

Оригинальная статья / Original article

<https://doi.org/10.21869/2223-1560-2020-24-1-159-174>



Применение нейронных сетей в задаче количественного анализа состава воздушной среды

О.Г. Бондарь¹, Е.О. Брежнева¹✉, Р.Е. Чернышов¹

¹ ФГБОУ ВО «Юго-Западный государственный университет»
ул. 50 лет Октября 94, г. Курск 305040, Российская Федерация

✉ e-mail: bregnevaeo@mail.ru

Резюме

Цель исследования: разработка методики генерации обучающих данных с целью обеспечения возможности использования метода искусственных нейронных сетей (ИНС) в газоаналитических системах. Рассматривается проблема повышения точности раздельного определения концентраций газов в многокомпонентных смесях в условиях колебания параметров окружающей среды. Повысить точность определения концентраций целевых газов предлагается за счет применения метода ИНС для совместной обработки сигналов датчиков.

Методы. Генерация обучающих данных для нейронной сети осуществлялась с помощью численного эксперимента и методов математического моделирования. Для оценки точности обучения было использовано среднеквадратическое отклонение (СКО) и рассчитывалась относительная погрешность. Обучение и исследование ИНС проводилось в среде MATLAB (приложение Neural Networks Toolbox). При разработке математических моделей датчиков газа опирались на теорию электрических цепей, электронную теорию хемосорбции и адсорбционную теорию гетерогенного катализа.

Результаты. Описана методика генерации обучающих наборов данных с использованием математических моделей газочувствительных датчиков. Предложенная методика обучения апробирована на конкретной задаче, в частности, разработано решающее устройство на основе ИНС для четырёхкомпонентного газоанализатора. Проведена оценка эффективности применения нейронных сетей для отстройки от взаимной перекрестной чувствительности датчиков.

Заключение. Предложена методика генерации обучающих данных с помощью имитационных моделей, позволяющая автоматизировать процесс обучения, исследования, выбора архитектуры и структуры ИНС и их тестирования. Проведена апробация метода. На основании анализа полученных погрешностей, сформулированы выводы об эффективности применения нейронных сетей для уменьшения погрешностей, вызванных перекрестной чувствительностью, при различных соотношениях концентраций основного и мешающего газов.

Ключевые слова: газочувствительные датчики; искусственные нейронные сети; обучение сети; имитационные модели; обработка информации; концентрация газа; погрешности измерения.

Конфликт интересов: Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Бондарь О.Г., Брежнева Е.О., Чернышов Р.Е. Применение нейронных сетей в задаче количественного анализа состава воздушной среды // Известия Юго-Западного государственного университета. 2020; 24(1): 159-174. <https://doi.org/10.21869/2223-1560-2019-24-1-159-174>.

Поступила в редакцию 14.12.2019

Подписана в печать 20.01.2020

Опубликована 21.02.2020

© Бондарь О.Г., Брежнева Е.О., Чернышов Р.Е., 2020

Application of Neural Networks in the Problem of Quantitative Analysis of Air Composition

Oleg G. Bondar¹, Ekaterina O. Brezhnev¹ ✉, Rostislav E. Chernyshov¹

¹ Southwest State University
50 Let Oktyabrya str. 94, Kursk 305040, Russian Federation

✉ e-mail: bregnevaeo@mail.ru

Abstract

Purpose of research is to develop a method for generating training data to enable the use of artificial neural networks (ANN) method in gas analyzer systems. The problem of increasing the accuracy of separate determination of gas concentrations in multicomponent mixtures under conditions of environmental parameters changes is considered. It is proposed to increase the accuracy of determining target gas concentrations by using the ANN method for joint processing of sensor signals.

Methods: Training data for the neural network were generated using numerical experiments and mathematical simulation methods. To assess the accuracy of training, the standard deviation (SD) was used and the relative error was calculated. ANN training and research were conducted in the MATLAB environment (the Neural Networks Toolbox application). When developing mathematical models of gas sensors, the theory of electrical circuits, electronic theory of chemisorption and the adsorption theory of heterogeneous catalysis were applied.

Results: A method for generating training data sets using mathematical models of gas sensors is described. The proposed training method has been tested on a specific task, in particular, a decision-making device based on ANN for a four-component gas analyzer has been developed. The efficiency of using neural networks for tuning out from the mutual cross-sensitivity of sensors was evaluated.

Conclusion: A method for generating training data using simulation models is proposed, which allows automating the process of training, research, choosing the architecture and structure of ANN and their testing. The method was tested. Based on the analysis of the obtained errors, conclusions are made about the efficiency of using neural networks to reduce errors caused by cross sensitivity at different concentrations of the main and interfering gases.

Keywords: gas sensors; artificial neural networks; network learning; simulation models; information processing; gas concentration; measurement errors.

Conflict of interest. The authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

Funding: The research was carried out with the support of RFBR grant 19-08-00440.

For citation: Bondar O. G., Brezhnev E. O., Chernyshov R.E. Application of Neural Networks in the Problem of Quantitative Analysis of Air Composition // *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University*. 2020, 24(1): 159-174 (In Russ.). <https://doi.org/10.21869/2223-1560-2020-24-1-159-174>.

