

На правах рукописи



Нгуен Ань Ту

**АЛГОРИТМИЧЕСКОЕ ОБЕСПЕЧЕНИЕ НЕЙРОННОЙ СЕТИ С ПОЛИНОМИ-
АЛЬНЫМИ КУСОЧНО-НЕПРЕРЫВНЫМИ ФУНКЦИЯМИ АКТИВАЦИИ ДЛЯ
ОБНАРУЖЕНИЯ ЗАКОНОМЕРНОСТЕЙ В ДАННЫХ**

Специальность: 05.13.01 – Системный анализ, управление и обработка информации
(научные исследования)

АВТОРЕФЕРАТ

диссертации на соискание ученой степени
кандидата технических наук

Томск 2019

Работа выполнена в федеральном государственном автономном образовательном учреждении высшего образования «Национальный исследовательский Томский политехнический университет» (ФГАОУ ВО НИ ТПУ) и в федеральном государственном бюджетном образовательном учреждении высшего образования «Томский государственный университет систем управления и радиоэлектроники» (ФГБОУ ВО «ТУСУР»)

Научный руководитель: доктор технических наук, профессор
Кориков Анатолий Михайлович

Официальные оппоненты: **Кошкин Геннадий Михайлович**, доктор физико-математических наук, профессор, ФГАОУ ВО «Национальный исследовательский Томский государственный университет» (г. Томск), профессор кафедры системного анализа и математического моделирования

Лемешко Борис Юрьевич, доктор технических наук, профессор, ФГБОУ ВО «Новосибирский государственный технический университет» (г. Новосибирск), главный научный сотрудник, профессор кафедры теоретической и прикладной информатики

Защита состоится «18» декабря 2019 г. в 15.00 часов на заседании диссертационного совета ДС.ТПУ.15 при ФГАОУ ВО «Национальный исследовательский Томский политехнический университет» по адресу: 634034, г. Томск, ул. Советская 84/3, ауд. 214.

С диссертацией можно ознакомиться в научно-технической библиотеке ФГАОУ ВО НИ ТПУ по адресу: г. Томск, ул. Белинского, 53а и на сайте: dis.tpu.ru

Автореферат разослан «___» _____ 2019 г.

Ученый секретарь
диссертационного совета



Пак Александр Яковлевич

ОБЩАЯ ХАРАКТЕРИСТИКА РАБОТЫ

Актуальность темы исследования. Методы и технологии искусственного интеллекта используются для решения многих практических задач: автоматизации и роботизации технологических процессов и производств, проектирование информационно-вычислительных систем, телекоммуникационных и компьютерных сетей и т.д. Искусственные нейронные сети и технологии, базирующиеся на них, занимают лидирующие позиции среди методов и технологий искусственного интеллекта. В естественных и технических науках задачи делятся на формализуемые и неформализуемые. С развитием науки и техники количество неформализуемых задач постоянно растет. К числу неформализуемых задач относятся и задачи обнаружения скрытых закономерностей в наборах данных. Для их решения развиваются специальные приемы и методы, обобщенные в теории систем и системном анализе, создаются экспертные системы – интеллектуальные системы, основанные на знаниях. Роль методов искусственного интеллекта, теории нейронных сетей и нейросетевых технологий в реализации методик системного анализа и разработке интеллектуальных систем трудно переоценить. Решение неформализуемых задач осложняется различными видами НЕ-факторов знаний: неопределенность, нечеткость, неточность, недоопределенность и неполнота знаний эксперта о свойствах проблемной области. Таким образом, задача обнаружения скрытых закономерностей в наборах данных на основе нейросетевых технологий является актуальной в научном аспекте и практически значимой.

Степень научной разработанности проблемы. Для повышения эффективности систем обработки информации и снижения вычислительных затрат, в теории нейронных сетей и нейросетевых технологий разрабатываются новые функции активации. Большая работа в этом направлении проведена такими авторами, как Билски Дж., Вонг К.В., Леунг К.С., Нага К., Накауама К., и др. Билски Дж. предложил новую логарифмическую функцию активации (ФА). Сравнение логарифмической ФА и ФА, основанных на экспонентах, сделано Азизом С.М., Камруззаманом Дж. Авторы исследуют скорость обучения и скорость сходимости по проблеме распознавания символов и классической проблеме классификации XOR, предлагая использовать обратную функцию тангенса как ФА. Пиккневский Ф., Рыбицкий Л. предложили две ФА, одна из которых основана на интеграции треугольной функции, а другая - на разнице между двумя сигмоидами (лог-экспоненциальная), и сравнивается с помощью метода барицентрического построения, который проецирует возможности отображения сети в гиперразмерный куб. Исследование показало, что лог-экспоненциальная функция медленно ускорялась, но она была эффективной в многослойном перцептроне с обучением методом обратного распространения. Гуарнери С., Камполуччи П., Каппарелли Ф., Пьяцца Ф., Унчини А. используют в качестве ФА кусочную интерполяцию на основе кубических сплайнов, обеспечивающую характеристики, сравнимые с сигмоидальной функцией, с уменьшенными вычислительными затратами. Ма Л., Хорасани К. предложили ФА на основе ортонормированных полиномов Эрмита. Авторы доказывают, что такая сеть демонстрирует отличные характеристики по сравнению с аналогичными нейронными сетями с сигмовидными ФА. Вонг К. В., Леунг С. С., Чанег С. исследовали обучение нейрон-

ных сетей с помощью алгоритма расширенного фильтра Калмана. Сеть протестирована на классические сигмоидальные и синусоидальные ФА, распознавание рукописного ввода, прогнозирование временных рядов, создание четности и отображение XOR. Они доказывают, что предложенная периодическая функция превосходит классические ФА с точки зрения конвергенции обучения. Накаямма К., Хара К., предлагают комбинацию сигмоидальной, синусоидальной и гауссовской ФА, чтобы использовать их независимые свойства деления пространства признаков. Авторы сравнивают гибридную структуру в задаче классификации многочастотных сигналов, делая вывод, что комбинация трех функции активации работает эффективнее, чем сигмоидальная (по скорости сходимости) и гауссовская (по шумоподавлению) и синусоидальная функция активации, даже если каждая из них обеспечивает достижение лучших результатов по отмеченным выше критериям.

