

ВОЗМОЖНОСТЬ ПРИМЕНЕНИЯ АППАРАТА НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ ЭРОЗИОННО-КОРРОЗИОННОГО ИЗНОСА ОБОРУДОВАНИЯ АЭС

А.Д. Вишнякова, О.М. Гулина, Н.Л. Сальников

Обнинский институт ядерной энергетики НИЯУ МИФИ

249040, Калужская обл., г. Обнинск, Студгородок, 1



Интенсивность процесса эрозионно-коррозионного износа (ЭКИ) определяется большим числом параметров, сложным образом влияющих друг на друга. Использование интеллектуальной нейронной сети (ИНС) для решения задачи прогнозирования ЭКИ позволяет оценить взаимное влияние всех факторов, выделить существенные свойства поступающей информации и, в конечном итоге, улучшить точность прогноза без определения всех зависимостей между множеством факторов, обуславливающих процесс ЭКИ. Предлагается подход к созданию и обучению оптимальной нейронной сети для задачи прогнозирования интенсивности ЭКИ в трубопроводах АС. Средствами ПО *Matlab* разработана интеллектуальная нейронная сеть, решающая задачу прогнозирования утонения стенки прямого участка трубопровода с однофазной средой второго контура АЭС с ВВЭР. Сеть обучена с помощью алгоритма упругого обратного распространения, выполнено исследование нескольких конфигураций ИНС, проведен анализ полученных результатов. Построена концептуальная схема интеллектуальной системы, реализованной в виде комплекса из трех видов ИНС: репликативной, самоорганизующейся карты Кохоннена и ИНС обратного распространения.

Ключевые слова: нейронная сеть, алгоритм обучения, эрозионно-коррозионный износ, трубопроводы АС.

ВВЕДЕНИЕ

Практически все элементы трубопроводов и оборудования пароводяного тракта АС, изготовленные из перлитных и слаболегированных сталей, подвержены эрозионно-коррозионному износу (ЭКИ). Эрозионно-коррозионные процессы возникают под воздействием гидродинамических факторов (эрозионная составляющая повреждения) и электрохимического окисления поверхности (коррозионная составляющая). Последствия эрозионно-коррозионного воздействия проявляются в виде утонений и, в конечном счете, разрушения элементов энергетического оборудования «до появления течи». Большое разнообразие зон и форм разрушения металла оборудования обусловлено различием геометрии, фазовых состояний, термогидродинамических характеристик, воднохимических параметров рабочей среды.

Поэтому актуальной является задача прогнозирования скорости ЭКИ для оптимизации объемов контроля оборудования АС и предотвращения критических ситуаций [1, 2].

© *А.Д. Вишнякова, О.М. Гулина, Н.Л. Сальников, 2015*

В мировой практике наиболее распространено прогнозирование ЭКИ на основе эмпирических данных. Эмпирические модели лишены физического смысла, но удовлетворительно описывают экспериментальные данные, характеризующие свойства реальных объектов. Обобщение и анализ многолетнего опыта эксплуатации и статистических данных о повреждаемости АС, а также исследование процессов и закономерностей эрозии-коррозии металла позволили разработать расчетные коды в США (*CHECWORKS*), Германии (*WATHEK*), Франции (*COMSY*) и России (ЭКИ-02, ЭКИ-03). Самой известной эмпирической моделью является модель *Chexal-Horowitz* [2], использованная в компьютерной программе *CHECWORKS*. В ней обширные эксплуатационные данные и данные лабораторных исследований применяются для количественной оценки факторов, влияющих на ЭКИ:

$$FACrate = F_1(T) \cdot F_2(AC) \cdot F_3(MT) \cdot F_4(O_2) \cdot F_5(pH) \cdot F_6(G) \cdot F_7(\alpha) \cdot F_8(H),$$

где T – температура; AC – состав сплава; MT – массообмен; O_2 – влияние кислорода; pH – влияние pH при данной температуре; G – геометрия; α – паросодержание; H – влияние гидразина.

Однако прогнозирование на основе эмпирических моделей не обеспечивает приемлемых результатов. Например, в полуэмпирической модели *Chexal-Horowitz*, построенной на учете зависимости между факторами, неявно заданной с помощью эмпирических таблиц [2], основными источниками неопределенности являются исходная толщина стенки компонента; не включенные в модель компоненты сплава; истинное качество пара в двухфазном потоке; неопределенности параметров водно-химического режима (ВХР) и т.п.

Единственным объективным источником информации о состоянии элемента трубопровода являются данные контроля. Поэтому для целей прогнозирования предлагается реализовать модель процесса ЭКИ с помощью аппарата нейронных сетей. Нейронные сети хорошо зарекомендовали себя в области моделирования систем и процессов, внутренние связи которых либо мало изучены, либо реализуют сложные взаимодействия [4 – 5].

