МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ РФ ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ БЮДЖЕТНОЕ ОБРАЗОВАТЕЛЬНОЕ УЧРЕЖДЕНИЕ ВЫСШЕГО ОБРАЗОВАНИЯ «САМАРСКИЙ ГОСУДАРСТВЕННЫЙ ТЕХНИЧЕСКИЙ УНИВЕРСИТЕТ»

На правах рукописи

ГИРИН Роман Викторович

ИНТЕЛЛЕКТУАЛЬНАЯ ИНФОРМАЦИОННО-ИЗМЕРИТЕЛЬНАЯ СИСТЕМА ТЕПЛОВИЗИОННОГО ДИАГНОСТИРОВАНИЯ ТЕХНИЧЕСКИХ ОБЪЕКТОВ НА ОСНОВЕ НЕЙРОННОЙ СЕТИ

Специальность:

05.11.16 -

Информационно-измерительные и управляющие системы (технические системы)

Диссертация на соискание ученой степени

кандидата технических наук

Научный руководитель -

доктор технических наук,

профессор С.П. Орлов

Самара - 2019

СОДЕРЖАНИЕ

ВВЕДЕНИЕ	5
1 ИНТЕЛЛЕКТУАЛЬНЫЕ ИНФОРМАЦИОННО-ИЗМЕРИТЕЛЬНЫЕ СИСТЕМЫ И МЕТОДЫ ТЕПЛОВОГО КОНТРОЛЯ ТЕХНИЧЕСКОГО	
СОСТОЯНИЯ ОБЪЕКТОВ	14
1.1 Методы дистанционного теплового контроля технических объектов	14
 1.2 Использование модельных термограмм технических объектов при сравнительной инфракрасной термографии 	20
 Анализ существующих ИИС технической диагностики на основе инфракрасной термографии 	28
1.4 Нейросетевые технологии в интеллектуализации ИИС контроля и диагностирования	30
1.5 Применение ИНС для распознавания графических образов	34
 1.6 Методика интеллектуализации ИИС тепловизионного диагностирования (ИИС ТД) на основе нейронных сетей и модельных термограмм 	38
1.6.1 Проблемы технического диагностирования на основе сравнительной инфракрасной термографии	38
1.6.2 Метод интеллектуализации ИИС тепловизионного диагностирования с использованием нейронной сети	39
Выводы по главе 1	43
2 РАЗРАБОТКА АРХИТЕКТУРЫ ИНТЕЛЛЕКТУАЛЬНОЙ ИНФОРМАЦИОННО-ИЗМЕРИТЕЛЬНОЙ СИСТЕМЫ ТЕПЛОВИЗИОННОГО	
ДИАГНОСТИРОВАНИЯ	45
2.1 Общая структура интеллектуальной ИИС ТД	45
2.2 Задача классификации неисправностей в контролируемом объекте по	
термограммам	48
2.2.1 Классы модельных термограмм	48
2.2.2 Классифицирующий нейросетевой оператор	53
2.3 Нейросетевой программный анализатор	54
2.4 Процедуры обучения ДНС	59

2.4.1 Моделирование термограмм матрицы ПЗС	61
2.4.2 Моделирование термограмм печатных плат электронных приборов	63
2.5 Анализ данных для обучения ДНС	65
2.6 Анализ метрологических характеристик ИИИС ТД	74
2.6.1 Исследование факторов, влияющих на погрешности ИИИС ТД	75
2.6.2 Инструментальные погрешности каналов	75
2.6.3 Анализ методической погрешности ДНС в составе ИИИС ТД	82
Выводы по главе 2	92
З ПРОЕКТИРОВАНИЕ ПРОГРАММНОЙ РЕАЛИЗАЦИИ НЕЙРОННОЙ СЕТИ ДЛЯ ИНФОРМАЦИОННО-ИЗМЕРИТЕЛЬНОЙ СИСТЕМЫ ТЕПЛОВИЗИОННОГО ДИАГНОСТИРОВАНИЯ	94
3.1 Объектно-ориентированная декомпозиция логики искусственных	
нейронных сетей	94
3.1.1 Структурная и функциональная декомпозиция логики ИНС	96
3.1.2 Технология проектирования программного кода логики ИНС	99
3.2 Реализация логики ИНС. Шаблон проектирования доменных классов искусственных нейронных сетей	100
3.2.1 Шаблон «Проектировочный грид»	101
3.2.2 Структура шаблона «Проектировочный грид»	102
3.2.3 Применение шаблона «Проектировочный грид» для классов нейронных слоев ИНС	105
3.2.4 Шаблон «Проектировочный грид» для нейронной сети с композитными	
слоями	111
3.2.5 Процедура формирования шаблона «Проектировочный грид»	113
3.2.6 Практическая реализация шаблона	114
3.3 Функции активации и двухстадийная нормализация выходных сигналов ИНС	117
3.3.1 Двухстадийная нормализация	117
3.3.2 Нормализация по диапазону в искусственных нейронных сетях	121
3.3.3 Построение нейронной сети с двухстадийной нормализацией в качестве	
функции активации	124

3.3.4 Результаты экспериментов с нейронными сетями с двухстадийной	
нормализацией	126
Выводы по главе 3	128
4 ЭКСПЕРИМЕНТАЛЬНЫЕ ИССЛЕДОВАНИЯ МЕТОДА	
ИНТЕЛЛЕКТУАЛИЗАЦИИ В ИИС ТД	129
4.1 Области использования результатов диссертационного исследования	129
4.2 Практическое использование метода интеллектуализации в ИИС	120
	101
4.2.1 Модернизация ИИС контроля ФМ ПЗС	131
4.2.2 Контроль контактной сети железной дороги	132
4.2.3 Контроль рельсового пути железной дороги	135
4.2.3 Диагностика агрегатов и систем управления беспилотного автомобиля КАМАЗ	140
4.3 Исследование точности классификации для различных структур и конфигураций нейронной сети	142
4.3.1 Общие характеристики нейронных сетей, использованных в ИИИС ТД	142
4.3.2 Сравнение показателей точности различных конфигураций	
конволюционных нейронных сетей	145
Выводы по главе 4	146
ЗАКЛЮЧЕНИЕ	148
БИБЛИОГРАФИЧЕСКИЙ СПИСОК	150
СПИСОК СОКРАЩЕНИЙ И УСЛОВНЫХ ОБОЗНАЧЕНИЙ	166
ПРИЛОЖЕНИЕ А ДОКУМЕНТЫ О ВНЕДРЕНИИ РЕЗУЛЬТАТОВ ЛИССЕРТАЦИОННОГО ИССЛЕДОВАНИЯ	167
	107

введение

Актуальность темы исследования

Современное развитие техники сопровождается возрастающими требованиями к надежности функционирования сложных объектов и систем. Выполнение этих требований обеспечивается с помощью контроля и технического диагностирования. Важным фактором эффективности процессов контроля и диагностирования является использование информационно-измерительных систем (ИИС) для обработки данных и автоматизации процессов контроля. Одним из направлений технического диагностирования является использование инфракрасной термографии для бесконтактного и дистанционного получения информации о состоянии объекта. При этом необходимо анализировать сложные тепловые образы технических состояний, обеспечивать высокую точность измерения термограмм и диагностических параметров, принимать решения о техническом обслуживании контролируемого объекта.

Степень разработанности темы исследования

Теоретическую основу выполненных в диссертации исследований составили основополагающие труды по теории информационно-измерительных систем таких ученых, как П.П. Орнатский, А.И. Мартяшин, О.П. Новоселов, Ф.Е. Темников, М.П. Цапенко, Цветков Э.И., В.М. Шляндин и др. [59, 81, 82, 84].

Использованию методов и систем контроля и технической диагностики посвящены работы И.А. Биргера., В.П. Вавилова, Д.В. Гаскарова, Н.С. Данилина, В.В. Клюева, П.П. Пархоменко, Р. Хадсона и др. [9, 12, 16, 34, 62, 79].

В области контроля радиоэлектронной аппаратуры и исследования их тепловых режимов существует большое число исследований и публикаций, среди которых выделяются работы Г.Н. Дульнева, Г.М. Кондратьева, Ю.Н. Кофанова, А.В. Светлова, А.В. Сигалова, С.У. Увайсова, А.С. Шалумова, Н.К. Юркова и др. [37, 46, 47, 67, 76, 77].

На современном этапе при построении интеллектуальных информационных систем все больше находят применение искусственные нейронные сети, что нашло отражение в работах отечественных и зарубежных ученых А.Ю. Дорогова, А.И. Иванова, Л.Г. Комарцовой, З.М. Селивановой, Н.Г. Ярушкиной, Г.Э. Яхъяевой, I. Goodfellow, S. Haykin, A. Krizhevsky, Y. LeCun, M. Nielsen, P. Norvig, S. Rassel и др. [35, 39, 45, 68- 70, 87, 88, 100, 104, 107, 115].

При разработке ИИС используются унифицированные системы теплофизического проектирования, такие как Ansys Icepak, FloTherm, Analog Workbench, Komnac-3D, Betasoft, COLDPLATE, COSMOS, Microwave Office, MSC Nastran, PRAC, ACOHИKA-TM и др. Однако они ориентированы на проведение тепловых расчетов приборов на этапе проектирования и экспериментальных исследований образцов систем и не могут быть использованы при штатной эксплуатации приборов для их технического диагностирования.

Несмотря на значительные достижения в создании систем технического диагностирования по тепловому состоянию объектов, существует необходимость в развитии методов, моделей и алгоритмов использования нейронных сетей в информационно-измерительных системах для повышения точности классификации отказов, автоматизации процесса контроля, поддержки принятия решений об эксплуатации объектов.

Основная задача, решению которой посвящено диссертационное исследование – это необходимость оперативного и достоверного определение технического состояния с использованием методов тепловизионного диагностирования при затрудненном доступе к контролируемому объекту для выявления неработоспособных и аварийных состояний, дефектов и отказов при испытаниях и штатной эксплуатации.

6

В связи с этим разработка новых интеллектуальных информационноизмерительных систем тепловизионного диагностирования (ИИИС ТД) является актуальной задачей.

Цель диссертационной работы - повышение точности и сокращение времени контроля при тепловизионном диагностировании технических объектов на основе разработки интеллектуальной информационно-измерительной системы с использованием глубоких нейронных сетей.

Для достижения поставленной цели поставлены и решены следующие основные задачи.

1. Провести анализ существующих информационно-измерительных систем тепловизионного контроля и диагностирования, выявить факторы, влияющие на их эффективность и метрологические характеристики.

2. Построить модели тепловых состояний контролируемых объектов для тепловизионного диагностирования на основе сравнительной инфракрасной термографии.

3. Разработать метод интеллектуализации информационно-измерительных систем и выбрать наиболее подходящие нейросетевые модели для определения работоспособности объектов с помощью сравнительной инфракрасной термографии.

4. Разработать архитектуру и общую структурную схему интеллектуальной информационно-измерительной системы теплового диагностирования с нейронной сетью в ее составе.

5. Выполнить анализ метрологических характеристик измерительных каналов ИИС диагностирования с нейронной сетью и оценить качество обучения нейронной сети.

6. Разработать методику анализа и проектирования программной логики, реализующей искусственную нейронную сеть, для последующего построения нейронных сетей различных конфигураций с заданными свойствами и характеристиками в составе ИИС диагностирования.

7. Провести экспериментальные исследования применения нейросетевых технологий в составе ИИС контроля и диагностики.

Объект исследования – информационно-измерительные системы тепловизионного диагностирования технических объектов с использованием искусственных нейронных сетей.

Предметом исследования являются структуры информационноизмерительных систем, модели и алгоритмы термографического контроля состояний технических объектов, а также их программная реализация.

Научная новизна диссертационной работы

1. Разработан интеллектуальный метод классификации технических состояний объекта с использованием информационно-измерительных систем тепловизионного диагностирования, *отличающийся* применением сравнительной инфракрасной термографии, формированием базы данных комплексных модельных термограмм, а также нейросетевого программного анализатора, обучающегося на комплексных модельных термограммах, *что позволило* повысить точность классификации отказов и автоматизировать принятие решений по техническому обслуживанию объекта контроля.

2. Предложен нейросетевой программный анализатор термограмм и дополнительных параметров объекта, *отличающийся* введением двухветвенной глубокой нейронной сети, состоящей из многослойной конволюционной сети и полносвязной сети, *что обеспечило* повышение достоверности классификации отказов и уменьшение времени анализа термограмм.

3. Предложена функция активации выходного слоя нейросетевого программного анализатора термограмм, *отличающаяся* последовательным применением норма-

8

лизации по диапазону и линейной нормализации, *что обеспечило* повышение точности и информативности классификации распознаваемых состояний контролируемого объекта.

4. Разработана методика объектно-ориентированного проектирования программной логики искусственных нейронных сетей для анализа термограмм, *отличающаяся* набором формальных правил декомпозиции программной логики сети и использованием предложенного шаблона, основанного на решеточной структуре взаимосвязей абстрактных доменных классов и программных интерфейсов нейронной сети, *что сократило время* разработки информационно-измерительной системы тепловизионного диагностирования.

Теоретическая и практическая значимость работы

Значимость теоретических результатов работы заключается в том, что предложенные метод интеллектуализации системы и методика проектирования нейронных сетей позволяют формализовать процесс проектирования информационноизмерительных систем для диагностирования неисправностей широкого класса объектов с использованием сравнительной инфракрасной термографии.

Практическая значимость работы состоит в следующем:

1. Интеллектуальная ИИС тепловизионного диагностирования применима при контроле, испытаниях и мониторинге состояний технических объектов различного вида: электронных приборов, электромеханических устройств, машин и механизмов. Оперативность определения технического состояния позволяет осуществлять контроль состояния в реальном времени в труднодоступных местах, в том числе для движущихся объектов.

2. Реализована программная библиотека на платформе CLR на языке C# для построения и обучения искусственных нейронных сетей, которая независима от других программных библиотек и может применяться для проектирования интел-

лектуальных информационных и управляющих систем на вычислительных мощностях с ограниченными ресурсами.

Методы исследования

Для решения поставленных задач использовались методы математического анализа, теории тепло- и массообмена, теории искусственного интеллекта, машинного обучения, теории измерительных систем, объектно-ориентированного проектирования.

Основные положения и результаты, выносимые на защиту

1. Интеллектуальный метод повышения точности классификации неисправностей в объекте с использованием информационно-измерительных систем тепловизионного диагностирования, основанный на применении сравнительной инфракрасной термографии, нейросетевого программного анализатора и базы данных, содержащей комплексные модельные термограммы.

2. Нейросетевой программный анализатор термограмм и дополнительных параметров объекта на основе двухветвенной нейронной сети, состоящей из глубокой конволюционной сети и полносвязной сети.

3. Функция активации выходного слоя нейросетевого программного анализатора термограмм, реализованная последовательным применением нормализации по диапазону и линейной нормализации.

4. Методика и шаблон проектирования программной логики искусственной нейронной сети для анализа термограмм, содержащие набор формальных правил декомпозиции программной логики сети и решеточную структуру взаимосвязей абстрактных доменных классов и программных интерфейсов нейронной сети.

Соответствие паспорту специальности

Результаты исследования соответствуют пунктам паспорта специальности 05.11.16 –Информационно-измерительные и управляющие системы (технические системы): п. 5 «Методы анализа технического состояния, диагностики и идентификации информационно-измерительных и управляющих систем, п. 6 «Исследование возможностей и путей совершенствования существующих и создания новых элементов, частей, образцов информационно - измерительных и управляющих систем, улучшение их технических, эксплуатационных, экономических и эргономических характеристик, разработка новых принципов построения и технических решений».

Достоверность результатов исследования

Достоверность обеспечивается корректным использованием математического аппарата и вводимых допущений и гипотез, имитационным моделированием и экспериментальными исследованиями разработанных ИИС, подтверждающими основные теоретические положения работы и не противоречащими известным положениям в данной области исследований.

Апробация результатов

Основные положения и результаты исследований докладывались на следующих научно-технических конференциях: XXI Международной конференции по мягким вычислениям и измерениям (SCM'2018), (г. Санкт-Петербург, 2018 г.); IV международной научно-технической конференции «Пром-Инжиниринг - 2018 (ICIE 2018)», (Москва, 2018 г.); Международной научно-технической конференции «Перспективные информационные технологии ПИТ- 2018», (г. Самара, 2018 г.); XI Международной научно-практической конференции «Наука и образование транспорту», (г. Самара, 2018 г.); II Международной научно-практической конференции

«Нечеткие Промышленные системы мягкие вычисления. применения. И Fuzzy Technologies in the Industry (FTI 2018)», (г. Ульяновск, 2018 г.): 4th International Conference on Intelligent Computing, Communication & Devices (ICCD2018), (Guangzhou, China, 2018 г.).

Внедрение

Диссертационная работа выполнялась в рамках Федеральной целевой программы: соглашение № 14.577.21.0187 «Разработка интеллектуального аппаратнопрограммного комплекса мониторинга протяжённых объектов в режиме реального времени», а также соглашение № 075-02-2018-225 «Разработка роботизированной системы сельскохозяйственных автомобилей на базе семейства автомобилей КА-МАЗ с автономным и дистанционным режимом управления».

Результаты диссертационной работы также использованы в АО НПЦ «ИН-ФОТРАНС», г. Самара, в системах термографического контроля контактной сети и диагностики рельсовых скреплений железной дороги.

Материалы диссертации использованы в учебном процессе ФГБОУ ВО «Самарский государственный технический университет» при подготовке магистров по направлениям 09.04.01 - «Информатика и вычислительная техника» и 12.04.01 -«Приборостроение».

Публикации

По результатам выполненных исследований опубликовано 12 работ, из них: 3 публикации в журналах, рекомендованных ВАК РФ, одна работа в трудах международной конференции, индексирующейся в Scopus, 2 свидетельства о регистрации программ для ЭВМ.

Личный вклад автора

Все результаты, определяющие научную новизну, получены автором лично. В публикациях, выполненных в соавторстве, лично автору принадлежат следующие результаты: разработка методики анализа и проектирования нейросетевого программного анализатора, а также его программная реализация, разработка метода интеллектуализации ИИС, разработка структуры ИИС ТД и исследование метрологических характеристик, исследование функций активации нейронных сетей.

Структура диссертации

Диссертация изложена на 172 страницах, состоит из введения, 4 глав, заключения, списка литературы из 134 наименований, содержит 45 рисунков, 18 таблиц и одно приложение.

1 ИНТЕЛЛЕКТУАЛЬНЫЕ ИНФОРМАЦИОННО-ИЗМЕРИТЕЛЬНЫЕ СИСТЕМЫ И МЕТОДЫ ТЕПЛОВОГО КОНТРОЛЯ ТЕХНИЧЕСКОГО СОСТОЯНИЯ ОБЪЕКТОВ

1.1 Методы дистанционного теплового контроля технических объектов

Методы теплового контроля представляют собой совокупность средств, методик и алгоритмов, позволяющих получить информацию о параметрах изделия на основе регистрации температуры в отдельных точках, теплового поля поверхности или теплового контраста диагностируемого объекта при его функционировании [12, 13, 43].

Анализ полученной информации позволяет сделать вывод о том, что характер изменения интенсивности теплового поля свидетельствует об изменении режима работы объекта. Тепловой метод контроля для диагностики электронновычислительных блоков впервые был применен компанией IBM в 1983 году при разработке источников питания [94].

Интенсивность теплового излучения радиоэлектронных приборов зависит от параметров конструкции и материалов, и от возможного наличия дефектов в них. Наличие дефектов является причиной интегрального или локального искажения температурного поля. Это выражается в появлении температурных перепадов. Пространственно-временное описание этих перепадов определяется потребляемой электрической мощностью, распределением тепловыделяющих элементов в объекте, условиями его теплообмена с окружающей средой, теплофизическими и геометрическими характеристиками и особенностями дефектов, а также временем тепловых переходных процессов в нестационарном режиме. Изменение характеристик отдельных участков объекта контроля приводит к изменению его общих температурных характеристик. Преимуществами теплового метода неразрушающего контроля относительно других методов диагностики являются:

 оперативное получение информации о температурном состоянии поверхности микросхемы;

 эффективность обнаружения скрытых дефектов, возникших на предыдущих этапах технологического процесса изготовления и проявившихся при внедрении или в процессе эксплуатации;

 минимальное влияние системы теплового контроля на диагностируемый объект.

Все тепловые методы неразрушающего контроля делятся на пассивные и активные. При использовании пассивных методов объект контроля нагревается за счет внутренних тепловых процессов, то есть для получения картины распределения температуры не требуется дополнительных источников тепла. Активные методы теплового контроля предусматривают использование дополнительного источника энергии и предназначены для выявления пассивных дефектов, то есть не выделяющих тепла при протекании через них электрического тока.

На рисунке 1.1 представлена классификация методов теплового контроля.

Во многих публикациях методы контроля по характеру взаимодействия с объектом делятся на [7, 13, 34]:

- контактные,

- неконтактные.

В настоящее время наиболее широкое применение получили бесконтактные тепловые методы неразрушающего контроля по собственному излучению объекта с визуализацией температурных полей [7, 8, 42, 60, 76, 86,108, 110, 119, 120].

Часто задача бесконтактной термометрии решается путем применения ИК радиометров, измеряющих интенсивность собственного теплового излучения объектов в широком диапазоне длин волн. Другим направлением является получение изображения температурного поля объекта в инфракрасном диапазоне и его последующая обработка.

В диссертационной работе область исследований связана с методами тепловизионного диагностирования, относящихся к инфракрасной (ИК) термографии.



Рисунок 1.1 – Классификация методов теплового контроля

На рисунке 1.1 показан ряд методов ИК термографии, в которых реализуется общая процедура, заключающаяся в измерении термограммы объекта и последующем сравнении с некоей эталонной термограммой. На основе этого сравнения принимается решение о техническом состоянии исследуемого объекта. Рисунок 1.2 демонстрирует схему сравнительной инфракрасной термографии.



Эталонная термограмма

Рисунок 1.2 – Сравнительная инфракрасная термография

Использование тепловизора, как основного инструмента измерения температуры объекта, относит эти методы к тепловизионному диагностированию. Одно из главных преимуществ тепловизора – дистанционное измерение температурного поля и формирование соответствующего изображения. В настоящее время существуют тепловизоры в миниатюрном исполнении. Это дает возможность встраивать их в конструктив контролируемого объекта.

Характеристика тепловизионных методов приведена в таблице 1.1 [12].

Название метода	Содержание
ИК термографии (ИКТ)	
Фототермическая ИКТ	Нагрев значительного участка объекта контроля и ис-
	пользование тепловизора вместо ИК радиометра
Импульсная	Равномерный импульсный нагрев больших зон и изме-
видеотермография	рение термограмм тепловизором
Термография при	Поток излучения от распределенного нагревателя про-
вынужденной диффузии	ецируется на объект контроля через щелевую маску, при
тепла	этом объект перемещают в поле зрения тепловизора
Синхронная	Объект подвергается воздействию ультразвуковыми
УЗ - термография	волнами, что изменяет температуру его участков
Вибротермография	Применяется вибрационная стимуляция контролируе-
	мого объекта
Теплоголография	Совместная регистрация термограмм и голографических
	интерферограмм объекта при нагреве
Электромагнитная ИКТ	На фототепловой мишени, расположенной вблизи объ-
	екта контроля, происходит наложение прямого и отра-
	женного СВЧ излучения. Тепловизор регистрирует тем-
	пературное поле мишени.
Тепловая томография	Послойное томографическое представление структуры
	объекта путем анализа температурных сигналов
Термоупругие	Обнаружение скрытых дефектов путем возбуждения в
испытания	объекте механических напряжений, сопровождающихся
	изменением температуры тела
Двухканальная	Совместное применение коротковолнового и длинно-
термография	волнового канала, в результате возможно разделение
	информации о температуре и коэффициенте излучения
Вихретоковая ИКТ	Активный нагрев металлических объектов токами высо-
*	кой частоты
Раман - ИКТ	Использование рамановского или комбинационного
	рассеивания падающего на тело света [108, 125]

Таблица 1.1 -	Тепловизионные м	етоды контроля
---------------	------------------	----------------

Для регистрации тепловой картины на практике наиболее часто применяется тепловизоры с матрицами в фокальной плоскости. Сигнал пропорционален интенсивности теплового излучения.

Преимуществами тепловизионного метода являются:

 высокая информативность (получение тепловой картины со всей поверхности диагностируемого объекта);

оперативность получения информации;

 дистанционность (позволяет использовать метод для измерения температуры с поверхности элемента, для которого физический контакт с контрольным датчиком недопустим);

 позволяет получать информацию об элементе различных размеров и мощности во время его работы в условиях, близких к рабочим.

В настоящее время тепловизоры являются оптимальным инструментом неразрушающего теплового контроля в различных отраслях промышленности. Основные сферы применения промышленных тепловизоров - это тепловой аудит объектов строительства, поиск неисправности электросетей, мониторинг производственных процессов и другие случаи, когда по неоднородности теплового поля можно судить о техническом состоянии контролируемых объектов [78].

В строительстве одним из основных направлений теплового контроля является общий энергоаудит зданий и сооружений с целью оптимизации расходов на энергию. Проведение инспекции здания с последующим анализом его особенностей и данных о расходе энергии позволяет определять оптимальные способы снижения энергопотерь.

В промышленном производстве основной целью теплового неразрушающего контроля является обнаружение дефектов оборудования на их ранней стадии. Аномальный нагрев механических компонентов, часто может указывать на чрезмерную нагрузку и риск выхода системы из строя. Среди наиболее распространенных направлений теплового контроля можно выделить превентивную диагностику промышленного оборудования, контроль заполнения резервуаров. К типовым объектам тепловизионного контроля в промышленном производстве можно отнести станки,

19

конвейеры, турбины, компрессоры, насосы, генераторы, ДВС, системы нагрева и охлаждения, различное гидравлическое оборудование.

В работе предприятий энергетического сектора, основными направлениями теплового контроля является поиск перегретых участков электросетей, дымовых труб, паровых и водогрейных котлов. Тепловизоры также часто применяются для поиска неисправностей в теплоизоляции трубопроводов и турбин, определения мест подсоса холодного воздуха, для проверки эффективности работы систем охлаждения трансформаторов, двигателей, линий электропередач и другого оборудования.

В нефтегазовом комплексе тепловизоры нашли свое применение при контроле наполняемости резервуаров, позволяя дистанционно определять температуру и уровень жидкости, делая этот процесс максимально быстрым и безопасным (при отказе систем автоматического оповещения).

В сфере электроники и электротехники тепловизоры позволяют оценить уровень нагрева в системах низкого, среднего и высокого напряжения. Полученные термограммы дают возможность своевременно обнаружить неисправные компоненты и предпринять меры по их ремонту.

1.2 Использование модельных термограмм технических объектов при сравнительной инфракрасной термографии

Контроль электронных приборов по термограммам их поверхности - перспективная область развития бесконтактной диагностики [34, 37, 41, 46, 47, 76, 78]. Типовая процедура контроля электронных элементов приведена на рисунке 1.3.

В процессе испытаний и эксплуатации с помощью тепловизора непрерывно измеряется температурное поле на поверхности прибора, которое показывает места и степень ненормативного разогрева прибора.

Важным аспектом обработки получаемых термограмм является их интерпретация. В процессе интерпретации измеренных термограмм выполняется их сопоставление с набором модельных термограмм [5]. Каждая модельная термограмма представляет собой наиболее характерную картину распределения температуры, соответствующую тому или иному состоянию контролируемого прибора. Сравнение термограммы, полученной с контролируемого прибора, и наиболее близкой к ней модельной термограммы, позволяет осуществить диагностирование технического состояния контролируемого прибора.





Следовательно, для точности диагностирования процесс построения модельных термограмм важен не менее, чем точность измерения реальной термограммы контролируемого прибора.

Наибольшее распространение получили два подхода к построению математических моделей тепловых режимов.

1. Представление элементов и кассет приборов, печатных плат в виде тел с изотермической поверхностью (рисунок 1.4,а). Метод изотермических поверхностей основан на выявлении в конструкции поверхностей элементов с одинаковыми или условно одинаковыми температурами в каждой точке поверхности (рисунки 1.4, б и

1.4,в). Это позволяет оперативно определить отказ элемента или значительное нарушение номинального режима работы по увеличению или уменьшению средней температуры элемента.

В тоже время усреднение температуры снижает способность системы обнаруживать начальные отклонения от штатного режима функционирования, которые в дальнейшем могут вести к потере работоспособности элемента. Также затруднено определение конкретной цепи в элементе, работающей не в номинальном режиме.



Рисунок 1.4 - Модели с изотермическими поверхностями электронных приборов

Расчет таких моделей может быть выполнен в системах АСОНИКА-Т и АСО-НИКА-ТМ, в состав которой входят программные модули, позволяющие синтезировать модели тепловых процессов по геометрической модели конструкции. На рисунке 1.5 показан пример рассчитанных цветовых карт величины и градиента температуры в описанной системе [4, 73].



Рисунок 1.5 - Температурное поле на поверхности прибора, рассчитанное в системе АСОНИКА - ТМ

2. Второй подход заключается в построении математической модели температурного режима элемента на основе решения нестационарного уравнения теплопроводности. Рассмотрим применение такой модели к описанию теплового поля большой интегральной микросхемы, рассматриваемой как однородное тело [64]. Теплофизическая модель элемента системы управления представляет собой твердое тело в виде параллелепипеда (рисунок 1.6).



