

ВОРОНЕЖСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ

На правах рукописи

Дуденков Владимир Михайлович

**РАЗРАБОТКА НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ
ЧЕЛОВЕКОМАШИННОГО ОБЩЕНИЯ**

Специальность

05.13.17 – Теоретические основы информатики

диссертация на соискание ученой степени

кандидата физико-математических наук

Научный руководитель

доктор технических наук,

профессор Новикова Нелля Михайловна

Воронеж – 2016

ОГЛАВЛЕНИЕ

Список сокращений	4
Введение.....	5
ГЛАВА I. Анализ информационных человеко-машинных систем.....	11
1.1. Основные понятия инженерной психологии	11
1.2. Основные характеристики системы «человек-машина».....	15
1.3. Роль человека в системе «человек-машина».....	26
1.4. Математические модели работы человека в системах «человек-машина»	31
Выводы по главе I	35
Глава II. Математическая имитационная модель работы человека-оператора в системе «человек-дисплей».....	37
2.1. Основные теоретические предпосылки для построения имитационной модели человека-оператора.....	38
2.2. Методика проведения эксперимента по распознаванию изображений человеком-оператором.....	50
2.3. Оценка зрительного утомления человека-оператора в эксперименте по распознаванию изображений	55
Выводы по главе II	63
Глава III. Нейросетевые модели распознавания изображений человеком- оператором	64
3.1. Базовые понятия нейросетевого моделирования.....	64
3.2. Использование сверточных нейронных сетей для распознавания изображений	79
3.3. Нейросетевой распознавательный комплекс и математическая модель работы человека-оператора.....	84
3.4. Использование гибридной сети нечеткой логики для принятия решения	89
Выводы по главе III.....	95
Глава IV. Описание программного комплекса и вычислительных экспериментов	98
4.1. Общая схема работы распознавательного комплекса.....	98
4.2. Компьютерное моделирование нейросетевого классификатора и эксперимент с операторами	105
Выводы по главе IV	113
ОСНОВНЫЕ ВЫВОДЫ ПО ДИССЕРТАЦИИ	114

Список использованных источников	116
Приложение А	125
Приложение В.....	127
Приложение С.....	128

СПИСОК СОКРАЩЕНИЙ

SOM	self-organizing map
UML	unified modeling language
ОСМ	обобщенный структурный метод
СОИ	средства отображения информации
СЧМ	система «человек-машина»
УО	управляемый объект
ЭВМ	электронно-вычислительная машина

ВВЕДЕНИЕ

Актуальность темы исследования. Сближение технологий, повышающих возможности человека в освоении биотехнологий, информационных технологий и когнитивных наук, является одним из современных направлений в развитии науки и техники. О важности и актуальности этого направления можно судить потому, что эта проблема обсуждалась в докладе министерства обороны Великобритании «Стратегический контекст будущего» и на конференции «Конвергенция технологий, повышающих возможности человека: нанотехнологии, биотехнологии, информационные технологии и когнитивные науки». Эту конференцию провела группа по изучению проблем национальной безопасности США. Реальное сближение фундаментальных и прикладных исследований осуществляется Агентством по прорывным исследовательским проектам в области обороны США (DARPA) и японской программой ERATO (Exploratory Research for Advanced Technology).

Результаты таких исследований приведут в кибернетике к тому, что максимально сблизятся возможности естественного и искусственного интеллектов за счет освоения нейроподобных вычислительных технологий. В военной технике – к развитию интерфейсов для системы «человек-машина», разработке систем, имитирующих поведение водителей и пилотов бронетанковой и авиационной техники, подводных лодок, кораблей, развитию более совершенных методов обучения и тренировки военнослужащих. Идет реальное финансирование исследований, направленных на сближение био- и информационных технологий, в результате чего наступает качественно новый этап развития и исследования человеко-машинных систем, в которых перераспределяются функции между искусственным и естественным интеллектами.

Степень разработанности темы исследования. Исследованию информационных человеко-машинных систем посвящено много работ как психологов (Ломов Б.Ф., Венда В.Ф., Зинченко В.П. и др.), так и инженеров

(Губинский А.И., Павлов В.В., Поспелов Д.А., Новикова Н.М. и др.). Среди зарубежных исследователей следует отметить работы Шеридана Т., Феррел У., Левис А. и др. В этих исследованиях рассматриваются различные модели работы человека-оператора в информационной системе, но ни в одном из исследований не рассмотрены нейросетевые модели и работа человека с дисплеем. Следовательно, построение и анализ математических моделей работы человека-оператора на основе нейронных сетей при работе с дисплеем является весьма актуальной задачей. Решению этой актуальной задачи посвящена данная диссертация.

Диссертационная работа выполнена в рамках одного из основных научных направлений Воронежского государственного университета «Математическое моделирование, программное и информационное обеспечение, методы вычислительной и прикладной математики и их применение к фундаментальным исследованиям в естественных науках».

Цель и задачи. Целью диссертационной работы является разработка модели работы человека-оператора при решении задачи распознавания и классификации изображений, а также нейросетевого распознавательного комплекса, основанного на данной модели.

Для достижения поставленной цели необходимо решить следующие задачи.

1. Разработать структурную модель работы человека-оператора в системе «человек-дисплей» на основании исследований в области инженерной и когнитивной психологии, психофизики и теории статистических решений.
2. На основе структурной модели разработать методику натурального эксперимента и провести эксперимент с группой операторов.
3. Исследовать возможность и особенности применения нейронных сетей для имитационного моделирования работы человека-оператора, распознающего изображения, предъявляемые на экране дисплея компьютера.

4. Разработать и реализовать нейросетевой распознавательный комплекс для моделирования работы человека-оператора.
5. Создать программное обеспечение компьютерных моделей и оценить их работоспособность на основе вычислительных экспериментов.

Научная новизна. В работе получены следующие результаты, характеризующиеся научной новизной:

1. Разработана структурная модель работы человека-оператора решающего задачу распознавания изображений, отличающаяся тем, что использует как статистические, так и психологические законы восприятия, и позволяющая оценить эффективность систем «человек-дисплей».
2. Структурная модель представлена в виде двух подсистем – когнитивной и решающей, что позволило применить нейросетевые модели для их компьютерной реализации.
3. Разработана архитектура построения нейросетевого комплекса, основанного на самоорганизующихся картах Кохонена и гибридной нейронной сети, позволяющая моделировать и оценивать работу человека-оператора.
4. Создано специальное программное обеспечение для проведения вычислительных экспериментов, позволяющее провести анализ работы нейросетевых моделей и человека-оператора.

Содержание диссертации соответствует специальности 05.13.17. – «Теоретические основы информатики» по следующим областям исследований: исследование информационных структур, разработка и анализ моделей информационных процессов и структур (п. 2 паспорта специальности); разработка методов, языков и моделей человеко-машинного общения; разработка методов и моделей распознавания, понимания и синтеза речи, принципов и методов извлечения данных из текстов на естественном языке (п. 6 паспорта специальности).

Теоретическая и практическая значимость работы. Работа имеет теоретический и практический характер. Теоретические обоснования разработки структурной модели работы человека-оператора по распознаванию изображений позволяют проектировать и использовать нейросетевые системы классификации в системе «человек-дисплей». Теоретические результаты диссертации используются в учебном процессе Воронежского государственного университета при чтении спецкурсов и выполнении курсовых, дипломных работ и магистерских диссертаций.

Практические результаты работы используются и тестируются на предприятия ООО «Тэга» в г. Воронеж. По результатам диссертационной работы получены свидетельства о государственной регистрации программ для ЭВМ № 2015618275 «DirectAndConvolutionNet 1.0» от 4 августа 2015г. и № 2015618276 «FuzzyAndCohonenNet 1.0» от 4 августа 2015г.

Методология и методы исследования. Для решения поставленных в диссертационной работе задач были использованы методы теории статистических решений, психофизики, инженерной и когнитивной психологии; методы теории распознавания образов и обработки изображений; технологии программирования, а также аппарат искусственных нейронных сетей.

Положения, выносимые на защиту. На защиту выносятся следующие результаты, впервые достаточно полно развитые и полученные в диссертации.

1. Модель работы человека-оператора в задаче распознавания изображений, основанная на применении теории статистических решений и инженерной психологии, психофизики и когнитивной психологии.
2. Алгоритм работы нейросетевого распознавательного комплекса на основе сегментации изображений, карт Кохонена, нечеткого гибридного классификатора, позволяющий распознавать изображения в условиях малого объема обучающей выборки.

3. Методика проведения вычислительных экспериментов по распознаванию зашумленных изображений с операторами и созданными нейросетевыми моделями, анализ результатов экспериментов.
4. Программный комплекс для проведения вычислительных экспериментов по разработанным алгоритмам.

Достоверность результатов работы. Результаты исследований, сформулированные в диссертации, получены на основе корректного использования взаимно дополняющих друг друга теоретических и экспериментальных (имитационное моделирование) методов исследований.

Личный вклад автора. Основные результаты по теме диссертации были получены лично автором и опубликованы в соавторстве с научным руководителем. Научный руководитель определил основные направления исследований.

Степень достоверности и апробация результатов. Основные положения диссертации докладывались и обсуждались на следующих конференциях: XIII, XIV, XVI Международной научно-технической конференции «Кибернетика и высокие технологии XXI века» (Воронеж, 2012, 2013, 2015), седьмой Международной научно-технической конференции «Информатизация процессов формирования открытых систем на основе САПР, АСНИ, СУБД и систем искусственного интеллекта» (Вологда, 2013), Воронежской весенней математической школе «Понтрягинские чтения - XXIV» (2013), XIV Международной научно-технической конференции «Информатика: проблемы, методология, технологии» (Воронеж, 2014), VII Международной научной конференции «Современные методы математики, теории управления и компьютерных технологий» (Воронеж, 2014), научных сессиях Воронежского государственного университета (2012-2016).

Публикации. По теме диссертации (лично и в соавторстве) опубликовано 12 работ, из них 2 работы – в изданиях, рекомендованных ВАК

РФ. Получены 2 свидетельства о государственной регистрации программ для ЭВМ.

Объем и структура работы. Диссертация состоит из введения, четырех глав, заключения и списка литературы из 80 наименований. Объем диссертации составляет 131 страницу, включая 114 страниц основного текста, содержащего 27 рисунков и 13 таблиц.

ГЛАВА I. АНАЛИЗ ИНФОРМАЦИОННЫХ ЧЕЛОВЕКО-МАШИННЫХ СИСТЕМ

1.1. Основные понятия инженерной психологии

Инженерная психология представляет собой отрасль науки, изучающую особенности и закономерности отношений между человеком и техникой. Традиционным определением инженерной психологии можно считать следующее высказывание [34]: «Инженерная психология - есть научная дисциплина, изучающая объективные закономерности процессов информационного взаимодействия человека и техники с целью использования их в практике проектирования, создания и изучения СЧМ». Таким образом, предметом инженерной психологии является система «человек-машина» (в качестве синонима часто употребляются понятия «антропотехническая система», «эргатическая система», «эрготехническая система», «система «человек-техника»). Главным субъектом труда в инженерной психологии является «оператор» (тот, кто посредством информационных процессов взаимодействует со сложной информационной системой). Цель инженерной психологии - создание психологических основ для проектирования оборудования с учётом влияния «человеческого фактора» и повышения продуктивности системы «человек-машина».

Рассматривая понятие системы «человек-машина», следует обратить внимание на некоторые терминологические особенности. Помимо термина система «человек - машина», в научной литературе можно встретить и другие, сходные термины: антропотехническая система, эргатическая система, система «человек-техника», система «оператор-машина» и др. Детальный анализ и особенности применения этих терминов рассмотрены Ю.Г. Фокиным [69]. Так, например, чтобы подчеркнуть роль внешней среды иногда используется такое понятие, как система «человек-машина-среда». Однако в этом нет особой необходимости, так как любая СЧМ всегда работает в условиях определенной среды. В дальнейшем ограничимся использованием термина система «человек-машина».

Исходя из предмета и цели инженерной психологии, можно сделать вывод, что эта научная дисциплина находится на стыке технических и психологических наук. Смежной с инженерной психологией дисциплиной является также эргономика. Эргономика — отрасль науки, изучающая человека и его деятельность в условиях производства, с целью совершенствования орудий, условий и процесса труда [42, 63]. Предметом исследования эргономики, также как и инженерной психологии, являются системы «человек-машина», в том числе и так называемые эргатические системы [34].

Поскольку инженерная психология находится на стыке технических и психологических наук, развернуто ответить на вопрос «Что же изучает инженерная психология?» можно двумя способами [17].

Как психологическая наука инженерная психология изучает психические и психофизиологические процессы и свойства человека, выясняя, какие требования к отдельным техническим устройствам и построению СЧМ в целом вытекают из особенностей человеческой деятельности, т. е. решает задачу приспособления техники и условий труда к человеку.

Как техническая наука инженерная психология изучает принципы построения сложных информационных систем, посты и пульты управления, кабины машин, технологические процессы для выяснения требований, предъявляемых к психологическим, психофизиологическим и другим свойствам человека-оператора.

В своем развитии инженерная психология прошла два основных этапа. Первоначально в ней преобладали исследования аналитического типа, связанные с оценками тех или иных отдельно взятых технических устройств и элементов с точки зрения их соответствия также отдельно взятым психологическим характеристикам человека. Этот этап развития инженерной психологии иногда называют коррективным [17]. Характерным для него является подход, который при анализе систем «человек - машина» основное

внимание уделяет технике, а не оператору (машиноцентрический подход). При этом человек рассматривается как простое звено СЧМ. В период коррективного этапа были выполнены многочисленные исследования восприятия показаний различных приборов и индикаторов, различения и опознания цифр, букв, условных знаков и т. д., т. е. отдельно взятых сигналов, при помощи которых информация передается человеку. То же самое можно сказать и относительно исследования управляющих движений. Эти исследования дали полезные результаты. Они позволили разработать инженерно-психологические требования к различным типам средств отображения информации и органам управления, к их взаимному расположению, последовательности использования и т. п. Однако реальная деятельность человека-оператора сводится в них к элементарным реакциям, поэтому накопленные в этих исследованиях данные имеют ограниченное применение.

Возникновению инженерной психологии предшествовало развитие физиологии и антропологии, а также практической деятельности, связанной с безопасностью и организацией труда. Тем не менее, простого объединения фрагментарных знаний из разных наук с целью использования их при проектировании техники оказалось недостаточно. Возникла необходимость в исследованиях, основанных на полноценной трактовке значимости человеческого фактора в системе «человек-машина». При этом появляется возможность не только приспособлять технику и схему ее функционирования к человеку или коллективу, но и формировать их способности в соответствии с требованиями, которые предъявляет к ним современная техника. Главный упор в этом случае делается на проектирование деятельности оператора, то есть происходит переход от машиноцентрического к антропоцентрическому подходу при анализе систем «человек-машина». Этот этап развития инженерной психологии называют проективным.

В процессе развития инженерной психологии осуществился переход от относительно простых и частных вопросов к более сложным и общим. При этом человек-оператор стал рассматриваться не как простое звено СЧМ, а как сложная высокоорганизованная система. Первостепенное значение при этом имеет реализация информационного подхода к анализу СЧМ. Это вытекает из логики развития инженерной психологии в качестве науки и из практических требований практики.

Выделяют следующие задачи инженерной психологии как науки [63, 66]:

1. Разработка теоретических основ проектирования деятельности человека-оператора с учётом специфики эксплуатируемой техники и рабочей среды.
2. Исследование закономерностей взаимодействия человека с техническими системами и окружающей средой.
3. Разработка принципов создания систем «человек-машина» и алгоритмов деятельности операторов.
4. Изучение факторов (в том числе психологических), влияющих на деятельность оператора.
5. Нахождение наиболее эффективного распределения функций между человеком и техникой в системе «человек-машина».
6. Изучение процессов преобразования информации оператором: приём информации, переработка информации, принятие решения, осуществление управляющих воздействий.
7. Обобщение опыта создания и эксплуатации человеко-машинных систем, стандартизация эффективных решений.
8. Поиск связей между качеством труда и обеспечивающими его эргономическими параметрами.
9. Разработка методологии построения рабочих мест и интерфейсов.
10. Изучение деятельности групп операторов, процесса их взаимодействия.

11. Проектирование и оценка систем «человек-машина». Это обобщающая задача, и при её решении используются результаты, полученные при решении всех предыдущих задач.

В качестве примеров конкретных практических задач инженерной психологии можно выделить следующие: проведение комплексных эргономических экспертиз, проектирование среды обитания, внедрение определенных стандартов поведения на производстве, и т. д. Рассмотрев задачи инженерной психологии, становится очевидной основная ее цель - повышение эффективности систем «человек-машина».

1.2. Основные характеристики системы «человек-машина»

Рассмотрим, что является предметом изучения, и какие задачи решает инженерная психология. Предмет инженерной психологии — процессы и структура информационного взаимодействия человека и технических систем, в том числе приёма, переработки, хранения информации, принятия решений и психической регуляции управляющих действий.

Объектом инженерной психологии является система «человек-машина». Под системой в общей теории систем понимается комплекс взаимосвязанных и взаимодействующих между собой элементов, предназначенный для решения единой задачи [76]. Системы могут быть классифицированы по различным признакам. Одним из них является степень участия человека в работе системы. С этой точки зрения различают автоматические, автоматизированные и неавтоматические системы. Работа автоматической системы осуществляется без участия человека. В неавтоматической системе работа выполняется человеком без применения технических устройств. В работе автоматизированной системы принимает участие и человек, и технические устройства. Такая система представляет собой систему «человек-машина». Таким образом, под СЧМ понимается система, состоящая из человека-оператора (группы операторов) и машины, посредством которой он осуществляет (они осуществляют) трудовую деятельность. Машинной в

данном случае называются технические средства, используемые в процессе деятельности. Под оператором в эргономике и инженерной психологии понимается человек, осуществляющий трудовую деятельность, основу которой составляет взаимодействие с объектом воздействия, машиной и средой на рабочем месте при использовании информационной модели и органов управления.

Теория инженерной психологии рассматривает функционирование технических устройств и деятельность человека по работе с этими устройствами как единый взаимосвязанный процесс. Именно эта концепция привела к возникновению современного понятия системы «человек-машина». Структурная схема системы «человек-машина» показана на Рисунок 1.2.1.

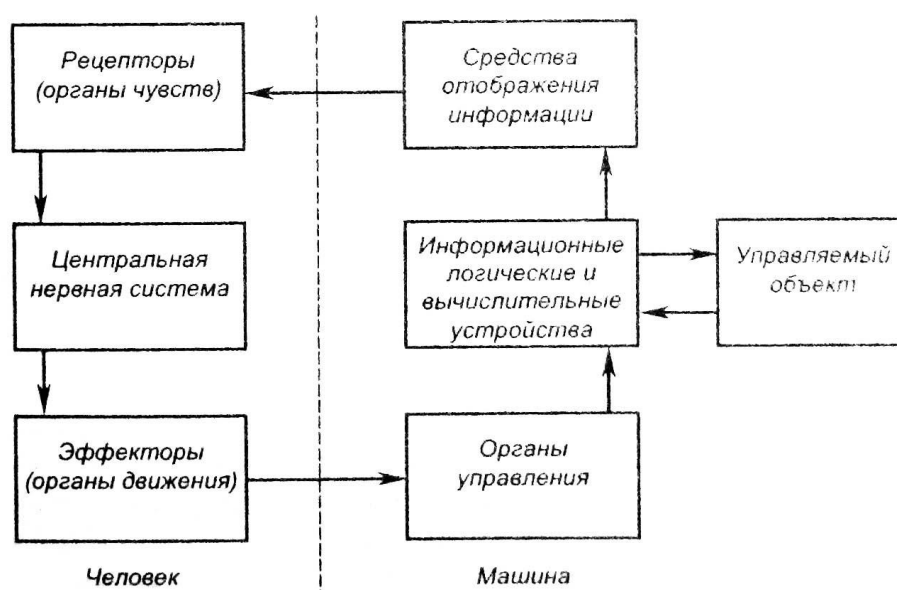


Рисунок 1.2.1. Структурная схема системы «человек—машина»

Изменения состояния управляемого объекта (УО) поступают в вычислительные и логические устройства системы и после некоторой обработки отображаются на средствах отображения информации (дисплеях и индикаторах). Следовательно, оператор воспринимает не непосредственно состояние УО, а некий образ, называемый информационной моделью. Информационная модель формируется с помощью средств отображения

информации. Информационная модель должна с заданной точностью отображать состояние УО. Кроме того, необходимо учитывать человеческий фактор – модель должна соответствовать возможностям оператора по приему и переработке информации. На основании воспринятого с помощью органов чувств состояния информационной модели у оператора формируется концептуальная модель УО, которая содержит полученное оператором представление о состоянии УО. Концептуальная модель сравнивается с некоторым эталоном, хранящимся в памяти оператора и отражающим требуемое состояние УО. После этого оператором принимается решение о необходимости изменения текущего состояния УО. Это решение передается эффекторам (органы движения), с помощью которых командная информация вводится в машину, в результате чего осуществляется перевод УО в нужное состояние. На этом заканчивается цикл регулирования в системе «человек-машина».

Исследователи в области инженерной психологии выделяют разные типы систем «человек-машина» [16, 17]. Основой для классификации могут служить следующие четыре группы признаков: целевое назначение системы, характеристики человеческого звена, тип и структура машинного звена, тип взаимодействия компонентов системы.

Целевое назначение системы оказывает определяющее влияние на многие ее характеристики и поэтому является исходным признаком. По целевому назначению можно выделить следующие классы систем:

1. Управляющие системы. В них основной задачей человека является управление машиной (или комплексом).
2. Обслуживающие системы. В таких системах человек контролирует состояние машинной системы, ищет неисправности, производит наладку, настройку, ремонт и т. п.
3. Обучающие системы. Системы данного класса вырабатывают у человека определенные навыки (технические средства обучения, тренажеры и т. п.).

4. Информационные системы. Основная задача информационных систем обеспечивать поиск, накопление или получение необходимой для человека информации.

5. Исследовательские системы. Используются при анализе тех или иных явлений, моделировании, поиске новой информации, новых заданий.

Особенность управляющих и обслуживающих систем заключается в том, что объектом целенаправленных воздействий в них является машинный компонент системы. В обучающих и информационных СЧМ объектом воздействий является человек. В исследовательских системах воздействие имеет и ту, и другую направленность.

По признаку характеристики «человеческого звена» можно выделить два класса СЧМ:

1. Моносистемы, в состав которых входит один человек и одно или несколько технических устройств;
2. Полисистемы, в состав которых входит некоторый коллектив людей и взаимодействующий с ним комплекс технических устройств.

По типу и структуре машинного компонента можно выделить инструментальные СЧМ, в состав которых в качестве технических устройств входят инструменты и приборы. Отличительной особенностью этих систем, как правило, является требование высокой точности выполняемых человеком операций.

В основу классификации СЧМ по типу взаимодействия человека и машины может быть положена степень непрерывности этого взаимодействия. По этому признаку различают системы непрерывного и эпизодического взаимодействия.

Рассмотренные классификации СЧМ не являются единственно возможными, существуют иные подходы к решению этой задачи [9, 10].

Несмотря на большое разнообразие систем «человек-машина», они имеют целый ряд общих черт и особенностей. Эти системы являются, как

правило, динамическими, целеустремленными, самоорганизующимися, адаптивными.

Системы «человек-машина» относятся к классу сложных динамических систем, т. е. систем, состоящих из взаимосвязанных и взаимодействующих элементов различной природы и характеризующихся изменением во времени состава структуры и (или) взаимосвязей. Из этого следуют характерные особенности, присущие СЧМ как сложной динамической системе:

1. Разветвленность структуры (или связей) между элементами (человеком и машиной) .
2. Разнообразие природы элементов (в состав СЧМ могут входить человек, коллектив людей, автоматы, машины, комплексы машин и т. д.) .
3. Перестраиваемость структуры и связей между элементами (например, при нормальном ходе технологического процесса оператор лишь следит за ходом его протекания, т. е. включен в контур управления как бы параллельно; при отклонении от нормы оператор берет управление на себя, т. е. включается в контур управления последовательно) ;
4. Автономность элементов, т. е. способность их автономно выполнять часть своих задач.

Системы «человек-машина» относятся также к классу целеустремленных систем. В общем случае считается, что система действует целеустремленно, если она продолжает преследовать одну и ту же цель, изменяя свое поведение при изменении внешних условий [76]. Существенной особенностью целеустремленных систем является их способность получать одинаковые результаты различными способами. Системы этого класса могут изменять свои задачи; они выбирают как сами задачи, так и средства их реализации. Целеустремленность СЧМ обусловлена тем, что в нее включен человек. Именно он ставит цели, определяет задачи и выбирает средства достижения цели.

Системы «человек-машина» можно рассматривать и как адаптивные системы. Свойство адаптации заключается в приспособлении СЧМ к изменяющимся условиям работы, в изменении режима функционирования в соответствии с новыми условиями. Для повышения эффективности СЧМ необходимо предусмотреть возможность адаптации как внутри самой системы, так и по отношению к внешней среде. До недавнего времени свойство адаптации СЧМ реализовалось благодаря приспособительным возможностям человека, гибкости и пластичности его поведения, возможности его изменения в зависимости от конкретной обстановки. В настоящее время, на повестку дня ставится вопрос о создании СЧМ, в которых свойство адаптации реализуется путем соответствующего технического обеспечения. Речь идет о создании таких технических средств, которые могут изменять свои параметры и условия деятельности в зависимости от текущего конкретного психофизиологического состояния человека и показателей эффективности его деятельности. Попытки решения этой задачи привели к появлению понятия взаимной адаптации человека и машины в системах управления, или иначе — созданию систем адаптивного информационного взаимодействия в СЧМ. Эта задача решается в рамках структурно-психологической концепции анализа и проектирования СЧМ. Одним из конкретных способов реализации такого подхода является профилактическое обслуживание СЧМ.

Системы «человек-машина» относятся также к числу адекватных систем. Под адекватностью понимается совокупность свойств системы, характеризующих ее приспособленность к выполнению данной задачи. Применительно к техническим звеньям адекватность определяется:

1. Правильной организацией СЧМ (наличие в структуре системы необходимого оборудования, программных средств, каналов связи, обученного персонала и т. д.).
2. Хорошими физическими характеристиками техники (механическими, энергетическими и т. п.).

3. Средствами активации функционирования (устройства приведения в готовность, переключения работы с одного режима на другой и т. п.).
4. Нормальными процессами (материально-техническое, метрологическое и др. виды обеспечения).

Применительно к человеку информационная адекватность определяется свойствами концептуальной модели. В основе этого вида адекватности лежат функциональная организация и свойства анализаторов, центральной нервной системы, психофизиологические законы преобразования информации человеком в процессе деятельности. Физическая адекватность характеризует антропологическое и силовое соответствие человека решаемым задачам. Активационная адекватность определяется мотивами, установками, потребностями, заинтересованностью человека в выполнении данного вида деятельности, характером эмоциональных реакций, свойствами внимания. Базовая адекватность определяется функционированием вегетативных систем, особенностями биохимических процессов и психическими состояниями. Разумеется, указанные четыре группы свойств не являются независимыми.