Объединение нейронных сетей с функциями принадлежности (ФП) из теории нечетких систем нашло применение для решения задач прогнозирования и классификации состояний объектов. Гомес-Чова Л., Кэмпс-Вальс Г., Кальпе-Маравилья Ж., Мартин-Герреро Ж.Д., Сория-Оливас Э., Серрано-Лопес А. определяют передачу гиперболического тангенса с помощью трех различных ФП, фактически определяя классическую ФА с помощью нечеткой логики. Основным преимуществом на этапе обучения является низкая вычислительная стоимость, обеспечиваемая тем, что обновление веса не всегда необходимо. Применение нейронных сетей с нечеткими ФА можно найти в работе Субаси А. Автор использует нейронные сети для обнаружения эпилептического припадка, обработки и классификации электроэнцефалографии сигналов. Вон И., Хунь Х.Т. предлагают метод аналитического обучения, отмеченный как экстремальное машинное обучение, для нейронных сетей с нечеткими ФА. Авторы тестируют методику по проблемам медицинской диагностики, классификации изображений и анализа спутниковых изображений. Ярушкиной Н.Г. представлена генетическая нейро-нечеткая система, которая построена на основе многослойной архитектуры с использованием И-, ИЛИ-нейронов и принципом «конкуренции и кооперации». В работе Ярушкиной Н.Г. отметим совместное применение генетических алгоритмов и нейронных сетей – это настройка ФП нечетких и нейро-нечетких систем.

Таким образом, существует обширное научное поле, в котором рассматриваются проблемы разработки ФА в теории нейронных сетей и ФП, изучаемые в теории нечетких систем, на основе которых можно создать новые нейронные сети с нечеткими ФА для решения задач обнаружения закономерностей в наборах данных.

Объектом исследования являются нейронные сети нового типа с функциями активации, базирующимися на функциях принадлежности теории нечетких систем.

Предметом исследования является моделирование и применение новых нейронных сетей для решения типовых задач обнаружения закономерностей в наборах данных: прогнозирование временных рядов, определение амплитуды детерминированного сигнала на фоне белого шума, классификация интенсивности марковского случайного потока событий и классификация объектов и их состояний.

Целью работы является разработка и исследование нейронных сетей нового ти-

па с полиномиальными кусочно-непрерывными функциями активации для обнаружения закономерностей в наборах данных, алгоритмов обучения и программных средств создания нечетких нейронных сетей для решения типовых задач обнаружения закономерностей в наборах данных.

Задачи исследования. Для достижения намеченной цели решены следующие задачи:

1. Анализ существующих полиномиальных кусочно-непрерывных ФП в теории нечетких систем с целью их использования в качестве ФА нечетких нейронных сетей.
2. Разработка тестовых наборов данных для типовых задач обнаружения закономерностей в данных.
3. Построение моделей нечетких нейронных сетей для тестовых задач обнаружения закономерностей в данных:
 - прогнозирование временных рядов со стохастическим трендом;
 - определение параметров детерминированного сигнала на фоне белого шума;
 - классификация интенсивности марковского случайного потока событий;
 - классификация объектов и их состояний.
4. Разработка алгоритмов обучения нечетких нейронных сетей для выше перечисленных тестовых задач обнаружения закономерностей в данных.
5. Математическое моделирование нечетких нейронных сетей для выше перечисленных тестовых задач обнаружения закономерностей в данных.

Научная новизна работы заключается в следующем:

1. Разработаны новые функции активации для нейронных сетей, которые основаны на функциях принадлежности теории нечетких систем и теории надежности, и на их базе разработаны новые нейронные сети.
2. Модифицированы алгоритмы обучения нейронных сетей для типовых задач обнаружения закономерностей в наборах данных. Усовершенствованы метод Левенберга – Марквардта, алгоритм кластеризации К - средних, вычисление весов выходного слоя нечетких нейронных сетей с использованием псевдообратного метода, алгоритм масштабированного сопряженного градиента.
3. Созданы модели новых нейронных сетей для типовых задач обнаружения закономерностей в наборах данных: прогнозирование временных рядов, определение амплитуды детерминированного сигнала на фоне белого шума, классификация интенсивности марковского случайного потока событий и классификация объектов и их состояний.

Теоретическая значимость и практическая значимость работы. Предложенные в работе модели и алгоритмы могут быть применены для создания программного обеспечения нечеткого нейросетевого классификатора (ННК) для повышения эффективности задачи прогнозирования временных рядов, определения амплитуды детерминированного сигнала на фоне белого шума, определения трафика в телекоммуникаци-

онных и компьютерных сетях как интенсивности марковского случайного потока событий и классификации объектов и их состояний.

Методы исследования основаны на теории нечетких систем, теории принятия решений, нейроинформатике, методах обучения нейронных сетей, цифровой обработки сигналов.

Научные положения, выносимые на защиту:

1. Новые функция активации нейронных сетей, основанные на функциях принадлежности LR-типа в теории нечетких систем и теории надежности, на базе этих функций разработаны новые нейронные сети.

Соответствует пункту 1 паспорта специальности 05.13.01: Теоретические основы и методы системного анализа, оптимизации, управления, принятия решений и обработки информации.

2. Модификация алгоритмов обучения нейронных сетей для типовых задач обнаружения закономерностей в наборах данных для повышения эффективности систем обработки информации.

Соответствует пункту 7 паспорта специальности 05.13.01: Методы и алгоритмы структурно-параметрического синтеза и идентификации сложных систем.

3. Модели новых нейронных сетей для типовых задач обнаружения закономерностей в наборах данных: прогнозирование временных рядов, определение амплитуды детерминированного сигнала на фоне белого шума, классификация интенсивности марковского случайного потока событий и классификация объектов и их состояний.

Соответствует пункту 11 паспорта специальности 05.13.01: Методы и алгоритмы прогнозирования и оценки эффективности, качества и надежности сложных систем.

Апробация результаты исследования. Основные положения диссертационной работы докладывались на Международной научно-практической конференции «Электронные средства и системы управления», г. Томск, 2016, 2017 гг.; Международной научно-практической конференции студентов, аспирантов и молодых учёных «Молодёжь и современные информационные технологии», г. Томск, 2016, 2017 гг.; Международной научной конференции «Информационные технологии в науке, управлении, социальной сфере и медицине », г. Томск, 2017 г.; The 22nd National Scientific Conference for Fluid Mechanics, Hai Phong, Viet Nam, 2019; The International Symposium on Applied Science (ISAS), Ho Chi Minh city, Viet Nam, 2019; Научных семинарах кафедры АСУ ТУСУР в 2015 – 2019 гг.

Основные результаты диссертационного исследования также апробированы в ходе практической деятельности автора и внедрены в 2-х компаниях (Midas Core Pte LTD, Singapore; Center of Education and Technology Transfer VIET4C, Viet Nam) и в учебный процесс в 1 образовательном учреждении (Кафедра АСУ ТУСУР).

