

УДК 519.71

А.В. Дегтярев, канд. тех. наук
О.В. Запорожец, канд. техн. наук
Т.А. Овчарова

ИДЕНТИФИКАЦИЯ НЕЛИНЕЙНОЙ ФУНКЦИИ ПРЕОБРАЗОВАНИЯ С ПОМОЩЬЮ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ

Предложен метод идентификации нелинейной функции преобразования при помощи искусственной нейронной сети. Исследована работоспособность предложенного метода для различных видов нелинейностей, проведен сравнительный анализ с полиномиальной аппроксимацией.

***Ключевые слова:** функция преобразования, идентификация, искусственная нейронная сеть, перцептрон, обучение.*

A.V. Degtyarev, PhD
O.V. Zaporozhets, PhD
T.A. Ovcharova

NONLINEAR TRANSFER FUNCTIONS IDENTIFICATION BY USING ARTIFICIAL NEURAL NETWORK

The technique of nonlinear transfer function identification by using an artificial neural network is proposed. The performance of the proposed method for different types of nonlinearities is investigated, the comparative analysis with polynomial fitting is implemented.

***Keywords:** transfer function, identification, artificial neural network, perceptron, learning.*

О.В. Дегтярьов, канд. тех. наук
О.В. Запорожець, канд. техн. наук
Т.О. Овчарова

ІДЕНТИФІКАЦІЯ НЕЛІНІЙНОЇ ФУНКЦІЇ ПЕРЕТВОРЕННЯ ЗА ДОПОМОГОЮ ШТУЧНОЇ НЕЙРОННОЇ МЕРЕЖІ

Запропоновано метод ідентифікації нелінійної функції перетворення за допомогою штучної нейронної мережі. Досліджено працездатність запропонованого методу для різних видів нелінійностей, проведено порівняльний аналіз з поліноміальною апроксимацією.

***Ключові слова:** функція перетворення, ідентифікація, штучна нейронна мережа, перцептрон, навчання.*

Введение.

Методы обработки экспериментальных данных играют существенную роль при решении различных технических задач, в том числе и в измерительной практике. С усложнением измерений и повышением требований к их точности обработка результатов приобретает все более важное значение. Во многих современных измерительных задачах получить необходимую точность результатов удастся, только применяя более эффективные методы обработки данных.

К разработке новых методов обработки данных побуждают потребности современной измерительной практики, для которой характерны усложнения измерительных задач и средств измерений. Расширение возможностей обработки данных связано с развитием методологии измерений, совершенствования математических методов, а также широким внедрением вычислительной техники.

Одним из перспективных направлений развития современных методов обработки сигналов, которое позволяет повысить точность измерений и реализовать достаточно сложные алгоритмы измерительных процедур, является применение искусственных нейронных сетей. Математический аппарат теории искусственных нейронных сетей позволяет успешно решать достаточно широкий спектр задач распознавания образов, классификации, моделирования, управления, прогнозирования, оптимизации и т.п. Во многом это обусловлено такими свойствами нейросетей, как способность к самоорганизации, обобщению и обучению, высокая степень адаптивности к изменению условий функционирования, устойчивость к сбоям, проведение вычислений в реальном масштабе времени [1-3]. Все эти характеристики являются достаточно привлекательными для использования нейросетевых методов обработки данных в измерительных задачах.

Следует отметить, что в последние годы наблюдается интерес к исследованиям в области метрологии и измерительной техники, связанным с

применением искусственных нейронных сетей для решения разнообразных измерительных задач. Результаты этих исследований нашли свое отражение в публикациях соответствующей тематики в научной периодике. В этой связи можно отметить работы, посвященные использованию искусственных нейронных сетей для решения задач калибровки средств измерений [4, 5], автоматизации поверки измерительных приборов [6], а также повышения точности геодезических, биометрических и других видов измерений [7, 8].

