

Рис. 6. Значения размаха отраженного импульса в различных точках диагностируемого объекта

Заключение. Результатом разработки является физическая и техническая база для применения методов акустики ДДС к оперативному решению ряда задач промышленности, связанных с диагностикой коррозионных процессов. Проведенные исследования показывают целесообразность использования акустического спектрального анализа в данной области. Его применение позволит перейти от менее точных и протяженных по времени выполнения методов контроля к более точным, быстрым, выполняемым в производственных условиях акустическим средствам и таким образом ускорить оперативное решение значительного количества технологических проблем.

Авторы благодарны БРФФИ (грант Т06М-227) и МО РБ за финансовую поддержку исследований.

СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ

1. Костюк Д.А., Кузавко Ю.А. Аномалии граничного отражения ультразвука от диссипативной среды // Письма в ЖТФ, 2001, том 27, вып.23 – С. 31-40.

2. Д.А.Костюк, Ю.А.Кузавко. Аномальное отражение продольного ультразвука от сильно диссипативной среды // Инженерно-физический журнал, 2004. - т. 77. - №5. - С. 161–169.
3. В.П. Данилевский, Д.А. Костюк, Н.В. Кудинов, Ю.А. Кузавко. Акустические спектроскопические методы и средства диагностики материалов и веществ // Материалы, технологии, инструменты. – №3. - т. 8, 2003. - С. 104-112.
4. Костюк Д. А., Кузавко Ю. А. Аномалии граничного отражения ультразвука от пленки диссипативной среды // Инженерно-физический журнал. - Том 75. - No 4, 2002 – С. 181-186.
5. Kozak A., Kostiuik D., Kuzavko Y., Nikolayuk L., Tomassi P. The acoustic spectral analysis of metal corroding surfaces // Proc. of the Internat. Conf. CORROSION 2005 „Science & Economy”. Poland, Warsaw, 8 – 10 June 2005, Inżynieria Powierzchni, 2005, 2A, p. 63 – 70.
6. Виноградова М.Б., Руденко О.В., Сухоруков А.П. Теория волн. – М.: Наука, 1990. - 432 с.
7. Дьелесан Э., Руайе Э. Упругие волны в твердых телах - М.: Наука, 1982 - 424 с.
8. Лепендин Л.Ф. Акустика. - М.: Высш. шк., 1978 – 448 с.
9. Козак А.Ф., Костюк Д.А., Кузавко Ю.А., Николаюк Л.Н. Акустический спектральный анализ коррозии ферромагнитных металлов и сплавов. // Сб-к тезисов 15 Петербургских чтений по проблемам прочности - Санкт-Петербург, 2005. - С. 87-88.
10. Козак А.Ф., Костюк Д.А., Кузавко Ю.А. Приборное решение акустического спектрального анализа для диагностики вязких сред // Современные методы и приборы контроля качества и диагностики состояния объектов. Материалы 2-й международной научно-технической конференции. – Могилев, 2006. - С. 54– 56.
11. Костюк Д.А., Николаюк Л.Н. Виртуальная лаборатория диагностики диссипативных сред // Современные информационные компьютерные технологии: сб. науч. ст. - Гродно: ГрГУ, 2006. - С. 58–63.
12. Козак А.Ф., Костюк Д.А., Марчик Д.В. Программно-аппаратная система акустического спектрального анализа корродирующих поверхностей // Современные проблемы математики и вычислительной техники. V респ. науч. конф. молодых ученых и студентов. - Брест, 2007. - С. 93 – 96.

Материал поступил в редакцию 17.12.07

KOZAK A.F., KOSTIUK D.A., KUZAVKO Yu.A. Application of acoustical spectroscopy software and hardware to corrosion diagnostics

The practical opportunity and perspectives of dispersion-dissipative media acoustics application for metals corrosion diagnostics is considered. Worked out software-hardware decision is intended for practical application of the acoustic spectral analysis of corrosion processes. Advantages of proposed approach are estimated.

УДК 681.324

Савицкий Ю.В.

АДАПТИВНЫЙ АЛГОРИТМ ГЕНЕРАЦИИ МНОГОСЛОЙНОЙ НЕЙРОННОЙ СЕТИ ПРОГНОЗИРОВАНИЯ

Введение. В настоящее время в мире накоплено значительное количество теоретических результатов и большой практический опыт в применении аппарата искусственных нейронных сетей для обработки информации в различных сферах. Предложен ряд высокоэффективных алгоритмов обучения, позволяющие улучшить адаптивные свойства нейросетевых моделей. Однако одной из нерешенных и наиболее серьезных до сих пор остается проблема выбора количества скрытых нейроэлементов в архитектурах нейронных сетей [1-4]. Решения подобных проблем в нейросетевых задачах требуют индивидуального подхода, а какие-либо универсальные методы архитектурного синтеза нейронных сетей в настоящее время отсутствуют. Это является весьма серьезным ограничением для использования нейросетевых моделей в практических задачах.

