

Н.А. Матвеева, Л.Я. Мартынович, Ю. В. Лазоренко

ИСПОЛЬЗОВАНИЕ РАДИАЛЬНО-БАЗИСНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ КЛАССИФИКАЦИИ СИГНАЛОВ

Аннотация. Представлены результаты исследования радиально-базисных и вероятностных нейронных сетей для решения задач классификации сигналов в дефектоскопии.

Ключевые слова: радиально-базисные, вероятностные нейронные сети, дефект, классификация.

Введение. В последнее время активно развивается новая область прикладной математики – теория нейронных сетей. Разработано огромное количество алгоритмов функционирования и обучения нейронных сетей, ведутся работы по созданию алгоритмов оптимизации их структуры с целью повышения быстродействия, качества результатов, снижения времени обучения. Нейросетевые технологии нашли применение в экономике, медицине, промышленности, многих других областях науки и техники, способны решать практически любые задачи, связанные с моделированием, прогнозированием, оптимизацией [1, 2].

В области нейросетевых технологий значительное количество исследований приходится на задачи машиностроения, в частности, авиационная и космическая отрасли. В этих областях существует тенденция перехода к производственным модулям с высоким уровнем автоматизации, а это требует все большего количества интеллектуальных решений, которые были бы в состоянии обрабатывать широкий диапазон изделий, оценивать качество продукта для минимизации контроля и помощи со стороны человека-оператора [3].

Детали и корпуса самолетов и космических аппаратов изготавливаются из композитных материалов. При проведении неразрушающего контроля таких изделий получают сигналы различной формы. Форма сигнала дает представление о характере дефекта. При этом следует учитывать шероховатость поверхности композитных материалов, которая добавляет шумы различной интенсивности и за-

трудняет распознавание формы сигнала, и, соответственно, вид дефекта.

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, 3].

Постановка задачи. В работе проводится сравнительный анализ применения радиально-базисных и вероятностных нейронных сетей для классификации зашумленных сигналов при вихретоковой дефектоскопии композитных материалов.

Основные положения. Сеть радиальных базисных функций – это нейронная сеть прямого распространения сигнала, которая содержит промежуточный (скрытый) слой радиально симметричных нейронов. Такой нейрон преобразовывает расстояние от данного входного вектора до соответствующего ему "центра" по некоторому нелинейному закону (обычно функция Гаусса). В свою очередь, радиальная функция – это функция $f(x)$, которая зависит только от расстояния между x и фиксированной точкой пространства X .

Байесовский алгоритм классификации предполагает, что плотность распределения представима в виде смеси гауссовских распределений с диагональными матрицами ковариации. Для этого записывается основная формула байесовского классификатора

$$a(x) = \arg \max_{y \in Y} \lambda_y P_y p_y(x), \quad (1)$$

где Y – множество ответов (классов), x принадлежит множеству объектов X , P_y – априорная вероятность класса Y , $p_y(x)$ – функция правдоподобия класса Y , – цена ошибки на объекте класса Y .

Представим плотности классов $p_y(x)$, $y \in Y$ в виде смесей k_y компонент. Каждая компонента имеет n -мерную гауссову плотность с параметрами: $\mu_{yj} = (\mu_{yj1}, \dots, \mu_{yjn})$ – центр и

$\sum_{y_j} = \text{diag}(\sigma_{y_{j1}}, \dots, \sigma_{y_{jn}})$ – ковариационная матрица при $j=1, \dots, k_y$. Поэтому смесь плотностей представляется в виде:

$$p_y(x) = \sum_{y=1}^{k_y} \bar{\omega}_{yj} P_{yj}(x), \quad (2)$$

Плотность каждой компоненты смеси (имеет вид гауссианы) представлена:

$$p_{yj}(x) = N(x; \mu_{yj}, \sum_{y_j}) \quad (3)$$

с условиями нормировки и неотрицательности весов $\sum_{j=1}^{k_y} \bar{\omega}_{yj} = 1, \bar{\omega}_{yj} > 0$.