Постановка задачи

Одной из весьма распространенных метрологических задач является идентификация функции преобразования средств измерений, суть которой состоит в нахождении функциональной зависимости между информативными параметрами входного и выходного сигналов по результатам их совместных измерений. При этом в большинстве случаев используется линейная модель, неизвестные параметры которой находятся с помощью хорошо известного метода наименьших квадратов [9, 10]. Однако в случаях, когда нелинейность функции преобразования носит существенный характер, такой подход не дает желаемого результата, поскольку приводит к возникновению большой методической погрешности измерения, обусловленной несоответствием номинальной и реальной функции преобразования

Для уменьшения погрешности можно воспользоваться методом псевдолинеаризации, то есть использовать для идентификации нелинейную функцию, которую можно привести к линейному виду путем замены переменных с последующим определением параметров этой функции по методу наименьших квадратов [10]. Но в таком случае необходимо иметь априорную информацию о виде этой нелинейной функции, то есть знать структуру математической модели средства измерения. Обоснованный выбор общего вида нелинейной зависимости является достаточно сложной задачей, которая плохо поддается формализации и осуществляется, исходя из известных

физических законов, аппроксимирующих возможностей выбранной функции и личного опыта человека, занимающегося решением задачи.

В статье предлагается альтернативный подход к решению задачи моделирования нелинейных измерительных преобразователей, основанный на использовании в качестве модели искусственной нейронной сети. Идея данного подхода перекликается с исследованием С.В. Водотыки [5]. Обоснованием целесообразности такого выбора служит тот факт, что искусственные нейронные сети по своей природе нелинейны, обладают хорошими аппроксимирующими свойствами и не требуют специально разработанных методов проектирования, их можно синтезировать через обучение.

На рис. 1 представлена структурная схема идентификации нелинейной функции преобразования. На вход объекта идентификации и нейросети подается входной сигнал $x(t)$. Выходной сигнал нейросети $\hat{y}(t)$ сравнивается с выходным сигналом нелинейного измерительного преобразователя $y(t)$.

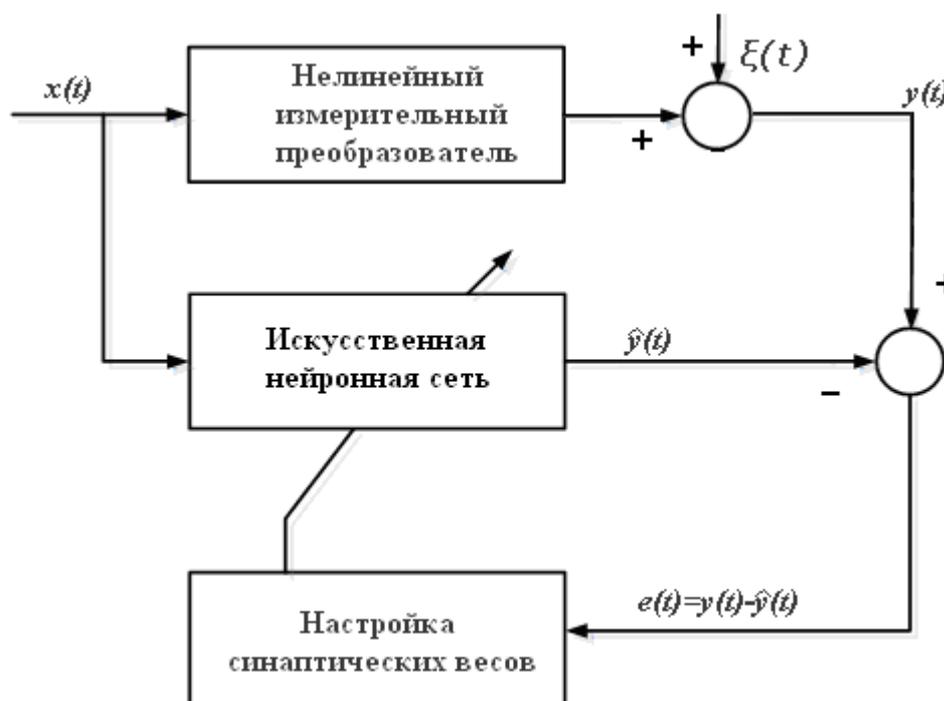


Рис. 1 – Структурная схема идентификации нелинейной функции преобразования

На выходной сигнал измерительного преобразователя накладывается аддитивная случайная помеха $\xi(t)$, описывающая влияние внутренних и внешних возмущающих факторов.