Для того чтобы нейронная сеть реализовывала с требуемой точностью заданное обучающей выборкой отображение и обладала при этом необходимыми обобщающими свойствами, она должна содержать определенное количество нейроэлементов в скрытых слоях. Однако многочисленные эксперименты в различных практических задачах демонстрируют сложность и нетривиальность решения данной проблемы. Если при увеличении количества нейронных

элементов в структуре сети наблюдается устойчивая тенденция к уменьшению погрешности обучения, то аппроксимирующие свойства модели при этом могут сильно изменяться. Это связано с проблемой переобучения сети (overtraining), которая возникает при использовании избыточной архитектуры сети. В такой ситуации может быть достигнута очень малая ошибка обучения, однако избыточная модель будет генерировать новые результаты, не входящие в обучающее множество, с большой погрешностью. При этом в процессе обучения выполняется запоминание обучающих эталонов, сопровождающееся ухудшением обобщающих свойств модели. В случае использования нейронной сети с недостаточным количеством скрытых элементов не может быть достигнута требуемая ошибка обучения, а следовательно, не может быть достигнута и требуемая точность прогнозов. В связи с этим задача определения архитектуры нейронной сети относительно обучающего множества в общем случае традиционно сводится к перебору возможных вариантов нейросетевых структур и к выполнению отдельно для каждого из них фаз инициализации, адаптации и оценивания принятой модели. Такой эвристический способ поиска адекватной структуры нейронной сети требует значительных временных и вычислительных затрат и

не может быть приемлемым для большинства практических задач. При этом методы проектирования многослойных нейронных сетей с рекуррентными связями (являющихся наиболее приемлемыми для организации моделей прогноза временных процессов) в настоящее время отсутствуют.

1. Методика генерации нейронной сети. Предлагаемый в работе алгоритм структурного синтеза нейронной сети заключается в сочетании методов адаптивного обучения и метода последовательного добавления нейроэлемента в слой сети с независимым обучением добавленных синаптических связей. Такой способ реконфигурации нейронной сети позволяет на каждом этапе синтеза внедрять нейроэлементы и соответствующие связи в скрытый слой сети и адаптировать их параметры так, чтобы уменьшить общую ошибку обучения сети и избежать повторного обучения уже синтезированного фрагмента сети. Тем самым применение данного алгоритма позволит значительно уменьшить временную и вычислительную сложность процесса проектирования нейросетевой модели прогноза.

Предлагаемый алгоритм ориентирован на определение оценки необходимого количества скрытых нейронов для трехслойных гетерогенных нейронных сетей с прямыми и рекуррентными связями.

Вследствие сильной зависимости обобщающих свойств нейросетевой модели от ее архитектуры стандартный критерий среднеквадратичной погрешности обучения не может являться достоверной оценкой качества моделей в задачах прогнозирования временных последовательностей. Предлагаемая методика оценивания свойств синтезируемой модели прогнозирования основана на разбиении исходного множества эталонов T , сформированного на основе исходной последовательности наблюдений по методу скользящего окна, на подмножество обучения T_{train} , и подмножество тестирования T_{test} , в которых соответствующие эталоны обучения определяются по следующим правилам:

$$T_{train} = \{X^i, D^i\}, i = 1, \dots, P_{train}, \quad (1)$$

$$T_{test} = \{X^k, D^k\}, k = P_{train} + 1, \dots, P.$$

Здесь P_{train} характеризует количество эталонов в подмножестве обучения T_{train} , P - общее количество эталонов, сформированных на основе исходного ряда.

Тестирование модели в предлагаемом методе заключается в оценивании соотношения среднеквадратичной погрешности тестирования на множестве T_{test} и среднеквадратичной погрешности обучения на множестве T_{train} :

$$Q_{NN} = \frac{MSE_{test}[T_{test}]}{MSE_{train}[T_{train}] + MSE_{test}[T_{test}]}, \quad (2)$$

где MSE_{test} и MSE_{train} представляют собой среднеквадратичные ошибки, рассчитанные соответственно для тестового и обучающего подмножества.