Received 14.12.2019

Accepted 20.01.2020

Published 21.02.2020

Введение

В автономных газоанализаторах и сложных газоаналитических системах

широко применяются полупроводниковые и термokatалитические датчики,

обладающие высокой стабильностью характеристик. Датчики таких типов реагируют не только на основной газ, но и обладают различной степенью чувствительности к целому ряду других мешающих газов, к колебаниям относительной влажности воздуха, давления и температуры, что приводит к дополнительным погрешностям измерений. Сигнал каждого газочувствительного датчика представляет собой реакцию на совокупность сразу нескольких внешних воздействий, поэтому перспективным направлением является применение совместной обработки информации, поступающей с каждого датчика газоаналитической системы. Для решения задач количественного и качественного анализа состава сложных газовых смесей высокую эффективность показывает метод ИНС [1-6].

Применение нейронной сети в газоанализаторах требует значительного объема обучающих и тестирующих данных, необходимых для проведения исследований, направленных на поиск оптимальной структуры сети, ее обучения, контроля эффекта «переобучения» и тестирования. Получение обучающих данных экспериментальным путем делает применение метода нецелесообразным в связи с высокой стоимостью и трудоемкостью работ.

Снять это ограничение может позволить разработка методики обучения ИНС, базирующейся на основе имитационного моделирования. Для реализа-

ции данного подхода необходимо иметь многопараметрические математические модели датчиков, учитывающие основные факторы, влияющие на их выходной сигнал.

Материалы и методы

Математически исходную задачу можно описать в виде системы, состоящей из n уравнений (n – число датчиков, входящих в состав системы), параметрами которой являются концентрации газов (C), относительная влажность воздуха (RH), температура воздуха (T), атмосферное давление (P) [7]:

$$\begin{cases} S_1 = f_1(C_1, C_2, \dots, C_j, \dots, C_k, T, P, RH) \\ \vdots \\ S_j = f_j(C_1, C_2, \dots, C_j, \dots, C_k, T, P, RH) \\ \vdots \\ S_k = f_k(C_1, C_2, \dots, C_j, \dots, C_k, T, P, RH) . \end{cases}$$

Решение задачи сводится к нахождению функций обратного преобразования:

$$\begin{cases} C_1 = F_1(S_1, S_2, \dots, S_i, \dots, S_k, T, P, RH) \\ \vdots \\ C_j = F_j(S_1, S_2, \dots, S_i, \dots, S_k, T, P, RH) \\ \vdots \\ C_k = F_k(S_1, S_2, \dots, S_i, \dots, S_k, T, P, RH) . \end{cases}$$

Применение метода ИНС позволит получить решение в аналитическом виде.

Обученная сеть должна преобразовывать сигналы s_i , поступающие на ее вход с основных и вспомогательных датчиков, в искомые концентрации газов c_i :

$$(s_1, s_2, \dots, s_{k+3})^T \rightarrow (c_1, c_2, \dots, c_k)^T .$$

К основным датчикам относятся газочувствительные датчики, к вспомогательным – датчики температуры, влажности, давления.

Исходные сигналы нормируются в заданном диапазоне (0-1), границы диапазона должны удовлетворять свойствам выбранной функции активации нейронов.

Выбор архитектуры и разработка структуры сети осуществляется эмпирически и требует большого количества обучающих и тестирующих данных, представляющих собой различные комбинации входных параметров и соответствующие им сигналы датчиков. Комбинации входных параметров (концентрации газов, параметры окружающей среды) должны быть сгенерированы случайным образом, чтобы максимально близко имитировать реальные условия работы газоанализатора. Получение таких выборок экспериментальным путем делает применение нейронных сетей в газоаналитических приборах невозможным, в связи с высокой стоимостью и трудоёмкостью работ. В данной работе генерацию обучающих данных предлагается осуществлять, используя методы имитационного моделирования.

Суть метода заключается в том, что в качестве уравнений системы используются математические модели датчиков, обладающие интерполяционными и экстраполяционными свойствами и

$$\frac{R_s}{R_0} = \frac{1}{(A_1 + A_2(C_{H_2O} \frac{P}{P_o})^{n_1} + A_3(C_{H_2O} \frac{P}{P_o})^{n_1} (C_{CO} \frac{P}{P_o})^{n_2} + A_4(C_{CO} \frac{P}{P_o})^{n_2} + \dots + A_6(C_{H_2O} \frac{P}{P_o})^{n_1} (C_{H_2} \frac{P}{P_o})^{n_3} + A_7(C_{H_2} \frac{P}{P_o})^{n_4}) \times e^{A_8(\frac{1}{T} - \frac{1}{T_0})} + A_5}, \quad (1)$$

где R_s – измеренное сопротивление датчика;

C_{CO} – концентрации монооксида углерода (об. %);

учитывающие максимальное число факторов, влияющих на выходной сигнал. Для обеспечения выше перечисленных свойств математические модели разрабатывались с учетом принципа работы датчиков, опираясь на протекающие в них физические и химические процессы. Математические модели модернизировались и разрабатывались для основных типов датчиков, выпускаемых промышленностью: полупроводниковых, термokatалитических, оптических и электрохимических [8]. Для оптических датчиков использовалась модернизированная модель, в которой были учтены влияния температуры и давления окружающего воздуха, для электрохимических датчиков использовалась уже существующая модель. Нахождение неизвестных параметров математических моделей реализовано в среде *MALAB* с помощью встроенной функции *lsqcurvefit* на основании параметров и характеристик, представленных производителем в технической документации конкретных датчиков.

