

ИСПОЛЬЗОВАНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ РЕШЕНИЯ ЗАДАЧ КЛАССИФИКАЦИИ В ДЕФЕКТОСКОПИИ

Аннотация. Представлены результаты исследования использования различных видов искусственных нейронных сетей для решения задач классификации сигналов в дефектоскопии.

Ключевые слова: вероятностные нейронные сети, сети Кохонена, LVQ-сети, дефект, классификация.

Введение. Одним из приоритетных направлений развития авиационной и космической техники на протяжении последних десятилетий является повышение уровня контроля пригодности изделий. Это в свою очередь связано с резким увеличением обрабатываемой информации, что значительно усложняет алгоритмы ее обработки, требует высокой квалификации эксперта, увеличивает время, необходимое на анализ информации и повышает вероятность ошибки.

Для уменьшения нагрузки на эксперта, повышения качества и оперативности определения дефектности изделий необходимо выполнять предварительный автоматизированный анализ полученной информации. Результатом такого анализа является классификация изделия (простейший случай – наличие или отсутствие дефекта).

Для решения сложных задач классификации все чаще используют нейронные сети, которые способны к моделированию различных процессов, адаптации и позволяют работать с зашумленными данными [1].

Целью данной работы является сравнительный анализ и оценка возможностей использования для решения задач классификации зашумленных сигналов различных видов нейронных сетей, в том числе вероятностной нейронной сети, нейронной карты Кохонена и LVQ-сети.

Основные положения. В авиационной и космической промышленности изделия изготавливаются с использованием композитных

материалов. При проведении неразрушающего контроля таких материалов получают сигналы различной формы. Форма сигнала дает представление о характере дефекта. При этом следует учитывать сложный рельеф поверхности композитных материалов, шероховатость поверхности добавляет шумы различной интенсивности. Это затрудняет распознавание формы сигнала, и, соответственно, вид дефекта.

Для решения задач распознавания формы сигнала и классификации типа дефекта предлагается использовать нейронные сети.

Каждая искусственная нейронная сеть представляет собой множество соединённых определённым образом простых элементов – нейронов. В результате это 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 [1].

В задаче классификации следует учитывать, что во входном векторе образов можно выделить несколько классов. 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 искусственных нейронных сетях производится процесс распознавания, а позже в результате распознавания – классификация.

Классификацию предлагается осуществлять с помощью таких нейронных сетей: вероятностной нейронной сети, сети Кохонена и LVQ-сети. Рассмотрим более подробно эти нейронные сети.

Вероятностные нейронные сети (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 -й 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:

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

где L_k – объем обучающей выборки k -го класса.

Вероятностная нейронная сеть содержит радиальный базисный и конкурирующий слои. Количество нейронов входа определяется количеством признаков вектора X . Слой образцов содержит по одному нейрону для каждого образца входного вектора из обучающей выборки. При общем объеме обучающей выборки длиной L образцов этот слой должен иметь L нейронов [1].

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. Вероятностные нейронные сети принадлежат к классу нейронных сетей «обучение с учителем».

Самоорганизующиеся карты Т. Кохонена (SOM - self organizing maps). Сети Кохонена принципиально отличаются от остальных. Они обучаются без надзора («обучение без учителя»), при котором обучающие данные содержат только значения входных переменных и не содержат соответствующие им выходные значения.

Стратегия метода построения SOM заключается в представлении множества экспериментальных данных в виде топологической карты, т.е. 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-нейроны 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:

$$W_{v(s+1)} = W_{v(s)} + \Theta(u, v, s) \alpha(s) \cdot (D(t) - W_{v(s)}), \quad (3)$$

где $W_{v(s)}$ – 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].

LVQ-сети. В основе LVQ (Learning Vector Quantization)-сети лежит механизм обучения конкурирующего слоя с использованием метода «обучение с учителем», когда заранее известно, к какому классу принадлежит каждый экземпляр выборки. Они являются развитием самоорганизующихся сетей Кохонена [1, 3].

LVQ-сеть состоит из двух последовательно соединенных слоев нейронов: конкурирующего и линейного. Конкурирующий слой используется для кластеризации векторов. Количество нейронов первого слоя соответствует длине вектора входа. Линейный слой обеспечивает соотнесение кластеров с целевыми классами, заданными пользователем. На каждый кластер во входном слое должен быть задан один нейрон, причём количество классов не должно быть больше количества кластеров.

Конкурирующий слой разделяет входные вектора x на классы, выделяя центры сосредоточения входных векторов m_i . Для этого определяют расстояние $n^1 = \|x - m_i\|$ между входными векторами x и начальными значениями центров сосредоточения векторов m_i , $i=1, 2, \dots, q$ (q – количество входных векторов).