1 – кристалл микросхемы , 2 - керамическая подложка , 3 – золотые контактные площадки

Рисунок 1.6 – Модель полупроводникового прибора

Трехмерное нестационарное уравнение теплопроводности учитывает ряд ограничений, характерных для множества конструкций и, в том числе, электронных элементов [6]:

$$\rho c \frac{\partial \Theta(x, y, z, t)}{\partial t} = \lambda \left(\frac{\partial^2 \Theta(x, y, z, t)}{\partial x^2} + \frac{\partial^2 \Theta(x, y, z, t)}{\partial y^2} + \frac{\partial^2 \Theta(x, y, z, t)}{\partial z^2} \right) + q(x, y, z, t),$$

где λ – теплопроводность материала, [Вт/м·К];

 Θ – температура в точке с координатами (*x*,*y*,*z*), [K];

q(x,y,z,t) – удельная мощность источника тепла в точке (x,y,z) и момент времени *t*, [Bt/m³];

 ρ – плотность материала, [кг/м³];

с – удельная теплоемкость, [Дж/кг·К];

х, *у*, *z* – декартовы координаты, [м];

t – время, [c].

Однако решение этого уравнения связано с рядом трудностей. Анализ экспериментов, проведенных с различными радиоэлектронными элементами, позволил сделать ряд допущений, в результате чего был выполнен переход к двухмерному уравнению температурного поля:

$$\rho c \frac{\partial \Theta(x, y, t)}{\partial t} = \lambda \left(\frac{\partial^2 \Theta(x, y, t)}{\partial x^2} + \frac{\partial^2 \Theta(x, y, t)}{\partial y^2} \right) + q(x, y, t), \tag{1.1}$$

где λ – теплопроводность материала, [Вт/м·К];

 Θ – температура в точке с координатами (*x*,*y*,*z*), [K];

q(x,y,t) – удельная мощность источника тепла в точке (*x*,*y*,) и момент времени *t*, [Bт/м³];

 ρ – плотность материала, [кг/м³];

с – удельная теплоемкость, [Дж/кг·К];

х, *у* – декартовы координаты, [м];

t – время, [c].

Полное описание теплового процесса получается при дополнении уравнения (1.1) начальными и граничными условиями.

Временные и геометрические условия, в которых лежит область решения уравнения:

$$t \in [0; t_{\text{max}}], x \in [0; a], y \in [0; b].$$

Временные (начальные) условия содержат распределение температуры в теле в начальный момент времени. В общем виде условие имеет вид:

$$t = 0; \ \Theta_{\omega} = f(x, y). \tag{1.2}$$

При равномерном распределении температуры по поверхности ω прибора начальное условие упрощается и имеет вид:

$$t = 0; \ \Theta_{\omega} = \text{const.}$$
 (1.3)

Граничные условия определяют особенности протекания процесса на поверхности тела и могут быть заданы несколькими способами.

При описании граничных условий первого рода задается распределение температуры на поверхности прибора для каждого момента времени:

$$\Theta = \Theta_{\omega}(x, y, t), \tag{1.4}$$

где Θ_{ω} – температура на поверхности тела.

При задании граничных условий второго рода задается значение теплового потока для каждой точки поверхности прибора в любой момент времени (закон Фурье):

$$-\lambda \left(\frac{\partial \Theta}{\partial n}\right)_{\omega} = q_{\omega}(x, y, t), \qquad (1.5)$$

где *n* – нормаль к поверхности ω тела;

 q_{ω} – тепловой поток, [Bт/м³];

В нашем случае экспериментальные данные подтверждают, что возможно сделать допущение о том, это значение постоянно. При задании граничных условий третьего рода задается взаимосвязь между потоком тепла за счет теплопроводности от твердой стенки и тепловым потоком из окружающей среды за счет температурного напора и тепловым потоком в виде излучения с поверхности ω:

$$-\lambda \left(\frac{\partial \Theta}{\partial n}\right)_{\omega} = \alpha (\Theta_{\omega} - \Theta_{oc}) + \varepsilon_r \sigma (\Theta^4 - \Theta_{oc}^4), \qquad (1.6)$$

где α – коэффициент конвективного теплообмена, [Bt/(м³ K)];

 Θ_{oc} – температура окружающей среды;

 ε_r - коэффициент теплового излучения поверхности ω ;

 $\sigma\,$ - постоянная Стефана – Больцмана, равная 5,67 $^{\cdot}10^{\cdot8}\,[Bt/m^2 \cdot K^4]$

При задании граничных условий для определения теплового потока взаимодействия между элементами, имеющими различных теплофизические характеристики, задают условия равенства температур и тепловых потоков по обе стороны от границы раздела:

$$\begin{cases} -\lambda_{1} \left(\frac{\partial \Theta_{1}}{\partial n} \right)_{\Gamma=0} = -\lambda_{2} \left(\frac{\partial \Theta_{2}}{\partial n} \right)_{\Gamma=0}; \\ \Theta_{1}(x_{\Gamma=0}, y_{\Gamma=0}, t) = \Theta_{2}(x_{\Gamma=0}, y_{\Gamma=0}, t), \end{cases}$$
(1.7)

где *x*_Г, *y*_Г – координаты границы раздела сред;

 Θ_1, Θ_2 – температуры соприкасающихся сред.

Это условие применяется, например, при решении задач теплопроводности для многослойных тел. Однако в случае учета процесса теплоизлучения контролируемым прибором это условие применяться не будет, и возможно сделать допущение, что прибор не имеет внутри подобных границ раздела.

Уравнение теплопроводности (1.1) в совокупности с вышеперечисленными условиями (1.2) – (1.7) дает полную математическую формулировку задачи теплопроводности. Для расчета температурного поля, формируемого под действием электрического тока, приняты следующие допущения:

а) теплофизические свойства материалов остаются постоянными, что обусловлено слабой зависимостью этих параметров от температуры и малым изменением температурного диапазона при штатной работе микросхемы;

б) теплопроводность для всех материалов, входящих в состав микросхемы, изотропна;

в) теплообмен во всем внутреннем объеме конструкции прибора производится только за счет теплопроводности.

В связи с тем, что в постановке задачи (1.1) – (1.7) присутствует нелинейное ограничение (1.6) решение уравнения осуществляется методом конечных разностей с применением схемы расщепления по координатам. Затем полученные одномерные разностные уравнения решаются с помощью построения итерационного цикла, при этом на каждом шаге итерации линейная система уравнений решается методом прогонки с использованием неявной разностной схемы аппроксимации.

Решение уравнения с соответствующими ограничениями позволяет построить расчетное двумерное температурное поле поверхности элемента. Будем называть такое распределение модельной термограммой.

При задании условий, соответствующих различным видам дефектов, появляется возможность получить множество двумерных температурных полей, которые затем используются в процедуре контроля и обнаружения неисправностей. Такое множество модельных термограмм в данной диссертации в дальнейшем используется для обучения нейросетевых компонентов интеллектуальной ИИС.

1.3 Анализ существующих ИИС технической диагностики на основе инфракрасной термографии

В настоящее время существует ряд информационно-измерительных и управляющих систем, предназначенных для испытаний и входного контроля радиоэлектронных компонентов и приборов [16, 41, 42, 67, 70].

Новым направлением является использование инфракрасной термографии для теплового контроля технических состояний таких изделий.

ИИС тепловизионного диагностирования в общем случае включает измерительный канал для получения температурного поля объекта. Он содержит тепловизор, блок обработки термограмм и блок анализа данных, в котором выполняется принятие решение о том, является ли контролируемый блок в исправном состоянии или в нем присутствуют неисправности.

Известна информационно-измерительная система для дистанционного тепловизионного контроля микросхемы фоточувствительной матрицы на приборах с зарядовой связью (ФМ ПЗС). На рисунке 1.7 приведена структура этой ИИС, измерительный канал которой состоит из следующих компонентов [6, 117]:

• Определение параметров окружающей среды выполняется с помощью Termohigrometer Poly MI 6401;

• Измерение температурного поля поверхности основано на применении тепловизора NEC R500;

• Измерение электрических параметров контролируемого прибора осуществляется с помощью цифрового осциллоскопа GDS-2104.

Контроль над режимами устройств выполняется с помощью компьютера и SPS-3610 и FPGA XC3S500E.

Главная идея основана на математической модели, описывающей множество состояний и возможных картин распределения температуры в устройстве, которым соответствуют дефекты и отказы. Классы различных дефектов разграничивают эти

множества. Решение о техническом состоянии контролируемого электронного устройства принимается оператором-термографистом на основе сопоставления фактически регистрируемой термограммы с расчетной термограммой, полученной с использованием математической модели.

Однако осталась не проработанной конкретная реализация компонента ИИС, выполняющего сопоставление фактически регистрируемой термограммы с модельной термограммой для принятия решения о техническом состоянии контролируемого объекта. Процесс классификации технических состояний выполнялся оператором-термографистом. Даже имея высокую квалификацию, он допускал ошибки при принятии решений. Кроме того, процесс диагностирования не был автоматизирован, что обусловило применение данной ИИС только в заводских испытаниях. Тем не менее, эта система является наиболее близкой и выбрана в качестве прототипа для разработки интеллектуальной ИИС и исследований, проводимых в настоящей диссертации.



Рисунок 1.7 - Структура информационно-измерительной системы тепловизионного контроля фоточувствительной матрицы ФМ ПЗС

Для устранения выше указанных недостатков в разрабатываемой ИИС тепловизионного диагностирования необходимо провести интеллектуализацию системы, так как этот подход является в настоящее время наиболее перспективным при повышении качества диагностирования и автоматизации процесса контроля.

1.4 Нейросетевые технологии в интеллектуализации ИИС контроля и диагностирования

Интеллектуализация информационно-измерительных систем - активно развивающееся направление совершенствования подобных систем. В настоящее время существует большое количество разных способов интеллектуализации систем, поэтому важным аспектом является систематизация подобных подходов. Одним из перспективных направлений в интеллектуализации при контроле плохо формализуемых объектов и в условиях неопределенности является разработка ИИС с использованием баз знаний и аппарата нечетких множеств. Другое направление, которое находит все большее применение – использование интеллектуальных классификаторов, в частности, нейронных сетей [57, 58, 67, 68, 69].

В западной литературе популярна классификация интеллектуальных систем по используемой в их основе эвристике. Согласно подобной классификации выделяют большое число различных систем, примерами которых являются интеллектуальные системы на основе сетей Байеса, на основе метода опорных векторов, пропозициональной логики, на основе искусственных нейронных сетей и многие другие.

Помимо этого, широко применяется классификация систем по способу их обучения. Используют понятия «система, обучаемая с учителем» (supervised learning) и «обучение без учителя» (unsupervised learning). При обучении с учителем интеллектуальная система обучается с использованием базы знаний, содержащей обучающую выборку. Каждый элемент обучающей выборки заранее классифицирован экспертом

предметной области. При обучении без учителя подобную классификацию должна выполнить сама нейронная сеть [104].

Независимо от применяемой терминологии, подавляющее большинство литературных источников отмечает важность классификации интеллектуальных систем по принципу их автономности в принятии решения, как при обучении, так и в процессе работы.

В другой работе проводится сопоставление подходов интеллектуализации измерительных систем контроля качества, основанных на различных эвристических методиках. В частности, выполнено сравнение систем с интеллектуальной поддержкой с применением метода опорных векторов, метода k-ближайших соседей, искусственных нейронных сетей. Сделан вывод, что применение ИНС дает наибольшую точность при принятии решений в интеллектуальной ИИС [128].

Интеллектуальные ИИС с использованием ИНС находят применение в различных областях. Список некоторых из них, вместе с описанием области применения ИНС, приведен в таблице 1.2.

Наименование ИИС	Область	Тип применяемой ИНС	Источник
	применения		
Информационно-	Оценка распределе-	Полносвязная ИНС, много-	[80]
измерительная система для	ния частиц по разме-	слойный перцептрон. Содер-	
гранулометрического ана-	рам или грануломет-	жит 180 нейронов во входном	
лиза жидких дисперсных	рического состава	слое (входные переменных), 25	
сред на основе видеотехни-	жидких дисперсных	– в промежуточном и 3 – в вы-	
ческих средств и нейросе-	сред.	ходном (выходные перемен-	
тевых технологий		ные). Мода M_0 , дисперсия D_0 и	
		коэффициент асимметрии Ка	
		являлись выходными перемен-	
		ными, которые, в свою оче-	
		редь, характеризовали картину	
		рассеяния частиц.	

Таблица 1.2 - Существующие ИИС с нейронными сетями

Продолжение таблицы 1.2

Наименование ИИС	Область	Тип применяемой ИНС	Источник
	применения		
Нейросетевая система управления процессом тер- мохимического обезвожи- вания нефтяных эмульсий	Управление процес- сом разделения водо- нефтяной эмульсии.	Полносвязная ИНС, состоящая из двух слоев нейронов: скры- того и выходного. Также име- ются входные нейроны, число которых соответствует числу входных значений – 3. Число нейронов в выходном слое со- ответствует числу выходов – 1. Выходное значение содержит значение доли отделившейся воды.	[3]
Система контроля качества (определение ключевых ха- рактеристик производимого продукта) в производстве полупроводников	Применяется в систе- ме «Виртуальная метрология (Virtual Metrology)» для кон- троля качества в про- изводстве полупро- водников.	Полносвязная ИНС. Число входов – 4, один скрытый слой из 5 нейронов, выходной слой из одного нейрона, выпол- няющего роль индикатора сиг- нализирующего в случае на- рушения качества продукции.	[128]
Интеллектуальная инфор- мационная система техни- ческой диагностики со- стояния подвижных миксе- ров	Применяется в метал- лургическом произ- водстве при диагно- стике систем футе- ровки	Много сегментная архитектура многослойной нейронной сети и модуль нейросетевого про- гнозирования для определения зон прогара по термограммам полвижных миксеров	[40]

Продолжение таблицы 1.2

Наименование ИИС	Область применения	Тип применяемой ИНС	Источник
Система контроля и диаг- ностики подсистем косми- ческих аппаратов	Сбор и анализ теле- метрической инфор- мации, которая обра- батывается интеллек- туальными средствами наземной командно- измерительной сис- темы, установленны- ми на высокопроиз- водительном GPU- кластере	Многослойная полносвязная сеть	[1]
Информационно- измерительная система контроля функционирова- ния комплекса многопара- метрического учета распре- деленного энергопотребле- ния	Алгоритм контроля функционирования комплекса многопа- раметрического учета распределенного энергопотребления на основе искусственной нейронной сети.	Многослойный персептрон со структурой МЛП N-P-М	[5]

Перспективным является применение ИНС в ИИС, обрабатывающих визуальные и графические образы. Очевидно, что регистрируемая в процессе контроля какого-либо технического объекта термограмма, может интерпретироваться и обрабатываться как растровое изображение. Как отмечается во многих исследованиях конволюционные ИНС различных модификаций - эффективный инструмент для классификации растровых изображений по содержанию в них различных признаков. В этой связи применение конволюционных ИНС может автоматизировать труд экспертов предметной области и операторов – термографистов , выполняющих интерпретацию термограмм для определения их технического состояния [109].

Подобная автоматизация имеет ряд преимуществ:

• возможность выполнять контроль технического состояния объектов в реальном времени;

• выявление технических неполадок в объекте на ранних стадиях;

• исключение человеческого фактора при классификации технического состояния контролируемого объекта по термограмме;

• выполнение контроля технического состояния по термограмме на автономном объекте, к которому исключен доступ человека;

• снижение трудозатрат на выполнение расшифровку термограммы.

1.5 Применение ИНС для распознавания графических образов

В основе искусственных нейронных сетей лежит концепция, предложенная в 1956 году Фрэнком Розенблатом (Frank Rosenblatt). Концепция перцептрона была развитием математической модели когнитивного процесса, протекающего в мозге, предложенной МакКаллочем (Warren McCulloch) и Питтсом (Walter Pitts) в 1943. На основании этих концепций в 1986 году Дэвидом Румельхартом (David Rumelhart) была выполнена первая программная реализация искусственного нейрона, ставшая концептуальной основой для всех современных реализаций искусственных нейронов [122].

Один отдельно взятый нейрон обладает ограниченной способностью к обучению. В этом контексте часто приводится пример того, что один нейрон не способен выполнить аппроксимацию даже такой простой функции, как «исключающее И» (exclusive OR, XOR). Способность к сложному когнитивному процессу искусственные нейронные сети приобрели именно благодаря объединению нескольких нейронов в систему или, как их еще называют, сеть. Существует очень большое количество нейронных сетей, различающихся по способу объединения нескольких нейронов в одну общую систему [116].

Современные ИНС представляют собой совокупность искусственных нейронов, объединенных в слои, которые, в свою очередь, последовательно выполняют обработку сигнала. Важным прорывом для построения сетей является технология обратного прохождения сигнала, предложенная Джефри Хинтоном (Geoffrey Hinton) и Дэвидом Румельхартом (David Rumelhart) в 1986 году. Именно благодаря этому предложенному подходу появилась возможность обучать многослойные искусственные нейронные сети. [122]

В контексте рассмотрения ИНС, эффективно обрабатывающих графические изображения, наиболее часто выделяют следующие две модификации: полносвязные нейронные сети и конволюционные.

Полносвязные (fully connected) ИНС представляют собой сети, в которых каждый отдельно взятый нейрон на отдельно взятом слое соединен (получает на вход сигнал) с каждым нейроном предыдущего слоя. Отдельно взятую связь между нейронами, по которой передается сигнал между ними, принято называть синаптической связью (по аналогии с биологическими нейронными сетями). Несмотря на простоту в реализации ИНС подобного рода, в контексте обработки изображений они получили небольшое распространение в виду ряда ограничений их возможностей. Наиболее существенное ограничение - невозможность распознавать образы на изображениях, подвергнутых незначительным аффинным преобразованиям. Однако, в некоторых случаях на практике подобные сети применяются в виду их относительной простоты.

Конволюционные или «свёрточные» (convolutional) ИНС впервые были предложены в работе Яна ЛеКуна (Yann LeCunn) в 1998 году [109]. Основная идея конволюционных ИНС была заимствована у биологических нейронных сетей. Архитектура конволюционной сети построена таким образом, что обработка сигнала в них осуществляется аналогично обработке сигнала в коре головного мозга млекопитающих в зоне, ответственной за восприятие зрительных образов. Нейроны, расположенные на отдельно взятом конволюционном слое, имеют одинаковые синаптические связи, и каждый нейрон получает на вход сигналы, находящиеся в пределах его поля восприятия (receptive field). Подобное построение сети позволяет распознавать характерные черты для того или иного объекта, независимо от его расположения и размера. Как показали изыскания Мэтью Зейлера (Matthew Zeiler), благодаря тому, что несколько конволюционных слоев выстроены последовательно от одного к другому слою. повышается уровень абстракции воспринимаемых сетью образов [109, 133].

С момента появления первого варианта реализации конволюционных ИНС они претерпели множество изменений. Несмотря на то, что принцип их работы остался неизменным, было найдено большое количество различных эвристик, улучшающих процесс их обучения и функционирования. Значительное внимание в современных исследованиях уделено функции активации, применяемой в искусственном нейроне.

В ранних работах, в качестве функции активации применялась функция, часто именуемая как логистическая регрессия следующего вида (рисунок 1.8,а):

$$f(x) = \frac{1}{1 - e^{-x}} \quad . \tag{1.9}$$

В более поздних работах стала применяться функция активации вида:

$$f(x) = \max(0, x) . (1.10)$$

Подобная функция активации впервые была предложена в публикации Алекса Крижевски (Alex Krizhevsky) и в этой же работе было предложено название этой функции - ReLU (rectified linear unit). Ее отличие от логистической регрессии (1.9) состоит в том, что, как видно из ее графика (рисунок 1.8,б), выходное значение находится в диапазоне от 0 до $+\infty$, при том, выходное значение функции логистической регрессии всегда находится в диапазоне от 0 до 1 [107].

По описанным в известных публикациях причинам это делает невозможным обучение ИНС с большим числом слоев в силу затухания сигнала ошибки. Особенность функции ReLU в том, что сигнал ошибки, соответствующий выходному сигналу слоя ИНС с данной функцией активации, не подвержен затуханию при обучении.


Рисунок 1.8 - Графики функций активации

Как было показано в работе Алекса Крижевски (Alex Krizhevsky), применение функции активации ReLU (наряду с некоторыми другими эвристиками) дало новый импульс для развития конволюционных ИНС [107].

Развитие конволюционных ИНС активно продолжается и в настоящее время. Яркими примерами современных конволюционных ИНС являются сети, описанные в [128].

Точность классификации изображений у подобных ИНС намного превышает точность классификации систем, построенных на каких-либо других эвристиках. К таким эвристикам относятся Байесовские сети, системы обработки градиентов цветов на растре, методы на основе опорных векторов. На сегодняшний день конволюционные ИНС для классификации изображений стали использоваться настолько широко, что полностью вытеснили альтернативные подходы в промышленном применении.

Важно отметить, что, вместе с возрастающей сложностью конволюционных ИНС, возрастает и потребность в более мощных вычислительных средствах для выполнения программной логики ИНС. Выбор конкретной архитектуры ИНС для решения поставленной задачи должен включать оценку доступности подобных вычис-

лительных мощностей. Это, в свою очередь, накладывает ответственность при выборе архитектуры ИНС, наиболее подходящей для решения отдельно взятой практической задачи. Подобный выбор должен учитывать множество факторов, например, общую сложность вычислений, производимых ИНС, и, соответственно, нагрузку, создаваемая ее программной реализацией на аппаратное обеспечение, точность классификации ИНС, время, необходимое на обучение сети, и другие подобные факторы.

Богатый набор разработок в области конволюционных нейронных сетей открывает перспективы для применения их в различных областях. Однако, применение конволюционных ИНС для выделения характерных черт, распознавания и классификации термограмм до сих пор является недостаточно изученной областью. Вместе с тем, применение конволюционных ИНС в тепловизионном диагностировании позволило бы в значительной степени автоматизировать процесс обработки термограмм и интеллектуализировать информационно-измерительные системы, предназначенные для теплового контроля технических состояний объектов

1.6 Методика интеллектуализации ИИС тепловизионного диагностирования (ИИС ТД) на основе нейронных сетей и модельных термограмм

1.6.1 Проблемы технического диагностирования на основе сравнительной инфракрасной термографии

Проблемы технического диагностирования на основе сравнительной инфракрасной термографии следующие:

• В большинстве случаев отсутствует достаточное число реальных термограмм, необходимых для сравнительного анализа. Поэтому не удается эффективно использовать способы интеллектуализации принятия решений с помощью нейронных сетей. • Множество полученных термограмм и множество неисправных состояний объекта не имеют взаимно-однозначного соответствия. Несколько неисправностей могут соответствовать одному и тому же распределению температуры на поверхности объекта. Необходимо решать обратную задачу классификации нескольких неисправностей по термограммам одного и того же вида. Решение обратной задачи может быть некорректным [75].

• Большой набор термограмм объекта неизбежно требует применения сложных алгоритмов анализа данных, что практически невозможно выполнить вручную оператору-термографисту. В этом случае принятие решений о дальнейшей эксплуатации контролируемого объекта в реальном времени затруднено, что может привести к аварийному выходу объекта из строя, вплоть до разрушения.

1.6.2 Метод интеллектуализации ИИС тепловизионного диагностирования с использованием нейронной сети

В диссертационной работе интеллектуализация ИИС проводится на базе предлагаемого ниже метода.

Интеллектуальный метод повышения точности классификации реализуется с помощью трех основных процедур [18, 57, 99]:

1. Построение комплексных модельных термограмм, полученных в результате решения уравнений теплопроводности и дополненных набором дополнительно измеряемых величин параметров объекта для получения точного соответствия неисправностям, а также формирование на их основе базы данных для диагностирования.

2. Использование в составе ИИС нейросетевого программного анализатора в виде глубокой двухветвенной нейронной сети (ДНС), состоящей из многослойной конволюционной сети для обработки термограмм и полносвязной нейронной сети для обработки дополнительных параметров объекта контроля.

3. Обучение двухветвенной нейронной сети на множестве комплексных термограмм и дальнейшее выполнение классификации технического состояния контролируемого объекта в процессе тепловизионного диагностирования для принятия решений о техническом обслуживании.

Более подробно действия, выполняемые при реализации предложенного метода, показаны ниже:

1. Для определенного класса контролируемых объектов на базе математических моделей нестационарного уравнения теплопроводности выполняется построение двухмерных расчетных термограмм, соответствующих различным техническим состояниям объекта. Совместно с выбранным ограниченным набором измеряемых величин параметров объекта, они образуют множество комплексных модельных термограмм.

2. На полученном множестве строятся подмножества вариативных расчетных термограмм и дополнительных параметров, охватывающие возможные отклонения тепловых состояний контролируемого объекта от номинальных и характеризующие неисправности.

3. В ИИС формируется база знаний для тепловизионного диагностирования, содержащая множество комплексных модельных термограмм.

4. В структуру ИИС тепловизионного диагностирования вводится нейросетевой программный анализатор термограмм, представляющий собой двухветвенную многослойную нейронную сеть для обработки термограмм и вектора дополнительно измеряемых параметров. ДНС состоит из двух ветвей – глубокой конволюционной нейронной сети и полносвязной сети.

5. Проводится обучение двухветвенной ИНС на множестве комплексных модельных термограмм из базы знаний. Для верификации качества обучения и эффективности выбранной структуры ИНС выполняется многомерный анализ классификации состояний объекта на обучающей выборке. 6. В процессе диагностирования ИИС выполняет измерение реальных термограмм поверхности и дополнительных параметров контролируемого объекта.

7. Измеренная реальная термограмма объекта поступает на вход конволюционной сети (основная ветвь ДНС), а дополнительно измеренные параметры объекта – на входы полносвязной сети (вспомогательная ветвь ДНС).

8. В результате работы двухветвенной ИНС производится классификация технических состояний контролируемого объекта и определение вида отказа. Затем система принятия решений выносит заключение о работоспособности или неработоспособности объекта и возможности его дальнейшей эксплуатации.

9. По результатам серии измерений термограмм может выполняться корректировка комплексных модельных термограмм в базе знаний, либо дополнение реальными термограммами для повышения точности и достоверности классификации технических состояний.

В таблице 1.3 показано сравнение разработанного метода с методикой диагностирования, использованной в ИИС контроля микросхем ФМ ПЗС по тепловой картине [6].

И	ИС контроля ФМ ПЗС	(прототип [6])	Разрабатываемая интеллектуальная ИИС тепловизионного			
			диагностирования (ИИИС ТД)			
N⁰	Содержание	Отличия	N⁰	Содержание этапов		
этапа	этапов контроля		этапа	диагностирования в ИИИС		
	Построение 2D те-	Этап аналогичен в	1	Построение 2D тепловых		
1	пловой модели	обеих методиках		моделей для различных		
	(TM)			типов объектов контроля		
	объекта контроля					
2	Оценка адекватно-	Этап аналогичен в	2	Оценка адекватности ТМ в		
	сти ТМ в результа-	обеих методиках		результате физических		
	те			экспериментов		
	физических экспе-			_		
	риментов					

Таблица 1.3 - Сравнение методик	тепловизионного	диагностирования
---------------------------------	-----------------	------------------

Продолжение таблицы 1.3

ИИС контроля ФМ ПЗС (прототип [6])			Разрабатываемая интеллектуальная			
			ИИС тепловизионного			
	1		диагно	стирования (ИИИС ТД)		
N⁰	Содержание	Отличия	Содержание этапов			
этапа	этапов контроля		этапа	диагностирования в ИИИС		
3	Проведение испы-	<u>В прототипе</u> :	3	Формирование вариатив-		
	таний объекта с	отсутствует база		ных комплексных моделей		
	измерением термо-	знаний с комплекс-		термограмм и наборов до-		
	грамм с помощью	ными модельными		полнительно измеряемых		
	тепловизора	термограммами; су-		величин параметров объ-		
		ществует погреш-		екта контроля		
		ность идентифика-				
		ции дефектов из-за				
		неоднозначности				
		решения				
4	Экспресс-анализ	В прототипе:	4	Формирование базы знаний		
	термограмм на	выполняется опера-		модельных термограмм		
	предмет попадания	тором.				
	температур харак-	<u>В ИИИС:</u>				
	терных точек по-	анализ термограмм				
	верхности в задан-	автоматизирован				
	ные пределы					
5	Сравнение реаль-	<u>В прототипе</u> :	5	Обучение двухветвенной		
	ных термограмм с	выполняется опера-		ИНС на модельных термо-		
	расчетными темпе-	тором путем после-		граммах		
	ратурными полями	довательного срав-				
	математических	нения.; невозмож-				
	моделей	ность оперативного				
		контроля состояния				
		объекта; высокая ве-				
		роятность ошибки				
		сравнения				
6	Определение типа	<u>В прототипе</u> :	6	Многомерный анализ каче-		
	дефектов по наи-	выполняется опера-		ства обучения двухветвен-		
	большему совпаде-	тором, невозмож-		ной ИНС (метод главных		
	нию термограммы	ность оперативного		компонентов, многомерное		
	и расчетного теп-	контроля состояния		шкалирование и т.п.)		
	лового поля	объекта; высокая ве-				
		роятность ошибки				
		классификации				

Продолжение таблицы 1.3

ИИС контроля ФМ ПЗС (прототип [6])			Разрабатываемая интеллектуальная			
			ИИС тепловизионного			
			диагностирования (ИИИС ТД)			
No	Содержание	Отличия	Содержание этапов			
этапа	этапов контроля		этапа	диагностирования в ИИИС		
7	Принятие решения	<u>В прототипе:</u> приня-	7	Проведение испытаний		
	о наличии дефектов	тие решения может		объекта с измерением тер-		
	и дальнейшей экс-	быть выполнено		мограмм и вектора допол-		
	плуатации объекта	слишком поздно, что		нительных параметров		
	контроля	приведет к критиче-				
		ским состояниям	8	Анализ технического со-		
		объекта.		стояния объекта с исполь-		
		<u>В ИИИС:</u>		зованием двухветвенной		
		анализ и принятие		ИНС		
		решений произво-				
		дится в реальном				
		времени с помощью				
		ИНС				
			9	Определение причин нера-		
				ботоспособности объекта		
				контроля по результатам		
				работы ИНС		
			10	СПР принимает решение о		
				дальнейшей эксплуатации		
				объекта и необходимости		
				корректировки моделей		

Выводы по главе 1

1. Проведен анализ существующих информационно-измерительных систем тепловизионного контроля и диагностирования, использующих сравнительную термографию. Выявлено, что наибольшее время при диагностике занимает процедура сравнения измеренных термограмм с эталонными образцами. Показано, что точность классификации отказов в объекте контроля, выполняемая оператором-термографистом, недостаточно высокая.

