

# НАУЧНО-ТЕХНИЧЕСКИЙ

## РАЗДЕЛ

УДК 539.4:620.178

**Деформационные кривые усталости сталей и методы определения их параметров. Сообщение 2. Методы, основанные на использовании искусственных нейронных сетей**

**В. Т. Трощенко<sup>a</sup>, Л. А. Хамаза<sup>a</sup>, В. А. Апостолюк<sup>b</sup>, Ю. Н. Бабич<sup>a</sup>**

<sup>a</sup> Институт проблем прочности им. Г. С. Писаренко НАН Украины, Киев, Украина

<sup>b</sup> Национальный авиационный университет, Киев, Украина

*Исследована возможность использования искусственных нейронных сетей для прогнозирования деформационных характеристик сталей (параметров уравнения кривой усталости Басквина–Мэнсона–Коффина) на основе характеристик прочности и пластичности при статическом нагружении путем создания четырех независимых нейронных сетей с различной конфигурацией входных и выходных данных. Показано, что прогнозирование параметров уравнения Басквина–Мэнсона–Коффина и расчет долговечностей при использовании искусственных нейронных сетей обеспечивают более высокую точность, чем существующие традиционные методы.*

**Ключевые слова:** искусственная нейронная сеть, параметры уравнения кривой усталости Басквина–Мэнсона–Коффина, долговечность, характеристики прочности и пластичности при статическом нагружении.

**Введение.** Ранее [1] проанализированы предложенные в литературных источниках методы оценки параметров деформационных кривых усталости (параметров уравнения Басквина–Мэнсона–Коффина) и показаны недостатки их определения. В данной работе исследуется возможность прогнозирования параметров деформационных кривых усталости на основе использования искусственных нейронных сетей (ИНС).

**Общая характеристика искусственных нейронных сетей.** Нейронная вычислительная методология является относительно новым направлением искусственного интеллекта, при разработке которой предпринимаются попытки имитировать структуру и работу биологических нейронных систем, таких как человеческий мозг, путем создания ИНС в компьютере. Использование ИНС особенно актуально при решении проблем, не имеющих четкой формулировки, или при необходимости воспроизведения какой-либо закономерности, которую трудно описать на основе известных физических моделей.

Методология такого подхода с исчерпывающим описанием нейронных сетей, учитывая многодисциплинарную природу этого предмета, изложена в

работе [2]. Ниже приводятся лишь общая характеристика ИНС и возможность их использования применительно к решению прикладных инженерных задач.

Искусственные нейронные сети состоят из простых взаимосвязанных элементов, называемых элементами обработки информации, или искусственными нейронами, которые действуют как микропроцессоры. Нейрон таким образом представляет собой единицу обработки информации в нейронной сети. На рис. 1 показана модель нейрона, положенного в основу ИНС [2], в которой можно выделить три основных элемента.

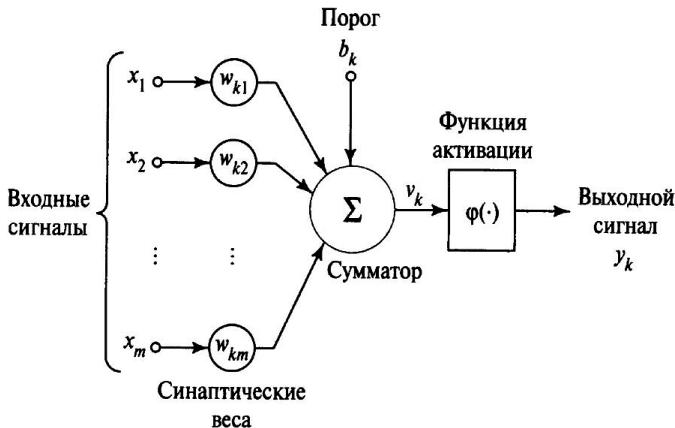


Рис. 1. Нелинейная модель нейрона.

1. Набор синапсов (или связей), каждый из которых характеризуется своим весом или силой связи. В частности, сигнал  $x_j$  на входе синапса  $j$ , связанного с нейроном  $k$ , умножается на вес  $w_{kj}$ . В отличие от синапсов мозга, синаптический вес искусственного нейрона может иметь как положительные, так и отрицательные значения.

2. Сумматор складывает входные сигналы, взвешенные относительно соответствующих синапсов нейрона. Эту операцию можно описать как линейную комбинацию.

3. Функция активации ограничивает амплитуду выходного сигнала нейрона. Эта функция также называется функцией сжатия. Обычно нормированный диапазон амплитуд выхода нейрона лежит в интервале  $[0, 1]$  или  $[-1, 1]$ .

В модель нейрона (рис. 1) включен пороговый элемент  $b_k$  (порог). Эта величина отражает увеличение или уменьшение входного сигнала, подаваемого на функцию активации.

В математическом представлении функционирование нейрона  $k$  можно описать следующей парой уравнений:

$$v_k = \sum_{j=1}^m w_{kj} x_j; \quad (1)$$

$$y_k = \varphi(v_k + b_k), \quad (2)$$

где  $x_1, x_2, \dots, x_m$  – входные сигналы;  $w_{k1}, w_{k2}, \dots, w_{km}$  – синаптические веса нейрона;  $v_k$  – линейная комбинация входных воздействий;  $b_k$  – порог;  $\varphi(\cdot)$  – функция активации;  $y_k$  – выходной сигнал нейрона.

Между различными нейронами, а также между функцией активации и пороговым значением внутри нейрона существуют связи (синапсы), которые характеризуются своим весом или силой связи. Активация (возбуждение или торможение) нейрона зависит от суммы веса входных сигналов и может быть либо положительной, либо отрицательной, либо равной нулю. Выходной сигнал нейрона вычисляется с использованием функции активации, которая также зависит от суммы синаптических весов и может быть положительной, отрицательной или равной нулю. Тип используемой функции активации зависит от типа разрабатываемой нейронной сети.

Искусственные нейронные сети обладают способностью обучаться на примерах. Обучение подразумевает изменение синаптических весов на основе набора маркированных учебных примеров, каждый из которых состоит из входного сигнала и соответствующего ему желаемого отклика. Из этого множества случайным образом выбирается пример, а ИНС модифицирует синаптические веса для минимизации расхождений между желаемым выходным сигналом и формируемым сетью согласно выбранному статистическому критерию. Это обучение проводится до тех пор, пока изменения синаптических весов не станут незначительными. Таким образом, ИНС обучается на примерах (на так называемом тренировочном наборе данных), составляя таблицу “вход–выход” для конкретной задачи. Обучившись на примерах из тренировочного набора данных, ИНС может затем самостоятельно осуществлять их классификацию, давать предсказания или принимать решения при предъявлении новых данных.

В литературных источниках представлено широкое разнообразие ИНС. Каждый тип ИНС имеет свои преимущества и недостатки в зависимости от решаемых задач. Одни из них применимы к решению задач оптимизации, тогда как другие используются при решении задач адаптации и обучения. Однако большинство ИНС, как правило, используются в структурах распознавания и классификации. Наиболее популярной ИНС применительно к решению прикладных инженерных задач является так называемая нейронная сеть обратного распространения ошибки [3–6].

**Искусственные нейронные сети обратного распространения ошибки.** Искусственная нейронная сеть обратного распространения ошибки относится к классу многослойных сетей прямого распространения. Обычно сеть состоит из множества сенсорных элементов (входных узлов или узлов источника), которые образуют входной слой, одного или нескольких скрытых слоев вычислительных нейронов и одного выходного слоя нейронов. Такие сети обычно называют многослойными персепtronами. На рис. 2 показан структурный график многослойного персептрона с одним скрытым слоем и одним выходным слоем. Данная сеть является полносвязной. Это значит, что каждый нейрон в любом слое связан со всеми нейронами (узлами) предыдущего слоя. Сигнал передается по сети исключительно в прямом направлении, слева направо, от слоя к слою.

