

УДК 004.93

*В.В. Кочан*

Научно-исследовательский институт интеллектуальных компьютерных систем  
Тернопольский национальный экономический университет, г. Тернополь, Украина  
oko@tneu.edu.ua

# Нейросетевые методы распознавания выходного сигнала многопараметрических сенсоров

В статье рассмотрено применение искусственных нейронных сетей для повышения точности распознавания сигнала многопараметрических сенсоров, погрешности которых описаны набором матмоделей, исчерпывающим все комбинации отклонений характеристик преобразования. Путем имитационного моделирования исследована погрешность распознавания выходного сигнала одномодульной и многомодульной нейронной сетью.

## Введение

В последнее время приобретают распространение многопараметрические сенсоры (МС) [1], чей сигнал преднамеренно зависит от многих физических величин (ФВ), которые влияют на все параметры сигнала МС. Возникает задача идентификации значений отдельных ФВ. Ее смысл сводится к задаче распознавания образов [2]. Анализ [3] показал, что нейронные сети (НС) дают наилучшие результаты, но известные решения распознают данные, полученные от массива сенсоров. **Цель статьи** – исследование распознавания сигналов одного МС, работающего в разных режимах, многослойным персептроном [4] с алгоритмом обучения обратного распространения ошибки.

## 1. Математические модели сигнала МПС

Распознавание сигналов МС исследуем на примере МС TGS-813 [5] для повышения точности распознавания концентраций оксида углерода (СО) и метана (СН<sub>4</sub>) в шахтных вентиляционных сетях. Характеристика преобразования (ХП) МС существенно нелинейна по концентрациям обоих газов [6]. Режим работы МС изменялся путем изменения напряжения источника питания. Из-за отсутствия нормирования ХП МС TGS-813 и ее значительного разброса возникает необходимость использования индивидуальных ХП. Однако прямые исследования нейросетевых методов распознавания практически невозможны из-за отсутствия представительных выборок индивидуальных ХП. Поэтому выбран следующий путь решения задачи:

1) аппроксимация ХП, полученной по данным [6] простой моделью, не создающей сложностей при распознавании;

2) построение моделей всех возможных отклонений индивидуальных ХП от номинальных для обоих режимов работы сенсоров;

3) исследование нейросетевых методов распознавания для всех возможных отклонений индивидуальных ХП от номинальных. Все возможные комбинации отклонений моделируются комбинациями знаков первой и второй производных функции зависимости выходного сигнала БПС от обеих ФВ (табл. 1).

Таблица 1 – Распределение знаков производных моделей отклонения ХП МС

Физические величины	Режимы работы	Модель (i)		Модель (ii)		Модель (iii)		Модель (iv)	
		1 пр.	2 пр.	1 пр.	2 пр.	1 пр.	2 пр.	1 пр.	2 пр.
Первая ФВ	1 реж.	+	+	+	–	+	–	+	+
	2 реж.	+	+	+	–	–	–	+	–
Вторая ФВ	1 реж.	–	+	–	–	–	–	–	+
	2 реж.	–	+	–	–	–	–	–	–

Численный анализ показал, что такие отклонения ХП МС удобно имитировать произведением двух полиномов разного порядка с разными коэффициентами

$$Y = (A \times (X_1 + B)^k + C \times (X_1 + B)) \times (D \times (X_2 + E)^l + F \times (X_2 + E)) \times G, \quad (1)$$

где  $X_1$  и  $X_2$  – концентрации СО и СН<sub>4</sub>;  $B, E$  – начальное сопротивление МС.

Все варианты отклонений реализуются изменением значений и полярности переменных  $A, B, C, D, E, F, G, k$  и  $l$  в соответствии с табл. 1.

## 2. Распознавание выходного сигнала МС

Метод распознавания выходного сигнала МС одномодульной НС использует модели разд. 1 для обучения НС – на их вход поступают результаты измерений, соответствующие аппликатам поверхностей, образующих ХП МС в разных режимах работы, а выходными данными НС являются значения ФВ, согласно осям абсцисс и ординат. Для обучения НС использован 81 обучающий вектор вида  $X_1; X_2; Y_1; Y_2$ , где  $\{X_1; Y_1\}$  – значения, которые описывают преобразование МС в первом режиме работы,  $\{X_2; Y_2\}$  – значения, которые описывают преобразование МС во втором режиме. Для тестирования обученной НС была создана выборка в 576 векторов таким образом, чтобы значения с входной выборки не попали в выборку тестирования. Результаты распознавания одномодульной НС показали среднее относительное отклонение распознавания около 1 % на моделях (i), (ii), (iii) и около 5 % на модели вида (iv). Погрешность 5 % не удовлетворяет требования безопасности шахтных вентиляционных сетей, поэтому исследования были продолжены.