И, наконец, системы «человек-машина» можно отнести к классу самоорганизующихся систем, т. е. систем, способных к уменьшению энтропии после вывода их из устойчивого, равновесного состояния под действием различного рода возмущений. Это свойство становится возможным благодаря целенаправленной деятельности человека, способности его планировать свои действия, принимать правильные решения и реализовывать их в соответствии с возникшими обстоятельствами. Способность к адаптации и самоорганизации обуславливает такое важное свойство систем «человек-машина», каким является их живучесть.

Помимо приведенных классификаций, исследователями особо выделяется отдельный подкласс систем «человек-машина», а именно системы «человек-компьютер» [33]. Проблема взаимодействия человека и компьютера возникла уже на первых этапах развития вычислительной

техники. Ранние исследования, посвященные развитию информационных технологий, связаны с созданием новой техники, построением машин, решающих задачи, которые обычно решаются людьми с помощью рассуждения. Главным предметом западных исследований являются те проблемы информатики, которые обычно объединяются под названием «вычислительные машины и мышление» [8, 80].

Принципиальное отличие системы «человек-машина» и системы «человек-компьютер» в том, что возможности компьютера позволяют решать такие «когнитивные задачи», как интерпретация, анализ, распознавание и др. Главное при этом - оптимальное распределение функций между человеком-оператором и компьютером.

По мнению ряда авторов [33], перспективным представляется деятельностный подход к разработке систем «человек-компьютер». И человек, и компьютер могут рассматриваться как некоторые преобразователи «действий», связанных с восприятием, сознанием и движением. Следовательно, при проектировании систем «человек-компьютер» необходимо выделить форму взаимодействия между двумя работающими подсистемами. Помимо деятельностного подхода в проектировании систем «человек-компьютер» выделяют и другие, традиционные, подходы.

1. Инженерный подход. Суть подхода сводится к детальному анализу поведения работника и объединение его элементарных действий в "однородную группу структурированных по определенному признаку задач" [33]. Но, к сожалению, все это трудно применить к умственным действиям.
2. Социотехнический подход. Суть данного подхода - в максимальном разделении труда в организации и определение функций и структурных особенностей его основных составляющих. Но это сложно при разработке простых, конкретных заданий, т.е. сложно в плане постановки таких заданий.

3. Поведенческий подход. Суть подхода - в персонализированной всесторонней оценке труда, что может использоваться и при получении исходных данных для пересмотра задач, т.е. для разработки новых заданий. Ограниченность подхода связана с отсутствием перечня необходимых признаков задач и с тем, что акцент делается больше на мотивационную составляющую, чем на исполнительскую.
4. Системный эргономический подход. Здесь предлагаются ясные идеи по структуре проектирования и даются специфические нормы и рекомендации, связанные с физическими параметрами интерфейса (т.е. системы) «человек-компьютер». Но данный подход не касается когнитивных аспектов мыслительной деятельности.

Важную роль в деятельностном подходе при разработке систем «человек-компьютер» играют следующие принципы теории действия [33]:

1. Поведение работника - это комплекс отдельных действий. Это упорядоченная система сенсорных, когнитивных и двигательных процессов, направленных на достижение определенной цели. Сама программа действий имеет определенную иерархию. Действия - это самые маленькие «единицы» деятельности, направленные на независимые и осознанные цели.
2. Действия, ведущие к одной и той же цели, могут иметь разный состав и структуру. Важны индивидуальные различия в действиях. Важны и динамические отличия в структуре поведения одного и того же человека.
3. Структура действий является окончательным продуктом процессов регуляции. Выделяются: подготовительные шаги программы действий и шаги по реализации программы. Нередко шаги, связанные с реализацией, одновременно являются и шагами по подготовке новых действий (например, если задача сложная, то в ходе ее реализации обнаруживаются новые проблемы и т.п.).

4. Регулятивные процессы, рассматриваемые с психофизиологической точки зрения, протекают на разных уровнях: сенсомоторная регуляция (основана на навыках) - в основном это бессознательная регуляция; перцептивно-концептуальная регуляция (основана на определенных правилах) - многое зависит от готовности оператора воспринимать определенные сигналы (информацию); интеллектуальная регуляция (основана на знаниях) - происходит осознанно, целенаправленно, с использованием обратной связи.
5. Во время выполнения одного и того же процесса все три уровня регуляции могут чередоваться. Обычно управление идет на сенсомоторном уровне, но если квалификации недостаточно, то происходит переход на более высокий уровень. В экстремальных ситуациях управление ведется на интеллектуальном уровне.
6. Наблюдается общая тенденция к повышению эффективности деятельности (человек самообучается в процессе своего труда, а также - за счет оптимизации самого труда: сокращение лишних операций и т.п.).
7. Регуляция действий зависит от функционального состояния человека, т.е. важна оптимальная нагрузка на работника. При чрезмерной нагрузке - перенапряжение. При недостаточной нагрузке - атрофия интеллектуальных способностей, даже если работник компенсирует монотонный труд воображением и игрой, производительность падает.
8. Для выполнения действий у человека есть несколько психофизиологических механизмов, каждый из которых имеет свои возможности и ограничения (по вниманию, мышлению, памяти).
9. Каждый человек располагает широким спектром поведенческих реакций и знаний. Все это ведет к значительным индивидуальным различиям, т.е. к индивидуальному стилю выполнения одинаковых заданий.

10. Включенность и выполнение определенных видов деятельности имеет ряд последствий для работающей личности. В плане вознаграждения (оправданные или неоправданные надежды, а может, и реализованные/нереализованные смыслы). В плане повышения своего опыта и квалификации. Но есть и явно негативные последствия (стресс, дефицит времени и профессиональные деструкции).

Выделяют следующие основные показатели, которые важно учитывать при проектировании «действенных систем» [33]:

1. Ориентация на задачу (полная информация о целях).
2. Обратная связь (своевременность информации о процессе).
3. Изменение в программе действия и уровне регуляции (возможность своевременного прерывания и корректировки процесса в случае непредвиденных обстоятельств).
4. Обеспечение деятельности по контролю (информация об уже выполненном действии, но такая информация не должна прерывать основной процесс).
5. Повышение эффективности работы (своевременная поддержка, например, если работник готов выполнять две задачи одновременно).
6. Стремление поддерживать оптимальную нагрузку работы (возможность регулировать уровень нагрузки самим работником).
7. Стремление уравнивать возможные различия между пользователями в области знаний, квалификации, способностей и стилей работы.

Из сказанного выше можно заключить, что рассмотренные особенности системы «человек-машина» определяются наличием в их составе человека и его возможностями решать задачи в зависимости от конкретных условий и обстановки. Из этого положения делается вывод, что исходным пунктом анализа и описания системы «человек-машина» должна быть именно деятельность человека.

1.3. Роль человека в системе «человек-машина»

Система «человек-машина» представляет собой частный случай сложных информационных систем, в которых функционирование машины и деятельность человека-оператора связаны единым информационным процессом.

В [35, 36] различают несколько типов операторской деятельности. Эти типы классифицируются в зависимости от основной функции, выполняемой человеком-оператором, и удельного веса образного, понятийного, сенсомоторного компонентов, включенных в операторскую деятельность.

1. Оператор-технолог. Непосредственно включен в технологический процесс, работает в основном в режиме немедленного обслуживания, совершает преимущественно исполнительские действия, руководствуясь четко регламентирующими действия инструкциями, содержащими, как правило, полный набор ситуаций и решений. Это операторы технологических процессов, автоматических линий.

2. Оператор-манипулятор. Основную роль в его деятельности играют механизмы сенсомоторной регуляции и в меньшей степени — понятийного и образного мышления. К числу функций оператора-манипулятора относится управление манипуляторами, роботами.

3. Оператор-наблюдатель, контролер. Это классический тип оператора (оператор радиолокационной станции, диспетчер транспортной системы). Для данного типа деятельности характерен большой вес информационных и концептуальных моделей. Он может работать как в режиме немедленного, так и отставленного обслуживания. Такой тип деятельности является массовым для операторов технических систем, работающих в реальном масштабе времени.

4. Оператор-исследователь. В значительно большей степени в его деятельности используется аппарат понятийного мышления и опыт, заложенный в концептуальных моделях. Органы управления играют для него еще меньшую роль, а вес информационных моделей достаточно велик. К

этой категории операторов относятся исследователи любого профиля: пользователи вычислительных систем, дешифровщики объектов (изображений).

5. Оператор-руководитель. Он управляет не техническими компонентами системы, а другими людьми. Управление осуществляется как непосредственно, так и опосредованно — через технические средства и каналы связи. К этой категории относятся руководители различных уровней, лица, принимающие ответственные решения, обладающие соответствующими знаниями, волей и интуицией. Основным режимом деятельности оператора-руководителя — оперативное мышление.

Наиболее распространенным типом операторской деятельности является работа оператора-наблюдателя, поэтому исследование этого типа деятельности представляется актуальной задачей.

При организации взаимосвязи человека и машины в СЧМ основная роль принадлежит уже не столько анатомическим и физиологическим, сколько психологическим свойствам человека: восприятию, памяти, мышлению, вниманию [75]. Поэтому от психологических свойств человека во многом зависит его информационное взаимодействие с машиной.

Деятельность человека-оператора в сложной системе “человек-машина” характеризуется следующими особенностями [52, 53].

1. Информационные системы непрерывно усложняются и, следовательно, непрерывно расширяются функции оператора и круг решаемых им задач.
2. В сложной информационной системе между человеком и управляемым объектом вклинивается система дистанционной передачи и обработки информации. Возникает проблема согласования технических средств системы с возможными для оператора объемом и скоростью восприятия и переработки информации.
3. В современной информационной сложной системе нагрузки на сенсорные каналы восприятия (зрительные, слуховые, тактильные)

распределяются неравномерно. А при дистанционном управлении основная нагрузка ложится на зрительный канал, который часто оказывается перегруженным.

4. Часто оператору приходится работать при жестких ограничениях на быстроту и точность действий при характерно высокой цене ошибки и большой эмоциональной напряженности, например, оператор радиолокационной станции (РЛС), дежурный оператор АЭС, космонавт.
5. В некоторых системах оператору приходится работать в необычных условиях жизнедеятельности.
6. Возможности современных технических устройств информационных систем существенно приблизились к возможностям человека, а по некоторым показателям превзошли его. Отсюда, чтобы обеспечить эффективную работу в целом системы «человек-машина», вытекает большая принципиальная проблема: какую функцию в системе управления наиболее рационально поручить оператору, а какую – компьютеру.

Проведем сравнение. По скорости, точности, объему переработки отдельных сигналов современные компьютеры в значительной мере превосходят возможности человека. Для восприятия единицы информации нервной клетке требуется 0.01 с., а компьютеры воспринимает бит за время намного порядков меньше. Однако мозг человека способен к параллельной и ассоциативной обработке информации.

Под восприятием в психологии понимается отражение предметов и явлений в совокупности их свойств. Технически возможно отобразить лишь отдельные свойства явлений, обычно вне их взаимосвязей, а возможности по объединению и обобщению сигналов пока ограничены. В отличие от компьютера, человек способен мгновенно воспринимать целые комплексы самых разнообразных признаков предметов через сигналы различных модальностей (зрительных, слуховых, тактильных), производить их

обобщения, формировать образ и трансформировать его с позиций задачи. Человек способен приспосабливаться к условиям восприятия, преодолевать трудности при восприятии неопределенной, двусмысленной информации и оценивать показатели вероятностного порядка. Человеку присуща константность восприятия размеров, формы, цвета и т.п., позволяющая ему независимо от условий предъявления объекта наблюдения (удаления, расположения в поле зрения, освещения и т.п.) узнавать объект.

Преимущество машинной памяти проявляется при хранении однотипных данных. Преимущество памяти человека в хранении большого числа связей. Машинную память можно свободно стирать, а убрать внешним воздействием данные из памяти человека либо невозможно, либо очень трудно. В тоже время человек способен забывать ненужные ему сведения.

Для воспроизведения на компьютере процессов мышления требуется существенное увеличение интегральных возможностей ввода информации из-за их недостаточной гибкости и пластичности в процессах мышления. Требуется разработка такого большого количества различных программ преобразования, объединения и обобщения информации каким обладает человек. Однако при решении отдельных задач с большим числом однородных и взаимосвязанных данных компьютер значительно превосходит человека.

По моторным функциям современные компьютеры, безусловно, превосходят человека. Компьютеры способны обеспечить точное регулирование параметров, как по величине и скорости их изменения, так и по производным высшего порядка, к чему не способен человек. Компьютеры могут иметь большой запас энергии. Однако моторный выход компьютера ограничен часто только определенным набором ответов. Человек же использует значительно большее количество вариантов ответных действий, которые практически очень трудно, либо невозможно заранее предусмотреть в компьютере.

Человек способен к высокой степени самоорганизации на различных уровнях. У компьютера эти способности к самоорганизации и использованию накапливаемого в памяти «опыта» пока небольшие. В случаях возникновения «трудностей» в работе технического звена машина либо прекращает работу, либо результат ее действия оказывается бессмысленным для системы. Человек же в таких случаях изыскивает пути к сохранению нормальной работы системы и к достижению цели.

Воздействия, как внешние, так и внутренние на человека и машину принципиально различны. Человек быстро устает, ему необходим периодический отдых. Человек не способен длительное время сосредоточить внимание на определенном объекте и может отвлекаться. Он чувствителен к различным стрессовым ситуациям, подвержен влиянию субъективных фактов и эмоциям. Всех этих «недостатков» нет у машины. Однако машина чувствительна к магнитным и электрическим полям (помехам), к внешней температуре и т.д.

Человек способен противостоять большинству внутренних нарушений, возникающих в его организме, и сохранять при этом нормальное функционирование. Внутренние нарушения в техническом устройстве ведут к нарушению работы всей системы.

На сегодняшнем уровне прогресса считается, что ЭВМ хорошо выполняет следующие функции:

1. Все виды математических расчетов.
2. Выполнение однообразных повторяющихся операций.
3. Хранение в памяти большого объема однородной информации, банка данных и знаний.
4. Решение задач, требующих дедуктивного мышления, т.е. получения на основе общих правил решений для частных случаев.
5. Выполнение действий, требующих быстрой реакции на команду.
6. На очереди проблема научить ЭВМ выполнять следующие функции, характерные для человека.

7. Распознавание ситуации в целом по многим сложно связанным характеристикам, а также при неполной информации. Но заметим, что теории распознавания образов и искусственного интеллекта быстро развиваются.
8. Индуктивное мышление, т.е. осуществление обобщений по отдельным фактам, особенно при неполной информации.
9. Решение задач, для которых отсутствуют алгоритмы или нет четко выраженных правил переработки информации.
10. Решение задач, в которых требуется гибкость и приспособляемость (адаптация) к изменяющимся условиям, особенно задач, которые заранее трудно предвидеть.
11. Решение задач высокой ответственности (принятия решений), в которых велика цена ошибки.

Научить компьютер этим способностям есть одна из задач новых бурно развивающихся теорий искусственного интеллекта, распознавания образов робототехники и зарождающейся теории интеллектуального интерфейса.

Ввиду быстро развивающихся компьютерных и смежных с ними наук и роста возможностей компьютера, можно ожидать, что уже в сравнительно недалеком будущем некоторым из перечисленных выше функций человек научит и компьютер.

1.4. Математические модели работы человека в системах «человек-машина»

В области исследований сложных информационных систем, которые являются человеко-машинными системами, важным и быстроразвивающимся направлением является разработка моделей человека, включенного в процесс обработки информации. Моделирование позволяет сделать вывод о принципиальной работоспособности системы, оценить ее потенциально возможные характеристики, установить зависимость от

различных параметров, определить оптимальные значения параметров, а также прогнозировать работу системы. Прогнозирование поведения человека-оператора необходимо вести методами, совместимыми с описанием действия машины, т.е. моделировать и прогнозировать поведение оператора как компонента системы «человек-машина». Человек решает обширный круг задач, связанных с обеспечением работоспособности системы, поэтому операторская деятельность может анализироваться с различных позиций.

Некоторые авторы [23, 53, 57] склонны трактовать систему «человек-машина» как одноканальную систему переработки информации. Согласно этой концепции работа оператора представляется в виде последовательности элементарных циклов, состоящих из отдельных законченных этапов. В качестве основных выделяются следующие этапы: прием информации, переработка и принятие решения, выдача управляющих воздействий. В [45] эти этапы разбиваются на более мелкие составляющие и показано, что качество выполнения оператором своих функций на различных этапах операторской деятельности не равнозначно.

Статистика показывает, что наибольшее число ошибок (до 80% и более), допускаемых человеком-оператором, приходится на этап приема информации [62].

Ряд исследователей [18, 19, 21, 36] пытается классифицировать умственную деятельность оператора при решении различных задач обработки информации. В [18, 43, 60] умственную деятельность оператора предлагается разграничить на три типа: сенсорный, сенсомоторный и логический. Умственный труд сенсорного типа объединяет операторов связанных с приемом информации по одному каналу и передачи ее без преобразования по нескольким каналам. Сенсомоторный тип умственной деятельности заключается в обработке информации директивного характера с выдачей результатов в стандартной форме для данного процесса. Деятельность такого типа присуща водителям транспорта, диспетчерам, операторам промышленных систем. При умственной деятельности

логического типа операторские функции заключаются в приеме и переработке информации, принятии решения и выдаче управляющих воздействий на соответствующие устройства системы. В реальной деятельности оператора присутствуют элементы всех трех типов.

Наиболее простые модели работы человека-оператора были получены в задачах ручного управления. В [74] используется метод линейных передаточных функций для описания работы человека-оператора. В [22] используются обобщенные рабочие характеристики функционирования человека при решении определенных задач. Обобщенные рабочие характеристики представляет совокупность начальных моментов s -го порядка случайной величины, характеризующей время и качество работы человека-оператора в конкретной задаче в виде функции характерных параметров.

Рассмотренные линейные модели обладают рядом недостатков. Во-первых, они не учитывают, что оператор может действовать дискретно. Во-вторых, не учитывается способность оператора изменять свое поведение при воздействии на входе системы случайных сигналов. Такие модели применяются для описания узкого класса систем с аналогово-непрерывной деятельностью.

Для анализа систем с дискретно-логической деятельностью разработан «обобщенный структурный метод» (ОСМ) [14] – набор методик и математических моделей для описания и оценки эффективности, качества и надежности функционирования системы «человек-машина». Функционально-семантические сети описывают в ОСМ функционирование любой эргатической системы.

Функциональные сети описывают последовательность выполнения операций при жесткой логической связи в выполнении отдельных операций. Семантические сети описывают характер логических связей (отношений) между отдельными элементами, составляющими сеть, без жесткой фиксации последовательности выполнения операций. Введение человека-оператора в

функциональную сеть позволяет иметь дело не только с алгоритмическими, но и с эвристическими видами деятельности человека в эргатической системе. Эвристические виды деятельности человека, такие как, например, принятия решений, не позволяют исследовать систему аналитическими методами.

Помимо рассмотренных детерминированных моделей широкое применение находят вероятностные модели, особенно при моделировании сложных видов деятельности операторов, взаимодействующих с различными средствами отображения информации (СОИ). В [49] на основании теории статистических решений построена математическая модель работы оператора-наблюдателя при решении задачи обнаружения сигналов. Для компьютерной реализации математических моделей необходимо построить соответствующий моделирующий алгоритм [1].

При имитационном моделировании реализующий модель алгоритм воспроизводит процесс функционирования системы во времени, причем имитируются элементарные явления, составляющие процесс, с сохранением их логической структуры и последовательности протекания во времени. Имитационные модели позволяют достаточно просто учитывать такие факторы, как наличие дискретных и непрерывных элементов, нелинейность характеристик элементов, многочисленные случайные воздействия и другие, которые создают трудности при аналитических исследованиях.

В [77, 44] имитационные модели используются для оценки надежности работы человека-оператора.

Кибернетические модели занимают особое место в моделировании работы человека-оператора. В этих моделях реальный объект рассматривается как «черный ящик», имеющий ряд входов и выходов, и моделируют некоторые связи между входами и выходами.

Несмотря на большое разнообразие моделей формализованного описания работы человека-оператора, отсутствуют модели, использующие нейронные сети.

Из рассмотренных математических моделей операторской деятельности наибольшее ограничение с точки зрения практического применения имеют аналоговые модели. Логико-математические модели получили более широкое распространение. Имитационное моделирование операторской деятельности представляется перспективным. При этом наиболее перспективным и актуальным для моделирования работы человека-оператора является использование нейронных сетей. Это объясняется тем, что человеческое поведение отличается большой сложностью, а нейронные сети позволяют учесть вариативность поведения человека, психофизиологические показатели его состояния, а также прогнозировать в целом поведение системы на этапе ее проектирования.

Выводы по главе I

1. Показано, что инженерная психология является научной дисциплиной, находящейся на стыке технических и психологических наук, что сказывается на анализе систем «человек-машина».
2. Рассмотрены этапы развития инженерной психологии от машиноцентрического (от машины к человеку) к антропоцентрическому (от человека к машине) подходу при исследовании деятельности человека-оператора.
3. Представлена структурная схема системы «человек-машина» и рассмотрена классификация этих систем по основным группам признаков: целевое назначение системы, характеристики человеческого звена, тип и структура машинного звена, тип взаимодействия компонентов системы.
4. В результате рассмотрения такой классификации показано, что наибольший интерес представляют информационные системы, которые используются для получения информации, необходимой для распознавания и принятия решений. В таких системах человек-оператор воспринимает информацию со средств отображения

(индикаторы, дисплеи), преобразует ее в концептуальную модель, на основании которой принимает решение об изменении состояния воспринимаемого объекта. Исследование таких систем представляется достаточно трудной и актуальной задачей.

5. Рассмотрен отдельный класс информационных систем «человек-компьютер», различные подходы к проектированию этих систем, представлен деятельностный подход, использующий принципы теории действий.
6. Приведена классификация и рассмотрены особенности операторской деятельности в информационных системах «человек-машина». Проведен сравнительный анализ работы человека-оператора и компьютера.
7. В результате рассмотрения многочисленных математических моделей работы человека-оператора, как линейных, так и нелинейных, детерминированных и статистических, получено, что наиболее перспективным является имитационное моделирование с использованием нейронных сетей.

ГЛАВА II. МАТЕМАТИЧЕСКАЯ ИМИТАЦИОННАЯ МОДЕЛЬ РАБОТЫ ЧЕЛОВЕКА-ОПЕРАТОРА В СИСТЕМЕ «ЧЕЛОВЕК-ДИСПЛЕЙ»

В информационных системах обработки информации человек-оператор является основным звеном, обеспечивающим эффективность работы системы. Его работа заключается в восприятии информации, ее обработки и принятия решения. Восприятие и обработка информации заключается в обнаружении и распознавании сигналов и изображений, предъявляемых на различных типах индикаторов. Такие задачи успешно решены для радиолокационных систем и индикаторов на электронно-лучевых трубках [54, 55, 49]. В работах [50, 48] получены математические модели работы человека-оператора в задаче распознавания изображений, наблюдаемых на телевизионном экране. Однако, полученные данные не могут быть использованы для оценки работы человека-оператора, воспринимающего изображения с экрана дисплея по следующим причинам [2]. Изображение на дисплее отличается от объектов наблюдения, привычных глазу. Оно состоит из дискретных точек, светится, мерцает. Цветное компьютерное изображение не соответствует естественным цветам по спектру. Зрительное утомление вызывают не только особенности изображения на экране, но и напряженность глаз при длительной работе с экраном дисплея [41]. Расположение информации на экране, ее структура и время предъявления имеют большое значение для работы глаз.

Несмотря на указанные трудности, информационные системы принятия решения в сложной внешней обстановке без поддержки человека-оператора не только не эффективны, но могут привести к непредсказуемым последствиям.

Поэтому возникает актуальная задача построения математической имитационной модели работы человека-оператора при восприятии изображений с экрана дисплея.

Целью данной главы является:

- 1) рассмотреть возможность математического моделирования работы человека-оператора на основании теории статистических решений и законов психофизики;
- 2) разработать методику и провести натурный эксперимент с группой операторов для исследования построенной математической модели.

2.1. Основные теоретические предпосылки для построения имитационной модели человека-оператора

Пусть $\vec{S} = [s(t_1), s(t_2), \dots, s(t_n)] = (s_1, s_2, \dots, s_n)$

$\vec{X} = [x(t_1), x(t_2), \dots, x(t_n)] = (x_1, x_2, \dots, x_n)$,

где $t_0 \leq t_1 \leq t_2 \leq \dots \leq t_n \leq T + t$, \vec{S} и \vec{X} представляют соответственно n -мерные векторы сигнала и наблюдаемых данных в пространствах Ω и Γ , Ω - пространство сигналов, Γ - пространство наблюдений. Помимо пространства сигналов и наблюдаемых данных рассматривается также пространство шумов N и пространство решений Δ . Вектор $\vec{\gamma} = [\gamma_1, \gamma_2, \dots, \gamma_m]$ представляет совокупность m решений $\gamma_1, \gamma_2, \dots, \gamma_m$ относительно сигнала \vec{S} , основанных на данных \vec{X} , полученных в результате наблюдения. Пусть $\delta(\gamma / \vec{X})$ - правило выбора решений, которое может представлять либо вероятность, либо плотность вероятности принятия решения γ на основании наблюдаемых данных \vec{X} . Величины $W(\vec{S})$ или $W(\theta)$ представляют соответственно плотности вероятностей n -мерного вектора \vec{S} или случайного параметра θ сигнала \vec{S} ; $W_n(\vec{X} / \vec{S})$ - условная n -мерная плотность вероятности наблюдаемых данных \vec{X} при данном сигнале \vec{S} (индекс n указывает, что W_n является функцией объема выборки или времени наблюдения), $W(N)$ - плотность вероятности шума N , который складывается с сигналом аддитивно.

В задачах обнаружения и распознавания сигнала, когда на выходе системы решениями являются «да» (смесь шума и сигнала) или «нет» (только шум), решения γ представляют дискретные точки в пространстве решений Δ , а само правило δ является вероятностью $0 < \delta \leq 1$. Последствия выбора правила решения δ оцениваются функцией потерь $F(\vec{S}, \gamma)$, с помощью которой каждому сигналу и связанному с ним решению приписывается количественная оценка. Для оценки качества системы выбирается средняя стоимость или средняя потеря, которая связана с правилом выбора решения соотношением [39]:

$$L(\vec{S}, \delta) = M_{\vec{S}, \vec{X}} \{F(\vec{S}, \gamma)\} = \int_{\Omega} d\vec{S} \int_{\Gamma} d\vec{X} \int_{\Delta} F(\vec{S}, \gamma) W(\vec{S}) W_n(\vec{X} / S) \delta(\gamma / \vec{X}) d\gamma, \quad (2.1.1)$$

где $M_{\vec{S}, \vec{X}} \{F(\vec{S}, \gamma)\}$ - математическое ожидание потери, когда распределение сигналов $W(\vec{S})$ известно. Это математическое ожидание зависит от решающего правила δ и распределения $W(\vec{S})$ и называется функцией риска [31].