Сигнал ошибки идентификации $e(t) = y(t) - \hat{y}(t)$, полученный при сравнении двух сигналов, используется для настройки синаптических весовых коэффициентов нейросети таким образом, чтобы выходной сигнал модели $\hat{y}(t)$ являлся наилучшим приближением выходного сигнала объекта $y(t)$.

Задача идентификации состоит в обучении нейросети для обеспечения минимума функционала:

$$J(t) = \frac{1}{2} e^2(t) = \frac{1}{2} (y(t) - \hat{y}(t))^2. \quad (1)$$

Моделирование нелинейного измерительного преобразователя с помощью трехслойного персептрона

Нейронная сеть, моделирующая нелинейный измерительный преобразователь, представляет собой трехслойный персептрон, структура которого приведена на рис. 2.

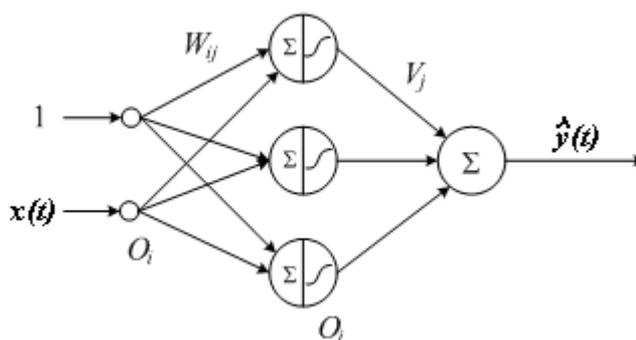


Рис. 2 – Трехслойный персептрон

Выходной слой персептрона образован одним нейроном, который формирует сигнал $\hat{y}(t)$ как взвешенную сумму выходных сигналов нейронов

скрытого слоя

$$\hat{y}(t) = \sum_{j=1}^n V_j O_j,$$

где O_j – выходной сигнал j -го нейрона скрытого слоя; V_j – синаптический вес j -го входа нейрона выходного слоя; n – количество нейронов в скрытом слое.

Скрытый слой образован нейронами с сигмоидальными функциями активации. Каждый нейрон этого слоя описывается следующими уравнениями

$$O_j = \frac{1}{1 + e^{-S_j}},$$
$$S_j = \sum_{i=1}^m W_{ij} O_i,$$

где O_i – выходной сигнал i -го нейрона входного слоя; W_{ij} – синаптический вес i -го входа j -го нейрона скрытого слоя; m – количество нейронов во входном слое.

Входной слой нейронов образован самими входными сигналами нейросети, в качестве которых в рамках данной задачи выступают входной сигнал $x(t)$ и постоянный сигнал равный 1, который обеспечивает смещение.

Настройку синаптических весов персептрона V_j и W_{ij} будем производить с использованием метода обратного распространения ошибки [1-3], согласно которому минимизация критерия оптимальности (1) осуществляется с помощью градиентной процедуры:

$$V_j(t) = V_j(t-1) - \mu_V \frac{\partial J(t)}{\partial V_j} = V_j(t-1) + \mu_V e(t) O_j,$$
$$W_{ij}(t) = W_{ij}(t-1) - \mu_W \frac{\partial J(t)}{\partial W_{ij}} = W_{ij}(t-1) + \mu_W e(t) V_j(t) O_j (1 - O_j) O_i,$$
(2)

где μ_V и μ_W – числовые коэффициенты, определяющие шаг градиентного поиска и влияющие на скорость обучения.

Обучающая выборка для процедуры обучения нейросети состоит из пар значений $\langle x(t), y(t) \rangle$, получаемых при работе всего устройства, когда на вход подают образцовый сигнал $x(t)$ и фиксируют соответствующее ему значение выходного сигнала $y(t)$.

