(cc) BY 4.0

Оригинальная статья / Original article

https://doi.org/10.21869/2223-1560-2021-25-2-123-139

Разработка нейронной модели полупроводникового датчика газа

О.Г. Бондарь ¹, Е.О. Брежнева ¹ ⊠, К.Г. Андреев ¹, Н.В. Поляков ¹

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

🖂 e-mail: bregnevaeo@mail.ru

Резюме

Цель исследования. Разработка нейронной модели полупроводникового датчика газа с целью генерации данных для обучения устройства обработки информации газоанализаторов на основе искусственных нейронных сетей (ИНС). Поиск и оптимизация состава и объема обчищающих данных. Нейронная модель датчика должна учитывать влияние на сигнал тех факторов, колебания которых вносят максимальный вклад в погрешности измерений. Апробация модели на полупроводниковых датчиках угарного газа и водорода.

Методы. Методы компьютерного моделирования, численные методы, теория нейронных сетей. Для сопоставления результатов моделирования и откликов реальных датчиков определялись относительная погрешность и среднеквадратическое отклонение.

Результаты. Проведены исследования различных структур нейронной модели полупроводникового датчика, осуществлен выбор структуры многослойной нейронной сети прямого распространения для двух полупроводниковых датчиков угарного газа и водорода, произведена оценка погрешностей моделирования, даны рекомендации по выбору оптимальной структуры и объему обучающих данных.

Заключение. Получены нейронные модели полупроводниковых датчиков угарного газа и водорода, сделаны выводы о возможности применения данной структуры ИНС при решении типовых задач. На основании анализа полученных погрешностей показана эффективность применения нейронных моделей датчиков для генерации обучающих данных. Максимальная относительная погрешность моделирования полупроводникового датчика монооксида углерода TGS2442 не превысила 5% по основной характеристике и 2% по дополнительным. Максимальная относительная погрешность моделирования полупроводникового датчика водорода TGS2442 не превысила 3% по основной характеристике и 1% по дополнительным.

Ключевые слова: полупроводниковые датчики газа; угарный газ; водород; температура; влажность; перекрестная чувствительность; искусственные нейронные сети; относительная погрешность; моделирование; среднеквадратическое отклонение, концентрация газа.

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

Для цитирования: Разработка нейронной модели полупроводникового датчика газа / О.Г. Бондарь, Е.О. Брежнева, К.Г. Андреев, Н.В. Поляков // Известия Юго-Западного государственного университета. 2021; 25(2): 123-139. https://doi.org/10.21869/2223-1560-2021-25-2-123-139.

Поступила в редакцию 19.04.2021

Подписана в печать 21.06.2021

Опубликована 24.08.2021

© Бондарь О.Г., Брежнева Е.О., Андреев К.Г., Поляков Н.В., 2021

Development of a Neural Model of a Semiconductor Gas Sensor

Oleg G. Bondar ¹, Ekaterina O. Brezhneva ¹ ⊠, Kirill G. Andreev ¹, Nikolay V. Polyakov ¹

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

🖂 e-mail: bregnevaeo@mail.ru

Abstract

Purpose of research: Development of a neural model of a semiconductor gas sensor in order to generate data for training an information-processing device of gas analyzers based on artificial neural networks (ANN). Search and optimization of cleaning data composition and volume. The neural model of the sensor should take into account the influence of those factors on the signal, the fluctuations of which make the maximum contribution to the measurement errors. Testing of the model based on semiconductor carbon monoxide and hydrogen sensors.

Methods. Methods of computer modeling, numerical methods, theory of neural networks. To compare the simulation results and the responses of real sensors, the relative error and standard deviation were determined.

Results. Studies of various structures of the neural model of a semiconductor sensor have been carried out, the structure of a multilayer neural network of direct propagation for two semiconductor carbon monoxide and hydrogen sensors has been selected, modeling errors have been estimated, recommendations have been given for choosing the optimal structure and the amount of training data.