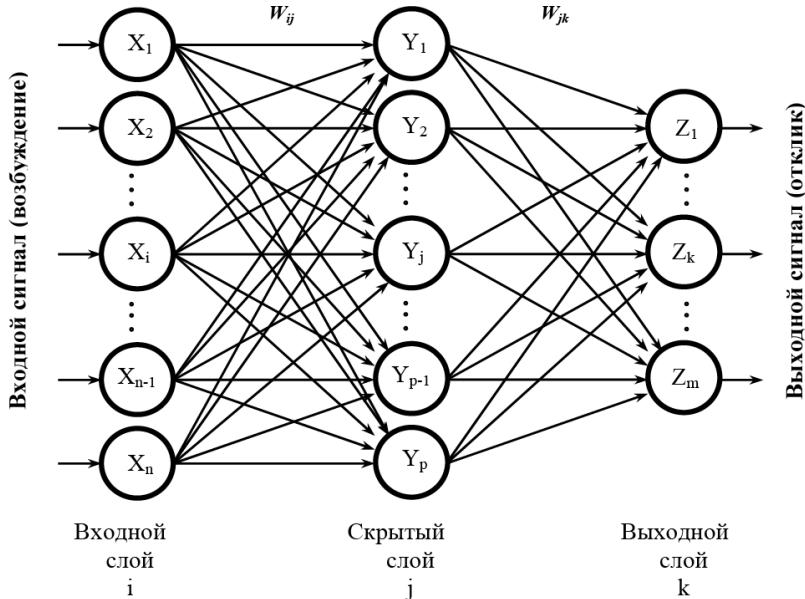


Рис. 2. Структурный график многослойного персептрана с одним скрытым слоем и одним выходным слоем.

Многослойные персептраны успешно применяются для решения разнообразных сложных задач. При этом обучение выполняется с помощью такого популярного алгоритма, как алгоритм обратного распространения ошибки, основанного на коррекции ошибок [2].

Обучение методом обратного распространения ошибки предполагает два прохода по всем слоям сети: прямой и обратный (рис. 3).

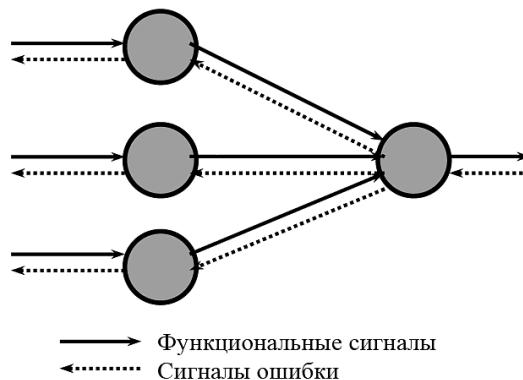


Рис. 3. Направление двух основных потоков сигнала для многослойного персептрана.

При прямом проходе входной (или функциональный) сигнал  $x_i$  ( $i=1, \dots, n$ ) подается на входные узлы сети  $X_i$  ( $i=1, \dots, n$ ), после чего он передается на все нейроны скрытого слоя. При этом каждый нейрон скрытого слоя  $Y_j$  ( $j=1, \dots, p$ ) суммирует входные сигналы, взвешенные относительно соответствующих синапсов нейрона ( $\sum x_i w_{ij}$ ), и с использованием активационной функции ( $\varphi$ ) передает активированное значение этой суммы в выходной слой:

$$y_j = \varphi \left( \sum_{i=1}^n x_i w_{ij} + b_j \right), \quad (3)$$

где  $w_{ij}$  – синаптический вес, связывающий выход нейрона  $i$  с его входом  $j$ ;  $b_j$  – порог.

В выходном слое каждый нейрон  $Z_k$  ( $k = 1, \dots, m$ ) производит суммирование входных сигналов от нейронов скрытого слоя, взвешенных относительно соответствующих синапсов нейрона ( $\sum y_j w_{jk}$ ), и с использованием функции ( $\varphi$ ) передает активированное значение этой суммы на выход нейросети:

$$z_k = \varphi \left( \sum_{i=1}^m y_i w_{ik} + b_k \right), \quad (4)$$

где  $w_{jk}$  – синаптический вес, связывающий выход нейрона  $j$  с его входом  $k$ ;  $b_k$  – порог.

В результате генерируется набор выходных сигналов, который и является фактической реакцией сети на данный входной сигнал. Во время прямого прохода все синаптические веса сети фиксированы. Кроме того, каждый нейрон имеет нелинейную функцию активации ( $\varphi$ ). Следует подчеркнуть, что данная нелинейная функция гладкая, т.е. всюду дифференцируема.

Одна из наиболее используемых форм функции, удовлетворяющих этому требованию, – сигмоидальная, определяемая логистической функцией (рис. 4, а):

$$\varphi_j = 1 / [1 + \exp(-\sum w_{ij}x_i + b_j)], \quad (5)$$

где  $w_{ij}$  – случайным образом выбранное значение синаптического веса от нейрона  $i$  в предыдущем слое к нейрону  $j$  в последующем слое;  $x_i$  – выходное значение сигнала нейрона  $i$ ;  $b_j$  – порог.

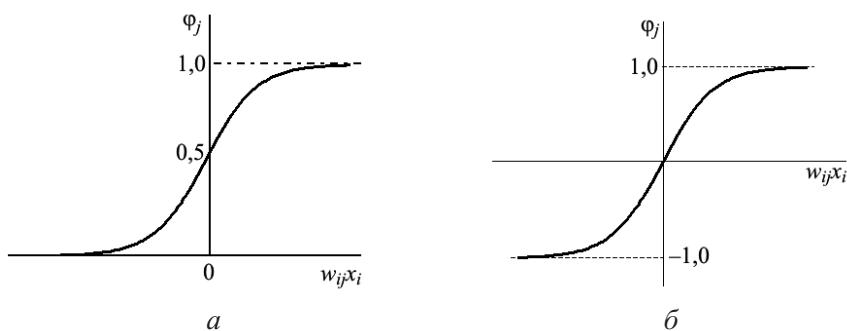


Рис. 4. Графики сигмоидальных функций активации: а – логистическая; б – гиперболического тангенса.

Часто используемой формой сигмоидальной нелинейности является также функция гиперболического тангенса (рис. 4, б), которая в общем виде описывается выражением

$$\varphi_j = a \operatorname{th}(b \Sigma w_{ij} x_i), \quad (a, b) > 0, \quad (6)$$

где  $a$  и  $b$  – константы. В действительности функция гиперболического тангенса является не более чем логистической функцией, только масштабированной и смещенной.

Во время обратного прохода все синаптические веса настраиваются в соответствии с правилом коррекции ошибок, а именно: фактический выход сети ( $o_k$ ) вычитается из желаемого отклика ( $d_k$ ), в результате чего формируется сигнал ошибки ( $e_k$ ):

$$e_k = d_k - o_k. \quad (7)$$

Этот сигнал впоследствии распространяется по сети в направлении, обратном направлению синаптических связей. Отсюда и название – алгоритм обратного распространения ошибки. Синаптические веса настраиваются с целью максимального приближения выходного сигнала сети к желаемому в статистическом смысле, что достигается за счет минимизации суммы среднеквадратических ошибок ( $e_k^2/2$ ) по всем нейронам выходного слоя:

$$E = \frac{1}{2} \Sigma e_k^2. \quad (8)$$

Осуществляется это следующим образом. Вычисляются локальные градиенты узлов сети. Локальный градиент нейрона  $j$ , расположенного в выходном слое, для логистической функции активации составляет:

$$\delta_k = e_k \varphi'_k = o_k (d_k - o_k)(1 - o_k), \quad (9)$$

для функции гиперболического тангенса –

$$\delta_k = e_k \varphi'_k = \frac{b}{a} (d_k - o_k)(a - o_k)(a + o_k), \quad (10)$$

где  $o_k$  – функциональный сигнал на выходе нейрона  $k$ ;  $d_k$  – его желаемый сигнал.

Локальный градиент нейрона  $j$ , расположенного в скрытом слое, для логистической функции активации будет:

$$\delta_j = \varphi'_j \Sigma \delta_k w_{jk} = o_j (1 - o_j) \Sigma \delta_k w_{jk}, \quad (11)$$

для функции гиперболического тангенса –

$$\delta_j = \varphi'_j \Sigma \delta_k w_{jk} = \frac{b}{a} (a - o_k)(a + o_k) \Sigma \delta_k w_{jk}, \quad (12)$$

где  $k$ -й слой является последующим по отношению к слою  $j$ .

Изменение синаптических весов слоя  $l$  сети выполняется в соответствии с обобщенным дельта-правилом

$$w_{ij}^{(l)}(n+1) = w_{ij}^{(l)}(n) + \alpha \delta_j^{(l)}(n) y_j^{(l-1)}(n) + \beta w_{ij}^{(l)}(n-1), \quad (13)$$

где  $y_j^{(l-1)}(n)$  – выходной сигнал нейрона  $j$ , расположенного в предыдущем слое  $(l-1)$ , на итерации  $(n)$ ;  $w_{ij}^{(l)}(n)$  – синаптический вес связи нейрона  $j$  слоя  $l$  с нейроном  $i$ -го слоя  $(l-1)$ ;  $\delta_j^{(l)}(n)$  – локальный градиент нейрона  $j$  на итерации  $(n)$ ;  $\alpha$  – параметр скорости обучения;  $\beta$  – постоянная момента.