2. Повышение качества диагностирования по термограммам связано с наличием достаточно представительного набора эталонных термограмм. Показано, что в большинстве случаев отсутствует необходимое число реальных термограмм, соответствующих отказам объекта. Предложено использовать модельные термограммы, получаемые при решении уравнений теплообмена.

3. Для диагностирования электронных приборов и элементов систем управления построены модели теплового состояния двух видов: а) на основе расчетных моделей приборов, выполненных в системе АСОНИКА-ТМ, б) на основе уравнения теплопроводности, в которой с помощью вариативных параметров имитируются неисправности различного рода для последующего обучения нейронной сети.

4. На основе проведенного анализа сделан вывод о целесообразности интеллектуализации процесса классификации технический состояний контролируемого объекта и использованием конволюционных нейронных сетей и глубокого обучения.

5. Для повышения достоверности и оперативности контроля объектов в процессе их эксплуатации предложен метод интеллектуализации информационноизмерительной системы диагностирования на основе глубоких нейронных сетей.

2 РАЗРАБОТКА АРХИТЕКТУРЫ ИНТЕЛЛЕКТУАЛЬНОЙ ИНФОРМАЦИОННО-ИЗМЕРИТЕЛЬНОЙ СИСТЕМЫ ТЕПЛОВИЗИОННОГО ДИАГНОСТИРОВАНИЯ

2.1 Общая структура интеллектуальной ИИС ТД

Известно, что искусственные нейронные сети (ИНС) эффективно распознают сложные образы [104, 109].

Существует большое количество приложений ИНС, где выполняется анализ информации в условиях неопределенности [114, 115].

В данной работе предлагается подход, основанный на применении специальной архитектуры нейронной сети для регуляризации некорректной обратной задачи распознавания термограмм при диагностике. Предлагаемая ИНС представляет собой две ветви (две нейронные сети), объединенные в одну комплексную нейронную сеть.

Иллюстрация разрабатываемого в диссертации метода интеллектуализации проводится на примере диагностирования неисправностей в радиоэлектронном приборе типа фоточувствительной матрицы ФМ ПЗС оптико-электронного преобразователя системы дистанционного зондирования Земли [5].

Как показано на рисунке 2.1, ИИИС ТД входит в состав информационноуправляющей системы, обеспечивающей анализ результатов диагностирования и управление контролируемым объектом.

На рисунке 2.1 используются следующие обозначения:

ИС – измерительная система, включающая каналы для измерения термограмм и дополнительного набора электрических параметров прибора;

СПР – система принятия решений о техническом обслуживании по результатам работы нейронной сети;

U - управляющие воздействия по техническому обслуживанию объекта по результатам тепловизионного диагностирования технических состояний; *W* - электрическая мощность, поступающая на входы контролируемого прибора;

 V – значения параметров, дополнительно измеряемых в контролируемом приборе;

 $\Theta(x, y)$ - установившееся распределение температур на плоской грани прибора;

Г - множество теплофизических и конструктивных параметров прибора, учитываемых при построении математической модели в виде уравнения теплопроводности;

 $\Theta^{M}(x, y)$ - модельное распределение температур на грани прибора;

 $\{\Theta_{kj}^{M}(x, y)\}$ - множество модельных термограмм *k*-го класса в базе знаний, используемых при обучении ИНС, $j = \overline{1, J_k}$, J_k – объем обучающей выборки для *k*-го класса неисправностей;

 V_{kj}^{M} , $j = \overline{1, J_{k}}$ - модельные значения дополнительных параметров прибора для *k*-го класса неисправностей;

 $\Theta_{P}^{H3M}(x, y)$ - измеренная термограмма установившегося распределения температур, полученная с помощью измерительного канала, включающего в себя тепловизор;

V^{*H3M*} - вектор реально измеренных величин дополнительных параметров;

 $d_0, d_1, ..., d_K$ - выходы ИНС, соответствующие классам технических состояний прибора, при этом d_0 - работоспособное состояние, а остальные выходы – соответствуют классам неисправностей.



Рисунок 2.1 - ИИИС ТД с нейросетевым программным анализатором термограмм и дополнительно измеряемых величин объекта

Во время испытаний и текущего контроля приборов результаты работы ИНС фиксируются в базе знаний и в дальнейшем используются для коррекции параметров математических моделей теплообмена прибора. Это позволяет уточнить модельные термограммы и повысить достоверность диагностики объектов путем дообучения нейронной сети.

2.2 Задача классификации неисправностей в контролируемом объекте по термограммам

2.2.1 Классы модельных термограмм

Основой нейросетевого программного анализатора является новая структура в виде двухветвенной нейронной сети (ДНС). Такая структура была предложена в силу следующих соображений.

Получение модельных термограмм – это решение ряда прямых задач теплопроводности вида (1.1) – (1.7), которые отличаются расположением внутренних источников тепла и их мощностью. Кроме того, при решении проводится изменение геометрических параметров объекта и некоторых параметров: теплопроводности, плотности и удельной теплоемкости материала.

В результате для выбранной поверхности объекта получается множество $\{\Theta_i^M(x, y)\}$ всех модельных термограмм:

$$\Theta_i^M(x, y) = F_i(x, y, q_n^i(x, y, z)), \ i = \overline{1, I}, \ n = \overline{1, N},$$

где х, у – координаты наблюдаемой поверхности,

 $q_n^i(x, y, z)$ - мощность *n*- го внутреннего источника тепла,

I – количество сформированных модельных термограмм.

Теперь встает задача сопоставления каждой модельной термограммы $\Theta_i^M(x, y)$ соответствующему техническому состоянию объекта. Эту задачу выполняют эксперты – специалисты в данной предметной области. Они используют априорную информацию о процессах, протекающих в объекте, в первую очередь, о тепловых процессах. В данной диссертации не рассматриваются вопросы организации таких экспертных заключений, а также оценка достоверности выводов экспертов.

Все термограммы работоспособных состояний объединяются в один класс D_0 . Остальные термограммы разделяются экспертами на *К* модельных классов D_1 , $D_2,...,D_K$, каждый из которых соответствует одному и только одному типу неработоспособного состояния объекта. На этом этапе возникает проблема неоднозначности классификации. По существу, имеем некорректную обратную задачу классификации двумерного сигнала [75]. Это вызвано тем, что при различных режимах внутренних источников тепла в объекте, температурное поле на наблюдаемой поверхности может быть практически одинаковым. Но при этом, в каждом из случаев в объекте могут быть разные неисправности.

Следует различать обратную задачу теплопроводности и обратную задачу классификации двумерного сигнала. В первом случае, неизвестный оператор обратной задачи представляется в виде универсального аппроксиматора, которым является нейронная сеть с неопределенными коэффициентами. Эти коэффициенты вычисляются в процессе обучения нейронной сети на эталонных примерах, полученных в результате решения прямых задач теплопроводности. Результатом является интерполяционное решение обратной задачи [61].

Во втором случае выполняется отнесение термограммы $\Theta_p^{H3M}(x, y)$, измеренной на поверхности объекта, к некоторому классу моделей. При этом прямое решение такой модели генерирует температурные распределения (модельные термограммы), к которым определенном смысле будет близка измеренная термограмма $\Theta_p^{H3M}(x, y)$. На рисунке 2.2 показана графовая модель различных технических состояний.

Из рис. 2.2 видно, что в общем случае одна и та же картина распределения тепла на поверхности контролируемого прибора может иметь место при его различных технических состояниях. В этом случае нет взаимно-однозначного соответствия между типовыми видами термограмм и состоянием контролируемого прибора.



Рисунок 2.2 - Графовая модель технического состояния объектов

В диссертации предлагается анализировать одновременно с термограммами вектор $V_r = (v_1, ..., v_l)$ дополнительных параметров, описывающих работу контролируемого устройства, L - число параметров, входящих в данный вектор. Главное условие – возможность измерения этих параметров.

Класс D_k определяется совокупностью Q_k источников тепла и значениями их удельной мощности, которым соответствует определенный тип неработоспособного состояния объекта:

$$Q_k(r) = \{q_1^k(r), ..., q_N^k\}, r = (x, y, z), r \in \Omega,$$

где *N* - число источников тепла в математической модели теплового режима объекта контроля,

Ω - область определения решения задачи теплопроводности.

Определим функцию параметризации

$$Q(r) = f(\Theta, V),$$

где $\Theta = \Theta(x, y)$ – термограмма поверхности объекта,

50

 $V = (v_1, ..., v_L) -$ вектор дополнительных параметров.

Тогда можно определить класс D_k следующим образом:

$$D_k: \{Q(r) \in D_k, ecnu Q(r) = f(\Theta, v_l) \land (E_k = 1), l \in L_k, r \in \Omega\},\$$

где *L_k* - индексное множество дополнительных параметров для *k*-го типа неисправности,

 $E_k \in \{0,1\}$ — экспертное заключение по соответствию заданной термограммы $\Theta(x, y)$ и дополнительных параметров *k*-му типу неисправности.

Потребуем выполнение следующего условия: для любой пары классов термограмм Θ^l и Θ^n , $l, n \in \{0, 1, ..., K\}, l \neq n$, есть как минимум одна пара элементов $\Theta^l_j \neq \Theta^n_i, j \in J_l, i \in J_n$ или $V^l_r \neq V^n_s, r \in R_l, s \in R_n$.

Следовательно, разделение термограмм с помощью вектора V на подмножества $T^k(x, y, V) \rightarrow D_k$ приводит к взаимно-однозначному соответствию между возможными состояниями контролируемого объекта и видом характерной термограммы, дополненной данными о величинах дополнительно измеряемых параметров.

Определение. Будем называть комплексной модельной термограммой пару $\{\Theta_{kj}^{M}, V_{kr}^{M}\}$, образованную модельной термограммой и значениями дополнительно контролируемых параметров.

Таким образом, имеем множество всех классов комплексных модельных термограмм:

$$T_{C} = \bigcup_{k} \{ \Theta_{kj}^{M} \}, \{ V_{kr}^{M} \}, \ j \in J_{k}; \ r \in R_{k}, \ k \in \{0, 1, ..., K\},\$$

где J_k и R_k – индексные множества расчетных термограмм и векторов дополнительных параметров, включаемых в *k*-й класс (рисунок 2.3).



Работоспособное состояние

Состояния неисправности или отказа в объекте

Рисунок 2.3 - Разделение комплексных модельных термограмм по классам, соответствующих различным техническим состояниям

Дополнительно измеряемые величины параметров объекта являются регуляризирующим фактором для обратной задачи классификации. Это делает обратную задачу корректной путем сужения бесконечного множества решений до конечных компактов, соответствующих выбранным неисправностям.

Предлагается использовать такие параметры, величины которых измеряются встроенными средствами контроля в объекте. Применительно к электронным приборам можно выделить:

- напряжения питания прибора;
- амплитуду напряжений входных, управляющих и выходных сигналов;
- частоту и фазу сигналов;
- сигналы, характеризующие установленный режим функционирования прибора.

Для электромеханических систем это могут быть:

- вибрация;
- геометрическое смещение элементов конструкции;
- величина электромагнитного поля;

 изображение с ультрафиолетовой видеокамеры, показывающее утечки тока, коронный разряд и т.п.

Сопоставление значений дополнительных параметров и термограмм, а также формирование комплексных модельных термограмм должно выполняться экспертами по проектированию и эксплуатации контролируемого объекта.

2.2.2 Классифицирующий нейросетевой оператор

Для класса неисправности *D_k* определим вектор макропараметров

$$T^{H3M} = (\Theta_P^{H3M}(x, y), v_1^{H3M}, ..., v_L^{H3M}),$$

измеренных с помощью ИИС.

Требуется найти нейросетевой оператор S_k , устанавливающий связь между векторами T^k и $T^{\text{ИЗМ}}$:

$$S_k: T^{M3M} \longrightarrow d_k.$$

Искомый классифицирующий оператор S_k реализован в виде двухветвенной нейронной сети. При обучении нейросетевой оператор S_k ставит в соответствие каждому из векторов T_i^M из базы данных эталонных комплексных модельных термограмм классифицирующий вектор $d_{\kappa\pi} = (d_0, d_1, ..., d_K)$. В результате обучения вычисляются весовые коэффициенты нейронов сети, которые обеспечивают минимум критерия ошибки выходного сигнала. Обучение проводится в течение достаточного числа эпох. Значения выходного вектора $d_{\kappa\pi}$ интерпретируются как вероятности принадлежности технического состояния к классу D_K .

Работа обученного нейросетевого оператора *S_k* проверяется на независимой тестовой выборке, не участвующей в процессе обучения.

2.3 Нейросетевой программный анализатор

Для реализации предложенного подхода разработан нейросетевой программный анализатор модельных термограмм и дополнительных параметров. В его состав включена двухветвенная нейронная сеть. Первая ветвь - многослойная конволюционная нейронная сеть, которая обучается на множестве построенных модельных термограмм. Вторая ветвь – это полносвязная нейронная сеть, которая обрабатывает вектор дополнительных параметров. На рисунке 2.4 показана структура предлагаемой двухветвенной нейронной сети.



Рисунок 2.4 - Схема двухветвенной нейронной сети

Функциональное преобразование входных сигналов нейронной сети с активационными функциями для нейронов скрытого слоя имеет вид:

$$y_k(x) = w_{0,k} + \sum_{j=1}^{\nu} w_{j,k} \, \varphi \Big(w_{0,j} + \sum_{i=1}^{p} w_{i,j} \, x_i \Big),$$

где $y = \{y_1, \dots, y_q\}$ - вектор выходов сети;

q = размер выходного слоя; $x = \{x_1, ..., x_p\}$ - вектор входов сети; p - размер входного слоя; v- размер скрытого слоя; $w_{j,k}$ - веса k -го нейрона выходного слоя; $w_{i,j}$ - веса j - го нейрона скрытого слоя, ϕ – функция активации.

Тепловизор и глубокая конволюционная нейронная сеть образуют основной измерительный канал. Архитектура конволюционной нейронной сети построена по принципам, предложенным Яном ЛеКуном, а также включает в себя некоторые черты, описанные в последующих работах [107, 114].

Предлагаемая нейронная сеть изображена на рисунке 2.5. Сеть также использует концепцию нормализации подвыборок (batch normalization), впервые представленную в [105].



Рисунок 2.5 - Глубокая нейронная сеть с двумя ветвями

Главная ветвь - это конволюционная нейронная сеть. Она состоит из нескольких конволюционных слоев, объединенных в сеть прямого прохождения сигнала. Термограммы используются в качестве входного сигнала для этой ветви.

Термограммы, как и любое другое изображение, могут быть представлены, как 3-х мерный массив, в котором каждое значение представляет цвет соответствующего пиксела. Ширина и высота массива совпадает с шириной и высотой изображения (в пикселах), а глубина массива равна 3, по одному на каждый из 3-х каналов (синий, зеленый, красный). Размер термограмм, используемых в ИИИС ТД, равен 225х225 пикселей.

Поле восприятия (receptive field) первого конволюционного слоя имеет 11x11 пикселей, отступ (padding) 1 и шаг (stride) 4 пикселов. Число карт «черт» (feature maps), создаваемых первым слоем, равно 6. Выходной сигнал первого конволюционного слоя передается слою, выполняющему выборку максимального значения в пределах заданного поля восприятия (max pooling layer). Размер поля восприятия этого слоя - 4х4 пиксела и шаг - 3 пиксела. Выходной сигнал этого слоя передается на вход другому конволюционному слою, размер поля восприятия которого равно 5х5 пикселей и шаг - 1 пиксель. Число формируемых карт черт этим слоем равно 16. После этого слоя применен еще один слой, выполняющий выборку максимального значения в пределах заданного поля восприятия. Размер поля восприятия этого слоя 4х4 пиксела и шаг - 2 пиксела. Выходной сигнал этого слоя передается далее третьему конволюционному слою с размером поля восприятия 6х6. Поскольку размер карт черт, используемых как входной сигнал для этого слоя, также размером 6х6 пикселей, то этот слой может рассматриваться как полносвязный. Выходной сигнал этого слоя — это вектор длиной 120 элементов. Выходной сигнал данного конволюционного слоя – это выходной сигнал всей главной ветви нашей сети.

Параметры конволюционных слоев (такие как поле восприятия, шаг, отступ) были выбраны таким образом, чтобы при заданном размере термограмм выходной сигнал являлся вектором.

Для учета дополнительных параметров, поступающих от встроенных датчиков контролируемого прибора, была введена вспомогательная ветвь. Это ветвь состоит из полносвязного слоя. Входными сигналами для этой ветви (3 элемента) служат нормализованные значения дополнительных параметров, измеряемые встроенными датчиками контролируемого прибора. Выходной сигнал этого слоя – это вектор длины 2. Этот вектор объединяется с вектором, полученным на выходе главной ветви, и результирующий вектор передается следующему полносвязному слою, который имеет в качестве функции активации нелинейную нормализацию (softmax) или двустадийную линейную нормализацию [17].

Выходные сигналы $d_0, d_1, ..., d_K$) двухветвенной нейронной сети интерпретируются как распределение вероятностей нахождения объекта контроля в различных состояниях.

Дополнительные сведения о структуре использованной сети сведены в таблицу 2.1.

ИНС была использована для классификации 4-х основных наиболее важных неисправностей микросхемы ФМПЗС, поэтому выходной слой использовавшейся сети содержит 5 нейронов (по одному на каждую неисправность и один, соответствующий исправному состоянию).

Недавние публикации рассматривают в деталях применение некоторых архитектур, которые позволяют моделировать разреженность в синаптических связях ИНС. В диссертации не применялись подобные подходы, и реализовывалась разреженность синаптических связей в так же, как было предложено в работе Яна ЛеКуна, выполняя выборку различных подмножеств карт черт на входе во второй конволюционный слой. Что касается нейронов конволюционных слоев, каждый из них полносвязно соединен с входом поля восприятия конволюционного слоя [109].

Тип	Число входных сигналов слоев	Поле восприятия (Receptive field)	IIIar	Отступ	Число выходных сигналов слоев	Число нейронов	Число карт черт на слой	Число карт черт	Число синаптиче- ских связей	Число изменяемых параметров
	Главная ветвь									
Конв. слой	225	11	4	1	55	18150	1	6	363x6	2184
Слой «Фильтр max»	55	4	3	0	18		1	6		
Конв. слой	18	5	1	0	14	3136	6	16	100x16	1616
Слой «Фильтр max»	14	4	2	0	6		1	16		
Конв. слой	6	6	6	0	1	120	16	12 0	576x120	69240
Вспомогательная ветвь. Полносвязный слой				2			3x2	8		
Общая ветвь. Полносвязный слой				5			122x5	615		
Итого: число нейронов - 21413				Итого число изменяемых параметров - 73663						

Таблица 2.1 - Характеристики нейросетевого программного анализатора

Принимая во внимание тот факт, что главная ветвь построенной сети – это широко использующаяся конволюционная нейронная сеть, ее веса могут быть инициализированы значениями, взятыми из сети сопоставимой конфигурации, обученной на выборке изображений. Хотя этот подход в данной работе при экспериментах не применялся, он может быть использован в случаях, когда критично важно сократить время обучения сети или в наличии нет достаточного числа термограмм для обучения полной сети. В проведенных экспериментах выполнялось полное обучение сети, и перед обучением выполнялась инициализация весов сети случайными значениями из диапазона (-2, 2).

В проведенных экспериментах обучение сети выполнялось с использованием обратного прохождения сигнала ошибки (back-propagation) [122].

2.4 Процедуры обучения ДНС

Несмотря на то, что обычно искусственные нейронные сети обучаются на выборке, составленной из образцов данных, которые предполагается обрабатывать сетью при ее непосредственной эксплуатации, в описываемой работе сеть обучалась на модельных термограммах, а не на термограммах, полученных с каких-либо реальных приборов. Это связано тем, что, рассматривая решаемую задачу с метрологической точки зрения, измерительный инструмент перед использованием проходит калибровку на эталонных данных. В качестве аналога эталона в рассматриваемой задаче выступили модельные термограммы, полученные с использованием математической модели, описанной в главе 1. Подобный подход обусловлен тем, что даже при регистрации термограмм с двух разных приборов одной модели они имеют некоторые незначительные отличия. Посредством применения модельных термограмм влияние отдельного взятого прибора было исключено.

Дополнение обучающей выборки широко применяется для повышения точности тренируемых ИНС. Особенно этот аспект важен, когда изначально обучающая выборка небольшая.

В то же время, для обучения описываемой диагностической ИНС не применялось дополнение датасета термограммами, полученными с помощью аффинных преобразований исходных термограмм. Это связано с тем, что изображение на выходе термографа всегда статично, и для данной предметной области не свойственно анализировать и распознавать изображения, меняющие свою ориентацию в пространстве.

Однако описанная выше методика моделирования, позволяющая получать теоретические термографические изображения, допускает варьирование некоторыми параметрами. На основе этих математических моделей были получены необходимые изображения термограмм для различных значений параметров источника тепла. Благодаря этому были сформированы несколько вариаций изображений, соответствующих различным категориям диагностируемых неисправностей. Полученные изображения были верифицированы путем их сопоставления с реально полученными термограммами, характерными для каждой из неисправностей. Так была сформирована репрезентативная выборка изображений для обучения ИНС.

Перечень использовавшихся дополнительных параметров микросхемы ФМПЗС включает следующие:

- частота синхронизирующих сигналов;
- частота выходных сигналов;
- уровень напряжения входных управляющих сигналов.

База знаний ИИС ТД содержит продукционные правила вида «Если – ТО», определяющие подмножества термограмм в зависимости от типа контролируемого прибора и набора дополнительно измеряемых параметров. Продукционные правила, формирующие подмножества модельных термограмм для обучения двухветвенной нейронной сети для прибора типа A_m имеют вид:

Если (Прибор A_m)

И Если (Условие γ_r)

И ЕСЛИ (Параметр v_k)

И ЕСЛИ (Неисправность F_j)

ТО (Термограмма T_i^M неисправности *j*).

Здесь условия $\gamma_1, ..., \gamma_r$ тепловизионного диагностирования задаются экспертом и определяют ограничения, вызванные внешней средой, режимами работы прибора и др.

Учитывая широкий перечень предметных областей, где может быть применим выносимый на защиту метод классификации технических состояний, подход к формированию модельных термограмм в каждой из них может отличаться.

2.4.1 Моделирование термограмм матрицы ПЗС

Рассматривая применение разрабатываемого метода интеллектуализации ИИС, при диагностировании технического состояния матрицы ПЗС были сделаны следующие предположения. Контролируемый прибор имеет форму параллелепипеда. Следовательно, надо рассматривать температурные поля на его шести гранях.

1. При креплении прибора в конструктиве системы как минимум одна грань будет соприкасаться со стенками конструкции. Максимальное число граней прибора, соприкасающихся с конструкцией, будет равно 5. Тогда количество видимых поверхностей прибора, которые можно исследовать тепловизором, находится в диапазоне от 1 до 5 граней.

2. Некоторые грани прибора, в частности, имеющие хороший теплоотвод, могут быть изотермическими. В этом случае, говорить о тепловой картине поверхности нет смысла. По существу, достаточно измерить интегральную температуру в какойлибо точке грани и сделать определенные выводы о техническом состоянии объекта. Но это не позволяет провести более тонкое исследование причин отказа прибора и не требует использования интеллектуальной измерительной системы.

3. Таким образом, в дальнейшем будем рассматривать одну грань поверхности контролируемого прибора, температурное поле которой имеет заметный градиент, визуально различимый на термограмме.

Приведенные на рисунке 2.6 модельные термограммы моделируют микросхемы, находящихся в технических состояниях, которые могут быть разделены на три группы.



а) образец, входящий в 1-ю группу, с температурой поверхности 38,4 °С;
б) образец, входящий во 2-ю группу, с температурой поверхности 23,5 °С;
в) образец, входящий в 3-ю группу, с температурой поверхности 39,1 °С
Рисунок 2.6 - Модельные термограммы ФМ ПЗС

1. Для первой группы микросхем на входы подавалась последовательность управляющих сигналов, значительно расширенная во временной области (т.е. с пониженной частотой следования импульсов). Данное отклонение может возникнуть при нарушении работы ПЛИС (например, при сбое конфигурационного регистра и, как следствие, изменении схемы, реализованной на ПЛИС) или при изменении параметров времязадающих элементов схемы.

2. Для второй группы было имитировано нарушение в цепях входных сигналов, проявляющееся в отсутствии (снижении амплитуды за допустимые пределы) сигналов, управляющих выходным регистром. Данное нарушение может быть вызвано нарушением работы схемы формирования опорных напряжений, например, отказом в прямом канале соответствующего импульсного стабилизатора или обрывом верхнего резистора-делителя напряжения прямого канала стабилизатора.

3. Для третьей группы имитировано повышение за допустимые пределы напряжения в цепях входных сигналов, управляющих выходным регистром, которое также вызывается нарушением работы схемы формирования опорных напряжений, на этот раз отказом цепи обратной связи импульсного стабилизатора или обрывом нижнего резистора-делителя напряжения прямого канала стабилизатора.

2.4.2 Моделирование термограмм печатных плат электронных приборов

При выполнении технической диагностики печатной платы прибора общий подход для формирования модельной термограммы остается неизменным. Однако есть некоторые особенности.

В общем случае, решение уравнения теплопроводности для формирования репрезентативного количества термограмм для печатной платы с большим числом конструктивных элементов на ней становится сравнительно затратной операцией в плане потребления вычислительных ресурсов. Одновременно с этим, при возникновении в печатной плате классифицируемых отказов тепловое поле изменяется, как правило, только на отдельных ее участках, а характер изменения температур на некоторых участках платы остается неизменным. Подобные области легко локализуются экспертом предметной области.

Исходя из этого, формирование модельных термограмм можно значительно упростить расчетом распределения температур только для наиболее вариативных областей платы и повторным использованием фрагментов термограммы для областей платы, где изменения распределения температур неизменно. Таким образом, решение уравнения теплопроводности необходимо выполнить только для некоторых участков поверхности платы, что значительно ускоряет процесс формирования модельной термограммы.

Примеры модельных термограмм для печатных плат приведены на рисунке 2.7.



Рисунок 2.7 - Модельные термограммы для печатной платы электронного прибора

Процесс формирования приведенных выше модельных термограмм состоит в следующем. Экспериментальным путем экспертом предметной области выделяются фрагменты печатной платы, на которых распределение температур изменяется значительно при изменении технического состояния платы. Эти области наиболее информативные для проведения диагностирования.

Например, такими областями являются корпуса микрочипов. Для данных областей выполняется расчет распределения температур с использованием уравнения теплопроводности. Полученные распределения температур для выделенных вариативных областей затем совмещаются с данными о распределении температур в областях с неизменным распределением температур. Затем, эти области могут быть однократно рассчитаны для всей обучающей выборки модельных термограмм или даже взяты с реально зарегистрированной термограммы.

Важно отметить, что кроме экономии вычислительных ресурсов, предлагаемая методика формирования модельных термограмм имеет большое практическое применение в предметных областях, где образцы печатных плат достаточно дорогостоящие. В этом случае умышленное провоцирование неисправности в них, для регистрации соответствующей термограммы неприемлемо.

2.5 Анализ данных для обучения ДНС

Известно, что перед обучением ИНС на каком-либо массиве данных важно выполнить анализ самих данных. В проводимых экспериментах применялись модельные термограммы, построенные для пяти различных технических состояний контролируемого прибора. Как уже было отмечено, характерной особенностью исследуемой задачи является отсутствие взаимно-однозначного соответствия между видом термограммы и техническим состоянием прибора. Такое соответствие достигается только посредством включения в рассмотрение дополнительных параметров, регистрируемых в процессе работы контролируемого прибора.

В ходе анализа данных было выявлено три основных вида модельных термограмм. При этом два из них соответствовали двум парам различных технических состояний контролируемого прибора каждая. Однако различие между техническими состояниями при обработке каждой из этих термограмм осуществимо при учете дополнительных параметров, регистрируемых в процессе эксплуатации контролируемого прибора.

Анализируя выделенные три класса модельных термограмм важно рассмотреть их распределение в пространстве всей выборки данных. Термограмма, в общем случае, находится в определенной точке многомерного пространства, расположение которой характеризуется значением интенсивности теплового излучения в каждой точке на этой термограмме. Число измерений пространства, в котором находятся все термограммы, равно числу точек на термограмме. В проводимых экспериментах использовались термограммы размером 225х225 пикселей, соответственно размерность пространства, в котором находились все термограммы равно 50625.