Большое число параметров, определяющих интенсивность процесса ЭКИ, сложным образом влияют друг на друга. Использование ИНС для решения задачи прогнозирования ЭКИ позволяет оценить взаимное влияние всех факторов, выделить существенные свойства поступающей информации и, в конечном итоге, улучшить точность прогноза. Способность искусственной нейронной сети к обобщению и абстрагированию помогает получить верный прогноз относительно величины эрозионно-коррозионного износа без определения всех зависимостей между множеством факторов, обуславливающих процесс ЭКИ. Но реальная модель сложна и имеет большое число входных переменных.

В работе предлагается подход к созданию и обучению оптимальной искусственной нейронной сети, решающей задачу прогнозирования интенсивности ЭКИ в трубопроводах АС.

О ПРИМЕНЕНИИ АППАРАТА НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ ПРОЦЕССА ЭКИ

Сеть – это модель процесса. Основными ее характеристиками являются структура, количество слоев, тип нейрона, входные и выходные величины, алгоритм обучения. Выбор атрибутов нейронной сети обусловлен объемом и качеством экспериментальных данных, имеющихся для обучения сети. Базой обучения являются результаты толщинометрии, химический состав металла, водно-химический режим теплоносителя, температура, скорость потока и др. (например, модель *CHECWORKS* [2]). Причем предварительной обработки данных и получения соответствующих зависимостей для конкретного фактора не требуется. Однако для повышения досто-

верности прогноза необходима фильтрация данных, заключающаяся в использовании лишь информации об утонениях, т.к. процесс ЭКИ связан с утонением стенки, а утолщения обусловлены другим процессом – переносом продуктов коррозии, который не должен вносить дополнительный шум в прогнозируемый процесс.

Для прогнозирования ЭКИ нет смысла в построении универсальной сети, учитывающей воздействие всех возможных входных факторов. Такой подход требует разработки сети сложной структуры с большим количеством слоев и нейронов и большеобъемной обучающей выборкой для получения приемлемого результата. Однако для каждого геометрического типа элементов трубопровода (прямой участок, гиб, отвод и т.п.) имеет смысл построить отдельную сеть, что значительно упростит структуру нейронной сети и повысит точность модели.

МОДЕЛЬ ИНС ДЛЯ ПРОГНОЗИРОВАНИЯ СКОРОСТИ ЭКИ

Чтобы обучить нейронную сеть прогнозированию скорости ЭКИ, необходимо представить на входы сети данные, влияющие на прогнозируемую величину. На выходе, согласно поставленной задаче, будет значение, характеризующее скорость ЭКИ. В качестве такой характеристики выбрана величина отклонения толщины стенки трубопровода от номинального значения (S).

В качестве входов будем использовать факторы, влияющие на процесс ЭКИ [1, 2]: температуру среды T ; скорость течения теплоносителя V ; содержание кислорода в теплоносителе O_2 ; показатель pH среды; массовое содержание хрома в материале Cr; массовое содержание молибдена в материале Mo; массовое содержание меди в материале Cu; внутренний диаметр трубопровода D ; геометрию трубопроводного элемента G ; содержание применяемого амина (аммиак, этаноламин, морфолин); длительность эксплуатации трубопровода в годах $t_{\text{экс}}$.

Чем больше размер входного вектора, тем сложнее должна быть архитектура НС, обрабатывающая это множество. Чем сложнее конфигурация сети, тем больше времени требуется для ее обучения и вероятнее возникновение проблем при обучении.

Неотъемлемый параметр задач прогнозирования – время, на которое осуществляется прогноз, $t_{\text{прог}}$. Таким образом, получим модель НС в виде «черного ящика» (рис. 1).

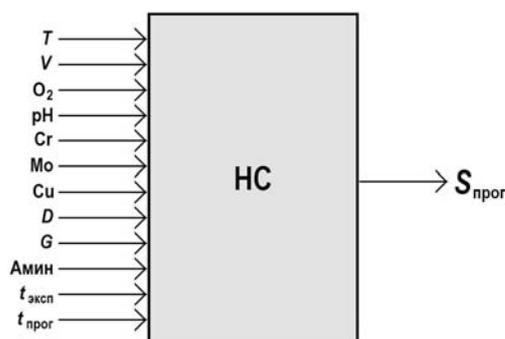


Рис. 1. Модель искусственной нейронной сети, решающей задачу прогнозирования

В качестве активационной функции использована сигмоидальная (или логистическая) функция вида $F(x) = 1 / (1 + \exp(-x))$, показанная на рис. 2.