Пошаговая корректировка синаптических весов нейронов продолжается до достижения системой устойчивого состояния, т.е. такого, при котором синаптические веса практически стабилизируются. В этот момент процесс обучения останавливается.

В последнее десятилетие ИНС широко используются при исследованиях в области прочности материалов, в частности – усталости, длительной прочности, механики разрушения [3–18].

Например, в работе [3] рассматривается ИНС обратного распространения для прогнозирования критического значения коэффициента интенсивности напряжений  $K_{Ic}$  в малоуглеродистой стали с использованием статических свойств материала (предела прочности, предела текучести и относительного удлинения при разрыве) при комнатной температуре с учетом влияния температуры испытания и ориентации плоскости распространения трещины. Исследованию и прогнозированию характеристик вязкости разрушения с использованием искусственных нейронных сетей посвящены также работы [4–10].

В [11] ИНС применяются для оценки индивидуальных деформационных характеристик сталей (параметров уравнения кривой усталости Басквина–Мэнсона–Коффина) на основе характеристик прочности и пластичности при статическом нагружении. Результаты нейросетевого моделирования показывают, что значения этих параметров на этапах тренировки и тестирования оцениваются с достаточно высокой точностью (коэффициент корреляции составляет 98...99%). Однако ничего не говорится о характере нейросети на этапе прогнозирования, т.е. когда тренированной нейросети предъявляются новые входные данные.

Построению кривой усталости и определению предела выносливости сталей с использованием нейронной сети обратного распространения посвящена работа [12]. При этом входными параметрами в ИНС служили такие характеристики: предел прочности и предел текучести материала; теоретический коэффициент концентрации напряжений; вид нагрузления (растяжение–сжатие, изгиб, кручение); амплитуда номинального напряжения. Показано, что точность предсказания результатов, достигаемая при расчетах с использованием нейросетей, выше, чем получаемая при традиционных аналитических методах расчета. Исследованию и прогнозированию характеристик усталости материалов с использованием ИНС посвящены также работы [13–17].

Моделирование длительной прочности аустенитных нержавеющих сталей на основе применения нейронных сетей рассматривается в [18].

**Метод оценки параметров деформационной кривой усталости с использованием искусственных нейронных сетей.** В настоящей работе исследована возможность использования ИНС для прогнозирования параметров уравнения кривой усталости Басквина–Мэнсона–Коффина на основе характеристик прочности и пластичности при статическом нагружении путем создания четырех независимых нейронных сетей с различной конфигурацией входных и выходных данных.

Каждая из четырех нейронных сетей представляет собой многослойный персепtron, состоящий из трех слоев нейронов: входного, скрытого и выходного, имеющего один нейрон. Структурный граф каждого из персептронов подобен представленному на рис. 2 с тем лишь отличием, что в выходном слое содержится только один нейрон.

Структура четырех нейронных сетей (выходной параметр, количество и содержание входных параметров, число нейронов в скрытом слое) для оценки параметров уравнения кривой усталости Басквина–Мэнсона–Коффина приведена в табл. 1.

Т а б л и ц а 1

Структура нейронных сетей для оценки параметров  $\sigma'_f$ ,  $\varepsilon'_f$ ,  $b$ ,  $c$ 

Выходные параметры	Количество входных параметров	Входные параметры	Число нейронов в скрытом слое
$\sigma'_f$	5	$\sigma_{\text{в}}$ , $\sigma_{0,2}$ , $HB$ , $\psi$ , $E$	10
$b$	6	$\sigma_{\text{в}}$ , $\sigma_{0,2}$ , $HB$ , $\psi$ , $E$ , $\sigma'_f$	11
$c$	7	$\sigma_{\text{в}}$ , $\sigma_{0,2}$ , $HB$ , $\psi$ , $E$ , $\sigma'_f$ , $b$	11
$\varepsilon'_f$	8	$\sigma_{\text{в}}$ , $\sigma_{0,2}$ , $HB$ , $\psi$ , $E$ , $\sigma'_f$ , $b$ , $c$	11

Последовательность использования нейронных сетей для оценки параметров  $\sigma'_f$ ,  $\varepsilon'_f$ ,  $b$ ,  $c$  следующая. В первую очередь оценивается коэффициент усталостной прочности  $\sigma'_f$ . При этом входными параметрами в нейронную сеть являются пять характеристик статической прочности и пластичности: предел прочности  $\sigma_{\text{в}}$ , предел текучести  $\sigma_{0,2}$ , твердость по Бринеллю  $HB$ , относительное сужение при разрыве  $\psi$ , модуль Юнга  $E$ . Остальные три параметра оцениваются в такой последовательности:  $b \rightarrow c \rightarrow \varepsilon'_f$ . При этом входные параметры каждой последующей нейронной сети состоят из входных данных, содержащихся в предыдущей нейронной сети, плюс определенный этой сетью параметр.

Обучение сетей осуществляется с использованием описанного выше алгоритма обратного распространения ошибки. Программа обучения написана на языке программирования Delphi, все тренировочные и прогнозные тесты выполнены на персональном компьютере.

Параметр интенсивности обучения  $\alpha$ , используемый в алгоритме обратного распространения, для всех четырех нейронных сетей принят равным 0,001. Малые значения параметра  $\alpha$  обеспечивают более медленную схо-

димость, при этом более точно определяется точка локального минимума на поверхности ошибок. Увеличение параметра  $\alpha$  для повышения скорости обучения, вследствие результирующего большого изменения синаптических весов, приводит систему в неустойчивое состояние.

Перед обучением нейронных сетей входные и выходные данные были масштабированы соответственно в пределах  $-1,0 \dots 1,0$  и  $-0,9 \dots 0,9$  согласно следующей зависимости:

$$X' = [(X - X_{\min}) / (X_{\max} - X_{\min})] (i_{\max} - i_{\min}) + i_{\min}, \quad (14)$$

где  $X_{\max}$  и  $X_{\min}$  – соответственно наибольшее и наименьшее значения  $X$ ;  $X'$  – масштабированное значение  $X$ ;  $i_{\max}$ ,  $i_{\min}$  – максимальное и минимальное значения  $X'$ .

Анализ параметров уравнения Басквина–Мэнсона–Коффина с использованием нейронных сетей базируется на экспериментальных данных о характеристиках прочности и пластичности при статическом и циклическом нагружении 190 различных сталей [1]. Это углеродистые, мало- и высоколегированные стали в широком диапазоне характеристик прочности ( $\sigma_{\text{в}}$  в интервале 410...2950 МПа), твердости (80...660 HB) и пластичности ( $\psi = 4 \dots 80\%$ ).

Экспериментальные данные 140 сталей использовались для тренировки нейронной сети, данные оставшихся 50 сталей – для прогнозирования одного из параметров уравнения Басквина–Мэнсона–Коффина с применением предварительно тренированной нейронной сети.

Сепарация общего количества 190 наименований сталей на 140 сталей, предназначенных для тренировки нейронной сети, и на 50 сталей, предназначенных для прогноза, осуществляется следующим образом.

На первом этапе тренировке подвергается нейронная сеть с использованием полного набора экспериментальных данных из 190 наименований сталей. Процесс обучения продолжается до достижения системой устойчивого состояния, т.е. такого, при котором средняя относительная ошибка определения оцениваемого параметра

$$MRE(\%) = \frac{1}{n} \sum_{i=1}^n \frac{|d_i - o_i|}{d_i} \cdot 100\%$$

и его среднеквадратическая ошибка

$$MSE(\%) = \sqrt{\frac{1}{n} \sum_{i=1}^n (d_i - \tilde{o}_i)^2},$$

где  $d_i$  – действительное значение оцениваемого параметра;  $o_i$  – его прогнозируемое значение;  $\tilde{o}_i$  – среднее значение прогнозируемого параметра, практически стабилизируются.

В процессе обучения нейронных сетей кроме непрерывного фиксирования параметра  $MRE(\%)$  производится определение максимальной относительной ошибки

$$RE_{\max}(\%) = \frac{|d_i - o_i|_{\max}}{d_i} \cdot 100\%,$$

а также коэффициента корреляции прогнозируемого значения оцениваемого параметра с его действительным значением ( $R$ ).

