

Оригинальная статья

<https://doi.org/10.21869/2223-1560-2023-27-1-124-140>

Двухмодульный нейросетевой способ обработки информации в газоаналитических системах

О.Г. Бондарь¹, Е.О. Брежнева¹ ✉, К.А. Ботиков¹, Н.В. Поляков¹

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

✉ e-mail: bregnevaeo@mail.ru

Резюме

Цель работы. Снижение дополнительных погрешностей измерения концентраций газов в газоаналитических системах (ГС), вызванных чувствительностью полупроводниковых сенсоров к нецелевым компонентам газовых смесей, температуре и влажности окружающей среды. Разработать и апробировать двухмодульный нейросетевой способ обработки информации в ГС, позволяющий автоматизировать процессы генерации обучающих данных и поиска оптимальной структуры искусственных нейронных сетей (ИНС), снизить погрешности воспроизведения характеристик сенсоров, за счет замены их математических моделей нейросетевыми.

Методы: теория искусственных нейронных сетей, численные методы, методы имитационного моделирования. Для оценки эффективности предложенного решения рассчитывались относительная погрешность (δ), среднеквадратическое отклонение (СКО), осуществлялось сравнение с аналогами.

Результаты. Исследован двухмодульный нейросетевой способ обработки информации в ГС. Методом численного моделирования проведены экспериментальные исследования по выбору оптимальных структур ИНС, объема и состава обучающих данных. В ходе экспериментальных исследований рассчитаны погрешности генерации обучающих данных с помощью ИНС (менее 5%) и определения концентраций детектируемых газов в условиях колебания параметров воздушной среды и состава газовой смеси (менее 4%).

Заключение. Предложен двухмодульный нейросетевой способ обработки информации, отличающийся применением двух последовательных модулей многослойных нейронных сетей для генерации обучающих данных и обработки информации, поступающей от сенсорного блока ГС. Применение вспомогательного модуля позволяет сжать исходные данные, унифицировать и автоматизировать процесс их генерации, а также повысить точность воспроизведения многопараметрических функций преобразования сенсоров, в сравнении с альтернативными способами. Представлены результаты экспериментальных исследований эффективности применения способа обработки информации для снижения дополнительных погрешностей количественного определения состава воздушной среды в условиях колебания параметров.

Ключевые слова: нейронные сети; концентрация газа; полупроводниковый сенсор; погрешности измерения; параметры воздушной среды.

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

Для цитирования: Двухмодульный нейросетевой способ обработки информации в газоаналитических системах / О.Г. Бондарь, Е.О. Брежнева, К.А. Ботиков, Н.В. Поляков // Известия Юго-Западного государственного университета. 2023; 27(1): 124-140. <https://doi.org/10.21869/2223-1560-2023-27-1-124-140>.

Поступила в редакцию 09.01.2023

Подписана в печать 28.02.2023

Опубликована 14.04.2023

© Бондарь О.Г., Брежнева Е.О., Ботиков К.А., Поляков Н.В., 2023

Введение

Решение задач раннего обнаружения пожаров, контроля параметров воздушной среды опасных производственных объектов и технологических процессов требует применения высокоточных, быстродействующих и надежных газоаналитических систем. В настоящее время особая роль уделяется вопросам повышения точности измерения концентраций газов в составе сложных многокомпонентных смесей в условиях колебания параметров воздушной среды. Как правило, в современных ГС для повышения точности измерений концентраций газов применяются высокоселективные и дорогостоящие оптические и электрохимические сенсоры. Ограниченный перечень детектируемых газов, низкое быстродействие, высокая стоимость, малый срок службы селективных электрохимических сенсоров значительно сужает область их применения. Как результат – актуальным направлением в данной области является разработка новых и модернизация существующих сенсоров газа и их схем включения [1-7]. Одними из таких типов сенсоров являются недорогие и быстродействующие полупроводниковые сенсоры, обладающие длительным сроком службы и высокой чувствительностью к широкому списку токсичных и взрывоопасных газов.

Принцип работы полупроводниковых сенсоров основан на изменении электропроводности чувствительного слоя при

адсорбции на него детектируемого газа. Основным недостатком полупроводниковых сенсоров является чувствительность к колебаниям температуры, влажности, а также низкая селективность, обусловленная физико-химическими процессами, лежащими в основе его функционирования.

Для снижения влияния колебаний параметров воздушной среды в ГС широко применяются методы пробоподготовки газовых смесей, осуществляется поиск оптимальных рабочих температур и материалов чувствительных пленок сенсоров [8].

Альтернативным направлением в решении данной задачи является применение интеллектуальных способов совместной обработки информации, реализуемых на базе микроконтроллера. Высокую эффективность для решения таких задач показали ИНС [9-11]. В настоящее время ИНС широко используются в системах технического зрения, автоматизированного управления технологическими процессами, в робототехнике, в биомедицине [12-18]. В ГС нейронные сети нашли применение при решении задач качественного анализа состава газовых смесей [9]. Известно применение нейронных сетей для раздельного определения концентраций газов в составе многокомпонентных смесей одним полупроводниковым сенсором, заключающееся в обработке сигналов

сенсоров, получаемых в динамическом температурном режиме [8,10].

Материалы и методы

В зависимости от условий эксплуатации ГС, сенсоры газа, входящие в ее состав, могут подвергаться значительным климатическим перепадам температуры и влажности. В связи с чем, в данной работе предпринята попытка использовать ИНС для совместной обработки информации, поступающей не только от сенсоров газа, но и от сенсоров температуры и влажности, с целью снижения дополнительных погрешностей измерений.

Основным ограничивающим фактором применения ИНС в ГС является процесс генерации обучающих данных. Наиболее распространённым методом их получения является использование только экспериментальных данных, что крайне дорогостояще и трудоемко, а

также усложняет автоматизацию процесса их генерации, накладывает ограничение на объем обучающей выборки [11, 19, 20].

