

Метрологія та вимірювальна техніка

УДК 006.091

С.В. Водотыка

Харьковский национальный университет радиоэлектроники, Харьков

ИСПОЛЬЗОВАНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ С ИНТЕРВАЛЬНОЙ АРИФМЕТИКОЙ ПРИ ПОСТРОЕНИИ КАЛИБРОВОЧНОЙ ЗАВИСИМОСТИ СРЕДСТВА ИЗМЕРЕНИЯ

Рассматривается процедура построения калибровочных зависимостей средств измерения с помощью искусственных нейронных сетей в случаях присутствия существенных неопределенностей результатов измерений эталонных величин и показаний средств измерения. Применения искусственных нейронных сетей также позволяет учесть вид закона распределения с помощью перехода от оценок и стандартных неопределенностей величин к их расширенным неопределенностям. Описан алгоритм Левенберга-Марквардта применительно к обучению искусственным нейронным сетям, оперирующих на основе теории интервальной арифметики.

Ключевые слова: неопределенность измерения, калибровка средства измерения, нейронная сеть.

Введение

Согласно определению термина «калибровка» задача построения калибровочной зависимости сводится к задаче аппроксимации неизвестной функции [1]. В то же время задача аппроксимации неизвестной функции является следствием 13-й проблемы, представленной Д. Гильбертом в 1900 г. на Всемирном математическом конгрессе в Париже. По прошествии нескольких десятков лет А.Н. Колмогоровым [2, 3] и его учеником В.И. Арнольдом [4] были получены фундаментальные теоретические результаты, свидетельствующие о принципиальной возможности представления непрерывных функций нескольких переменных в виде суперпозиции функций меньшего числа переменных. Затем Хехт-Нильсеном [5] эти результаты были переработаны применительно к искусственным нейронным сетям (ИНС) [6]. Таким образом, была доказана возможность построения ИНС, выполняющего преобразование, заданное любой обучающей выборкой, различающихся между собой примеров, и установлено, что такая сеть является двуслойной (трехслойная с одним скрытым слоем) с конечным числом нейронов и сигмоидальной функцией активации первого (скрытого) слоя [7].

Задача построения КЗ с помощью ИНС в случаях, когда неопределенностью результатов измерений эталонной величины и величины показаний СИ можно пренебречь, была решена в [8]. Однако на практике, в частности в количественном химическом анализе, наличие существенных неопределенностей результатов измерений приводит к тому, что полученные оценки параметров КЗ смещены. Следствием этого является недостоверная оценка неизвестной величины с помощью обратной КЗ (функции анализа [9]). Также из-за сложности получения аналитического выражения для нахождения обратной КЗ рекомендуется выполнять поиск функции

анализа (ФА), представляющей зависимость значения эталонной величины от показаний СИ [9].

Для применения статистических методов необходимо выполнение довольно строгих условий (в частности, наличия статистической однородности данных), которые не всегда выполняются на практике. Это побуждает нас к разработке других подходов к описанию и оцениванию неопределенностей, которые не опираются на вероятностные модели, дают надежные оценки результата измерения и его неопределенности. Одним из них является интервальный анализ, который не опирается на вероятностные модели и использует информацию об исходных данных в виде границ, в которых содержатся эти данные. Такой подход носит чисто детерминистический характер [10].

Мы показали, что ИНС хорошо аппроксимируют точечные значения, поэтому можно на их основе создать алгоритм, аппроксимирующий интервальные оценки. Назовем его искусственная нейронная сеть с интервальной арифметикой (ИНСИА) [11].

1. Использование интервальной арифметики при построении ИНС

Для описания ИНСИА вначале приведем основные математические операции, которые потребуются в дальнейшем, для интервальных чисел. Над двумя интервальными числами $A \in [a_L; a_R]$ и $B \in [b_L; b_R]$ можно произвести следующие операции:

$$- \text{сложение: } A + B = C \in [a_L + b_L; a_R + b_R];$$

$$- \text{вычитание: } A - B = C \in [a_L - b_R; a_R - b_L];$$

$$- \text{взятие монотонно возрастающей функции: } f(A) = [f(a_L); f(a_R)].$$

Постановка задачи будет следующая: необходимо построить ИНС, реализующую зависимость $Y = g(X)$, где Y и X – интервальные числа. Для этого создадим обучающие образы (табл. 1).