При обнаружении сигналов используется функция стоимости вида:

$$F(\vec{S}, \gamma) = C(\vec{S}, \gamma) \quad (2.1.2)$$

где C не зависит от правила выбора решения δ и связывает с различными возможными решениями γ относительно \vec{S} заранее устанавливаемые постоянные стоимости. На основании соотношений (2.1.1) и (2.1.2) можно написать выражения условного и среднего риска для правила выбора решения δ .

Условный риск:

$$r(\vec{S}, \delta) = \int_{\Gamma} W_n(\vec{X} / \vec{S}) d\vec{X} \int_{\Delta} C(\vec{S}, \gamma) \delta(\gamma / \vec{X}) d\gamma. \quad (2.1.3)$$

Средний риск:

$$R = M \{r(\vec{S}, \delta)\} = \int_{\Omega} W(\vec{S}) d\vec{S} \int_{\Gamma} W_n(\vec{X} / \vec{S}) d\vec{X} \int_{\Delta} C(\vec{S}, \gamma) \delta(\gamma / \vec{X}) d\gamma. \quad (2.1.4)$$

Выражения (2.1.3) и (2.1.4) можно представить в другом виде, при котором учитывается значение вероятностей ошибок, соответствующих различным возможным решениям.

Пусть $p(\gamma/\vec{S})$ - условная вероятность того, что устройство выдает решение γ (при нерандомизированных правилах решения), если сигнал равен \vec{S} и принято правило выбора решений $\delta(\gamma/\vec{X})$, так что

$$p(\gamma/\vec{S}) = \int_{\Gamma} W_n(\vec{X}/\vec{S}) \delta(\gamma/\vec{X}) d\vec{X}. \quad (2.1.5)$$

Теперь выражение для риска можно представить в виде:

$$r(\vec{S}, \delta) = \int_{\Delta} p(\gamma/\vec{S}) C(\vec{S}, \gamma) d\gamma. \quad (2.1.6)$$

Это выражение равно просто сумме стоимостей, соответствующих всем возможным решениям при заданном сигнале \vec{S} , причем стоимостям придаются веса, определяемые вероятностями их появления.

Если выбраны функции стоимости и, как было показано, системе можно приписать среднюю и условную оценки потерь, то можно определить оптимальную систему. Определим оптимальную систему для случая, когда предполагается полное знание априорных вероятностей появления сигнала $W(\vec{S})$ и когда удобна оценка с помощью среднего риска $R[W(\vec{S}), \delta]$. Условимся считать оптимальной системой систему с наименьшим средним риском, конечно, приписанные заранее стоимости одинаковы для сравниваемых систем. Такую оптимальную систему называют байесовской системой, а минимальный средний риск – байесовым риском. Байесовская система подчинена байесовскому правилу выбора решений δ^* , причем δ^* - это правило выбора решений, которому соответствует наименьшая при данном априорном распределении $W(\vec{S})$ средняя оценка потерь L .

Если априорные вероятности сигналов не известны или известны не полностью, то используется минимаксное правило выбора решения δ_M^* . Минимаксным правилом δ_M^* называется такое правило, при котором

максимальная условная оценка потерь $L(\vec{S}, \delta)_{\max}$ для всех возможных значений сигнала \vec{S} не превышает максимальную условную оценку потерь при любом другом правиле выбора решений δ . Минимаксное решение, по сравнению с другими, дает самую надежную защиту от больших потерь, но в то же время оно может оказаться излишне осторожным для наиболее вероятных состояний процесса на входе системы.

Важной задачей, к которой применимы методы теории решений, является обнаружение и распознавание сигнала на фоне шума. Оптимальное обнаружение, как и распознавание, рассматривается в смысле минимальной средней стоимости или среднего риска. Рассматривается двухальтернативная задача. При бинарном обнаружении и распознавании гипотеза H_0 , что имеется только шум, испытывается против альтернативы H_1 , что имеются сигнал и шум, так что в пространстве решений есть только две точки (γ_0, γ_1) соответственно. Предполагается, что если решения определены и окончательны, то

$$\delta(\gamma_0 / \vec{X}) + \delta(\gamma_1 / \vec{X}) = 1. \quad (2.1.7)$$

Пусть \vec{S} сигнал на входе, который мог присутствовать на протяжении времени наблюдения, тогда кратко обе гипотезы можно записать: $H_0 | \vec{S} \in \Omega_0$ и $H_1 | \vec{S} \in \Omega_1$, где Ω_0 и Ω_1 - соответствующие неперекрывающиеся друг друга классы сигналов или гипотез [27].

Теперь частоту появления сигналов в неперекрывающихся классах Ω_0, Ω_1 можно охарактеризовать плотностями вероятности $w_0(\vec{S}), w_1(\vec{S})$, нормированными в соответствующих пространствах:

$$\int_{\Omega_0} w_0(\vec{S}) d\vec{S} = 1, \quad \int_{\Omega_1} w_1(\vec{S}) d\vec{S} = 1. \quad (2.1.8)$$

Пусть q и $p = 1 - q$ - соответственно априорные вероятности того, что появится некоторый сигнал из классов Ω_0 и Ω_1 , тогда априорное

распределение вероятностей $W(\vec{S})$ во всем пространстве сигналов $\Omega = \Omega_0 + \Omega_1$ примет вид:

$$W(\vec{S}) = qw_0(\vec{S}) + pw_1(\vec{S}) = q\delta(\vec{S} - 0) + pw_1(\vec{S}). \quad (2.1.9)$$

Это равенство справедливо, если в классе Ω_0 имеется лишь один (нулевой) сигнал. При наличии в классе Ω_1 также лишь одного сигнала $\vec{S}_1 \neq 0$ выражение (2.1.9) принимает вид:

$$W(\vec{S}) = q\delta(\vec{S} - 0) + p\delta(\vec{S} - \vec{S}_1).$$

Каждой из возможных комбинаций сигнала на входе и решения приписываются стоимости, которые выражаются в виде платежной матрицы Π_{ij} :

$$\Pi_{ij} = \begin{pmatrix} \Pi_{00} & \Pi_{01} \\ \Pi_{10} & \Pi_{11} \end{pmatrix}, \quad \Pi_{01} > \Pi_{00} > 0; \quad \Pi_{10} > \Pi_{11} \geq 0. \quad (2.1.10)$$

По главной диагонали расположены выигрыши за правильное решение, а по побочной – платы (потери) за ошибочные решения.

Предположим, что $W_n(\vec{X} / \vec{S})$ непрерывная функция по \vec{S} , испытания рассматриваются при постоянном объеме выборки; функция стоимости является ограниченной функцией сигнала \vec{S} и решения γ , которые, в свою очередь, ограничены замкнутыми областями, и класс правил выбора решений ограничен непоследовательными правилами [39]. Интегрирование по пространству решений Δ в (2.1.1) заменяется суммированием, так что с учетом соотношений (2.1.10) средний риск равен

$$R = \int_{\Gamma} \{ \delta(\gamma_0 / \vec{X}) [q\Pi_{00}W_n(\vec{X} / 0) + p\Pi_{01}\langle W_n(\vec{X} / \vec{S}) \rangle_s] + \delta(\gamma_1 / \vec{X}) [p\Pi_{11}\langle W_n(\vec{X} / \vec{S}) \rangle_s + q\Pi_{10}W_n(\vec{X} / 0)] \} d\vec{X}, \quad (2.1.11)$$

где $p + q = 1$, и из (2.1.9) следует

$$\int_{\Omega_1} W(\vec{S}) W_n(\vec{X} / \vec{S}) d\vec{S} = p \langle W_n(\vec{X} / \vec{S}) \rangle_s = p \int_s w_1(\vec{S}) W_n(\vec{X} / \vec{S}) d\vec{S},$$

$$\int_{\Omega_0} W(\vec{S}) W_n(\vec{X} / \vec{S}) d\vec{S} = q W_n(\vec{X} / 0) = q \int_s w_0(\vec{S}) W_n(\vec{X} / \vec{S}) d\vec{S}. \quad (2.1.12)$$

Имеется два рода возможных ошибок. Ошибка 1-го рода, когда шум принимается за сигнал и шум (ложная тревога при обнаружении или ошибка 1 рода при распознавании), и ошибка 2-го рода, когда принимается решение о наличии только шума, а на самом деле имеются шум и сигнал (пропуск сигнала при обнаружении, или ошибка 2-го рода при распознавании).

Усредненная условная вероятность α появления ошибки 1-го рода равна

$$\alpha = P\{\gamma_1 / H_0\} = \int_{\Gamma} W_n(\vec{X} / 0) \delta(\gamma_1 / \vec{X}) d\vec{X}.$$

Вероятность правильного решения, состоящего в принятии верной гипотезы, дополняет α до 1:

$$1 - \alpha = P\{\gamma_0 / H_0\} = \int_{\Gamma} W_n(\vec{X} / 0) \delta(\gamma_0 / \vec{X}) d\vec{X}.$$

Усредненная условная вероятность β появления ошибки второго рода равна

$$\beta = P\{\gamma_0 / H_1\} = \int_{\Gamma} \langle W_n(\vec{X} / \vec{S}) \rangle_s \delta(\gamma_0 / \vec{X}) d\vec{X}.$$

Вероятность правильного решения, отклонение ложной гипотезы дополняет β до 1, т.е.

$$1 - \beta = P\{\gamma_1 / H_1\} = \int_{\Gamma} \langle W_n(\vec{X} / \vec{S}) \rangle_s \delta(\gamma_1 / \vec{X}) d\vec{X}.$$

Байесовское правило выбора решения можно найти из (2.1.11). Это выражение перепишем с учетом ограничения (2.1.7), получим

$$R = q\Pi_{00} + q\Pi_{11} + \int_{\Gamma} \delta(\gamma_0 / \vec{X}) [p(\Pi_{10} - \Pi_{11}) \langle W_n(\vec{X} / \vec{S}) \rangle_s -$$

$$-q(\Pi_{01} - \Pi_{00}) W_n(\vec{X} / 0)] d\vec{X} \quad (2.1.13)$$

Задача состоит в том, чтобы выбрать $\delta(\gamma_0/\vec{X})$ и отсюда $\delta(\gamma_1/\vec{X})$, таким образом, чтобы минимизировать средний риск. Поскольку δ принимают лишь положительные значения, меньшие (или равные) единицы, то интеграл в (2.1.13) будет иметь наименьшее значение, если для каждого наблюдения $\vec{X} \in \Gamma$ выбрать правило δ следующим образом:

если $p(\Pi_{10} - \Pi_{11})\langle W_n(\vec{X}/\vec{S}) \rangle_s \geq q(\Pi_{01} - \Pi_{00})W_n(\vec{X}/0)$, то

$$\delta^*(\gamma_1/\vec{X}) = 1; \delta^*(\gamma_0/\vec{X}) = 0, \quad (2.1.14a)$$

т.е. решать, что имеется сигнал и шум:

если $p(\Pi_{10} - \Pi_{11})\langle W_n(\vec{X}/\vec{S}) \rangle_s < q(\Pi_{01} - \Pi_{00})W_n(\vec{X}/0)$, то

$$\delta^*(\gamma_1/\vec{X}) = 0, \delta^*(\gamma_0/\vec{X}) = 1, \quad (2.1.14b)$$

т.е. решать, что имеется только шум.

Полученное байесовское правило выбора решения оказалось нерандомизированным, хотя при выводе (2.1.13) учитывалась возможность получения рандомизированного оптимального правила выбора решений (2.1.7).

Вводится обобщенное отношение правдоподобия, при помощи которого можно сформулировать байесовское правило выбора решения в более сжатом виде:

выбирать решение γ_1 , если $\Lambda_n(\vec{X}) \geq \Lambda_0$

выбирать решение γ_0 , если $\Lambda_n(\vec{X}) < \Lambda_0$ (2.1.15)

Отношение правдоподобия:

$$\Lambda_n(\vec{X}) = \frac{p \cdot \langle W_n(\vec{X}/\vec{S}) \rangle_s}{q \cdot W_n(\vec{X}/0)}.$$

Величина Λ_0 называется порогом и зависит от выбранных заранее стоимостей и априорных вероятностей появления сигнала и шума.

$$\Lambda_0 = \frac{q}{p} \cdot \frac{(\Pi_{01} - \Pi_{00})}{(\Pi_{10} - \Pi_{11})} > 0 \quad (2.1.16)$$

Байесовское правило по существу представляет разделение пространства наблюдений Γ на две области, причем граница проходит по значениям \vec{X} , которые удовлетворяют уравнению $\Lambda_n(\vec{X}) = \Lambda_0$.

Назначение стоимостей зависит от тех задач, которые выполняет система. При обнаружении сигналов в шумах в радиолокации ложные тревоги более нежелательны и опасны, чем пропуски сигнала, при распознавании образов в радиосвязи нежелательны ошибки двух видов. Поэтому Λ_0 будет различным в соответствии с принятым критерием [39]. Для того чтобы вычислить $\Lambda_n(\vec{X})$, система должна "знать" априорные вероятности $p, q, w_1(s)$, а также условную вероятность $W_n(\vec{X} / \vec{S})$. Таким образом, в процессе выработки решения используется вся имеющаяся информация.

Применение теории статистических решений к задачам распознавания образов позволяет построить как и в случае обнаружения сигналов оптимальный байесовский классификатор. В [13] показано, что если величина потери при правильном выборе класса принимается нулевой, а при ошибочном решении составляет некоторую ненулевую величину, например 1 (симметричная функция потерь), то байесовский классификатор вычисляет дискриминантные функции вида:

$$d_j(\vec{x}) = W(\vec{x} / \omega_j)P(\omega_j), j = 1, 2, \dots, M \quad (2.1.17)$$

Классификатор относит образ \vec{x} к тому классу ω_j , у которого значение дискриминантной функции $d_j(\vec{x})$ оказывается наибольшим. В формуле (2.1.17) $P(\omega_j)$ - вероятность появления образа из класса ω_j , $W(\vec{x} / \omega_j)$ - плотность распределения образов каждого класса.

В [13] получено уравнение байесовских дискриминантных функций для классов с нормальным распределением функции $W(\vec{x} / \omega_j)$ при условии симметричности функции потерь.

$$d_j(\vec{x}) = \ln P(\omega_j) - \frac{1}{2} \ln |A_j| - \frac{1}{2} [(\vec{x} - \vec{m}_j)^T A_j^{-1} (\vec{x} - \vec{m}_j)] \quad j = 1, 2, \dots, M \quad (2.1.18)$$

В формуле (2.1.18) $|A_j|$ – определитель матрицы A_j . Для математического ожидания и ковариационной матрицы используются оценки

$$\vec{m}_j = \frac{1}{M_j} \sum_{x \in \omega_j} \vec{x}, \quad (2.1.19)$$

$$\vec{A}_j = \frac{1}{M_j} \sum_{x \in \omega_j} \vec{x} \vec{x}^T - \vec{m}_j \vec{m}_j^T, \quad (2.1.20)$$

где M_j - число образов из класса ω_j , на которых проводится суммирование.

Как и в случае обнаружения сигналов байесовская дискриминантная функция представляет собой разделяющую поверхность в виде линий для двумерных классов, если выполняются следующие условия:

- 1) классы имеют нормальное распределение;
- 2) все ковариационные матрицы единичные;

Теория статистических решений и построенная на ее основе теория обнаружения и распознавания сигналов оказали большое влияние на развитие психофизики и математической психологии [32, 38, 51]. Исследования психологов, основанные на применении теории статистических решений в психофизике, позволили построить модель работы человека-оператора в задаче распознавания изображений и принятия решений. Эта структурная модель в виде схемы представлена на рисунке 2.1.1.




Рисунок 2.1.1. Структурная модель работы человека-оператора в задаче распознавания изображений. 1 – когнитивная подсистема, 2 – решающая подсистема, 3 – исполнительная подсистема, 4 – внутренние источники информации и память

Рассмотрим работу модели, представленной на рисунке 2.1.1. Одним из основных предположений современной психофизики является предположение о существовании «пространства ощущений» или «сенсорного пространства». Предполагается, что наряду с физическим пространством, в котором определены ощущаемые человеком объекты, такие как звук, свет, изображения и так далее, имеется пространство ощущений. Существование сенсорного пространства является не только теоретической гипотезой, но подтверждено экспериментально в психофизических экспериментах [19].

При восприятии объекты отображаются нейронной системой в сенсорное пространство, и на основании этого отображения принимаются решения. Следует отметить, что под нейронной системой человека понимается сенсорная система, включающая в себя рецепторы, механизмы принятия решения, память и «выходные органы», осуществляющие реакции.

Введем некоторые обозначения. Множество входных сигналов обозначим через \vec{S} . \vec{S} включает в себя и пустое множество. Множество помех или шум будем обозначать N . Тогда конкретное значение входного воздействия, поступающее в данный момент на вход наблюдателя, можно обозначить $x_j \in \vec{S}, \vec{N}$. Поступившее воздействие x_j преобразуется блоком формирования сенсорного образа с помощью некоторого оператора $F_1(x_j)$ в образ воздействия или субъективный сенсорный результат наблюдения - x_{sj} . Множество $\{x_{sj}\}$ реализуется в сенсорном пространстве наблюдателя T_s , т.е. $x_{sj} \in T_s$.

Утверждение 1. Преобразование $\{x_j\} \rightarrow \{x_{sj}\}$ возможно, когда оператор F_1 является линейным преобразованием поступившего воздействия в сенсорный результат наблюдения.

Для модели работы человека-оператора, решающего задачу обнаружения и распознавания изображений, этот оператор может быть представлен в виде $F_1(x_j) = kx + b$, где k и b – некоторые константы.

При восприятии входного воздействия большое значение имеет порог ощущения или порог восприятия. Порог x^* есть критическое значение стимула, т.е. то минимальное воздействие, которое воспринимает нейронная система человека. Именно в этом смысле понимали порог Вебер, Фехнер и другие исследователи. Понятию порога ощущения и его измерению посвящено много работ [19, 32]. Применение теории статистических решений позволило ввести порог Λ_0 , который обобщает понятие порога x^* , введенного Вебером и Фехнером, и используется на практике. В сенсорном пространстве порог как важный фактор включен в процесс принятия решения. На основании понятия сенсорного пространства можно предложить психофизическую интерпретацию отношения правдоподобия $\Lambda_n(\vec{X})$. Можно считать, что $\Lambda_n(\vec{X})$ задает преобразование пространства стимулов в сенсорное пространство.

Рассмотрим работу решающего блока.

Утверждение 2. Оператор $F_2(x_{sj})$ задает однозначное отображение сенсорного пространства в пространство решений с помощью дискриминантных функций.

На основании сенсорных результатов наблюдения в соответствии со сформированным критерием оптимальности выполняется оператор $F_2(x_{sj})$, применяя некоторое правило принятия решения δ из множества возможных правил решения $\delta_n \in \Delta$.

Человек-оператор выбирает один из возможных способов действия r_{si} из множества возможных способов R_s , т. е. $r_{si} \in R_s$. Наконец, с помощью оператора $F_3(r_{sj})$ наблюдатель реализует выбранные действия – дает реакцию r_j из множества R , $r_j \in R$.

Блок внутренней информации отражает влияние на другие подсистемы схемы прошлого опыта человека, особенностей процессов памяти и внимания, мотивационно-оценочных структур, а также эмоционального состояния.

Для работы модели необходимо осуществить отображение, характер которого определяется работой блока принятия решения. Конечные члены этого отображения фиксирует экспериментатор.

$$S \rightarrow T_s \rightarrow R_s \rightarrow R$$

Данное отображение представляет собой информационный процесс обработки входной сенсорной информации с целью получения конкретных результатов действий человека.

На основании утверждений 1 и 2 работу блока принятия решения можно представить следующим образом. Человек-оператор принимает решение на основании сравнения отношения правдоподобия с порогом (2.1.15), (2.1.16) с учетом платежной матрицы (2.1.10). Он выбирает такое правило решения $\delta \in \Delta$, которому при известном априорном

распределении входного воздействия соответствует наименьшая средняя оценка потерь, т.е. байесовское правило решения.

Модель может иметь распространение на задачи, использующие другие правила и критерии, например, минимаксный критерий, критерий Неймана-Пирсона, критерий «идеального наблюдателя».

Человеко-машинная система это информационная система, целевое назначение, элементный состав и структура которой ориентированы на различного рода преобразование данных и информации в интересах обеспечения потребностей пользователей [1]. На основании такого определения информационной системы структурная модель работы человека оператора может быть представлена в виде следующих подсистем: 1 – когнитивная, 2 – решающая, 3 – исполнительная, 4 – внутренние источники информации и память.

Утверждение 3. Все элементы модели связаны единым информационным процессом и между ними осуществляется согласованное информационное взаимодействие, подразумевающее единство целей, тогда, когда выполняются утверждения 1 и 2.

На рисунке 2.1.1 штрихами обозначены плохо изученные или гипотетические взаимодействия, сплошными линиями – изученные и экспериментально подтвержденные взаимодействия.

Рассмотренная психофизическая модель может служить основой для исследования характеристик работы человека-оператора и для методики проведения экспериментов.

2.2. Методика проведения эксперимента по распознаванию изображений человеком-оператором

Установим цели эксперимента с человеком оператором. Основная цель эксперимента – сбор данных об эффективности работы человека-оператора в задаче классификации изображений, для дальнейшего анализа и сравнения с

результатами функционирования автоматизированного распознавательного комплекса.

Входными параметрами эксперимента являются искаженные изображения для классификации. Сформулируем задачу классификации изображений следующим образом. Пусть имеются изображения двух классов: первый будем условно называть истинными целями (или просто «целями»), а второй ложными («ловушками»). Экземпляры классов представлены на рисунке 2.2.1.




Рисунок 2.2.1. Образцы изображений классов «цели» (А) и «ловушки» (В, С, D)

Все изображения растровые, приведены к одному размеру и являются бинарными - состоят только из черных и белых пикселей.

При распознавании предъявляются искаженные изображения в случайном порядке, необходимо определить принадлежность каждого из объектов к одному из классов. Примеры искаженных изображений представлены на рисунке 2.2.2.




Рисунок 2.2.2. Искаженные изображения классов «цели» (А) и «ловушки» (В, С, D)

Опишем теперь условия проведения эксперимента. Входными параметрами в эксперименте выступают искаженные изображения двух описанных выше классов. В качестве искажающих эффектов используется ряд моделей зашумления изображения, представленных в [13]: аддитивный гауссов шум, импульсный шум, шум Релея. Рассмотрим модели шумов более подробно.

Плотность распределения вероятностей гауссова шума задается выражением

$$p(z) = \frac{1}{\sqrt{2\pi}\sigma} e^{-(z-\mu)^2/2\sigma^2},$$

где z представляет собой значение яркости, μ - среднее значение случайной величины z , σ - ее среднеквадратичное отклонение.

Плотность распределения вероятностей импульсного шума задается выражением

$$p(z) = \begin{cases} P_a & \text{при } z = a, \\ P_b & \text{при } z = b, \\ 0 & \text{в др. случаях.} \end{cases}$$

где P_a - вероятность замены яркости пикселей изображения на значение a , P_b - вероятность замены яркости пикселей изображения на значение b . Если $b > a$, то пиксель с яркостью b выглядит как светлая точка на изображении. Пиксель с яркостью a выглядит, наоборот, как темная точка. Если одно из значений вероятности (P_a или P_b) равно 0, то шум называют униполярным.

Плотность распределения вероятностей шума Релея задается выражением

$$p(z) = \begin{cases} \frac{2}{b}(z-a)e^{-(z-a)^2/b} & \text{при } z \geq a, \\ 0 & \text{при } z < a. \end{cases}$$

Математическое ожидание и дисперсия случайной величины, подчиненной этому закону распределения, имеют вид

$$\mu = a + \sqrt{\pi b / 4},$$

$$\sigma^2 = \frac{b(4 - \pi)}{4}.$$

Степень искажения изображений варьировалась в разных экспериментах. Каждый из операторов участвовал в нескольких экспериментах, с последовательным повышением предельной степени искажения. Эксперименты проводились с контрольными выборками разного объема (40-115 объектов), при этом с увеличением объема контрольной выборки увеличивалась и предельная степень искажения изображений.

В эксперименте принимали участие операторы, предварительно ознакомленные с сутью эксперимента и внимательно изучившие эталонные образцы изображений, что обеспечивало чистоту экспериментов. Оператор должен по предъявляемому на дисплее изображению определить его принадлежность к одному из классов («цели» или «ловушки»). На результат работы оператора может оказать влияние время, в течение которого он наблюдал истинную или ложную цель. Из физиологии зрения известно, что время, необходимое для распознавания изображения, колеблется в пределах 200-500 мсек. Для всех операторов выбрано время предъявления изображения равное 2 сек. Это время показа изображения строго выдерживалось, оператор работал в условиях отсутствия дефицита времени.

Решение, принятое оператором, фиксировалось на счетчике результатов следующим образом:

$n_{\text{цц}}$ – число предъявлений, в которых оператор опознал истинную цель, когда она ему предъявлялась;

$n_{\text{цл}}$ – число предъявлений, в которых оператор принял истинную цель за ложную;

$n_{\text{лл}}$ – число предъявлений, в которых ложная цель была принята за ложную;

$n_{\text{лц}}$ – число предъявлений, когда оператор ложную цель принял за истинную.

Для полученных данных вычислялись вероятности $P_{\text{цц}} = n_{\text{цц}}/n_1$; $P_{\text{лл}} = n_{\text{лл}}/n_2$; где n_1 – число предъявлений истинной цели, n_2 – число предъявлений ложной цели. Используя полученные данные можно вычислить усредненные вероятности правильного распознавания $P_{\text{прав}}$ и вероятность ошибки $P_{\text{ош}}$, а также их зависимость от степени искажения изображения. Эти вероятности являются оценкой работы человека-оператора в сложной системе.

Основным оборудованием в эксперименте является LSD дисплей, на котором операторам предъявляются изображения для классификации. Для эксперимента было разработано специальное программное обеспечение на языке программирования C++ в среде Visual Studio 2010. Главное окно программы, с помощью которой выполняется эксперимент, изображено на рисунке 2.2.3.

