

МИНИСТЕРСТВО ОБРАЗОВАНИЯ И НАУКИ РОССИЙСКОЙ ФЕДЕРАЦИИ
федеральное государственное бюджетное образовательное учреждение
высшего образования

«Тольяттинский государственный университет»

Институт машиностроения

(наименование института полностью)

Кафедра «Оборудование и технологии машиностроительного производства»

(наименование кафедры)

15.04.05 Конструкторско-технологическое обеспечение машиностроительных
производств

(код и наименование направления подготовки)

Технология автоматизированного машиностроения

(направленность (профиль))

МАГИСТЕРСКАЯ ДИССЕРТАЦИЯ

на тему: Нейросетевой подход для моделирования термосиловой обработки

Студент	<u>В.В. Гасс</u> (И.О. Фамилия)	_____ (личная подпись)
Научный руководитель	<u>Д.А. Расторгуев</u> (И.О. Фамилия)	_____ (личная подпись)
Консультанты	<u>В.Г. Виткалов</u> (И.О. Фамилия)	_____ (личная подпись)

Руководитель программы д.т.н., доцент Н.М. Бобровский _____
(ученая степень, звание, И.О. Фамилия) (личная подпись)

« _____ » _____ 20 _____ г.

Допустить к защите

Заведующий кафедрой к.т.н., доцент Н.Ю. Логинов. _____
(ученая степень, звание, И.О. Фамилия) (личная подпись)

« _____ » _____ 20 _____ г.

Тольятти 2018

СОДЕРЖАНИЕ

ВВЕДЕНИЕ.....	3
1. КЛАССИФИКАЦИЯ ТИПОВ СЕТЕЙ.....	9
2. ТЕРМОСИЛОВАЯ ОБРАБОТКА.....	19
3. ПРОЦЕСС ОБУЧЕНИЯ.....	22
4. НАУЧНЫЕ ИССЛЕДОВАНИЯ.....	43
ЗАКЛЮЧЕНИЕ.....	71
СПИСОК ИСПОЛЬЗУЕМЫХ ИСТОЧНИКОВ.....	72
ПРИЛОЖЕНИЯ.....	75

ВВЕДЕНИЕ

Искусственная нейронная сеть (ИНС) или «нейронная сеть» (НС) – это в первую очередь компьютерная или математическая модель, устроенная в плане функционирования и организации на основе биологических сетей. Впервые это определение возникло при анализе процессов, происходящих в мозге, и попытке воссоздать эти процессы искусственно. Первые нейронные сети были созданы У. Мак-Калокком и У. Питтсом [1].

Она представляет собой область связанных и работающих друг с другом множества элементарных процессов (нейронов), которые взаимодействуют только с получаемыми и отсылаемыми сигналами. Размер этой системы прямо пропорционален сложности задачи, которую она может решить. НС – это инструмент для создания и анализа сложных взаимосвязей между поступающей и исходящей информацией. Полезность ИНС состоит в том, что её модели могут быть применимы для написания функции, на основе наблюдений (имеющихся данных). Это наиболее полезно там, где высокая сложность имеющихся данных или поставленной задачи делает вывод необходимой функции в ручную слишком трудоемким занятием [2].

Одним из важнейших преимуществ НС является её обучение – определение неизвестных взаимосвязей входных и выходных данных для создания алгоритма действий при решении подобных задач.

Этапы работы с сетью:

- Сбор, подготовка и нормализация данных;
- Определение типа сети;
- Подборка внутренних характеристик путем многократных экспериментов;
- Подборка определенных параметров и алгоритмов обучения;
- Обучение;
- Проверка корректности обучения;
- Поднастройка параметров и завершение обучение.

Необходимо рассмотреть некоторые пункты более конкретно.

Сбор, подготовка и нормализация данных.

Данный этап можно рассматривать как самый сложный в процессе обучения. Данные должны отвечать определенным параметрам:

- Показательность — информация должна представлять действительное положение вещей;

- Однозначность — данные, которые противоречат друг другу значительно снизят точность обучения.

Данные приводят к виду необходимому для подачи на обучение. Обучение на «сырых» данных приводит к значительному снижению точности. Есть несколько способов поднять «восприятие» сети.

- Нормировка необходима для данных, у которых разная размерность. Данные с большей размерностью будут оказывать более значительное влияние на обучение и это приведет к перекосу в нем. При нормировке все данные приводят к единой размерности;

- Квантование применяется при использовании непрерывных сигналов, в процессе которого определяется необходимый отрезок данных;

- Фильтрация применяется на «зашумленных» или искаженных данных.

Определение типа сети.

Тип сети определяется на основе задач и данных под обучение. Под разные задачи и количество, и вид исходных данных существует свой, наиболее подходящий тип сети.

Подборка внутренних характеристик путем многократных экспериментов.

Когда общая структура определена, необходимо подобрать характеристики сети, такие как количество слоев, обходные соединения, количество нейронов и их передаточные функции.

Подборка определенных параметров и алгоритмов обучения.

Правильный алгоритм влияет не только на скорость процесса, но и на возможное возникновение критических ситуаций в обучении, таких как паралич системы. Чтобы точно определиться с алгоритмом, важно провести серию экспериментов.

Проверка корректности обучения

Проверять корректность необходимо, даже при успешном обучении, т.к. могут быть ошибки в понимании сетью объекта обучения. Тестирование проводится на тех данных, которые не принимали участия в обучении. Чем меньше заданный процент ошибки сети, тем больше данных нужно для тестирования.

Есть несколько различных схем обучения: с учителем, без учителя и обучение с подкреплением [3].

Обучение под контролем — это способ, в процессе которого от системы требуют обучаться на основе пар «побудитель – ответ». Между входами и заданными выходами существует корреляция, но она неизвестна. Определено только конечное множество данных — пар «побудитель – ответ», называемых обучающим множеством. На основе этой информации необходимо восстановить, то есть написать алгоритм, способный для любых данных показать максимально точный ответ [6].

Обучение без учителя или самообучение — это способ машинного обучения, при котором система самопроизвольно обучается выполнять задачу без корректировки со стороны координатора. Обычно это подходит только для задач, в которых уже известны описания большого числа объектов, и требуется выявить внутренние зависимости, взаимосвязи, закономерности, имеющиеся между объектами [7].

Обучение с подкреплением — это способ машинного обучения, в процессе которого испытуемая система проходит через обучение, взаимодействуя с определенной средой. Откликом среды выступают сигналы

подкрепления, поэтому оно является одним из видов обучения с учителем, а в роли учителя выступает среда или её модель [11].

ИНС применяются во многих сферах деятельности человека и для решения различных задач, таких как:

Классификация и опознание образов: объектом могут быть различные данные: звуки, изображения, текстовые символы и т. д. Входом являются примеры того, что сеть должна опознать, а в качестве выхода – классы, к которым их можно причислить. Важно задать точное определение признаков принадлежности. После обучения нужно проверить правильность на новых примерах [18, 20].

В выходном слое каждый нейрон отвечает за один из классов. Между выходом сети и определенным классом создается связь, которая при предоставлении образа подает сигнал, что данный образ принадлежит такому-то классу, а с других выходов поступает сигнал о том, что образ не принадлежит их классам. В случае, если сеть подает сигнал о принадлежности объекта сразу двум классам, то это значит, что сеть «не уверена» и не может дать однозначный ответ [9].

Принятие решений и управление: данные задачи схожи с классификацией. Входными данными являются характеристики ситуации, а выходными признаки решения, которые приняла ИС [16].

Кластеризация: сеть распределяет множество сигналов на классы, количество и характеристики которых неизвестны. После этого сеть научиться сама определять, к чему причислить тот или иной сигнал. Также она может определять новые типы сигналов, которые не присутствовали в обучающей программе. Для кластеризации обычно используют сети Кохонена [19].

Прогнозирование: возможность прогнозирования напрямую зависит от способности обобщать и находить скрытые зависимости между входом и выходом. После обучения сеть может предсказывать будущие значения определенных последовательностей на основе загруженных данных, только в

том случае, если данные действительно определяют будущие значения [29-31].

Аппроксимация: нейронная сеть может упрощать непрерывные функции. Неважно, какой вид нелинейной характеристики будет у нейрона. Тип функции будет влиять только на сложность сети, но это не повлияет на способность аппроксимировать [21].

Сжатие данных и ассоциативная память: возможность обобщать и находить скрытые зависимости между входом и выходом позволяет сжимать большие объемы информации, а также восстанавливать исходный образ или сигнал из поврежденных и нечетких данных [10].

Экономика и бизнес: прогнозирование различных временных рядов, оптимизация различных потоков, оценка рисков, выявление переоцененных и недооцененных компаний и т.д.

Связь: сжатие различной информации, оптимизация сетей и схем маршрутизации пакетов, кодирование и декодирование.

Авионика: распознавание различных сигналов, беспилотные летательные аппараты, обучаемые автопилоты.

Медицина: обработка различных медицинских изображений, мониторинг пациентов, анализ лечения, постановка диагноза и т.д.

Автоматизация производства: контроль качества, мониторинг и визуализация информации, оптимизация режимов производственного процесса, робототехника и т.д.

Безопасность и системы слежения: опознание лиц и автомобильных номеров, обнаружение подделок, определение человека по отпечаткам, голосу, подписи и т.д. [13].

Цель работы:

Исследование применения нейросетевых технологий для процесса ТСО.

Задачи работы:

1. Провести общий анализ принципов работы с сетью, её устройства, видов, типов и видов обучения.
2. Провести анализ процесса ТСО, причин и преимуществ его использования и проблемы распределения упругопластических деформаций.
3. Построить алгоритм для работы с сетью для задач по классификации и аппроксимации.
4. Провести обучение сети с различными параметрами для задачи аппроксимации нелинейной зависимости и подобрать наилучшую модель для её решения.
5. Провести обучение сети в программе ANFIS, на основе результатов которого можно составить алгоритм управления ТСО с помощью данной программы.
6. Провести обучение сети с различными параметрами для задачи классификации входных сигналов и подобрать наилучшую модель для её решения.

1. КЛАССИФИКАЦИЯ ТИПОВ СЕТЕЙ

В этой главе рассмотрим структуры и типы нейронных сетей [25-26].

«Искусственная нейронная сеть (ИНС) – это модель, состоящая из множества элементов, которые взаимосвязаны друг с другом (рис. 1.1)» [15].

«Преимущества сетей, благодаря которым их следует использовать в ТСО:

- 1) Пластичность – они обладают обширной областью применения.
- 2) Ассоциативная память.
- 3) Генерализация – простота в обучении.
- 4) Надежность – имеют механизм остановки процесса обучения во избежание переобучения и снижения точности» [15].

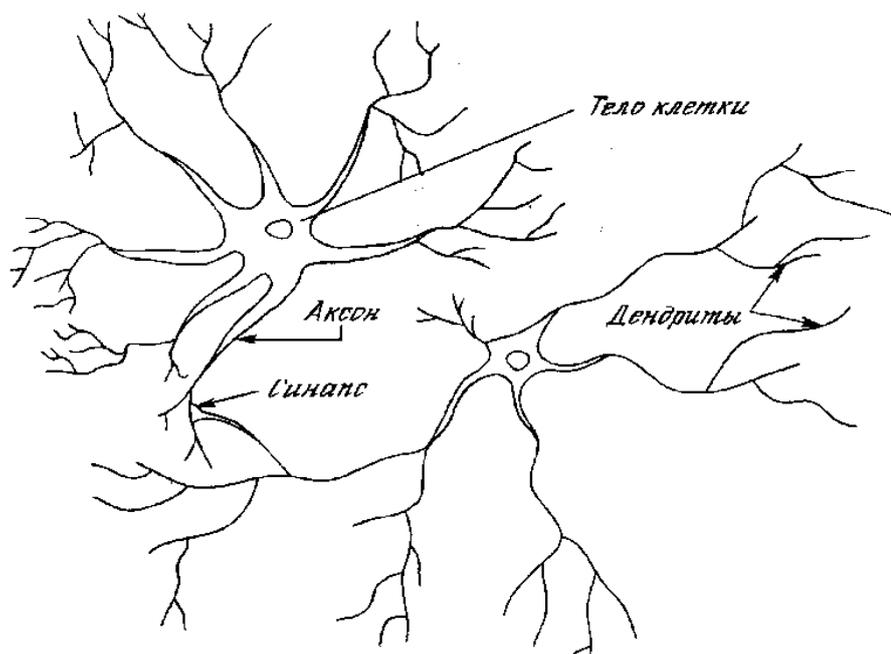


Рис. 1.1 Органическая сеть

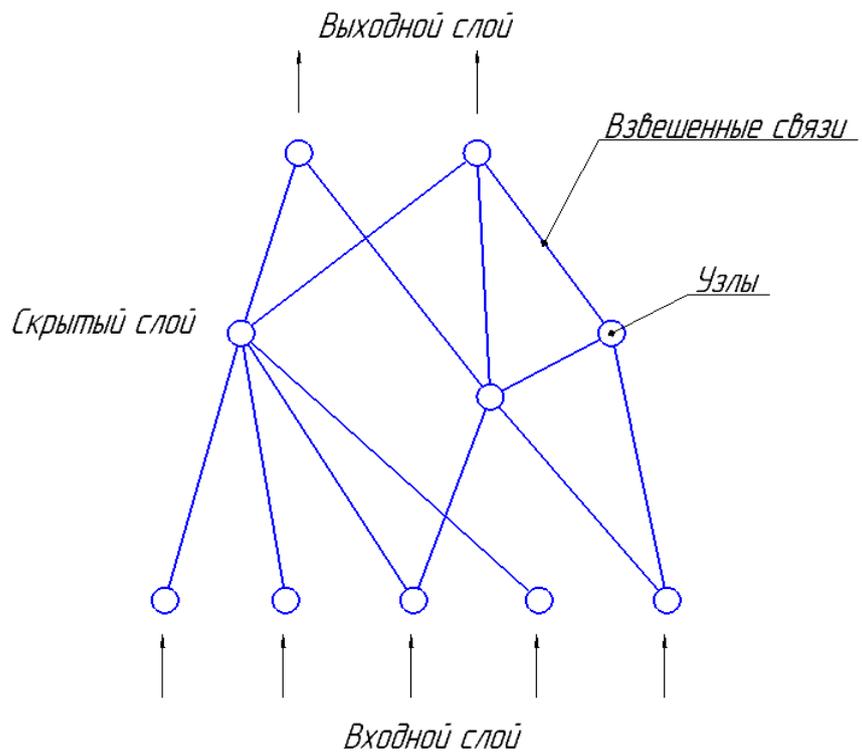


Рис. 1.2 Модель ИНС

По принципу активации сети разделяются на:

1) Линейные $\Phi(a_i) = ka_i$

2) Ступенчатые $\Phi(a_i) = \begin{cases} 1: & \sum_{j=1}^N w_{ij}x_j > U_i \\ 0: & \text{Otherwise (остальное)} \end{cases}$

3) Сигмоидальные $\Phi(a_i) = \frac{1}{1+e^{-ka_i}}$

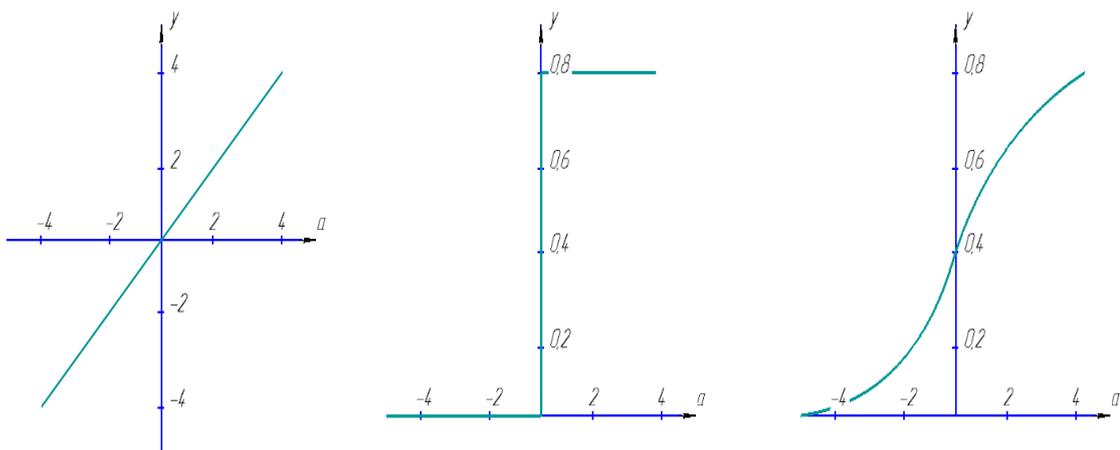


Рис 1.3 Функции активирования

«Взглянем на строение НС. Нейроны – главные простейшие ячейки, из которых составлена ИНС (рис. 1.4). Количество слоев (рис. 1.5) подразделяют ИНС на однослойную (рис. 1.6) или многослойную (рис. 1.7)» [15].

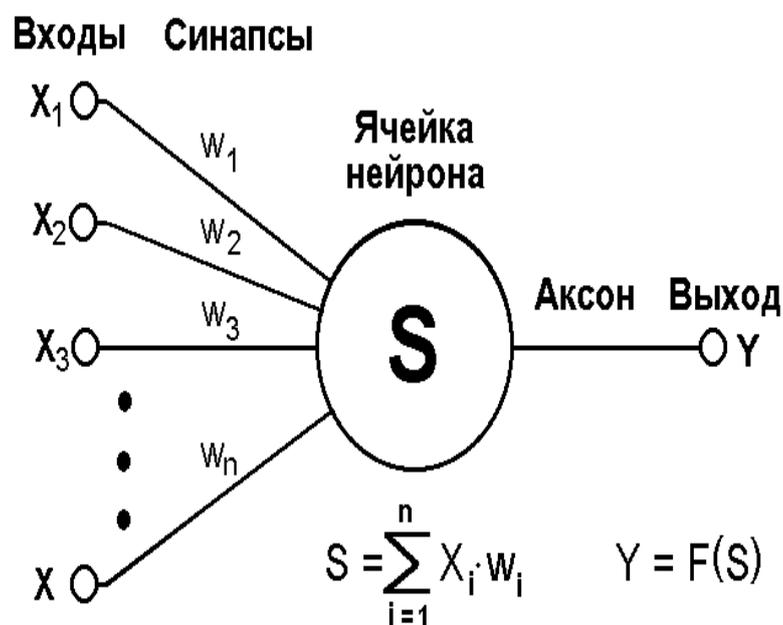


Рис. 1.4 Строение нейрона

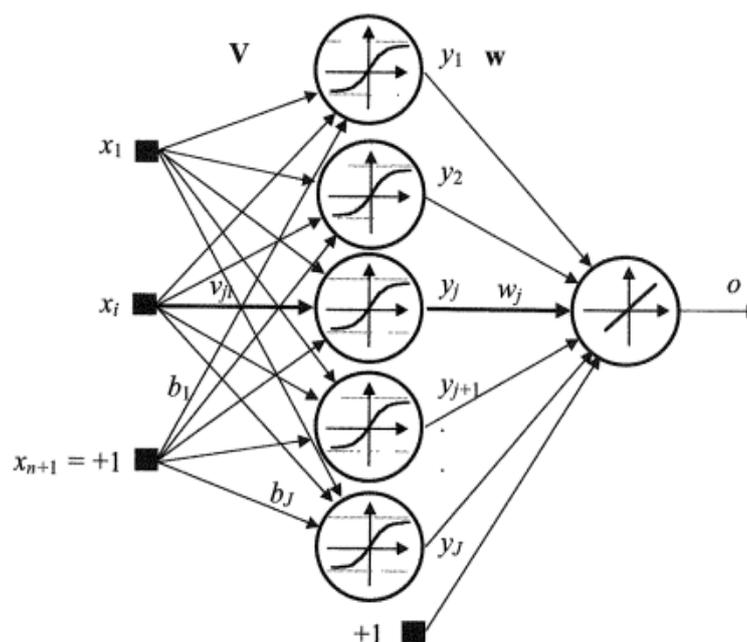


Рис. 1.5 Слои НС

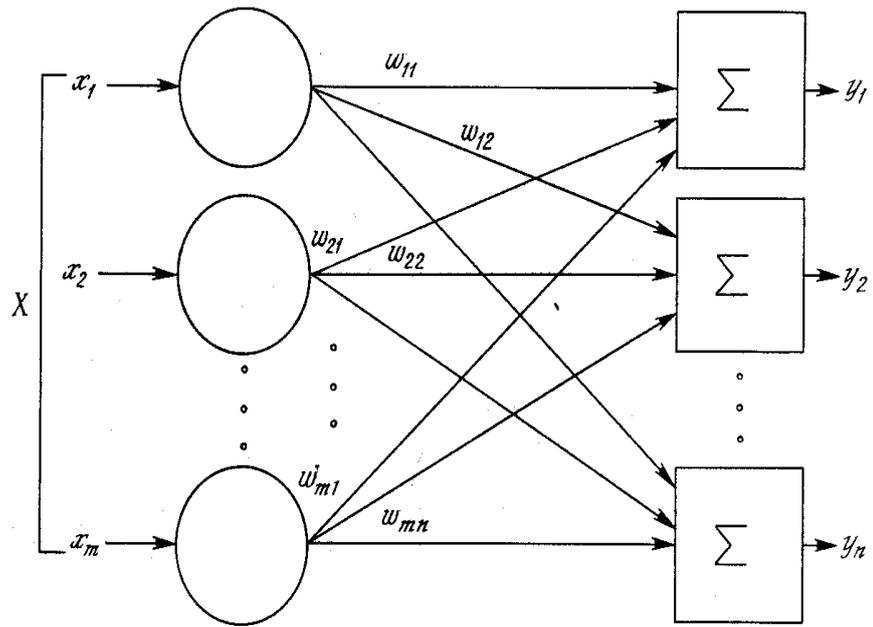


Рис. 1.6 Структура однослойных сетей

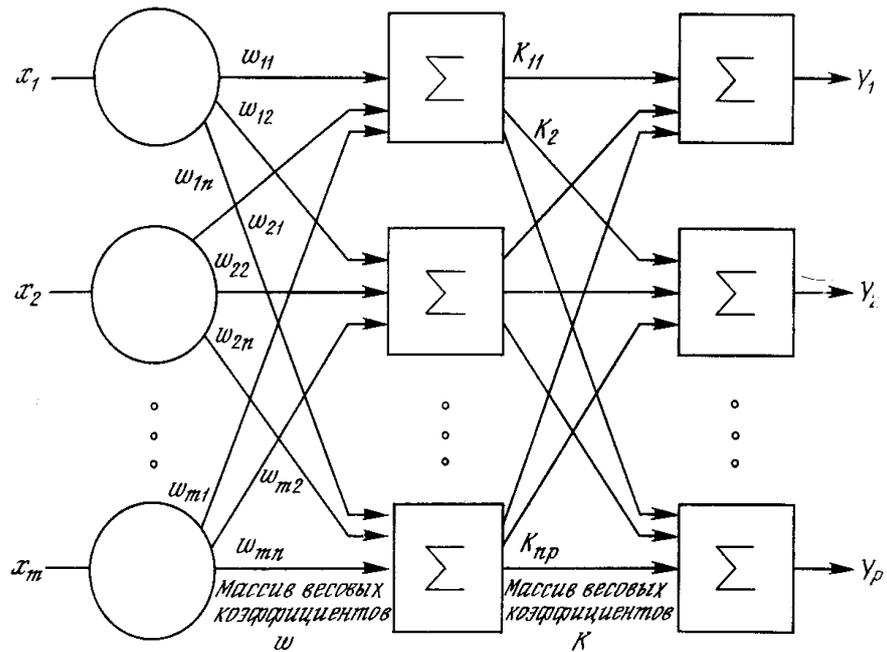


Рис. 1.7 Структура многослойных сетей

«Определение структуры сети является одним из основных этапов работы с нейронными сетями.

Для того чтобы ИНС вела себя корректно и без сбоев, её нужно настроить и регулировать её параметры. Это является основными принципами работы с сетью. Регулируя нужные параметры, мы обучаем сеть на выполнение необходимого спектра задач. Одним из важных преимуществ

ИНС будет то, что она сама подстраивает свои параметры для достижения лучшего результата.

Архитектуру сети подбирают в соответствии с поставленными задачами. Определяется количество слоев и нейронов в каждом из слоев, функция активации каждого слоя и способ взаимодействия слоев друг с другом.

Классификация базовых нейронных сетей.

Персептроны – это одни из первых нейронных сетей и наиболее простые однослойные сети. Они применяются для решения задач по классификации. Они характерны своим «быстродействию» [15].

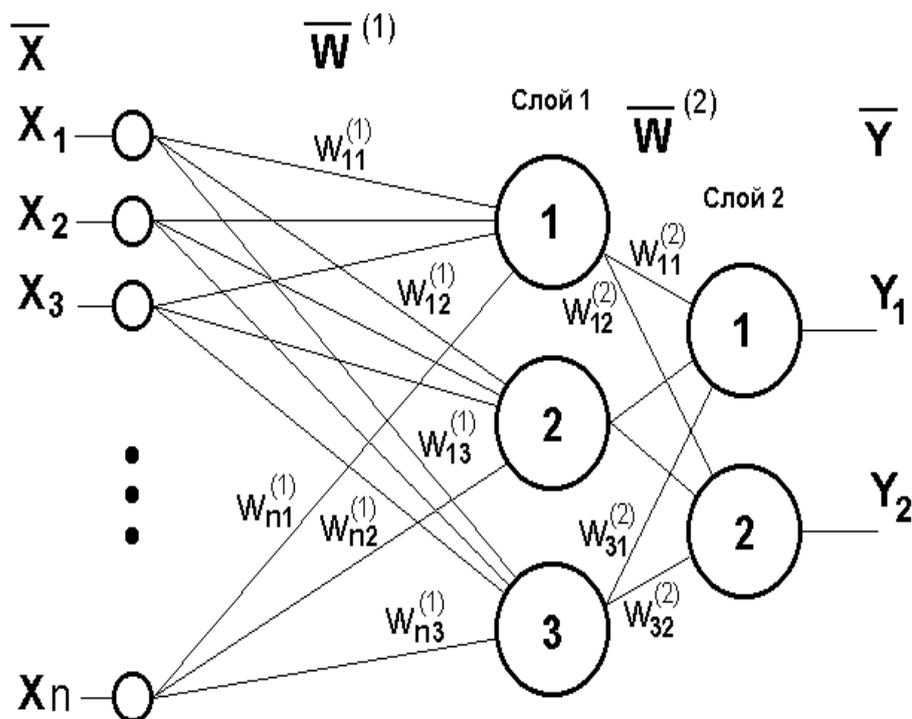


Рис. 1.8 Строение персептронов

«Линейные ИНС – имеют сходство с персептронами. Имеют только одно отличие – линейные функции активации» [15].

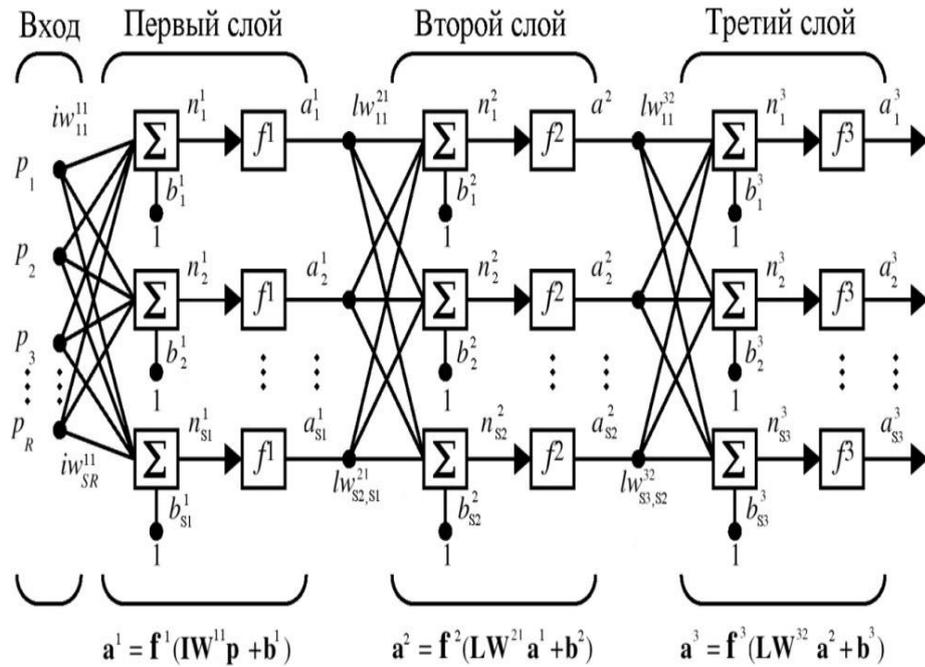


Рис. 1.9 Строение многослойных сетей

«Радиальные базисные сети. В них присутствует гораздо большее количество нейронов, чем в других сетях, которые имеют прямую передачу сигнала. Эта сеть обучается по принципу обратного распространения ошибки. Главным достоинством этих сетей является минимальное время обучения» [15].

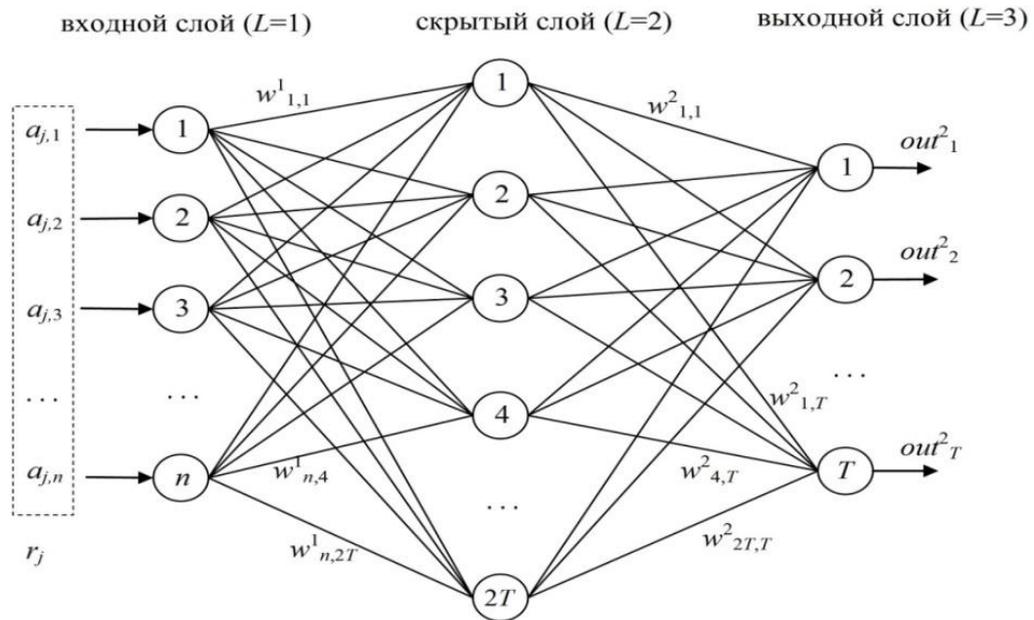


Рис. 1.10 Строение базисных радиальных сетей

«Также существуют два подтипа этой сети – сеть GRNN (Generalized Regression Neural Networks) и сеть PNN. Сеть GRNN используется для анализа временных рядов, решения обобщенных регрессий и задач по упрощению зависимостей. Отличие только в том, что блок, находящийся во втором слое, применяется для вычисления нормированного скалярного произведения векторов входа и массивов строк» [15].

