

ВЕРОЯТНОСТНЫЕ НЕЙРОННЫЕ СЕТИ В ЗАДАЧАХ КЛАССИФИКАЦИИ ДЕФЕКТОВ

Аннотация. Рассмотрены возможность применения вероятностных нейронных сетей для классификации сигналов дефектоскопии. Обученная нейронная сеть промоделирована на проверочном множестве зашумленных сигналов.

Ключевые слова: вероятностные нейронные сети, классификация образов, ядерная функция.

Введение. Задача распознавания несплошностей и принятие решения о годности изделий до недавних пор целиком была возложена на человека, осуществляющего контроль изделий. Существуют характерные особенности формы сигнала от дефектов различного типа. Опытные специалисты часто используют эту информацию для принятия решения о браке – распознают сигналы прибора НК.

Нейросетевые методы [1, 2], активно развивающиеся в последнее время, обладают универсальностью, адаптивными свойствами и обеспечивают высокую эффективность распознавания. Но, в свою очередь, характеризуются такими недостатками, как длительность и сложность процесса обучения, сложность подбора параметров нейронной сети для уверенного решения задачи, логическая непрозрачность механизма принятия решений.

Перспективными отмечаются радиально-базисные структуры, отличающиеся высокой скоростью обучения и универсальными аппроксимирующими возможностями [3, 4]. К этим структурам относятся и вероятностные нейронные сети, которые имеют ряд существенных преимуществ и используются в различных задачах классификации образов.

Целью данной работы является исследование возможности использования вероятностных нейронных сетей в задачах классификации сигналов дефектоскопии в режиме реального времени.

Основные положения. При проведении неразрушающего контроля композитных материалов получаются сигналы различной формы. Форма сигнала дает представление о характере дефекта. При этом следует учитывать сложный рельеф поверхности композитных материалов. Из-за шероховатости поверхности материалов возникают шумы различной интенсивности. Возникает проблема распознать форму сигнала, и, соответственно, вид дефекта.

Применение различных методов распознавания образов проводит к классификации объектов по нескольким классам. С этой целью применяется аппарат вероятностных нейронных сетей(PNN – Probabilistic Neural Network). Такие сети представляют собой параллельную реализацию статистических методов Байеса. В PNN образцы классифицируются на основе оценок их близости к соседним образцам. При этом используется ряд критериев статистических методов, на основе которых принимается решение о том, к какому классу отнести еще не классифицированный образец. Формальным правилом при классификации является то, что класс с более плотным распределением в области неизвестного образца, а также с более высокой априорной вероятностью и с более высокой ценой ошибки классификации, будет иметь преимущество по сравнению с другими классами. Для оценки функции плотности распределения вероятностей используются непараметрические методы оценки. Как правило, применяют метод Парцена, в соответствии с которым для каждого учебного образца рассматривается некоторая весовая функция, которую еще называют функцией потенциала или ядра. Чаще всего в качестве ядерных функций берут упрощенные функции Гаусса:

$$f(X) = e^{-\frac{|X-X_i|^2}{2\sigma^2}} \quad (1)$$

где X_i – i -ый образец одного из распознаваемых классов, $i = \overline{1, L}$, X – неизвестный образец, σ - параметр, задающий ширину(отклонение) ядерной функции Гаусса и определяющий ее влияние. Чтобы определить функцию плотности распределения вероятностей для всего k -го класса, функции Гаусса для всех учебных векторов суммируются:

$$\phi(X) = \sum_{i=1}^{L_k} e^{-\frac{|X-X_i|^2}{2\sigma^2}}, \quad (2)$$

где L_k – объем обучающей выборки k -го класса.

Вероятностная нейронная сеть содержит, по меньшей мере, три слоя: входной, радиальный и выходной. Входной слой сети расчетов не выполняет и служит для приема и деления признаков входного вектора. Количество нейронов входного слоя определяется количеством признаков вектора X . Слой образцов содержит по одному нейрону для каждого образца входного вектора из обучающей выборки. То есть при общем объеме обучающей выборки, которая содержит L образцов, этот слой должен иметь L нейронов. Входной слой и слой образцов образуют полно связную структуру.