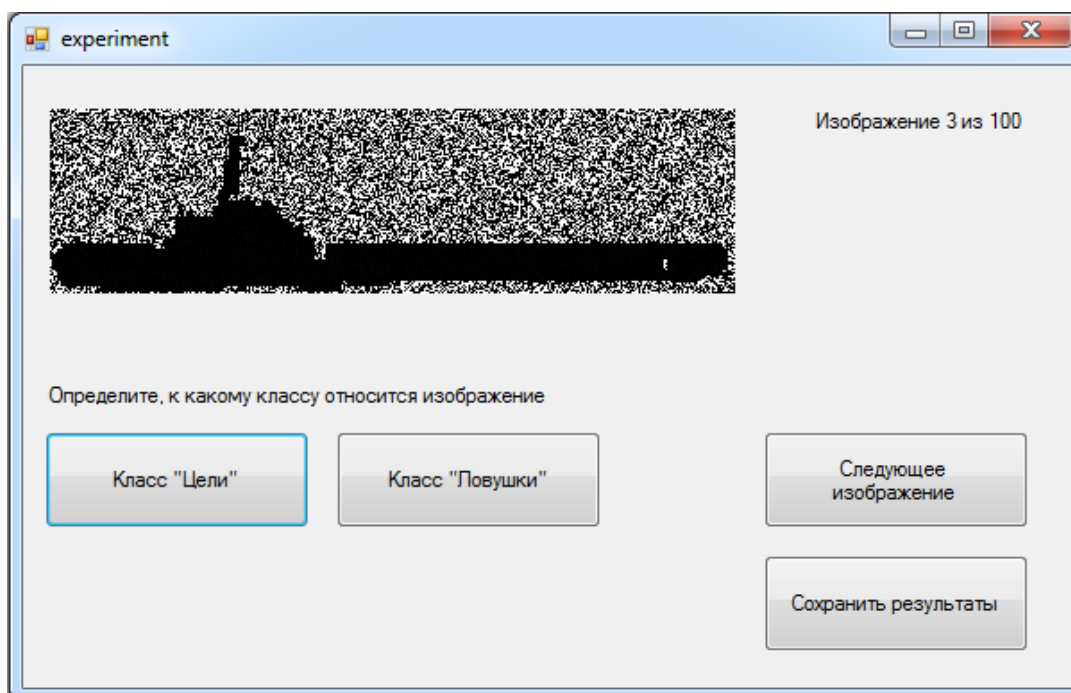


Рисунок. 2.2.3. Окно программы, с помощью которой выполняется эксперимент с человеком-оператором

Представленная программа демонстрирует испытуемому поочередно зашумленные изображения. Интерфейс программы позволяет отнести демонстрируемое изображение к одному из классов («Цели» или «Ловушки»). По окончании эксперимента результаты могут быть сохранены в текстовый файл для дальнейшего анализа.

2.3. Оценка зрительного утомления человека-оператора в эксперименте по распознаванию изображений

При проведении экспериментов с операторами следует обращать внимание на их психофизические характеристики. Показано, что при работе с дисплеем развивается усталость и психическая напряженность, снижается удовлетворенность работой в силу ее однообразия, и как следствие всей системы «человек-дисплей» [6]. Поэтому наблюдение за утомлением операторов представляется актуальной задачей при проведении эксперимента. В системе «человек-дисплей» наибольшая нагрузка приходится на зрительный анализатор, поэтому особое внимание стоит

обращать именно на зрительное утомление. В работе [46] обоснована важность отслеживания зрительного утомления человека-оператора для оценки его функционального состояния и качества его работы, а, следовательно, и качества работы всей системы «человек-дисплей».

При проведении эксперимента будем фиксировать зрительное утомление операторов с помощью методики, представленной в работе [46].

Суть методики заключается в следующем: испытуемому предлагается смотреть с некоторого расстояния на рабочее окно экрана монитора, на котором представлено черное на белом фоне кольцо (рисунок 2.3.1).

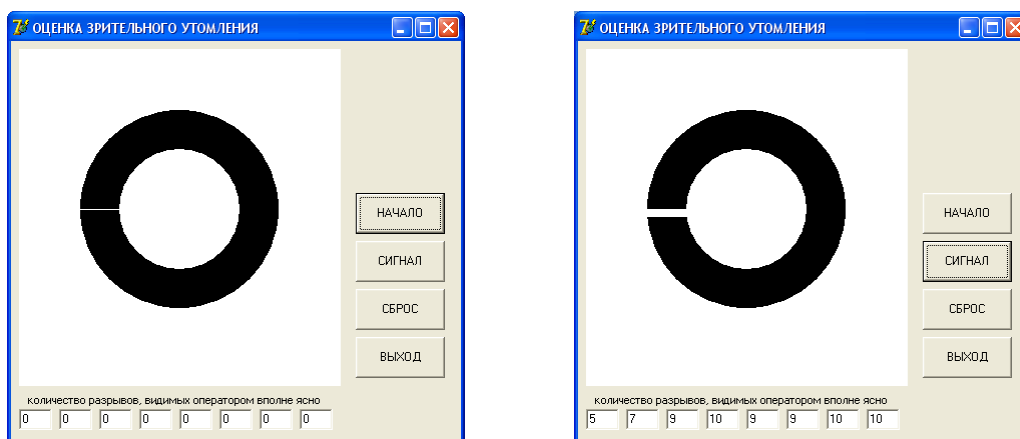


Рисунок. 2.3.1. Окно программы по оценке зрительного утомления оператора

Наблюдение начинается с нажатия на кнопку «НАЧАЛО» и включает десять предъявлений испытуемому тестового объекта — разрыва в этом кольце. При каждом последующем предъявлении разрыв автоматически появляется в новом месте в течение фиксированного интервала времени, составляющего две секунды. В случае если оператор видит разрыв вполне ясно, ему необходимо подать соответствующий сигнал путем нажатия на кнопку «СИГНАЛ» (рисунок 2.3.1). При каждом таком нажатии в специальном поле будет отображаться их количество и, следовательно, число периодов ясного видения, начиная с нуля. Когда число предъявлений тестового объекта достигнет десяти, число поданных сигналов фиксируется и

программа завершает работу. Всего проводится восемь последовательных экспериментов с каждым оператором, при этом ширина разрыва увеличивается каждый раз на один пиксель с одного до восьми, т.е. до такого размера тестового объекта, когда испытуемый начинает постоянно отчетливо его различать. При нажатии на кнопку «сброс» все результаты обнуляются, кнопка «выход» немедленно завершает работу программы.

При обработке полученных экспериментальных данных вычислялась средняя вероятность обнаружения тестового объекта, т.е. показатель «устойчивости ясного видения», взятый в среднем по всем операторам до осуществления зрительной работы и после нее. Расчеты велись с использованием следующей формулы:

$$C_k = \frac{1}{n} \sum_{i=1}^n C_{ik}, \quad (2.3.1)$$

где C_{ik} – показатель «устойчивости ясного видения» i -го оператора в k -м эксперименте, n – количество операторов, принимавших в нем участие. Приведем обобщенные результаты, полученные авторами в [46] в таблице 2.3.1.

Таблица 2.3.1. Средние показатели для операторов до и после зрительной работы

	ширина разрыва в кольце, в пикселях							
	показатель «устойчивости ясного видения»							
	1	2	3	4	5	6	7	8
$C_k 1$	0,653	0,847	0,927	0,967	1,000	0,993	1,000	1,000
$C_k 2$	0,573	0,793	0,913	0,933	0,980	0,980	0,987	0,987
$C_1 - C_2$	0,080	0,054	0,014	0,034	0,020	0,013	0,013	0,013

В этой таблице $C_k 1$ – показатель C_k , вычисленный для неустоленных операторов; $C_k 2$ – для утомленных, после совершения зрительной работы; а $C_1 - C_2$ – их разница, характеризующая степень утомления операторов.

По представленной методике проведем соответствующие измерения в процессе прохождения эксперимента по классификации. Цель измерения – определить подвергается ли человек-оператор в ходе эксперимента зрительному утомлению. На основании результатов измерения будет вынесено решение о чистоте эксперимента.

Авторами [46] не была указана ширина кольца с разрывом, с помощью которого вычислялся показатель «устойчивости ясного видения». Исходя из того, что данный параметр оказывает непосредственное влияние на объем объекта обнаружения («разрыва»), можно предположить, что изменяя ширину кольца, можно получить принципиально разные результаты измерений.

Для вычисления показателя «устойчивости ясного видения» было разработано программное обеспечение на языке программирования C++ в среде Visual Studio 2010, повторяющее функционал, представленный в [46], но позволяющее изменять и учитывать при анализе результатов ширину кольца. Окно описанной программы представлено на рисунке 2.3.2.

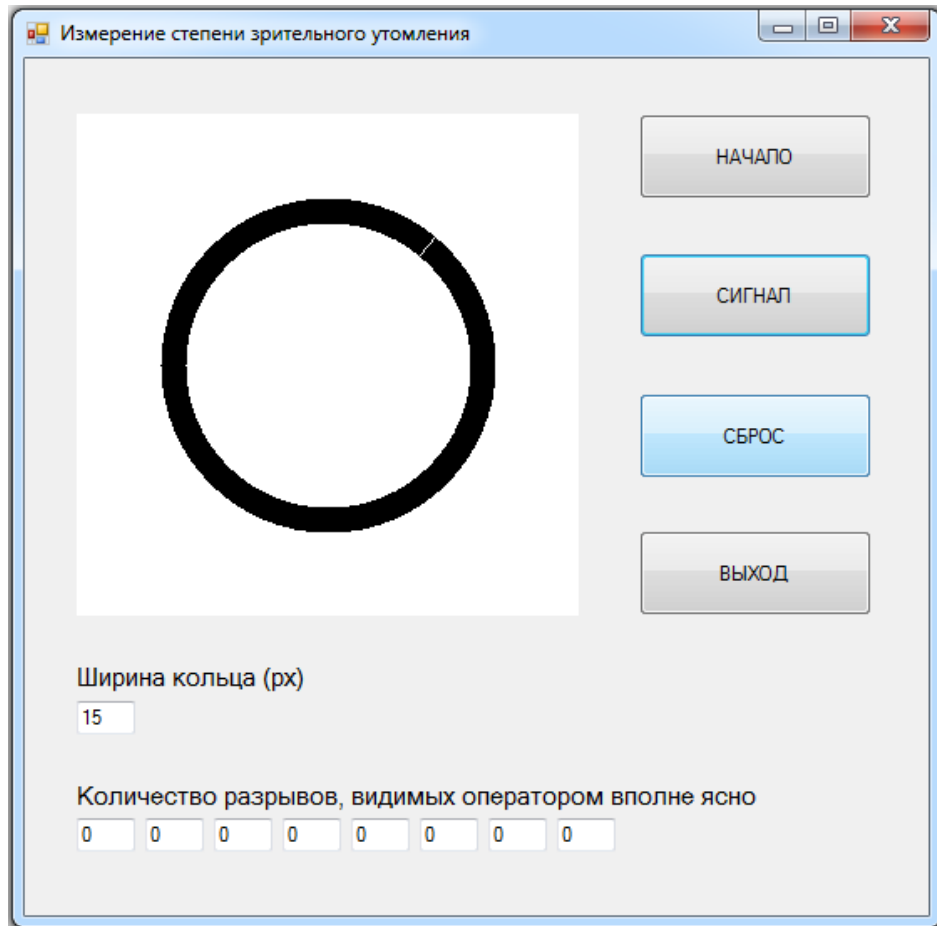


Рисунок. 2.3.2. Окно программы, с помощью которой выполняется эксперимент с человеком-оператором

Будем вычислять показатель «устойчивости ясного видения» до и после эксперимента по классификации изображений. Каждому из испытуемых будет предложено определить количество ясно видимых разрывов размером от 1 до 8 пикселей при ширине кольца 5, 10 и 20 пикселей. Приведем результаты опытов с десятью операторами в таблицах 2.3.2 и 2.3.3.

Таблица 2.3.3. Результаты опытов с операторами после проведения эксперимента по классификации изображений

операторы		ширина разрыва в кольце, в пикселях							
		показатель «устойчивости ясного видения» (вероятность обнаружения тестового объекта)							
	Ширина кольца, в пикселях	1	2	3	4	5	6	7	8
1-й	5	0,6	0,8	1,0	1,0	1,0	0,9	1,0	1,0
	10	0,9	1,0	0,9	1,0	1,0	1,0	1,0	1,0
	20	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0
2-й	5	0,7	0,9	1,0	1,0	1,0	1,0	1,0	1,0
	10	0,9	1,0	1,0	0,9	1,0	1,0	1,0	1,0
	20	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0
3-й	5	0,9	1,0	1,0	1,0	0,9	1,0	1,0	1,0
	10	0,9	1,0	1,0	1,0	1,0	1,0	1,0	1,0
	20	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0
4-й	5	0,9	0,9	1,0	1,0	1,0	1,0	1,0	1,0
	10	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0
	20	1,0	1,0	1,0	1,0	0,9	1,0	1,0	1,0
5-й	5	0,7	1,0	1,0	0,9	1,0	1,0	1,0	1,0
	10	0,9	1,0	1,0	1,0	1,0	1,0	1,0	1,0
	20	1,0	1,0	1,0	1,0	1,0	0,9	1,0	1,0
6-й	5	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0
	10	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0
	20	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0
7-й	5	0,7	0,8	1,0	0,9	1,0	1,0	1,0	1,0
	10	0,8	0,9	1,0	1,0	1,0	1,0	1,0	1,0
	20	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0
8-й	5	0,9	1,0	1,0	0,9	1,0	1,0	1,0	1,0
	10	0,9	1,0	1,0	1,0	1,0	1,0	1,0	1,0
	20	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0
9-й	5	1,0	1,0	1,0	1,0	1,0	1,0	0,9	1,0
	10	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0
	20	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0
10-й	5	0,8	0,9	1,0	1,0	1,0	1,0	1,0	1,0
	10	0,9	1,0	1,0	1,0	1,0	0,9	1,0	1,0
	20	0,9	1,0	1,0	1,0	1,0	1,0	1,0	1,0

Таблицы 2.3.2 и 2.3.3 оформлены следующим образом:

1. 1-ый столбец – номер оператора;
2. 2-ой столбец – ширина кольца в пикселях – 5, 10, 20;
3. Строки – ширина разрыва в кольце в пикселях от 1 до 8;

4. На пересечении строк и столбцов стоят вероятности обнаружения разрыва в кольце, т.е. показатель «устойчивости ясного видения» до проведения эксперимента (таблица 2.3.2) и после проведения эксперимента (таблица 2.3.3).

Вычислим показатель «устойчивости ясного видения», взятый в среднем по всем операторам до осуществления зрительной работы и после нее с помощью формулы (2.3.1).

Таблица 2.3.4. Средние показатели для операторов до и после зрительной работы

операторы		ширина разрыва в кольце, в пикселях							
		показатель «устойчивости ясного видения» (вероятность обнаружения тестового объекта)							
	Ширина кольца, в пикселях	1	2	3	4	5	6	7	8
$C_k 1$	5	0,83	0,95	0,98	0,99	0,99	0,99	1,00	1,00
	10	0,96	1,00	0,99	0,98	1,00	0,99	0,99	1,00
	20	0,99	0,99	1,00	1,00	0,99	1,00	1,00	1,00
$C_k 2$	5	0,82	0,93	1,00	0,97	0,99	0,99	0,99	1,00
	10	0,92	0,99	0,99	0,99	1,00	0,99	1,00	1,00
	20	0,99	1,00	1,00	1,00	0,99	0,99	1,00	1,00
$C_1 - C_2$	5	0,01	0,02	-0,02	0,02	0,00	0,00	0,01	0,00
	10	0,04	0,01	0,00	-0,01	0,00	0,00	-0,01	0,00
	20	0,00	-0,01	0,00	0,00	0,00	0,01	0,00	0,00

Как видно из таблицы 2.3.4 изменение ширины кольца оказывает значительное влияние на результаты опытов. Так, худшие средние значения показателя «устойчивости ясного видения» получены при наименьшей ширине кольца (5 пикселей). Именно по этим значениям удобнее всего судить о зрительном утомлении операторов.

Исходя из полученных результатов измерения показателя «устойчивости ясного видения» можно сделать вывод, что в процессе прохождения эксперимента по классификации изображений операторы не подвергались значительному зрительному утомлению.

Выводы по главе II

1. Рассмотрены основные положения теории статистических решений, на основании которых строятся алгоритмы распознавания образов и принятия решений.
2. Показана возможность применения теории статистических решений для построения оптимальных дискриминантных функций для классификаторов образов, которые возможно использовать для описания поведения человека-оператора.
3. На основании законов психофизики и теории статистических решений получена структурная модель работы человека-оператора при восприятии информации с экрана дисплея.
4. Представлена методика проведения экспериментов с человеком-оператором по распознаванию изображений, в соответствии с которой разработано специальное программное обеспечение на языке программирования C++.
5. Были проведены опыты по фиксации зрительного утомления операторов, показано, что в эксперименте по классификации изображений операторы не подвергались зрительному утомлению.

ГЛАВА III. НЕЙРОСЕТЕВЫЕ МОДЕЛИ РАСПОЗНАВАНИЯ ИЗОБРАЖЕНИЙ ЧЕЛОВЕКОМ-ОПЕРАТОРОМ

3.1. Базовые понятия нейросетевого моделирования

В главе I было сделано предположение о том, что при моделировании работы человека-оператора по классификации и распознаванию изображений перспективной методикой является применения искусственных нейронных сетей. Рассмотрим данный тезис более подробно.

Искусственные нейронные сети представляют собой оригинальную технологию, которая создана на стыке таких дисциплин как нейрофизиология, математика и информатика [5, 67]. Они зарекомендовали себя как эффективный метод решения трудно формализуемых задач по прогнозированию, классификации и распознаванию образов. Фундаментальной особенностью искусственных нейронных сетей является их архитектура и способ обработки информации.

Важнейшим свойством нейронных сетей является адаптивность. Так, нейронные сети, обученные действовать в определенной среде, в условиях колебаний параметров среды могут переобучиться и адаптироваться для работы. Чем выше адаптивные способности системы, тем более устойчивой будет ее работа в нестационарной среде. Идея адаптивности является естественной для классификации образов, обработки сигналов и задач управления.

В контексте задачи классификации образов можно разработать нейронную сеть, собирающую информацию не только для определения конкретного класса, но и для увеличения достоверности принимаемого решения. Впоследствии эта информация может использоваться для исключения сомнительных решений, что повысит продуктивность нейронной сети.

Знания представляются в самой структуре нейронной сети с помощью ее состояния активации. Каждый ее нейрон может быть подвержен влиянию

всех остальных нейронов сети. Как следствие, существование нейронной сети непосредственно связано с контекстной информацией.

Нейронные сети обладают высокой отказоустойчивостью. При неблагоприятных условиях их производительность падает, но незначительно. Например, если поврежден какой-то нейрон или его связи, извлечение запомненной информации затрудняется, но это не приведет к катастрофическим последствиям. В тоже время, большую роль здесь играет характер повреждений. Так, принимая в расчет распределенный характер хранения информации в нейронной сети, можно утверждать, что серьезные повреждения структуры нейронной сети существенно повлияют на ее работоспособность.

Параллельная структура нейронных сетей дает потенциальную возможность ускорения решения некоторых задач.

Нейронные сети являются универсальным механизмом обработки информации. Это означает, что одно и то же проектное решение нейронной сети может использоваться во многих предметных областях.

Строение нейронных сетей определяется аналогией с мозгом, который является эмпирическим доказательством возможности отказоустойчивых параллельных вычислений [30]. Нейробиологи рассматривают искусственные нейронные сети как средство моделирования физических явлений [4]. Инженеры в свою очередь постоянно пытаются почерпнуть у нейробиологов новые идеи.

Сравним результаты работы нейросетевого алгоритма в задаче классификации образов с одним из классических вероятностных классификаторов - байесовским классификатором. В качестве нейросетевого алгоритма рассматривается многослойный персептрон, обучаемый по методу обратного распространения ошибки [40, 47].

Алгоритм обучения методом обратного распространения описывается следующим образом:

1. Инициализация. Генерируются синаптические веса и пороговые значения с помощью датчика равномерно распределенных чисел со средним значением 0.
2. Предъявление примеров обучения. В сеть подаются образы из обучающего множества (эпохи). Для каждого образа последовательно выполняются прямой и обратный проходы.
3. Прямой проход. Пусть пример обучения представлен парой $(x(n), d(n))$, где $x(n)$ — входной вектор, предъявляемый входному слою сенсорных узлов; $d(n)$ — желаемый отклик, предоставляемый выходному слою нейронов для формирования сигнала ошибки. Вычисляем индуцированные локальные поля и функциональные сигналы сети, проходя по ней послойно в прямом направлении. Индуцированное локальное поле нейрона j слоя l вычисляется по формуле

$$v_j^{(l)}(n) = \sum_{i=0}^{m_0} w_{ji}^{(l)}(n) y_i^{(l-1)}(n), \quad (3.1.1)$$

где $y_i^{(l-1)}(n)$ - выходной сигнал нейрона i , расположенного в предыдущем слое $l-1$, на итерации n ; $w_{ji}^{(l)}$ - синаптический вес связи нейрона j слоя l с нейроном i слоя $l-1$. Для $i=0$ $y_0^{(l-1)}(n) = +1$, а $w_{j0}^{(l)}(n) = b_j^l(n)$ - порог, применяемый к нейрону j слоя l . Если используется сигмоидальная функция, то выходной сигнал нейрона j слоя l выражается следующим образом:

$$y_j^{(l)}(n) = \varphi_j(v_j(n)). \quad (3.1.2)$$

Если нейрон j находится в первом скрытом слое (т.е. $l=1$), то

$$y_i^{(0)}(n) = x_j(n), \quad (3.1.3)$$

где $x_j(n)$ — j -й элемент входного вектора $x(n)$. Если нейрон j находится в выходном слое (т.е. $l=L$, где L — глубина сети), то

$$y_i^{(L)}(n) = o_j(n). \quad (3.1.4)$$

Вычисляем сигнал ошибки

$$e_j(n) = d_j(n) - o_j(n), \quad (3.1.5)$$

где $d_j(n)$ - j -й элемент вектора желаемого отклика $d(n)$.

4. Обратный проход. Вычисляем локальные градиенты узлов сети по следующим формулам:

$$\delta_j^{(l)}(n) = e_j^{(l)}(n) \varphi_j'(v_j^{(l)}(n)) \quad \text{для нейрона} \quad (3.1.6)$$

j выходного слоя L ,

$$\delta_j^{(l)}(n) = \varphi_j'(v_j^{(l)}(n)) \sum_k \delta_k^{(l+1)}(n) \delta_{kj}^{(l+1)}(n) \quad (3.1.7)$$

для нейрона j скрытого слоя l ,

где штрих в функции $\varphi_j'(\cdot)$ обозначает дифференцирование по аргументу.

Изменение синаптических весов слоя l сети выполняется в соответствии с обобщенным дельта-правилом:

$$w_{ji}^{(l)}(n+1) = w_{ji}^{(l)}(n) + \alpha w_{ji}^{(l)}(n-1) + \eta \delta_j^{(l)}(n) y_i^{(l-1)}(n), \quad (3.1.8)$$

где η – параметр скорости обучения; α – постоянная момента.

5. Итерации. Последовательное выполнение прямого и обратного прохода, в ходе которого сети предъявляются все примеры обучения из эпохи, пока не будет достигнут критерий останова.

Использование в алгоритме обратного распространения ошибки метода градиентного спуска позволяет эффективно обучать многослойные сети, однако этот алгоритм не прост в вычислительном плане, особенно для сетей со сложной поверхностью ошибки.

Рассмотрим теперь байесовский классификатор, с которым предполагается сравнивать многослойный персептрон. В байесовском классификаторе или байесовской процедуре проверки гипотез минимизируется средний риск. Байесовский классификатор в гауссовой среде аналогичен персептрону в том смысле, что оба классификатора являются линейными. Узнаем вероятность правильной классификации двух классов с гауссовым распределением, используя расчеты из [73].

Пусть классифицируются два класса с гауссовым распределением, с функциями плотности условной вероятности

$$f_X(x|C_1) = \frac{1}{2\pi\sigma_1^2} \exp\left(-\frac{1}{2\sigma_1^2} \|x - \mu_1\|^2\right),$$

$$f_X(x|C_2) = \frac{1}{2\pi\sigma_2^2} \exp\left(-\frac{1}{2\sigma_2^2} \|x - \mu_2\|^2\right).$$
(3.1.9)

Вектор среднего значения и дисперсия для первого класса соответственно равны $[0,0]^T$ и 1, для второго - $[2,0]^T$ и 4. Пусть $P(e|C_1)$ – условная вероятность ошибки для входного вектора из класса C_1 , а $P(e|C_2)$ – условная вероятность ошибки для входного вектора из класса C_2 . Для приведенных выше вектора среднего значения и дисперсии $P(e|C_1) = 0,1056$, $P(e|C_2) = 0,2642$, при этом вероятность ошибки классификатора $P_e = 0,1849$. Тогда вероятность правильной классификации будет составлять 81,51%. Теперь, зная вероятность правильной классификации байесовского классификатора, сравним его с многослойным персептроном, проведя компьютерный эксперимент.

Для проведения компьютерного эксперимента был выбран язык программирования C++ и интегрированная среда разработки Borland C++ Builder. Моделирование классифицируемых случайных величин, распределенных по Гауссу, выполнялось на основании центральной предельной теоремы, следствием которой является то, что для получения нормальной выборки, можно воспользоваться базовыми случайными числами. В нашем эксперименте они генерировались стандартной функцией C++ `rand()`. В соответствии с центральной предельной теоремой, случайная величина с заданным математическим ожиданием и дисперсией генерируется с помощью набора базовых случайных чисел R по формуле:

$$y = \mu + D\left(\sum_{i=1}^{12} R_i - 6\right), \quad (3.1.10)$$

где y – случайная величина, R_i - базовое случайное число, μ - математическое ожидание, D – дисперсия. По указанному алгоритму генерируется как обучающая, так и тестовая выборка векторов.

Результаты работы программы представлены в таблице 3.1.1.




Рисунок. 3.1.1. Программа тестирования возможностей многослойного персептрона

Количество примеров обучения пользователь может изменять динамически, в процессе работы программы, а количество слоев и количество нейронов в слое - в коде программы.

Проведем ряд опытов и занесем их результаты в таблицу 3.1.1. Объем тестовой выборки во всех опытах – 32000 образов.

Таблица 3.1.1. Результаты работы многослойного персептрона

Номер опыта	Объем обучающей выборки	Количество уровней (L)	Количество нейронов в уровне (m) (кроме послед.)	Вероятность правильной классификации
1	0	3	2	29,7%
2	500	3	2	69,7%
3	2000	3	2	70,1%
4	8000	3	2	67,%
5	500	7	3	28,8%
6	1000	7	3	69,5%
7	2000	7	1	32,2%
8	2000	5	2	70,1%
9	500	3	8	75,7%
10	200	3	8	76,4%
11	200	3	8	61,7%
12	170	3	8	81,1%
13	170	3	8	60,7%

Таблица 3.1.1 позволяет нам выявить, от чего зависит результативность работы нейронной сети. Исходя из теоретического материала, можно выдвинуть предположение, что на процент правильно классифицированных образов влияют: архитектура сети (количество уровней сети и количество нейронов в каждом уровне) и размер обучающей выборки. Обозначим количество уровней L , а количество нейронов, во всех уровнях кроме последнего - m (в последнем уровне всегда 2 нейрона, по числу классов для распознавания).

