

ПРИКЛАДНЫЕ ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ

УДК 004.8.032.26; 669.017:53

А.В. Лемзиков, С.П. Кундас

ОБУЧЕНИЕ НЕЙРОННЫХ СЕТЕЙ
ДЛЯ ПРОГНОЗИРОВАНИЯ СВОЙСТВ СТАЛЕЙ

Предлагается метод оптимизации начальных значений весовых и сдвиговых коэффициентов нейронных сетей с помощью генетического алгоритма. Приводится обоснование эффективности предложенного метода при предварительной оптимизации нейронных сетей с произвольной структурой. Показывается применение предложенного метода при обучении нейронных сетей, позволяющих с допустимой для практического использования погрешностью прогнозировать температурные зависимости значений теплопроводности, удельной теплоемкости и плотности углеродистых конструкционных сталей.

Введение

Генетические алгоритмы (ГА) представляют собой методы поиска, основанные на принципах генетики и естественного отбора [1]. Поиск решения в ГА осуществляется путем манипуляций внутри популяции частных решений-кандидатов.

Каждый член популяции представлен в виде «хромосомы», кодирующей единичное решение исследуемой задачи. В задачах, содержащих произвольное количество оптимизируемых параметров, хромосома состоит из соответствующего числа «генов», каждый из которых кодирует один параметр. Начальное состояние хромосом выбирается случайным образом в рамках диапазонов допустимых значений оптимизируемых параметров. В дальнейшем хромосомы оцениваются с применением функции приспособленности (ФП), выбираемой исходя из особенностей решаемой задачи. Значение ФП характеризует, насколько хромосома приближена к искомому оптимуму.

Оптимизация с применением ГА представляет собой итерационный процесс. Каждая итерация состоит из ряда операций над хромосомами, целью которых является улучшение значения функции приспособленности. К операциям, производимым над хромосомами, относят различные варианты скрещивания и мутации, называемые также генетическими операторами [2].

Существует несколько алгоритмов скрещивания, выбор и реализация которых существенно зависят от принятого способа записи генов в хромосоме. В работах [1, 3–5] принято двоичное кодирование генов, при котором ген преобразуется в строку фиксированной длины, состоящую из символов 0 и 1. Хромосома в данном случае представляет собой простую конкатенацию строк-генов. При этом каждый ген может принимать конечное количество значений, которое ограничено количеством возможных комбинаций, определяемых из длины строки. Кроме того, в указанном случае гены могут принимать только значения с фиксированным шагом, если в алгоритме кодирования не реализованы специальные нелинейные механизмы.

В качестве альтернативного способа кодирования может использоваться представление генов в виде чисел с плавающей запятой [5], где ген является неделимой частью хромосомы и может принимать произвольные значения из заданного диапазона. В общем случае скрещивание может быть записано в виде выражений [2]:

$$s_v^t = \{v_1, \dots, v_N\}; s_w^t = \{w_1, \dots, w_N\};$$

$$s_v^{t+1} = \{v_1, \dots, v_k, w_{k+1}, \dots, w_N\}; s_w^{t+1} = \{w_1, \dots, w_k, v_{k+1}, \dots, v_N\},$$

где s_v^t, s_w^t – хромосомы v и w в момент времени t (предки); v_i – значения генов хромосомы s_v ; w_i – значения генов хромосомы s_w ; N – количество генов в хромосоме; k – коэффициент скрещивания; s_v^{t+1}, s_w^{t+1} – хромосомы v и w в момент времени $t+1$ (потомки).

Значение коэффициента скрещивания может выбираться случайным образом из диапазона $[2; N-1]$ либо вычисляться исходя из значений ФП хромосом-предков. В последнем случае хромосома, обладающая лучшей приспособленностью, передаст потомку большее количество своих генов.

Операция мутации производит случайное изменение произвольного гена хромосомы (либо произвольного элемента строки, если используется двоичное кодирование генов) [5]. Выбор хромосомы и гена для мутации осуществляется случайным образом на основании заранее определенного параметра, называемого степенью мутации. По аналогии с явлениями природы степень мутации обычно выбирается достаточно малой [1], хотя алгоритмически ничто не запрещает выбрать иное значение этого параметра.

Таким образом, на каждой итерации поколения хромосом сменяются за счет выполнения операций скрещивания и мутации. Хромосома с наилучшим значением ФП в текущем поколении (элитная хромосома) копируется без изменений в следующее поколение, что обеспечивает как минимум неухудшение приспособленности последующих поколений.

1. Применение ГА для предварительной оптимизации нейронных сетей

В работе [6] рассмотрен вопрос, связанный со стратегией выбора начальных значений весов нейронов в искусственных нейронных сетях (ИНС). Предложены варианты, при которых весовые коэффициенты инициализируются значениями в диапазонах $[-0,05; 0,05]$, $[-0,1; 0,1]$ либо границы диапазона определяются выражением

$$w_{ij} \approx \frac{1}{\sqrt{n(i)}},$$

где $n(i)$ – число нейронов в слое i .

В любом случае начальные значения весовых коэффициентов нейронов выбираются случайным образом независимо от вида решаемой задачи, что негативно сказывается на скорости обучения и может привести к попаданию сети в локальный минимум ошибки.