Ниже представлена разработанная ранее математическая модель полупроводникового датчика монооксида углерода [8]:

C_{H_2O} – концентрация водяных паров (об. %);

C_{H_2} – концентрация водорода (об. %);

$A_1 - A_5, n_i$ – константы, определяемые при параметризации;

T_0, P_0 – температура и атмосферное давление, при которых осуществлялась калибровка датчика;

P – атмосферное давление (кПа)

T – температура (К).

Для нахождения неизвестных параметров модели использовалась техническая документация на полупроводниковый датчик монооксида углерода

TGS2442 (производитель *Figaro*). При нахождении коэффициентов у концентраций газов параметры окружающей среды соответствовали нормальным условиям ($P=101.3$ кПа, $T=293,15$ К, $RH=50\%$), По результатам нахождения неизвестных параметров математической модели (1) получены следующие значения максимальных относительных погрешностей (σ_{max}) (табл.1).

Таблица 1. Погрешности параметризации математической модели датчика CO

Table 1. Parameterization errors of the mathematical model of the CO sensor

Варьируемый фактор и диапазон изменения	Дополнительные условия параметризации	σ_{max}
C_{CO} (0,003 – 0,1 об. %)	В отсутствии водорода	5,00 %
C_{H_2} (0,003 – 0,1 об. %)	В отсутствии монооксида углерода	0,91 %
T (283,15 K - 313,15 K)	$C_{CO}=0,01$ об. %, в отсутствии водорода	6,02 %

Проведена оценка устойчивости разработанной математической модели на тестирующих данных, которые не были задействованы при параметризации (при нормальных условиях). В табл. 2 сопоставлены результаты параметризации ($\sigma_{пар}$) и тестирования ($\sigma_{тест}$) разработан-

ной математической модели полупроводникового датчика.

Используя выражения (1), исследовались экстраполяционные свойства модели относительно влияния факторов окружающей среды (относительной влажности и температуры воздуха) при различных концентрациях целевого газа.

Таблица 2. Результаты оценки устойчивости математической модели

Table 2. The results of evaluating the stability of the mathematical model

Варьируемый фактор и диапазон изменения	Дополнительные условия параметризации	$\sigma_{пар}$	$\sigma_{тест}$
C_{CO} (0,003 – 0,1 об. %)	В отсутствии водорода	0,24	0,22
C_{H_2} (0,003 – 0,1 об. %)	В отсутствии угарного газа	0,67	0,62
RH (10 - 90%)	В чистом воздухе	0,43	0,42
T (268,15 K – 323 K)	$C_{CO}=0,01$ об. %, в отсутствии водорода	3,95	3,71

На рис. 1 представлены многопараметрические графики, демонстрирующие изменение выходного сигнала датчика при варьировании влажности воздуха и различных значениях концентраций целевого газа (температура и давление соответствуют нормальным условиям, мешающий газ отсутствует), полученные с помощью разработанной математической модели и предоставленные производителем.

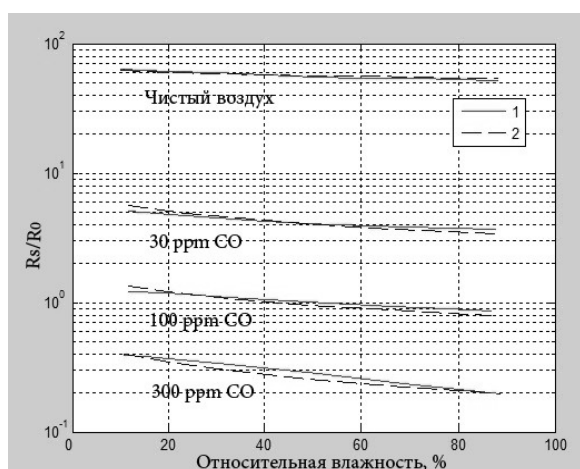


Рис. 1. Результаты моделирования влияния влажности в чистом воздухе и в присутствии CO: 1 – данные производителя; 2 – результат моделирования

Fig. 1. The results of modeling the effect of humidity in clean air and in the presence of CO: 1 – manufacturer's data; 2 – simulation result

На рис. 2 представлены графики, отражающие зависимость сопротивления датчика от колебаний температуры окружающей среды при различных концентрациях монооксида углерода (давление и относительная влажность воздуха соответствуют нормальным условиям, мешающий газ отсутствует), представ-

ленные производителем и полученные с помощью математической модели (1).




Рис.2. Результаты моделирования влияния температуры в присутствии CO: 1 – данные производителя; 2 – результат моделирования

Fig. 2. The results of modeling the effect of temperature in the presence of CO: 1 – manufacturer data; 2 – simulation result

В табл. 3 представлены значения полученных погрешностей, характеризующие расхождения реальных данных и результатов моделирования влияния факторов окружающей среды (относительной влажности и температуры воздуха).

Максимальная погрешность (при 0,03 об. % CO) соответствует температурам свыше 318,15 K, в диапазоне температур от 268,15 K до 318,15 K ее значение менее 5,95%.

Анализ значений погрешностей, полученных при тестировании и исследовании экстраполяционных свойств математической модели, а именно, зависимости сопротивления датчика от концентрации целевого газа при нормальных условиях, при изменении относительной влажности воздуха и температуры в ра-

бочем диапазоне при различных концентрациях монооксида углерода, позволяет судить об адекватности разработанной математической модели.