В компьютерном эксперименте С. Хайкина [73] была рассмотрена нейронная сеть с одним скрытым уровнем и двумя нейронами в нем ($L=3$, $m=2$); она же была признана оптимальной для данной задачи. Повторим его эксперимент с обучающим множеством в 500, 2000, 8000 (опыты №1, №2 и №3) объектов и тестовым множеством 32000 объектов. В своих опытах

Хайкин получил вероятность правильной классификации более 80%, в нашем эксперименте вероятность корректной классификации несколько меньше. Это стоит связать с измененными относительно эксперимента Хайкина внутренними параметрами сети: так в данном эксперименте использовалась нулевая константа момента.

Хайкин признает архитектуру сети с одним скрытым слоем и двумя нейронами в нем оптимальной для данной задачи. Проверим данное утверждение, увеличив L до 7. Из опыта №6 видно, что процент успешно классифицированных образов в целом не изменился. Однако стоит отметить, что с увеличением количества уровней у нейронной сети может снизиться стабильность работы: выдает приемлемый результат только при обучающей выборке определенных диапазонов (опыты №5 и №7). С учетом того, что эксперимент с 5 уровнями (опыт №8) также закончился результатом 70%, дальнейших опытов по увеличению числа уровней проводить не будем. Можно сделать вывод, что с увеличением количества уровней сети усложняется процесс ее настройки. Возможно, для других задач увеличение количества уровней способствует нахождению наилучшего решения, однако в нашем эксперименте остановимся на трех уровнях.

Выясним, как на работу нейронной сети влияет количество нейронов в уровне. Опытным путем было выяснено, что наилучшие результаты можно получить при количестве нейронов в уровне от семи до одиннадцати. Рассмотрим результаты работы нейронной сети с $m=8$. В опытах №9, №10 и №12 можно проследить следующую закономерность - с уменьшением примеров для обучения несколько возрастает результативность работы сети. Возможным объяснением данного результата могут служить удачные образцы для обучения. Поскольку примеры для обучения генерируются случайно, при небольшом их количестве возрастает вероятность получить "хорошую" выборку для обучения, однако вероятность низкого результата также возрастает. Как мы видим при успешном обучении возможно

достижения результата байесовского классификатора, а может и превосходящего его.

Проведенный эксперимент показал, что многослойный персептрон может успешно справляться с задачей классификации образов, как и байесовский классификатор. Для успешной работы архитектуру сети необходимо подбирать для каждой конкретной задачи, экспериментируя с количеством слоев и количеством нейронов в слое. Важным параметром является и качество обучающей выборки нейронной сети. Хайкин упоминает об этом [73], однако он не рассматривает данный вопрос подробно. При проектировании нейронных сетей можно пользоваться приемом, получившим название схема акцентирования, согласно которой более сложные примеры подаются в систему чаще, чем более легкие [79]. Простота или сложность отдельных примеров выявляется с помощью анализа динамики ошибок (в разрезе итераций), генерируемых системой при обработке обучающих примеров. Как мы увидели из проведенного эксперимента, качество обучающей выборки является одним из ключевых понятий; при проектировании нейронных сетей именно ему следует уделять особое внимание.

Проведем теперь сравнительный анализ нейросетевого метода распознавания с детерминированным методом распознавания, использующим потенциальные функции. Свое название потенциальные функции заимствуют из физики, так как они напоминают функции потенциала электрического поля вокруг точечного электрического заряда. Допустим, необходимо разделить два класса ω_1 и ω_2 . Выборочные образы, принадлежащие обоим классам, представлены векторами или точками в n -мерном пространстве образов. Если ввести аналогию между точками, представляющими выборочные образы, и некоторым источником энергии, то в любой из этих точек потенциал достигает максимального значения и быстро уменьшается при переходе во всякую точку, отстоящую от точки, представляющей выборочный образ x_k . На основе этой аналогии можно

допустить существование эквипотенциальных контуров, которые описываются потенциальной функцией $K(x, x_k)$. Решающие функции для классификации образов можно получить из потенциальных функций для векторов, представляющих выборочные образы x_k , $k=1, 2, 3, \dots$, в пространстве образов. Потенциальную функцию для любой точки x_k , соответствующей выборочному образу, можно представить выражением

$$K(x, x_k) = \sum_{i=1}^{\infty} \lambda_i^2 \varphi_i(x) \varphi_i(x_k), \quad (3.1.11)$$

где функции $\varphi_i(x)$, $i=1, 2, \dots$, полагаются для удобства ортонормированными, а действительные числа λ_i , $i=1, 2, \dots$, отличные от нуля, выбраны таким образом, чтобы потенциальная функция $K(x, x_k)$ для образов $x_k \in \omega_1 \cup \omega_2$ была ограничена.

Решающую функцию $d(x)$ можно построить, исходя из последовательности потенциальных функций $K(x, x_1)$, $K(x, x_2), \dots$, соответствующей последовательности образов обучающей выборки x_1, x_2, \dots , предъявляемых системе в процессе обучения. Решающую функцию $d(x)$, связанную с потенциальными функциями $K(x, x_k)$ множеством ортогональных функций $\varphi_i(x)$, можно представить в виде ряда

$$d(x) = \sum_{i=1}^{\infty} c_i \varphi_i(x) . \quad (3.1.12)$$

Коэффициенты c_i , $i=1, 2, \dots$, входящие в (3.1.12), неизвестны и могут быть определены по обучающей выборке образов с помощью итеративной процедуры. Решающая функция $d(x)$ является относительно гладкой функцией, и в малой области число её экстремумов невелико; значения $d(x)$ в близко расположенных точках мало отличаются. Решающая функция, определяемая формулой (3.1.12), связана с потенциальной функцией (3.1.11) рекуррентным соотношением

$$d_{k+1}(x) = d_k(x) + r_{k+1} K(x, x_{k+1}), \quad (3.1.13)$$

где k – номер шага итерации, а r_{k+1} – коэффициенты, определяемые соотношениями

$$r_{k+1} = \begin{cases} 0 & \text{при } x_{k+1} \in \omega_1 \text{ и } K_k(x_{k+1}) > 0, \\ 0 & \text{при } x_{k+1} \in \omega_2 \text{ и } K_k(x_{k+1}) < 0, \\ 1 & \text{при } x_{k+1} \in \omega_1 \text{ и } K_k(x_{k+1}) \leq 0, \\ -1 & \text{при } x_{k+1} \in \omega_2 \text{ и } K_k(x_{k+1}) \geq 0. \end{cases} \quad (3.1.14)$$

Если алгоритм дает правильную классификацию, то коэффициент $r_{k+1}=0$. Решающую функцию $d(x)$ можно непосредственно получить из потенциальной функции.

Перейдем к рассмотрению результатов работы алгоритмов. Как и в эксперименте с байесовским классификатором будет рассмотрена задача распознавания векторов случайных гауссовских величин, однако при этом будут распознаваться наборы образов разной степени схожести. Под схожестью в данном случае понимается разница между математическими ожиданиями и дисперсиями двух классов образов.

Проведем ряд опытов, чтобы выяснить эффективность каждого из алгоритмов. Для этого будем постепенно усложнять задачу – делать классы все более и более похожими друг на друга, уменьшая различия между математическими ожиданиями и дисперсиями классов. Результаты приведены в таблице 3.1.2 и 3.1.3.

Таблица 3.1.2. Результаты работы нейросетевого алгоритма

№	μ_1 (мат. ожидание класса 1)	μ_2 (мат. ожидание класса 2)	σ_1 (среднеkv. отклонение класса 1)	σ_2 (среднеkv. отклонение класса 2)	Точность классификации
1	0.1	2	0.5	0.7	67% - 83%
2	0.3	1.5	0.5	0.5	57% - 75%
3	0.5	0.8	0.5	0.7	40% - 65%

Таблица 3.1.3. Результаты работы алгоритма потенциальных функций

№	μ_1 (мат. ожидание класса 1)	μ_2 (мат. ожидание класса 2)	σ_1 (среднеkv. отклонение класса 1)	σ_2 (среднеkv. отклонение класса 2)	Точность классификации
1	0.1	2	0.5	0.7	100%
2	0.3	1.5	0.5	0.5	99% - 100%
3	0.5	0.8	0.5	0.7	56% - 68%

Критерием для сравнения алгоритмов является также скорость их работы. Сравнение будет проводиться без учета времени, затраченного на обучение (обучение производится для нейронной сети и метода потенциальных функций), так как обучение проводится только один раз перед любым количеством тестовых испытаний. Данные о времени, затраченном на обработку 100 тестовых примеров каждым из алгоритмов, приведены в таблице 3.1.4.

Таблица 3.1.4. Время работы алгоритмов

Алгоритм	Затраченное время (с)
Потенциальных функций	0,0025 – 0,00765
Нейронная сеть	0,0015 – 0,0037

Анализируя полученные данные, можно прийти к некоторым выводам относительно эффективности рассматриваемых методов классификации. Распознавательная способность нейронной сети ниже распознавательной способности классификатора, основанного на методе потенциальных функций. При этом точность классификации метода потенциальных функций приближалась к 100% в опытах над классами с низкой степенью схожести, а диапазон точности классификации был существенно уже или вообще отсутствовал. В проведенных экспериментах особый интерес представляет опыт №3 в таблицах 3.1.2 и 3.1.3. В данном опыте образы для классификации являются, очевидно, линейно-неразделимыми, что резко снижает точность классификации метода потенциальных функций, в то время как для нейронной сети точность классификации убывает равномерно в соответствии с увеличением сложности задачи. В описанном случае точность классификации для метода потенциальных функций и метода обратного распространения ошибки практически идентична. При использовании нейросетевого алгоритма в каждом из опытов наблюдался некоторый разброс эффективности классификации, т.е. в некоторых случаях нейронная сеть работала существенно лучше, чем в других. Помимо того, что тестовые примеры в данном случае имеют стохастический характер, здесь, как и в

эксперименте с байесовским классификатором, играет роль качество обучающей выборки. Рассмотрим данную проблему подробнее.

Эффективность используемой обучающей выборки основывается на двух факторах – объеме и качестве. Тема размера обучающей выборки подробно освещена в [73], где показана прямая зависимость между объемом обучающей выборки и способностью к обобщению. Количество обучающих примеров не должно превышать некоторого порога насыщения, после которого наступает переобучение или избыточное обучение. Следует отметить, что сеть, обученная на слишком большом количестве примеров, близка к простому запоминанию данных обучения, некорректно реагируя на отличные от них сигналы. Вопрос оптимального объема обучающей выборки также затрагивается в [73], однако автор на нем подробно не останавливается. Качество обучающих примеров связывается с понятием их сложности, т.е. для повышения качества обучающей выборки следует использовать примеры, вызывающие наибольшие ошибки обучения и соответственно максимально отличающиеся от использованных ранее. Было выдвинуто предположение, что в данном случае решающее значение имело качество обучающей выборки.

Проведем экспериментальный анализ обучающих выборок с целью выявления факторов, влияющих на эффективность работы многослойного персептрона. С помощью нелинейного проекционного метода, называющегося отображением Семмона, перенесем входные образы на двумерную плоскость, с целью визуального сравнения “успешных” и “неуспешных” обучающих выборок. Суть данного метода в максимально точном соответствии расстояний между многомерным набором данных и точками на двумерной плоскости. Подробно отображение Семмона описано в [26].

Смоделируем входные векторы многослойного персептрона, рассмотренного ранее в эксперименте по распознаванию двух классов гауссовских случайных величин, на плоскость. Для обучения персептрона

использовалась выборка небольшого объема, состоящая из 50 случайно смоделированных образов. В результате моделирования векторов обучения на плоскость получены графики, аналогичные представленным на рисунках 3.1.2 и 3.1.3.

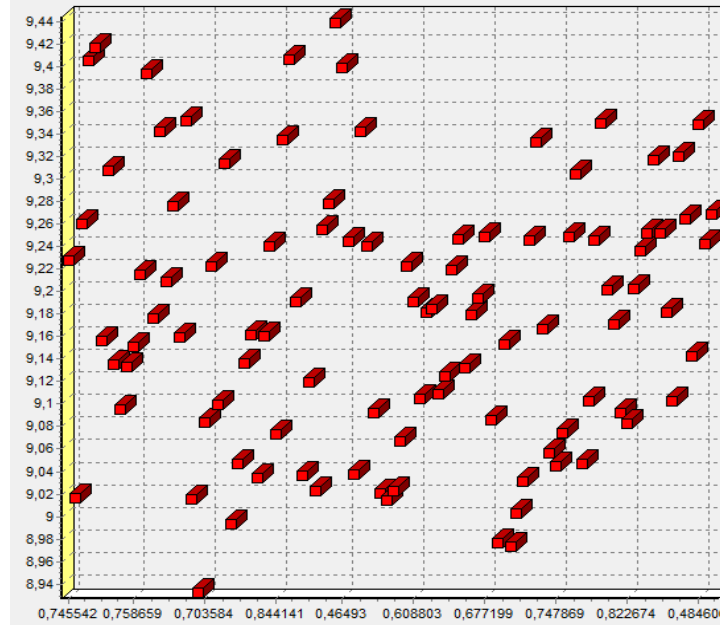


Рисунок. 3.1.2. Отображение обучающих векторов многослойного персептрона на плоскость с помощью отображения Семмона. Эффективность персептрона – 74%. Объем выборки – 100 примеров.

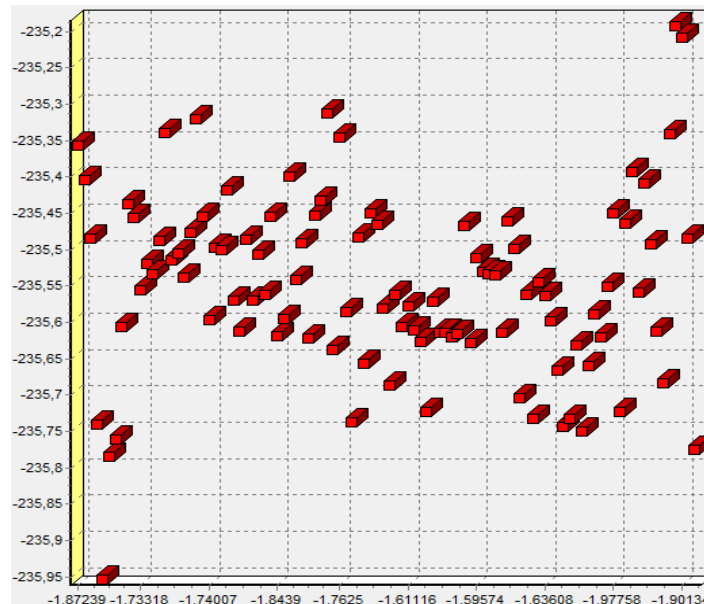


Рисунок. 3.1.3. Отображение обучающих векторов многослойного персептрона на плоскость с помощью отображения Семмона. Эффективность персептрона – 62%. Объем выборки – 100 примеров.

Проведем визуальный анализ графика, представленного на рисунке 3.1.2. Многослойный персептрон, обучающие векторы которого моделировались на графике, эффективно распознавал 74% образов, что для данного небольшого объема обучающей выборки представляется хорошим результатом. Обратим внимание на равномерное распределение всех проекций входных векторов по плоскости, с небольшим увеличением плотности точек к середине графика. На рисунке 3.1.3 представлен график менее эффективной нейронной сети с вероятностью корректной классификации 65%. На нем можно наблюдать большую плотность точек в некоторых локальных областях, вместе с заметными пробелами в других. Можно сделать вывод, что подобное распределение точек провоцирует худшие результаты обобщения нейронной сети.

Таким образом, исходя из результатов проведенных экспериментов, можно сделать вывод, что на способность обобщения многослойного персептрона влияет суммарная информативность обучающих примеров, выражающаяся в их отличии друг от друга. При использовании нелинейного проекционного метода отображения Семмона, мера информативности выражается в равномерности заполнения плоскости графиков.

Следует отметить, что визуальная оценка с помощью проекционного метода отображения Семмона проводилась для наглядной демонстрации взаимосвязи примеров обучающей выборки и конечной эффективности работы сети. При этом не стоит считать ее единственной возможной методикой, и более детальное исследование требует дополнительного анализа.

Из совокупности полученных данных можно сделать некоторые выводы. Нейросетевые алгоритмы способны составить конкуренцию классическим методам распознавания образов, таким как байесовский классификатор и метод потенциальных функций. При этом для простых задач линейно-разделимых классов целесообразнее использовать именно классические методы распознавания: так наибольшую эффективность

распознавания случайных гауссовских величин продемонстрировал метод потенциальных функций. Также стоит отметить сложность настройки нейронных сетей. При использовании данного класса алгоритмов следует обращать особое внимание на архитектуру сети, процесс обучения. В то же время нейронная сеть, обученная по методу обратного распространения ошибки, превзошла классификатор, основанный на методе потенциальных функций, по ресурсоемкости, скорости работы. Нейронные сети корректнее использовать для более сложных задач, для задач классификации линейно-неразделимых классов и при работе с большими объемами данных. Таким образом нейросетевые алгоритмы будет целесообразно применить в задаче распознавания и классификации изображений. При этом следует использовать нейросетевые алгоритмы со сложной архитектурой, рассчитанные именно на работу с изображениями.

3.2. Использование сверточных нейронных сетей для распознавания изображений

Задача распознавания изображений относится к классу трудно формализуемых задач, поэтому одним из эффективных методов ее решения является нейросетевое моделирование [11, 25, 73]. Из всего многообразия нейросетевых алгоритмов представляется целесообразным использовать сверточную нейронную сеть, спроектированную специально для работы с графическими изображениями. Были проведены исследования [64, 78], показывающие её эффективность при распознавании таких объектов как рукописный текст, автомобильные номера и человеческие лица.

Идея сверточных нейронных сетей заключается в чередовании сверточных слоев и субдискретизирующих слоев. Суть субдискретизирующих слоев заключается в уменьшении в заданное количество раз размерности изображения за счет его усреднения. В сверточных слоях, как следует из названия, к нейронам сети применяется операция свертки, при которой каждый фрагмент изображения поэлементно

умножается на некоторую матрицу - ядро свертки, результат суммируется, пропускается через функцию активации и записывается в аналогичную позицию выходного изображения. Все слои состоят из набора карт признаков, нейроны каждой из которых используют один и тот же набор синаптических весов. Именно за счет использования общих синаптических весов, удастся минимизировать необходимые ресурсы.

Перейдем теперь к конкретному примеру применения сверточной нейронной сети. Пусть требуется провести эксперимент по классификации изображений, описанный в главе II, а именно разбить изображения кораблей на два класса, один из которых условно назовем «Цель», а другой «Ловушка». Для упрощения вычислений предположим, что единственным фактором принадлежности корабля к тому или иному классу является форма его локатора - участок изображения размером 32x32 пикселя (рис. 3.2.1).



Рисунок 3.2.1. Корабль класса «Цель» (А) и корабль класса «Ловушка» (В), справа от каждого корабля показан его локатор.

Нейронная сеть будет состоять из 7 слоев, из которых первые 5 - последовательно чередующиеся сверточные и субдискретизирующие слои, а последние 2 слоя – полносвязные. Архитектура сети представлена на рисунке 3.2.2.




Рисунок 3.2.2. Архитектура сверточной нейронной сети.

Из рисунка 3.2.2 видно, что количество настраиваемых параметров для первого слоя будет равно 150 ($5 \cdot 5 \cdot 6$), для второго – 24, для третьего – 1500, для четвертого – 64, для пятого – 400. Для 6 и 7 полносвязного слоя количество параметров будет соответственно равно 256 и 32. Таким образом, общее количество настраиваемых параметров для всей сети составляет 2426 параметров, что в разы меньше чем требуется многослойному персептрон для решения аналогичной задачи.

Стоит отметить, что сверточная нейронная сеть обучается, как и многослойный персептрон по методу обратного распространения ошибки (3.1.1-3.1.8), однако требует более тонкой настройки. Так, при использовании сверточной сети обязательно применение операции нормализации входов. Под нормализацией входов понимается предварительная обработка всех входных переменных так, чтобы их среднее значение стало близким к нулю. Практическая значимость нормализации входов описана в [79]. В рассматриваемом случае классификации изображений локаторов кораблей естественно присваивать нейронам, соответствующим белым пикселям, значение 0, а нейронам, соответствующим черным пикселям, некоторое небольшое положительное значение.

Как было отмечено выше, использование сверточной нейронной сети выгоднее в плане экономии вычислительных ресурсов, чем использование многослойного персептрона. Дополнительным оптимизационным приемом при использовании сверточной нейронной сети может быть использование статичной величины, для коррекции синаптических весов сверточных и субдискретизирующих слоев. Коррекция синаптических весов рассчитывается по формуле:

$$\Delta w_{ji}(n) = \alpha \Delta w_{ji}(n-1) + \eta y_i(n) \delta_j(n), \quad (3.2.1)$$

где Δw_{ji} - коррекция синаптического веса, связывающего i и j нейрон, y_i - выход i -го нейрона, δ_j - градиент j -го нейрона, α - постоянная момента, η - скорость обучения, n - номер эпохи обучения. Заменяем переменную величину коррекции статичной, заранее определенной, величиной. При этом градиент определяет только знак этой величины. Подбор значения такой величины осуществляется эмпирически, для нашей задачи ее абсолютное значение составляет 0.00005. При использовании статичной коррекции параметров время, затрачиваемое на каждую итерацию, уменьшается в полтора раза. Таким образом проблемы с высокими вычислительными затратами на обучение могут быть, если и не решены, то по крайней мере минимизированы.

Результаты экспериментов со сверточной нейронной сетью по распознаванию фрагментов изображений приведены в таблице 3.2.1.

Таблица 3.2.1. Результаты экспериментов со сверточной нейронной сетью

Номер опыта	Эпох обучения сверточных нейронных сетей	Верно классифицированные образы	Неверно классифицированные образы
1	10	0.51	0.49
2	20	0.67	0.33
3	30	0.81	0.19
4	40	0.83	0.17
5	50	0.83	0.17
6	60	0.83	0.17

На основании представленных результатов можно сделать вывод о том, что сверточная нейронная сеть может быть успешно применена в задаче распознавания изображений. Применяя сверточную нейронную сеть ко всему изображению, получим результаты, приведенные в таблице 3.2.2.

Таблица 3.2.2 Результаты экспериментов со сверточной нейронной сетью

Номер опыта	Эпох обучения сверточных нейронных сетей	Верно классифицированные образы	Неверно классифицированные образы
1	10	0.52	0.48
2	20	0.56	0.44
3	30	0.65	0.35
4	40	0.67	0.33
5	50	0.70	0.30
6	60	0.70	0.30

Сравнивая результаты экспериментов из таблиц 3.2.1 и 3.2.2 можно сделать вывод о том, что с увеличением размера изображения падает точность классификации нейронной сети и ее эффективность уменьшается в 1.2 раза. Это можно связать с тем, что при распознавании зашумленного изображения возникают проблемы с обработкой некоторых признаков, которые отсутствовали при обработке изображения меньшего размера, и сеть требует дополнительной настройки.

Таким образом, представляется актуальной задача поиска алгоритма, альтернативного сверточной нейронной сети. Данный алгоритм должен отвечать следующим требованиям:

1. Обладать распознавательной способностью, сравнимой с распознавательной способностью сверточной нейронной сети.
2. Быть экономичным с точки зрения вычислительных ресурсов.
3. Быть простым с точки зрения настройки и обучения, обучаться на выборках небольшого объема.

В соответствии с выводами, сделанными в главе I, представляется разумным разрабатывать архитектуру искомого нейросетевого алгоритма в соответствии со структурной моделью работы человека-оператора в системе «человек-машина».

3.3. Нейросетевой распознавательный комплекс и математическая модель работы человека-оператора

На сегодняшний день наиболее совершенным опознающим устройством, способным принимать оптимальные решения при наличии помех является человек-оператор. Поэтому, разрабатывая автоматизированный комплекс для распознавания изображений, представляется разумным опираться на введенную в главе II ескую модель работы человека-оператора (рис. 2.1.1), используя при этом в качестве распознавательного алгоритма нейронные сети.

Стоит обратить внимание на то, что нейросетевой подход успешно согласуется с введенной математической моделью работы человека-оператора. Рассмотрим два основных подхода, выделяемых Хайкином при построении распознавательных систем [73].

1. Система состоит из двух частей: сети извлечения признаков, обучаемой без учителя, и сети классификации, обучаемой с учителем. В концептуальных терминах образ представляется как набор из n наблюдений, каждое из которых можно рассматривать как вектор x в n -мерном пространстве наблюдений. Извлечение признаков описывается с помощью преобразования, которое переводит вектор x в промежуточный вектор y в m -мерном пространстве признаков, где $m < n$. За счет снижения размерности данные входного образа сжимаются, упрощая задачу классификации. Сама классификация описывается как преобразование, которое отображает промежуточный вектор y в один из классов пространства решений.

2. Система представляет собой единую многослойную сеть прямого распространения, обучаемую с учителем. Задача извлечения признаков выполняется вычислительными узлами скрытого слоя сети.

В задаче распознавания изображений представляется целесообразным использовать первый подход. Его схема приведена на рисунке 3.3.1.




Рисунок 3.3.1. Схема нейросетевого подхода к распознаванию образов с разделением на сеть извлечения признаков и сеть классификации

Отметим также, что первый подход соответствует традиционному подходу к статистическому распознаванию образов [71], общая схема которого представлена на рисунке 3.3.2.




Рисунок 3.3.2. Блок-схема системы статистического распознавания образов

При таком подходе возможна более тонкая настройка отдельных сетей системы, чем при использовании монолитной сети. Кроме того, при работе с промежуточным вектором признаков, размерностью меньше входного, возможна экономия вычислительных ресурсов.

Если рассматривать структурную модель работы человека-оператора с точки зрения разделения распознавательной системы на две нейронные сети, то она примет вид, представленный на рисунке 3.3.3.