Conclusion. Neural models of semiconductor carbon monoxide and hydrogen sensors have been obtained, conclusions have been drawn about the possibility of using this ANN structure in solving typical problems. Based on the analysis of the errors obtained, the effectiveness of using neural models of sensors to generate training data has been shown. The maximum relative error of modeling the TGS2442 semiconductor carbon monoxide sensor did not exceed 5% for the main characteristic and 2% for additional ones. The maximum relative error of modeling the TGS2442 semiconductor carbon deling of the TGS2442 semiconductor hydrogen sensor did not exceed 3% for the main characteristic and 1% for additional ones.

Keywords: semiconductor gas sensors; carbon monoxide; hydrogen; temperature; humidity; cross-sensitivity; artificial neural networks; relative error.

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

For citation: Bondar O. G., Brezhneva E. O., Andreev K. G., Polyakov N. V. Development of a Neural Model of a Semiconductor Gas Sensor. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University.* 2021; 25(2): 123-139 (In Russ.). https://doi.org/10.21869/2223-1560-2021-25-2-123-139.

Received 19.04.2021

Accepted 21.06.2021

Published 24.08.2021

Введение

Обучение ИНС требует наличия большого числа экспериментальных данных, представляющих собой совокупность значений входных параметров (концентрация газов, температура, влажность) и соответствующие им сигналы датчиков [1-7]. Специфика применения ИНС для обработки информации в газоаналитических системах накладывает дополнительные ограничения и требования к

процессу генерации данных [8-10]. Получение такого числа данных только экспериментальным путем нецелесообразно с точки зрения финансовых затрат и трудоемкости.

Существует альтернативный метод – применение математических моделей датчиков [11-12]. Достоинствами метода являются возможность экстраполяции данных и унификация моделей в рамках одного типа датчиков. К его недостаткам следует отнести сложность автоматизации процесса параметризации многофакторных моделей, а также рост погрешности воспроизведения влияния температуры и влажности на границах диапазонов. Снизить погрешности можно увеличив сложность моделей, что повлечет за собой усложнение процесса их параметризации.

В данной работе предлагается исследовать альтернативный метода генерации обучающих данных с помощью нейронных моделей самих датчиков. Для решения поставленной задачи необходимо осуществить выбор структуры нейронной сети и объем обучающих данных, необходимый для получения требуемого уровня погрешности воспроизведения характеристик датчиков не выше 5% (максимальная относительная погрешность) по каждому из факторов. Разработка и апробация нейронных моделей будет проводиться на полупроводниковых датчиках, обладающих рядом преимуществ по сравнению с другими типами датчиков [13].

Материалы и методы

Исследование возможности применения ИНС для решения задач аппроксимации исходных данных, в том числе и в области анализа состава воздушных сред, показало, что наибольшей эффекобладают тивностью многослойные нейронные сети прямого распространения [8]. В связи с чем, в данной работе осуществляется исследование различных структур фиксированной архитектуры ИНС. На рис. 1 представлена структурная схема многослойной нейронной сети прямого распространения с логистической функцией активации нейронов во входном и промежуточном слоях и линейной в выходном слое. Согласно проведенным ранее исследованиям, наилучший результат показал алгоритм обучения LM Левенберга – Марквардта (использует матрицу Якоби для оценки матрицы Гессе) [14].

На рис. 2 представлен алгоритм обучения нейронной модели датчика газа. На первом этапе проводилась оцифровка исходных характеристик датчиков с помощью полинома в программе MatLab с использованием встроенной функции lsqcurvefit, реализующей нелинейный метод наименьших квадратов. Исследования проводились для полупроводникового датчика водорода TGS821 фирмы Figaro. Результаты аппроксимации характеристик датчиков представлены в табл. 1.

