

МОДЕЛИРОВАНИЕ НЕЙРОСЕТИ ДЛЯ РЕШЕНИЯ ЗАДАЧ КЛАСИФИКАЦИИ В ДЕФЕКТОСКОПИИ

Аннотация. Проведено моделирование трехслойной нейронной сети прямого распространения для решения задач классификации сигналов в дефектоскопии.

Ключевые слова: нейронные сети, многослойный персептрон, обучение на основе обратного распространения.

Введение. Задача идентификации (процессов, систем, сигналов) или построение математической модели по результатам наблюдений занимает одно из главных мест в современной теории управления и принятия решений в разных областях науки и техники. Традиционные подходы становятся все менее пригодными. Большинство процессов не могут быть описано с помощью традиционных статистических моделей, поскольку они являются нелинейными и обладают слабыми адаптивными способностями[1, 2].

В настоящее время эти проблемы решают с помощью искусственных нейронных сетей. Нейронные сети – это математические модели, состоящие из элементарных единиц обработки информации (нейронов), накапливающих экспериментальные знания и предоставляющих их для последующей обработки. К важнейшим свойствам нейронных сетей относятся параллельность обработки информации одновременно всеми нейронами, способность к обучению, абстрагированию и обобщению полученных знаний. Наличие таких характеристик обеспечивает получение ожидаемой реакции сети применительно к соответствующим данным, нечувствительность нейронной сети к малым изменениям входных сигналов, а также возможность работы с искаженными вариантами анализируемых объектов[3].

Проблемы классификации являются одними из наиболее часто возникающих и решаемых задач в производственной деятельности. Их решение заключается в разработке таких правил и закономерностей, которые позволили бы распознать определённые явления или объекты и определить их принадлежность к каким-то классам (груп-

пам, категориям). На основе многочисленных исследований подтверждено, что нейронные сети обеспечивают высокую эффективность распознавания[4] .

Целью данной работы является построение и исследование модели нейронной сети для решения задач классификации зашумленных сигналов, получаемых при сканировании композитных материалов

Основные положения. При проведении неразрушающего контроля композитных материалов измерительные сигналы имеют различную форму. Форма сигнала дает представление о характере трещины. Можно выделить три вида сигналов: унимодальный, унимодальный с пологой вершиной и бимодальный. В свою очередь композитные материалы отличаются сложным рельефом поверхности и изменениями объемной электрической проводимости, при проведении контроля возникают шумы различной интенсивности, что значительно усложняет процесс получения надежного сигнала дефекта. Появляется проблема распознать сигнал и его классифицировать.

Для решения задачи идентификации и классификации предлагается использовать искусственные нейронные сети[5, 6]. Каждая искусственная нейронная сеть представляет собой множество соединённых определённым образом простых элементов - нейронов, это в результате даёт огромную вычислительную мощность параллельной обработки данных. Конкретный вид выполняемого нейронной сетью преобразования данных обуславливается не только характеристиками входящих в её структуру нейронов, но и особенностями её архитектуры, а именно топологией межнейронных связей, направлением и способами передачи информации между нейронами, а также способами обучения сети.

В задаче классификации нейронная сеть должна отнести каждое наблюдение к одному из классов или, в общем случае, оценить вероятность принадлежности наблюдения к каждому из классов. В ситуации, когда классифицируемый входной сигнал не соответствует ни одному из образцов (например, нарушен случайными помехами), в нейронных сетях производится процесс распознавания, а позже в результате распознавания - классификация.