Альтернативным вариантом генерации обучающих данных является применение эмпирических и теоретических моделей сенсоров [21]. Применение математических моделей усложняет процесс автоматизации генерации данных, так как требует адаптации их структуры и параметризации нелинейных многопараметрических функций, кроме того, теоретические модели не всегда позволяют достичь заданной величины погрешности воспроизведения характеристик сенсоров.

На рис. 1 и 2 представлены схемы, демонстрирующие суть предлагаемого способа обработки информации в ГС, отличающегося применением двух модулей нейронной сети.



Рис. 1. Вспомогательный модуль на основе нейронных сетей: C_n — концентрации газов; T — температура; RH — относительная влажность воздуха; S — выходной сигнал сенсора

Вспомогательный модуль нейронной сети используется для автоматической генерации обучающих данных в требуемом объеме, а основной модуль осуществляет совместную обработку сигналов сенсоров на основе ИНС. Исходные данные (концентрации газов C_n , температура T , влажность RH и соответствующие им сигналы S_n) для обучения нейронных моделей сенсоров могут быть получены с помощью разработанного измерительного модуля на базе *Arduino Nano* (рис. 3) или оцифровкой, имеющих функции преобразований сенсоров. Блоки оптимизации и параметризации используются на этапе поиска структуры и коэффициентов нейронной сети, обеспечивающей требуемый уровень погрешностей.

Выходом нейронной модели сенсора является его сигнал, который используется на этапе обучения нейронной сети для совместной обработки информации в основном модуле.

Процесс обучения нейронной сети основного модуля начинается с генерации виртуальных газовых смесей случайным образом по равномерному закону. Каждая газовая смесь (Mix_{gas}) характеризуется набором значений концентраций основных компонентов (C_n) и параметров воздушной среды (влажности RH и температуры T):

$$Mix_{gas} = (C_1, \dots, C_n, RH, T)^T.$$

Обученные ранее нейронные модели сенсоров генерируют совокупность сигналов S_i , соответствующих составу поданной на вход газовой смеси и параметрам воздушной среды.

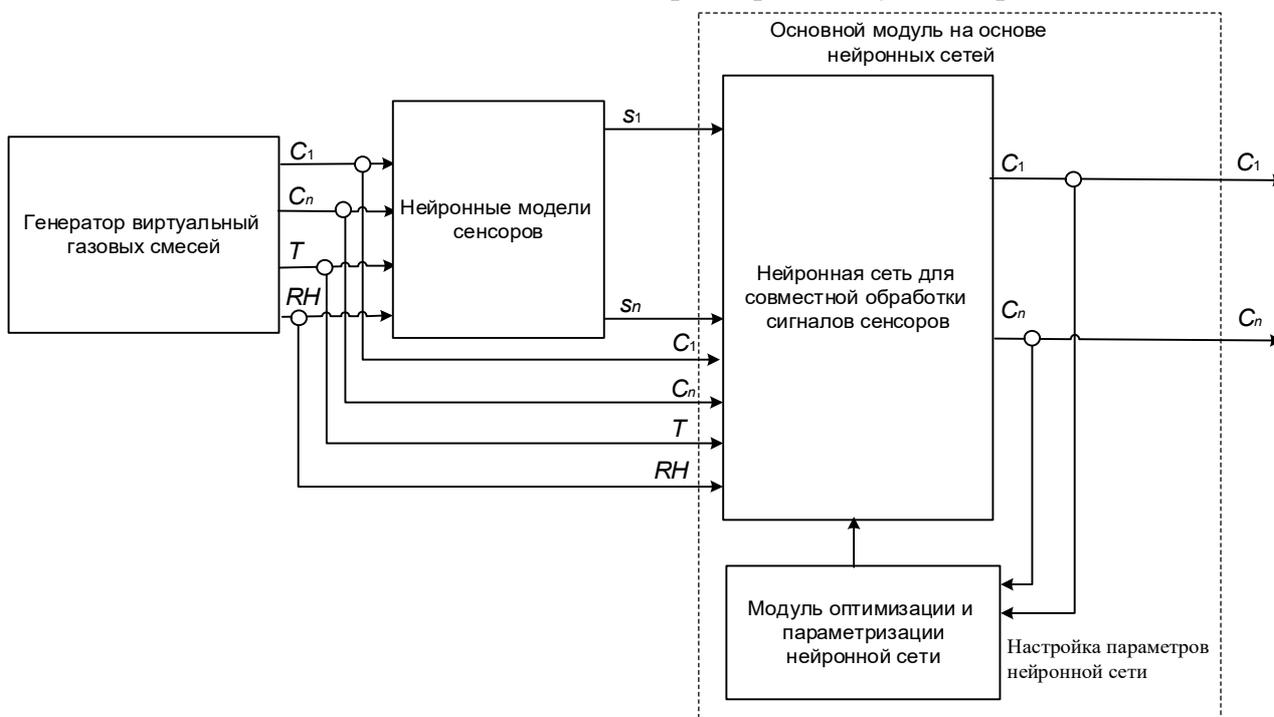


Рис. 2. Основной модуль на основе нейронных сетей

Обучающими данными для основного модуля ИНС служат концентрации детектируемых газов, совокупности сигналов сенсоров газа и параметров воздушной среды:

$$C=(C_1, \dots, C_n)^T,$$

$$S=(S_1, \dots, S_n, S_{RH}, S_T)^T.$$

Апробация способа проводилась на массово выпускаемых полупроводниковых сенсорах фирмы *Figaro*, типовые характеристики которых представлены на примере сенсора угарного газа *TGS2442*

(рис. 4 – 6). Приведенные в технической документации характеристики демонстрируют высокую чувствительность сенсора не только к перекрестному газу водороду, но и к колебаниям температуры и относительной влажности воздуха. Применение предложенного способа должно позволить снизить погрешности измерения детектируемого угарного газа при отклонении параметров среды от нормальных условий.