Алгоритм обучения персептрона будет состоять из таких шагов:

- 1) присвоить синаптическим весам V_j , W_{ij} случайные начальные значения;
- 2) подать на вход нейросети очередной образец обучающей выборки $\langle x(t), y(t) \rangle$;
- 3) рассчитать выходной сигнал $\hat{y}(t)$ и ошибку $e(t) = y(t) - \hat{y}(t)$;
- 4) скорректировать синаптические весовые коэффициенты нейронов с помощью процедуры (2);
- 5) повторить шаги 2–4 до тех пор, пока значение целевой функции (1) не станет достаточно малым. После этого обучение завершается.

Результаты экспериментальных исследований

Для исследования свойств и характеристик предложенной системы использовался метод имитационного моделирования на ЭВМ. В качестве нейросети использовался трехслойный персептрон, на выходе которого стоял сумматор, а скрытый слой был образован тремя нейронами с сигмоидальными функциями активации. Настройка синаптических весов производилась с использованием алгоритма Левенберга-Марквардта, обладающего более высоким быстродействием по сравнению с методом градиентного спуска. Измерительное устройство моделировалось различными видами нелинейных функциональных зависимостей:

- 1) синусоидальная $y = \sin(ax + b)$;
- 2) степенная $y = ax^b$;
- 3) гиперболическая $y = a + b/x$;

4) дробно-линейная I $y = \frac{1}{a + bx}$;

5) дробно-линейная II $y = \frac{cx}{a + bx}$;

6) показательная I $y = ae^{bx}$;

7) показательная II $y = ae^{b/x}$;

8) логарифмическая I $y = a + b \ln x$;

9) логарифмическая II $y = a + b / \ln x$.

Проведен сравнительный анализ качества аппроксимации нелинейной функции преобразования искусственной нейронной сетью и полиномами 3-го, 4-го и 5-го порядка.

Результаты идентификации представлены в табл. 1 и на рис. 3.

Таблица 1

Функция	Формула	Среднеквадратическая погрешность идентификации			
		Полином 3-й степени	Полином 4-й степени	Полином 5-й степени	Трехслойный персептрон
1. Синусоидальная	$y = \sin(ax + b)$	0,0122	0,0121	0,0121	0,0113
2. Степенная	$y = ax^b$	0,0377	0,0208	0,0120	0,0059
3. Гиперболическая	$y = a + b/x$	0,0407	0,0189	0,0128	0,0136
4. Дробно-линейная I	$y = \frac{1}{a + bx}$	0,0761	0,0416	0,0277	0,0270
5. Дробно-линейная II	$y = \frac{cx}{a + bx}$	0,0279	0,0141	0,0097	0,0092
6. Показательная I	$y = ae^{bx}$	0,0323	0,0204	0,0207	0,0212
7. Показательная II	$y = ae^{b/x}$	0,0478	0,0280	0,0183	0,0164
8. Логарифмическая I	$y = a + b \ln x$	0,0382	0,0245	0,0206	0,0230
9. Логарифмическая II	$y = a + b / \ln x$	0,3303	0,2199	0,1476	0,0733