Для классификации в работе используется многослойные нейронные сети прямого распространения. Такие нейронные сети пред-

ставляют собой нелинейные системы, позволяющие гораздо лучше классифицировать линейно-неразделимые данные, чем обычно используемые статистические методы. Многослойный персептрон (multilayer perceptron - MLP) состоит из множества входных узлов (узлов источника), которые образуют входной слой, одного или нескольких скрытых слоев вычислительных нейронов и одного выходного слоя нейронов, при этом сигнал распространяется по сети в прямом направлении от входного через скрытые к выходному слою. При обучении MLP используется алгоритм обратного распространения ошибки (back-propagation learning) [6]. Суть этого алгоритма заключается в следующем:

- во время прямого распространения генерируется набор выходных сигналов, который является реакцией сети на предъявляемый входной образ, при этом все синаптические веса нейронов остаются фиксированными;

- во время обратного прохода все синаптические веса настраиваются в соответствии с правилом коррекции ошибок, при котором фактический выход вычитается из желаемого отклика, в результате чего формируется сигнал ошибки;

- сигнал ошибки распространяется по сети в обратном направлении, подстраивая все синаптические веса нейронов с целью максимального приближения выходного сигнала сети к желаемому [6].

Каждый нейрон MLP обучаемого на основе обратного распространения имеет нелинейную гладкую (всюду дифференцируемую) функцию активации,

Наличие в многослойном персептроне скрытых нейронов позволяет сети обучаться решению сложных задач, последовательно извлекая наиболее важные признаки из входного образа (вектора). Многочисленные эксперименты показывают, что обучение на основе обратного распространения хоть и позволяет получить высокую точность классификации, однако требует недопустимо большого (для решения практических задач) времени обучения. Поэтому обратное распространение использует различные алгоритмы оптимизации для сокращения времени обучения.

Применение градиентного алгоритма обучения является специфической реализацией градиентного спуска в пространстве весовых коэффициентов и смещений MLP и обеспечивают движение по по-

верхности функционала ошибки в направлении, противоположном вектору градиента. К ним относятся алгоритмы: градиентного спуска с параметром скорости обучения (настройки) – GD (traingd); градиентного спуска с адаптацией параметра скорости обучения – GDA (trainгда); пороговый алгоритм с эвристической стратегией изменения приращения настраиваемых параметров – Rprop (trainrp) [6, 7].

Формально все алгоритмы градиентного спуска можно записать в следующем виде:

$$w_{k+1} = w_k - \alpha_k g_k \quad (1)$$

где w_k – вектор весовых коэффициентов;

α_k – параметр скорости обучения;

g_k – вектор градиента функционала ошибки.

Переходя от k -й итерации к $k+1$ -й, алгоритм выполняет коррекцию весовых коэффициентов:

$$\Delta w_k = w_{k+1} - w_k = -\alpha_k g_k, \quad (2)$$

Из (2) следует, что метод градиентного спуска работает на основе линейной аппроксимации функции стоимости в окрестности текущей точки w_k , при которой единственным источником информации о поверхности ошибок является градиент g_k . Такое ограничение обеспечивает значительное преимущество – простоту реализации. К сожалению, оно приносит и нежелательный результат – низкую скорость сходимости.

В работе применяется алгоритм GDA, который использует эвристическую стратегию изменения параметра α в процессе обучения. На каждом цикле обучения вычисляются значения настраиваемых параметров и новые значения выходов и погрешностей. Новые значения сравниваются со значениями, полученными на предыдущем шаге. Если новая погрешность меньше прежней, то параметр скорости настройки увеличивается, и наоборот.

Анализ результатов экспериментальных исследований. Для моделирования нейронной сети использовался инструмент Neural Networks Toolbox пакета прикладных программ MATLAB 6.5, поскольку он довольно гибкий, обеспечен широким набором команд и функций для проектирования и исследования нейронных сетей [7].

Для моделирования сигналов, получаемых при сканировании композитных материалов, используется разность экспонент [8] в точках $x = -2, -1.9, \dots, 2$:

$$y(x) = \exp(-1,5x^2) - k \cdot \exp(-3x^2) \quad (3)$$

где k изменяется от 0 до 1. Используя различные значения k , можно получить такие формы сигналов дефектоскопии: узкий унимодальный сигнал (характерен для длиной трещины, длина которой превышает зону контроля), пологий унимодальный и бимодальный (характерен для коротких трещин и точечных дефектов).