126 Информатика, вычислительная техника и управление / Computer science, computer engineering and control



Рис. 1. Структурная схема нейронной сети прямого распространения

Fig. 1. Block diagram of a forward propagation neural network



Рис. 2. Алгоритм создания нейронной модели датчика

Fig. 2. Algorithm for creating a neural model of the sensor

Известия Юго-Западного государственного университета / Proceedings of the Southwest State University. 2021; 25(2): 123-139

Таблица 1. Погрешности аппроксимации характеристик TGS821

No	Vanarranucrura / Characteristic	CKO %	Количество точек /		
JN≌	Характеристика / Спагастеньне	CKO, 70	Number of points		
1	$Y(C_{H_2}), C_{CO}=0,T=20^{\circ}C, RH=65\%$	0,18	600		
2	Y(C _{CO}), C _{H2} =0,T=20°C, RH=65%	0,34	600		
3	Y(T), $C_{H_2}=100, C_{CO}=0, RH=35\%$	0,06	500		
4	Y(T), $C_{H_2}=100, C_{CO}=0, RH=65\%$	0,05	500		
5	Y(T), $C_{H_2}=100, C_{CO}=0, RH=95\%$	0,05	500		
6	Y(RH), C _{H2} =100,C _{CO} =0,T=20°C	0,001	500		
-	Всего		3200		

Table 1	. Ap	proximation	errors of	TGS821	characteristic
---------	------	-------------	-----------	--------	----------------

Для оценки объема обучающего множества обратимся к формуле *Baum* и *Haussler* [15]:

 $n \ge w/\varepsilon$,

где w – количество весов сети; ε – величина ошибки.

Применение данной формулы требует информации о начальной структуре ИНС. Исследования проводились с исходной структурой сети 4-3-1. Количество нейронов во входном и выходном слоях определяется задачей проектирования сети (имитация многопараметрической функции): четыре входных параметра (концентрации основного и перекрестного газов, температура, влажность), один выходной параметр (сигнал датчика). Начальное число нейронов в скрытом слое выбрано равным полусумме нейронов во входном и выходном слоях [16-19]. Данная структура сети содержит 32 коэффициента и для обеспечения погрешности воспроизведения не свыше 1% (взят с запасом) требует выборку объемом не менее 3200 точек. На основании анализа погрешностей, выпускаемых промышленностью газоанализаторов [20], зададимся максимальным значением величины погрешности воспроизведения характеристик равным 5%.

Воспроизведение характеристик в виде совокупности точек осуществляется блоком генерации выборки (см. рис. 1). Блок генерирует матрицу входных параметров размера $P \times N$ и матрицу выходного параметра размера $1 \times N$, где P – количество влияющих на сигнал датчика параметров; N – необходимое количество точек в выборке. Осуществляем предварительное нормирование данных в диапазоне 0-1. Значения факторов генерируются по равномерному закону распределения.

В процессе исследования варьировалось число нейронов в скрытом слое, осуществлялся контроль «эффекта переобучения», обучение каждой струк-

Известия Юго-Западного государственного университета / Proceedings of the Southwest State University. 2021; 25(2): 123-139

туры проводилось 3 раза, сохранялась сеть, показавшая наилучший результат. Количество точек по каждой характеристике, использующихся при обучении нейронной сети, указано в табл. 1 в последнем столбце.

Результаты и их обсуждение

В табл. 2 представлены результаты исследования, направленного на поиск оптимальной структуры ИНС.

Таблица 2. Исследование погрешностей ИНС разных структур

Структура ИНС	Объем обуча- ющей выбор- ки / The scope of the training choice	Эпох обу- чения пройдено / The epochs of education have been passed	Максимальная относительная по- грешность,% / Maximum relative sinfulness,% /	Номер характери- стики с максималь- ной погрешностью / The number of the characteristic with the maximum error
	650	1867	20.4	2
4-3-1	1500	1639	20.3	2
	3200	2000	26.4	2
	650	1132	18.7	2
4-4-1	1500	1669	16.6	2
	3200	1563	10.5	2
	650	2000	6.5	2
4-6-1	1500	2000	6.3	2
	3200	2000	4.5	2
	650	174	>50	2
4-10-1	1500	515	23.2	2
	3200	2000	4.5	2

Table 2. Study of the errors of the ANN of different structures

По каждому набору обучающих данных проводилось три обучения, в табл. 2 представлены результаты с наименьшим значением относительной погрешности. На основании анализа результатов исследования была выбрана структура ИНС с шестью нейронами в

скрытом слое. Дальнейшее усложнение структуры не приводит к значительному снижению погрешности. В табл. 3 представлены результаты детального исследования погрешностей по каждой характеристике.