Публикации по теме работы. По материалам диссертации опубликовано 12 работ, в том числе 5 публикаций в изданиях, включенных в перечень ведущих рецензируемых

научных журналов и изданий, рекомендованных ВАК Российской Федерации; 1 публикация в WoS, 2 публикации в Scopus.

Структура и объем работы. Диссертация состоит из введения, 4 глав, заключения, списка литературы. Объем диссертации составляет 112 страниц, включая 39 рисунков, 5 таблиц и список литературы из 118 наименований.

СОДЕРЖАНИЕ РАБОТЫ

Во введении обосновывается актуальность выбранной темы диссертации, характеризуется степень ее разработанности, определяются цели и задачи, осуществляется выбор предмета и объекта исследования. Определяется научная новизна и формулируются положения, выносимые на защиту.

В первой главе дано общее введение в искусственные нейронные сети. Отмечены основные достижения и проблемы теории и практики искусственных нейронных сетей (ИНС). Изложено общее описание известных видов нейронных сетей (НС): многослойный персептрон, радиально-базисная функциональная НС, нелинейная авторегрессионная НС и нечеткая НС.

Проанализированы процессы обучения нейронных сетей: с учителем и без учителя. При выборе алгоритмов обучения необходимо обратить внимание на следующие факторы: размер, качество и характер данных, доступное вычислительное время, сроки решения, интерпретация и т.д.

Выполнен анализ различных типов ФА ИНС: пороговая функция, функция сигмоида, гиперболический тангенс. Предложено применение в ИНС новых ФА, базисующихся на ФП нечетких чисел LR - типа. ФП LR-типа определяется следующим выражением:

$$\mu_A(x) = \begin{cases} f_L(x), & x \in [A, B); \\ 1, & x = B; \\ f_R(x), & x \in (B, C]; \\ 0, & x \notin [A, C]. \end{cases} \quad (1)$$

В случае когда $f_L(x), f_R(x)$ в (1) являются полиномами второго порядка и $f_L'(x) = 0, f_R'(x) = 0$ в характеристических точках нечеткой величины, форму ФП, определяемой выражением (1), можно изменять, налагая на функции $f_L(x)$ и $f_R(x)$ одно из четырех дополнительных условий:

$$\begin{cases} f_L'(A) = 0; \\ f_R'(B) = 0. \end{cases} \quad (2) \quad \begin{cases} f_L'(B) = 0; \\ f_R'(B) = 0. \end{cases} \quad (3)$$

$$\begin{cases} f_L'(A) = 0; \\ f_R'(C) = 0. \end{cases} \quad (4) \quad \begin{cases} f_L'(B) = 0; \\ f_R'(C) = 0. \end{cases} \quad (5)$$

Нечеткие нейронные сети (ННС) с новыми ФА, представленными на рисунке 1, предложено именовать ННС 2-го типа. Изложенное является обоснованием для решения следующих типовых задач обнаружения закономерностей в наборах данных:

- 1) прогнозирование временных рядов со стохастическим трендом;
- 2) определение параметров детерминированного сигнала на фоне белого шума;
- 3) классификация интенсивности марковского случайного потока событий;
- 4) классификация объектов и их состояний.

Внешний вид ФП треугольных нечетких чисел с учетом условий (2) – (5) представлен на рисунке 1.




Рисунок 1. Формы ФП с учетом дополнительных условий: а) условия (2); б) условия (3); в) условия (4); г) условия (5).

Во второй главе диссертации представлено использование новых ФА в многослойной однонаправленной нейронной сети (МОНС) для прогноза и определения параметров сигналов. В параграфе 2.1 разработана структура МОНС с использованием метода скользящего окна для прогноза временных рядов с ФА вида а, б, в, г (здесь и далее внешний вид ФА соответствует рисунку 1). На рисунке 2 представлен метод скользящего окна в МОНС.

Математическая модель сети может быть выражена как

$$\hat{X}_t = w_0 + \sum_{j=1}^Q w_j \cdot f \left(w_{0j} + \sum_{i=1}^P w_{i,j} \cdot X_{t-i} \right), \quad (6)$$

где P и Q - количество входных и скрытых нейронов соответственно, w_j , $j = 0, 1, \dots, Q$ - элементы весовых векторов $\mathbf{w}$ от скрытого слоя до выхода, $w_{i,j}$, $i = 1, 2, \dots, P$ & $j = 1, 2, \dots, Q$ - элементы весовых векторов $\mathbf{w}$ от входа к скрытым нейронам.

Для процесса обучения данные распределяются случайным образом с использованием 70% для обучения и 30% для тестирования. Алгоритм Левенберга - Марквардта

обратного распространения (ЛМОП) используется для обучения.

Представлено три набора данных (три временных ряда): набор данных 1 – ежемесячный австралийский импорт из Японии от июля 65-го года до октября 93-го года, набор данных 2 – обменный курс австралийского доллара (доллар Австралии за 1 доллар США) от июля 69-го года до августа 95-го года и набор данных 3 – экспорт квартальных австралийских национальных счетов от сентября 1959-го года до июня 1995-го года.




Рисунок 2. Метод скользящего окна в МОНС

В таблице 1 приведены среднеквадратичные ошибки (СКО) для определения лучшей модели НС для прогнозирования временных рядов.

Таблица 1. СКО каждого эксперимента

Тип НС \ Данные	НС-сигм	НС-а	НС-б	НС-в	НС-г
Набор данных 1	23×10^{-4}	25×10^{-4}	25×10^{-4}	23×10^{-4}	24×10^{-4}
Набор данных 2	18×10^{-4}	17×10^{-4}	16×10^{-4}	16×10^{-4}	21×10^{-4}
Набор данных 3	$2,74 \times 10^{-4}$	$7,01 \times 10^{-4}$	$2,33 \times 10^{-4}$	$2,89 \times 10^{-4}$	$4,38 \times 10^{-4}$

Из результатов тестирования следует, что разрабатываемые нами модели нечетких нейронов и ННС второго типа вполне успешно решают задачу прогнозирования временных рядов. СКО для прогнозируемых данных в МОНС с ФА вида a , b , v , z (в таблице 1 НС- a , НС- b , НС- v , НС- z соответственно) не значительно отличаются от СКО для прогнозируемых данных в обычной МОНС (НС- сигм). Эксперименты показывают, что модель НС с ФА вида b наиболее эффективна.

В параграфе 2.2 мы разрабатываем и исследуем НС с использованием ФА вида a , b , v , z для определения основных параметров детерминированного сигнала на фоне белого шума.

