

На правах рукописи

Гаврилов Александр Игоревич

**НЕЙРОСЕТЕВАЯ РЕАЛИЗАЦИЯ
ПРОЦЕДУРЫ ИДЕНТИФИКАЦИИ ДИНАМИЧЕСКИХ СИСТЕМ**

Специальность 05.13.01 – управление в технических системах

**Автореферат
диссертации на соискание ученой степени
кандидата технических наук**

МОСКВА – 2000

Работа выполнена на кафедре Систем автоматического управления
Московского государственного технического университета
имени Н.Э. Баумана.

Научный руководитель: доктор технических наук, профессор К.А. Пупков

Официальные оппоненты:

- доктор физико-математических наук, профессор А.П. Карпенко
- кандидат технических наук, доцент Б.П. Тюхов

Ведущая организация: Государственное унитарное предприятие «Научно-исследовательский и конструкторский институт монтажных технологий» (ГУП «ГП НИКИМТ»).

20. в 14³⁰ на заседании
Московского государственного
университета по адресу: Москва, 107005,

университета
имени Н.Э. Баумана.

2009г.

1565311

НТБ МГТУ им. Н.Э. Баумана



1565311

Гаврилов А. И. Нейросетевая

К.А. Неусыпин

10

1565311

Одним из подходов, вызывающих все больший интерес, является использование искусственных нейронных сетей (нейронных сетей, НС) для решения задач как идентификации (построения НС моделей) нелинейных динамических объектов, так и для проектирования систем автоматического управления в целом (нейроконтроллеров). Проблемам использования НС в технических приложениях посвящено огромное количество периодических научных журналов, в частности “Neural Networks” (с 1983 года), “IEEE Transactions on Neural Networks” (с 1990 года). В России с 1992 г. издается журнал “Нейрокомпьютер”. По данной тематике ежегодно проводится большое число конференций и симпозиумов, в том числе российские

числа, российские
М Г Т У
им. Н. Э. Баумана
БН 007 А

“Нейроинформатика и нейрокомпьютеры”, Ростов-на-Дону, 1992 г., 1995 г., 1998 г., “Нейрокомпьютеры и их применение”, Москва, ежегодно, начиная с 1995 г. Исследования в области нейросетевых технологий поддерживаются Российским фондом фундаментальных исследований.

Теория искусственных нейронных сетей представляет собой дисциплину, у истоков которой – исследования принципов функционирования биологических нейронных структур. Развитие дисциплины привело к созданию НС моделей, значительно отличающихся от своих биологических прототипов, но обладающих такими характерными чертами, как способность к обучению, обобщению и абстрагированию. Именно эти свойства НС позволяют эффективно решать задачу построения формальных моделей сложных нелинейных динамических объектов при отсутствии априорной информации, необходимой для применения традиционных методов идентификации.

Помимо систем управления нейронные сети используются для решения таких задач, как адаптивная обработка сигналов и фильтрация, распознавание образов и кластеризация, создание памяти, адресуемой по содержанию, а также в медицине и банковской деятельности.

Технические системы, включающие в себя искусственные нейронные сети в качестве прогнозирующих моделей, адаптивных регуляторов или универсальных высокопараллельных вычислителей, могут быть отнесены к классу интеллектуальных систем, способных на основе использования сведений и знаний при наличии мотивации синтезировать цель и находить рациональные способы ее достижения.

Цель работы – создание формализованного подхода к нейросетевой реализации процедуры идентификации, применимого к широкому классу динамических систем, и разработка технических приложений на основе сформированного подхода. В соответствии с поставленной целью, основными задачами работы являются:

- обоснование возможности использования НС в качестве формальных моделей динамических объектов;
- разработка базовых нейросетевых модельных структур;
- разработка, анализ и алгоритмизация многостадийной процедуры идентификации на основе нейросетевых модельных структур, включая планирование и проведение эксперимента; выбор структуры НС

модели; обучение НС; тестирование (установление адекватности) модели; оптимизацию структуры НС;

- создание программно-аппаратного комплекса мониторинга технологического процесса дуговой сварки, основанного на применении прогнозирующих нейросетевых моделей.

Методы исследования. Для решения поставленных задач использовались методы теории оптимизации, теории дискретных систем, теории вероятности и математической статистики. В экспериментальных исследованиях применялось цифровое моделирование на ЭВМ.