В качестве обучающего выбран алгоритм обратного распространения – систематический метод для обучения многослойных искусственных нейронных сетей, обеспечивающий построение в пространстве весов «аппроксимации» для траектории, вычисляемой методом наискорейшего спуска. Вычислительная мощность алгоритма заключается в эффективном расчете частных производных функции сети $F(\mathbf{w}, \mathbf{x})$ по всем элементам настраиваемого вектора весов \mathbf{w} для данного входного вектора \mathbf{x} .

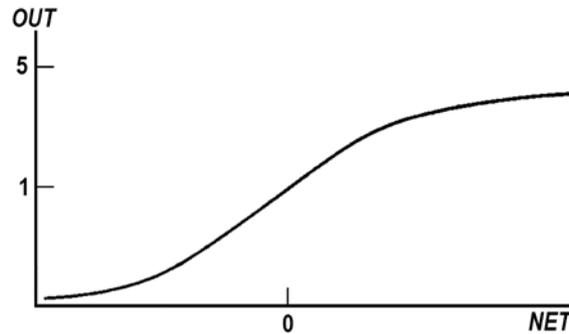


Рис. 2. Сигмоидальная функция. *OUT* – выход нейрона, *NET* – вход

Алгоритм обратного распространения можно представить следующей последовательностью действий:

- 1) выбрать очередную обучающую пару из обучающего множества и подать входной вектор на вход сети;
- 2) вычислить выход сети;
- 3) вычислить разность между выходом сети и требуемым выходом (целевым вектором обучающей пары);
- 4) выполнить коррекцию весов сети так, чтобы минимизировать ошибку;
- 5) повторять шаги с первого по четвертый для каждого вектора обучающего множества до тех пор, пока ошибка на всем множестве не достигнет приемлемого уровня.

Коррекция весов осуществляется по формуле

$$\Delta w_{pq,k} = \eta \delta_{q,k} \cdot OUT,$$

где $\Delta w_{pq,k}$ – величина коррекции веса от нейрона p к нейрону q ; η – скорость обучения; OUT – выход нейрона.

Значение δ для нейронов выходного слоя определяется выражением

$$\delta = OUT \cdot (1 - OUT) \cdot (Target - OUT),$$

где $OUT \cdot (1 - OUT)$ – производная от сигмоидальной функции активации; $Target$ – целевое значение.

Величина $\delta_{q,k-1}$, необходимая для нейрона скрытого слоя, получается суммированием произведений величины $\delta_{q,k}$ нейрона, к которому он присоединен в выходном слое, и соответствующего веса и умножением на производную сжимающей функции:

$$\delta_{q,k-1} = OUT_{p,k} \cdot (1 - OUT_{p,k}) \cdot [\sum_q \delta_{q,k} w_{pq,k}].$$

Для решения задачи прогнозирования величины ЭКИ реализована упрощенная модель нейронной сети (рис. 3), содержащая сокращенное количество входных параметров.

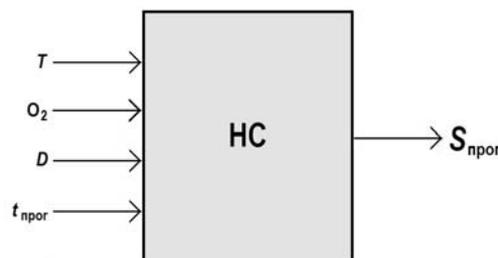


Рис. 3. Упрощенная модель нейронной сети, решающей задачу прогнозирования ЭКИ

ПРАКТИЧЕСКАЯ РЕАЛИЗАЦИЯ НЕЙРОННОЙ СЕТИ

Построение нейронной сети – экспериментальный процесс. Основная проблема при конструировании сети состоит в выборе оптимального уровня сложности.

Подготовка данных. Входные сигналы упрощенной модели нейронной сети выбраны с учетом их относительной важности: температура среды, внутренний диаметр трубопровода, содержание кислорода в среде и время, на которое осуществляется прогнозирование. Таким образом, обучающее множество состоит из векторов, содержащих четыре элемента. Для каждого из параметров заданы интервалы возможных значений. При этом факторы, не вошедшие в реализуемую модель, приняты постоянными: pH = 7; коэффициент Келлера – 0,04; содержание хрома – 0,03%; содержание меди – 0,03%; содержание молибдена – 0,03%; тип амина – аммиак; скорость течения теплоносителя $V = 6,1$ м/с.