Аналогичным образом была разработана и исследована математическая модель для термokatалитических датчиков [9-11]. Параметризация модели и

оценка погрешностей моделирования осуществлялась по данным производителя *Nemoto* для датчика водорода *NP-AHS*. Точность аппроксимации математической модели термokatалитического датчика по концентрации водорода составила 0,37%, по тестирующей выборке – 0,41%.

Таблица 3. Погрешности моделирования полупроводникового датчика

Table 3. Errors in modeling a semiconductor sensor

C_{CO} , об. %	RH , (10-90%)		T , (268,15 K – 323 K)	
	σ , %	СКО, %	σ , %	СКО, %
Чистый воздух	0,59	0,42	–	–
0,003	16,01	5,51	29,02	8,21
0,01	16,05	5,31	29,01	3,71
0,03	8,02	4,72	10,02	3,18

Модернизированная модель оптического датчика была параметризована по данным производителя *Dynament* для датчика диоксида углерода *MSH-P-CO2/NC/TC*. Значение максимальной относительной погрешности по целевому газу (CO_2) не превысило 3,61 %.

Параметризация существующей линейной модели электрохимического датчика кислорода *I-01* проводилась по данным производителя *International Technology*.

Выбор перечня детектируемых газов (CO , H_2 , CO_2 , O_2) для апробации предложенной методики был сделан на основании анализа проблемы контроля параметров воздушных сред опасных производственных объектов [12-15]. Типы и модели датчиков конкретных производителей выбирались исходя из их ха-

рактеристик и применяемых к ним требований надежности, быстродействия, срока службы, стоимости и т.д. [16].

Результаты и их обсуждение

Библиотека среды *MatLAB* предлагает пользователю большой выбор нейронных сетей различных архитектур. В результате проведенных исследований и анализа работ, посвященных проблеме аппроксимации функции с помощью ИНС, была выбрана многослойная нейронная сеть прямого распространения (многослойный персептрон), показавшая наилучший результат в сравнении с сетями других архитектур (радиально-базисной, сеть Элмана, обобщенно-регрессионная нейронная сеть) [4,17-19].

Исследования различных структур многослойного персептрона проводи-

лись на обучающей и контрольной выборках, для исключения эффекта «переобучения» [20]. Для предотвращения эффекта переобучения объем обучающей выборки должен многократно превышать число определяемых коэффициентов модели. Применение разработанной методики генерации обучающих данных позволяет создавать выборки требуемого объема. Заметить эффект переобучения и своевременно остановить процесс позволяет оценка величины расхождения погрешностей по контрольной и обучающей выборкам.

На вход многослойного персептрона подавались нормированные сигналы (y) с n датчиков, входящих в состав системы:

$$\begin{bmatrix} y_{1CO} & y_{1H_2} & \dots & y_{1n} \\ y_{2CO} & y_{2H_2} & \dots & y_{2n} \\ \dots & \dots & \dots & \dots \\ y_{mCO} & y_{mH_2} & \dots & y_{mn} \end{bmatrix},$$

где m – количество отсчетов по каждому контролируемому параметру. Объем обучающей выборки оценивался в соответствии с рекомендациями в [17]. Значения подаваемых на вход сигналов датчиков получали подстановкой различных сочетаний входных параметров (концентраций газов, значений давления, температуры, влажности), сгенерированных случайным образом, в математические модели датчиков. Рассчитанные по моделям значения сигналов нормировались в диапазоне 0-1. На выходе многослойного персептрона выдаются искомые концентрации газов:

$$\begin{bmatrix} c_{1CO} & c_{1H_2} & \dots & c_{1n} \\ c_{2CO} & c_{2H_2} & \dots & c_{2n} \\ \dots & \dots & \dots & \dots \\ c_{mCO} & c_{mH_2} & \dots & c_{mn} \end{bmatrix}.$$

Исходные значения концентраций газов и параметров воздушной среды задавались в соответствии с рабочими диапазонами датчиков.

Исследовались различные структуры многослойного персептрона: общая для всех типов датчиков, специализированная по каждому газу и комбинированная.

Общая ИНС преобразует сигналы трёх основных газовых датчиков (полупроводникового, термокаталитического и оптического типов) и трех дополнительных датчиков (температуры, давления и влажности) в отдельные значения концентраций трех газов (CO , CO_2 , H_2). В данном блоке обеспечивается подавление взаимной перекрёстной чувствительности датчиков CO и H_2 и влияния температуры, давления и влажности.

Специализированные сети представляют собой отдельные каналы по каждому из определяемых газов. Структура специализированной сети для определения монооксида углерода содержит пять входных нейронов (по числу основных и дополнительных датчиков) и один нейрон в выходном слое (по числу определяемых газов, CO), число нейронов в скрытом слое получено экспериментальным путем и равняется пяти. Аналогичную структуру имеет специа-

лизирующая нейронная сеть для определения концентрации водорода. Специализированная сеть для диоксида углерода, вследствие высокой селективности оптического датчика, имеет упрощённую двухслойную конфигурацию, с тремя нейронами во входном и одним нейроном в выходном слое.

Комбинированная структура: сети для определения концентраций монооксида углерода и водорода были объединены в единый блок, концентрация диоксида углерода определялась ранее разработанной специализированной сетью. В табл. 4 представлены результаты поиска оптимальной структуры многослойного персептрона.