Кроме того, в работах [6, 7] отмечена проблема «перетренировки» («переобучения») нейронной сети. Она заключается в том, что в ряде случаев увеличение количества нейронов в скрытом слое обуславливает ухудшение обобщающих способностей сети в целом. При этом уменьшение количества нейронов приводит сеть в состояние локального минимума, что также является нежелательным. В качестве компромисса возможно применение сетей с несколькими скрытыми слоями, размеры которых меньше, чем размер сети в случае одного скрытого слоя. Недостатком таких сетей является то, что они медленнее, чем однослойные, сходятся к глобальному оптимуму при обучении.

В настоящей работе предлагается алгоритм, позволяющий ускорить процесс обучения нейронных сетей с произвольным количеством скрытых слоев за счет применения ГА для предварительной оптимизации начальных значений весовых и сдвиговых коэффициентов нейронов (рис. 1).

Суть алгоритма заключается в следующем. В качестве элементов хромосом (генов) ГА принимается совокупность всех весовых и сдвиговых коэффициентов нейронной сети с выбранной структурой. ФП хромосомы вычисляется путем создания нейронной сети, заполнения ее весовыми коэффициентами из хромосомы и определения ошибки прогнозирования. Последующие итерации ГА позволяют сформировать такую хромосому, чтобы построенная из нее нейронная сеть обладала минимальной погрешностью прогнозирования (либо находилась в окрестностях глобального минимума функции ошибки).

Следует отметить, что предложенный алгоритм в силу своих ограничений не позволяет полностью «обучить» нейронную сеть. В общем случае весовые коэффициенты обученной нейросети принимают значения, не ограниченные какими-либо диапазонами, и зависят от вида решаемой задачи, типа активационной функции нейронов, интервалов нормализации обучающих векторов и т. п. При применении ГА требуется предварительно задавать диапазоны изменения значений оптимизируемых переменных (генов), в результате алгоритм не позволяет получить оптимальные значения весовых коэффициентов. Однако исследования ав-

торов показывают, что сеть, прошедшая предварительную оптимизацию с помощью ГА, позволяет достичь лучших результатов при последующем классическом обучении с учителем.