Линейный слой преобразует класс входного вектора, определенный конкурирующим слоем $a1$ в класс определенный пользователем $a2$. Произведение $a1$ на значения весов LW линейных нейронов, которые установлены равными единице, если $a1$ и $a2$ совпадают, и нулем – если не совпадают. Соответствующие произведения $n^2 = a^1 LW$ подаются на выходы всех линейных нейронов, образуя вектор $a2$, все элементы которого равны 0, за исключением элемента, который отвечает классу, определенному пользователем (этот элемент вектора равен 1).

Чтобы сеть начала работать, необходимо провести обучение. Обучение LVQ-сети выполняется по алгоритмам LVQ1 и LVQ2 [3].

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 интегральной информативной характеристикой таких сигналов есть их площадь.

Плавное изменение формы сигнала от унимодального с максимальной амплитудой (дефекты превышают зону контроля) до бимодального с провалом вершины (точечные дефекты) моделируется с помощью выражения [2]:

$$y(x) = (2^n - 1) \cdot \exp(-1,5x^2) - k \cdot \exp(-3x^2), \quad (4)$$

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

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

Площадь получаемых модельных сигналов вычисляется путем интегрирования выражения (4) 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 $\sigma' = 1/\sqrt{6}$:

$$Q = (2^n - 1) \sqrt{\frac{2\pi}{3}} \left(1 - \frac{\sqrt{2}}{2} k\right) \quad (5)$$

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 $Q_{\min} = 110.71$ до максимального $Q_{\max} = 369.036$, после чего увеличение размеров дефектов не регистрируется.

Процесс обучения нейронных сетей и классификации дефектов реализовывался в среде Matlab R2010b[3]. Для всех типов нейронных сетей использовалось обучающее множество, состоящее из значений площадей модельных сигналов (5). Проверка качества обучения выполнялась на контрольных значениях площадей зашумленных сигналов.

Для моделирования сигналов с шумом к выражению (5) добавлялись случайные величины, распределенные по нормальному закону со средним значением 0 и среднеквадратичным отклонением от 0 до 0,2 с шагом 0,05 [3]. Для вычисления площади таких сигналов использовалась формула трапеций [4].

В случае использования вероятностной нейронной сети классификация сигналов выполнялась по трем классам: унимодальный, по-

логий унимодальный и бимодальный. Задавалось 10 векторов входа и, каждый из них, соотносился с одним из трех классов.

Самоорганизующаяся сеть Кохонена формировалась в виде одномерного слоя из 3 нейронов, в соответствии с числом классов дефектов. Выполнялось обучение на протяжении 200 итераций. Обученную нейронную сеть использовали для классификации зашумленных сигналов.

При использовании LVQ-сети конкурирующий слой состоял из 3 нейронов по числу кластеров, а линейный слой из 2 нейронов по числу классов, на которые разбивались площади зашумленных сигналов. Кластеры формировались по форме сигналов: унимодальный, пологий унимодальный та бимодальный. Количество выходных классов обусловлено наличием или отсутствием дефектов.

Если при проведении неразрушающего контроля композитного материала получали унимодальный или пологий унимодальный сигнал, то в изделии есть дефект. Бимодальный сигнал указывал на точечный дефект или на неточность измерений.

Проверку нейронных сетей для определения точности выявления дефектов осуществляли путем подачи на вход обученных нейронных сетей зашумленных сигналов. Для каждого значения шума выполнялось 1000 измерений и определились общие относительные ошибки работы:

$$P = \frac{n}{N} \times 100\% \quad (6)$$

где n – число ошибок распознавания, N – общее количество измерений. Результаты исследования приведены на рис. 1.




Рисунок 1 – Оценка погрешности работы нейронных сетей

Выводы. Проведенный анализ показал принципиальную возможность применения искусственных нейронных сетей для определения дефектности изделий из композитных материалов. На основании полученных погрешностей работы нейронных сетей для дальнейшей работы целесообразно использовать нейронные сети с более сложной структурой, а исследуемые в работе – использовать для предварительной обработки информации.

ЛИТЕРАТУРА

1. Хайкин Саймон. Нейронные сети: полный курс, 2-е издание.: Пер. с англ. – М.: Издательский дом «Вильямс», 2006.
2. Хандецкий В.С. Спектральная идентификация сигналов в дефектоскопии композитов с использованием теории статистических испытаний / В.С. Хандецкий, В.В. Герасимов // Вісник ДНУ: Фізика. Радіоелектроніка. – Дніпропетровськ: – 2003. № 10. – С. 128 – 132.
3. Медведев В.С. Нейронные сети. MATLAB 6 / В.С. Медведев, В.Г. Потемкин – М.: ДИАЛОГ-МИФИ, 2002. – 496 с.
4. Бронштейн И.Н. Справочник по математике для инженеров и учащихся втузов / И.Н. Бронштейн, К.А. Семендяев – М.: Наука, 1986.