В качестве модели используем аддитивную смесь сигнала y и белого шума ε . В качестве сигнала используем сигнал в виде синусоиды:

$$y = x \times \sin(2\pi ft), \quad (7)$$

где x – амплитуда основного сигнала, f – основная частота сигнала. В качестве белого шума ε используем $N(0, \sigma^2)$, т.е. белый шум, является нормально распределенными случайными величинами с нулевым математическим ожиданием и дисперсией σ^2 .

В экспериментах выбираем амплитуды из интервала $[1; 1,5]$; дискретное время t – это 500 эквидистантных значений от 0 до 0,5 (с); задаем $f = 60$ Гц. Затем добавляем аддитивный гауссовский белый шум (отношение сигнал /шум = 0,05 дБ). Таким образом, на вход НС поступает временной ряд, представляющий собой упорядоченную последовательность значений, характер которой меняется во времени t . Задачей НС является прогноз значения x – амплитуды сигнала на входе НС.

Для тестирования НС со второй моделью данных, выбираем 5 значений амплитуды в интервале от 1,1 до 1,5 и для каждого значения амплитуды создаем 20 зашумленных сигналов. Также как и с первой моделью данных проводится 5 экспериментов, в которых используется так же обычная НС с сигмоидной ФА для определения значения амплитуды.

В таблице 2 приведены СКО по выбору лучшей модели НС для определения амплитуды сигнала на фоне белого шума.

Таблица 2. СКО для результатов экспериментов со второй моделью данных

Амплитуда сигнала Тип НС	1,1	1,2	1,3	1,4	1,5
НС- a	230×10^{-4}	43×10^{-4}	230×10^{-4}	53×10^{-4}	157×10^{-4}
НС- b	129×10^{-4}	28×10^{-4}	41×10^{-4}	82×10^{-4}	339×10^{-4}
НС- v	88×10^{-4}	16×10^{-4}	$4,96 \times 10^{-4}$	$1,93 \times 10^{-4}$	$4,23 \times 10^{-4}$
НС- z	164×10^{-4}	25×10^{-4}	$2,10 \times 10^{-4}$	100×10^{-4}	217×10^{-4}
НС- сигм	278×10^{-4}	74×10^{-4}	34×10^{-4}	63×10^{-4}	315×10^{-4}

Из результатов тестирования следует, что разрабатываемые нами модели нечетких нейронов и ННС второго типа вполне успешно решают задачу определения ам-

плитуды детерминированного сигнала на фоне белого шума. СКО в НС с ФА вида a , $\bar{b}$, $\bar{v}$, $\bar{z}$ (в таблице 2 НС- a , НС- $\bar{b}$, НС- $\bar{v}$, НС- $\bar{z}$ соответственно) в большинстве экспериментов показывают лучшее качество определения. Эксперименты показывают, что модель НС с ФА вида $\bar{v}$ наиболее эффективна. Модели нейронной сети с ФА вида a , $\bar{b}$, $\bar{z}$ также показывают хорошие результаты, но они незначительно отличаются от НС-*сигм*.

В третьей главе решается задача исследования возможности применения НС, структура которой может быть представлена в виде МОНС (рисунок 3) с использованием ФА вида a , $\bar{b}$, $\bar{v}$, $\bar{z}$, которые представлены на рисунке 4, для классификации и кластеризации интенсивности λ_i потоков событий.




Рисунок 3. Структура сети

Пусть $\lambda(t)$ – кусочно-постоянный случайный процесс с двумя состояниями $\lambda(t) = \lambda_1$ либо $\lambda(t) = \lambda_2$ ($\lambda_1 < \lambda_2$). Случайный процесс $\lambda(t)$ принципиально не наблюдаем. Время пребывания процесса $\lambda(t)$ в i -м состоянии является случайной величиной, распределенной по экспоненциальному закону с параметрами λ_i ($i = 1, 2$), т.е. рассматриваемый случайный процесс моделирует МАР-поток (Markovian Arrival Process) событий с экспоненциальной функцией распределения $F_i(t) = 1 - e^{-\lambda_i t}$, $i = 1; 2$.




Рисунок 4 – ФА второго типа.

Наборы точек $\langle A, B, C \rangle$ на рисунке 4 являются характеристическими точками ФА.

Зададим $AB = BC = \sigma$; и $B = \mu$. Пусть $a = (\mu - \sigma)$ если $\mu - \sigma \leq x \leq \mu$ и $a = (\mu + \sigma)$ если $\mu \leq x \leq (\mu + \sigma)$ получим общее описание (обобщенная) ФА вида a :

$$f(x) = \frac{1}{\sigma^2} x^2 + \frac{-2a}{\sigma^2} x + \frac{a^2}{\sigma^2}. \quad (8)$$

Аналогично, для ФА вида b , общее описание (обобщенная) ФА вида b определяются следующим образом:

$$f(x) = \frac{-1}{\sigma^2} x^2 + \frac{2\mu}{\sigma^2} x + \frac{a^2 - 2\mu a}{\sigma^2}, \quad (9)$$

где $a = (\mu - \sigma)$ если $\mu - \sigma \leq x \leq \mu$ и $a = (\mu + \sigma)$ если $\mu \leq x \leq (\mu + \sigma)$.

Для ФА вида c :

$$f(x) = k_1 \left(\frac{1}{\sigma^2} x^2 + \frac{-2a}{\sigma^2} x + \frac{a^2}{\sigma^2} \right) + k_2 \left(\frac{-1}{\sigma^2} x^2 + \frac{2\mu}{\sigma^2} x + \frac{a^2 - 2\mu a}{\sigma^2} \right), \quad (10)$$

где $a = (\mu - \sigma)$, $k_1 = 1$, $k_2 = 0$ если $\mu - \sigma \leq x \leq \mu$ и $a = (\mu + \sigma)$, $k_1 = 0$, $k_2 = 1$ если $\mu \leq x \leq (\mu + \sigma)$.

Для ФА вида d :

$$f(x) = k_1 \left(\frac{1}{\sigma^2} x^2 + \frac{-2a}{\sigma^2} x + \frac{a^2}{\sigma^2} \right) + k_2 \left(\frac{-1}{\sigma^2} x^2 + \frac{2\mu}{\sigma^2} x + \frac{a^2 - 2\mu a}{\sigma^2} \right), \quad (11)$$

где $a = (\mu + \sigma)$, $k_1 = 0$, $k_2 = 1$ если $\mu - \sigma \leq x \leq \mu$ и $a = (\mu - \sigma)$, $k_1 = 1$, $k_2 = 0$ если $\mu \leq x \leq (\mu + \sigma)$.