Известным приемом повышения точности измерений является разбиение диапазона входных сигналов на поддиапазоны. В теории НС использование отдельной НС для каждого поддиапазона называется модульными НС [7]. Естественными критериями разбиения являются минимум погрешности распознавания во всем диапазоне. Однако для МС характерно ограничение объема обучающей выборки. Поэтому обучающая выборка была разбита на одинаковые подвыборки из-за того, что НС плохо обучаются на выборках малого объема [4], а оптимизация разбиения в соответствии с критерием минимума погрешности ведет к итерационному сужению границ поддиапазона с максимальной погрешностью, что приводит к повышению результирующей погрешности распознавания из-за плохого обучения НС, то есть появляется паразитная положительная обратная связь. Принудительное равномерное разбиение обучающей выборки лишено этого недостатка.

В соответствии с изложенным для исследования метода распознавания выходного сигнала МС с помощью модульных НС (рис. 3), выборка обучения (81 вектор) разделена на три части по 27 обучающих векторов. Выборка тестирования (576 векторов) также разделена на три части по 192 вектора. Каждый модуль НС функционировал отдельно, распознавая выходной сигнал МС в своем диапазоне. После распознавания во всех поддиапазонах анализировалось суммарное относительное отклонение распознавания.

### 3. Результаты моделирования

Для имитационного моделирования использована среда MATLAB 6.5. Каждый модуль одномодульной и трехмодульной НС состоял из двух нейронов входного и двух нейронов выходного слоя. Исследования показали, что максимальную точность для одномодульной НС обеспечивает 10 нейронов скрытого слоя с сигмоидной функцией активации. На рис. 1, 2 показаны усредненные по всем моделям (в соответствии с табл. 1) зависимости максимального и среднего относительного отклонения распознавания обоих ФВ для суммарной среднеквадратической ошибки обучения НС  $10^{-2}$ ,  $10^{-3}$ ,  $10^{-4}$  и  $10^{-5}$ .

Как видно из рис. 1, 2, трехмодульная НС снизила максимальное отклонение в 5 – 10 раз, а среднее – в 3 – 4 раза по сравнению с одномодульной НС. Кроме того, метод многомодульных НС позволяет снизить вычислительную сложность обучения.




Рисунок 1 – Результаты распознавания двух физических величин одномодульной НС

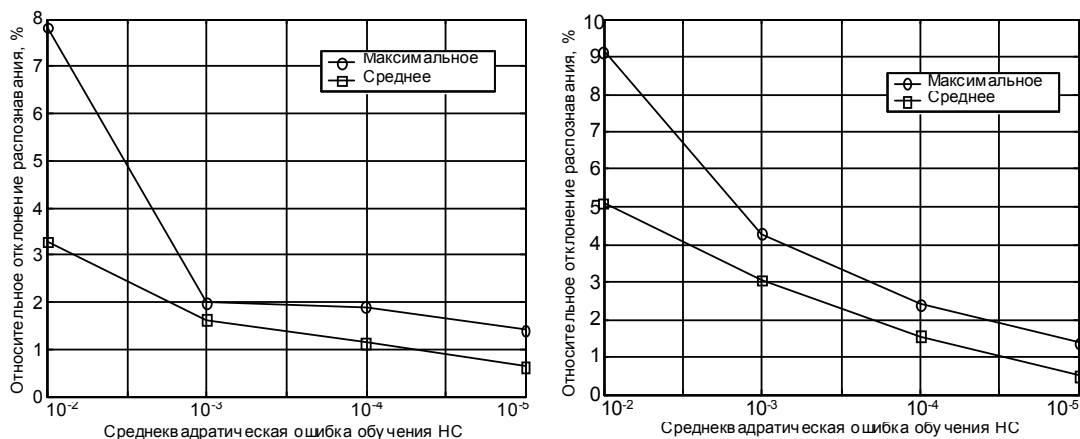


Рисунок 2 – Результаты распознавания двух физических величин трехмодульной НС

Вычислительная сложность алгоритма может быть определена [8] эквивалентным количеством операций типа сложение / умножение. Так как архитектуры НС в обоих методах одинаковы, количество операций при обучении НС обоих методов будет равным, то есть количество итераций будет однозначно характеризовать их вычислительную сложность. Исследования показали, что в среднем вычислительная сложность снижается в три раза, что дает возможность обучения НС на задачи микроконтроллере. Недостаток модульных НС – увеличение памяти констант пропорционально количеству модулей, а возрастание вычислительной сложности из-за выбора диапазона пренебрежимо мало.