Рассмотрим более детально процесс оценивания модели при использовании предложенного метода тестирования в алгоритме синтеза. Известно, что использование различного вида рекуррентных нейронных сетей позволяет формировать динамические модели временных рядов, когда каждое новое значение ряда формируется с учетом всех предыдущих значений. Следовательно, для выполнения корректного тестирования модели, начиная с какой-либо точки ряда, необходимо вычислить выходные активности сети с первого элемента моделируемой последовательности. Поэтому для организации подмножества обучения используются первые элементы ряда, а последующие элементы входят в состав тестового подмножества. Тестирование заключается в вычислении выходной активности сети, начиная с первого элемента обучающего подмножества, до последнего элемента подмножества тестирования. Если нейронная структура содержит недостаточное количество элементов в скрытом слое, то, очевидно, что погрешность обучения сети будет высокой, что в свою очередь приведет к еще более высокому уровню погрешности тестирования на эталонах, не входивших в обучающее множество. В случае обучения

избыточной архитектуры большая погрешность тестирования будет определяться большой вероятностью искажения выходной информации в точках тестирования, не входивших в обучающее подмножество, при низком уровне погрешности обучения. Таким образом, задача синтеза скрытого слоя нейронной сети сводится к построению модели такой структуры, для которой может быть достигнуто минимальное значение погрешности тестирования (2):

$$Q_{NN} \rightarrow MIN. \quad (3)$$

Следует отметить, что достоверность оценки (3) повышается при моделировании рядов большой размерности. Очевидно, что большую часть элементов исходного ряда необходимо использовать для организации обучающего подмножества.

2. Инициализация начальной структуры нейронной сети.

Первой стадией выполнения алгоритма синтеза является определение стартовой архитектуры нейронной сети. С целью избежания структурной избыточности на начальных этапах процесса синтеза примем в качестве стартовой нелинейную сеть с малым количеством скрытых нейроэлементов минимальной архитектуры:

$$NN = (N^{[1]}, N^{[2],min}, 1), \quad (4)$$

которая соответствует трехслойной нелинейной модели с $N^{[1]}$ количеством входных нейроэлементов, $N^{[2],min}$ нелинейных нейронов скрытого слоя и одним линейным нейроэлементом скрытого слоя (рис. 1а).




Рис. 1. Схема этапов синтеза нейронной сети: а) исходная модель; б) стадия добавления нейроэлементов и межнейронных связей (штриховыми линиями показаны добавляемые элементы и синаптические связи); B_1, B_2 – элементы задержки распространения сигналов на один такт функционирования нейронной сети; w – весовые коэффициенты нейронов соответствующего слоя; x – входные сигналы; y – выходные активности нейронов соответствующего слоя

Параметрами данной модели, подлежащими адаптации в процессе обучения, являются весовые связи нелинейных и линейного

нейронов. В качестве критерия оценки результатов обучения модели будем использовать среднюю скорость убывания ошибки, определяемую за некоторый заданный период наблюдения («окно наблюдений») за ошибкой. Для определения момента окончания обучения и перехода к следующей фазе алгоритма будем задавать минимальное значение скорости убывания ошибки. Применение данной методики для выхода из процесса обучения целесообразно по следующим причинам: 1) невозможно заранее определить такое минимальное значение погрешности обучения, которое может быть достигнуто для данной конфигурации сети относительно текущего обучающего множества; 2) слишком малая скорость убывания ошибки увеличивает временную сложность алгоритма; 3) применение «окна наблюдений» позволяет частично избежать влияния возможных незначительных осцилляций ошибки на преждевременное прерывание процесса обучения.

Как было указано выше, критерием оценивания свойств архитектуры NN (которое должно быть выполнено по окончании любого этапа алгоритма синтеза) является Q_{NN} . Результатом успешного выполнения любой стадии процесса синтеза является достижение меньшего уровня погрешности Q_{NN} по сравнению с предыдущим этапом алгоритма.

Следующей фазой предлагаемого алгоритма является последовательное увеличение нелинейных свойств модели, выполняемое путем добавления нейронов и соответствующих синаптических связей в скрытый слой сети.

3. Этап добавления нелинейного элемента в архитектуру сети. Этап добавления нелинейного элемента в скрытый слой сети позволяет увеличивать нелинейные свойства сети, улучшая тем самым аппроксимирующие способности синтезируемой модели прогноза. Очевидно, что непосредственное добавление необученного элемента является неэффективным шагом процесса синтеза, так как приведет к значительному перераспределению пространства весовых коэффициентов всех элементов сети, что эквивалентно полному переобучению всего синтезированного фрагмента сетевой архитектуры. Поэтому в работе предлагается метод последовательного добавления элемента и соответствующих синаптических связей, предполагающий его независимое обучение с целью уменьшения достигнутой на предыдущих этапах синтеза ошибки обучения.

