

МОСКОВСКИЙ ГОСУДАРСТВЕННЫЙ ТЕХНИЧЕСКИЙ УНИВЕРСИТЕТ
ИМЕНИ Н.Э.БАУМАНА

На правах рукописи
УДК 52.50

Кручинин Илья Игоревич

**МОДЕЛИРОВАНИЕ И СРАВНИТЕЛЬНЫЙ АНАЛИЗ
ПРОЦЕССОВ РАСПОЗНАВАНИЯ И КЛАССИФИКАЦИИ
МНОГОМЕРНЫХ ОБЪЕКТОВ ПЕРЕСЕКАЮЩИХСЯ
КЛАССОВ НА ОСНОВЕ ПРЕДСТАВЛЕНИЙ ТЕОРИИ
НЕЧЕТКИХ МНОЖЕСТВ И НЕЙРОСЕТЕВЫХ
ТЕХНОЛОГИЙ**

Специальность 05.13.17 – Теоретические основы информатики

АВТОРЕФЕРАТ

диссертации на соискание ученой степени
кандидата технических наук

Москва – 2003

Работа выполнена в Калужском филиале Московского государственного технического университета им. Н.Э.Баумана

Научный руководитель - доктор физико-математических наук,
профессор Логинов Б.М.

Официальные оппоненты - доктор физико-математических наук
Волков П.К.
кандидат технических наук,
доцент Шкатов П.Н.

Ведущая организация - Научный центр нейροкомпьютеров

Защита состоится 4 декабря 2003 г. на заседании диссертационного совета Д 212.141.10 в Московском государственном техническом университете им. Н.Э.Баумана по адресу: 107005, г. Москва, 2-я Бауманская ул., д. 5.

С диссертацией можно ознакомиться в библиотеке МГТУ им. Н.Э.Баумана.

Автореферат разослан "24" октября 2003 г.

Ученый секретарь
Диссертационного Совета
к.т.н., доцент



Иванов С.Р.



ОБЩАЯ ХАРАКТЕРИСТИКА РАБОТЫ

Актуальность диссертационной работы. В настоящее время значительные усилия исследователей в области искусственного интеллекта направлены на разработку методов решения задач классификации и распознавания объектов в условиях неточной исходной информации. Подобного рода задачи часто возникают на практике, например, при обработке зашумленных сигналов с датчиков технологических процессов, обработке результатов социологических опросов, прогнозировании в геологии, диагностике в биологии и медицине.

Условием, затрудняющим распознавание объектов, зачастую является пересечённость классов объектов по различным признакам, вследствие чего плохо применимы традиционные вероятностно-статистические методы анализа информации.

Как правило, решение этого класса задач осуществляется на основе экспертных систем, база знаний которых включает опыт экспертов, который, в свою очередь, может содержать скрытые противоречия, не устранимые инженерами по знаниям, что может существенно снизить ценность получаемых результатов.

Таким образом, разработка новых подходов, методов и моделирование на их основе процессов классификации и распознавания объектов по совокупности их количественных и качественных признаков в условиях пересечения и многозначности классов объектов, когда в силу изначальной неопределённости методы статистического анализа оказываются малоэффективными, является актуальной и важной задачей.

Целями диссертационной работы являлись:

- сравнительный анализ известных методов распознавания и классификации многомерных объектов пересекающихся классов;
- решение задачи психодиагностики.

Научная новизна работы состоит в следующем:

- проведён всесторонний анализ применения нейронных сетей прямого распространения без обратных связей для решения задачи классификации на широком классе полигонов многомерных объектов пересекающихся классов;
- предложен новый метод решения задач распознавания и классификации, основанный на объединении аппарата теории нечётких множеств и нейросетевых технологий.

Теоретическая и практическая ценность состоит в том, что в работе предложен новый метод анализа нечёткой информации, который можно применить для решения широкого круга задач во многих прикладных

РРТУ
Э. Бауман
ИИИД

областях. Многомерные числовые объекты могут отражать качественные или количественные оценки промышленной продукции, состояния экономики, символьные последовательности, возникающие при формализации естественных и абстрактных текстов (кодов). Ранжирование нечётких объектов по совокупности разнотипных признаков дает возможность классифицировать в соответствии с семантикой нечёткости реальные процессы, то есть извлекать знания из нечётких фактов, которые, в свою очередь, могут быть использованы как элементы экспертных систем и обучающих программ.

Полученные в работе результаты: новый метод, модели и алгоритмы используются при прогнозировании и оценки профессиональной пригодности в Калужской таможне и в Информационном центре УВД Калужской области. Копии актов о внедрении прилагаются.

Внедрение результатов работы продолжается. Результаты могут быть использованы при разработке других автоматизированных систем распознавания, классификации, предсказания и диагностики в условиях пересекающихся классов объектов для создания «интеллектуального советника» в неопределенных ситуациях.

Достоверность результатов работы обусловлена корректной постановкой задачи, применением математически обоснованных методов её решения, сравнением результатов с экспериментальными данными.

На защиту выносятся следующие положения:

- метод вычисления функций принадлежности многомерных объектов к классам; метод соотнесения объектов к одному из классов на основе свёртки;
- модель, использующая представления теории нечётких множеств;
- гибридная модель, базирующаяся на объединении представлений теории нечётких множеств и нейросетевых технологиях;
- результаты экспериментальных исследований эффективности использования существующих нейросетевых и разработанных методов при решении задач распознавания, классификации и диагностики профессиональной пригодности кадров.

Апробации работы. Результаты диссертационной работы докладывались на следующих отечественных и зарубежных конференциях: International Conference on Artificial Intelligence (Durban, South Africa, 1999); International Conference on Computer Modeling, Simulation and Communication (Jaipur, India, 1999); 1-я Российская конференция молодых ученых по математическому моделированию (Калуга, 2000); 2-я Российская конференция молодых ученых по математическому моделированию (Калуга, 2002).