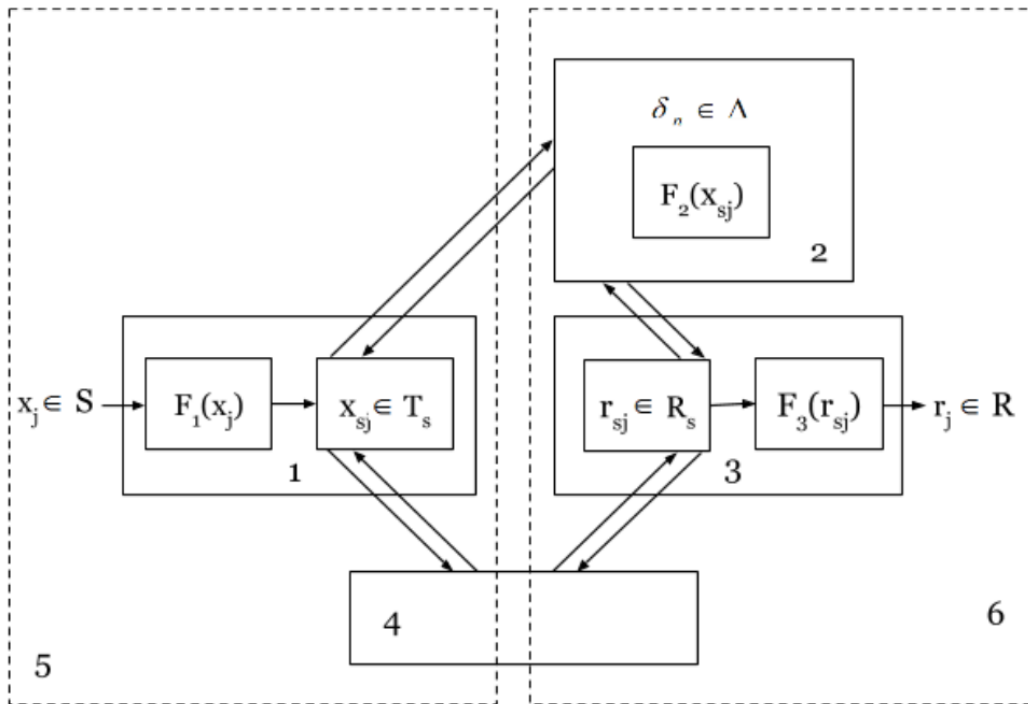


Рисунок 3.3.3. Структурная модель работы человека-оператора в системе «человек-машина». 1 – когнитивная подсистема, 2 – решающая подсистема, 3 – исполнительная подсистема, 4 – внутренние источники информации и память, 5 – подсистемы, моделируемые сетью извлечения признаков, 6 – подсистемы, моделируемые сетью, отвечающей за принятие решения.

Отметим, что в [73] предполагается использовать в качестве сетей извлечения признаков (когнитивной подсистемы) нейронные сети, обучаемые без учителя. Однако для этой цели могут использоваться и сети, обучаемые с учителем, такие как сверточные нейронные сети. Сети, обучаемые с учителем, используются при этом и в качестве решающей и исполнительной подсистемы. При этом исполнительная подсистема может как не выполнять никаких действий (в простейшем случае) так и, например, отправлять некоторые из входных образов на дообучение. Внутренние источники информации и память принадлежат обеим сетям, и формально обозначают место хранения настроенных синаптических весов сетей.

Помимо непосредственно нейросетевых алгоритмов в когнитивной системе будем использовать такой метод работы с изображениями, как

сегментация. Под сегментацией в данном случае понимается процесс получения компактного представления полезного содержания объекта [68, 70, 72]. Применение сегментации совместно с нейросетевым подходом позволит сэкономить вычислительные ресурсы. В самом деле, при работе с большими изображениями будет дано слишком много пикселей, чтобы обрабатывать их по отдельности. Вместо этого предпочтительно некоторое компактное, резюмирующее представление. Разумеется, это представление зависит от поставленной задачи, однако можно попытаться выделить его общие желательные характеристики: в представлении типичного изображения должно быть относительно немного информационных компонентов и эти компоненты должны быть содержательными. Для поиска такого представления существует широко освещенная в литературе методика сегментации [3, 28, 56, 70].

Естественно думать, что сегментация — это попытка определить, какие компоненты набора данных естественно связать вместе. При такой формулировке приходим к задаче кластеризации [15]. При этом изображение будет представлено как набор кластеров связанных пикселей. Конкретный критерий, согласно которому производится кластеризация, будет зависеть от поставленной задачи. Пиксели могут связываться из-за общего цвета, текстуры, из-за того, что они находятся рядом.

Рассмотрим методику сегментации применительно к нашей задаче. Значительная часть изображений для классификации повторяется, поэтому имеет смысл работать только с различающимися областями, на основе которых составляется карта отличий (рис. 3.3.4).




Рисунок 3.3.4. Карта отличий

На данной карте выделим темно-серым цветом точки, которые отличаются на 2-х изображениях из 4-х возможных (зоны максимально возможного отличия), и светло-серым цветом – точки, которые отличаются на одном изображении. После построения карты отличий предполагается провести ее сегментацию на участки с помощью агломеративного метода иерархической кластеризации. При этом процесс кластеризации начинается с того, что каждый объект карты отличий представляет собой самостоятельный кластер. Затем на каждой итерации пары близлежащих кластеров последовательно объединяются в общий кластер. Итерации продолжаются до тех пор, пока все объекты не будут объединены в один кластер или пока не выполнится условие остановки. Для определения меры близости между кластерами используется взвешенное евклидово расстояние:

$$\rho_{BE}(x_i, x_j) = \sqrt{\sum_{l=1}^k \omega_l (x_{il} - x_{jl})^2},$$

где x_{il} , x_{jl} - значения l -го признака у i -го (j -го) объекта ($l = 1, 2, \dots, k$, $i, j = 1, 2, \dots, n$).

Взвешенное евклидово расстояние применяется в тех случаях, когда каждой l -ой компоненте вектора наблюдений удается приписать некоторый «вес» ω_l , пропорциональный степени важности признака в задаче классификации. Обычно принимают $0 \leq \omega_l \leq 1$, где $l = 1, 2, \dots, k$. В нашем случае $\omega_1 = 1$ для точек максимального отличия и $\omega_2 = 0.7$ для остальных точек. В результате агломеративной кластеризации выделено пять сегментов изображения (рис. 3.3.5).




Рисунок 3.3.5. Результат сегментации карты отличий

Каждый из сегментов изображения подается на вход соответствующей ему сверточной нейронной сети. Однако в отличие от алгоритма, представленного в параграфе 3.2, выходы сверточных нейронных сетей будут поступать в качестве входных значений в решающую подсистему. В качестве решающей подсистемы будет использоваться не обычный многослойный перцептрон, а гибридная сеть нечеткой логики (в англоязычной литературе обозначаемая термином *fuzzy-neural*) [29]. Данный выбор связан с тем, что результаты работы гибридных сетей основываются на аппарате нечеткой логики, который обеспечивает возможность принятия правильных решений в условиях отсутствия полной информации. Рассмотрим гибридные нейронные сети подробнее.

3.4. Использование гибридной сети нечеткой логики для принятия решения

В качестве одного из наиболее поразительных свойств человеческого интеллекта можно выделить умение принимать правильные решения при условии отсутствия полной информации. Значительное продвижение в этом направлении сделано профессором Калифорнийского университета Лотфи А. Заде. Его научные труды [20] послужили толчком к развитию новой математической теории. Заде расширил классическое канторовское понятие множества, допустив, что функция принадлежности элемента множеству может принимать любые значения в интервале $[0; 1]$, а не только значения 0 либо 1. Такие множества были названы им нечеткими. Заде определил также ряд операций над этими множествами и предложил обобщение методов логического вывода. Затем было введено понятие лингвистической переменной, значениями которой выступают нечеткие множества [20]. Получившийся математический аппарат уже можно было использовать в качестве фундамента для описания процессов интеллектуальной деятельности, включая нечеткость и неопределенность выражений. На основе нечеткой логики были разработаны механизмы нечетких выводов с

базой знаний в виде нечетких предикат, используемые в различных экспертных и управляющих системах [59].

Системы управления с нечеткой логикой можно использовать в тех же задачах, где используются искусственные нейронные сети. При этом анализ обученной нейронной сети весьма сложен и накопленные знания распределены между всеми нейронами и недоступны наблюдателю; системы управления с нечеткой логикой лишены этих недостатков. В то же время нейронные сети в отличие от системы управления с нечеткой логикой обладают способностью к обучению и адаптации. Таким образом, представляется разумной идея об объединении систем нечеткой логики и нейронных сетей в единый комплекс, который будет обладать достоинствами каждого из алгоритмов. Подобный вывод подкрепляется тем фактом, что системы с нечеткой логикой и искусственные нейронные сети эквивалентны друг другу. При определенных условиях нечеткая система может быть представлена в форме многослойной сети с прямым распространением сигнала [61]. Их выводы основываются на аппарате нечеткой логики, а функции принадлежности подстраиваются с использованием алгоритмов обучения нейронных сетей (в частности алгоритма обратного распространения ошибки). Гибридные сети не только используют априорную информацию, но и приобретают новые знания и являются логически прозрачными.

Чтобы прояснить сущность гибридных нейронных сетей, следует сравнить простейшую нейронную сеть (рис. 3.4.1), имеющую два входа и только один нейрон и элементарную гибридную сеть (рис. 3.4.2).




Рисунок 3.4.1. Стандартная нейронная сеть

Здесь входные сигналы x_i умножаются на веса w_i ; полученные произведения суммируются и пропускаются через некоторую активационную функцию f . Пусть в качестве функции активации выбрана сигмоидная функция. Приведенную сеть, в которой используются операции умножения, суммирования, будем называть стандартной нейронной сетью. В случае применения других операций, таких как t -норма или t -конорма, приходим к нейронной сети, которая будет называться нечеткой или гибридной.

Таким образом, можно ввести следующее определение: гибридная нейронная сеть — это нейронная сеть с четкими сигналами, весами и активационной функцией, но с объединением x_i и w_i , а также их произведений с использованием t -нормы, t -конормы или некоторых других непрерывных операций [29]. Входы, выходы и веса гибридной нейронной сети — вещественные числа, принадлежащие отрезку $[0, 1]$. Рассмотрим в качестве примера моделирование нечеткого нейрона «И». Сигналы x_i и веса w_i в данном случае объединяются с помощью треугольной конормы, а выход образуется с применением треугольной нормы

$$y = \text{AND}(v_1, v_2) = T(v_1, v_2) = T(S(w_1, x_1), S(w_2, x_2))$$

Если принять

$$T = \min, S = \max$$

то нечеткий нейрон «И» реализует композицию \min - \max :

$$y = \min(w_1 \vee x_1, w_2 \vee x_2)$$

его структура представлена на рисунке 3.4.2.




Рисунок 3.4.2. Структура гибридного нейрона «И»

Рассмотрим методику обучения и использования гибридных нейронных сетей. Гибридная сеть должна осуществить следующее отображение:

$$y^k = f(x^k) = f(x_1^k, x_2^k, \dots, x_n^k), k = 1, 2, \dots, N,$$

при обучающем множестве

$$\{(x^1, y^1), \dots, (x^N, y^N)\}.$$

Для моделирования отображения f используется алгоритм нечеткого вывода с предикатными правилами вида:

П_i: если x_1 есть A_{i1} , x_2 есть A_{i2} , ..., x_n есть A_{in} , то $y = z_i$, $i=1, 2, \dots, m$,

где A_{ij} – нечеткие числа треугольной формы, z_i – вещественные числа.

Степень истинности i -го правила определяется с помощью операции умножения:

$$\alpha_i = \prod_{j=1}^n A_{ij}(x_j^k).$$

При этом выход нечеткой системы определяется дискретным аналогом центроидного метода:

$$o^k = \frac{\sum_{i=1}^m \alpha_i z_i}{\sum_{i=1}^m \alpha_i},$$

Введение функции ошибки для k -го предъявленного вида

$$E_k = \frac{1}{2} (o^k - y^k)^2,$$

позволяет использовать градиентный метод для настройки параметров предикатных правил. Величины z_i корректируются соотношением:

$$z_i = z_i - \eta \frac{\partial E_k}{\partial z_i} = z_i - \eta (o^k - y^k) \frac{\alpha_i}{\alpha_1 + \alpha_2 + \dots + \alpha_m}, i = 1, 2, \dots, m,$$

где η – константа скорости обучения.

Теперь перейдем непосредственно к построению гибридной сети нечеткой логики для нашей задачи классификации изображений. Схема ее работы представлена на рисунке 3.4.3.




Рисунок 3.4.3. Гибридная нейронная сеть

Данная сеть может быть описана послойно следующим образом:

1. Слой 1. Принимает входные значения x_i и определяет их степени принадлежности нечетким множествам A_i и B_i , которые будут подробно описаны ниже.
2. Слой 2. Каждый нейрон слоя 2 представляет собой рассмотренный выше гибридный нейрон «И».
3. Слой 3. Нейроны слоя 3 являются стандартными нейронами, входы которых это линейные комбинации выходов предыдущего слоя, а выходы формируются функцией активации сигмоидного типа.

Для каждого из входных признаков x_1, x_2, \dots, x_N введем нечеткие понятия A_1, A_2, \dots, A_N («является целью») и B_1, B_2, \dots, B_N («является ловушкой»). Для этих нечетких понятий определим сигмоидные функции принадлежности:

$$A_k(x) = \frac{1}{1 + e^{-b_k(x - a_k)}},$$

$$B_k(x) = \frac{1}{1 + e^{b_k(x - a_k)}},$$

где b_k и a_k – настраиваемые параметры, $k = 1 \dots N$.

Каждая пара таких функций принадлежности обладает следующим свойством, упрощающим расчеты при настройке сети:

$$A_k(x) + B_k(x) = 1. \quad (3.4.1)$$

Наглядно симметричные функции принадлежности представлены на рисунке 3.4.4.




Рисунок 3.4.4. Симметричные функции принадлежности

Используя указанные нечеткие понятия, создадим систему нечетких правил:

Π_1 : если x_1 есть A_1 , x_2 есть A_2 , ..., x_{N-1} есть A_{N-1} , x_N есть A_N , то $y = z_1$

Π_2 : если x_1 есть A_1 , x_2 есть A_2 , ..., x_{N-1} есть A_{N-1} , x_N есть B_N , то $y = z_2$

...

Π_2^N : если x_1 есть B_1 , x_2 есть B_2 , ..., x_{N-1} есть B_{N-1} , x_N есть B_N , то $y = z_2^N$

В рассматриваемой системе правил A_k , B_k – нечеткие числа треугольной формы, $k = 1 \dots N$, где N – количество входов сети, y – переменная вывода, z_i – вещественные числа, определяющие степень истинности i -го правила. Общий выход нечеткой системы определяется дискретным аналогом центроидного метода [29]. При решении нашей задачи классификации изображений, имеем 5 входных признаков, и каждый входной признак имеет две функции принадлежности. Таким образом, будет сформировано 2^5 правил (по числу размещений с повторениями из 2 по 5). Нейроны второго слоя реализуют нечеткую операцию «И» для соответствующих им нечетких правил. Нейроны третьего слоя формируют итоговое решение по классификации всего изображения. Обучение слоев сети осуществляется по методу обратного распространения ошибки, его модификация для гибридных сетей подробно рассматривается в специальной литературе [29].

Представленная гибридная нейросетевая модель обеспечивает достаточный базис для построения решающей подсистемы (рис. 3.3.3). Вычислительный эксперимент по ее использованию в задаче классификации изображений будет представлен в главе IV.

Выводы по главе III

1. Рассмотрены основные понятия нейросетевого моделирования, проведен ряд экспериментов по настройке и обучению многослойного персептрона. В результате компьютерного моделирования получены оценки работы байесовского классификатора, метода потенциальных функций и

многослойного персептрона. Получено, что помимо архитектуры сети, обучающие выборки оказывают наибольшее влияние на эффективность работы нейронной сети.

2. С помощью нелинейного проекционного метода отображения Семмона был проведен экспериментальный и визуальный анализ влияния обучающих выборок на эффективность работы многослойного персептрона. На способность обобщения многослойного персептрона влияет суммарная информативность обучающих примеров, выражающаяся в отличии их друг от друга.
3. Рассмотрен алгоритм работы сверточной нейронной сети и проведен эксперимент по распознаванию изображений кораблей. Показано, что для упрощения вычислений можно выделить участок изображения размером 32 x 32 пикселя, являющийся формой лоатора корабля, главным признаком распознавания.
4. Проведен вычислительный эксперимент со сверточной нейронной сетью, распознающей фрагменты изображений и полное изображение. Анализ экспериментов показал, что эффективность работы сверточной нейронной сети уменьшается в 1.2 раза при распознавании полного изображения. Показано, что применение сверточной нейронной сети экономит вычислительные средства по сравнению с многослойным персептроном.
5. Применение нейросетевого подхода к распознаванию образов дало возможность представить структурную модель работы человека-оператора в виде двух подсистем моделируемых сетью извлечения признаков (когнитивная подсистема) и сетью, отвечающей за принятие решений (решающая и исполнительная подсистема).
6. Для экономии вычислительных ресурсов построена карта отличий распознаваемых изображений и проведена ее сегментация на участки с помощью агломеративного метода иерархической кластеризации. Выделено 5 сегментов.

7. Рассмотрена работа гибридной нейронной сети нечеткой логики и оценена возможность ее применения для моделирования решающей подсистемы. На основе нейросетевых моделей, гибридных нейронных сетей и сегментации разработан алгоритм классификации изображений, согласующийся с исследованиями в области инженерной психологии, психофизики и теории статистических решений, используемый для моделирования работы человека-оператора в системе «человек-дисплей».

ГЛАВА IV. ОПИСАНИЕ ПРОГРАММНОГО КОМПЛЕКСА И ВЫЧИСЛИТЕЛЬНЫХ ЭКСПЕРИМЕНТОВ

4.1. Общая схема работы распознавательного комплекса

Проведем вычислительный эксперимент с нейросетевым классификатором изображений, описанным в главе III. Напомним общую схему работы классификатора. На базе классифицируемых изображений создается карта отличий (рис. 3.3.4), которая разбивается на некоторое количество фрагментов с помощью сегментации (рис. 3.3.5). Для каждого из фрагментов обучается сверточная нейронная сеть. Выходы сверточных нейронных сетей поступают в гибридный классификатор.

Программный комплекс для моделирования данного классификатора был разрабатывался на языке программирования C++ в среде Visual Studio 2010. В вычислительном эксперименте итоговый классификатор изображений показал высокие результаты – вплоть до 96% правильно распознанных изображений (см. табл. 4.1.1).

Таблица 4.1.1. Результаты работы нечеткой нейронной сети

Номер опыта	Эпох обучения сверточных нейронных сетей	Эпох обучения сети нечеткой логики	Вероятность правильной классификации
1	10	50	61%
2	20	50	66%
3	30	50	68%
4	10	100	72%
5	20	100	84%
6	30	100	87%
7	10	200	75%
8	20	200	92%
9	30	200	95%
10	10	500	77%
11	20	500	92%
12	30	500	96%

Высокий процент распознавания достигается при большом количестве эпох обучения сети нечеткой логики, однако, если при этом не будет проведена достаточная настройка сверточной нейронной сети, качество распознавания снизится.

Разграничение ответственности между сверточными сетями и сетью нечеткой логики позволяют классифицировать изображение даже в том случае, когда один или несколько участков изображения будут искажены до неузнаваемости, опираясь в своем решении на оставшиеся участки. Стоит отметить, что описанная архитектура позволяет обучать каждую из сверточных сетей параллельно, что способствует минимизации суммарного времени обучения.

Временные затраты на обучение представлены в таблице 4.1.2. Для каждой из сетей представлено минимальное и максимальное значение по результатам 10 экспериментов, при этом для сверточной нейронной сети представлены значения для разных фрагментов карты отличий.

Таблица 4.1.2. Время работы алгоритмов

Нейронная сеть	Эпох обучения	Затраченное время (с)
Сверточная нейронная сеть	30	5,122 – 7,513
		9,788 – 13,547
		11,419 – 15,207
		6,714 – 9,391
		8,628 – 11,410
Гибридная нейронная сеть	500	30,187 – 35,534

В результате проведенного опыта можно сделать вывод, что использование гибридного классификатора описанной архитектуры является предпочтительным при решении задач классификации изображений значительного размера, при наличии небольшой обучающей выборки. Однако при этом возникает вопрос о приемлемости использования в классификаторе подобного классификатора сверточных нейронных сетей. Сверточные нейронные сети разрабатывались исходя из предпосылки, что их настройка будет проходить в условиях большого объема обучающей выборки и

окончательное решение о принадлежности к тому или иному классу будет принимать слой полной связи сети. Для рассматриваемой нами задачи распознавания изображений кораблей в условиях небольшого набора обучающих примеров, возможно будет целесообразнее использовать иной тип нейронных сетей в качестве ядра когнитивной подсистемы. В качестве такого типа сетей предлагается использовать самоорганизующуюся карту Кохонена: нейросетевой алгоритм, обучающийся без учителя, со сравнительно простой архитектурой [26].

Рассмотрим общие положения моделирования самоорганизующихся карт Кохонена. Алгоритм функционирования самоорганизующихся карт представляет собой один из вариантов кластеризации многомерных векторов. Все нейроны самоорганизующихся карт упорядочены в некоторую структуру. Обычно в качестве такой структуры выступает четырехугольная (иногда шестиугольная) сетка (см. рис. 4.1.1).




Рисунок. 4.1.1. Четырехугольная сетка самоорганизующейся карты Кохонена (SOM)

В ходе обучения модифицируются веса нейрона-победителя и его ближайших соседей. Количество нейронов, которые считаются соседями на конкретной итерации алгоритма, называется радиусом обучения. Каждый

нейрон характеризуется n -мерным вектором весовых коэффициентов $w=[w_1, w_2, \dots, w_n]^T$, где n определяется размерностью входных векторов, и степень модификации зависит от близости к нейрону-победителю. В результате схожие векторы исходного пространства окажутся рядом на сетке. При этом, как было сказано выше, нейроны также взаимодействуют друг с другом. Величина этого взаимодействия определяется расстоянием между нейронами на сетке. Таким образом, самоорганизующиеся карты выполняют функцию проецирования многомерного пространства в пространство с более низкой размерностью.

Перед применением алгоритма SOM необходимо определиться с конфигурацией сетки и количеством нейронов в сети. Именно от количества нейронов в сетке зависит детализация результата работы алгоритма и точность обобщающей способности карты. Иногда рекомендуется использовать максимально возможное количество нейронов в карте. При этом начальный радиус обучения в значительной степени влияет на обобщающую способность. В случае, когда количество узлов карты превышает количество примеров в обучающей выборке, успех работы SOM в большой степени зависит от подходящего выбора начального радиуса обучения. Однако, если размер карты составляет десятки тысяч нейронов, то обучение займет слишком много времени и вычислительных ресурсов. Поэтому в реальных задачах разумно будет искать допустимый компромисс при выборе количества узлов.

Перед началом обучения карты необходимо проинициализировать весовые коэффициенты нейронов. Удачно выбранный способ инициализации может существенно ускорить обучение. Инициализировать начальные значения можно как случайными значениями, так и элементами обучающей выборки. После инициализации начинается пошаговая коррекция весовых коэффициентов. На каждом шаге обучения из исходного набора данных выбирается один из образов, а затем производится поиск наиболее похожего на него вектора коэффициентов нейронов. Найденный нейрон признается нейроном-победителем. Под похожестью в данной задаче понимается

расстояние между векторами, обычно вычисляемое в евклидовом пространстве. Таким образом,

$$\|x - w_c\| = \min_i \{\|x - w_i\|\},$$

где i – индекс узла, c – нейрон-победитель. После определения нейрона-победителя веса сети корректируются. Для модификации весовых коэффициентов используется формула:

$$w_i(t+1) = w_i(t) + h_{ci}(t) \cdot [x(t) - w_i(t)],$$

где i – индекс узла, t – номер эпохи, вектор $x(t)$ выбирается случайно из обучающей выборки на итерации t , а $h(t)$ – функция соседства нейронов. Эта функция представляет собой невозрастающую функцию от времени и расстояния между нейроном-победителем и соседними нейронами в сетке. Простым примером функции соседства, является функция, определяющая окрестность узла-победителя:

$$h_{ci}(t) = \begin{cases} \alpha(t), & i \in N_c(t) \\ 0, & i \notin N_c(t) \end{cases},$$

где $N_c(t)$ – множество индексов точек, соседствующих с узлом-победителем, $\alpha(t)$ – коэффициент скорости обучения. $N_c(t)$ и $\alpha(t)$ монотонно уменьшаются с течением времени.

Обучение состоит из двух основных фаз: на первоначальном этапе выбирается достаточно большое значение скорости обучения и радиуса обучения, что позволяет расположить вектора нейронов в соответствии с распределением примеров в выборке, а затем производится точная подстройка весов, когда значения параметров скорости обучения много меньше начальных.

Основное преимущество самоорганизующихся карт Кохонена состоит в наглядности выходной информации. Эти сети позволяют упростить многомерную структуру, и являются наряду, например, с отображением Семмона одним из методов проецирования многомерного пространства в пространство с более низкой размерностью [26].

Базовым при изучении самоорганизующихся карт Кохонена является понятие обучения без учителя. Как было показано, веса карты модифицируются только на основе входных значений. Самоорганизующиеся карты Кохонена учатся понимать структуру многомерных данных и решать задачу их кластеризации.

Вернемся теперь к нашей задаче по классификации изображений. Для каждой из областей, выделенных в процессе сегментации, на эталонных изображениях сформируем самоорганизующуюся карту. Результаты для одного из фрагментов представлены на рисунке 4.1.2.

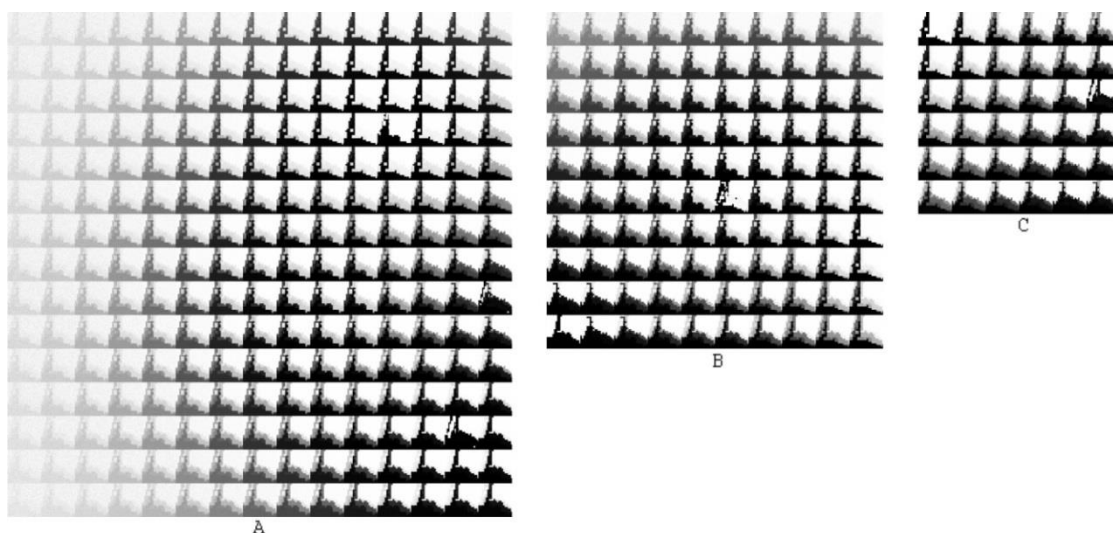


Рисунок 4.1.2. Самоорганизующиеся карты Кохонена. А - размером 15 x 15 ячеек, В - размером 10 x 10 ячеек, С - размером 6 x 6 ячеек

Когда нейросетевой модели передается изображение для классификации, изображение сегментируется на фрагменты и для каждого из фрагментов ищется ближайшая ячейка из соответствующей ему карты Кохонена.