Чтобы обеспечить равное влияние каждой из переменных на изменение весов в процессе тренировки, данные нормированы на интервал (0, 1) – диапазон выходных значений сигмоидальной функции. Для этого использовано линейное шкалирование. Линейное шкалирование величины v в переменную s , распределенную в диапазоне от нуля до единицы, осуществляется с помощью формулы

$$s = [v - \min(v_{1...n})] / [\max(v_{1...n}) - \min(v_{1...n})].$$

Обратное преобразование из s в v выполняется в соответствии с формулой

$$v = \min(v_{1...n}) + s \cdot [\max(v_{1...n}) - \min(v_{1...n})].$$

Выбор структуры сети. При проектировании нейронной сети для решения задачи прогнозирования ЭКИ принято решение о построении сужающейся сети, т. к. в этом случае повышается ее обобщающая способность.

Для вычисления верхней границы h числа скрытых элементов можно использовать теорему Колмогорова, которая утверждает, что любая функция n переменных может быть представлена как суперпозиция $2n+1$ одномерных функций: $h \leq 2i + 1$.

Анализ опубликованных результатов указывает на то, что для решения большинства практических задач достаточно одного, иногда двух скрытых слоев [4, 5].

Количество нейронов в скрытых слоях существенно зависит от имеющегося обучающего множества. Количество тренировочных примеров должно быть приблизительно равным количеству весов сети ω , умноженному на обратную величину ошибки ε :

$$n \geq \omega/\varepsilon.$$

Обучение нейронной сети. При построении нейронной сети для любой задачи потребуется построить несколько нейронных сетей различной сложности и выбрать из них оптимальную.

Прогноз утонения стенки трубопроводов под воздействием процесса ЭКИ с помощью различных нейронных сетей, обучаемых на основе алгоритма обратного распространения, либо приводил к параличу сети, либо требовал очень много времени.

Принято решение о применении более быстрого алгоритма обучения, а именно, алгоритма упругого обратного распространения, который в отличие от стандартного алгоритма обратного распространения использует только знаки частных производных для подстройки весовых коэффициентов. Для равномерного покрытия поля значений входных параметров разработана специальная процедура.

В результате в среде *MatLab* была построена и обучена с помощью алгоритма упругого обратного распространения нейронная сеть, состоящая из входного слоя, содержащего четыре элемента, двух скрытых слоев с четырьмя нейронами в каждом и выходного слоя с одним элементом. Средняя квадратичная ошибка прогноза, вычисляемого реализованной сетью, равна 0,035 (рис. 4).

В таблице 1 показаны целевые значения выхода сети и значения, выданные сетью.

Таблица 1

Целевые и полученные значения

| | | | | | | | | | | |
|---------------------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
| Целевые значения | 0,128 | 0,423 | 0,109 | 1,352 | 0,707 | 4,65 | 0,265 | 0,628 | 1,81 | 0,155 |
| Полученные значения | 0,128 | 0,170 | 0,127 | 1,046 | 0,570 | 4,412 | 0,198 | 0,654 | 1,475 | 0,121 |

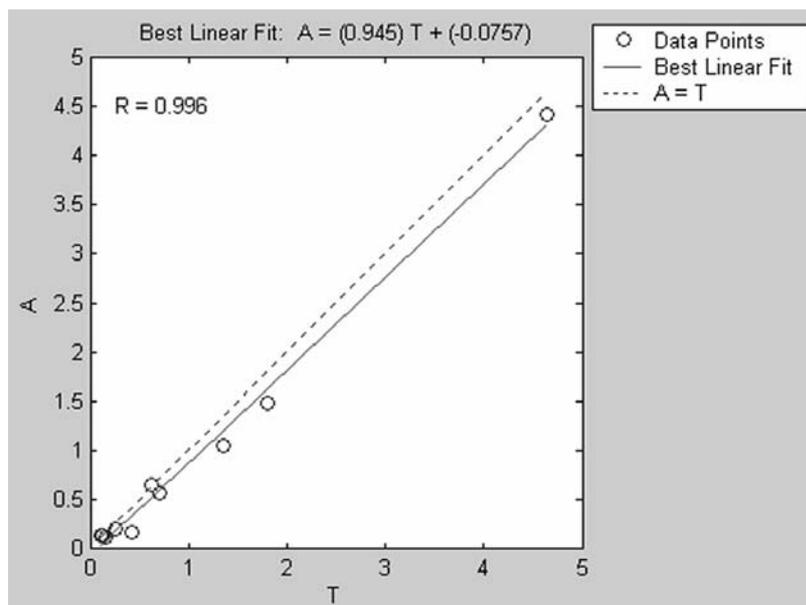


Рис. 4. Фрагмент экрана вывода результатов. График линейной регрессии между выходом сети и эталоном

ИССЛЕДОВАНИЕ МОДЕЛИ

Чтобы судить об адекватности построенной оптимальной нейронной сети, необходимо выяснить, на какой части области определения входных параметров нейронная сеть ведет себя корректно. На рисунках 5 – 8 приведены зависимости между выходами сети и эталоном для используемых параметров.