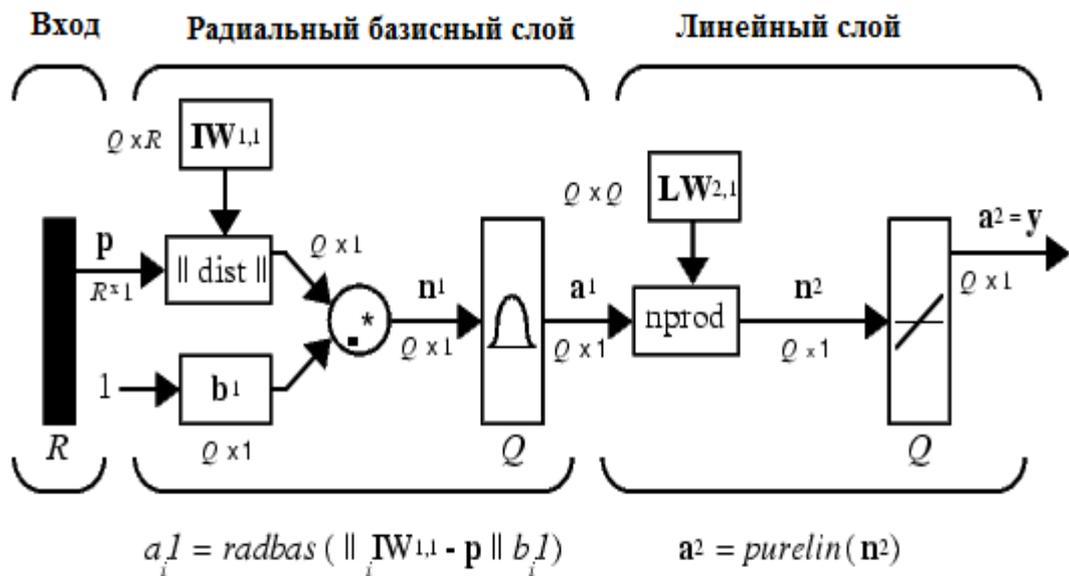


Рис. 1.11 Структура GRNN сетей

«Сеть PNN (Probabilistic Neural Networks) используется для решения вероятностных задач. Отличается тем, что второй слой является конкурирующим. Он определяет вероятность принадлежности входного вектора к заданному классу» [15].

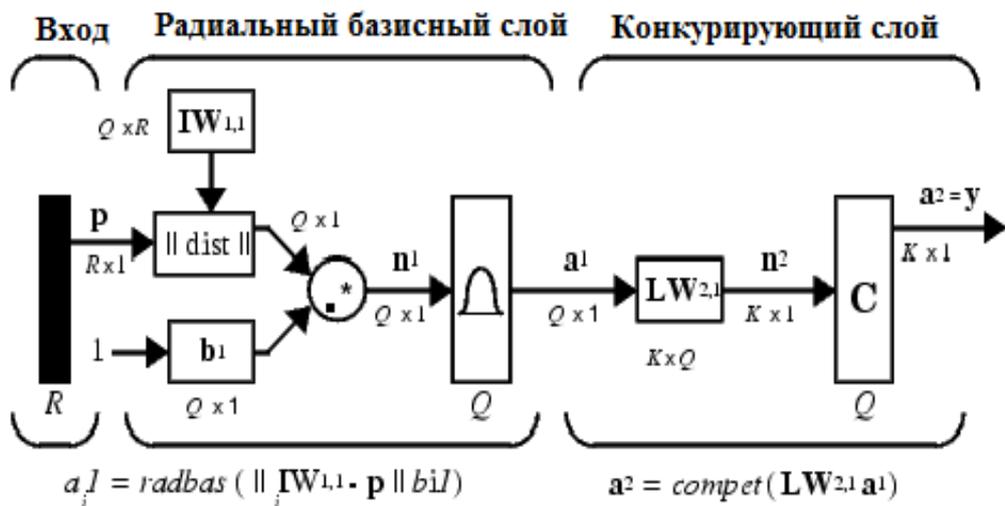


Рис. 1.12 Структура PNN сетей

«Слой Кохонена – это нейронная сеть, имеющая один слой, задача которого в том, чтобы сгруппировать входные векторы» [15].

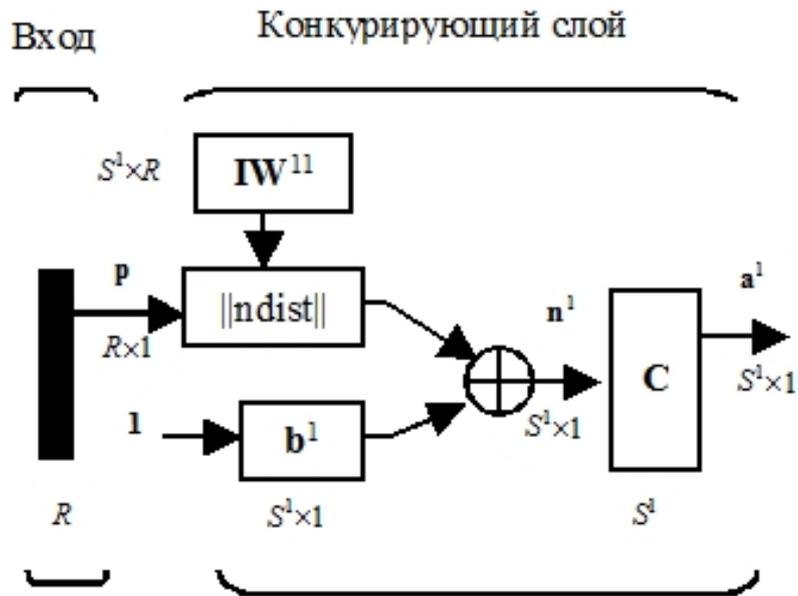


Рис. 1.13 Структура слоев Кохонена

«Карта Кохонена – отличается от слоя Кохонена только тем, что в ней нет смещения» [15].

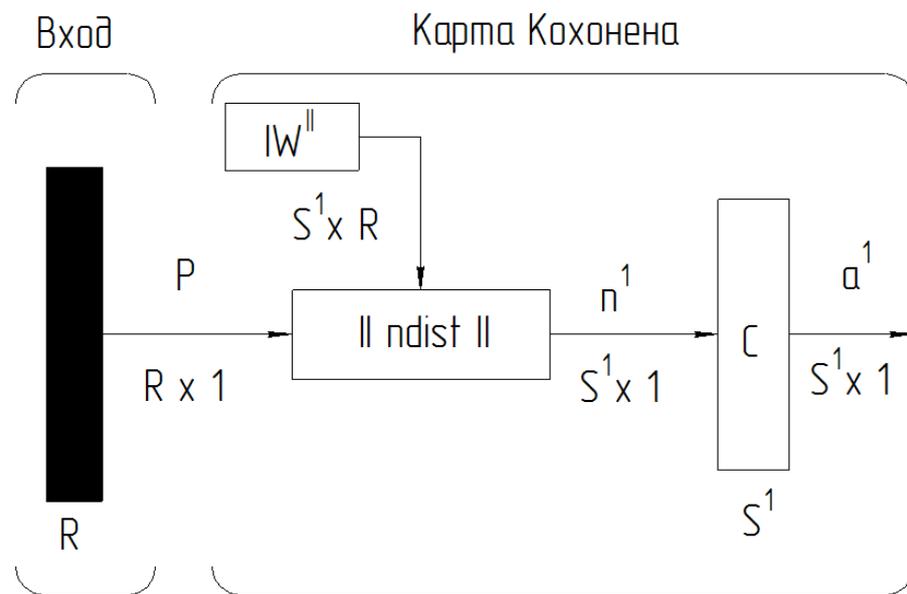


Рис. 1.14 Структура карт Кохонена

«LVQ (Learning Vector Quantization) – делает группировку и классификацию входных векторов. Группировкой векторов занимается конкурирующий слой, а линейный определяет принадлежность векторов к заданному классу» [15].

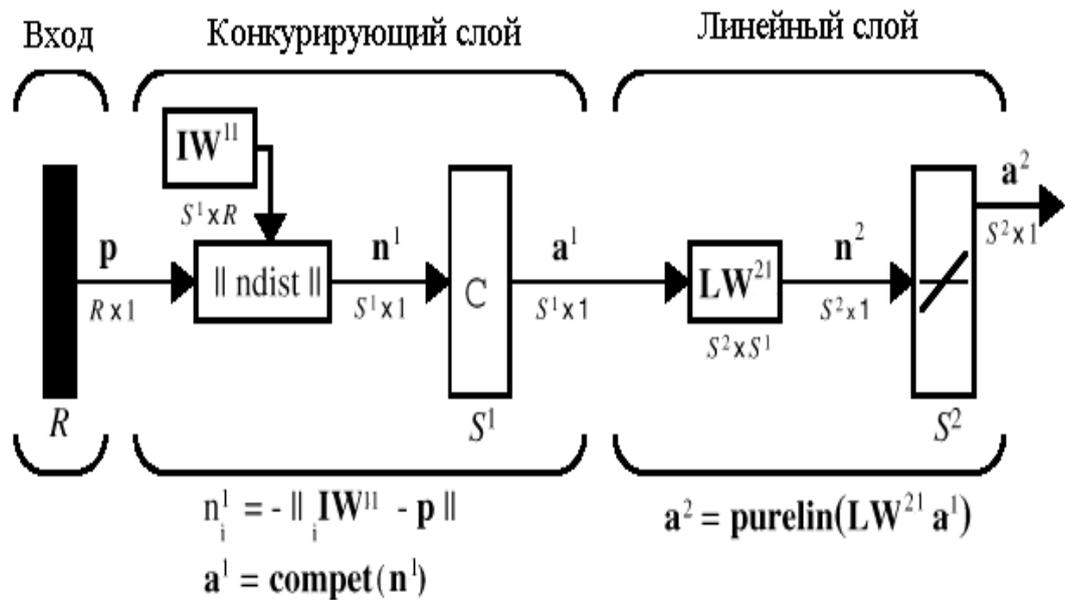


Рис. 1.15 Структура LVQ сетей

«Рекуррентные сети – имеют блоки динамической задержки и обратной связи, позволяющие работать с различными динамическими моделями. Они подразделяются на сеть Элмана и сеть Хопфилда.

Сеть Элмана позволяет на основе полученных, в предыдущих экспериментах, данных разрабатывать стратегию управления для управления перемещающимися объектами» [15].

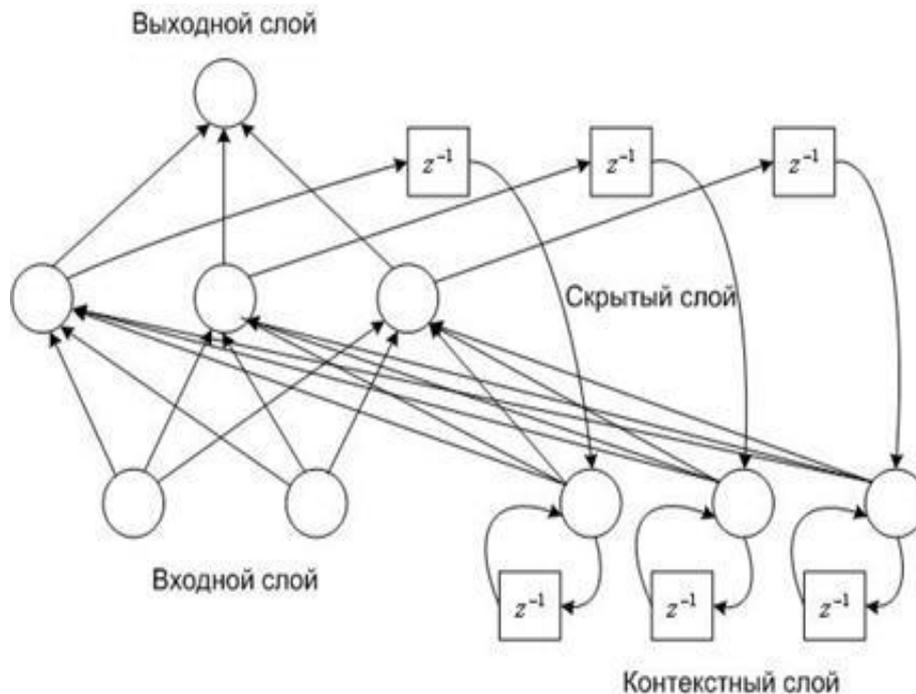


Рис. 1.16 Структура сетей Элмана

«Сеть Хопфилда – состоит из большого количества точек равновесия и создана по образу рекуррентной сети. При определении начальных условий, которыми могут быть один или несколько входных векторов, в одной из точек формируется состояние равновесия. Затем создается выход, который отправляется на вход. Эти действия повторяются, пока выходной вектор не сформирует состояние равновесия. Каждый выходной вектор должен приблизиться к точке равновесия, максимально близкой к входному сигналу» [15].

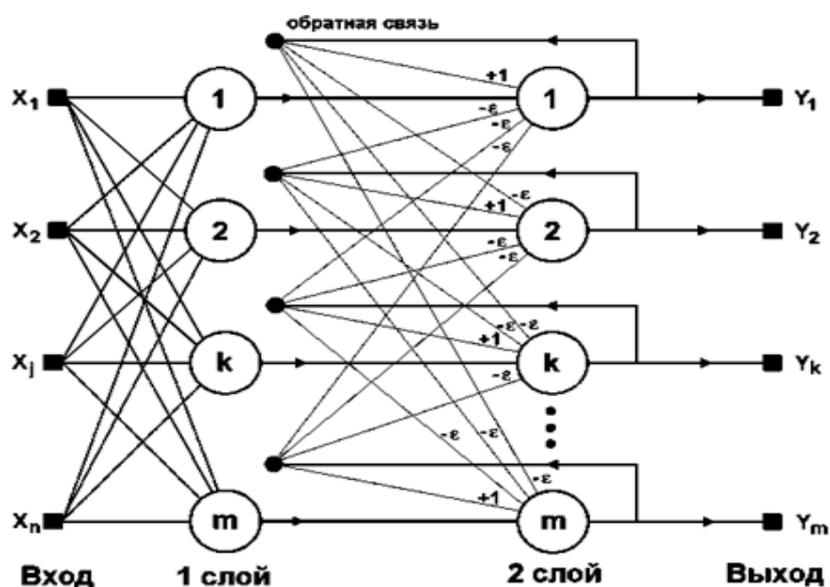


Рис. 1.17 Строение сетей Хопфилда

2. ТЕРМОСИЛОВАЯ ОБРАБОТКА

«Далее рассмотрим процесс термосиловой обработки МЖД в стапеле.

Использование стапеля в процессе ТСО необходимо для увеличения стабильности геометрии МЖД за счет создания равномерных остаточных осевых напряжений [4-5] и направления структуры материала по длине» [15].

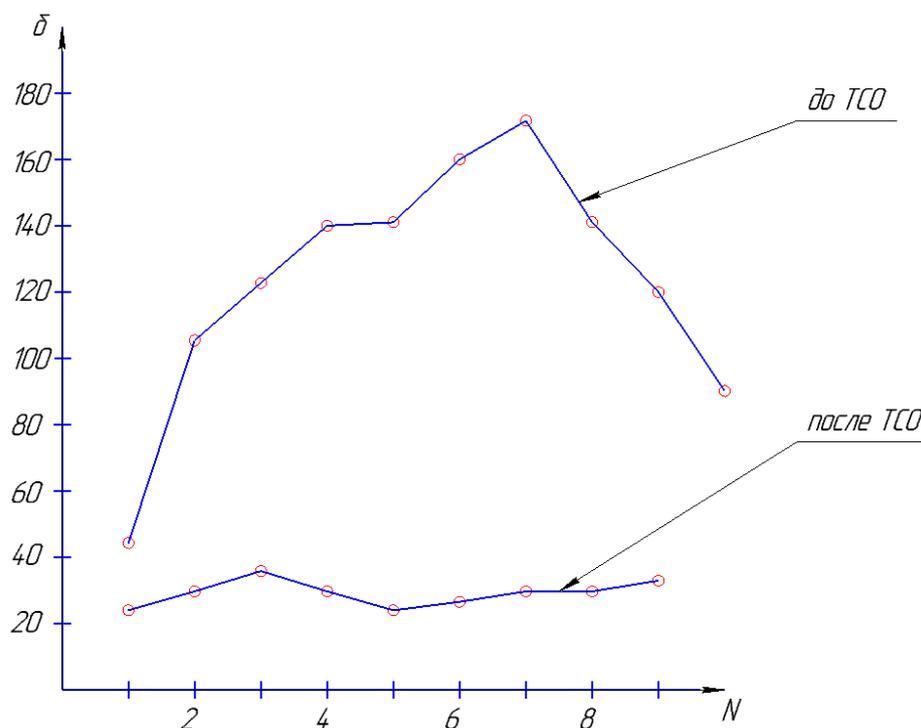


Рис. 2.1 Результаты процесса

«Этот процесс создает однородное распределение пластических деформаций по всему объему детали, выравнивание свойств материала и сильно снижает уровень всех остаточных напряжений, что приводит к существенному снижению коробления изделия [8].

Суть ТСО заключается в том, что на заготовку устанавливают распорные втулки и закрепляют в стапеле, который состоит из нескольких слоев. Отличие в величине температурных удлинений, которое создается путем выбора материалов с отличным друг от друга коэффициентом расширения, приводит к созданию необходимых усилий. Они заключаются в том, что стапель и втулки расширяются на разную величину и это приводит к различным усилиям на заготовке. Большая теплоемкость приводит к тому,

что они остывают медленнее, чем заготовка [8, 14]. Это позволяет поддерживать нужное усилие в течение всего процесса» [15].

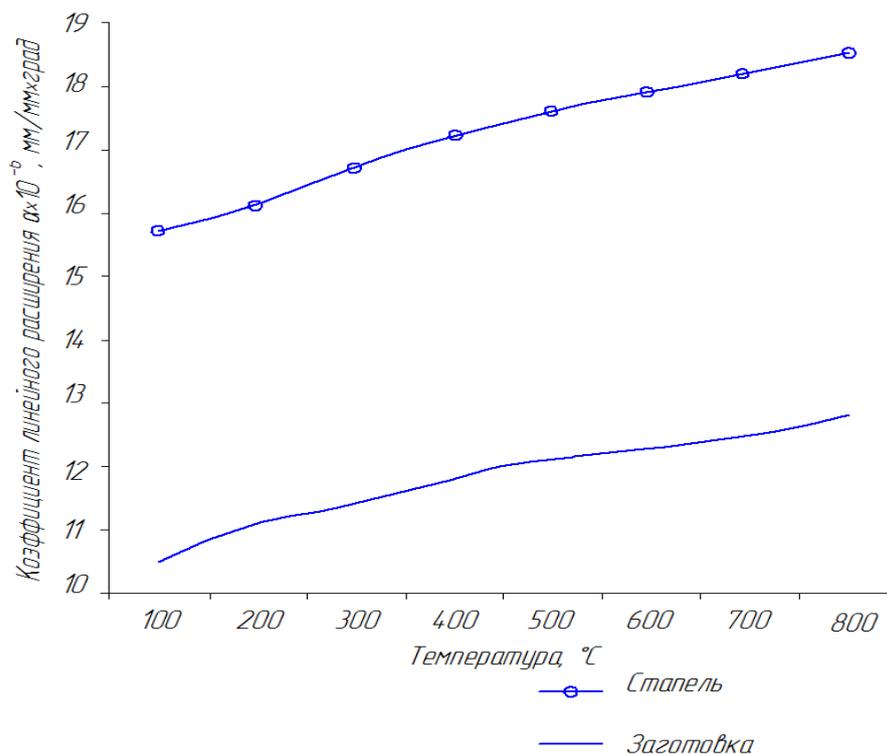


Рис. 2.2 Взаимосвязь увеличения длины от нагревания

«Зависимость деформация-напряжение, представленная на рисунке 2.3, обладает значительной степенью нелинейности и разделена на отдельные участки: полочка, которая является линейной и участка упрочнения [17]. Изменение температуры в процессе деформации довольно сильно усложняет процесс анализа и контроля» [15].

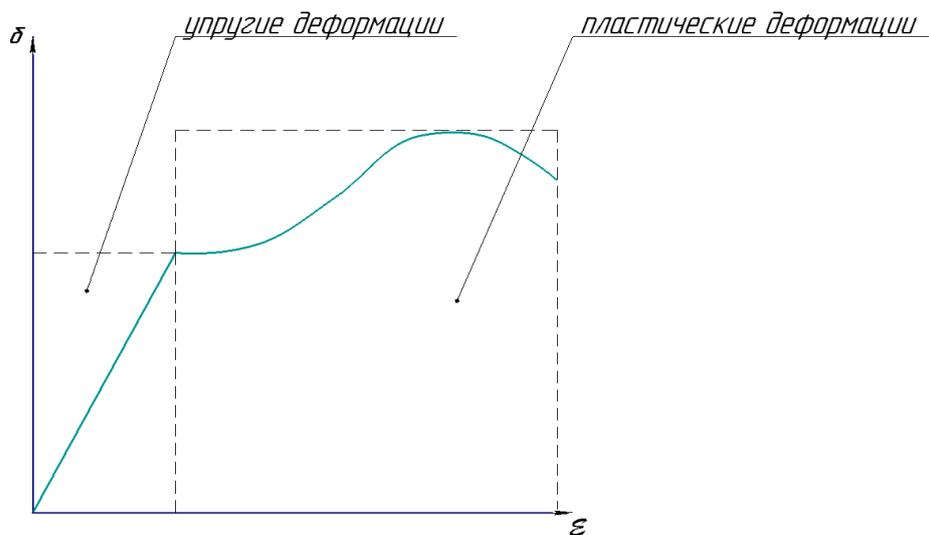


Рис. 2.3 Зависимость деформации и напряжения

«Для максимального уменьшения коробления МЖВ нужно чтобы фазовое превращение протекало равномерно, т.к. в процессе мартенситного превращения $\alpha \rightarrow \gamma$ снижается степень упрочнения и начинается деформация [17,24]. При температурах закалки область остаточных напряжений стремится к нулю, одинаково по сечениям и слой наклепа полностью снимается. При охлаждении трудно поддерживать такое состояние, т.к. условия совместимости упругопластических деформаций не выполняется в процессе остывания и разгрузки» [15].

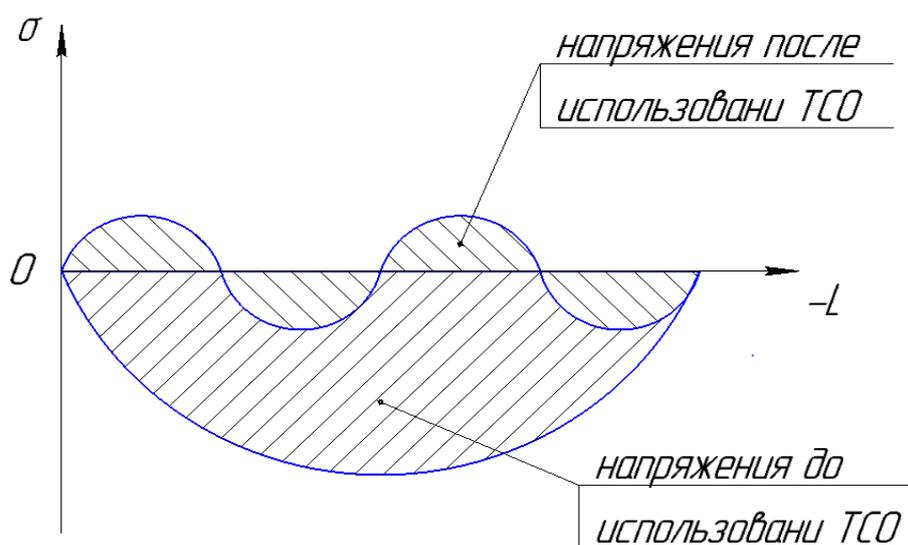


Рис. 2.4 Распределение напряжений в продольном направлении заготовки

3. ПРОЦЕСС ОБУЧЕНИЯ

Далее рассмотрим этапы обучения сети для решения задач по аппроксимированию нелинейных зависимостей и классификации входных сигналов, которые включают в себя анализ и нормирование данных, полученных после ТСО, выбор структуры НС, алгоритмов для обучения и внутренних параметров [22].

Для работы с сетью используем программу MATLAB R2014a. Графический интерфейс программы представлен на рисунке 3.1. В данном интерфейсе доступны все необходимые команды для проведения работ с ИНС.

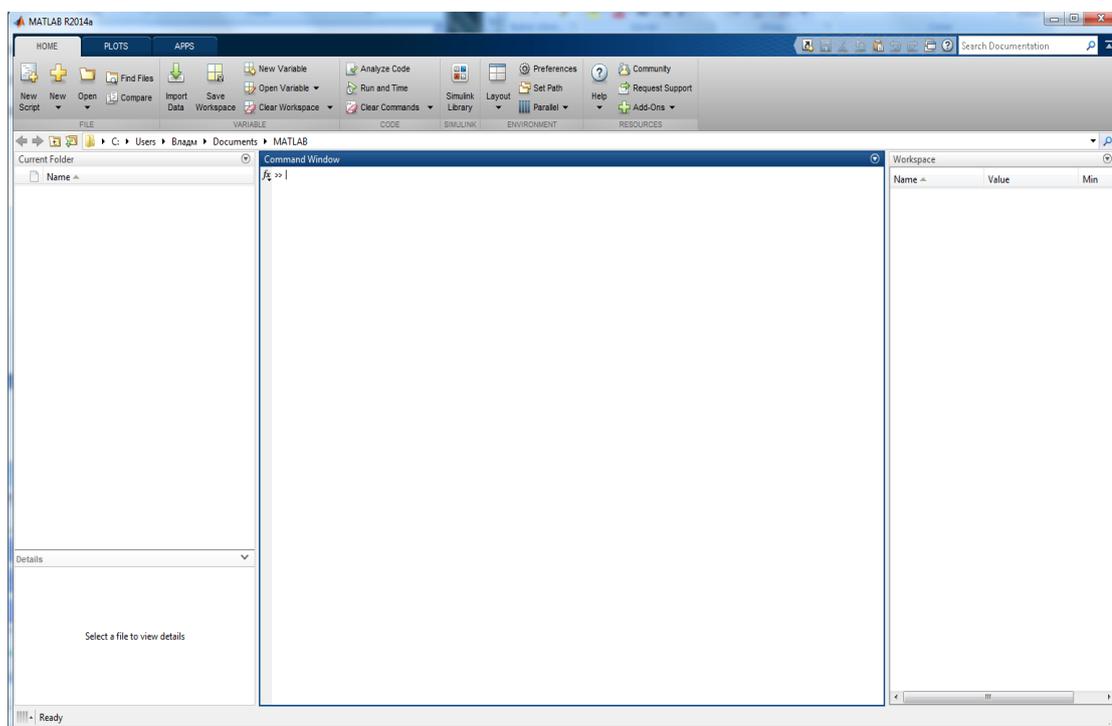


Рис. 3.1 Графический интерфейс MATLAB R2014a

Загрузим данные. Для определения степени равномерности распределения деформации по всей длине заготовки введем значение коэффициента локальности.

«Он определяется по формулам:

$$k_1 = \frac{\varepsilon_{maxi}}{\varepsilon_{cp}}; \quad (3.1)$$

или

$$k_2 = \frac{\varepsilon_{maxi}}{\varepsilon_{mini}}, \quad (3.2)$$

где ε_{maxi} - максимальная деформация на участке;

ε_{cp} - средняя деформация по всему валу;

ε_{mini} - минимальная деформация на участке» [15].

Пакет данных x это характеристики процесса ТСО, а U – коэффициент локальности (рис. 3.2 – 3.3).

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	500	300	500	500	500	300	300	300	500	400	400	400	300	300	400
2	4	4	4	6	8	4	6	8	8	8	6	4	6	8	6
3	5.6400	0.7200	4.3500	1.1600	1.4700	2.0500	2.1600	4.0800	1.8900	0.5870	1.1300	2.9000	1.9000	0.8700	3.9700

Рис. 3.2 Параметры ТСО

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	4.0650	10.6380	1.7540	6.5780	5.2080	3.7450	2.9410	1.8760	4.0480	8.6580	4.3100	2.6450	4.0320	8.8490	1.9230
2															
3															

Рис. 3.3 Коэффициент локальности

Далее мы будем строить сеть для задачи упрощения нелинейных зависимостей.

Введем «nnstart» в командную строку и начнем создание сети в появившемся стартовом окне (рис. 3.4).

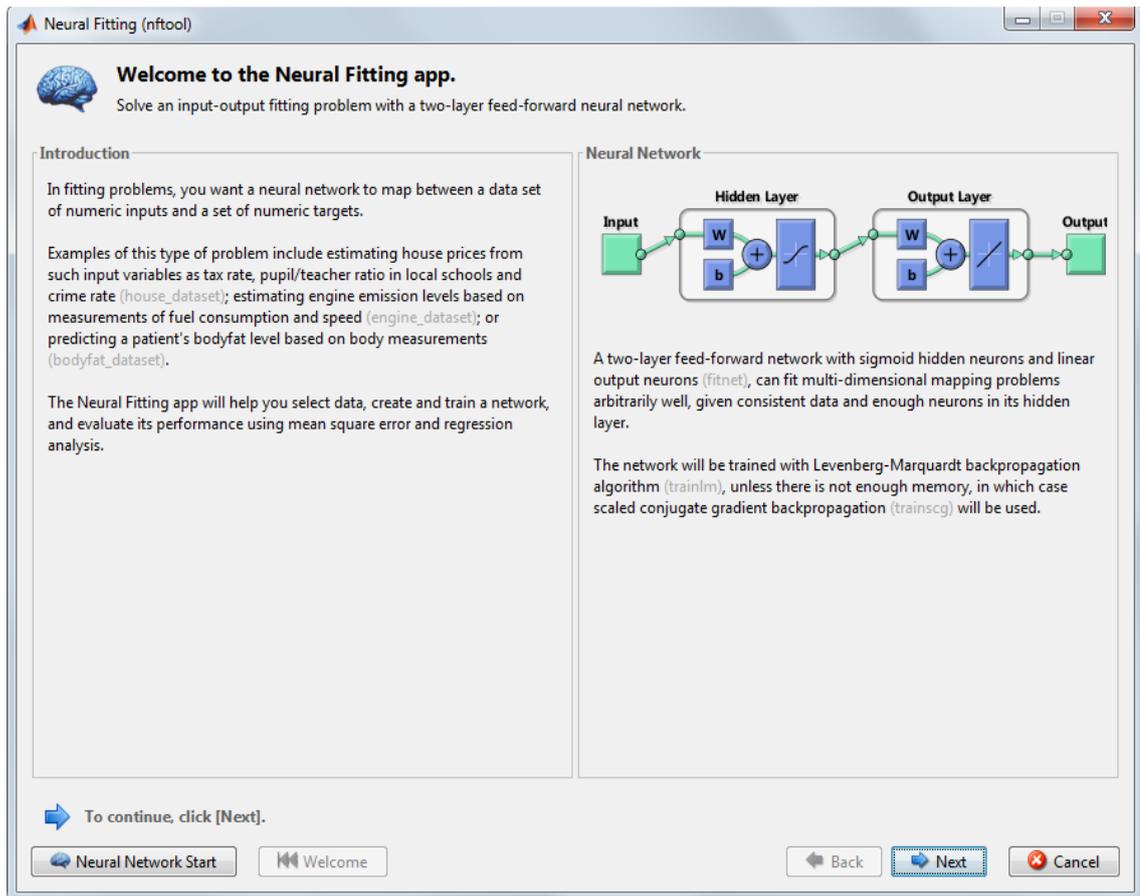


Рис. 3.4 Стартовое окно

Для решения подобных задач лучше всего подходят двухслойные сети с сигмоидальными и линейными функциями активаций (рис.3.5). С такой структурой сеть может максимально точно выполнять задачи многомерной аппроксимации. Для получения точных результатов необходимо выполнять операцию нормирования. В данном случае обучение проходит по алгоритму Левенберга – Марквардта (`trainlm`) [23].