Публикации. По теме диссертации опубликовано 11 печатных работ.

Объём работы. Диссертационная работа состоит из введения, четырёх глав, выводов и списка литературы. Работа изложена на 209 страницах текста, содержит 68 рисунков, 9 таблиц, 109 библиографических ссылок.

СОДЕРЖАНИЕ РАБОТЫ

Во введении обосновывается актуальность темы диссертации, её практическое значение, формулируются основные цели исследования, основные положения, выдвигаемые на защиту, изложена структура диссертации.

В первой главе диссертации проводится рассмотрение известных методов решения задач распознавания и классификации нечётких объектов. Проанализированы основные трудности, возникающие при решении задачи распознавания и классификации многомерных объектов пересекающихся классов. Рассмотрены возможные подходы и методы решения данного класса задач.

В п. 1.1 с целью проведения сравнительного анализа характеристик функционирования различных классификаторов на объектах с различной степенью сложности, были определены три типа множеств объектов, характеризующиеся разной степенью пересечённости классов объектов: простое или слабо пересекающееся множество, содержащее не более 5% пересечений классов объектов, разделенное или средне пересекающееся множество, содержащее от 5% до 20% пересечений классов объектов, и сильно пересекающееся множество, содержащее более 20% пересечений классов объектов. Для каждого типа множеств обучающая и тестовая выборки содержали порядка 10^3 элементов.

В п. 1.2 проведен сравнительный анализ классификации нечётких объектов на основе известных нейросетевых технологий для многослойных гомогенных сетей, обучаемых на основе алгоритмов обратного распространения ошибки. Рассмотрено четыре модификации алгоритма: метод скорейшего спуска (ОРО), адаптивный алгоритм (АА), множественный адаптивный алгоритм (МАО) и алгоритм сопряженных градиентов (АСГ). Для каждой модификации определены оптимальные значения внутренних параметров архитектуры сети, как с точки зрения минимального уровня ошибки функционирования, так и с точки зрения наименьших необходимых вычислительных ресурсов.

Полученные результаты позволили установить, что нейронные сети, функционирующие на основе алгоритмов обратного распространения

ошибки, даже при оптимальных значениях своих внутренних параметров из-за большой ошибки классификации (от 34%) не позволяют в дальнейшем образом решать задачи распознавания и классификации для классов объектов с высокой степенью пересечённости.

Вторая глава диссертации посвящена моделированию процессов распознавания и классификации пересекающихся классов объектов на основе теории нечётких множеств.

В п. 2.1 рассматриваются известные способы вычисления функций принадлежности объектов к нечётким множествам, нечёткие меры доверия, возможности и необходимости событий и меры учёта неопределённости в ситуациях, когда недостаточна модель полной группы несовместных событий, на которых основана теория вероятностей. Рассмотрены известные способы вычисления меры необходимости пересечения и объединения множеств, способы свёртки нечётких множеств, получения критерия для ранжирования многомерных объектов и для сравнения разнотипных признаков по надёжности диагностики неизвестных объектов.

В п. 2.2 проводится описание разработанной системы распознавания и классификации многомерных объектов пересекающихся классов на основе представлений теории нечётких множеств. Разработанная система состояла из двух основных модулей – модуля предобработки и модуля распознавания и классификации.

Задачей модуля предобработки являлось создание опорных вектор-функций принадлежности, представляющих собой интегральные характеристики экспертных баз данных для каждого класса.

Модуль предобработки содержал три основных блока – блок экспертной базы данных, блок вектор-функций принадлежности и блок предобработки данных.

В экспертную базу данных помещались исходные массивы $\{P_K\}$, составленные из N – мерных векторов K классов:

$$\tilde{X}_{K,P_k}^{(N)} = \left(x_{k,p}^{(1)}, x_{k,p}^{(2)}, x_{k,p}^{(3)}, \dots, x_{k,p}^{(N)} \right)^T, \quad p = 1, 2, 3, \dots, P_k, k = 1, 2, 3, \dots, K. \quad (1)$$

Массивы векторов $\tilde{X}_{K,P_k}^{(N)}$ поступали в блок предобработки, где для каждого из них производился расчёт массива вектор-функций принадлежности

$$\tilde{M}_{K,P_k}^{(N)} = \left(\mu_{k,p}^{(1)} \left(x^{(1)} \right), \mu_{k,p}^{(2)} \left(x^{(2)} \right), \dots, \mu_{k,p}^{(N)} \left(x^{(N)} \right) \right)^T, \quad p = 1, 2, 3, \dots, P_k, k = 1, 2, 3, \dots, K. \quad (2)$$

В работе рассмотрены три вида контуров функций принадлежности. Треугольный:

$$\mu_{k,p}^{(n)}(x^{(n)}) = \max \left\{ 0, 1 - \theta^{(n)} |x^{(n)} - c^{(n)}| \right\}, \quad \theta > 0, \quad (3)$$

гиперболический:

$$\mu_{k,p}^{(n)}(x^{(n)}) = \left[1 + \theta^{(n)} |x^{(n)} - c^{(n)}| \right]^{-1}, \quad \theta > 0, \quad (4)$$

и Гауссов:

$$\mu_{k,p}^{(n)}(x^{(n)}) = \exp \left[-\theta^{(n)} |x^{(n)} - c^{(n)}| \right], \quad \theta > 0. \quad (5)$$

Следует отметить, что разработанная система не предъявляет жёстких требований к виду характеристической функции.