В результате исследования получено, что построенная нейронная сеть корректно выполняет прогнозирование на интервале изменения внутреннего диаметра трубопровода до 600 мм при концентрациях кислорода до 45 мкг/кг и на временном интервале от одного года до четырех лет.

Алгоритмы обучения и модели нейронных сетей. Прежде всего нейронные сети классифицируют по способу обучения: с учителем или без учителя. При обучении с учителем предполагается, что для каждого входного вектора существует целевой вектор, представляющий собой требуемый выход. Вместе они называются обучающей парой. Обычно сеть обучается на некотором числе таких пар, пока ошибка по всему обучающему массиву не достигнет приемлемо низкого уровня.

Обучение без учителя не нуждается в целевом векторе для выходов, следовательно, не требуется сравнение с predetermined идеальными ответами. Обучающее множество состоит лишь из входных векторов. Обучающий алгоритм подстраивает веса сети так, чтобы получались согласованные выходные векторы, т. е. чтобы предъявление достаточно близких входных векторов давало одинаковые выходы.

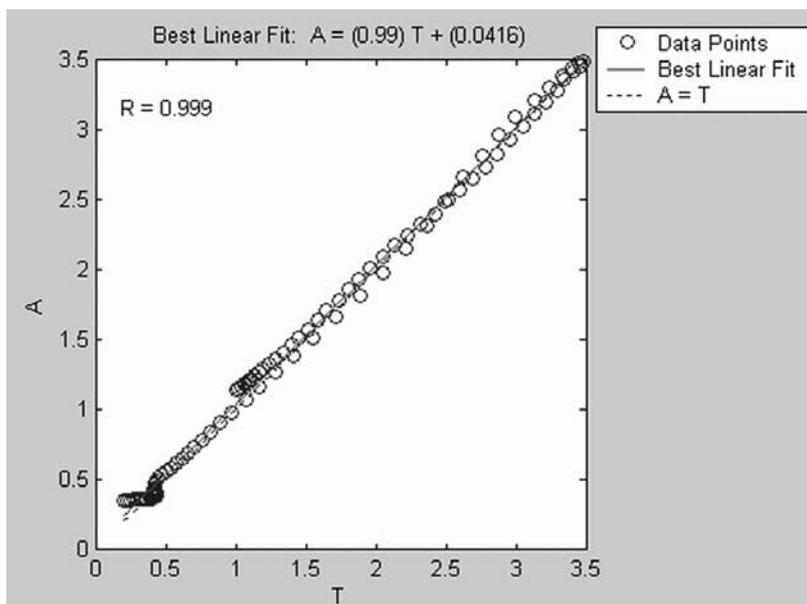


Рис. 5. Фрагмент экрана вывода результатов. График линейной регрессии между выходом оптимальной сети и эталоном в зависимости от температуры

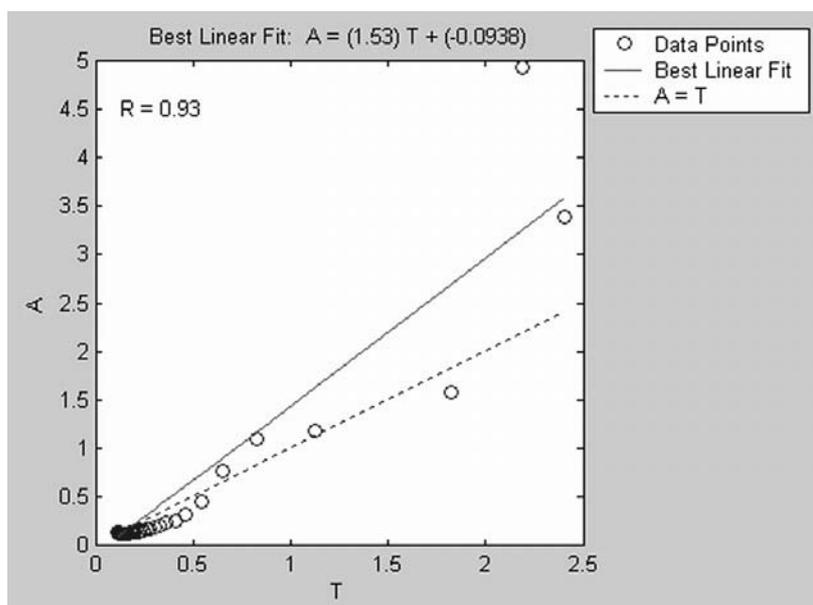


Рис. 6. Фрагмент экрана вывода результатов. График линейной регрессии между выходом оптимальной сети и эталоном в зависимости от содержания кислорода

Процесс обучения, следовательно, выделяет статистические свойства обучающего множества и группирует сходные векторы в классы. Предъявление на вход вектора из данного класса даст определенный выходной вектор, но до обучения невозможно предсказать, какой выход будет производиться данным классом входных векторов. Следовательно, выходы подобной сети должны трансформироваться в некоторую понятную форму, обусловленную процессом обучения.

