha^* = 1 - \beta^* = 0,99; 0,999; 0,9999$ приводит к значительному увеличению объемов обучающих и контрольной выборок вплоть до $m^* = 586800$ и $n^* = 1173400$ при $1 - \alpha^* = 0,9999$ и $a_\varepsilon = 0,01$. Это вполне согласуется с физическими представлениями, поскольку распознавание со столь высокой достоверностью нормальных совокупностей, средние значения которых могут быть так близко расположены друг от друга, требует достаточно большого времени обучения для составления хороших эталонных описаний совокупностей, то есть получения возможно более качественных оценок средних \hat{a}_1 и \hat{a}_2 , и достаточно большого времени для принятия решения для обеспечения его высокой достоверности.

Данная процедура оптимизации может быть обобщена на случай распознавания одномерных нормальных совокупностей, у которых неизвестны не только средние a_1, a_2 , но и общая дисперсия σ^2 [80]. При этом также минимизируется суммарный объем обучающих и контрольной выборок, необходимых для достижения заданного уровня достоверности, при том же ограничении: нормированная разность между средними значениями совокупностей $(a_2 - a_1 / \sigma)$ должна быть не меньше $a_\epsilon > 0$. Однако, при неизвестной дисперсии σ^2 записать выражение вероятностей ошибок через параметр a_ϵ и объемы обучающих m и контрольной n выборок по типу (1.17) оказывается затруднительным, вследствие чего для нахождения требуемых значений m^* и n^* наряду со строгими целесообразно использовать приближенные методы, основанные на том, что при переходе от неизвестной дисперсии к известной вероятности ошибок распознавания изменяются незначительно [80]. Если вместо априорно известной дисперсии σ^2 в процессе решения задачи оптимизации (1.18) - (1.24) использовать ее оценку, формируемую в процессе обучения, то в результате получаются значения объемов выборок m_1^* и n_1^* , которые являются приближениями к истинным значениям m^* и n^* .

Для случая оптимизации систем распознавания одномерных образов, различающихся средними и дисперсиями, в [82] на основе полученных выражений для ошибок распознавания [82] 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

$$d^2 = \frac{(a_2 - a_1)^2}{\sigma_1} \text{ и } r = \frac{\sigma_2^2}{\sigma_1^2}. \quad (1.25)$$

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 [82] таблиц для выбора оптимальных объемов выборок m^* и n^* , требуемых для достижения заданной достоверности $1 - \alpha^*$ ориентируясь на наихудший случай $d^2 = d_0, r = r_0$.

1.5.2 Оптимизация временных характеристик системы распознавания многомерных нормальных совокупностей

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 r .

Рассмотрим оптимизацию временных характеристик систем распознавания многомерных совокупностей с неизвестными векторами средних a_1 и a_2 и общей ковариационной матрицей M при фиксированном числе признаков r .

Важным моментом при проведении оптимизации является определение расстояния между классами d и задание его минимального значения $d_e > 0$, используемого при решении задачи оптимизации [80]. 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 a_1 и a_2 и общей ковариационной матрицей M выражается также скалярной величиной - расстоянием Махаланобиса [78]

$$d^2 = (a_2 - a_1)^T M^{-1} (a_2 - a_1). \quad (1.26)$$

Задача оптимизации временных характеристик системы может быть сформулирована как задача минимизации суммарного объема $\rho = r \cdot (2m + n)$

обучающих и контрольной выборки, 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 $d_\varepsilon > 0$, 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 [80] 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 V , минимизирующего некоторый критерий $H(V)$ и удовлетворяющего ограничениям $h_i(V, \alpha, \beta) \geq b_i$, $i = \overline{1, Q}$ на допустимые значения параметров и вероятности ошибок.

Как и в рассмотренном одномерном случае, в качестве критерия оптимальности рассматриваемой системы распознавания целесообразно использовать минимальный суммарный объем $\rho = p \cdot (2m + n)$ обучающих и контрольных наблюдений ($p = \text{const}$), получающийся из (1.12) при $K = 2$, $m_1 = m_2 = m$, $b = 1$ [80]:

$$\begin{aligned} \rho &= p(2m + n) \rightarrow \min; \\ \alpha = \beta &= \left[\theta(p) / (p - 3)!! \right] \int_{-\pi/2}^{\pi/2} D_p \cdot \left(\sin \varphi / \sqrt{2/m} \right) \times \\ &\times F \left(-\sin \varphi / \sqrt{2/m + 4/n} \right) \cdot \cos^{p-2} \varphi \, d\varphi \leq \alpha^*. \end{aligned} \quad (1.27)$$

При заданном d_ε , учитывая инвариантность решения задачи (1.27) относительно умножения критерия на положительное число, задача переписывается в следующем виде [82]

$$\rho = d_\varepsilon^2 (2m + n) \rightarrow \min;$$

$$\alpha = \beta = \left[\theta(p) / (p-3)!! \right] \int_{-\pi/2}^{\pi/2} D_p \cdot \left(\sin \varphi / \sqrt{2/m} \right) \times \\ \times F \left(-\sin \varphi / \sqrt{2/m + 4/n} \right) \cdot \cos^{p-2} \varphi \, d\varphi \leq \alpha^* . \quad (1.28)$$

В [80] показано, что в силу свойств функции (1.27) с достаточной для практических приложений точностью в качестве решения (m^*, n^*) задачи (1.28) целесообразно принять

$$m^* = \left[x_0 / (2d_\varepsilon^2) \right] + 1, \quad n^* = \left[x_0 / d_\varepsilon^2 \right] + 1, \quad (1.29)$$

где $[t]$ – целая часть t , а x_0 и y_0 – решение следующей задачи оптимизации в классе непрерывных функций, выполненное стандартными численными методами:

$$x + y \rightarrow \min; \\ \varphi(x, y) = \left[\theta(p) / (p-3)!! \right] \int_{-\pi/2}^{\pi/2} D_p \cdot \left(\sqrt{x} \cdot \sin \varphi / 2 \right) \times \\ \times F \left(-\sin \varphi / 2\sqrt{1/x + 1/y} \right) \cdot \cos^{p-2} \varphi \, d\varphi \leq \alpha^* . \quad (1.30)$$

Для решения задачи (1.30) используется итерационная процедура, описанная в [80]. Анализ результатов расчетов значений оптимальных объемов обучающих и контрольной выборок, приведенных в [85, 22] показывает, что при сравнительно невысоких требованиях к точности измерения расстояния между классами $d_\varepsilon^2 = 0,01$ 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_g^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 [80]. Для доведения последней до требуемого по условиям задачи уровня $1 - \alpha^* = 1 - \beta^*$ необходимо несколько увеличить значения оптимальных объемов выборок m^* и n^* [80].

Данная процедура оптимизации может быть обобщена и на случай распознавания многомерных нормальных совокупностей с неизвестными векторами средних $\mathbf{a}_1, \mathbf{a}_2$ и с неизвестной общей ковариационной матрицей \mathbf{M} [82]. При этом также минимизируется суммарный объем $\rho = p \cdot (2m + n)$ обучающих и контрольных наблюдений, необходимых для достижения заданного уровня достоверности при том же ограничении: расстояние Махаланобиса d^2 между совокупностями s_1 и s_2 , определяемое формулой (1.26), должно быть не меньше некоторого минимального значения $d_g^2 > 0$, в качестве которого целесообразно выбирать точность измерения этого расстояния (являющегося скаляром) в реальных системах. Однако в случае неизвестной ковариационной матрицы \mathbf{M} выражение вероятностей ошибок α и β через параметр d_g и объемы обучающих m и контрольной n выборок по типу (1.27) оказывается затруднительным [82], вследствие чего целесообразно использовать приближенные методы, основанные на использовании вместо неизвестных значений вероятностей ошибок α и β их асимптотических значений α_0 и β_0 [82]

$$\alpha_0 = F\left[\frac{-2 \ln c / (n\tau) - a}{\sigma}\right], \quad \beta_0 = F\left[\frac{(2 \ln c / (n\tau) - a)}{\sigma}\right], \quad (1.31)$$

где $a = d^2 / (\tau - p - 1)$; $\tau = 2m - 2$;

$$\sigma^2 = \frac{4(\tau-1)}{(\tau-p) \cdot (\tau-p-1) \cdot (\tau-p-3)} \left[\frac{d^2}{n} + \frac{1}{m} \cdot \left(d^2 + \frac{2p}{n} \right) + \frac{p}{m^2} \right] + \frac{2d^4}{(\tau-p-1)^2 \cdot (\tau-p-3)}.$$

Рассмотрим оптимизацию временных характеристик систем распознавания многомерных образов, различающихся векторами средних и ковариационными матрицами при фиксированном числе признаков.

Основой для оптимизации многомерных ансамблей, различающихся неизвестными векторами средних \mathbf{a}_1 , \mathbf{m}_1 и ковариационными матрицами \mathbf{M}_1 , \mathbf{M}_2 является полученное в [82] выражение вероятности ошибки распознавания первого рода α и получающееся из него заменой k_0 на $-k_0$, m_1 на m_2 , \mathbf{a}_1 на \mathbf{a}_2 , \mathbf{M}_1 на \mathbf{M}_2 соответствующее выражение для вероятности ошибки распознавания второго рода β [82].

В данном случае значения α и β зависят от величин $n, m_1, m_2, \mathbf{b}_\varepsilon, \mathbf{D}, p$, где

$$\mathbf{D} = \begin{bmatrix} d_1 & & & 0 \\ & \cdot & & \\ & & \cdot & \\ 0 & & & d_p \end{bmatrix}.$$

Задача оптимизации принимает вид [82]:

$$\begin{aligned} \rho = m_1 + m_2 + n &\rightarrow \min; \\ \alpha(n, m_1, m_2, \mathbf{b}_\varepsilon, \mathbf{D}, p) &\leq \alpha^*; \quad \beta(n, m_1, m_2, \mathbf{b}_\varepsilon, \mathbf{D}, p) \leq \beta^* \end{aligned} \quad (1.32)$$

при априорно налагаемом ограничении на абсолютные значения разностей $\Delta a_j = |a_{2j} - a_{1j}| \geq a_j^\varepsilon$ между компонентами неизвестных \mathbf{a}_1 и \mathbf{a}_2 , заключающемся в том, что они не должны быть меньше некоторых минимальных значений a_j^ε , в качестве которых из практических соображений естественно взять точности измерения этих разностей Δa_j в реальных системах, в силу чего в (1.32) [82]

$$\mathbf{b}_\varepsilon = \mathbf{A}\mathbf{a}^\varepsilon, \quad \mathbf{a}^\varepsilon = \left| a_1^\varepsilon \dots a_p^\varepsilon \right|^T, \quad (1.33)$$

где \mathbf{A} - матрица декоррелирующего преобразования [1.15].

При близких значениях элементов матриц \mathbf{M}_1 и \mathbf{M}_2 и \mathbf{a}_1 и \mathbf{a}_2 , когда достижение высокой достоверности распознавания $1 - \alpha^* = 1 - \beta^*$ возможно только за счет больших объемов выборок, а также при большом количестве используемых признаков p , вместо точных значений α и β для облегчения расчетов целесообразно использовать в (1.32) α_0 и получаемое из него соответствующей заменой параметров выражение для β_0 .

В [82] рассматривается часто встречающийся на практике случай пропорциональных матриц \mathbf{M}_1 и \mathbf{M}_2 ($\mathbf{M}_1 = h\mathbf{M}_2, h > 0, h \neq 1$), и полагается для простоты $m_1 = m_2 = m, \alpha^* = \beta^*, k_0 = 0$. Записываются минимизируемый функционал и граничные условия исходя из выражения для ошибки классификации первого и второго рода [82]. Задача оптимизации решается стандартными численными методами.

В [82] приведены оптимальные объемы контрольной n^* и обучающих m^* выборок, обеспечивающие достоверность распознавания $1 - \alpha^* = 0,8; 0,9; 0,95; 0,99$ при количестве признаков $p = 2$ и 10 , точностях измерения расстояния $d_\varepsilon^2 = 0,01 \dots 1,0$ и значениях коэффициента $h = 1,01 \dots 2,0$. Анализ результатов решения задачи оптимизации показывает, что с ростом h , при h близких к 1 , преобладает тенденция, обуславливающая рост α и β , что ведет к увеличению m^* и n^* , требуемых для достижения заданной достоверности $1 - \alpha^*$. Однако при дальнейшем увеличении h до $2,0$ оптимальные значения m^* и n^* уменьшаются. Это объясняется тем, что с ростом h усиливается влияние тенденции, ведущей к уменьшению α и β , и начиная с некоторого значения h^* ее влияние становится доминирующим. При этом h^* тем меньше, чем меньше d_ε^2 и чем больше p .

Действительно, увеличение с ростом h дисперсий величин, составляющих обучающие и контрольные выборки из класса s_2 , должно приводить при

постоянных m, n, d_{ε}^2 и p к увеличению α и β , причем β – в большей степени. С другой стороны, чем больше h , тем сильнее отличие распределений $N^p\{a_1, M_1\}$ и $N^p\{a_2, M_2\}$ друг от друга и тем меньше, следовательно, должны быть α и β при неизменных m, n, d_{ε}^2 и p .

Как известно из рассмотрения случая равных ковариационных матриц M_1 и M_2 , увеличение с ростом p числа оцениваемых параметров $a_{kj}, k = 1, 2, j = \overline{1, p}$ приводит к росту α и β при неизменных m, n, d_{ε}^2 и h . Этим объясняется рост m^* и p^* при увеличении числа признаков от 2 до 10 для h , близких к 1 [82]. Однако с ростом h достаточно быстро проявляется преобладание другой тенденции, ведущей к уменьшению α и β и состоящей в том, что с ростом p при неизменных m, n, d_{ε}^2 и h растет количество параметров, а именно дисперсий признаков, по которым имеет место отличие распределений $N^p\{a_1, M_1\}$ и $N^p\{a_2, M_2\}$ друг от друга.

1.5.3 Оптимизация размерности признакового пространства

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 [78]. 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 [82], а в общей формулировке задачи оптимизации распознающей системы (1.13) минимизации подлежит общее количество измерений [82]

$$\rho = p \left(\sum_{k=1}^K m_k + nb \right); \quad p \leq q, \quad (1.34)$$

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.

Рассмотрим решение задачи оптимизации размерности признакового пространства при произвольных объемах обучающих и контрольной выборок, которое представлено в [82].

Задача оптимизации размерности признакового пространства при $K = 2$, $m_1 = m_2 = m$, $b = 1$ должна включать в себя как составную часть рассмотренную в п. 1.5.2 задачу 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 M распознаваемых совокупностей s_1 и s_2 диагональной с дисперсиями на диагонали [82, 45]. В этом случае расстояние Махаланобиса [82]

$$d^2 = \sum_{i=1}^p \left[(a_{i2} - a_{i1}) / \sigma_i \right]^2 = \sum_{i=1}^p \delta_i, \quad (1.35)$$

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. Для получения приближенного решения, обеспечивающего достоверность распознавания не хуже заданного значения α^* , можно заменить в (1.36) все δ_i на δ и использовать вместо расстояния Махаланобиса его оценку снизу $d_n^2 = \delta p$ [82], которую и следует подставить вместо d^2 в выражение для вероятности ошибки распознавания, получающееся из (1.27) [82]

$$\begin{aligned} \alpha = \beta = & \left\{ \theta(p) \exp\{-\delta mp / 4\} / [\sqrt{2\pi}(p-3)!!] \right\} \times \\ & \times \int_0^\infty \int_{-\pi/2}^{\pi/2} t^{p-1} \cdot \cos^{p-2} \varphi \cdot \exp\left\{-(1/2)(t^2 - \sqrt{2\delta mp} t \sin \varphi)\right\} \times \\ & \times F\left(-\sqrt{\delta p} \sin \varphi / \sqrt{2/m + 4/n}\right) dt d\varphi = \alpha(m, n, p). \end{aligned} \quad (1.36)$$

Очевидно, задача оптимизации признакового пространства (включающая в себя и оптимизацию суммарного объема обучающих и контрольных наблюдений) записывается следующим образом [82]:

$$(2m + n)p \rightarrow \min, \quad \alpha(m, n, p) \leq \alpha^*. \quad (1.37)$$

При заданном δ , учитывая инвариантность решения задачи (1.37) относительно умножения критерия на положительное число, задача переписывается в следующем виде:

$$\delta(2m+n)p \rightarrow \min, \quad \alpha(m, n, p) \leq \alpha^*. \quad (1.38)$$

Если сделать замену переменных $x = 2\delta mp$; $y = \delta np$, тогда также, как и в одномерном случае, в силу свойств функции (1.36) с достаточной для практических приложений точностью в качестве решения (m^*, n^*, p^*) задачи (1.38) можно принять следующий набор из трех целых чисел:

$$m^* = [x_0 / (2\delta p_0)] + 1, \quad n^* = [y_0 / (\delta p_0)] + 1, \quad p^* = p_0, \quad (1.39)$$

где x_0, y_0, p_0 (p_0 - целое число) являются решениями следующей экстремальной задачи [82]:

$$\begin{aligned} & x + y \rightarrow \min; \\ \alpha = \beta = & \left\{ \theta(p) \exp(-x/8) / [\sqrt{2\pi}(p-3)!!] \right\} \times \\ & \times \int_0^\infty \int_{-\pi/2}^{\pi/2} t^{p-1} \cdot \cos^{p-2} \varphi \cdot \exp\left\{-(1/2)(t^2 - \sqrt{x} \cdot t \sin \varphi)\right\} \times \\ & \times F\left[-\sin \varphi / \left(2\sqrt{1/m + 1/n}\right)\right] dt d\varphi = \alpha^*. \end{aligned} \quad (1.40)$$

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 $\alpha = \beta$ уменьшает-

ся. 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

$$\alpha(M, N, p_0) \leq \alpha^*. \quad (1.41)$$

Зафиксировав найденное значение $p = p_0$, необходимо решить задачу оптимизации (1.40). Для ее решения в [82] используется итерационная процедура.

Зависимость $\alpha(M, N, p)$ от размерности признакового пространства при $\delta = 0,1$ приведена в [82]. 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 [82]. 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 1 главы

1. Анализ методов распознавания изображений показал, что сигналы изображений, могут быть представлены векторными случайными процессами. С учетом перспективности применения для классификации сигналов изображений методов статистической теории распознавания образов, является актуальной задача разработки моделей сигналов изображений, эффективных при использовании этих моделей для распознавания изображений.

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. С точки зрения практической реализации распознающих систем является целесообразной следующая постановка задачи оптимизации. Необходимо минимизировать суммарное количество наблюдений (т.е. объем обучающих и контрольных выборок и размер признакового пространства), которое является достаточным для обеспечения требуемого уровня достоверности распознавания при заданных ограничениях, например, время принятия решений.

4. 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 закону распределения признаков, так и виду их статистической взаимосвязи.

2 ИССЛЕДОВАНИЕ ХАРАКТЕРИСТИК СИГНАЛОВ ИЗОБРАЖЕНИЙ В РАСПОЗНАЮЩИХ СИСТЕМАХ

2.1 Объект исследования

Как уже было сказано, в п.1.1 существует широкий круг задач, в которых изображения рассматриваются как источник информации, на основе которой необходимо вынести некоторое решение. Основой для решения такого круга задач является теория распознавания образов. Кроме того, было отмечено, что не существует каких-либо формальных методов построения моделей сложных сигналов. При этом при создании распознающих систем на разработчика возлагается задача выбора и конструирования моделей, эффективность которых зачастую зависит от его опыта и интуиции.

Принимая во внимание сложность объекта исследования и практическую невозможность создания общей адекватной модели изображения, необходимо сузить круг рассматриваемых вопросов до одной практической задачи, решаемой при каком-либо из видов целевой функции.

Большинство авторов работ по теории распознавания образов [12, 74, 80, 17, 78] сходятся во мнении, что создание абстрактной распознающей системы распознающей системы без приложения к какой-либо реальной задаче, зачастую не имеет ни какой практической значимости. Более плодотворным в указанном направлении является иной подход: решение конкретной практической задачи и последующее обобщение результатов на группу задач, в какой-то мере близких к решаемой. Согласно данному подходу в диссертации рассматривается задача построения системы распознавания изображений.

Выбор в качестве основного объекта исследования, оцифрованных полутоновых изображений реальных объектов обусловлен несколькими факторами: во-первых, актуальностью задачи распознавания изображений; во-вторых, соз-

дание классификационных обучающих выборок для экспериментальной оценки результатов работы.

2.2 Выбор математической модели сигналов изображений

Под объектом понимается связанная область точек изображения, имеющая 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 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 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 затеняют изображение объекта, наиболее адекватной является модель, предложенная Агарвалом (Aggarval) [55, 56, 39].

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

$$Z(i, j, t) = A \cdot S(i, j, \lambda(k)) + f_c(i, j, \lambda(k)) \cdot S_B(i, j) + n(t), \quad (2.1)$$

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 средним квадратическим 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 изображения могут затеняться близко расположенными элементами фона. При малоконтрастных динамических сценах принадлежность каждой точки изображения объекту или фону является случайной, а их классификация носит статистический характер.

В этом случае наиболее удобной является модель 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 изображения "фон-объект" и "объект-фон".

В этом случае видео сигнал имеет вид:

$$Z(i, j, k) = A \cdot S(i, j, \lambda(k)) \cdot f_c(i, j, \lambda(k)) + [1 - f_c(i, j, \lambda(k))] \cdot S_B(i, j, k) + n(k), \quad (2.2)$$

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, средним квадратическим 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 [55, 56, 40].

Однако, эти модели изображений хороши в случае решения задачи сопровождения и определения координат динамического или статического 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 изображений использовать аддитивную смесь сигнала и шума

$$Z(i, j) = A(i, j) + n(t), \quad (2.3)$$

где $A(i, j)$ – значение сигнала яркости в точке (i, j) ;

$n(t)$ – белый шум, некоррелированный по пространству и времени, с нулевым средним $m_0 = 0$, средним квадратическим отклонением σ_0 .

Такая модель является наиболее адекватна при решении задачи классификации сигналов изображений, в виду того что анализу сразу подвергается вся фоно-целевая сцена анализируемого протяженного объекта [32].

2.3 Методы преобразования сигналов изображений

В общем случае изображение представляет собой случайную двумерную функцию яркости. При этом если изображение рассматривать в последовательности кадров, то в данном случае появляется еще и временная зависимость.

В нашем случае подразумевается анализ изображений, на которых оператором, либо системой автоматически, выбирается объект подлежащий распознаванию. Тем самым, в некоторой степени удастся сузить область анализируемых данных.

Как рассматривалось в п. 1.1, изображения описывается рядом признаков формирования, которых определяется классом решаемой задачи. В нашем случае, основываясь на представлении яркостного сигнала изображения как случайный процесс, возможен следующий подход к формированию процессов, отображающих изображение объекта в последовательности кадров необходимых для формирования информационной системы признаков. При этом анализу подвергается система выборочных строк, число строк может варьироваться, которые равномерно пересекают протяженный объект (рисунок 2.1). В этой связи получаем набор реализаций случайных процессов в пределах одного кадра $Z_i(j)$. В результате чего переходим от двумерной модели изображения к системе одномерных реализаций сигналов изображения [31]. При этом для простоты восприятия яркостных сигналов изображений проведем нормировку по максимальному уровню сигнала, как показано на рисунке 2.2. В нашем случае, как говорилось ранее используются полутоновые статические изображения пред-

ставленные 256 градациями (8 бит) яркостного сигнала. Для увеличения длины реализации яркостного сигнала изображения это можно сделать в пределах последовательности кадров данного изображения объекта.



Рисунок 2.1 – Формирование системы одномерных реализаций




Рисунок 2.2 – Выборочная реализация номерованного яркостного сигнала изображения

В большинстве случаев, как было уже сказано в п. 1.2, перед непосредственной обработкой изображений необходимы некоторые преобразования связанные с устранением искажающих факторов. Наиболее эффективным из них в большинстве случаев является яркостная нормализация. [57] Под нормализаци-

ей понимается такое преобразование изображения, которое позволяет привести его к виду, удобному для распознавания. Более того, для того чтобы достоверно проводить классификацию объектов, необходимо выполнение еще одного факта – нормализация по площади занимаемым объектом на изображении. Во-первых, площади протяженных объектов подвергаемых классификации (распознаванию) должны быть примерно одинаковы, допустимые расхождения порядка 5%. Во-вторых, площадь занимаемая объектом на изображении должна быть максимальна, т.е. объект должен быть вписан в апертуру анализируемого изображения. Вопросы нормализации будут рассмотрены в п. 2.3.1.

Проведенные исследования показали, что в ряде случаев сигналы яркости оцифрованных полутонных изображений не являются стационарными процессами. Для того чтобы приблизить сигналы изображений к виду близкому к стационарному применяется динамическая интерполяция сигнала. Заключаящаяся в построении разностного сигнала изображения с опорным равномерным случайным процессом, определяющаяся выражением

$$X_i(j) = Z_{iH}(j) - \eta_i(j), \quad (2.4)$$

где $Z_{iH}(j)$ – нормализованный сигнал анализируемого изображения, определяемое выражением 2.11;

$\eta_i(j)$ – дискретные отсчеты равномерного случайного процесса, некоррелированного с анализируемым, и определенным на интервале не меньшем интервала определения анализируемого сигнала.

Приведенная операция (2.4) в ряде источников [24, 60, 59], именуемая как динамическая интерполяция анализируемого сигнала служит, во-первых, для стационаризации процесса, во-вторых, если в качестве опорного процесса используется равномерный процесс, то в результате такой свертки получается равномерное распределение значений анализируемого сигнала по интервалу квантования и, в-третьих, данная операция позволяет избежать плохой обусловленности корреляционных матриц. Результаты данной операции приведе-

ны на рисунке 2.3, здесь в качестве примера была сформирована система из пяти анализируемых строк.

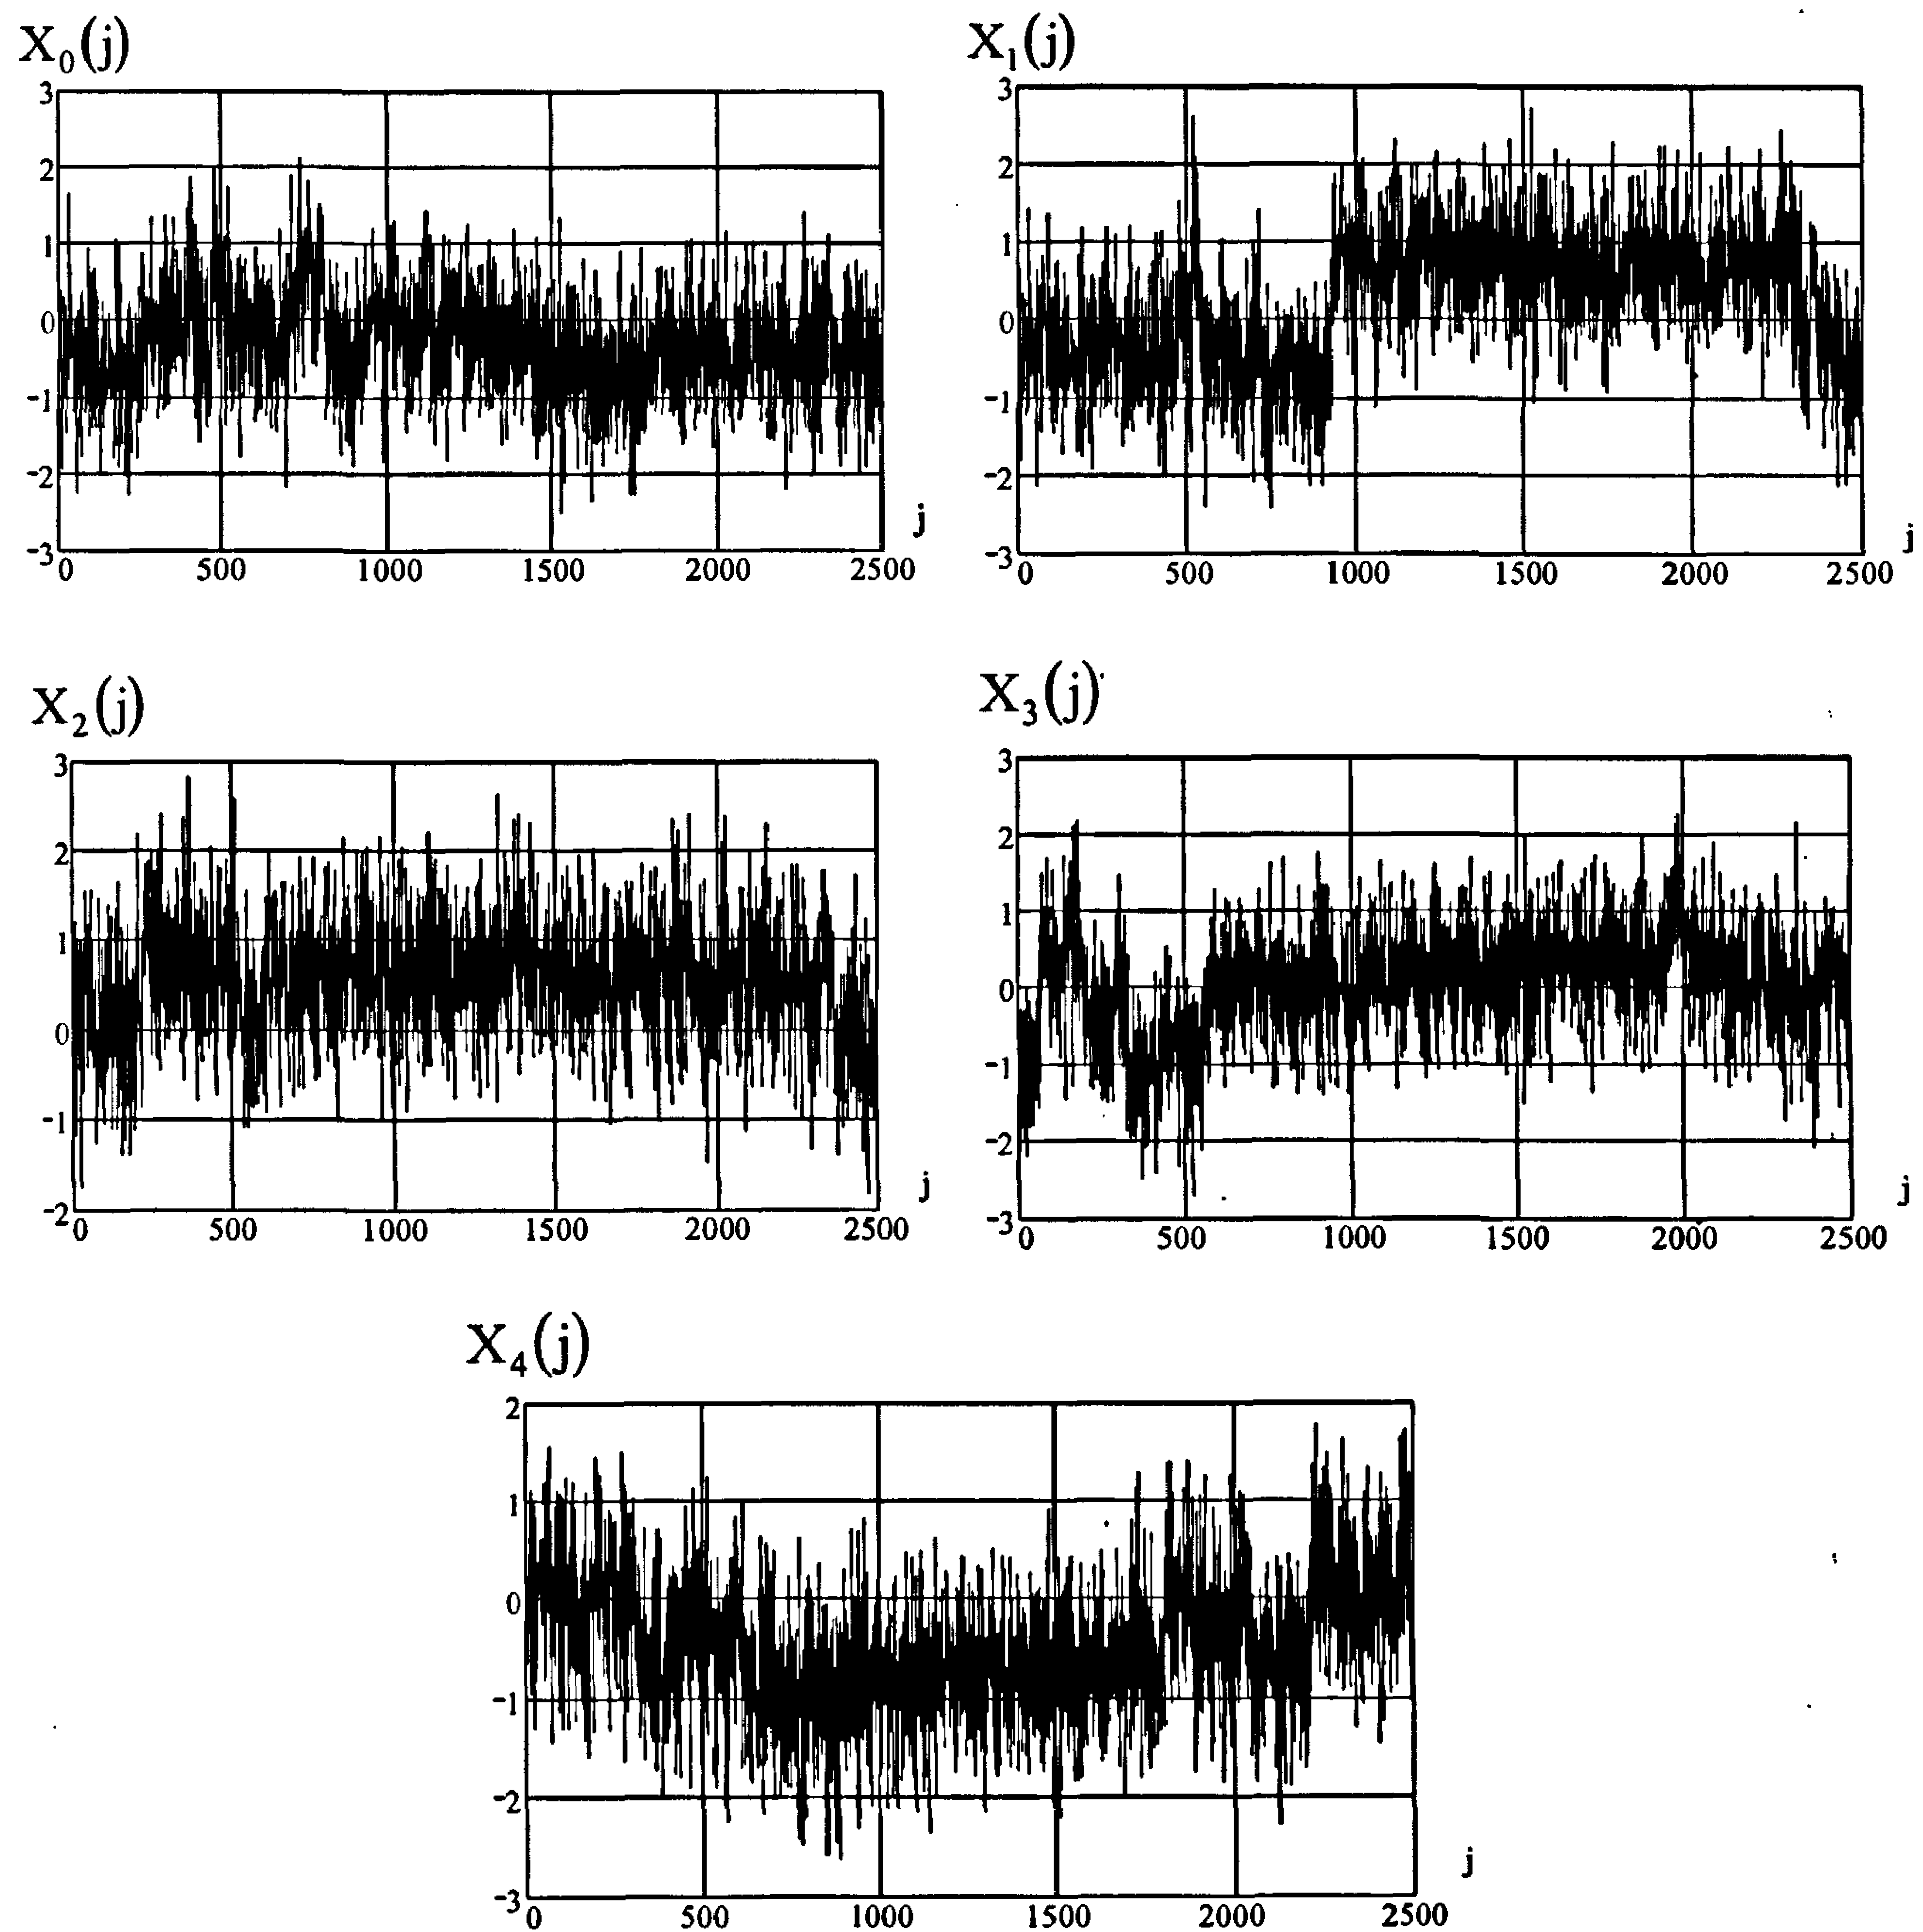


Рисунок 2.3 – Сформированная система одномерных реализаций сигналов изображения

Как отмечено в [25, 63, 94, 57] в качестве системы эффективных признаков, может быть использована система моментных функций. В статистическом распознавании использование моментных функций, в том числе и смешанных

моментов позволяет получить эффективную систему признаков и осуществить классификацию объектов, подробнее это будет рассмотрено в главе 3.

2.3.1 Нормализация сигналов изображений

Одним из важных этапов решения задачи обнаружения и распознавания объектов на цифровых изображениях является нормализация яркостных искажений. Такие искажения в системах дистанционного формирования изображений возникают вследствие как природных, так и технических факторов (условий наблюдения, освещенности, влияния атмосферы, времени экспозиции и т.д.). В результате их действия яркостные статистические характеристики фона и объектов на изображении могут существенно изменяться при сохранении неизменной формы объектов [40]. Из предположения, что основную информацию об объектах несут их геометрические характеристики, следует необходимость яркостной нормализации, то есть преобразования изображения к виду, независимому от случайного характера яркостных искажений.