На базе $\bar{M}_{k,p_i}^{(N)}$ для каждого класса производился расчёт опорного массива интегральных экспертных вектор-функций принадлежности

$$\bar{H}_k^{(N)} = \left(\eta_k^{(1)}(x^{(1)}), \eta_k^{(2)}(x^{(2)}), \eta_k^{(3)}(x^{(3)}), \dots, \eta_k^{(N)}(x^{(N)}) \right)^T, \quad k = 1, 2, 3, \dots, K, \quad (6)$$

где

$$\eta_k^{(n)}(x^{(n)}) = \mu_{k,1}^{(n)}(x^{(n)}) \cup \mu_{k,2}^{(n)}(x^{(n)}) \cup \dots \cup \mu_{k,p_i}^{(n)}(x^{(n)}) = \bigcup_{p=1}^{p_i} \mu_{k,p}^{(n)}(x^{(n)}), \quad k = 1, 2, 3, \dots, K. \quad (7)$$

Система предъявляет требования к однотипности и нормированности операций. Используемые в работе операции объединения являются t -нормами, что позволяет использовать их ассоциативность и даёт возможность последовательно вычислять объединение более чем двух множеств. Были рассмотрены 4 теоретико-множественные операции объединения, определённые своими характеристическими функциями. Простое объединение, введённое Заде:

$$\mu_{k,p}^{(n)}(x^{(n)}) \cup \mu_{k,q}^{(n)}(x^{(n)}) = \max \left\{ \mu_{k,p}^{(n)}(x^{(n)}), \mu_{k,q}^{(n)}(x^{(n)}) \right\}, \quad (8)$$

и параметризованные операции объединения, предложенные Хамахером:

$$\mu_{k,p}^{(n)}(x^{(n)}) \cup \mu_{k,q}^{(n)}(x^{(n)}) = \frac{\mu_{k,p}^{(n)}(x^{(n)}) \cdot \mu_{k,q}^{(n)}(x^{(n)})}{\gamma + (1 - \gamma) \left(\mu_{k,p}^{(n)}(x^{(n)}) + \mu_{k,q}^{(n)}(x^{(n)}) - \mu_{k,p}^{(n)}(x^{(n)}) \cdot \mu_{k,q}^{(n)}(x^{(n)}) \right)}, \quad (9)$$

$\gamma \geq 0$

Ягером:

$$\mu_{k,p}^{(n)}(x^{(n)}) \cup \mu_{k,q}^{(n)}(x^{(n)}) = \min \left\{ 1, \left[\mu_{k,p}^{(n)}(x^{(n)}) \right]^r + \left[\mu_{k,q}^{(n)}(x^{(n)}) \right]^r \right\}^{\frac{1}{r}}, \quad r \geq 1, \quad (10)$$

Дюбуа и Праде:

$$\begin{aligned} & \mu_{k,p}^{(n)}(x^{(n)}) \cup \mu_{k,q}^{(n)}(x^{(n)}) = \\ & = \frac{\mu_{k,p}^{(n)}(x^{(n)}) + \mu_{k,q}^{(n)}(x^{(n)}) - \mu_{k,p}^{(n)}(x^{(n)}) \cdot \mu_{k,q}^{(n)}(x^{(n)}) - \min\{\mu_{k,p}^{(n)}(x^{(n)}), \mu_{k,q}^{(n)}(x^{(n)}), 1 - \alpha\}}{\max\{(1 - \mu_{k,p}^{(n)}(x^{(n)})), (1 - \mu_{k,q}^{(n)}(x^{(n)})), \alpha\}}, \quad (11) \end{aligned}$$

$$\alpha \in [0; 1]$$

Совокупности интегральных экспертных вектор-функций принадлежности $\bar{H}_K^{(N)}$, полученные на основе ЭБД для каждого класса, помещались далее в блок векторных функций принадлежности (ВФП) и использовались для последующих расчётов.

Назначение модуля распознавания и классификации следует из его названия. Этот модуль состоял из четырех блоков: блока транспортировки, блока свертки, блока ранжирования и блока архива решений.

Значения координат входного вектора

$$\bar{Z}^{(N)} = (z^{(1)}, z^{(2)}, z^{(3)}, \dots, z^{(N)})^T,$$

подлежащего распознаванию и классификации, поступали в транспортный блок, и после проверки на целостность и непротиворечивость передавались в модуль предобработки, в блок ВФП, в котором на основании массива интегральных экспертных вектор-функций принадлежности $\bar{H}_K^{(N)}$ производился расчёт значений для каждого класса K векторов-функций принадлежности:

$$\bar{M}_K^{(N)}(z) = (\mu_K^{(1)}(z^{(1)}), \mu_K^{(2)}(z^{(2)}), \mu_K^{(3)}(z^{(3)}), \dots, \mu_K^{(N)}(z^{(N)}))^T, \quad k = 1, 2, 3, \dots, K. \quad (12)$$

Рассчитанные значения ВФП $\bar{M}_K^{(N)}(z)$ возвращались в модуль распознавания и классификации, в транспортный блок, откуда после проверки на целостность и непротиворечивость передавались далее в блок свертки, в котором для каждого класса K для входного вектора $\bar{Z}^{(N)}$ производился расчёт свертки $M_K(z)$ на основе выражения:

$$M_K(z) = \mu_K^{(1)}(z^{(1)}) \cap \mu_K^{(2)}(z^{(2)}) \cap \dots \cap \mu_K^{(N)}(z^{(N)}) = \bigcap_{n=1}^N \mu_K^{(n)}(z^{(n)}), \quad k = 1, 2, 3, \dots, K. \quad (13)$$

Система предъявляет требования к однотипности и нормированности операций. Используемые в работе операции пересечения являются z -нормами (t -сонормами), что позволяет использовать их ассоциативность и даёт возможность последовательно вычислять пересечение более чем двух множеств. Были рассмотрены 4 теоретико-множественные операции пересечения, определённые своими характеристическими функциями. Простое пересечение, введённое Заде:

$$\mu_k^{(p)}(z^{(p)}) \cap \mu_k^{(q)}(z^{(q)}) = \min\{\mu_k^{(p)}(z^{(p)}), \mu_k^{(q)}(z^{(q)})\}, \quad (14)$$

