

УДК 006.091

С.В. Водотыка

Харьковский национальный университет радиоэлектроники, Харьков, Украина

ИСПОЛЬЗОВАНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ПРИ ПОСТРОЕНИИ КАЛИБРОВОЧНОЙ ЗАВИСИМОСТИ СРЕДСТВА ИЗМЕРЕНИЯ

Рассматривается процедура построения калибровочной зависимости средств измерения с помощью искусственных нейронных сетей, которые позволяют свести выбор характера зависимости между эталонной величиной и показанием средства измерения либо к линейной, либо к нелинейной. Описан порядок обучения искусственных нейронных сетей методом обратного распространения ошибки и алгоритмом Левенберга-Марквардта применительно к построению калибровочной зависимости. Проведено эмпирическое сравнение результатов калибровки с помощью метода наименьших квадратов и с помощью нейронных сетей.

Ключевые слова: неопределенность измерения, калибровка средства измерения, метод наименьших квадратов, нейронная сеть.

Введение

Решение задачи калибровки средств измерения (СИ) сводится к построению аппроксимирующей зависимости величин показаний СИ от эталонных значений [1]. С этой целью применяются разнообразные регрессионные методы математического анализа, основным недостатком которых является увеличение погрешности адаптации при неправильном выборе математической модели. Однако применение искусственных нейронных сетей (ИНС), представляющих собой универсальный аппарат для аппроксимации функций, помогает устранить этот недостаток. Одним из свойств ИНС является то, что любая функция вида:

$$f: [0,1]^n \rightarrow [0,1]$$

может быть аппроксимирована трехслойной ИНС с одним скрытым слоем и алгоритмом обратного распространения ошибки с любой степенью точности [2].

Данная теорема наводит на мысль о применении ИНС для построения калибровочной зависимости (КЗ) СИ. С этой целью разработана последовательность действий для построения КЗ СИ с помощью двухслойной ИНС.

1. Описание двухслойной ИНС

Предлагается использовать двухслойную ИНС, активационная функция первого слоя которой зависит от располагаемой априорной информации о характере зависимости между эталонной величиной и показанием СИ. Если имеется информация о линейности этой зависимости, то активационная функция первого слоя является линейной, если же доступна информация о нелинейности, то функция – сигмоидальная. При этом активационная функция второго слоя всегда линейная. Количество нейронов в пер-

вом слое равно $(m-1)$, где m – количество точек калибровки или в терминологии нейронных сетей количество образов для обучения. ИНС для аппроксимации искомой зависимости изображена на рис. 1.1.

Отметим, что построение обратной функции к КЗ имеет ряд преимуществ [3], поэтому ИНС будем использовать в качестве преобразователя показаний СИ в эталонную величину.

Сеть имеет один вход I_1 и один выход O_1^2 (верхний индекс – номер слоя, нижний – номер нейронного элемента (НЭ) в этом слое). Вход сети соединен со всеми НЭ первого слоя с помощью синаптических связей с весовыми коэффициентами ω_{1p}^1 ($p = 1 \dots m-1$, верхний индекс – номер слоя ИНС, нижний индекс – комбинация номеров нейронных элементов (НЭ), которые соединены с помощью данного весового коэффициента). Каждый выход НЭ первого слоя соединен с НЭ второго слоя, выход которого является выходом всей ИНС.

С математической точки зрения ИНС можно выразить функцией, состоящей из более простых параметрических функций. Передачу информации от слоя к слою для нашей ИНС можно выразить следующим образом:

$$\bar{Y} = O_1^2 = f_2(S_1^2) = \sum_{k=1}^p O_k^1 \omega_{k1}^2 - T_1^2; \quad (1.1)$$

$$O_k^1 = f_1(S_k^1) = f_1(\bar{X} \omega_{1k}^1 - T_k^1),$$

где \bar{X} , \bar{Y} – нормированные значения входного и выходного сигнала сети; f_j – функция активации нейрона в j -м слое; T_i^j – порог i -го НЭ в j -м слое.

При этом функция активации первого слоя зависит от априорной информации о характере зависимости между эталонной величиной и показанием СИ:

2. Обучение двуслойной ИНС

Обучение ИНС основано на минимизации среднеквадратической ошибки сети:

$$E = e^T e = \frac{1}{2} \sum_{r=1}^m (O_r^2 - \bar{y}_i)^2,$$

где O_1^2 – вычисленное значение выхода ИНС при подаче на вход образа \bar{x}_i ; \bar{y}_i – желаемое значение выхода НС при подаче на вход образа \bar{x}_i .