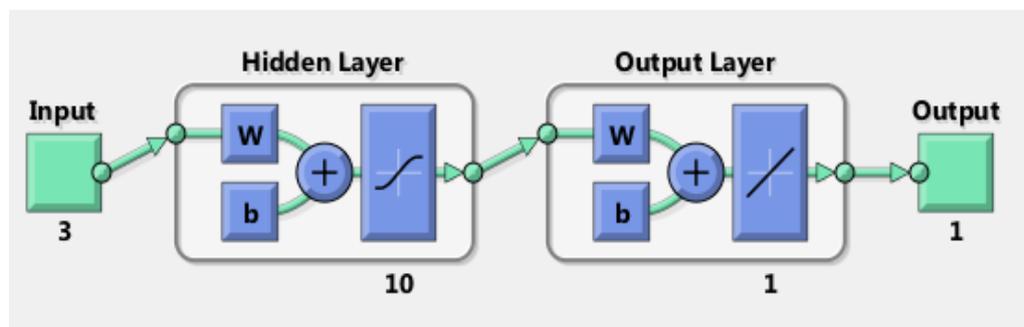


Рис. 3.5 Строение сети

«Помечаем данные x и U как Input data и Target data соответственно и отмечаем расположение образцов по столбцам» [15].

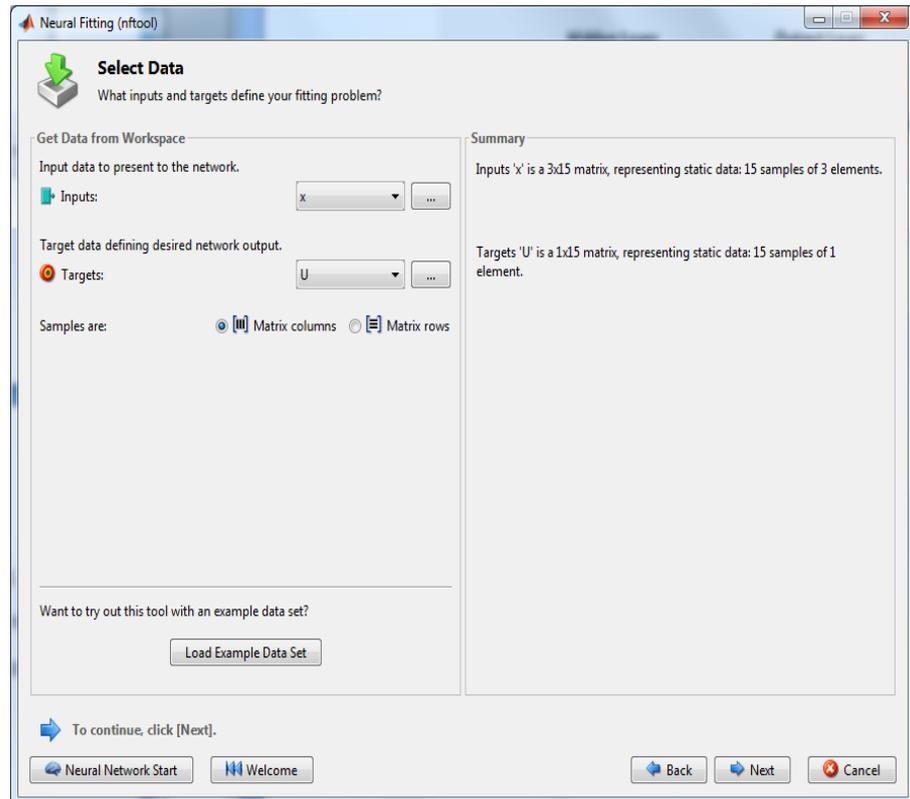


Рис. 3.6 Выбор данных

Определяем сколько будет нейронов. В данном случае, выберем 10 нейронов.

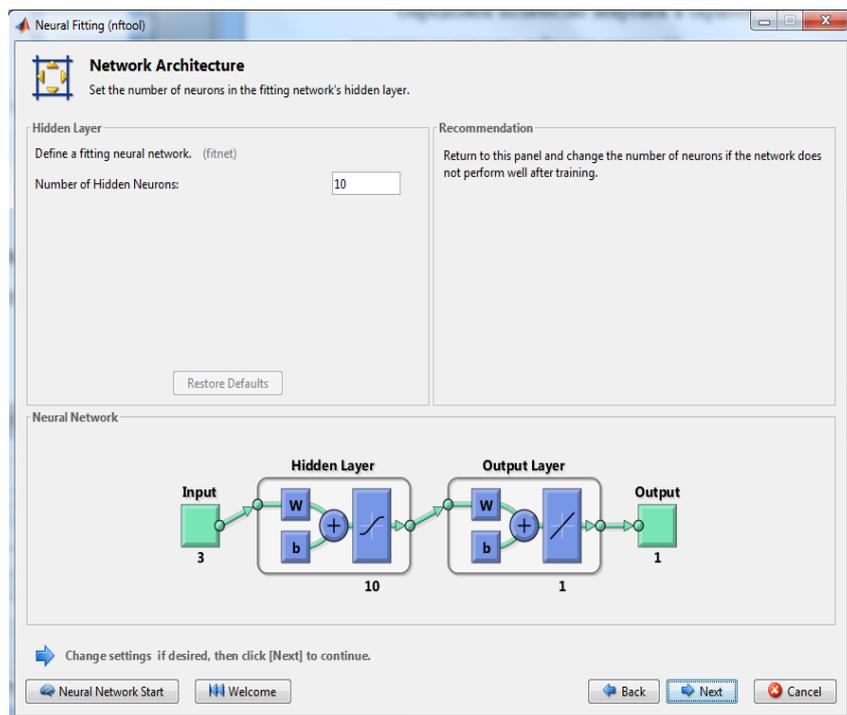


Рис. 3.7 Определение количества нейронов

Нужно выбрать алгоритм. Применим алгоритм Левенберга – Маркварта. Мы можем распределить данные между обучающими, проверяющими и тестирующими множествами. Проверяющие множества служат для проверки обобщения и остановки обучения, если ошибка прекращает уменьшаться. Тестирующие множества не применяются в обучение, но служат для проверки его качества.

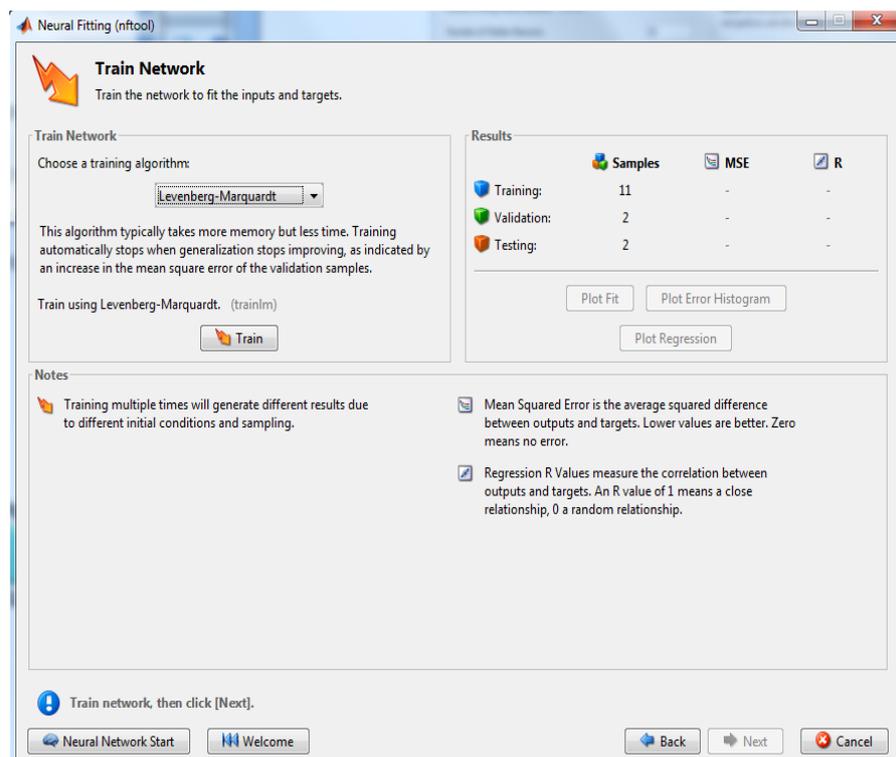


Рис. 3.8 Определение схемы обучения

Анализировать обучение можно с помощью интерфейса, представленного на рисунке 3.9.

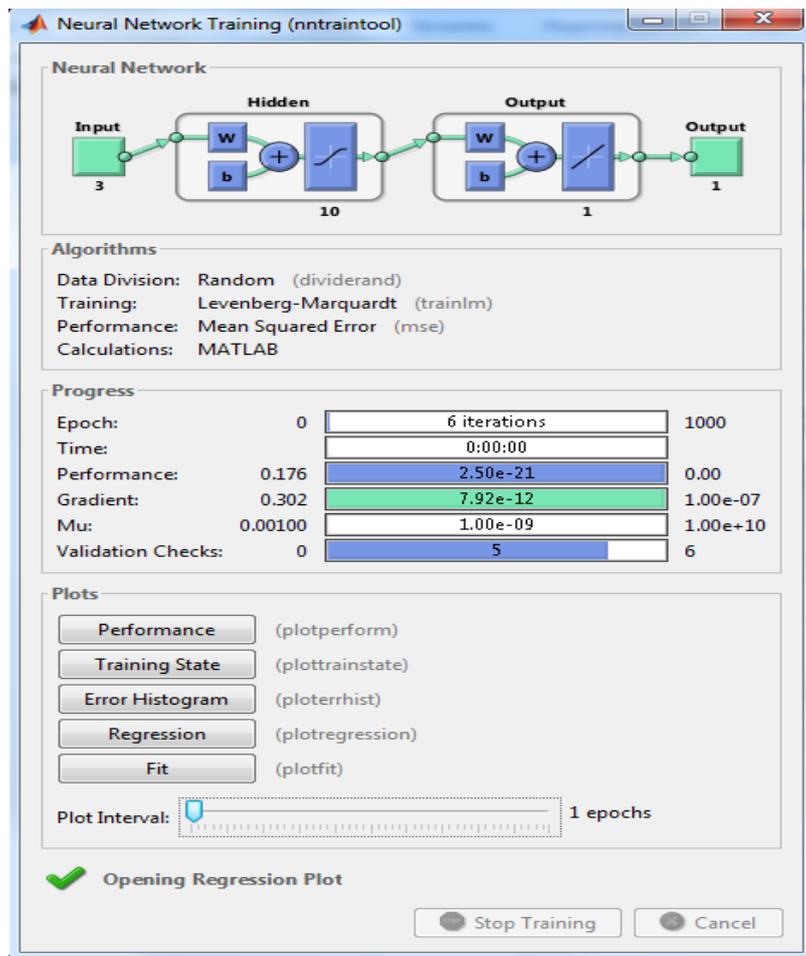


Рис. 3.9 Окно процесса обучения

Итоги обучения и размеры ошибок показаны на рисунках 3.10-3.13.

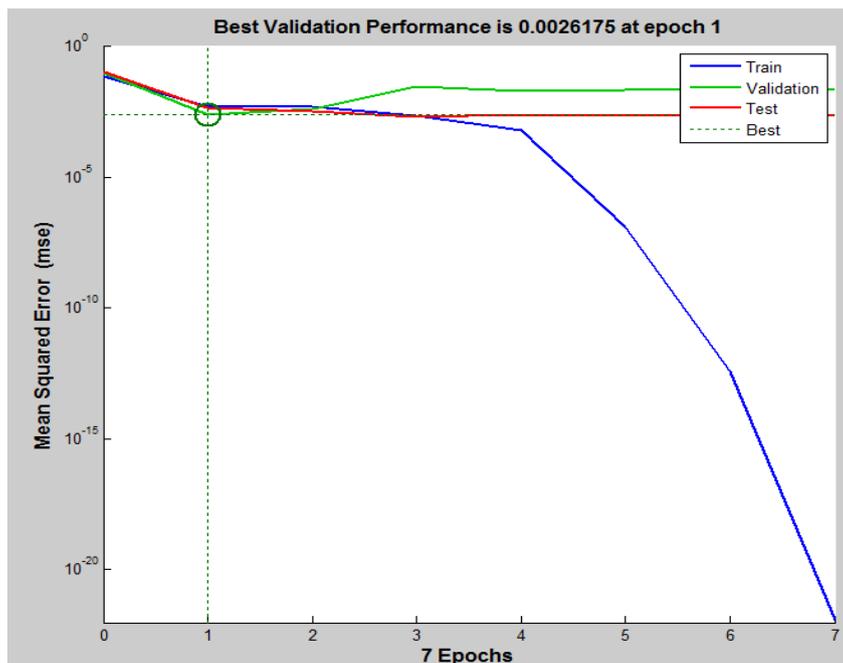


Рис. 3.10 График обучения

По графику обучения видно, что за 1 эпоху была достигнута минимально возможная ошибка. Чтобы избежать переобучения процесс был остановлен, когда ошибка перестала снижаться.

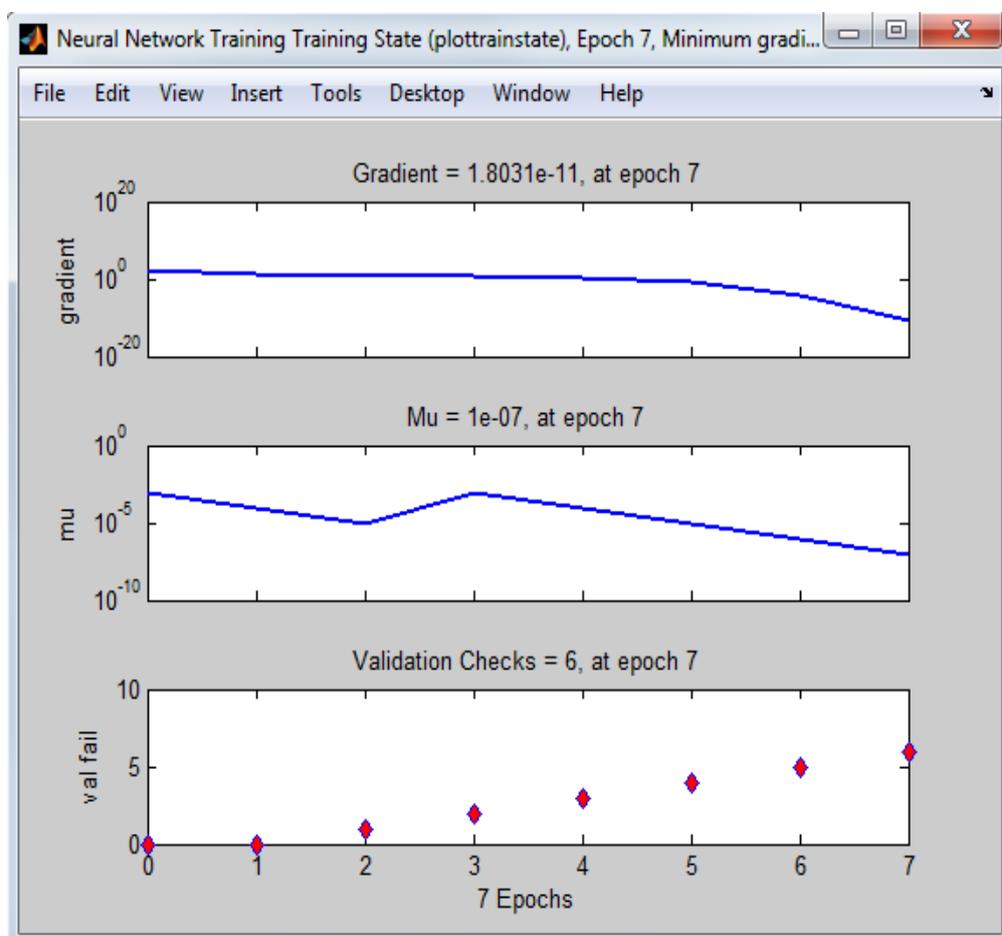


Рис. 3.11 График состояния обучения

График gradient показывает, как изменялся градиент ошибки по весам. График mu отображает изменения в параметрах алгоритма Левенберга – Марквардта. Данный параметр индивидуальный для каждого алгоритма. На val fail графике показывается, как изменялась ошибка на контрольных множествах [28].

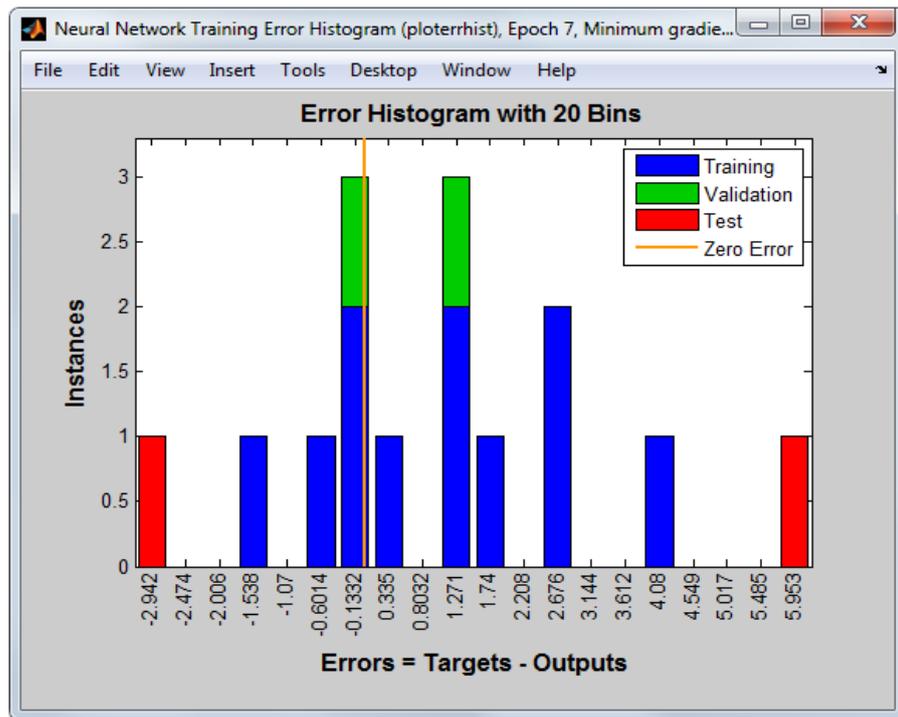


Рис. 3.12 Гистограмма ошибок

Этот график показывает, на каких примерах и какую погрешность дает сеть. Погрешность определяется как разница между заданными и выходными параметрами. График отражает погрешность для трех основных множеств обучения.

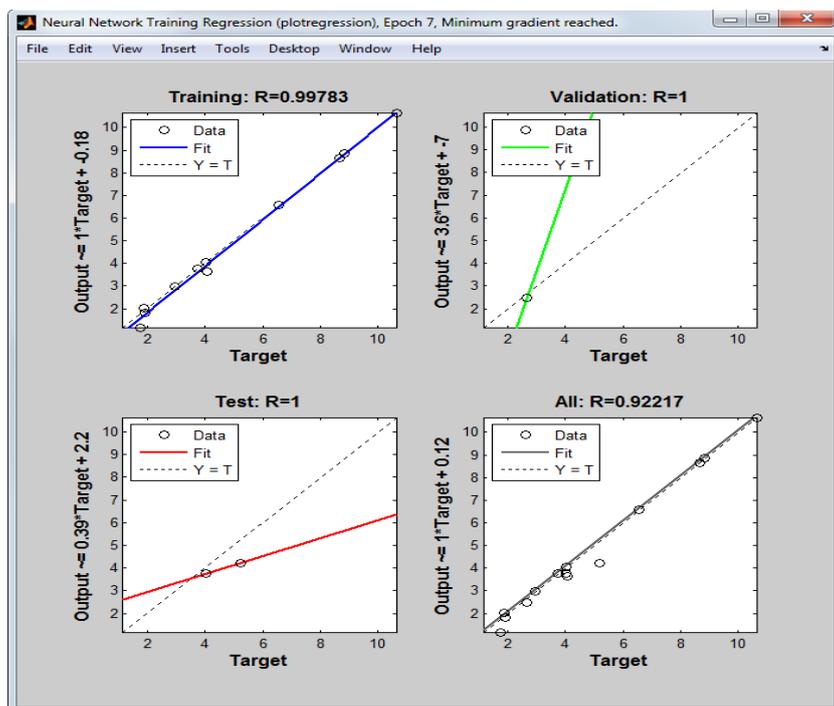


Рис. 3.13 Графики результатов обучения

Здесь можно наблюдать как строится регрессия линейного типа для результатов по четырем различным множествам. Для каждого из множеств отдельно высчитывается корреляционный коэффициент R [27].

Меняя количество нейронов и алгоритмы их обучения, можно найти оптимальные параметры обучения, что способствует улучшению конечных результатов.

После сравнения данных (рис. 3.14), можно сделать вывод, что обучение прошло успешно, т.к. ошибка находится в допустимых пределах, и данную обученную сеть можно использовать на практике для решения подобных задач по аппроксимации.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	1.3097	10.7357	1.6730	6.6131	5.0533	5.5417	3.8223	1.7170	4.1213	9.1073	4.6231	1.0052	4.8948	8.9067	1.7402
2															
3															

Рис. 3.14 Результаты обучения сети

Задача классификации имеет схожую схему обучения, но с некоторыми отличиями.

В задаче распознавания образов и классификации входные данные должны быть представлены в виде векторов, составляющие которых являются признаками определяемых объектов. Признаки указываются как числа. Для данной задачи выходными параметрами являются только 2 числа: 0 и 1 или допустимо и недопустимо (рис. 3.15).

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	0	0	1	0	0	1	1	1	0	0	0	1	0	0	1
2	1	1	0	1	1	0	0	0	1	1	1	0	1	1	0

Рис. 3.15 Выходные данные

Начнем процесс обучения сети.

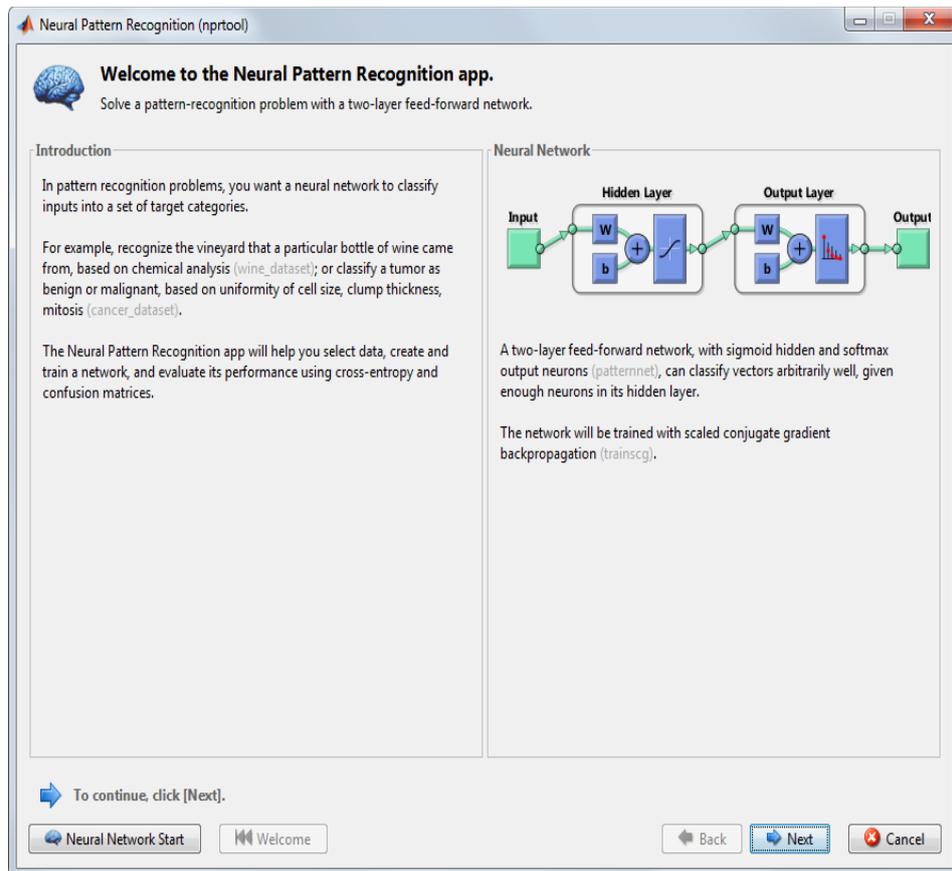


Рис. 3.16 Стартовое окно

Данная сеть имеет двухслойную структуру с прямым распространением. Во входном слое используется функция активации сигмоидального вида, а в выходном типа softmax.

$$a_i = \frac{e^{n_i}}{\sum_i e^{n_i}}, \quad (3.3)$$

где a_i – выход нейронов;

n_i – выход адаптивных сумматоров нейронов.

Складываются все нейроны в каждом слое. Данная схема исключает то, что сумма выходов будет отлична от единицы, при совершенно разных значениях сигналов сумматоров.

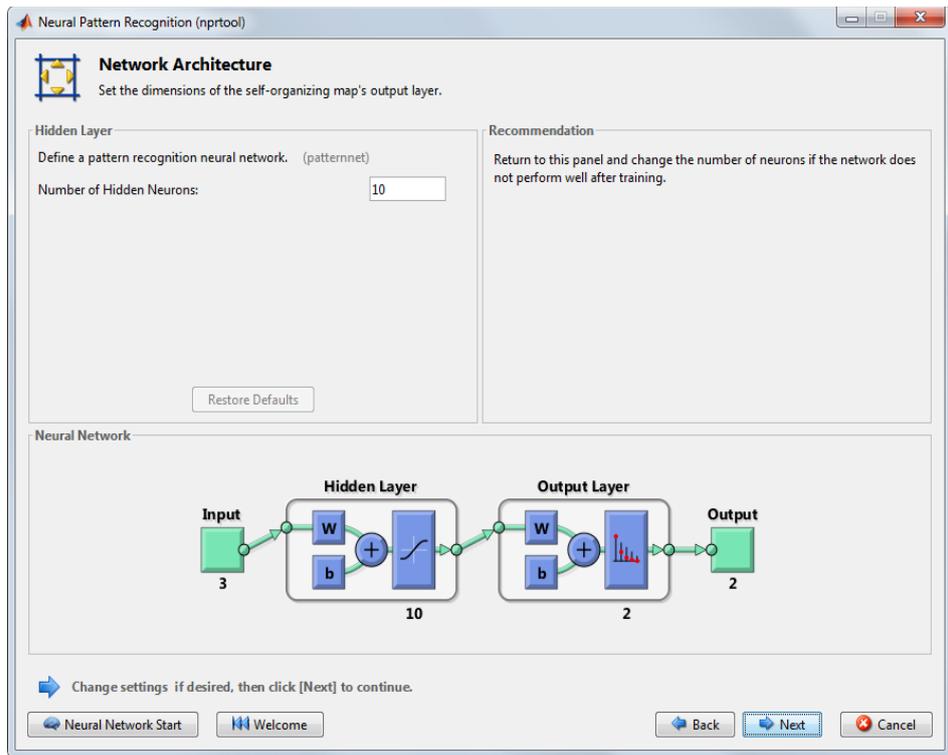


Рис. 3.17 Структура сети

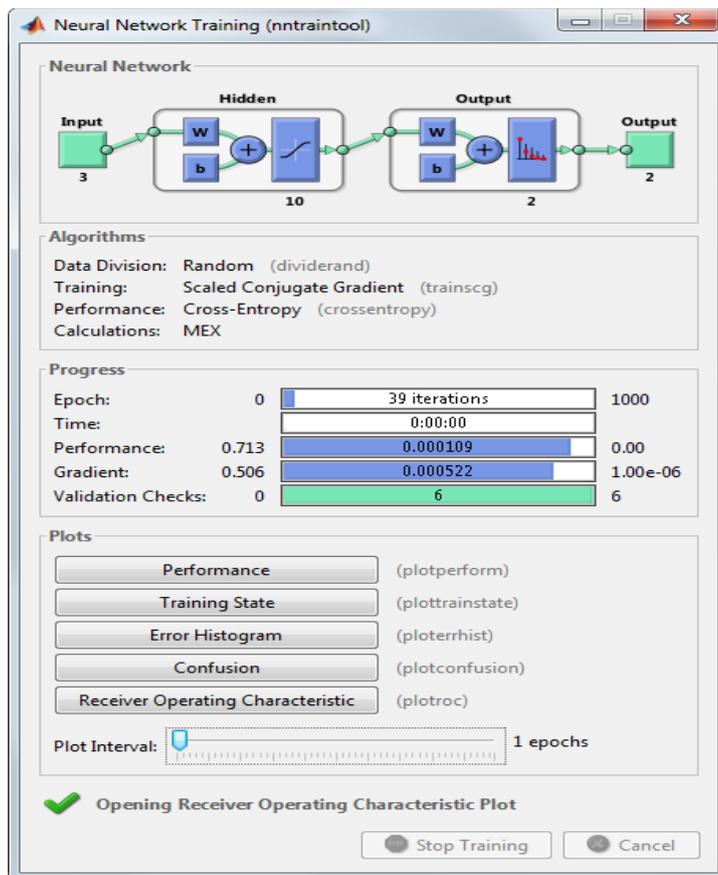


Рис. 3.18 Окно процесса обучения

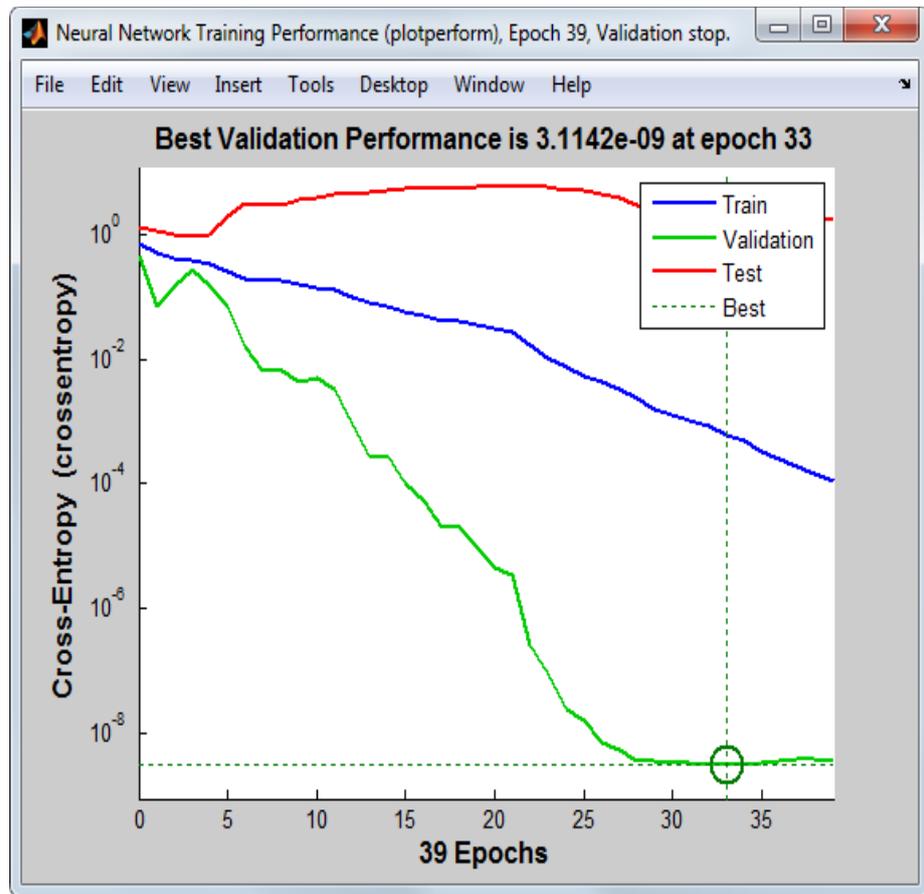


Рис. 3.18 График обучения распознавания

В качестве области определения ошибки используем кросс – энтропию или перекрестную энтропию. Ошибка на выходе рассчитывается как:

$$E = - \sum_{q=1}^Q \sum_{i=1}^n t_i^{(q)} \ln y_i^{(q)}, \quad (3.4)$$

где n – число выходов;

$y_i^{(q)}$ – действительное величина выхода после подачи информации;

Q – число примеров в обучающем множестве;

$t_i^{(q)}$ – целевая величина выхода после подачи информации.