При отсутствии априорной информации об искажениях вид и параметры нормализующего яркостного преобразования определяются непосредственно по обрабатываемому изображению. Обычно вид преобразования задается, а параметры вычисляются на основе яркостных статистических характеристик (среднего, дисперсии, гистограммы) [57, 67, 68], однако параметры могут быть определены и с помощью других признаков изображения (например, моментных инвариантов [57]).

Рассмотрим математическую модель изображения, в котором 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 можно поставить в соответствие эталонное изображение, каждый элемент которого определяется в зависимости от его принадлежности области D_0 или D_b :

$$\bar{f}(n_1, n_2) = \begin{cases} 0, & \text{при } (n_1, n_2) \in D_b \\ 1, & \text{при } (n_1, n_2) \in D_0 \end{cases}. \quad (2.5)$$

Используя данное представление, получаем модель нормализуемого изображения:

$$f(n_1, n_2) = (\bar{\zeta}_0(n_1, n_2) + A_0)\bar{f}(n_1, n_2) + \bar{\zeta}_b(n_1, n_2)(1 - \bar{f}(n_1, n_2)) + A + v(n_1, n_2). \quad (2.6)$$

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

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

Преобразование Θ устранения яркостных искажений изображения должно обеспечивать:

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

$$\|y(\Theta(f(n_1, n_2))) - y(\bar{f}(n_1, n_2))\| \rightarrow \min, (n_1, n_2) \in D, \quad (2.7)$$

где y – вектор признаков, вычисляемых на области изображения D (в качестве признаков можно использовать отсчеты 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 изображения:

$$y(\Theta(Af(n_1, n_2) + B)) = y(\Theta(f(n_1, n_2))), \quad (2.8)$$

где A, B – параметры преобразования;

– для эталонного изображения (2.5) должно выполняться соотношение

$$y(\Theta(\bar{f}(n_1, n_2))) = y(\bar{f}(n_1, n_2)). \quad (2.9)$$

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

$$E\{y(\Theta(f(n_1, n_2)))\} = y(\bar{f}(n_1, n_2)). \quad (2.10)$$

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

$$Z_H(j) = \frac{Z(j)}{m[Z_N(j)]}, \quad (2.11)$$

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

Далее рассмотрим вопрос нормализации объекта по занимаемой им площади на изображении. В основе данного подхода лежит численный метод Монте-Карло [16], при этом задача выделения контуров объекта в данной работе не рассматривался, поэтому эта операция проводилась вручную.

Известно, метод Монте-Карло предназначен для приближенного подсчета сложной подынтегральной функции, каким и является изображение протяженного объекта. В основе данного метода лежит вероятностный подход, основанный на центральной предельной теореме. Его преимущество, во-первых, в многомерном случае число вычисляемых значений подынтегральной функции растет значительно медленнее, чем при квадратурных формулах, при заданной точности вычисления, а во-вторых, точность не зависит от гладкости подынтегральной функции. Недостатком этого метода является то, что результат носит вероятностный характер, т.е. отсутствие строгих оценок погрешностей.

В рамках данной работы мы не будем подробно описывать этот метод, просто обозначим его подробное описание можно прочитать в литературе [16]. В нашем случае воспользуемся упрощенным выражением

$$S_{об} \approx \frac{1}{N} \sum_{i=1}^N k_i, \quad (2.12)$$

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

2.4 Укрупнение описания сигналов 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) [78, 87, 79, 63] с целью улучшения их разделимости (повышения достоверности классификации) иногда приводят к противоречивым рекомендациям по выбору эффективных признаков. Так, например, при выборе признаков методом минимизации внутри-

классового 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 [87].

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 [80] 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 [20] 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 [74, 49] 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 преобразо-

вания для рассматриваемых признаков. Рассмотрим один из подходов к решению таких задач, предложенный в [22].

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

$$L = M[y] = \int_{-\infty}^{\infty} \varphi(x) p(x) dx \quad (2.13)$$

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 (2.13) на интервале в виде [59]

$$\frac{1}{T_p} \int_0^{T_p} \varphi[x(t)] dt = \lim_{q \rightarrow \infty} \frac{1}{q} \sum_{n=1}^q \varphi[x(t_n)] \Delta t_n, \quad (2.14)$$

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 \mathcal{E} .

Выражение

$$\mathcal{E} = \frac{1}{q} \sum_{n=1}^q \varphi[x(t_n)] \Delta t_n = 0 \quad (2.15)$$

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

$$\begin{cases} M[y] \geq 0, & \{x(t_k)\}_{k=1}^q \in \omega_1 \\ M[y] < 0, & \{x(t_k)\}_{k=1}^q \in \omega_2 \end{cases}, \quad (2.16)$$

где ω_1, ω_2 – объект первого и второго класса, то эта поверхность может служить разделяющей [52].

Из определения оператора (2.13) 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

$$\varphi(x) = F_\eta(x) = P_\eta[X \leq x], \quad (2.17)$$

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

В этом случае результат преобразования может быть записан

$$L = \int_{-\infty}^{\infty} F_\eta(x) p(x) dx \quad (2.18)$$

или

$$L = \int_{-\infty}^{\infty} \int_{-\infty}^x p_{\eta}(y)p(x)dydx \quad (2.19)$$

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

Из (2.19) 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 (2.18) 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 (2.18) 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 (2.18).

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 [52, 87], наилучшим является байесовский классификатор, минимизирующий ошибки классификации (диагностирования).

Для построения в дальнейшем разделяющих поверхностей и оценок вероятности правильной классификации необходимо знать статистические характеристики функционалов (2.13) и (2.18), 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 [20]. 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

$$M[L] = \int_{-\infty}^{\infty} \varphi(x) M[\hat{p}(x)] dx. \quad (2.20)$$

Дисперсию преобразованного процесса можно определить из выражения

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

Получаем

$$\sigma_L^2 = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \varphi(x_1) \varphi(x_2) \{M[\hat{p}(x_1)] M[\hat{p}(x_2)] - M[\hat{p}(x_1) \hat{p}(x_2)]\} dx_1 dx_2 =$$

$$= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \varphi(x_1)\varphi(x_2)\mathbb{K}(x_1, x_2)dx_1dx_2, \quad (2.21)$$

где $\mathbb{K}_p(x_1, x_2) = \frac{2}{T_p} \int_0^{T_p} (T_p - \tau) \mathfrak{p}(x_1, x_2; \tau) d\tau - \mathfrak{p}(x_1)\mathfrak{p}(x_2);$

$$\tau = t_2 - t_1;$$

$\mathfrak{p}(x_1, x_2; \tau)$ – двумерная плотность вероятности анализируемого процесса $x(t)$, при этом процесс $x(t)$ является стационарным эргодическим.

Таким образом, полученные в результате анализа выражения (2.13), реализуемого системой распознавания, статистические соотношения (2.20), (2.21) 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 (2.18) следует, что если $p(x)$ представлена своей оценкой $\mathfrak{p}(x)$, то

$$M[L] = \int_{-\infty}^{\infty} M[F_\eta(x)\mathfrak{p}(x)]dx = \int_{-\infty}^{\infty} M[F_\eta(x)\mathfrak{p}(x)]dx \quad (2.22)$$

В выражении (2.22) 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 (2.22) записано в той же форме, что и (2.20), то выражение для дисперсии результата преобразования может быть записано в виде, аналогичном (2.21)

$$\sigma_L^2 = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} F_{\eta}(x_1) F_{\eta}(x_2) \mathcal{E}_p(x_1, x_2) dx_1 dx_2. \quad (2.23)$$

В практических приложениях в распоряжении исследователя часто имеются лишь оценки плотностей распределения и корреляционных функций, поэтому выражения (2.20), (2.21), (2.22) и (2.23) можно приближенно определить следующим образом:

для функции преобразования $\varphi(x)$

$$M[L] \approx \Delta x \sum_{k=1}^n \varphi(x_k) M[\varphi(x_k)]; \quad (2.24)$$

$$\sigma_L^2 \approx (\Delta x)^2 \sum_{k=1}^n \varphi^2(x_k) \mathcal{E}_p^2(x_k); \quad (2.25)$$

для функции распределения $F_{\eta}(x)$

$$M[L] \approx \Delta x \sum_{k=1}^n F_{\eta}(x_k) M[\varphi(x_k)]; \quad (2.26)$$

$$\sigma_L^2 \approx (\Delta x)^2 \sum_{k=1}^n [F_{\eta}(x_k)]^2 \mathcal{E}_p^2(x_k); \quad (2.27)$$

здесь Δx – интервал квантования анализируемого процесса $x(t)$;

n – количество уровней квантования процесса $x(t)$;

$M[\varphi(x_k)] = M\left[\frac{1}{\Delta x} \int_{x_{k-1}}^k \varphi(x) dx\right]$ – математическое ожидание оценки плотности вероятности процесса $x(t)$ в точках интерполяции;

$\mathcal{E}_p^2(x_k)$ – дисперсия оценок $M[\varphi(x_k)]$.

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.

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. 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.

3 РАЗРАБОТКА МОДЕЛЕЙ ПРИНЯТИЯ РЕШЕНИЙ ПРИ НЕПАРАМЕТРИЧЕСКОМ РАСПОЗНАВАНИИ СИГНАЛОВ ИЗОБРАЖЕНИЙ

3.1 Формирование системы признаков на основе метода стохастического кодирования сигналов изображений

В ряде случаев одномерные начальные статистические моменты различных порядков для различных объектов могут быть близки, что не позволяет использовать их для классификации. Поэтому было предложено в качестве системы классификационных признаков использовать второй смежный момент, в качестве которого используется первый отсчет взаимной корреляционной функции, формирование системы таких признаков рассмотрено в данной главе.

Как отмечалось раньше, использование нелинейного преобразования первичных признаков позволяет с одной стороны укрупнить описание классифицируемых сигналов, то есть отобразить исходное многомерное пространство признаков в одномерное пространство функционалов, с другой стороны – с применением в качестве функции преобразования функции распределения некоторого вспомогательного процесса – позволяет как бы "обобщить" или представить более компактно свойства всех сигналов, принадлежащих одному классу.

Рассмотрим один из методов реализации алгоритма стохастического кодирования сигналов [18, 20], 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 [14, 52], 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:

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

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

Нетрудно заметить, что выражение (3.8) совпадает с выражением (2.19), определяющим оператор преобразования в случае использования функции преобразования $\varphi(x) = F_\eta(x)$.

Рассмотрим частный случай [87], 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

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

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

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

то получим

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

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

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

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

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 [82].

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 [59] показано, что знаковая функция

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

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 $M[\text{sgn } Z_1 \text{sgn } Z_2] = M[z_1 z_2]$. 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, то (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 $z(t)$.

Приведем примеры определения численного значения признаков на основе алгоритмов (3.10) и (3.16):

а) Определим значение $M[z(t)]$ в случае, когда классифицируемый сигнал имеет нормальное распределение, а опорный сигнал распределен по закону Рэлея. Плотность распределения анализируемого сигнала

$$p_X(x) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(x-a)^2}{2\sigma^2}} \sigma, \quad a = 0,5; \quad \sigma_H = 0,33.$$

Плотность распределения опорного сигнала

$$p_\eta(\eta) = \begin{cases} 0, & -\infty < \eta < 0; \\ \frac{\eta}{\sigma_p^2} e^{-\eta^2/2\sigma_p^2}, & 0 \leq \eta < \infty, \end{cases} \quad \sigma_p = 0,31.$$

Интервал распределения процессов $X(t)$ и $\eta(t)$ будем во всех примерах брать равным $[0, 1]$, тогда

$$\begin{aligned} M[z] &= \int_0^1 \left[\int_0^x p_\eta(\eta) d\eta \right] p_X(x) dx = \int_0^1 \left[1 - e^{-\frac{x^2}{2\sigma_p^2}} \right] \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(x-a)^2}{2\sigma^2}} dx = \\ &= \int_0^1 p_X(x) dx - \int_0^1 e^{-\frac{x^2}{2\sigma_p^2}} \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(x-a)^2}{2\sigma^2}} dx = \\ &= 1 - \frac{1}{\sqrt{2\pi\sigma}} \int_0^1 \exp \left\{ - \underbrace{\left(\frac{\sigma_p^2 + \sigma^2}{2\sigma^2 \sigma_p^2} \right)}_{p^2} x^2 + \underbrace{\left(\frac{2a\sigma_p^2}{2\sigma^2 \sigma_p^2} \right)}_q x - \underbrace{\frac{a^2 \sigma_p^2}{2\sigma^2 \sigma_p^2}}_c \right\} dx = \\ &= 1 - \frac{e^{-c}}{\sqrt{2\pi\sigma}} \int_0^1 e^{-p^2 x^2 + qx} dx. \end{aligned}$$

Интеграл в последнем выражении является табличным [28], в результате запишем

$$M[z] = 1 - \frac{1}{\sqrt{2\pi\sigma_H}} e^{-c} \frac{\sqrt{\pi}}{p} e^{q^2/4p^2}.$$

Определив p , q , c и подставив их в последнее выражение, окончательно получаем $M[z] = 1 - 0,45 \cdot 0,44 \cdot 1,784 = 0,65$.

б) Определим теперь $M[z]$ в случае, когда сигнал распределен по нормальному закону, а опорный сигнал распределен по экспоненциальному закону

$$p_X(x) = \frac{1}{\sqrt{2\pi\sigma_H}} \exp\left\{-\frac{(x-a)^2}{2\sigma_H^2}\right\}; a = 0,5; \sigma_H = 0,33;$$

$$p_\eta(\eta) = \begin{cases} 0, & -\infty < \eta < 0; \\ \alpha e^{-\alpha\eta}, & 0 \leq \eta < \infty, \quad \alpha = 5. \end{cases}$$

Интегральный закон распределения опорного сигнала имеет вид

$$F_\eta(x) = \int_0^x p_\eta(\eta) d\eta = 1 - e^{-\alpha x}, \quad 0 \leq x < \infty,$$

$$\begin{aligned} M[z] &= \int_0^1 (1 - e^{-\alpha x}) \frac{1}{\sqrt{2\pi\sigma_H}} e^{-\frac{(x-a)^2}{2\sigma_H^2}} dx = \\ &= \int_0^1 p_X(x) dx - \frac{1}{\sqrt{2\pi\sigma_H}} \int_0^1 e^{-\frac{(x-a)^2}{2\sigma_H^2} - \alpha x} dx = \\ &= 1 - \frac{1}{\sqrt{2\pi\sigma_H}} e^{-\frac{a^2}{2\sigma_H^2}} \int_0^1 e^{-\frac{x^2}{2\sigma_H^2} + \frac{x(2a-2\alpha\sigma_H^2)}{2\sigma_H^2}} dx = \\ &= 1 - \frac{1}{\sqrt{2\pi\sigma_H}} e^{-c} \int_0^1 e^{-p^2 x^2 + qx} dx. \end{aligned}$$

Интеграл в правой части – такого же вида, как и в предыдущем примере, следовательно, $M[z] = 1 - \frac{1}{\sqrt{2\pi\sigma}} e^{-c} \frac{\sqrt{\pi}}{p} e^{q^2/4p^2}$.

Определив p , q , c и подставив их в последнее выражение, окончательно получаем $M[z] = 1 - \frac{1,95}{2} \cdot e^{-1,195} \cdot e^{0,0024} = 1 - 0,296 = 0,704$.

в) Приведем теперь пример расчета признака на основе алгоритма (3.26) для случая, когда сигнал распределен по нормальному закону, а опорные сигналы распределены по закону Рэлея.

Двумерная плотность распределения исследуемого сигнала имеет вид

$$p_2(x_t, x_{t+nT_0}; \tau = nT_0) = \frac{1}{2\pi\sigma_H^2 \sqrt{1-\rho^2(\tau)}} e^{-\left\{ \frac{x_t^2 - 2\rho(\tau)x_t x_{t+\tau} + x_{t+\tau}^2}{2\sigma_H^2 [1-\rho^2(\tau)]} \right\}},$$

где $\sigma_H = 0,33$; $\rho(T_0) = 0,5$; $\rho(2T_0) = 0,25$; $\tau = nT_0$ ($n = 1, 2, 3, \dots$).

Одномерные плотности опорных сигналов:

$$p_U(U) = \frac{U}{\sigma_p^2} e^{-\frac{U^2}{2\sigma_p^2}}, \quad 0 \leq U < \infty; \quad p_V(V) = \frac{V}{\sigma_p^2} e^{-\frac{V^2}{2\sigma_p^2}}, \quad 0 \leq V < \infty; \quad \sigma_p = 0,31.$$

$$\begin{aligned}
M[z_1 z_2] &= M[z_t z_{t+nT_0}] = \\
&= \int_0^1 \int_0^1 F_U(x_t) F_V(x_{t+nT_0}) p_2(x_t, x_{t+nT_0}; \tau = nT_0) dx_t dx_{t+nT_0} = \\
&= \int_0^1 \int_0^1 \left(1 - e^{-\frac{x_t^2}{2\sigma_p^2}} \right) \left(1 - e^{-\frac{x_{t+nT_0}^2}{2\sigma_p^2}} \right) p_2(x_t, x_{t+nT_0}; \tau = nT_0) dx_t dx_{t+nT_0} = \\
&= \int_0^1 \int_0^1 p_2(x_t, x_{t+\tau}; \tau = nT_0) dx_t dx_{t+\tau} - \\
&\quad - \int_0^1 \int_0^1 e^{-\frac{x_t^2}{2\sigma_p^2}} p_2(x_t, x_{t+\tau}; \tau = nT_0) dx_t dx_{t+\tau} - \\
&\quad - \int_0^1 \int_0^1 e^{-\frac{x_{t+\tau}^2}{2\sigma_p^2}} p_2(x_t, x_{t+\tau}; \tau = nT_0) dx_t dx_{t+\tau} + \\
&\quad + \int_0^1 \int_0^1 e^{-\frac{(x_t^2 + x_{t+\tau}^2)}{2\sigma_p^2}} p_2(x_t, x_{t+\tau}; \tau = nT_0) dx_t dx_{t+\tau}
\end{aligned}$$

Определяя интегралы в правой части и опуская промежуточные вычисления, найдем $M[z_t z_{t+\tau}] = 1 - 0,45 - 0,45 + 0,3213 = 0,4213$.

В итоге отметим, что 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. При этом наибольший интерес представляет случай равномерного 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 одноразрядного 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

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

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

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

Дисперсия оценки (3.13) может быть определена следующим образом [58]:

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

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 $P^* = \frac{1}{N} \sum_{i=1}^N z(iT_0)$ в N 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 [24]

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

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 [24].

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 [24], где k – разрядность представления $X(t)$ двоичным кодом; S – порядок определяемой моментной функции процесса $z(t)$.

Например, если $k = 12-16$, $S = 2$, то $\alpha = 6-8$.

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 [20, 90] 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, ги-

потеза 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 нуля. Однако практически удастся 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

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

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

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

при фиксированном объеме выделенного пространства

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

то максимизируемый функционал I принимает вид [74]

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

где λ – множитель Лагранжа.

В [74] показано, что искомая граница Γ выделенной области G должна удовлетворять условию

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

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 [91]. 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 [45]. 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 \vec{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 [74]

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

где λ – множитель Лагранжа.

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

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

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 метод 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 [74]

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

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 3.3.

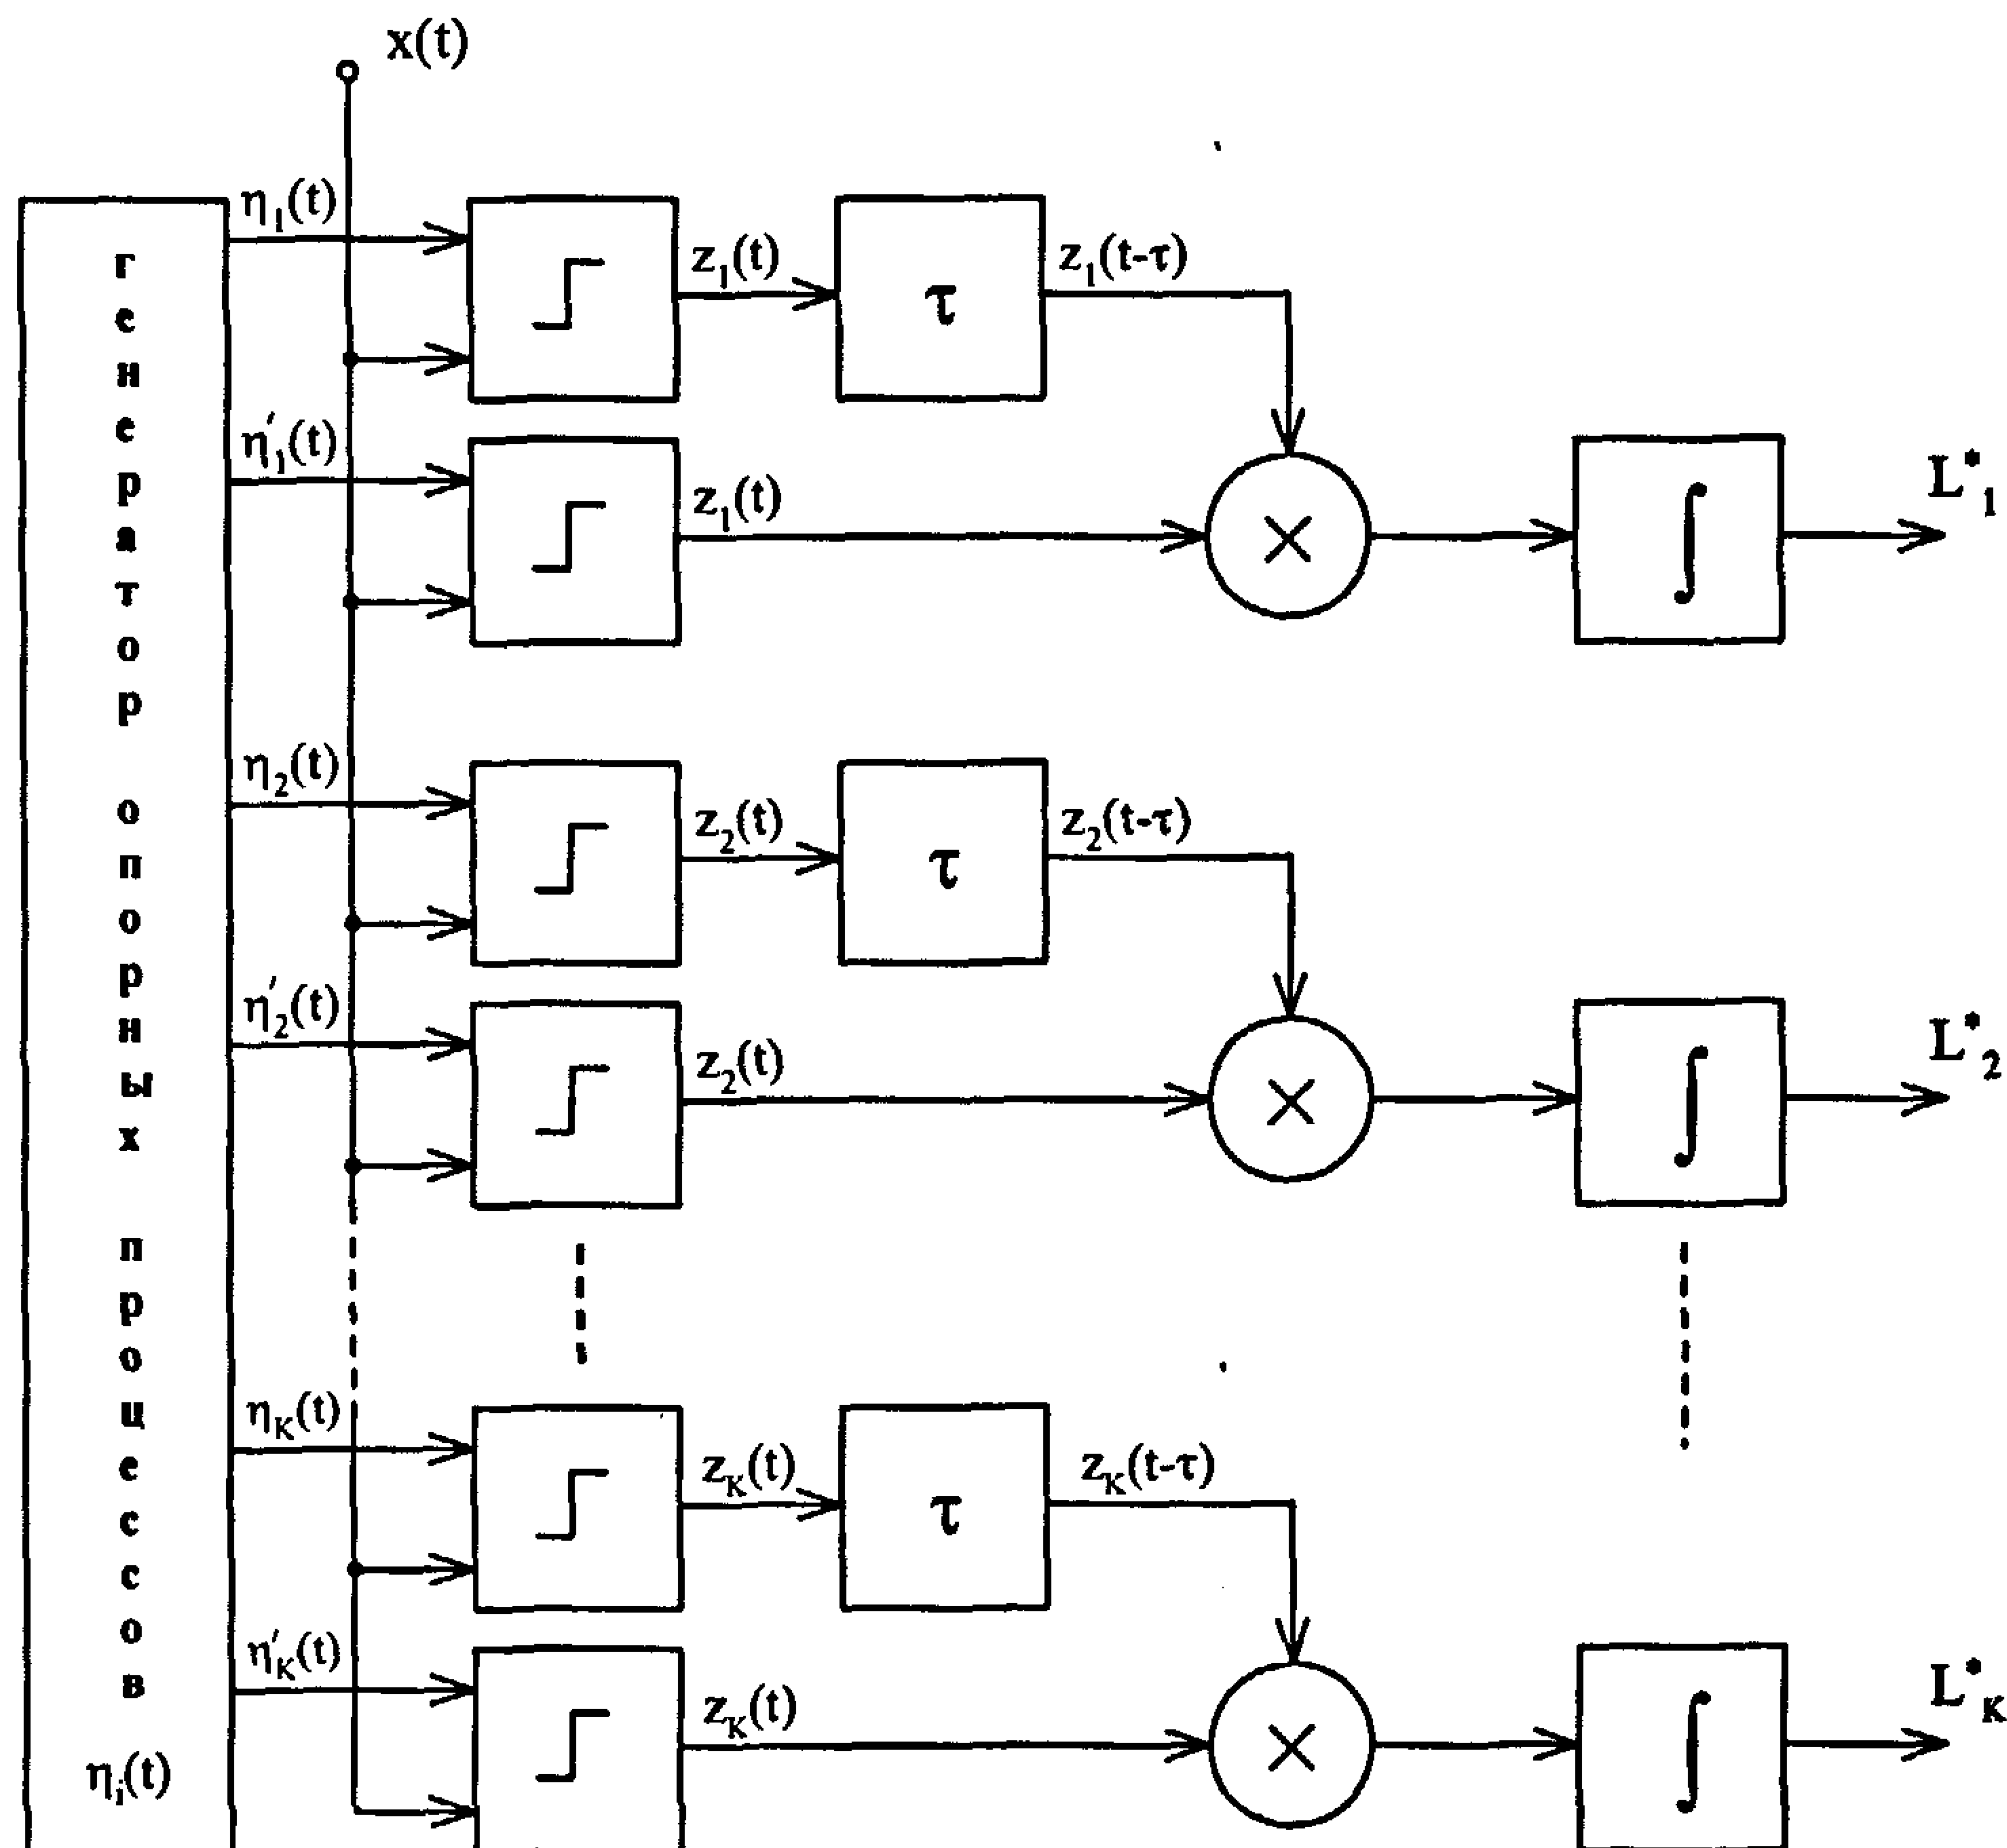


Рисунок 3.1 – Структурная схема формирователя вектора признаков \bar{L}_i^*

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 (3.27), статистические характеристики которой (2.14) и (2.15) зависят как от статистических характеристик распознаваемого процесса $x(t)$, так и от статистических характеристик опорного процесса $\eta_i(t)$, имеющего функцию распределения $F_{\eta_i}(x)$.

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 [74] предлагается рекуррентная процедура определения радиуса гиперсферы, основанная на алгоритмах обучения, изложенных в [91]

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

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 (число опорных распределений);

N – количество оценок r_j^* , полученных при обучении.

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

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

где $\sigma_{r,j}$ – среднеквадратическое 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 [80], 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. 1.5.3 методы оптимизации количества используемых признаков применимы только в случаях, когда известны хотя бы оценочные зависимости ошибок первого и второго рода (1.40) 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.