Модель структуры нейронной сети для распознавания сигналов приведена на рис. 1, где $IW\{1,1\}$, $LW\{2,1\}$, $LW\{3,2\}$ – весовые матрицы входного, скрытого и выходного слоев, соответственно; $b\{1\}$, $b\{2\}$, $b\{3\}$ – векторы смещения входного, скрытого и выходного слоев, соответственно; $p1$ – входной информационный векторный массив; y – выходной векторный массив; $a1$, $a2$, $a3$ – массивы значений функций активации первого, скрытого и выходного слоев, соответственно.

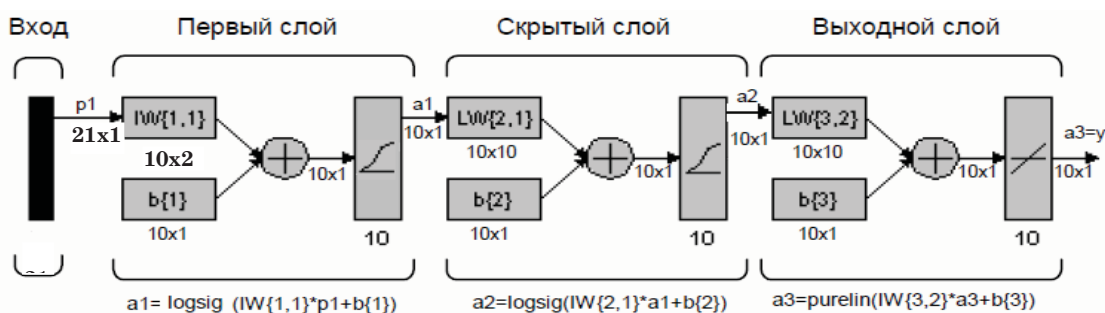


Рисунок 1 - Структурная схема нейронной сети

Для решения поставленной задачи сформирована трехслойная сеть обратного распространения, включающая 21 нейрон во входном слое (по числу компонент входного вектора) с передаточной функцией logsig , 10 нейронов во втором слое с логистической сигмоидальной функцией logsig и 3 нейрона в выходном слое (по числу компонент выходного вектора) с линейной функцией purelin . Входной и выходной слою преимущественно осуществляют подготовку данных для дальнейшего использования, а также преобразование полученных результатов. Скрытый слой выполняет все основные вычисления, и его функцией активации может быть логистическая сигмоидальная или гиперболический тангенс.

Чтобы нейронная сеть могла обрабатывать искаженные векторы входа, выполним ее обучение на идеальных и на искаженных векторах. Обучение выполняется с помощью функции `traindga`, которая реализует метод обратного распространения ошибки с адаптацией параметра скорости настройки.

Сначала проведем обучение сети при отсутствии шума с максимальным количеством циклов обучения 200 или до достижения допустимой средней квадратичной погрешности, которая равняется 0.01. Как видно на рис. 2 сеть научилась уже после 86 эпох (циклов).

Затем проведем обучение при наличии шума. Искаженные векторы имеют шум со средним значением 0.1 и 0.2. При обучении с шумом максимальное количество циклов обучения оставим прежним, а допустимую погрешность увеличим до 0.06 (рис.3).




Рисунок 2 - Обучение сети при отсутствии шума

Оценим эффективности функционирования созданной нейронной сети. Тестирование реализуется следующим образом. Шум со средним значением 0 и стандартным отклонением от 0 до 0,3 с шагом 0,05 добавляется к векторам входа. Для каждого уровня шума формируется 10 зашумленных сигналов и вычисляется выход сети. После этого оценивается количество ошибочных классификаций и вычисляется процент ошибки. Соответствующий график погрешности сети от уровня шума приведен на рис. 4.