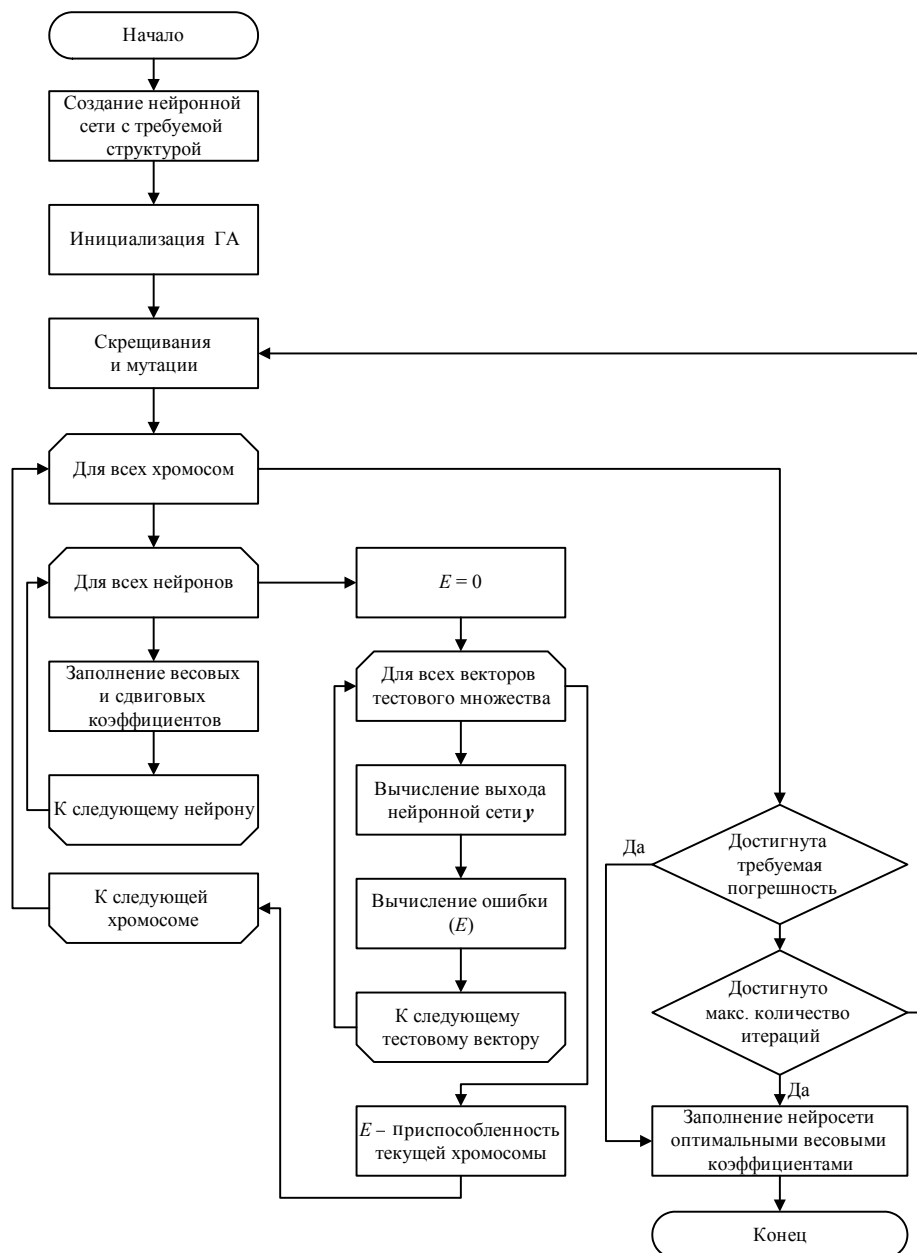


Рис. 1. Блок-схема алгоритма предварительной оптимизации нейронных сетей

Для иллюстрации работы предложенного алгоритма была осуществлена оптимизация начального состояния нейронной сети, предназначенной для прогнозирования значений функции $\sin(x)$ в диапазоне $[0, 2\pi]$. Выбранная ИНС содержала один скрытый слой с четырьмя нейронами (активационная функция – гиперболический тангенс). Изменение значения ФП элитной хромосомы и результаты прогнозирования соответствующей нейронной сети на различных этапах работы алгоритма показаны на рис. 2.

Рассмотрим операции над хромосомами, которые привели к улучшению ФП (рис. 3). Ряд операций скрещивания и мутации привел к тому, что в 83-м поколении образовалась хромосома A , мутации которой к 90-му поколению образовали элитную хромосому C . Ее скрещивание с хромосомой D 91-го поколения позволило улучшить функцию приспособленности (хромосома E). В результате скрещивания хромосом E и F была получена окончательная элит-

ная хромосома *G* (рис. 2, *д*). Так, за счет выполнения генетических операторов осуществлялась предварительная оптимизация коэффициентов нейронной сети, что косвенно «обучило» ее и позволило уменьшить погрешность прогнозирования (рис. 2, *д*) по сравнению с начальным состоянием (рис. 2, *б*).

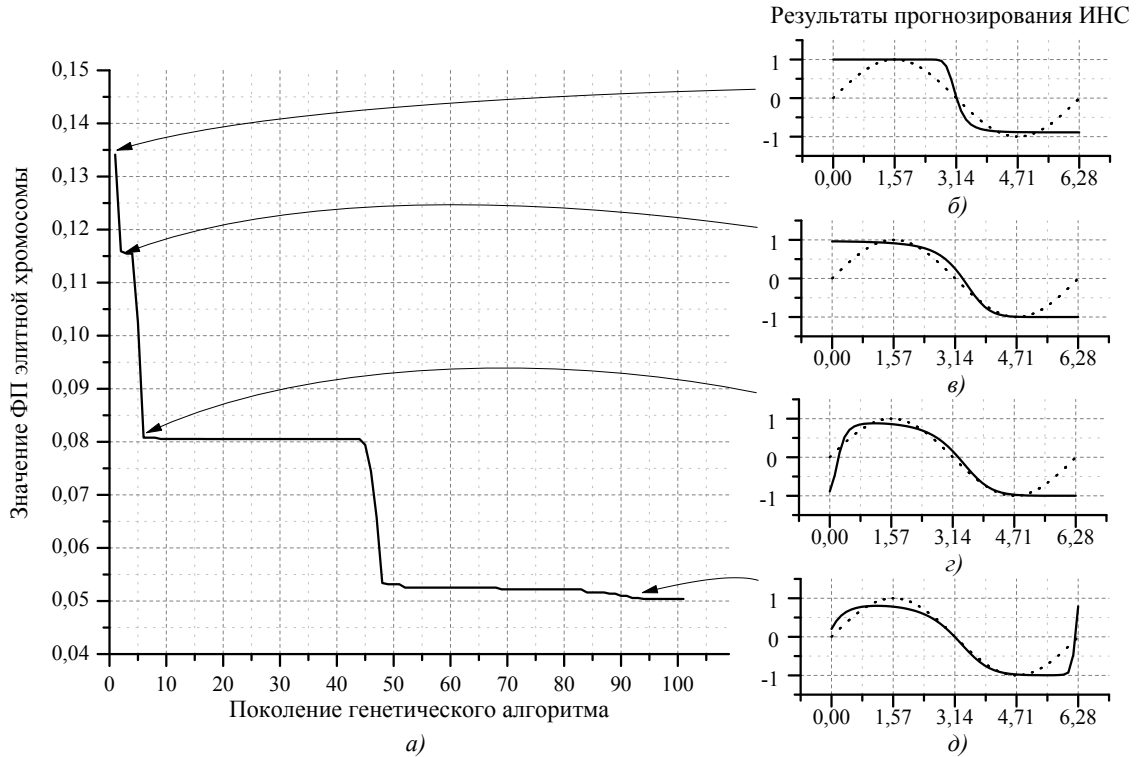


Рис. 2. Пример использования предложенного алгоритма:
а) изменение значения ФП элитной хромосомы в процессе работы ГА;
б)–д) результаты прогнозирования соответствующих нейронных сетей




Рис. 3. Схема операций над хромосомами, улучшивших значение ФП

Кроме описанного вычислительного эксперимента, для оценки эффективности предложенного алгоритма при оптимизации сетей со сложной структурой было проведено обучение двух идентичных ИНС (содержащих три скрытых слоя по пять нейронов в каждом), предназначенных для прогнозирования значения температуры начала мартенситного превращения (*M_n*) в сталях [7]. Начальное состояние сетей перед обучением показано на рис. 4.