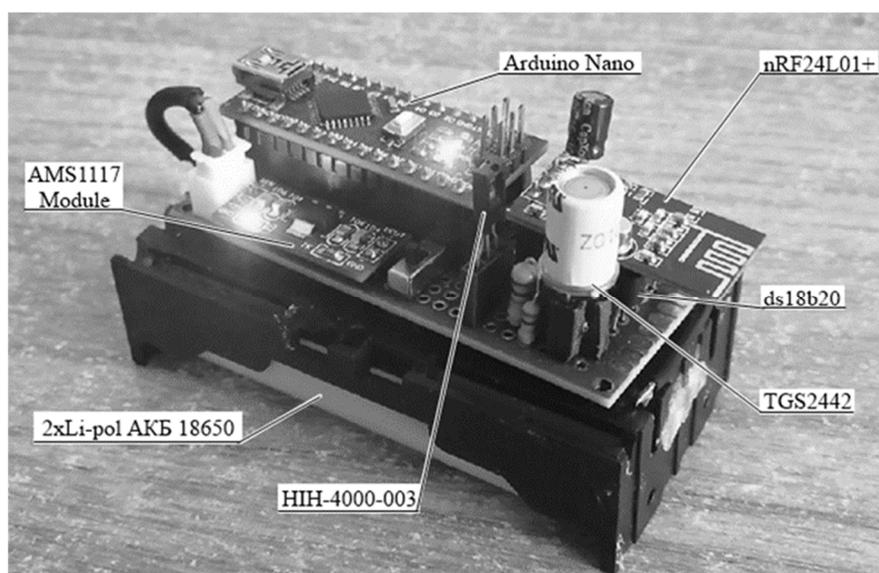


Рис. 3. Измерительный модуль: **ds18b20** – датчик температуры, **НИН-4000-003** – датчик влажности, **TGS2442** – сенсор угарного газа

Исследования проводились в два основных этапа. На первом этапе осуществлялась разработка нейронной модели полупроводниковых сенсоров для вспомогательного модуля, на втором – нейронной модели основного модуля для совместной обработки информации, поступающей от сенсорной части ГС. При разработке нейронных моделей

пользовались общими рекомендациями по выбору начального значения числа нейронов в скрытом слое и по оценке объема обучающих данных n [22]:

$$n = \frac{w}{\varepsilon},$$

где w – число настраиваемых коэффициентов сети; ε – величина ошибки.

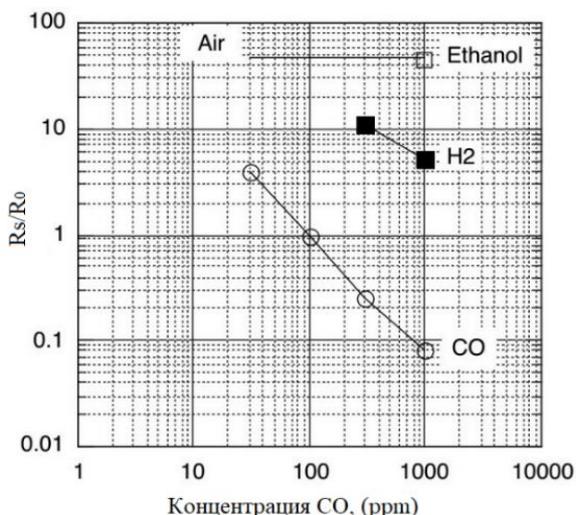


Рис. 4. Характеристика чувствительности сенсора TGS2442 к детектируемому угарному газу и перекрестному газу (водороду): R_s/R_0 – выходной сигнал сенсора, определяем отношением измеренного сопротивления к сопротивлению сенсора при концентрации CO 100 ppm

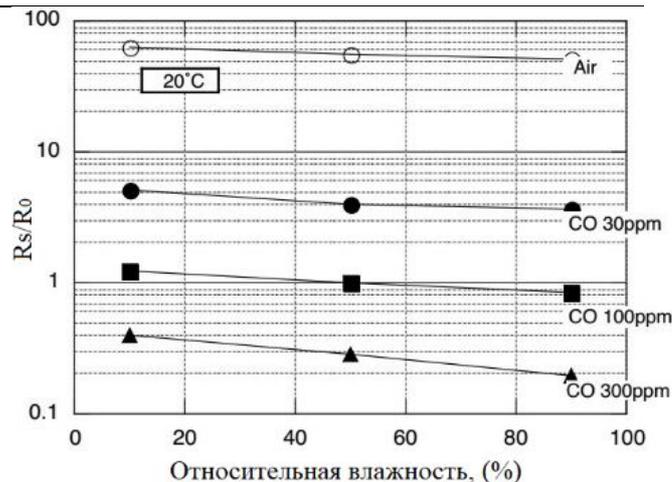


Рис. 6. Характеристика чувствительности сенсора TGS2442 к колебаниям относительной влажности

Общими при разработке двух модулей являлись задачи поиска оптимальной структуры ИНС и оптимального состава и объема обучающих данных. Методика поиска оптимальной структуры ИНС заключалась в постепенном наращивании числа нейронов в скрытом слое до достижения требуемого уровня максимальной относительной погрешности на тестовой выборке. При достижении целевого значения осуществлялось контрольное увеличение числа нейронов в скрытом слое и в случае, если не отмечалось значительного снижения уровня погрешности, фиксировалось предыдущее значение.

Вторая задача была направлена на уменьшение объема обучающих данных за счет варьирования числа тренировочных примеров по каждому из влияющих на сигнал факторов. Как только по одному из влияющих факторов наблюдался рост уровня погрешностей, число тренировочных примеров по нему фиксировалось.