В современной теории ИНС наиболее популярны два алгоритма обучения:

– метод обратного распространения ошибки (МОРО) [4];

– алгоритм Левенберга-Марквардта (АЛМ).

Мы будем использовать АЛМ, но при расчете частных производных среднеквадратической ошибки по настраиваемым параметрам сети будет использоваться МОРО.

Согласно алгоритму Левенберга-Марквардта обучение НС, представленной на рис. 3, происходит следующим образом [5]:

1). Задается параметр регуляризации λ , его степень изменения β (в большинстве источников рекомендуется выбирать $\lambda = 0,01$ и $\beta = 10$) и желаемая среднеквадратическая ошибка преобразования E_m .

2). Весовые коэффициенты и пороги ИНС инициализируются по правилу:

$$\omega_{11}^1 = \zeta; \quad \omega_{i(i+1)}^1 = \omega_{i1}^1 + \zeta;$$

$$\omega_{11}^2 = \omega_{1(m-1)}^1 + \zeta; \quad \omega_{(i+1)1}^2 = \omega_{i1}^2 + \zeta$$

$$T_i^1 = 1; \quad T_i^2 = 1,$$

где ζ – маленькая величина ($\zeta = 10^{-4}$).

3). Вычисляется среднеквадратическая ошибка обратной КЗ:

$$E_{dep} = \frac{1}{2} \sum_{i=1}^m (\tilde{y}_i - y_i)^2, \quad (2.1)$$

где \tilde{y}_i – значение, вычисленное по (1.3).

4). На вход нейронной сети подаются по очереди нормированные показания СИ $\bar{x}_1, \bar{x}_2, \dots, \bar{x}_m$, для каждого из которых вычисляются частные производные с помощью МОРО [5]:

$$\frac{\partial e_j}{\partial \omega_{i1}^2} = \begin{cases} \omega_{i1}^2 \omega_{i1}^1 (1 - \omega_{i1}^1 \bar{x}_j) (\bar{x}_j)^2, & \text{если КЗ нелинейная;} \\ \omega_{i1}^2 (\bar{x}_j), & \text{если КЗ линейная;} \end{cases}$$

$$\frac{\partial e_j}{\partial \omega_{i1}^2} = \delta_i^2 O_i^1 = O_i^1 = \omega_{i1}^1 \bar{x}_j;$$

$$\frac{\partial e_j}{\partial T_i^1} = \delta_i^1 = \omega_{i1}^2 \omega_{i1}^1 \bar{x}_j (1 - \omega_{i1}^1 \bar{x}_j); \quad \frac{\partial e_j}{\partial T_i^2} = 1.$$

$$f_1(S_k^1) = \begin{cases} \bar{X} \omega_{1k}^1 - T_k^1, & \text{если КЗ линейная;} \\ \frac{1}{1 + e^{-\omega_{1k}^1 + T_k^1}}, & \text{если КЗ нелинейная.} \end{cases}$$




Рис. 1.1. ИНС для калибровки СИ

Постановка задачи выглядит следующим образом:

1) на основе результатов показаний СИ X и эталонных величин Y получены точки калибровки (табл. 1.1):

Таблица 1.1

Точки калибровки

X	x_1	x_2	\dots	x_m
Y	y_1	y_2	\dots	y_m

2) с помощью результатов измерений необходимо обучить ИНС для получения зависимости:

$$\bar{Y} = g(\bar{X}); \quad (1.2)$$

3) использовать ИНС для получения значений неизвестных величин на основании показаний СИ.

Согласно выражению (1) и (2) ИНС преобразует нормированные сигналы [4], поэтому перед использованием ИНС необходимо произвести нормирование точек калибровки:

$$\bar{X} = \frac{X - x_{\min}}{x_{\max} - x_{\min}}, \quad \bar{Y} = \frac{Y - y_{\min}}{y_{\max} - y_{\min}},$$

где x_{\max} , x_{\min} – максимальное и минимальное значения показаний СИ; y_{\max} , y_{\min} – максимальное и минимальное значения эталонной величины.

Теперь зависимость между показанием СИ и эталонной величиной будет иметь вид:

$$Y = (y_{\max} - y_{\min}) \cdot g \left[\frac{X - x_{\min}}{x_{\max} - x_{\min}} \right] + y_{\min}, \quad (1.3)$$

где g – преобразование, выполняемое ИНС.