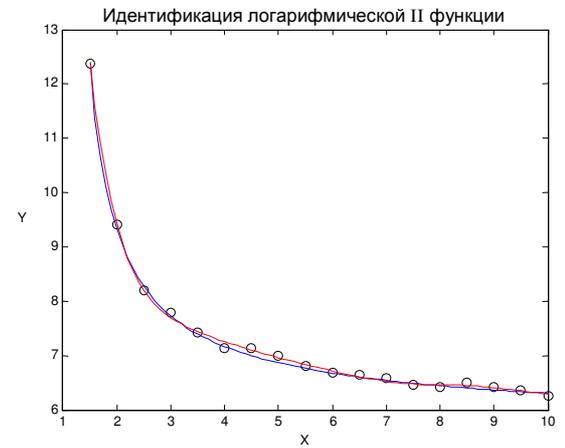
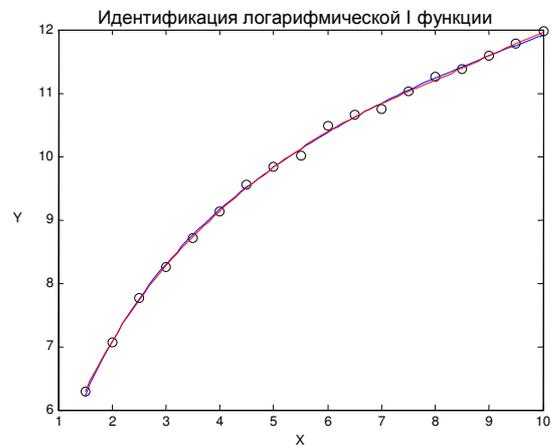
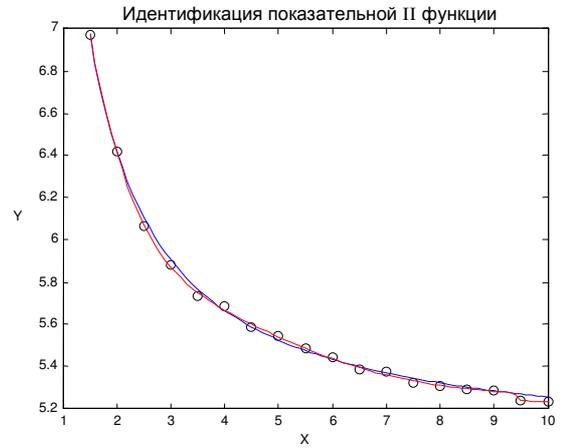
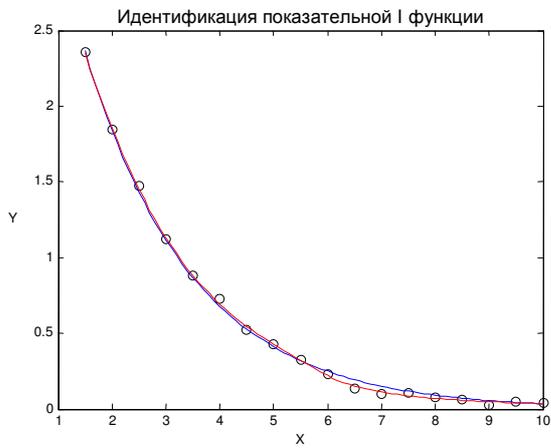
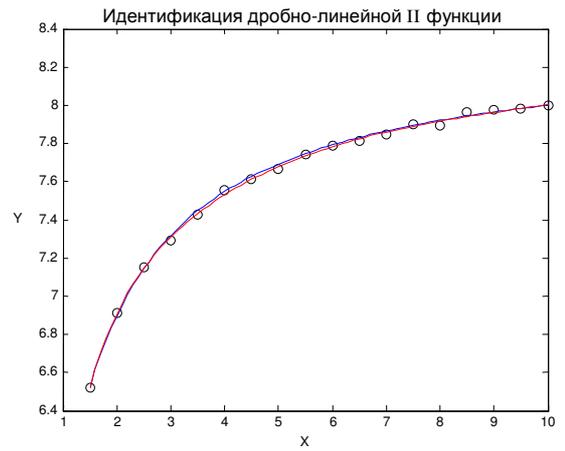
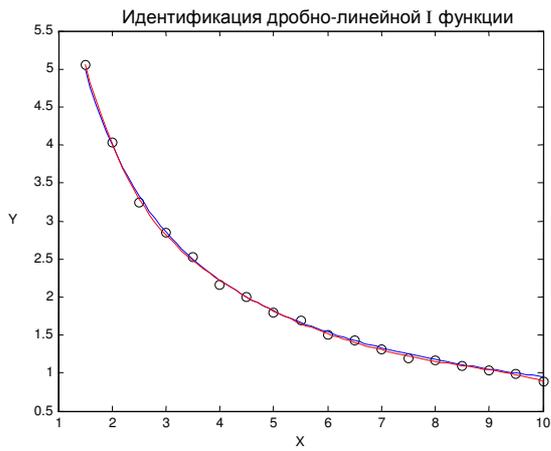
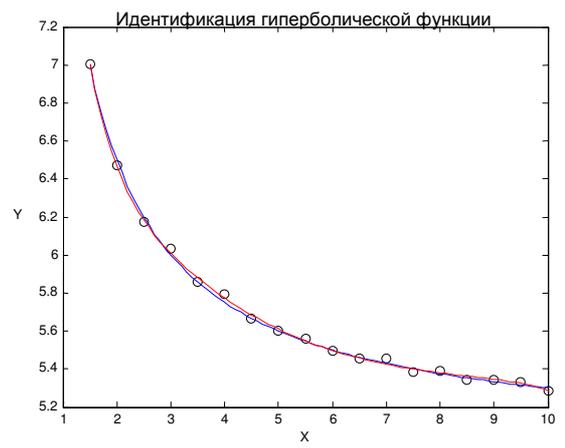
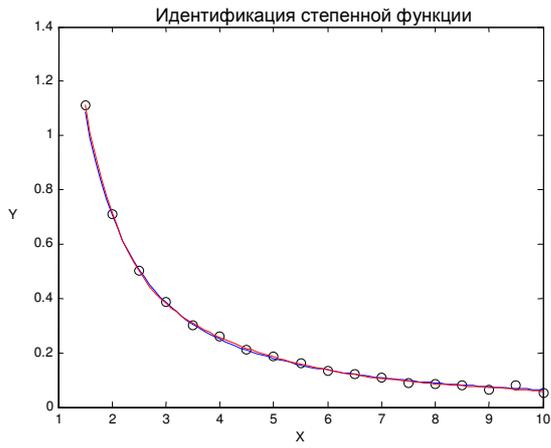