и параметризованные операции пересечения, предложенные Хамахером:

$$\mu_k^{(p)}(z^{(p)}) \cap \mu_k^{(q)}(z^{(q)}) = \frac{\mu_k^{(p)}(z^{(p)}) + \mu_k^{(q)}(z^{(q)}) - (1-\gamma) \cdot \mu_k^{(p)}(z^{(p)}) \cdot \mu_k^{(q)}(z^{(q)})}{1 + \gamma \cdot \mu_k^{(p)}(z^{(p)}) \cdot \mu_k^{(q)}(z^{(q)})}, \quad \gamma \leq 1, (15)$$

Ягером:

$$\mu_k^{(p)}(z^{(p)}) \cap \mu_k^{(q)}(z^{(q)}) = 1 - \min \left\{ 1, \left(\left[1 - \mu_k^{(p)}(z^{(p)}) \right]^r + \left[1 - \mu_k^{(q)}(z^{(q)}) \right]^r \right)^{\frac{1}{r}} \right\}, \quad r \geq 1, (16)$$

Дюбуа и Праде:

$$\mu_k^{(p)}(z^{(p)}) \cap \mu_k^{(q)}(z^{(q)}) = \frac{\mu_k^{(p)}(z^{(p)}) \cdot \mu_k^{(q)}(z^{(q)})}{\max \left\{ \mu_k^{(p)}(z^{(p)}), \mu_k^{(q)}(z^{(q)}), \alpha \right\}}, \quad \alpha \in [0; 1]. (17)$$

Полученные значения свертки $M_K(z)$ поступали далее в блок ранжирования, в котором производилось их ранжирование и упорядочение с последующим выводом значений на экран и записью в архив решений.

Функции интерфейса разработанной системы локализованы в отдельном модуле – модуле интерфейса. Здесь были реализованы процедуры, связанные с вводом-выводом информации в блоки, обеспечением возможности выбора видов опорных ВФП (3)-(5) и настройкой их параметров, обеспечением возможности выбора типа процедур вычисления теоретико-множественных операции объединения (8)-(11) и пересечения (14)-(17) и настройкой их параметров.

В п. 2.3. диссертации проведен анализ результатов моделирования процессов распознавания и классификации многомерных объектов пересекающихся классов на базе разработанной модели применительно к оценке профессиональной пригодности. В качестве основы были выбраны комбинированные тесты, базирующиеся на методиках психодиагностики ММРП и 16PF. Тесты содержали 8 шкал, каждая из которых, в свою очередь, содержала от 15 до 20 вопросов с возможными бинарными ответами («да» или «нет»). Исходный массив результатов комплексного тестирования содержал ответы 452 претендентов, из которых к числу удовлетворяющих требованиям профессиональной пригодности были отнесены сотрудники, успешно проработавшие не менее одного года. К числу претендентов, не удовлетворяющих требованиям профессиональной пригодности, были отнесены лица, не получившие положительного заключения экспертной комиссии или уволенные в течение первого года работы. Исходный массив результатов тестирования был разбит на две части, первая из которых содержала ответы 312 претендентов и была предназначена для заполнения исходной таблицы экспериментальных данных. Вторая часть, содержащая ответы 140 претендентов, была

предназначена для последующего тестирования разработанной модели распознавания и классификации. Каждая из частей массива содержала одинаковые доли лиц, удовлетворяющих и не удовлетворяющих сформулированным выше требованиям профессиональной пригодности.



Рис. 1. Зависимость уровня ошибки ε в процентах от вида контура огибания ВФП и типа теоретико-множественных операций объединения при тестировании на множествах средней сложности.

Полученные результаты позволили установить, что независимо от способа расчёта значений функции принадлежности и использования различных приемов вычисления интегральной совокупности признаков принадлежности пересекающихся классов многомерных объектов, значения уровня относительной ошибки тестирования оказываются недопустимо высокими (могут превышать 50%). Установлено, что наименьший уровень относительной ошибки классификации удастся достичь в случае использования теоретико-множественных операций объединения и пересечения по Дюбуа-Праде и выбора функции принадлежности Гауссова вида. В этом случае ошибка составляла 24,3%, то есть оставалась довольно большой.

В третьей главе диссертации проводится анализ возможности моделирования процессов распознавания и классификации многомерных объектов пересекающихся классов различной степени сложности на основе нейросетевых технологий.

В п. 3.1. проведено моделирование процессов классификации с помощью нейронных сетей, работающих на основе радиальных базисных функций. Внутренними параметрами данной нейросетевой архитектуры являются: число базисных функций N , множество центров μ_i каждой базисной функции; множество векторов дисперсии σ_i каждой базисной функции. Фактически вся совокупность указанных параметров при решении конкретной задачи подбирается эмпирически, при этом оптимальное число базисных функций выбирается путем простого перебора, а нахождение совокупностей векторов μ_i и σ_i может быть реализовано на основании различных методик. В работе первоначальные оценочные значения дисперсий базисных функций определялись по алгоритму K ближайших соседей путём установления значения дисперсии каждой базисной функции равного среднему расстоянию (по метрике Евклида) от центра радиальной базисной функции других пяти ближайших центров радиальных базисных функций:

$$\sigma_j = \frac{1}{K} \sum_{k=1}^K \sqrt{\sum_{n=1}^M (\mu_j^{(n)} - \mu_k^{(n)})^2}, \quad K = 5. \quad (18)$$

Далее вводилась общая константа пропорциональности h (как частный случай масштабирующей матрицы), которая являлась множителем дисперсии и использовалась для масштабирования значений дисперсии базисных функций.