Для правильного функционирования ИНС, т.е. выполнения преобразование входного сигнала в выходной с заданной среднеквадратической ошибкой, необходимо произвести процедуру обучение ИНС.

5). Используя частные производные, вычисленные в п.4, строится матрица Якоби и вычисляются

новые значения весовых коэффициентов и порогов ИНС:

$$J = \begin{bmatrix} \frac{\partial e_1}{\partial \omega_{11}^1} & \dots & \frac{\partial e_1}{\partial \omega_{1(m-1)}^1} & \frac{\partial e_1}{\partial \omega_{11}^2} & \dots & \frac{\partial e_1}{\partial \omega_{(m-1)1}^2} & \frac{\partial e_1}{\partial T_1^1} & \dots & \frac{\partial e_1}{\partial T_{(m-1)}^1} & 1 \\ \frac{\partial e_2}{\partial \omega_{11}^1} & \dots & \frac{\partial e_2}{\partial \omega_{1(m-1)}^1} & \frac{\partial e_2}{\partial \omega_{11}^2} & \dots & \frac{\partial e_2}{\partial \omega_{(m-1)1}^2} & \frac{\partial e_2}{\partial T_1^1} & \dots & \frac{\partial e_2}{\partial T_{(m-1)}^1} & 1 \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots & \vdots \\ \frac{\partial e_m}{\partial \omega_{11}^1} & \dots & \frac{\partial e_m}{\partial \omega_{1(m-1)}^1} & \frac{\partial e_m}{\partial \omega_{11}^2} & \dots & \frac{\partial e_m}{\partial \omega_{(m-1)1}^2} & \frac{\partial e_m}{\partial T_1^1} & \dots & \frac{\partial e_m}{\partial T_{(m-1)}^1} & 1 \end{bmatrix};$$

$$\Delta P(t) = [J^T J + \lambda I]^{-1} J^T e;$$

$$\omega_{11}^1(t+1) = \omega_{11}^1(t) - \Delta P_1(t), \dots, \omega_{1(m-1)}^1(t+1) = \omega_{1(m-1)}^1(t) - \Delta P_{m-1}(t);$$

$$\omega_{11}^2(t+1) = \omega_{11}^2(t) - \Delta P_m(t), \dots, \omega_{(m-1)1}^2(t+1) = \omega_{(m-1)1}^2(t) - \Delta P_{2m-2}(t);$$

$$T_1^1(t+1) = T_1^1(t) - \Delta P_{2m-1}(t), \dots, T_1^1(t+1) = T_{m-1}^1(t) - \Delta P_{3m-3}(t);$$

$$T_1^2(t+1) = T_1^2(t) - \Delta P_{3m-2}(t),$$

где под индексом вектора $\Delta P(t)$ подразумевается номер его элемента.

6). Вычисляется среднеквадратическая ошибка обратной КЗ (2.1).

7). Если в результате изменения параметров среднеквадратическая ошибка обратной КЗ увеличилась, то вернуться на шаг 6 (т.е. восстановить прежние значения весов) и увеличить λ : $\lambda = \lambda \cdot \beta$. Если ошибка уменьшилась, то уменьшить λ : $\lambda = \lambda / \beta$ и вернуться на шаг 3.

9). Повторять шаги 3-8 до тех пор, пока среднеквадратичная ошибка обратной КЗ не станет меньше заданной, т. е. $E_{dep} \leq E_m$.

Все эти вычислительные операции очень трудно выполнить вручную, поэтому рекомендуется использовать специальные математические пакеты такие, как MathCad или Matlab.

3. Пример использования предложенного алгоритма

В табл. 3.1 приведены результаты измерений концентрации пропана в азоте для калибровки хроматографа Цвет 500 с пламенно ионизационным детектором. В данном случае Y – концентрация пропана в калибровочной газовой смеси, а X – площади хроматографических пиков (измерялись с помощью системы автоматизации анализа САА-06). Измерения площади пиков проводились не менее 5 раз в каждой точке калибровки, после чего значения усреднены и занесены в табл. 3.1.

После нормирования точек калибровки и обучения двуслойной ИНС с 4-мя НЭ в первом слое за 385 эпох удалось достичь среднеквадратической ошибки преобразования $E_{dep} = 0.00209927$. На рис. 3.1 изображено изменение среднеквадратической ошибки преобразования.




Рис. 3.1. Изменение среднеквадратической ошибки обратной КЗ

Линейная функция (рис. 3.1) использовалась в качестве активационной для первого слоя, так как пламенно ионизационные детекторы обладают линейной функцией преобразования.