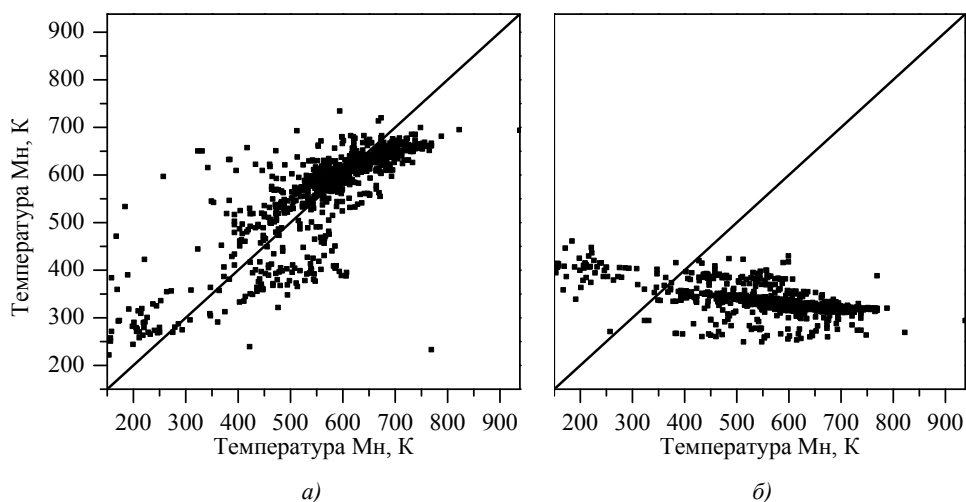


Рис. 4. Результаты прогнозирования значений температуры Mn нейронными сетями перед обучением: а) после предварительной оптимизации; б) без оптимизации

Как видно на рис. 4, а, результаты прогнозирования сети, прошедшей предварительную оптимизацию, еще до обучения коррелируют с исходными данными. Это означает, что состояние нейросети уже находится в окрестностях минимума ошибки прогнозирования. Дальнейшее обучение (рис. 5) позволяет достичь лучшей точности прогнозирования, чем в случае использования нейросети, не прошедшей предварительную оптимизацию.

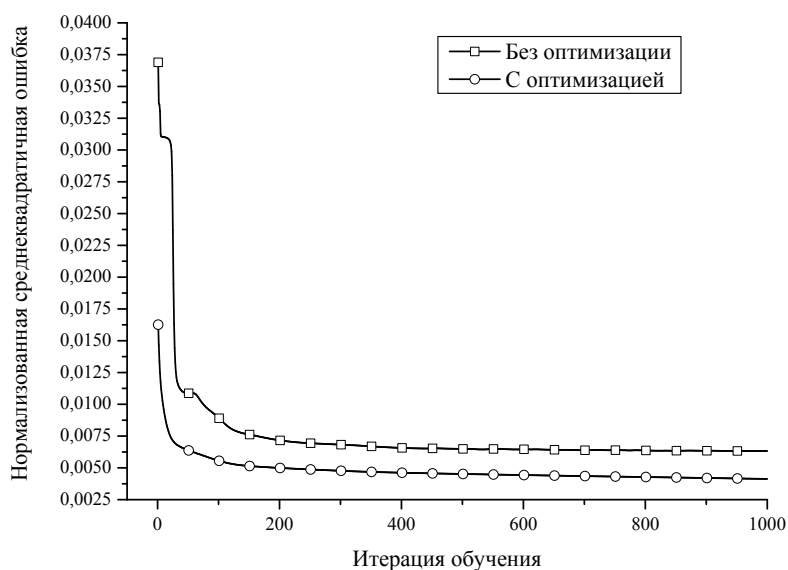


Рис. 5. Динамика изменения ошибки обучения нейронных сетей

Итак, использование ГА позволяет уменьшить количество итераций обучения ИНС, необходимых для достижения определенной точности прогнозирования, за счет оптимизации начальных значений весовых и сдвиговых коэффициентов. Предложенный алгоритм применялся при разработке нейронных сетей, позволяющих прогнозировать температурные зависимости значений теплофизических свойств углеродистых конструкционных сталей.

2. Разработка ИНС для прогнозирования теплофизических свойств углеродистых сталей с применением алгоритма предварительной оптимизации

Определение температуры в произвольной точке детали является базовой задачей при моделировании закалки. На основании информации об изменении температуры осуществляется

расчет фазовых превращений и эксплуатационных характеристик детали, изменение объема детали за счет температурного расширения (сжатия) существенно меняет картину напряженно-деформированного состояния.