Полученные результаты позволили определить зависимость величины ошибки ε при тестировании исследуемых множеств от коэффициента пропорциональности h для нейронных сетей с различным количеством радиальных базисных функций N . Было установлено, что во всех случаях вне зависимости от числа базисных функций с увеличением ширины, к которому приводит увеличение коэффициента пропорциональности, уровень ошибки тестирования неизменно уменьшался до тех пор, пока ширина базисной функции не достигала определенного значения. После достижения этого значения на некотором интервале h , который может быть достаточно протяжённым, величина ошибки изменяется мало. Дальнейшее увеличение значений коэффициента h , независимо от рассматриваемого в модели числа базисных функций, неизменно сопровождается увеличением ошибки ε .

Анализ показал, что отмеченные закономерности непосредственно связаны со спецификой интерполяционного отображения, реализуемого рассматриваемыми нейросетевыми классификаторами радиального типа, при котором необходимо существование таких радиальных базисных

функций, которые могли бы обеспечить покрытие всего пространства, реализуя при этом достаточно гладкую интерполяцию.

При очень малом значении коэффициента h , радиальные базисные функции будут слишком узкими и не будут перекрываться другими базисными функциями. Это в значительной степени затрудняет реализацию хорошей интерполяции, что в конечном итоге приводит к высоким значениям ошибки. По мере того, как значения коэффициента h увеличиваются, ширина радиальных базисных функций возрастает и происходит перекрытие соседних базисных функций. В результате этого становится возможной хорошая интерполяция и уменьшение ошибки.




Рис. 2. Зависимость уровня ошибки ε в процентах от коэффициента пропорциональности h для нейросетей с различным количеством радиальных базисных функций N при тестировании на множествах средней сложности (слева) и высокой сложности (справа).

Полученные результаты позволили установить достаточно большой интервал значений коэффициента h , в пределах которого изменение коэффициента пропорциональности не сопровождается значительными изменениями ошибки ε .

В пределах этого интервала базисные функции достигают оптимального уровня перекрытия для решения рассматриваемых задач. По мере дальнейшего увеличения значений коэффициента h , дисперсия радиальных базисных функций становится слишком большой, и большинство базисных функций начинают утрачивать свою индивидуальность, становясь в значительной мере похожими друг на

друга. Такая ситуация, подобно ситуации с узкими базисными функциями, приводит к плохой интерполяции, и, как следствие, к большой ошибке.

Центры базисных функций μ_i определялись на полном обучающем множестве на основании одной из версий алгоритма Линде-Бузо-Грея, называемого также алгоритмом K -средних. Суть этого алгоритма сводится к тому, что для произвольно выбранного образца из обучающего множества определяются его ближайшие (в смысле метрики Евклида) K соседей. После чего путём усреднения находятся координаты центра первого кластера, так называемого кластера K -средних, которые присваиваются центру первой базисной функции. Потом случайным образом выбирается второй образец и процедура возобновляется. В общем случае при большом значении K алгоритм K -средних требует значительных ресурсов памяти и достаточно большого объёма вычислений, особенно в случае ёмкого обучающего множества.

Альтернативой методу K -средних для определения центров μ_i может служить метод случайного выбора векторов обучающего множества с последующим использованием их координат в качестве центров базисных функций.

На основании результатов проведенного моделирования для всех классов исследуемых множеств были получены зависимости уровня ошибки функционирования ε радиальных нейросетевых классификаторов от коэффициента пропорциональности h , полученные при использовании метода K -средних для различных значений K , и на основании метода случайного выбора векторов обучающего множества в качестве центров радиальных базисных функций.

Анализ полученных результатов позволил установить, что при использовании алгоритма K -средних во всех случаях, за исключением кривой с параметром $K = 100$, характер изменения кривых $\varepsilon(h)$ при больших значениях дисперсии базисных функций оказывается весьма близким. При малых значениях дисперсии, когда базисные функции становятся узкими, параметр K оказывает более заметное влияние на значение величины уровня ошибки ε . Установлено, что наилучший результат достигается при значении параметра K равным пяти, хотя, в целом, изменение параметра K в интервале значений от 2 до 10 в случае выбора оптимального значения коэффициента пропорциональности h равного 20, не приводит к существенному увеличению ошибки.

Установлено, что определение центров радиальных базисных функций на основании случайного выбора из векторов обучающего множества во всех случаях приводит к значительному увеличению ошибки функционирования нейронной сети.

Это связано с тем, алгоритм K -средних определяет центры радиальных базисных функций вне зависимости от плотности распределения векторов в обучающем множестве, в то время как определение центров радиальных базисных функций на основании случайного выбора рассчитано на равномерное распределение векторов.

Проделанная работа позволила установить оптимальные значения внутренних параметров радиальной нейронной сети, необходимые для проведения последующего (см. ниже) сравнительного анализа на исследуемых типах множеств.

В п. 3.2. проведено моделирование процессов классификации на основе полиномиальных нейросетей.

Для исследуемых типов множеств изучено влияние общего числа полиномиальных коэффициентов C , числа слоёв полиномиальной нейросети L , ширины слоя W и степени полиномов n на величину ошибки функционирования ε . Получены многопараметрические зависимости ошибки ε от внутренних нейросетевых параметров (C, L, W, n) . Установлены оптимальные с точки зрения минимизации ошибки ε значения внутренних параметров. Проанализированы проекционные одномерные зависимости $\varepsilon(C)$, $\varepsilon(L)$, $\varepsilon(W)$ и $\varepsilon(n)$, отвечающие соответствующим фиксированным и оптимальным значениям внутренних параметров. Показано, что в качественном отношении характер зависимостей $\varepsilon(C)$, $\varepsilon(L)$, $\varepsilon(W)$ и $\varepsilon(n)$ остается практически неизменным для различных типов исследуемых множеств, однако в количественном отношении тип множества может существенно влиять как на значения оптимальных внутренних параметров, так и на уровень минимальной ошибки функционирования полиномиальной нейронной сети.