Выразим плотность каждой компоненты $P_{yj}(x)$ через взвешенное евклидово расстояние от объекта x до центра компоненты μ_{yj} (т.е. подставим в основную формулу байесовского классификатора (1) вместо $P_y(x)$ формулу (2) с учетом (3)), получим:

$$a(x) = \arg \max_{y \in Y} \lambda_y P_y \sum_{j=1}^{k_y} N_{yj} e^{(-\frac{1}{2} p_{yj}(x, \mu_{yj}))}, \quad (4)$$

где $N_{yj} = (2\pi)^{-\frac{\pi}{2}} (\sigma_{y_{j1}}, \dots, \sigma_{y_{jn}})^{-1}$ — нормировочные множители.

Полученный алгоритм подобен нейронной сети, состоящей из трёх уровней или слоёв. Первый слой образован $k_1 + \dots + k_M$ гауссианами $P_{yj}(x), y \in Y, j = 1, \dots, k_y$. На входе они принимают описание объекта x , на выходе выдают оценки близости объекта x к центрам μ_{yj} , равные значениям плотностей компонент в точке x . Второй слой состоит из M сумматоров, вычисляющих взвешенные средние этих оценок с весами $\bar{\omega}_{yj}$. На выходе второго слоя появляются оценки близости объекта x каждому из классов, равные значениям плотностей классов $P_{yj}(x)$. Третий слой образуется единственным блоком *argmax*, принимающим окончательное решение об отнесении объекта x к одному из классов. Таким образом, при классификации объекта x оценивается его близость к каждому из центров μ_{yj} по метрике $P_{yj}(x, \mu_{yj}), j = 1, \dots, k_y$. Объект относится к тому классу, к чьим центрам он располагается ближе.

Описанный трёхуровневый алгоритм классификации называется сетью с радиальными базисными функциями или **RBF-сетью** (radial basis function network). Нейронная сеть радиальных базисных

функций содержит в общем случае три слоя: обычный входной слой, выполняющий распределение данных образца для первого слоя весов; слой скрытых нейронов с радиально симметричной активационной функцией и выходной слой.

Обучение *RBF-сети* сводится к восстановлению плотности каждого из классов $p_y(x)$. Результатом обучения являются центры μ_{yj} и дисперсии \sum_{yj} компонент $j = 1, \dots, k_y$. Можно отметить, что, оценивая дисперсии, фактически подбираем метрики P_{yj} с помощью которых будут вычисляться расстояния до центров μ_{yj} . При использовании описанного алгоритма для каждого класса определяется оптимальное число компонент смеси.

Для построения *RBF-сети* необходимо выполнение следующих условий.

Во-первых, наличие эталонов, представленных в виде весовых векторов нейронов скрытого слоя. Во-вторых, наличие способа измерения расстояния входного вектора от эталона. Обычно это стандартное евклидово расстояние. В-третьих, специальная функция активации нейронов скрытого слоя, задающая выбранный способ измерения расстояния. Обычно используется функция Гаусса, существенно усиливающая малую разницу между входным и эталонным векторами. Выходной сигнал эталонного нейрона скрытого слоя - это функция (гауссиан), который зависит только от расстояния между входным и эталонным векторами.

Обучение слоя образцов-нейронов сети подразумевает предварительное проведение кластеризации для нахождения эталонных векторов и определенных эвристик для определения значений.

Нейроны скрытого слоя соединены по полносвязной схеме с нейронами выходного слоя, которые осуществляют взвешенное суммирование.

При решении задачи классификации можно оценить плотность вероятности для каждого класса, сравнить между собой вероятности принадлежности различным классам и выбрать наиболее вероятный. Это и происходит, когда мы обучаем нейронную сеть «решать» задачу классификации. Сеть пытается определить (аппроксимировать) плотность вероятности.