Выражение (8), (9), (10), (11) являются ФА, которые используются в ядре нейрона скрытого слоя ННС на рисунке 3.

Процесс обучения ННС состоит в выборе трех наборов параметров: центр μ и ширина σ для каждого из нейронов ННС и матрицы выходных весов между нейронами ННС и выходными узлами. Как правило, центр и распределение функций активации нейронов ННС должны иметь характеристики, подобные данным. Для определения центров ФА нейронов ННС обычно используются неконтролируемые учебные процедуры по кластеризации. В данной работе, алгоритм кластеризации К-средних используются для определения центра и ширины ФА нейронов ННС. Каждый кластер соответствует ядру ФА. Расположение центров ядра функций активации определяется с помощью следующего уравнения:

$$\mu_i = \frac{1}{p} \sum_{j=1}^p X_j,$$

где μ_i является центром i -го нечеткого скрытого нейрона; p – количество данных в формируемом кластере; X_j – j -е данное в i -ом кластере.

Настройка ширины ядра является труднорешаемой задачей при построении ННС. Если ширина ядра слишком велика, то оценка плотности вероятности сглаживается. Наоборот, когда она слишком мала, может быть чрезмерная адаптация к определенному набору данных. Ширина ядра устанавливается на среднее расстояние между данными соответствующего кластера:

$$\sigma_i = \sqrt{\frac{1}{p} \sum_{j=1}^p (X_j - \mu_i)^2}, \quad (12)$$

где σ_i является шириной i -го нечеткого скрытого нейрона; μ_i является центром i -го нечеткого скрытого нейрона; p – количество функциональных данных в данном кластере. X_j – j -е данное в i -ом кластере. Ширина ядра (12) гарантирует, что отдельные ФА не слишком острые или/и не слишком плоские.

Веса ННС между скрытым слоем и выходным слоем рассчитываются с использованием метода псевдообращения. На рисунке 3 X представляют собой входные наборы данных о пространственных входных признаках. Выход у ННС в наблюдаемый момент времени j ($j = 1; 2; \dots; N$, N – количество наблюдаемых моментов времени) имеет следующий вид:

$$y_j = \sum_{i=1}^k w_i f(x_i), \quad j = 1; 2; \dots; N, \quad (13)$$

где w_i – вес между выходным нейроном и i -м скрытым нейроном; $f(x)$ – обобщенная ФА; k – число нейронов скрытого слоя.

Уравнение (13) можно записать в виде

$$Y = \Phi w,$$

где

$$\Phi(\mu, \sigma, X) = \begin{bmatrix} \varphi_1(\mu_1, \sigma_1, X_1) & \dots & \varphi_K(\mu_K, \sigma_K, X_1) \\ \dots & \dots & \dots \\ \varphi_1(\mu_1, \sigma_1, X_v) & \dots & \varphi_K(\mu_K, \sigma_K, X_v) \\ \dots & \dots & \dots \\ \varphi_1(\mu_1, \sigma_1, X_N) & \dots & \varphi_K(\mu_K, \sigma_K, X_N) \end{bmatrix}, \quad v = 1; 2; \dots; N.$$

φ – функция активации. Матрица Φ (размерность $N \times K$) называется выходной матрицей скрытого слоя нейронной сети; i -я строка Φ является i -м скрытым выходным нейроном относительно входов $X_1, X_2, \dots, X_N$.

Пусть T – матрица выходных данных обучения. Если $\Phi w = T$, то выходные веса w вычисляются по формуле

$$w = (\Phi^T \Phi)^{-1} \Phi^T T,$$

где $(\Phi^T \Phi)^{-1} \Phi^T$ является обобщенной псевдообратной выходной матрицей Мура–Пенроуза скрытого слоя.

В данной главе представлены результаты исследования по классификации параметров случайных потоков на основе четырех экспериментов:

- первый эксперимент: марковские случайные потоки событий имеет 2 интенсивности $\lambda_1 \in (0; 0,5]$, $\lambda_2 \in (0,5; 1]$, параметры λ_1 , λ_2 не фиксированы и не известны;
- второй эксперимент: марковские случайные потоки событий имеет 2 интенсивности $\lambda_1 \in (0; 0,5]$, $\lambda_2 \in (0,5; 1]$, параметры λ_1 , λ_2 фиксированы, но не известны;
- третий эксперимент: марковские случайные потоки событий имеет 2 интенсивности $\lambda_1 = 0,25$, $\lambda_2 = 0,75$, то есть параметры λ_1 , λ_2 фиксированы и известны;
- четвертый эксперимент: марковские случайные потоки событий имеет 10 разных интенсивностей λ_i ($i = 1, 2, \dots, 10$) ($\lambda_1 < \lambda_2 < \dots < \lambda_{10}$).

Анализ результатов экспериментов показывает что, разрабатываемые нами модели ННС вполне успешно решают задачи классификации по интенсивности марковских случайных потоков событий. При этом на всех тестовых наборах ННС с ФА вида δ обеспечивает лучший результат во всех экспериментах.

В четвертой главе разработана структура ННК, использующих импульсные нечеткие ФА нейронов ННС. Приведено описание функции и структуры слоев ННК. ННК представляет собой многослойную однонаправленную сеть, состоящую из следующих слоев: входной слой, слой нечетких ФА, слой фаззификации, слой дефаззификации, слой нормализации и выходной слой. На рисунке 5 изображен ННК с двумя классификационными признаками и тремя классами. Каждый вход определяется тремя лингвистическими переменными.

Слой нечетких ФА: функция активации для каждого входа идентифицируется в этом слое. В данной главе используется четыре вида нечетких ФА. Внешний вид этих ФА представлен на рисунке 1 a , b , $в$, $г$, а также на рисунке 4 a , b , $в$, $г$.