На следующем этапе из обученной таким образом нейронной сети отбираются 140 комплектов экспериментальных данных с худшими значениями относительной ошибки определения оцениваемого параметра

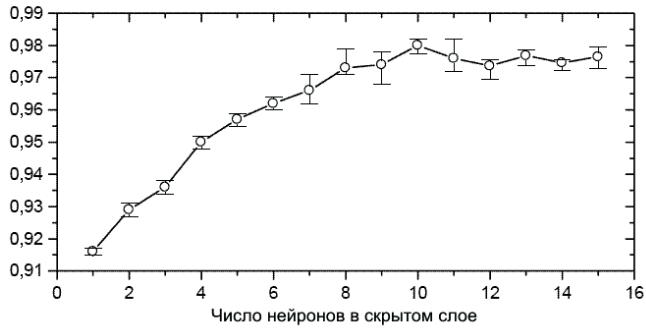
$$RE_i(\%) = \frac{|d_i - o_i|_i}{d_i} \cdot 100\%.$$

На базе отобранных экспериментальных данных 140 наименований сталей осуществляется обучение нейронной сети с последующим прямым прохождением через обученную сеть остальных 50 комплектов экспериментальных данных. Обучение нейронной сети с использованием для тренировки отобранных экспериментальных данных 140 наименований сталей продолжается многократно до тех пор, пока коэффициенты корреляции прогнозируемого значения оцениваемого параметра с его действительным значением ( $R$ ) и среднеквадратические ошибки оценки прогнозируемого параметра ( $MSE$ ) в обучаемой нейронной сети и для 50 прогнозируемых параметров не будут приблизительно равными или их разница будет минимальной. При этом критериями наиболее оптимальной обученной нейронной сети являются минимальная средняя относительная ошибка в определении оцениваемого параметра  $MRE(\%)$  и максимальное значение коэффициента корреляции ( $R$ ) как для обученной сети, так и для 50 прогнозируемых параметров.

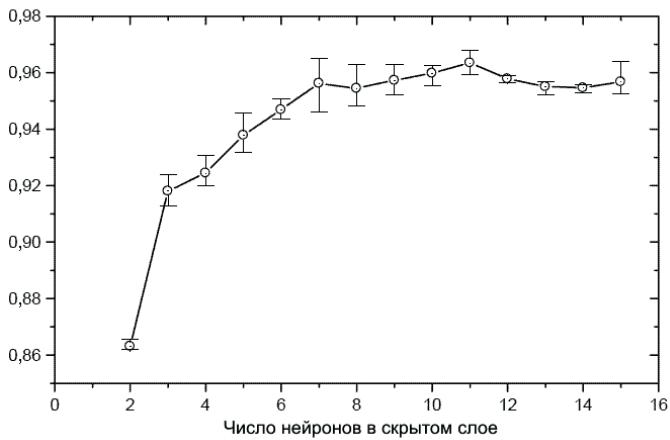
Определение оптимального количества нейронов в скрытом слое осуществляется следующим образом. На рис. 5,а в качестве примера проиллюстрирован принцип нахождения оптимальной архитектуры нейронной сети в терминах числа нейронов в скрытом слое. Рассматривается случай прогнозирования коэффициента циклической прочности  $\sigma'_f$ . Число нейронов на входе составляет 5, число нейронов на выходе – 1 и число имеющихся в распоряжении пар экспериментальных данных – 190 (140 для тренировки и 50 для прогнозирования). Там же представлена зависимость коэффициентов корреляции расчетного значения оцениваемого параметра с его действительным значением в обучаемой нейронной сети  $R_{\text{тр}}(\sigma'_f)$  и для 50 прогнозируемых параметров  $R_{\text{пр}}(\sigma'_f)$  от числа нейронов в скрытом слое. В каждом случае значения соответствующих коэффициентов корреляции определяются как среднее после 5...10 тренировочных проходов, осуществленных в идентичных условиях. Из этих данных следует, что при увеличении числа нейронов в скрытом слое от 1 до 10 значения коэффициентов корреляции быстро возрастают. Дальнейшее увеличение числа нейронов не приводит к росту коэффициентов корреляции, их значения несколько уменьшаются, а затем стабилизируются. На основании изложенного можно утверждать, что опти-

мальной для рассмотренной нейронной сети является архитектура с десятью нейронами в скрытом слое. Аналогично описанному выше были определены оптимальные архитектуры нейронных сетей для прогнозирования остальных трех параметров уравнения Басквина–Мэнсона–Коффина ( $\epsilon'_f$ ,  $b$  и  $c$ ). Результаты такого определения представлены на рис. 5, $\delta$ – $\varepsilon$  и в табл. 1.

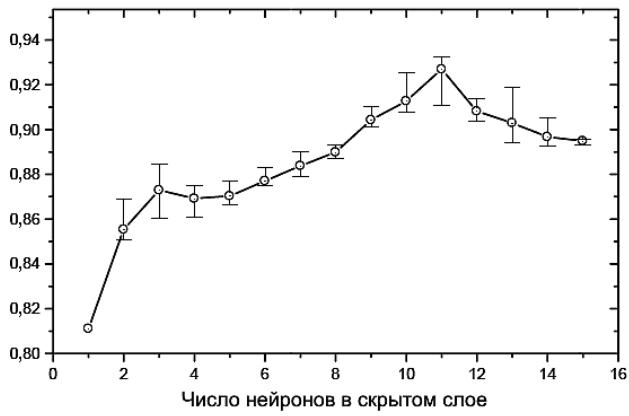
$$R_{\text{Tp}}(\sigma'_f) = R_{\text{np}}(\sigma'_f)$$

*a*

$$R_{\text{Tp}}(\epsilon'_f) = R_{\text{np}}(\epsilon'_f)$$

*δ*

$$R_{\text{Tp}}(b) = R_{\text{np}}(b)$$

*ε*

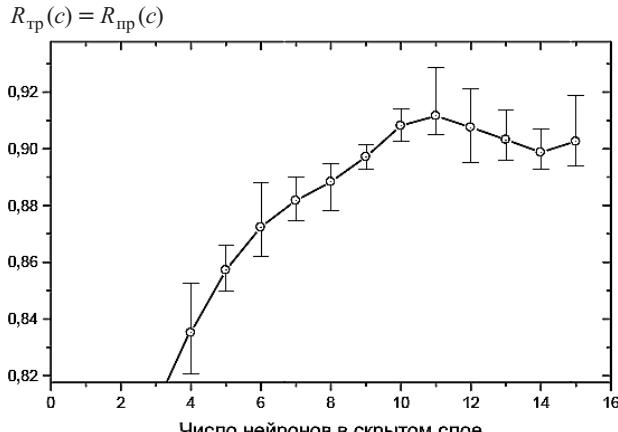


Рис. 5. Коэффициенты корреляции между предсказанными нейронными сетями и экспериментальными значениями коэффициентов усталостной прочности  $\sigma'_f$  ( $a$ ) и пластиичности  $\varepsilon'_f$  ( $b$ ), а также экспоненты усталостной прочности  $b$  ( $c$ ) и усталостной пластиичности  $c$  ( $\varepsilon$ ) для различного числа нейронов в скрытом слое.

На рис. 6 приведены результаты оценки параметров уравнения Басквина–Мэнсона–Коффина ( $\sigma'_f$ ,  $\varepsilon'_f$ ,  $b$  и  $c$ ) с использованием нейронных сетей для тренировочного и прогнозируемого набора экспериментальных данных. Можно констатировать достаточно высокую точность оценки деформационных усталостных характеристик с использованием нейронных сетей по сравнению с существующими традиционными методами.