Обычно оценка плотности вероятности основана на ядерных оценках. В этом случае рассуждают, если наблюдение расположено в данной точке пространства, то это свидетельствует о том, что в данной точке имеется некоторая плотность вероятности. Кластеры из близко лежащих точек указывают на то, что в этом месте плотность вероятности большая. Вблизи наблюдения имеется большее доверие к уровню плотности, а по мере отдаления от него доверие убывает и стремится к нулю. В методе ядерных оценок в точке, соответствующей каждому наблюдению, помещается некоторая простая функция, затем они складываются и, в результате, получается оценка для общей плотности вероятности. Чаще всего в качестве ядерных функций берут упрощенные функции Гаусса:

$$f(X) = e^{-\frac{|X-X_i|^2}{2\sigma^2}}, \quad (5)$$

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:

$$\phi(X) = \sum_{i=1}^{L_k} e^{-\frac{|X-X_i|^2}{2\sigma^2}}, \quad (6)$$

где L_k – объем обучающей выборки k -го класса.

Метод аппроксимации плотности вероятности с помощью ядерных функций во многом похож на метод радиальных базисных функций, и таким образом мы приходим к вероятностной нейронной сети. Такая сеть представляет собой реализацию методов ядерной аппроксимации, оформленной в виде нейронной сети.

Нейронная сеть *PNN* (Probabilistic Neural Network) состоит из трех слоев: входного, радиального и выходного. Радиальные элементы берутся по одному на каждое обучающее наблюдение. Каждый из них представляет гауссову функцию с центром в этом наблюдении. Каждому классу соответствует один выходной элемент. Каждый такой элемент соединен со всеми радиальными элементами, относящимися к его классу, а со всеми остальными радиальными элементами он имеет нулевое соединение. Таким образом, выходной элемент просто складывает отклики всех элементов, принадлежащих к его клас-

су. Значения выходных сигналов получаются пропорциональными ядерным оценкам вероятности принадлежности соответствующим классам, и пронормировав их на единицу, получаем окончательные оценки вероятности принадлежности классам.

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 (когда дефекты превышают зону контроля) до бимодального с наибольшим провалом вершины (точечные дефекты) моделируется с помощью выражения [4]:

$$y(x) = \exp(-1,5x^2) - k \cdot \exp(-3x^2), \quad (7)$$

где k изменяется от 0 до 1, а x от -2 до 2 с шагом $0,1$. 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 модельного сигнала является информативной характеристикой сигналов вихретоковой дефектоскопии и вычисляется путем интегрирования выражения (7) по абсциссе от $-\infty$ до $+\infty$, и является разностью известных [5] площадей под двумя ненормированными гауссовыми кривыми со значениями параметра 5 $\sigma = 1 / \sqrt{3}$ и $\sigma' = 1 / \sqrt{6}$:

$$Q = \sqrt{\frac{2\pi}{3}} \left(1 - \frac{\sqrt{2}}{2} k\right), \quad (8)$$

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

Для решения задачи классификации сигналов, полученных при сканировании композитных материалов, в работе использовались радиально-базисные (RBF) и вероятностные (PNN) нейронные сети.

Классификация сигналов выполнялась двумя способами: по площади, с использованием выражения (8) и по координатам, с учетом выражения (7). Для каждого из способов использовалось два вида зашумления: случайными величинами, распределенные по нормальному закону, и аддитивным белым гауссовым шумом.

Для моделирования использовалась программная среда MATLAB R2011a с ППП Neural Network Toolbox 6].

В случае классификации сигналов по площади сначала определялся вектор индексов классов, в соответствии с которым строилась матрица связности в разреженном виде. После чего, используя формулу (7), для каждого значения k от 0 до 1 с шагом 0,1 заполнялась матрица Q , каждое число которой соответствует значением вектора индексов классов. Для обучения нейронных сетей использовался вектор, содержащий значения площадей идеальных сигналов.

После обучения нейронных сетей на идеальных сигналах проводилось зашумление сигналов. Сначала к выражению (7) добавлялись случайные величины, распределенные по нормальному закону со средним значением 0 и среднеквадратичным отклонением от 0 до 0,2 с шагом 0,05 [4]. Для зашумления сигналов белым гауссовым шумом использовалась функция среды $awgn(x, snr, 'measured')$, где x – вектор сигнала, скаляр snr задает отношение сигнал/шум в децибелах. Если значения x являются комплексными, функция $awgn$ добавляет комплексный шум. При этом мощность сигнала x автоматически измеряется. Для вычисления площади зашумленных сигналов использовалась формула трапеций [5].