Научная новизна, практическая и теоретическая ценность работы. На основе анализа, систематизации и обобщения научных достижений в таких областях, как теория автоматического управления, информатика, вычислительная математика и статистика, нейрофизиология, физика и технология производства микрочипов, сформирован комплексный формализованный подход к решению задачи идентификации динамических объектов с использованием нейросетевых моделей. Предлагаемый подход обладает как существенной научной новизной, так и практической значимостью.

В ходе выполнения работы получены следующие основные теоретические результаты:

- Сформированы базовые нейросетевые модельные структуры с линейным регрессионным входом, использующие характерные свойства нейронных сетей (способность к обучению на множестве экспериментальных данных, обобщение и абстрагирование) для моделирования нелинейных динамических систем.
- Выявлены особенности применения методов безусловной минимизации функций многих переменных для решения задачи оптимизации параметров нейросетевых моделей.
- Исследованы и алгоритмизированы методы подтверждения моделей: многошаговое прогнозирование, оценка ошибки обобщения, корреляционные оценки ошибки прогнозирования.
- Предложен подход к оптимизации структуры нейросетевых моделей с целью улучшения их рабочих характеристик, основанный на контрастировании весовых коэффициентов НС.

- Разработан подход к оценке качества сварных соединений на основе анализа ширины обратного валика шва, прогнозируемой нейросетевой моделью.

Разработанные и исследованные в работе нейросетевые алгоритмы идентификации динамических объектов могут быть использованы при создании программного обеспечения и технических средств информационно-вычислительных комплексов моделирования систем управления нелинейными процессами при отсутствии достаточного объема априорной информации.

Практической реализацией разработанных алгоритмов является программный продукт, представляющий собой композицию модулей, соответствующих каждой стадии процедуры идентификации и объединенных в одной оболочке. Интуитивно понятный интерфейс пользователя, быстрота и вычислительная робастность используемых алгоритмов позволяют получать адекватные нейросетевые модели динамических объектов за рекордно короткие сроки и с минимальным участием пользователя (проектировщика).

Научную новизну и значительную практическую ценность составляют нейросетевые модели технологического процесса дуговой сварки, позволяющие эффективно прогнозировать качество сварного соединения на основе информационных сигналов, получаемых от уникального лабораторного стенда.

Реализация и внедрение результатов. Основные теоретические и практические результаты получены в ходе выполнения научно-исследовательской работы в рамках Федеральной программы «Университеты России – фундаментальные исследования» (проект №1229 «Исследование и создание интеллектуальных систем») и межвузовской программы «Многопроцессорные ЭВМ с параллельной структурой и виртуальная реальность» (приказ Министерства общего и профессионального образования РФ №572 от 02.03.98).

Разработанные в рамках настоящей работы алгоритмы и программное обеспечение использованы в научно-учебном центре «Сварка и контроль» при создании системы автоматического управления сварочным процессом.

Апробация работы. Материалы теоретических исследований представлены на конференциях: Второй международный симпозиум "Интеллектуальные системы" (Россия, Санкт-Петербург, 1996г.); XXXIII научная конференция Российского университета дружбы народов (Россия, Москва, 1997г.); Третий международный симпозиум "Интеллектуальные системы" (Россия, Псков, 1997г.); Научно-техническая конференция студентов, аспирантов и молодых специалистов МГИЭМ (Россия, Москва, 1999).

По результатам проведенных исследований опубликовано 5 научных работ.

Структура и объем работы. Диссертация состоит из введения, 3 глав, заключения, списка литературы из 95 наименований и приложений. Основная часть работы изложена на 184 страницах, содержит 2 таблицы и 40 рисунков. Общий объем приложений – 30 страниц.

СОДЕРЖАНИЕ РАБОТЫ

Во введении показана актуальность темы диссертационной работы, сформулированы цели и задачи исследования, обоснованы научная новизна и практическая ценность исследований, приведены сведения об апробации работы и публикациях, представлены основные научные результаты, полученные в ходе выполнения работы.

В первой главе рассматривается традиционная постановка задачи идентификации объектов типа «черный ящик» и существующие методы построения описания динамических систем на основе линейных регрессионных модельных структур. Даются определения НС с позиций различных научных областей (теория управления, математика и статистика, вычислительная техника). Рассматриваются фундаментальные особенности функционирования НС, их классификация и категории решаемых задач; обосновывается возможность реализации процедуры идентификации нелинейных динамических объектов на основе одного класса нейросетевых модельных структур – многослойных перцептронов.