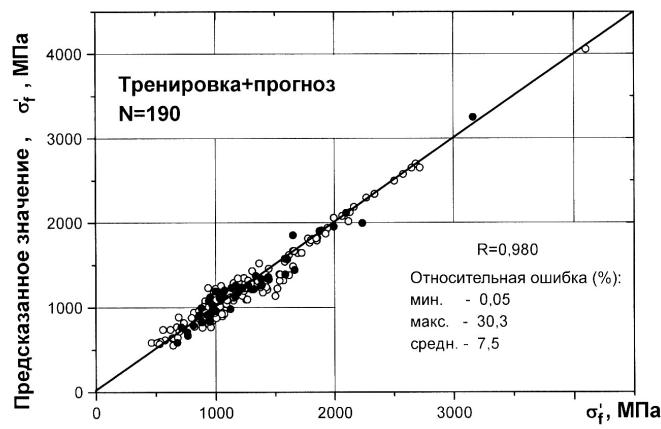
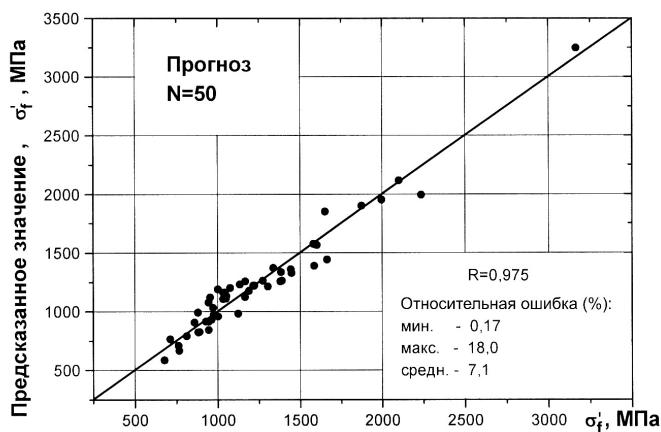
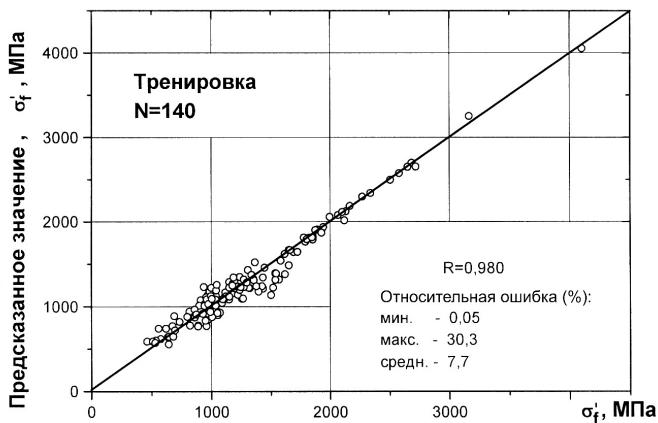
На рис. 7, 8 показано сравнение предсказаний по традиционным методам с таковыми при использовании искусственных нейронных сетей для рассматриваемых параметров. Видно, что средняя относительная ошибка оценки деформационных усталостных характеристик ( $\sigma'_f$ ,  $\varepsilon'_f$ ,  $b$  и  $c$ ) во втором случае намного меньше, чем в первом.

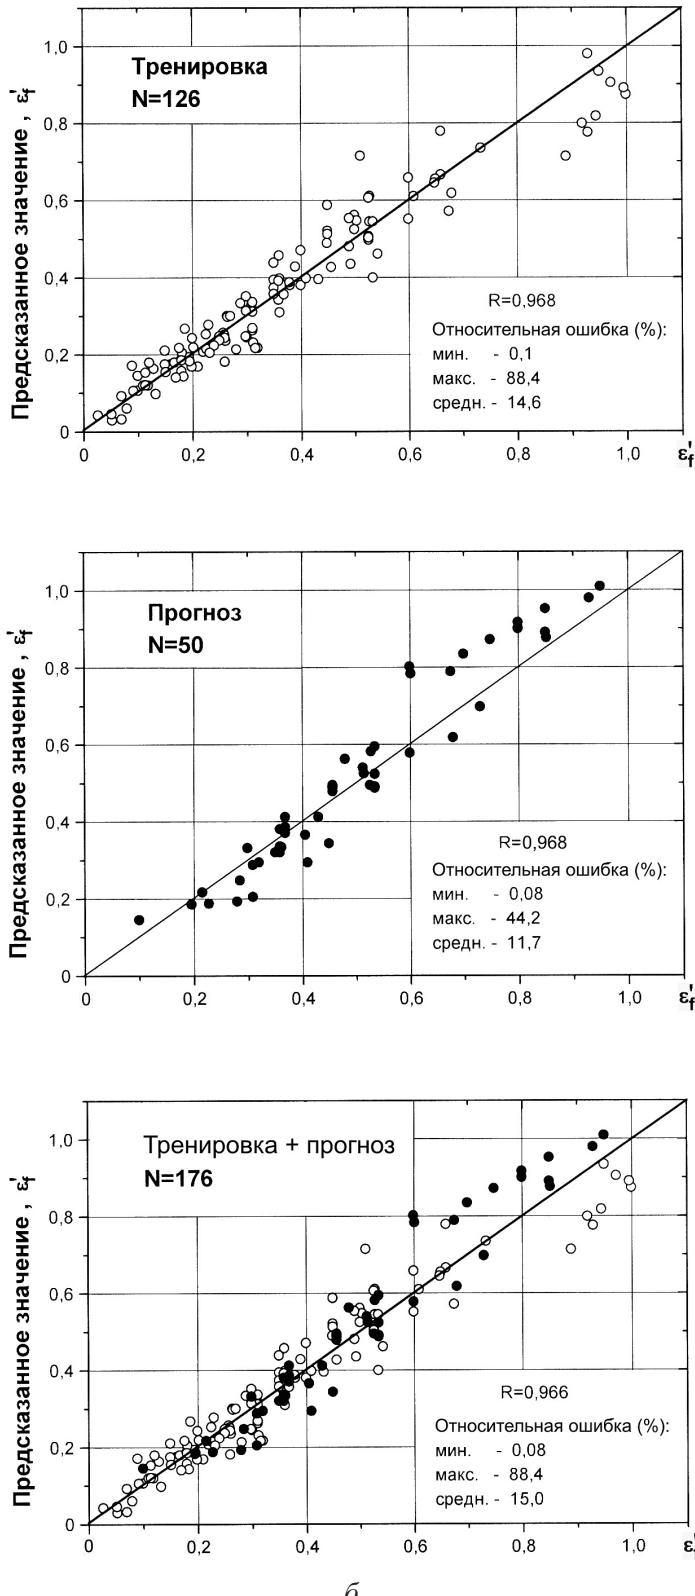
С использованием результатов оценки параметров уравнения Басквина–Мэнсона–Коффина с помощью ИНС для тренировочного и прогнозируемого набора экспериментальных данных проведем сравнение экспериментальных значений долговечностей с расчетными (рис. 9).

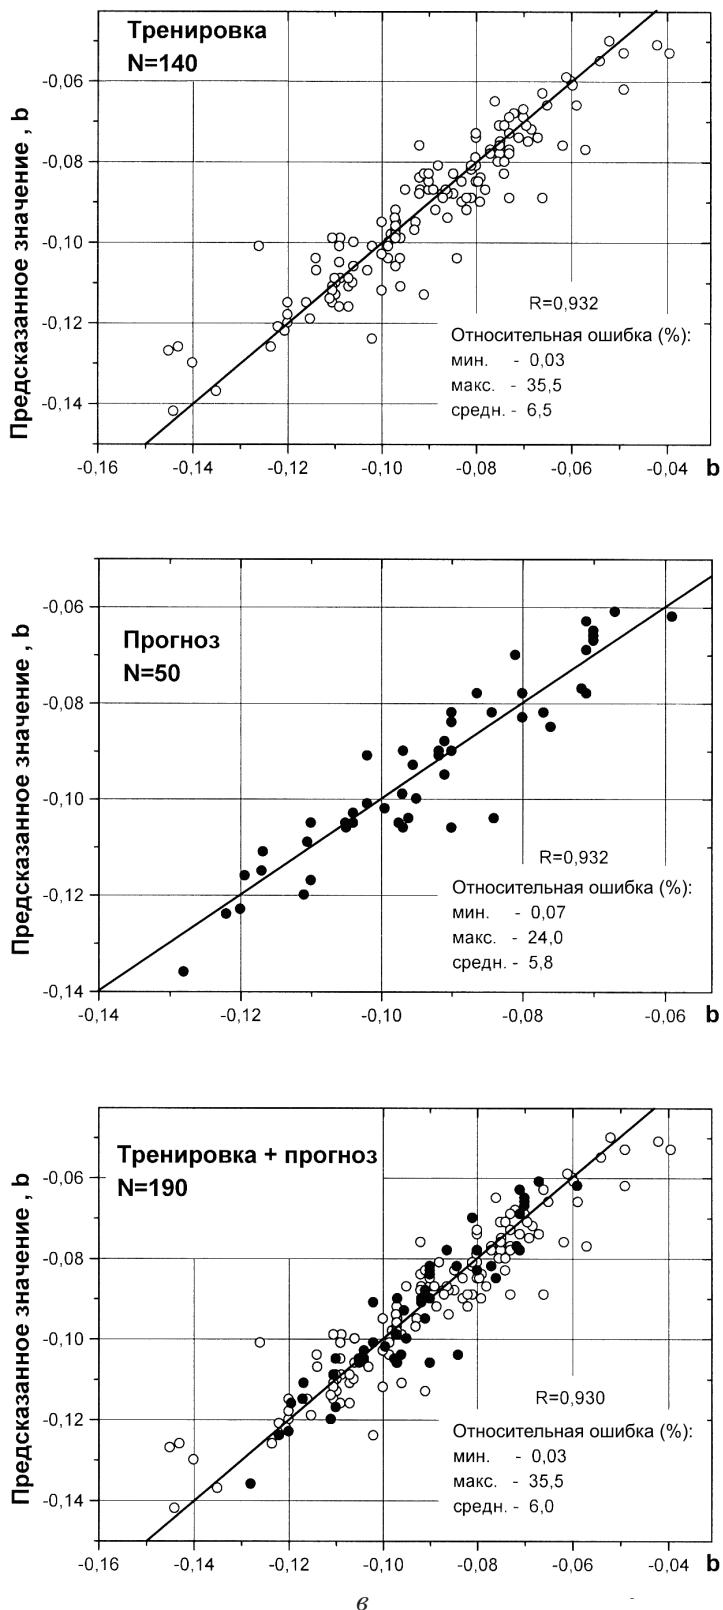
Для характеристики рассеивания результатов сравнения на рис. 9 приведено в процентном выражении количество данных сопоставления, соответствующее двух- (72,0%), трех- (91,1%), пяти- (98,1%) и десятикратному (99,8%) отклонению экспериментальных значений долговечностей от расчетных.