Таблиця 1
Обучающие образы для ИНСИА

X	$[x_{L1}; x_{R1}]$	$[x_{L2}; x_{R2}]$...	$[x_{Lm}; x_{Rm}]$
Y	$[y_{L1}; y_{R1}]$	$[y_{L2}; y_{R2}]$...	$[y_{Lm}; y_{Rm}]$

Описываемая ИНС является сетью с прямой передачей информации, и все математические выражения, используемые [8], необходимо переписать, используя интервальную арифметику. Для наглядности математических выражений представим один из нейронов ИНСИА (рис. 1).




Рис. 1. Простой НЭ

Нейронный элемент ИНСИА преобразует информацию по правилу [11]:

$$[O_L; O_R] = f\left(\sum_{i=1}^n \omega_i [I_L; I_R] - [T_L; T_R]\right), \quad (0.1)$$

$$O_L = f\left(\sum_{i=1}^n \text{sgn}^+(\omega_i) \omega_i I_L + \sum_{i=1}^n \text{sgn}^-(\omega_i) \omega_i I_R - T_L\right);$$

$$O_R = f\left(\sum_{i=1}^n \text{sgn}^-(\omega_i) \omega_i I_L + \sum_{i=1}^n \text{sgn}^+(\omega_i) \omega_i I_R - T_R\right),$$

где $\text{sgn}^+(x)$ – знаковая функция:

$$\text{sgn}^a(x) = \begin{cases} 0, & \text{если } a = '+' \cup x < 0 \text{ или } a = '-' \cup x > 0; \\ 1, & \text{если } a = '+' \cup x > 0 \text{ или } a = '-' \cup x < 0. \end{cases}$$

Используя (0.1), функции преобразования, выполняемые двуслойной ИНСИА (графическое представление см. [8]) можно представить как:

– для первого (скрытого) слоя:

$$O_{Li}^1 = f\left(\text{sgn}^+(\omega_{i1}^1) \omega_{i1}^1 x_L + \text{sgn}^-(\omega_{i1}^1) \omega_{i1}^1 x_R - T_{Li}^1\right);$$

$$O_{Ri}^1 = f\left(\text{sgn}^-(\omega_{i1}^1) \omega_{i1}^1 x_L + \text{sgn}^+(\omega_{i1}^1) \omega_{i1}^1 x_R - T_{Ri}^1\right);$$

$$f(x) = \begin{cases} x, & \text{если } g(X) \text{ линейна;} \\ \frac{1}{1 + e^{-x}}, & \text{если } g(X) \text{ нелинейна;} \end{cases}$$

– для второго (выходного) слоя:

$$O_{Ll}^2 = \sum_{i=1}^n \text{sgn}^+(\omega_{il}^2) \omega_{il}^2 O_{Li}^1 + \sum_{i=1}^n \text{sgn}^-(\omega_{il}^2) \omega_{il}^2 O_{Ri}^1 - T_{Ll}^2;$$

$$O_{Rl}^2 = \sum_{i=1}^n \text{sgn}^-(\omega_{il}^2) \omega_{il}^2 O_{Li}^1 + \sum_{i=1}^n \text{sgn}^+(\omega_{il}^2) \omega_{il}^2 O_{Ri}^1 - T_{Rl}^2.$$

2. Обучение ИНСИА

Так как алгоритм работы ИНСИА отличается от обычной ИНС, то следовательно необходимо модифицировать и алгоритм обучения ИНСИА, который построен на минимизации среднеквадратической ошибки сети. Для ИНСИА она будет иметь вид:

$$E = E_L + E_R,$$

где $E_L = e_L^T e_L = \frac{1}{2} \sum_{i=1}^m (O_L^2 - y_{Li})^2$ – среднеквадратическая ошибка левой границы интервала;

$E_R = e_R^T e_R = \frac{1}{2} \sum_{i=1}^m (O_R^2 - y_{Ri})^2$ – среднеквадратическая ошибка правой границы интервала.

Для минимизации среднеквадратической ошибки ИНСИА будем использовать алгоритм Левенберга-Марквардта (АЛМ) [12], а частные производные по среднеквадратическим ошибкам правой и левой границ интервала по параметрам ИНСИА будем вычислять с помощью метода обратного распространения ошибки (МОРО).