Традиционным методом построения моделей динамических объектов является реализация процедуры идентификации с использованием регрессионных модельных структур.

Понятие регрессии непосредственно связано с задачей прогнозирования величины y на основе информации, полученной при измерении других величин $\varphi_1, \dots, \varphi_d$. В случае динамических систем зависимая переменная y является выходом системы в некоторый момент времени (t), а регрессоры φ_i содержат информацию о прошлом поведении системы.

Таким образом, обобщенное описание произвольного динамического объекта может быть представлено в следующем виде:

$$\hat{y}(t|\theta) = g(\varphi(t, \theta), \theta), \quad (1)$$

где $\varphi(t, \theta)$ - регрессионный вектор, $\theta = [\theta_1, \theta_2, \dots, \theta_p]$ - вектор настраиваемых параметров. Выражение (1) носит название прогнозирующей модели.

Прогнозирующая модель $g(\varphi(t, \theta), \theta)$ может быть реализована на нейросетевой модельной структуре, имеющей следующее математическое представление:

$$g_i(\varphi(t, \theta), \theta) = \hat{y}_i(t|\theta) = \hat{y}_i(t|w, W) = F_i \left(\sum_{j=1}^{n_h} W_{ij} f_j \left(\sum_{l=1}^{n_\varphi} w_{jl} \varphi_l + w_{j0} \right) + W_{i0} \right), \quad (2)$$

где $f_j(x) = \tanh(x)$ - активационная функция нейронов скрытого слоя; $F_i(x) = kx$; $k = \text{const}$ - активационная функция нейронов выходного слоя; n_φ - размерность регрессионного вектора (число входов НС); n_h - число нейронов в скрытом слое; θ - вектор настраиваемых параметров нейронной сети, включающий весовые коэффициенты и нейронные смещения (w_{jl}, W_{ij}).

Использование многослойных нейронных сетей в качестве прогнозирующих моделей динамических систем обусловлено способностью НС моделировать произвольные нелинейные непрерывные функции в результате обучения на множестве примеров (экспериментальных данных). Дополнительные преимущества нейронных сетей состоят в способности выделять общие принципы при предъявлении некоторого набора обучающих векторов (обобщение) и возможности работы с неполным набором данных (абстрагирование).

Во второй главе рассматриваются особенности реализации многоэтапной процедуры идентификации динамических объектов на

основе нейросетевых модельных структур. Особое внимание уделяется практическим аспектам: созданию репрезентативной выборки экспериментальных данных и их предварительной обработке, рациональному выбору структуры нейросетевой модели, адаптации алгоритмов поиска минимума функций многих переменных к обучению нейронных сетей, структурной оптимизации нейросетевых моделей, проверке адекватности полученной модели.

Обобщенная процедура идентификации динамических систем включает в себя следующие основные стадии:

- подготовка и проведение эксперимента;
- выбор модельной структуры;
- оценка (оптимизация параметров) модели;
- принятие решения об адекватности модели (подтверждение модели).

На стадии подготовки и проведения эксперимента решается задача сбора необходимого количества экспериментальных данных во всем рабочем диапазоне системы: $Z^N = \{u(t), y(t)\}$, $t = 1, \dots, N$, где $u(t), y(t)$ - вход и выход системы соответственно; N - число дискретных отсчетов в множестве экспериментальных данных.

В случае, когда априорные знания о физике объекта или тесты на нелинейность позволяют сделать заключение о целесообразности применения нейросетевого подхода к идентификации объекта, возникает ряд специфических вопросов постановки эксперимента, сбора и предварительной обработки данных для обучения и тестирования нейронной сети, причем полнота и достоверность данных во многом определяет качество идентификации.

В работе рассмотрены проблемы, связанные с выбором частоты дискретизации, синтезом тестирующего (входного) сигнала, возникновением нежелательных элементов в множестве экспериментальных данных, и предложены практические методы их решения.