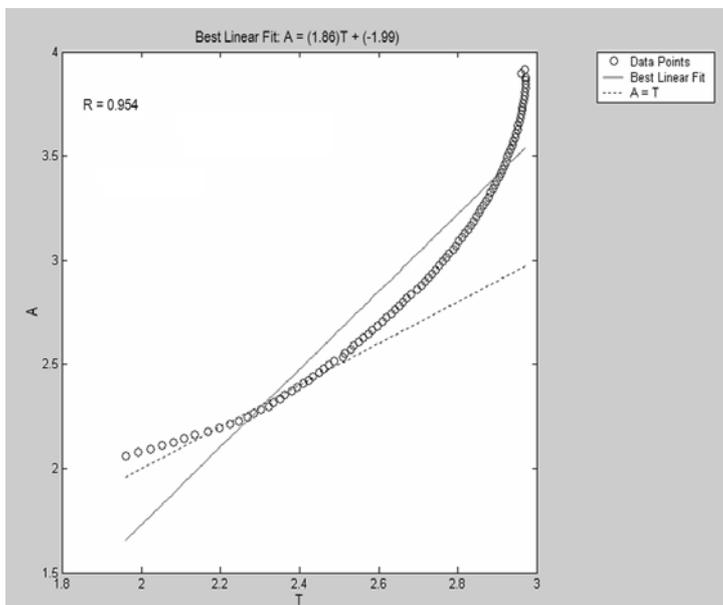


Рис. 7. Фрагмент экрана вывода результатов. График линейной регрессии между выходом оптимальной сети и эталоном в зависимости от внутреннего диаметра трубопровода

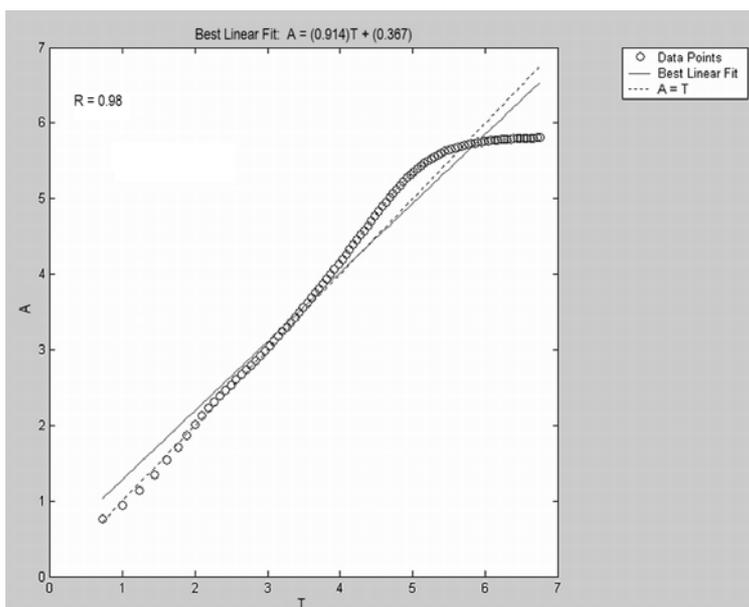


Рис. 8. Фрагмент экрана вывода результатов. График линейной регрессии между выходом оптимальной сети и эталоном в зависимости от времени эксплуатации

Предлагается скомбинировать рассмотренные модели нейронных сетей таким образом, чтобы оптимизировать решение задачи прогнозирования скорости ЭКИ с помощью НС для повышения качества ожидаемого прогноза.

При подробном изучении алгоритмов обучения НС выяснено, что для решения поставленной задачи нельзя обойтись только методами обучения НС без учителя, т. к. основной задачей, которая решается такими сетями, является классификация, выделение признаков из данных. Но сочетание подобных методов с алгоритмами обучения НС с учителем (например, алгоритмом обратного рас-

пространения ошибки) может улучшить и упростить решение задачи прогнозирования скорости ЭКИ.

Для сокращения размерности входного вектора можно использовать *репликативную нейронную сеть* [4, 5]. Цель обучения такой НС состоит в том, чтобы вектор, воспроизводимый выходным слоем, совпадал с вектором, поданным на входной слой. Можно сказать, что обучение производится без учителя, так как эталонами являются сами входные данные. Предварительная обработка входных данных с помощью репликативной сети, отображающей m -мерное входное пространство в n -мерное ($n < m$) путем «выявления» характерных признаков входного множества, позволяет упростить дальнейшее обучение основной НС, решающей задачу прогнозирования.