В связи с уменьшением выборки обучения модульных МС исследовано оптимальное количество нейронов скрытого слоя таких НС для обеспечения максимальной точности распознавания. Результаты исследований показали, что лучшие результаты обеспечивает меньшее число нейронов скрытого слоя (9 нейронов одномодульных НС для математических моделей (i), (ii) и 5 нейронов трехмодульных НС для моделей (iii), (iv)), то есть метод модульных НС на этапе распознавания обеспечивает 10 %-е уменьшение вычислительной сложности для моделей (i – ii) и 50 %-е уменьшение для моделей (iii – iv).

При воздействии помех возможно неверное определение поддиапазона вблизи его границ. Как показали исследования (рис. 6), максимальное и среднее значения возникающей при этом дополнительной погрешности малы, и достаточно обеспечить помехозащищенность, необходимую с точки зрения допустимой погрешности измерения.




Рисунок 3 – Зависимости максимальной (а) и средней (б) относительной погрешности распознавания от перекрытия поддиапазонов

## Выводы

Исходя из результатов исследований, можно сделать вывод о перспективности применения для распознавания сигналов МС многомодульных нейронных сетей. Они дают значительное снижение вычислительной сложности при одновременном повышении точности даже в наиболее сложных случаях. Это важно для распределенных систем на базе микроконтроллеров с ограниченной вычислительной мощностью, например, для микроконтроллеров 89С52 среднее время обучения составляет 73 секунды. Применение описанного метода ФВ возможно для распознавания концентраций вредных газов СО и СН<sub>4</sub> в аэрогазовой среде угольных шахт с целью предотвращения аварийных ситуаций.

## Литература

1. Capone S., Siciliano P., Bârsan N., Weimar U., Vasanelli L. Analysis of CO and CH<sub>4</sub> gas mixtures by using a micromachined sensor array // Sensors and Actuators B: Chemical. – 2001. – Vol. 78, № 1-3. – P. 40-48.
2. Derde M.P., Massart D.L. Supervised pattern recognition: the ideal method? // Analytica Chimica Acta. – 1986. – Vol. 191. – P. 1-16.
3. Michie D., Spiegelhalter D.J., Taylor C.C. Machine Learning, Neural and Statistical Classification. – New York: Ellis Horwood, 1994.

4. Хайкин С. Нейронные сети: полный курс: Пер. с. англ. / Под. ред. Куссуль Н.Н. – 2-е изд. – М.: Издательский дом «Вильямс», 2006. – 1104 с.
5. Режим доступа: <http://www.figarosensor.com/products/813pdf.pdf>
6. Zakrzewski J., Domanski W., Chaitas P. and Laopoulos Th. Improving Sensitivity and Selectivity of SnO<sub>2</sub> Gas Sensors by Temperature Variation // IEEE International Workshop on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications. – Lviv (Ukraine). – 2003. – P. 296-299.
7. Галинская А.А. Модульные нейронные сети: обзор современного состояния разработок // Математические машины и системы. – 2003. – № 3-4. – С. 87-102.
8. Мельник А.А. Специализированные компьютерные системы реального времени. – Львов: Издательство НУ «Львовская политехника», 1998. – 60 с.

***V.V. Kochan***

**Нейромережні методи розпізнавання вихідного сигналу багатопараметричних сенсорів**

У статті розглянуто використання штучних нейронних мереж для підвищення точності розпізнавання сигналу багатопараметричних сенсорів, похибки яких описані набором математичних моделей, що вичерпують всі можливі комбінації відхилень характеристик перетворення. Шляхом імітаційного моделювання досліджена похибка розпізнавання вихідного сигналу одномодульною та багатомодульною нейронною мережею.

***V.V. Kochan***

The application of artificial neural networks is described for improvement of recognition accuracy of multi-sensor signal. The errors of multi-sensor signal are modeled by the set of mathematical models which cover all possible combinations of conversion characteristic deviations. The recognition of output signal by single and modular neural network is researched by simulation modeling.

*Статья поступила в редакцию 18.11.2008.*