Слой суммирования содержит количество нейронов, равное количеству классов, на которые разбиваются входные образы. Каждый нейрон слоя суммирования имеет связи только с нейронами слоя образцов, которые относятся к соответствующему классу. Все веса связей слоя суммирования в традиционной вероятностной нейронной сети приравниваются единицам.

Исходный нейрон выполняет функции дискриминатора пороговой величины. Он указывает, какой нейрон слоя суммирования имеет максимальный выходной сигнал. Тем самым определяется класс, к которому принадлежит представленный входной образ. Веса связей нейрона исходящего слоя устанавливаются так, чтобы на его выходе идентифицировался нейрон слоя суммирования с наибольшим значением активности.

Предъявление сети каждого из L образцов сопровождается указанием от учителя номера k -го класса, которому принадлежит входящий образец. Последовательность предъявления обучающих образцов может быть любой. После предъявления всех L векторов обучающей выборки, формируется структура сети, и параметры сети определены в виде матрицы. На этом процесс обучения вероятностной нейронной сети завершается и сеть готова к классификации неизвестных образцов.

В рабочем режиме сети подается входной образ X неизвестного класса, который сначала нормализуется, а потом умножается на матрицу весов и соответствующим образом активизирует нейроны слоя образцов. Каждый нейрон слоя образцов показывает на своём выходе некоторый уровень активности $y_i(X)$. Каждый k -ый нейрон слоя суммирования складывает равные активности $y_i(X)$ всех нейронов слоя образцов своего k -го класса. Этот нейрон показывает на своём

выходе общий уровень активности данного k -го класса $y^k(X)$, $k = \overline{1, L}$, определяет, какой нейрон слоя суммирования имеет максимальный выходной сигнал $y^k(X)$. Таким образом, по номеру k -го нейрона определяется номер класса k , к которому с большей вероятностью принадлежит образ X . Таким образом, вероятностные нейронные сети принадлежат к классу нейронных сетей с учителем.

Практическая реализация. При сканировании изделий из композитных материалов пространственная база получаемых сигналов ограничена снизу диаметром зоны электромагнитного контроля. Поскольку амплитуда сигналов в каждой точке абсциссы определяется проекцией дефекта изделия на плоскость, перпендикулярную направлению вихревых токов, то информативной характеристикой таких сигналов есть их площадь.

Плавное изменение формы сигнала от унимодального с максимальной амплитудой (когда дефекты превышают зону контроля) до бимодального с наибольшим провалом вершины (точечные дефекты) моделируется с помощью выражения:

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

где k изменяется от 0 до 1, а x от -2 до 2 с шагом 0.1 . Изменяя значения k , можно получить различные формы сигналов дефектоскопии: узкий унимодальный, пологий унимодальный и бимодальный.

Площадь модельного сигнала является информативной характеристикой сигналов вихревоковой дефектоскопии и вычисляется путем интегрирования выражения (3) по абсциссе от $-\infty$ до $+\infty$, и является разностью известных [8] площадей под двумя ненормированными гауссовыми кривыми со значениями параметра $\sigma = 1 / \sqrt{3}$ и $\sigma' = 1 / \sqrt{6}$:

$$Q = \sqrt{\frac{2\pi}{3}} \left(1 - \frac{\sqrt{2}}{2} k \right), \quad (4)$$

где Q измеряется в квадратных относительных единицах длины, приведенной к эквивалентному диаметру катушки вихревокового преобразователя.

Для моделирования сигналов с шумом к выражению (3) добавляются случайные величины, распределенные по нормальному закону со средним значением 0 и среднеквадратичным отклонением от 0 до

0,2 с шагом 0,05 [6]. Для вычисления площади таких сигналов используем формулу трапеций[8].