Анализ представленных на рис. 9 данных показывает, что расчет долговечностей при использовании искусственных нейронных сетей обеспечивает более высокую точность, чем существующие традиционные методы. Если, например, метод искусственных нейронных сетей дает хороший прогноз долговечности по сравнению с экспериментальной для не менее 98% данных сопоставления в полосе 5-кратного отклонения долговечностей, то для традиционных методов эта цифра составляет лишь 40...67%. В полосе 3-кратного отклонения долговечностей количество данных сопоставления с удовлетво-

рительным совпадением расчетных долговечностей с экспериментальными для метода искусственных нейронных сетей составляет не менее 91%, тогда как для традиционных методов – всего 28...55%. И наконец, в полосе 2-кратного отклонения долговечностей – 72 и 14...33% соответственно.

*a*





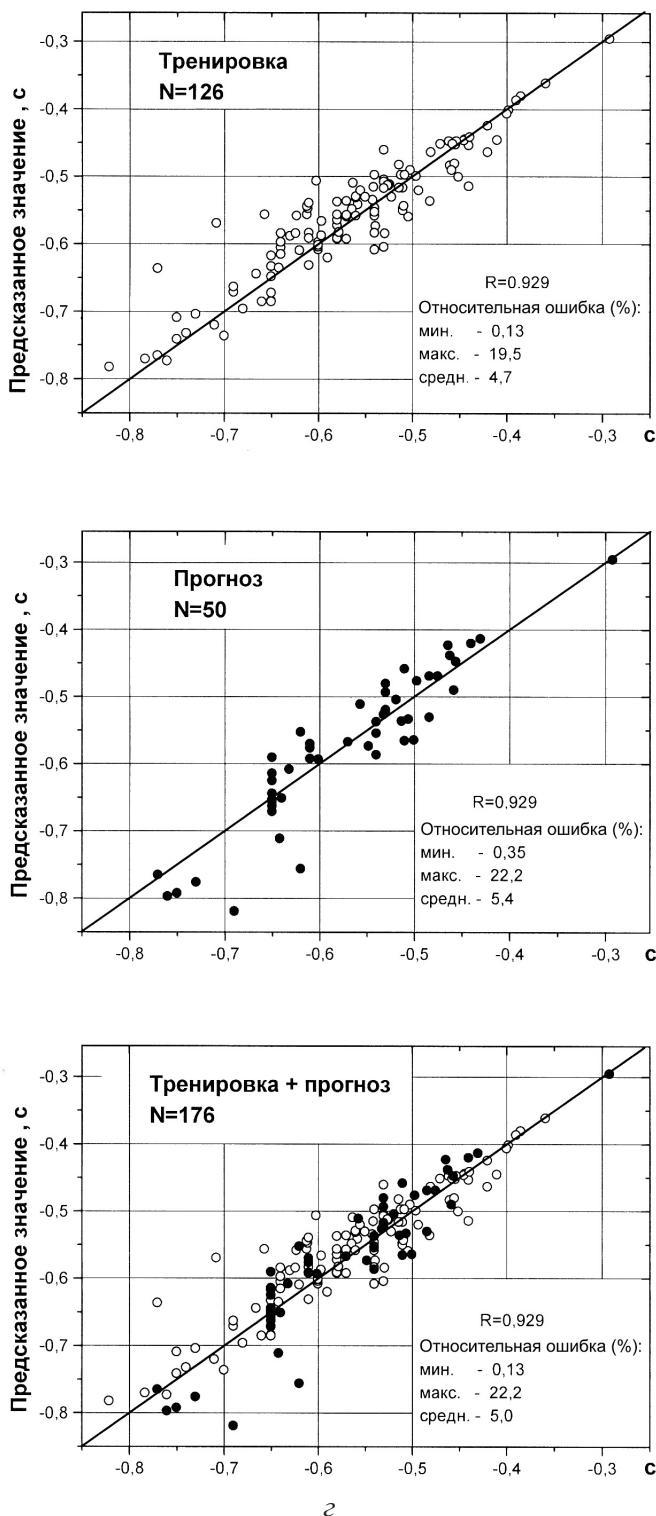


Рис. 6. Оценка коэффициентов усталостной прочности  $\sigma'_f$  (а) и пластичности  $\varepsilon'_f$  (б), а также экспоненты усталостной прочности  $b$  (в) и пластичности  $c$  (г) с использованием нейронных сетей. ( $N$  – количество экспериментальных точек.)

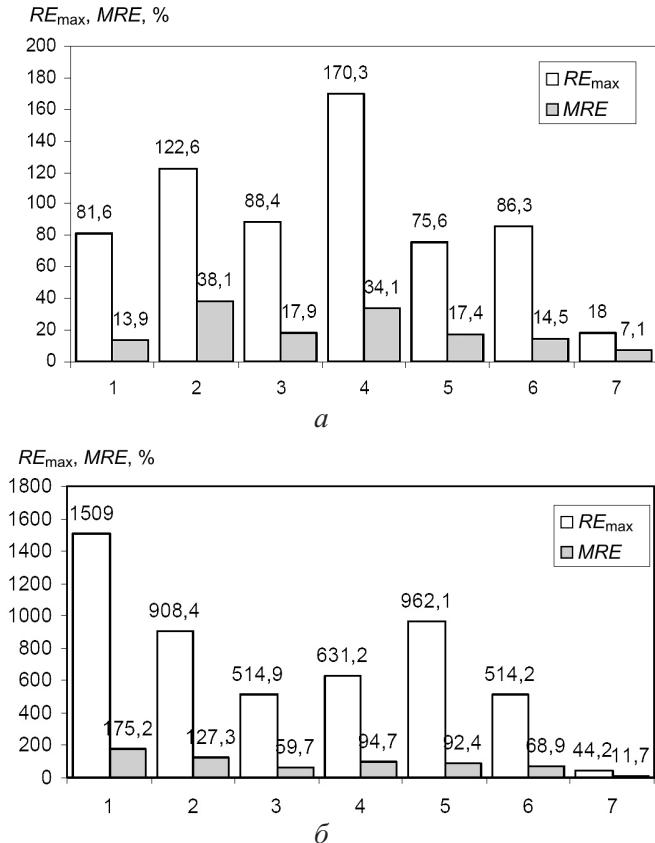


Рис. 7. Сравнение предсказаний по традиционным методам с таковыми при использовании искусственных нейронных сетей для коэффициентов усталостной прочности  $\sigma'_f$  (а) и пластичности  $\epsilon'_f$  (б). (Здесь и на рис. 8: 1 – метод Митчелла; 2 – метод универсальных наклонов; 3 – модифицированный метод универсальных наклонов; 4 – модифицированный метод четырехточечной корреляции; 5 – метод Боймеля–Зигера; 6 – метод твердости; 7 – искусственные нейронные сети.)

В заключение высажем некоторые соображения относительно способности нейронных сетей обратного распространения ошибки к хорошему обобщению.

Как показано выше, при обучении методом обратного распространения в сеть подается обучающая выборка и вычисляются синаптические веса многослойного персептрона, загружая в сеть максимально возможное количество примеров. При этом предполагается, что обученная таким образом сеть будет способна к обобщению. Сеть обладает хорошей обобщающей способностью, если отображение “входа на выход”, осуществляемое ею, является корректным (или близким к этому) для данных, никогда ранее не “виденных” сетью в процессе обучения. При этом полагают, что данные принадлежат той же совокупности, из которой они брались для обучения. Нейронная сеть, спроектированная с учетом хорошего обобщения, будет осуществлять корректное отображение “входа на выход” даже тогда, когда входной сигнал несколько отличается от примеров, использованных для обучения сети [1].