Установлено, что в случае простого множества оптимальный уровень ошибки оказывается менее 1%, когда число полиномиальных коэффициентов больше 100 вне зависимости от степени полиномов. При этом кривая $\varepsilon(C)$, отвечающая фиксированным оптимальным значениям внутренних параметров, характеризуется сначала резким экспоненциальным монотонным убыванием при увеличении параметра C до 100; дальнейшее увеличение значения параметра C характеризуется резким снижением скорости убывания кривой $\varepsilon(C)$, которая в дальнейшем достигает своего насыщения, в результате чего уровень минимальной ошибки функционирования оказывается фактически неизменным.

Кривые зависимостей $\varepsilon(L)$ и $\varepsilon(W)$, отвечающие оптимальным фиксированным значениям внутренних параметров, также характеризуются двумя стадиями монотонного убывания: резкого

экспоненциального и асимптотически плавного. При этом независимо от степени полиномов ошибка оказывается меньше 1%, когда число слоёв L превышает 5, а ширина полиномиального слоя превышает 8.

Для множества средней сложности оптимальный уровень ошибки составляет менее 3%, когда число полиномиальных коэффициентов превышает 200 для полиномов третьей степени и когда значение параметра C становится превышает 300 для полиномов второй степени. Кривые зависимостей $\varepsilon(L)$ и $\varepsilon(W)$, отвечающие оптимальным фиксированным значениям внутренних параметров, также оказываются чувствительными к степени полинома. Для полиномов второй степени минимальная величина ошибки не превышает 3%, когда число полиномиальных слоёв больше 7 при 19 полиномиальных узлах. Для полиномов третьей степени тот же уровень ошибки достигается уже при значении параметра L равном 6 и W равном 14.

В случае множества высокой сложности вследствие плохой детерминированности границ раздела элементов, относящихся к различным классам, значения оптимального уровня ошибки функционирования нейронной сети оказываются аномально высокими и достигают своего минимального значения, не превышающего 21%, когда число коэффициентов превышает 300 и 500 для полиномов третьей и второй степени соответственно.

Полученные результаты позволили установить, что в том случае, когда в полиномиальных узлах формируются полиномы третьей степени, минимальный уровень ошибки ε для множества высокой сложности достигается на 7 слое, в то же время в случае формирования в полиномиальных узлах полиномов второй степени, минимальный уровень ошибки ε достигается на 8 слое.

Анализ зависимостей уровня ошибки ε от ширины слоя W показал, что для пересекающегося множества резкое снижение уровня ошибки ε , при котором её значение не превышает 21%, наблюдается в случае увеличения ширины слоя до 28 при формировании в полиномиальных узлах полиномов второй степени и при увеличении ширины слоя до 24 в случае формирования в полиномиальных узлах полиномов третьей степени. Следует заметить, что вне зависимости от степени рассматриваемых полиномов, формируемых в полиномиальных узлах, дальнейшее увеличение максимальной ширины слоя не приводит к значительным изменениям уровня ошибки ε .

В п. 3.3 для различных типов исследуемых множеств проводится сравнительный анализ полученных результатов функционирования всех рассмотренных в работе видов нейронных сетей. Анализ эпюр значений

уровня ошибки, полученных при тестировании на нейросетевых классификаторах показал, что независимо от используемой сети, усложнение типа исследуемых множеств приводит к увеличению уровня ошибки. Совокупность полученных результатов позволяет сделать вывод, что для всех типов исследуемых множеств нейронные сети, функционирующие на основе простого адаптивного алгоритма и алгоритма сопряженных градиентов, приводят к слишком высокой ошибке. В то же время, нейронные сети на основе простого алгоритма обратного распространения ошибки (метода градиентного спуска), множественного адаптивного алгоритма, а специализированные сети радиальных базисных функций и полиномиальные сети приводят, в случае оптимального выбора соответствующих внутренних параметров, к очень близким значениям величины уровня ошибки.

Анализ эпюр ресурсов времени, необходимого для обучения различных нейросетей, позволил установить, что независимо от сложности исследуемых в работе множеств наиболее эффективной с точки зрения необходимых ресурсов времени, уходящего как на обучение, так и на тестирование, является нейросетевая архитектура, функционирующая на основе радиальных базисных функций.

Анализ полученных в работе эпюр значений ресурсов памяти, необходимой для обучения различных нейросетей, позволил установить, что независимо от типа исследуемых множеств наиболее эффективной с точки зрения затрат ресурсов памяти, необходимых как для обучения, так и для тестирования, является нейросетевая архитектура с парадигмой обратного распространения ошибки. Несколько большие требования к ресурсам памяти предъявляет нейронная сеть, использующая алгоритм множественной адаптации. Самыми неэффективными, с точки зрения расхода ресурсов памяти для обучения, являются полиномиальные нейронные сети.

В соответствии результатами сравнительного анализа процессов нейросетевой классификации, проведенных в п. 3.3 диссертации, РБФ сети наиболее эффективно расходуют системные ресурсы. Это позволяет сделать вывод об их общей наибольшей эффективности из всего класса рассмотренных в работе нейронных сетей.

Вот почему для моделирования процессов классификации профессиональной пригодности на основании комплексного тестирования, которому посвящён п. 3.4. диссертации, была выбрана нейросетевая архитектура РБФ. Центры базисных функций определялись в соответствии с результатами, полученными в п. 3.1, на основании метода K -средних ($K = 5$). Число входов и выходов классификатора составляло 8 и 2

соответственно. Оптимальные значения количества базисных функций и их дисперсий подбирались экспериментально в соответствии с методикой, описанной в п. 3.1 диссертации. Исходный массив результатов комплексного тестирования и его разбиение на обучающее и тестовое подмножества полностью соответствовал изложенному выше описанию (п. 2.3).