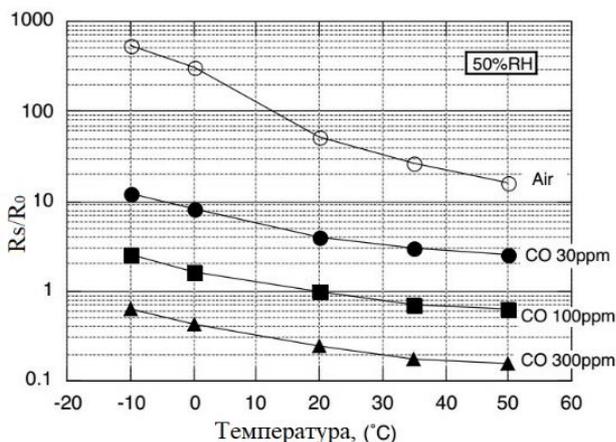


Рис. 5. Характеристика чувствительности сенсора TGS2442 к колебаниям температуры

Многослойная сеть прямого пространства обучалась по 3 раза для каждого набора обучающих данных. Для оценки эффективности обучения сети использовались тестовые выборки, включающие в себя значения влияющих факторов, отсутствующие в обучающих данных. В процессе обучения сети, с помощью встроенной функции *MATLAB*, осуществлялся контроль «эффекта переобучения».

За исходную структуру нейронной модели полупроводниковых сенсоров была взята структура 4-3-1, где четыре нейрона во входном слое соответствуют четырем воздействующим факторам, таким как влажность (*RH*), температура (*T*), детектируемый и перекрестный газы. Число нейронов в выходном слое выбирается равным единице и соответствует целевому сигналу сенсора. Исходный объем обучающей выборки составил три тысячи двести значений. Наилучший результат был получен для структуры нейронной модели 4-6-1, по прохождению двух тысяч эпох максимальная относительная погрешность не превышала 5%, среднее квадратическое отклонение 0,14%.

Результаты и их обсуждение

Исследования проводились численным методом в среде *MATLAB* с использованием специализированного программного пакета по нейронным сетям *Neural*

Networks Toolbox. Базовой для исследований являлась архитектура ИНС прямого распространения, функция активации (ФА) нейронов входного и скрытого слоев – сигмоида, выходного – линейная ФА.

По вышеописанной методике были получены оптимальные объемы и составы обучающих данных для трех типовых полупроводниковых сенсоров угарного газа *TGS2442*, водорода *TGS821* и метана *TGS2612-D00*. Результаты эксперимента представлены в табл. 1.

Анализ полученных результатов демонстрирует возможность применения унифицированной нейронной модели полупроводниковых сенсоров структурой 4-6-1, относительная погрешность δ воспроизведения характеристик сенсоров которой не превышает 5,0 %.

Анализ результатов показал, что объем обучающей выборки может быть значительно снижен за счет уменьшения тренировочных примеров по зависимостям выходного сигнала сенсора от температуры и влажности. Наибольший вклад в объем обучающих данных вносятся основные зависимости, представляющие собой функции сигналов сенсора от концентраций детектируемых газов.

Показано, что для повышения эффективности обучения сети воспроизводить основную зависимость следует увеличивать частоту тренировочных примеров по краям диапазона характеристики.

Таблица 1. Результаты эксперимента по оптимизации объема (n) и состава обучающих данных для нейронных моделей сенсоров

Воспроизводимая характеристика	Диапазон	n	δ , %	СКО / MSE, %
Сенсор водорода <i>TGS821</i>				
1- $S(H_2)$	30 – 100 <i>ppm</i>	70	3,74	0,19
	100 – 1000 <i>ppm</i>	130	2,65	
	1000 – 3000 <i>ppm</i>	350	0,92	
2 – $S(CO)$	30 – 3000 <i>ppm</i>	300	3,1	0,19
3 – $S(RH)$	30 - 90 %	50	2,6	1,25
4 – $S(T)$ при $RH=35\%$	-10 - +40 °C	50	1,84	0,33
5 – $S(T)$ при $RH=65\%$		50	3,63	0,91
6 – $S(T)$ при $RH=95\%$		50	1,68	0,52
Сенсор угарного газа <i>TGS2442</i>				
1 – $S(CO)$	30 – 100 <i>ppm</i>	300	3,12	0,15
	100 – 1000 <i>ppm</i>	250	4,85	
	1000 – 3000 <i>ppm</i>	700	2,03	
2 – $S(H_2)$	30 – 3000 <i>ppm</i>	500	0,73	0,11
3 – $S(RH)$ при $C_{co}=30$ <i>ppm</i>	35 - 90 %	100	0,70	0,38
4 – $S(RH)$ при $C_{co}=1000$ <i>ppm</i>		100	1,05	0,39
5 – $S(RH)$ при $C_{co}=300$ <i>ppm</i>		200	0,92	0,54
6 – $S(T)$ при $C_{co}=30$ <i>ppm</i>	-10 - +40 °C	100	1,0	0,14
7 – $S(T)$ при $C_{co}=100$ <i>ppm</i>		200	1,8	0,28
8 – $S(T)$ при $C_{co}=300$ <i>ppm</i>		200	0,73	0,36
Сенсор метана <i>TGS2612-D00</i>				
1 – $S(CH_4)$	10 – 100 <i>ppm</i>	100	1,6	0,15
	100 – 5000 <i>ppm</i>	25		
2 – $S(H_2)$	10 – 5000 <i>ppm</i>	125	1,0	0,23
3 – $S(RH)$ при $C_{CH_4}=5000$ <i>ppm</i>	35 - 90 %	100	3,6	0,27
4 – $S(T)$ при $RH=35$ %	-10 - +50 °C	100	1,0	0,14
5 – $S(T)$ при $RH=65$ %		100	3,0	0,15
6 – $S(T)$ при $RH=95$ %		100	1,1	0,11

Состав и объем обучающих данных напрямую зависит от экстраполяционных возможностей ИНС, в связи с чем в

данной работе были проведены соответствующие исследования. С этой целью, в обучающих данных намеренно

сужались границы диапазонов изменения факторов, влияющих на сигнал сен-

сора, а тестирование осуществлялось во всем рабочем диапазоне.