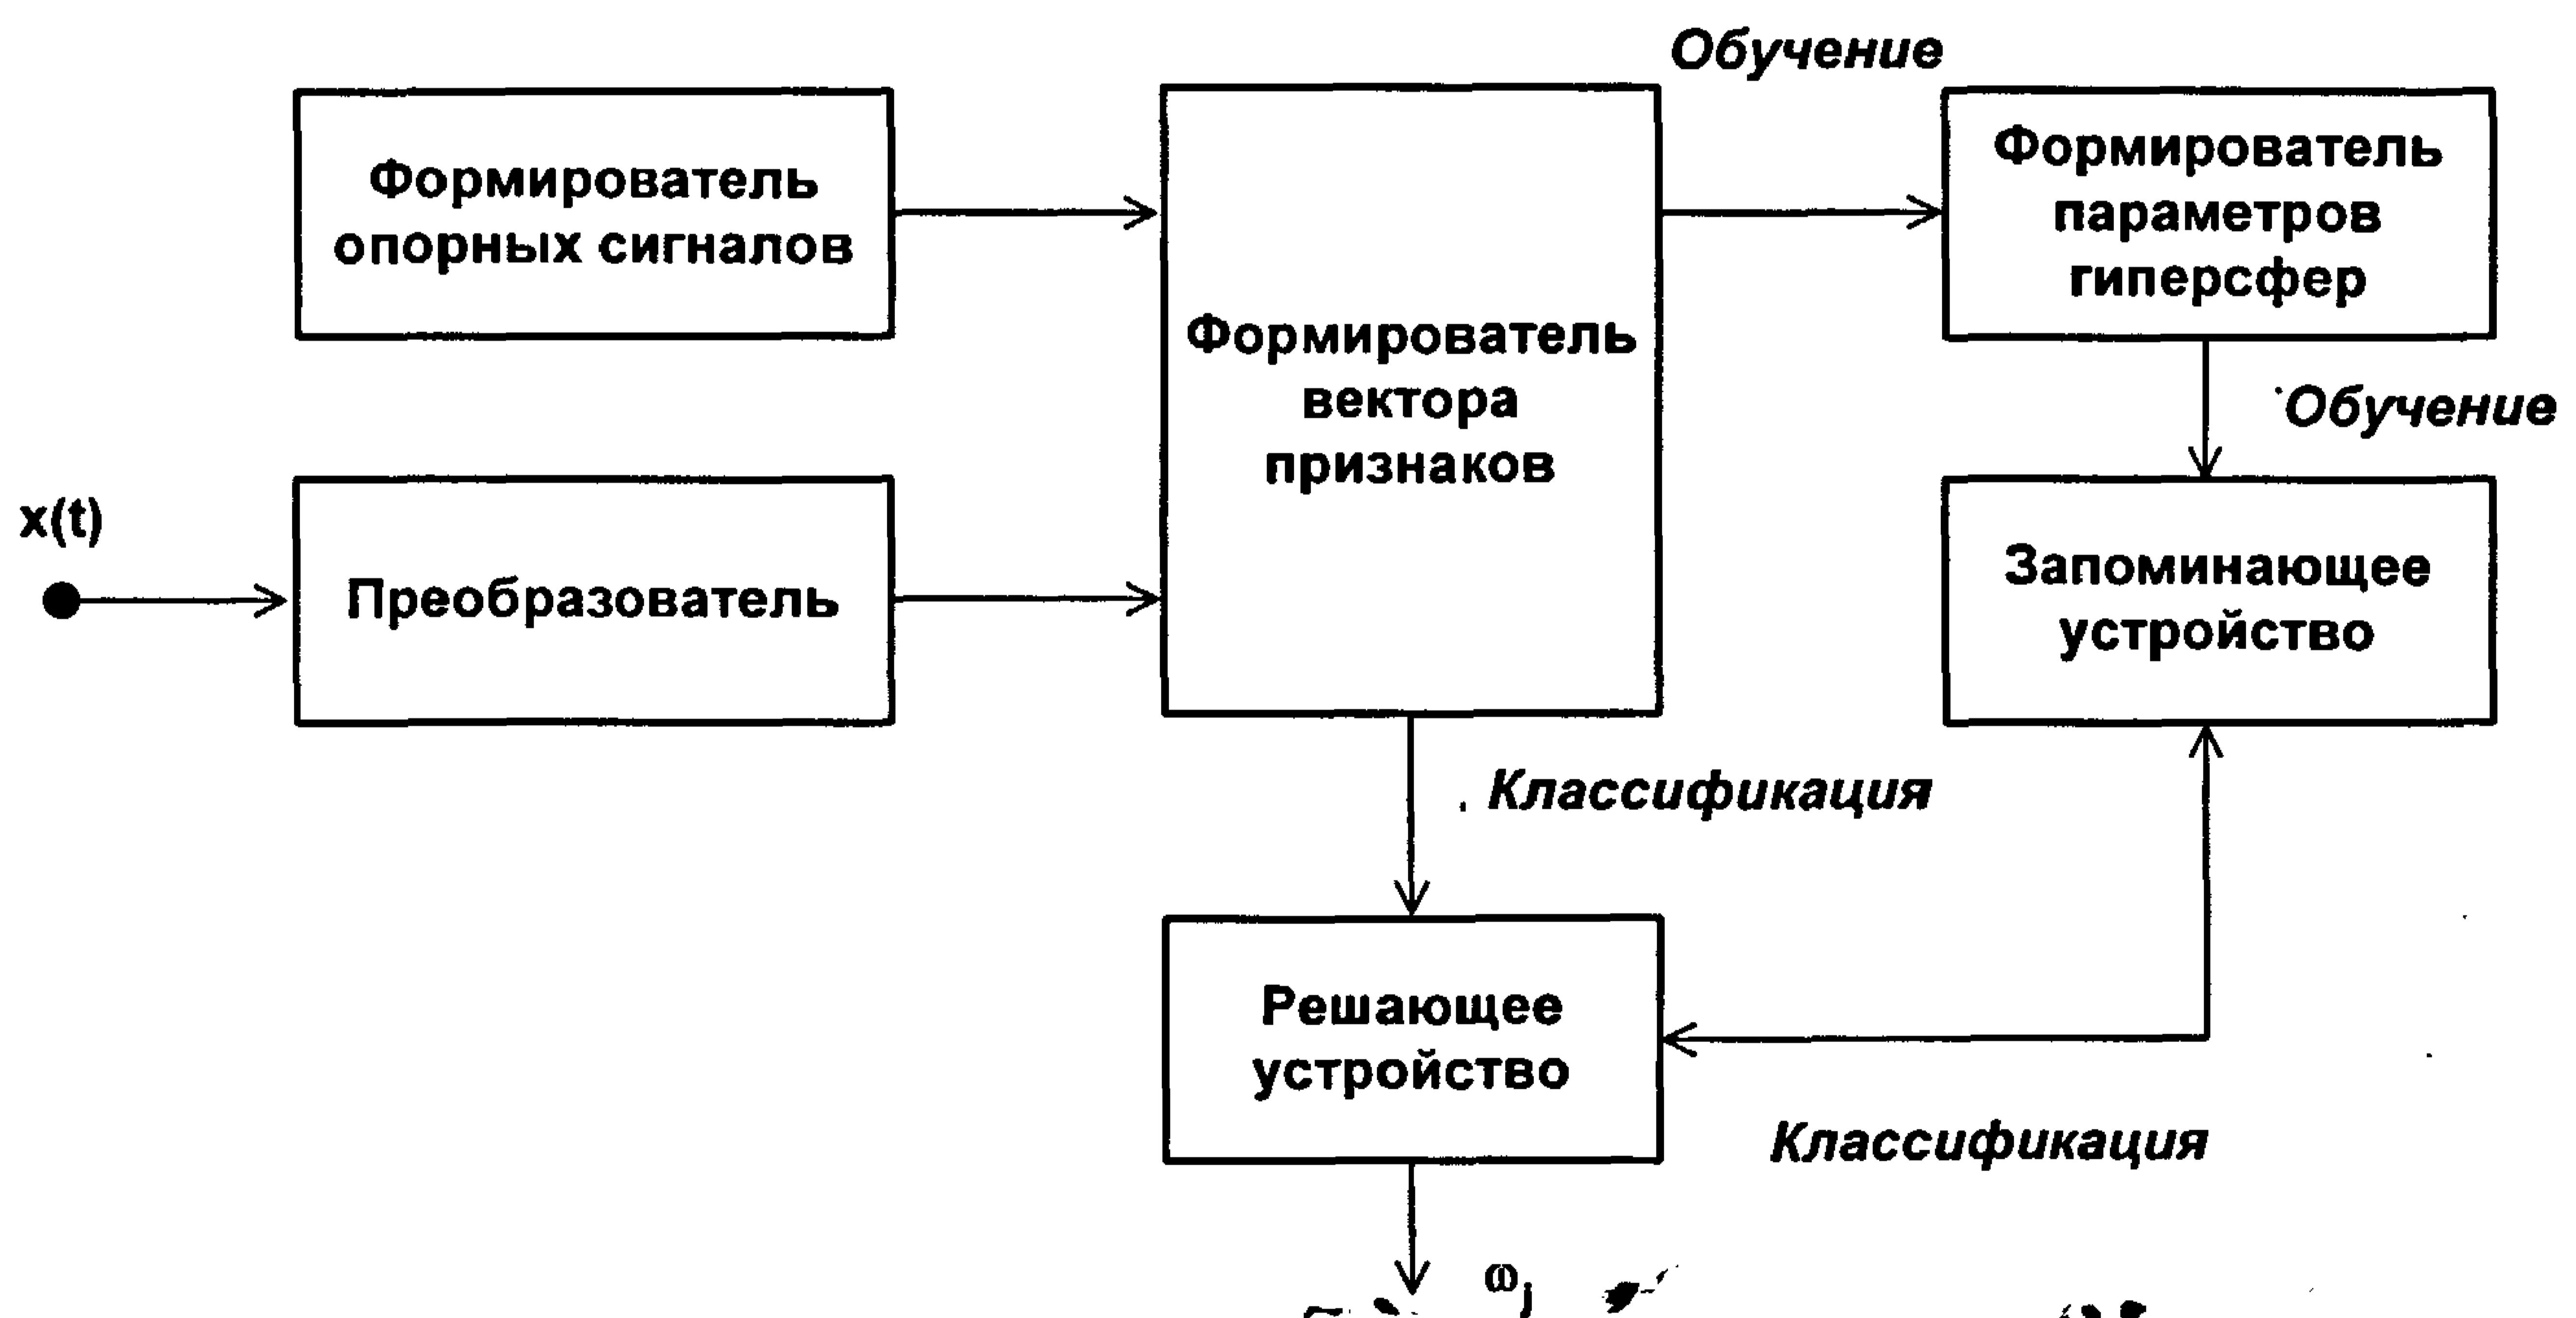


Рисунок 3.2 – Структурная схема НК

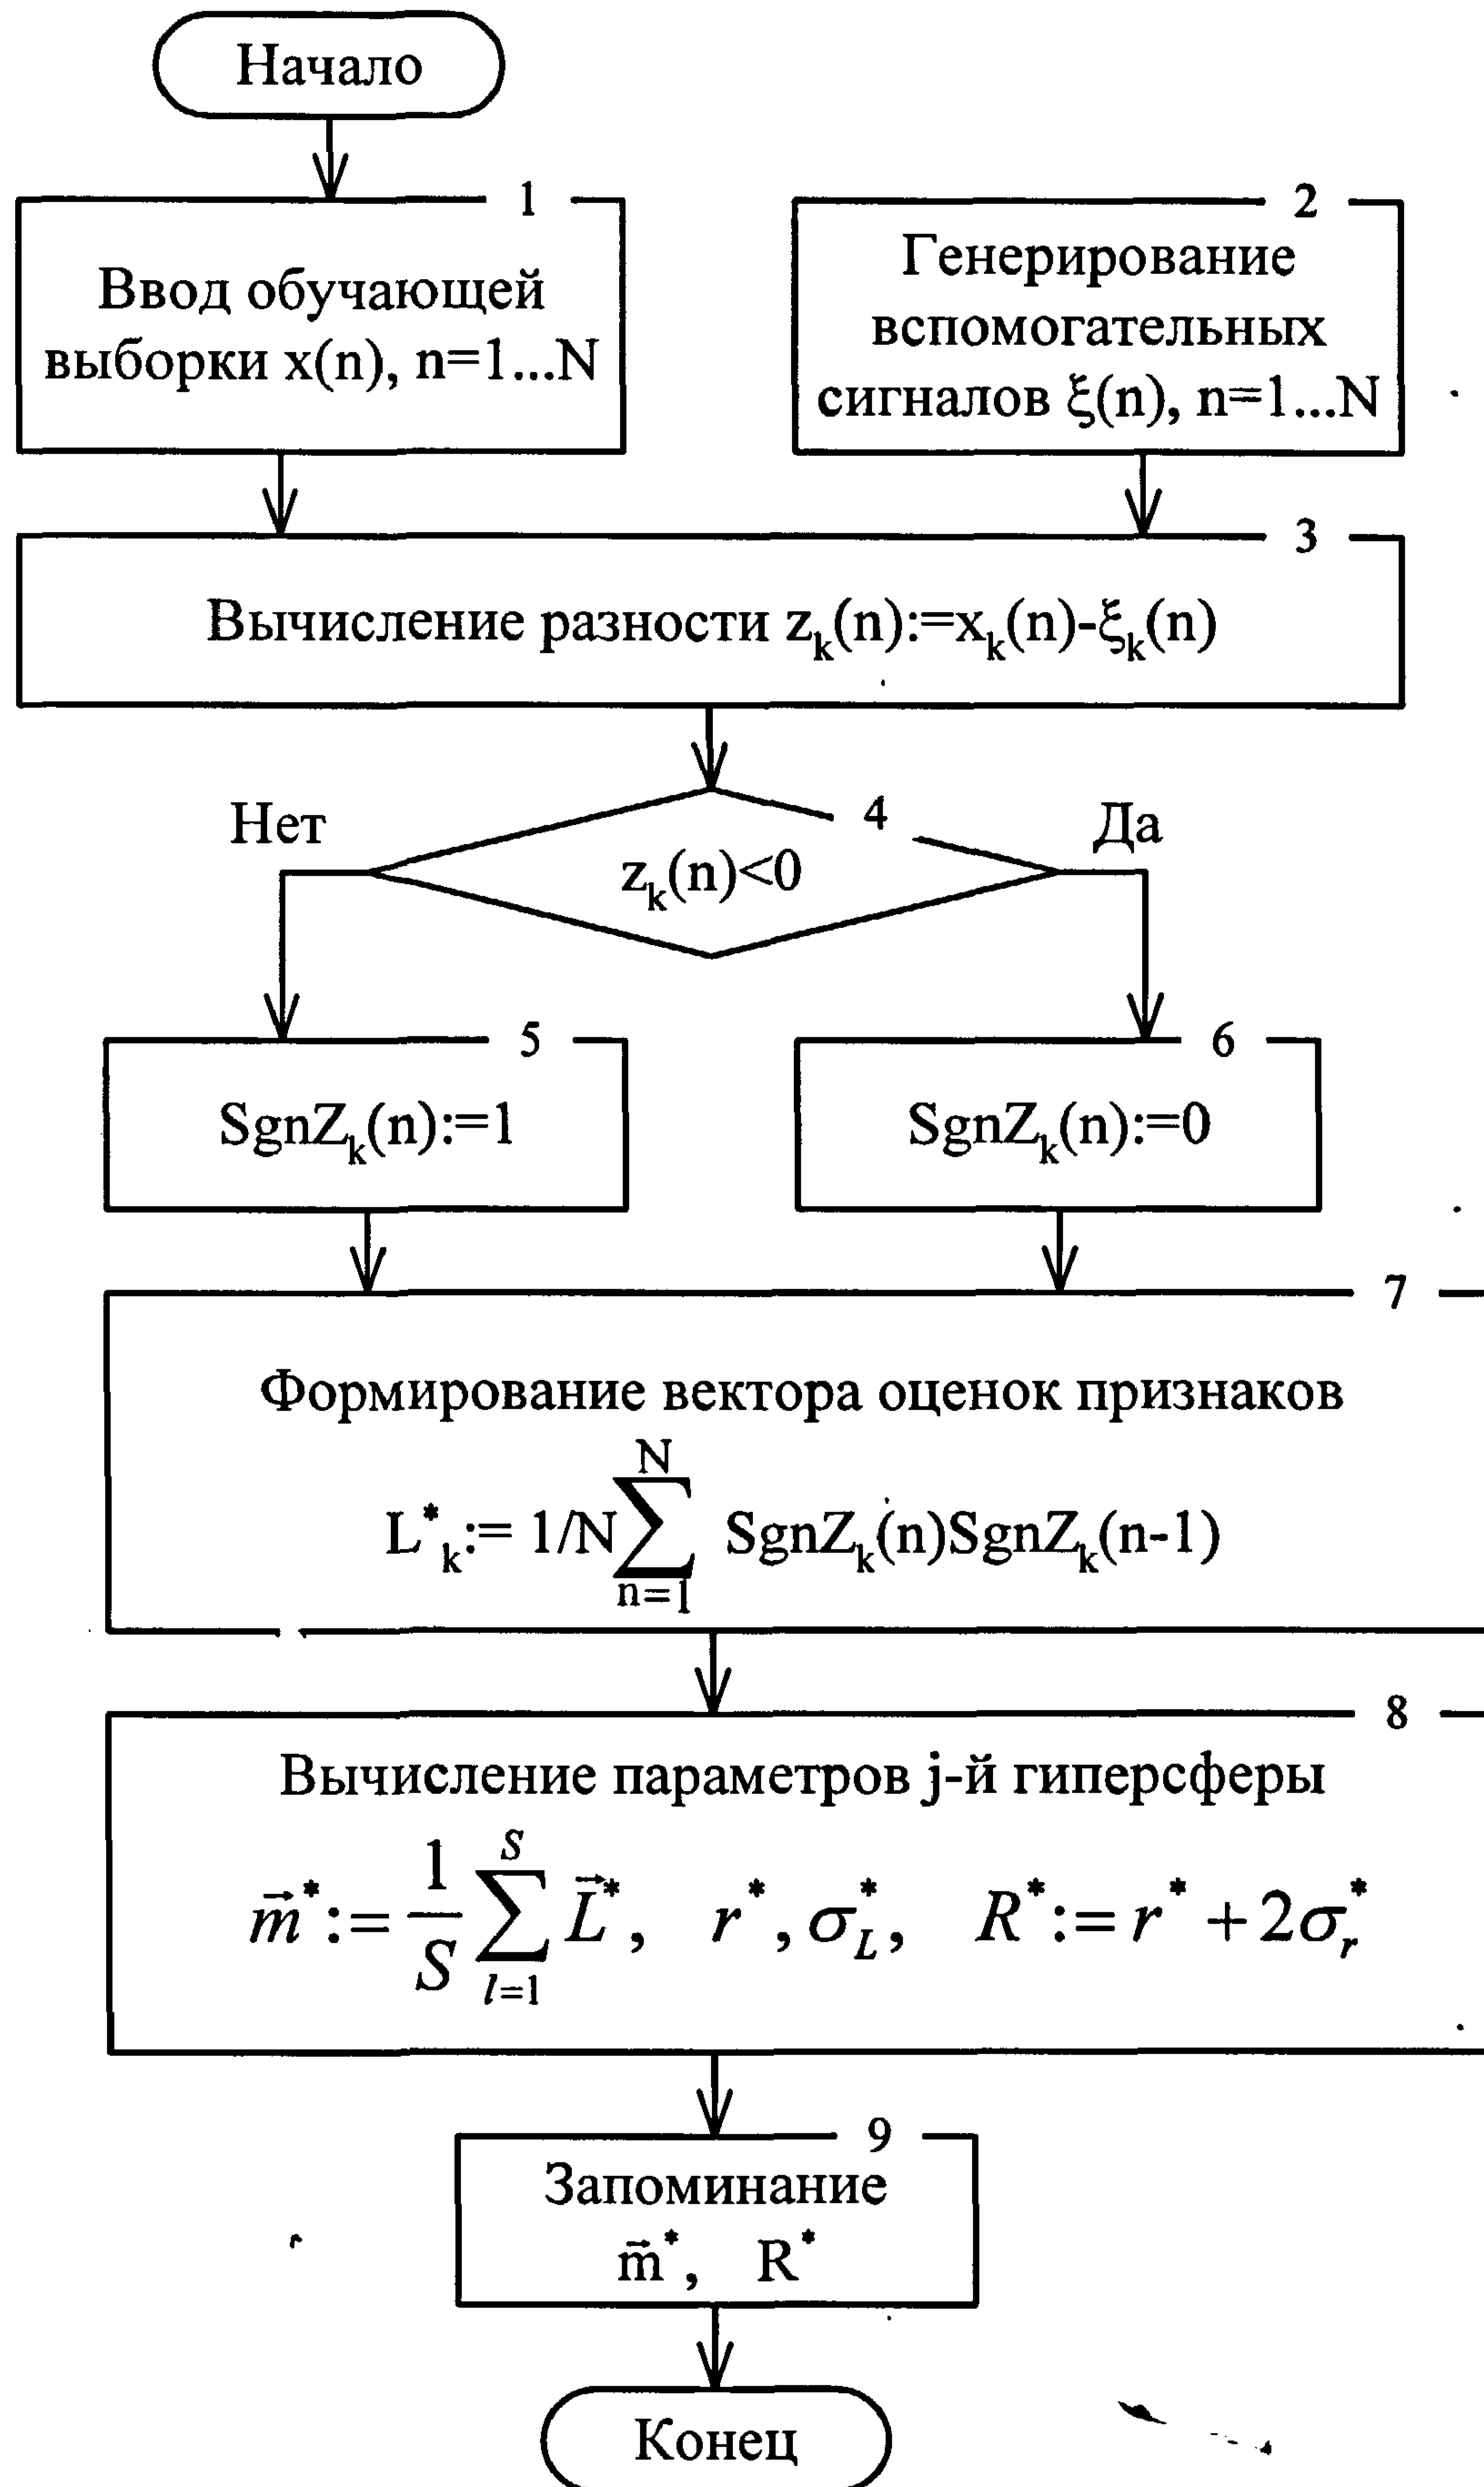


Рисунок 3.3 – Схема алгоритма работы НК в режиме "Обучение"

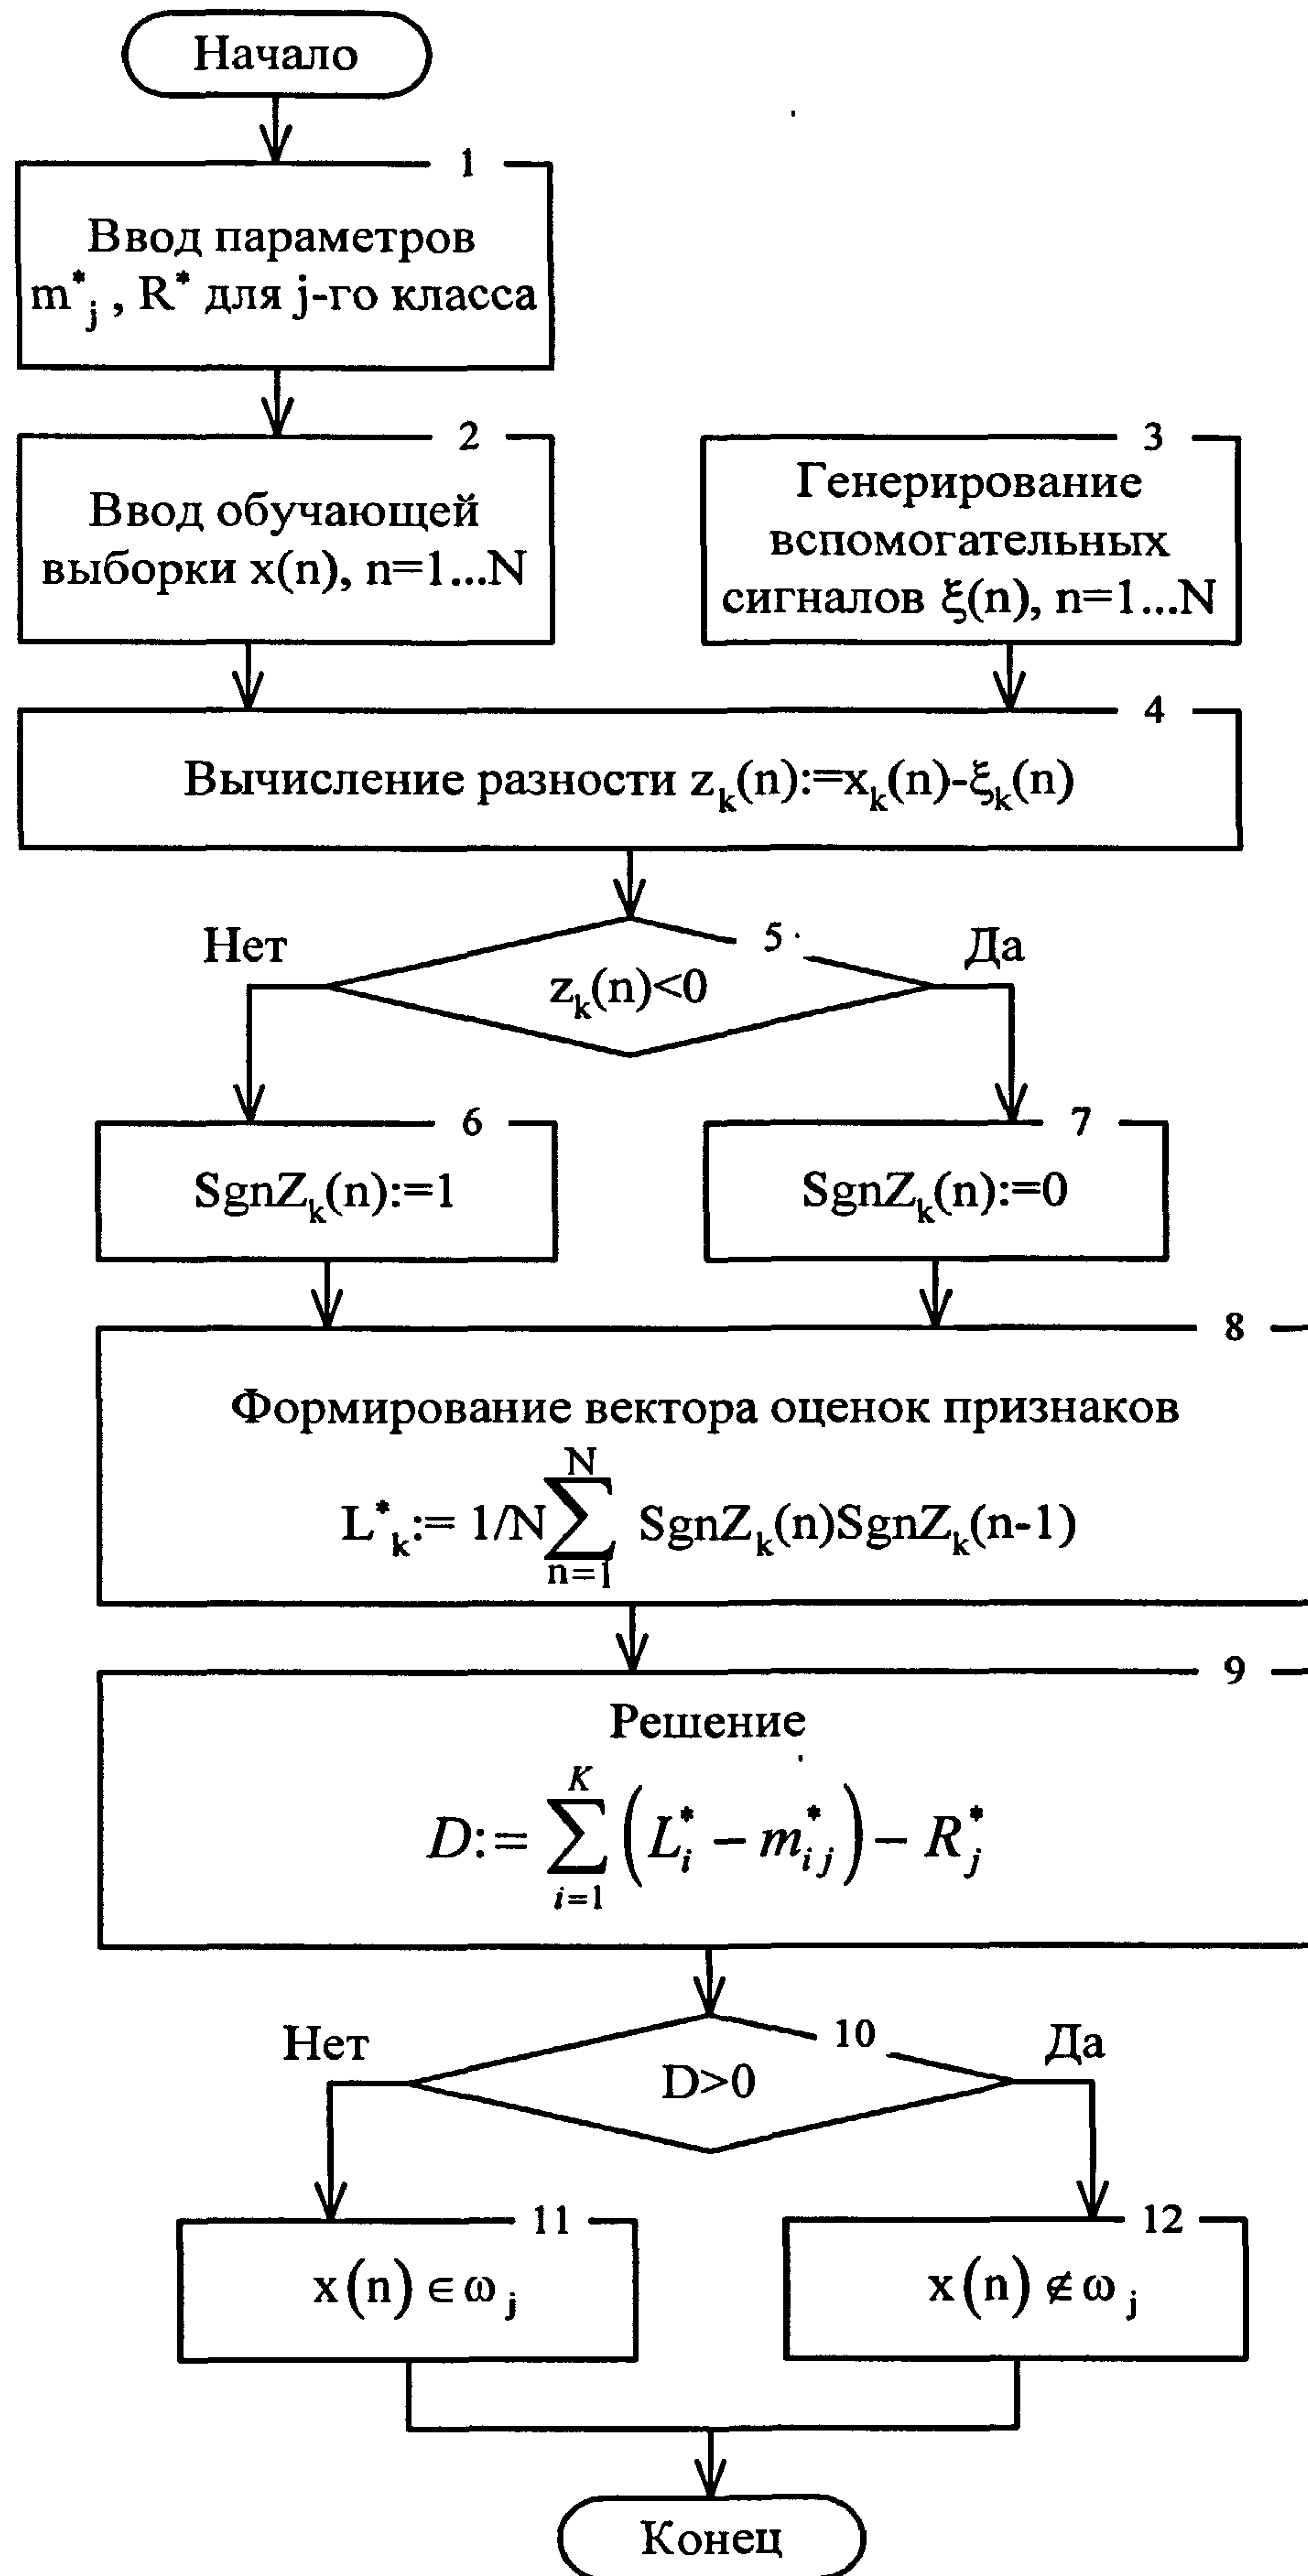


Рисунок 3.4 – Схема алгоритма работы НК в режиме "Классификация"

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

С целью нахождения видов опорных распределений, минимизирующих дисперсии оценок признаков, было проведено статистическое моделирование по программе, написанной с использованием пакета программ для математического моделирования MathCAD Professional 2003 (MathCAD 11) фирмы MathSoft Inc. [95, 73, 48, 41, 7]. Листинг программы содержит графики для $m_r(k)$ и $\sigma_r(k)$ - зависимостей математического ожидания (МО) и среднеквадратического отклонения (СКО) признаков от использованных опорных распределений различных видов [90]. Структурная схема числового эксперимента может быть представлена в виде, приведенном на рисунке 3.5, а определение погрешности результатов моделирования проведено в п.4.6. На рисунках 3.6 – 3.13 показаны виды опорных распределений, входных сигналов и зависимости изменения $m_r(k)$ и $\sigma_r(k)$ от номера опорного распределения для значения интервала наблюдения $T = 10^3 \Delta t$, где Δt – интервал дискретизации исследуемых сигналов.

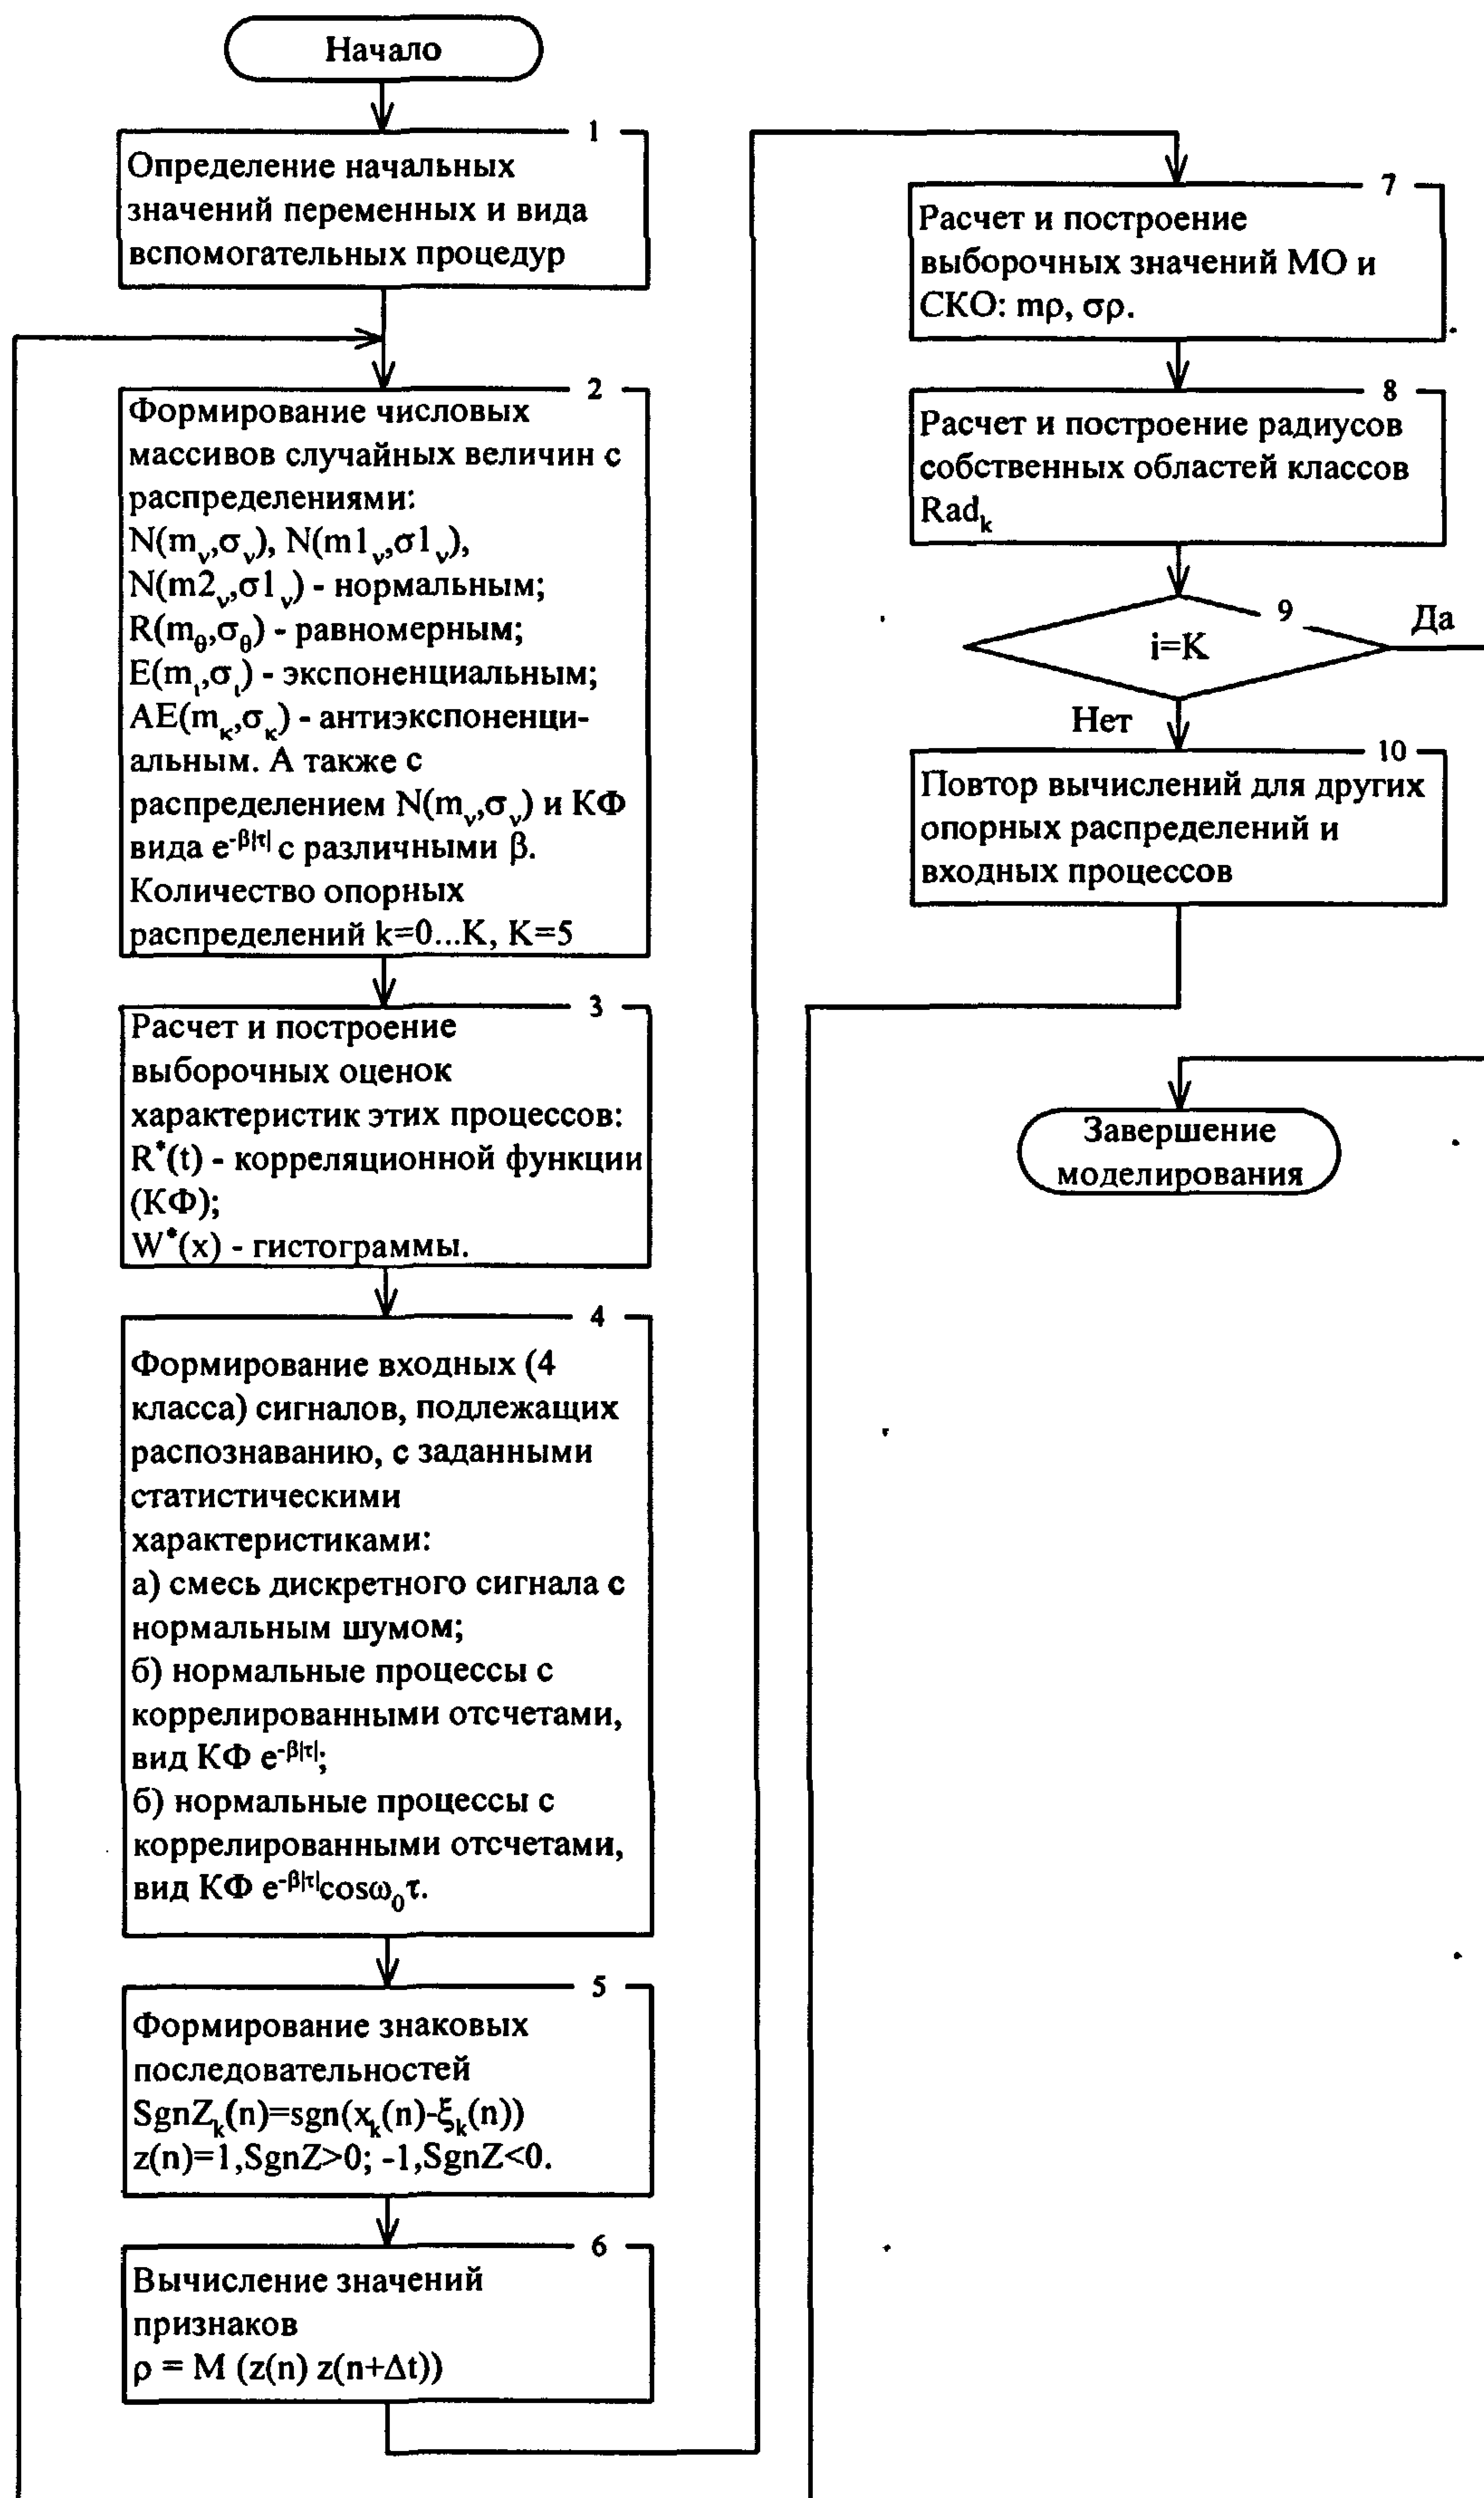


Рисунок 3.5 – Структурная схема программы моделирования работы НК (формирование классификационных признаков в режиме обучения)

На рисунках 3.6 и 3.7 показаны два вида входных сигналов, подлежащих распознаванию.