Выбор самоорганизующихся карт Кохонена в качестве базиса когнитивной подсистемы обусловлен рядом преимуществ, которые они дают. Перечислим эти преимущества.

1. Самоорганизующиеся карты Кохонена удобно масштабировать, в зависимости от доступных вычислительных ресурсов, что наглядно показано на рисунке 4.1.2.
2. Результат работы самоорганизующихся карт Кохонена нагляден и удобен для зрительного восприятия и анализа.
3. Самоорганизующиеся карты Кохонена обеспечивают приведение многомерного признака в признак двумерный, или даже одномерный. Поясним данную мысль подробнее на примере. Допустим, в качестве одного из признаков для обработки, в нашу сеть подается изображение размером 20 на 20 пикселей. Если подать его в блок принятия решений без какой-либо предварительной обработки, то данный признак будет рассматриваться как вектор из 400 элементов. При использовании SOM изображение-признак будет сравниваться с ячейками карты, и в блок принятия решения будет передан с координатами максимально схожей ячейки (размерностью 2, если рассматривать SOM как матрицу, или 1, если рассматривать SOM как массив).
4. Самоорганизующиеся карты Кохонена могут использоваться как для простого упорядочивания входных признаков, так и для моделирования новых признаков. Так, например, все изображения представленные на рисунке 4.1.2 сгенерированы всего из 4 эталонных изображений.
5. С помощью самоорганизующихся карт Кохонена можно обрабатывать самые разные типы данных: числовые, графические, звуковые и так далее. Эта особенность не находит применения в решении текущей задачи по классификации изображений, однако она представляется важной для упоминания.

Таким образом, карты Кохонена используются для преобразования многомерного признака (участка изображения) в признак одномерный (координату наиболее близкой к предъявленному образу ячейке). Множество одномерных признаков – множеству психических образов $\{x_s\}$ (рис. 3.3.3). В

дальнейшем, множество таких признаков будет передано решающей подсистеме, моделируемой гибридной нейронной сетью.

4.2. Компьютерное моделирование нейросетевого классификатора и эксперимент с операторами

Рассмотрим этапы работы распознавательного комплекса от начала и до конца. На каждом из изображений тестовой выборки выделяются фрагменты, исходя из проведенной ранее процедурой сегментации. Каждый из фрагментов сравнивается с ячейками соответствующей ему самоорганизующейся карты Кохонена, сформированной на этапе обучения. Номера ячеек передаются в качестве входных параметров гибридному классификатору. На выходе классификатора получаем два вещественных числа, сравнивая которые делается вывод о принадлежности изображения к тому или иному классу. В данном алгоритме сегментация изображения и набор самоорганизующихся карт Кохонена соответствует когнитивной подсистеме, а гибридная сеть – решающей подсистеме в структурной модели работы человека-оператора. Общая схема функционирования нейросетевого классификатора представлена на рисунке 4.2.1.




Рисунок 4.2.1. Общая схема функционирования нейросетевого классификатора. Блок 1 соответствует когнитивной подсистеме, а блок 2 - решающей.

Описание программного комплекса. Программный комплекс для моделирования нейросетевого классификатора был разработан на языке программирования C++ в среде Visual Studio 2010 и полностью соответствует парадигме объектно-ориентированного программирования [37]. Он представляет собой библиотеки классов, реализующие ряд нейросетевых алгоритмов: многослойные сети прямого распространения, сверточные нейронные сети, самоорганизующиеся карты Кохонена, гибридные нейронные сети. Алгоритм работы самоорганизующих карт Кохонена представлен на рисунке 4.2.2.

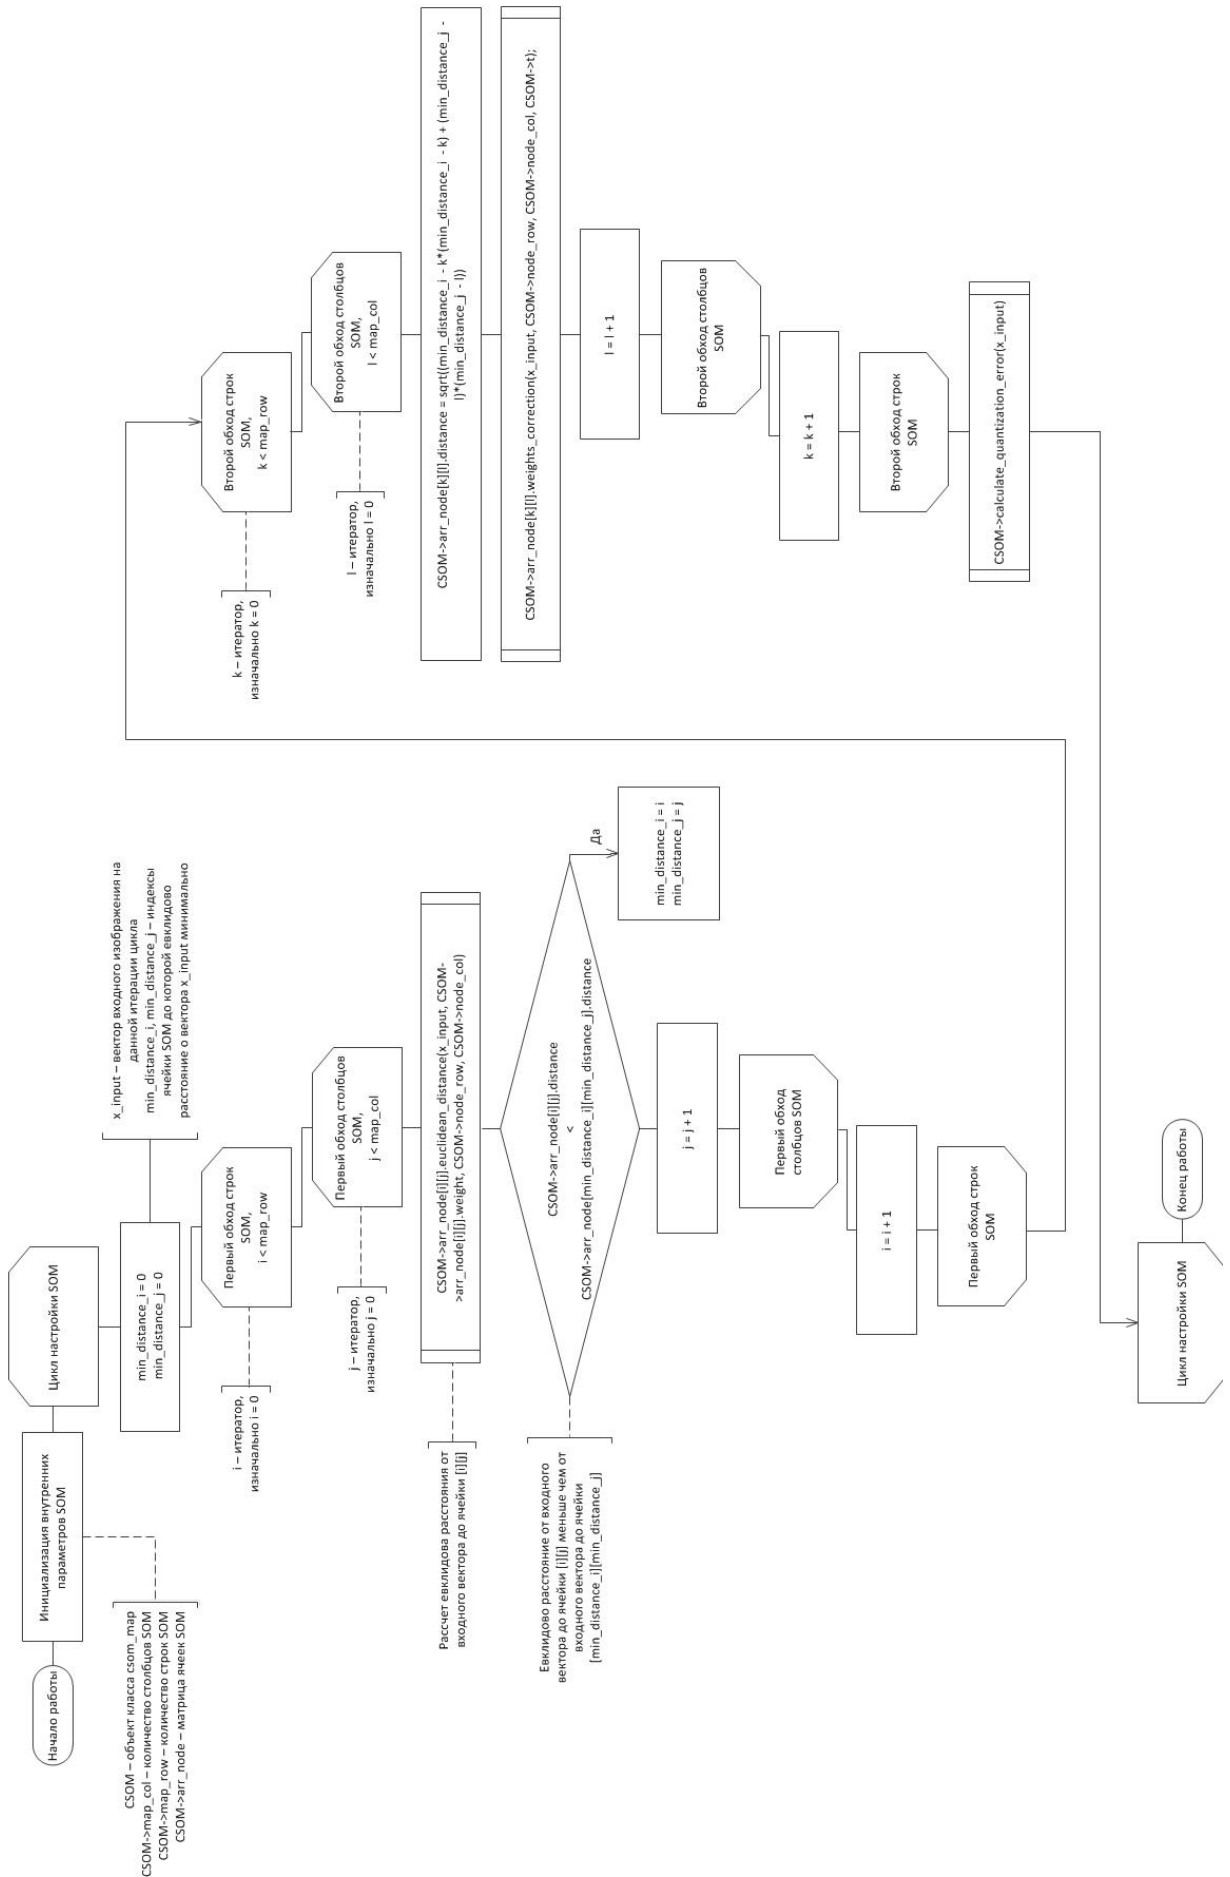


Рисунок. 4.2.2. Алгоритм CSOM

С UML-схемой классов можно ознакомиться в приложении В. Главное окно программы, написанной с помощью представленных библиотек, изображено на рисунке 4.2.3.

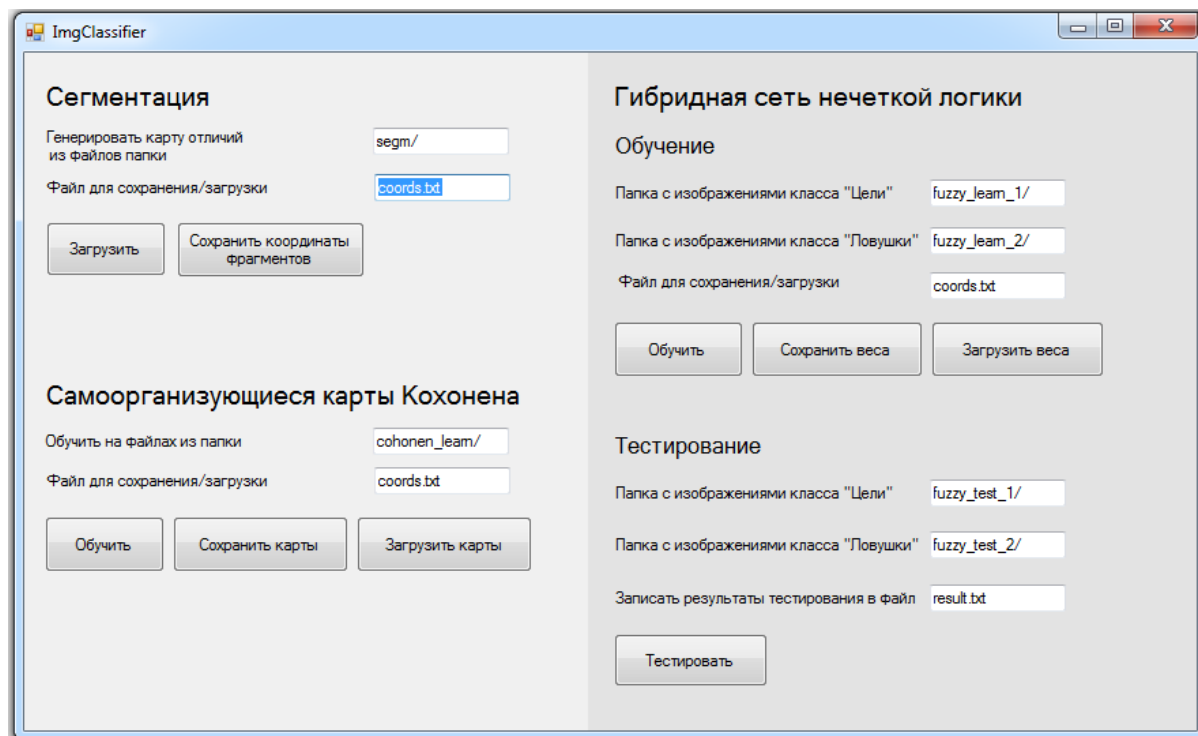


Рисунок. 4.2.3. Окно программы

В результате работы программы мы получаем детальную информацию о правильно и неправильно классифицированных изображениях, записанную в текстовый файл для дальнейшего анализа.

Представленная программа позволяет последовательно пройти все шаги обучения и тестирования нейросетевого классификатора. С помощью представленного интерфейса каждый из шагов обучения может быть записан в текстовый файл, который затем можно загрузить при следующей загрузке программы.

Управление тестовой и обучающей выборкой осуществляется через файловую систему: разработанный интерфейс позволяет выбирать адреса папок с изображениями для каждого из этапов работы. Общая схема работы

программного комплекса по классификации образов представлена на рисунке 4.2.4.

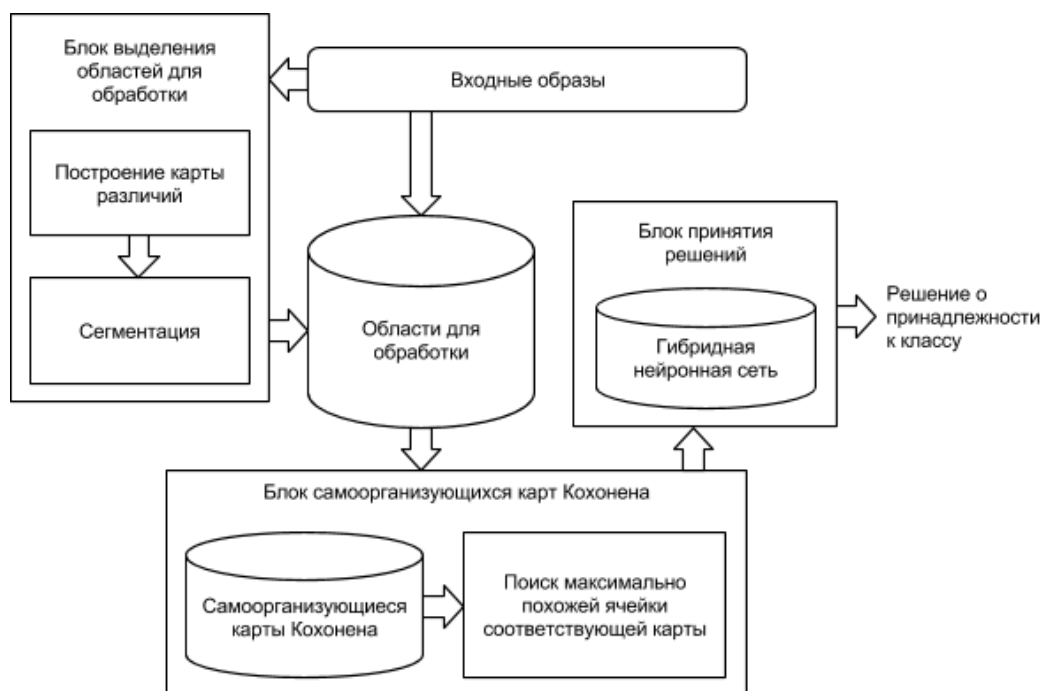


Рис. 4.2.4. Структура программного комплекса по классификации изображений

Эксперимент с оператором. В эксперименте принимали участие обученные операторы, что обеспечивало чистоту экспериментов. Оператор должен по предъявляемому на дисплее изображению определить его принадлежность к одному из классов («цели» или «ловушки»). Подробно методика проведения эксперимента с человеком-оператором была рассмотрена ранее в главе II.

Эксперименты проводились с контрольными выборками разного объема, при этом с увеличением объема контрольной выборки увеличивалась и предельная степень искажения изображений. Результаты экспериментов с человеком-оператором и нейронной сетью представлены в таблице 4.2.1.

Таблица 4.2.1. Результаты экспериментов с человеком-оператором и нейронной сетью

Объем контрольной выборки		40 примеров, 15% макс. процент зашумления	55 примеров, 25% макс. процент зашумления	70 примеров, 35% макс. процент зашумления	85 примеров, 45% макс. процент зашумления	100 примеров, 55% макс. процент зашумления	115 примеров, 65% макс. процент зашумления
Человек-оператор	$P_{\text{прав.}}$	0.99	0.98	0.96	0.91	0.85	0.80
Человек-оператор	$P_{\text{ош.}}$	0.01	0.02	0.04	0,09	0.15	0.20
Нейронная сеть	$P_{\text{прав.}}$	0.99	0.99	0.96	0.92	0.92	0.87
Нейронная сеть	$P_{\text{ош.}}$	0.01	0.01	0.04	0.08	0.08	0.13

Проведем статистический анализ полученных результатов. Проверим принадлежность рассмотренных выборок одной генеральной совокупности. Для проверки однородности применим непараметрический ранговый критерий Вилкоксона [24]. Достоинство этого критерия состоит в том, что он применим к случайным величинам, распределения которых неизвестны. Суть критерия заключается в проверке нулевой гипотезы, утверждающей, что функции распределения равны $H_0 : F_1(x) = F_2(x)$. Гипотеза H_0 принимается, если

$$S = \sum_{x_i \geq 0} R_i^+ = \sum_{i=1}^n R_i h(x_i) > C$$

где R_i^+ - ранг положительного элемента x_i в вариационном ряду, составленном из абсолютных значений независимых измерений x_1, x_2, \dots, x_n ; $h(x)$ - функция единичного скачка, C - критическое значение Вилкоксона.

Для того, чтобы при заданном уровне значимости α проверить нулевую гипотезу $H_0 : F_1(x) = F_2(x)$ об однородности двух выборок ($n_1 \leq n_2$) при альтернативе $H_1 : F_1(x) \neq F_2(x)$, необходимо

1. Расположить обе выборки в возрастающем порядке, т.е. в виде одного вариационного ряда и найти наблюдаемое значение критерия $W_{набл.}$ – сумму порядковых номеров элементов первой выборки.
2. Найти по таблице значений нижнюю критическую точку $w_{нижн.кр.}(Q, n_1, n_2)$ где $Q = \alpha/2$.
3. Найти верхнюю критическую точку по формуле

$$w_{верхн.кр.} = (n_1 + n_2 + 1)n_1 - w_{нижн.кр.}$$

Если $W_{набл.} < w_{нижн.кр.}$ или $W_{набл.} > w_{верхн.кр.}$ - нулевую гипотезу отвергают.

Если $w_{нижн.кр.} < W_{набл.} < w_{верхн.кр.}$ - нулевую гипотезу принимают.

Проверим гипотезу об однородности экспериментальных выборок при уровне значимости $\alpha=0.05$. Из двух выборок построим один вариационный ряд, элементы которого пронумеруем:

Таблица 4.2.2. Вариационный ряд

Порядковый номер	1	2	3	4	5	6	7	8	9	10	11	12
Вариационный ряд	0.99	0.99	0.99	0.98	0.96	0.96	0.92	0.92	0.91	0.87	0.85	0.80

Найдем наблюдаемое значение критерия Вилкоксона – сумму порядковых номеров элементов выборки результатов эксперимента с нейросетевым классификатором.

$$W_{набл.} = 1 + 3 + 5 + 7 + 8 + 10 = 34$$

Найдем по таблицам [12] нижнюю критическую точку, учитывая, что $Q = \alpha/2 = 0,05/2 = 0,025$, $n_1 = 6$, $n_2 = 6$

$$w_{нижн.кр.}(0,025;6;6) = 26$$

Найдем верхнюю критическую точку

$$w_{верхн.кр.} = (n_1 + n_2 + 1)n_1 - w_{нижн.кр.} = 52$$

Так как $26 < 34 < 52$, т.е. $w_{нижн.кр.} < W_{набл.} < w_{верхн.кр.}$ - гипотеза об однородности выборок принимается.

Следовательно, работу человека-оператора по распознаванию изображений можно описать предложенной автором моделью с вероятностью 0,95.

Из результатов проведенных экспериментов видно, что нейронная сеть показала более высокую распознавательную способность, чем человек-оператор. Отметим, что подобные выводы правомерны для узкого класса задач по распознаванию изображений: все изображения были изначально приведены к одному размеру, который не изменялся в процессе тестирования; кроме того в экспериментах использовалось только два типа искажающих воздействий. В тоже время идея разбиения нейросетевых моделей на блоки в соответствии с введенной психофизической моделью представляется универсальной, а сама модель – актуальной для дальнейших исследований. Кроме того, использование распознавательного комплекса, основанного на самоорганизующихся картах Кохонена и гибридной нейронной сети, обладает рядом преимуществ.

1. Самоорганизующиеся карты Кохонена хорошо масштабируются (в зависимости от доступных вычислительных ресурсов) и результат их работы нагляден, что делает их крайне привлекательными для использования инженером-проектировщиком нейронной сети.
2. Гибридная нейронная сеть реализует понятную систему нечетких выводов и позволяет использовать при классификации математический аппарат теории нечеткой логики.
3. За счет разделения исходного образа на несколько фрагментов, гибридная нейронная сеть может при соответствующей настройке успешно выполнять классификацию при частичной или даже полной потере информации на одном из них.
4. Применение приведенной нейросетевой модели обосновано с точки зрения психофизики, нейросетевого моделирования и теории статистических решений.

Выводы по главе IV

1. Был разработан программный комплекс для моделирования многослойных нейронных сетей прямого распространения, самоорганизующихся карт Кохонена и гибридных нейронных сетей.
2. Разработан нейросетевой классификатор изображений, согласующийся с введенной в главе II моделью работы человека-оператора, в котором в качестве когнитивной подсистемы используется набор самоорганизующихся карт Кохонена, а в качестве решающей подсистемы – гибридная нейронная сеть.
3. Были проведены эксперименты с операторами и нейросетевым классификатором, проведен сравнительный анализ результатов этих экспериментов.
4. Применен критерий Вилкоксона для проверки гипотезы о принадлежности выборок результатов экспериментов с операторами и нейросетевыми моделями одной генеральной совокупности. Применение критерия Вилкоксона показало, что работу человека-оператора по распознаванию изображений можно описать предложенной автором моделью с вероятностью 0.95.
5. На основании проведенных экспериментов был составлен список преимуществ разработанного нейросетевого классификатора, был сделан вывод о целесообразности его использования при решении задачи распознавания изображений в условиях ограниченной обучающей выборки и дальнейших исследований.

ОСНОВНЫЕ ВЫВОДЫ ПО ДИССЕРТАЦИИ

1. Анализ систем «человек-машина» и «человек-компьютер» показал, что наибольший интерес представляют информационные системы, которые используются для получения информации, необходимой для распознавания изображений и принятия решений человеком-оператором, воспринимающим информацию с экрана дисплея компьютера.
2. На основании теории статистических решений и исследований в области инженерной психологии и психофизики синтезирована структурная модель работы человека-оператора в системе «человек-машина», учитывающая взаимосвязи между памятью, восприятием, генерированием внутренних представлений. Относительно модели выдвинут ряд математических утверждений.
3. Разработана методика проведения эксперимента по классификации изображений человеком-оператором, отличительной чертой которой является отслеживание зрительного утомления оператора на основании вычисления показателя «устойчивости ясного видения» до и после эксперимента. Для проведения эксперимента разработано специальное программное обеспечение.
4. На основании изучения алгоритмов нейросетового моделирования и в соответствии со структурной моделью работы человека-оператора разработан алгоритм работы нейросетового комплекса распознавания изображений, состоящий из двух блоков, соответствующих когнитивной подсистеме и решающей. Для моделирования когнитивной подсистемы используются самоорганизующиеся карты Кохонена, а гибридная нейронная сеть нечеткой логики моделирует решающую подсистему.
5. Вычислительный эксперимент с нейросетевым распознавательным комплексом и эксперимент с группой операторов показали, что

предложенная структурная модель и её программная реализация адекватно описывают работу человека-оператора. На основании статистического анализа можно сделать вывод о том, что работу человека-оператора по распознаванию изображений можно описать предложенной автором моделью с вероятностью 0,95. Проведен эксперимент, в котором показаны преимущества разработанного комплекса над алгоритмом сверточных нейронных сетей.