Набор точек $\langle A, B, C \rangle$ (см. рисунок 4) являются характеристическими точками ФА. Задаем $AB = BC = \sigma$; и $B = \mu$. Пусть $a = (\mu - \sigma)$, $k_1 = 0$, $k_2 = 1$ если $\mu - \sigma \leq x \leq \mu$ и $a = (\mu + \sigma)$, $k_1 = 1$, $k_2 = 0$ если $\mu \leq x \leq (\mu + \sigma)$, тогда получим четыре ФА соответственно:

$$\begin{aligned}
 a) \quad & \begin{cases} f_{ij}(x_{sj}) = \frac{1}{\sigma_{ij}^2} x_{sj}^2 + \frac{-2a_{ij}}{\sigma_{ij}^2} x_{sj} + \frac{a_{ij}^2}{\sigma_{ij}^2}, \\ f_{ij}(x_{sj}) = 0, \text{ иначе,} \end{cases} \\
 б) \quad & \begin{cases} f_{ij}(x_{sj}) = \frac{-1}{\sigma_{ij}^2} x_{sj}^2 + \frac{2\mu_{ij}}{\sigma_{ij}^2} x_{sj} + \frac{a_{ij}^2 - 2\mu_{ij}a_{ij}}{\sigma_{ij}^2}, \\ f_{ij}(x_{sj}) = 0, \text{ иначе,} \end{cases}
 \end{aligned}$$

$$в) \begin{cases} f_{ij}(x_{sj}) = k_1 \left(\frac{1}{\sigma_{ij}^2} x_{sj}^2 + \frac{-2a_{ij}}{\sigma_{ij}^2} x_{sj} + \frac{a_{ij}^2}{\sigma_{ij}^2} \right) + k_2 \left(\frac{-1}{\sigma_{ij}^2} x_{sj}^2 + \frac{2\mu_{ij}}{\sigma_{ij}^2} x_{sj} + \frac{a_{ij}^2 - 2\mu_{ij}a_{ij}}{\sigma_{ij}^2} \right), \\ f_{ij}(x_{sj}) = 0, \text{ иначе,} \end{cases}$$

$$з) \begin{cases} f_{ij}(x_{sj}) = k_1 \left(\frac{-1}{\sigma_{ij}^2} x_{sj}^2 + \frac{2\mu_{ij}}{\sigma_{ij}^2} x_{sj} + \frac{a_{ij}^2 - 2\mu_{ij}a_{ij}}{\sigma_{ij}^2} \right) + k_2 \left(\frac{1}{\sigma_{ij}^2} x_{sj}^2 + \frac{-2a_{ij}}{\sigma_{ij}^2} x_{sj} + \frac{a_{ij}^2}{\sigma_{ij}^2} \right), \\ f_{ij}(x_{sj}) = 0, \text{ иначе.} \end{cases}$$




Рисунок 5. Структура нейро-нечеткого классификатора

Слой фаззификации: каждый узел в этом слое генерирует сигнал, соответствующий степени выполнения нечеткого правила для выборки. Этот сигнал можно назвать степенью возбуждения (the firing strength) нечеткого правила в отношении объекта, подлежащего классификации. Степень возбуждения по этому правилу заключается в следующем:

$$\beta_{is} = \prod_{j=1}^N f_{ij}(x_{sj}), \quad (14)$$

где N - количество классификационных признаков.

Слой дефаззификации: в этом слое вычисляются веса выходов; каждое правило влияет на каждый класс в соответствии с их весами. Если правило управляет определенной областью класса, вес между этим выходом правила и конкретным классом будет больше, чем другие веса. В противном случае веса классов малы. Вес выхода для s -й выборки, относящейся к k -му классу, вычисляется следующим образом:

$$o_{sk} = \sum_{i=1}^U \beta_{is} w_{ik}, \quad (15)$$

где w_{ik} обозначает степень принадлежности к k -му классу, который контролируется i -м правилом и U представляет собой количество правил; o_{sk} обозначает весовой выход для s -й выборки, принадлежащего k -му классу.

Слой нормализации: выходы сети должны быть нормализованы, так как суммирование весов может быть больше чем 1, в некоторых случаях

$$h_{sk} = \frac{o_{sk}}{\sum_{l=1}^K o_{sl}} = \frac{o_{sk}}{\delta_s}, \quad \delta_s = \sum_{l=1}^K o_{sl}, \quad (16)$$

где h_{sk} представляет нормированное значение s -ого выборки, которая относится к k -му классу; и K - количество классов. После этого метка класса s -й выборки определяется максимальным значением как

$$C_s = \max_{k=1,2,\dots,K} \{h_{sk}\}, \quad (17)$$

где C_s обозначает метку класса для s -й выборки.

Антецедентные параметры сети $\theta = \{S_{M \times N}, C_{M \times N}, W_{M \times K}\}$ могут быть адаптированы любым методом оптимизации S и C – матриц, содержащих значения σ и μ , соответственно; W представляет весовую матрицу соединений от слоя фаззификации до слоя дефаззификации; M , N , K - количество правил, признаков и классов соответственно; метод кластеризации K - средних используются для получения исходных параметров матриц S и C . Метод кластеризации K - средних предназначен для разделения входного пространства признаков на несколько кластеров, в которых каждая точка данных принадлежит кластеру с ближайшим средним значением.

Метод масштабированного сопряженного градиента (МСГ) используется для адаптации параметров сети. МСГ - это алгоритм сопряженного градиента второго порядка, который минимизирует целевые функции нескольких переменных.

Параметр w_{ik} в формуле (15) также можно адаптировать с помощью метода МСГ. Однако при обучении w_{ik} может быть больше 1. В этих случаях значения весов могут быть потеряны для кластеров из этого же класса. По этой причине либо w_{ik} должен быть ограничен, либо w_{ik} определяется из отношения числа выборки k -го класса в i -й области нечеткого правила относительно общего числа выборок k -го класса:

$$w_{ik} = \frac{D_i}{D_k}, \quad (18)$$

где D_i - число выборок k -го класса, которые принадлежат к i -й нечеткой области правил и D_k - число всех выборок k -го класса.

Функция стоимости, используемая в методе МСГ, определяется методом наименьших квадратов по разности цели и вычисленного значения класса:

$$E = \frac{1}{N} \sum_{s=1}^N E_s, \quad (19)$$

$$E_s = \frac{1}{2} \sum_{k=1}^K (t_{sk} - h_{sk})^2, \quad (20)$$

где N – количество выборок, t_{sk} и h_{sk} являются целевыми и вычисленными значениями s -й выборки, принадлежащей k -му классу, соответственно. Если s -я выборка принадлежит k -му классу, то целевое значение t_{sk} устанавливается равным 1, а в противном случае - равным 0.