Первый вид входных сигналов – нормальные процессы с одинаковыми одномерными плотностями распределения вероятностей и различными корреляционными функциями (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 функциями корреляции, оценочные значения которых представлены на рисунке 3.8. Вид корреляционных функций – экспоненциальный ($R(\tau) = e^{-\beta|\tau|}$). Входные процессы сгенерированы в соответствии с алгоритмом, изложенным в [11, 8, 19], 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.

Второй вид входных сигналов – нормальные процессы с одинаковыми одномерными плотностями распределения вероятностей и различными корреляционными функциями. Различия КФ понимаются в том же смысле, что и для второго вида входных сигналов. На рисунке 3.7 представлены примеры временных диаграмм процессов с различными функциями корреляции, оценочные значения которых представлены на рисунке 3.9. Однако в отличие от предыдущего случая вид корреляционных функций – экспоненциально-косинусный ($R(\tau) = e^{-\beta|\tau|} \cos \omega_0 \tau$). Физической моделью рекуррентных процедур, использованных в этом случае, является пропускание широкополосного нормального шума через контур с центральной частотой $f_{Ц}$. В данном случае четыре класса случайных процессов были сгенерированы для значений f_0 , равных $f_0 = 20$ Гц, $f_1 = 80$ Гц, $f_2 = 200$ Гц, $f_3 = 400$ Гц.




Рисунок 3.6 – Входной сигнал I

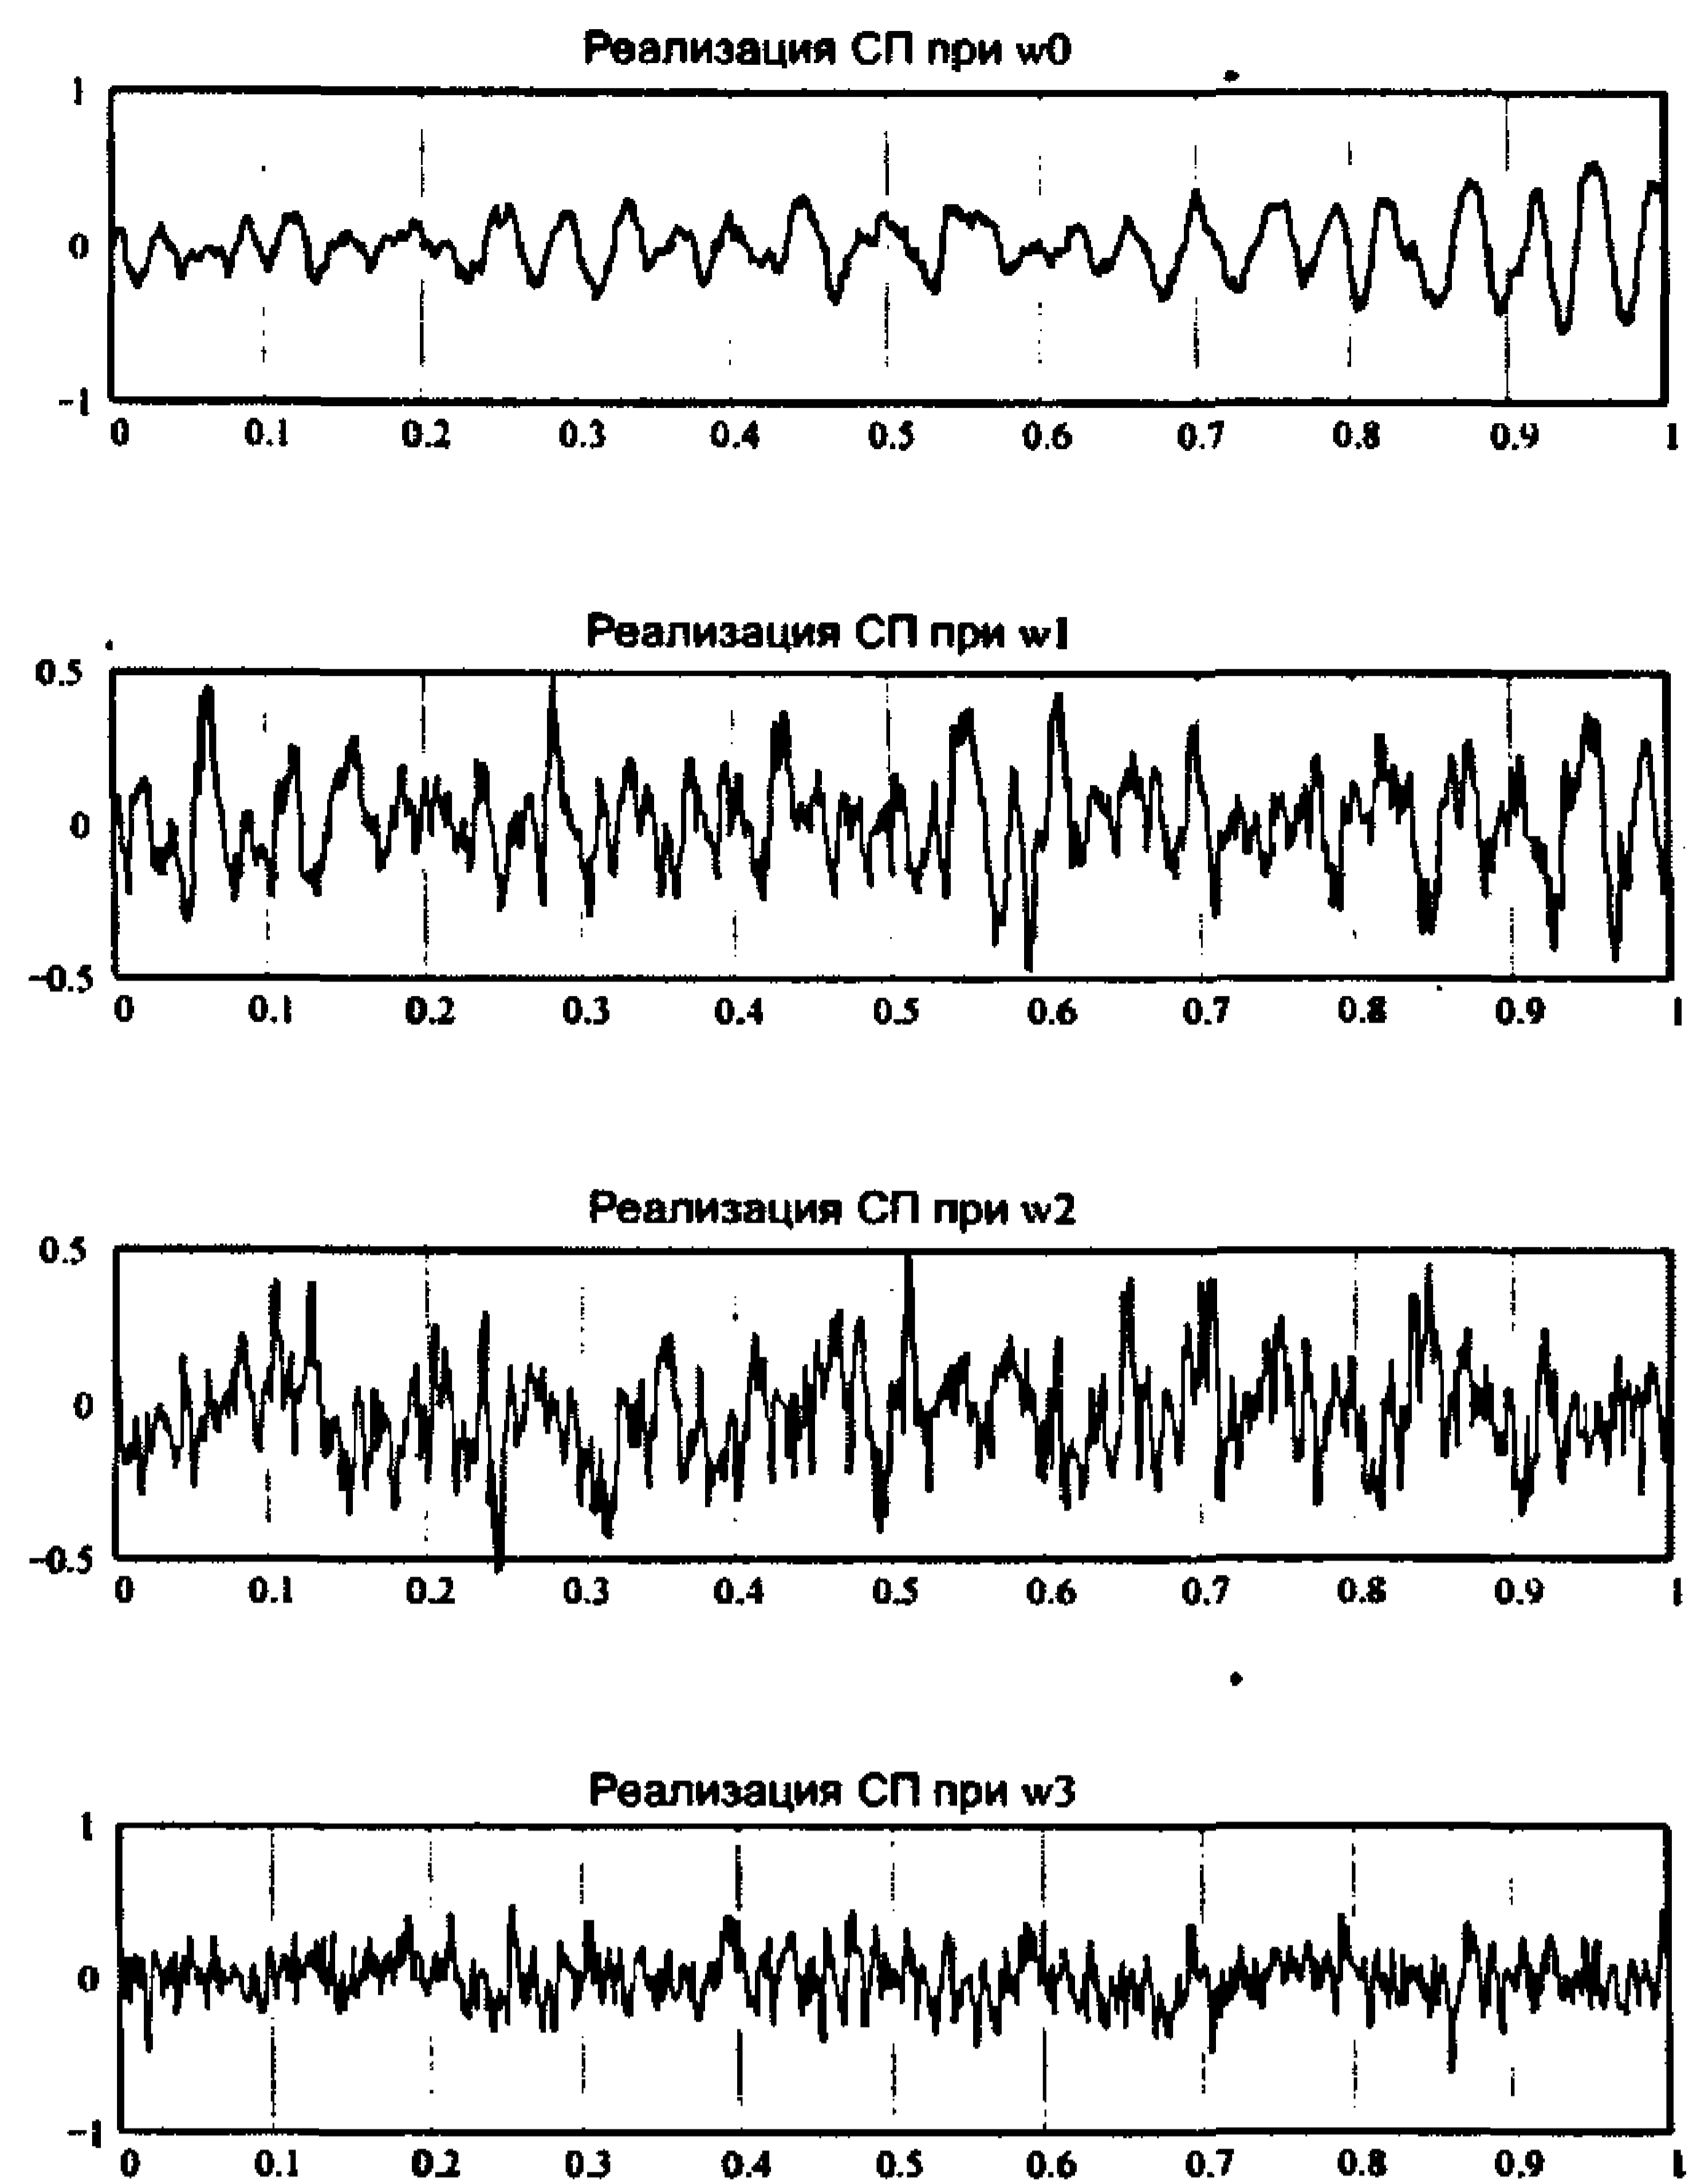


Рисунок 3.7 – Входной сигнал II




Рисунок 3.8 – Оценки корреляционных функций сигнала I




Рисунок 3.9 – Оценки корреляционных функций сигнала II

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 3.10, а выборочная КФ для одного из процессов – на рисунке 3.11.




Рисунок 3.10 – Плотности распределения вероятностей опорных процессов




Рисунок 3.11 – Оценки выборочной корреляционных функций опорного процесса

На рисунках 3.12 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 двум видам входных процессов, приведенных на рисунках 3.6 и 3.7. На указанных рисунках 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 входных процессов.

Таблица 3.1 – Радиусы собственных областей классов для двух видов входных процессов

	класс 0	класс 1	класс 2	класс 3
I входной сигнал	0.163	0.109	0.080	0.082
II входной сигнал	0.213	0.116	0.107	0.099

Такое компактное расположение графического материала, иллюстрирующего результаты моделирования, возможно несколько неудачно с точки

зрения сложности восприятия, однако довольно удобно для сравнительного анализа эффективности сформированных признаков. Более наглядное представление о последовательности получения данных результатов можно получить из листинга программы моделирования.




Рисунок 3.12 – Графики изменения значений МО, СКО и относительного СКО признаков




Рисунок 3.13 – Графики изменения значений МО, СКО и относительного СКО признаков

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.3.12, 3.13 видно, что в случае классификации процессов с одинаковыми одномерными плотностями распределений и различными КФ (рисунки 3.6 и 3.7) наибольшей разделяющей способностью обладают те опорные сигналы, плотность вероятности которых больше остальных перекрывается с плотностью вероятности входного сигнала, подлежащего классификации. Так, максимальное различие между МО признаков (рисунки 3.12.а, 3.13.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 входных сигналов I; при этом относительные значения среднеквадратических дисперсий признаков минимальны (рисунки 3.12.в, 3.13.в).

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 $[a, b]$, что обеспечит хотя бы для одного из признаков максимальное перекрытие плотностей вероятности входных и опорных процессов;

- для того, чтобы избежать генерирования "лишних" опорных сигналов, можно применять методы разведочного анализа данных (РАД) [2, 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. 1.4, 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 $\rho = p(2m+n)$, 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 p 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 p выборок [80]. Задача минимизации общего числа выборок уже рассматривалась в предыдущих пунктах и основные ее аспекты уже сформулированы. Необходимо только добавить, что, как уже указывалось, 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 [22], что количество отсчетов входного сигнала, необходимое для формирования одного признака и объем выборки, по которой формируется собственная область класса, связаны напрямую. 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 из исходного сигнала, 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 статистическое моделирование по программе, представленной в приложении А. Листинг программы содержит графики для $m_r(i)$ и $\sigma_r(i)$ - зависимостей математического ожидания и среднеквадратического отклонения признаков от количества отсчетов сигналов, используемых для их формирования, а также зависимости $Rad(i)$ для радиусов собственных областей заданных классов сигналов, получаемых при обучении классификатора. Структурная схема числового эксперимента может быть представлена в виде рисунок 3.14. На рисунках 3.15 – 3.22 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 входные сигналы, подлежащие распознаванию, одного вида. Они соответствуют I виду сигналов в предыдущем пункте, то есть нормальные процессы с одинаковыми одномерными плотностями распределений (рисунок 3.15) и различными корреляционными функциями. Вид КФ – экспоненциальный. Оценочные значения КФ сгенерированных входных процессов представлены на графиках на рисунке 3.16. Множество входных процессов разбито на 4 класса, соответствующие корреляционным функциям на рисунке 3.16.

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 3.17, а выборочная КФ для одного из процессов – на рисунке 3.18.

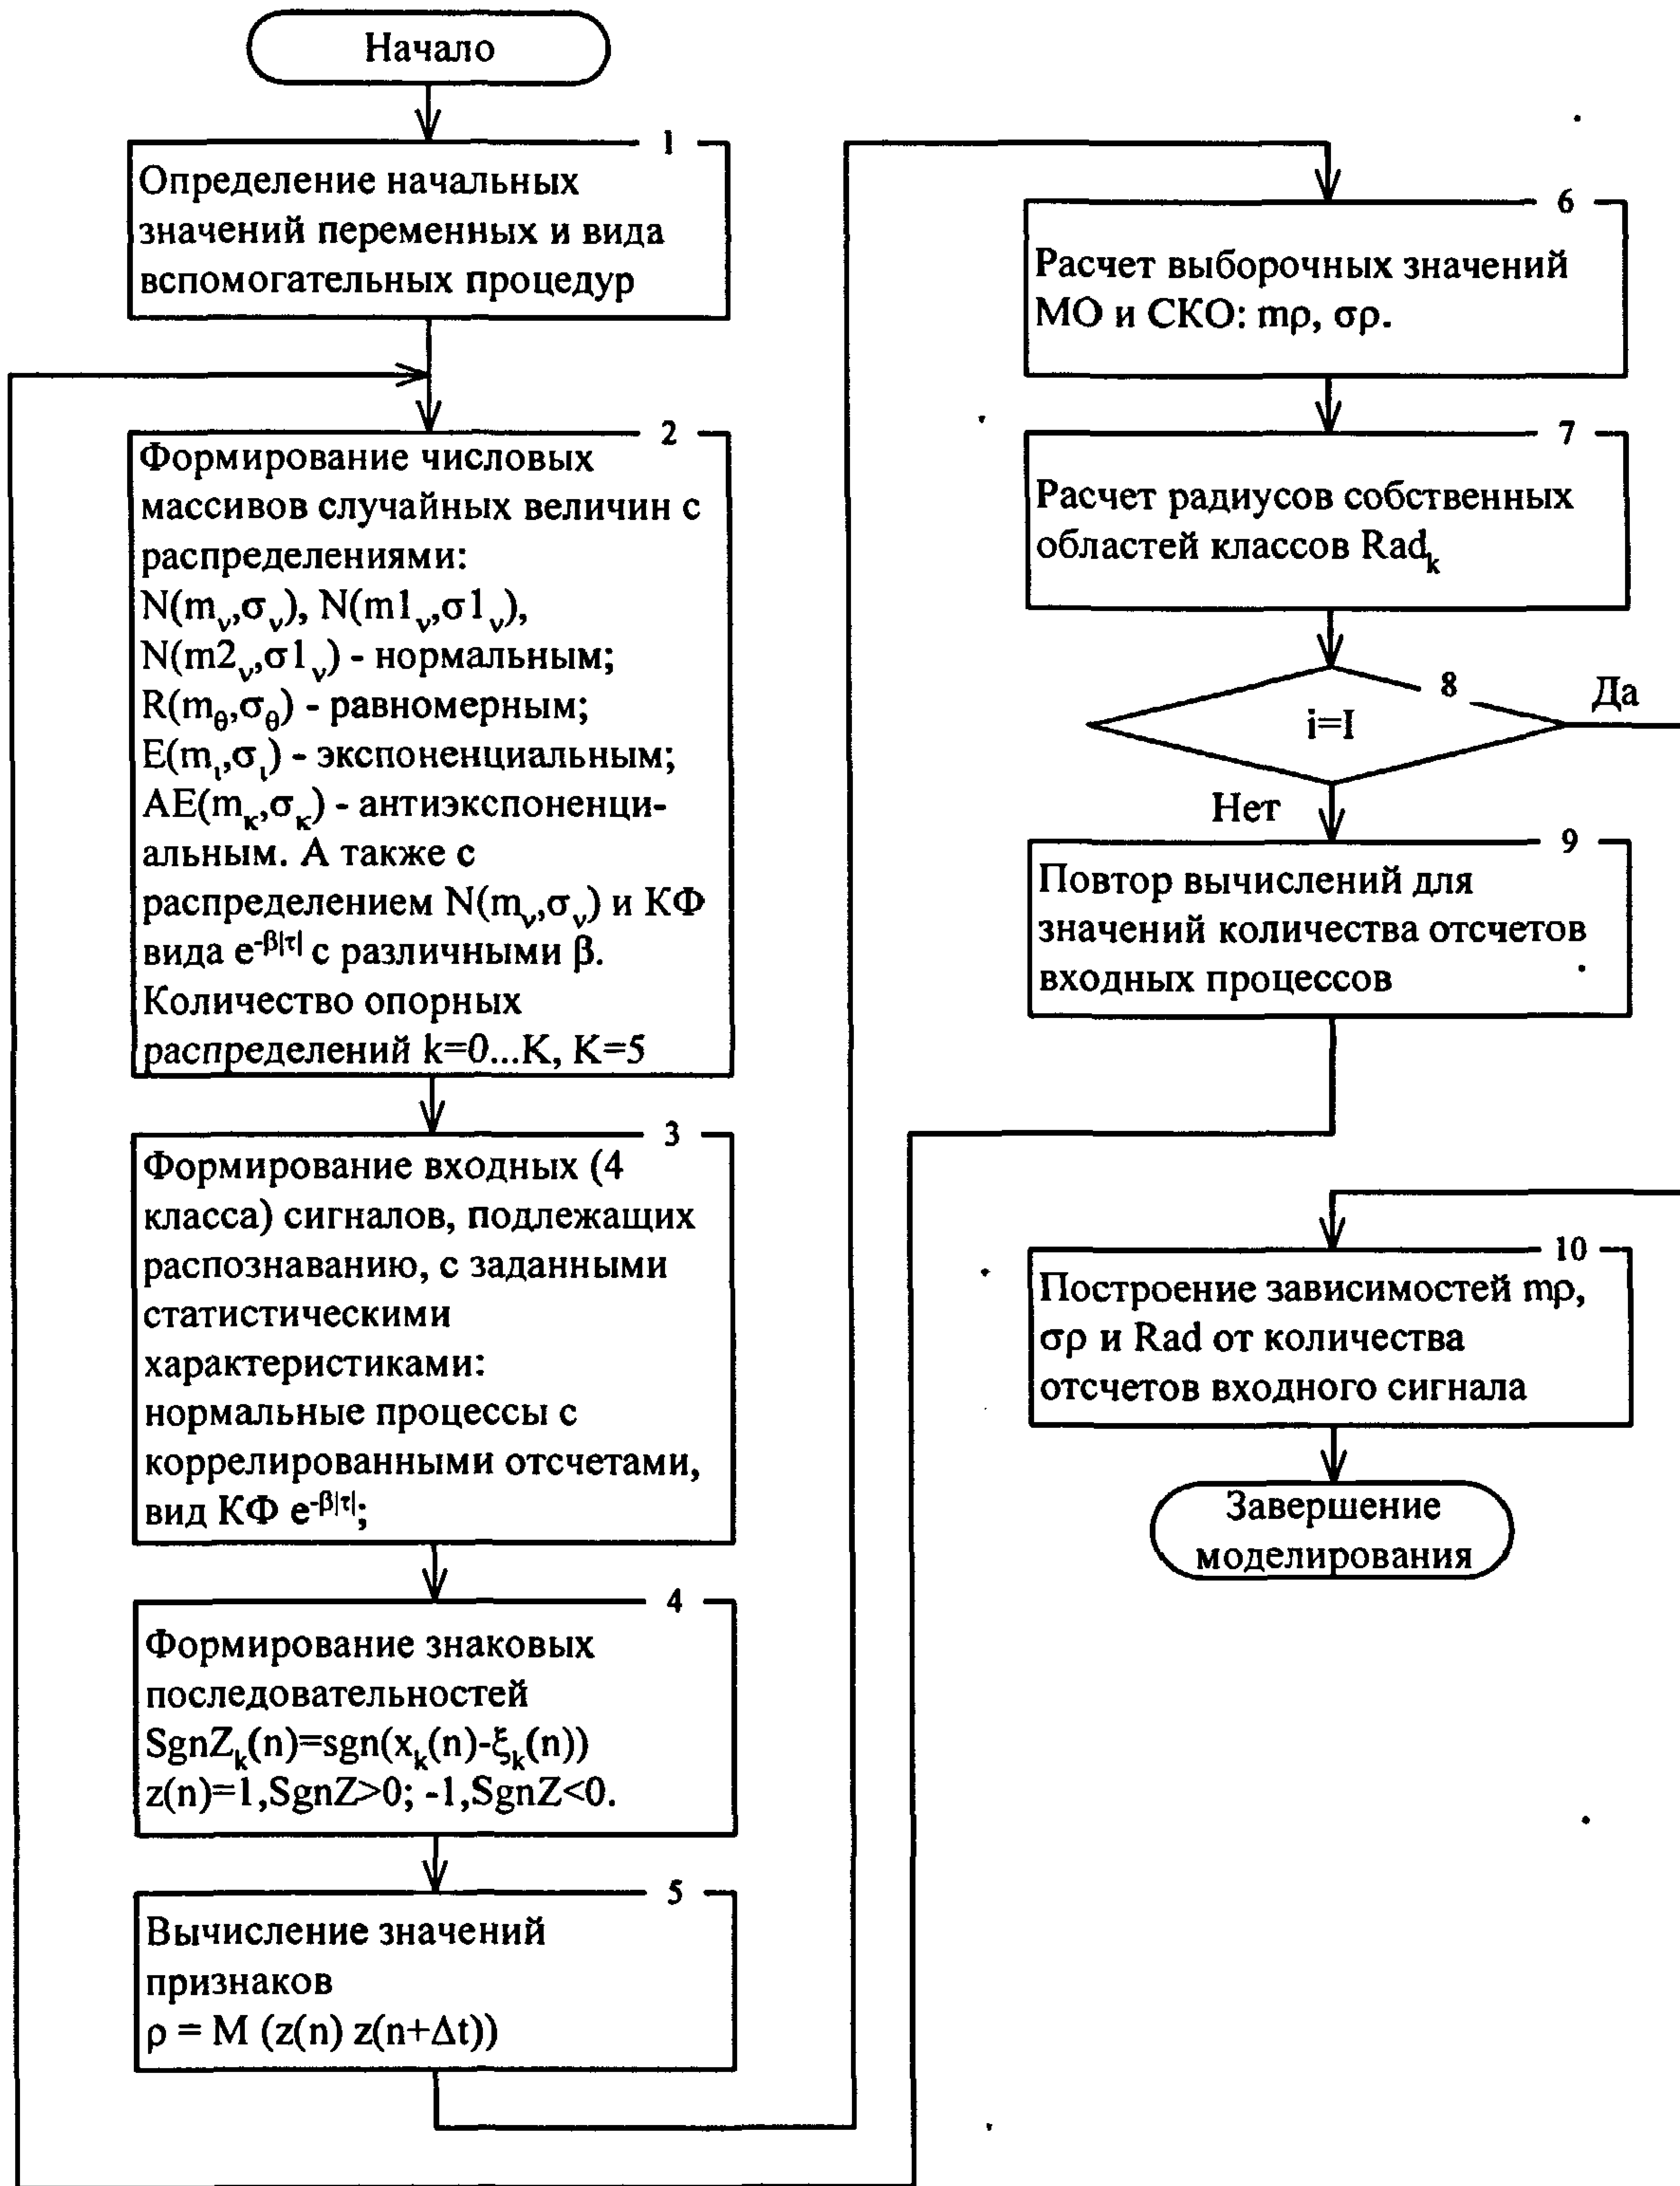


Рисунок 3.14 – Структурная схема программы моделирования работы НК (формирование классификационных признаков при различных интервалах обучения)