Самоорганизующиеся карты Кохоннена полезны для повышения точности прогнозирования ЭКИ. В этих картах нейроны помещаются в узлах решетки, обычно одно- или двумерной. В ходе конкурентного процесса нейроны избирательно настраиваются на различные входные образы или классы входных образов. Положения нейронов при настройке упорядочиваются по отношению друг к другу так, что на решетке создается значимая система координат. Сеть, представляющая самоорганизующиеся карты Кохоннена, обучается по следующему алгоритму.

1. Вектор входного множества \mathbf{x} подается на вход сети.
2. Определяются расстояния D_j между \mathbf{x} и весовыми векторами \mathbf{w}_j каждого нейрона по формуле

$$D_j = \sqrt{\sum_i (x_i - w_{ij})^2},$$

где x_i – i -й элемент входного вектора \mathbf{x} , w_{ij} – вес входа i нейрона j .

3. Нейрон, имеющий весовой вектор, ближайший к \mathbf{x} , объявляется победителем. Этот весовой вектор, называемый \mathbf{w}_c , становится основным в группе весовых векторов, которые лежат в пределах расстояния D от \mathbf{w}_c .

4. Группа весовых векторов настраивается в соответствии с условием

$$\mathbf{w}_j(t+1) = \mathbf{w}_j(t) + \alpha[\mathbf{x} - \mathbf{w}_j(t)]$$

для всех весовых векторов в пределах расстояния D от \mathbf{w}_c .

5. Повторяются шаги с первого по четвертый для каждого входного вектора.

Обучающий алгоритм настраивает весовые векторы в окрестности возбужденного нейрона таким образом, чтобы они были похожими на входной вектор. В процессе обучения группа соседних весовых точек перемещается ближе к точке входного вектора. Входные векторы группируются в классы в соответствии с их положением в векторном пространстве. Определенный класс ассоциируется с определенным нейроном, перемещая его весовой вектор в направлении центра класса и способствуя его возбуждению при появлении на входе любого вектора данного класса.

После сокращения размерности входного вектора с помощью репликатора и получения закодированного входного сигнала нужно определить, к какому из классов входного пространства этот сигнал принадлежит. Наконец, для каждого класса входного множества должна быть построена НС, обученная с помощью алгоритма обратного распространения, которая и будет вычислять нужный прогноз – утонение стенки трубопровода относительно номинальной величины за прогнозируемый срок.

Таким образом, интеллектуальная система, реализованная как комплекс нейронных сетей, решающий задачу прогнозирования скорости ЭКИ, состоит из трех типов НС:

- репликативная нейронная сеть, сокращающая размерность входного множества;
- самоорганизующаяся карта Кохоннена, классифицирующая входной сигнал;
- нейронные сети, обученные с помощью алгоритма обратного распространения, реализующие вычисление прогнозируемой величины для каждого класса входных сигналов.

Предлагаемая интеллектуальная система позволяет оптимизировать объем обучающего множества для произвольного количества параметров модели.

ЗАКЛЮЧЕНИЕ

Реализован нейросетевой подход, позволяющий оценить взаимное влияние факторов, определяющих интенсивность процесса ЭКИ в оборудовании АС, выделить существенные свойства поступающей информации и, в конечном итоге, улучшить точность прогноза.

Средствами ПО *Matlab* разработана искусственная нейронная сеть, решающая задачу прогнозирования утонения стенки прямого участка трубопровода с однофазной средой второго контура АЭС с ВВЭР. Сеть обучена с помощью алгоритма упругого обратного распространения, выполнено исследование нескольких конфигураций НС и проведен анализ полученных результатов.

В результате построена концептуальная схема прикладной интеллектуальной системы, реализованной в виде комплекса из трех видов НС: репликативной НС, самоорганизующейся карты Кохоннена и НС, обученной с помощью алгоритма обратного распространения.

Литература

1. Бараненко В.И., Янченко Ю.А., Гулина О.М., Докукин Д.А. О расчете скорости эрозионно-коррозионного износа и остаточного ресурса трубопроводов АЭС// Известия вузов. Ядерная энергетика. – 2010. – № 2. С.55-63.
2. Chexal V.K. (Bind), Horowitz J.S. Chexal-Horowitz Flow-Accelerated Corrosion Model-Parameter and Influences. Current perspective of Inter. Pressure vessels and Piping: Codes and Standard. Book No. 409768. –1995. – PP. 231-243.
3. Гулина О.М., Бараненко В.И., Докукин Д.А. Методологическая основа прогнозирования эрозионно-коррозионного износа оборудования АС методом нейросетевого моделирования// Известия вузов. Ядерная энергетика. – 2008. – № 1. С. 3-8.
4. Уоссерман Ф. Нейрокомпьютерная техника: теория и практика./ Пер. на русский язык Ю. А. Зуева, В. А. Точенова, 1992. www.codenet.ru/progr/alg/nks/
5. Свинглер К. Применение Neural Networks. Практическое руководство./ Пер. Ю.П. Маслобова. Свободный доступ на http://matlab.exponenta.ru/neuralnetwork/book4/3_3.php

Поступила в редакцию 18.02.2015 г.