В качестве базовых нелинейных нейросетевых модельных структур предлагаются следующие модификации линейных регрессионных моделей:

Нейросетевая авторегрессионная модель:

Регрессор:

$$\varphi(t, \theta) = \begin{bmatrix} y(t-1) \dots y(t-n_a) & u(t-n_k) \dots u(t-n_b-n_k+1) \end{bmatrix}^T. \quad (3)$$

Прогнозирующая модель:

$$\hat{y}(t|\theta) = \hat{y}(t|t-1, \theta) = g(\varphi(t), \theta). \quad (4)$$

Нейросетевая авторегрессионная модель скользящего среднего:

Регрессор:

$$\begin{aligned} \varphi(t, \theta) &= \begin{bmatrix} y(t-1) \dots y(t-n_a) & u(t-n_k) \dots u(t-n_b-n_k+1) & \varepsilon(t-1) \dots \varepsilon(t-n_c) \end{bmatrix}^T = \\ &= \begin{bmatrix} \varphi_1^T(t) & \varepsilon(t-1) \dots \varepsilon(t-n_c) \end{bmatrix}^T, \end{aligned} \quad (5)$$

где $\varepsilon(t) = y(t) - \hat{y}(t|\theta)$ - ошибка прогнозирования (невязка).

Прогнозирующая модель:

$$\hat{y}(t|\theta) = g(\varphi_1(t), \theta) + (C(q^{-1}) - 1)\varepsilon(t), \quad (6)$$

где $C(q^{-1}) = 1 + c_1 q^{-1} + \dots + c_n q^{-n}$ - полином от оператора запаздывания q^{-1} .

Нейросетевая модель типа “обновления пространства состояний”.

Регрессор:

$$\varphi(t) = \begin{bmatrix} \hat{x}^T(t|\theta) & u^T(t) & \varepsilon^T(t|\theta) \end{bmatrix}^T. \quad (7)$$

Прогнозирующая модель:

$$\begin{aligned} \hat{x}(t+1|\theta) &= g(\varphi(t), \theta), \\ \hat{y}(t|\theta) &= C(\theta)\hat{x}(t|\theta). \end{aligned} \quad (8)$$

Выбор семейства моделей, подходящих для описания конкретной системы, определяется априорными знаниями о физических принципах функционирования объекта и конкретной постановкой задачи. Помимо вышеперечисленных базовых моделей могут быть использованы их комбинации и модификации.

На стадии разработки структуры нейросетевой модели возникает ряд проблем, наиболее существенными из которых являются выбор вектора входов НС (регрессора) и определение внутренней структуры НС.

Наиболее трудоемким представляется определение глубины регрессии, т.е. количества n ; значений компонент регрессора (числа отсчетов сигналов) в предыдущие моменты времени. В работе предлагается автоматизированная процедура определения глубины регрессии, основанная на сопоставлении коэффициентов

$$q_{ij} = \frac{|y(t_i) - y(t_j)|}{|\varphi(t_i) - \varphi(t_j)|}, \quad i \neq j, \quad (9)$$

полученных для модельной структуры типа $y(t) = g(\varphi(t), \theta)$ с регрессионным вектором

$$\varphi(t) = [\varphi_1 \quad \varphi_2 \quad \varphi_3 \quad \dots \quad \varphi_z]^T = \\ = [y(t-1) \quad \dots \quad y(t-n) \quad u(t-d) \quad \dots \quad u(t-d-m)]^T \quad (10)$$

на множестве экспериментальных данных $Z^N = \{[y(t), u(t)], t = 1, 2, \dots, N\}$.

При использовании НС в качестве модельных структур значительную роль играет не только выбор регрессора, но и задание внутренней структуры сети - числа «скрытых» слоев и количества нейронов в каждом скрытом слое. В работе даются практические рекомендации по априорному (до проведения процедуры обучения) выбору внутренней структуры нейросетевой модели, рассматриваются методы структурной оптимизации моделей после реализации процедуры обучения.