Задача теплопроводности (без граничных условий) описывается выражениями, решение которых в трехмерной и двухмерной постановках реализовано в большинстве современных конечно-элементных комплексов [8–11]:

$$Q = -\lambda \nabla T; \quad (1)$$

$$\rho C \frac{\partial T}{\partial t} = -\nabla \cdot Q + q, \quad (2)$$

где Q – плотность теплового потока, $\frac{Вт}{м^2}$; λ – коэффициент теплопроводности, $\frac{Вт}{м \cdot К}$; T – температура, $К$; ρ – плотность, $\frac{кг}{м^3}$; C – коэффициент удельной теплоемкости, $\frac{Дж}{кг \cdot К}$; t – время, $с$; q – источник тепла, $\frac{Вт}{м^3}$.

Таким образом, для решения уравнения теплопроводности, являющегося базовым уравнением при моделировании закалки, необходимо знать значения коэффициента теплопроводности, коэффициента удельной теплоемкости и плотности закаливаемой стали.

Источниками информации о свойствах используемых материалов могут выступать различные справочники физических свойств сталей и сплавов, программные средства, предоставляющие информацию о свойствах материалов на основании встроенных баз данных или путем вычислений с применением термодинамических законов и сведений о химическом составе исследуемой стали. В то же время с учетом возможности нейронных сетей по аппроксимации экспериментальных данных целесообразным является разработка программных средств, позволяющих, используя ИНС и базы данных с экспериментальными измерениями, определять значения требуемых свойств в зависимости от температуры и химического состава исследуемой стали.

Авторами предложена следующая методика создания нейронных сетей для прогнозирования свойств сталей:

1) создание обучающих множеств для каждого прогнозируемого свойства; создание тестовых множеств, информация из которых будет применяться для определения результирующей погрешности прогнозирования. Обучающие множества состоят из пар входных (химический состав и температура испытаний) и выходных (значение описываемого свойства при определенных условиях) векторов;

2) создание набора нейронных сетей с различным количеством нейронов в скрытом слое (при необходимости – с различным количеством скрытых слоев), в общем случае – создание набора нейронных сетей с различными активационными функциями и выбор числа нейронов в них в соответствии с теоремой Колмогорова [12] в зависимости от числа входных переменных;

3) обучение нейронных сетей (с применением алгоритма предварительной оптимизации в случае необходимости), определение результирующей ошибки обучения;

4) определение тестовой ошибки прогнозирования каждой нейронной сети с использованием тестовых множеств;

5) выбор нейросетей-кандидатов на основании тестовой ошибки прогнозирования;

6) исследование результатов работы сетей-кандидатов, сравнение результатов прогнозирования с экспериментальными данными; выбор нейронной сети с наименьшей суммарной погрешностью прогнозирования.

Применение предложенной методики позволяет разработать нейронную сеть с оптимальной для решения поставленной задачи структурой, обучить сеть для достижения минимальной погрешности прогнозирования и провести верификацию для оценки точности аппроксимации исходных экспериментальных данных. Отличительной особенностью предложенной методики

является детерминированный подход к выбору структуры нейронных сетей начального набора, использование объективных критериев (тестовая ошибка прогнозирования) для выбора сетей-кандидатов, что позволяет достичь наиболее оптимальной структуры нейросети и наименьшей погрешности прогнозирования.

Предложенная методика использована для разработки нейронных сетей, позволяющих прогнозировать значения теплопроводности, теплоемкости и плотности конструкционных углеродистых сталей.

В работах [13, 14] приведены значения содержания основных легирующих элементов [15] в конструкционных углеродистых качественных сталях (табл. 1).

Анализ приведенной в табл. 1 информации показывает, что количество мышьяка и азота не меняется в рассматриваемых сталях, а количество серы, фосфора и меди изменяется незначительно. Следовательно, указанные элементы можно исключить из входного вектора нейронных сетей. Кроме того, учитывая, что наибольшее влияние на свойства стали оказывает содержание в ней углерода (при незначительных вариациях количества остальных элементов, что справедливо для конструкционных углеродистых сталей), исследуются отдельные случаи, когда входной вектор обучающего множества содержит только два компонента – количество углерода и температуру испытаний.

Таблица 1

Основные статистические значения распределения химических элементов в конструкционных углеродистых качественных сталях

Наименование параметра	Содержание элемента в стали, %									
	<i>C</i>	<i>Si</i>	<i>Mn</i>	<i>S</i>	<i>P</i>	<i>Cr</i>	<i>Ni</i>	<i>As</i>	<i>N</i>	<i>Cu</i>
Минимум	0,08	0,03	0,35	0,03	0,025	0,1	0,15	0,08	0,008	0,2
Максимум	0,86	0,27	0,65	0,04	0,035	0,25	0,3	0,08	0,008	0,3
Среднее значение	0,36	0,23	0,55	0,037	0,034	0,22	0,284	0,08	0,008	0,28
Среднеквадратичное отклонение (СКО)	0,241	0,086	0,121	0,005	0,003	0,052	0,036	0,000	0,000	0,041

В качестве выходного выступает вектор с единственным компонентом – значением теплопроводности, теплоемкости или плотности при условиях, заданных соответствующим входным вектором (табл. 2).