Как и при использовании простой ИНС, для правильного обучения необходимо из исходной области данных перейти в нормированную:

$$[\hat{x}_{Li}; \hat{x}_{Ri}] = \frac{[x_{Li}; x_{Ri}] - \min(x_L)}{\max(x_R) - \min(x_L)};$$

$$[\hat{y}_{Li}; \hat{y}_{Ri}] = \frac{[y_{Li}; y_{Ri}] - \min(y_L)}{\max(y_R) - \min(y_L)},$$

где $\min(x_L), \max(x_R)$ – минимальное и максимальное значения левой и правой границ доверительного интервала для X; $\min(y_L), \max(y_R)$ – минимальное и максимальное значения левой и правой границ доверительного интервала для Y.

Теперь с помощью нормированных точек калибровки можно обучить ИНСИА, используя АЛМ:

1). Задается параметр регуляризации λ ($\lambda = 0.01$) и желаемая среднеквадратичная ошибка преобразования с помощью ИНСИА E_m .

2). Весовые коэффициенты и пороги инициализируются также, как и для простой ИНС [8].

3). Вычисляется прямой проход по сети для всех точек калибровки согласно функций преобразования ИНСИА для всех слоев.

4). Вычисляются ошибки левой и правой границ интервалов на выходе каждого НЭ:

$$\delta_{Ll}^2 = 1; \delta_{Rl}^2 = 1;$$

$$\delta_{Lk}^1 = \left[\text{sgn}^+(\omega_{k1}^2) \omega_{k1}^2 + \text{sgn}^-(\omega_{k1}^2) \omega_{k1}^2 \right];$$

$$\delta_{Rk}^1 = \left[\text{sgn}^-(\omega_{k1}^2) \omega_{k1}^2 + \text{sgn}^+(\omega_{k1}^2) \omega_{k1}^2 \right].$$

5). Для каждой точки калибровки рассчитываются частные производные составляющих векторов ошибок сети e_L и e_R по ее настраиваемым параметрам согласно МОРО для каждой точки калибровки:

$$\frac{\partial e_L}{\partial \omega_{k1}^2} = O_{Lk}^1; \frac{\partial e_R}{\partial \omega_{k1}^2} = O_{Rk}^1; \frac{\partial e_L}{\partial \omega_{1k}^1} = \delta_{Lk}^1 x_{L1};$$

$$\frac{\partial e_R}{\partial \omega_{1k}^1} = \delta_{Rk}^1 x_{R1}; \frac{\partial e_L}{\partial T_{Ll}^2} = 1; \frac{\partial e_R}{\partial T_{Rl}^2} = 1;$$

$$\frac{\partial e_L}{\partial T_{Lk}^1} = \delta_{Lk}^1; \frac{\partial e_R}{\partial T_{Rk}^1} = \delta_{Rk}^1.$$

6). Строятся две матрицы Якоби:

$$J_L = \begin{bmatrix} \frac{\partial e_{L1}}{\partial p_1} & \frac{\partial e_{L1}}{\partial p_2} & \dots & \frac{\partial e_{L1}}{\partial p_{N_{\omega}+2NT}} \\ \frac{\partial e_{L2}}{\partial p_1} & \frac{\partial e_{L2}}{\partial p_2} & \dots & \frac{\partial e_{L2}}{\partial p_{N_{\omega}+2NT}} \\ \vdots & \vdots & \dots & \vdots \\ \frac{\partial e_{Lm}}{\partial p_1} & \frac{\partial e_{Lm}}{\partial p_2} & \dots & \frac{\partial e_{Lm}}{\partial p_{N_{\omega}+2NT}} \end{bmatrix};$$

$$J_R = \begin{bmatrix} \frac{\partial e_{R1}}{\partial p_1} & \frac{\partial e_{R1}}{\partial p_2} & \dots & \frac{\partial e_{R1}}{\partial p_{N_{\omega}+2NT}} \\ \frac{\partial e_{R2}}{\partial p_1} & \frac{\partial e_{R2}}{\partial p_2} & \dots & \frac{\partial e_{R2}}{\partial p_{N_{\omega}+2NT}} \\ \vdots & \vdots & \dots & \vdots \\ \frac{\partial e_{Rm}}{\partial p_1} & \frac{\partial e_{Rm}}{\partial p_2} & \dots & \frac{\partial e_{Rm}}{\partial p_{N_{\omega}+2NT}} \end{bmatrix}.$$