Продемонстрируем использование вероятностной нейронной сети для классификации сигналов, получаемых при сканировании композитных материалов. Используя выражения (3) и (4), подсчитаем площади для модельных сигналов. Из них выбираем 7 значений, определяющих 41-компонентные вектора входов, и соотнесем каждый из них с одним из трех классов. Слой образцов имеет 7 нейронов: по 2 для первого и второго классов и 3 – для третьего класса. Слой суммирования содержит три нейрона, в соответствии с числом классов, на которые разбиваются входные векторы.

На полученном обучающем множестве промоделируем сеть и убедимся, что она правильно решает задачу классификации.

Выполним классификацию на элементах тестового множества, которое состоит из значений площадей зашумленных сигналов.

Результаты классификации представлены на рис. 1 и показывают, что три представляемых сети вектора, отмеченные звездочками, классифицируются сетью РНН, состоящей из семи нейронов, абсолютно правильно.

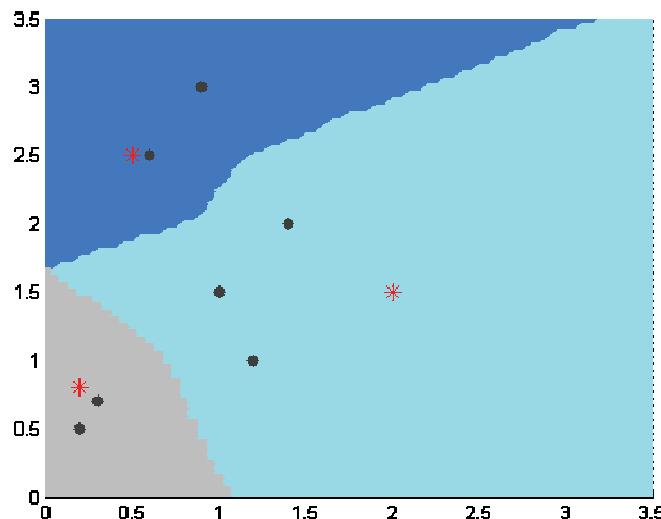


Рисунок 1 - Результаты классификации

Для оценивания эффективности функционирования созданной нейронной сети проведем ее тестирование. Шум со средним значением 0 и стандартным отклонением от 0 до 0,2 с шагом 0,05 добавляется к векторам входа. Для каждого значения шума проведем 100 измерений и определим значение долей неправильно классифицированных сигналов:

$$P = \frac{n}{N} \times 100, \%$$

где n – число неправильно классифицированных сигналов, N – их общее количество.

Таблица

Количество неправильно классифицированных сигналов

Значение шума, σ	0	0,05	0,1	0,15	0,2
P	0	0	11	23	35

Выводы. В данной работе проанализированы возможности применения вероятностных нейронных сетей для классификации зашумленных сигналов при проведении неразрушающего контроля. Эти сети отличаются высокой скоростью обучения, что позволяет использовать их в режиме реального времени.

ЛИТЕРАТУРА

1. Аксенов С.В. Организация и использование нейронных сетей (методы и технологии) / С.В. Аксенов, В.Б. Новосельцев – Томск: Издво НТЛ, 2006. – 128 с.
2. Хайкин Саймон. Нейронные сети: полный курс, 2-е издание.: Пер. с англ. – М.: Издательский дом «Вильямс», 2006
3. Тихонов Е. В. Методы и алгоритмы прогнозирования экономических показателей на базе нейронных сетей и модулярной арифметики / Е. В. Тихонов, В. А. Кузьмищев. – Невинномысск: НИЭУП, 2004. – 166 с.
4. Сигеру О. Нейроуправление и его приложения / О. Сигеру. – М.: ИПРЖР, 2001. – 321 с.
5. 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
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. Бронштейн И.Н. Справочник по математике для инженеров и учащихся втузов/ И.Н. Бронштейн, К.А. Семенджяев – М.: Наука, 1986.

Получено 19.01.2011г.