Авторы

Вишнякова Анастасия Дмитриевна, инженер
E-mail: anvish@iate.obninsk.ru

Гулина Ольга Михайловна, профессор, доктор техн. наук
E-mail: olga@iate.obninsk.ru

Сальников Николай Леонидович, профессор, доктор техн. наук
E-mail: salnikov@iate.obninsk.ru

UDC 621.039:004.8

APPLICATION OF A NEURAL NETWORK TO PREDICT THE FAC RATE OF NPP EQUIPMENT

Vishnyakova A.D., Gulina O.M., Salnikov N.L.

Obninsk Institute for Nuclear Power Engineering, National Research Nuclear University «MEPhI». 1, Studgorodok, Obninsk, Kaluga reg., 249040 Russia

ABSTRACT

NPP piping elements manufactured from carbon steel are subjected to Flow-Accelerated Corrosion (FAC) process. Consequence of this process is broken piping element until the leak appears. So prediction of the FAC rate is very important for

NPP safety and economy. The rate of FAC process is defined by the large number of parameters influencing each to other by different manner. Such factors are about 12. There are some procedures to predict FAC rate but the problem of mathematical model parameters estimation is very complicated. Using of neural network (NNW) to predict FAC rate allows estimating of factors mutual influence, defining important of data and improving of prediction accuracy without definition of functions between factors. The paper deals with development and education of optimal NNW to predict the FAC rate at NPP piping. From review of some different NNW, methods of network education and analysis of control data (control of thickness of piping) there is realizing the NNW to predict the FAC rate at NPP straight pipe with single-phase flow for PWR by means of MatLab. Some configurations of NNW are researching. To arise NNW extension capacity there is solved to build decremented network. To estimate the number of latent layers the Kolmogorov theorem is applied. For example NNW with four factors is considering. For some areas of factors values correct behavior of NNW is shown. As result there is suggesting the conceptual scheme of intellectual system as complex of three types of NNW: replicate NNW, self-adjusting card of Cokhonnen and inverse propagation NNW.

Key words: neural network, education algorithm, erosion-corrosion wear, NPP piping.

REFERENCES

1. Baranenko V.I., Yanchenko Y.A., Gulina O.M., Dokukin D.A. O raschyote skorosti erozionno-korrozionnogo iznosa i ostatochnogo resursa truboprovodov AES (Estimation of FAC Rate and Service Life for NPP Piping). *Izvestiya vuzov. Yadernaya energetika*. 2010, no. 2, pp. 55-63.
2. Chexal V.K. (Bind), Horowitz J.S. Chexal-Horowitz Flow-Accelerated Corrosion Model-Parameter and Influences. *Current perspective of Inter. Pressure vessels and Piping: Codes and Standard*. Book No. 409768, 1995, pp. 231-243.
3. Gulina O.M., Baranenko V.I., Dokukin D.A. Metodologicheskaya osnova prognozirovaniya erozionno-korrozionnogo iznosa oborudovaniya AES metodom neirosetevogo modelirovaniya (Methodological base to predict the FAC rate by Neural Network Modeling). *Izvestiya vuzov. Yadernaya energetika*. 2008, no. 1, pp. 3-8.
4. Wassermann F. Neirokomp'yuternaya tehnika: teoriya i praktika (Neural computer technology: Theory and practice). 1992.
Avaiable at <http://www.codenet.ru/progr/alg/nks/> (in Russian).
5. Swingler K. Primenenie Neural Networks. Prakticheskoe rukovodstvo (*Neural Networks Application. Guidance*).
Avaiable at http://matlab.exponenta.ru/neuralnetwork/book4/3_3.php/ (in Russian).

Authors

Vishnyakova Anastasiya Dmitrievna, Engineer

E-mail: anvish@iate.obninsk.ru

Gulina Ol'ga Mihajlovna, Professor, Dr. Sci. (Engineering)

E-mail: olga@iate.obninsk.ru

Salnikov Nikolaj Leonidovich, Professor, Dr. Sci. (Engineering)

E-mail: salnikov@iate.obninsk.ru