Таблица 4. Результаты исследования различных структур сети

Table 4. The results of the research on various network structures

Структура сети	Число коэффициентов	СКО, %		
		CO	H_2	CO_2
Общая ИНС	155	0,51	0,27	0,13
Специализированные ИНС	148	0,55	0,07	0,16
Комбинированная структура	128	0,57	0,13	0,15

Анализ полученных результатов показывает, что минимальное число весовых коэффициентов при сопоставимых значениях среднеквадратических отклонений позволяет обеспечить комбинированная структура сети. Такое решение принято в качестве оптимального. Комбинированная структура ИНС представлена на рис. 3.

Сеть состоит из трёх независимых блоков. В первом блоке (112 коэффициентов) на вход нейронной сети подаются сигналы, поступающие с пяти датчиков (5 нейронов во входном слое), а на выходе сети – концентрации двух газов (CO и H_2), в выходном слое два нейрона, в промежуточном 10. Структура второго блока по каналу диоксида углерода аналогична соответствующей специализированной сети. Количество ней-

ронов в скрытом слое подбиралось эмпирически, критерием выбора являлся компромисс между сложностью структуры сети и значениями, получаемых погрешностей.

Ниже представлена методика оценки эффективности применения метода нейронных сетей для повышения точности измерений концентраций газов за счет подавления влияющих факторов (перекрестная чувствительность, температура, влажность, давление). Тестируемые выборки генерировались с помощью математических моделей. Описание методики исследования представлено ниже:

– для конкретного значения концентрации целевого газа изменялось значение влияющего фактора в пределах допустимых границ;

– в математическую модель подставлялись соответствующие значения концентрации газа и воздействующего фактора, и рассчитывался сигнал датчика;

– полученное в п.2 значение сигнала датчика и заданное значение воздействующего фактора подавались на нейронную сеть, которая выдавала соответствующую концентрацию газа;

– вычислялась ошибка нейронной сети, для чего рассчитывалась погрешность расхождения, заданного и полу-

ченного нейронной сетью значений концентраций газа;

– определялась концентрация газа, соответствующая значению сигнала датчика, полученному в п.2 по реальным характеристикам датчика, представленным производителем;

– сравнивались относительные погрешности вычисления концентрации целевого газа с помощью метода ИНС и без него (по пунктам 3 и 5).

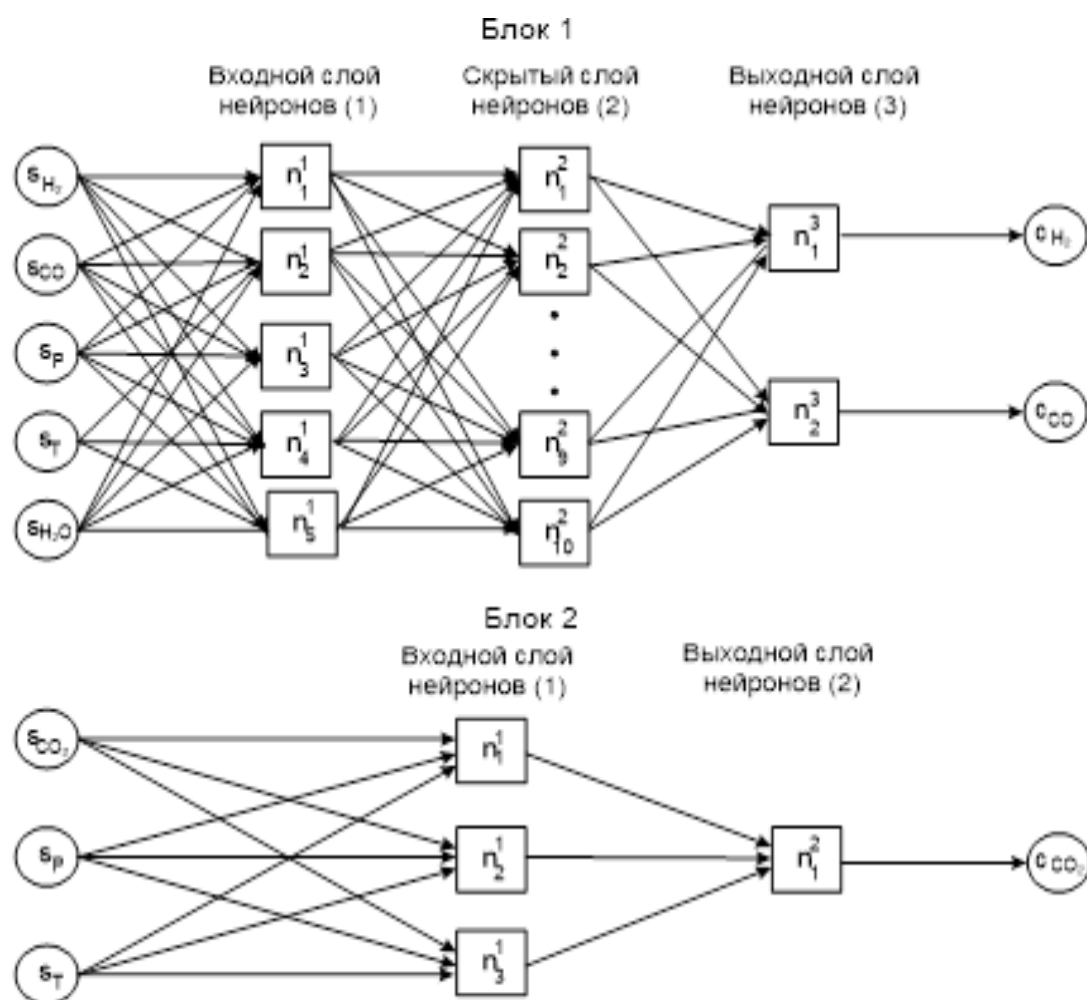


Рис.3. Комбинированная структура сети: S_{CO} , S_{H_2} , S_{CO_2} , S_{H_2O} , S_T , S_P – сигналы датчиков (CO , H_2 , CO_2 , T , P , RH); C_{CO} , C_{H_2} , C_{CO_2} – концентрации соответствующих газов