На стадии оценки (оптимизации параметров) модели реализуется отображение $Z^N \rightarrow \hat{\theta}$ множества экспериментальных данных на множество параметров (весовых коэффициентов) выбранной нейросетевой модельной структуры с целью получения оптимального, в силу некоторого критерия, прогноза выходного сигнала $\hat{y}$. В теории нейронных сетей этот процесс носит название обучения, а традиционно используемым критерием является среднеквадратичная ошибка прогнозирования:

$$V_N(\theta, Z^N) = \frac{1}{2N} \sum_{t=1}^N (y(t) - \hat{y}(t|\theta))^2 = \frac{1}{2N} \sum_{t=1}^N \varepsilon^2(t, \theta). \quad (11)$$

Таким образом, обучение НС состоит в нахождении вектора параметров $\hat{\theta}$, минимизирующих критерий (11):

$$\hat{\theta} = \arg \min_{\theta} V_N(\theta, Z^N). \quad (12)$$

Для нахождения вектора оптимальных параметров используются методы последовательного приближения, или итеративные методы поиска:

$$\theta^{(i+1)} = \theta^{(i)} + \mu^{(i)} f^{(i)}, \quad (13)$$

где $\theta^{(i)}$ - значение параметров на текущей итерации i , $f^{(i)}$ - направление поиска, $\mu^{(i)}$ - шаг алгоритма. В работе исследуются особенности ряда

методов минимизации критерия (11), среди которых - градиентный метод, метод Ньютона, Гаусса-Ньютона и Левенберга - Маркадта. Рассматриваются вопросы адаптации указанных методов к реализации процедуры обучения нейронных сетей.

На стадии принятия решения об адекватности модели проверяется соответствие модели реальной системе и условиям, в которых ее предполагается использовать. Данный этап является наиболее трудоемким и требует непосредственного участия инженера-разработчика. В работе анализируется ряд оценок и тестов, позволяющих сделать верное заключение о возможности дальнейшего использования модели. Помимо традиционной проверки эффективности работы модели на тестовом множестве (перекрестной оценки) предлагается ряд корреляционных оценок, в том числе второго порядка, рассматриваются методы имитационного моделирования и подтверждения модели на основе исследования средней ошибки обобщения.

Оценка средней ошибки обобщения используется также для структурной оптимизации НС моделей.

Третья глава посвящена вопросам построения программно-аппаратного комплекса мониторинга технологического процесса дуговой сварки, основным элементом которого являются прогнозирующие нейросетевые модели. Значительное внимание уделяется особенностям технологического процесса и построению критериальных оценок качества получаемого сварного соединения. Приводятся основные технические характеристики лабораторной установки, дается обзор функциональных возможностей разработанного программного продукта NNPredictor. Детально рассматривается процедура получения прогнозирующих нейросетевых моделей, начиная от постановки эксперимента и заканчивая установлением адекватности полученной модели исследуемому объекту. Экспериментально подтверждается эффективность применения разработанных нейросетевых моделей для решения задачи оценки качества сварного соединения.

Технологический процесс дуговой сварки рассматривается как единая электрогидродинамическая система «источник-дуга-сварочная ванна», подверженная влиянию возмущений, основными из которых являются:

- изменения длины дуги, вызываемые неровностями на поверхности изделия, капельным переносом металла и другими причинами;
- изменение вылета электрода вследствие возможных колебаний расстояния между токоподводящим мундштуком и изделием;
- изменения напряжения холостого хода источника питания и сопротивления цепи, вызываемые колебаниями напряжения сети, нагревом обмоток, нестабильностью контактов и другими причинами;
- изменения момента на валу двигателей перемещения сварочного автомата, приводящие к изменению скорости сварки;
- изменения геометрии сборки стыка под сварку, зазора, притупления, угла раздела кромок;
- структурная и химическая неоднородность свариваемого материала;
- изменение толщины свариваемого материала по длине стыка;
- изменение состояния свариваемой поверхности металла (наличия на поверхности окисных пленок, масла и других нежелательных составляющих);
- эрозия и изменение химического состава электрода в процессе сварки;
- смещение электрода относительно стыка свариваемого изделия.

Перечисленные возмущения, вызывая отклонения от номинала основных параметров режима (тока и напряжения дуги, скорости сварки) и изменяя условия ввода теплоты в зоне стыка, приводят к снижению качества сварного соединения.

Сложность решения задачи построения расчетных моделей технологического процесса сварки обусловлена необходимостью учета физических процессов, происходящих в сварочном контуре (электрических, электромагнитных, тепловых, механических, гидродинамических и т.д.). Попытки применения для описания технологического процесса сварки известных теоретических положений математической физики, теоретической гидромеханики, электротехники, теории поля и теплопередачи приводят к получению нелинейных дифференциальных уравнений в частных производных с переменными коэффициентами. Решение таких уравнений затруднительно даже с использованием современных вычислительных средств. Поэтому в инженерной практике для получения математических моделей процесса широко используются методы идентификации, основанные на анализе

реализаций входных и выходных параметров технологического процесса.