Таблица 3. Результат тестирования ИН	С
--------------------------------------	---

Эпох обучения / Eras of learning	Номер характеристики / Feature number	Среднеквадратическая погрешность, % / Standard error, %	Максимальная относи- тельная погрешность, % / Maximum relative error, %
	1	0.12	4.49
	2	0.07	2.03
2000	3	0.14	0.23
2000	4	0.05	0.10
	5	0.07	0.32
	6	0.1	0.30

 Table 3. ANN test result

Анализ результатов показал, что максимальные погрешности воспроизведения характерны для зависимостей сигнала датчика от концентрации газов. Величина погрешностей воспроизведения влияния факторов (температуры и влажности) позволяет сделать вывод о возможном снижении объема обучающих данных по этим характеристикам. В табл. 4 представлены результаты эксперимента по поиску оптимального объема обучающих данных. С целью снижения погрешности воспроизведения основной характеристики, был увеличено количество точек в диапазоне 1000-3000 *ppm*.

Таблица 4. Измененный состав обучающей и контрольной выборок и погрешности тестирования модели датчика *TGS*821

Характеристика / Characteristic	Диапазон / Range	Кол-во точек / Number of points	Макс. относи- тельная по- грешность, % / Max. relative sinfulness, %	СКО, %
1- Y(H2)	303000ppm	1000	2.08	0 70
	10003000ppm	250	2.98	0.79
2- Y(CO)	303000ppm	500	2.74	0.06
3- Y(RH)	3590%	100	0.67	0.36
4- Y(T) RH=35%	-1040°C	100	0.06	0.02
5- Y(T) RH=65%	-1040°C	100	0.72	0.13
6- Y(T) RH=95%	-1040°C	100	0.74	0.15
Всего/Макс.		2150	2,98	0.79

 Table 4. Modified composition of the training and control samples and testing errors of the TGS821 sensor model

Анализ полученных результатов позволил сделать выводы о возможности снижения количества точек в обучающей выборке по характеристикам 2-6, а также разбить на поддиапазоны основную характеристику 1, увеличив число точек в диапазоне минимальных и максимальных концентраций. Итоговый состав выборки представлен в табл. 5. Объем тестирующей выборки составил 10 000 точек, что подтвердило отсутствие «эффекта переобучения» и интерполяционные свойства ИНС.

Таблица 5. Измененный состав обучающей и контрольной выборок и погрешности тестирования модели датчика *TGS*821

Table 5. Modified composition of the training	and control samples a	nd testing errors of the TGS82	21
sensor model			

Характеристика / Characteristic	Диапазон / Range	Кол-во точек / Number of points	Макс. относи- тельная по- грешность, % / Max. relative sinfulness, %	СКО, %
	30100ppm	65	3.84	
1- Y(H2)	1001000ppm	135	2.85	0.2
	10003000ppm	400	0.93	
2- Y(CO)	303000ppm	250	3.2	0.2
3- Y(RH)	3590%	50	2.5	1.23
4- Y(T) RH=35%	-1040°C	50	1.84	0.33
5- Y(T) RH=65%	-1040°C	50	3.63	0.91
6- Y(T) RH=95%	-1040°C	50	1.68	0.52
Всего/Макс.		1050	3.84	1.23

При дальнейшем уменьшении объема обучающей выборки погрешности растут как по основной характеристике, так и по дополнительным. По результатам тестов, максимальная относительная погрешность ИНС не превышает 4%, а среднеквадратичное отклонение по каждой из характеристик не превышает 1.3%. Объем обучающей выборки составил 1050 точек.

График обучения ИНС представлен на рис. 3.

