

## НЕЙРОННЫЕ СЕТИ В ЗАДАЧАХ КЛАССИФИКАЦИИ ДЕФЕКТОВ

*Аннотация.* Исследована возможность применения нейронной сети Кохонена для классификации сигналов дефектоскопии. Обученная нейронная сеть промоделирована на проверочном множестве зашумленных сигналов.

*Ключевые слова:* нейронная сеть Кохонена, классификация сигналов, самообучение.

**Введение.** Задача определения дефектности изделий и принятие решения о годности связана с интенсивным использованием человеческого интеллекта и квалифицированного труда. Перспективным является использование методов искусственного интеллекта для решения этой задачи в автоматическом режиме без участия человека. Среди таких методов высокую эффективность продемонстрировали искусственные нейронные сети, и, прежде всего, самоорганизующиеся карты Т. Кохонена (*SOM - self organizing maps*)[1], положенные в основу автоматической классификации различных видов информации. Эффективность карт Кохонена определяется, прежде всего, их вычислительной простотой и возможностью работы в реальном времени путем последовательной обработки информации по мере ее поступления.

**Целью данной работы** является использование нейронных сетей Кохонена в задачах классификации зашумленных сигналов дефектоскопии.

**Теоретическое обоснование.** Стратегия метода построения *SOM* заключается в представлении множества экспериментальных данных в виде топологической карты – решетки размерностью  $n \times m$ , состоящей из нейронов. Каждый нейрон представляет собой вектор, определяющий в  $d$ -мерном пространстве признаков некоторую характерную точку. В результате реализации алгоритма обучения векторы нейронов распределяются в пространстве признаков, аппроксимируя

статистические взаимосвязи между данными обучающего множества [1,2].

В процессе работы алгоритма настраиваются синаптические веса нейронов. Для настройки сети определяется мера соседства нейронов (мера близости). Зоны соседства нейронов уменьшаются с течением времени. В начале обучения весовым коэффициентам сети присваиваются малые случайные значения

Общее число синаптических весов равно  $n \times m$ . Для всех нейронов вычисляется Евклидово расстояние до входного вектора и выбирается нейрон-

-победитель с наименьшим расстоянием. Затем производится подстройка весов для нейрона-победителя и всех нейронов из его зоны соседства. Модификации весов рассчитываются по формуле:

$$Wv(s + 1) = Wv(s) + \Theta(u, v, s) \alpha(s)(D(t) - Wv(s)), \quad (1)$$

где  $Wv(s)$  – значение весового коэффициента связи входного нейрона и выходного нейрона в момент времени  $s$ ,  $u$  – нейрон-победитель для  $D(t)$ ,  $\alpha(s)$  – шаг обучения, уменьшающийся с течением времени и  $D(t)$  – входной вектор. Функция соседства  $\Theta(u, v, s)$ , зависящая от расстояния решетки между нейроном -победителем (нейрон  $u$ ) и нейроном  $v$ . Далее предъявляется новое наблюдение и процесс повторяется.[1].

**Основная часть.** 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 интегральной информативной характеристикой таких сигналов есть их площадь.

Плавное изменение формы сигнала от унимодального с максимальной амплитудой (дефекты превышают зону контроля) до бимодального с наибольшим провалом вершины (точечные дефекты) моделируется с помощью выражения[3]:

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

где  $(2^n - 1)$  – это максимальное значение сигнала  $n$ -разрядного АЦП.

В результате получаются сигналы различной формы: при  $k = 0 \div 0.35$  – узкий унимодальный сигнал, описывающий длинную трещину, длина которой превышает зону контроля. При изменении  $k = 0.35 \div 0.55$  получаем пологий унимодальный сигнал, характерный для трещин меньшей размерности; при  $k = 0.6 \div 1$  получаем бимодальный сигнал, который характерен для маленьких трещин (при  $k = 1$  – точечный дефект).

Площадь получаемых модельных сигналов вычисляется путем интегрирования выражения (2) по абсциссе от  $-\infty$  до  $+\infty$ , и является разностью известных [4] площадей под двумя ненормированными гауссовыми кривыми со значениями параметра  $\sigma = 1/\sqrt{3}$  и  $\sigma' = 1/\sqrt{6}$ :

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

где  $Q$  измеряется в квадратных относительных единицах длины, приведенной к эквивалентному диаметру катушки вихретокового преобразователя (ВТП).

В случае АЦП с разрядностью  $n=8$  площади соответствующих сигналов ВТП изменяются от минимального значения  $Q_n = 110.71$  до максимального  $Q_m = 369.036$ , после чего увеличение размеров дефектов не регистрируется.

**Практическая реализация.** Для моделирования использовалась вычислительная среда Matlab R2010b. В качестве обучающего множества для нейронной сети Кохонена использовались значения площадей модельных сигналов (3).

Для проверки качества классификации выбирались значения площадей зашумленных сигналов. Шум со средним значением 0 и стандартным отклонением от 0 до 0,3 с шагом 0,05 добавлялся к векторам входа. Для вычисления площади таких сигналов использовалась формула трапеций [4].

Самоорганизующаяся сеть Кохонена формировалась в виде одномерного слоя из 3 нейронов, в соответствии с числом классов дефектов. Выполнялось обучение на протяжении 200 итераций (рис. 1).




Рисунок 1- Моделирование сети Кохонена в Neural Networks Toolbox

Обученную нейронную сеть использовали для классификации входных векторов из проверочного множества (рис. 2).




Рисунок 2 - Распределение зашумленных сигналов

После классификации нейронная сеть выдавала такие результаты (рис.3):




Рисунок 3 - Распределение кластеров нейронной сети Кохонена

Для оценивания эффективности функционирования созданной нейронной сети проводилось ее тестирование на 1000 векторах входа для различных уровней шума и определялась доля неправильно классифицированных сигналов:

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

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

Таблица 1

Количество неправильно классифицированных сигналов

| Значение шума, $\sigma$ | 0 | 0,05 | 0,1 | 0,15 | 0,2  |
|-------------------------|---|------|-----|------|------|
| $P$                     | 0 | 3,4  | 8   | 15   | 25,4 |

**Выводы.** В данной работе проанализированы возможности применения нейронной сети Кохонена для классификации зашумленных сигналов при проведении неразрушающего контроля. Эти сети характеризуются тем, что настройка синаптических весов происходит в режиме самообучения, при этом каждый поступающий на вход сигнал вызывает адаптацию

тех или иных параметров искусственной нейронной сети. Это процесс может протекать непрерывно, обеспечивая возможность решения задачи в реальном времени.

### ЛИТЕРАТУРА

1. Kohonen T. Self-Organizing Maps / T. Kohonen // Berlin :Springer-Verlag. – 1995. – 362 p.
2. Хайкин Саймон. Нейронные сети: полный курс, 2-е издание.: Пер. с англ. – М.: Издательский дом «Вильямс», 2006
3. 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
4. Бронштейн И.Н. Справочник по математике для инженеров и учащихся втузов/ И.Н. Бронштейн, К.А. Семендяев – М.: Наука, 1986.