Рисунок 3.15 – Плотность распределения вероятностей входных процессов




Рисунок 3.16 – Оценки КФ четырех классов входных процессов

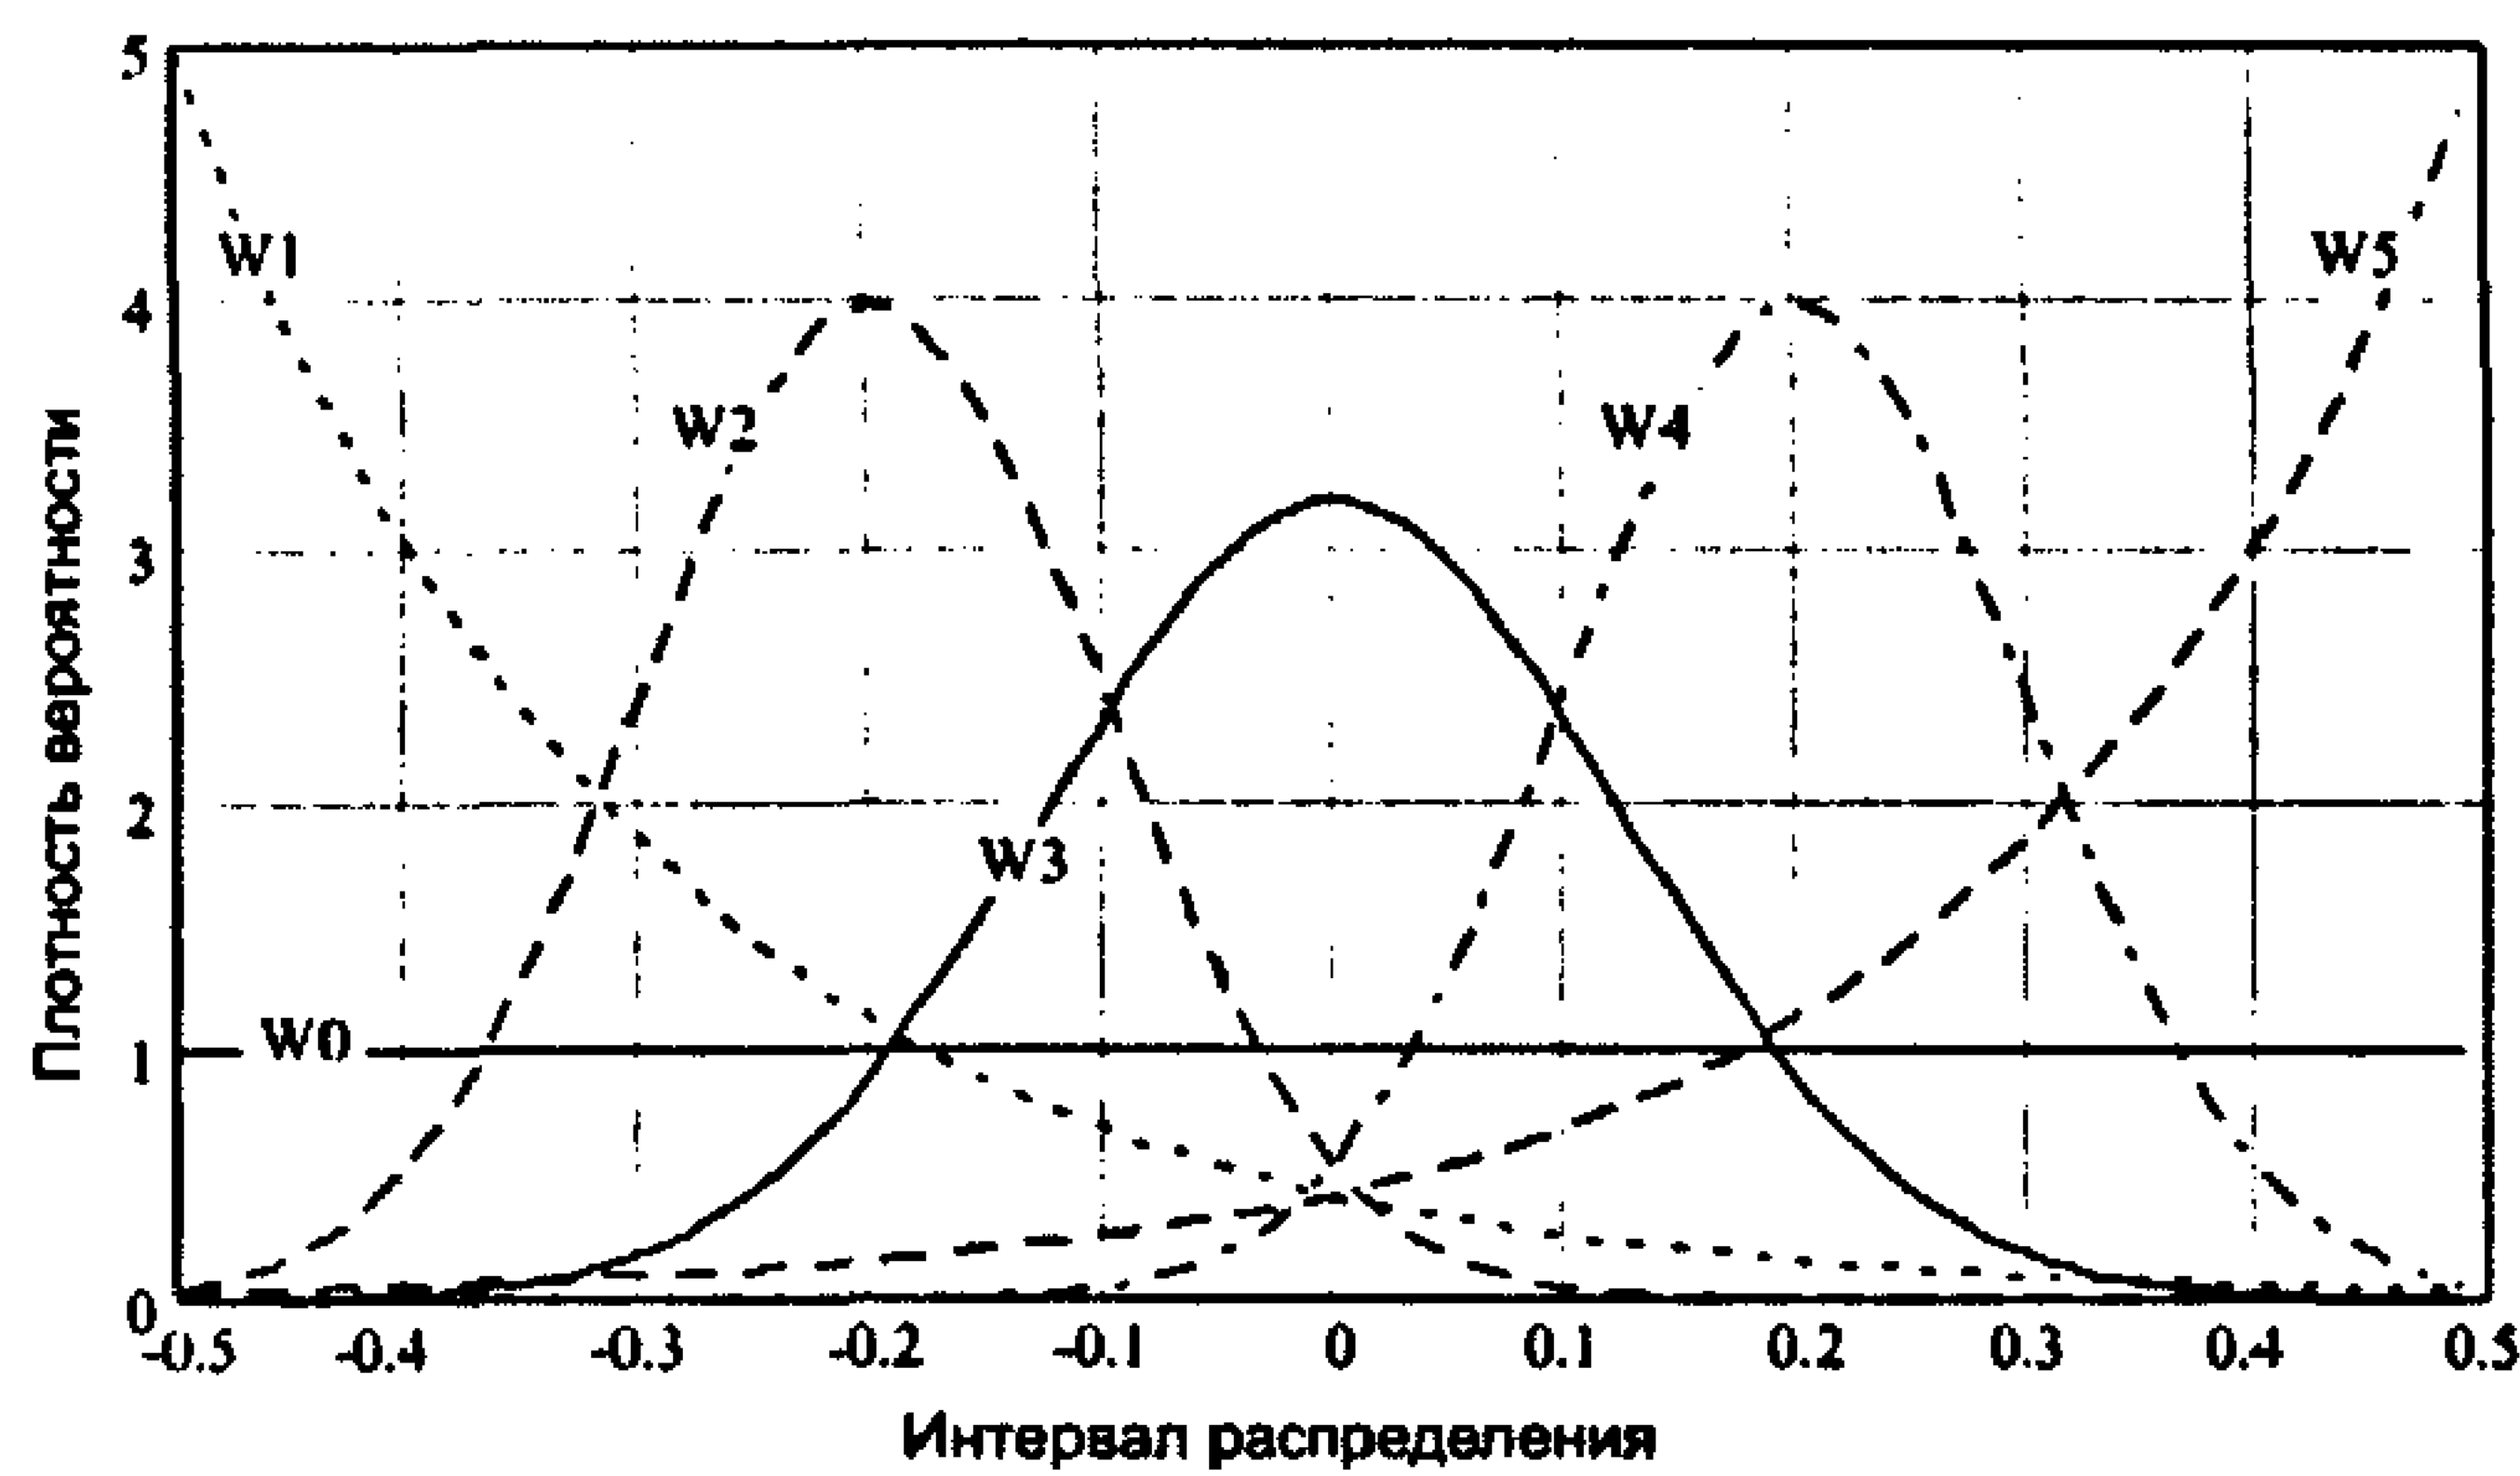


Рисунок 3.17 – Плотности распределения вероятностей опорных процессов



Рисунок 3.18 – Оценка КФ одного из опорных процессов

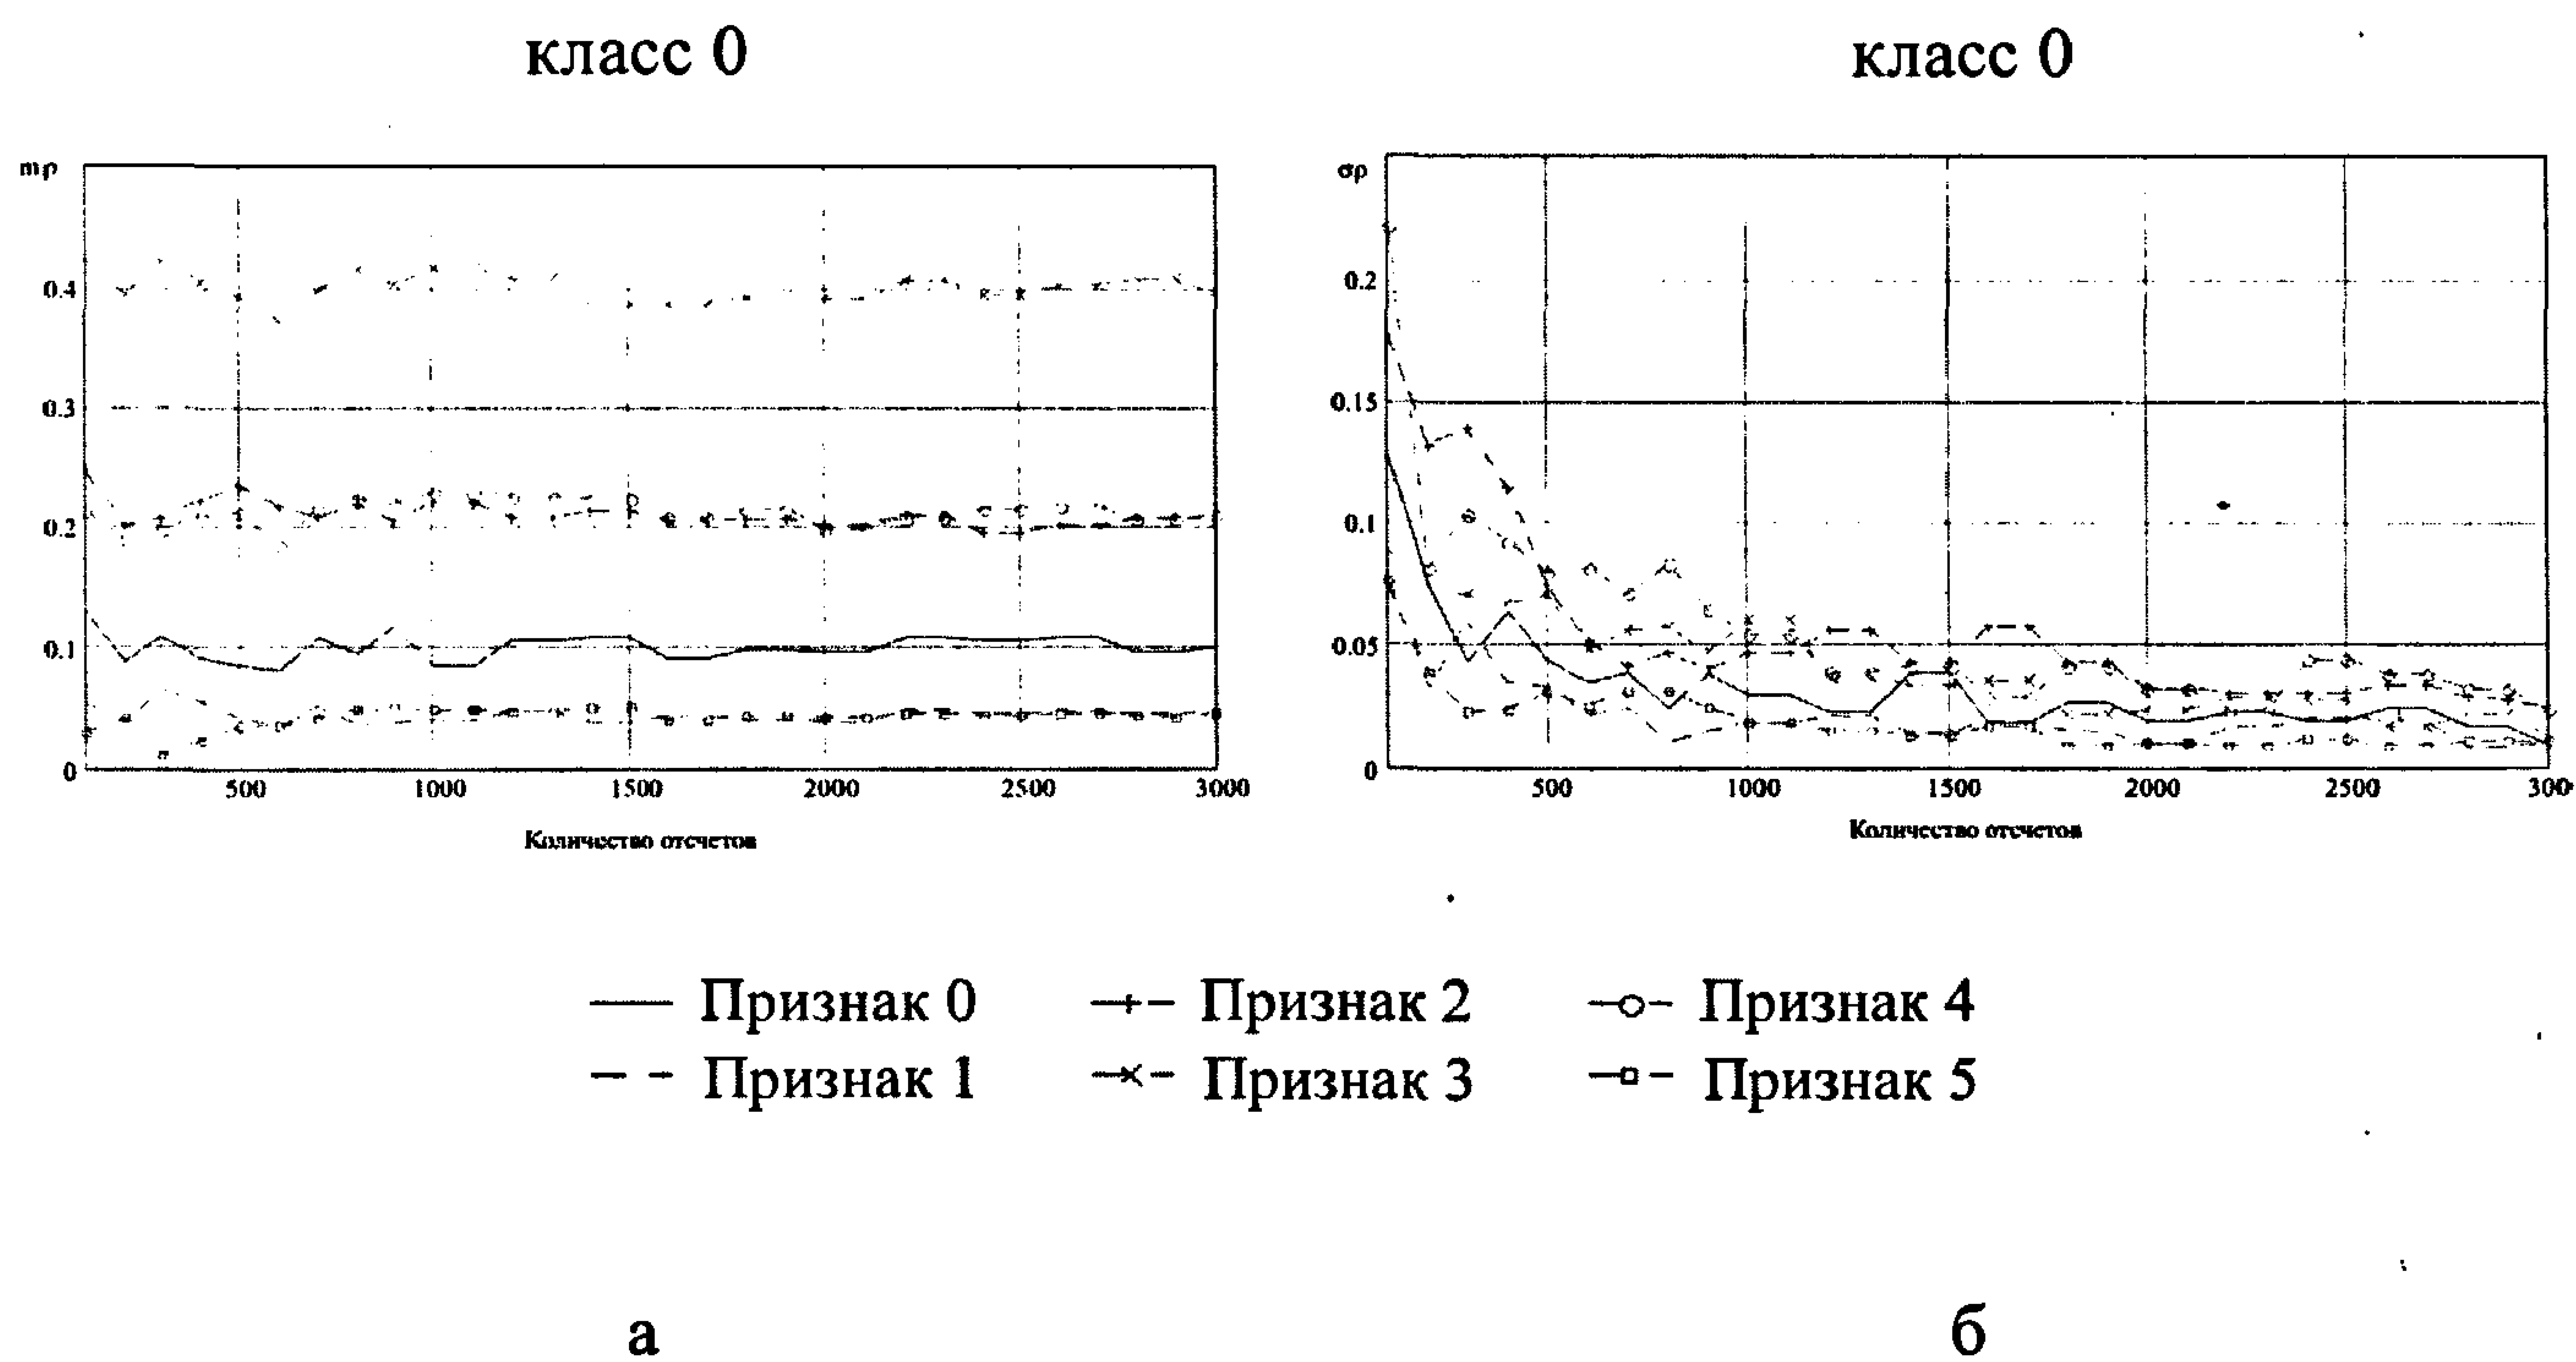


Рисунок 3.19 – Графики изменения МО и СКО оценок признаков класса при увеличении количества отсчетов в обучающей выборке

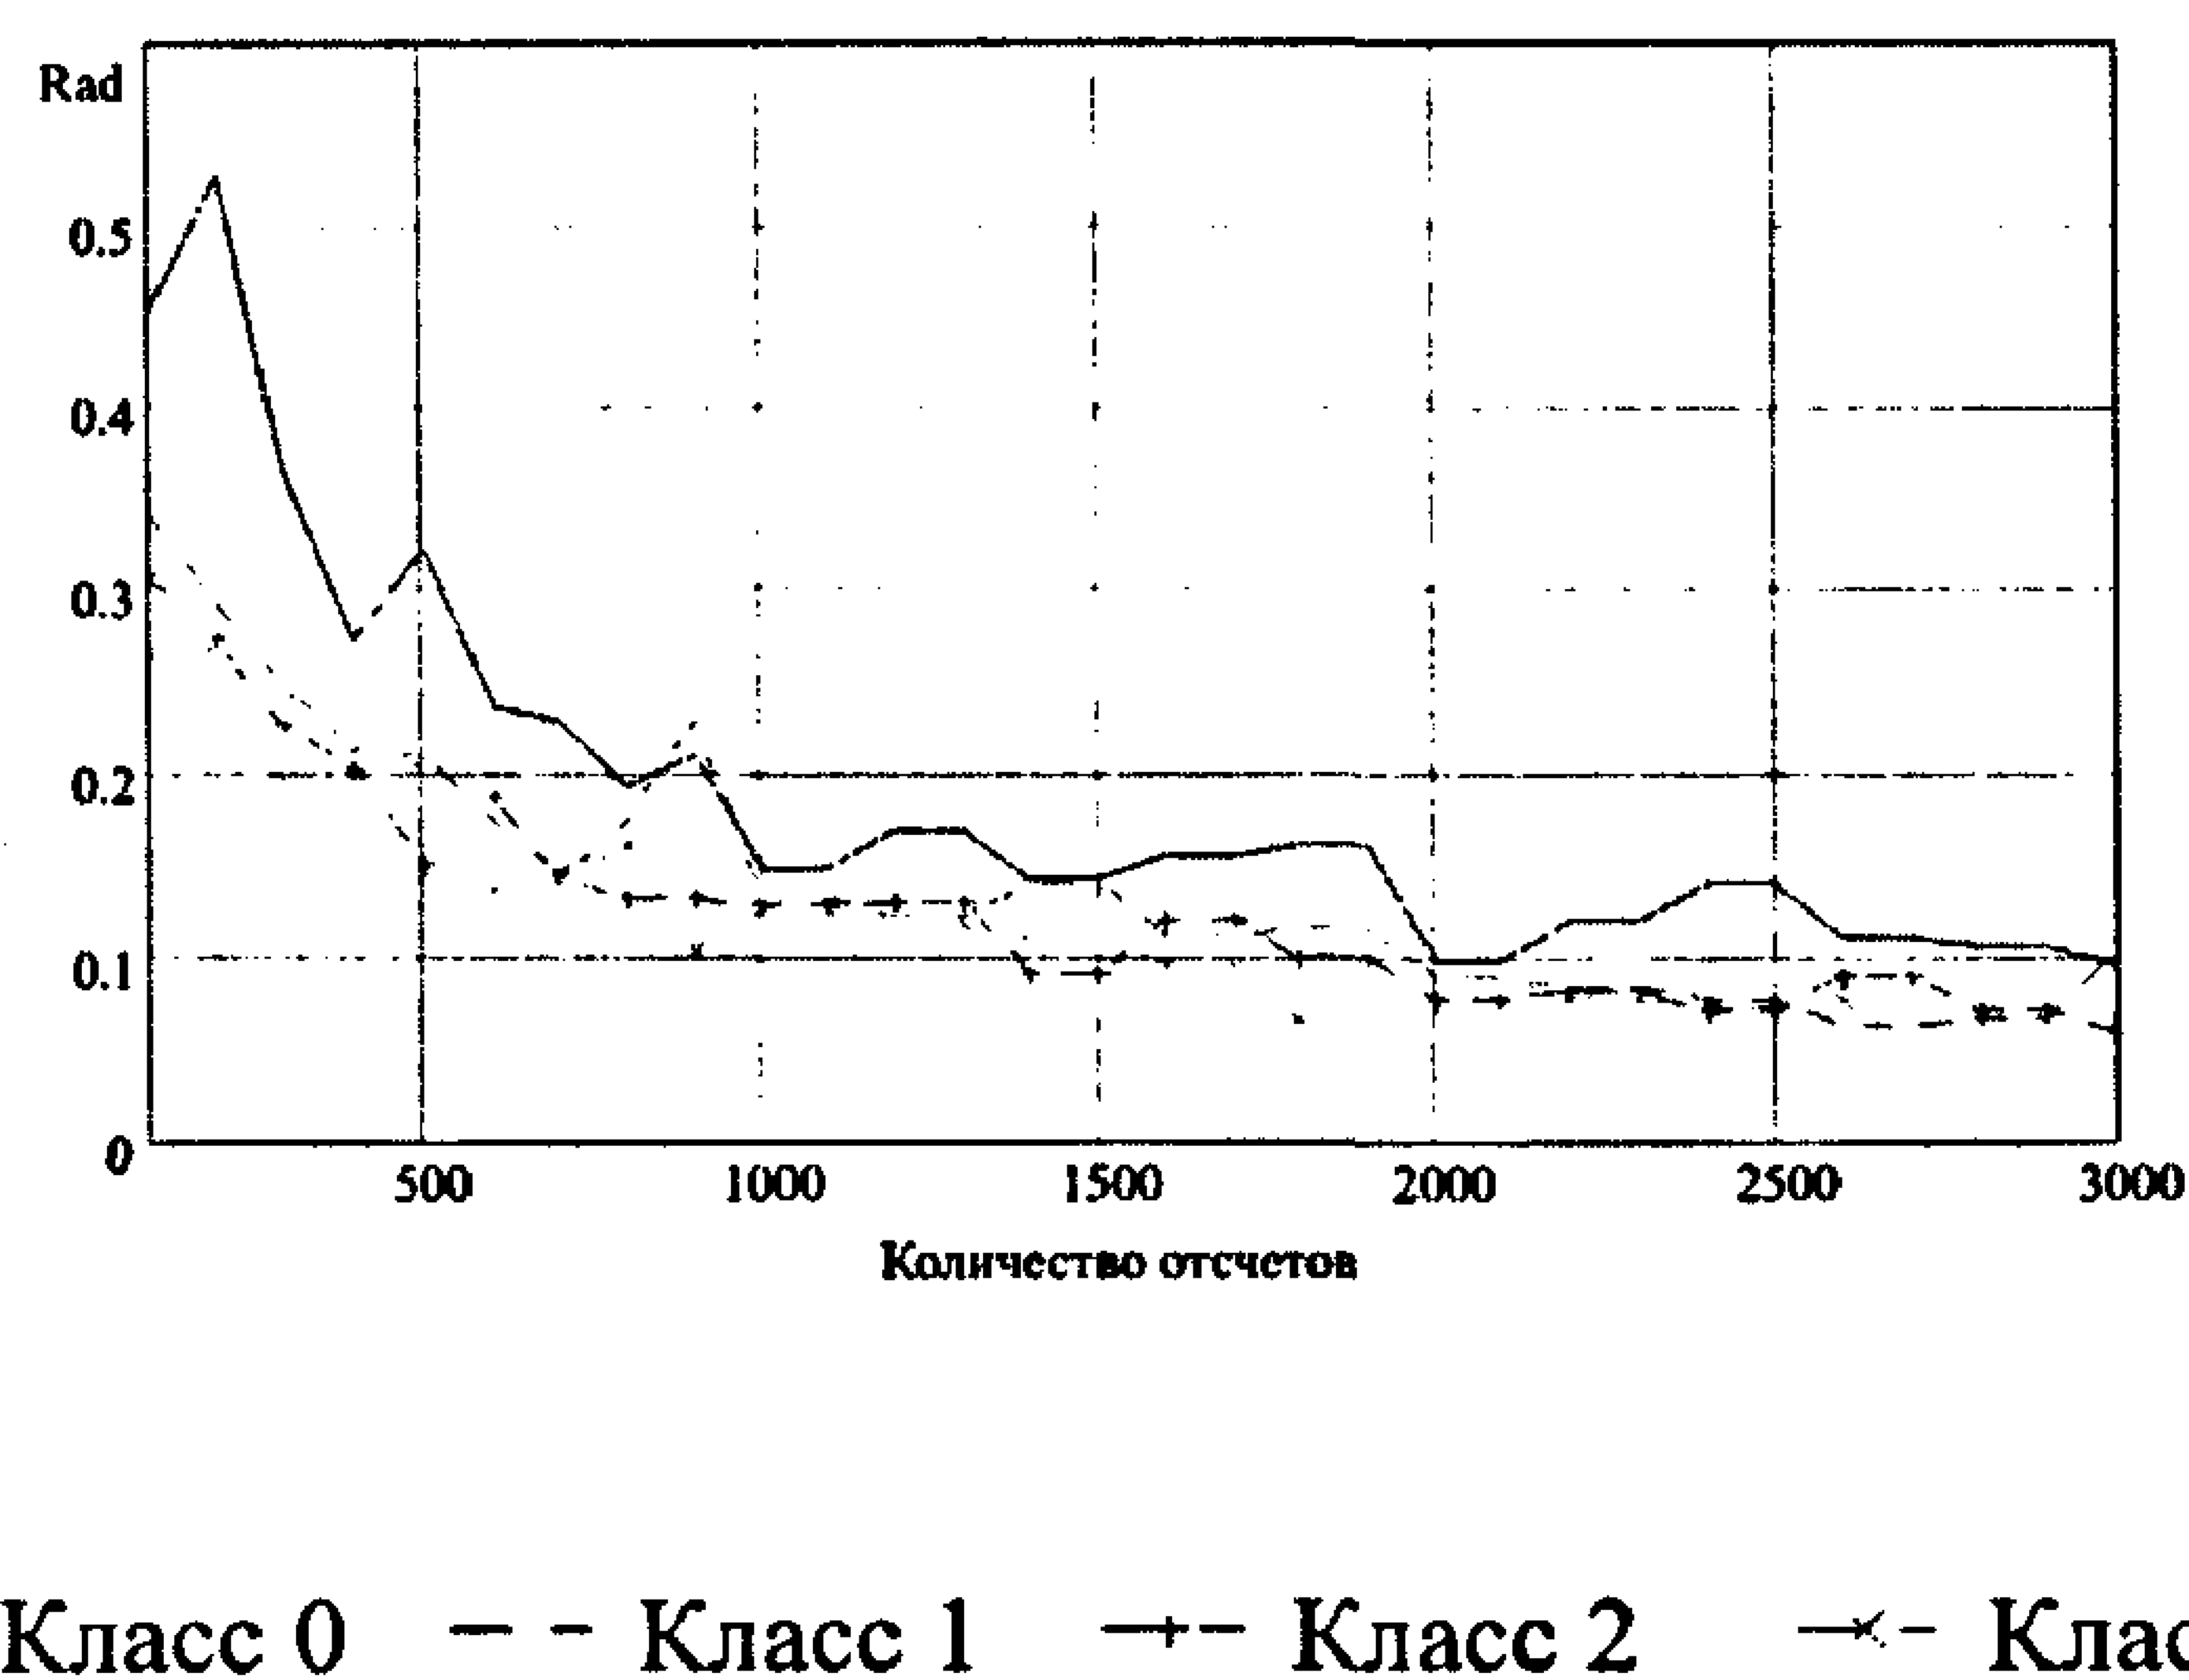


Рисунок 3.20 – График изменения радиусов собственных областей классов при увеличении количества отсчетов в обучающей выборке

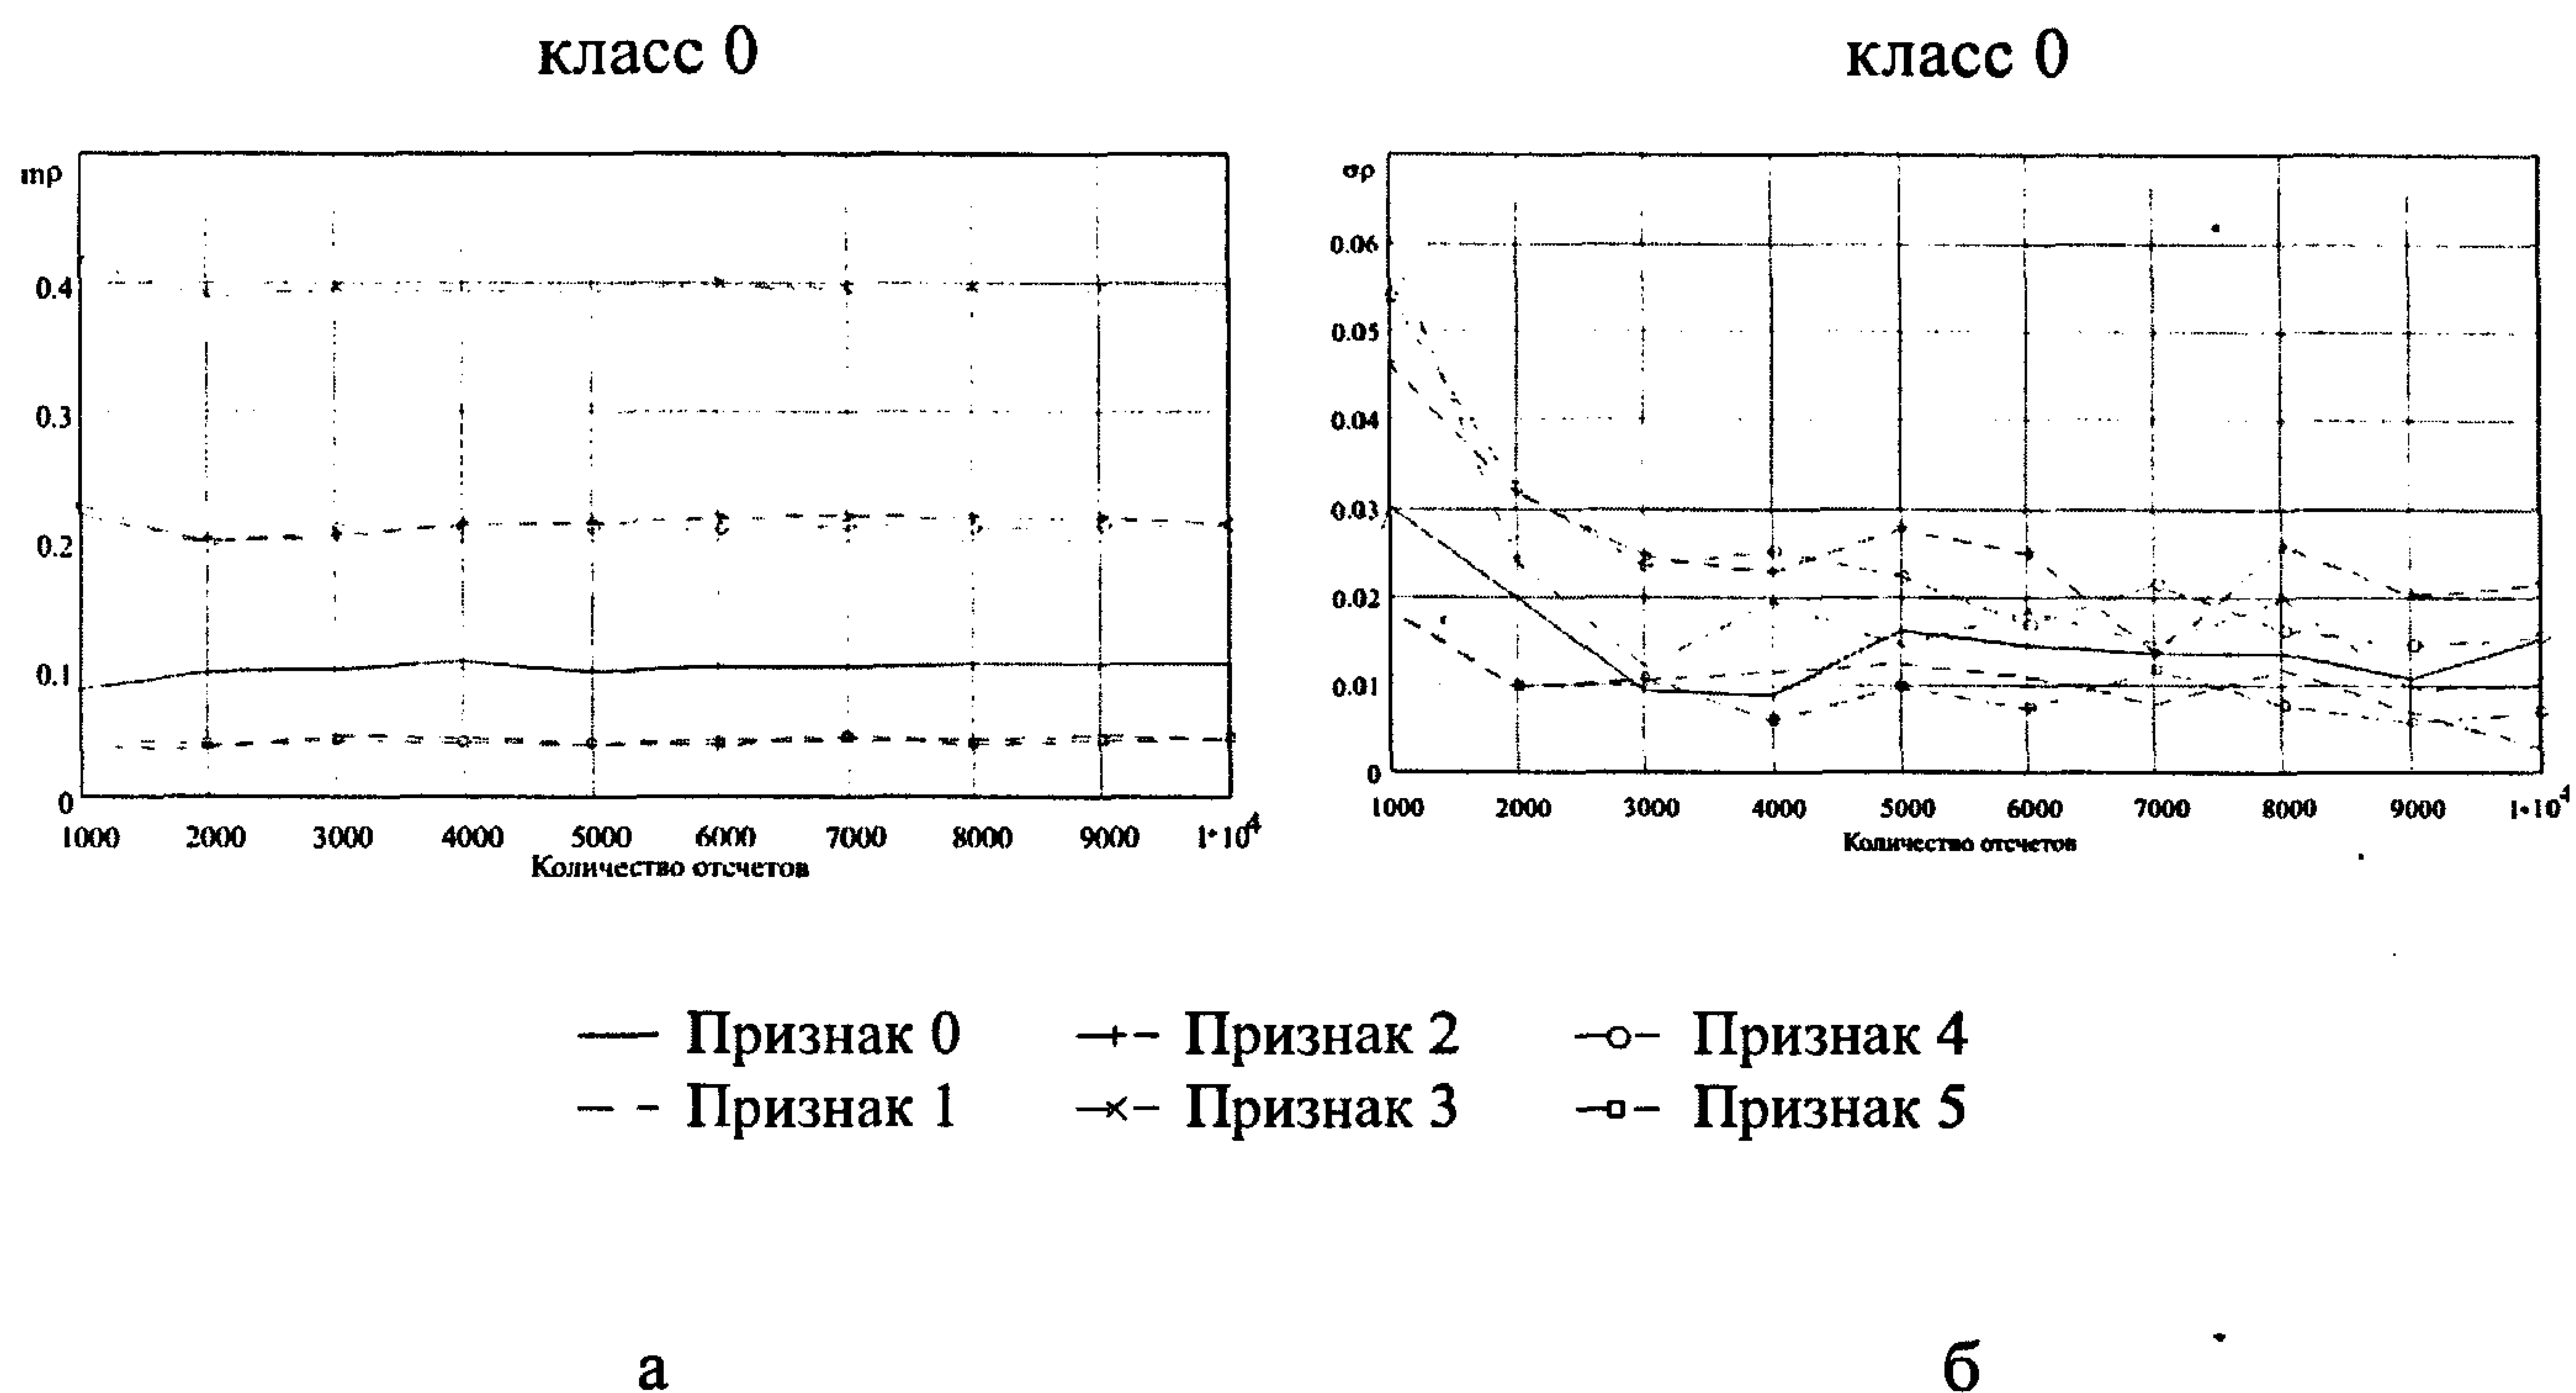


Рисунок 3.21 – Графики изменения МО и СКО оценок признаков класса при увеличении количества отсчетов в обучающей выборке




Рисунок 3.22 – График изменения радиусов собственных областей классов при увеличении количества отсчетов в обучающей выборке

На рисунках 3.19 и 3.20 представлены графики зависимостей значений МО, СКО и радиусов собственных областей классов, полученных при обучении, от количества отсчетов, взятых из входного сигнала, для формирования одного значения признака. Опорные процессы – некоррелированные, с модами плотностей вероятности, распределенными в диапазоне значений сигналов. Радиусы найдены исходя из количества отсчетов признаков каждого класса, равного 10. На данных графиках представлены зависимости при изменении числа отсчетов классифицируемых сигналов от 100 до 3000. На рисунках 3.21 и 3.22 представлены те же зависимости, но при изменении числа отсчетов классифицируемых сигналов от 10^3 до 10^4 . Графики для МО и СКО приведены только для одного из четырех исследуемых классов.

Анализируя полученные результаты можно отметить следующее.

1. Из рисунков 3.19 – 3.22 видно, что увеличение количества отсчетов входного процесса для формирования одного признака ведет к "стабилизации" оценок МО и уменьшению СКО. 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 признаков от времени обучения, при симметричных распределениях классифицируемых процессов эффект использования опорных сигналов с равномерно распределенными по интервалу $[a, b]$ модами симметричен (на рис.3.19.а, 3.21.а оценки МО признаков класса 1 и 5, 2 и 4 практически совпадают). То есть в данном случае можно использовать

опорные процессы с модами, равномерно распределенными только в половине интервала $[a, b]$.

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 $20\tau_{м.к.}$; 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. Исследованы зависимости показателей качества разработанного алгоритма от вида и количества опорных распределений и от времени обучения и классификации. Данные зависимости 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 ИЗОБРАЖЕНИЙ

4.1 Задачи исследования

Основной задачей, решаемой в данной главе, является моделирование эффективности работы разработанного непараметрического классификатора в сравнение с известным непараметрическим классификатором k -ближайших соседей. Сравнительный эксперимент будет проводиться на предложенных моделях сигналов изображений, определение вида зависимостей вероятности классификации от количества объектов.