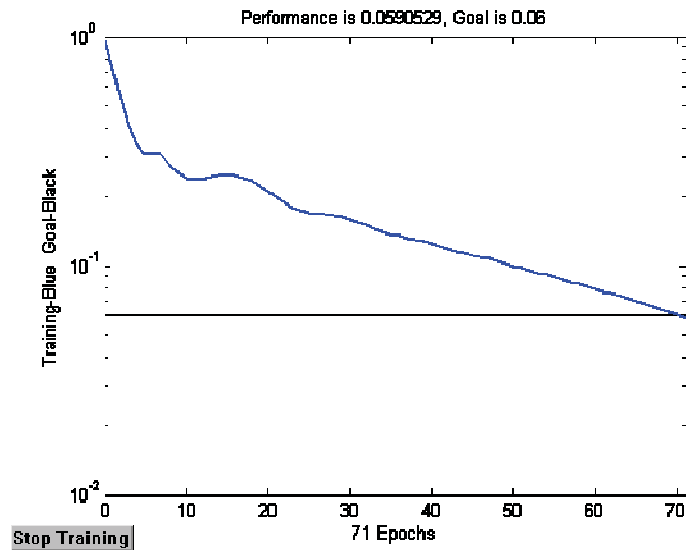


Рисунок 3- Обучение сети при наличии шума

Сеть имеет маленькую погрешность, если среднеквадратичное значение шума находится в пределах от 0 до 0.1. С увеличением уровня шума процент ошибок резко возрастает.

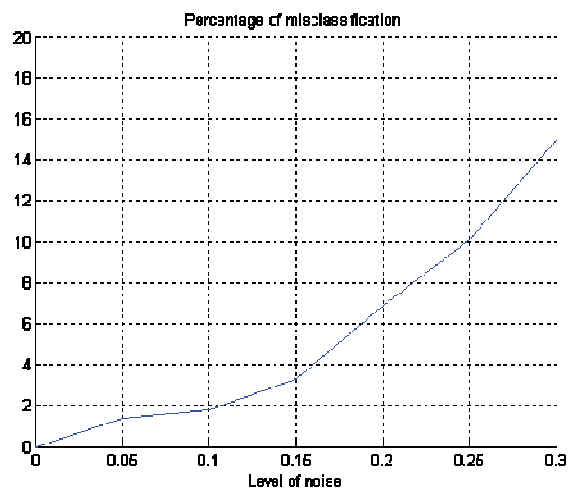


Рисунок 4 - Зависимость погрешности сети от уровня входного шума

Выводы. Исследована модель нейронной сети – многослойный персептрон – для классификации сигналов дефектоскопии. Обучение нейронной сети на разных наборах искаженных векторов позволило научить ее работать с искаженными данными, что характерно для реальных сигналов.

ЛИТЕРАТУРА

1. Биргер И.А. Техническая диагностика. - М.: Машиностроение, 1978.
2. Горелик А.Л., Скрипкин В.А. Методы распознавания. - М.: Высшая школа, 1989.- с.
3. Хайкин С.. Нейронные сети: полный курс, 2-е изд., испр.: Пер. с англ. – М.: Издательский дом «Вильямс», 2006. – 1104 с.
4. Стариков А.В. Практическое применение нейронных сетей для задач классификации (кластеризации) // BaseGroup. – 2000 (www.basegroup.ru).
5. Аксенов С.В. Организация и использование нейронных сетей (методы и технологии) / С.В. Аксенов, В.Б. Новосельцев – Томск: Изд-во НТЛ, 2006.
6. Дьяконов В., Круглов В. Математические пакеты расширения MATLAB. Специальный справочник. – СПб.: Питер, 2001. – 480 с.
7. Медведев В.С. Нейронные сети. MATLAB 6 / В.С. Медведев, В.Г. Потемкин – М.: ДИАЛОГ-МИФИ, 2002. – 496 с
8. Хандецкий В.С. Спектральная идентификация сигналов в дефектоскопии композитов с использованием теории статистических испытаний / Хандецкий В.С., Герасимов В.В. // Вісник ДНУ: Фізика. Радіоелектроніка. – Дніпропетровськ: – 2003. № 10. – С. 128 – 132

Получено 15.01.2011г.