Частную производную от E , относящуюся к μ_{ij} , можно вычислить:

$$\frac{\partial E}{\partial \mu_{ij}} = \sum_{s=1}^N \frac{\partial E}{\partial E_s} \left(\sum_{k=1}^K \frac{\partial E_s}{\partial h_{sk}} \cdot \frac{\partial h_{sk}}{\partial o_{sk}} \cdot \frac{\partial o_{sk}}{\partial \beta_{is}} \cdot \frac{\partial f_{ijs}}{\partial \mu_{ij}} \right). \quad (21)$$

Для функции активации вида $\tilde{b}$:

$$\begin{cases} f_{ij}(x_{sj}) = \frac{-1}{\sigma_{ij}^2} x_{sj}^2 + \frac{2\mu_{ij}}{\sigma_{ij}^2} x_{sj} + \frac{a_{ij}^2 - 2\mu_{ij}a_{ij}}{\sigma_{ij}^2}, \\ f_{ij}(x_{sj}) = 0, \text{ иначе,} \end{cases} \quad (22)$$

где $a = (\mu - \sigma)$ если $\mu - \sigma \leq x \leq \mu$ и $a = (\mu + \sigma)$ если $\mu \leq x \leq (\mu + \sigma)$; $f_{ij}(x_{sj})$ представляет собой степень принадлежности i -го правила и j -й признак; x_{sj} представляет собой s -й выборку и j -й признак входной матрицы.

Из (14) - (22) получим:

$$\frac{\partial E}{\partial \mu_{ij}} = \frac{1}{N} \sum_{s=1}^N \sum_{k=1}^K \left((h_{sk} - t_{sk}) \left(\frac{1 - h_{sk}}{\delta_s} \right) w_{ik} \beta_{is} \frac{2x_{sj} - 2\mu_{ij}}{-x_{sj}^2 + 2\mu_{ij}x_{sj} + \sigma_{ij}^2 - \mu_{ij}^2} \right).$$

Аналогично

$$\frac{\partial E}{\partial \sigma_{ij}} = \frac{1}{N} \sum_{s=1}^N \sum_{k=1}^K \left((h_{sk} - t_{sk}) \left(\frac{1 - h_{sk}}{\delta_s} \right) w_{ik} \beta_{is} \frac{2(x_{sj} - 2\mu_{ij})^2}{\sigma_{ij}(-x_{sj}^2 + 2\mu_{ij}x_{sj} + \sigma_{ij}^2 - \mu_{ij}^2)} \right).$$

Аналогично получаются частные производные от E , относящиеся к μ_{ij} для остальных ФА.

Разработанный выше ННК с нашими ФА и алгоритмом МСГ исследован на зада-

че классификации набора данных ирисы Фишера для нахождения отображения между четырьмя входными переменными (длина наружной, ширина наружной, длина внутренней и ширина внутренней) и тремя классами (Setosa, Versicolor и Virginica). Другой эксперимент с ННК по классификации состояний объекта проведен на наборе данных шкалы баланса, который получен из UC Irvine Machine Learning Repository и был сгенерирован для моделирования результатов психологических экспериментов, проведенных Зиглером.

Результаты тестирования ННК представлены в таблице 3. Эффективность работы ННК при идентификации теста будем оценивать процентным отношением между количеством правильных результатов тестирования и общим количеством данных тестирования. СКО характеризует точность результатов экспериментов с ННК.

Таблица 3. Результаты классификации набора данных ННК с различными ФА

Тип ФА	Эффективность ННК на тесте (%)		СКО	
	Ирисы Фишера	Шкала баланса	Ирис Фишера	Шкала баланса
Гауссоида	96	88,78	$2,297 \cdot 10^{-7}$	0,13
Вида <i>a</i>	96	87,82	$5,031 \cdot 10^{-6}$	0,12
Вида <i>b</i>	97,33	89,10	$6,361 \cdot 10^{-4}$	0,15
Вида <i>c</i>	97,33	77,88	0,0418	0,31
Вида <i>d</i>	96	60,25	0,041	0,61

Из таблицы 3 следует, что результаты классификации с использованием предлагаемых нами ФА не превосходят результат классификации с использованием гауссовой ФА (СКО ННК с гауссовой ФА на тесте ирисы Фишера самая малая), однако использование ННК с ФА вида *a* и *b* вполне приемлемо на разных тестах. Эффективность ННК с ФА вида *b* и *c* на тесте ирисы Фишера самая высокая.

Проведем сравнительный анализ результатов классификации ННК с предлагаемыми ФА и классификации с использованием радиальной базисной нейронной сети (РБНС). В таблице 4 представлены результаты эксперимента по классификации предлагаемым ННК и РБНС для выбранных тестов ирисы Фишера и шкалы баланса.

Таблица 4. Результаты классификации ННК и РБНС

Метод использования	Эффективность на тестах (%)	
	Ирисы Фишера	Шкала баланса
ННК	96 – 97,33	60,25 – 89,10
РБНС	65,33	54,91

Из таблицы 4 следует, что предлагаемый ННК эффективнее РБНС в решаемой задаче классификации.

На рисунке 6 показана динамика СКО ННК на тесте ирисы Фишера в сравнении

с учебными эпохами.




Рисунок 6. СКО ННК на тесте ирисы Фишера

Из рисунка 6 следует, что обучение ННК с ФА ϵ и ζ на основе алгоритма СМГ не эффективно. СКО (точность работы ННК с этими ФА) почти не изменяются и слишком велики, поэтому для ННК этого типа необходим поиск других методов обучения. Относительно обучения ННК с ФА a и b на основе алгоритма СМГ следует сделать более оптимистичный вывод и утверждать, что ННК данных типов эффективно решают задачи классификации объектов и их состояний.

ОСНОВНЫЕ РЕЗУЛЬТАТЫ РАБОТЫ И ВЫВОДЫ

В диссертации решена актуальная научно-техническая задача алгоритмического обеспечения НС нового типа с полиномиальными кусочно-непрерывными ФА для обнаружения закономерностей в наборах данных. Основные научные и практические результаты состоят в следующем.

1. Проведён анализ процессов обучения НС для различных типов ФА НС. Предложено применение в НС новых ФА (ФА вида a , b , ϵ , ζ), базирующихся на полиномиальных кусочно-непрерывных функциях принадлежности нечетких чисел LR - типа. Новый тип НС с полиномиальными кусочно-непрерывными ФА предложено именовать нечеткими НС (ННС) второго типа. Создано алгоритмическое обеспечение НС обработки информации для обнаружения закономерностей в наборах данных:

- прогнозирование временных рядов со стохастическим трендом;
- определение параметров детерминированного сигнала на фоне белого шума;

- классификация интенсивности марковского случайного потока событий;
- классификация объектов и их состояний.

2. Разработана структура МОНС с использованием метода скользящего окна для прогноза временных рядов с ФА вида $a, b, в, г$. Процесс обучения реализуется с помощью алгоритма Левенберга - Марквардта обратного распространения. Реальные наборы данных используются для тестирования. Среднеквадратичная ошибка (СКО) используется для определения лучшей модели МОНС. Эксперименты показывают, что модель НС с ФА вида $b, в$ наиболее эффективна.