Для проведения экспериментальной проверки эффективности работы разработанного классификатора исходными данными будут использованы сигналы оцифрованных изображений реальных объектов, принадлежащих четырем классам объектов.

4.2 Методы моделирования устройств обработки сигналов, основанные на использовании современных пакетов программ для математического моделирования

Построение цифровой модели устройств различных физических объектов сопровождается решением следующих задач [88, 43]:

- 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, представляемых современными пакетами для математического моделирования. Структура цифровой модели определяется видом математического описания структурных компонент классификатора. Возможные методы построения цифровой модели (и цифрового моделирования) удобно классифицировать в следующем виде[88, 43]:

- 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.

Представленная классификация носит приближенный характер и полностью не отражает многообразия существующих методов, однако позволяет подобрать подходящие для решаемых задач методы моделирования.

Наиболее универсальным из представленных методов моделирования устройств обработки сигналов является метод статистических испытаний (МСИ) [43], который нашел широкое применение на практике и используется для анализа как линейных, так и нелинейных цепей. В основе метода лежат предельные соотношения теории вероятностей – центральная предельная теорема и закон больших чисел. Основное достоинство МСИ заключается в том, что при точном знании математических моделей системы и случайных внешних воздействий позволяет получить результаты, не отличающиеся от натурального

эксперимента. Указанные достоинства МСИ, а также существо 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 классификации. 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.

Основными требованиями, которые должны быть выполнены на данном этапе, являются адекватность математического описания физической модели системы и минимум вычислительных затрат для получения каждого 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 этих чисел (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 [56]. Точность получаемых результатов с использованием МСИ определяется СКО оценок m_{Θ}^* и D_{Θ}^* , а именно, значениями

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

Как указывается в работах [89, 56], точность МСИ относительно медленно возрастает с увеличением числа испытаний. Так, например, увеличение количества испытаний на два порядка приводит к уменьшению значений σ_{m^*} и σ_{D^*} только на порядок.

Поскольку целью исследования является определение характеристик устойчивости и эффективности предлагаемых алгоритмов с последующим сравнительным анализом, нас будут интересовать 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 моделирования используются пакеты программ для математического моделирования "Mathcad 2003". Использование такого рода пакетов предоставляет исследователю большие возможности. Основные из этих возможностей имеют вид [100]:

1) везде используется привычный способ математической записи. Если существует общепринятый способ изображения уравнений, математической операции или графика, то он используется в пакете;

2) интерфейс WYSIWIG ("то, что Вы видите, это то, что Вы получаете") позволяет получать на экране дисплея всю информацию о расчетах, т.е. не существует скрытой информации;

3) вычислительные алгоритмы имеют модульную структуру. Если какие-то математические возможности, например, комплексная арифметика или матричные операции при вычислениях не используются, то можно считать, что они просто отсутствуют, поскольку программные модули, поддерживающие эти вычисления, не загружаются в оперативную память ЭВМ;

4) числовые алгоритмы, используемые в пакетах, являются общепринятыми и отличаются большой устойчивостью и хорошей изученностью. Вычисление интегралов, обращение матриц и решение уравнений осуществляется надежными стандартными методами.

Посредством программного интерфейса решена задача обмена информацией между пользователем и программным модулем в привычной для пользователя форме. При этом интерфейс, поддерживающий ввод-вывод в виде стандартных формул и таблиц, позволяет сочетать достоинства формульного метода и МСИ построения цифровой модели.

Указанные возможности программных пакетов заставляют изменить подход к проведению числового моделирования. Во-первых, нет необходимости, как это делалось ранее, рассчитывать число шагов программы моделирования с целью их оптимизации, поскольку при выполнении стандартных вычислений используются оптимизированные по этому критерию процедуры. Также нет необходимости разрабатывать формы для представления вводимой и выводимой информации, писать тексты программ известных алгоритмов стандартных математических вычислений, используемых при расчетах (например, процедуры обращения матриц, БПФ и т.п.) – они входят в состав пакета.

Во-вторых, растущая вычислительная мощь современных компьютеров, позволяет сократить время вычисления даже очень сложных пакетов программ моделирования до величин, имеющих порядок десятков секунд. И тенденция к

уменьшению времени вычисления будет сохраняться достаточно продолжительное время.

Заметим, однако, что остаются ситуации, когда использование универсальных пакетов не целесообразно. В силу их универсальности, вычисления определенных выражений (в частности, содержащие большое количество вложенных циклов) с использованием этих пакетов занимают значительно больше времени, чем написание и использование программ на языках высокого уровня (например, Delphi, СИ++). Но для таких ситуаций в пакетах Mathcad имеется возможность дополнить ядро, производящее вычисления, функциями пользователя, которые представляют собой программные модули, написанные на языке СИ, и поддерживающие протокол обмена данными между программами, входящими в состав пакета.

Основной проблемой при моделировании с использованием специальных пакетов, остается точность результатов моделирования. При решении некорректных задач (вид решения которых, существенно зависит от изменения исходных данных) необходимо так строить вычисления, чтобы ошибка, получаемая на каждом этапе, была минимальной или компенсировалась на последующем шаге вычислений. В целом это оказывается недостаточным. Необходимо, по возможности, располагать блоки вычислительных операций в таком порядке, который обеспечивает наибольшую устойчивость результатов моделирования к изменяющимся входным данным. При использовании математических пакетов, в которых вычисления производятся, как правило, в порядке расположения формул, это приводит к необходимости изменении формул так, чтобы обеспечить передачу результатов вычислений в нужном порядке. Многочисленные примеры в пакете Mathcad, подтверждающие данные выводы, приведены в [48, 95].

4.3 Моделирование алгоритмов непараметрического распознавания

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:

- 1) длительности интервала наблюдения или количества отсчетов входного сигнала, необходимых для формирования одного признака;
- 2) размерности вектора признаков r ;
- 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.

Моделирование 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 $P_{ош i}$ 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 опорными 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 программы представлен в приложении А и Б, на основе которых были получены результаты моделирования.

Моделирование проводилось для 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.

На рисунке 4.5 представлены графики зависимости суммарных вероятностей ошибок от количества объектов обучения для случая двухальтернативного распознавания при некоррелированных опорных процессах. На входе системы те же сигналы, но выбранные парами соответствующие увеличению расстояния между классами в признаковом пространстве.

Анализ полученных результатов приводит к следующему выводу.

1) Минимум вероятности ошибки классификации достигается при росте объема обучающей выборки;

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

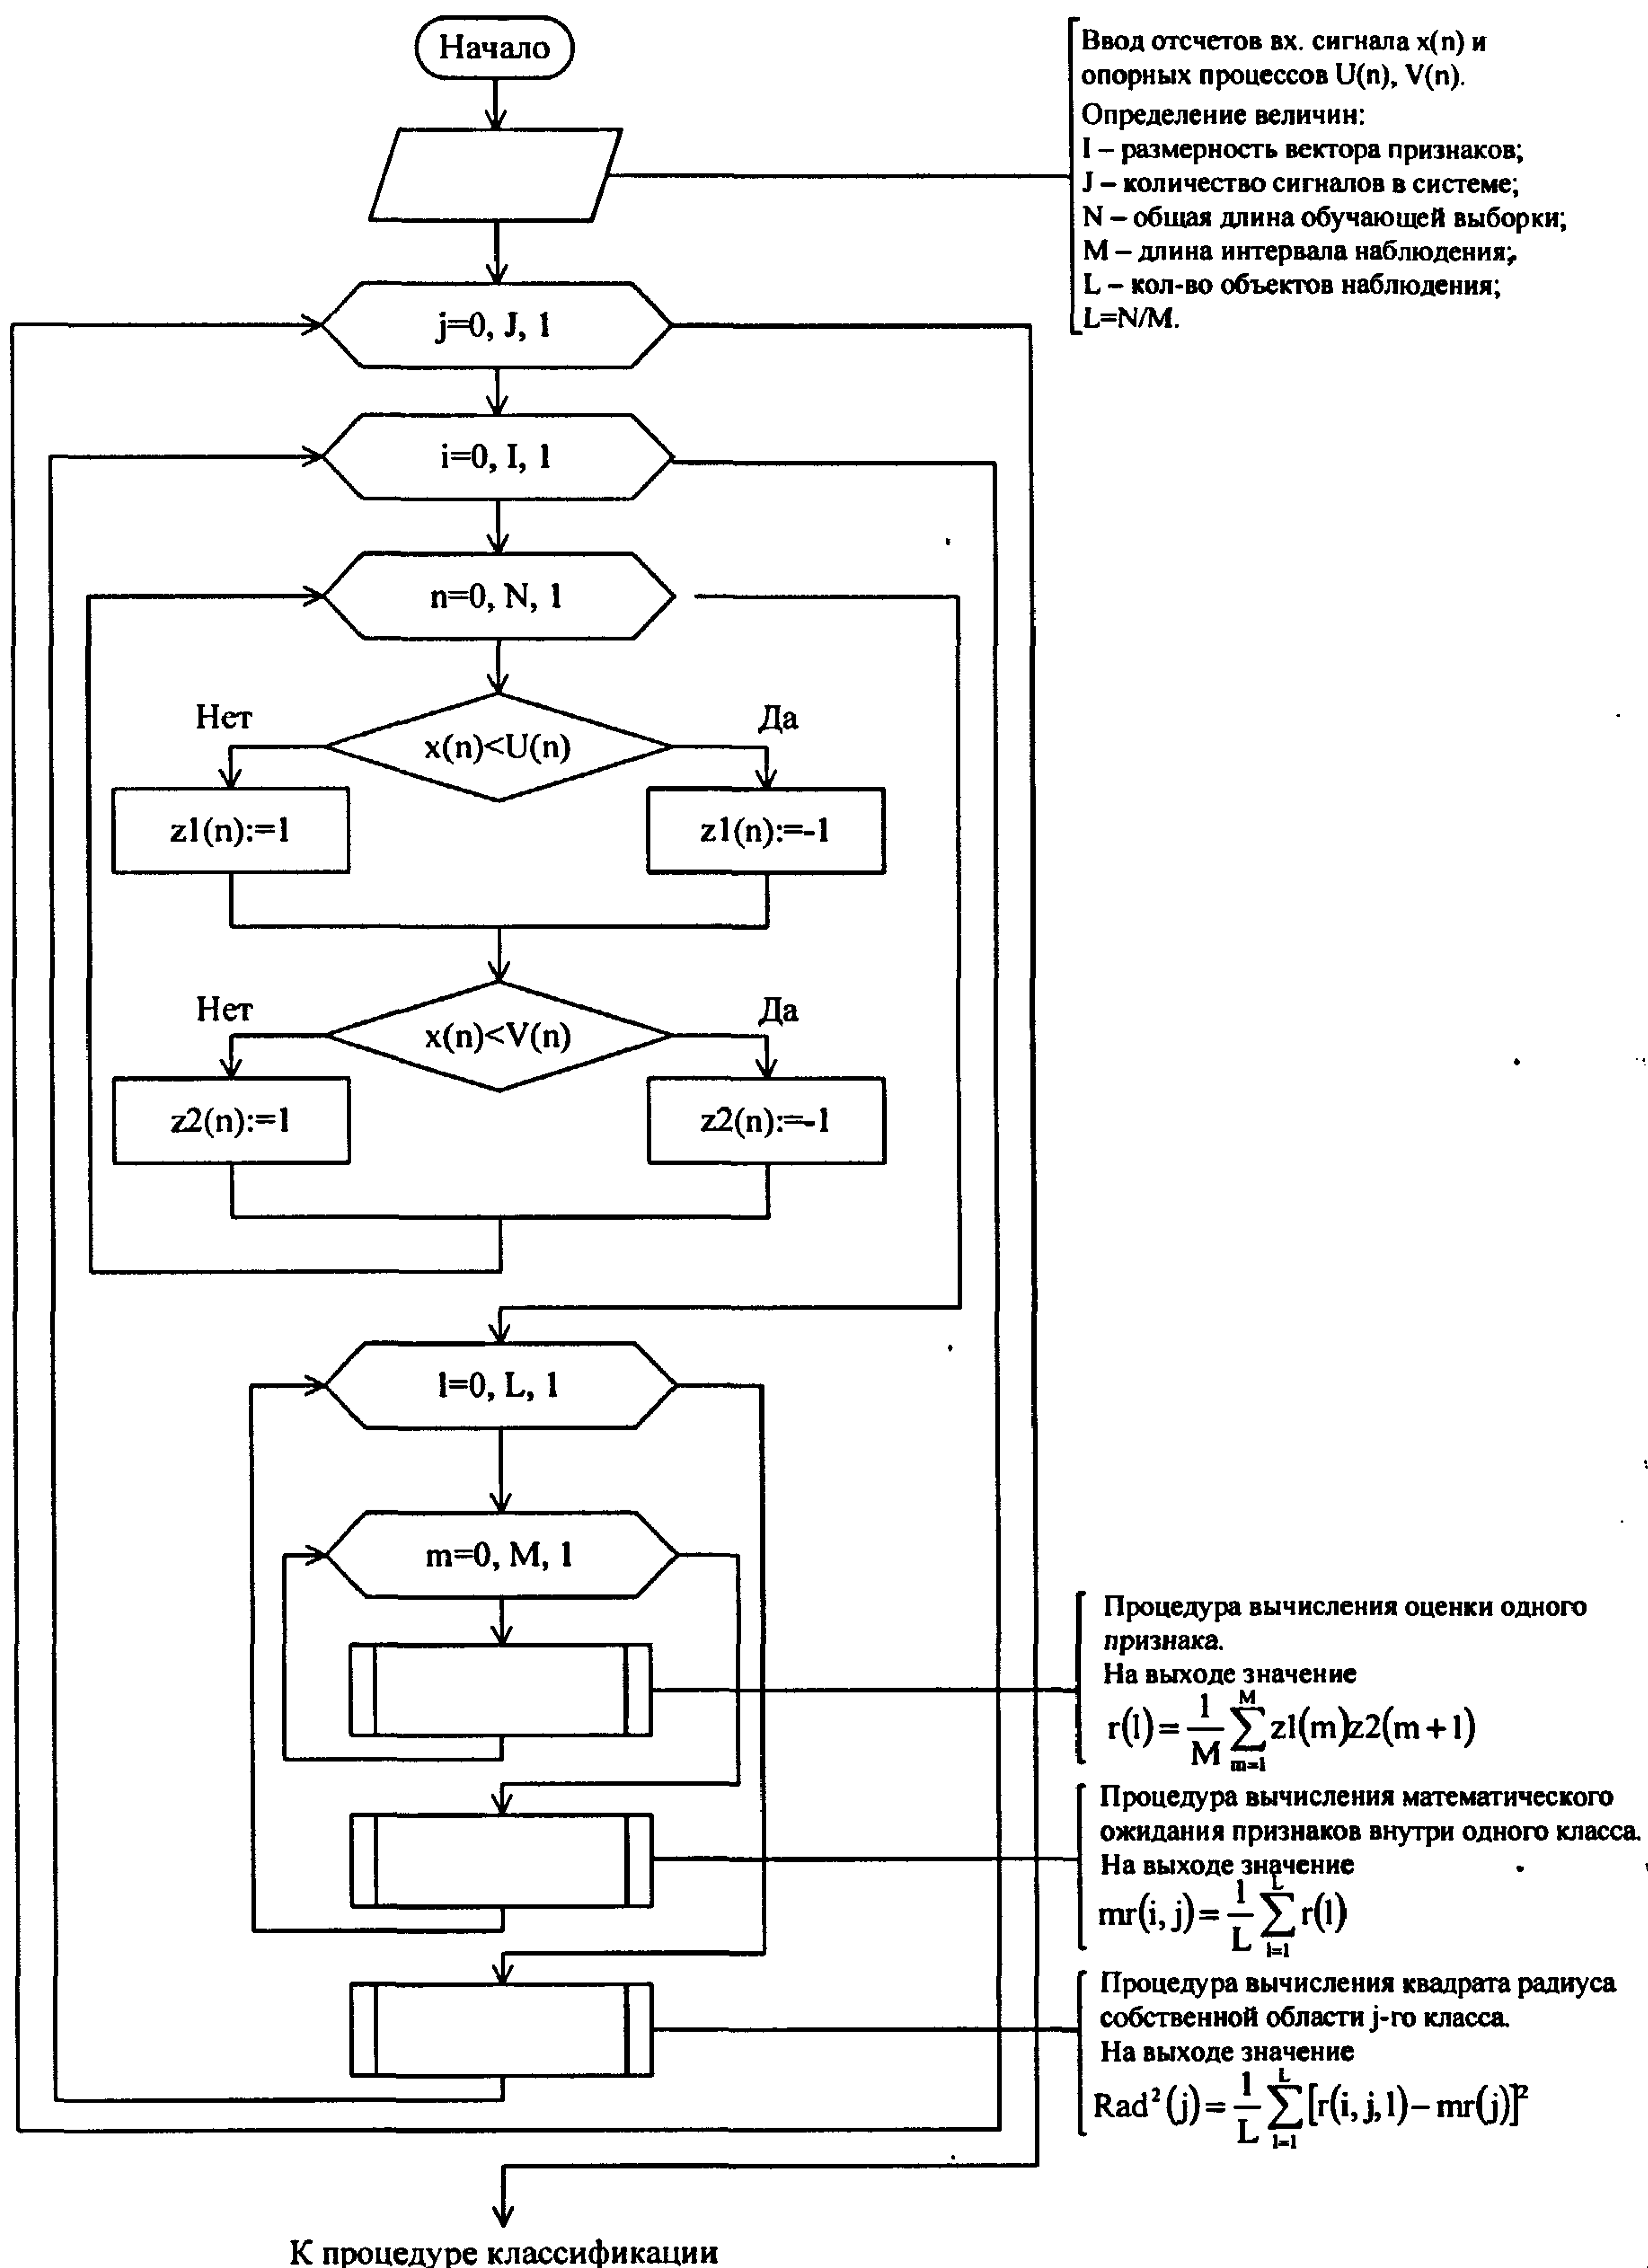


Рисунок 4.1 – Структурная схема алгоритма программы моделирования работы классификатора в режиме обучения

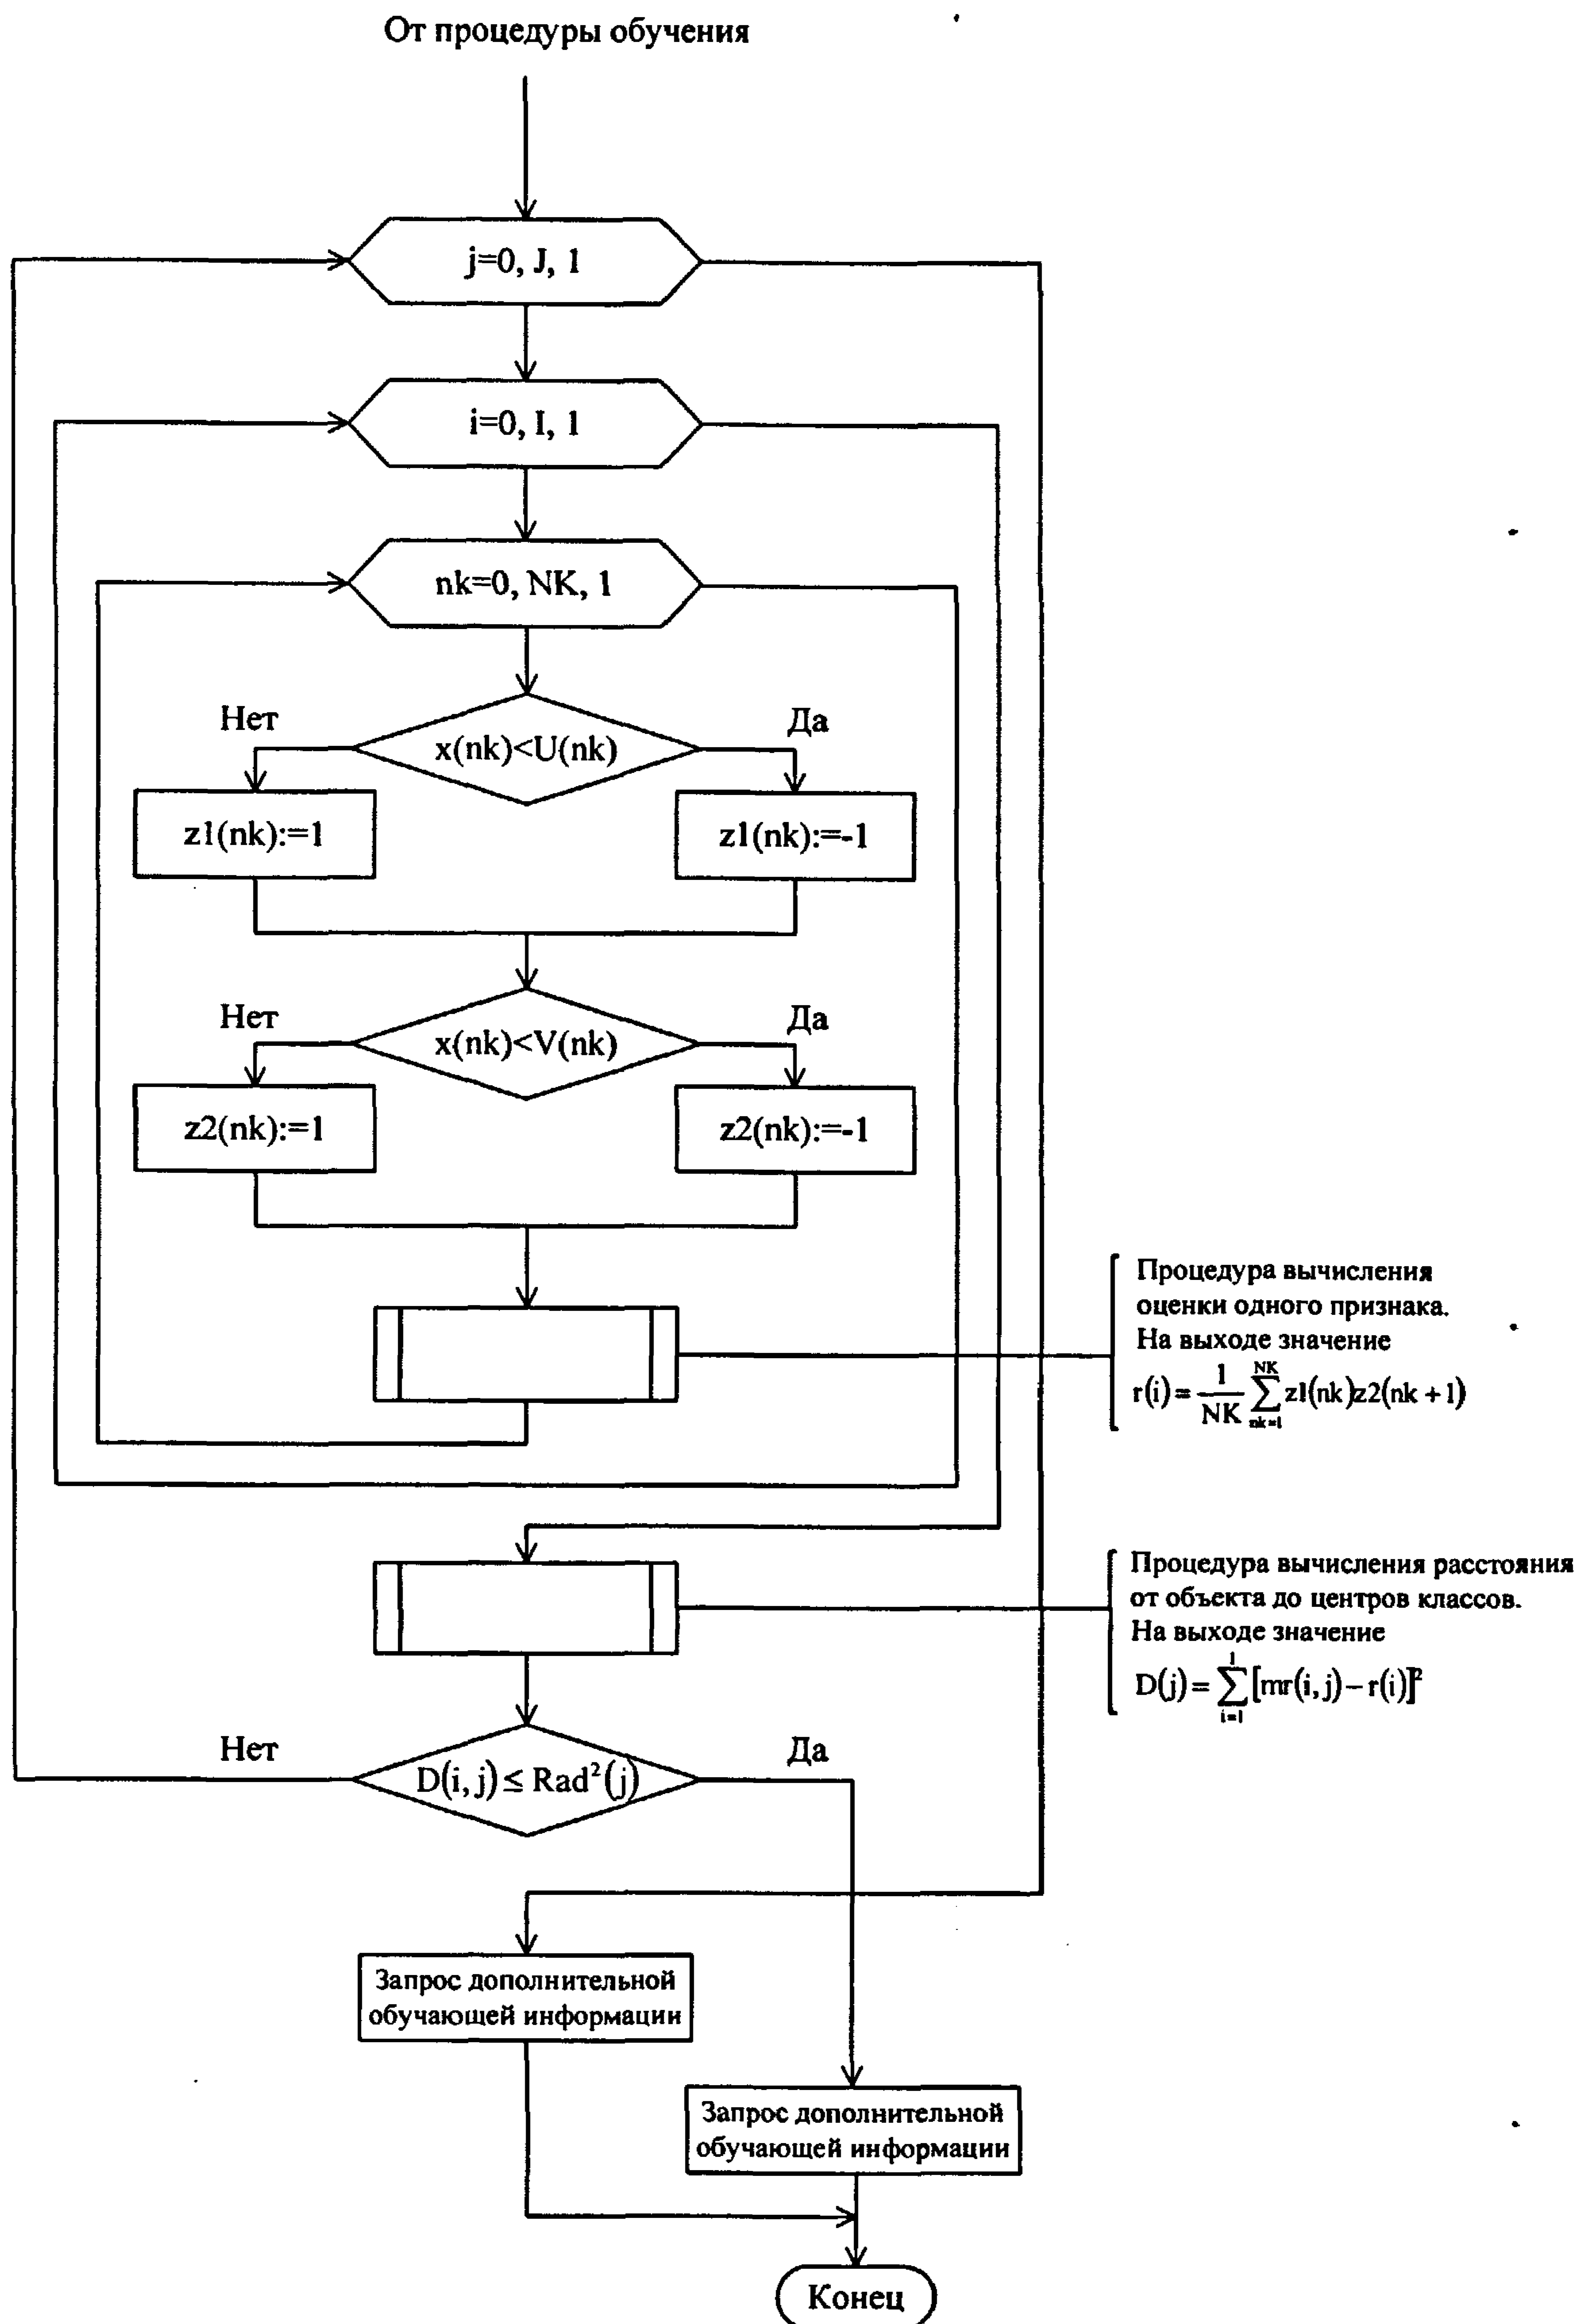


Рисунок 4.2 – Структурная схема алгоритма программы моделирования работы классификатора в режиме классификация

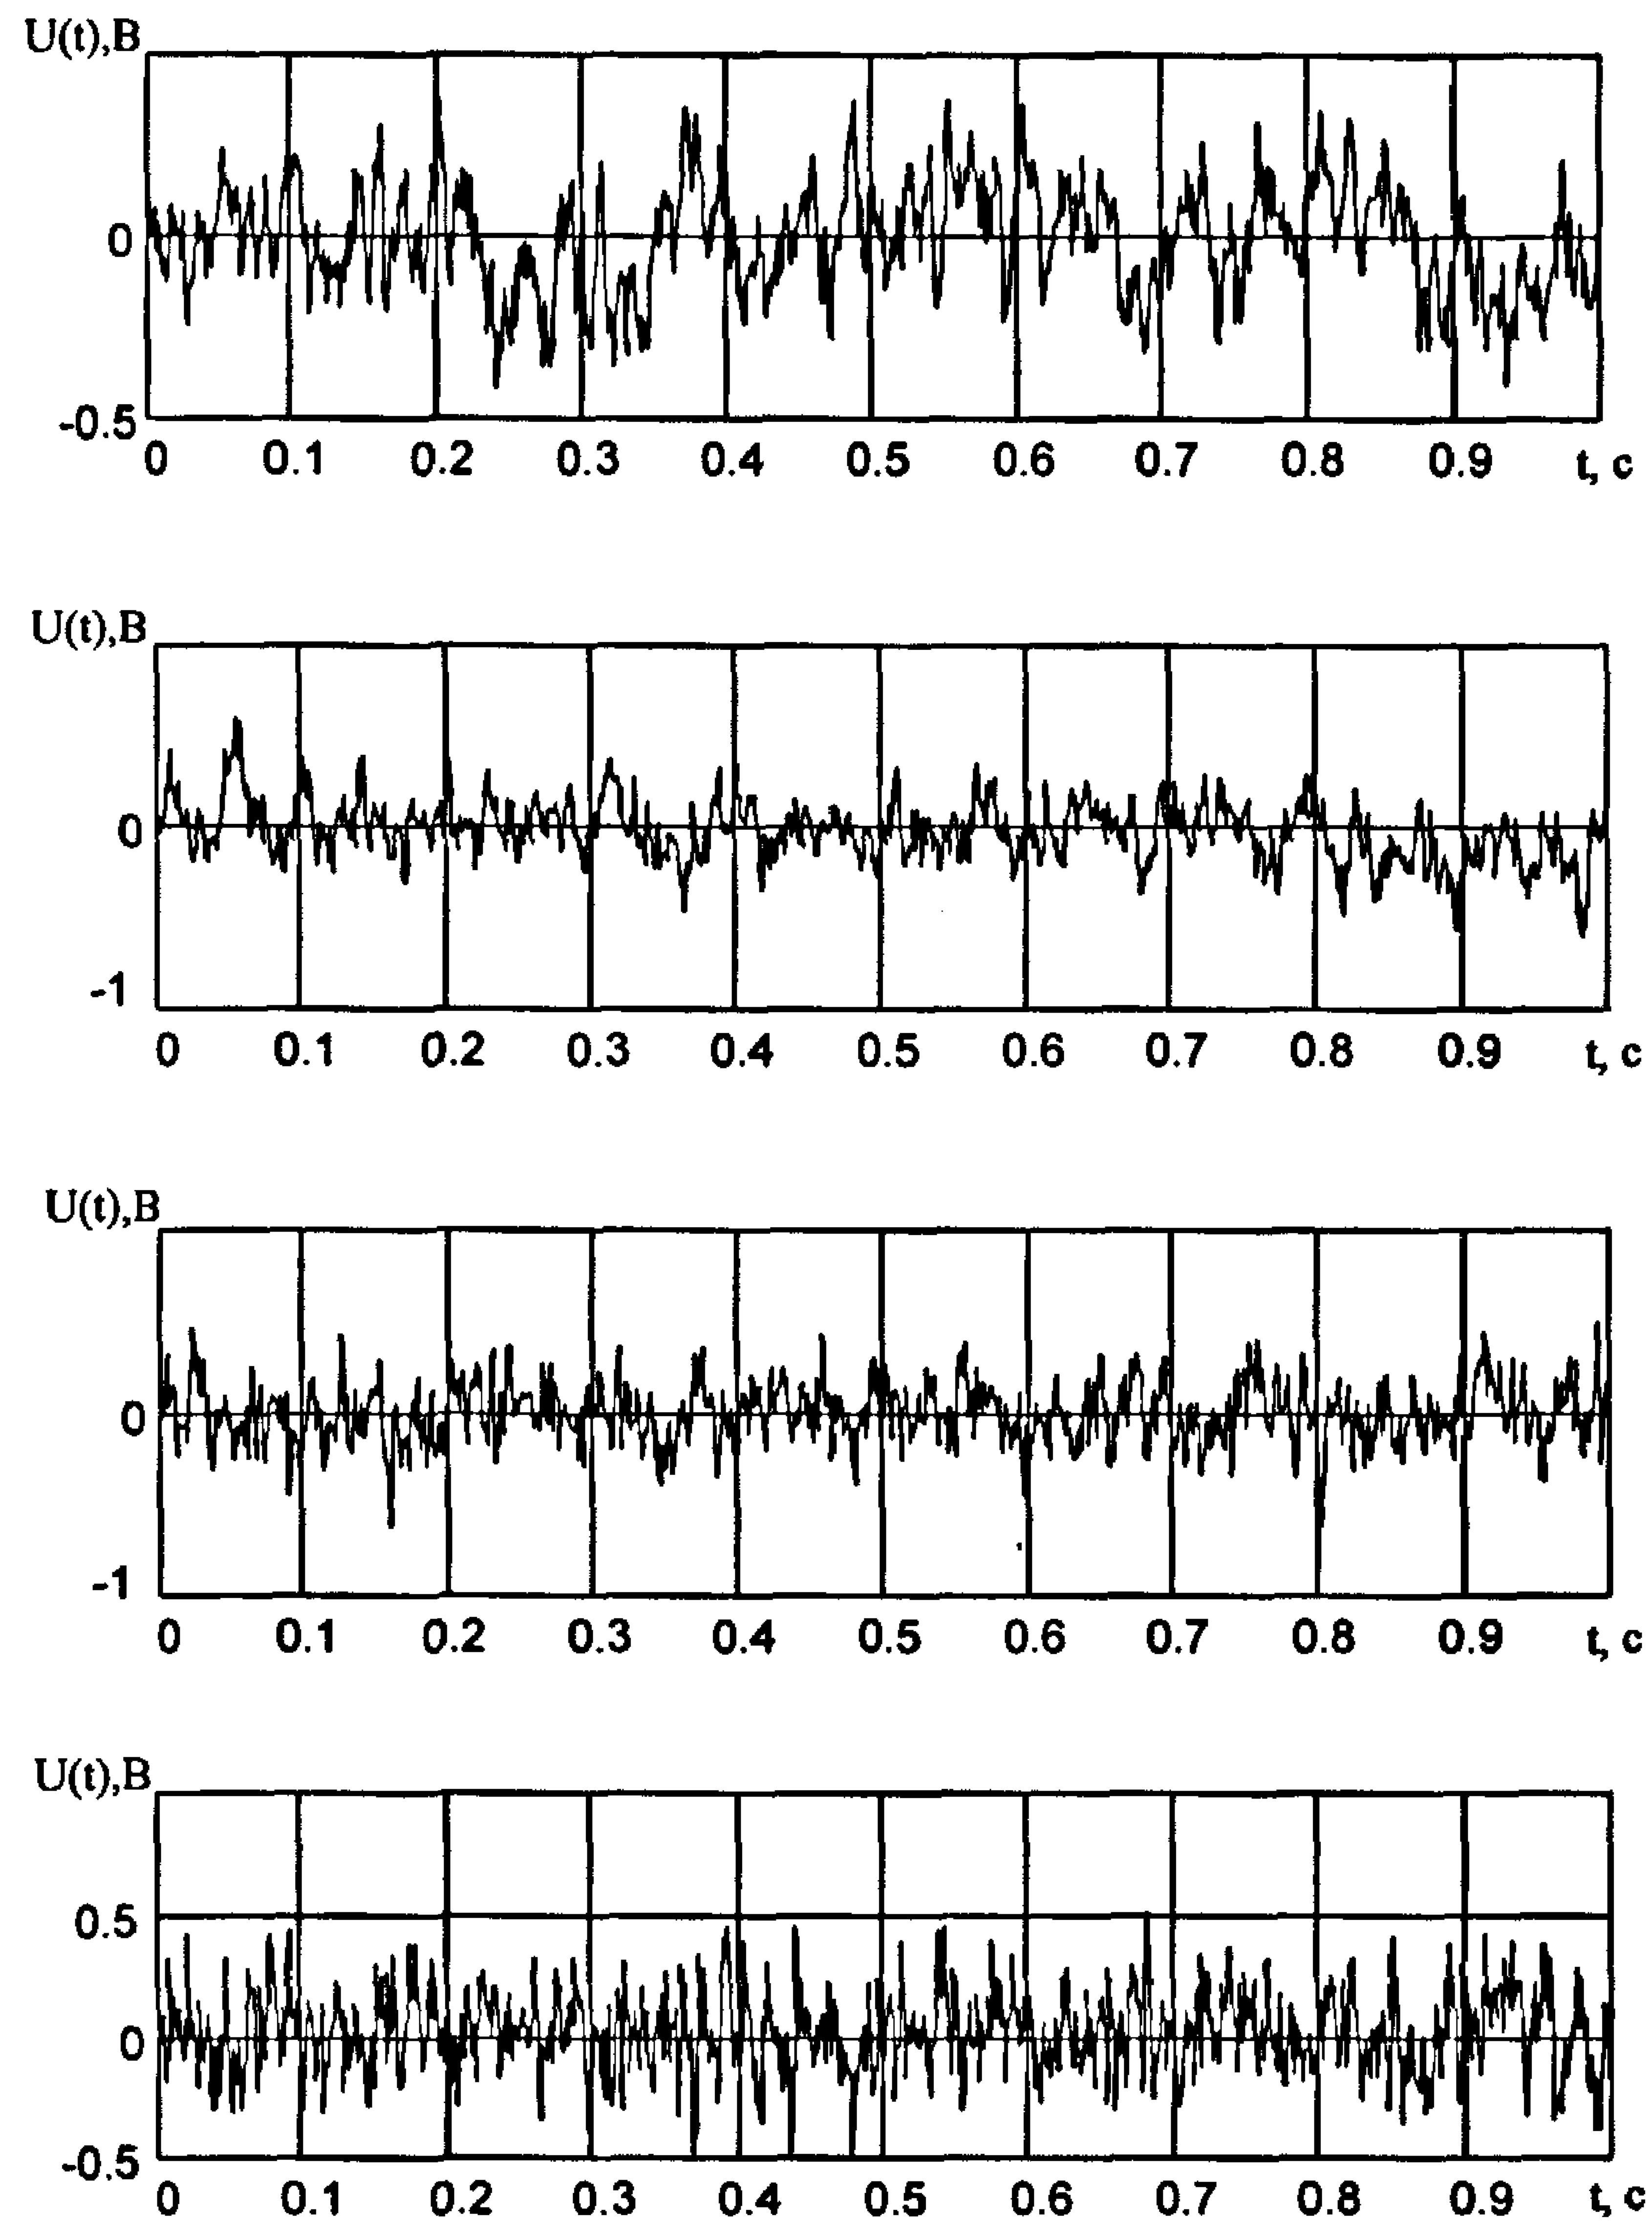


Рисунок 4.3 – Временные диаграммы реализаций входных процессов







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



а)



б)



в)

Рисунок 4.5 – Зависимости оценок суммарных вероятностей ошибок классификации от числа объектов обучения по классам

4.4 Оценка вычислительной сложности программы моделирования

Оценку вычислительной сложности программы моделирования работы НК МСОК произведем в соответствии с методикой, предложенной в [69]. 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 3 будут иметь следующие значения:

$$I=2, \quad J=2, \quad N=10^4, \quad M=10^3, \quad L=10, \quad NK=10^3, \quad Z=2, \quad \Sigma_{об} \cong 0.96 \cdot 10^6, \\ \Sigma_{кл} \cong 0.096 \cdot 10^6, \quad \Sigma = 1.056 \cdot 10^6.$$

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

Целью данного подраздела является объективное сравнение характеристик предлагаемых алгоритмов и известными алгоритмами непараметрической классификации. Оставляя за рамками данной работы анализ известных алго-

ритмов 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 [92].