Таблица 2. Исследование экстраполяционных возможностей ИНС

Воспроизводимая характеристика	Диапазон обучающих данных	Диапазон тестовых данных	δ , %	СКО / MSE, %
1- $S(H_2)$	50 - 2500 ppm	30 - 3000 ppm	4,80	1,52
2 - $S(CO)$			3,91	1,21
3 - $S(RH)$	45 - 80 %	35 - 90 %	2,72	2,05
4 - $S(T)$ при $RH=35\%$	-5 - +30 °C	-10 - +40 °C	4,12	2,27
5 - $S(T)$ при $RH=65\%$			1,27	0,58
6 - $S(T)$ при $RH=95\%$			2,32	1,21

Полученные значения максимальной относительной погрешности (менее 5%) воспроизведения данных, отсутствующих в обучающей выборке и выходящих за ее границы, позволяют судить об удовлетворительных экстраполяционных свойствах ИНС.

На следующем этапе с помощью нейронных моделей сенсоров генерировались обучающие, тестирующие и контрольные (контроль «эффекта переобучения») данные для проведения экспериментальных исследований по оптимизации структуры и оценки эффективности применения основного модуля ИНС с целью отстройки от перекрестной чувствительности газовых сенсоров и подавления влияния колебаний пара-

метров воздушной среды в газоаналитических системах.

Апробация проводилась на газоаналитической системе угарный газ-водород. На рис. 7 представлена обобщенная структура ИНС основного модуля.

Поиск оптимальной структуры ИНС и объема обучающих данных осуществлялся по описанной выше методике для нейронных моделей вспомогательного модуля (табл. 3).

В табл. 4 представлены результаты тестирования ИНС структурой 4-6-2. Эксперимент показал, что число коэффициентов в структуре ИНС 4-2-2 недостаточно для решения поставленной задачи, для структуры 4-8-2 проявляется «эффект переобучения» сети.

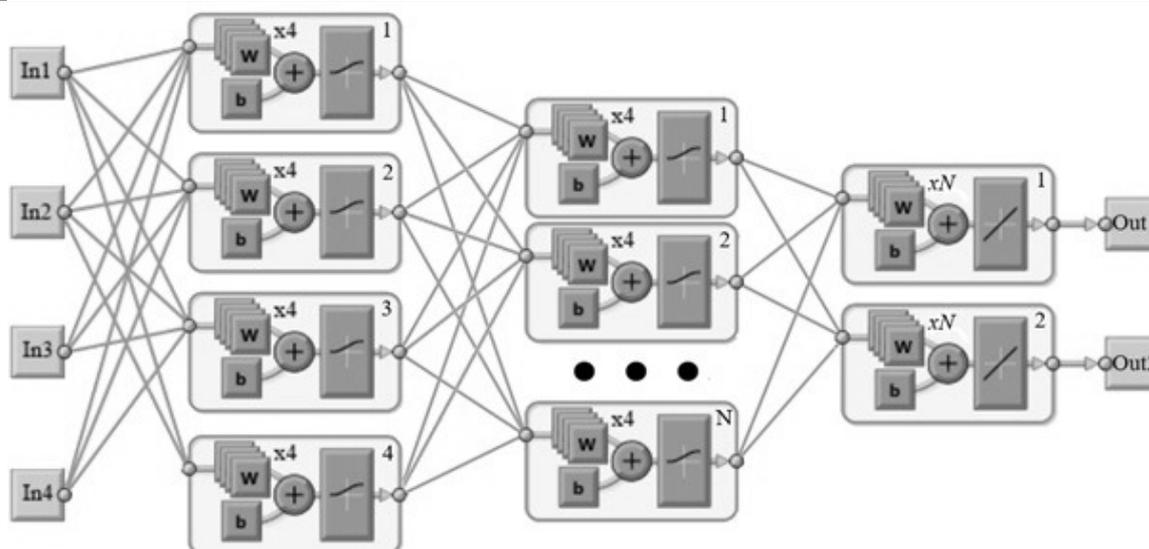


Рис. 7. Обобщенная структура ИНС основного модуля: **In** – входы сети, на которые подаются сигналы сенсоров; **Out** – выходы сети, соответствующие концентрациям газов

Таблица 3. Результаты поиска оптимальной структуры ИНС для основного модуля

Table 3. Search results for the optimal ANN structure for the main module

Структура ИНС	n	Пройдено эпох обучения (макс. 3000) /	δ , %	СКО / MSE, %
4-2-2	2200	2351	162,0	2,1
4-4-2	2200	3000	18,3	0,37
	1200	3000	23,3	0,2
	700	3000	25,0	0,5
4-6-2	2200	3000	14,1	0,21
	1200	3000	6,3	0,24
	700	3000	6,5	0,32
	600	3000	3,8	0,28
	500	3000	6,2	0,37
4-8-2	2200	3000	13,1	0,13
	1200	2835	18,3	0,15
	700	471	28,5	0,56