В настоящей работе в качестве формальных моделей объекта управления применяются нейросетевые структуры с регрессионным входом (2). Расчетным параметром для оценки качества сварного соединения является ширина шва на обратной стороне пластины (b). Данный параметр является достаточно информативным, т.к. позволяет выявить возможность появления большого числа опасных для сварного соединения дефектов: непровар, прожог, отклонение от заданной геометрической формы поперечного сечения шва и т.д. В то же время во многих случаях измерить этот параметр как в процессе сварки, так и после нее не представляется возможным, например, из-за конструктивных особенностей сварного соединения (трубы, обечайки, цистерны и т.п.).

Для определения связи между выбранным критерием качества b и измеряемыми параметрами процесса (током сварки I , скоростью сварки V , температурой в околошовной зоне T , световым излучением дуги L) применяется нейросетевая структура следующего вида:

Регрессор:

$$\varphi(t, \theta) = [I(t-1) \dots I(t-n) \quad L(t-1) \dots L(t-n) \quad T(t-1) \dots T(t-n) \quad V(t-1) \dots V(t-n)]^T, \quad (14)$$

где n - глубина регрессии.

Прогнозирующая модель:

$$\hat{b}(t|\theta) = \hat{b}(t-1, \theta) = g(\varphi(t), \theta), \quad (15)$$

где $g(\varphi(t), \theta)$ - нелинейное преобразование, реализуемое двухслойной нейронной сетью в соответствии с выражением (2).

Для обучения нейросетевой модели использовалась база данных, содержащая результаты 12-ти экспериментов (каждый эксперимент содержит набор параметров I, L, T, V, b , эквивалентных 20 см сварного шва). Сварные швы получали в пластинах толщиной 2 мм из нержавеющей стали X18H10T. Сварка проводилась с использованием управляемого источника питания Кетрри и экспериментального сварочного стенда, с наложением на основные технологические параметры искусственных возмущений (отклонение силы тока до 20 %, скорости сварки до 15 %, расхода защитного газа до 15 % от заданных в технологии значений). Измерения ширины обратного валика полученного сварного соединения

производились с помощью экспериментального лазерного профилометра.

Обучение НС реализовывалось за 80 – 200 итераций (в зависимости от инициализации весовых коэффициентов) при использовании алгоритма Левенберга – Маркардта.

Результаты проверки обученной нейросетевой модели на тестовом множестве и исследование корреляционных функций невязок (на «близну» и независимость от предыдущих данных) подтвердили адекватность разработанной модели технологическому процессу аргонодуговой сварки пластин встык с полным проплавлением.

Основные результаты получены с использованием программного комплекса NNPredictor, разработанного в рамках диссертационной работы. NNPredictor - программный продукт для решения задач обработки результатов эксперимента, идентификации, моделирования и прогнозирования поведения динамических систем и технологических процессов, реализованный в интегрированной среде для выполнения инженерных и научных расчетов MATLAB версии 5.2. Выбор системы MATLAB в качестве базовой среды программирования обусловлен широкими возможностями по выполнению операций с векторами, матрицами и массивами данных, наличием встроенных процедур решения дифференциальных и разностных нелинейных уравнений, задач оптимизации, построения различных типов графиков, трехмерных поверхностей и линий уровня. Наличие средств сопряжения с реальными техническими устройствами и возможность моделирования в реальном масштабе времени позволяют создавать эффективные цифровые системы диагностики и автоматического регулирования.

NNPredictor реализует следующий набор функций:

Группа функций подготовки и анализа экспериментальных данных:

- чтение экспериментальных данных из файлов произвольного формата;
- интерактивный просмотр, анализ, масштабирование данных;
- создание базы данных экспериментов;
- расширенный поиск экспериментов по базе данных и их визуализация;
- подбор данных для реализации процедуры идентификации (обучения НС).

Группа функций выбора модельной структуры, обучения, подтверждения НС модели и прогнозирования:

- выбор структуры нейросетевой модели;
- различные варианты параметризации модели (алгоритмы обучения НС);
- анализ и тестирование НС модели;
- прогнозирование на основе НС модели.