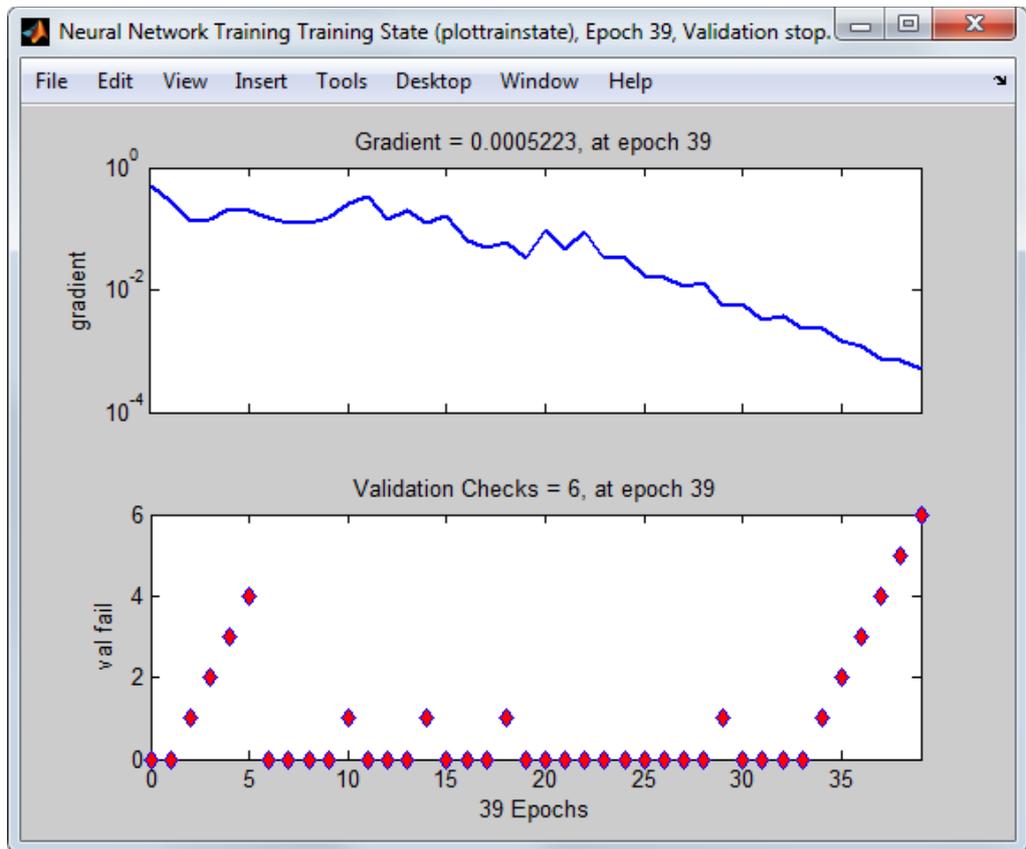


Рис. 3.19 График состояния обучения

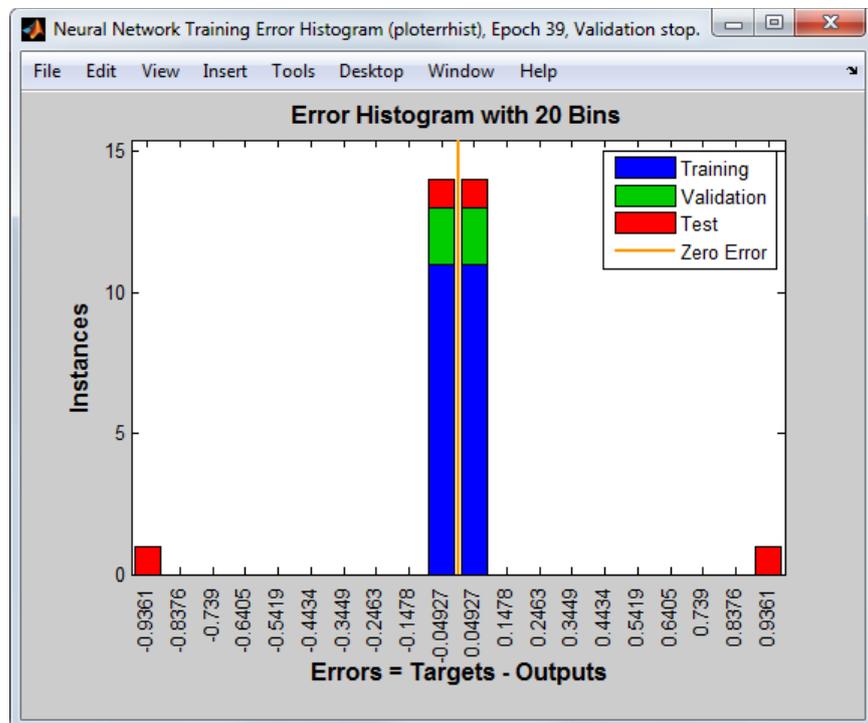


Рис. 3.20 Гистограмма ошибок



Рис. 3.21 Матрица несоответствий

Данная матрица показывает, как сеть справилась с задачей классификации на тот или иной класс. Столбцы – это целевые классы, а строки – фактические. Матрица разделена на матрицы трех главных множеств и на общую. Эта матрица показывает, что ошибка допущена только в распознавание тестового множества.

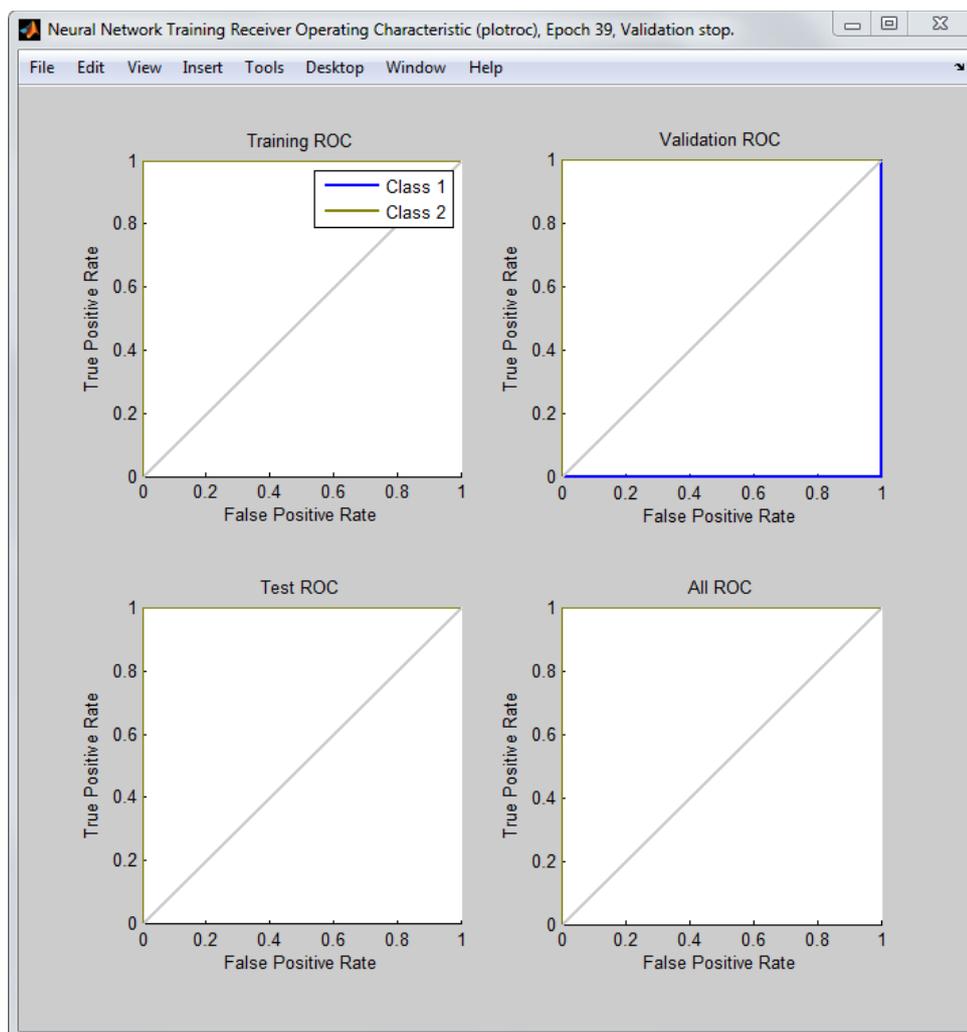


Рис. 3.22 Характеристические кривые обнаружения

Классификатор распределяет данные к определенному классу в зависимости от того, превысил ли порог – граничное значение, которое разделяет классы, сигнал.

Определяются два граничных значения: процент положительных примеров (**True Positives Rate**) – множество выходов, которые выше или равны граничному значению, разбитое на величину единичных заданных параметров; процент не положительных примеров (**False Positives Rate**) – множество выходов, которое ниже граничного значения, разбитое на величину нулевых заданных параметров.

В идеальном случае график проходит по верхнему левому углу, в котором процент положительных примеров абсолютна. Из этого следует, что

чем ближе кривая к этому положению, тем лучше модель способна предсказывать.

Далее рассмотрим принцип работы в программе ANFIS.

«ANFIS – это аббревиатура от Adaptive-Neuro – Based Fuzzy Inference System – адаптируемая сеть с нечетким выводом. Она была создана Янгом в конце прошлого века. ANFIS одна из самых первых сетей гибридного нейро – нечеткого типа – нейросеть с прямым распространением сигнала специального типа. Структура изоморфна по отношению к нечеткой базе значений» [20].

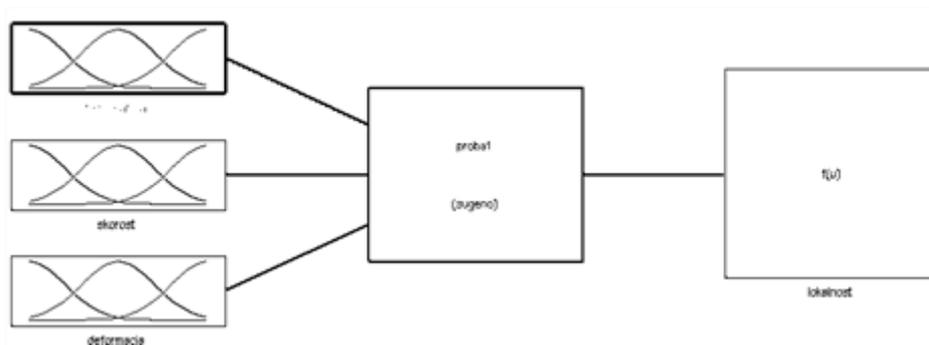


Рис. 3.23 Структура системы вывода

«Отношение входа – выхода обозначается в виде нечеткой структуры.

$$y = b_{j,0} + b_{j,1} \cdot x_1 + b_{j,2} \cdot x_2 + \dots + b_{j,n} \cdot x_n, \quad (3.5)$$

где $b_{j,n}$ – коэффициенты;

m – множество правил;

k – количество термов в j – ом правиле, которое равно числу экспериментов;

i – компоненты вектора входа X ;

$a_{i,pj}$ – нечеткий терм для оценивания переменной x_i .

Вывод j – ого правила d_j базы определяется по принципу линейной функции, зависящей от входа» [20].

$$d_j = b_{j,0} + \sum_{i=1}^n b_{j,i} \cdot x_i \quad (3.6)$$

Составленные системы выводятся как набор лингвистических или графических правил. Лингвистические правила формулируются как нечёткие правила по основе «ЕСЛИ...- ТО...», в полное мере отражают влияние

изменения вектора входов x на выход модели y . Каждый вектор входа представлен определенным количеством нечётких термов (от 3 до 7).

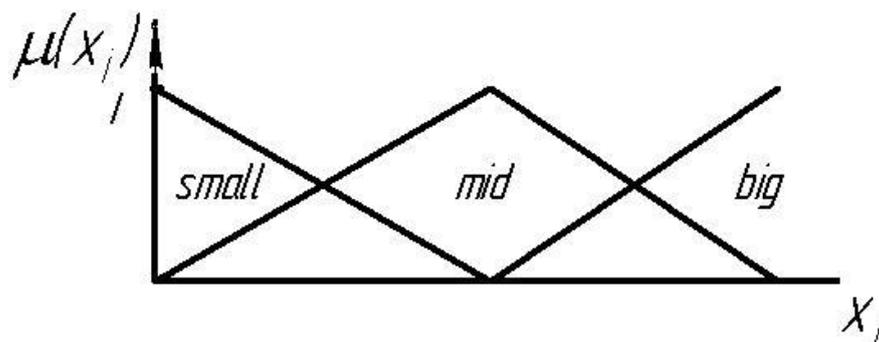


Рис. 3.24 Графические правила

ANFIS реализует систему нечеткого вывода Сугено как пятислойную сеть. Эта система является гибридной. Данные входа анализируются нечёткими множествами, а выход представляется в виде линейной функции.

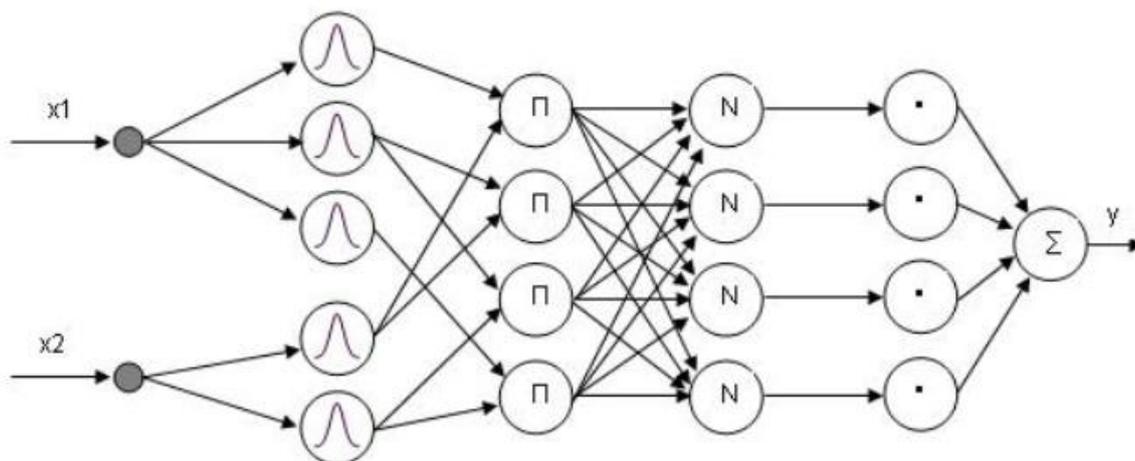


Рис. 3.25 Структура ANFIS

- Первый слой – термы входа;
- Второй слой – antecedent правил нечеткого вида;
- Третий слой – упорядочение выполняемых правил;
- Четвертый слой – вывод правил;
- Пятый слой – объединение и сведение результатов, полученных из различных правил.

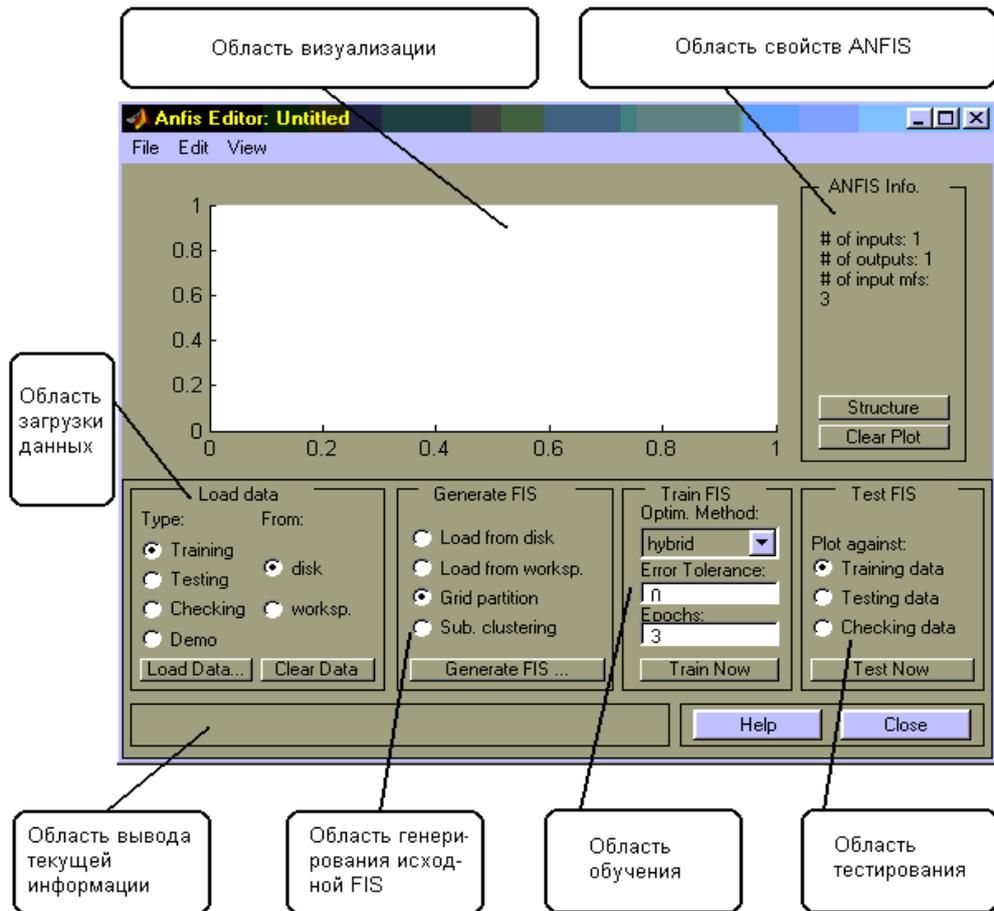


Рис. 3.26 Окно ANFIS – редактора

Область загрузки позволяет загружать различные пакеты данных под определенные задачи: обучение, тестирование или проверка сети.

Область генерирования используется для создания исходной системы нечеткого вывода.

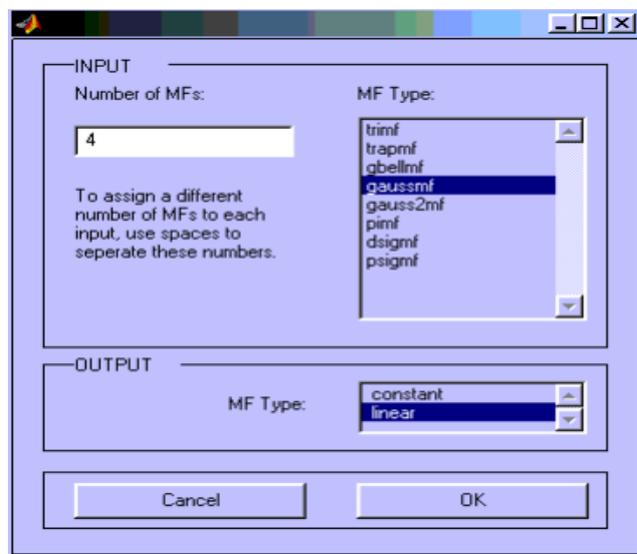


Рис. 3.27 Окно изменения параметров исходной структуры

В меню редактирования сетки мы можем задавать количество термов для каждого входного сигнала и вид функции принадлежности.

Во время обучения можно посмотреть структуру сети, правила ввода и вывода сигналов и графики зависимостей между данными (рис.3.28 – 3.30).

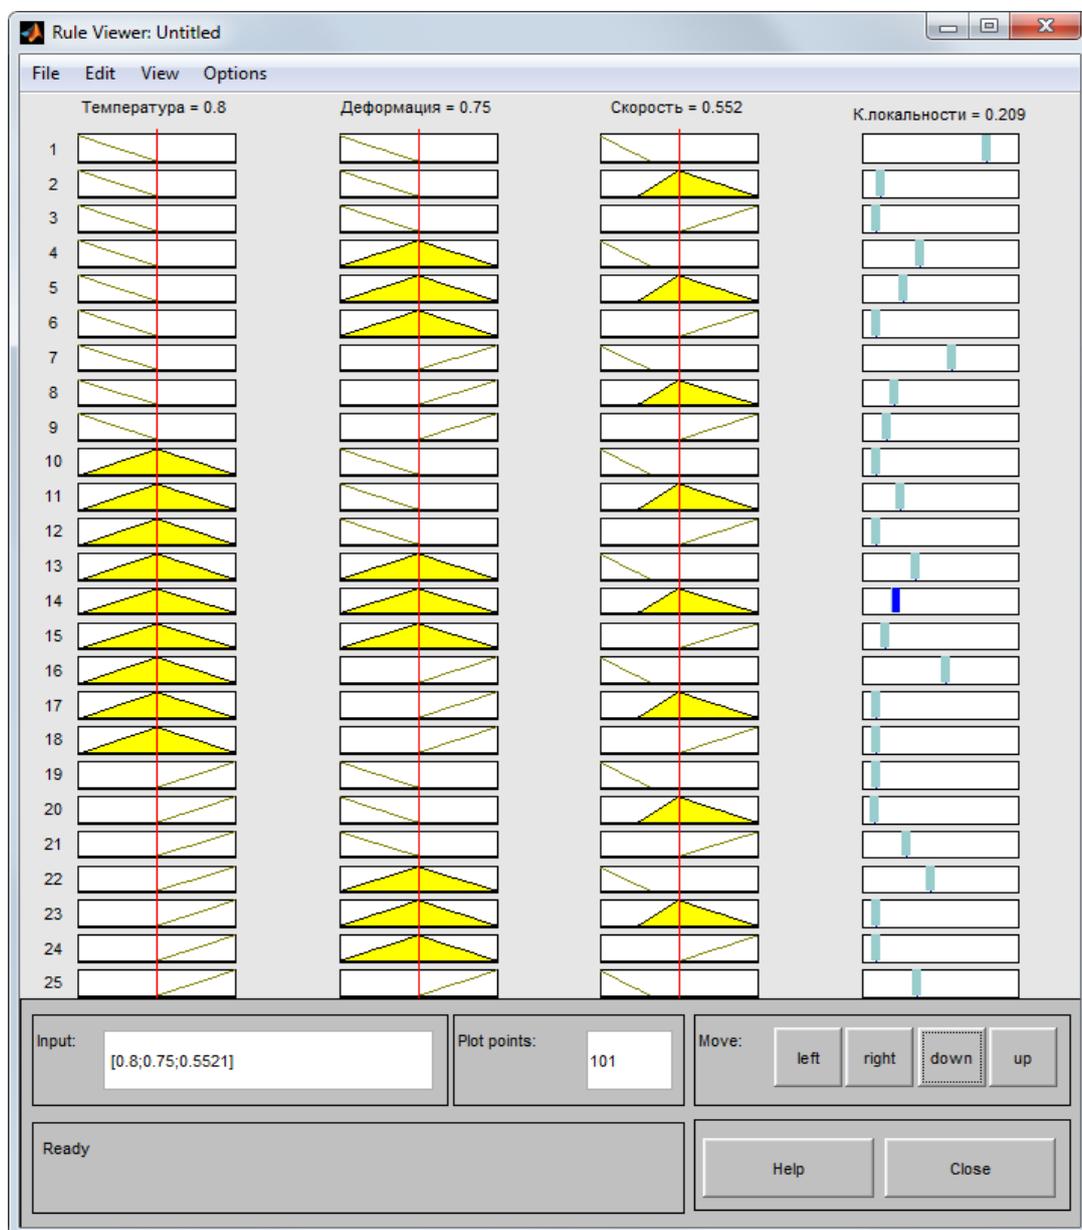


Рис. 3.28 Графические правила

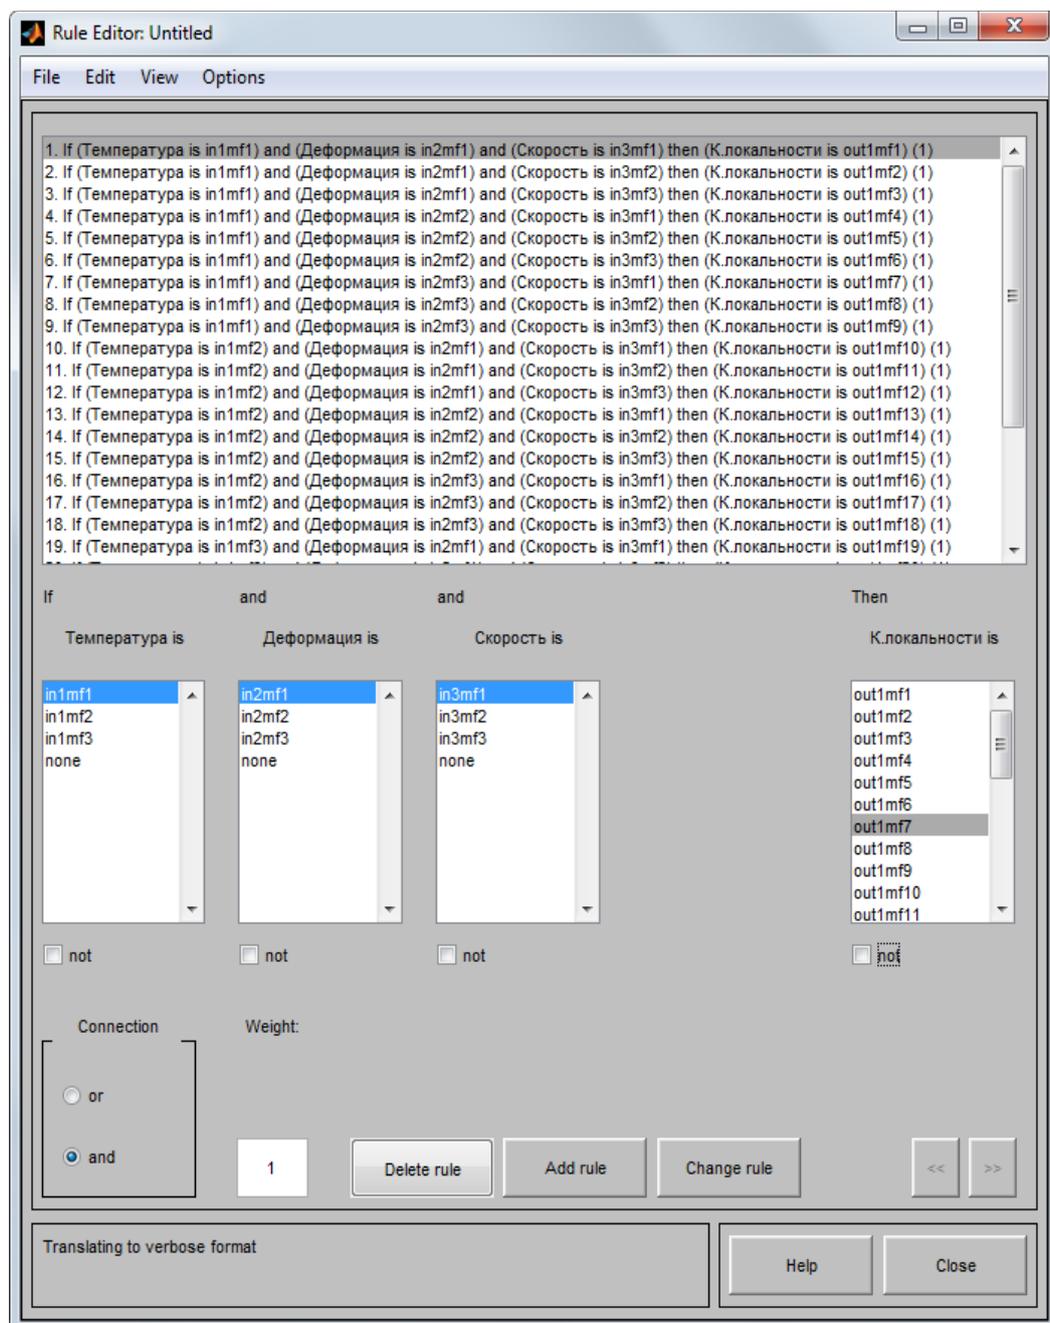


Рис. 3.29 Лингвистические правила

Данные графики показывают по какому принципу сеть соотносила входные и выходные данные. Данные правила можно использовать для управления различными процессами. Сеть сама будет регулировать и выбирать нужные режимы и параметрами для получение заданных результатов.