Таблица 4. Результаты тестирования ИНС структурой 4-6-2

Детектируемый газ	Условия тестирования	δ , %/ Δ , ppm	СКО / MSE, %
CO	$C_{CO}=30 - 3000 \text{ ppm}$, $C_{H_2}=0 \text{ ppm}$, $RH=50\%$, $T=25^{\circ}C$	3,80 %	0,21
	$C_{CO}=0 \text{ ppm}$, $C_{H_2}=30 - 3000 \text{ ppm}$, $RH=50\%$, $T=25^{\circ}C$	0,83 ppm	-
	$C_{CO}=30 \text{ ppm}$, $C_{H_2}=0 \text{ ppm}$, $RH=35-95 \%$, $T=25^{\circ}C$	0,9 %	0,4
	$C_{CO}=100 \text{ ppm}$, $C_{H_2}=0 \text{ ppm}$, $RH=35-95 \%$, $T=25^{\circ}C$	0,5 %	0,4
	$C_{CO}=300 \text{ ppm}$, $C_{H_2}=0 \text{ ppm}$, $RH=35-95 \%$, $T=25^{\circ}C$	0,3 %	0,2
	$C_{CO}=30 \text{ ppm}$, $C_{H_2}=0 \text{ ppm}$, $RH=50 \%$, $T=-10-+40^{\circ}C$	3,0 %	1,7
	$C_{CO}=100 \text{ ppm}$, $C_{H_2}=0 \text{ ppm}$, $RH=50 \%$, $T=-10-+40^{\circ}C$	3,6 %	0,8
	$C_{CO}=300 \text{ ppm}$, $C_{H_2}=0 \text{ ppm}$, $RH=50 \%$, $T=-10-+40^{\circ}C$	0,8 %	0,2
H ₂	$C_{CO}=30 - 3000 \text{ ppm}$, $C_{H_2}=0 \text{ ppm}$, $RH=50\%$, $T=25^{\circ}C$	0,46 ppm	-
	$C_{CO}=0 \text{ ppm}$, $C_{H_2}=30 - 3000 \text{ ppm}$, $RH=50\%$, $T=25^{\circ}C$	3,4 %	0,28
	$C_{CO}=0 \text{ ppm}$, $C_{H_2}=100 \text{ ppm}$, $RH=35 - 95\%$, $T=25^{\circ}C$	0,8	0,6
	$C_{CO}=0 \text{ ppm}$, $C_{H_2}=100 \text{ ppm}$, $RH=35\%$, $T=-10-+40^{\circ}C$	2,1	1,2
	$C_{CO}=0 \text{ ppm}$, $C_{H_2}=100 \text{ ppm}$, $RH=65\%$, $T=-10-+40^{\circ}C$	3,9	1,5
	$C_{CO}=0 \text{ ppm}$, $C_{H_2}=100 \text{ ppm}$, $RH=95\%$, $T=-10-+40^{\circ}C$	1,0	2,8

Наилучший результат показала нейронная сеть структурой 4-6-2, для которой проводились дополнительные исследования по снижению объема обучающих данных. Получен следующий оптимальный объем и состав обучающих данных:

1. $S(CO)$ – 200 точек;

2. $S(H_2)$ – 200 точек;

3. $S(RH)$ – 100 точек;

4. $S(T)$ – 100 точек.

На рис. 8-11, в виде графиков, представлены результаты тестирования нейронной сети основного модуля по каналу угарного газа при нормальных условиях и влияниях факторов окружающей среды.

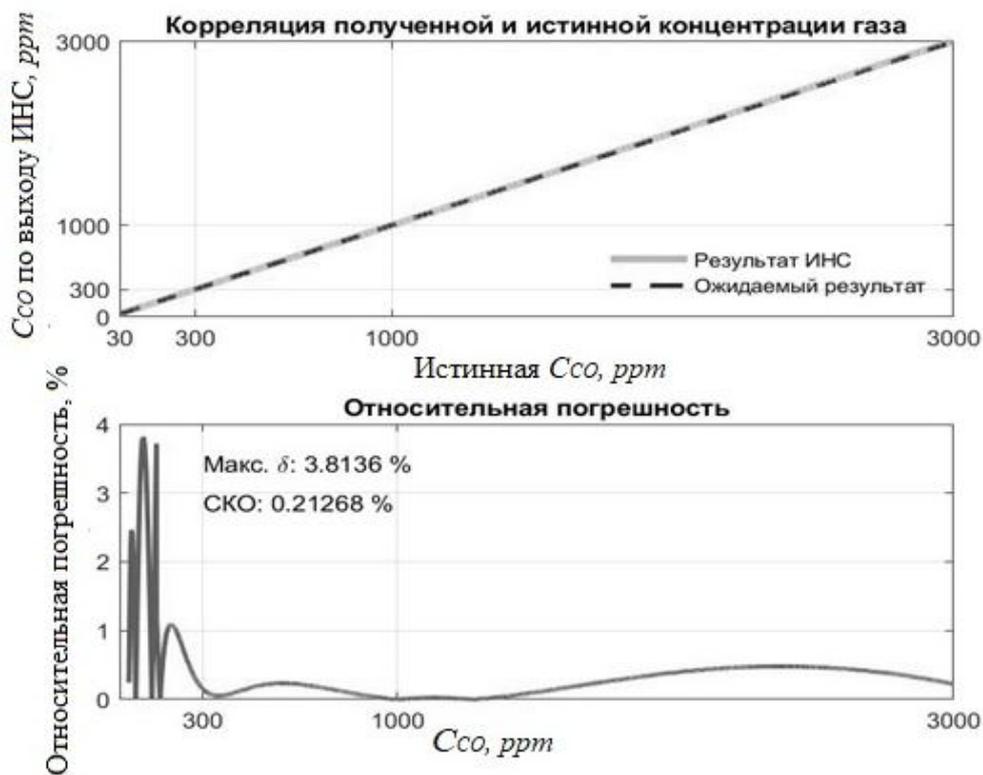


Рис. 8. Тестирование ИНС основного модуля определять концентрацию угарного газа при нормальных условиях