Общее управление всеми процессами и функционированием системы в целом осуществляется с помощью программной оболочки, включающей в себя основное окно программы с набором функциональных кнопок и окно представления графических результатов.

Идентификация является многоэтапной процедурой, причем практически каждый этап требует непосредственного участия инженера-разработчика. Использование специализированных многофункциональных программных средств с «дружественным» интерфейсом пользователя, включающих в себя как нейросетевые алгоритмы, так и функции предварительной обработки и анализа экспериментальных данных, может значительно облегчить процесс создания оптимальных НС моделей. Пакет программ NNPredictor в полной мере отвечает вышеуказанным требованиям и может быть эффективно использован для решения задачи идентификации нелинейных динамических систем.

ЗАКЛЮЧЕНИЕ

В результате проведенной научно-исследовательской работы получены следующие основные результаты:

1). Исследованы особенности функционирования нейронных сетей и обоснована возможность их использования в качестве формальных моделей динамических объектов.

2). Разработан комплексный формализованный подход к решению задачи идентификации динамических систем, основанный на применении нейросетевых модельных структур.

3). Предложены базовые нейросетевые модельные структуры с линейным регрессионным входом, использующие характерные свойства нейронных сетей (способность к обучению на множестве

экспериментальных данных, обобщение и абстрагирование) для моделирования нелинейных динамических систем.

4). Разработаны алгоритмы оптимизации параметров нейросетевых моделей, основанные на применении методов безусловной минимизации функций многих переменных.

5). Исследованы и алгоритмизированы методы принятия решения об адекватности модели: многошаговое прогнозирование, оценка ошибки обобщения, корреляционные оценки ошибки прогнозирования.

6). Предложен подход к оптимизации структуры нейросетевых моделей с целью улучшения их рабочих характеристик, основанный на контрастировании весовых коэффициентов НС.

7). Разработан многофункциональный программный продукт, ориентированный на автоматизированное решение задачи идентификации динамических систем.

8). На основе разработанного подхода к решению задачи идентификации получены эффективные прогнозирующие нейросетевые модели технологического процесса аргоно-дуговой сварки неплавящимся электродом.

Полученные в результате экспериментальных исследований нейросетевые модели технологического процесса дуговой сварки могут быть использованы как в системе мониторинга геометрических параметров сварного шва, так и в контурах систем автоматического управления.

В дальнейшем предполагается применить полученные научные результаты для создания средств аппаратной поддержки нейровычислений (нейропроцессоров) и разработки нейроконтроллеров.


По теме диссертации опубликованы следующие основные работы:

1. Гаврилов А.И. Управление процессами сварки на основе нейросетевых моделей // Проблемы теории и практики в инженерных исследованиях.: Тезисы докладов XXXIII научной конференции Российского университета дружбы народов. - Москва, 1997. - С.232-233.
2. Гаврилов А.И. Перспективы применения нейросетевых технологий в системах автоматического управления // Вестник МГТУ им. Н.Э. Баумана. Приборостроение. - 1998. - №1. - С. 119-126.

3. Гаврилов А.И., Внуков А.А. Горохова О.В. Разработка алгоритмов идентификации динамических систем с использованием нейросетевых технологий // Научно-техническая конференция студентов, аспирантов и молодых специалистов МГИЭМ: Тезисы докладов. – Москва, 1999. – С. 140.
4. Gavrilov A.I. Development of automatic control system using neural network technology // Интеллектуальные системы.: Тезисы докладов третьего международного симпозиума. - Псков, 1998. - С. 206-208.
5. Gavrilov A.I. Development of automatic control system for laser welding using neural network technology // CONTROL'98.: Proc. of UKACC International Conference. - Wales, Swansea (UK), 1998. – P. 416 – 428.

Принята к публикации в журнале «Вестник МГТУ им. Н.Э. Баумана» следующая статья:

Гаврилов А.И. Методика идентификации технологических процессов с использованием нейросетевых вычислительных структур // Вестник МГТУ им. Н.Э. Баумана. Приборостроение. - 2000. - №1.



Подписано в печать: 8.02.00 г. Бумага офсетная
Формат бумаги 60/90 _{1/16}. Усл. п. л. 1,0
Тираж 100 экз. Заказ № 43

Отпечатано в издательстве МПУ "Народный учитель" с готового оригинал-макета
107005. г. Москва, ул. Радио, д. 10-а, т. 265-41-63