Результаты тестирования ИНС по каждой характеристике датчика представлены на рис. 3 – 6. На графиках $Y_{C\Gamma EH}(X)$ – сгенерированная по графикам из технической документации зависимость сигнала датчика от параметра X. $Y_{\Pi OЛУЧ}(X)$ – полученная с помощью ИНС зависимость сигнала датчика от параметра X. Параметры CO, H2, RH и T – это концентрация угарного газа, концентрация водорода, относительная влажность и температура соответственно.



Рис. 3. График обучения ИНС для *TGS*821: **1** – обучающая выборка; **2** – контрольная выборка; **3** – лучший результат



Fig. 3. ANN training schedule for TGS821: 1 - training sample; 2 - control sample; 3 - best result

Рис. 4. Тестирование ИНС по воспроизведению характеристики 1

Fig. 4. Testing the ANN for reproducing characteristic 1



Рис. 5. Тестирование ИНС по воспроизведению характеристики 2

Fig. 5. Testing the ANN for reproducing characteristic 2



Рис. 6. Тестирование ИНС по воспроизведению температурной зависимости (характеристики 4-6) **Fig. 6.** Testing of the ANN for reproducing the temperature dependence (characteristics 4-6)



Рис. 7. Тестирование ИНС по характеристике 3

Fig. 7. Testing the ANN according to characteristic 3

Аналогичные исследования были проведены для датчика угарного газа *TGS*2442. Наилучшие результаты также

показала нейронная сеть структурой 4-6-1, погрешность тестирования не превысила 5% (табл. 6).

Таблица 6. Измененный состав обучающей и контрольной выборок и погрешности тестирования модели датчика *TGS*2442

|--|

			Макс. относи-	
Vanaumanuamuua /	Treeses or /	Кол-во то-	тельная по-	
Аарактеристика /	Диапазон /	чек / Num-	грешность, % /	СКО, %
Characteristic	Range	ber of points	Max. relative	
			sinfulness, %	
1- Y(CO)	303000ppm	1250	4.85	0.05
2- Y(H2)	303000ppm	500	2.03	0.11
3- Y(RH)CO=30ppm	3590%	50	0.73	0.38
4- Y(RH)CO=100ppm	3590%	50	0.7	0.39
5- Y(RH)CO=300ppm	3590%	100	1.05	0.54
6- Y(T) CO=30ppm	-1040°C	50	0.92	0.14
7- Y(T) CO=100ppm	-1040°C	100	1	0.28
8- Y(T) CO=300ppm	-1040°C	100	1.8	0.36
Всего/Макс.		2200	4.85	0.54

Полученные результаты демонстрируют высокую эффективность применения нейронных моделей датчиков для генерации обучающих данных. Реализация данной методики позволяет снизить погрешности воспроизведения дополнительных характеристик (чувствительность к влажности, температуре) с максимальных 8% (СКО), в случае использования математических моделей датчиков, до 0,54% (табл. 7).

Максимальная относительная погрешность воспроизведения температурной характеристики при математическом моделировании составляла 29% в диапазоне температур от +30 - +50 °C, предложенный метод генерации данных позволяет воспроизводить все характеристики с максимальной относительной погрешностью менее 5%.

Дополнительным достоинством является возможность автоматизации процесса создания нейронных моделей датчиков, в то время, как параметризация коэффициентов математических моделей для различных датчиков в одной партии требует трудоемких работ и реализации сложных алгоритмов.