Таблица 2

Основные статистические характеристики зависимости теплопроводности (λ , Вт/м·К), удельной теплоемкости (C , Дж/кг·К) и плотности (ρ , кг/м³) от температуры испытаний

Температура, °С	Минимум			Максимум			Среднее значение			СКО		
	λ	C	ρ	λ	C	ρ	λ	C	ρ	λ	C	ρ
20	–	–	7800	–	–	7871	–	–	7839,6	–	–	22,4
100	47	465	7799	60	487	7846	52,1	476,4	7828,1	4,2	8,3	14,7
200	42	479	7769	56	500	7814	49,6	490,0	7796,2	4,1	6,9	14,6
300	39	495	7737	51	517	7781	46,2	509,2	7762,0	3,1	6,7	14,5
400	38	512	7698	47	536	7745	43,2	528,4	7726,8	2,5	7,4	15,5
500	35	539	7662	43	583	7708	39,3	557,7	7689,6	2,2	12,0	15,5
600	30	567	7623	39	586	7668	35,4	577,5	7650,4	2,7	7,4	14,8
700	26	611	7583	36	636	7628	32,0	623,8	7610,8	2,5	8,7	14,2
800	25	691	7582	32	720	7624	27,9	701,1	7600,1	2,1	8,8	13,5
900	25	697	7549	30	708	7602	26,8	702,4	7589,9	1,4	2,9	15,9

Для каждого теплофизического свойства формировался набор из девяти нейронных сетей, обладающих различным количеством нейронов в скрытом слое (слоях) и использующих разные активационные функции нейронов (сигмоидальную, биполярную сигмоидальную и гиперболический тангенс). Обозначение нейронных сетей приведено в табл. 3.

Количество нейронов в скрытых слоях выбиралось исходя из следующих соображений. Сети *sig5*, *bsig5* и *htan5* содержат два входа – содержание углерода и температуру испытаний ($N=2$).

Следовательно, по теореме Колмогорова оптимальное количество нейронов в скрытом слое равно пяти ($2N + 1$). На входы остальных сетей подаются следующие значения: количество углерода, кремния, марганца, хрома, никеля и температура испытаний (шесть величин), оптимальное количество нейронов в этом случае – 13. Для двухслойных нейронных сетей выбрана комбинация рассмотренных вариантов, при которой в первом скрытом слое – 13 нейронов, а во втором – 5.

Таблица 3

Расшифровка обозначений структур нейронных сетей,
используемых для прогнозирования теплофизических свойств сталей

Обозначение нейронной сети	Количество скрытых слоев	Количество нейронов в слоях	Количество входов	Тип активационной функции
<i>sig5</i>	1	5	2	Сигмоидальная
<i>bsig5</i>	1	5	2	Биполярная сигмоидальная
<i>htan5</i>	1	5	2	Гиперболический тангенс
<i>sig13</i>	1	13	6	Сигмоидальная
<i>bsig13</i>	1	13	6	Биполярная сигмоидальная
<i>htan13</i>	1	13	6	Гиперболический тангенс
<i>sig13+5</i>	2	13, 5	6	Сигмоидальная
<i>bsig13+5</i>	2	13, 5	6	Биполярная сигмоидальная
<i>htan13+5</i>	2	13, 5	6	Гиперболический тангенс

Результаты обучения (среднеквадратичное отклонение результатов прогнозирования от значений тестового множества) всех вариантов нейронных сетей показаны в табл. 4. В соответствии с предложенной методикой на основании тестовой ошибки прогнозирования были отобраны следующие сети-кандидаты для значений:

теплопроводности – *sig5*, *sig13* и *sig13+5*;

удельной теплоемкости – *bsig5*, *sig13*, *bsig13*, *bsig13+5* (на основании низкого значения ошибки обучения) и *htan13+5*;

плотности – *sig5*, *bsig5*, *sig13*, *htan13*, *htan13+5*.

Таблица 4

Результаты обучения нейронных сетей (E_T – тестовая ошибка; $E_{обуч}$ – ошибка обучения)

Нейронная сеть	Теплопроводность, Вт/м·К		Удельная теплоемкость, Дж/кг·К		Плотность, кг/м ³	
	E_T	$E_{обуч}$	E_T	$E_{обуч}$	E_T	$E_{обуч}$
<i>sig5</i>	1,73	1,35	11,43	9,19	9,11	10,57
<i>bsig5</i>	1,75	1,33	9,54	8,73	9,76	10,16
<i>htan5</i>	2,00	1,50	12,01	12,28	10,01	10,54
<i>sig13</i>	1,25	1,25	12,69	12,12	10,98	9,78
<i>bsig13</i>	1,35	1,00	13,02	8,25	11,17	8,34
<i>htan13</i>	1,27	1,04	13,28	8,49	11,03	8,38
<i>sig13+5</i>	1,28	1,15	11,60	8,49	13,03	10,30
<i>bsig13+5</i>	1,35	0,95	13,27	6,84	12,17	8,34
<i>htan13+5</i>	1,34	0,96	10,63	6,45	10,21	7,21

Выбор наиболее оптимальной структуры нейросетей осуществлялся на основе анализа погрешностей прогнозирования теплопроводности для сталей 10, 45 и 70. Выбор сталей обусловлен необходимостью исследовать весь диапазон изменения содержания углерода в рассматриваемой группе сталей. Однако для прогнозирования плотности вместо стали 70 проводились сравнения значений для стали 20 в связи с тем, что ни в одном из исследованных литературных источников [13, 14, 16, 17] не приведена температурная зависимость плотности для стали 70. Результаты сравнения погрешностей прогнозирования даны в табл. 5.