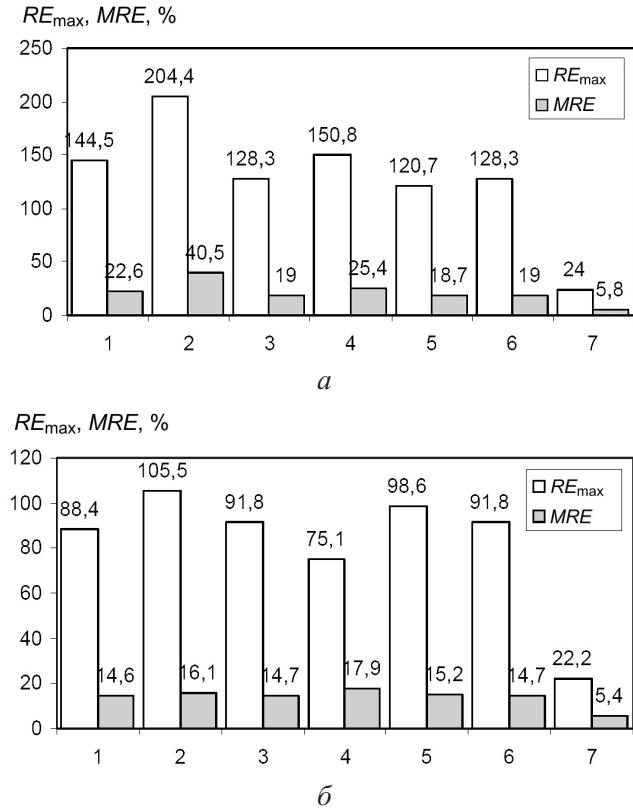


Рис. 8. Сравнение предсказаний по традиционным методам с таковыми при использовании искусственных нейронных сетей для экспонент усталостной прочности  $b$  (а) и пластичности  $c$  (б).

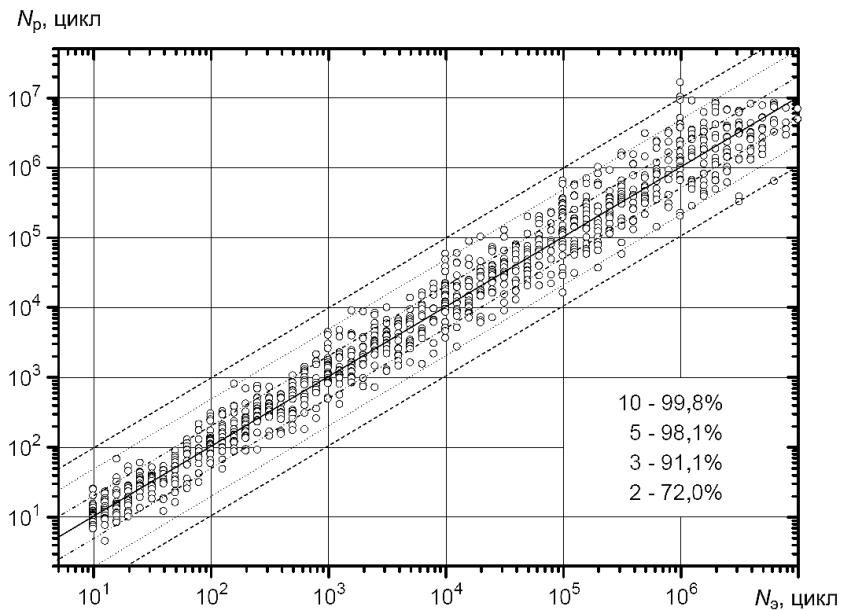


Рис. 9. Сравнение расчетных значений долговечности с экспериментальными при использовании искусственных нейронных сетей.

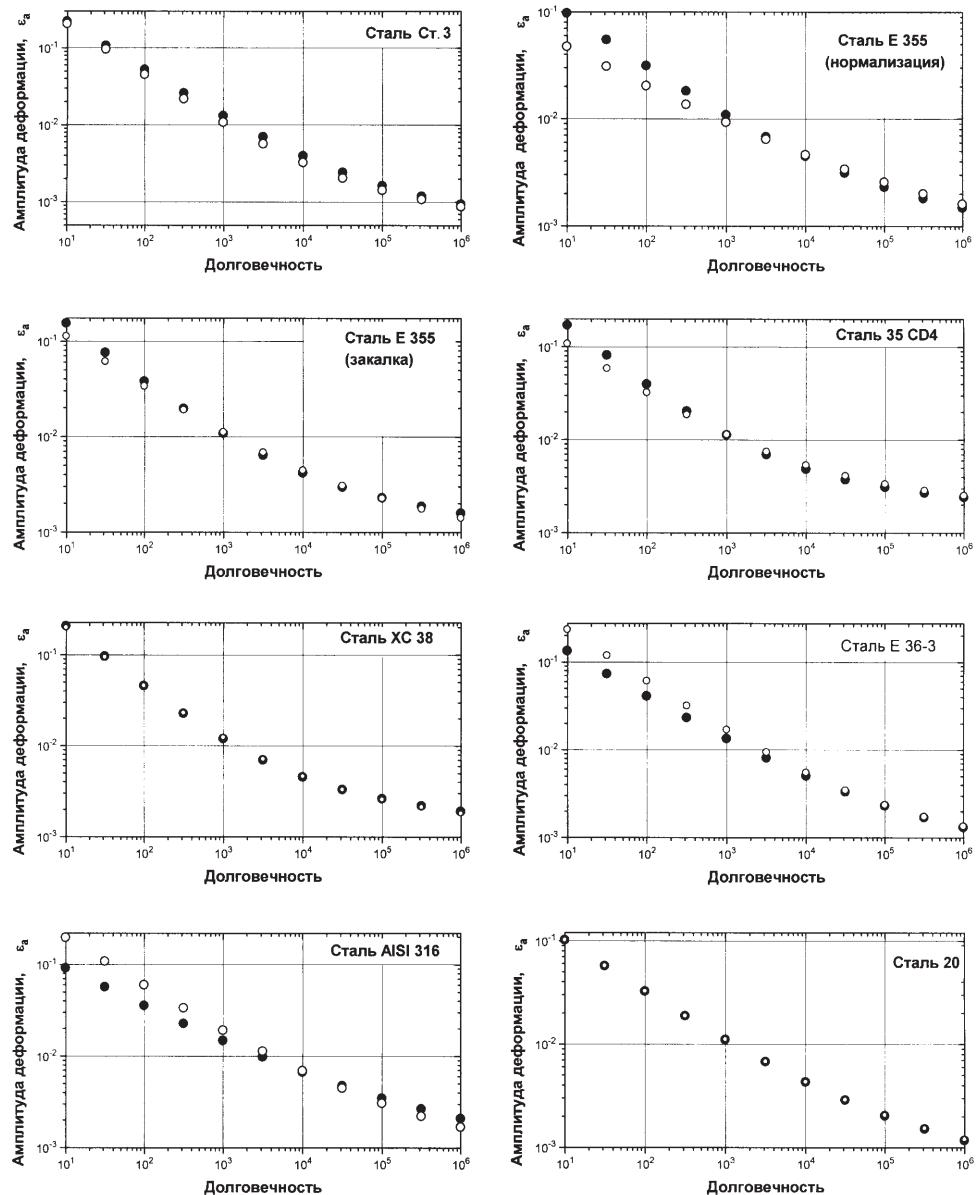


Рис. 10. Прямое сопоставление экспериментальных (●) значений долговечности с расчетными (○), полученными с использованием искусственных нейронных сетей.

Прямая иллюстрация возможностей разработанных нейронных сетей к хорошему обобщению при расчете полной диаграммы Басквина–Мэнсона–Коффина показана на рис. 10 для восьми различных материалов, которые не использовались в процессе обучения и тестирования (табл. 2).

В табл. 2 приведены механические характеристики сталей, на основе которых с использованием четырех нейронных сетей определялись параметры деформационных кривых усталости. Там же представлены экспериментальные (над чертой) и рассчитанные с использованием нейронных сетей (под чертой) значения параметров  $\sigma'_f$ ,  $\epsilon'_f$ ,  $b$  и  $c$ .