Fig. 3. Combined network structure: S_{CO} , S_{H_2} , S_{CO_2} , S_{H_2O} , S_T , S_P – sensor signals (CO , H_2 , CO_2 , T , P , RH) C_{CO} , C_{H_2} , C_{CO_2} – concentrations of the corresponding gases

На рисунке 4-5 в качестве примера представлены диаграммы, позволяющие сопоставить относительные погрешно-

сти, вызванные чувствительностью датчиков к мешающему газу, до и после применения нейронной сети.




Рис. 4. Диаграммы относительных погрешностей измерения концентрации монооксида углерода в присутствии водорода, до и после применения метода ИНС: **а** – $C_{H_2} = 0,2\%$; **б** – $C_{H_2} = 2\%$ (погрешности ИНС обозначены черным цветом, погрешности без применения метода - серым цветом)

Fig. 4. Charts of relative errors in measuring the concentration of carbon monoxide in the presence of hydrogen, before and after the application of the ANN method: **a** – $C_{H_2} = 0,2\%$; **б** – $C_{H_2} = 2\%$ (errors of the ANN are indicated in black, errors without using the method are indicated in gray)




Рис. 5. Диаграммы относительных погрешностей измерения водорода в присутствии угарного газа, до и после применения метода ИНС: **а** – $C_{CO} = 0,01\%$; **б** – $C_{CO} = 0,1\%$ (погрешности ИНС обозначены черным цветом, погрешности без применения метода - серым цветом)

Fig. 5. Charts of relative measurement errors of hydrogen in the presence of carbon monoxide, before and after the application of the ANN method: **a** – $MTR = 0,01\%$; **б** – $MTR = 0,1\%$ (ANN errors are indicated in black, errors without using the method are gray)

Анализ диаграмм относительных погрешностей измерения концентрации монооксида углерода в присутствии водорода (рис. 4) показывает, что использование нейронной сети для снижения влияния мешающих газов на сигнал датчиков обладает высокой эффективностью. Для концентраций монооксида углерода до 0,01 об.% и концентрации мешающего газа водорода 0,2% погрешность снижается в 10 раз. С ростом концентрации мешающего газа (водорода) до 2% эффективность применения нейронных сетей возрастает, погрешность снижается в 20 раз при концентрациях угарного газа выше 0,01 об.%.

Анализ диаграмм относительных погрешностей измерения концентрации водорода в присутствии монооксида углерода (рис. 5) показывает, что использование метода нейронных сетей для подавления перекрестной чувствительности позволяет достичь наилучшего результата. При низких концентрациях анализируемого газа погрешность снижается в десятки раз. Для объемных концентраций водорода свыше 1% датчик практически не чувствителен к угарному газу в диапазоне концентраций монооксида углерода 0,003-0,1%. При низких концентрациях мешающего монооксида углерода (до 0,1 об.%) и концентрациях водорода свыше 1,0 об.% перекрестной чувствительностью датчика можно пренебречь.

Выводы

Проведенные в данной работе исследования позволяют судить об эффективности применения нейронной сети для обработки сигналов датчиков в газоанализаторах. Показано, что процесс разработки структуры сети, ее обучение и тестирование, требует большого числа обучающих данных. Получение их экспериментальным путем делает применение метода нецелесообразным.

Разработанная методика генерации обучающих данных с помощью математических моделей сенсоров позволяет автоматизировать процесс, снизить стоимость работ и их трудоемкость. Предложенный метод позволяет генерировать данные случайно в требуемом объеме, что дает возможность не только обучать и тестировать ИНС, но и контролировать процесс переобучения на отдельной выборке.

Значения погрешностей, полученные в результате оценки эффективности применения нейронных сетей для подавления влияния перекрестной чувствительности, демонстрируют высокий потенциал применения ИНС для обработки информации в многокомпонентных газоанализаторах. При низких концентрациях основного газа и высоких концентрациях мешающего газа погрешности измерений снижаются в десятки раз.