Для проведения анализа термограмм исходную размерность пространства, в которой находится выборка необходимо сократить до удобно воспринимаемого вида. Для этого были применены три техники понижения размерности [2]: метод главных компонент (Principal component analysis, PCA), многомерное шкалирование (Multidimentional scaling, MDS), Т-распределенное стохастическое встраивание соседей (t-Distributed Stochastic Neighbor Embedding, tSNE) [134].

В общем виде задача понижения размерности может быть записана в следующем виде:

$$X = (x^{(1)}, \dots, x^{(p)}) \implies Z(X) = (z^{(1)}, z^{(2)}, \dots, z^{(p')}), \quad p' << p$$

где x⁽¹⁾, ... x^(p) – координаты, определяющие положение элемента выборки в исходном многомерном пространстве,

z⁽¹⁾, ... z^(p') – координаты, определяющие положение элемента выборки в пространстве сокращенной размерности,

р – число измерений исходного пространства,

р' – число измерений сокращенного пространства.

В приводимых далее формулах надстрочные индексы у обозначений $x^{(1)}, \ldots x^{(p)}$ и $z^{(1)}, \ldots z^{(p')}$ опускаются для краткости, а подстрочные индексы соответствуют индексу экземпляра в выборке.

Метод РСА:

$$\sum_{jk} = \frac{1}{n-1} \sum_{i=1}^{n} (x_{ij} - \overline{x}_j) (x_{ik} - \overline{x}_k)$$
$$\bar{x} = \frac{\sum_{i=1}^{n} x_i}{n},$$
$$L = U^T \sum U,$$
$$W = U L^{-\frac{1}{2}},$$
$$Z(X) = XW,$$

где где

L – диагональная матрица с собственными числами матрицы \sum ;

U – матрица с собственными векторами матрицы \sum

Meтод MDS:

$$d = \begin{bmatrix} d_{11} & \cdots & d_{1n} \\ \vdots & \ddots & \vdots \\ d_{n1} & \cdots & d_{nn} \end{bmatrix}, d_{ij} = \sqrt{\sum_{k=1}^{p} (x_i^{(k)} - x_j^{(k)})^2},$$
$$d^* = \begin{bmatrix} d^*_{11} & \cdots & d^*_{1n} \\ \vdots & \ddots & \vdots \\ d^*_{n1} & \cdots & d^*_{nn} \end{bmatrix}, d^*_{ij} = \sqrt{\sum_{k=1}^{p} (z_i^{(k)} - z_j^{(k)})^2},$$
$$C(d^*) = \sum_{i \neq j} (d^*_{ij} - d_{ij})^2,$$
$$d^*_{t+1} = d^*_t - \alpha \nabla C(d^*_t),$$
$$C(d^*_0) \ge C(d^*_1) \ge C(d^*_2) \dots,$$

где *d* – матрица дистанций между объектами в исходном пространстве,

*d** – матрица дистанций между объектами в пространстве меньшей размерности,

 $C(d^*)$ – целевая функция, подлежащая минимизации градиентным спуском. Метод tSNE:

$$p_{j|i} = \frac{\exp\left(\frac{-||x_i - x_j||^2}{2\sigma_i^2}\right)}{\sum_{k \neq i} \exp\left(\frac{-||x_i - x_k||^2}{2\sigma_i^2}\right)},$$

$$p_{ij} = \frac{p_{j|i} + p_{i|j}}{2n},$$

$$\sum_j p_{ij} > \frac{1}{2n},$$

$$q_{ij} = \frac{\exp\left(-||z_i - z_j||^2\right)}{\sum_{k \neq l} \exp\left(-||z_k - z_l||^2\right)},$$

$$C = KL(P||Q) = \sum_{i} \sum_{j} p_{ij} \log \frac{p_{ij}}{q_{ij}},$$
$$p_{ij} = p_{ji}, q_{ij} = q_{ji}, p_{ii} = 0, q_{ii} = 0, \forall i, j,$$

где σ – стандартное отклонение нормального распределения,

p_{ij} – вероятность расположения в одном кластере i-ого и j-ого элементов в исходном многомерном пространстве.

q_{ij} – вероятность расположения в одном кластере i-ого и j-ого элементов в пространстве пониженной размерности.

KL – разница между энтропией и кросс-энтропией (KL-расхождение, Kullback Leibler divergence)

С-целевая функция, подлежащая минимизации градиентным спуском.

Из обучающей выборки было выбрано по 50 примеров модельных термограмм для каждого из трех анализируемых классов термограмм. Диаграммы разделения на компоненты были построены с помощью программного средства Scikit-learn [113].

Полученные PCA, MDS и tSNE диаграммы представлены на рисунках 2.8 - 2.10 соответственно.



а) две главные компоненты, б) три главные компоненты Рисунок 2.8 – РСА диаграмма для трех классов термограмм



а) две компоненты, б) три компоненты





а) две компоненты, б) три компоненты

Рисунок 2.10 - tSNE диаграмма для трех классов типовых термограмм

Как видно из представленных диаграмм каждый из классов термограмм выделим в отдельный кластер. Подобное обстоятельство позволяет утверждать, что данная выборка пригодна для обучения ИНС на ней.

69

Пространство термограмм не содержит областей, где присутствуют образцы, принадлежащие разным классам. Иными словами, пространство обучающей выборки не содержит зашумленных областей.

Однако решаемая в данной работе прикладная задача сводится к классификации пяти различных типовых состояний контролируемого прибора, двум парам из которых сопоставляются два соответствующих класса термограмм. Как уже было отмечено выше, для распознавания этих состояний помимо термограмм приняты в рассмотрение дополнительные сигналы, регистрируемые в процессе эксплуатации контролируемого прибора.

Диаграммы PCA, MDS и tSNE распределения термограмм в совокупности с дополнительными параметрами для пяти классов технического состояний контролируемого прибора представлены на рисунках 2.11 – 2.13 соответственно.



Рисунок 2.11 - РСА диаграмма для пяти классов технического состояния контролируемого прибора определяемых по термограммам и дополнительным параметрам, регистрируемым в процессе эксплуатации контролируемого прибора



Рисунок 2.12 - MDS диаграмма для пяти классов технического состояния

контролируемого прибора



Рисунок 2.13 - tSNE диаграмма для пяти классов технического состояния контролируемого прибора

Из диаграмм следует, что две пары технических состояний контролируемого прибора, каждой из которых соответствует по одной типовой термограмме, трудно

разделимы. Фактически они едва разделимы даже визуально на представленных диаграммах.

Вывод: наивная реализация ИНС, где термограммы вместе со значениями доп. параметров подаются на один вход – это не лучшая архитектура ИНС для данной задачи технического диагностирования.

Это обстоятельство служит обоснованием того, что вторая ветвь ДНС, принимающая на вход дополнительные сигналы, измеряемые в контролируемом приборе, объединяется с главной ветвью в том месте, где главная ветвь уже извлекла из термограммы набор черт в виде вектора. Объединение дополнительных сигналов, измеряемых в процессе эксплуатации, с вектором черт, извлеченных из термограммы конволюционной ветвью, дают в результате совокупность данных, легко разделимых в пространстве обучающей выборки. Для подтверждения этого был выполнен следующий эксперимент.

Аналогично тому, как изначальная выборка термограмм может быть использована для построения диаграмм понижения размерности, совокупность значений вектора черт, извлеченных из термограммы конволюционной ветвью, может быть использована для построения аналогичных диаграмм. На вход обученной конволюционной ветви были поданы термограммы, а на вход вспомогательной ветви поданы дополнительные сигналы (как и в основных экспериментах с ДНС) и сохранены сформированные выходные сигналы соединительного слоя (Y-соединения).

Описывая этот же эксперимент другими словами, у исходной ДНС временно был убран последний слой, выполняющий классификацию, и при подаче термограмм и дополнительных сигналов на ДНС были сохранены все выходные сигналы, получаемые на выходе из соединительного слоя (Y-соединение).

72
Полученная совокупность зарегистрированных сигналов была проанализирована теми же методиками понижения размерности: MDS, PCA, tSNE. Полученные диаграммы представлены на рисунках 2.14 – 2.16.



Рисунок 2.14 – Двух и трех компонентные РСА диаграммы для пяти классов технического состояния прибора



Рисунок 2.15 - Двух и трех компонентные MDS диаграмма для пяти классов технического состояния прибора



Рисунок 2.16 - Двух и трех компонентные tSNE диаграмма для пяти классов состояния контролируемого прибора

Как видно из диаграмм, приведенных на рисунках 2.14 - 2.16, вектор из 122 черт, извлеченных из изображений термограммы средствами конволюционной ветви ДНС, и объединенный с дополнительными параметрами, регистрируемыми в процессе эксплуатации контролируемого прибора, которые обработаны вспомогательной ветвью, достаточно хорошо разделим.

Можно сделать следующий вывод:

- исследуемая задача классификации состояний решаема с помощью предложенной архитектуры ДНС,

- объединения сигналов двух ветвей ДНС должна располагаться именно так, как предлагается в настоящей работе.

2.6 Анализ метрологических характеристик ИИИС ТД

В этом пункте проведен метрологический анализ измерительных каналов ИИ-ИС с нейронной сетью, выполняющей интеллектуальный анализ и принятие решений по диагностике состояний радиоэлектронных приборов.

2.6.1 Исследование факторов, влияющих на погрешности ИИИС ТД

В качестве объекта контроля рассматривается радиоэлектронный прибор, находящийся в конструктиве системы и функционирующий в штатном или испытательном режиме. Внутри прибора находится *n* точечных источников тепла $q^n(x_n, y_n, t)$, которые формируют температурное поле на поверхности прибора.

Использование искусственной нейронной сети (ИНС) в измерительном канале интеллектуальной ИИС ТД заставляет рассматривать ИНС в новом ключе. Поскольку в измерительный канал интеллектуальной ИИС ТД входит искусственная нейронная сеть, то встает вопрос оценки погрешности ИНС при выполнении ею классификации технических состояний объекта. В современных публикациях уже поднималась проблема рассмотрения ИНС с точки зрения классической метрологии [35, 40, 64]. Однако в случае применения ИНС для классификации термограмм существуют свои особенности.

В первую очередь, будем рассматривать систематические погрешности измерительных каналов, компонентами которых являются инструментальные и методические погрешности.

Относительная систематическая погрешность бсис определялась по формуле

$$\delta_{cuc} = \delta_{H} + \delta_{M},$$

где δ_{u} – инструментальная погрешность ИНС,

δ_м – методическая погрешность ИНС.

2.6.2 Инструментальные погрешности каналов

Под инструментальной погрешностью искусственной нейронной сети понимается погрешность работы аппаратного обеспечения, выполняющего программную логику, реализующую ИНС. В некоторых работах подробно исследованы инструментальные погрешности искусственной нейронной сети и показано, что для каждого отдельно взятого входного сигнала будет формироваться один и тот же выходной сигнал ИНС (при округлении значений выходного сигнала до двух знаков после запятой). Поэтому в проводимых экспериментах эта составляющая погрешности, связанная с программной реализацией, принимается равной нулю [44, 71].

Структурные модели процессов измерений в измерительных каналах для анализа электронного прибора по термограммам представлены на рисунке 2.17.

Номинальная функция преобразования при измерении температурного поля поверхности [52, 82]

$$\Theta_{\mu_{3M}}^{HOM}(x, y) = S_W S_{MT} S_T W - S_{\mu_T} S_{A \mu_{1} \mu} t_{OC} , \qquad (2.1)$$

где S_W – функция преобразования электрической мощности *W*, поступающей на входы прибора, в двумерное температурное поле $\Theta(x,y)$ на контролируемой поверхности;

 $S_{\rm MT}$ – чувствительность канала передачи температурного поля поверхности прибора на оптическую воспринимающую плоскость тепловизора; $S_{\rm T}$ – чувствительность тепловизора; $S_{{\cal A}T}$ - чувствительность первичного преобразователя датчика температуры t_{OC} окружающей среды; $S_{{\cal A}{\cal U}\Pi}$ – чувствительность аналого-цифрового преобразователя в канале измерения окружающей среды.

Первый измерительный канал с входным сигналом *W* осуществляет определение температурного поля $\Theta_T(x, y)$ поверхности прибора. Второй канал измеряет температуру окружающей среды $t_{\rm OC}$ для дальнейшего вычисления перегрева точек поверхности $\Theta_P^{H3M}(x, y) = \Theta_T - \Theta_{OC}$.



Рисунок 2.17 - Структурные модели измерительных каналов для измерения величин, описывающих техническое состояние микросхемы

Множество *V* дополнительно измеряемых величин в микросхеме матрицы ПЗС содержит три компоненты:

 $V_{1} = F_{C_{HX}}$ - частота синхронизирующих сигналов,

 $V_2 = F_{B_{blx}}$ - частота выходных сигналов,

 $V_3 = U_{Bx}$ - напряжение входных управляющих сигналов.

Номинальные функции преобразования для компонентов вектора V:

$$F_{IJ3M.CHx}^{HOM} = S_{IIIIY1} S_{TK1} F_{CHx}, \qquad (2.2)$$

$$F_{II3M.Bbix}^{HOM} = S_{\Pi\Pi\Psi 2} S_{TK2} F_{Bbix} , \qquad (2.3)$$

$$U_{\mu_{3M},Bx}^{HOM} = S_{\mu_{1}\mu_{1}}S_{AL}U_{Bx}, \qquad (2.4)$$

где $S_{ППЧ1}$, $S_{ППЧ2}$, $S_{ППH}$ - чувствительности первичных измерительных преобразователей ППЧ1 и ППЧ2 частот и входного напряжения управляющих сигналов ППН; S_{TK1} , S_{TK2} , S_{TK3} - чувствительности телеметрических каналов передачи соответствующих измеряемых параметров; $S_{AЦПH}$ – чувствительность функции преобразования аналого-цифрового преобразователя в канале измерения входного напряжения.

Реальные функции преобразования для модели на рисунке 2.17 имеют вид:

а) Измерение термограммы

$$\Theta_{P}^{H3M}(x, y) = S_{T}(1 + \delta_{T}) \{ (\Delta_{CX} + \Delta_{CY} + \Delta_{OT} + \Delta_{OKT} + S_{MT}S_{W}(1 + \delta_{MT})(1 + \delta_{W})W \} + \Delta_{T} - S_{AUT}(1 + \delta_{AUT})(S_{T}(1 + \delta_{T})t_{OC} + \Delta_{T}) - \Delta_{KB}, \qquad (2.5)$$

б) Измерение частотных сигналов

$$F_{\mu_{3M,C_{HX}}} = S_{TK1} (1 + \delta_{TK1}) (\Delta_{\mu_{1}\mu_{1}} + S_{\mu_{1}\mu_{1}} (1 + \delta_{\mu_{1}\mu_{1}}) F_{C_{HX}}) + \Delta_{TK1} , \qquad (2.6)$$

$$F_{H3M,B_{blx}} = S_{TK2} (1 + \delta_{TK2}) (\Delta_{\Pi\Pi 42} + S_{\Pi\Pi 42} (1 + \delta_{\Pi\Pi 42}) F_{B_{blx}}) + \Delta_{TK2} , \qquad (2.7)$$

в) Измерение амплитуды напряжения входных сигналов

$$U_{\mu_{3M,Bx}} = S_{TK3}(1 + \delta_{TK3})(S_{AUTH}(1 + \Delta_{AUTH})(S_{IIIIH}(1 + \delta_{IIIIH})U_{Bx} + \Delta_{IIIIH}) + \Delta_{AUTI}) + \Delta_{TK3}.$$
(2.8)

Погрешности, входящие в выражения (2.5) – (2.8), сведены в таблицы 2.1 и 2.2.

Погрешность измерения термограммы поверхности контролируемого прибора равна

$$\Delta \Theta = \Theta_P^{H3M} - \Theta_{H3M}^{HOM},$$

подставляя сюда выражения (2.1) и (2.5), получаем

$$\Delta \Theta = (\delta_W + \delta_{MT} + \delta_T) S_W S_{MT} S_T W + (\delta_{\mathcal{A}T} + \delta_{\mathcal{A}\mathcal{U}\mathcal{I}}) S_{\mathcal{A}T} S_{\mathcal{A}\mathcal{U}\mathcal{I}} t_{\mathcal{O}C} + S_T (\Delta_{CX} + \Delta_{CY} + \Delta_{OT} + \Delta_{OKT}) - S_{\mathcal{A}\mathcal{U}\mathcal{I}} \Delta_{\mathcal{A}T} - \Delta_T - \Delta_{KB} , \qquad (2.9)$$

при этом погрешности считаются скалярными величинами, а их произведения приближенно равными нулю.

Таблиц	a 2.1 - My.	пьтипликати	ивные погр	ешности,	учитываем	ые в
метроло	огической	модели ИИ	ИС			

Номер	Условное	Описание мультипликативной погрешности
уравнения	обозначение	
2.5	δ_W	Погрешность, вызванная изменением электриче-
		ских, теплофизических и конструктивных пара-
		метров при изготовлении серии микросхем
2.5	δ_{MT}	Погрешность чувствительности канала передачи
		термограммы на оптическую плоскость матрицы
		тепловизора
2.5	δ_T	Мультипликативная погрешность тепловизора
2.5	$\delta_{\mathcal{A}T}$	Погрешность первичного преобразователя датчи-
		ка температуры окружающей среды
2.5	$\delta_{A \amalg \Pi}$	Мультипликативная погрешность преобразования
		аналог-код в АЦП
2.6	$\delta_{\Pi\Pi \Psi I}$	Погрешность первичного преобразователя изме-
		рения частоты синхронизирующих сигналов
2.6	δ_{TKI}	Погрешность канала передачи телеметрической
		информации о частоте синхронизирующих сигна-
		ЛОВ
2.7	$\delta_{\Pi\Pi 42}$	Погрешность первичного преобразователя изме-
		рения частоты выходных сигналов
2.7	δ_{TK2}	Погрешность канала передачи телеметрической
		информации о частоте выходных сигналов
2.8	$\delta_{\Pi\Pi H}$	Погрешность первичного преобразователя изме-
		рения входных управляющих сигналов
2.8	$\delta_{A \amalg \Pi H}$	Мультипликативная погрешность преобразования
		напряжения в код в АЦП
2.8	δ_{TK3}	Погрешность канала передачи телеметрической
		информации об амплитуде входных управляю-
		щих сигналов

Таблица 2.2 - Аддитивные погрешности, учитываемые в метрологической модели ИИИС

Номер	Условное	Описание аддитивной погрешности
уравнения	обозначение	
2.5	Δ_{CX}, Δ_{CY}	Погрешности установки тепловизора, которые
		определяются горизонтальными смещениями
		относительно центральной оптической оси, пер-
		пендикулярной к поверхности контролируемого
		прибора
2.5	Δ_{OT}	Погрешность, вызванная угловым отклонением
		оптической оси тепловизора от поверхности
		контролируемого прибора
2.5	Δ_{OKT}	Погрешность, вызванная отраженной кажущей-
		ся температурой других объектов
2.5	Δ_T	Аддитивная погрешность тепловизора
2.5	$\Delta_{\mathcal{Д}T}$	Погрешность первичного преобразователя дат-
		чика температуры окружающей среды
2.5	Δ_{KB}	Погрешность квантования, определяемая раз-
		рядностью АЦП
2.6	$\Delta_{\Pi\Pi\Psi I}$	Аддитивная погрешность измерения частоты
		F _{CHX}
2.6	Δ_{TKI}	Погрешность телеметрического канала частоты
		синхронизирующих сигналов
2.7	$\Delta_{\Pi\Pi 42}$	Аддитивная погрешность измерения частоты
		F _{Bblx}
2.7	Δ_{TK2}	Погрешность телеметрического канала частоты
		выходных сигналов
2.8	$\Delta_{\Pi\Pi H}$	Аддитивная погрешность измерения амплитуды
		входных управляющих сигналов
2.8	$\Delta_{A \downarrow I I I}$	Погрешность квантования АЦП
2.8	$\Delta_{\mathrm TK3}$	Погрешность телеметрического канала напря-
		жений входных управляющих сигналов

Из выражения (2.9) следует, что мультипликативная погрешность измерения термограмм определяется, как

$$\delta \Theta_{H3M}^{M} = (\delta_{W} + \delta_{MT} + \delta_{T}) S_{W} S_{MT} S_{T} W + (\delta_{\mathcal{A}T} + \delta_{\mathcal{A}\mathcal{U}\mathcal{I}}) S_{\mathcal{A}T} S_{\mathcal{A}\mathcal{U}\mathcal{I}} t_{OC} .$$
(2.10)

Соответственно, аддитивная погрешность равна

$$\Delta \Theta_{IJ3M}^{A} = S_{T} (\Delta_{CX} + \Delta_{CY} + \Delta_{OT} + \Delta_{OKT}) - S_{AUII} \Delta_{AT} - \Delta_{T} - \Delta_{KB} . \qquad (2.11)$$

Погрешности измерения частотных сигналов прибора равны

$$\Delta F_{CHX} = F_{IJ3M.CHX} - F_{IJ3M.CHX}^{HOM} , \qquad (2.12)$$

$$\Delta F_{B_{blx}} = F_{II3M,B_{blx}} - F_{II3M,B_{blx}}^{HOM} . \tag{2.13}$$

Выполняя аналогичные подстановки выражений (2.2) и (2.6) в (2.12) и (2.3), а (2.7) в (2.13), получаем мультипликативные погрешности измерений

$$\delta F^{M}_{IJ3M.Chx} = (\delta_{\Pi\Pi 41} + \delta_{TK1}) S_{TK1} S_{\Pi\Pi 41} F_{Chx},$$

$$\delta F^{M}_{IJ3M.Bbix} = (\delta_{\Pi\Pi 42} + \delta_{TK2}) S_{TK2} S_{\Pi\Pi 42} F_{Bbix},$$

и аддитивные погрешности

$$\Delta F^{A}_{IJ3M,C_{HX}} = S_{TK1} \Delta_{\Pi\Pi II1} + \Delta_{TK1},$$

$$\Delta F^{A}_{IJ3M,B_{bIX}} = S_{TK2} \Delta_{\Pi\Pi II2} + \Delta_{TK2} .$$

Погрешность измерения амплитуд входных управляющих сигналов U_{Bx} определяется аналогичным образом. Соответственно, мультипликативная составляющая погрешности

$$\delta U^{M}_{\mu_{3M,Bx}} = (\delta_{\Pi\Pi H} + \delta_{A \mu \Pi H} + \delta_{TK3}) S_{TK3} S_{A \mu \Pi H} S_{\Pi\Pi H} U_{Bx}$$

и аддитивная составляющая равна

$$\Delta U^{A}_{\mathcal{H}3M,\mathcal{B}x} = S_{\mathcal{T}\mathcal{K}3}S_{\mathcal{A}\mathcal{L}\mathcal{I}\mathcal{I}\mathcal{H}}\Delta_{\mathcal{I}\mathcal{I}\mathcal{I}\mathcal{H}} + S_{\mathcal{T}\mathcal{K}3}\Delta_{\mathcal{A}\mathcal{L}\mathcal{I}\mathcal{I}} + \Delta_{\mathcal{T}\mathcal{K}3} \quad .$$

В таблице 2.3 приведены рассчитанные значения погрешностей для измерительного канала с тепловизором.

Погрешность	Значение
δ_{W}	±0.0668%
δ _{MT}	±0,003%
$\delta_{ m ALI\Pi}$	±0,02%
δ _{ДΤ}	$\pm 0,05^{0}C$
$\delta_{ m T}$	±0,002%
Δ_{T}	0,35° C
Δ_{KB}	$\pm 0,01^{0}$ C
$\Delta_{CX} = \Delta_{CY}$	$\pm 0,03^{0}C$
Δ_{OT}	$\pm 0,027^{0}C$
$\Delta \Theta^A_{_{\mathcal{U}\mathcal{S}\mathcal{M}}}$	$\pm 0,5^{\circ}C$
$\partial \Theta_{_{U3M}}$	$\pm 0,033^{\circ}C$
$\Delta \Theta$	$\pm 0,533^{0}C$

Таблица 2.3 - Погрешности измерительного канала с тепловизором

2.6.3 Анализ методической погрешности ДНС в составе ИИИС ТД

Использование расчетных термограмм при обучении ИНС вместо большого множества реальных термограмм приводит к методической погрешности $\Delta_{\rm M}$ определения технического состояния объекта при дальнейшей эксплуатации ИИИС. Основными факторами, влияющими на ее величину, являются:

• погрешность модели вычислительного метода решения нестационарного уравнения теплопроводности, а также погрешности дискретизации и округления,

• разброс теплофизических параметров прибора,

- вариативность геометрических параметров прибора,
- влияние архитектуры нейронной сети,
- влияние характера данных, обрабатываемых нейронной сетью,
- выбор способа и параметров обучения нейронной сети.

Метрологическая модель канала с двухветвенной нейронной сетью для формирования модельных термограмм, в которой учтены методические погрешности, представлена на рисунке 2.18.

Оценка относительной методической погрешности δ_M определяется как:

$$\delta_{M} = \sqrt{\delta_{CT}^{2} + \delta_{\mathcal{A}}^{2} + \delta_{OE}^{2}},$$

где δ_{CT} – методическая погрешность, вносимая структурой ИНС;

δ_Д – погрешность, определяемая зашумленностью данных;

δ_{*OF*} – погрешность, определяемая способом обучения нейронной сети.

Поскольку модельные термограммы получены путем решения нестационарного уравнения теплопроводности методом трехдиагональной прогонки, при анализе будем рассматривать составляющие методической погрешности, которые сведены в таблицу 2.4.

В метрологической модели приняты следующие обозначения: $S_{MM} = S_{\lambda}S_{\rho}S_{c}S_{\alpha}S_{\varepsilon}$ – функция преобразования в математической модели параметров прибора в тепловое состояние, зависящая от значений теплофизических параметров прибора; S_{4M} – функция преобразования в численном методе решения уравнения теплопроводности; S_{MHC} – функция преобразования двухветвенной ИНС; δ_{MM} , δ_{4M} , Δ_{4MC} – мультипликативные и аддитивные погрешности соответственно математической модели, численного метода и искусственной нейронной сети.



Рисунок 2.18 – Структурная модель канала с ИНС для классификации термограмм

Условное	Описание погрешности
обозначение	
	Составляющие погрешности Δ_{4M}
$\Delta_{ au}$	Погрешность от шага по времени т
$\Delta_{ m JC}$	Погрешности дискретизации
$\Delta_{ m O}$	Погрешность округления
Δ_h	Погрешность от шага <i>h</i> по сетке разностной модели
	Составляющие погрешности б _{ММ}
δ	Мультипликативная погрешность неоднородности теп-
	лопроводности материала или отличия принятого при
	расчете значения 🛛 от реального
$\delta_{ ho}$	Мультипликативная погрешность неоднородности плот-
	ности р материала
δ_C	Мультипликативная погрешность неоднородности удель- ной теплоемкости <i>с</i> материала
δ_{α}	Мультипликативная погрешность от различия коэффици-
	ента конвективного теплообмена α по поверхности при-
	бора
δ_{ϵ}	Мультипликативная погрешность от различия коэффици-
	ента теплового излучения є по поверхности прибора
	Составляющие общей аддитивной погрешности Δ_{MM}
Δ_{Qx} , Δ_{Qy} , Δ_{Qz}	Погрешности смещения реальных координат источника
	с мощностью $Q(x,y,z)$ от расчетного источника с коорди-
	натами $Q(x_0, y_0, z_0)$ при численном решении уравнения те-
	плопроводности

Таблица 2.4 - Методические погрешности

Используя аналогичный подход, определяем общее выражение для методической погрешности канала, включающего математическую модель и программную реализацию численного метода:

$$\Delta \Theta^{M} = (\delta_{\lambda} + \delta_{\rho} + \delta_{c} + \delta_{\alpha} + \delta_{\varepsilon} + \delta_{q_{M}})S_{\lambda}S_{\rho}S_{c}S_{\alpha}S_{\varepsilon}S_{q_{M}}W + (\Delta_{Qx} + \Delta_{Qy} + \Delta_{Qz})S_{q_{M}} + \Delta_{h} + \Delta_{\tau} + \Delta_{\mathcal{AC}} + \Delta_{O}.$$

$$(2.14)$$

Из выражения (2.14) можно получить мультипликативную и аддитивную составляющие методической погрешности.

Проблема возникает с определением погрешностей, вносимых ИНС, поскольку в настоящий момент нет общепринятых методик для их оценки. В работе [36] предлагается считать погрешность вносимую аппаратным обеспечением, выполняющим программную логику ИНС, пренебрежимо малой величиной по сравнению с погрешностью, обусловленной качеством обучения и выбранной архитектурой ИНС. Однако, такой подход может привести к недооценке как собственных погрешностей нейронов в сети, так и возможному увеличению результирующей погрешности на выходе нейронной сети за счет передачи погрешностей входных сигналов.

Будем использовать подход к расчету погрешностей ИНС, предложенный в работах [45, 72].

Подход заключается в учете собственных погрешностей нейронов и нахождении выражений для зависимости выходной погрешности ИНС от погрешностей на входах сети. Нейрон рассматривается как последовательное соединение двух блоков: нелинейного преобразователя функции активации и сумматора входных сигналов с соответствующими весовыми коэффициентами (рисунок 2.19).