7). Вычисляются настраиваемые параметры сети:

$$\Delta P_L(t) = [J_L^T J_L + \lambda I]^{-1} J_L^T e_L;$$

$$\Delta P_R(t) = [J_R^T J_R + \lambda I]^{-1} J_R^T e_R;$$

$$P(t+1) = P(t) - \Delta P_L(t) - \Delta P_R(t).$$

8). Вычисляется среднеквадратическая ошибка преобразования с помощью ИНСИА:

$$E_{FA} = \frac{1}{2} \sum_{i=1}^m (o_{Li} - y_{Li})^2 + \frac{1}{2} \sum_{i=1}^m (o_{Ri} - y_{Ri})^2,$$

где o_{Li} , o_{Ri} – не нормированные значения на выходе НСИА при подаче на вход $[\hat{x}_{Li}; \hat{x}_{Ri}]$:

$$[o_{Li}; o_{Ri}] = [O_{Li}^2; O_{Ri}^2](\max(y_{Ri}) - \min(y_{Li})) + \min(y_{Li});$$

9). Повторять шаги 2-6 до тех пор, пока суммарная среднеквадратичная ошибка сети не станет меньше заданной, т. е. $E_{FA} \leq E_m$, и пока все середины интервалов $[o_{Li}; o_{Ri}]$ не будут лежать в интервале $[y_{Li}; y_{Ri}]$, т.е.

$$o_i = (o_{Li} + o_{Ri})/2 \in [y_{Li}; y_{Ri}], \forall i \in \{0; m\}.$$

Вторая часть критерия остановки итераций АЛМ говорит о том, что все оцененные с помощью ИНСИА точки должны лежать в доверительных границах, определенных для эталонных величин. Если этот критерий не выполняется, то можно гово-

рить о не правильном выборе модели зависимости или же о присутствии грубых погрешностей или промахов в результатах измерений. Если же мы предполагаем, что среди результатов измерений присутствуют промахи или грубые погрешности, то следует либо их исключить отбросить, либо отбросить вторую часть критерия останова.

После обучения ИНСИА ее можно использовать для оценивания неизвестной величины по показаниям калибруемого СИ. Для этого необходимо подать доверительный интервал для полученного показания СИ на вход ИНСИА, вычислить выход ИНСИА и воспользоваться выражениями:

$$[\tilde{Y}_L; Y_R] = [O_L; O_R](\max(y_R) - \min(y_L)) + \min(y_L),$$

$$\tilde{Y} = (\tilde{Y}_L + \tilde{Y}_R)/2.$$

В данном случае на выходе ИНСИА мы получаем интервальное значение, характеризующее неизвестную величину. Будем предполагать, что при использовании ИНСИА мы включаем все погрешности эталонных величин и показаний СИ в их доверительные интервалы, а погрешность аппроксимации зависит напрямую от погрешности адекватности модели, тогда половина величины вычисленного интервала и является расширенной неопределенностью неизвестной величины:

$$U(\tilde{Y}) = \frac{\tilde{Y}_R - \tilde{Y}_L}{2}.$$

СКО результатов, полученных с помощью ИНСИА, напрямую зависят от погрешности адекватности, т.е. важным этапом при построении сети является выбор активационной функции первого слоя. Если из априорной информации известно, что зависимость между показанием СИ и эталонной величиной линейна, то необходимо выбирать линейную активационную функцию, в противном случае – сигмоидальную.

Таким образом, процедуру построение КЗ СИ при помощи ИНСИА можно представить схематически (рис. 2).

Для определения числа НЭ в первом (скрытом) слое ИНС была предложена формула, являющаяся следствием теорем Арнольда-Колмогорова-Хехт-Нильсена [6]. Для задачи построения ФА ее можно записать следующим образом:

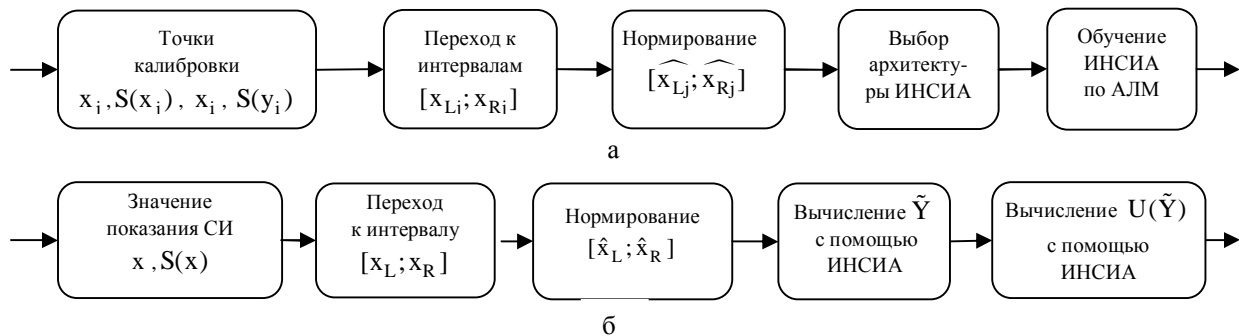


Рис. 2. Применения ИНСИА при построении КЗ СИ (а) и при ее использовании (б)