Список литературы

1. Metal Oxide Semi-Conductor Gas Sensors in Environmental Monitoring / F. George., L. M. Cavanagh, A. Afonja, R. Binions // *Sensors*. 2010. P. 5469-5502
2. Measure of carbon dioxide using a gas sensor of a semiconductor type based on tin dioxide (SnO₂) / H. Abderrahim, M. Berrebia, A. Hamou, H. Kherief, Y. Zanoun, K. Zenata // *J. Mater. Environ. Sci.* 2011. 2 (2). P. 94-103
3. Бельшева Т.В., Боговцева Л.П., Гутман Э.Е. Применение металлооксидных полупроводниковых гетеросистем для газового анализа // *International Scientific Journal: for Alternative Energy and Ecology*. 2004. №2. С.67-66.
4. Дрейзин В. Э., Брежнева Е. О., Бондарь О. Г. Устройство обработки сигналов многокомпонентного газо- анализатора // *Приборы и Системы. Управление, контроль, диагностика*. 2011. № 12. С. 43-48 .
5. Брежнева Е.О., Бондарь О.Г. Газоанализатор монооксида углерода и водорода // *Известия Юго-Западного государственного университета*. 2012. № 2-3. С. 67-70.
6. Томакова Р.А., Филист С.А., Яа З.До. Универсальные сетевые модели для задач классификации биомедицинских данных // *Известия Юго-Западного государственного университета*. 2012. № 4-2 (43). С. 44-50.
7. Дашковский А.А., Примиский В.Ф. Математическое моделирование многокомпонентных газоаналитических измерений и анализ погрешностей // *Восточно-Европейский журнал передовых технологий*. 2005. № 6/2 (18). С. 108-111.
8. Дрейзин В. Э., Брежнева Е. О. Моделирование газочувствительных датчиков // *Информационно-измерительные диагностические и управляющие системы. Диагностика-2011: материалы 2-ой Международной науч.-техн. конф. Курск, 2011. С. 53-59.*
9. Bondar O. G., Brezhneva E. O., Pozdnyakov V. V. Methods and Algorithms for Control of a Thermocatalytic Hydrogen Sensor // *Measurement Techniques*. August, 2018. Vol.61. N 5. P.514-519.
10. Electro-thermal modeling of a microbridge gas sensor / R. P. Manginell, J. H. Smith, A. J. Ricco, R. C. Hughes, D. J. Moreno // *Sandia National Laboratories, Albuguergue, NM87185-1080*. 1997. P. 360-371
11. Дрейзин В. Э., Брежнева Е.О., Бондарь О. Г. Моделирование каталитического датчика водорода // *Известия Юго-Западного государственного университета*. 2011. № 5(38). Ч. 1. С. 69-76.
12. Драздейл Д. Введение в динамику пожаров. М.: Стройиздат, 1990. 424 с.
13. Щеглов П.П., Шароварников А.Ф. Токсичные продукты термического разложения и горения полимерных материалов при пожаре. М.: ВИПТШ МВД России, 1992. 80 с.
14. Кошмаров Ю. А. Прогнозирование опасных факторов пожара в помещении. М.: Академия ГПС МВД России, 2000. 118 с.

15. Дрейзин В. Э., Брежнева Е. О. Сравнительный анализ характеристик промышленных газочувствительных датчиков // Датчики и системы. 2011. № 3. С. 68-78.
16. Сазонов С.Ю., Титенко Е.А., Ханис Н.А. Подход к прогнозированию возникновения пожароопасной ситуации в дата-центре на основе нейронных сетей // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение, 2015. № 4 (17). С. 8-14.
17. Swingler K. Applying neural networks: A practical guide. London: Academic Press, 1996. 345 p.
18. Foresee F.D., Hagan M.T. Gaus-Newton approximation to Bayesian regularization. // Proceedings of the 1997 International Joint Conference on Neural Networks. 1997. P. 1930-1935.
19. Дрейзин В.Э., Гримов А.А. Измерительный блок для нейтронного спектрометра реального времени с вычислительным восстановлением энергетических спектров с помощью нейронных сетей // Известия Юго-Западного государственного университета. 2012. № 2-3. С. 223-228.
20. Применение глубоких нейронных сетей в задаче получения карты глубины из двумерного изображения / Д.И. Михальченко, А.Г. Ивин, О.Ю. Сивченко, Е.А. Аксаментов // Известия Юго-Западного государственного университета. 2019; 23(3): 113-134. <https://doi.org/10.21869/2223-1560-2019-23-3-113-134>.

References

1. George F., Cavanagh L. M., Afonja A., Binions R. Metal Oxide Semi-Conductor Gas Sensors in Environmental Monitoring. *Sensors*, 2010, pp. 5469-5502.
2. Abderrahim H., Berrebia M., Hamou A., Kherief H., Zanoun Y., Zenata K. Measure of carbon dioxide using a gas sensor of a semiconductor type based on tin dioxide (SnO₂). *J. Mater. Environ. Sci.*, 2011, 2 (2), pp. 94-103.
3. Belysheva T.V., Bogovtseva L.P., Gutman E.E. Primenenie metalloksidnykh poluprovodnikovykh geterosistem dlya gazovogo analiza [The use of metal oxide semiconductor heterosystems for gas analysis]. *International Scientific Journal: for Alternative Energy and Ecology*, 2004, no. 2, pp.67-66 (In Russ.).
4. Dreizin V., Brezhneva E. O., Bondar O. G. Ustroistvo obrabotki signalov mnogokomponentnogo gazo- analizatora [The signal processing device of a multicomponent gas analyzer]. *Pribory i Sistemy. Upravlenie, kontrol', diagnostika = Devices and Systems. Management, control, diagnostics*, 2011, no. 12, pp. 43-48 (In Russ.).
5. Brezhnev E.O., Bondar O.G. Gazoanalizator monooksida ugleroda i vodoroda [Gas analyzer of carbon monoxide and hydrogen]. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University*, 2012, no. 2-3, pp. 67-70 (In Russ.).

6. Tomakova R.A., Filist S.A., Yaa Z. Do. Universal'nye setevye modeli dlya zadach klassifikatsii biomeditsinskikh dannykh [Universal Network Models for Classification of Biomedical Data]. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University*, 2012, no. 4-2 (43), pp. 44-50 (In Russ.).