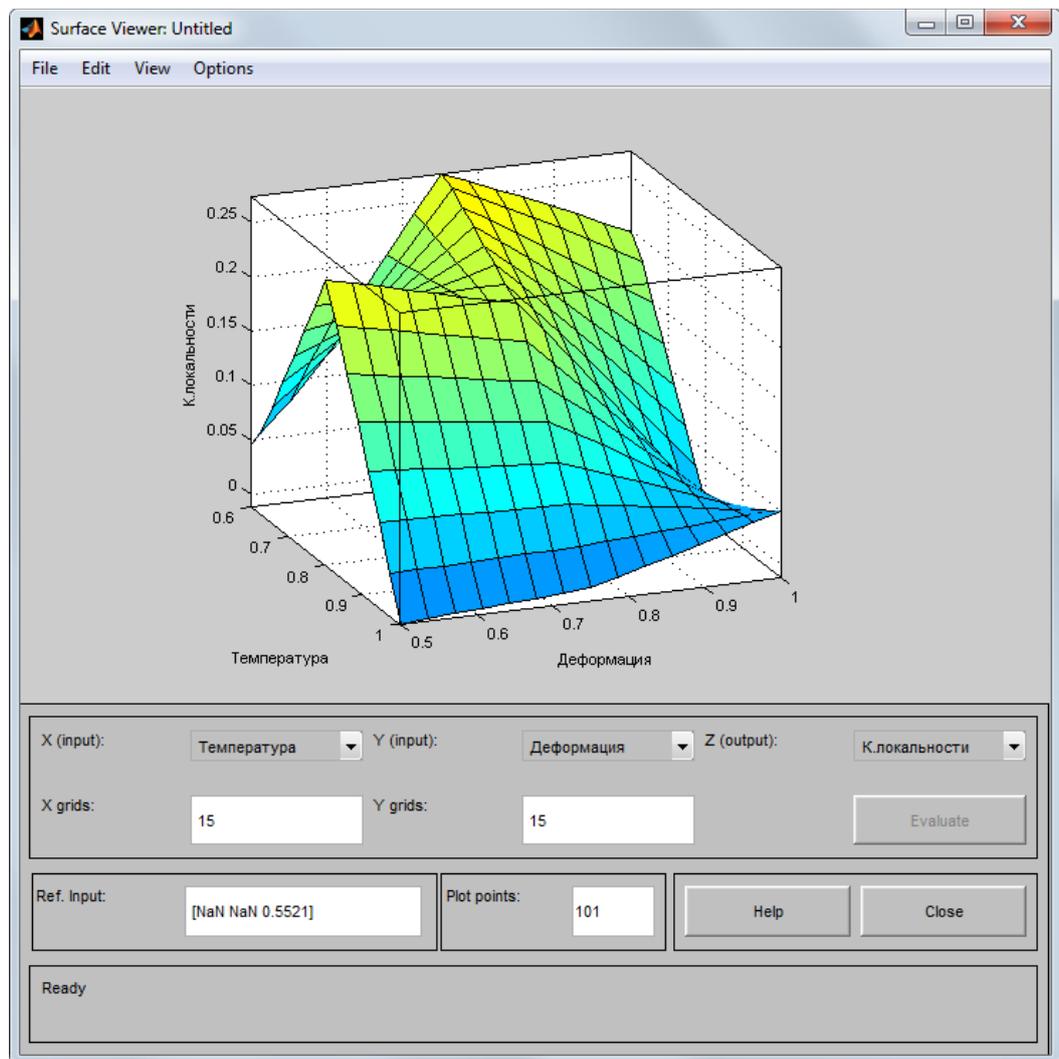


Рис. 3.30 График зависимостей данных

Этот график иллюстрирует взаимосвязи между данными. На нем наглядно видно, какие значения нужно использовать для получения желаемого результата.

4. НАУЧНЫЕ ИССЛЕДОВАНИЯ

В данной главе будет проводиться операция аппроксимации и классификации сложных нелинейных зависимостей процесса ТСО. Путем перебора параметров НС будет определяться наилучшие сочетания для решения поставленной задачи.

«Рассмотрим объекты и характеристики процесса ТСО. Для исследования использовались образцы, изготовленные из стали 40Х. Опыты проводились на температурах $T^\circ = 300^\circ\text{C}$, 400°C , 500°C . На отметках $\varepsilon = 4\%$; 6% ; 8% устанавливался размер пластической деформации» [15].

«На образце были нанесены засечки, с расстоянием между ними равным диаметру заготовки. Изменения геометрических параметров образцов измерялось до и после завершения процесса. На основе измерений выводились зависимости изменения длины и диаметров заготовки» [15].

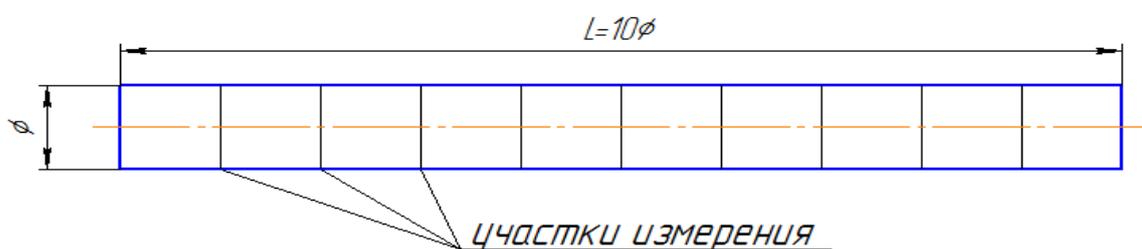


Рис. 4.1 Маложесткий вал

Результаты показали то, что деформации распределены неравномерно по длине бруска. На это влияло неравномерность свойств и то, что пластические деформации распространяются волнообразно.

За основные влияющие факторы были взяты температура величина и скорость деформации.

Данные, которые были выявлены после завершения экспериментов, показаны на рисунках 4.2 – 4.3.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	500	300	500	500	500	300	300	300	500	400	400	400	300	300	400
2	4	4	4	6	8	4	6	8	8	8	6	4	6	8	6
3	5.6400	0.7200	4.3500	1.1600	1.4700	2.0500	2.1600	4.0800	1.8900	0.5870	1.1300	2.9000	1.9000	0.8700	3.9700

Рис.4.2 Температура, величина и скорость деформации

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	4.0650	10.6380	1.7540	6.5780	5.2080	3.7450	2.9410	1.8760	4.0480	8.6580	4.3100	2.6450	4.0320	8.8490	1.9230

Рис.4.3 Коэффициент локальности

«Для оптимизации работы сети и уменьшения погрешности, проведем операцию нормирование данных по следующим формулам:

$$T = \frac{T_i}{T_{max}}, \text{ } ^\circ\text{C}; \quad (4.1)$$

$$\varepsilon = \frac{\varepsilon_i}{\varepsilon_{max}}; \quad (4.2)$$

$$\dot{\varepsilon} = \frac{\dot{\varepsilon}_i}{\dot{\varepsilon}_{max}}, \text{ } \text{с}^{-1}; \quad (4.3)$$

$$k = \frac{k_i}{k_{max}}; \quad (4.4)$$

где k – коэффициент локальности;

k_i – коэффициент локальности в каждом эксперименте;

k_{max} – максимальный коэффициент;

ε – размер деформаций;

ε_i – размер деформаций в каждом эксперименте;

ε_{max} – максимальный размер деформаций;

T – температура, °C;

T_{max} – максимальный размер температуры, °C;

T_i – температура в каждом эксперименте, °C;

$\dot{\epsilon}$ – величина скорости деформаций, c^{-1} ;

$\dot{\epsilon}_i$ – величина скорости деформаций в каждом эксперименте, c^{-1} ;

$\dot{\epsilon}_{max}$ – максимальная скорость деформации, c^{-1} » [15].

Данные, вычисленные в ходе нормирования, указаны на рисунках 4.4 –

4.5.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	1	0.6000	1	1	1	0.6000	0.6000	0.6000	1	0.8000	0.8000	0.8000	0.6000	0.6000	0.8000
2	0.5000	0.5000	0.5000	0.7500	1	0.5000	0.7500	1	1	1	0.7500	0.5000	0.7500	1	0.7500
3	1	0.1276	0.7713	0.2057	0.2606	0.3635	0.3830	0.7234	0.3351	0.1041	0.2003	0.5142	0.3369	0.1542	0.7040

Рис. 4.4 Нормированные температура, скорость и величина деформации

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	0.3821	1	0.1649	0.6183	0.4896	0.3520	0.2765	0.1763	0.3805	0.8139	0.4052	0.2486	0.3790	0.8318	0.1808

Рис. 4.5 Нормированный коэффициент локальности

Для упрощения применим двухслойную нейронную сеть с обратным распространением ошибки и с функцией активации сигмоидального типа на входе и линейной на выходе. Во время обучения будем менять алгоритмы обучения и количество нейронов в скрытом слое.

Будет использоваться алгоритм обучения Левенберга – Маркварта, который характерен своим быстродействием и подходит для решения задач с небольшой выборкой данных. Количество нейронов будет меняться на 10, 15 и 20.

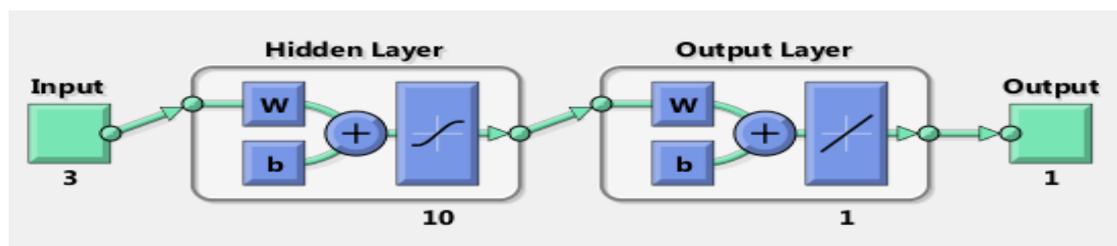


Рис. 4.6 Структура сети

Графики итогов обучения и ошибок сети с 10 нейронами представлены на рисунках 4.7 – 4.11.

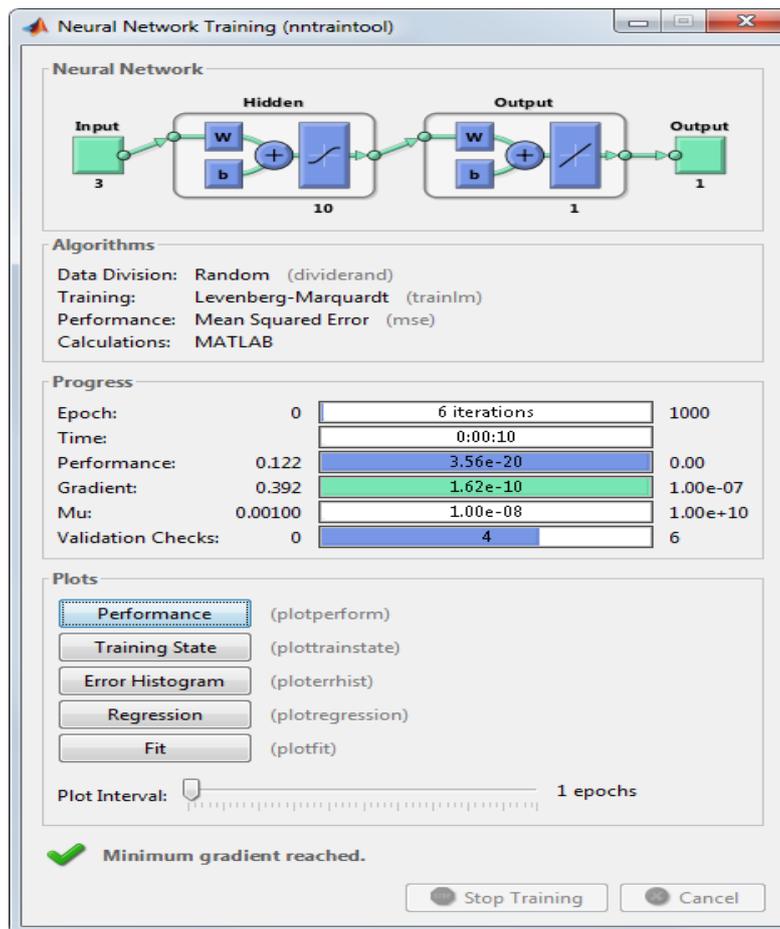


Рис. 4.7 Интерфейс обучения с 10 нейронами

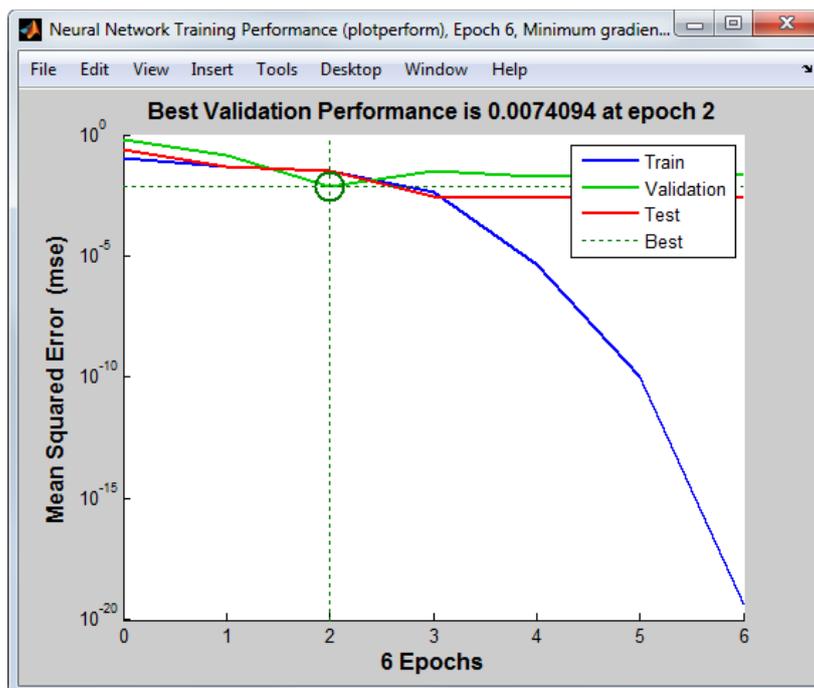


Рис. 4.8 График обучения с 10 нейронами

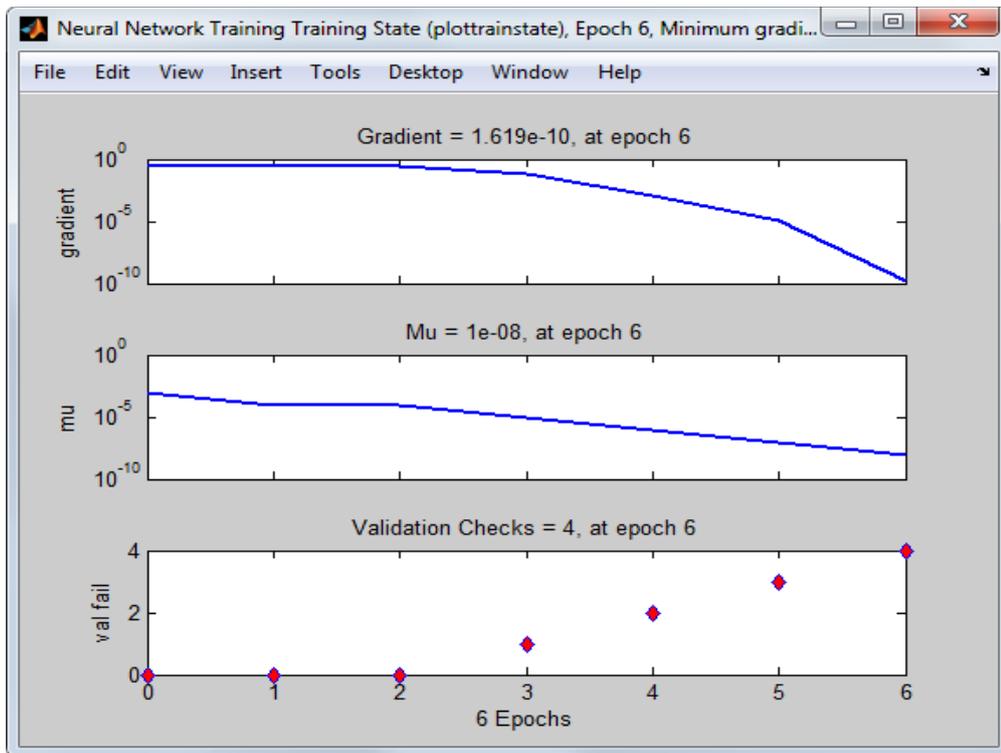


Рис. 4.9 График состояния обучения с 10 нейронами

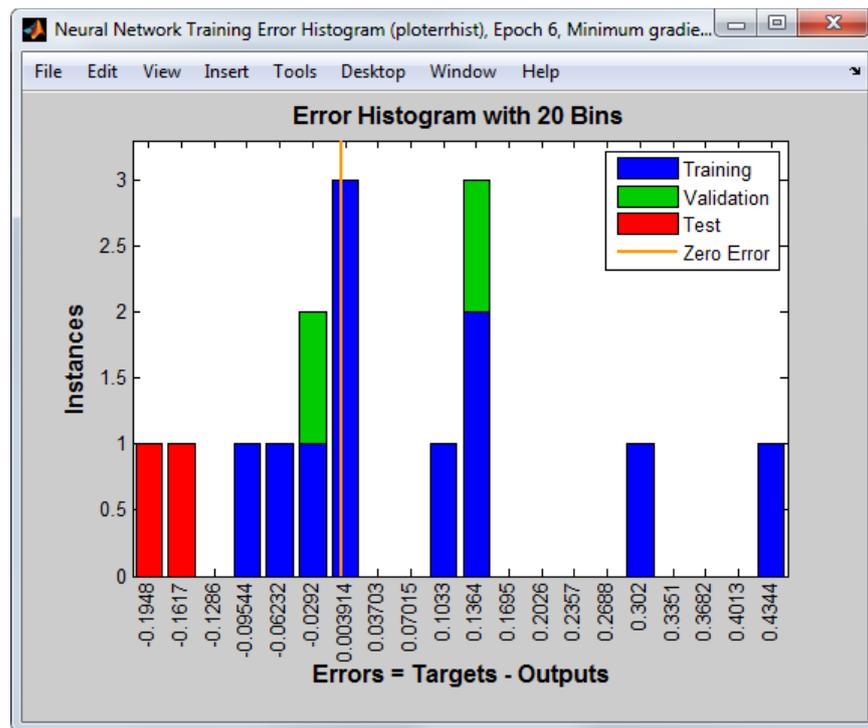


Рис. 4.10 Гистограмма ошибок с 10 нейронами

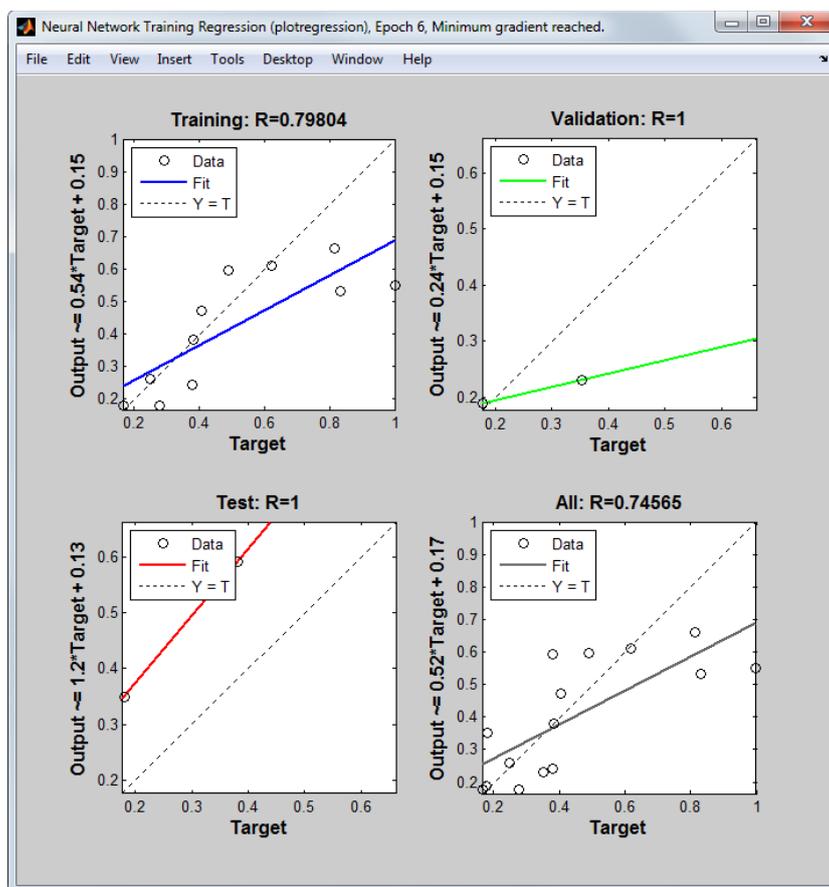


Рис. 4.11 Графики результатов обучения с 10 нейронами

Эта модель решила задачу за 2 эпохи. Однако она имеет значительные погрешности в обучающих выборках. Ошибка распределена на достаточно широком диапазоне значений. Это также сильно снизило общее качество обучения. Вероятно, эта погрешность появилась из-за расхождения в количестве нейронов и количестве экспериментов.

Графики итогов обучения и ошибок сети с 15 нейронами представлены на рисунках 4.12 – 4.16.

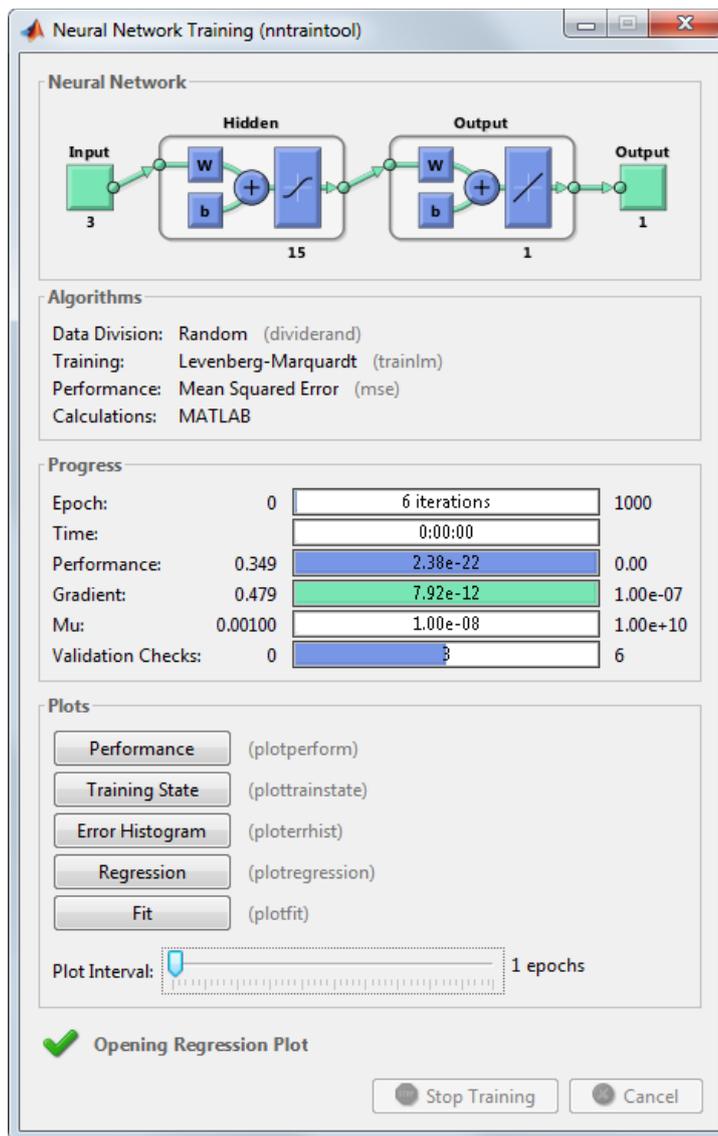


Рис. 4.12 Интерфейс обучения с 15 нейронами

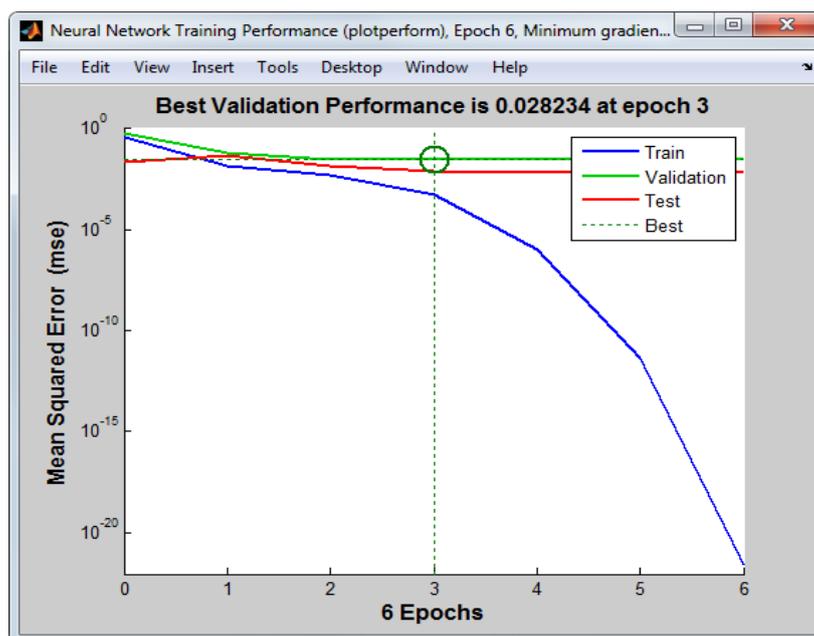


Рис. 4.13 График обучения с 15 нейронами

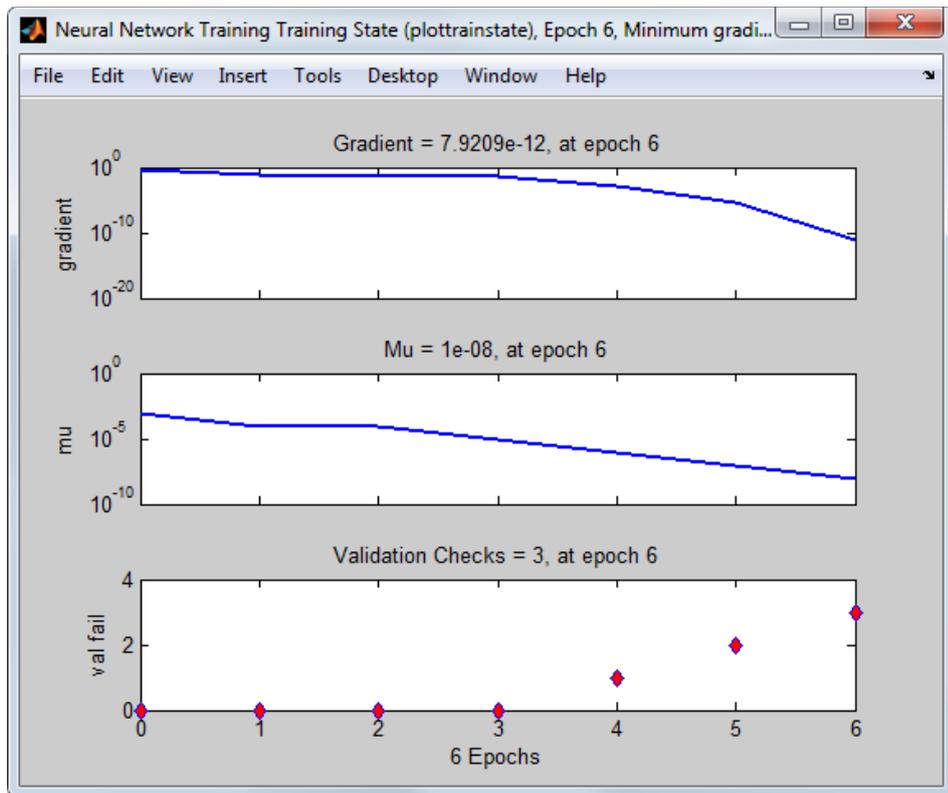


Рис. 4.14 График состояния обучения с 15 нейронами

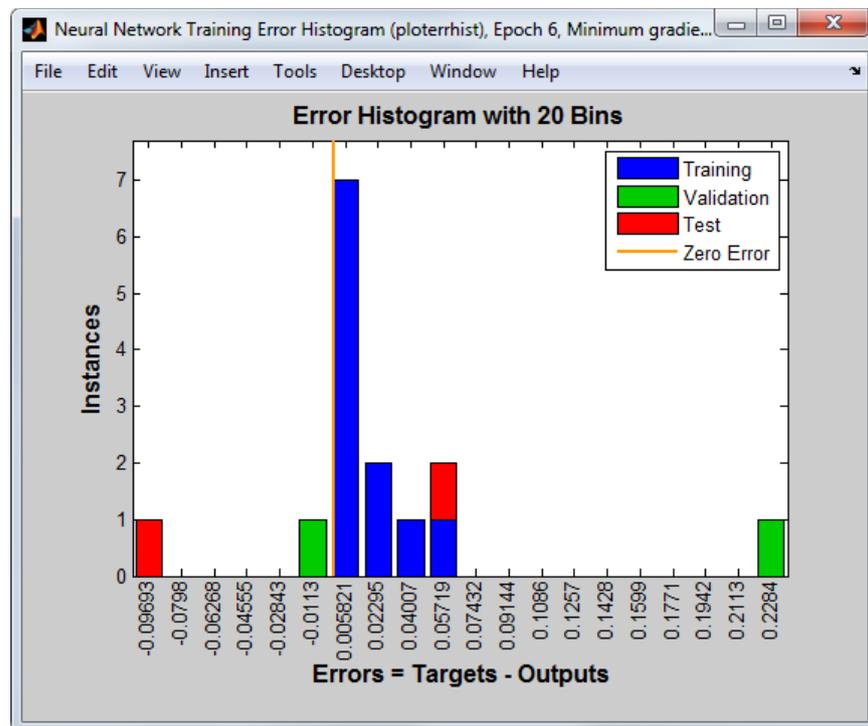


Рис. 4.15 Гистограмма ошибок с 15 нейронами

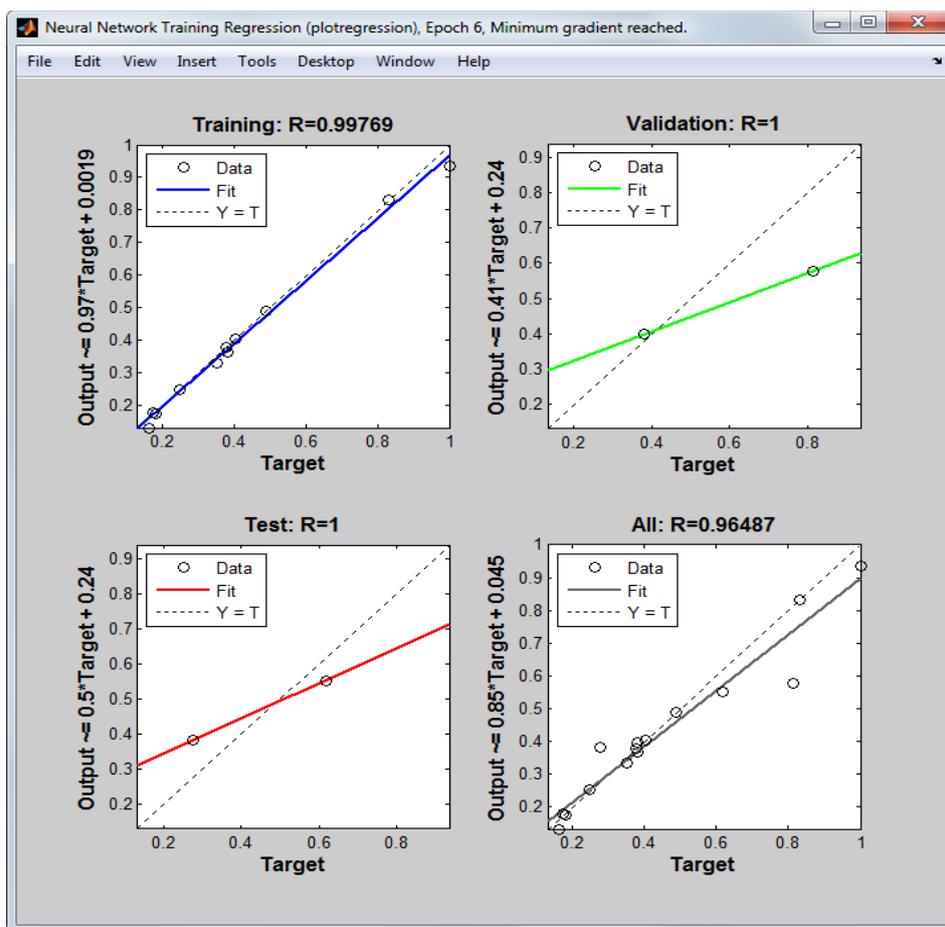


Рис. 4.16 Графики результатов обучения с 15 нейронами

Эта модель потратила 3 эпохи для решения задачи. Ошибка является незначительной и распространена в узком спектре значений. Ошибка представлена в основном в обучающем множестве. Это делает модель наиболее предпочтительной для практического применения.