Проведенное моделирование и анализ позволили найти оптимальные значения коэффициента пропорциональности h и числа радиальных базисных функций N , которым отвечали наилучшие характеристики функционирования сети. При этом минимальная величина ошибки сети составила 23,1%. Следует признать, что полученная ошибка незначительно меньше ошибки функционирования системы, основанной на нечёткой логике.

Четвёртая глава диссертации посвящена разработке нового метода, соединяющего в себе преимущества модели, основанной на представлениях теории нечётких множеств (см. гл. 2), и нейросетевых подходов. В рамках диссертации была предложена новая гибридная модель.

В п. 4.1 проводится описание разработанной модели. Согласно результатам, полученным во второй главе диссертации, использование представлений теории нечётких множеств может приводить к удовлетворительным результатам при решении задач распознавания и классификации объектов пересекающихся классов. Вместе с тем, результаты исследований, проведенных в третьей главе диссертации, показали, что достижение наименьшей ошибки при распознавании и классификации многомерных объектов пересекающихся классов становится возможным в случае применения нейронных сетей РБФ. С целью исследования возможности улучшения имеющихся результатов была предпринята попытка создания гибридной модели, позволяющей соединить в себе достоинства каждого из рассмотренных подходов.

Разработанная система состояла из двух основных модулей – модуля предобработки и модуля распознавания и работала в трех режимах:

- 1) подготовка опорного массива вектор-функций принадлежности;
- 2) обучение нейронной сети;
- 3) распознавание и классификация.

В первом режиме функционировал только модуль предобработки, в задачу которого входило создание опорных вектор-функций принадлежности, представляющих собой интегральные характеристики экспертных баз данных для каждого класса.

Модуль предобработки содержал три основных блока – блок экспертной базы данных, блок вектор-функций принадлежности и блок предобработки данных.

В экспертную базу данных помещались исходные массивы $\{P_k\}$, составленные из N – мерных векторов K классов (1).

Массивы векторов $\tilde{X}_{k,p}^{(N)}$ поступали в блок предобработки, где для каждого из них производился расчёт массива вектор-функций принадлежности (2), на базе которого для каждого класса производился расчёт опорного массива интегральных экспертных вектор-функций принадлежности (6)–(7).

Совокупности интегральных экспертных вектор-функций принадлежности $\tilde{H}_k^{(N)}$, полученные на основе ЭБД для каждого класса, помещались далее в блок ВФП и использовались для последующих расчётов.

Второй режим работы системы связан с обучением нейронной сети РБФ. В этом режиме в блоке ВФП модуля предобработки для всех векторов $\tilde{X}_{k,p}^{(N)}$ на основании массива опорных интегральных экспертных вектор-функций принадлежности $\tilde{H}_k^{(N)}$ производился расчёт значений для каждого класса K векторов-функций принадлежности $\tilde{M}_k^{(N)}(x)$.

Рассчитанные значения ВФП $\tilde{M}_k^{(N)}(x)$ направлялись в модуль распознавания и классификации в транспортный блок, и после проверки на целостность и непротиворечивость передавались далее в нейросетевой блок для обучения нейронной сети. После обучения полученные результаты и параметры РБФ сети заносятся в архив решений.

В режиме распознавания и классификации значения координат входного вектора $\tilde{Z}^{(N)}$, подлежащего распознаванию и классификации, поступали в транспортный блок, откуда после проверки на целостность и непротиворечивость передавались в блок ВФП модуля предобработки, где на основании массива опорных интегральных экспертных вектор-функций принадлежности $\tilde{H}_k^{(N)}$ производился расчёт значений для каждого класса K векторов-функций принадлежности (12).

Рассчитанные значения ВФП $\tilde{M}_k^{(N)}(z)$ возвращались в модуль распознавания и классификации в транспортный блок, откуда после проверки на целостность и непротиворечивость передавались далее в нейросетевой блок, в котором и проводилось их распознавание и классификация. Полученные решения и использовавшиеся параметры теоретико-множественных операций записывались в архив решений и выводились на экран.

Как и на систему, рассмотренную во второй главе, на гибридную систему накладывается ряд ограничений по виду теоретико-множественных операций. Операции объединения (8)-(11), использованные в разработанной гибридной системе, полностью удовлетворяют этим ограничениям.

В задачи модуля интерфейса, в котором были локализованы все зависимые от аппаратной части функции, помимо ввода-вывода информации в блоки, обеспечения возможности выбора видов опорных ВФП (3)-(5) и настройки их параметров, обеспечения возможности выбора типа процедур вычисления операций объединения (8)-(11) и настройки их параметров, входило обеспечение возможности установки внешних и внутренних параметров нейронной сети на радиальных базисных функциях.

На основании разработанной системы было проведено моделирование процессов распознавания и классификации объектов пересекающихся классов на примере рассмотренного ранее (во второй главе диссертации) массива психодиагностических данных.




Рис. 3. Зависимость уровня ошибки ε в процентах от вида контура огибания ВФП и типа теоретико-множественных операций объединения при тестировании на множествах средней сложности.

Полученные результаты продемонстрировали очевидное преимущество разработанной гибридной модели над рассмотренными ранее классификаторами. Применение разработанной гибридной модели в процессах классификации многомерных объектов пересекающихся классов

при использовании оптимальных параметров системы позволяет достичь минимальной ошибки ε , составляющей 8,7 %, что почти в 3 раза меньше, чем минимальная ошибка, показанная на лучшем нейросетевом классификаторе.

Следует отметить, что наименьший уровень ошибки для всех типов исследуемых множеств был получен при использовании параметризованной операции объединения по Дюбуа и Праде.