Рисунок 2.20 – Стандартный нейрон

Дисперсия ошибки выходного сигнала нелинейного преобразователя равна

$$\sigma_{\rm GBLX,\varphi}^2 = \left(\frac{d\varphi}{dv}\right)^2 \sigma_{\rm GX,\varphi}^2,$$

и для сумматора

$$\sigma_{\rm \tiny Gbix.\Sigma}^2 = \sum_i w_i^2 \sigma_i^2.$$

Результирующее выражение входных и выходных дисперсий нейрона имеет вид:

$$\sigma_{\rm Gblx,\phi}^2 = \left(\frac{d\varphi}{dx}\right)^2 \sum_i w_i^2 \sigma_i^2.$$

Аналогичные рассуждения и преобразования используются при учете собственных погрешностей элементов нейрона.

Для нелинейного преобразователя выходной сигнал представим, как

$$y_j = \varphi(v) + \varepsilon_{\varphi},$$

где v - значение активации нейрона j, ε_{φ} - погрешность преобразования функции активации.

Дисперсия выходного сигнала равна

$$D(\varphi(v+\varepsilon)+\varepsilon_{\varphi}=\sigma_{\varphi.6bx}^{2}+\left(\frac{d\varphi}{dv}\right)^{2}\sigma_{\varphi.6x}^{2}.$$

Для сумматора имеем уравнение

$$v_j = \sum_i w_i^2(x_i + \varepsilon_i) + \varepsilon_{\Sigma},$$

где ε_{Σ} - собственная погрешность сумматора.

Тогда дисперсия выходного сигнала сумматора нейрона равна

$$\sigma_{\Sigma.Gbix}^2 = D(\sum_i w_i \varepsilon_i + \varepsilon_{\Sigma}) = \sum_i w_i^2 \sigma_i^2 + \sigma_{\Sigma}^2.$$

Из полученных ранее выражений следует общее выражение для значения дисперсии выходного сигнала нейрона:

$$\sigma_{\rm Gbax}^2 = \left(\frac{d\varphi}{dv}\right)^2 \left(\sum_i w_i^2 \sigma_i^2 + \sigma_{\Sigma}^2\right) + \sigma_{\varphi}^2,$$

и при равенстве дисперсий входных погрешностей σ_i^2 получаем соотношение, связывающее погрешность выходного сигнала нейрона с погрешностью его входных сигналов:

$$\sigma_{ex.i}^{2} = \left(\frac{\sigma_{ebix}^{2} - \sigma_{\varphi}^{2}}{\left(\frac{d\varphi}{dv}\right)^{2}} - \sigma_{\Sigma}^{2}\right) / \sum_{i} w_{i}^{2}.$$
(2.15)

Выражение (2.15) позволяет провести обратный проход от выхода нейронной сети к ее входам, последовательно вычисляя погрешности нейронов на этом пути. В результате можно оценить по допустимой выходной погрешности ИНС требуемые дисперсии погрешностей входных сигналов сети.

Влияние архитектуры нейронной сети

Одним из важных факторов, влияющих на точность классификации в ИНС, является соответствие ее архитектуры выполняемой задаче обработки данных. На сегодняшний день известно достаточно большое количество модификаций ИНС, каждая из которых в той или иной степени подходит для решения какой-либо отдельно взятой категории задач. Формального критерия применимости некоторой модификации ИНС для обработки тех или иных данных, к сожалению, нет. Систематизируя экспериментальные данные, накопленные в различных публикациях [107, 109, 115], можно сформулировать критерии применимости некоторых типов ИНС, наиболее хорошо показавших себя при решении определенной группы задач.

Для рассматриваемой задачи анализа термограмм примером учета влияния архитектуры ИНС на получаемую точность классификации является выбор конволюционной нейронной сети вместо полносвязной. Известен ряд особенностей конволюционных нейронных сетей, которые делают их более производительными в ряде задач, связанных с обработкой изображений [8, 12]. Конволюционные нейронные сети дают более устойчивые результаты при классификации изображений, подвергнутых аффинным преобразованиям. Этого нельзя сказать про полносвязанные нейронные сети.

В качестве примера можно привести результаты следующего эксперимента. Полносвязная ИНС была обучена на некоторой выборке термограмм. Затем эти термограммы были подвергнуты аффинным преобразованиям, в частности, повороту на незначительный угол (5-10 градусов). При попытке классифицировать новые термограммы с помощью полносвязной ИНС, было получено значительное уменьшение доли точных классификаций. В этом случае разница между количеством точных классификаций, выполненных конволюционной ИНС и полносвязной сетью, интерпретировалась как методическая погрешность влияния архитектуры, связанная с применением полносвязной ИНС для решения задач классификации термограмм.

Влияние характера данных

Как отмечается в [111], при машинном обучении вид используемых данных так же важен, как и алгоритм, применяемый для их обобщения. Как известно, набор данных характеризуют понятием зашумленность [2]. В этом случае под шумом понимают наличие какой-либо области в пространстве обучающей или тестовой выборки, где представлены образцы нескольких классов, неразделимых прямой (общем случае, гиперплоскостью в *n*-мерном пространстве).

Анализируя данные в выборке, можно определить долю образцов выборки, находящихся в подобных областях. Это позволяет приблизительно оценить порог точности работы ИНС, обученной на этой выборке, т.к. образцы, представляющие собой шум, скорее всего, будет вносить ошибку в работу сети. Это служит основанием для приводимых далее формул, позволяющих выполнить приблизительную количественную оценку минимально возможной методической погрешности ИНС, обученной на рассматриваемой выборке.

Для оценки выборки и выделения отдельных зашумленных областей применялся метод снижения размерности исследуемого признакового пространства Dimensionality reduction [113].

Оценка относительной методической погрешности $\delta_{\mathcal{A}}$, вызываемой зашумленности данных, может быть определена по выражению:

$$\delta_{\mathcal{I}} = N_m / N,$$

где N_m – выделенное число элементов обучающей выборки, находящихся в зашумленной области;

N - общее число элементов обучающей выборки.

Влияние качества обучения нейронной сети

Помимо вышеизложенных аспектов, процесс обучения ИНС носит не менее важный характер. Выбор параметров обучения (число эпох, темп обучения и т.п.) вносит свой вклад в качество итоговой обученной ИНС, что в свою очередь неизбежно влияет на ее точность. Поэтому справедливо отметить, что корректный подбор этих параметров влияет на величину итоговой методической погрешности, вносимой ИНС.

Методическая погрешность, вызываемая влиянием структуры ИНС и качеством обучения, может оцениваться разными способами. Как уже отмечалось выше, можно сопоставлять точность сети путем сравнения с точностью какой-либо широко известной сети. Так часто поступают на практике в публикациях, анонсирующих какую-либо новую ИНС [115].

Альтернативно можно выполнить сравнение доли ошибочных классификаций нейронной сети со значением зашумленности данных, полученных при их статистическом анализе. Заранее можно предположить, что ИНС будет ошибочно классифицировать данные, принадлежащие зашумленной этой части выборки. Таким образом, получаем меру приближенности точности ИНС к максимально возможной на рассматриваемой выборке.

Суммарная методическая погрешность, вносимая структурой ИНС и качеством обучения, может быть оценена по формуле:

$$\delta_{CT} + \delta_{OE} \le \delta_T - \delta_{\mathcal{A}}, \qquad \delta_T > \delta_{\mathcal{A}}, \qquad (2.16)$$

где δ_{OE} – методическая погрешность, вносимая качеством обучения ИНС,

 δ_T – погрешность ИНС, оцененная на тестовой выборке.

Если будет получено $\delta_T \leq \delta_A$, это может быть признаком допущенных ошибок в эксперименте. Например, тестовая выборка была составлена нерепрезентативно.

Относительная погрешность ИНС, оцененная на тестовой выборке, определяется из соотношения:

$$\delta_T = P_e / P_e$$

где *P_e* – число ошибочно выполненных классификаций ИНС,

P – суммарное число выполненных классификаций ИНС, равное числу элементов тестовой выборки.

При оценке ИИС с нейронной сетью в ее составе в дальнейшем используется следующее определение.

Точность ИНС, как классификатора, оцененная на тестовой выборке, равна:

Accuracy =
$$P_T/P = 1 - \delta_{\text{MHC}}$$
,

где P_T - доля анализируемых термограмм, по которым ИНС приняла

правильное решение при обработке Р термограмм,

 $\delta_{\text{ИHC}}$ - основная погрешность ИНС.

Для учета пропусков и ложных оценок используется таблица контингентности (таблица 2.5).

Таблица 2.5 – Таблица	контингентности для	<i>k</i> -го класса дефекта
-----------------------	---------------------	-----------------------------

		Экспертная оценка		
		Положительная	Отрицательная	
		(дефект есть)	(дефекта нет)	
	Дефект есть	TP	FP	
Оценка,	-		Ошибки 1 рода	
выполненная	Дефекта нет	FN	TN	
ИНС	-	Ошибки 2 рода		

Величины в таблице имеют следующий смысл: *TP*- истинно-положительное решение, *TN* – истинно-отрицательное решение, *FP* – ложно-положительное решение, *FN* – ложно-отрицательное решение.

Тогда точность классификации

Precision=TP/(TP+FP),

и полнота классификации

Описанный подход был применен для оценки погрешности классификации отказов, выполняемой конволюционной ИНС при обработке термограмм в различных предметных областях. Экспериментальные результаты описаны в четвертой главе.

Выводы по главе 2

1. Разработана структура ИИИС тепловизионного диагностирования электронных приборов, основанная на предложенном методе интеллектуализации. Ключевым элементом в этой структуре является новый нейросетевой программный анализатор, представляющий собой глубокую двухветвенную нейронную сеть в виде комбинации конволюционной и полносвязной сетей.

2. Показано, что использование модельных термограмм приводит к некорректной обратной задаче классификаций технических состояний объекта. Для перехода к условно-корректной задаче предложено использовать в нейросетевом программном анализаторе ограниченный набор дополнительно измеряемых параметров объекта.

3. На основе анализа существующих разновидностей нейронных сетей сделан вывод: для задачи классификации термограмм электронных приборов наиболее подходит глубокая конволюционная сеть. Показано, что для анализа дополнительно измеряемых параметров объекта контроля целесообразно использовать полносвязную нейронную сеть.

4. Для анализа достоверности сформированной обучающей выборки термограмм предложено использовать методики снижения размерности: метод главных компонент, многомерное шкалирование и Т-распределенное стохастическое встраивание соседей.

5. Проведен метрологический анализ измерительных каналов ИИИС ТД с нейронной сетью. Выполнен анализ инструментальных погрешностей, при этом показано, что основной канал измерения термограмм с помощью тепловизора обеспечивает основную приведенную погрешность не более 0,5%. Исследованы факторы, определяющие методическую погрешность, вносимую нейронной сетью в процесс классификации термограмм. Сделан вывод, что основным фактором является зашумленность исходных термограмм, используемых при обучении.

З ПРОЕКТИРОВАНИЕ ПРОГРАММНОЙ РЕАЛИЗАЦИИ НЕЙРОННОЙ СЕТИ ДЛЯ ИНФОРМАЦИОННО-ИЗМЕРИТЕЛЬНОЙ СИСТЕМЫ ТЕПЛОВИЗИОННОГО ДИАГНОСТИРОВАНИЯ

3.1 Объектно-ориентированная декомпозиция логики искусственных нейронных сетей

Использование искусственных нейронных сетей (ИНС) стало прорывом во многих областях машинного обучения и искусственного интеллекта [10, 116].

В этой связи актуальна разработка различных подходов к проектированию ИНС. Во многих проектах необходимо наличие программной библиотеки, предоставляющей ИНС таким образом, чтобы можно было гибко варьировать и расширять ее функциональность. Это, в свою очередь, достижимо только в случае рационального проектирования логики ИНС. В этом плане задачи реализации ИНС не отличаются от какого-либо другого проекта, связанного с разработкой программного обеспечения [95].

В настоящее время разработано большое число программных реализаций нейронных сетей. При этом во многих реализациях получены эффективные решения, которые целесообразно использовать в дальнейших разработках. В тоже время отсутствует методологический подход, который бы опирался на эффективные приемы объектно-ориентированного проектирования и использовал накопленные знания в области искусственных нейронных сетей.

В диссертационной работе используется объектно-ориентированный подход к анализу логики искусственных нейронных сетей. Задачей исследования является построение онтологического паттерна на основе структурной и функциональной декомпозиции логики обработки информации в ИНС [10, 96]. Совокупность реализаций ИНС, доступных в исходных кодах, можно условно разделить на две большие группы. К первой относятся реализации специализированной платформы для алгоритмов машинного обучения, в числе и ИНС [96, 97].

Во вторую группу входят библиотеки, которые не используют каких-либо сторонних платформ, и именно они рассматриваются в данной публикации. Выполненная авторам имплементация ИНС, также не использует сторонних платформ для алгоритмов машинного обучения, и выполнение кода осуществляется непосредственно на CLR [121].

В силу актуальности тем, связанных с использованием ИНС, в настоящее время существует большое число примеров их исходных кодов. Многие из программных библиотек, доступных в исходных кодах, выделяют класс нейронной сети, на который возложено хранение перечня слоев. Этот класс инкапсулирует логику взаимодействия данных слоев для обеспечения прямого и обратного прохождения сигнала. Некоторые варианты реализации также добавляют в логику нейронной сети функциональность, обеспечивающую сбор и обработку основной статистики, накапливаемой при обучении нейронной сети. Интересно отметить, что с определенной точки зрения, подобное совмещение может противоречить принципу единственности ответственности.

Реализация ИНС в программной библиотеке Caffe, доступная в исходном коде на языке C++, содержит богатую палитру различных имплементаций слоев нейронов ИНС. Эти слои удобно взаимно заменять, получая новую функциональность ИНС, обеспеченную набором слоев с заданными характеристиками, такими как функция активации, принцип, по которому сигнал корректируется на вес синоптической связи, и др. [132].

Хорошо известно, что нейронные сети широко варьируются по своей структуре, принципу передачи сигнала между слоями, применяемым функциям активации и другим характеристикам. Программная библиотека, описанная в работе И. Василье-

95

ва, обеспечивает реализации ИНС на языке Java при едином технологическом подходе к сетям разной структуры [130].

При всем многообразии различных подходов к имплементации ИНС возможно консолидировать основные идеи, заложенные в них и, в целом, сформулировать общий подход к декомпозиции логики ИНС.

3.1.1 Структурная и функциональная декомпозиция логики ИНС

Рассматривая всю совокупность логики ИНС, можно выделить следующие основные структурные компоненты [20]:

• *Функция активации*. Она может быть представлена в виде сущности, инкапсулирующей логику, связанную с функцией активации. Эта сущность содержит данные о параметрах функции активации и логику вычисления ее значений и ее производной.

• Функция ошибки. Эта сущность применяется при обучении ИНС. Для тренировки ИНС применяет подход, который в области машинного обучения именуется «Обучение с учителем». В ходе этого процесса вместе с входным сигналом доступны сведения об ожидаемом выходном сигнале, который возможно сравнить с фактически полученным сигналом. Оценку величины расхождения эталонного результата и фактического оценивают с использованием функции ошибки для определения величины, на которую необходимо скорректировать веса синаптических связей.

• Слой нейронов ИНС. Он может быть представлен в виде сущности, инкапсулирующей логику работы совокупности искусственных нейронов, находящихся на одном слое ИНС. Он обеспечивает хранение значений весов синаптических связей и содержит логику вычисления поля индуцирования (передаваемого функции активации) на основании входного сигнала. Поскольку данная логика использует функцию активации, каждый слой содержит хотя бы один объект функции активации.

• *Нейронная сеть*. Может быть представлена в виде совокупности одного или нескольких слоев искусственных нейронов вместе с логикой их взаимодействия (передача сигнала в процессе его прямого и обратного прохождения, хранение значений предыдущих сигналов при необходимости и прочая подобная логика). Нейронная сеть для своего функционирования должна содержать хотя бы один слой нейронов.

В то же время, рассматривая функциональную организацию логики ИНС, можно выделить следующие уровни:

• Логика прямого прохождения сигнала. Она представляет собой основной режим работы нейронной сети, когда сигнал, поданный на вход ИНС, передается вход функции активации по синаптическим связям с корректировкой на их веса. При этом функция активации, в свою очередь, формирует выходной сигнал отдельно взятого слоя нейронов или ИНС в целом. В конволюционных сетях все нейроны, расположенные на одном слое, используют одинаковые синаптические связи. Это должно учитываться и в логике прямого прохождения сигнала, и в логике корректировки весов при обучении.

• Логика обратного прохождения сигнала ошибки. Эта функциональность применяется для обучения ИНС. При обратном прохождении сигнала выходные значения ИНС сравниваются с эталонным сигналом (который доступен при обучении с учителем) и их расхождение оценивается с использованием функции ошибки. Полученная ошибка на выходном слое передается на предшествующий слой и далее до входного слоя.

• Логика корректировки весов и сдвигов нейронной сети. Подобная корректировка необходима для обучения нейронной сети. Удобно, когда эта логика гибкая и взаимозаменяемая. При этом частная производная функции ошибки использу-

97

ется для определения непосредственно величины, на которую корректируется вес связи или сдвиг. При необходимости имплементация логики ИНС должна выполнять замену используемой функции ошибки.

• Вспомогательная логика. К данной функциональной части можно отнести логику, выполняющую матричные операции, к которым сводится большинство численных преобразований, выполняемых внутри нейронной сети. Например, при использовании концепции глубокого обучения необходимо осуществить предобучение каждого отдельного слоя заданной нейронной сети на базе «Обучение без учителя», с последующим обучением всей ИНС на основе «Обучение с учителем». На стадии предобучения требуется логика, выполняющая анализ структуры заданной нейронной сети, генерацию автоэнкодеров для предобучения каждого слоя и само предобучение со сбором статистики. С целью соблюдения принципа единственности ответственности эта логика инкапсулирована в отдельном классе [100].

В некоторых технических решениях требования таковы, что необходимо использовать уже обученную нейронную сеть, без последующей ее корректировки и дообучения. Для обеспечения эксплуатации нейронной сети в таких условиях важно выполнить группировку функционала, составляющего ИНС, в двух вариантах: функционал, необходимый для эксплуатации и функционал, необходимый для обучения.

Рассматривая выполненную выше структурную декомпозицию, легко заметить, что для проектирования и эксплуатации ИНС достаточно иметь в распоряжении функцию активации, один или несколько слоев нейронной сети и сущность, соответствующую самой нейронной сети. Сущность, соответствующая функции ошибки, требуется только в процессе обучения ИНС.

Функциональная декомпозиция показывает, что для работы ИНС достаточно иметь логику, обеспечивающую прямое прохождение сигнала, в совокупности с некоторой долей вспомогательной логики (например, логики, выполняющей матричные операции). Логика обратного прохождения сигнала и логика корректировки весов синаптических связей требуются только в процессе обучения ИНС.

Используя описанный подход при объектно-ориентированном проектировании, будем разделять логику ИНС на две группы классов:

• классы, инкапсулирующие логику обучаемых ИНС и их компонентов;

• классы, инкапсулирующие логику необучаемых ИНС и их компонентов.

Важно заметить, что обучаемые ИНС в себе содержат логику необучаемых, поэтому эти классы связаны наследованием.

В проводимой декомпозиции выделяется логика нейронов, находящихся на отдельно взятом слое ИНС. Дальнейшая декомпозиция на уровни логики отдельно взятых нейрона не выполняется в силу следующих соображений. На практике в структуре нейронных сетей на отдельно взятом слое используются нейроны схожей конфигурации. Учитывая это, арифметические операции, выполняемые на отдельно взятом слое ИНС, можно выразить и реализовать в коде в виде матричных операций. Некоторые матричные операции, такие как умножение, достаточно ресурсоемки и обладают большой асимптотической сложностью, однако при этом они обладают алгоритмическим параллелизмом. Кроме того, такие вычисления можно выполнять на графических процессорах GPU в рамках концепции GPGPU [112, 126].

3.1.2 Технология проектирования программного кода логики ИНС

Основные принципы, которые использовались при проектировании описываемой реализации ИНС:

• Функциональность отдельно взятой выделенной сущности должна представлять собой логическую целостность для удобства чтения и понимания кода.

• Совокупность выделенных сущностей должна обладать достаточной степенью слабой связанности для обеспечения возможности независимо развивать, тестировать и использовать различные сущности.

99

• Каждый отдельно взятый класс, инкапсулирующий какую-либо логику, должен соответствовать принципу единственной ответственности, то есть быть ответственным за решение какой-либо отдельно взятой задачи и только ее.

В целом, следование этим принципам нацелено на проектирование кода так, чтобы заложенные концепции позволяли удобно компоновать различные ИНС и расширять функционал простым образом (добавление новых функций активации, функций оценки ошибки, поддержка различных конфигураций ИНС и т.п.).

На основании проведенного выше анализа и декомпозиции логики ИНС была выполнена ее имплементация с использованием языка С#.

3.2 Реализация логики ИНС. Шаблон проектирования доменных классов искусственных нейронных сетей

Как известно ошибки, допущенные при проектировании программного обеспечения, обходятся очень дорого. Неудачные решения на начальных этапах архитектурного проектирования могут иметь очень серьезные последствия, которые поставят под вопрос способность реализуемого программного продукта решать поставленную задачу. Исправление ошибок проектирования – существенная многостадийная переработка всего программного продукта. Это обстоятельство обуславливает актуальность разработки различных средств, облегчающих процесс принятия важных проектировочных решений [56].

Совокупность классов, моделирующих сущности предметной области программного проекта, часто именуют системой доменных классов. Будем придерживаться этой терминологии в данной публикации.

Каждый проект индивидуален, и сформулировать рекомендации, общие для всех программных продуктов, было бы утопичным подходом. Однако в современной литературе используют понятие «шаблон проектирования». Под ним понимается совокупность рекомендаций, помогающих эффективно решить задачу проектирования структуры кода или архитектуры программного продукта. Описываемые в статье идеи оформлены в виде шаблона проектирования и проиллюстрированы на примере создания классов, входящих в программную реализацию искусственных нейронных сетей (ИНС) [26, 99].

3.2.1 Шаблон «Проектировочный грид»

Известны публикации, в которых даются рекомендации, как определить, когда следует использовать абстрактный класс, а в каких случаях - интерфейс. В этих рекомендациях отмечается, что нужно решить, к какому виду взаимоотношения относится моделируемая программным кодом функциональность: Is-A («Является») или Can-Do («Может делать»). На основании этого предлагается в дальнейшем отношение Is-A реализовать в виде базового класса (в том числе, абстрактного класса) и его наследника, а отношение Can-Do - в виде программного интерфейса и его реализации в необходимом классе. Однако в упомянутых выше работах не приводятся рекомендации, как системно построить взаимосвязи между всеми абстрактными классами и интерфейсами [121].

В диссертации разработан подход к проектированию нейронных сетей для ИИС, использующий их описание с помощью проектировочного шаблона для доменных классов ИНС [19].

При проектировании доменных классов перечень членов базовых классов и интерфейсов, а также связи между ними формируют концепцию, которая определяет создание программной библиотеки. Эта концепция важна для гибкого и простого развития данной библиотеки, выражающегося в добавлении различных дочерних классов, являющихся более специализированными практическими реализациями базовых сущностей. Проектирование и разработка совокупности базовых классов, находящихся в начале цепочки наследования всех последующих классов программной библиотеки.

Разработанный шаблон можно назвать проектировочным гридом (решеткой). Это название обусловлено топологией шаблона в виде решетки, в которой для наглядности располагаются доменные классы и интерфейсы.

Система доменных классов ИНС обладает достаточной сложностью, что делает актуальным разработку средств, упрощающих их проектирование, и подчеркивает эффективность использования шаблона.

3.2.2 Структура шаблона «Проектировочный грид»

В основе шаблона лежит принцип упорядоченности объектов по сложности. В объектно-ориентированном проектировании для оценки сложности классов используются различные метрики, например, можно рассматривать метрику LOC [56].

Пусть некоторый абстрактный класс С имеет метрику сложности М. Отношение частичного порядка на множестве классов определим, как

$$C_i \leq C_i \Leftrightarrow M_i \leq M_i \land i \leq j,$$

где в левой части обозначение " \leq " - знак отношения упорядоченности классов, а в правой части " \leq " – знак «больше или равно».

Отметим, что при проектировании доменных классов можно учитывать и другие метрики, например, метрику LCOM недостатка связности методов в классах, метрику секционирования классов, связности по методам или MOOD метрики Ф. Абреу [89, 90, 118].

Шаблон имеет решеточную структуру, в которой проектируемые классы располагаются по мере их упорядоченности. При этом различаются горизонтальная и вертикальная ориентации. На рисунке 3.1 представлен пример структуры шаблона «Проектировочный грид».

Вдоль горизонтальной оси расположены абстрактные доменные классы ADC и интерфейсы I. По вертикальной оси выстраиваются подмешанные интерфейсы (mixin) MI [97].

Правила расположения проектируемых объектов в гриде следующие.

1. На основе анализа признаков общности и различности выделяются базовые сущности, которые расположены вдоль горизонтальной оси. Эти абстрактные классы ADC расположены слева направо в порядке увеличения сложности в соответствии с выбранной метрикой *М*^{ADC}:

$$ADC_i \leq ADC_j \Leftrightarrow M_i^{ADC} \leq M_j^{ADC} \land i \leq j$$

2. Интерфейсы располагаются в ряд под классами, которые являются непосредственной их реализацией. Интерфейс, описывающий наиболее общие свойства и методы, расположен слева. Класс, который его реализует, находится над ним. Далее располагается интерфейс, описывающий набор методов и свойств, реализующих следующую выделенную при анализе функциональность. Над ним располагается класс, реализующий этот интерфейс, одновременно с этим этот класс является наследником одного из классов, расположенных слева от него. Таким образом, можно развивать эту иерархию классов и перечень интерфейсов.

3. Вдоль вертикальной оси расположены подмешанные интерфейсы МІ. Эти интерфейсы описывают перечень свойств и методов, характерных для функциональности, которая может быть у любого класса, независимо от того, какой класс, расположенный вдоль горизонтальной оси, является его наследником. Расположенные вдоль вертикальной оси подмешанные интерфейсы независимы друг от друга. Их можно располагать в любом порядке.



ADC – абстрактные доменные классы, *I* - интерфейсы, *MI* – подмешанные (mixin) интерфейсы

Рисунок 3.1 - Структура шаблона «Проектировочный грид»

4. Некоторые из этих интерфейсов могут быть связаны между собой наследованием. В этом случае такие интерфейсы образуют подгруппу. Внутри данной подгруппы можно выстроить интерфейсы в порядке усложнения, проходя от наследника к потомку. Внутри таких подгрупп вдоль вертикальной оси существует упорядоченность и ее можно ориентировать снизу вверх в соответствии с выбранной метрикой M^{MI} :

$$MI_i < MI_i \Leftrightarrow M_i^{MI} < M_i^{MI} \land i \le j$$

5. После упорядочивания базовых классов и интерфейсов внутри решетки шаблона располагаются классы, которые являются наследниками выбранных базовых классов и реализуют заданный подмешанный интерфейс. При этом линия, иллюстрирующая связь наследования идет от горизонтальной оси вертикально, а линия, иллюстрирующая реализацию выбранного подмешанного интерфейса, располагается горизонтально. Таким образом, все линии на диаграмме классов ортогональ-

ны, образуя сетку или грид. Место их пересечения образует ячейку на гриде, в которой располагается некоторый класс, соответствующей отдельной реализации какойлибо сущности предметной области.

3.2.3 Применение шаблона «Проектировочный грид» для классов нейронных слоев ИНС

Система доменных классов искусственной нейронной сети – это совокупность достаточно большого числа классов с большим количеством взаимосвязей между ними. Как известно, совокупность нейронов в ИНС группируется в слой. Выделяют различное количество слоев, которые могут входить в состав нейронной сети. Важно иметь возможность добавления новых классов слоев нейронов без переделки существующего кода. Этот принцип часто именуют «открыт - закрыт» (open-closed), заключающийся в открытости кода к дальнейшему развитию и его закрытости для модификации и переделывания. В нашем случае это достигается введением совокупности базовых классов и интерфейсов, специфичных для каждого вида слоев нейронов. Затем с использованием именно этих классов описывается вся программная логика нейронной сети [111].

Все частные случаи слоев (их специфические виды) реализованы в виде классов наследников одного из базовых классов. Они легко добавляются в программную библиотеку без переделки существующего кода, поскольку программная логика ИНС оперирует базовыми классами (и всеми его наследниками) и интерфейсами (и всеми их реализациями) единообразно. Таким образом, легко моделируется общность в системе доменных классов. При этом различность поведения специфичных слоев нейронов моделируется различными реализациями, в случае программных интерфейсов, и полиморфизмом, в случае иерархии классов.

Рассмотрим концепцию шаблона «Проектировочный грид» на примере реализации различных типов слоев нейронов. Сначала выделим набор наиболее важных групп функциональностей для каждого из слоев, согласно принципу Can-Do. В нашем случае были выделены следующие интерфейсы: ILayer, INeuronLayer, IReceptiveLayer.

Интерфейс **ILayer** описывает базовое поведение, свойственное любому слою, входящему в ИНС. Например, каждый слой имеет сведения о количестве входных и выходных сигналов. Соответственно, в интерфейсе объявляются свойства, предоставляющие доступ к этим значениям и другие подобные свойства. В интерфейсе **INeuronLayer** объявляются свойства и методы, необходимые для работы с нейронами, находящимися на данном слое. Слои нейронов, применяемые для оптического распознавания образов, обладают специфичной совокупностью общих для них особенностей. Это находит отражение в необходимых членах классов, содержащих логику подобных слоев. Совокупность этих членов объявлена в интерфейсе **IReceptiveLayer**. Это описание показывает, как на основании анализа признаков общности и различности поведения можно выделить различные группы функциональностей и отразить их в перечне программных интерфейсов.