Добавление в скрытый слой гетерогенной сети архитектуры $NN = (N^{[1]}, N^{[2]}, 1)$, $N^{[2]} \geq 1$ нелинейного элемента, обучаемого независимо в составе сформированной архитектуры сети, уменьшает общую ошибку обучения сети в совокупности с добавленным нейроном. Для доказательства данного утверждения рассмотрим более детально процесс добавления в слой нелинейных нейронов нового элемента (рис. 1б) и предлагаемый метод его обучения. После добавления нейроэлемента и соответствующих весовых связей в составе общей нейронной структуры необходимо модифицировать весовые коэффициенты таким образом, чтобы уменьшить уже достигнутую на предыдущих этапах синтеза погрешность обучения модели. Для этого зафиксируем параметры (значения весов и порогов нейроэлементов) уже синтезированной сети и выполним обучение добавленного элемента согласно общим правилам адаптивного обучения. При этом на этапе вычисления выходной активности сети (которая необходима для выполнения итерации обучения) участвуют все нейроэлементы сети (их синаптические связи и пороги), а адаптации подлежат только добавленные в результате реконфигурации межнейронные связи. Следовательно, модификация параметров добавленного фрагмента будет минимизировать только ту часть погрешности, которая не смогла быть компенсирована моделью предшествовавшей архитектуры. Процесс обучения завершается при достижении минимальной скорости убывания погрешности обучения. Таким образом, нейроэлемент, обу-

ченный в соответствии с предложенным выше алгоритмом, после внедрения в сеть уменьшает общую ошибку обучения, что позволяет сохранить адаптированные параметры исходного фрагмента архитектуры в процессе дообучения реконфигурированной модели.

Окончательной фазой добавления нового нейрона является дообучение всех нейроэлементов реконфигурированной архитектуры с последующим тестированием модели. Таким образом, в результате последовательного выполнения процедуры адаптивного добавления нейроэлементов в синтезируемую модель формируется гетерогенная архитектура $NN = (N^{[1]}, \hat{N}^{[2]}, 1)$, где оценка $\hat{N}^{[2]}$ определяется с использованием вышеописанных правил, исходя из минимизации Q_{NN} на каждой последующей стадии добавления нейроэлементов. Процесс последовательного добавления элементов заканчивается при увеличении Q_{NN} относительно предыдущей архитектуры.

4. Этап обучения сформированной архитектуры нейронной сети. Необходимой завершающей стадией предлагаемого алгоритма является обучение сформированной модели до минимально возможной погрешности. Для этого используется вся совокупность обучающих эталонов, сформированных из элементов моделируемого временного ряда.

Следует отметить, что целью описанного выше алгоритма является, прежде всего, определение количества скрытых нейроэлементов сети для организации избыточной модели. Поэтому существует два пути для окончательного формирования нейросетевой модели прогноза: дообучение синтезированной сети либо переинициализация сети с выбранным количеством нейроэлементов скрытого слоя и полным обучением. Очевидно, что в первом случае временная сложность процесса обучения может быть уменьшена за счет использования в рассматриваемом этапе результатов обучения, полученных в процессе синтеза модели. Однако обобщающая способность такой модели может быть хуже, чем у модели, полученной в результате полного обучения сети, что является следствием механистичности процесса добавления нейронов и недостатком конструктивных алгоритмов.

Предложенная методика была опробована в вычислительных экспериментах по прогнозированию модельных временных процессов Энона и Лоренца. В результате были сформированы более компактные нейросетевые модели, содержащие в среднем на 40% – 50% меньше количество скрытых нейронов по сравнению с наиболее удачными моделями, в которых количество скрытых нейронов было подобрано опытным путем (при приблизительно одинаковых результатах обучения и прогнозирования). При этом пропорционально снизилась временная сложность процесса обучения. Следует, однако, отметить более высокую чувствительность генерируемой модели к начальной инициализации весов и параметрам обучения.

СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ

1. Choi C.H., Choi J. Y. Construction Of Neural Networks To Approximate Arbitrary Continuous Functions Of One Variable // Electron. Lett. – 1992. – №2. – P. 151–153.
2. Fahlan Scott E., Lebiere C. The Cascade–Correlation Learning Architecture. // Neural Information Processing System. – 1990. – №2. – P. 524–532.
3. Fahlan Scott E., Lebiere C. The Cascade–Correlation Learning Architecture. // Neural Information Processing System. – 1990. – №2. – P. 524–532.
4. Wynne–Jones M. Node Splitting: A Constructive Algorithm For Feed–Forward Neural Networks // Neural Computing And Applications. – 1993. – Vol. 1, №1. – P. 17–22.

Материал поступил в редакцию 17.01.08

SAVICKI Y.V. Adaptive algorithm of generation there is a lot of layer neuron's of a network of forecasting

In clause the adaptive algorithm of generation a lot of layer neuron's of a network with various types between neuron's of communications(connections) is offered. The main purpose(appointment) of algorithm is the construction of more compact models neuron's of networks and reduction of temporary complexity of process of selection of quantity(amount) of the latent elements in many layer architecture. On the basis of results of computing experiments the positive and negative features of algorithm are analyzed.