В литературе [87] достаточно подробно описаны методы оценивания плотности вероятности и их использования для построения оптимальных решающих правил. Среди них: методы оценки Парзена, метод к ближайших соседей, 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 подходящей метрикой. Тогда в качестве оценки плотности вероятности в точке X можно принять [87]

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

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

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

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

$$(N_1/N_2)P(X/\omega_1) \stackrel{<}{>} (N_1/N_2)P(X/\omega_2) \rightarrow X \in \begin{cases} \omega_1, \\ \omega_2 \end{cases}, \quad (4.11)$$

или, подставляя (4.9) в (4.10) получим

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

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 [92]

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

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 пространства, 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 4.6, 4.7, графики зависимости $P_{\text{ош}}(n)$ – на рисунке 4.8 [20].

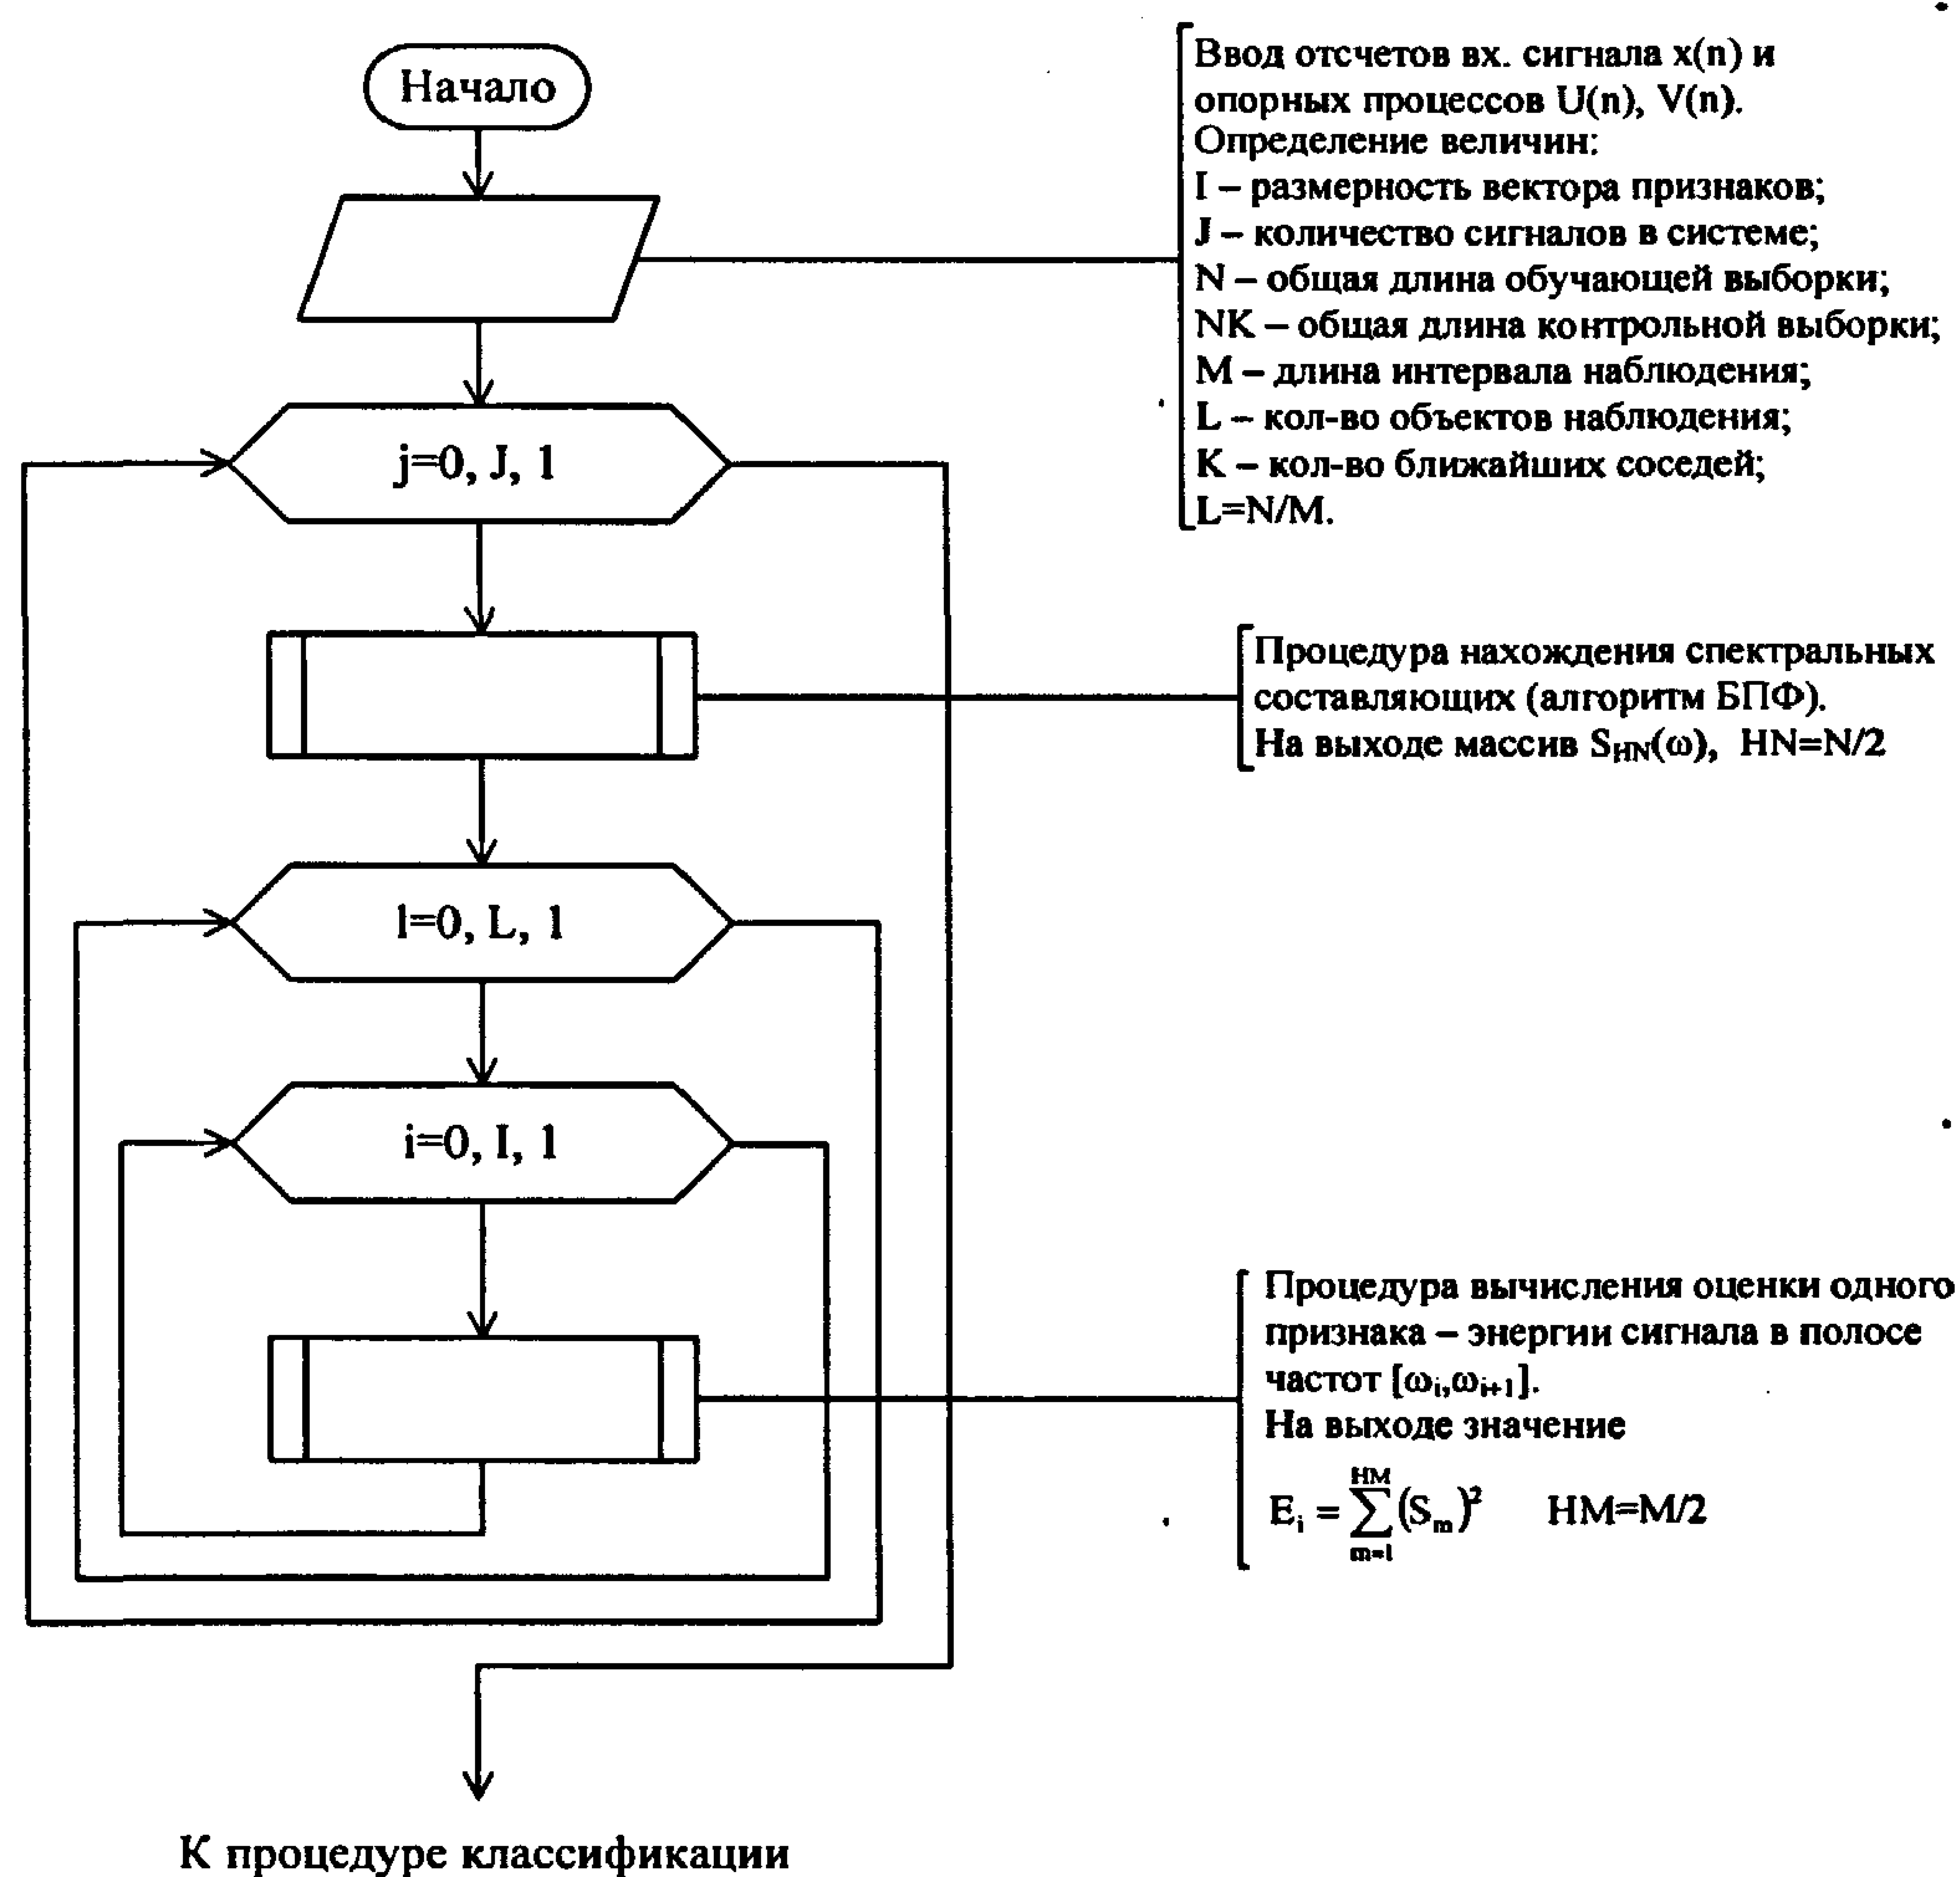


Рисунок 4.6 – Структурная схема алгоритма программы моделирования работы классификатора k -ближайших соседей в режиме обучения

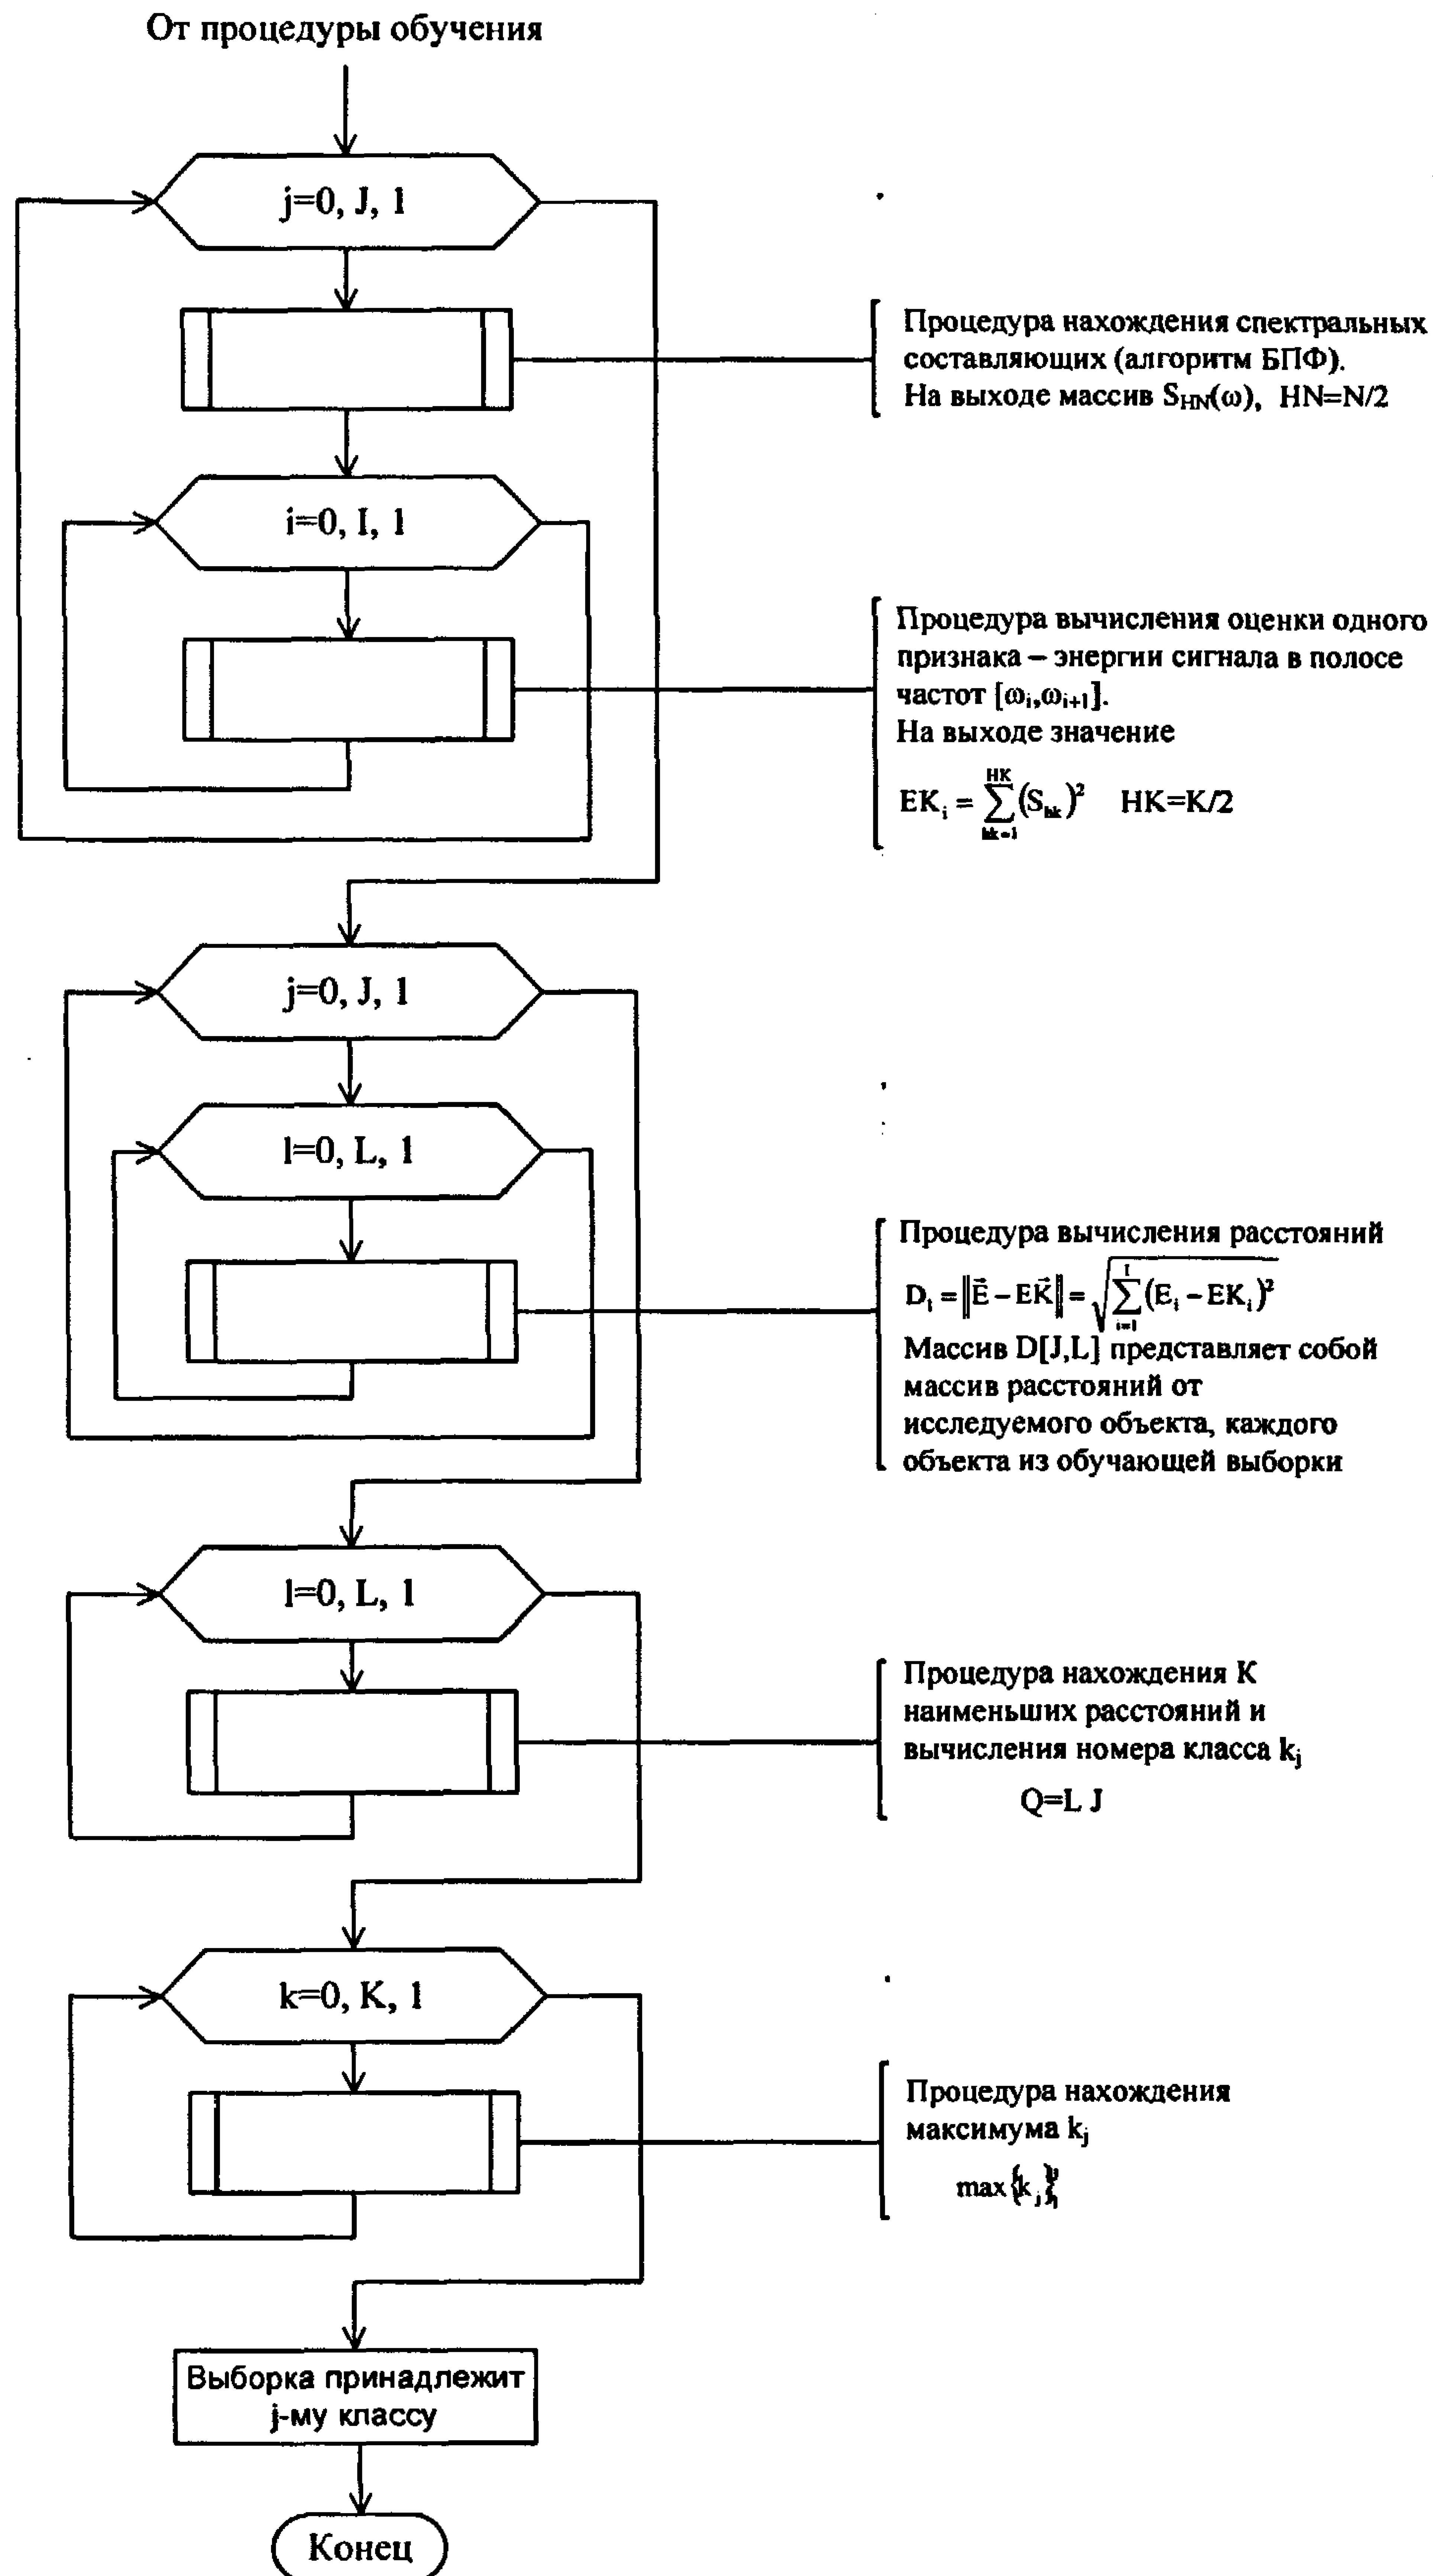


Рисунок 4.7 – Структурная схема алгоритма программы моделирования работы классификатора k -ближайших соседей в режиме классификации




Рисунок 4.8 – 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 4.6 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.

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:

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

Таким образом, сравнивая основные показатели эффективности (представленные на рисунке 4.4 и рисунке 4.8) 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 20-30) 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 моделирования

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.

Оценка ошибок статистического моделирования, в общем виде затруднительна, ввиду отсутствия общих аналитических выражений для ошибок моделирования систем случайных величин с произвольными законами распределения [3, 4, 50]. Воспользуемся методикой оценивания вероятности ошибки для заданного классификатора, приведенной в [87]. Когда неизвестны априорные вероятности классов $P(\omega_i)$, $i=1, 2$, то можно случайно извлечь N объектов и

проверить, дает ли данный классификатор правильные решения для этих объектов. Такие объекты называют случайной выборкой.

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:

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

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

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

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

Таким образом, оценка ε является несмещенной.

Поскольку плотность вероятности оценки ε известна, то можно вычислить доверительные интервалы по формуле:


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

Стоит отметить, явный вид для суммы слагаемых в выражении (4.27) не найден. Но соотношения между величинами ε , ε , N и γ затабулированы с помощью численных методов, и на рисунке 4.9 [87] показано соотношение между истинной вероятностью ошибки ε и ее оценки ε для коэффициента доверия $\gamma = 0,95$.

Для некоторых, полученных в приложении 3 значений $\beta_{\text{ош}}$ и p значения доверительных интервалов приведены в таблице 4.1.

Таблица 4.1 – Значения доверительных интервалов

N	n	некорр. ОП $\hat{\epsilon}$	некорр. ОП $\min[\hat{\epsilon}]$	некорр. ОП $\max[\hat{\epsilon}]$
100	2	0,37	0,26	0,47
100	4	0,31	0,22	0,43
100	6	0,25	0,16	0,35
100	8	0,16	0,08	0,24
100	10	0,10	0,04	0,17

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.




Рисунок 4.10 – Структурная схема 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 видеофрагмента статического изображения, в формате MPEG. Далее в персональной ЭВМ происходит разкадровка видеофрагмента и анализу уже подвергается последовательность кадров, представляющая собой файлы в формате BMP.


Предварительно на ЭВМ устанавливается программный пакет MathCad 11 с написанной программной реализацией разработанного непараметрического классификатора, обеспечивающего классификацию сигналов изображений, а в целом и распознавание объектов. Программа работы классификатора приведена в приложении А и Б.

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 данного эксперимента были выбраны микроавтобусы, имеющие схожий тип кузова, изображения которых приведены на рисунке 4.11. Далее для удобства примем следующие обозначения изображению "Форд" присвоим "Класс0", "Фольксваген" – "Класс1", "Соболь" – "Класс2", "Соболь_2" – "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.




а) Форд



б) Фольксваген



в) Соболь



г) Соболь_2

Рисунок 4.11 – Изображения протяженных статических объектов

Таблица 4.2 – Изменения радиусов собственных областей от размерности признакового пространства

Размерность признакового пространства, К	Класс 0	Класс 1	Класс 2	Класс 3
5	0,05	0,051	0,051	0,05
7	0,061	0,06	0,06	0,06
10	0,071	0,071	0,071	0,069

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

Размерность признакового пространства, К	Класс 0	Класс 1	Класс 2	Класс 3
5	$3,58 \cdot 10^{-3}$	$3,92 \cdot 10^{-3}$	$3,96 \cdot 10^{-3}$	$4,13 \cdot 10^{-3}$
7	$3,36 \cdot 10^{-3}$	$3,4 \cdot 10^{-3}$	$3,37 \cdot 10^{-3}$	$3,72 \cdot 10^{-3}$
10	$3,18 \cdot 10^{-3}$	$3,34 \cdot 10^{-3}$	$3,11 \cdot 10^{-3}$	$3,42 \cdot 10^{-3}$

Далее приведем матрицы вероятностей перепутывания при классификации этих классов объектов:

а) при размерности признакового пространства $K = 5$

$$\begin{bmatrix} 0.88 & 0.12 & 0 & 0 \\ 0.29 & 0.71 & 0 & 0 \\ 0 & 0 & 0.99 & 0 \\ 0 & 0 & 0 & 0.99 \end{bmatrix};$$

б) при размерности признакового пространства $K = 7$

$$\begin{bmatrix} 0.9 & 0.1 & 0 & 0 \\ 0.26 & 0.74 & 0 & 0 \\ 0 & 0 & 0.99 & 0.01 \\ 0 & 0 & 0 & 0.99 \end{bmatrix};$$

в) при размерности признакового пространства $K = 10$

$$\begin{bmatrix} 0.92 & 0.08 & 0 & 0 \\ 0.2 & 0.8 & 0 & 0 \\ 0 & 0 & 0.99 & 0 \\ 0 & 0 & 0 & 0.99 \end{bmatrix}.$$

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 реализации 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. Разработана методика преобразования оцифрованных сигналов изображений объекта в одномерные реализации случайных процессов, позволяющая перейти от двумерного представления сигналов изображений к одномерным.

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 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.
3. Акимов П.С. Непараметрическое обнаружение сигналов. // Радиотехника. 1972. Т.32. №11. – С.17-30.
4. Акимов П.С. и др. Сигналы и их обработка в информационных системах. Учебн. пособие для вузов. М.: Радио и связь, 1994. – 256с.
5. Астанин С.В. Методы и системы распознавания образов – Таганрог: Изд-во ТРТУ, 2003. – 160 с.
6. Банди Б. Методы оптимизации. Вводный курс: Пер. с англ. М.: Радио и связь, 1988. – 128с.
7. Бидасюк Ю.М. Mathsoft MathCAD 11: Самоучитель. М.: Диалектика, 2004. – 208 с.
8. Бобнев М.П. Генерирование случайных сигналов. М.: Энергия, 1971. – 240 с.
9. Браверман Э.М., Дорофеюк А.А., Лумельский В.Я. Применение методов обучения машин распознаванию образов. М.: Наука, 1971. – 254 с.
10. Бусленко Н.П., Калашников В.В., Коваленко И.Н. Лекции по теории сложных систем. М.: Советское радио, 1971. – 328 с.
11. Быков В.В. Цифровое моделирование в статистической радиотехнике. М.: Советское радио, 1971. – 328 с.
12. Васильев В.И. Распознающие системы: Справочник. Киев.: Наукова думка, 1983. – 423 с.
13. Вапник В.Н., Червоненкис А.Я. Теория распознавания образов (статистические проблемы обучения) М.: Наука, 1974. – 416 с.
14. Вентцель Е.С. Теория вероятностей. М.: Наука, 1969. – 576 с.
15. Витих В.А., Сергеев В.В., Соيفер В.А. Обработка изображений в автоматизированных системах научных исследований. – М.: Наука, 1982. – 311 с.
16. Волков Е.А. Численные методы / Учебное пособие – М.: Наука, 1982. – 256 с.
17. Вопросы статистической теории распознавания / Под ред. Б.В. Варского М.: Сов. радио, 1967. – 400с.
18. Галустов Г.Г. Классификатор случайных сигналов // Известия СКНЦ ВШ. Новочеркасск, 1984. Серия «Технические науки». № 3. – С. 54-57.

19. Галустов Г.Г. Моделирование случайных процессов и оценивание их статистических характеристик. М.: Радио и связь, 1999. – 120 с. .
20. Галустов Г.Г., Теоретические и аппаратные основы, анализа и синтез сложных сигналов диагностических систем. / диссертация на соискание ученой степени доктора технических наук. Таганрог. 1991.
21. Галустов Г.Г. Укрупнение описания случайных процессов с целью их классификации // Межведомственный тематический сборник "Вопросы медицинской электроники". Таганрог, 1986. Вып. 6. – С. 57-62.
22. Галустов Г.Г., Цымбал В.Г., Михалев М.В. Принятие решений в условиях неопределенности. М.: Радио и связь, 2001. – 196 с.
23. Гастев Ю.А. Гомоморфизмы и модели: Логико-алгебраические аспекты моделирования. – М.: Наука, 1975. – 150 с.
24. Гладкий В.С. Вероятностные вычислительные модели. М.: Наука, 1973. – 298 с.
25. Гонсалес Р., Вудс Р. Цифровая обработка изображений М.: Техносфера, 2005. – 1072 с.
26. Горелик А.Л., Скрипкин В.А. Построение систем распознавания. М.: Сов. радио, 1974. – 224 с.
27. Горелик А.Л., Гуревич И.Б., Скрипкин В.А. Современное состояние проблемы распознавания. М.: Радио и связь, 1985. – 160 с.
28. Градштейн И.С., Рыжик И.М. Таблицы интегралов, сумм, рядов и произведений. М.: Наука, 1971. – 184 с.
29. Драган Я.П. Структура и представления моделей стохастических сигналов. Киев: Наукова думка, 1980. – 384 с
30. Дуда Р., Харт П. Распознавание сигналов и анализ сцен. М.: Мир, 1976. – 511 с.
31. Дударов Д.А. Использование вероятностных признаков при обработке изображений // Первая ежегодная научно-техническая конференция студентов и аспирантов базовых кафедр ЮНЦ 2005. Сборник тезисов докладов. – Ростов на Дону: ЮНЦ, 2005. – 48 с.
32. Дударов Д.А. Использование метода стохастического кодирования при распознавании оцифрованных изображений // Материалы международной научной конференции "Оптимальные методы решения научных и практических задач" – часть 2 – Таганрог: Изд. "Антон", ТРТУ, 2005. – с. 14-17.
33. Дударов Д.А. Исследование методов преобразования изображений с целью повышения их информативности // Девятая Международная научно-техническая конференция студентов и аспирантов "Радиоэлектроника, электротехника и энергетика". Тезисы докладов. Т.1. – М.: Издательство МЭИ, 2003. – с. 90-91.