Рис. 3 – Результаты моделирования

Выводы

Результаты сравнительного анализа показывают, что трехслойный персептрон успешно решает задачу идентификации нелинейной функции преобразования, а точность аппроксимации для различных видов функций у него выше, чем у полиномиальных моделей. В целом результаты имитационного моделирования подтверждают работоспособность предложенной нейросетевой модели и согласуются с теоретическими выкладками.

Преимуществом предлагаемого подхода является инвариантность нейросетевой модели к виду нелинейной функции преобразования измерительного устройства и возможность синтезировать такую систему через обучение, не привлекая сложных методов проектирования. Указанные факторы значительно расширяют возможности применения таких моделей в метрологической практике.

Список литературы

1. Wasserman, P. D. Neural Computing: Theory and Practice [Text] / P. D. Wasserman. – N.Y. : Van Nostrand Reinhold, 1989. – 230 p.
2. Бодянский, Е. В. Искусственные нейронные сети: архитектуры, обучение, применения [Текст] / Е. В. Бодянский, О. Г. Руденко. – Харьков : ТЕЛЕТЕХ, 2004. – 369 с.
3. Хайкин, С. Нейронные сети: полный курс [Текст] : 2-е изд., испр., пер. с англ. – М. : ООО «ИД Вильямс», 2006. – 1104 с.
4. Khrobostov, D.A. Sensor Calibration with Artificial Neural Network [Text] / D. A. Khrobostov, G. F. Filaretov // 45th International Scientific Colloquium. – Imenau, 2000. – Additional Issue. – P. 2–7.
5. Водотыка, С. В. Использование искусственных нейронных сетей при построении калибровочной зависимости средства измерения [Текст] / С. В. Водотыка // Системи обробки інформації. – 2011. – Вип. 1 (91). – С. 24-28.
6. Киселев, С. К. Использование искусственных нейронных сетей для автоматизации поверки измерительных приборов [Текст] / С. К. Киселев // Промышленные АСУ и контроллеры. – 2004. – № 1. – С. 52–55.
7. Драгина, О. Г. Повышение точности и разрешающей способности растровых измерительных систем на принципах нейросетевой обработки

информации [Текст] : дис. ... канд. техн. наук / О. Г. Драгина. – М., 2004. – 210 с.

8. Голыгин, Н. Х. Возможности повышения точности геодезических измерений на основе искусственных нейросетей [Текст] / Н. Х. Голыгин, О. Б. Хиноева, Х. К. Ямбаев // Изв. ВУЗов. Геодезия и аэрофотосъемка. – 2005. – № 5. – С. 17–27.

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

10. Захаров, И. П. Обработка результатов измерений [Текст] : учеб. пособие / И. П. Захаров. – Харьков: Изд-во НУВД, 2001. – 126 с.