Таблица 5

Численные значения погрешностей прогнозирования теплофизических свойств сталей исследуемыми вариантами нейронных сетей

Нейронная сеть	Теплопроводность, Вт/м·К				Удельная теплоемкость, Дж/кг·К				Плотность, кг/м ³			
	Сталь			Сумма	Сталь			Сумма	Сталь			Сумма
	10	45	70		10	45	70		10	20	45	
<i>sig5</i>	0,3	0,57	1,24	2,11	–	–	–	–	11,38	7,33	7,13	25,83
<i>bsig5</i>	–	–	–	–	7,64	9,96	3,85	21,45	6,43	7,1	7,51	21,04
<i>sig13</i>	0,68	1,15	1,72	3,55	9,82	19,21	5,27	34,30	7,71	7,86	7,69	23,26
<i>bsig13</i>	–	–	–	–	3,72	11,53	4,03	19,28	–	–	–	–
<i>htan13</i>	–	–	–	–	–	–	–	–	8,04	11,91	6,88	26,82
<i>htan13+5</i>	–	–	–	–	3,40	8,51	2,07	13,94	7,21	11,44	6,53	25,17
<i>bsig13+5</i>	–	–	–	–	3,63	8,50	1,81	13,99	–	–	–	–
<i>sig13+5</i>	0,84	0,85	1,33	3,03	–	–	–	–	–	–	–	–

На основании суммарной ошибки прогнозирования в качестве наиболее оптимальных были выбраны следующие варианты нейронных сетей для прогнозирования:

теплопроводности – однослойная, 5 нейронов в скрытом слое, сигмоидальная активационная функция (*sig5*);

удельной теплоемкости – двухслойная, 13 нейронов в первом слое, 5 во втором, активационная функция – гиперболический тангенс (*htan13 + 5*);

плотности – однослойная, 5 нейронов в скрытом слое, биполярная сигмоидальная активационная функция (*bsig5*).

Результаты прогнозирования теплопроводности, удельной теплоемкости и плотности выбранными вариантами нейронных сетей, а также их сравнение с экспериментальными данными для стали 35 показаны на рис. 6.

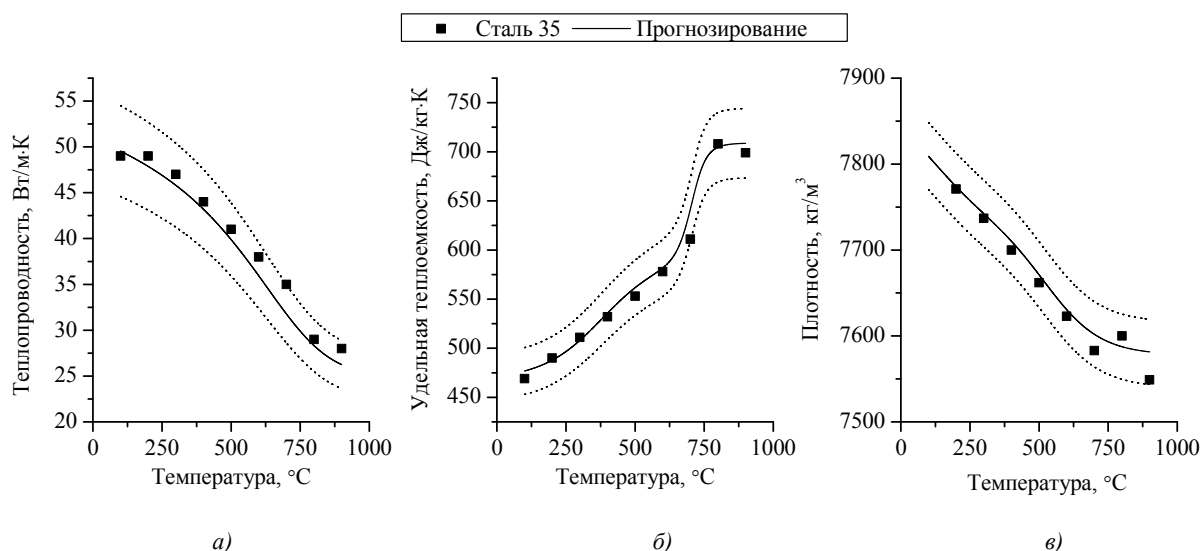


Рис. 6. Результаты прогнозирования температурных зависимостей теплофизических свойств стали 35 с помощью разработанных нейронных сетей: а) теплопроводности (интервал погрешности 10 %); б) удельной теплоемкости (интервал погрешности 5 %); в) плотности (интервал погрешности 0,5 %)

Заключение

Предложенный метод предварительной оптимизации весовых и сдвиговых коэффициентов ИНС с помощью ГА позволяет ускорить процесс обучения нейронных сетей с произвольным количеством скрытых слоев. В качестве элементов хромосом (генов) ГА принимается со-