Совокупность таких программных интерфейсов образует набор функциональностей, выделенных по признаку Can-Do. На основании этой совокупности продолжим описание взаимосвязей между доменными классами, добавив взаимосвязи вида Is-A. В примере были выделены следующие абстрактные классы: Layer, NeuronsLayer, ReceptiveLayer, ReceptiveNeuronsLayer.

При введении абстрактного класса **Layer** моделирование начинается со слоя, который не содержит ни одного нейрона. При кажущейся на первый взгляд бесполезности такого слоя (и моделирующего его доменного класса) он служит базой для реализации различных вспомогательных слоев. Одним из примеров такого преобразования является локальная нормализация [104].

Взаимодействие со слоем нейронов и подобным вспомогательным слоем, не содержащим нейронов, различается. Например, в слое нейронов доступ к данным о

нейронах предоставляется через перечень необходимых членов класса (свойств). Тогда как в слое, выполняющим предопределенную нормализацию, в таких членах класса нет нужды. Подобные обстоятельства являются мотивацией для различий между абстрактными классами **Layer** и **NeuronLayer**, при этом второй класс является потомком первого. Кроме того, класс Layer служит базовым классом для всех остальных слоев ИНС. Это позволит, при необходимости, единообразно оперировать с любым слоем, входящим в программную библиотеку. Так как класс Layer реализует интерфейс **ILayer**, а класс **NeuronLayer** - интерфейс **INeuronLayer**, совокупность данных абстрактных классов дополняет выделенные нами до этого связи Can-Do отражением взаимосвязи Is-A для моделируемых доменных сущностей. Аналогичным образом выстроены взаимосвязи наследования и реализации и для классов **ReceptiveLayer**, **ReceptiveNeuronsLayer**.

Для наглядности описываемая система доменных классов и интерфейсов приведена на рисунке 3.2. На нем рассмотренные абстрактные классы и интерфейсы представлены на UML диаграмме классов. При этом есть отличие от традиционного изображения UML диаграммы: в соответствии с рисунком 3.1 добавлены две оси по горизонтали и вертикали, вдоль которых выстроены базовые интерфейсы и классы, реализующие частные случаи слоев нейронных сетей.

В таблице 3.1 показано соответствие условных обозначений базовых классов и интерфейсов на рисунке 3.2.

Проведем дальнейшее усложнение системы доменных классов, моделирующих слои нейронов ИНС, и рассмотрим функциональность, которая может быть свойственна различным их типам. Для нейронных сетей такой функциональностью является программная логика, необходимая слою нейронов для того, чтобы участвовать в обучении и передаче сигнала в обратном направлении.

Базовые абстрактные классы слоев нейронов ИНС			
ADC1	Layer		
ADC2	NeuronsLayer		
ADC3	ReceptiveLayer		
ADC4	ReceptiveNeuronsLayer		
Интерфейсы			
I1	ILayer		
I2	INeuronsLayer		
I3	IReceptiveLayer		
Подмешанные интерфейсы			
MI1	ILearnableLayer		
MI2	IBackwardProclayer		

Таблица 3.1 - Обозначения базовых классов и интерфейсов на UML диаграмме

Сложные сети образуют собой совокупность большого числа различных слоев. Например, ИНС, используемые при оптическом распознавании объектов, содержат конволюционные слои, пулинговые слои, полносвязные слои, а также, возможно, несколько вспомогательных слоев. В процессе обучения нейронной сети каждый слой должен обеспечить прохождение сигнала в обратном направлении и, при необходимости, корректировку входящих в него обучаемых параметров независимо от того, к какому типу он принадлежит. Подобная функциональность - хороший кандидат для реализации в виде «подмешанного» интерфейса.


Рисунок 3.2 - UML диаграмма классов, реализующих программную логику слоев нейронов искусственной нейронной сети

В нашем случае были выделены два «подмешанных» интерфейса: **IBackwardProcLayer** и **ILearnableLayer**. Интерфейс **IBackwardProcLayer** объявляет члены, которые должен иметь слой для обеспечения обратного прохождения сигнала. Интерфейс **ILearnableLayer** объявляет перечень членов, которые должны реализовывать класс слоя нейронов для обучения. Любой обучаемый слой априори является слоем, способным участвовать в обратном пропуске сигнала. Это обстоятельство отражается в том, что для обеспечения наследования членов, описываемых **IBackwardProcLayer**, интерфейс **ILearnableLayer** является его наследником. Подмешанные интерфейсы, расположенные вдоль вертикальной оси, не находятся в какой-либо зависимости от взаимосвязи Is-A, отражаемой на уровне классов, находящихся в самом начале цепочки наследования. Этот интерфейс может реализовывать любой класс, добавляемый в программную библиотеку. Например, в случае доменных классов ИНС подмешанный интерфейс **ILearnableLayer** может реализовать любой класс слоя нейронов, который может участвовать в обучении, независимо от типа слоя.

После того, как в проектировочном гриде заданы базовые классы и интерфейсы, можно легко добавлять различные реализации - частные случаи различных нейронных слоев. На диаграмме классов на рисунке 3.2 это классы, расположенные внутри осей в центре диаграммы. Их условные обозначения раскрыты в таблице 3.2. Легко видеть, что классы, находящиеся в центре диаграммы, связаны зависимостями наследования, идущими вертикально от горизонтальной оси и зависимостью реализация интерфейса, идущими горизонтально от вертикальной оси.

Классы слоев нейронов ИНС				
C1	FullyConnectedLayer			
C2	MaxPoolLayer			
C3	DeconvolutionLayer			
C4	ConvolutionLayer			
C5	LearnableFullyConnectedLayer			
C6	LearnableDeconvLayer			
C7	LearnableConvLayer			
C8	BackProcessMaxPoolLayer			

Таблица 3.2 - Обозначения классов слоев нейронов ИНС на рисунке 3.2

Такой подход позволяет при реализации системы доменных классов легко контролировать все зависимости между классами. Все линии, иллюстрирующие связи между сущностями, ортогональны. На подобной диаграмме сразу заметны избыточные и некорректные зависимости.

При использовании проектировочного грида достаточно сложная система доменных классов становится наглядной на диаграмме, позволяя системному аналитику и программисту сформировать понимание всей системы доменных классов. При добавлении новых классов в программную библиотеку легко определить, какой базовый класс следует выбрать для наследования.

3.2.4 Шаблон «Проектировочный грид» для нейронной сети с композитными слоями

Как было отмечено, базовые классы располагаются в гриде вдоль горизонтальной оси. Их наследники - практические реализации классов, находятся в центре диаграммы. Однако промежуточные базовые классы для подгрупп других классов могу выделяться и среди классов, расположенных на диаграмме внутри осей диаграммы. Такие классы удобно добавлять для избегания дублирования кода, и это нисколько не противоречит обсуждаемой концепции проектировочного грида.

В нашем случае примером такого класса является базовый класс для всех композитных конволюционных и деконволюционных слоев **CompositeReceptiveNeuronsLayer**, который изображен на UML диаграмме на рисунке 3.3.



Рисунок 3.3 - UML диаграмма классов, реализующих программную логику композитных слоев нейронов ИНС

В таблице 3.3 приведены обозначения композитных классов на UML диаграмме на рисунке 3.3.

Таблица 3.3

Композитные классы слоев нейронов ИНС			
CC1	CompositeReceptiveNeuronsLayer		
CC2	CompositeDeconvolutionLayer		
CC3	CompositeConvoutionLayer		
CC4	LearnableCompositeDeconvLayer		
CC5	LearnableCompositeConvLayer		

Композитные слои используются для агрегирования нескольких слоев внутри одного слоя нейронов. Это является частным случаем применения шаблона проектирования «Компоновщик» (Composite pattern) [92]. Удобно реализовывать композитный конволюционный и деконволюционный слой, выделяя общую функциональность для данных слоев в базовый класс **CompositeReceptiveNeuronsLayer**. Этот класс располагается во внутренней части проектировочного грида.

3.2.5 Процедура формирования шаблона «Проектировочный грид»

Построение шаблона «Проектировочный грид» заключается в следующих этапах.

1. Выбрать для рассмотрения отдельно взятую категорию сущностей, которые необходимо смоделировать в программном коде. Например, слой нейронов ИНС.

2. Выделить наиболее важные группы функциональностей на основе структурного и поведенческого анализа. Объявить программный интерфейс, соответствующий каждой из выделенных групп. Сделать каждый из этих объявленных интерфейсов независимым от других.

3. На основе функциональностей Can-Do, полученных на предыдущем шаге, выделить наборы базовых классов (в том числе и абстрактных), которые формируют взаимоотношения Is-A между классами в предметной области.

4. Расположить интерфейсы и классы, полученные на предыдущих двух шагах, вдоль горизонтальной оси проектировочного грида.

5. На основе дальнейшего анализа выделить наборы функциональностей, которые являются взаимосвязями Can-Do без привязки к Is-A. Расположить выделенные программные интерфейсы вдоль вертикальной оси.

6. Провести проверку полученной структуры шаблона, при этом наиболее важные для проекта признаки общности и признаки различности доменных классов должны быть расположены вдоль горизонтальной оси.

7. В полученном шаблоне добавлять классы, являющиеся отдельно взятыми практическими реализациями. Построенный грид позволит осознанно выстраивать только необходимые связи между доменными классами. Хорошим признаком служит наличие только ортогональных линий, отражающих связи между сущностями на диаграмме.

8. В ходе проектирования проводить периодическую верификацию шаблона «Проектировочный грид». Убирать паразитные (не ортогональные) связи в нем. Уточнять свое виденье и понимание системы доменных классов. Отражать эти изменения корректировкой кода, реализованного на основе проектировочных решений, применяя технологию рефакторинга [97].

На рисунке 3.4 приведена схема алгоритма проектирования программной логики нейронной сети с использованием шаблона «Проектировочный грид».

3.2.6 Практическая реализация шаблона

Шаблон «Проектировочный грид» использовался при проектировании нейросетевого программного анализатора в составе интеллектуальной информационноизмерительной системы диагностики радиоэлектронных приборов [58, 99].

Основная ветвь нейросетевого анализатора – это широко применяемая конволюционная нейронная сеть. Она представляет собой несколько конволюционных слоев, объединенных в сеть прямого прохождения сигнала.



Рисунок 3.4 – Алгоритм проектирования программной логики с использованием шаблона «Проектировочный грид»

На вход данной ветви ИНС подается растровое изображение термограммы прибора. Выходной сигнал этой ветви формируется последним конволюционным слоем. После конволюционных слоев следует полносвязный слой с многосверточной функцией активации.

Для учета сигнала дополнительных датчиков в структуру нейросетевого анализатора была добавлена вспомогательная ветвь. Она представлена в виде полносвязного слоя нейронов. На ее вход подается вектор данных, полученных от вспомогательных встроенных датчиков электронного прибора. Вектор выходного сигнала этого слоя объединяется с вектором выходного сигнала последнего конволюционного слоя главной ветви, и полученный объединенный вектор передается на вход слоя, выполняющего нелинейную или двустадийную линейную нормализацию. Этот слой, являющийся выходным слоем для всей ИНС, служит для категоризации неисправности контролируемого блока.

Проведенные эксперименты при диагностике фоточувствительных матриц на ПЗС показали, что разработанная ИНС выявляет дефекты в контролируемых приборах с вероятностью 97%.

Предложенные идеи построения проектировочного грида являются логическим развитием идей, сформулированных другими авторами. Однако именно представление проектировочных решений в виде описанного шаблона дало наибольшую формализацию и четкость при работе со сложными системами доменных классов.

Эффективность применения предлагаемого шаблона рассмотрена на примере системы доменных классов, реализующих программную логику ИНС. Однако следует отметить, что затронутый перечень рассмотренных типов различных типов сетей и входящих в них слоев нейронов, разумеется, не претендует на то, чтобы быть полным.

Разработанная методика декомпозиции программной логики нейронных сетей и проектировочный шаблон реализованы в виде программных средств и программной библиотеки, на которые получены свидетельства о государственной регистрации программы для ЭВМ [25, 26].

Предложенный концептуальный подход, связанный с изображением сложной системы доменных классов в виде решеточной структуры с целью формализации зависимостей между входящими сущностями, может использоваться и в других программных проектах.

3.3 Функции активации и двухстадийная нормализация выходных сигналов ИНС

Применение нейронной сети для категорирования тесно связано с формированием распределения вероятностей принадлежности сущности к заданному перечню категорий. При решении этой задачи важную роль играет алгоритм нормализации выходных значений [115].

В диссертации рассмотрены теоретические аспекты различных подходов к нормализации совокупности значений, а также применение этих подходов для преобразования выходных сигналов нейронных сетей. Заложенные принципы и разработанная программная библиотека могут быть применены в различных технических приложениях.

3.3.1 Двухстадийная нормализация

В общем случае под нормализацией значений понимают приведение совокупности некоторых значений к заданному диапазону. Наиболее известные подходы нормализации – это линейная нормализация, нелинейная нормализация, а также нормализация по диапазону.

Пусть имеется совокупность каких-либо значений, далее именуемая выборкой, которую нам надо нормализовать. Линейная нормализация задается формулой (3.1), а нелинейная нормализация – формулой (3.2):

$$L(a) = a_i / \sum_{j=1}^n a_j,$$
(3.1)

$$L_{sm}(a) = e^{a_i - D} / \sum_{j=1}^{n} e^{a_j - D}, \qquad (3.2)$$

где *а* – значение переменной из исходной выборки;

i – индекс переменной *a* в выборке;

n – число значений в выборке,

 $D = \max\{a_1, a_2, \dots, a_n\}.$

В случае линейной нормализации после ее применения все нормализованные значения находятся в диапазоне от 0 до 1, и сумма этих значений равна 1. Подобное свойство позволяет трактовать полученные значения как вероятности, а всю выборку - как вероятности полной группы событий. Однако, следует отметить, что линейная нормализация в случае применения к выборкам, содержащим отрицательные значения, теряет данное свойство.

После применения нелинейной нормализации все значения находятся в диапазоне от 0 до 1 и сумма всех значений, входящих в выборку, равна 1. Это справедливо и в случае присутствия в выборке отрицательных чисел.

Обладая описанными выше свойствами, этот вид нормализации в некоторых случаях прекрасно подходит. Однако у нелинейной нормализации есть одна важная особенность, из-за которой часто нормализованная выборка представлена единственным значением 1 (соответствующей максимальному значению переменной до нормализации) или 0. Подобный тип векторов называют 1-hot вектор или унитарным кодом.

Это происходит в силу следующих причин. Если не использовать корректирующую константу D, то из-за экспоненциального роста при вычислении могут быть получены очень большие значения функции. При этом их будет невозможно сохранить в используемом в программе типе данных, даже при достаточно умеренных значениях a. Однако, при использовании D легко заметить, что вычисление сводится к манипуляции значениям $e^0 = 1$ и значениями экспоненты от отрицательных аргументов. Как известно, функция экспоненты в области отрицательных аргументов асимптотически стремится к 0.

Полученный таким образом вектор унитарного кода будет проблематично интерпретировать как распределение вероятностей,.

Нормализация по диапазону задается формулой следующего вида:

$$R_{d}(a) = a_{i} - \min_{j} \{a_{j}\} / (\max_{j} \{a_{j}\} - \min_{j} \{a_{j}\}), \qquad (3.3)$$

где *а* – значение переменной из заданной выборки;

i – индекс переменной в выборке;

j – индекс выборки;

 \min_i и \max_i - минимальное и максимальное значения в *j*-ой выборке.

Подобный подход к нормализации приводит все значения в диапазон между 0 и 1, даже если в исходную выборку входили отрицательные числа. Однако недостаток в том, что подобная нормализованная выборка не суммируется в единицу, что не позволяет интерпретировать ее как распределение вероятностей полной группы событий.

В данной работе предлагается двухстадийная нормализация, применимая в случаях, когда нужно получить выборку, представляющую собой множество значений в диапазоне от 0 до 1, сумма которых равна 1, и не имеющих предрасположенности приобретать вид вектора унитарного кода. Для этого предлагается последовательно применять нормализацию по диапазону и линейную нормализацию.

Говоря о задачах классификации, решаемых нейронными сетями, важно отметить, что выходы сети можно интерпретировать как оценки вероятности того, что элемент принадлежит некоторому классу. В этом случае методы нормализации выходных значений нейронной сети играют ключевую роль.

Для обучения нейронной сети применяется подход, при котором выходные значения сети сопоставляются с известными значениями ожидаемых выходных сигналов. Эти значения нам известны, т.к. обучающая выборка сопровождается экземплярами наборов входных сигналов, аннотированных с ожидаемым выходным сигналом. Задание функции ошибки, выражающей различие ожидаемого и фактического выходных сигналов, служат индикатором того, насколько точно работает ИНС. Процесс обучения нейронной сети можно сформулировать как нахождение производной заданной целевой функции потерь и движение против градиента роста данной функции с целью повышения точности сети. В свою очередь, при нахождении градиента находятся частные производные целевой функции потерь и, по правилу цепи, производные соответствующих функций, входящих в нее. Процесс обучения нейронной сети представлен на рисунке 3.5.

Рассмотрим производную функции потерь сети, использующей двустадийную нормализацию. При получении сигнала активации в нейронной сети он передается функции активации, которая представляет собой последовательность нормализации по диапазону, а затем к полученным результатам применяется линейная нормализация. Это позволяет получить выборку с суммой значений, равной 1, которую можно трактовать как распределение вероятностей полной группы событий.

Функция двухстадийной нормализации – это функция, принимающая вектор из *n* элементов и возвращающая вектор из *n* нормализованных элементов как результат:

$$L(R_{d}(a)):\begin{bmatrix}a_{1}\\a_{2}\\...\\a_{n}\end{bmatrix} \rightarrow \begin{bmatrix}L(R_{d}(a))_{1}\\L(R_{d}(a))_{2}\\...\\L(R_{d}(a))_{n}\end{bmatrix},$$
(3.4)

где $L(R_d(a))_1, L(R_d(a))_2, \dots L(R_d(a))_n$ вычисляются по формулам (3.1) и (3.3).



Рисунок 3.5 - Общая схема процесса обучения ИНС

3.3.2 Нормализация по диапазону в искусственных нейронных сетях

Рассмотрим процесс нахождения производной в случае применения нормализации по диапазону. В случае нахождения производной функции, принимающей вектор значений и возвращающей вектор в качестве результата, необходимо специфицировать: а) по какому выходному компоненту находится производная; б) по какой входной переменной находится частная производная.

Двухстадийная нормализация заключается в последовательном применении двух функций, и тогда производная определяется по правилу цепи. Определим выражение для производной *i*-ого выходного компонента по *j*-ой входной переменной для нормализации по диапазону:

121

$$\frac{\partial R_{d_i}}{\partial a_j} = \partial \left(\frac{a_i - \min_k \{a_i\}}{\max_k \{a_i\} - \min_k \{a_i\}}\right) / \partial a_j, \tag{3.5}$$

где *а* – значение переменной из заданной выборки;

i – индекс переменной в исходной выборке;

j – индекс компоненты выходного вектора, возвращаемого функцией; min_k и max_k - минимальное и максимальное значения в *k*-ой выборке. Получаем:

$$\frac{\partial R_{d_i}}{\partial a_j} = 1/(\max_k \{a_i\} - \min_k \{a_i\}), \quad \forall i : i = j,$$

$$\frac{\partial R_{d_i}}{\partial a_j} = 0, \quad \forall i : i \neq j,$$
(3.6)

где использованы те же переменные, что и в выражении (3.5).

Для производной *i*-ого выходного компонента по *j*-ой входной переменной при линейной нормализации имеем:

$$\frac{\partial L_i}{\partial a_j} = \frac{-a_i + \sum_{k=1}^n a_k}{\left(\sum_{k=1}^n a_k\right)^2}, \quad \forall i : i = j,$$

$$\frac{\partial L_i}{\partial a_j} = \frac{-a_i}{\left(\sum_{k=1}^n a_k\right)^2}, \quad \forall i : i \neq j.$$
(3.7)
$$(3.7)$$

Важно заметить, что в искусственной нейронной сети функции активации передают значения входных сигналов, скорректированные в зависимости от весов, что можно выразить следующим образом:

$$g_i(W_{ij}) = W_{i1}x_1 + W_{i2}x_2 + \dots + W_{it}x_t,$$
(3.9)

где *W_{ij}* – вес связи *j*-ого входа ИНС и *i*-ого нейрона;

х – входной сигнал поступивший в ИНС;

t – число входных сигналов.

Вся цепочка преобразований выполняемая в искусственной нейронной сети (обозначим ее как фунцию *P(W)*) может быть выражена следующим образом

$$P(W) = L(R_d(g(W))),$$

где функции L(a), Rd(a) и g(W) определены в (3.1), (3.3) и (3.9), соответственно.

Поскольку оценка точности результатов, выдаваемых нейронной сетью, по сравнению с известным правильным ответом в ходе обучения выполняется с использованием кросс-энтропии, получаем следующие формулы для определения значений ее частных производных [2]:

$$\frac{\partial E(W)}{\partial W_{ij}} = -\frac{\sum_{k=1}^{n} a_k}{a_y} \cdot \frac{(\sum_{k=1}^{n} a_k) - a_y}{(\sum_{k=1}^{n} a_k)^2} \cdot \frac{x_j}{\max_s \{b_s\} - \min_s \{b_s\}}, \forall i : i = j,$$
(3.10)

$$\frac{\partial E(W)}{\partial W_{ij}} = -\frac{x_j}{(\max_s \{b_s\} - \min_s \{b_s\}) \sum_{k=1}^n a_k}, \ \forall i : i \neq j,$$
(3.11)

где *j* – индекс, нумерующий столбец матрицы весов (совпадает с индексом, нумерующим элемент входного сигнала);

i – индекс, нумерующий строку матрицы весов;

n – число компонент в векторе возвращаемом функциями L(a), Rd(a) и g(W);

у – индекс элемента в векторе, который соответствует известному нам результату, который в обучающем нейронную сеть примере отмечен как верный (ожидаемый) результат;

а – аргумент функции линейной нормализации;

b – аргумент функции нормализации по диапазону,

 \min_s и \max_s - минимальное и максимальное значения в *s*-ной выборке.

Анализируя (3.10) и (3.11) легко заметить, что значения, которые корректируют веса нейронной сети, отличны от 0 не только для нейрона, соответствующего известному нам результату, отмеченному в обучающем примере как верный (ожидаемый) результат. Таким образом, выполняется корректировка всех весов в процессе обучения, а не отдельно взятых, как это имеет место в случае применения только нормализации по диапазону.

3.3.3 Построение нейронной сети с двухстадийной нормализацией в качестве функции активации

Для сравнения различных подходов нормализации были проведены эксперименты с ИНС, в которых в качестве функций активации применялась в одном случае нелинейная нормализация, а в другом случае - двухстадийная нормализация. Подобная нормализация часто применяется как завершающий слой нейронных сетей, которые выполняют категорирование.

Структура искусственных нейронных сетей, применявшихся в экспериментах, изображена на рисунке 3.6.



Рисунок 3.6 - Структура нейронных сетей

Параметры сетей, использовавшихся в экспериментах, приведены в таблице 3.5.

Наименование	Значение
параметра	
Число слоев	1
Число нейронов	10
Число входов	4900
Число связей	49000

Таблица 3.5 - Параметры ИНС

Для экспериментов выбран тестовый набор (датасет) Национального института стандартизации NIST США. Содержание базы датасетов представляет собой 814 255 сегментированных рукописных цифр и букв из специально заполненных форм. Эти символы представлены в виде растровых изображений размером 128х128 пикселей и снабжены маркером, показывающим, какой именно символ изображен в виде 62 ASCII кодов, соответствующих цифрам и символам: "0"- "9", "A"- "Z" и "a"- "z".

Соответственно, структура ИНС, обрабатывающих данный датасет, имеет 4900 входных сигналов. Такое число входов необходимо для передачи в сеть изображения размером 70х70. На каждый из входов подавалось значение, соответствующее значению пиксела. Перед началом обучения веса сетей инициализировались случайными значениями, находящимися в диапазоне от -2.0 до 2.0.

Сети обучались на части базы, которая содержит цифры. Подходы, изложенные в данной работе применимы и для сетей, выполняющих категорирование (распознавание) не только цифр, но и всех остальных символов, представленных в базе датасетов.

3.3.4 Результаты экспериментов с нейронными сетями с двухстадийной нормализацией

Были построены нейронные сети, в одной из которых качестве функций активации применялась нелинейная нормализация, а в другой - двухстадийная нормализация. После обучения сети были протестированы на выборке, представленной в директории hsf 4 в базе датасетов.

Рассмотрим пример обработки изображения с цифрами. Выполним сравнение двух методов: нелинейной нормализации и двухстадийной нормализации. Распределение значений, полученных на выходе искусственной нейронной сети, в качестве функции активации, в которой применена двухстадийная нормализация, приведено в таблице 3.6. В этой же таблице для сравнения приведены выходные сигналы ИНС, в которой применялась нелинейная нормализация.

Оба распределения характерны для каждой из использованных в эксперименте ИНС. Как видно при сопоставлении этих распределений в случае применения нелинейной нормализации на выходе имеется вектор сигналов в виде унитарного кода. В то же время, при применении двухстадийной нормализации выходные значения представляют собой значения в диапазоне от 0 до 1, которые являются долей единицы.

Подобные значения можно интерпретировать как вероятность принадлежности распознаваемого символа к той или иной категории. Категория может быть оценена по наибольшему значению, при этом его абсолютная величина может служить оценкой степени точности результата.

Кроме проверки работы обученных нейронных сетей на тестовой выборке целесообразно получить визуализацию весов связей сети. Подобная визуализация может быть получена следующим образом. Если взять матрицу весов и выбрать из нее все веса связей от всех входов сети к первому нейрону (нейрону, ответственному за категоризацию изображения, на котором цифра «0»), то получаются веса связей сети, которые ИНС «выучила» для того, чтобы распознавать 0.

Аналогично можно выбрать все веса, соответствующие другим категориям, (в нашем случае - другим цифрам, представленным на растровых изображениях). При применении подобной группировки будет получено 10 групп (по числу категорий) весов, при этом в каждой группе будет 4900 связей. Если полученные 4900 связей изобразить на растровом изображении 70х70 пикселей, присваивая каждому пикселю значения цвета тем темнее, чем более больший вес мы имеем, то будет получена наглядная визуализация весов сети. При этом черному цвету соответствует большое значение веса, а белому – малое.

Результаты экспериментальных исследований точности классификации ИНС с использованием двухстадийной нормализации в качестве функции активации приведены в главе 4.

Цифра на изо-	Имя файла базы	Вектор выходного сигнала			
бражении	данных NIST (в	искусствен	ной нейронной сети		
	поддирректории by_class)	Нелинейная нормализация	Двустадийная нормализация		
0	$30\hsf_4\hsf_4_00$	1; 0; 0; 0; 0; 0; 0;	0,16; 0; 0,1; 0,1; 0,09;		
	000.png	0; 0; 0; 0; 0;	0,1; 0,1; 0,09; 0,1; 0,09		
2	$32\hsf_4\hsf_4_00$	0; 0; 1; 0; 0; 0;	0,02; 0,03; 0,2; 0,05;		
	000.png	0; 0; 0; 0; 0;	0,17; 0,1; 0,1; 0; 0,16; 0,18;		
7	$37\hsf_4\hsf_4_00$	0; 0; 0; 0; 0; 0; 0;	0,1; 0; 0,1; 0,14; 0,1;		
	000.png	0; 1; 0; 0;	0,09; 0,06; 0,15; 0,09;		
			0,13;		

Таблица 3.6 - Распределение на выходе ИНС

Продолжение таблицы 3.6

Цифра на	Имя файла базы	Вектор в	ыходного сигнала
изображении	данных NIST (в	искусственной нейронной сети	
	поддирректории	Нелинейная	Двустадийная
	by_class)	нормализация	нормализация
5	35\hsf_4\hsf_4_00 000.png	0; 0; 0; 0; 0; 0; 0; 0; 0; 0; 0; 1;	0,12; 0; 0,08; 0,1; 0,13; 0,13; 0,1; 0,07; 0,13; 0,14;
3	33\hsf_4\hsf_4_00 000.png	0; 0; 0; 1; 0; 0; 0; 0; 0; 0; 0;	0,06; 0; 0,11; 0,2; 0,1; 0,1; 0,05; 0,07; 0,1; 0,14;

Выводы по главе 3

1. Разработана методика декомпозиции программной логики нейронной сети в составе нейросетевого программного анализатора. На ее основе предложена технология проектирования программного кода логики конволюционных нейронных сетей для анализа термограмм.

2. С целью объектно-ориентированного проектирования ИНС для нейросетевого программного анализатора предложен шаблон «Проектировочный грид». В его основе лежит принцип использования упорядоченности абстрактных классов и программных интерфейсов по сложности выбранной метрики программной логики. Показано, что сокращение времени проектирования программного кода ИНС составило не менее 25%.

3. С целью повышения точности и информативности классификации состояний контролируемого объекта предложена функция активации выходного слоя нейросетевого программного анализатора термограмм, отличающаяся последовательным применением нормализации по диапазону и линейной нормализации (двухстадийная нормализация).

4 ЭКСПЕРИМЕНТАЛЬНЫЕ ИССЛЕДОВАНИЯ МЕТОДА ИНТЕЛЛЕКТУАЛИЗАЦИИ В ИИС ТД

4.1 Области использования результатов диссертационного исследования

Разработанные метод интеллектуализации, нейросетевой программный анализатор и методика проектирования нейронных сетей были использованы в следующих информационно-измерительных системах:

1. При модернизации ИИС ТД микросхем фоточувствительной матрицы на ПЗС для оптико-электронного преобразователя.