Таблица 7. Сравнительный анализ методик генерации обучающих данных

Тип датчика /	Варьируе- мый фактор	Диапазон значений параметра /	Условия /	Мат. м / М то	иодели lat. dels	ИН	łC
Sensor type	/ Variable factor	Range of parameter values	Conditions	$\delta_{max}, \ \%$	СКО, %	$\delta_{max}, \ \%$	СКО, %
Полупровод- никовый	Концентра- ция <i>СО</i>	30 – 1000 ppm	RH=50% $C_{H_2}=0 \text{ o6.\%};$ T = 293,15 K	5	0,24	4,85	0,05
	Концентра- ция <i>Н</i> ₂	300 – 1000 ppm	RH=50% $C_{CO}=0$ oб.%; T = 293,15 K	0,9	0,67	2,03	0,11
	Влажность	10-90 %	$C_{CO}=30-1000 ppm$ $C_{H_2}=0 \text{ of. \%};$ T=293,15 K	16	5,5	0,73	0,38
	Температура	-5-+50°C	RH=50 %; C _{CO} =30-1000 <i>ppm</i> C _{H2} =0 об.%	29	8,2	0,7	0,39

Table 7. Comparative analysis of training data generation techniques

Выводы

В результате проведенных работ получены нейронные модели полупроводниковых датчиков газа, позволяющие воспроизводить сигнал при колебаниях параметров окружающей среды с относительной погрешностью менее 5% и генерировать обучающие данные в требуемом количестве в автоматическом режиме. Полученные модели учитывают чувствительность к перекрестному газу, влажности и температуре и имеют одинаковую структуру 4-6-1. Определен оптимальный объем обучающих данных, подтверждены интерполяционные свойства многослойной нейронной сети прямого распространения.

Список литературы

1. 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.

2. 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.

3. 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. 2015. № 4 (17). С. 8-14.

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

5. 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.

6. 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.

7. Применение 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.

8. Дрейзин В. Э., Брежнева Е. О., Бондарь О. Г. Устройство обработки сигналов многокомпонентного газоанализатора // Приборы и Системы. Управление, контроль, диагностика. 2011. № 12. С. 43-48.

Известия Юго-Западного государственного университета / Proceedings of the Southwest State University. 2021; 25(2): 123-139

9. 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.

10. 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. P.514-519.

11. Metal Oxide Semi-Conductor Gas Sensors in Environmental Monitoring / F. George., L. M. Cavanagh, A. Afonja, R. Binions // Sensors. 2010. P. 5469-5502.

12. 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.

13. Дрейзин В.Э., Брежнева Е. О. Сравнительный анализ характеристик промышленных газочувствительных датчиков // Датчики и системы. 2011. № 3. С. 68-78.

14. Дьяконов В. П., Круглов В. В. MatLab 6.5 SP1/7/7 SP1/7 SP2. М: Солон – Пресс, 2006. 456 с.

15. Латыпова Рамиля Нейронные сети. М.: LAP LambertAcademicPublishing, 2012. 572 с.

16. Основы нейрокибернетики. М.: Высшая школа, 2015. 372 с.

17. Редько В.Г. Подходы к моделированию мышления. М/: ИЛ, 2016. 392 с.

18. Редько В.Г. Эволюция, нейронные сети, интеллект: Модели и концепции эволюционной кибернетики. М.: Высшая школа, 2017. 224 с.

19. Тадеусевич Рышард [и др.]. Элементарное введение в технологию нейронных сетей с примерами программ. Москва: СПб.: Питер, 2011. 408 с.

20. Брежнева Е. О., Дрейзин В. Э. Выбор сенсоров для разработки многосенсорного газоанализатора газовых смесей // Безопасность жизнедеятельности. 2011. № 4. С. 5-11.

References

1. Tomakova R.A., Filist SA, Yaa Z.D. Tomakova R.A. Universal'nye setevye modeli dlya zadach klassifikatsii biomeditsinskikh dannykh [Universal network models for classification problems of biomedical data]. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University*, 2012, no. 4-2 (43), pp. 44-50 (In Russ.).

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

3. Sazonov S. Yu., Titenko E. A., Khanis N. A. Podkhod k prognozirovaniyu vozniknoveniya pozharoopasnoi situatsii v data-tsentre na osnove neironnykh sete [Approach to predicting the occurrence of a fire hazard in a data center based on neural networks]. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University*, 2015, no. 4 (17), pp. 8-14 (In Russ.).