Далее зашумленные сигналы обрабатывались нейронной сетью, и результаты заносились в матрицу результатов.

Проверка функционирования нейронной сети проводилось на 1000 векторах входа для различных уровней шума. Результаты эксперимента представлены на рис. 1, 2.

При проведении классификации сигналов, которые задаются разностью экспонент (7), сначала выбирались 10 значений, определяющих 41-компонентные вектора входов, и соотносились каждый из них с одним из трех классов. Слой образцов имеет 10 нейронов: по 5

для первого, 2 для второго классов и 3 – для третьего класса. Слой суммирования содержит три нейрона, в соответствии с числом классов, на которые разбиваются входные векторы.




Рисунок 1 – Погрешности нейронных сетей при классификации сигналов, зашумленных случайными величинами, распределенными по нормальному закону со средним значением 0 и среднеквадратичным отклонением от 0 до 0,2




Рисунок 2 – Погрешности нейронных сетей при классификации сигналов, зашумленных белым гауссовым шумом

Определялся вектор индексов классов, в соответствии с которым строилась матрица связности в разреженном виде. Затем, используя выражение (7), для каждого значения k от 0 до 1 с шагом 0,1 заполняется матрица, каждый сигнал которой соответствует значениям вектора индексов классов.

Для обучения нейронных сетей используется вектор, который содержит идеальные сигналы, состоящие из 41 координаты. Для моделирования сигналов с шумом к выражению (7) добавлялись случайные величины, распределенные по нормальному закону и, затем, белый гауссов шум.

Проверка правильности функционирования нейронной сети проводилось на 1000 векторах входа для различных видов шума. Для каждого значения шума выполнялось 1000 измерений и определились общие относительные ошибки работы:

$$P = \frac{n}{N} \times 100\%, \quad (9)$$

где n – число ошибок распознавания, N – общее количество измерений. Результаты эксперимента представлены на рис. 3, 4.



Рисунок 3 – Оценка погрешности работы нейронных сетей при распознавании сигналов, зашумленных случайными величинами, распределенными по нормальному закону




Рисунок 4 – Оценка погрешности работы нейронных сетей при распознавании сигналов, зашумленных белым гауссовым шумом

Выводы. Проведенные исследования показали принципиальную возможность применения искусственных нейронных сетей для определения дефектности изделий из композитных материалов. При зашумлении белым гауссовым шумом результаты обработки сигналов нейронными сетями показывают лучшие результаты, что соответствует реальности, т.к. шум, присутствующий при сканировании композитных материалов близок к белому гауссову шуму.

Сравнивая методы классификации сигналов можно сделать вывод, что вероятностные нейронные сети более точно определяют класс, к которому относится сигнал, описываемый разностью экспонент, а не по площади, где радиально-базисная нейронная сеть показывает лучшие результаты.

ЛИТЕРАТУРА

1. Хайкин Саймон. Нейронные сети: полный курс, 2-е издание.: Пер. с англ. – М.: Издательский дом «Вильямс», 2006
2. Осовский С. Нейронные сети для обработки информации. /пер. с польского – М. : Финансы и статистика, 2004, 344с.
3. Архангельский В.И. Нейронные сети в системах автоматизации / В. И. Архангельский, И. Н. Богаенко, Г. Г. Грабовский, Н. А. Рюмшин. – К.: Техніка, 1999. - 363 с.
4. 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
5. Бронштейн И.Н. Справочник по математике для инженеров и учащихся втузов/ И.Н. Бронштейн, К.А. Семендяев – М.: Наука, 1986
6. Медведев В.С. Нейронные сети. MATLAB 6 / В.С. Медведев, В.Г. Потемкин – М.: ДИАЛОГ-МИФИ, 2002. – 496 с.