2. При создании ИИС контроля состояния путевой контактной сети железной дороги.

3. При разработке интеллектуальной системы диагностики агрегатов и элементов системы управления беспилотным автомобилем семейства КАМАЗ.

Кроме того, логика конволюционных слоев, разработанная в рамках диссертационной работы, была дополнительно апробирована в задаче распознавания железнодорожных скреплений по их видеоизображениям, снимаемых вагономлабораторией в процессе прохода по магистрали для оперативного обнаружения дефектов. При решении этой задачи не использовался анализ какого-либо теплового поля и дополнительные параметры, однако решение этой задачи послужило дополнительной верификацией корректности функционирования программной реализации конволюционной сети.

В процессе работ по внедрению были выполнены экспериментальные исследования по обучению двухветвенной нейронной сети, проведен анализ характеристик и параметров искусственных нейронных сетей и выполнено сравнение различных структур и конфигураций. Определены метрологические показатели информационно-измерительных систем.

4.2 Практическое использование метода интеллектуализации в ИИС тепловизионного диагностирования

В таблице 4.1 сведены основные характеристики применения разработанного метода интеллектуализации в различных информационно-измерительных системах контроля и диагностирования. Каждое из применений описано более подробно в нижеследующих подпунктах.

Таблица 4.1 - Характеристики интеллектуальных ИИС с нейросетевым программным анализатором

Область	ИИС	ИИС контроля	Система контроля	
применения	тепловизионного	контактной сети	рельсового пути с	
Парамотри	диагностирования	железной дороги	использованием	
Параметры	ФМ ПЗС		нейросетевого	
			анализатора	
Точность	97,5%	98%	90%	
классификации				
отказов и				
дефектов				
Сокращение	на 20%	на 30%	в 2 раза	
времени				
классификации				
по сравнению				
с обработкой				
оператором				
Архитектура	Двухветвенная	Двухветвенная	Конволюционная	
нейросетевого	ИНС	ИНС	ИНС	
программного	Число нейронов	Число нейронов	Число нейронов	
анализатора	=21413	=21413	=11212687	
	Число изменяе-	Число изменяе-	Число изменяе-	
	мых параметров =	мых параметров =	мых параметров =	
	73663	73663	38123138	
	Число слоев =7	Число слоев =7	Число слоев =6	
Параметры	300 эпох с	300 эпох с	100 эпох с	
обучения	темпом 0,00005	темпом 0,00005	темпом 0,00005	

4.2.1 Модернизация ИИС контроля ФМ ПЗС

Проведена модернизация ИИС ТД фоточувствительной матрицы оптикоэлектронного преобразователя в составе системы дистанционного зондирования Земли. Модернизация заключается в использовании разработанного метода и нейросетевого программного анализатора для дистанционного контроля микросхем при наземных испытаниях [56, 58, 99].

При экспериментальной проверке разработанной ИИС ТД использовалось следующее оборудование: тепловизор FLIR E6, имеющий точность $0,06^{\circ}$ C, многофункциональный прибор Metrel MI 6401Poly с погрешностью измерения температуры окружающей среды $\pm 0,2^{\circ}$ C и цифровой осциллограф GDS 2104. Двухветвенная ИНС построена на основе архитектуры, описанной в работе, а также включает в себя некоторые эвристики, предложенные в работах [107, 109, 126].

Программная реализация ИНС выполнена на языке С# и содержит конволюционную сеть с 8573 нейронами в трех конволюционных слоях главной ветви и полносвязную сеть с 6 нейронами в одном слое в вспомогательной ветви. Нейронная сеть обучалась на выборке из 250 термограмм в течение 300 эпох с темпом обучения 0,00005.

Измерительный канал с тепловизором имеет основную относительную погрешность 0,5 %, погрешность классификации неисправностей с помощью нейросетевого программного анализатора составила не более 1,6 %. Общая погрешность диагностирования состояний ФМ ПЗС не превысила 2,5 %.

В описываемых экспериментах сравнение проводилось на обучающей выборке, составленной из модельных термограмм. Это связано с тем, что использование каких-либо термограмм, снятых с реальных приборов, невольно закладывало бы неявным образом особенности работы тех приборов, которые использовались при формировании данной обучающей выборки. Это не совсем корректно, т.к. различность, которая была зафиксирована в ходе экспериментов при работе даже двух приборов одной модели, не должна вносить свой вклад в обучение ИНС. Это послужило мотивацией для формирования обучающей выборки из модельных термограмм, полученных на основе математической модели распределения температуры по поверхности прибора, находящемся в том или ином состоянии (режим работоспособности или один из возможных отказов). Верификация таких модельных термограмм осуществлялась путем их сопоставления с реальными термограммами, полученных при измерении тепловизором поверхности приборов.

4.2.2 Контроль контактной сети железной дороги

Совместно с АО «НПЦ «ИНФОТРАНС», г. Самара, были проведены работы по созданию системы контроля контактной высоковольтной сети железной дороги. Система эксплуатируется в составе компьютеризированного вагона-лаборатории для контроля контактной сети, автоматики и связи КВЛ-АРКС. В состав ИИС входит измерительный канал с тепловизором Micro Epsilon TIM600 и блок оперативной обработки термограмм на основе разработанного в данной диссертации нейросетевого программного анализатора [23].

Основной компонентой блока является конволюционная нейронная сеть для обнаружения ненормативного разогрева элементов контактной сети, что свидетельствует о наличии дефектов. Характеристики тепловизора: оптическое разрешение 640х480 пикселов, погрешность $\pm 2^{\circ}$ С, диапазоны измеряемых температур от 0°С до 250° С и от 150° С до 900° С.

Во время контроля контактной сети осуществляется:

 измерение положения контактного провода (до четырех одновременно) в плане (зигзаг) и высоты подвеса одновременно в двух режимах – при нажатии токоприемника и без нажатия (с помощью оптического сканирования); • определение типа (переменное, постоянное) и измерение величины напряжения контактной сети;

• измерение температуры наружного воздуха;

 определение сверхнормативных отклонений параметров визуально наблюдаемых объектов контактной сети;

 тепловизионный и ультрафиолетовый контроль объектов контактной сети;

• видеоконтроль состояния обустройства контактной сети с возможностью фиксации отметок оператора и записи речевых комментариев и последующим сплошным или выборочным просмотром по заданным критериям (опоры, стрелки, отметки оператора и т.п.).

• автоматизированная балльная оценка технического состояния контактной сети.

Использовался нейросетевой программный анализатор (п.2.2) для обработки термограмм. При этом, как в случае и с классификацией технического состояния матрицы ПЗС, некоторые технические состояния контактной сети соответствовали практически идентичным по виду термограммам. Для их распознавания применялись дополнительные параметры, подаваемые на вспомогательную ветвь ДНС. В качестве дополнительных параметров для регуляризации задачи классификации были использованы:

 V_1 - температура наружного воздуха,

V₂ - величина напряжения контактной сети,

 V_3 - высота контактного провода,

V₄ – отклонение провода от осевой линии.

Пример термограмм контактной сети приведен на рисунке 4.1.

Разработанная в диссертации ДНС, технические характеристики которой приведены в п. 2 2, обучалась в течение 300 эпох, с темпом обучения 0.00005 на модельных термограммах контактной сети в количестве 250 штук (по 50 штук на каждую категорию состояния участка контактной сети).



Рисунок 4.1 - Пример обрабатываемых термограмм контактной сети

Динамика точности ДНС на различных эпохах приведена в таблице 4.2. и на рисунке 4.2.

Номер эпохи	Точность ДНС
3	0.136
50	0.548
100	0.764
150	0.864
200	0.94
250	0.976
300	0.98

Таблица 4.2 - Динамика точности ДНС в различных эпохах



135

Рисунок 4.2 - Динамика точности ДНС в процессе обучения

Полученная точность классификации составила 98 %.

Использование разработанного метода интеллектуализации в ИИИС ТД в значительной степени автоматизировала процесс классификации технического состояния контактной сети. Этот результат является важной составляющей своевременной технической диагностики состояния железнодорожных путей.

4.2.3 Контроль рельсового пути железной дороги

Постоянный мониторинг геометрических параметров рельсового пути и технических состояний его элементов – актуальная задача [14].

Программная логика конволюционных слоев, разработанная в рамках диссертационной работы, была дополнительно апробирована в системе для контроля рельсового пути магистральной железной дороги в составе компьютеризированного путеизмерительного вагона-лаборатории КВЛ-П2.1.

В реальном времени выполняется обработка изображений рельсов и элементов их скреплений. Изображения поступают с четырех видеокамер испытательного вагона-лаборатории. Пример изображений скреплений, обрабатываемых искусственной нейронной сетью приведен на рисунке 4 3. Проводится предварительная обработка данных для улучшения качества изображений. Далее используется обученная конволюционная сеть, которая обеспечила обнаружение дефектов скреплений рельсов и их классификацию с точностью не менее 90%.



а) железнодорожное полотно с отсутствующим скреплением,
 б) исправное скрепление
 Рисунок 4.3 – Изображения скреплений рельсов

Обучающая выборка, составленная из изображений железнодорожных скреплений в исправном состоянии и отсутствующих скреплений, была проанализирована методами понижения размерности для выявления факта возможности выделить различные типы дефектов и исправное состояние.

Полученные диаграммы представлены на рисунке 4.4

На рисунке 4.4 показаны следующие диаграммы: рис. 4.4, а и рис. 4.4, б диаграммы главных компонент (PCA) для двух и трех главных компонент соответственно; рис. 4.4, в и рис. 4.4, г - диаграммы многомерного шкалирования (MDS) для двух и трех компонент; рис. 4.4, д и рис. 4.4, е - диаграммы стохастического внедрения t-распределенных соседей (tSNE) для двух и трех компонент.



Рисунок 4.4 – Диаграммы сокращения размерности для обучающей выборки из рельсовых скреплений

137

Представленные на рисунке 4.4 диаграммы показывают, что рассматриваемые в данной задаче классы разделимы в пространстве выборки, что обосновывает возможность обучения нейросетевого анализатора для решения задачи классификации.

Обученная на выборке из 50000 экземпляров (по 25000 на каждый из двух классов: исправные скрепления и отсутствующие скрепления рельсов) конволюционная нейронная сеть с темпом обучения 0.00005 и числом эпох 100 достигла точности классификации 90%.

Основную сложность при обработке изображений в данном применении имеют изображения, на которых скрепления закрыты присутствующими посторонними предметами и мусором на железнодорожном полотне. В примененном варианте не применялись какие-либо дополнительные данные. Этот вариант интелектуализации ИИС является частным, поскольку в нем ДНС на вторую ветвь не принимает никаких дополнительных сигналов. Однако при дальнейшем развитии системы возможно рассмотреть их применение. Примером таких данных могут быть конструкционные метрики железнодорожного полотна.

Для верификации работы обученной нейронной сети был проведен ряд дополнительных экспериментов. Один из них заключался в том, что обученной сети подавались на вход изображения, на которых поэтапно закрывались черным квадратом наиболее характерные для рассматриваемого скрепления элементы. Аналогичные эксперименты проводились в работе и часто именуются «тест с покрытием» (occlusion test) [133]. По результатам классификации с помощью нейронной сети можно судить, какие именно элементы на изображении вносят наибольший вклад в пользу того или иного исхода классификации. Пример изображений для описываемого эксперимента приведен на рисунке 4.5.

На рисунке 4.6 над каждым изображением приведен вектор значений, полученных на выходе нейронной сети. Первый элемент вектора - это вероятность при-

138

сутствия скрепления на изображении, второй элемент – вероятность отсутствия на изображении скрепления.



 а) немодифицированное изображение, б) некоторая часть наиболее важных элементов для скрепления закрыта, в) полностью закрыты значительная часть наиболее важных элементов для скрепления.

Рисунок 4.5 – Изображения скреплений рельсов с закрытыми элементами изображения



Рисунок 4.6 – Результаты классификации модифицированных изображений в ходе эксперимента с закрытием элементов

Проведенный эксперимент показывает корректность работы разработанного нейросетевого программного анализатора, так как при классификации состояния рельсового скрепления нейронная сеть выделяет те же наиболее ключевые составляющие их изображения, что и человек - эксперт в данной предметной области.

4.2.3 Диагностика агрегатов и систем управления беспилотного автомобиля КАМАЗ

Результаты диссертационного исследования использованы в рамках выполнения проекта «Разработка роботизированной системы сельскохозяйственных автомобилей на базе семейства автомобилей «КАМАЗ» по Федеральной Целевой Программе при создании интеллектуальной системы диагностики агрегатов и элементов.

Задача оперативной диагностики освещена на рисунке 4.7.

В основе диагностики агрегатов и автомобиля и электронных элементов управления лежит сравнительная термография с использованием конволюционной нейронной сети.

На рисунке 4.8 показано место интеллектуальной системы диагностики в общей структуре КАМАЗа.



Рисунок 4.7 - Задача оперативной диагностики беспилотного КАМАЗа

В системе диагностики используются тепловизоры FLIR E8 для обзорного контроля и миниатюрные встроенные тепловизоры Optis PI400 для постоянного контроля наиболее важных агрегатов (рисунок 4.8).



Рисунок 4.8 - Интеллектуальная ИИС тепловизионной диагностики и ее взаимосвязь с агрегатами и узлами автомобиля КАМАЗ

4.3 Исследование точности классификации для различных структур и конфигураций нейронной сети

4.3.1 Общие характеристики нейронных сетей, использованных в ИИИС ТД

Как уже было отмечено, определение технического состояния контролируемого прибора сводится не только к обработке термограмм, но и дополнительных параметров прибора. Для этих целей разработана двухветвенная нейронная сеть. Однако для исследования производительности сети можно ограничиться экспериментами с главной ветвью сеть, выполняющей обработку изображения термограммы. Это связано с тем, что вспомогательная ветвь, применяемая в предложенной ДНС, представлена полносвязной сетью, выполняющей обработку входного вектора из 3 элементов. В проведенных экспериментах было обнаружено незначительное влияние этой ветви на общую вычислительную сложность ДНС.

Сравнивая показатели работы различных типов ИНС, используемых в качестве главной ветви предложенной ДНС, можно заметить следующее обстоятельство. Существует достаточно большое число различных принципов построения нейронных сетей. Конволюционная и полносвязная сети – это лишь два частных случая. Помимо различия в эвристике, лежащей в основе той или иной сети, каждая из них различается числом слоев, числом искусственных нейронов в пределах отдельно взятого слоя и другими параметрами. В таблице 4.3 приведено сравнение показателей точности различных типов сетей.

Время обучения для каждой сети показано с учетом того, что ИНС обучалась на типовой виртуальной машине MS Azure типа Standard DS1 v2 (один виртуальный процессор, 3.5 GB оперативной памяти). При обучении сети все вычисления производились только на центральном процессоре (CPU) без использования технологий переноса вычислений на графический ускоритель (GPU). Однако в случае необходимости время обучения, указанное в таблице 4.3, можно уменьшить при использова-

нии более мощного аппаратного обеспечения, выполняющего программную логику ИНС, а также использованием вычислений на GPU.

Так же время обучение зависит от числа используемых образцов в обучающей выборке. В описываемых экспериментах применялось по 50 образцов модельных термограмм для каждого распознаваемого средствами ИНС класса. В виду специфичных черт на термограмме для каждого из распознаваемых классов такой выборки было достаточно для обучения ИНС, что подтвердили результаты на тестовой выборке в экспериментах.

Как видно из сопоставления данных сетей, полносвязные сети показали себя как наиболее быстро обучаемые в проведенных экспериментах. Подобную модификацию сетей можно использовать в производственном цикле, где время на переобучение сети на обновленном подмножестве термограмм должно быть минимально возможным. Недостатком данной архитектуры является то, что подобная сеть крайне неустойчива к самым незначительным отличиям во входном сигнале. Даже смещение изображения на входной термограмме всего на несколько пикселов может значительно снизить точность классификации выполняемой данной ИНС. Конволюционные сети лишены такого недостатка. Однако, как видно из таблицы 4.3, такие сети дольше обучаются.

Полносвязная однослойная сеть представляет собой сеть, входной сигнал которой представляет собой вектор, длина которого представляет собой произведение высоты изображения термограммы на ширину и на глубину (которая равна трем, по одному значению для каждого из RGB канала). Подобных входной сигнал передается на единственный в данной ИНС слой, где расположены 3 нейрона (по одному, на каждый распознаваемых класс термограмм). В качестве функции активации в подобной сети использовалась нелинейная нормализация (softmax) или двустадийная нормализация [17]. Двухслойная полносвязная ИНС в целом аналогична вышеописанной, за исключением лишь того, что в ней присутствует дополнительный слой, состоящий из 300 нейронов. В качестве функции активации в этом слое применялась функция активации логистическая регрессия.

Таблица	4.3 -	Сравнение	показателей	точности	для не	которых '	гипов
нейронно	й сети	4					

Тип архи- тектуры сети	Тип сети	Точ- ность сети на тестовой выборке	Точность сети на обучаю- щей вы- борке	Число эпох обуче- ния	Темп обуче- ния	Время обу- чения
Одно-	Полно	0.8828	0.8761	20	0.001	
слойная	ПОЛНО-	0.9035	0.8993	50	0.001	
сеть	СБИЗНИЯ	0.9128	0.9112	100	0.001	30 минут
Двухслой-	Полно-	0.922	0.9281	20	0.001	
ная сеть		0.9443	0.9544	50	0.001	
(300 нейро- нов в скры- том слое)	связная	0.9564	0.9701	100	0.001	30 минут
Конволю- ционная сеть	Конво- люцион- ная сеть	0.9661	0.9669	100	0.000005	4 часа

В отличие от полносвязных сетей, принимающих на вход одномерный вектор, конволюционные ИНС в качестве входного сигнала имеют трехмерный массив, в котором каждое значение представляет цвет соответствующего пиксела. Ширина и вы-
сота массива совпадает с шириной и высотой изображения (в пикселах), а глубина массива равна 3, по одному на каждый из 3-х каналов (синий, зеленый, красный).

Важно отметить, что в качестве функции активации во всех конволюционных слоях в разработанной сети применялась функция активации ReLU.

4.3.2 Сравнение показателей точности различных конфигураций конволюционных нейронных сетей

Конволюционные сети могут различаться целым рядом характеристик, которые, в свою очередь, различают их по числу параметров (и, следовательно, времени обучения и обработки сигнала) и точности. Для исследования этого аспекта в экспериментах для сравнения были использованы несколько модификаций конволюционных сетей. Результаты их точности, время на обучение и некоторые другие параметры представлены в таблице 4.4.

Различные модификации были получены путем варьирования числа карт черт, формируемых каждым из конволюционных слоев. Таким образом, были получены сопоставимые архитектуры сетей с различным числом переменных (весов синаптических связей). Показатели точности каждой из них показаны на графике на рисунке 4.10.

	Число карт черт				
Молифи-	конволюционного слоя			Число пара-	Точность
кация ИНС	Первый слой	Второй слой	Третий слой	метров	сети
1	3	5	50	13268	0.94
2	5	10	100	51500	0.96
3	7	15	150	114732	0.96
4	10	30	200	304000	0.96
5	20	50	500	1256080	0.97
6	50	100	700	3564110	0.96

Таблица 4.4 - Зависимость точности сети от числа синаптических связей

Подобный характер зависимости числа переменных параметров (весов синаптических связей) в нейронной сети от ее точности был вполне ожидаем. Точность сети растет с числом параметров до достижения некоторого максимума, а затем начинает снижаться, т.к. сеть с избыточным числом параметров становится предрасположенной к переобучению (overfit). Несмотря на то, что эта зависимость широко известна, в данном случае она позволяет осуществить подбор сети по соотношению «число параметров - точность»



Number of params, x10³

Рисунок 4.10 - Зависимость точности ИНС от общего числа ее параметров

Выводы по главе 4

1. Проведены экспериментальные исследования влияния архитектур разработанных нейронных сетей на их точностные параметры характеристик нейронных сетей, а также на процесс обучения двухветвенной нейронной сети.

2. Разработана модернизированная информационно-измерительная система с нейросетевым программным анализатором термограмм, который применяется при

инфракрасной термографии электронных блоков. Точность классификации неисправностей зависит от вида контролируемого прибора. Для печатных плат электронных приборов получена точность классификации 97,5% при обучении в 300 эпохах с темпом обучения 0,00005. Достигнуто сокращение времени диагностирования на 20% по сравнению с обработкой данных оператором.

3. Выполнено внедрение метода интеллектуализации и нейросетевого программного анализатора в системы контроля элементов инфраструктуры железной дороги, в частности, для контроля контактной сети и диагностики рельсовых стыков.

Практические результаты подтвердили обоснованность и достоверность научных результатов диссертационного исследования.

ЗАКЛЮЧЕНИЕ

Все задачи исследований, поставленные в диссертации, выполнены.

Основные выводы и результаты, полученные в работе:

1. Проведен анализ существующих информационно-измерительных систем тепловизионного контроля и диагностирования. Выявлено, что наибольшее время при диагностике занимает процедура сравнения измеренных термограмм с эталонными образцами. Показано, что точность классификации отказов в объекте контроля, выполняемая оператором-термографистом, недостаточно высокая. Для повышения достоверности и оперативности контроля объектов в процессе их эксплуатации предложено проводить интеллектуализацию информационно-измерительной системы диагностирования с использованием искусственных нейронных сетей.

2. Для диагностирования электронных приборов и элементов систем управления построены модели теплового состояния двух видов: а) на основе расчетных моделей приборов, выполненных в системе АСОНИКА-ТМ, б) модели на основе уравнения теплопроводности, в которой с помощью вариативных параметров имитируются неисправности различного рода для последующего обучения нейронной сети.

3. На основе анализа существующих разновидностей нейронных сетей сделан вывод о том, что наиболее подходящей для задачи классификации термограмм электронных приборов является глубокая конволюционная ветвь с полем 225х225 пикселов. Показано, что для анализа дополнительно измеряемых параметров объекта контроля целесообразно использовать полносвязную нейронную сеть.

4. Разработан метод интеллектуализации информационно-измерительных систем тепловизионного диагностирования и реализован нейросетевой программный анализатор термограмм, представляющий собой двухветвенную нейронную сеть в виде комбинации конволюционной и полносвязной сетей.

148

5. С целью повышения точности классификации предложена функция активации в двухветвенной нейронной сети, реализованная в виде последовательного выполнения нормализации по диапазону и линейной нормализации.

6. На основе предложенного метода интеллектуализации разработана архитектура и общая структура ИИИС ТД для диагностики различных технических объектов.

7. Разработаны структурные модели измерительных каналов интеллектуальной ИИС. Выполнен анализ инструментальных погрешностей, при этом показано, что основной канал измерения термограмм с помощью тепловизора обеспечивает основную приведенную погрешность не более 0,5%. Исследованы факторы, определяющие методическую погрешность, вносимую нейронной сетью в процесс классификации термограмм. Сделан вывод, что основным фактором является зашумленность исходных термограмм, используемых при обучении. На множестве из 250 термограмм получена точность классификации не менее 98% при обучении в 300 эпохах с темпом обучения 0,00005.

8. Разработана методика декомпозиции программной логики нейронной сети в составе нейросетевого программного анализатора. Предложен шаблон «Проектировочный грид», использующий упорядоченность абстрактных классов и программных интерфейсов по сложности выбранной метрики ПО. Сокращение времени проектирования программного кода ИНС составило не менее 25%.

9. Проведены экспериментальные исследования разработанных метода и нейронных сетей при построении ИИС диагностирования различного назначения.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Абрамов, Н.С. Применение искусственных нейронных сетей в задачах контроля и диагностики подсистем космических аппаратов/Н.С. Абрамов, В.Ф. Заднепровский, А.А. Талалаев, В.П. Фраленко //Современные проблемы науки и образования. – 2014. – № 3. – Режим доступа: http://www.science-education.ru/ru/article/view?id=13242 (дата обращения: 02.05.2018)

 Айвазян, С.А. Прикладная статистика. Основы эконометрики. 2-е изд. /С.А. Айвазян, В.С. Мхитарян– М.: Юнити, 2001. – 656 с.

3. Артюшкин, И.В. Нейросетевая система управления процессом термохимического обезвоживания нефтяных эмульсий/Дис. канд. техн. наук: 05.13.06//И.В. Артюшкин//Самарский государственный технический университет, 2018. - 140 с.

4. АСОНИКА-ТМ: стойкость конструкций РЭС к тепловым, механическим и комплексным воздействиям. Сайт ООО «НИИ «АСОНИКА» [Электронный pecypc]. – Режим доступа: https://asonika-online.ru/products/asonika-tm/ (дата обращения: 04.02.2019)

5. Ахполова, Е.А. Техническая диагностика оптико-электронного преобразователя системы дистанционного зондирования Земли/Е.А. Ахполова, С.П. Орлов//Вестник Волжского ун-та им. Татищева. – 2015. - № 2(24). –С. 63-71.

6. Ахполова, Е.А. Информационно-измерительная система для контроля оптико-электронного преобразователя по тепловой картине ПЗСматрицы/Дис. канд. техн. наук: 05.11.16/Пензенский государственный университет. – 2016. – 142 с. 7. Бекешко, Н.А. Тепловые методы неразрушающего контроля изделий и элементов радиоэлектроники / Н.А. Бекешко //Измерение, контроль, автоматизация. – 1979. – № 5. – С. 13-24.

 Белозеров, А.Ф. Современные направления применения ИК радиометров и тепловизоров в научных исследованиях и технике /А.Ф. Белозеров, А.И. Омелаев, В.Л. Филиппов // Оптический журнал. – 1998.
 – №6 – С. 16-20.

9. Биргер, И.А. Техническая диагностика /И.А. Биргер. – М.: Машиностроение, 1978. – 240 с.

10. Буч, Г. Объектно-ориентированный анализ и проектирование с примерами приложений. 3-е издание/Г. Буч. - М.: ООО «И.Д. Вильямс», 2008. - 720 с.

Буч, Г. Язык UML. Руководство пользователя/Г. Буч, Дж. Рамбо,
 И. Якобсон. – М.: ДМК Пресс, 2006. – 496 с.

12. Вавилов, В.П. Инфракрасная термография и тепловой контроль/В.П. Вавилов. – М.: ИД Спектр, 2009. – 544 с.

Вавилов, В.П. Тепловизоры и их применение /В.П. Вавилов, А.Г.
 Климов. – М.: Интел универсал, 2002. – 88 с.

14. Гаврилова, Н.М. Применение алгоритмов машинного обучения для поиска рельсовой колеи/ Н.М. Гаврилова, И.А. Дейлид, С. А. Молодяков// Труды XXI Международной конференции по мягким вычислениям и измерениям (SCM-2018). - СПб.: СПбГЭТУ «ЛЭТИ», 2018. – С. 139-142.

15. Галушкин, А. И. Синтез многослойных систем распознавания образов/А.И. Галушкин. — М.: Энергия, 1974.

16. Гаскаров, Д.В. Интеллектуальные информационные системы: учеб. пособие для вузов /Д.В. Гаскаров. – М. : Высш. Шк., 2003. – 431 с. 17. Гирин, Р.В. Двухстадийная нормализация выходных сигналов искусственных нейронных сетей /Р.В. Гирин, С.П. Орлов //Вестник Самарского гос. тех. ун-та. Серия «Технические науки». – 2017. – № 4(56). – С.7-16.

18. Гирин, Р.В. Искусственная нейронная сеть для диагностики объектов по термограммам/Р.В. Гирин//Труды Международной научнотехнической конференции «Перспективные информационные технологии (ПИТ 2018)».- Самара: Изд-во Самар. научн. центра РАН. – 2018. – С. 434-437.

19. Гирин, Р.В. Шаблон проектирования доменных классов искусственных нейронных сетей/ Р.В. Гирин , С.П. Орлов //Системы управления и информационные технологии. – 2018. - №2(72). – С. 22-28

20. Гирин, Р.В. Объектно-ориентированная декомпозиция программной логики искусственных нейронных сетей/ Р.В. Гирин, С.П. Орлов // Онтология проектирования. - 2018. –Т.8. - №1(27). – С.110 – 123.

21. Гирин Р.В. Анализ метрологических характеристик тепловизионной системы технического диагностирования с нейронной сетью/Р.В. Гирин // Вестник Самарского гос. тех. ун-та. Серия «Технические науки». – 2018. – № 4. – С.66-81.

22. Гирин Р.В. Искусственная нейронная сеть для технической диагностики систем управления методом термографии/ Р.В. Гирин Р.В., С.П. Орлов, Уютова О.Ю.//Труды IV Международной научно-технической конференции «Пром-Инжиринг», 2018.

23. Гирин Р.В. Нейросетевой программный анализатор для контроля элементов железнодорожного пути/Р.В. Гирин, С.П. Орлов//Вестник Самарского государственного университета путей сообщения. - 2019. - № 2. – С.21-30.

24. Гирин Р.В. Нейросетевые технологии при контроле движущихся объектов по тепловой картине/Р.В. Гирин//Наука и образование транспорту: материалы XI Международной научно-практической конференции (2018, Самара). . Том 2. – Самара: СамГУПС, 2018. С.28-31.

25. Гирин Р.И. Программа для реализации обучения искусственных нейронных сетей для классификации объектов/Р.В. Гирин, С.П. Орлов, С.В. Сусарев. Свидетельство о государственной регистрации программы для ЭВМ № 2019612598 от 22.02.2019 г.