3. Выполнена разработка структуры МОНС с ФА вида $a, b, в, г$ для определения амплитуды детерминированного сигнала на фоне белого шума. Алгоритм Левенберга - Марквардта обратного распространения используется для обучения. Синусоидальные сигналы с добавлением к нему гауссовского белого шума с отношением сигнал/шум = 0,05 дБ используются в качестве наборов данных для тестирования. Лучшие результаты показали в МОНС с ФА вида $a, b, в, г$ (особенно МОНС с ФА вида $в$) по сравнению с результатами в обычной МОНС.

4. Исследована возможность применения ННС нового типа для классификации интенсивности потоков событий (марковских случайных процессов). Создана структура ННС второго типа в виде МОНС с использованием ФА вида $a, b, в, г$. Процесс обучения ННС второго типа состоит в выборе трех наборов параметров: центра μ и ширины σ для ФА вида $a, b, в, г$ нейронов ННС и матриц выходных весов между нейронами ННС и выходными узлами ННС. Результаты экспериментов доказывают что, разрабатываемые нами модели ННС, успешно решают задачи классификации интенсивности марковских случайных потоков событий. ННС с ФА вида b обеспечивает лучший результат во всех экспериментах.

5. Выполнена разработка ННК. ННК представляет собой МОНС, состоящую из следующих слоев: входной слой, слой нечетких ФА, слой фаззификации, слой дефаззификации, слой нормализации и выходной слой. Антецедентные параметры сети определяются методом кластеризации К – средних. Алгоритм масштабированного сопряженного градиента (МСГ) используется для обучения ННК. Для тестирования используются типовые наборы данных: ирисы Фишера и шкала баланса. Проведен сравнительный анализ разработанных ННК с известными ННК: ННК с гауссовой ФА и радиальная базисная нейронная сети (РБНС). Сравнительный анализ доказывает конкурентоспособность двух из четырех разработанных ННК по эффективности и точности классификации. ННС с ФА вида a и b показывают лучшие результаты по классификации объектов и их состояний.

СПИСОК ПУБЛИКАЦИЙ АВТОРА

Работы, опубликованные в журналах, рекомендованных ВАК России

1. Нгуен, А.Т. Компьютерное моделирование показателей нечеткой надежности / А.Т. Нгуен, А.А. Ефремов // Доклады ТУСУРа. – 2016. – Т. 19, № 1. – С. 57-62. DOI: 10.21293/1818-0442-2016-19-1-57-62.

2. Нгуен, А.Т. Модель нейронной сети с нечеткими функциями активации для прогнозирования временного ряда / А.Т. Нгуен, А.М. Кориков // Доклады ТУСУРа. – 2016. – Т. 19, № 4. – С. 49–51. DOI: 10.21293/1818-0442-2016-19-4-49-51.
3. Нгуен, А.Т. Нечеткая нейросетевая классификация интенсивности марковского случайного потока событий / А.М. Кориков, А.Т. Нгуен // Доклады ТУСУРа. – 2017. – Т. 20, № 2. – С. 79–83. DOI: 10.21293/1818-0442-2017-20-2-79-83.
4. Нгуен, А.Т. Нейро-нечеткая классификация объектов и их состояний / А.М. Кориков, А.Т. Нгуен // Научный вестник НГТУ. – 2018. – № 3 (72). – С. 73–86. – DOI: 10.17212/1814-1196-2018-3-73-86.
5. Нгуен, А.Т. Нейронные сети с полиномиальными кусочно-непрерывными функциями активации для поиска закономерностей в данных / А.Т. Нгуен, А.М. Кориков // Доклады ТУСУРа. – 2019. – Т. 22, № 1. – С. 71-76. DOI: 10.21293/1818-0442-2019-22-1-71-76.

Работы, зарегистрированные в международной базе научного цитирования Scopus и WoS

6. Nguyen, A.Tu. Models of neural networks with fuzzy activation functions / A.Tu. Nguyen, A.M. Korikov // IOP Conference Series: Materials Science and Engineering. – 2017. Vol. 177 [Электронный ресурс]. – Режим доступа: <http://iopscience.iop.org/article/10.1088/1757-899X/177/1/012031>, свободный (дата обращения: 01.03.2017). DOI:10.1088/1757-899X/177/1/012031.
7. Nguyen, A.Tu. Application of Artificial Neural Networks to Predict Dynamic Responses of Wing Structures due to Atmospheric Turbulence / A.Tuan Nguyen, J.H. Han, A.Tu Nguyen // IJASS, Vol.18, No.3, pp. 474-484, September, 2017. DOI: 10.5139/IJASS.2017.18.3.474.
8. Nguyen, A. Tu. Fuzzy Neural Network Technology Support Decision-Making / A.Tu Nguyen, A.M. Korikov, A.Tuan Nguyen // Advances in Computer Science Research. — 2017. — Vol. 72 : Information technologies in Science, Management, Social sphere and Medicine (ITSMSSM 2017). — pp. 128-131. DOI: <https://doi.org/10.2991/itsmssm-17.2017.27>.

Публикации в других изданиях

9. Нгуен, А.Т. Методы описания блок-схем надежности систем / В.Т. Динь, А.Т. Нгуен // Сборник трудов XI Международной научно-практической конференции студентов, аспирантов и молодых учёных «Молодёжь и современные информационные технологии». – 2013. – Томск: Издательство ТПУ. – С.56-58.
10. Нгуен, А.Т. Способ описания структуры резервирования технических систем / В.Т. Динь, А.Т. Нгуен // Сборник трудов XII Всероссийской научно-практической конференции студентов, аспирантов и молодых ученых «Технологии Microsoft в теории и практике программирования». – 2015. – Томск: Издательство ТПУ. – С.81-85.
11. Нгуен, А.Т. Задачи обучения нечетких нейронных сетей / А.Т. Нгуен, А.М. Кориков // Сборник материалов международной научно-практической конференции «Электронные средства и системы управления». – Томск: В-Спектр, 2017. – С. 65- 68.

12. Нгуен, А.Т. Нечеткая нейросетевая кластеризация интенсивности МС - потоков событий / А.Т. Нгуен, А.М. Корилов, А.Туан Нгуен // Сборник материалов международной научно-практической конференции студентов, аспирантов и молодых ученых «Молодежь и современные информационные технологии». – 11.2017. – С. 53-54.