6. На базе разработанных алгоритмов разработано программное обеспечение для классификации изображений, которое зарегистрировано в федеральной службе по интеллектуальной собственности, патентам и товарным знакам. Разработанные библиотеки для моделирования сетей прямого распространения, самоорганизующихся карт Кохонена и гибридных нейронных сетей написаны с использованием парадигмы ОПП, могут быть с легкостью интегрированы в любые программы на языке C++.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Алгазинов Э. К. Анализ и компьютерное моделирование информационных процессов и систем / Э. К. Алгазинов, А. А. Сирота. – М.: Диалог-МИФИ, 2009. – 416с.
2. Андреева О. Н. Оценка зрительной восприимчивости изображений оператором АРМ в системах реального времени / О. Н. Андреева, А. В. Брунов // Нейрокомпьютеры: разработка, применение. - 2013. – № 8. – С. 50-53.
3. Анисимов Б. В. Распознавание и цифровая обработка изображений / Б. В. Анисимов, В. Д. Курганов, В. К. Злобин. – М.: Высшая школа, 1983. – 295с.
4. Анохин П. К. Биология и нейрофизиология условного рефлекса / П. К. Анохин. – М.: Медицина, 1968. – 548с.
5. Арбиб М. Мозг, машина и математика / М. Арбиб. – М.: Наука, 1968. – 224с.
6. Бодров В. А. Информационный стресс / В. А. Бодров. – М.: ПЕРСЭ, 2000. – 352с.
7. Брунер Д. Психология познания / Д. Брунер. – М.: Прогресс, 1977. – 413с.
8. Вейценбаум Д. Возможности вычислительных машин и человеческий разум. От суждений к вычислениям / Д. Вейценбаум. – М.: Радио и связь, 1982. – 369с.
9. Венда В. Ф. Организация труда операторов: инженерно-психологические проблемы / В. Ф. Венда, А. И. Нафтульев, В. Ф. Рубахин. – М.: Экономика, 1978. – 224с.
10. Венда В. Ф. Системы гибридного интеллекта: Эволюция, психология, информатика / В. Ф. Венда. – М.: Машиностроение, 1990. – 448с.
11. Глезер В. Д. Механизмы опознания зрительных образов / В. Д. Глезер. – М.: Наука, 1966. – 204с.
12. Гмурман В. Е. Теория вероятностей и математическая статистика / В. Е. Гмурман. – М.: Высшая школа, 1972. – 368с.

13. Гонсалес Р. Цифровая обработка изображений / Р. Гонсалес, Р. Вудс. – М.: Техносфера, 2005. – 1072с.
14. Губинский А. И. Надежность и качество функционирования эргатических систем / А. И. Губинский. – Л.: Наука, 1982. – 268с.
15. Дж. Ту Принципы распознавания образов / Ту Дж. , Гонсалес. Р.. – М.: МИР, 1978. – 411с.
16. Душков Б. А. Психология труда, профессиональной, информационной и организационной деятельности. 3-е изд / Б. А. Душков, А. В. Королев, Б. А. Смирнов. – М.: Академический проект, Деловая книга. – 848с.
17. Душков Б. А. Основы инженерной психологии. 3-е изд / Б. А. Душков, А. В. Королев, Б. А. Смирнов. – Москва: Академический проект, Деловая книга. – 390с.
18. Егоров А. С. Психофизиология умственного труда / А. С. Егоров, В. П. Загрядский. – Л.: Наука, 1973. – 272с.
19. Забродин Ю. М. Особенности решения сенсорных задач человеком / Ю. М. Забродин, Е. З. Фришман, Г. С. Шляхтин. – М.: Наука, 1981. – 197с.
20. Заде Л. Нечеткая логика: Понятие лингвистической переменной и его применение к принятию приближенных решений / Л. Заде. – М.: Мир, 1976. – 167с.
21. Запорожец А. В. Избранные психологические труды / А. В. Запорожец. – М.: Педагогика, 1986. – 323с.
22. Зараковский Г. М. Закономерности функционирования эргатических систем / Г. М. Зараковский, В. В. Павлов. – М.: Радио и связь, 1987. – 232с.
23. Зинченко В. П. Человек и техника / В. П. Зинченко, Г. Л. Смолян. – М.: Знание, 1965. – 143с.
24. Кобзарь А. И. Прикладная математическая статистика / А. И. Кобзарь. – М.: ФИЗМАТЛИТ, 2006. – 816с.
25. Колерс П. Распознавание образов. Исследование живых и автоматических распознающих систем / П. Колерс, М. Иден. – М.: МИР, 1970. – 288с.

26. Кохонен Т. Самоорганизующиеся карты / Т. Кохонен. – М.: БИНОМ, 2008. – 655с.
27. Крамер Г. Математические методы статистики / Г. Крамер. – М.: Мир, 1975. – 648с.
28. Красильников Н. Н. Цифровая обработка 2D- и 3D-изображений / Н. Н. Красильников. – СПб: БХВ-Петербург, 2011. – 608с.
29. Круглов В. В. Нечеткая логика и искусственные нейронные сети / В. В. Круглов, М. И. Дли, Р. Ю. Голунов. – М.: ФИЗМАТЛИТ, 2001. – 201с.
30. Куффлер С. От нейрона к мозгу / С. Куффлер, Дж. Николс. – М.: Мир, 1979. – 440с.
31. Леман Э. Проверка статистических гипотез / Э. Леман. – М.: Наука, 1979. – 408с.
32. Леонов Ю. П. Теория статистических решений и психофизика / Ю. П. Леонов. – М.: НАУКА, 1977. – 223с.
33. Леонова А. Б. Психология труда и организационная психология: современное состояние и перспективы / А. Б. Леонова, О. Н. Чернышева. – М.: Радикс, 1995. – 448с.
34. Ломов Б. Ф. Основы инженерной психологии. 2-е изд / Б. Ф. Ломов, Б. А. Душков, В. Ф. Рубахин, Б. А. Смирнов. – М.: Высшая школа, 1986. – 448с.
35. Ломов Б. Ф. Справочник по инженерной психологии / Б. Ф. Ломов. – М.: Машиностроение, 1982. – 368с.
36. Ломов Б. Ф. Человек и техника. Очерки инженерной психологии / Б. Ф. Ломов. – М.: Советское радио, 1966. – 464с.
37. Медведев В. И. Особенности объектно-ориентированного программирования на C++/CLI, C# и Java / В. И. Медведев. – Казань: РИЦ «Школа», 2010. – 444с.
38. Мещеряков Б.Г. Большой психологический словарь / Б.Г. Мещеряков, В.П. Зинченко – М.: АСТ, 2009. – 816с.
39. Мидлтон Д. Введение в статистическую теорию связи / Д. Мидлтон. – М.: Советское радио, 1962. Т.2. – 830с.

40. Минский М. Перцепторы / М. Минский, С. Прейперт. – М.: Мир, 1971. – 264с.
41. Мирошников М. М. Иконика в физиологии и медицине / М. М. Мирошников, В. А. Лисовский, Е. В. Филиппов. – Л.: Наука, 1987. – 391с.
42. Мунипов В. М. Эргономика: человекоориентированное проектирование техники, программных средств и среды / В. М. Мунипов, В. П. Зинченко. – М.: Логос, 2001. – 356с.
43. Найссер У. Познание и реальность / У. Найссер. – М.: Прогресс, 1981. – 232с.
44. Никифоров Г. С. Надежность профессиональной деятельности / Г. С. Никифоров. – СПб: Изд-во Санкт-Петербургского ун-та, 1996. – 176с.
45. Николаев В. И. Контроль работы судовых энергитических установок / В. И. Николаев. – Л.: Судостроение, 1965. – 239с.
46. Новикова Н. М. Исследование зрительного утомления человека-оператора / Н. М. Новикова, А. С. Александров // XII международная научно-техническая конференция «Кибернетика и высокие технологии XXI века». Сб. материал. – Воронеж – 2011. – Т.1. – 11-12 мая – С.85-90.
47. Новикова Н. М. Интеллектуальные интерфейсы : учебник ВГУ / Н. М. Новикова, В. Н. Будко. – Воронеж: ИПЦ ВГУ, 2011. – 308с.
48. Новикова Н. М. Характеристики статистической модели распознавания зрительных образов человеком-оператором / Н. М. Новикова, С. Л. Подвальный // Информационные технологии. – 2005. – № 7. – С. 66-76.
49. Новикова Н. М. Вероятностно-временная модель обнаружения сигналов человеком-оператором / Н. М. Новикова // Системный анализ и управление в биомедицинских системах. – 2004. – Т.3. – № 4. – С. 326-330.
50. Новикова Н. М. Многоальтернативное распознавание изображений человеком-оператором / Н. М. Новикова // Системы управления и информационные технологии. – 2004. – № 5. – С. 98-100.
51. Норман Д. Переработка информации у человека / Д. Норман, П. Линдсей. – М.: Мир, 1974. – 550с.

52. Павлов В. В. Конфликты в технических системах / В. В. Павлов. – Киев: Выща школа, 1982. – 184с.
53. Платонов Г. А. Человек за пультом / Г. А. Платонов. – М.: Транспорт, 1969. – 167с.
54. Поветко В. Н. Единая функциональная модель зрения для информационных систем обнаружения / В. Н. Поветко // Радиотехника. – 1996. – № 6. – С. 88-92.
55. Понькин В. А. Оценка возможностей человека-оператора по различению пространственно протяженных объектов по их изображениям / В. А. Понькин, Н. В. Лаптев // Информационный конфликт в спектре электромагнитных волн. – 1999. – № 6. – С. 30-34.
56. Потапов А. А. Новейшие методы обработки изображений / А. А. Потапов, Гуляев Ю. В. , Никитов С. А. , Пахомов А. А. , Герман. В. А.. – М.: ФИЗМАТЛИТ, 2008. – 496с.
57. Раевский А. Н. К проблеме классификации систем "человек-машина" / А. Н. Раевский, А. В. Антонов // Проблемы инженерной психологии. – 1968. С. 54-58.
58. Розенфельд А. Распознавание и обработка изображений с помощью вычислительных машин / А. Розенфельд. – М.: МИР, 1972. – 230с.
59. Ротштейн А. П. Интеллектуальные технологии идентификации: нечеткие множества, нейронные сети, генетические алгоритмы / А. П. Ротштейн. – Винница: УНИВЕРСУМ-Винница, 1999. – 320с.
60. Рубахин В. Ф. Психологические основы обработки первичной информации / В. Ф. Рубахин. – Л.: Наука, 1974. – 296с.
61. Рутковская Д. Нейронные сети, генетические алгоритмы и нечеткие системы / Д. Рутковская, М. Пилиньский, Л. Рутковский. – М.: Горячая линия - Телеком, 2006. – 452с.
62. Рыжков В. А. Эволюция человеко-машинных интерфейсов / В. А. Рыжков // Нейрокомпьютеры: разработка, применение. – 2005. – № 8-9. – С. 119-136.

63. Сергеев С. Ф. Инженерная психология и эргономика / С. Ф. Сергеев. – М.: НИИ школьных технологий, 2008. – 176с.
64. Спицин В. Г. Алгоритм обнаружения лиц на основе сверточной нейронной сети / В. Г. Спицин // Нейрокомпьютеры: разработка, применение, № 10, 2013. С. 48-52.
65. Столин В. В. Построение зрительного образа при псевдоскопическом восприятии / В. В. Столин // Вопросы психологии. – 1972. – № 6. – С. 103-116.
66. Стрелков Ю. К. Инженерная и профессиональная психология: Учебное пособие для студентов высших учебных заведений / Ю. К. Стрелков. – М.: Издательский центр «Академия», 2001. – 360с.
67. Уоссермен Ф. Нейрокомпьютерная техника: Теория и практика / Ф. Уоссермен. – М.: Мир, 1992. – 186с.
68. Фисенко В. Т. Компьютерная обработка и распознавание изображений / В. Т. Фисенко, Т. Ю. Фисенко. – Санкт-Петербург: СПбГУИТМО, 2008. – 195с.
69. Фокин Ю. Г. Эргономика управления в антропотехнических системах / Ю. Г. Фокин, В. А. Пухов, В. Н. Степанов. – М.: Министерство обороны СССР, 1979. – 336с.
70. Форсайт Д. Компьютерное зрение. Современный подход / Д. Форсайт, Ж. Понс. – М.: Вильямс, 2004. – 928с.
71. Фукунага К. Введение в статистическую теорию распознавания образов / К. Фукунага. – М.: Наука, 1979. – 368с.
72. Фурман А. Я. Введение в контурный анализ и его приложения к обработке изображений и сигналов / А. Я. Фурман, А. В. Кревецкий, А. К. Передреев, А. А. Роженцов, Р. Г. Хафизов, И. Л. Егошина, А. Н. Леухин. – М.: ФИЗМАТЛИТ, 2003. – 592с.
73. Хайкин С. Нейронные сети. Полный курс. 2-е изд / С. Нейронные сети. Полный курс. Хайкин. – М.: Издательский дом "Вильямс", 2006. – 1104с.

74. Шеридан Т. Б. Системы человек-машина / Т. Б. Шеридан, У. Р. Феррел. – М.: Машиностроение, 1980. – 400с.
75. Шнейдерман Б. Психология программирования: человеческие факторы в вычислительных и информационных системах / Б. Шнейдерман. – М.: Радио и связь, 1984. – 304с.
76. Эмири О. О целеустремленных системах / О. Эмири, Р. О. Акоф. – М.: Мир, 1974. – 272с.
77. Albers S. Using a simulation model to represent the time dependence of human reliability / S. Albers // Proc. 5-th. EuRe Data Conf. Berlin. – 1986. – P. 445-453.
78. LeCun Y. Convolutional networks for images, speech, and time series / Y. LeCun, Y. Bengio. – London: THE MIT PRESS, 1995. – 1290с.
79. LeCun Y. Efficient Learning and Second-order Methods. A Tutorial at NIPS 93 / Y. LeCun. – Denver, 1993. – 311 p.
80. Treisman A. M. Strategies and Models of Selective Attention / A. M. Treisman // Psychological Review. – 1969. № 76. – P. 282.

ОСНОВНЫЕ РЕЗУЛЬТАТЫ ДИССЕРТАЦИИ ОПУБЛИКОВАНЫ В СЛЕДУЮЩИХ РАБОТАХ

Публикации в изданиях, рекомендованных ВАК РФ

1. Дуденков В.М. Распознавание изображений с помощью сверточной нейронной сети и нечеткого гибридного классификатора / Н.М. Новикова, В.М. Дуденков // Нейрокомпьютеры: разработка, применение – 2015. – №2. – С. 43-47.
2. Дуденков В.М. Нейросетевая модель работы человека-оператора в системе «человек-дисплей» / Н.М. Новикова, В.М. Дуденков // Научные ведомости БелГУ – 2015. №7(204) – С. 153-158.

Свидетельства о регистрации программ

3. Свидетельство о регистрации программы «DirectAndConvolutionNet 1.0» / Дуденков В.М. – М.: ФГУ ФИПС, 2014. Рег. № 2015618275 от 04.08.2015г.
4. Свидетельство о регистрации программы «FuzzyAndCohonenNet 1.0» / Дуденков В.М. – М.: ФГУ ФИПС, 2014. Рег. № 2015618276 от 04.08.2015г.

Статьи и материалы конференций

5. Дуденков В.М. Оптимальный многослойный персептрон для классификации образов / Н.М. Новикова, В.М. Дуденков // Кибернетика и высокие технологии XXI века (С&Т): материалы XIII Международ. науч.-техн. конф. – Воронеж, 2012. Т.1. – С. 109-119.
6. Дуденков В.М. Нейросетевые и детерминированные алгоритмы распознавания образов / Н.М. Новикова, В.М. Дуденков // Кибернетика и высокие технологии XXI века (С&Т): материалы XIV Международ. науч.-техн. конф. – Воронеж, 2013. Т.1. – С. 298-304.
7. Дуденков В.М. Использование сверточной нейронной сети в задаче распознавания графических изображений / В.М. Дуденков // Информатизация процессов формирования открытых систем на основе

- САПР, АСНИ, СУБД и систем искусственного интеллекта: материалы седьмой Международ. науч.-техн. конф. – Вологда, 2013. – С. 77-80.
8. Дуденков В.М. Моделирование сверточных нейронных сетей / В.М. Дуденков // Понтрягинские чтения: материалы XXIV Воронежской весенней математической школы. – Воронеж, 2013. – С. 71-72.
 9. Дуденков В.М. Анализ влияния примеров обучения на эффективность работы многослойного персептрона / В.М. Дуденков // Информатика: проблемы, методология, технологии: материалы XIV Международ. науч.-метод. конф. – Воронеж, 2014. – С. 51-53.
 10. Дуденков В.М. Распознавание изображений с помощью самоорганизующихся карт Кохонена и сетей нечеткой логики / В.М. Дуденков // Современные методы математики, теории управления и компьютерных технологий: материалы VII Международ. науч. конф. – 2014. – С. 131-133.
 11. Дуденков В.М. Моделирование нейронной сети для распознавания изображений на основе гибридной сети и самоорганизующихся карт Кохонена / Н.М. Новикова, В.М. Дуденков // Аспирант. – 2015. - №2 – С. 31-34.
 12. Дуденков В.М. Универсальный алгоритм классификации образов на основе самоорганизующихся карт Кохонена и гибридных сетей // Кибернетика и высокие технологии XXI века (С&Т): материалы XVI Международ. науч.-техн. конф. – Воронеж, 2015. – С. 1-6.

ПРИЛОЖЕНИЕ А

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2015618275

DirectAndConvolutionNet 1.0

Правообладатель: *Федеральное государственное бюджетное образовательное учреждение высшего профессионального образования «Воронежский государственный университет» (RU)*

Автор: *Дуденков Владимир Михайлович (RU)*

Заявка № 2015613406

Дата поступления 23 апреля 2015 г.

Дата государственной регистрации

в Ресстре программ для ЭВМ 04 августа 2015 г.



*Врио руководителя Федеральной службы
по интеллектуальной собственности*

Л.Л. Кирий

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2015618276

FuzzyAndCohonenNet 1.0

Правообладатель: *Федеральное государственное бюджетное образовательное учреждение высшего профессионального образования «Воронежский государственный университет» (RU)*

Автор: *Дуденков Владимир Михайлович (RU)*

Заявка № 2015613405

Дата поступления 23 апреля 2015 г.

Дата государственной регистрации

в Реестре программы для ЭВМ 04 августа 2015 г.

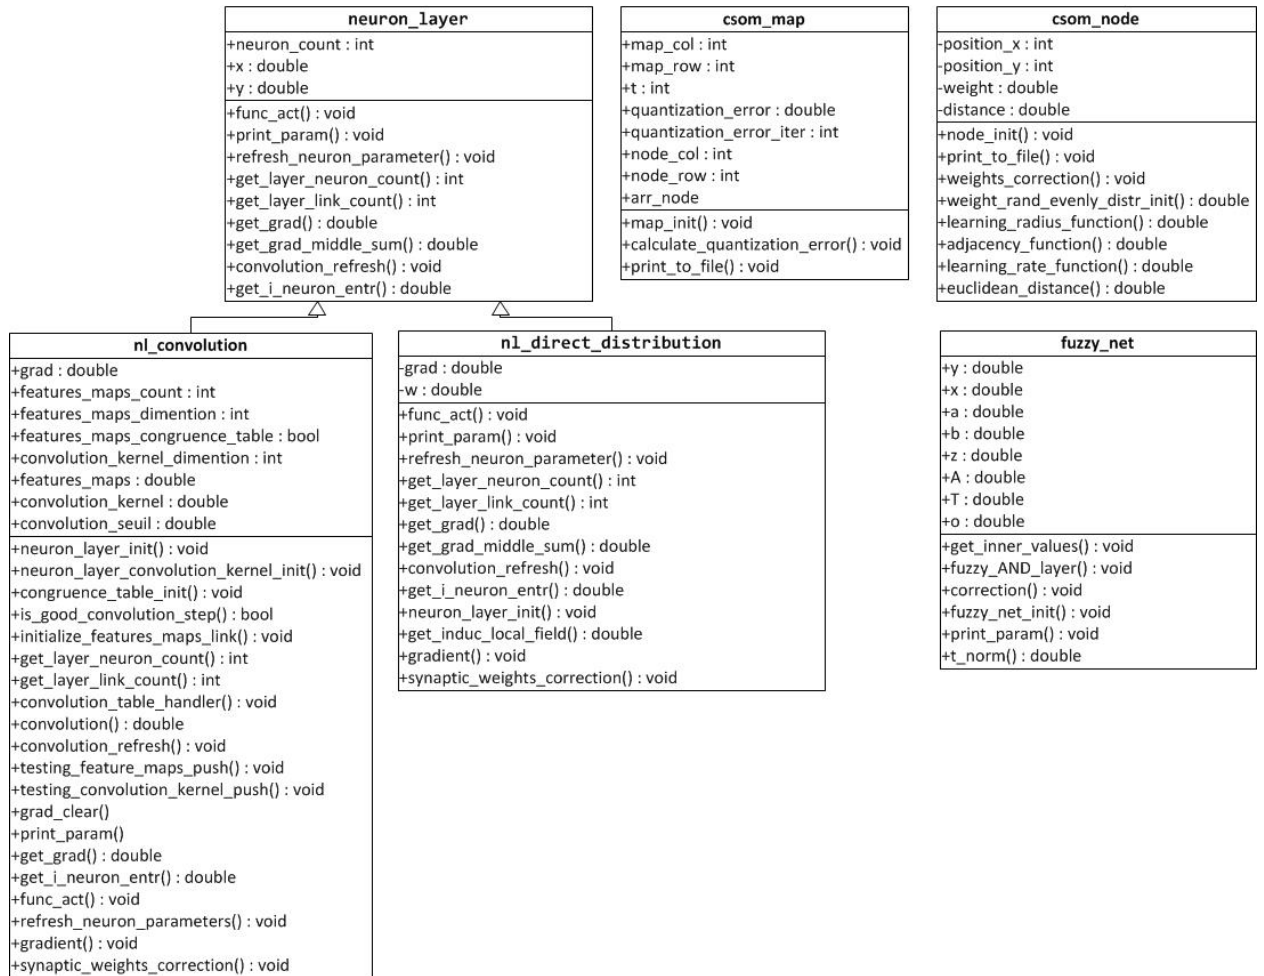


*Врио руководителя Федеральной службы
по интеллектуальной собственности*

Л.Л. Кирий

ПРИЛОЖЕНИЕ В

UML FuzzyAndCohonenNet 1.0 и DirectAndConvolutionNet 1.0



ПРИЛОЖЕНИЕ С

«УТВЕРЖДАЮ»
 Ректор Воронежского
 государственного университета
 Гиндицкий Д.А.
 2016 г.



АКТ

**о внедрении в учебный процесс
 ФГБОУ ВО «Воронежский государственный университет»
 научных разработок соискателя ученой степени
 кандидата физико-математических наук Дуденкова В.М.**

Наименование диссертации: «Разработка нейросетевых моделей
 человекомашинного общения».

Автор: Дуденков Владимир Михайлович.

Научный руководитель: д.т.н., проф. Новикова Нелля Михайловна.

Разработки выполнены в ФГБОУ ВО «Воронежский государственный университет», кафедрой Технической кибернетики и автоматического регулирования в рамках одного из основных научных направлений Воронежского государственного университета «Математическое моделирование, программное и информационное обеспечение, методы вычислительной и прикладной математики и их применение к фундаментальным исследованиям в естественных науках» в период с 1 сентября 2013 г. по 30 мая 2016 г., протокол № 7.

1. Вид результатов внедрения в учебный процесс: алгоритм и компьютерная модель нейросетевого распознавательного комплекса на

основе сегментации изображений, карт Кохонена, нечеткого гибридного классификатора, позволяющая распознавать изображения в условиях малого объема обучающей выборки.

2. Область применения: применяется в рамках основной образовательной программы обучения высшего профессионального образования направления 010400 «Прикладная математика и информатика» для дисциплин «Распознавание образов» для студентов 4 курса. Вид учебных занятий – лекции и лабораторные работы.
3. Форма внедрения: тема в курсе лекций и лабораторной работе.
4. Технический уровень (государственное или общественное признание): нет.
5. Основные публикации по теме диссертации:

Публикации в изданиях, рекомендованных ВАК РФ

1. Дуденков В.М. Распознавание изображений с помощью сверточной нейронной сети и нечеткого гибридного классификатора / Н.М. Новикова, В.М. Дуденков // Нейрокомпьютеры: разработка, применение – 2015. – №2. – С. 43-47.
2. Дуденков В.М. Нейросетевая модель работы человека-оператора в системе «человек-дисплей» / Н.М. Новикова, В.М. Дуденков // Научные ведомости БелГУ – 2015. №7(204) – С. 153-158.

Статьи и материалы конференций

3. Дуденков В.М. Оптимальный многослойный персептрон для классификации образов / Н.М. Новикова, В.М. Дуденков // Кибернетика и высокие технологии XXI века (С&Т): материалы XIII Международ. науч.-техн. конф. – Воронеж, 2012. Т.1. – С. 109-119.
4. Дуденков В.М. Нейросетевые и детерминированные алгоритмы распознавания образов / Н.М. Новикова, В.М. Дуденков // Кибернетика и высокие технологии XXI века (С&Т): материалы XIV Международ. науч.-техн. конф. – Воронеж, 2013. Т.1. – С. 298-304.

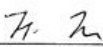
5. Дуденков В.М. Использование сверточной нейронной сети в задаче распознавания графических изображений / В.М. Дуденков // Информатизация процессов формирования открытых систем на основе САПР, АСНИ, СУБД и систем искусственного интеллекта: материалы седьмой Международ. науч.-техн. конф. – Вологда, 2013. – С. 77-80.
6. Дуденков В.М. Моделирование сверточных нейронных сетей / В.М. Дуденков // Понтрягинские чтения: материалы XXIV Воронежской весенней математической школы. – Воронеж, 2013. – С. 71-72.
7. Дуденков В.М. Анализ влияния примеров обучения на эффективность работы многослойного персептрона / В.М. Дуденков // Информатика: проблемы, методология, технологии: материалы XIV Международ. науч.-метод. конф. – Воронеж, 2014. – С. 51-53.
8. Дуденков В.М. Распознавание изображений с помощью самоорганизующихся карт Кохонена и сетей нечеткой логики / В.М. Дуденков // Современные методы математики, теории управления и компьютерных технологий: материалы VII Международ. науч. конф. – 2014. – С. 131-133.
9. Дуденков В.М. Моделирование нейронной сети для распознавания изображений на основе гибридной сети и самоорганизующихся карт Кохонена / Н.М. Новикова, В.М. Дуденков // Аспирант. – 2015. - №2 – С. 31-34.
10. Дуденков В.М. Универсальный алгоритм классификации образов на основе самоорганизующихся карт Кохонена и гибридных сетей // Кибернетика и высокие технологии XXI века (С&Т): материалы XVI Международ. науч.-техн. конф. – Воронеж, 2015. – С. 1-6.
11. Свидетельство о регистрации программы «DirectAndConvolutionNet 1.0» / Дуденков В.М. – М.: ФГУ ФИПС, 2014. Рег. № 2015618275 от 04.08.2015г.

12. Свидетельство о регистрации программы «FuzzyAndCohonenNet 1.0» /
Дуденков В.М. – М.: ФГУ ФИПС, 2014. Рег. № 2015618276 от
04.08.2015г.


6. Эффект от внедрения: повышение качества образования: повышение
качества знаний о моделировании классификаторов изображений на
основе гибридных нейронных сетей.

Научный руководитель

Д.т.н., профессор


 / Новикова Н.М./ __. __. 2016

Автор

 / Дуденков В.М./ __. __. 2016

Декан факультета ПММ

Д.т.н., профессор

 / Шашкин А.И./ __. __. 2016