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

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

6. Dreizin V. E., Grima A. A. Izmeritel'nyi blok dlya neitronnogo spektrometra real'nogo vremeni s vychislitel'nym vosstanovleniem energeticheskikh spektrov s pomoshch'yu neironnykh setei [Measurement unit for a real-time neutron spectrometer with numerical recovery 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.).

7. Mikhalchenko D. I., Ivin A. G., Shevchenko O. Yu., Aksamentov E. A. Primenenie neironnykh setei v zadache polucheniya karty glubiny iz dvumernogo izobrazheniya [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.

8. Dreizin V. E., Brezhneva E. O., Bondar O. G. Ustroistvo obrabotki signalov mnogokomponentnogo gazoanalizatora [Signal processing Device for multicomponent gas analysis.]. *Pribory i Sistemy. Upravlenie, kontrol', diagnostika = Devices and Systems Management, Control, Diagnostics*, 2011, no. 12, pp. 43-48 (In Russ.).

9. Bondar O. G., Brezhneva E. O., Chernyshov R. E. Primenenie neironnykh setei v zadache kolichestvennogo analiza sostava vozdushnoi sredy [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

Известия Юго-Западного государственного университета / Proceedings of the Southwest State University. 2021; 25(2): 123-139

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

11. George F., Cavanagh L. M., Afonja A., Binions R. Metal Oxide Semi-Conductor Gas Sensors in Environmental Monitoring. *Sensors*, 2010, pp. 5469-5502.

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

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

14. Diakonov V. P., Kruglov V. V. *MatLab 6.5 SP1/7/7 SP1/7 SP2*. Moscow, Solon-Press Publ., 2006. 456 p. (In Russ.).

15. Latypova Ramilya. *Neironnye seti* [Neural networks]. Moscow, LAP Lambert Academic Publishing, 2012. 572 p. (In Russ.).

16. Osnovy neirokibernetiki [Fundamentals of Neurocybernetics]. Moscow, Vysshaya shkola Publ., 2015. 372 p. (In Russ.).

17. Redko V. G. Podkhody k modelirovaniyu myshleniya [Approaches to modeling thinking]. Moscow, IL Publ., 2016. 392 p. (In Russ.).

18. Redko V. G. *Evolyutsiya, neironnye seti, intellekt: Modeli i kontseptsii evolyutsionnoi kibernetiki* [Evolution, neural networks, intelligence: Models and concepts of evolutionary Cybernetics]. Moscow, Vysshaya shkola Publ., 2017. 224 p. (In Russ.).

19. Tadeusevich Ryszard [et al.]. *Elementarnoe vvedenie v tekhnologiyu neironnykh setei s primerami programm* [Elementary introduction to neural network technology with examples of programs]. Moscow, Saint-Petersburg, Piter Publ., 2011. 408 p. (In Russ.).

20. Brezhneva E. O., Dreizin V. E. Vybor sensorov dlya razrabotki mnogosensornogo gazoanalizatora gazovykh smesei [Selection of sensors for the development of a multi-sensor gas analyzer for gas mixtures]. *Bezopasnost' zhiznedeyatel'nosti* = *Life Safety*, 2011, no. 4, pp. 5-11 (In Russ.).

Информация об авторах / Information about the Authors

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

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

Андреев Кирилл Геннадьевич, студент кафедры Космического приборостроения и систем связи, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: skyline.ozerki@gmail.com

Поляков Николай Владимирович, студент кафедры Космического приборостроения и систем связи, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail:nikera2016@mail.ru **Oleg G. Bondar**, Cand. of Sci. (Engineering), Associate Professor, Space Instrumentation and Communication Systems Department, Southwest State University, Kursk, Russian Federation, e-mail: b.og@mail.ru

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

Kirill G. Andreev, Student, Space Instrumentation and Communication Systems Department, Southwest State University, Kursk, Russian Federation, e-mail: skyline.ozerki@gmail.com

Nikolay V. Polyakov, Student, Space Instrumentation and Communication Systems Department, Southwest State University, Kursk, Russian Federation, e-mail: nikera2016@mail.ru