Графики итогов обучения и ошибок сети с 20 нейронами представлены на рисунках 4.17 – 4.21.

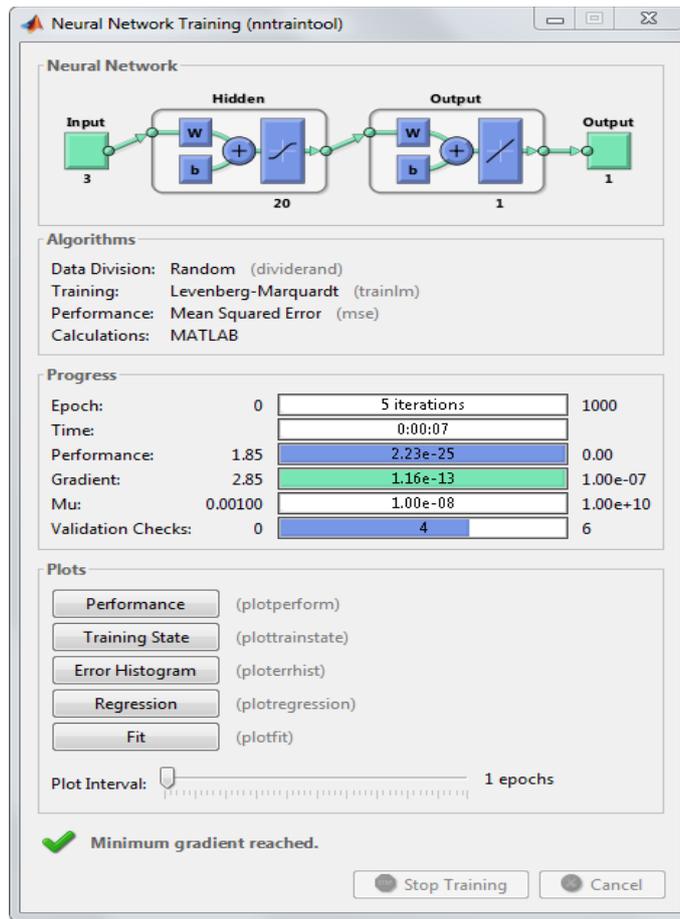


Рис. 4.17 Интерфейс обучения с 20 нейронами

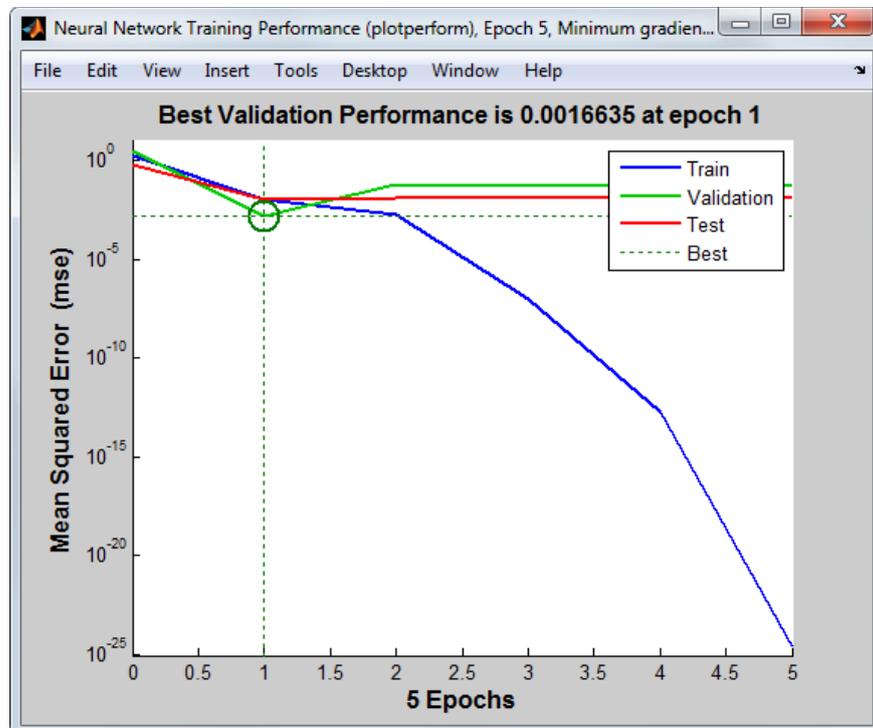


Рис. 4.18 График обучения с 20 нейронами

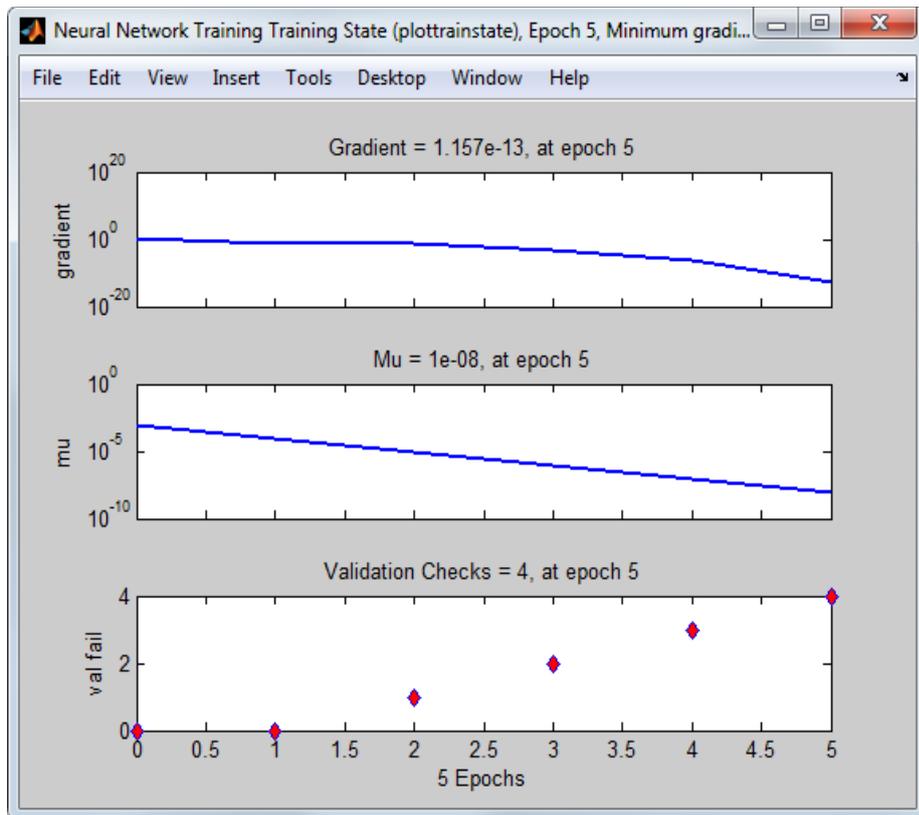


Рис. 4.19 График состояния обучения с 20 нейронами

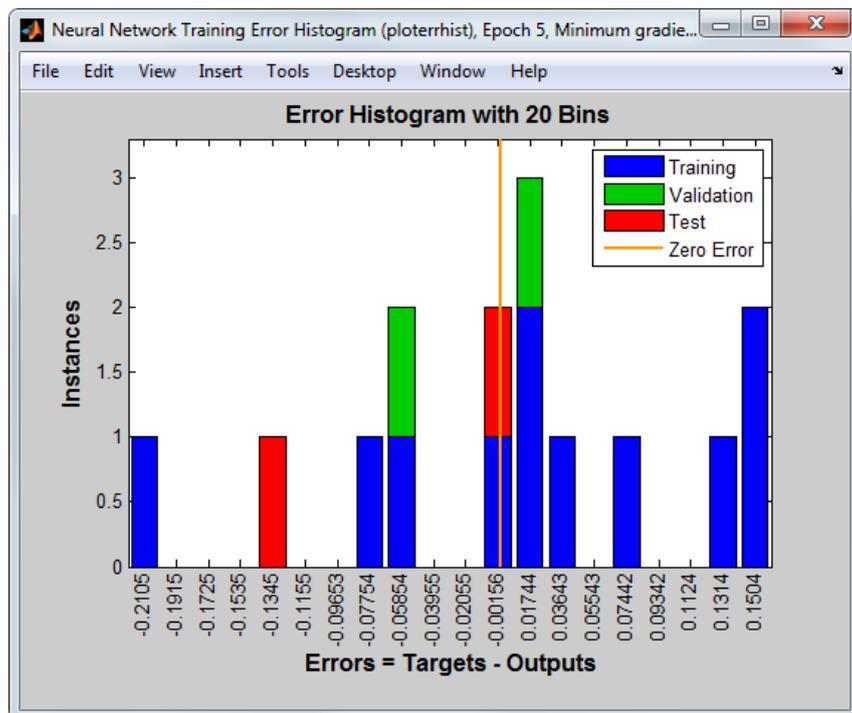


Рис. 4.20 Гистограмма ошибок с 20 нейронами

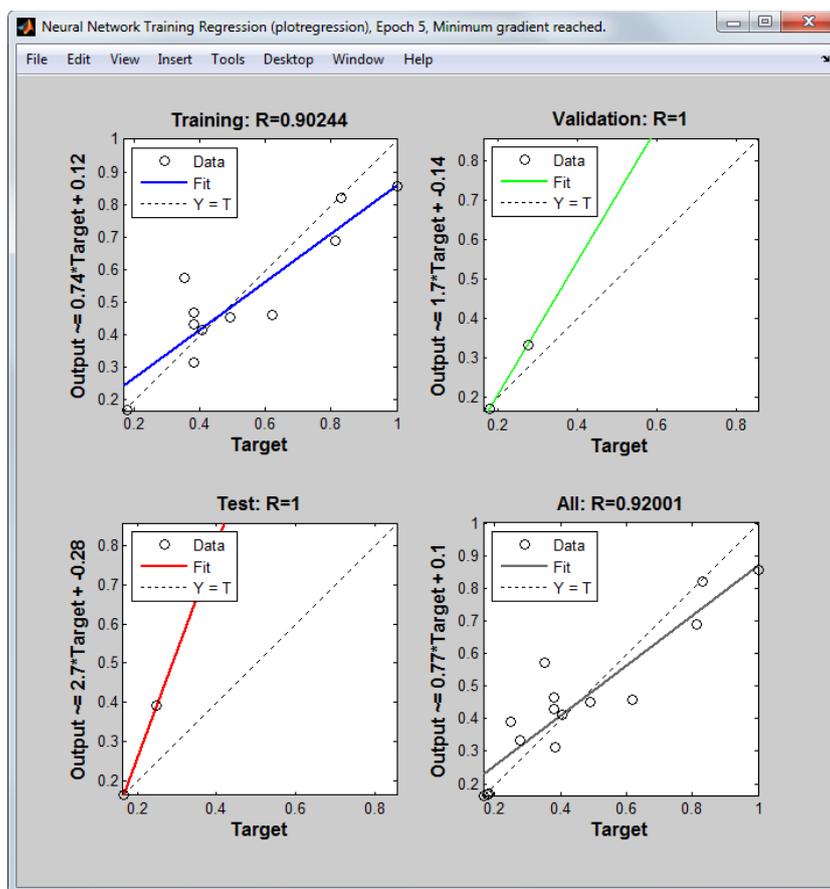


Рис. 4.21 Графики результатов обучения с 20 нейронами

Сеть с 20 нейронами показала наилучший результат по скорости решения. Значительная величина ошибки в обучающем множестве и широкий диапазон её распространения делает модель неприменимой на практике для решения схожих задач.

Представленная модель с 15 нейронами успешно прошла обучение за 3 эпохи и аппроксимировала нелинейные зависимости процесса ТСО с минимальной величиной ошибки и с узким диапазоном распространения, что делает её применимой для практических задач аппроксимации и использование для анализа и управления процессом ТСО.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	0.2053	0.9282	0.2118	0.6474	0.6712	0.3560	0.2318	0.1439	0.5809	0.7767	0.3211	0.2937	0.3191	0.7759	0.1673

Рис. 4.22 Выходные данные обучения

В качестве сравнения обучим гибридную систему ANFIS. Загрузим сгруппированные данные в ANFIS – редактор.

	1	2	3	4
1	1	0.5000	1	0.3821
2	0.6000	0.5000	0.1276	1
3	1	0.5000	0.7713	0.1649
4	1	0.7500	0.2057	0.6183
5	1	1	0.2606	0.4896
6	0.6000	0.5000	0.3635	0.3520
7	0.6000	0.7500	0.3830	0.2765
8	0.6000	1	0.7234	0.1763
9	1	1	0.3351	0.3805
10	0.8000	1	0.1041	0.8139
11	0.8000	0.7500	0.2003	0.4052
12	0.8000	0.5000	0.5142	0.2486
13	0.6000	0.7500	0.3369	0.3790
14	0.6000	1	0.1542	0.8318
15	0.8000	0.7500	0.7040	0.1808

Рис. 4.23 Данные для обучения

Выберем структуру сетки. Количество термов для каждого входного сигнала задаем равным трем. Функцию принадлежности выбираем треугольную. Выходной сигнал выберем линейного типа. Сеть обучалась по принципу обратного распространения ошибки.

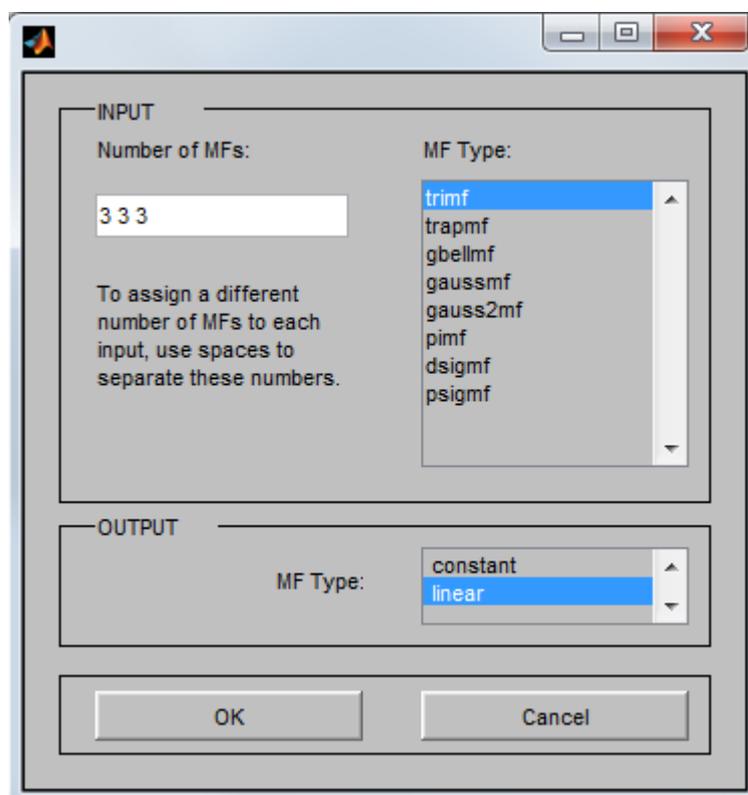


Рис. 4.24 Структура сетки

Далее проведем обучение. Правила системы, структуру сети и вывода, зависимости между входными и выходными данными показаны на рисунках 4.25 – 4.30.

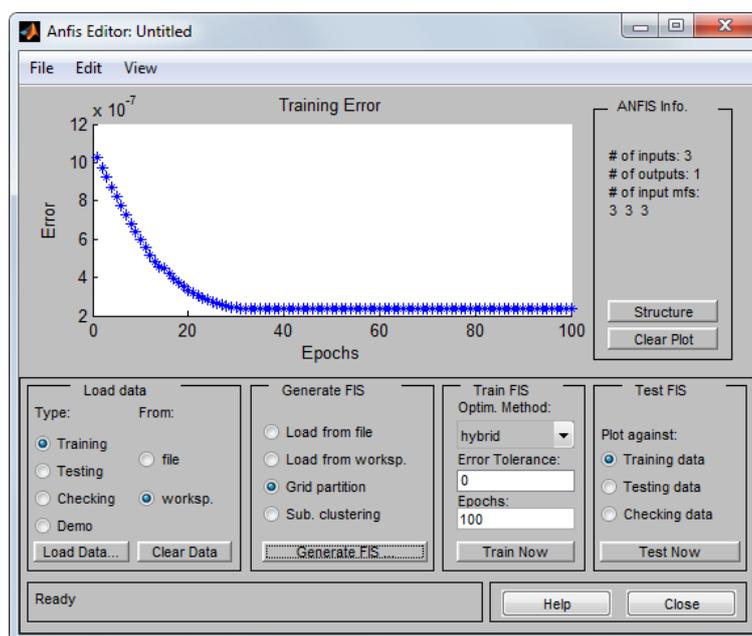


Рис. 4.25 Кривая обучения

В качестве времени обучения установим 100 эпох, а допустимую ошибку установим на значение ноль. Сеть справилась с обучением за 30 эпох.

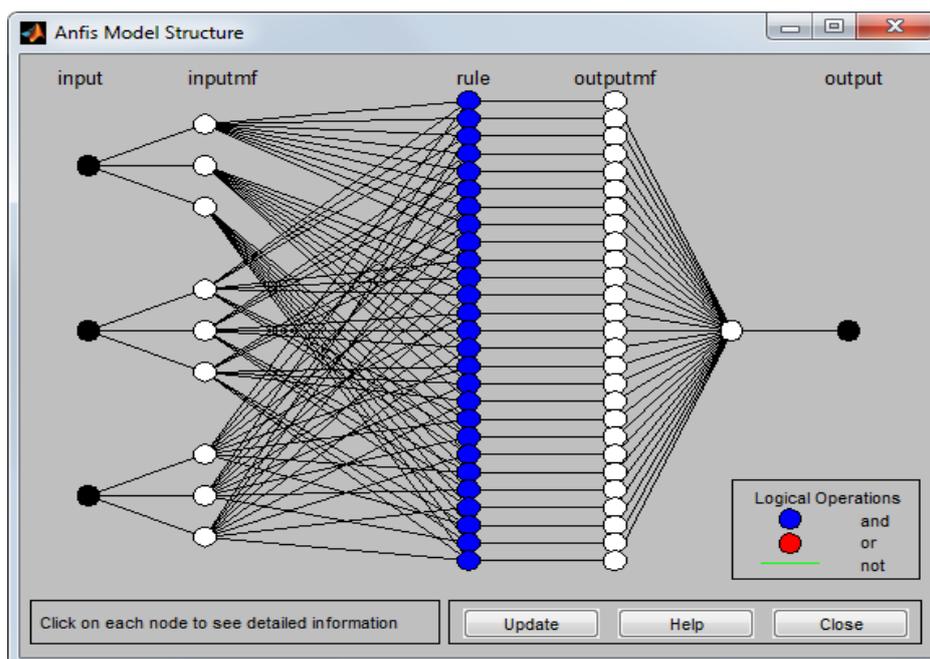


Рис. 4.26 Структура сети

На данном рисунке видно, какая структура получилась у нашей системы. На нем четко видно все пять слоев сети и как они взаимодействуют друг с другом.

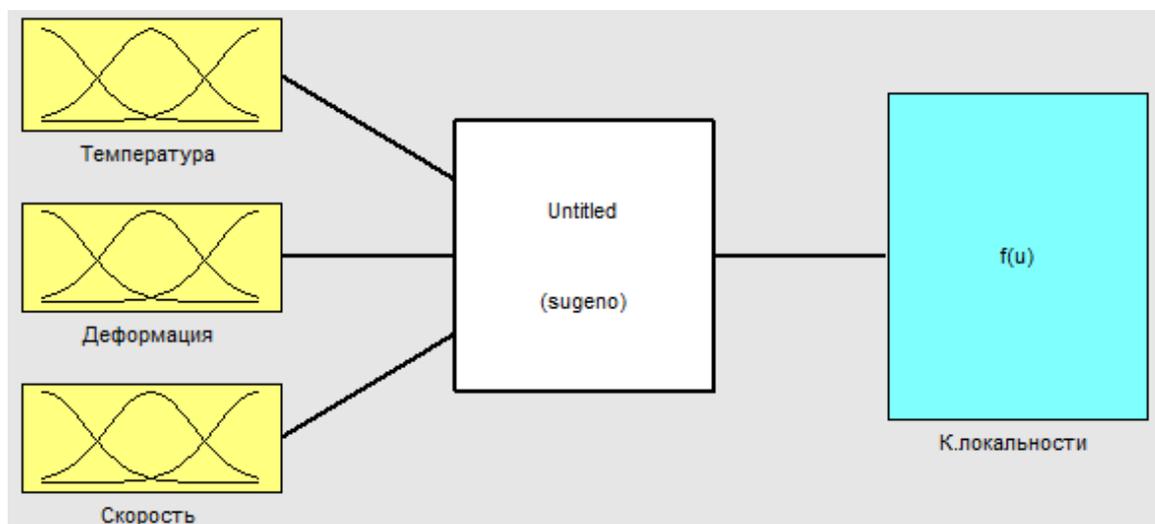


Рис. 4.27 Структура нечеткого вывода

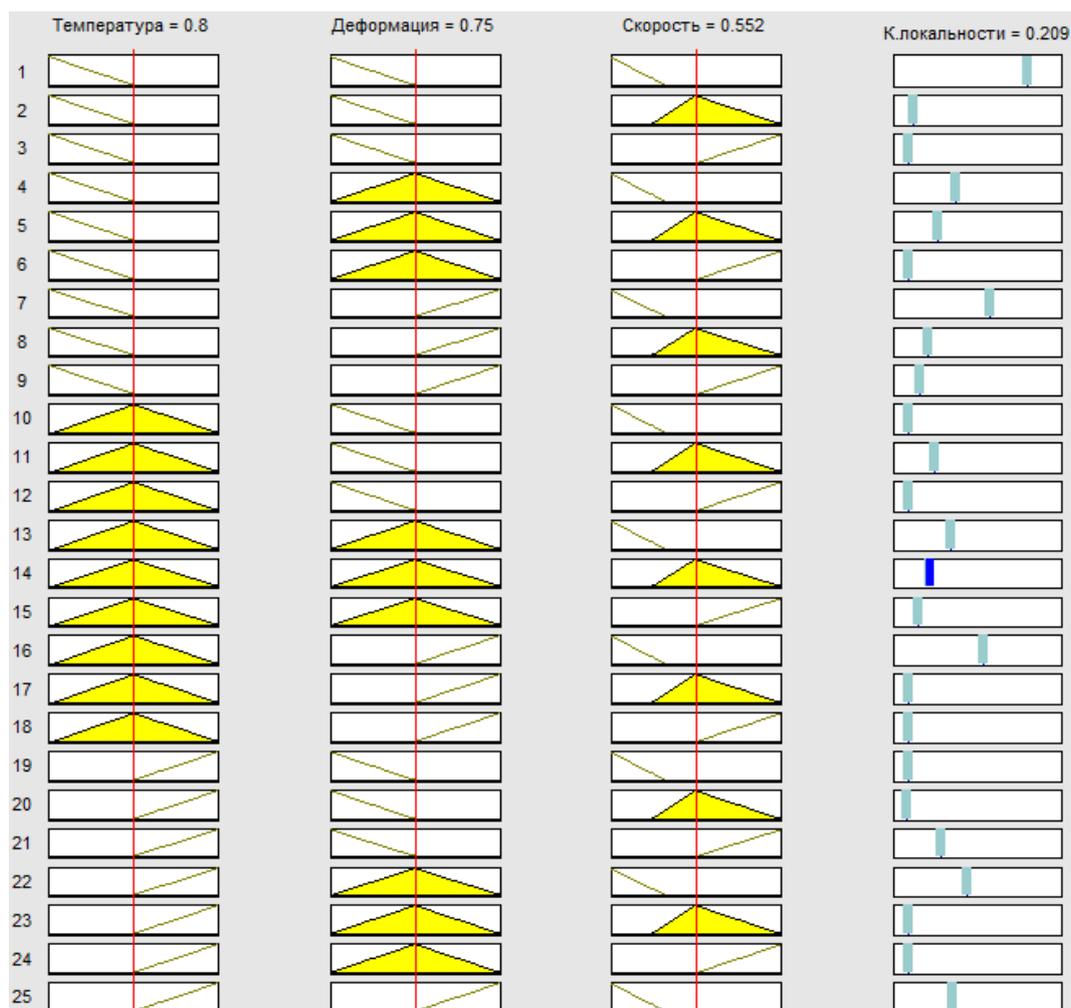


Рис. 4.28 Графические правила

1. If (Температура is in1mf1) and (Деформация is in2mf1) and (Скорость is in3mf1) then (К.локальности is out1mf1) (1)
2. If (Температура is in1mf1) and (Деформация is in2mf1) and (Скорость is in3mf2) then (К.локальности is out1mf2) (1)
3. If (Температура is in1mf1) and (Деформация is in2mf1) and (Скорость is in3mf3) then (К.локальности is out1mf3) (1)
4. If (Температура is in1mf1) and (Деформация is in2mf2) and (Скорость is in3mf1) then (К.локальности is out1mf4) (1)
5. If (Температура is in1mf1) and (Деформация is in2mf2) and (Скорость is in3mf2) then (К.локальности is out1mf5) (1)
6. If (Температура is in1mf1) and (Деформация is in2mf2) and (Скорость is in3mf3) then (К.локальности is out1mf6) (1)
7. If (Температура is in1mf1) and (Деформация is in2mf3) and (Скорость is in3mf1) then (К.локальности is out1mf7) (1)
8. If (Температура is in1mf1) and (Деформация is in2mf3) and (Скорость is in3mf2) then (К.локальности is out1mf8) (1)
9. If (Температура is in1mf1) and (Деформация is in2mf3) and (Скорость is in3mf3) then (К.локальности is out1mf9) (1)
10. If (Температура is in1mf2) and (Деформация is in2mf1) and (Скорость is in3mf1) then (К.локальности is out1mf10) (1)
11. If (Температура is in1mf2) and (Деформация is in2mf1) and (Скорость is in3mf2) then (К.локальности is out1mf11) (1)
12. If (Температура is in1mf2) and (Деформация is in2mf1) and (Скорость is in3mf3) then (К.локальности is out1mf12) (1)
13. If (Температура is in1mf2) and (Деформация is in2mf2) and (Скорость is in3mf1) then (К.локальности is out1mf13) (1)
14. If (Температура is in1mf2) and (Деформация is in2mf2) and (Скорость is in3mf2) then (К.локальности is out1mf14) (1)
15. If (Температура is in1mf2) and (Деформация is in2mf2) and (Скорость is in3mf3) then (К.локальности is out1mf15) (1)
16. If (Температура is in1mf2) and (Деформация is in2mf3) and (Скорость is in3mf1) then (К.локальности is out1mf16) (1)
17. If (Температура is in1mf2) and (Деформация is in2mf3) and (Скорость is in3mf2) then (К.локальности is out1mf17) (1)
18. If (Температура is in1mf2) and (Деформация is in2mf3) and (Скорость is in3mf3) then (К.локальности is out1mf18) (1)
19. If (Температура is in1mf3) and (Деформация is in2mf1) and (Скорость is in3mf1) then (К.локальности is out1mf19) (1)
20. If (Температура is in1mf3) and (Деформация is in2mf1) and (Скорость is in3mf2) then (К.локальности is out1mf20) (1)
21. If (Температура is in1mf3) and (Деформация is in2mf1) and (Скорость is in3mf3) then (К.локальности is out1mf21) (1)
22. If (Температура is in1mf3) and (Деформация is in2mf2) and (Скорость is in3mf1) then (К.локальности is out1mf22) (1)
23. If (Температура is in1mf3) and (Деформация is in2mf2) and (Скорость is in3mf2) then (К.локальности is out1mf23) (1)
24. If (Температура is in1mf3) and (Деформация is in2mf2) and (Скорость is in3mf3) then (К.локальности is out1mf24) (1)
25. If (Температура is in1mf3) and (Деформация is in2mf3) and (Скорость is in3mf1) then (К.локальности is out1mf25) (1)

Рис. 4.29 Лингвистические правила

На последних двух рисунках видно как сеть обрабатывала данные, и какие зависимости она построила для получения заданных результатов. Эти правила представляют собой перебор параметров входного сигнала, для подбора соответствующего выходного. Данные правила можно использовать как алгоритм управления процессом ТСО. Задавая коэффициент локальности, который мы хотим получить, мы будем получать от сети набор параметров, которые позволят нам получить необходимый результат. Также сеть будет управлять процессом ТСО. При изменении одного из параметров, допустим скорости деформации, она будет изменять два других. Это позволит ускорить и облегчить процесс ТСО и также повысить его точность.