Т а б л и ц а 2

**Механические характеристики сталей и экспериментальные  
и расчетные значения параметров  $\sigma'_f$ ,  $\varepsilon'_f$ ,  $b$ ,  $c$**

Марка стали	$\sigma_b$ , МПа	$\sigma_{0,2}$ , МПа	$E$ , ГПа	$\psi$ , %	$HB$ , кг/мм <sup>2</sup>	$\sigma'_f$ , МПа	$\varepsilon'_f$	$b$	$c$	Литературный источник
Ст. 3	416	252	200,0	64,0	118	$\frac{698,0}{706,2}$	$\frac{0,9500}{0,9550}$	$\frac{-0,107}{-0,109}$	$\frac{-0,640}{-0,674}$	[19]
20	459	246	207,5	61,2	139	$\frac{871,0}{872,0}$	$\frac{0,3230}{0,3250}$	$\frac{-0,110}{-0,108}$	$\frac{-0,517}{-0,518}$	[19]
Е 355 (нормализация)	570	400	200,0	74,0	168	$\frac{860,0}{868,9}$	$\frac{0,3100}{0,1090}$	$\frac{-0,090}{-0,096}$	$\frac{-0,520}{-0,398}$	[20]
Е 355 (закалка)	760	570	210,0	50,0	225	$\frac{1239,0}{1228,0}$	$\frac{0,6500}{0,3860}$	$\frac{-0,100}{-0,113}$	$\frac{-0,640}{-0,553}$	[20]
35 CD4	1100	1005	210,0	62,0	280	$\frac{1323,0}{1362,0}$	$\frac{0,7825}{0,3800}$	$\frac{-0,072}{-0,073}$	$\frac{-0,675}{-0,569}$	[21]
ХС 38	750	525	195,0	63,0	222	$\frac{1248,0}{1261,4}$	$\frac{0,9720}{0,8910}$	$\frac{-0,091}{-0,096}$	$\frac{-0,686}{-0,666}$	[21]
Е 36-3	547	350	200,0	72,0	161	$\frac{1080,0}{1003,4}$	$\frac{0,4390}{0,9090}$	$\frac{-0,120}{-0,109}$	$\frac{-0,533}{-0,598}$	[21]
AISI 316	575	250	192,0	75,0	140	$\frac{1100,0}{1086,0}$	$\frac{0,2350}{0,6580}$	$\frac{-0,097}{-0,108}$	$\frac{-0,434}{-0,534}$	[21]

На рис. 10 экспериментальные и расчетные кривые усталости построены на основе параметров  $\sigma'_f$ ,  $\varepsilon'_f$ ,  $b$  и  $c$ , приведенных в табл. 2. Видно, что разработанные нейронные сети обеспечивают удовлетворительное их согласование при расчете полной диаграммы Басквина–Мэнсона–Коффина даже для материалов, не используемых в процессе проектирования искусственных нейронных сетей.

## Выводы

1. Разработан метод оценки параметров деформационной кривой усталости Басквина–Мэнсона–Коффина на основе характеристик прочности и пластичности при статическом нагружении, базирующийся на применении специально созданных четырех независимых нейронных сетей с различной конфигурацией входных и выходных данных.

2. Установлено, что оценка параметров уравнения Басквина–Мэнсона–Коффина  $\sigma'_f$ ,  $\varepsilon'_f$ ,  $b$  и  $c$  при использовании нейронных сетей осуществляется с достаточно высокой точностью. Сравнение предсказаний при использовании искусственных нейронных сетей с таковыми в соответствии с традиционными методами для рассматриваемых параметров показывает, что средняя и максимальная относительная ошибка оценки деформационных усталостных характеристик в первом случае намного меньше, чем во втором.

3. Расчет долговечностей при использовании искусственных нейронных сетей обеспечивает более высокую точность по сравнению с традиционными методами.

## Резюме

Досліджено можливість використання штучних нейронних мереж для прогнозування деформаційних характеристик сталей (параметрів рівняння кривої утоми Басквіна–Менсона–Кофіна) на основі характеристик міцності і пластичності при статичному навантаженні шляхом створення чотирьох незалежних нейронних мереж із різною конфігурацією входних і вихідних даних. Показано, що прогнозування параметрів рівняння Басквіна–Менсона–Кофіна і розрахунок довговічностей при використанні штучних нейронних мереж забезпечують більш високу точність, ніж існуючі традиційні методи.

1. Трощенко В. Т., Хамаза Л. А. Деформационные кривые усталости сталей и методы определения их параметров. Сообщ. 1. Традиционные методы // Пробл. прочности. – 2010. – № 6. – С. 26 – 43.
2. Хайкин С. Нейронные сети: полный курс. – 2-е изд., испр. / Пер. с англ. – М.: ООО “И.Д. Вильямс”, 2006. – 1104 с.
3. Kang J. Y., Choi B. I., and Lee H. J. Application of artificial neural network for predicting plain strain fracture toughness using tensile test results // Fatigue Fract. Eng. Mater. Struct. – 2006. – **29**. – P. 321 – 329.
4. Haque M. E. and Sudhakar K. V. ANN back-propagation prediction model for fracture toughness in microalloy steel // Int. J. Fatigue. – 2002. – **24**. – P. 1003 – 1010.
5. Seibi A. and Al-Alawi S. M. Prediction of fracture toughness using artificial neural networks (ANNs) // Eng. Fract. Mech. – 1997. – **56**. – P. 311 – 319.
6. Ince R. Prediction of fracture parameters of concrete by artificial neural networks // Ibid. – 2004. – **71**. – P. 2143 – 2159.
7. Kang J. Y. and Song J. H. Neural network applications in determining the fatigue crack opening load // Int. J. Fatigue. – 1998. – **20**. – P. 57 – 69.
8. Haque M. E. and Sudhakar K. V. ANN based prediction model for fatigue crack growth in DP steel // Fatigue Fract. Eng. Mater. Struct. – 2001. – **23**. – P. 63 – 68.
9. Haque M. E. and Sudhakar K. V. Prediction of corrosion-fatigue behaviour of DP steel through arificial neural networks // Int. J. Fatigue. – 2001. – **23**. – P. 1 – 4.
10. Cheng Y., Huang W. L., and Zhou C. Y. Artificial neural network technoligy for the data processing of on-line corrosion fatigue crack growth monitoring // Int. J. Press. Vess. Piping. – 1999. – **76**. – P. 113 – 116.
11. Genel K. Application of arificial neural network for predicting strain-life fatigue properties of steels on the basis of tensile tests // Int. J. Fatigue. – 2004. – **26**. – P. 1027 – 1035.

12. Artymiak P., Bukowski L., Feliks J., et al. Determination of  $S-N$  curves with the application of artificial neural networks // Fatigue Fract. Eng. Mater. Struct. – 1999. – 22. – P. 723 – 728.
13. Venkatesh V. and Rack H. J. A neural network approach to evaluated temperature creep-fatigue life prediction // Ibid. – 21. – P. 225 – 234.
14. Pleune T. T. and Chopra O. K. Using artificial neural networks to predict the fatigue life of carbon and low-alloy steels // Nucl. Eng. Design. – 2000. – 197. – P. 1 – 12.
15. Junior R. C. S. F., Neto A. D. D., and Aquino E. M. F. Building of constant life diagrams of fatigue using artificial neural networks // Int. J. Fatigue. – 2005. – 27. – P. 746 – 751.
16. Malinov S. and Sha W. Software products for modelling and simulation in materials science // Comput. Mater. Sci. – 2003. – 28. – P. 179 – 198.
17. Genel K., Kurnaz S. C., and Durman M. Modelling of tribological properties of alumina fiber reinforced zinc–aluminum composites using artificial neural network // Mater. Sci. Eng. – 2002. – A. – 363. – P. 203 – 210.
18. Sourmail T., Bhadieshia H. K. D. H., and MacKay D. J. Neural network model of creep strength of austenitic stainlees steels // Mater. Sci. Tech. – 2002. – 8. – P. 655 – 663.
19. Трощенко В. Т., Лепихин П. П., Хамаза Л. А., Бабич Ю. Н. Автоматизированный банк данных “Прочность материалов” // Пробл. прочности. – 2009. – № 3. – С. 5 – 13.
20. Lieurade H. P. and Maillard-Salin C. Low-cycle fatigue behavior of welded joints in high strength steels // Low-Cycle Fatigue and Life Prediction. – ASTM STP 770, C. Amzallag, B. N. Leis, and P. Rabble (Eds). – 1982. – P. 311 – 336.
21. Truchon M. Application of low-cycle fatigue test results to crack initiation from notches // Low-Cycle Fatigue and Life Prediction. – ASTM STP 770, C. Amzallag, B. N. Leis, and P. Rabbe (Eds). – 1982. – P. 254 – 268.

Поступила 06. 04. 2009