$$m/(2(1 + \log_2 m)) \leq N_{НЭ} \leq 1,5(m+1) + 0,5,$$

где $N_{НЭ}$ – количество НЭ в первом (скрытом) слое ИНС.

3. Пример использования ИНСИА при калибровке хроматографа

Возьмем пример из [9]. Результаты измерения содержания азота в синтетическом природном газе, показания хроматографа и соответствующие им СКО представлены в табл. 2.

После перехода от исходных точек калибровки к нормированным (табл. 3) зададим среднеквадратическую ошибку преобразования: $E_m = 0.022$ и, используя АЛМ, обучим ИНСИА, активационная функция первого слоя которой сигмоидальная. За $t = 9974$ эпох (итераций) удалось обучить ИНСИА до указанного значения среднеквадратической ошибки преобразования. Изменение среднеквадратической ошибки сети представлено на рис. 3.

По графику можно судить о неустойчивом поведении сети. Это связано с тем, что мы пытаемся одновременно минимизировать две функции e_L и e_R , которые зависят от одних и тех же параметров. Однако итерационный процесс сходится, и в результате ИНСИА преобразует интервальные значения с заданной среднеквадратической ошибкой.

Результаты использования ИНСИА для определения содержания азота, представлены в табл. 4.

Также в таблице представлены результаты, полученные с помощью полиномиальной функции анализа второго порядка, параметры которой вычислены с помощью метода, описанного в [9].

Таблица 2

Результаты измерений

X	S(X)	Y	S(Y)
60	35	$1,5 \cdot 10^{-3}$	$9 \cdot 10^{-4}$
$7.786 \cdot 10^3$	$1.357 \cdot 10^2$	$1.888 \cdot 10^{-1}$	$4.5 \cdot 10^{-4}$
$8.170 \cdot 10^4$	36.7	1.990	$4 \cdot 10^{-3}$
$1.562 \cdot 10^5$	$2.232 \cdot 10^2$	3.796	$3.9 \cdot 10^{-2}$
$2.333 \cdot 10^5$	$1.372 \cdot 10^2$	5.677	$1.25 \cdot 10^{-2}$
$2.930 \cdot 10^5$	$2.455 \cdot 10^2$	7.118	$1.25 \cdot 10^{-2}$
$3.809 \cdot 10^5$	$1.251 \cdot 10^2$	9.210	$2 \cdot 10^{-2}$
$4.497 \cdot 10^5$	$3.218 \cdot 10^2$	10.90	$2.5 \cdot 10^{-2}$




Рис. 3. Изменение среднеквадратической ошибки при обучении ИНСИА

Таблица 3

Точки калибровки в виде интервалов и их нормированные значения

X	Y	\hat{X}	\hat{Y}
[-10;130]	$[-3 \cdot 10^{-4}; 0.0033]$	[0.0000; 0.0003]	[0.0000; 0.0003]
$[7.5146 \cdot 10^3; 8.0574 \cdot 10^3]$	[0.1879; 0.1897]	[0.0167; 0.0179]	[0.0172; 0.0174]
$[80.966 \cdot 10^4; 82.434 \cdot 10^4]$	[1.9820; 1.9980]	[0.1798; 0.1831]	[0.1810; 0.1825]
$[1.5575 \cdot 10^5; 1.5665 \cdot 10^5]$	[3.7180; 3.8740]	[0.3459; 0.3479]	[0.3396; 0.3538]
$[2.3303 \cdot 10^5; 2.3357 \cdot 10^5]$	[5.6520; 5.7020]	[0.5175; 0.5187]	[0.5162; 0.5207]
$[2.9251 \cdot 10^5; 2.9350 \cdot 10^5]$	[7.0930; 7.1430]	[0.6495; 0.6517]	[0.6478; 0.6523]
$[3.8035 \cdot 10^5; 3.8085 \cdot 10^5]$	[9.1700; 9.2500]	[0.8446; 0.8457]	[0.8374; 0.8448]
$[4.4906 \cdot 10^5; 4.5034 \cdot 10^5]$	[10.8500; 10.9500]	[0.9971; 1.0000]	[0.9909; 1.0000]