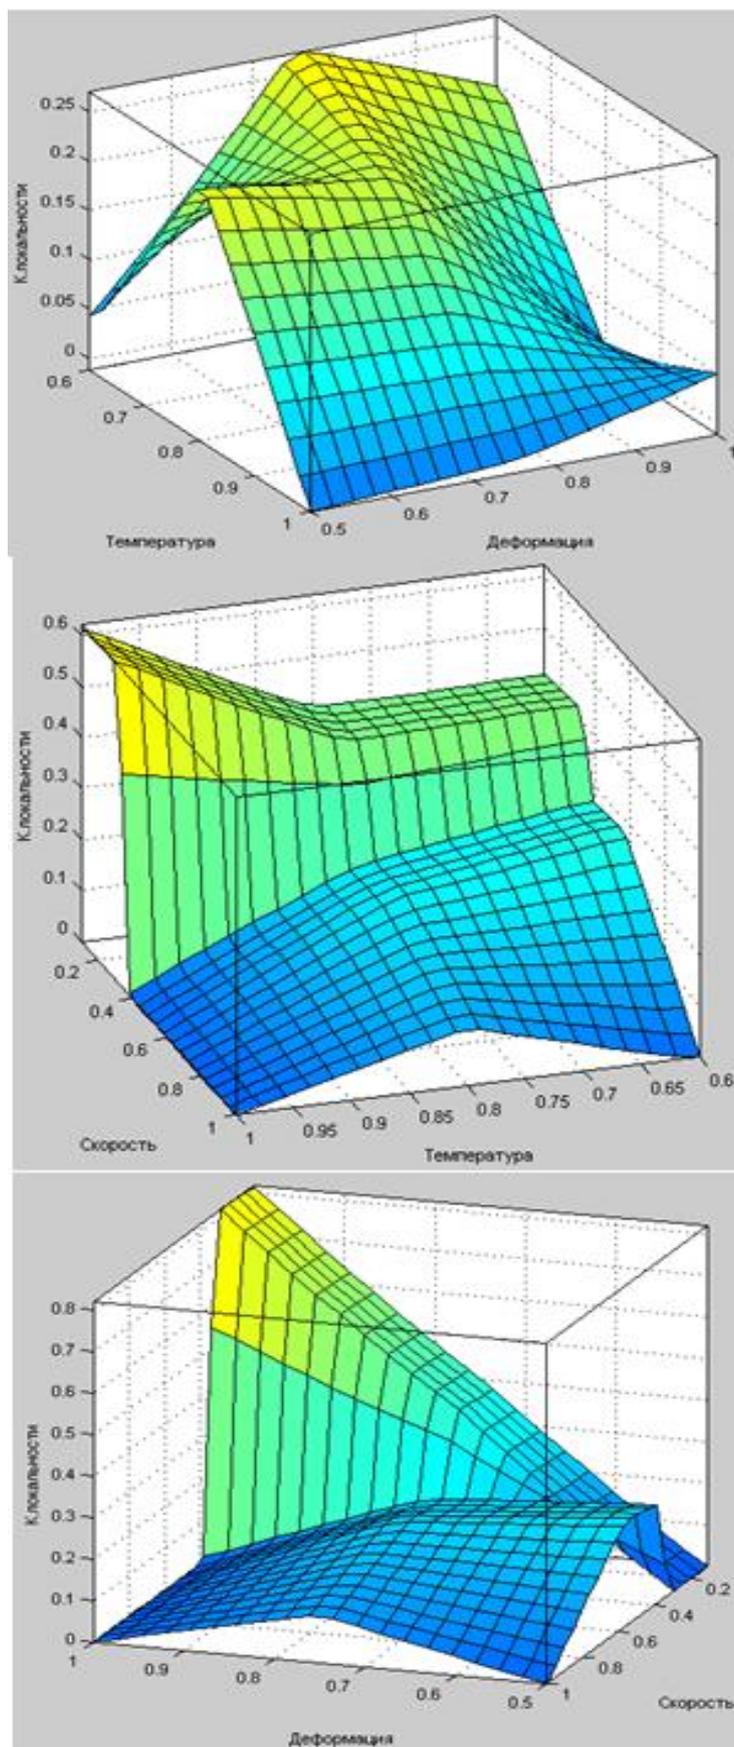


Рис. 4.30 Графики зависимостей входных и выходных данных

На этих графиках видны зависимости между входными и выходными сигналами. Они позволяют с достаточной точностью определить, при каких параметрах мы получим то или иное выходное значение.

Далее проведем классификацию допустимых и недопустимых параметров. В качестве граничного значения выберем величину коэффициента локальности равного четырем. Все значения ниже этой величины будут допустимыми, а которые выше – недопустимыми. На основе этого правила подготовим выходные критерии для классификации (рис. 4.31). Опыты будут проводиться при различных количествах нейронов. В данном случае это будет 10, 15 и 20 нейронов.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	0	0	1	0	0	1	1	1	0	0	0	1	0	0	1
2	1	1	0	1	1	0	0	0	1	1	1	0	1	1	0

Рис. 4.31 Выходные данные

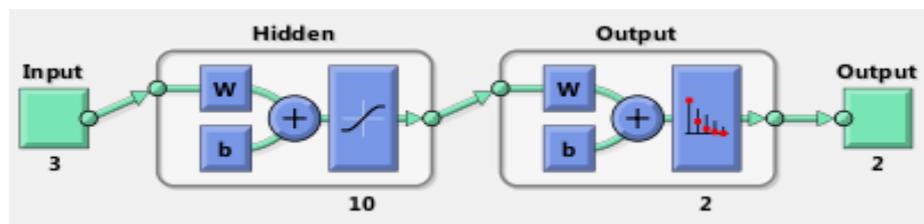


Рис. 4.32 Структура сети

Графики итогов обучения и ошибок сети с 10 нейронами представлены на рисунках 4.33 – 4.38.

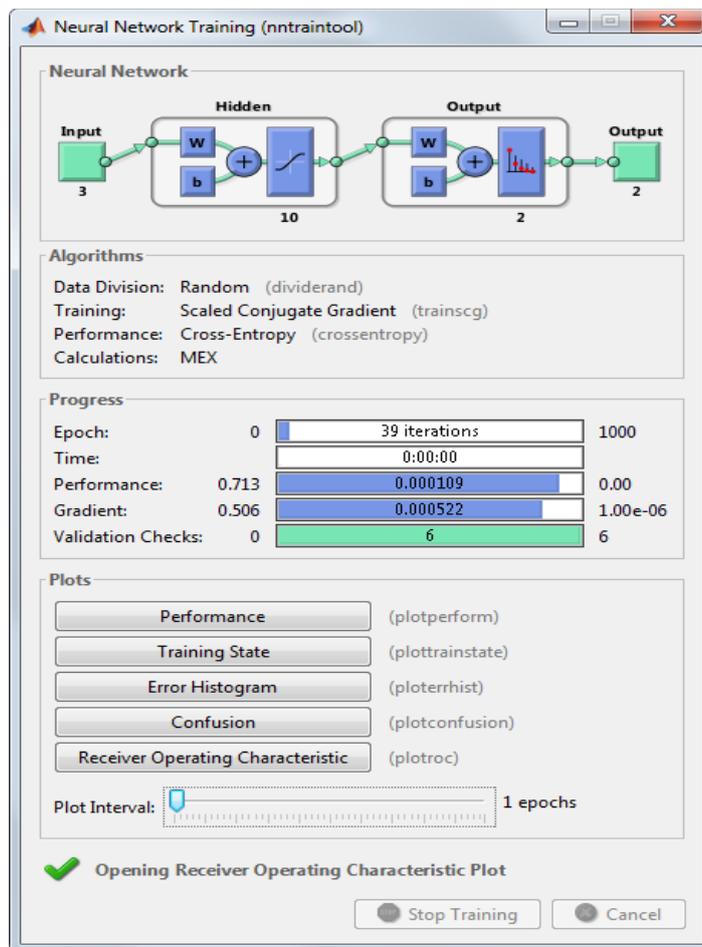


Рис. 4.33 Окно процесса обучения при 10 нейронах

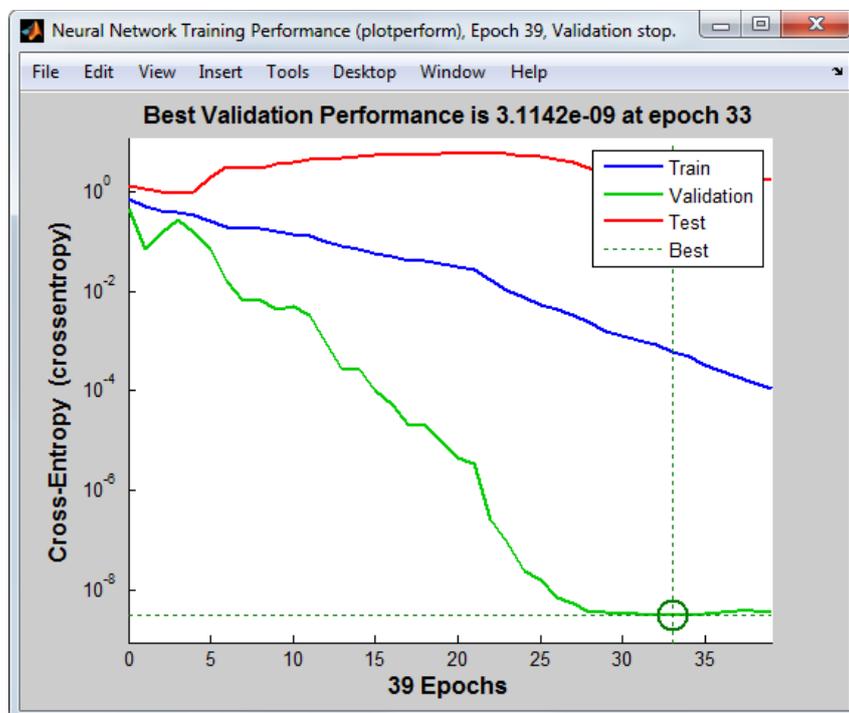


Рис. 4.34 График обучения распознавания при 10 нейронах

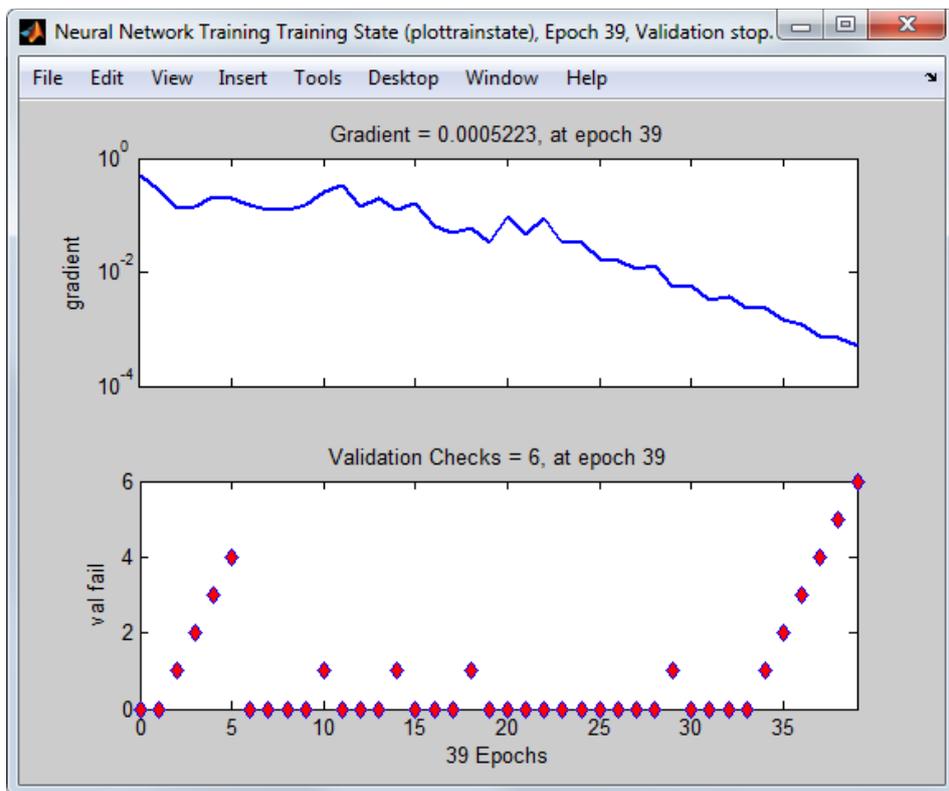


Рис. 4.35 График состояния обучения при 10 нейронах

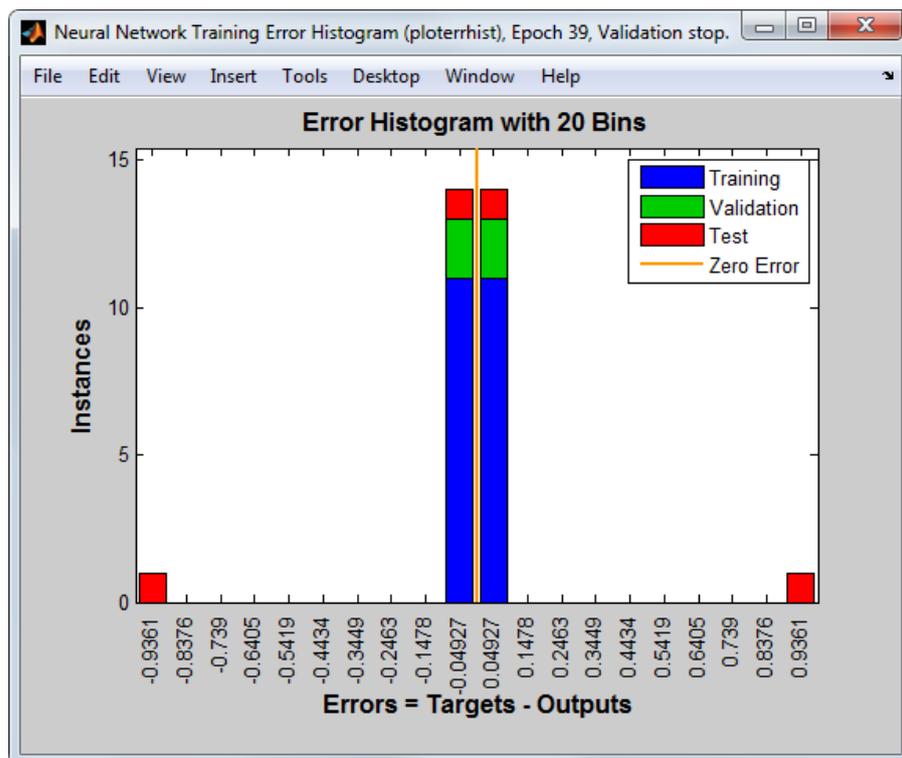


Рис. 4.36 Гистограмма ошибок при 10 нейронах



Рис. 4.37 Матрица несоответствий при 10 нейронах

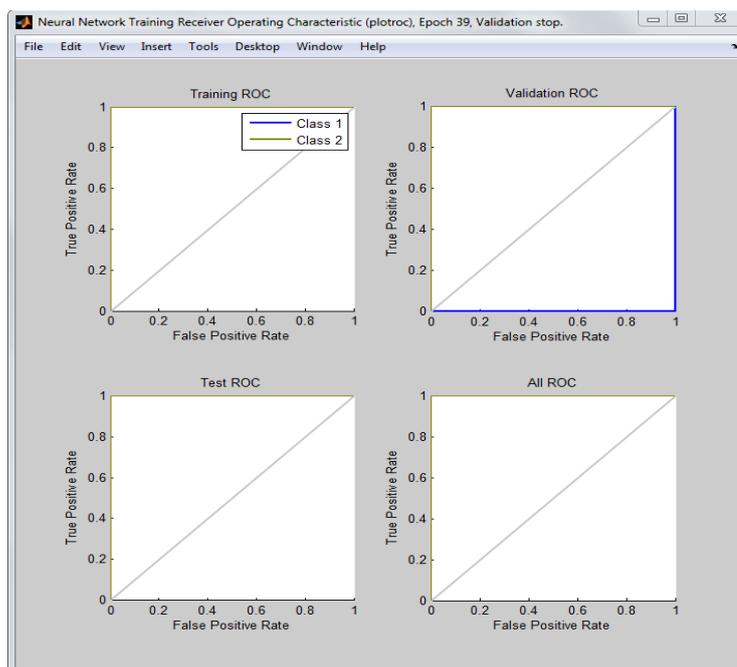


Рис. 4.38 Характеристические кривые обнаружения при 10 нейронах

Данная модель прошла обучение на 33 эпохе. Ошибка представлена на узком диапазоне значений, но имела место быть во многих примерах. Также сеть ошиблась в одном случае тестового множества. Данная точность

неприемлема, т.к. нужна абсолютная точность. Данная модель не подходит для практического применения.

Графики итогов обучения и ошибок сети с 15 нейронами представлены на рисунках 4.39 – 4.44.

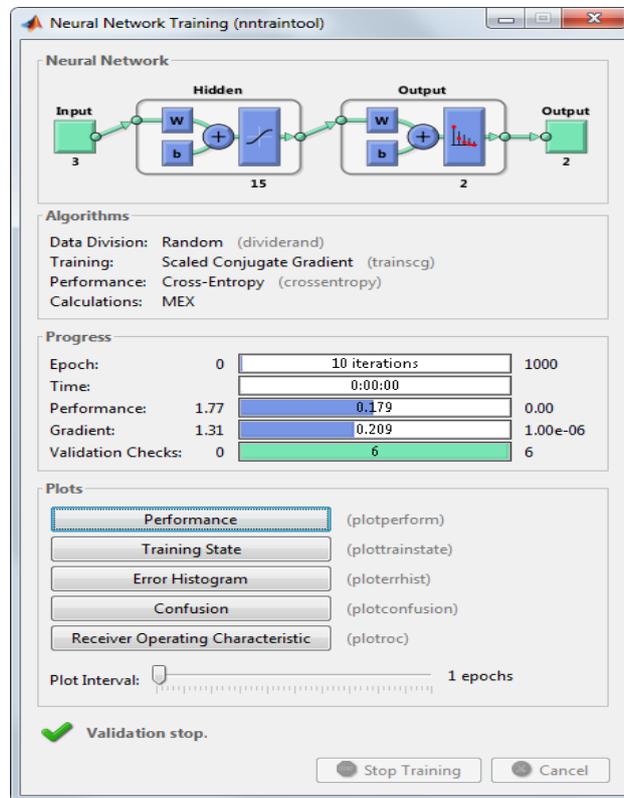


Рис. 4.39 Окно процесса обучения при 15 нейронах

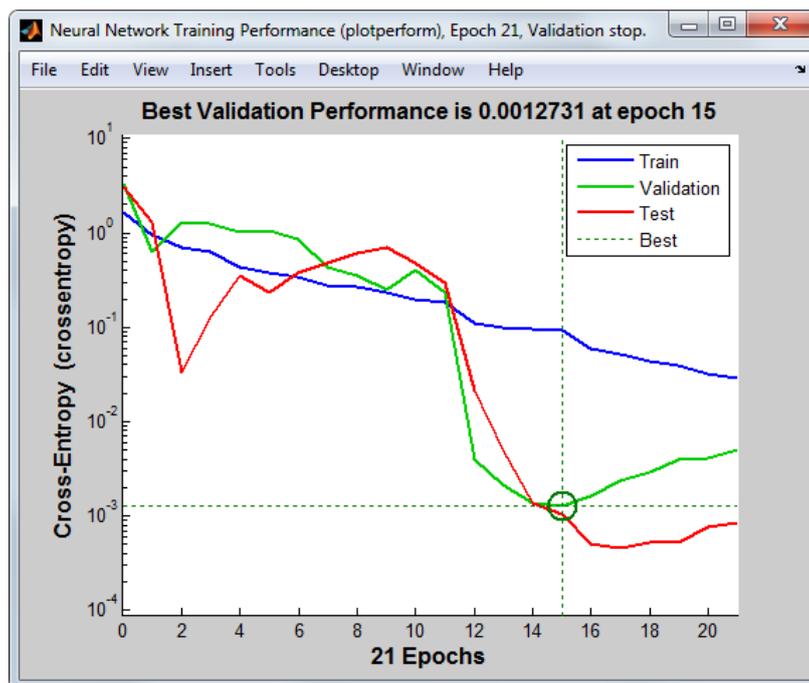


Рис. 4.40 График обучения распознавания при 15 нейронах

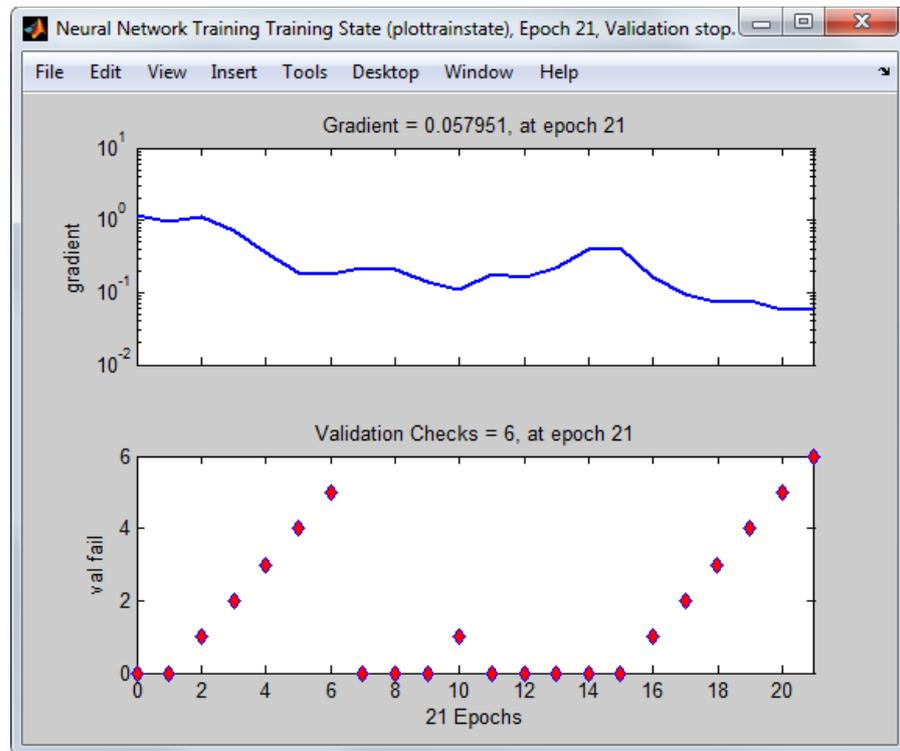


Рис. 4.41 График состояния обучения при 15 нейронах

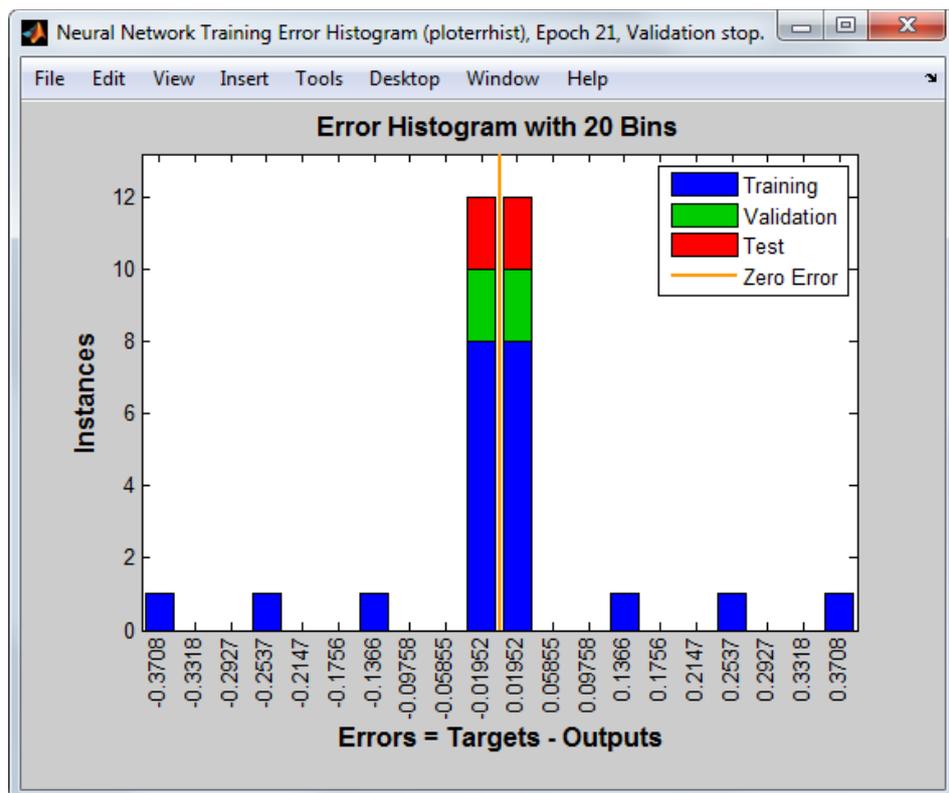


Рис. 4.42 Гистограмма ошибок при 15 нейронах



Рис. 4.43 Матрица несоответствий при 15 нейронах

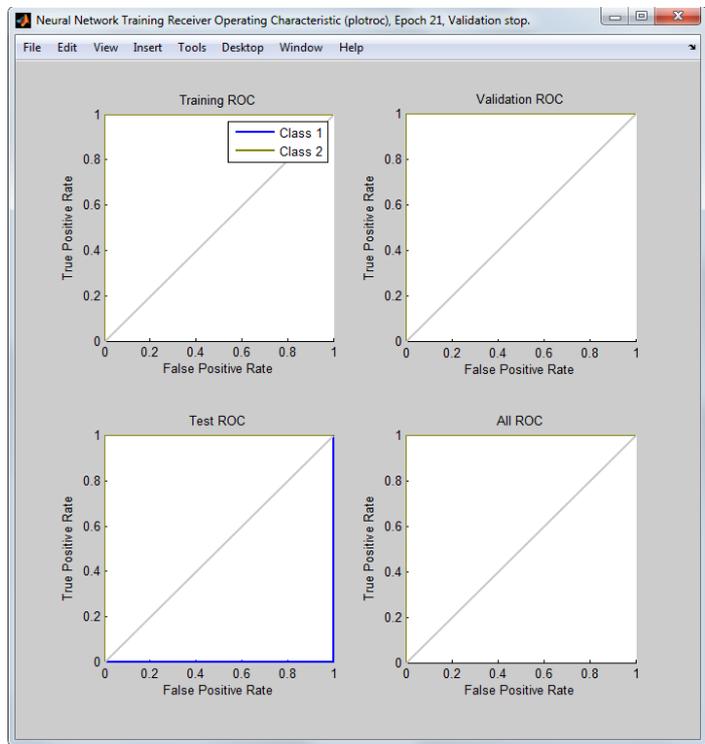


Рис. 4.44 Характеристические кривые обнаружения при 15 нейронах

Данная модель справилась с задачей за 15 эпох. Основная ошибка представлена только в двух значениях и в меньшем количестве примеров. Она точно определила все значения по классам. Эта модель наиболее предпочтительна для практического применения.

Графики итогов обучения и ошибок сети с 20 нейронами представлены на рисунках 4.45 – 4.50.