вокупность всех весовых и сдвиговых коэффициентов нейронной сети с выбранной структурой. ФП хромосомы вычисляется путем создания нейронной сети, заполнения ее весовыми коэффициентами из хромосомы и определения ошибки прогнозирования. Последующие итерации ГА позволяют сформировать такую хромосому, чтобы построенная из нее нейронная сеть обладала минимальной погрешностью прогнозирования, т. е. находилась в окрестностях глобального минимума функции ошибки. С применением алгоритма предварительной оптимизации были разработаны нейронные сети, позволяющие прогнозировать температурные зависимости значений теплофизических свойств (коэффициент теплопроводности, удельную теплоемкость и плотность) конструкционных углеродистых сталей в зависимости от их химического состава. Погрешность прогнозирования результирующих сетей не превышает 10 % для теплопроводности, 5 % для удельной теплоемкости и 0,5 % для плотности. Использование разработанных нейронных сетей позволяет без применения справочной информации в автоматическом режиме для произвольной конструкционной углеродистой стали определить температурные зависимости теплофизических свойств, необходимые для проведения моделирования процесса термической обработки.

Список литературы

1. Cantu-Paz, E. Efficient and accurate parallel genetic algorithms / E. Cantu-Paz. – Boston : Kluwer Academic Publishers, 2001. – 162 p.
2. Chambers, L. The Practical Handbook of Genetic Algorithms. Applications. Second Edition / L. Chambers. – Chapman & Hall/CRC, 2001. – 520 p.
3. Microstructural optimization of alloys using a genetic algorithm / A.J. Kulkarni [et al.] // *Materials Science & Engineering*. – 2004. – A 372 (2004). – P. 213–220
4. Paluch, B. Combining a finite element programme and a genetic algorithm to optimize composit structures with variable thickness / B. Paluch, M. Grediac, A. Faye // *Composite Structures*. – 2007. – doi:10.1016/j.compstruct.2007.04.023.
5. Michalewicz, Z. Genetic Algorithms + Data Structures = Evolution Programs / Z. Michalewicz. – Germany : Springer, 1992. – 388 p.
6. Головкин, В.А. Нейронные сети: обучение, организация и применение : учеб. пособие для вузов. Кн. 4 / В.А. Головкин ; под ред. А.И. Галушкина. – М. : ИПРЖР, 2001. – 256 с.
7. Применение нейросетей для определения характерных точек фазовых превращений в сталях с различным химическим составом / А.В. Лемзиков [и др.] // *Информатика*. – 2007. – № 1 (13). – С. 89–97.
8. ANSYS, Inc. Products // ANSYS, Inc. official site [Electronic resource]. – Mode of access : <http://www.ansys.com/products/default.asp>. – Date of access : 29.07.2009.
9. COMSOL : Products // Comsol Myltiphsics Modeling [Electronic resource]. – Mode of access : <http://comsol.com/products/>. – Date of access : 06.08.2009.
10. DEFORM – Scientific Forming Technologies Corporation [Electronic resource]. – Mode of access: <http://www.deform.com/products/deform-ht>. – Date of access : 15.08.2009.
11. MARC – Overview // MSC Software Corporation [Electronic resource]. – Mode of access: <http://www.mssoftware.com/products/marc.cfm>. – Date of access : 18.08.2009.
12. Колмогоров, А.Н. О представлении непрерывных функций нескольких переменных суперпозициями непрерывных функций меньшего числа переменных / А.Н. Колмогоров // *Доклады АН СССР*. – 1956. – Т. 108, № 2. – С. 179–182.
13. Сорокин, В.Г. Марочник сталей и сплавов / В.Г. Сорокин, А.В. Волосникова, С.А. Вяткин ; под ред. В.Г. Сорокина. – М. : Машиностроение, 1989. – 640 с.
14. Колосков, М.М. Марочник сталей и сплавов / М.М. Колосков, Е.Т. Долбенко, Ю.В. Каширский ; под ред. А.С. Зубченко. – М. : Машиностроение, 2001. – 672 с.
15. Мальцев, И.М. Лекции по курсу «Материаловедение». На правах рукописи / И.М. Мальцев. – Н. Новгород : НГТУ, 1995. – 103 с.
16. Metal Ravne steel selector // Metal Ravne d.o.o [Electronic resource]. – Mode of access: <http://www.metalravne.com/selector/selector.html>. – Date of access : 18.08.2009.

17. Справочник статей // ООО «Спецметаллсервис» [Электронный ресурс]. – Режим доступа : http://s-metall.com.ua/spravochnik_stalej.html. – Дата доступа : 24.08.2009.

Поступила 02.09.09

*Белорусский государственный университет
информатики и радиоэлектроники,
Минск, ул. П. Бровки, 6
e-mail: adminset@bsuir.unibel.by*

A.V. Lemzikov, S.P. Kundas

**TRAINING ARTIFICIAL NEURAL NETWORKS
FOR PREDICTING PROPERTIES OF STEELS**

A genetic-algorithm-based method of preliminary optimization of the weight and bias coefficients of artificial neural networks is proposed. The efficiency of the proposed algorithm for optimization of the neural networks with arbitrary internal structures is demonstrated. An application of the proposed algorithm for prediction of temperature-dependent thermal conductivity, heat capacity and density for low-alloyed carbon steels is discussed.