Таблица 4

Использование ИНСИА

X	70000	370000
S(X)	40	200
\hat{Y} , ИНСИА	1.7039	8.9753
$u(\hat{Y})$, ИНСИА	0.0016	0.0056
\hat{Y} , ISO 6143:2001	1.7061	8.9727
$u(\hat{Y})$, ISO 6143:2001	0.0033	0.0118

Заключение

Использование ИНС при построение КЗ СИ имеет ряд преимуществ перед классическими методами:

1) выбор характера зависимости между показанием СИ и эталонной величиной сводится лишь к выбору либо линейной, либо нелинейной активационной функции первого слоя двухслойной ИНСИА. При этом в случае нелинейной зависимости не требуется определять вид параметрической функции. Это позволяет свести к минимуму погрешность адекватности построенной математической модели, и упростить работу инженера, выполняющего калибровку;

2) расширенная неопределенность результата оценивания неизвестной величины с помощью ИНСИА изменяется согласно качеству аппроксимации измерительных данных искомой ИНСИА, т.е. если представленную ФА разделить на несколько отрез-

ков, содержащих равное количество точек калибровки, то расширенная неопределенность будет меньше там, где ИНС аппроксимировала точки калибровки с меньшей среднеквадратической ошибкой. Это говорит о том, что мы можем больше доверять тем результатам, которые находятся ближе к точкам калибровкам с меньшей ошибкой, чем тем, которые находятся рядом с точками с большим значением ошибки. Следовательно, если в результатах измерений будут неучтенные грубые погрешности или промахи, то это сразу же отразится на увеличении расширенной неопределенности результата оценивания неизвестной величины по показаниям СИ. А значит, если мы хотим уменьшить расширенную неопределенность предсказанных значений или приблизить ее к постоянному значению, то требуется выбирать как можно больше точек в калибруемом диапазоне;

3) при переходе от оценок и их СКО к интервальным оценкам учитываются параметры закона распределения данных величин – доверительная вероятность и коэффициент охвата;

4) при использовании ИНСИА и в случае отсутствия грубых погрешностей и промахов результатов измерений строится такая ФА, что ее точки, находящиеся вблизи точек калибровки, обязательно находятся в их доверительных интервалах, т.е. полученная ФА проходит через точки, находящиеся в границах доверительных интервалов калибровочных точек;

7) расширенная неопределенность, предсказанного значения ИНСИА, находится из предположения, что погрешность адекватности математической модели минимальна и исключены грубые погрешности и промахи результатов измерений. Такие предположения всегда используются и при классическом построении ФА другими методами, однако при использовании ИНСИА это ведет к равенству полученного доверительного интервала и расширенной неопределенности предсказанного значения.

Список литературы

1. JCGM 200:2008. *International Vocabulary of Metrology – Basic and General Concepts and Associated Terms (VIM)*. – BIPM, 2008. – 104 p.
2. Колмогоров А.Н. О представлении непрерывных функций нескольких переменных в виде суперпозиций одного переменного и сложения / А.Н. Колмогоров // Доклады АН СССР. – М.: АН СССР, 1957. – Т. 154. – С. 953-956.
3. Колмогоров А.Н. О представлении непрерывных функций нескольких переменных суперпозицией непрерывных

функций меньшего числа переменных / А.Н. Колмогоров // Доклады АН СССР. – М.: АН СССР, 1956. – Т. 108. – С. 2.

4. Арнольд В.И. О функции трех переменных / В.И. Арнольд // Доклады АН СССР. – М.: Изд-во АН СССР, 1957. – Т. 114. – С. 679-681.

5. Hecht-Nielsen R. Kolmogorov's mapping neural network existence theorem / R. Hecht-Nielsen // International Conference NN, IEEE Press. – 1987. – V. III. – P. 11-13.

6. Ясницкий Л.Н. Введение в искусственный интеллект / Л.Н. Ясницкий. – М.: Изд. центр "Академия", 2008. – 176 с.

7. Головкин В.А. Нейронные сети: обучение, организация и применение / В.А. Головкин. – М.: Радиотехника, 2000. – 256 с.