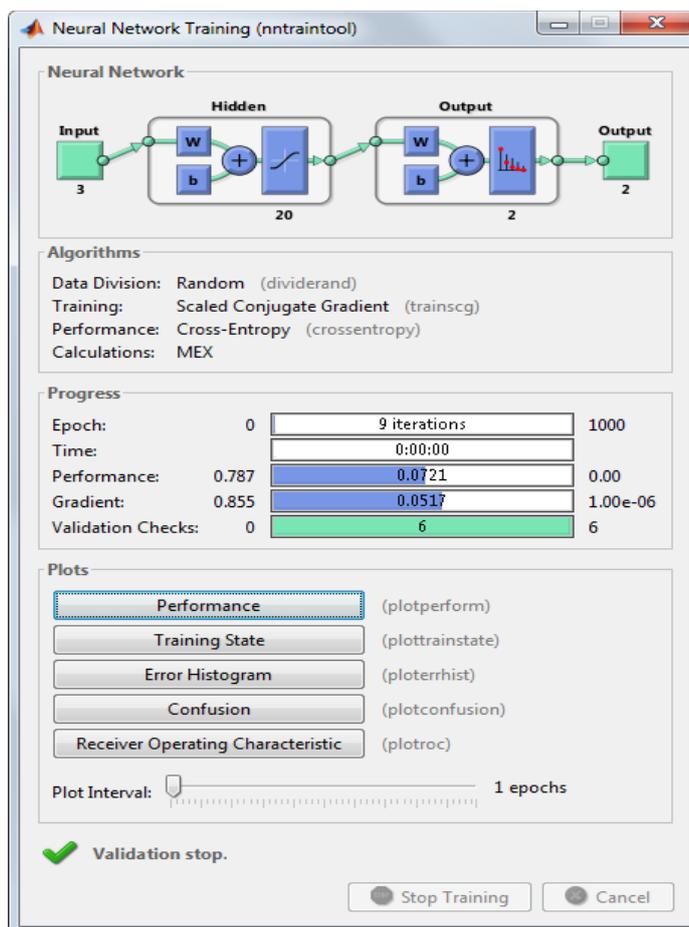


Рис. 4.45 Окно процесса обучения при 20 нейронах

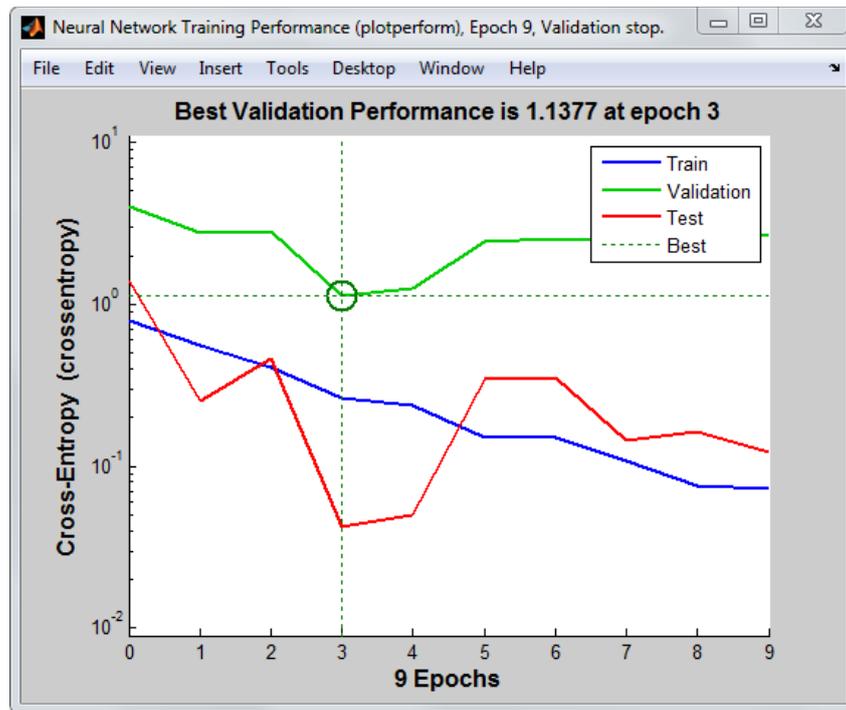


Рис. 4.46 График обучения распознавания при 20 нейронах

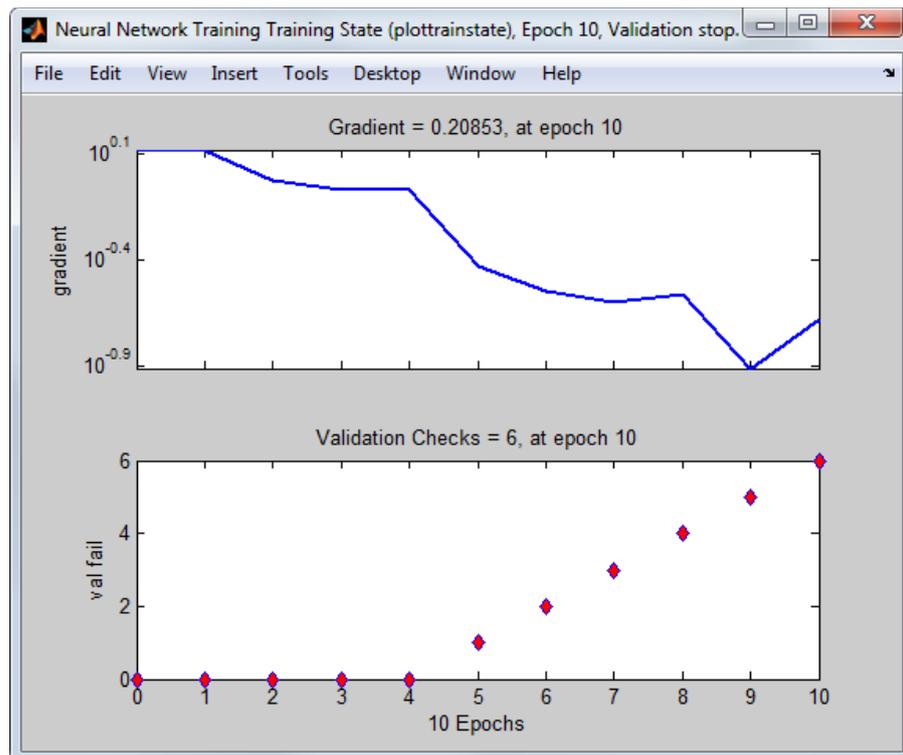


Рис. 4.47 График состояния обучения при 20 нейронах

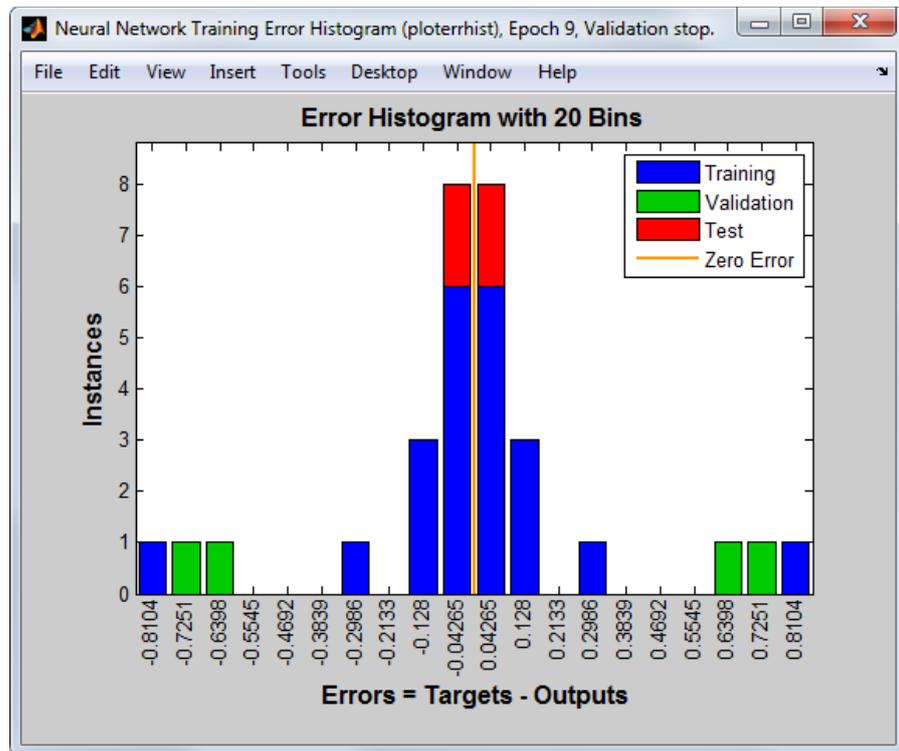


Рис. 4.48 Гистограмма ошибок при 20 нейронах

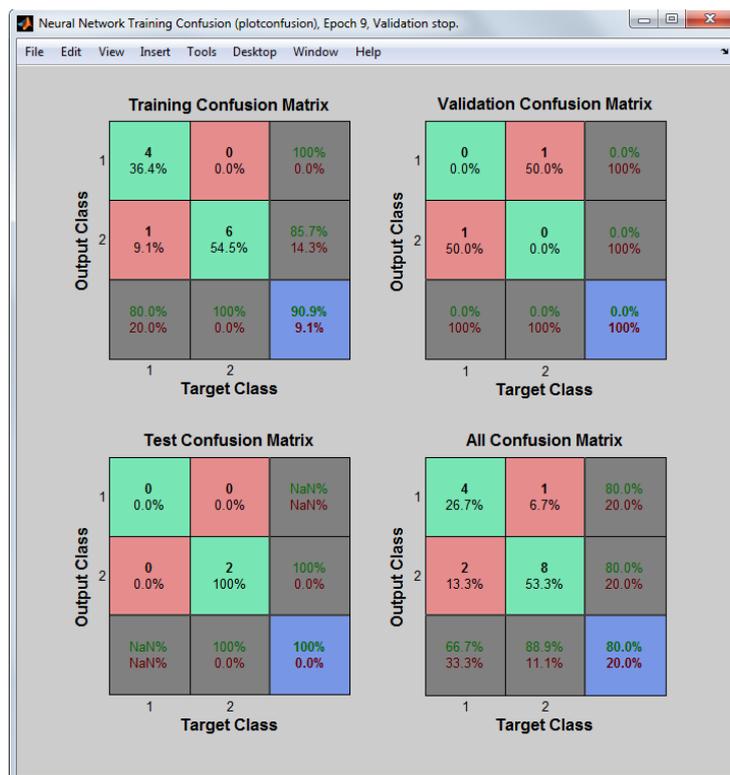


Рис. 4.49 Матрица несоответствий при 20 нейронах

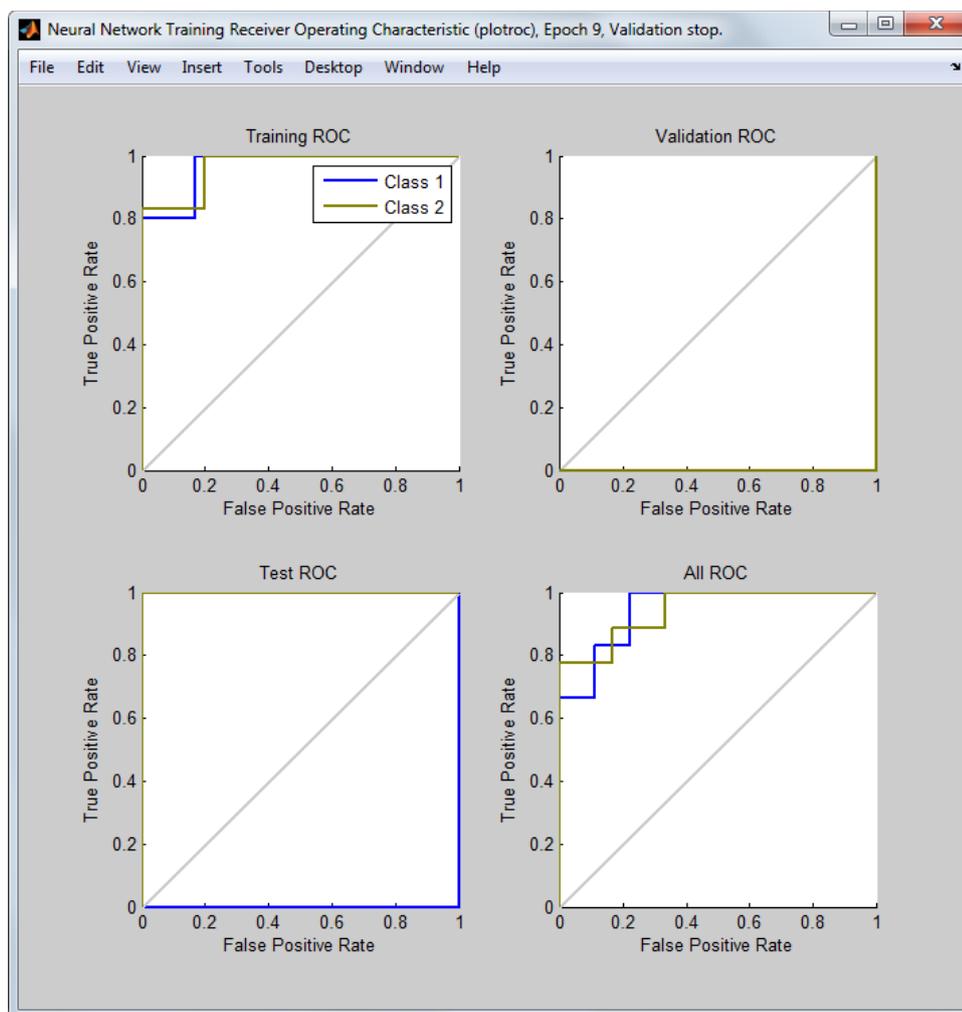


Рис. 4.50 Характеристические кривые обнаружения при 20 нейронах

Данная модель справилась с обучением всего за 3 эпохи, но ошибки в обучающих и проверяющих множествах делает её абсолютно неприменимой на практике.

Модель с 15 нейронами полностью справилась с обучением и затратила на это относительно немного времени. Её можно использовать для классификации параметров процесса ТСО при его проектировании. Это поможет быстро отсеивать те величины входных параметров, которые не приведут к нужному результату. И наоборот, при задании необходимого результата, сеть сразу покажет какие параметры помогут его получить. Это упростит и ускорит проектирование процессов.

ЗАКЛЮЧЕНИЕ

В данной магистерской диссертации были рассмотрены и решены следующие задачи:

1. Провели общий анализ принципов работы сетью, её устройства, видов, типов и видов обучения, на основании которого делали выводы о более предпочтительных, для решения поставленных задач, параметрах.

2. Провели анализ процесса ТСО , причин и преимуществ его использования и проблемы распределения упругопластических деформаций, на основании которого делались выводы об основных параметрах влияющих на деформации и задачах, которые можно решить при помощи ИНС.

3. Построили поэтапный алгоритм для работы с сетью для задач по классификации и аппроксимации, на котором показаны все этапы обучения сети под ту или иную задачу.

4. Провели обучение сети с различными параметрами для задачи аппроксимации нелинейной зависимости, и выбрали оптимальную модель для её решения и которую можно применять на практике для решения подобных задач.

5. Провели обучение сети в программе ANFIS, на основе результатов которой можно составить алгоритм управления ТСО с помощью данной программы.

6. Провели обучение сети с различными параметрами для задачи классификации входных сигналов, и выбрали наилучшую модель для её решения и которую можно применять на практике для решения подобных задач.

СПИСОК ИСПОЛЬЗУЕМЫХ ИСТОЧНИКОВ

1. Терехов В. А., Ефимов Д. В., Тюкин И. Ю. Нейросетевые системы управления. — М.: Высшая школа, 2002. — 184 с. — ISBN 5-06-004094-1.
2. Журавлев Ю. И., Рязанов В. В., Сенько О. В. «Распознавание». Математические методы. Программная система. Практические применения. — М.: Фазис, 2006. ISBN 5-7036-0108-8.
3. Вятчинин Д. А. Нечёткие методы автоматической классификации. — Минск: Технопринт, 2004. — 219 с.
4. Патент РФ №2254383. Способ термосиловой обработки длинномерных осесимметричных деталей и устройство для его осуществления/Д.А. Расторгуев, О.И. Драчев, Д.Ю. Воронов. - №2003136837/02; заявл. 19.12.2003; опубл. 20.06.2005, Бюл. №17. – 12 с.
5. Драчев, О.И. Моделирование упруго-пластических деформаций при термосиловой обработке/ О.И. Драчев, Д.А. Расторгуев, М.В. Старостина //Вектор науки Тольяттинского государственного университета. –2012. –№ 3. –С. 80-85.
6. Haykin, S. Neural Networks and Learning Machines// Mc Master University. – Canada, 2008. - p. 936.
7. Саттон Ричард С., Барто Эндрю Г. Обучение с подкреплением. — М.: БИНОМ. Лаборатория знаний, 2017. — 399 с. — ISBN 978-5-94774-351-7.
8. Драчев, О.И. Новая технология термосиловой обработки маложестких валов/О.И. Драчев, Д.Ю.Воронов, Д.А. Расторгуев// Известия Волгоградского государственного технического университета. 2004. № 1. С. 32-35.
9. Штовба, С.Д. Проектирование нечетких систем средствами MATLAB/ С.Д. Штовба . – М.: Горячая линия – Телеком, 2007. – 288 с.

10. Reddy N. S. Temperature Deformation Behavior of Ti-6Al-4V Alloy with an Equiaxed Microstructure: a Neural Networks Analysis/ N. S. Reddy, You-Hwan Lee//Metals and materials International, Vol. 14, No. 2 (2008), pp. 213-221.
11. Горбань А. Н. Обобщенная аппроксимационная теорема и вычислительные возможности нейронных сетей // Сибирский журнал вычислительной математики, 1998, т. 1, № 1. — С. 12—24.
12. Горина, Л.Н. Методические указания к дипломному проектированию / Л.Н. Горина. – Тольятти: ТГУ, 2003г. – 17с.
13. Сигеру Омату, Марзуки Халид, Рубия Юсоф. Нейроуправление и его приложения. 2-е изд. — М.: ИПРЖР, 2000. — 272 с. ISBN 5-93108-006-6.
14. Драчев, О.И. Повышение эффективности обработки маложестких валов при комбинированном термосиловом нагружении/О.И. Драчев, Д.А. Расторгуев, М.В. Старостина //Металлообработка. 2012. № 3 (69). С. 30-35.
15. Гасс, В.В. Повышение эффективности термосиловой обработки на основе нейросетевого моделирования: Бакалаврская работа. Тольятти: ТГУ, 2016.- 69 с.
16. Нейроинформатика / Горбань А. Н., Дунин-Барковский В. Л. [и др.]. — Новосибирск: Наука, 1998.
17. Драчев, О.И. Экспериментальная установка для равномерного осевого пластического деформирования маложестких деталей при термосиловой обработке/О.И. Драчев, Д.Ю.Воронов, Д.А. Расторгуев// Известия Волгоградского государственного технического университета. 2004. № 9. С. 15-18.
18. Уоссермен, Ф. Нейрокомпьютерная техника: Теория и практика. — М.: Мир, 1992. — 240 с. — ISBN 5-03-002115-9.
19. Еремин Д. М., Гарцеев И. Б. Искусственные нейронные сети в интеллектуальных системах управления. — М.: МИРЭА, 2004. — 75 с. ISBN 5-7339-0423-2.
20. Терехов, В.А. Нейросетевые системы управления/ В.А. Терехов, Д.В. Ефимов, И.Ю. Тюкин. – М.: Высш. шк. 2002. – 183 с.

21. Jitender K. Mill-cut: a neural network system for the prediction of thermo-mechanical loads induced in end-milling operations/ K. Jitender, Villedieu L., Xirouchakis P./Int. J. Adv. Manuf. Technol. (2008) 37: pp. 256–264.
22. Оссовский, С. Нейронные сети для обработки информации/С. Оссовский - Издательство: Финансы и статистика М. 2002 .-345 с.
23. Мак-Каллок, У. С., Питтс, В. Логическое исчисление идей, относящихся к нервной активности // Автоматы / Под ред. К. Э. Шеннона и Дж. Маккарти. — М.: Изд-во иностр. лит., 1956. — С. 363—384.
24. Патент РФ №2232198. Устройство для термосиловой обработки/ Д.А. Расторгуев, О.И. Драчев, Д.Ю. Воронов/ - 2003113840/02; заявл. 12.05.2003; опубл. 10.07.2004.
25. Cirstea, M. Neural and Fuzzy Logic Control of Drives and Power Systems/ A. Dinu, J. Khor, M. McCormick// Newnes. 2002.- p. 400.
26. Вороновский Г. К., Махотило К. В., Петрашев С. Н., Сергеев С. А. Генетические алгоритмы, искусственные нейронные сети и проблемы виртуальной реальности. — Харьков: Основа, 1997. — 112 с. ISBN 5-7768-0293-8.
27. Медведев, В.С. Нейронные сети. Matlab 6/ В.С. Медведев, В.Г.Потемкин. Издательство: Диалог МИФИ - 2002 . – 496 с.
28. Гудфеллоу Я., Бенджио И., Курвилль А. Глубокое обучение. — М.: ДМК-Пресс, 2017. — 652 с. ISBN 978-5-97060-554-7.
29. Леоненков, А.В. Нечеткое моделирование в среде MATLAB и fuzzyTECH/ А.В.Леоненков. – Спб.:БХВ-Петербург, 2003. – 736 с.
30. Николенко С., Кадуриин А., Архангельская Е. Глубокое обучение. — СПб.: Питер, 2018. — 480 с. ISBN 978-5-496-02536-2.
31. Sun Y. Prediction of Tensile Property of Hydrogenated Ti600 Titanium Alloy Using Artificial Neural Network/ Y. Sun, W.D. Zeng, X.M. Zhang, Y.Q. Zhao, X. Ma//Journal of Materials Engineering and Performance.- Volume 20(3) April 2011 – pp. 345-350

ПРИЛОЖЕНИЯ

Министерство образования и науки Российской Федерации
федеральное государственное бюджетное образовательное учреждение
высшего образования
«Тольяттинский государственный университет»

**ПРИКЛАДНАЯ
МАТЕМАТИКА И ИНФОРМАТИКА:
СОВРЕМЕННЫЕ ИССЛЕДОВАНИЯ
В ОБЛАСТИ ЕСТЕСТВЕННЫХ
И ТЕХНИЧЕСКИХ НАУК**

*Материалы
IV научно-практической международной конференции
(школы-семинара) молодых ученых*

В двух частях

ЧАСТЬ 1



Тольятти
2018

УДК 001.8
ББК 72.52
П759

П759 Прикладная математика и информатика: современные исследования в области естественных и технических наук: Сборник научных статей IV научно-практической международной конференции (школы-семинара) молодых ученых : 23-25 апреля 2018 г. В двух частях. – Тольятти : Издатель Качалин Александр Васильевич, 2018.

ISBN 978-5-6041225-1-8

Часть 1 : Материалы пленарных докладов, секций I, II. – 604 с.

ISBN 978-5-6041225-2-5

В авторской редакции.

В сборнике представлены материалы по проблемам междисциплинарных исследований в области математики, теоретической и прикладной информатики, экономики, социологии.

Цель сборника – привлечение молодых ученых к научно-исследовательской деятельности, обмен научными результатами и исследовательским опытом.

Сборник адресован научным сотрудникам, преподавателям, аспирантам и студентам различных специальностей.

Конференция проводится при финансовой поддержке РФФИ (проект 18-31-10012\18)

УДК 001.8
ББК 72.52

ISBN 978-5-6041225-2-5 (ч.1)
ISBN 978-5-6041225-1-8

© Авторы статей, 2018
© ФГБОУ ВО «Тольяттинский
государственный университет», 2018

<i>И.И. Валиев</i>	МЕТОД УСЛОВНОГО ГРАДИЕНТА ДЛЯ ЗАДАЧИ МИНИМИЗАЦИИ ГЛАДКОЙ ФУНКЦИИ НА ПЕРЕСЕЧЕНИИ СФЕРИЧЕСКОЙ ПОВЕРХНОСТИ И ВЫПУКЛОГО КОМПАКТА.....	228
<i>Ф.А. Венедиктов, А.А. Гольшвейга</i>	МОДЕЛИРОВАНИЕ КРИТЕРИЯ ОПТИМАЛЬНОСТИ СИСТЕМ АВТОМАТИЧЕСКОГО РЕГУЛИРОВАНИЯ НА ОСНОВЕ КВАДРАТИЧНОЙ ИНТЕГРАЛЬНОЙ ОЦЕНКИ КАЧЕСТВА	233
<i>Т.В. Ветлугина</i>	НЕКОТОРЫЕ СВОЙСТВА ОТКЛОНЕНИЙ УСТОЙЧИВЫХ РЕШЕНИЙ РАЗНОСТНОГО УРАВНЕНИЯ С ЗАПАЗДЫВАНИЕМ	238
<i>А.М. Войтович</i>	ПРИМЕНЕНИЕ СТОХАСТИЧЕСКОЙ АППРОКСИМАЦИИ ДЛЯ АДАПТАЦИИ РЕГРЕССИОННЫХ МОДЕЛЕЙ.....	241
<i>Р.Р. Галин, Н.С. Лебедекина</i>	АЛГОРИТМ ИНТЕГРАЛЬНОЙ ОЦЕНКИ ЭФФЕКТИВНОСТИ ГОСУДАРСТВЕННОГО УПРАВЛЕНИЯ В СФЕРЕ МОЛОДЕЖНОЙ ПОЛИТИКИ.....	245
<i>Г.М. Ганзев, К.А. Терещенко, А.С. Зиганишина, Н.В. Улитин, В.П. Захаров</i>	УСТАНОВЛЕНИЕ КИНЕТИЧЕСКИХ ПАРАМЕТРОВ ПОЛИМЕРИЗАЦИИ ИЗОПРЕНА НА КАТАЛИТИЧЕСКОЙ СИСТЕМЕ $TiCl_4-Al(i-C_4H_9)_3$ С ПРЕДВАРИТЕЛЬНЫМ ФОРМИРОВАНИЕМ РЕАКЦИОННОЙ СМЕСИ В ТРУБЧАТОМ ТУРБУЛЕНТНОМ АППАРАТЕ.....	251
<i>В.В. Гасс</i>	НЕЙРОСЕТЕВОЙ ПОДХОД ДЛЯ МОДЕЛИРОВАНИЯ ТЕРМОСИЛОВОЙ ОБРАБОТКИ	257
<i>С.Н. Гвоздева, В.С. Титов</i>	ПРИМЕНЕНИЕ НЕИНВЕРТИРУЮЩИХ ДИФФЕРЕНЦИАТОРОВ ДЛЯ ФОРМИРОВАНИЯ ОБРАЗЦОВЫХ СИГНАЛОВ В ПРЕОБРАЗОВАТЕЛЯХ ПАРАМЕТРОВ МНОГОЭЛЕМЕНТНЫХ ДВУХПОЛЮСНИКОВ	263
<i>О.В. Гермидер, В.Н. Попов</i>	ИЗОТЕРМИЧЕСКОЕ ТЕЧЕНИЕ РАЗРЕЖЕННОГО ГАЗА В ПРЯМОМ ЭЛЛИПТИЧЕСКОМ ЦИЛИНДРЕ	268
<i>А.В. Горячева, Е.Ю. Лискина</i>	МОДЕЛИРОВАНИЕ ВЛИЯНИЯ КРИЗИСОВ НА УЧЕТНУЮ ЦЕНУ ОБЕЗЛИЧЕННОГО МЕТАЛЛИЧЕСКОГО СЧЕТА «ЗОЛОТО».....	273

Список использованных источников

1. Минскер К.С. Гидродинамическое воздействие на каталитическую систему $TiCl_4-Al(i-C_4H_9)_3$ при полимеризации изопрена / К.С. Минскер, В.П. Захаров, И.В. Садыков, И.А. Ионова, Ал.Ал. Берлин, Ю.Б. Монаков // Вестник Башкирского Университета. – 2003. – №3-4. – С. 29-31.
2. Захаров В.П. Молекулярные характеристики цис-1,4-полиизопрена при формировании каталитической системы $TiCl_4-Al(i-C_4H_9)_3$ в турбулентном режиме / В.П. Захаров, И.В. Садыков, К.С. Минскер, Ал.Ал. Берлин, Ю.Б. Монаков // Высокомолекулярные соединения. – 2004. – Т. 46. – С. 1765-1769.
3. Мингалева В.З. Стереоспецифическая (со)полимеризация 1,3-диенов при формировании микрогетерогенных титановых и неодимовых катализаторов в турбулентных потоках: дис. ... д-ра. хим. наук / В.З. Мингалева. – Уфа, 2014. – 377 с.
4. Бигаева Л.А. Полуаналитический метод решения обратных задач кинетики ионно-координационной полимеризации: дис. ... к-та. физ.-мат. наук / Л.А. Бигаева. – Уфа, 2009. – 160 с.

УДК 621.78.01

В.В. Гасс

**НЕЙРОСЕТЕВОЙ ПОДХОД ДЛЯ МОДЕЛИРОВАНИЯ
ТЕРМОСИЛОВОЙ ОБРАБОТКИ**

Научный руководитель: Д.А. Расторгуев, к.т.н., доцент

Тольяттинский государственный университет

(Россия, г. Тольятти, wait.94@mail.ru)

Для обеспечения прямолинейности оси валов, труб разработан способ термосиловой обработки (ТСО) [1-3]. Он характеризуется приложением силы для деформации заготовки при ее нагреве. Основная задача при этом – формирование равномерных и минимальных остаточных напряжений, что позволит сохранить геометрию детали в эксплуатационный период.

Процесс ТСО отличается сложностью протекания термомеханических процессов, трудностью контроля технологических

параметров, неопределенностью и не полнотой исходных данных (распределение физико-механических свойств, структуры материала, химического состава). Это приводит к трудностям моделирования такого процесса [4]. Использование методов искусственного интеллекта позволяет упростить процесс. На основе нейронных сетей (НС) предлагается создать модель с использованием экспериментальных данных [5, 6].

За входные параметры взяли три технологических параметра ТСО: температура нагрева, величина и скорость деформации. Для характеристики эффективности проведения ТСО определялся коэффициент локальности, который определяет равномерность деформирования заготовки по длине.

На основе различных НС было проведено моделирование с изменением количества нейронов, находящихся в скрытом слое и по минимуму полученной ошибки обучения делались выводы [6].

Значения входных параметров и коэффициентов локальности, полученные в конце экспериментов приведены в табл. 1 и 2. Поверхности зависимостей коэффициента локальности от технологических факторов - на рис.1.

Таблица 1

Значения технологических параметров термосиловой обработки

№ эксперимента	1	2	3	4	5	6
Температура, °С	500	300	500	500	500	300
Величина деформации	4	4	4	6	8	4
Скорость деформации, с ⁻¹	5.640	0.720	4.350	1.160	1.470	2.050

Продолжение таблицы 1

7	8	9	10	11	12	13	14	15
300	300	500	400	400	400	300	300	400
6	8	8	8	6	4	6	8	6
2.160	4.080	1.890	0.587	1.130	2.900	1.900	0.870	3.970

Таблица 2

Коэффициент локальности

№ эксперимента	1	2	3	4	5	6
Значение коэффициента	4.065	10.638	1.754	6.578	5.208	3.745

Продолжение таблицы 2

7	8	9	10	11	12	13	14	15
2.941	1.876	4.048	8.658	4.310	2.645	4.032	8.849	1.923

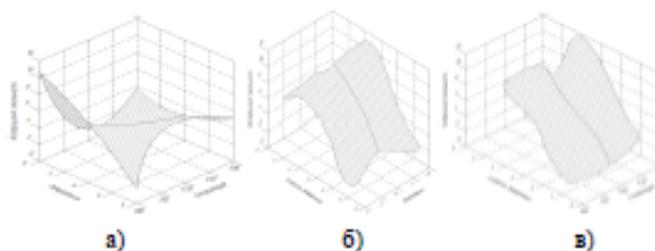


Рис. 1. Коэффициент локальности в координатах: а – деформация-температура; б – скорость деформации – деформация; в – скорость деформации – температура

На рис. 2 показаны результаты моделирования нагружения ступенчатой заготовки при ТСО в системе ANSYS из которых видна локальность деформирования, связанная с особенностями геометрии вала.

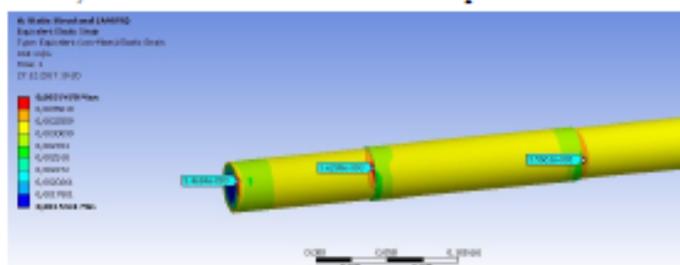


Рис. 2. Распределение пластических деформаций после процесса ТСО

Перед обучением НС была выполнена обработка данных по следующим формулам (нормирование) (табл. 3):

$$T = \frac{T_i}{T_{max}}, \text{ } ^\circ\text{C}; \quad (1)$$

$$\varepsilon = \frac{\varepsilon_i}{\varepsilon_{max}}; \quad (2)$$

$$\dot{\varepsilon} = \frac{\dot{\varepsilon}_i}{\dot{\varepsilon}_{max}}, \text{ } \text{с}^{-1}; \quad (3)$$

где T_{max} – максимальная температура по всем экспериментам, $^\circ\text{C}$;

T_i – температура в i -том эксперименте, $^\circ\text{C}$;

ε_i – величина деформации в i -том эксперименте, %;

ε_{max} – максимальная величина деформации по всем экспериментам, %;

$\dot{\varepsilon}_i$ – скорость деформации в i -том эксперименте, с^{-1} ;

$\dot{\varepsilon}_{max}$ – максимальная скорость деформации по всем экспериментам, с^{-1} .

Таблица 3

Обработанные данные по входным параметрам

№ эксперимента	1	2	3	4	5	6
Температура, $^\circ\text{C}$	1	0.600	1	1	1	0.600
Величина деформации	0.500	0.500	0.500	0.750	1	0.500
Скорость деформации, с^{-1}	1	0.127	0.771	0.206	0.260	0.363

Продолжение таблицы 3

7	8	9	10	11	12	13	14	15
0.600	0.600	1	0.800	0.800	0.800	0.600	0.600	0.800
0.750	1	1	1	0.750	0.500	0.750	1	0.750
0.383	0.723	0.335	0.104	0.200	0.514	0.337	0.154	0.704

Из графиков (см. рис. 1) видна существенная нелинейность зависимости коэффициента от входных параметров, которую НС должна аппроксимировать. Для обучения использовалась НС прямого распространения сигнала (см. рис. 3). В скрытом слое использовалось 10, 15 и 20 нейронов. Функции активации скрытого слоя – сигмоидальная, выходного – линейная.

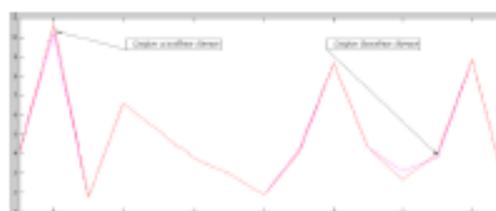


Рис. 5. График данных обучения

Исследован сложный процесс ТСО. Получена математическая модель на основе НС сети прямого распространения сигнала с 15 нейронами в скрытом слое.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Драчев О.И. Новая технология термосиловой обработки маложестких валов/О.И. Драчев, Д.Ю.Воронов, Д.А. Расторгуев// Известия Волгоградского государственного технического университета. 2004. № 1. С. 32-35.
2. Драчев О.И. Повышение эффективности обработки маложестких валов при комбинированном термосиловом нагружении/О.И. Драчев, Д.А. Расторгуев, М.В. Старостина //Металлообработка. 2012. № 3 (69). С. 30-35.
3. Патент РФ №2232198. Устройство для термосиловой обработки/ Д.А. Расторгуев, О.И. Драчев, Д.Ю. Воронов/ - 2003113840/02; заявл. 12.05.2003; опубл. 10.07.2004.
4. Драчев О.И. Моделирование упруго-пластических деформаций при термосиловой обработке/О.И. Драчев, Д.А. Расторгуев, М.В. Старостина //Вектор науки Тольяттинского государственного университета. –2012. –№ 3. –С. 80-85.
5. Haykin S. Neural Networks and Learning Machines// Mc Master University. – Canada, 2008. - p. 936.
6. Медведев В.С. Нейронные сети. Matlab 6/ В.С. Медведев, В.Г.Потемкин. Издательство: Диалог МИФИ - 2002 . – 496 с.