26. Гирин Р.В. Программная библиотека средств конструирования логики искусственных нейронных сетей/Р.В. Гирин. Свидетельство о государственной регистрации программы для ЭВМ № 2019613046 от 06.03. 2019 г

27. Горюнов, Н.Н. Интегральный ИК-радиометр с неохлаждаемым приемником для контроля качества полупроводниковых приборов и микросхем / Н.Н. Горюнов, В.С. Бромов, В.С. Хмарцев. – М.: Электронная техника, 1974. – Вып. 1, сер. 2. – 112 с.

28. Госсорг, Ж. Инфракрасная термография. Основы, техника, применение /Ж. Госсорг; пер. с франц. – М.: Мир, 2005. – 416 с.

29. ГОСТ 27518-87 Диагностирование изделия. Общие требования – переизданное. – М.: Стандартинформ, 2009. –7 с.

ГОСТ Р 53698-2009 Контроль неразрушающий. Методы тепловые.
 Термины и определения. – М.: Стандартинформ, 2010. – 10 с.

31. ГОСТ Р 8.596-2002. Государственная система обеспечения единства измерений (ГСИ). Метрологическое обеспечение измерительных систем. Основные положения. - М.: ИПК Издательство стандартов, 2002.

 ГОСТ Р ИСО 13372-2013. Контроль состояния и диагностика машин. Термины и определения. - М.: Стандартинформ, 2014. – 21 с. 33. ГОСТ Р ИСО 18434-1-2013. Контроль состояния и диагностика машин. Термография. Часть 1. Общие методы. - М.: Стандартинформ, 2014. – 28 с.

34. Данилин, Н.С. Неразрушающий контроль качества продукции радиоэлектроники /Н.С. Данилин. – М.: Издательство стандартов, 1976. – 240 с.

35. Дорогов, А.Ю. Теория и проектирование быстрых перестраиваемых преобразований и слабосвязанных нейронных сетей/А.Ю. Дорогов. – СПб.: Политехника, 2014. – 328 с.

36. Дружинина, Л. В. Анализ и классификация погрешностей обучения информационно-измерительных систем на базе нейронных сетей/Л.В. Дружинина, Д.Г. Дружинин// Молодой ученый. - 2016. - № 21(125). - С. 127-129.

Дульнев, Г.Н. Методы расчета теплового режима приборов /Г.Н.
 Дульнев, В.Г. Парфенов, А.В. Сигалов. – М.: Радио и связь, 1990. – 312 с.

38. Жуков, А.Г. Тепловизионные приборы и их применение /А.Г.
Жуков, А.Н. Горюнов, А.А. Кальфа. – М.: Радио и связь, 1983. – 166 с.

39. Иванов А.И. Многомерная нейросетевая обработка биометрических данных с программным воспроизведением эффектов квантовой суперпозиции/А.И. Иванов. – Пенза: Изд-во АО «Пензенский научноисследовательский электротехнический институт», 2016. – 133 с.

40. Интеллектуальная информационная система технической диагностики состояния подвижных миксеров/В.А. Емельянов, Н.Ю. Емельянова, ФГАОУ ВО «Крымский федеральный университет им. В.И. Вернадского//Патент RU 2641682. G06N3/02, G01N25/00. 2018.

41. Ишков, А.С. Измерительно-управляющая система для испытаний на импульсную термоэлектротренировку радиоэлектронных компонентов/

А.С. Ишков, Г.А. Солодимова, А.В. Светлов//Приборы и техника эксперимента. - 2016. - № 3. - С. 157-158.

42. Ишков, А.С. Контроль технического состояния резистивных потенциометров с применением растровой электронной микроскопии/А.С. Ишков, А.В. Светлов, Г.А. Солодимова, С.И. Торгашин//Измерение. Мониторинг. Управление. Контроль. – 2017 - . № 4 (22). - С. 77-83.

43. Канарчук, В.Е. Бесконтактная тепловая диагностика машин / В.Е. Канарчук, А.Д. Чигринец. – М.: Машиностроение, 1987. – 160 с.

44. Кобяков, П.В. Измерение параметров динамических систем на основе искусственных нейронных сетей, использующих алгоритм Калмана/П.В. Кобяков//Автореф. дис. на соиск. учен. степ. канд. техн.наук: 05.11.16. – СПБ: СПб ГПУ, 2004. – 16 с.

45. Комарцова, Л.Г. Нейрокомпьютеры/Л.Г. Комарцова, А.В. Максимов. М.: МГТУ им. Н. Э. Баумана, 2004 г.

46. Кофанов, Ю.Н. Моделирование тепловых процессов при проектировании, испытаниях и контроле качества РЭС /Ю.Н. Кофанов, А.И. Манохин, С.У. Увайсов. – М.: МГИЭМ, 1998. – 140 с.

47. Кофанов, Ю.Н. Повышение надежности приборов выявлением скрытых дефектов комплектующих элементов /Ю.Н. Кофанов, С.У. Увайсов, К.Н. Касьян// Измерительная техника. – 1996. – № 3. – С. 24-27.

48. Кузнецов, Г.В. / Разностные методы решения задач теплопроводности: учеб. пособие / Г.В. Кузнецов, М.А. Шеремет. – Томск: Изд-во ТПУ, 2007. – 172 с.

49. Кулаков, М.В. Измерение температуры поверхности твердых тел /М.В. Кулаков, Б.И. Макаров. – М.: Энергия, 1969. – 136 с.

50. Куликовский, Л.Ф. Основы информационной техники / Л.Ф. Куликовский, В.К. Морозов. – М.: Высшая школа, 1977. – 360 с. 51. Мак-Каллок, У. С. В. Логическое исчисление идей, относящихся к нервной активности/У.С. Мак-Каллок, В. Питтс // Автоматы / Под ред. К. Э. Шеннона и Дж. Маккарти. — М.: Изд-во иностр. лит., 1956. — С. 363—384.

52. Марусина, М.Я. Основы метрологии, стандартизации и сертификации: учеб. пособие/М.Я. Марусина, В.Л. Ткалич, Е.А. Воронцов, Н.Д. Скалецкая. – СПб.: СПбГУ ИТМО, 2009. – 164 с.

53. МИ 222-80. Методика расчета метрологических характеристик измерительных каналов информационно-измерительных систем по метрологическим характеристикам компонентов. – М.: Издательство стандартов, 2005. – 24 с.

54. Надежность и эффективность в технике: Справочник. В 10 т. / Ред.совет: В.С. Авдуевский (пред.) [и др.], Т. 9. Техническая диагностика/ под общ. ред. В.В. Клюева, П.П. Пархоменко – М.: Машиностроение, 1987. – 352 с.

55. Нестерук, Д.А. Тепловой контроль и диагностика: учеб. пособие/Д.А. Нестерук, В.П. Вавилов. – Томск:, 2007. – 104 с.

56. Орлов, С.А. Программная инженерия/С.А. Орлов. Учебник для вузов. 5-е изд. – СПб.: Питер, 2016. – 640 с.

57. Орлов, С.П. Интеллектуализация информационно-измерительных систем контроля и диагностирования на основе нейросетевых технологий /С.П. Орлов, Р.В. Гирин, О.Ю. Уютова// Мягкие измерения и вычисления. – 2018. - № 4. - С.4-12.

58. Орлов, С.П. Интеллектуализация контроля и диагностики электронных приборов на основе нейронных сетей/С.П. Орлов, Р.В. Гирин//Труды XXI Международной конференци по мягким вычислениям и измерениям (SCM-2018). - СПб.: СПб ГЭТУ «ЛЭТИ», 2018. – С. 99-102. 59. Орнатский, П.П. Теоретические основы информационноизмерительной техники /П.П. Орнатский. – Киев: Вища школа, 1983. – 455 с.

60. Ощенков, П.К. Вопросы развития тепловых методов неразрушающего контроля в электронике /П.К. Ощенков, Н.А. Бекешко //Физикотехнические методы неразрушающего контроля элементов и приборов электронной техники. – М.: Сов. Радио, 1969. – С. 79-88.

61. Павлов Д.Ю. Решение обратной коэффициентной задачи теплопроводности с помощью нейросети/Д.Ю. Павлов//Вестник МГУ. Серия 15 ВМК. – 1994. – №4. – С. 51-56.

62. Пархоменко, П.П. Основы технической диагностики. Модели объектов, методы и алгоритмы диагноза / П.П. Пархоменко, В.В. Карибский, Е.С. Согомонян, В.Ф. Халчев. – М.: Энергия, 1976. – 464 с.

63. Патанкар, С.В. Численное решение задач теплопроводности и конвективного теплообмена при течении в каналах /С.В. Патанкар. – Пер. с англ. Е.В. Калабина; под. ред. Г.Г. Янькова. – М. : Изд-во МЭИ, 2003. – 312 с.

64. Рыбаков, И.М. Информационнно-измерительная система исследования теплообмена проводящих слоев печатного узла/Дис.канд. техн. наук: 05.11.16, 05.11.14//И.М. Рыбаков//Пензенский государственный университет, 2018. – 173 с.

65. РМГ 29-2013. Государственная система обеспечения единства измерений. Метрология. Основные термины и определения. - М.: Стандартинформ, 2014.

66. Самарский, А.А. Теория разностных схем /А.А. Самарский – М. : Наука, 1977. – 656 с.

67. Светлов А.В. Методики входного контроля операционных усилителей/А.В. Светлов, М.Ю. Паршуков, В.В. Комаров, Е.В. Сапунов//Надежность и качество сложных систем. - 2014. - № 2 (6). - С. 56-61. 68. Селиванова, З.М. Интеллектуализация информационноизмерительных систем неразрушающего контроля теплофизических свойств твердых материалов/З.М. Селиванова. – М.: Изд-во «Машиностроение-1», 2006. – 184 с.

69. Селиванова, З.М. Математические модели и алгоритм для совершенствования информационно-измерительной системы неразрушающего контроля теплофизических свойств материалов/ З.М. Селиванова, Т.А. Хоан// Вестник Тамбовского государственного технического университета. - 2016. -Т. 22. - № 4. - С. 520-534.

70. Селиванова, З.М. Комплексный метод повышения точности информационно-измерительной системы для определения теплофизических свойств материалов при воздействии дестабилизирующих факторов/ З.М. Селиванова, Т.А. Хоан //Измерительная техника. - 2017. - № 5. - С. 44-48.

71. Сенашова, М.Ю. Погрешности нейронных сетей/М.Ю. Сенашова//Методы нейроинформатики/Под ред. А.Н. Горбаня. – Красноярск: КГТУ, 1998. – 205 с.

72. Солдатов, А.А. Информационно-измерительная система контроля функционирования комплекса многопараметрического учета распределенного энергопотребления на основе искусственной нейронной сети/А.А. Солдатов/Дис. канд. техн. наук: 05.11.16/ Казанский национальный исследовательский университет им. А.Н. Туполева - КАИ. – 2019. – 167 с.

73. Стасенко, К.С. Метод и интеллектуальная информационноизмерительная система для повышения точности допускового контроля теплопроводности теплоизоляционных материалов/ К.С. Стасенко, З.М. Селиванова// Вестник Тамбовского государственного технического университета. -2015. - Т. 21. - № 1. - С. 42-49. 74. Сферы применения тепловизоров//НТЦ «Эксперт», 2018. – Режим доступа: http://www.ntcexpert.ru/44-in4/k44/523-sfery-primenenija-teplovizorov-76803588 (дата обращения: 09.06.2018)

75. Тихонов А.Н. Методы решения некорректных задач/А.Н. Тихонов,В.Я. Арсенин. – М.: Наука, 1979. – 288 с.

76. Увайсов, С.У. Методы диагностирования радиоэлектронных устройств систем управления на протяжении их жизненного цикла / Дис. докт. техн. наук: 05.13.05/ С.У. Увайсов; Московский государственный институт электроники и математики (технический университет). – Москва, 2000. – 506 с.

77. Увайсов, С.У. Обеспечение возможности моделирования печатных узлов сложной формы в АСОНИКА-ТМ / С.У. Увайсов, К.И. Беляков//Инновации на основе информационных и коммуникационных технологий. - 2012. - № 1. - С. 315-316.

78. Федоров, В.К. Контроль и испытания в проектировании и производстве радиоэлектронных средств / В.К. Федоров, Н.П. Сергеев, А.А. Кондрашин. – М.: Техносфера, 2005. – 502 с.

79. Хадсон, Р. Инфракрасные системы /Р. Хадсон. – М.: Мир, 1972. – 530 с.

80. Харисова, З.И. Информационно-измерительная система для гранулометрического анализа жидких дисперсных сред на основе видеотехнических средств и нейросетевых технологий/Дис. канд. техн. наук: 05.11.16//З.И. Харисова//Уфимский государственный авиационный технический университет, 2018. - 157 с.

Цапенко, М.П., Измерительные информационные системы:
 Структуры и алгоритмы, системотехническое проектирование: учеб. пособие для вузов. — 2-е. изд. — М.: Энергоатомиздат, 1985. — 438 с.

82. Цветков, Э.И. Основы математической метрологии/Э.И. Цветков.– СПб.: Политехника, 2005

83. Шлыков, Г.П. Теория измерений: уравнения, модели, оценивание точности: учеб. пособие/Г.П. Шлыков. – Пенза: Изд-во Пенз. гос. ун-та, 2008. – 100 с.

84. Шляндин, В.М. Цифровые электроизмерительные приборы /В.М. Шляндин, В.В. Богданов, А.А. Богородицкий, Д.И. Леонтьев [и др.]; под ред. В.М. Шляндина. – М.: Энергия, 1972. – 400 с.

85. Яковлев, Н.И. Бесконтактные электроизмерительные приборы для диагностирования электронной аппаратуры / Н.И. Яковлев. – Л.: Энергоатомиздат, 1990. – 256 с.

86. Ярочкина, Г.В. Радиоэлектронная аппаратура и приборы: монтаж и регулировка / Г.В. Ярочкина. – М.: ИРПО; ПрофОбрИздат, 2002. – 240 с.

87. Ярушкина, Н. Г. Основы теории нечетких и гибридных систем:
учеб. пособие / Н. Г. Ярушкина. - Москва : Финансы и статистика, 2004. - 319
с.

88. Яхъяева, Г. Э. Нечеткие множества и нейронные сети : учеб. пособие / Г. Э. Яхъяева. - 2-е изд., испр. - Москва : Интернет-Ун-т Информ. Технологий ; БИНОМ. Лаб. знаний, 2008. - 315 с.

89. Abreu, F.B. The Design of Eiffel Programs: Quantitative Evaluation Using the MOOD metrics/F.B. Abreu, R. Esteves, M. Goulao//Proc. of the TOOLS'96. – 1996. - 20 pp.

90. Bieman, J.M. Cohesion and Reuse in Object-Oriented Systems/ J.M. Bieman, B-K. Kang //Proc. ACM Symposium on Software Reusability (SSR'95). – 1995. – P. 259-265.

91. Briand, L.C. A Unified Framework for Coupling Measurements in Object-Oriented Architectural Elements/ L.C. Briand, J.W. Daly, J.K. Wust //IEEE Transaction on Software Engineering. – 1999. Vol. 25. – P. 91-121.

92. Canziani, A. An Analysis of Deep Neural Network Models for Practical Applications/A. Canziani, A. Paszke, E. Culurciello //CoRR, 2016, volume abs/1605.07678

93. Chrzanowski, K. Error of temperature measurement with multiband infrared systems/ K. Chrzanowski, M. Szulim //Applied Optics. – 1999. – Vol. 38. – N_{010} . – P. 1998.

94. Fishbune, R.J. Infrared thermography for electronic assembly design verification/R.J. Fishbune//IBM Power Technology and Qualificatrion, 2000. – 7 p.

95. Fowler, M. Inversion of Control Containers and the Dependency Injection pattern /M. Fowler. - URL: https://www.martinfowler.com/articles/ injection.html (дата обращения: 12.12.2018)

96. Fowler, M. Patterns of Enterprise Application Architecture/M. Fowler.
Addison-Wesley, 2002. – 560 p.

97. Fowler, M. Refactoring: Improving the Design of Existing Code, 1st Edition/M. Fowler. - Addison-Wesley Professional, 1999. – 431 p.

98. Gamma, E. Design Patterns: Elements of Reusable Object-Oriented Software/E. Gamma, R. Helm, R. Johanson, J. Vlissides. – Addison-Wesley Professional, 1994. - 395 p.

99. Girin, R.V. The use of neural networks for testing and failure analysis of electronic devices /R.V. Girin, S.P. Orlov// Proc. of the II International Scientific-Practical Conference "Fuzzy Technologies in the Industry (FTI 2018)". - CEUR-WS.org/Vol – 2258/paper21. – 2018. – pp. 160-167.

100. Goodfellow, I. Deep learning/I. Goodfellow, Y. Bengio, Y. Courville. – URL: http://www.deeplearningbook.org (дата обращения: 11.03.2018)

101. Grother, P. NIST Special Database 19 Handprinted Forms and Characters, 2nd Edition/P. Grother, K. Hanaoka. - National Institute of Standards and Technology, September 13, 2016.

102. He, K. Deep Residual Learning for Image Recognition/ K. He, X. Zhang, S. Ren, J. Sun//IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – 2016. – P. 770-778

103. Heller, P. Thermal imaging speeds circuit design by Pinpointing Hot Spots/P. Heller// EDN. – 23 February 1997. – P. 79-86.

104. Hykin, S. Neural networks. A Comprehensive Foundation. Second Edition /S. Hykin. - Prentice Hall, 1999. – 905 p.

105. Ioffe, S. Batch normalization: Accelerating deep network training reducing internal covariate shift/ S.Ioffe, C. Szegedy//Cornell University Library. -URL: https://arxiv.org/abs/1502.03167v3 (дата обращения: 12.12.2018)

106. Jacobsen, I. Object Oriented Software Engineering: A Use Case Driven Approach /I. Jacobsen, M. Christerson, P. Jonsson, G. Overgaard. - Addison-Wesley/ACM Press, 1992. – 56 p.

107. Krizhevsky, A. ImageNet classification with deep convolutional neural networks/A. Krizhevsky, I. Sutskever, G. Hinton // NIPS'12 Proceedings of the 25th International Conference on Neural Information Processing Systems. - 2012. - Vol. 1. - P. 1097-1105.

108. Kuball, M. Integrated Raman-IR thermography for reliability and performance optimization, and failure analysis of electronic device/ M. Kuball, A. Sarua, J.W. Pomeroy, A. Falk, A. Albright, M.J. Uren, T. Martin// Conference Proceedings from the 33rd International Symposium for Testing and Failure Analysis, ISTFA 2007, USA. – ASM International. - 2007. – P. 1-5.

109. LeCun, Y. Gradient-based learning applied to document recognition/
Y. LeCun, L. Bottou, Y Bengio, P. Haffner. - Piscataway, NJ, USA. IEEE Press. –
2001. – P. 306–351.

110. Maldague, X.P.V. Theory and practice of infrared technology for nondestructive testing / X.P. V. Maldague. – John Wiley & Sons, Inc., U.S.A., 2001. – 704 p.

111. Meyer, B. Object-Oriented Software Construction. 2nd ed./B. Meyer. –Prentice Hall, 1997. – 1254 p.

112. Mittal, S. A Survey of CPU-GPU Heterogeneous Computing Techniques/S. Mittal, J. Vetter//ACM Computing Surveys (CSUR). - 2015. – Vol.47 (№ 4). - P. 1–35.

113. Machine Learning in Python. Decomposing signals in components. https://scikit-learn.org/stable/modules/decomposition.html#decompositions (дата обращения 24.09.2018).

114. Nair, V. Rectified Linear Units Improve Restricted Boltzmann Machines/V. Nair, G. Hinton //Proceedings of ICML. - 2010. -V. 27. - P. 807-814.

115. Nielsen, M. Neural Networks and Deep Learning, free online book/M.
Nielcen. – URL: http://neuralnetworksanddeeplearning.com (дата обращения 16.11.2017)

116. Norvig, P. Artificial Intelligence: A Modern Approach, Edition: 3rd/P.Norvig, S. Rassell. - Pearson, 2010. -1109 p.

117. Orlov, S.P. Intelligent measuring system for testing and failure analysis of electronic devices/S.P. Orlov, A.N. Vasilchenko//2016 XIX IEEE International Conference on Soft Computing and Measurements. – 2016. V.1. – P.401-403.

118. Ott, L. Developing Measures of Class Cohesion for Object-Orientied Software/ L. Ott, J.M. Bieman, B-K. Kang, B. Mehra//Proc. Annual Oregon Workshop of Software Metrics (AOWSM'95). – 1995. – 11 p.

119. Peterman, D. Radiometry of Semiconductor Devices. IEEE International Convent / D. Peterman // Record. – 1967. – P. 78. 120. Randle, W.R. The Application of Infrared Measurements Techniques to Electronic Design and Testing / W.R. Randle // Applied Optics. – 1998. – Vol. 7, № 7. – P. 1796.

121. Richter, J. CLR via C#, 4th Edition/J. Richter. - Microsoft Press, 2012.– 896 p.

122. Rumelhart, D. E. Learning Internal Representations by Error Propagation/D.E. Rumelhart, G.E. Hinton, R.J. Williams// Parallel Distributed Processing: explorations in the microstructure of cognition. Cambridge, MA: MIT Press. – 1986. - Vol. 1. – P. 318-362.

123. Russakovsky, O. Imagenet large scale visual recognition challenge/ O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, Z. Huang, A. Karpathy, A. Khosla, M. Bernstein.//International Journal of Computer Vision. -2014. - Vol. 115. – P. 211-252.

124. Sahin, H. Orthorectification by using gpgpu method, International Archives of the Photogrammetry/ H. Sahin, S. Kulur // Remote Sensing and Spatial Information Sciences, XXII ISPRS Congress. – 2012. - Vol. XXXIX-B4.

125. Sarua, A. Integrated Raman/IR thermography for monitoring of selfheating in AlGaN/GaN transistor structure/A Sarua, H. Ji, M. Kuball, M.J.Uren, T. Martin, , K.P. Hilton, R.S. Balmer //IEEE Trans. Electron Dev., 2006. - Vol. 53. N. 10. - P. 2438-2447.

126. Sedgewick, R. Algorithms.4th Edition/R. Sedgewick, K. Wayne. -Addison-Wesley Professional, 2011. - 992 p.

127. Szegedy, C. Going deeper with convolutions/C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S.E. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, A. Rabinovich // IEEE Conference on Computer Vision and Pattern Recognition (CVPR)/ - 2015. - P. 1-9.

128. Tilouche, Sh. Classification Algorithms for Virtual Metrology/Sh. Tilouche, S. Basseto, V.P. Nia //Proc. 2014 IEEE International Conference on Management of Innovation and Technology, Singapore, 2014. – P.495-499.

129. Troelsen, A. Pro C# 7: With .NET and .NET Core. 8th Edition /A. Troelsen, P. Japikse. - Apress, 2017. – 1410 p.

130. Vasilev, I. Java deep learning library. – URL: https://github.com/ivanvasilev/neuralnetworks (дата обращения 26.11.2017)

131. Xavier, P. V. Maldague. Theory and Practice of Infrared Technology for Nondestructive Testing/ P. V. Maldague Xavier. - John Wiley & Sons, Inc., 2001, 684 p.

132. Yangqing, J. Caffe, Сайт проекта/J. Yangqing. – URL: http://caffe.berkeleyvision.org/. (дата обращения: 03.09.2017)

133. Zeiler, M.D., Fergus R. Visualizing and Understanding Convolutional Networks /M.D. Zeiler, R. Fergus//Computer Vision – ECCV 2014. Lecture Notes in Computer Science. – 2014.- Vol. 8689. - P. 818-833.

134. Van der Maaten, L. Visualizing Data using t-SNE/ L. Van der Maaten,
G. Hinton// Journal of Machine Learning Research. - 2008. – Vol. 9. – P. 2579 –
2605.

СПИСОК СОКРАЩЕНИЙ И УСЛОВНЫХ ОБОЗНАЧЕНИЙ

- АЦП аналого-цифровой преобразователь
- ДНС двухветвенная нейронная сеть
- ИИИС интеллектуальная ИИС
- ИИС информационно-измерительная система
- ИКТ инфракрасная термография
- ИНС искусственная нейронная сеть
- ПЗС приборы с зарядовой связью
- ПО программное обеспечение
- СПР система принятия решений
- ТД тепловизионное диагностирование
- ТМНК температурные методы неразрушающего контроля
- ФМ ПЗС фоточувствительная матрица на ПЗС
- ADC абстрактные доменные классы
- GPU графический процессор
- **MDS** метод многомерного шкалирования
- MI «подмешанные» (mixin) интерфейсы
- РСА метод главных компонент
- t-SNE- Т-распределенное стохастическое встраивание соседей

ПРИЛОЖЕНИЕ А

ДОКУМЕНТЫ О ВНЕДРЕНИИ РЕЗУЛЬТАТОВ ДИССЕРТАЦИОННОГО ИССЛЕДОВАНИЯ



АКТ

о внедрении результатов диссертационной работы Гирина Романа Викторовича «Интеллектуальная информационно-измерительная система тепловизионного диагностирования технических объектов на основе нейронной сети», представленной на соискание ученой степени кандидата технических наук

Комиссия в составе первого заместителя генерального директора по научно-технической политике Симакова О.Б., руководителя методикотехнологического департамента, к.т.н. Ефремова Д.В., заместителя руководителя департамента аппаратных разработок, к.т.н. Урсова С.Н. составила настоящий акт о том, что результаты диссертационной работы Гирина Р.В. имеют высокую научную и практическую ценность и используются в научно-технических разработках АО НПЦ ИНФОТРАНС.

 Метод интеллектуализации информационно-измерительных систем на основе применения нейронных сетей использован в тепловизионной системе диагностики состояния элементов контактной сети, устанавливаемой на мобильные средства диагностики инфраструктуры ОАО «РЖД». Этот подход позволил сократить время автоматизированной обработки и оценки в 6 раз и повысить достоверность автоматического распознавания и классификации дефектных состояний элементов контактной сети по температурному режиму до 98%.

2. Адаптированный нейросетевой программный анализатор внедрён в программное обеспечение автоматической расшифровки изображений видеоизмерительной системы верхнего строения железнодорожного пути в части определения дефектов рельсовых скреплений и рельсовых накладок. Достоверность классификации дефектов элементов верхнего строения пути возросла до 94%.

Председатель комиссии:

Первый заместитель генерального директора по научно-технической политике

Члены комиссии:

Руководитель методико-технологического департамента, к.т.н.

Заместитель руководителя департамента аппаратных разработок, к.т.н.

О.Б. Симаков

Д.В. Ефремов

С.Н. Урсов

J J



AKT

об использовании результатов диссертационной работы Гирина Романа Викторовича «Интеллектуальная информационно-измерительная система тепловизионного диагностирования технических объектов на основе нейронной сети», представленной на соискание ученой степени кандидата технических наук

Комиссия в составе руководителя проекта, директора института автоматики и информационных технологий СамГТУ к.т.н., доцента Губанова Н.Г. и заместителя заведующего кафедрой «Автоматизация управление И технологическими процессами» СамГТУ к.т.н., доцента Сусарева С.В. составила настоящий акт о том, что результаты диссертационной работы Гирина P.B. использованы при выполнении проекта «Разработка роботизированной системы сельскохозяйственных автомобилей на базе семейства автомобилей КАМАЗ с автономным и дистанционным режимом управления» по соглашению № 075-02-2018-225 в рамках Федеральной целевой программы «Исследования и разработки по приоритетным направлениям развития научно-технологического комплекса России на 2014-2020 годы».

Разработанные Гириным Р.В. метод интеллектуализации ИИС и нейросетевой программный анализатор на базе искусственной нейронной сети использованы при проектировании диагностической тепловизионной системы контроля основных агрегатов роботизированного автомобиля КАМАЗ. Внедрение результатов позволяет повысить точность обнаружения аварийных состояний агрегатов в реальном времени при эксплуатации автомобиля.

Директор ИАИТ, к.т.н., доцент

Зам. зав. кафедрой АУТП к.т.н., доцент

Н.Г. Губанов

С.В. Сусарев



АКТ

о внедрении результатов диссертационной работы Гирина Романа Викторовича «Интеллектуальная информационно-измерительная система тепловизионного диагностирования технических объектов на основе нейронной сети», представленной на соискание ученой степени кандидата технических наук

Комиссия в составе к.э.н., доцента, начальника учебного управления Алонцевой Е.А., д.т.н., профессора, заведующего кафедрой «Вычислительная кафедрой заведующего к.т.н., доцента, Иващенко A.B., техника» Ярославкиной Е.Е., составила «Информационно-измерительная техника» настоящий акт о том, что результаты диссертационной работы Гирина Р.В. внедрены в учебный процесс на кафедрах «Вычислительная техника» и «Информационно-измерительная техника» при подготовке магистров по направлениям 09.04.01 «Информатика и вычислительная техника» и 12.04.01 «Приборостроение».

Теоретические результаты диссертационной работы Гирина Р.В. и программные средства для проектирования нейронных сетей в ИИС использованы в дисциплинах «Интеллектуальные системы и базы знаний» и «Интеллектуальные информационные системы», а также при выполнении выпускных квалификационных работ. Реализация полученных автором результатов позволила повысить эффективность и качество обучения.

Начальник УУ к.э.н., доцент

Е.А. Алонцева

Зав. кафедрой ВТ д.т.н., профессор

Heeceee Aupp

А.В. Иващенко

Зав. кафедрой ИИТ к.т.н., доцент

Е.Е. Ярославкина