Таблица 3.1

Результаты измерений

X	1299	3441	7590	11754	16369	24930
Y	0,5	1,0	2,0	3,0	4,0	6,0

После получения обратной КЗ измеряется площадь хроматографических пиков для образцов с неизвестной концентрацией пропана (табл. 3.2).

Таблица 3.2

Результаты измерений

X	1445	4125	8015	10820
\tilde{Y} , МНК	0,5529	1,1758	2,0800	2,7321
\tilde{Y} , ИНС	0,5528	1,1758	2,0801	2,7321
$U(\tilde{Y})$, $P=0,9545$	0,0766	0,0735	0,0706	0,0700

Расширенная неопределённость была рассчитана по выражениям представленным в [6] для метода наименьших квадратов (МНК) с коэффициентом охвата равным 2.

Как видно из табл. 3.2 обратная КЗ, представленная в виде ИНС аппроксимирует результаты измерения не хуже, чем МНК.

Заключение

Предложенная процедура построение обратной КЗ, основанная на использовании ИНС, позволяет свести выбор вида аппроксимирующей зависимости между показанием СИ и эталонной величиной либо

к линейной, либо к нелинейной. Данное свойство помогает сократить время на обработку результатов измерений в случае отсутствия информации о линейности данной зависимости.

Следует также отметить, что если искомая зависимость существенно линейна, то ИНС не сможет найти лучшую аппроксимацию нежели МНК, однако ИНС может приближаться к параметрам зависимости по МНК с заданной точностью.

Применение ИНС при построении обратной КЗ требует использования специальных программных средств, однако процедура, предложенная в данной статье, может служить основанием для написания отдельной узконаправленной программы, которая в дальнейшем упростила процедуру построения КЗ.

Список литературы

1. JCGM 200:2008 International Vocabulary of Metrology – Basic and General Concepts and Associated Terms (VIM), BIPM, 2008 – 104 p.
2. Головки В.А. Нейронные сети: обучение, организация и применение / В.А. Головки. – М.: Радиотехника, 2000. – 256 с.
3. ДСТУ ISO 6143-2003 Аналіз газів. Методи компарування для визначення та перевіряння складу повітряних газових сумішей. – К.: Держспоживстандарт, 2003. – 27 с.
4. Хайкин С. Нейронные сети: полный курс / С. Хайкин. – 2-е изд., испр., пер. с англ. – М.: ООО «ИД Вильямс», 2006. – 1104 с.
5. Hagan M. Training Feedforward Networks with the Marquardt Algorithm // IEEE Transactions on Neural Networks. – November 1994. – Vol. 5, No. 6. – P. 989-993.
6. Захаров И.П. Теория неопределенности в измерениях / И.П. Захаров, В.Д. Кукуш. – Х.: Консум, 2002. – 256 с.

Поступила в редколлегию 22.12.2010

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

ВИКОРИСТАННЯ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ ПРИ ПОБУДОВІ КАЛІБРУВАЛЬНОЇ ЗАЛЕЖНОСТІ ЗАСОБУ ВИМІРЮВАННЯ

С.В. Водотика

Розглядається процедура побудови калібрувальної залежності засобу вимірювання за допомогою штучних нейронних мереж, які дозволяють звести вибір характеру залежності між еталонною величиною і показанням засобу вимірювання або до лінійної, або до нелінійної. Описаний порядок навчання штучних нейронних мереж методом зворотного поширення помилки і алгоритмом Льювенберга-Марквардта стосовно побудови калібрувальної залежності. Проведено емпіричне порівняння результатів калібрування за допомогою методу найменших квадратів і за допомогою нейронних мереж.

Ключові слова: невизначеність вимірювання, калібрування засобу вимірювання, метод найменших квадратів, нейронна мережа.

USING OF ARTIFICIAL NEURON NETWORKS FOR CONSTRUCTION OF CALIBRATION DEPENDENCE OF MEASURING TOOLS

S.V. Vodotyka

Procedure of construction of calibration dependence of measuring tools is examined by using artificial neuron networks, which allow to take the choice of character of dependence between value of measurement standard and corresponding indication of measuring tool either to linear or to nonlinear. A teaching order of artificial neuron networks by the method of back propagation error and by algorithm of Levenberg-Marquardt is described to applies to the construction of calibration dependence. Empiric comparison of results of calibration by the method of least squares and by neuron networks is conducted.

Keywords: measuring vagueness, calibration of measuring mean, least-squares method, neuron network.