Проведенный анализ позволил установить, что полученное практически трехкратное улучшение результатов связано со следующими двумя особенностями гибридной модели. Во-первых, в отличие от модели, функционирующей на основе представлений теории нечётких множеств, вместо блока свёртки здесь используется нейросетевой блок РБФ, то есть свертку фактически осуществляет нейронная сеть, а не теоретико-множественная операция пересечения. И, во-вторых, в гибридной системе, в отличие от нейросетевого классификатора на основе РБФ, процедуры обучения и распознавания проводятся на основе соответствующих векторных массивов $\bar{M}_k^{(N)}(x)$ и $\bar{M}_k^{(N)}(z)$, что, естественно, требует больших затрат ресурсов, но приводит к значительному улучшению результатов, особенно в условиях недостаточно большой обучающей выборки.

К сожалению, разработанная модель не может считаться полностью универсальной. Самым значительным её ограничением остаётся ограничение на размерность входных данных. Установлено, что классификация объектов в пространствах с размерностью более 10 приводит к существенному ухудшению результатов. Это связано с ростом ошибки, возникающей из-за применения теоретико-множественных операций объединения на этапе подготовки опорного массива вектор-функций принадлежности. Другой недостаток модели проявляется в ограничениях на теоретико-множественные операции, в частности, в виде требования к их нормированности.

Тем не менее, разработанная модель и построенная на её основе система, позволили успешно решить задачу психодиагностики, показав значительное преимущество над традиционными методами.

ОСНОВНЫЕ РЕЗУЛЬТАТЫ И ВЫВОДЫ

1. Разработаны экспериментальные полигоны трех классов объектов различной степени сложности, для которых проведено моделирование процессов распознавания и классификации на основе шести нейросетевых классификаторов; установлены оптимальные значения внутренних параметров нейронных сетей; проведен сравнительный анализ эффективности использования различных нейросетевых архитектур применительно к вопросам распознавания и классификации объектов различной степени сложности.
2. Для многомерных объектов пересекающихся классов введены понятия векторных функций принадлежности (ВФП) и предложен способ расчёта интегральных опорных ВФП на базе обобщенных представлений теории нечётких множеств.
3. Предложен метод распознавания многомерных объектов в условиях пересекающихся классов на основе введенных понятий, обобщенных и модифицируемых операций теории нечётких множеств.
4. Предложен гибридный метод распознавания и классификации многомерных объектов в условиях пересекающихся классов на основе обобщенных представлений и модифицируемых операций теории нечётких множеств и специализированных нейросетевых технологий.
5. Разработаны и реализованы в виде программного комплекса системы для моделирования процессов распознавания и классификации многомерных объектов пересекающихся классов на базе метода, основанного на обобщенных представлений теории нечётких множеств, и гибридного метода, основанного на представлениях теории нечётких множеств и нейросетевых технологиях.
6. Проведены экспериментальные исследования, наглядно демонстрирующие эффективность применения предложенной гибридной модели на примере решения задачи психодиагностики. Проанализированы ограничения и разработаны рекомендации по применению модели. Внедрение разработанной диагностической системы позволило полностью автоматизировать процесс диагностики и трехкратно снизить уровень ошибки.

1. Kruchinin I.I., Loginov B.M. Forecasting the bank loro account cashflow with the help of neural network // Artificial Intelligence. - Durban (South Africa): IAAMSAD, 1999. – Vol. II. - P.69-74.
2. Kruchinin I.I., Loginov B.M. Experts system construction for forecasting the bank's cash-flow parameters analysis // Proceedings of the International Conference on Computer Modeling, Simulation and Communication. – Jaipur (India), 1999. – P.114-115.
3. Кручинин И.И., Логинов Б.М. Моделирование процессов классификации на основе нейросетей с парадигмой обратного распространения ошибки. – Калуга, 2000. – 38 с. (Деп. в ВИНТИ РАН от 20.12.00, №3193-B00).
4. Кручинин И.И., Лачихин А.В. Разработка библиотеки классов на СИ⁺⁺ для нейронных сетей, обучаемых по методу обратного распространения ошибки // Тезисы докладов 1-й Российской конференции молодых ученых по математическому моделированию. – Москва, 2000. – С.232-234.
5. Кручинин И.И., Логинов Б.М. Математические модели, алгоритмы и методики моделирования процессов классификации. – Калуга, 2000. – 68с. (Деп. в ВИНТИ РАН от 13.12.00, №3130-B00).
6. Кручинин И.И., Канарейкин Д.Е. Предобработка входных сигналов нейросетей // Тезисы докладов 1-й Российской конференции молодых ученых по математическому моделированию. – Москва, 2000. – С.229-231.
7. Кручинин И.И., Твердохлеб Н.С., Логинов Б.М. Моделирование процессов классификации на базе нейросетевых архитектур функционирующих на основе радиальных базисных функций. – Калуга, 2001. – 25 с. (Деп. в ВИНТИ РАН от 16.01.01, №118-B2001).
8. Loginov B.M., Kruchinin I.I., Lamakin A.Yu. Classification processes simulation based on the neural networks with different paradigms // Development and Practice of Artificial Intelligence Techniques. - Durban (South Africa): IAAMSAD, 2000. - P.185-193.
9. Кручинин И.И., Ломовцева О.Б., Логинов Б.М. Моделирование процессов классификации на основе полиномиальных нейросетей. – Калуга, 2001. – 42 с. (Деп. в ВИНТИ РАН от 06.02.01, №320-B2001).
10. Кручинин И.И., Логинов Б.М. Моделирование процессов классификации многомерных объектов пересекающихся классов на основе представлений нечётких множеств // Труды 2-й Российской конференции молодых ученых по математическому моделированию. – Москва: МГТУ, 2002. – с.14-23.
11. Кручинин И.И., Логинов Б.М. Моделирование процессов классификации многомерных объектов пересекающихся классов на основе гибридных нейросетей // Труды 2-й Российской конференции молодых ученых по математическому моделированию. – Москва: МГТУ, 2002. – с.24-30.