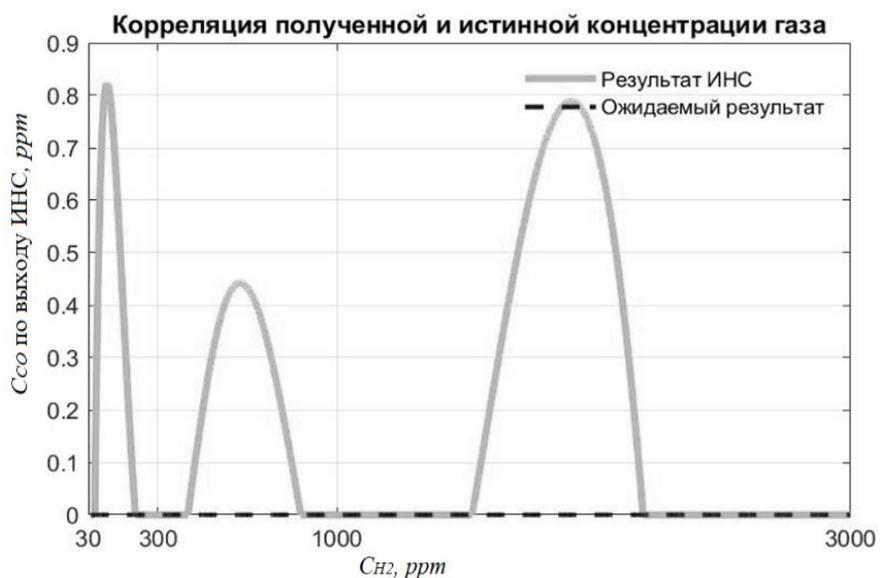


Рис. 9. Тестирование ИНС основного модуля обеспечивать отстройку от перекрестного газа – водорода в диапазоне 30 – 3000 ppm

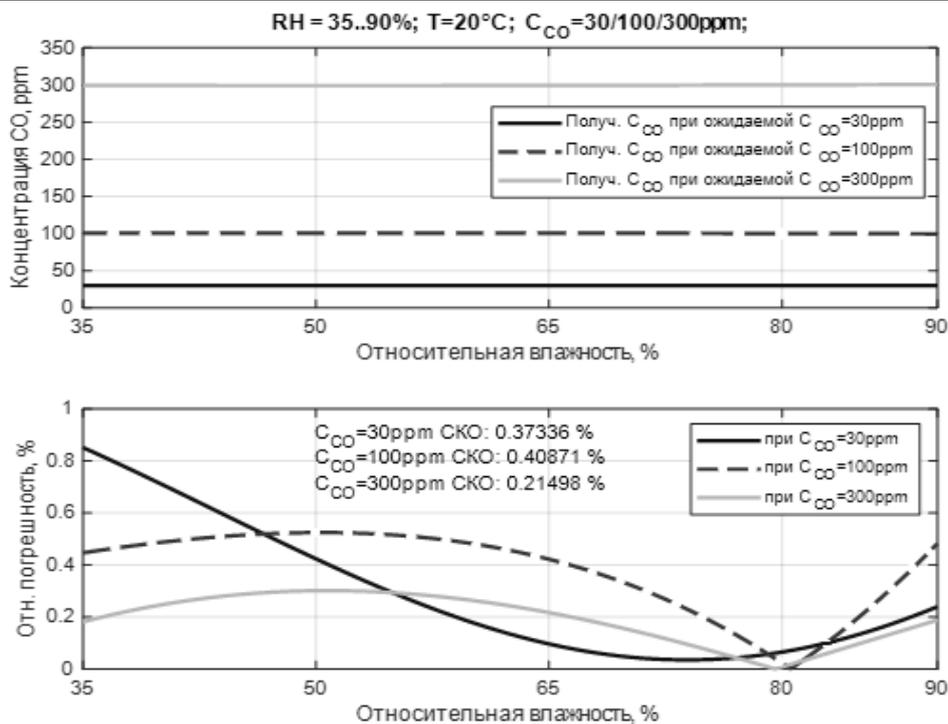


Рис. 10. Тестирование ИНС основного модуля обеспечивать отстройку от влияния влажности в диапазоне 35-90% в присутствии 30, 100, 3000 ppm CO

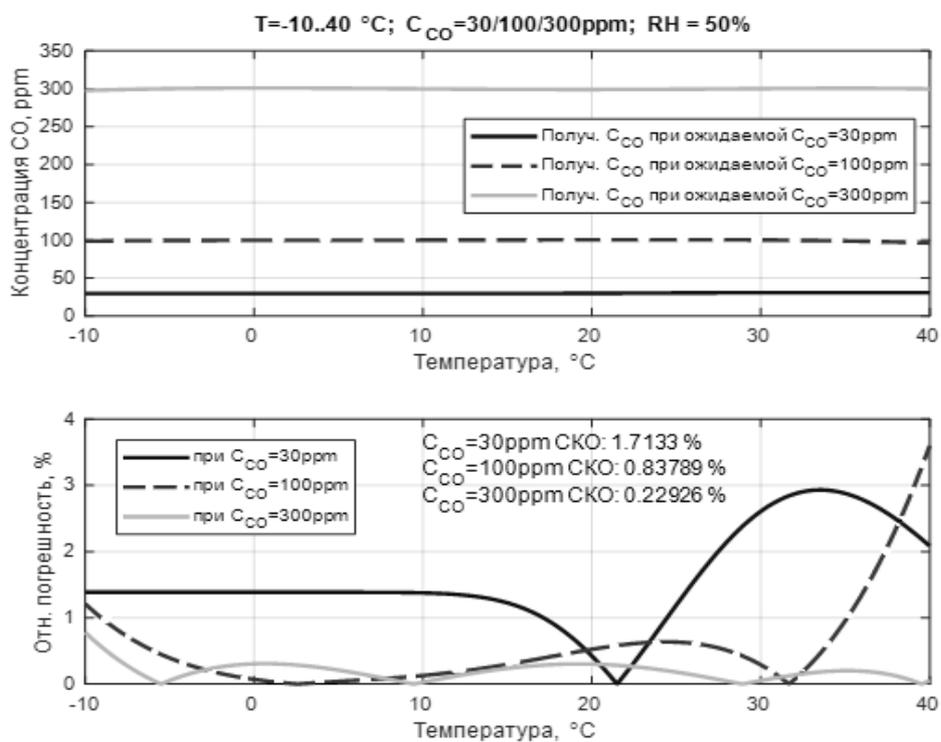


Рис. 11. Тестирование ИНС основного модуля обеспечивать отстройку от влияния температуры в диапазоне -10 - +40 °C в присутствии 30, 100, 3000 ppm CO

В табл. 5 представлены результаты сравнения погрешностей, предложенного двухмодульного нейросетевого спо-

соба обработки информации с аналогами, отдельно для вспомогательного и основного модулей [11, 21, 23].