7. Dashkovsky A.A., Primsky V.F. Matematicheskoe modelirovanie mnogokomponentnykh gazoanaliticheskikh izmerenii i analiz pogreshnostei [Mathematical modeling of multicomponent gas analytical measurements and error analysis]. *Vostochno-Evropeiskii zhurnal peredovykh tekhnologii = East European Journal of Advanced Technology*, 2005, no. 6/2 (18), pp. 108-111 (In Russ.).

8. Dreizin V.E., Brezhnev E. O. [Modeling of gas-sensitive sensors]. *Materialy 2-oi Mezhdunarodnoi nauch.-tekhn. konf. "Informatsionno-izmeritel'nye diagnosticheskie i upravlyayushchie sistemy. Diagnostika-2011"* [Materials of the 2nd International scientific and technical. conf. "Information-measuring diagnostic and control systems. Diagnostics-2011"]. Kursk, 2011, pp. 53-59 (In Russ.).

9. Bondar O. G., Brezhneva E. O., Pozdnyakov V. V. Methods and Algorithms for Control of a Thermocatalytic Hydrogen Sensor. *Measurement Techniques*, August, 2018, vol.61, no. 5, pp.514-519.

10. Manginell R. P., Smith J. H., Ricco A. J., Hughes R. C., Moreno D. J. P. Moreno Electro-thermal modeling of a microbridge gas sensor. *Sandia National Laboratories, Albuquerque, NM87185-1080*, 1997, pp. 360-371.

11. Dreizin V. E., Brezhnev E.O., Bondar O. G. Modelirovanie kataliticheskogo datchika vodoroda [Modeling a catalytic hydrogen sensor]. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University*, 2011, no. 5 (38), pt.1, pp. 69-76 (In Russ.).

12. Drazdale D. *Vvedenie v dinamiku pozharov* [Introduction to Fire Dynamics]. Moscow, Stroyizdat Publ., 1990, 424 p. (In Russ.).

13. Scheglov P.P., Sharovarnikov A.F. *Toksichnye produkty termicheskogo razlozheniya i gorennya polimernykh materialov pri pozhare* [Toxic products of thermal decomposition and combustion of polymeric materials in case of fire]. Moscow, 1992, 80 p. (In Russ.).

14. Koshmarov Yu. A. *Prognozirovaniye opasnykh faktorov pozhara v pomeshchenii* [Prediction of hazardous factors of fire in the room]. Moscow, 2000, 118 p. (In Russ.).

15. Dreizin V.E., Brezhneva E.O. Sravnitel'nyi analiz kharakteristik promyshlennykh gazochuvstvitel'nykh datchikov [Comparative analysis of the characteristics of industrial gas-sensitive sensors]. *Datchiki i sistemy = Sensors and systems*, 2011, no 3, pp. 68-78 (In Russ.).

16. Sazonov S.Yu., Titenko E.A., Hanis N.A. Podkhod k prognozirovaniyu vznikenoveniya pozharoopasnoi situatsii v data-tsentre na osnove neironnykh setei [Approach to prediction of fire management in the data center based on neural networks]. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika*,

17. Swingler K. Applying neural networks: A practical guide. London, Academic Press, 1996, 345 p.

18. Foresee F.D., Hagan M.T. Gaus-Newton approximation to Bayesian regularization. *Proceedings of the International Joint Conference on Neural Networks*, 1997, pp. 1930-1935.

19. Dreyzin V. E., Grimov A. A. Izmeritel'nyi blok dlya neitronnogo spektrometra real'nogo vremeni s vychislitel'nym vosstanovleniem energeticheskikh spektrov s pomoshch'yu neironnykh setei [A Measuring unit for a real-time neutron spectrometer with computational reconstruction of energy spectra using neural networks]. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University*, 2012, no. 2-3, pp. 223-228 (In Russ.).

20. Mikhalchenko D.I., Ivin A.G., Sivchenko O.Yu., Aksamentov E.A. [Application of Deep Neural Networks in the Problem of Obtaining Depth Maps from Two-Dimensional Images]. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University*. 2019, 23(3): 113-134 (In Russ.). <https://doi.org/10.21869/2223-1560-2019-23-3-113-134>.

Информация об авторах / Information about the Authors

Бондарь Олег Григорьевич, кандидат технических наук, доцент, доцент кафедры космического приборостроения и систем связи ФГБОУ ВО «Юго-Западный государственный университет», г. Курск, Российская Федерация, e-mail: b.og@mail.ru

Oleg G. Bondar, Cand. of Sci. (Engineering), Associate Professor, Department of Space Instrumentation and Communication Systems, Southwest State University, Kursk, Russian Federation, e-mail: b.og@mail.ru

Брежнева Екатерина Олеговна, кандидат технических наук, доцент, доцент кафедры космического приборостроения и систем связи ФГБОУ ВО «Юго-Западный государственный университет», г. Курск, Российская Федерация, e-mail: bregnevaeo@mail.ru

Ekaterina O. Brezhneva, Cand. of Sci. (Engineering), Associate Professor, Department of Space Instrumentation and Communication Systems, Southwest State University, Kursk, Russian Federation, e-mail: bregnevaeo@mail.ru

Чернышов Ростислав Евгеньевич, студент кафедры космического приборостроения и систем связи ФГБОУ ВО «Юго-Западный государственный университет», г. Курск, Российская Федерация, e-mail: rostyslav231@gmail.com

Rostislav E. Chernyshov, Student, Department of Space Instrumentation and Communication Systems, Southwest State University, Kursk, Russian Federation, e-mail: rostyslav231@gmail.com