34. Дударов Д.А. Обработка полутонных изображений с использованием вейвлет-преобразований // Материалы Международной научной конференции "Искусственный интеллект. Интеллектуальные и многопроцессорные системы 2004" – Т.2. Таганрог: Изд-во ТРТУ, 2004. – с. 337-339.
35. Дударов Д.А. Преобразование ТВ-сигнала с целью повышения информативности изображения // VI Всероссийская научная конференция студентов и аспирантов "Техническая кибернетика, радиоэлектроника и системы управления". Тезисы докладов. Таганрог: Изд-во ТРТУ 2002. – с. 38-39.
36. Дударов Д.А. Специализированная телевизионная система // Восьмая Международная научно-техническая конференция студентов и аспирантов " Радиоэлектроника, электротехника и энергетика". Тезисы докладов В 3-х т. – М.: Издательство МЭИ, 2002. Т.1. – с. 99-100.
37. Дударов Д.А. Формирование решающего правила при классификации изображений с использованием метода стохастического кодирования // Материалы международной научной конференции "Оптимальные методы решения научных и практических задач" – часть 2 – Таганрог: Изд. "Антон", ТРТУ, 2005. – с.18-21.
38. Дударов Д.А, Мелешкин С.Н, Клименко В.В. Формирование решающих правил при пороговой обработке двумерных оцифрованных сигналов // Десятая Международная научно-техническая конференция студентов и аспирантов " Радиоэлектроника, электротехника и энергетика". Тезисы докладов. В3-х т.Т.1. – М.: Издательство МЭИ, 2004. – 96 с.
39. Дударов Д.А., Мелешкин С.Н. О математических моделях телевизионного сигнала при решении задач сопровождения и обнаружения // Материалы международной научной конференции "Информационный подход в естественных, гуманитарных и технических науках" – часть 4 – Таганрог: ТРТУ, 2004. – с.27-30.
40. Дударов Д.А., Мелешкин С.Н. Системы параметров изображения фона достаточной для идентификации фона в широком диапазоне сцен // Материалы международной научной конференции "Информационный подход в естественных, гуманитарных и технических науках" – часть 4 – Таганрог: ТРТУ, 2004. – с.30-34.
41. Дьяконов В.П. Энциклопедия Mathcad 2001i и Mathcad 11. М.: Солон-пресс, 2004. – 468 с.
42. Евсиков Ю.А., Чапурский В.В. Преобразование случайных процессов в радиотехнических устройства. Учеб. пособ. для радиотехн. специальностей вузов. М.: Высш. школа, 1977. – 264 с.
43. Ермаков С.М., Михайлов Г.А.. Курс статистического моделирования. М.:

- Наука, 1976. – 168 с.
44. Журавлев Ю.И. Непараметрические задачи распознавания образов // Кибернетика, 1986. №6 – с. 83-103.
 45. Загоруйко Н.Г. Методы распознавания и их применение. М.: Сов. радио, 1972. – 206 с.
 46. 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.
 47. Казанцев Г.Д., Курячий М.И., Пустынский И.Н. Измерительное телевидение: Учебное пособие для вузов – М.: Высш. шк., 1994. – 288с.
 48. Кирьянов Д.В. Самоучитель MathCAD 2001. – СПб.: "ВНУ-СПб", 2001. – 544 с.
 49. Киселев Н.В. Методы построения систем распознавания и классификации негауссовых сигналов. Л.: ЛГУ, 1986. – 186 с.
 50. Киселев Н.В., Сечкин В.А. Техническая диагностика методами нелинейного преобразования. Л.: Энергия, 1980. – 108 с.
 51. Ковалевский В.А. Методы оптимальных решений в распознавании изображений. – М.: Наука, 1976. – 328 с.
 52. Коваленко И.Н., Филлипова А.А. Теория вероятностей и математическая статистика. М., Высшая школа, 1973. – 368 с.
 53. Коган И.М. Прикладная теория информации. М.: Радио и связь, 1981. – 216 с.
 54. Левин Б.Р. Теоретические основы статистической радиотехники. Кн. 3. М.: Сов. радио, 1976. – 288 с.
 55. 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.
 56. Мартышевский Ю.В. Телевизионные средства определения координат объектов, расположенных на сложном фоне / диссертация на соискание ученой степени доктора технических наук. Томск 2002.
 57. Методы компьютерной обработки изображений / Под ред. В.А. Сойфера. – М.: Физматлит, 2001. – 784 с.
 58. Миленький А.В. Классификация сигналов в условиях неопределенности. М.: Сов. радио, 1975. 328 с.
 59. Мирский Г.Я. Аппаратурное определение характеристик случайных процессов. М.: Энергия, 1972. 456 с.
 60. Мирский Г.Я. Характеристики стохастической взаимосвязи и их измерения. М.: Энергия, 1982. – 320 с.
 61. Непараметрические методы классификации и их применение.

- Новосибирск: Наука, 1993 с.
62. Ольховский Ю.Б., Новоселов О.Н., Мановцев А.П. Сжатие данных при телеизмерениях. М.: Сов. радио, 1971. – 304 с.
 63. Омельченко В.А. Основы спектральной теории распознавания сигналов. Харьков: Вища школа, 1983. – 159 с.
 64. Патрик Э. Основы теории распознавания образов. Пер. с англ. / Под ред. Б.Р. Левина. М.: Сов. радио, 1980. – 408 с.
 65. Прикладная статистика: Классификация и снижение размерности. – М.: Финансы и статистика. 1989. – 607 с.
 66. Применение цифровой обработки сигналов. Пер. с англ. / Под ред. А. Оппенгейма. М.: Мир, 1980. – 552 с.
 67. Прэтт У.К. Цифровая обработка изображений. Т.1. – М.: Мир, 1982. – 312 с.
 68. Прэтт У.К. Цифровая обработка изображений. Т.2. – М.: Мир, 1982. – 480 с.
 69. Райли Д. Абстракция и структуры данных: Вводный курс / Пер. с англ. М.: Мир, 1973. – 752 с.
 70. Распознавание образов при помощи цифровых вычислительных машин / Под ред. Л. Хармон. М.: Мир, 1974. – 287 с.
 71. Распознавание образов. Состояние и перспективы / Пер. с англ. К. Верхаген, Р. Дейн, Ф. Грун и др. М.: Радио и связь, 1985. – 104 с.
 72. Распознавание образов: Теория и приложения. М.: Наука, 1977. – 128 с.
 73. Семенов М.Г. Математическое моделирование в MathCad. М.: Изд-во "Альтекс-А", 2003. – 208 с.
 74. Сенин А.Г. К анализу критериев оптимальности, используемых при обучении распознаванию образов // Автометрия, 1971. № 5. С. 20-25.
 75. Сенин А.Г. Распознавание случайных сигналов. Новосибирск: Наука. Сибирское отделение. 1974. – 76 с.
 76. Сергиенко А.Б. Цифровая обработка сигналов /– СПб.: Питер, 2002. – 608 с.
 77. Тихонов В.И. Выбросы случайных процессов. М.: Наука, 1970. – 392 с.
 78. Ту Дж., Гонсалес Р. Принципы распознавания образов. М.: Мир, 1978. – 432 с.
 79. Фомин В.Н. Математическая теория обучаемых опознающих систем. Л.: Изд-во ЛГУ, 1976. – 235 с.
 80. Фомин Я.А., Тарловский Г.Р. Статистическая теория распознавания образов. М.: Радио и связь, 1986. – 264 с.
 81. Фомин Я.А. Теория выбросов случайных процессов. М.: Связь, 1980. – 216 с.
 82. Фомин Я.А., Савич А.В. Оптимизация распознающих систем. М.:

- Машиностроение, 1993. – 288 с.
83. Форсайт Д.А., Понс А. Компьютерное зрение. Современный подход.: Пер. с англ. – М.: Издательский дом "Вильямс", 2004. – 928 с.
 84. Френкс Л. Теория сигналов. М.: Сов. радио, 1974. – 344 с.
 85. Фу К. Последовательные методы в распознавании образов и обучении машин. М.: Наука, 1979. – 287 с.
 86. Фу К. Структурные методов распознавания образов / Пер с англ. Под ред. М.А. Айзермана. М.: Наука, 1977. – 319 с.
 87. Фукунага К. Введение в статистическую теорию распознавания образов. М.: Наука, 1979. – 367 с.
 88. Цветнов В.В., Борисов Ю.П. Математическое моделирование радиотехнических систем и устройств. М.: Радио и связь, 1985. – 176 с.
 89. Цифровая обработка изображений в информационных системах: Учебное пособие / Грузман И.С., Киричук В.С. и др. – Новосибирск, НГТУ, 2002. – 587 с.
 90. Цымбал В.Г. Разработка и исследование методов формирования признаков пространств в медицинских диагностических системах / диссертация на соискание ученой степени кандидата технических наук. Таганрог 1999.
 91. Цыпкин Я.З. Основы теории обучающихся систем. М.: Наука, 1970. – 252 с.
 92. Шапиро Е.И. Непараметрические оценки плотности вероятности в задачах обработки результатов наблюдений: обзор // Зарубежная радиоэлектроника. №2, 1976 – с. 3-33.
 93. Шибанов Г.П. Распознавание в системах автоконтроля. М.: Машиностроение, 1973. – 424 с.
 94. Ярославский Л.П. Введение в цифровую обработку изображений. – М.: Сов. Радио, 1979. – 312с.
 95. Mathcad 2001. Специальный справочник. / Под ред. В.П. Дьяконов М.: Питер, 2002. – 832 с.

ПРИЛОЖЕНИЯ

ПРИЛОЖЕНИЕ А

Обучение

Объект 1 - Ford:

kadr := 20

```

PG := P ←  $\frac{\text{READBMP}(\text{"ford\_g"})}{255}$ 
str ← 100
Ps ← PT
dop ← length(Ps<str>) - 211
N ← 211 + dop
kadr ← 20
Z ← kadr - 2
mat ←  $\left| \begin{array}{l} \text{for } t \in 0..9 \\ fg_t \leftarrow \text{mean}[Ps^{<(t+1) \cdot str>}] \\ fg \end{array} \right.$ 
mv ← mean(mat)
for gk ∈ 0..99
rez_gk ←  $\left| \begin{array}{l} g \leftarrow \frac{Ps^{<1 \cdot str>}}{mv} \\ x \leftarrow \left| \begin{array}{l} s \leftarrow g \\ \text{for } i \in 0..Z \\ s \leftarrow \text{stack}(s, g) \\ s \end{array} \right. \\ \text{opor} \leftarrow \text{norm}(kadr \cdot N, 1, 0.6) \\ v \leftarrow x - \text{opor} \\ V\_sgn \leftarrow \left| \begin{array}{l} \text{for } p \in 0..kadr - 1 \\ \text{for } j \in 0..N - 1 \\ S_{j,p} \leftarrow \left| \begin{array}{l} 1 \text{ if } v_{p \cdot N + j} \geq 0 \\ -1 \text{ otherwise} \end{array} \right. \\ S \end{array} \right. \\ L0 \leftarrow \left| \begin{array}{l} \text{for } p \in 0..kadr - 1 \\ \left| \begin{array}{l} U \leftarrow \text{stack}(V\_sgn^{<p>}, 0) \\ B_p \leftarrow \frac{1}{N} \cdot \sum_{n=0}^{N-1} U_n \cdot U_{n+1} \end{array} \right. \\ B \end{array} \right. \\ M\_L_0 \leftarrow \text{mean}(L0) \\ L \leftarrow L0 \\ gl \leftarrow \frac{Ps^{<2 \cdot str>}}{mv} \end{array} \right.$ 

```



```

x ← | s ← g1
    | for i ∈ 0..Z
    |   s ← stack(s, g1)
    | s

opor ← | for i ∈ 0.. kadr·(N) - 1
        |   di ← md(2.5)
        | d

v = x - opor

V_sgn ← | for p ∈ 0.. kadr - 1
          |   for j ∈ 0.. N - 1
          |     Sj,p ← | 1 if vp·N+j ≥ 0
          |               | -1 otherwise
          | S

L1 ← | for p ∈ 0.. kadr - 1
      |   U ← stack(V_sgn⟨p⟩, 0)
      |   Bp ←  $\frac{1}{N} \cdot \sum_{n=0}^{N-1} U_n \cdot U_{n+1}$ 
      | B

M_L1 ← mean(L1)

L ← augment(L, L1)

g2 ←  $\frac{P_s^{⟨3\text{-str}⟩}}{mv}$ 

x ← | s ← g2
    | for i ∈ 0..Z
    |   s ← stack(s, g2)
    | s

opor ← rexp(kadr·N, 1)

v = x - opor

V_sgn ← | for p ∈ 0.. kadr - 1
          |   for j ∈ 0.. N - 1
          |     Sj,p ← | 1 if vp·N+j ≥ 0
          |               | -1 otherwise
          | S

L2 ← | for p ∈ 0.. kadr - 1
      |   U ← stack(V_sgn⟨p⟩, 0)
      |   Bp ←  $\frac{1}{N} \cdot \sum_{n=0}^{N-1} (U_n \cdot U_{n+1})$ 
      | B

M_L2 ← mean(L2)

L ← augment(L, L2)

```

```

g3 ←  $\frac{P_s^{(4.\text{str})}}{mv}$ 
x ←  $\left\{ \begin{array}{l} s \leftarrow g3 \\ \text{for } i \in 0..Z \\ \quad s \leftarrow \text{stack}(s, g3) \\ s \end{array} \right.$ 
opor ← morm(kadr·N, 0.3, 1.2)
v = x - opor
V_sgn ←  $\left\{ \begin{array}{l} \text{for } p \in 0..kadr - 1 \\ \quad \text{for } j \in 0..N - 1 \\ \quad \quad S_{j,p} \leftarrow \left\{ \begin{array}{l} 1 \text{ if } v_{p \cdot N + j} \geq 0 \\ -1 \text{ otherwise} \end{array} \right. \\ S \end{array} \right.$ 
L3 ←  $\left\{ \begin{array}{l} \text{for } p \in 0..kadr - 1 \\ \quad \left\{ \begin{array}{l} U \leftarrow \text{stack}(V\_sgn^{(p)}, 0) \\ B_p \leftarrow \frac{1}{N} \cdot \sum_{n=0}^{N-1} U_n \cdot U_{n+1} \end{array} \right. \\ B \end{array} \right.$ 
M_L3 ← mean(L3)
L ← augment(L, L3)
g4 ←  $\frac{P_s^{(5.\text{str})}}{mv}$ 
x ←  $\left\{ \begin{array}{l} s \leftarrow g4 \\ \text{for } i \in 0..Z \\ \quad s \leftarrow \text{stack}(s, g4) \\ s \end{array} \right.$ 
opor ←  $\left\{ \begin{array}{l} \text{for } i \in 0..kadr \cdot (N) - 1 \\ \quad d_i \leftarrow \text{md}(5) - 1 \\ d \end{array} \right.$ 
v ← x - opor
V_sgn ←  $\left\{ \begin{array}{l} \text{for } p \in 0..kadr - 1 \\ \quad \text{for } j \in 0..N - 1 \\ \quad \quad S_{j,p} \leftarrow \left\{ \begin{array}{l} 1 \text{ if } v_{p \cdot N + j} \geq 0 \\ -1 \text{ otherwise} \end{array} \right. \\ S \end{array} \right.$ 
L4 ←  $\left\{ \begin{array}{l} \text{for } p \in 0..kadr - 1 \\ \quad \left\{ \begin{array}{l} U \leftarrow \text{stack}(V\_sgn^{(p)}, 0) \\ B_p \leftarrow \frac{1}{N} \cdot \sum_{n=0}^{N-1} U_n \cdot U_{n+1} \end{array} \right. \\ B \end{array} \right.$ 

```

```

M_L4 ← mean(L4)
L ← augment(L, L4)
g5 ←  $\frac{P_s^{(6\text{-str})}}{mv}$ 
x ←  $\left\{ \begin{array}{l} s \leftarrow g5 \\ \text{for } i \in 0..Z \\ \quad s \leftarrow \text{stack}(s, g5) \end{array} \right.$ 
s
opor ← morm(kadr·N, 0.5, 0.8)
v ← x - opor
V_sgn ←  $\left\{ \begin{array}{l} \text{for } p \in 0..kadr - 1 \\ \quad \text{for } j \in 0..N - 1 \\ \quad \quad S_{j,p} \leftarrow \left\{ \begin{array}{l} 1 \text{ if } v_{p \cdot N + j} \geq 0 \\ -1 \text{ otherwise} \end{array} \right. \end{array} \right.$ 
S
L5 ←  $\left\{ \begin{array}{l} \text{for } p \in 0..kadr - 1 \\ \quad \left\{ \begin{array}{l} U \leftarrow \text{stack}(V\_sgn^{(p)}, 0) \\ B_p \leftarrow \frac{1}{N} \cdot \sum_{n=0}^{N-1} U_n \cdot U_{n+1} \end{array} \right. \end{array} \right.$ 
B
M_L5 ← mean(L5)
L ← augment(L, L5)
g6 ←  $\frac{P_s^{(7\text{-str})}}{mv}$ 
x ←  $\left\{ \begin{array}{l} s \leftarrow g6 \\ \text{for } i \in 0..Z \\ \quad s \leftarrow \text{stack}(s, g6) \end{array} \right.$ 
s
opor ← morm(kadr·N, 1.5, 1)
v ← x - opor
V_sgn ←  $\left\{ \begin{array}{l} \text{for } p \in 0..kadr - 1 \\ \quad \text{for } j \in 0..N - 1 \\ \quad \quad S_{j,p} \leftarrow \left\{ \begin{array}{l} 1 \text{ if } v_{p \cdot N + j} \geq 0 \\ -1 \text{ otherwise} \end{array} \right. \end{array} \right.$ 
S
L6 ←  $\left\{ \begin{array}{l} \text{for } p \in 0..kadr - 1 \\ \quad \left\{ \begin{array}{l} U \leftarrow \text{stack}(V\_sgn^{(p)}, 0) \\ B_p \leftarrow \frac{1}{N} \cdot \sum_{n=0}^{N-1} U_n \cdot U_{n+1} \end{array} \right. \end{array} \right.$ 
B

```

```

M_L6 ← mean(L6)
L ← augment(L, L6)
g7 ←  $\frac{P_s^{\langle 8 \cdot \text{str} \rangle}}{mv}$ 
x ←  $\left| \begin{array}{l} s \leftarrow g7 \\ \text{for } i \in 0..Z \\ \quad s \leftarrow \text{stack}(s, g7) \end{array} \right|$ 
   s
opor ← rexp(kadr·N, 2)
v ← x - opor
V_sgn ←  $\left| \begin{array}{l} \text{for } p \in 0..kadr - 1 \\ \quad \text{for } j \in 0..N - 1 \\ \quad \quad S_{j,p} \leftarrow \left| \begin{array}{l} 1 \text{ if } v_{p \cdot N + j} \geq 0 \\ -1 \text{ otherwise} \end{array} \right| \end{array} \right|$ 
   S
L7 ←  $\left| \begin{array}{l} \text{for } p \in 0..kadr - 1 \\ \quad \left| \begin{array}{l} U \leftarrow \text{stack}(V\_sgn^{\langle p \rangle}, 0) \\ B_p \leftarrow \frac{1}{N} \cdot \sum_{n=0}^{N-1} U_n \cdot U_{n+1} \end{array} \right| \end{array} \right|$ 
   B
M_L7 ← mean(L7)
L ← augment(L, L7)
g8 ←  $\frac{P_s^{\langle 9 \cdot \text{str} \rangle}}{mv}$ 
x ←  $\left| \begin{array}{l} s \leftarrow g8 \\ \text{for } i \in 0..Z \\ \quad s \leftarrow \text{stack}(s, g8) \end{array} \right|$ 
   s
opor ←  $\left| \begin{array}{l} \text{for } i \in 0..kadr \cdot N - 1 \\ \quad d_i \leftarrow \text{md}(3) - 0.5 \end{array} \right|$ 
   d
v ← x - opor
V_sgn ←  $\left| \begin{array}{l} \text{for } p \in 0..kadr - 1 \\ \quad \text{for } j \in 0..N - 1 \\ \quad \quad S_{j,p} \leftarrow \left| \begin{array}{l} 1 \text{ if } v_{p \cdot N + j} \geq 0 \\ -1 \text{ otherwise} \end{array} \right| \end{array} \right|$ 
   S
L8 ←  $\left| \begin{array}{l} \text{for } p \in 0..kadr - 1 \\ \quad \left| \begin{array}{l} U \leftarrow \text{stack}(V\_sgn^{\langle p \rangle}, 0) \\ B \leftarrow \frac{1}{N} \cdot \sum U \cdot U \end{array} \right| \end{array} \right|$ 

```


$$PZ := \frac{1}{100} \sum_{i=0}^{99} PG_i$$

PZ =

	0
0	0.525
1	0.169
2	0.287
3	0.37
4	0.023
5	0.35
6	0.238
7	0.175
8	0.229
9	0.018
10	0.071

M_L := $\left\{ \begin{array}{l} \text{for } i \in 0..9 \\ a_i \leftarrow (PZ)_i \\ a \end{array} \right.$

R0 := PZ₁₀

m0 := M_L

R0 = 0.071

m0 =

	0
0	0.525
1	0.169
2	0.287
3	0.37
4	0.023
5	0.35
6	0.238
7	0.175
8	0.229
9	0.018

DF := stack(m0, R0)

WRITEPRN("ford_c") := DF

ПРИЛОЖЕНИЕ Б

Классификация

DD0 := READPRN("ford_c.prn")

DD0 =

	0
0	0.525
1	0.169
2	0.287
3	0.37
4	0.023
5	0.35
6	0.238
7	0.175
8	0.229
9	0.018
10	0.071

R0 := DD0₁₀

R0 = 0.071

m0 := $\left\{ \begin{array}{l} \text{for } i \in 0..9 \\ s_i \leftarrow \text{DD0}_i \\ s \end{array} \right.$

m0 =

	0
0	0.525
1	0.169
2	0.287
3	0.37
4	0.023
5	0.35
6	0.238
7	0.175
8	0.229
9	0.018

DD1 := READPRN("vv_c.prn")

DD1 =

	0
0	0.506
1	0.137
2	0.273
3	0.321
4	7.031·10 ⁻³
5	0.44
6	0.265
7	0.299
8	0.098
9	0.031
10	0.071

R1 := DD1₁₀

R1 = 0.071

m1 := $\left\{ \begin{array}{l} \text{for } i \in 0..9 \\ s_i \leftarrow \text{DD1}_i \\ s \end{array} \right.$

m1 =

	0
0	0.506
1	0.137
2	0.273
3	0.321
4	7.031·10 ⁻³
5	0.44
6	0.265
7	0.299
8	0.098
9	0.031

DD2 := READPRN("sobol_c.prm")

DD2 =

	0
0	0.426
1	0.278
2	0.313
3	0.207
4	0.018
5	0.587
6	0.048
7	0.479
8	0.099
9	0.029
10	0.071

R2 := DD2₁₀

R2 = 0.071

m2 := $\left\{ \begin{array}{l} \text{for } i \in 0..9 \\ s_i \leftarrow \text{DD2}_i \\ s \end{array} \right.$

m2 =

	0
0	0.426
1	0.278
2	0.313
3	0.207
4	0.018
5	0.587
6	0.048
7	0.479
8	0.099
9	0.029

DD3 := READPRN("sobol2_c.prm")

DD3 =

	0
0	0.208
1	0.286
2	0.141
3	0.191
4	0.024
5	0.574
6	0.019
7	0.536
8	0.101
9	0.022
10	0.069

R3 := DD3₁₀

R3 = 0.069

m3 := $\left\{ \begin{array}{l} \text{for } i \in 0..9 \\ s_i \leftarrow \text{DD3}_i \\ s \end{array} \right.$

m3 =

	0
0	0.208
1	0.286
2	0.141
3	0.191
4	0.024
5	0.574
6	0.019
7	0.536
8	0.101
9	0.022

```

Rez := P ←  $\frac{\text{READBMP}(\text{"sobel\_g"})}{255}$ 
str ← 95
sm ← 3
Ps ← PT
dop ← length(Ps<str>) - 211
N ← 211 + dop
kadr ← 1
sum0 ← 0
sum1 ← 0
sum2 ← 0
sum3 ← 0
Z ← kadr - 2
mat ← | for t ∈ 0..9
      | fgt ← mean[Ps<(t+1)·str+sm>]
      | fg
mv ← mean(mat)
for kp ∈ 0..99
fcckp ← | g ←  $\frac{Ps^{\langle 1 \cdot \text{str} + \text{sm} \rangle}}{mv}$ 
        | x ← g
        | opor ← morm(kadr·N, 1, 0.6)
        | v ← x - opor
        | V_sgn ← | for p ∈ 0..kadr - 1
                | for j ∈ 0..N - 1
                | Sj,p ← | 1 if vp·N+j ≥ 0
                | -1 otherwise
                | S
        | L0 ← | for p ∈ 0..kadr - 1
              | U ← stack(V_sgn<p>, 0)
              | Bp ←  $\frac{1}{N} \cdot \sum_{n=0}^{N-1} U_n \cdot U_{n+1}$ 
              | B
        | L ← L0
        | g1 ←  $\frac{Ps^{\langle 2 \cdot \text{str} + \text{sm} \rangle}}{mv}$ 
        | x ← g1
        | opor ← | for i ∈ 0..kadr·N - 1
                | di ← md(2.5)

```

```

      | d
v = x - opor
V_sgn ← | for p ∈ 0..kadr - 1
        | for j ∈ 0..N - 1
        |   S_{j,p} ← | 1 if v_{p·N+j} ≥ 0
        |               | -1 otherwise
        | S
L1 ← | for p ∈ 0..kadr - 1
    |   U ← stack(V_sgn^{(p)}, 0)
    |   B_p ← 1/N · ∑_{n=0}^{N-1} U_n · U_{n+1}
    | B
L ← stack(L, L1)
g2 ←  $\frac{P_s^{(3 \cdot \text{str} + \text{sm})}}{mv}$ 
x ← g2
opor ← rexp(kadr·N, 1)
v = x - opor
V_sgn ← | for p ∈ 0..kadr - 1
        | for j ∈ 0..N - 1
        |   S_{j,p} ← | 1 if v_{p·N+j} ≥ 0
        |               | -1 otherwise
        | S
L2 ← | for p ∈ 0..kadr - 1
    |   U ← stack(V_sgn^{(p)}, 0)
    |   B_p ← 1/N · ∑_{n=0}^{N-1} U_n · U_{n+1}
    | B
L ← stack(L, L2)
g3 ←  $\frac{P_s^{(4 \cdot \text{str} + \text{sm})}}{mv}$ 
x ← g3
opor ← morm(kadr·N, 0.3, 1.2)
v = x - opor
V_sgn ← | for p ∈ 0..kadr - 1
        | for j ∈ 0..N - 1
        |   S_{j,p} ← | 1 if v_{p·N+j} ≥ 0
        |               | -1 otherwise
        | S
L3 ← | for p ∈ 0..kadr - 1

```

$$\begin{array}{|l}
 \left| \begin{array}{l}
 U \leftarrow \text{stack}(V_sgn^{(p)}, 0) \\
 B_p \leftarrow \frac{1}{N} \cdot \sum_{n=0}^{N-1} U_n \cdot U_{n+1}
 \end{array} \right. \\
 \left| B
 \end{array}$$

$L \leftarrow \text{stack}(L, L3)$
 $g4 \leftarrow \frac{P_s^{(5 \cdot \text{str} + \text{sm})}}{mv}$
 $x \leftarrow g4$
 $\text{opor} \leftarrow \left| \begin{array}{l} \text{for } i \in 0..kadr \cdot N - 1 \\ d_i \leftarrow \text{rnd}(5) - 1 \end{array} \right|$
 $\left| d$
 $v = x - \text{opor}$
 $V_sgn \leftarrow \left| \begin{array}{l} \text{for } p \in 0..kadr - 1 \\ \text{for } j \in 0..N - 1 \\ S_{j,p} \leftarrow \left| \begin{array}{l} 1 \text{ if } v_{p \cdot N + j} \geq 0 \\ -1 \text{ otherwise} \end{array} \right. \end{array} \right|$
 $\left| S$
 $L4 \leftarrow \left| \begin{array}{l} \text{for } p \in 0..kadr - 1 \\ \left| \begin{array}{l} U \leftarrow \text{stack}(V_sgn^{(p)}, 0) \\ B_p \leftarrow \frac{1}{N} \cdot \sum_{n=0}^{N-1} U_n \cdot U_{n+1} \end{array} \right. \\ \left| B \end{array} \right.$
 $L \leftarrow \text{stack}(L, L4)$
 $g5 \leftarrow \frac{P_s^{(6 \cdot \text{str} + \text{sm})}}{mv}$
 $x \leftarrow g5$
 $\text{opor} \leftarrow \text{morm}(kadr \cdot N, 0.5, 0.8)$
 $v = x - \text{opor}$
 $V_sgn \leftarrow \left| \begin{array}{l} \text{for } p \in 0..kadr - 1 \\ \text{for } j \in 0..N - 1 \\ S_{j,p} \leftarrow \left| \begin{array}{l} 1 \text{ if } v_{p \cdot N + j} \geq 0 \\ -1 \text{ otherwise} \end{array} \right. \end{array} \right|$
 $\left| S$
 $L5 \leftarrow \left| \begin{array}{l} \text{for } p \in 0..kadr - 1 \\ \left| \begin{array}{l} U \leftarrow \text{stack}(V_sgn^{(p)}, 0) \\ B_p \leftarrow \frac{1}{N} \cdot \sum_{n=0}^{N-1} U_n \cdot U_{n+1} \end{array} \right. \\ \left| B \end{array} \right.$
 $L \leftarrow \text{stack}(L, L5)$

$$g6 \leftarrow \frac{P_s^{(7 \cdot \text{str} + \text{sm})}}{mv}$$

$$x \leftarrow g6$$

$$\text{opor} \leftarrow \text{morm}(\text{kadr} \cdot N, 1.5, 1)$$

$$v = x - \text{opor}$$

$$V_sgn \leftarrow \begin{array}{l} \text{for } p \in 0.. \text{kadr} - 1 \\ \quad \text{for } j \in 0.. N - 1 \\ \quad \quad S_{j,p} \leftarrow \begin{array}{l} 1 \text{ if } v_{p \cdot N + j} \geq 0 \\ -1 \text{ otherwise} \end{array} \end{array}$$

S

$$L6 \leftarrow \begin{array}{l} \text{for } p \in 0.. \text{kadr} - 1 \\ \quad U \leftarrow \text{stack}(V_sgn^{(p)}, 0) \\ \quad B_p \leftarrow \frac{1}{N} \cdot \sum_{n=0}^{N-1} U_n \cdot U_{n+1} \end{array}$$

B

$$L \leftarrow \text{stack}(L, L6)$$

$$g7 \leftarrow \frac{P_s^{(8 \cdot \text{str} + \text{sm})}}{mv}$$

$$x \leftarrow g7$$

$$\text{opor} \leftarrow \text{rexp}(\text{kadr} \cdot N, 2)$$

$$v = x - \text{opor}$$

$$V_sgn \leftarrow \begin{array}{l} \text{for } p \in 0.. \text{kadr} - 1 \\ \quad \text{for } j \in 0.. N - 1 \\ \quad \quad S_{j,p} \leftarrow \begin{array}{l} 1 \text{ if } v_{p \cdot N + j} \geq 0 \\ -1 \text{ otherwise} \end{array} \end{array}$$

S

$$L7 \leftarrow \begin{array}{l} \text{for } p \in 0.. \text{kadr} - 1 \\ \quad U \leftarrow \text{stack}(V_sgn^{(p)}, 0) \\ \quad B_p \leftarrow \frac{1}{N} \cdot \sum_{n=0}^{N-1} U_n \cdot U_{n+1} \end{array}$$

B

$$L \leftarrow \text{stack}(L, L7)$$

$$g8 \leftarrow \frac{P_s^{(9 \cdot \text{str} + \text{sm})}}{mv}$$

$$x \leftarrow g8$$

$$\text{opor} \leftarrow \begin{array}{l} \text{for } i \in 0.. \text{kadr} \cdot N - 1 \\ \quad d_i \leftarrow \text{md}(3) - 0.5 \end{array}$$

d

$$v = x - \text{opor}$$

$$V_sgn \leftarrow \begin{array}{l} \text{for } p \in 0.. \text{kadr} - 1 \end{array}$$

```

      for j ∈ 0..N-1
      Sj,p ←  $\begin{cases} 1 & \text{if } v_{p \cdot N + j} \geq 0 \\ -1 & \text{otherwise} \end{cases}$ 
      S
L8 ← for p ∈ 0..kadr-1
      U ← stack(V_sgn(p), 0)
      Bp ←  $\frac{1}{N} \cdot \sum_{n=0}^{N-1} U_n \cdot U_{n+1}$ 
      B
L ← stack(L, L8)
g9 ←  $\frac{P_s^{(10 \cdot \text{str} + \text{sm})}}{mv}$ 
x ← g9
opor ← for i ∈ 0..kadr·N-1
      di ← md(4) - 1.5
      d
v = x - opor
V_sgn ← for p ∈ 0..kadr-1
      for j ∈ 0..N-1
      Sj,p ←  $\begin{cases} 1 & \text{if } v_{p \cdot N + j} \geq 0 \\ -1 & \text{otherwise} \end{cases}$ 
      S
L9 ← for p ∈ 0..kadr-1
      U ← stack(V_sgn(p), 0)
      Bp ←  $\frac{1}{N} \cdot \sum_{n=0}^{N-1} U_n \cdot U_{n+1}$ 
      B
L ← stack(L, L9)
Dr0 ←  $\sum_{i=0}^{10-1} (L_i - m0_i)^2 - (2R0)^2$ 
FF0 ←  $\begin{cases} 0 & \text{if } Dr0 > 0 \\ 1 & \text{otherwise} \end{cases}$ 
sum0kp ← FF0
Dr1 ←  $\sum_{i=0}^{10-1} (L_i - m1_i)^2 - (2R1)^2$ 
FF1 ←  $\begin{cases} 0 & \text{if } Dr1 > 0 \\ 1 & \text{otherwise} \end{cases}$ 
sum1kp ← FF1

```

$$\begin{aligned}
 \text{Dr2} &\leftarrow \sum_{i=0}^{10-1} (L_i - m2_i)^2 - (2R2)^2 \\
 \text{FF2} &\leftarrow \begin{cases} 0 & \text{if } \text{Dr2} > 0 \\ 1 & \text{otherwise} \end{cases} \\
 \text{sum2}_{\text{kp}} &\leftarrow \text{FF2} \\
 \text{Dr3} &\leftarrow \sum_{i=0}^{10-1} (L_i - m3_i)^2 - (2R3)^2 \\
 \text{FF3} &\leftarrow \begin{cases} 0 & \text{if } \text{Dr3} > 0 \\ 1 & \text{otherwise} \end{cases} \\
 \text{sum3}_{\text{kp}} &\leftarrow \text{FF3} \\
 \text{sum} &\leftarrow \text{augment}(\text{sum0}, \text{sum1}, \text{sum2}, \text{sum3})
 \end{aligned}$$

Rez =

	0	1	2	3
0	0	0	1	0
1	0	0	1	0
2	0	0	1	0
3	0	0	1	0
4	0	0	1	0
5	0	0	1	0
6	0	0	1	0
7	0	0	1	0
8	0	0	1	0
9	0	0	1	0
10	0	0	1	0
11	0	0	1	0
12	0	0	1	0
13	0	0	1	0
14	0	0	1	0
15	0	0	1	0

$$\sum_{i=0}^{99} \text{Rez}_{i,2} = 100$$


ПРИЛОЖЕНИЕ В

"УТВЕРЖДАЮ"

Директор НИИ МВС ТРТУ

И.А. Каляев

июня 2005 г.



АКТ

внедрения результатов диссертационной работы
на соискание ученой степени кандидата технических наук
Дударова Дениса Александровича

Результаты, полученные в кандидатской диссертации Дударова Д.А. "Исследование и разработка методов формирования решающих правил при классификации сигналов изображений" использовались в разработках в лаборатории № 23 НИИ МВС ТРТУ в рамках НИР "Известность-Т" и "Миля-Т".

В частности внедрены следующие результаты:


- методика преобразования оцифрованных сигналов изображения на основе нелинейного преобразования;
- алгоритм формирования классификационных признаков на основе метода стохастического кодирования сигналов изображений;
- методы классификации полутоновых оцифрованных изображений на основе метода стохастического кодирования сигналов изображений.

Разработанные алгоритмы отличаются высокой универсальностью и могут быть использованы в ряде приборов для автоматизированной классификации изображений. Полученные в диссертации научные и практические результаты реализованы при разработке устройств систем технического зрения дистанционно управляемых и автономных объектов.

Зав. лабораторией № 23

к.т.н.

Капустян С.Г.



"УТВЕРЖДАЮ"

Главный инженер

НКС "МИУС" ТРТУ

А.Н. Головченко

июня 2005г.

АКТ

внедрения результатов диссертационной работы
на соискание ученой степени кандидата технических наук
Дударова Дениса Александровича

Полученные результаты, в кандидатской диссертации Дударова Д.А. "Исследование и разработка методов формирования решающих правил при классификации сигналов изображений" использовались в разработках отдела 15 НКБ "МИУС" ТРТУ в рамках темы Стенд 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

Начальник отдела 24

В.Н. Сапрунов

В.А. Буряк



ТВЕРЖДАЮ"

научной работе

В.М. Курейчик

июня 2005 г.

АКТ

внедрения результатов диссертационной работы на соискание ученой степени кандидата технических наук Дударова Дениса Александровича

Комиссия в составе декана РТФ к.т.н., доцента Грищенко С.Г., д.т.н., профессора Плаксиенко В.С., к.т.н., доцента Бровченко С.П. рассмотрела научные и практические результаты кандидатской диссертации Дударова Д.А. "Исследование и разработка методов формирования решающих правил при классификации сигналов изображений" и составила настоящий акт о внедрении в учебный процесс на кафедре РПрУ и ТВ научных и практических результатов данной диссертационной работы.

При постановке лабораторных и практических работ по курсу "Основы цифрового телевидения" использовались следующие результаты, полученные в диссертации:

- обзор и анализ современных систем компьютерной обработки изображений;
- методы формирования статистических признаков сигналов изображения;
- стенд к лабораторной работе "Специализированная ТВ-система".

Предложенные модели и алгоритмы могут быть использованы для количественного анализа и физической интерпретации экспериментальных данных при проведении автоматической классификации, а так же для разработки методов и аппаратуры распознающих систем.

Председатель: декан РТФ
к.т.н., доцент

Грищенко С.Г.

Члены комиссии: д.т.н., профессор

Плаксиенко В.С.

к.т.н., доцент

Бровченко С.П.