8. Водотыка С.В. Использование искусственных нейронных сетей при построении калибровочной зависимости средства измерения / С.В. Водотыка // Системы обработки информации. – X.: ХУПС, 2011. – Вып. 1 (91). – С. 24-28.

9. ДСТУ ISO 6143-2003. Аналіз газів. Методи компарування для визначення та перевіряння складу повітряних газових сумішей. – К.: Держспоживстандарт, 2003. – 27 с.

10. Грановский В.А. Методы обработки экспериментальных данных при измерениях / В.А. Грановский, Т.Н. Сирая. – Л.: Энергоатомиздат, 1990. – 288 с.

11. Kim H.J. Time Series Prediction Using An Interval FIR Network / H.J. Kim, T.W. Ryu // Neural Information Processing – Letters and Reviews. – 2005. – № 3. – P. 39-45.

12. Hagan M. Training Feedforward Networks with the Marquardt Algorithm / M. Hagan, M. Menhaj // IEEE Transactions on Neural Networks. – November 1994. – Vol. 5, No. 6. – P. 989-993.

13. Дрейпер Н. Прикладной регрессионный анализ / Н. Дрейпер, Г. Смит. – М.: Издательский дом "Вильямс", 2007. – 912 с.

14. Гилл Ф. Практическая оптимизация / Ф. Гилл, У. Мюррей, М. Райт. – М.: Мир, 1985. – 509 с.

15. Хайкин С. Нейронные сети: полный курс / С. Хайкин. – 2-е изд., испр., пер. с англ. – М.: ООО «ИД Вильямс», 2006. – 1104 с.

16. Efron B. Bootstrap methods: Another look at the jackknife / B. Efron // The Annals of Statistics. – 1979. – № 7. – P. 1-26.

17. Levenberg K. A Method for the Solution of Certain Problems in Least-Squares / K. Levenberg // Quarterly Applied Mathematics 2. – 1944. – P. 164-168.

18. Belohvalek R. Backpropagation for interval patterns / R. Belohvalek // Neural Network World. – 1997. – № 3. – P. 335-346.

19. Efron B. An introduction to bootstrap / B. Efron, R. Tibshirani. – New York: Chapman & Hall, 1993. – 437 p.

20. Hecht-Nielsen R. Kolmogorov's mapping neural network existence theorem / R. Hecht-Nielsen // International Conference NN, IEEE Press. – 1987. – V. III. – P. 11-13.

21. Анатольев С. Основы бустрапирования / С. Анатольев // Квантиль. – 2007. – № 3. – С. 1-12.

Поступила в редколлегию 23.02.2011

Рецензент: д-р техн. наук, проф. И.В. Руженцев, Харьковский национальный университет радиоэлектроники, Харьков.

ВИКОРИСТАННЯ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ З ІНТЕРВАЛЬНОЮ АРИФМЕТИКОЮ ПРИ ПОБУДОВІ КАЛІБРУВАЛЬНОЇ ЗАЛЕЖНОСТІ ЗАСОБУ ВИМІРЮВАННЯ

С.В. Водотыка

Розглядається процедура побудови калібрувальних залежностей засобів вимірювання за допомогою штучних нейронних мереж у випадках присутності істотних невизначеностей результатів вимірювань еталонних величин та показань засобів вимірювання. Застосування штучних нейронних мереж також дозволяє врахувати від закону розподілу за допомогою переходу від оцінок і стандартних невизначеностей величин до їх розширених невизначеностей. Описано алгоритм Левенберга-Марквардта стосовно виховання штучних нейронних мереж, що оперують на основі теорії інтервальної арифметики.

Ключові слова: невизначеність вимірювання, калібрування засобу вимірювання, нейронна мережа.

USING OF ARTIFICIAL NEURON NETWORKS WITH INTERVAL ARITHMETIC FOR CONSTRUCTION OF CALIBRATION DEPENDENCIES OF MEASURING TOOLS

S.V. Vodotyka

We consider the procedure for constructing of the calibration curves of measuring tools using artificial neural networks in the presence of significant uncertainties in the measurement results of reference values and the readings of measuring devices. Application of artificial neural networks can also take into account the form of the distribution with the transition from the estimates and the standard uncertainty values to their expanded uncertainty. The algorithm of Levenberg-Marquardt is applied to artificial neural networks that operate on the basis of the theory of interval arithmetic.

Keywords: *measurement uncertainty, calibration of measuring tools, neural network.*