Таблица 5. Результаты сравнения с аналогами

Table 5. Comparison results with peers

Источники погрешностей		Вспомогательный модуль		Основной модуль		
		Математические модели	Нейронная модель	ГС на основе высокоселективных сенсоров	ГС на основе полупроводниковых сенсоров	ГС на основе ИНС
Основная погрешность, % ($C_{пер}=0$ ppm, $RH=50\%$, $T=25^{\circ}C$)	C_{CO}	5,0	4,85	15,0	5,0	3,8
	C_{H2}	0,9	2,03	15,0	-	3,4
Погрешности при появлении перекрестного газа ($C_{пер}=30 - 3000$ ppm), %		-	-	<30, (6,7 привед. погр.)	47,0 ppm (абсолютная)	0,83 ppm
Погрешности от изменения влажности окружающей среды ($RH=35-95\%$), %		16,0	1,8	18,0	18,0	0,9
Погрешности от изменения температуры окружающей среды ($T=-10-+40^{\circ}C$), %		29,0	1,05	37,5	58,0	3,6
Быстродействие, с		-	-	30,0	8,0	8,0
Срок службы, мес.		-	-	36,0	60,0	60,0

Выводы

Описан двухмодульный нейросетевой способ обработки информации в ГС. К особенностям стоит отнести использование двух последовательных модулей нейронных сетей для генерации обучающих данных и обработки сигналов сенсоров. В программе *MATLAB* с использованием специализированного программного пакета по нейронным сетям *Neu-*

ral Networks Toolbox методом численного моделирования проведены экспериментальные исследования по выбору оптимальных структур ИНС и объема и состава обучающих данных. Показано, что оптимальный вклад в объем обучающих данных вносят зависимости выходных сигналов сенсоров от концентраций детектируемых газов. В ходе экспериментальных исследований рассчитаны погрешности генерации обу-

чающих данных с помощью ИНС (менее 5%) и определения концентраций детектируемых газов в условиях коле-

бания параметров воздушной среды и состава газовой смеси (менее 4%).

Список литературы

1. Ayodele B.V., Khan M.R., Nooruddin S.S. et al. Modelling and optimization of syngas production by methane dry reforming over samarium oxide supported cobalt catalyst: response surface methodology and artificial neural networks approach // *Clean Techn Environ Policy*. 2017. Vol. 19. P. 1181–1193.

2. Газовые сенсоры для измерений концентрации вредных веществ: особенности применения / В. М. Тележко, М. В. Тютчев, М. В. Аверьянова, А. Д. Паранин, Е. В. Хойна // *Измерительная техника*. 2021. №10. С. 65–71.

3. Tin dioxide nanoparticles with high sensitivity and selectivity for gas sensors at sub-ppm level of hydrogen gas detection / ХТ. Yin, WD. Zhou, J. Li et al. // *J Mater Sci: Mater Electron*. 2019. Vol. 30. P. 14687–14694.

4. Light enhanced room temperature resistive NO₂ sensor based on a gold-loaded organic–inorganic hybrid perovskite incorporating tin dioxide / Y. Chen, X. Zhang, Z. Liu et al. // *Microchim Acta*. 2019. Vol. 47.

5. Cerium-doped SnO₂ nanomaterials with enhanced gas-sensitive properties for adsorption semiconductor sensors intended to detect low H₂ concentrations / G. Fedorenko, L. Oleksenko, N. Maksymovych et al. // *J Mater Sci*. 2020. Vol. 55. P. 16612–16624.

6. Oleksenko L.P., Maksymovych N.P. Sensors for CO Based on Semiconductor Nanomaterials Pd/SnO₂// *Theor Exp Chem*. 2019. Vol. 55. P. 201–206.

7. Bondar O. G., Brezhneva E. O., Pozdnyakov V. V. Methods and Algorithms for Control of a Thermocatalytic Hydrogen Sensor // *Measurement Techniques*, 2018. Vol. 61. № 5. P. 514-519.

8. Анисимов О.В. Исследование отклика тонкопленочного сенсора на основе оксида олова в импульсном режиме для различных газов // *Известия вузов. Физика*. 2006. №3. С. 186-187.

9. Khaldi S., Dibi Z. Neural Network Technique for Electronic Nose Based on High Sensitivity Sensors Array // *Sens Imaging*. 2019. Vol. 15.

10. Анищенко Ю.В., Гусельников М.Э. Контроль аварийных выбросов в атмосферу // *Известия Самарского научного центра Российской академии наук. Специальный выпуск «Безопасность. Технологии. Управление»*. 2009. С.9-14.

11. Гусельников М.Э., Кротова Ю.В. Разработка полупроводникового газоанализатора // *Безопасность жизнедеятельности*. 2008. №1. С. 50-52.
12. Кавалеров Б.В., Бахирев И.В., Килин Г.А. Использование нейронных сетей для управления газотурбинными установками малой и средней мощности // *Российская электротехника*. 2019. №90. С. 737–740.
13. Cao X., Suganthan P.N. Video shot motion characterization based on hierarchical overlapped growing neural gas networks // *Multimedia Systems*. 2003. Vol. 9. P. 378–385.
14. Three-day forecasting of greenhouse gas CH₄ in the atmosphere of the Arctic Belyy Island using discrete wavelet transform and artificial neural networks / A. Rakhmatova, A. Sergeev, A. Shichkin et al. // *Neural Comput & Applic*. 2021. Vol. 33. P. 10311–10322.
15. Cretu AM., Chagnon-Forget M., Payeur P. Selectively densified 3D object modeling based on regions of interest detection using neural gas networks // *Soft Comput*. 2017. Vol. 21. P. 5443–5455.
16. Марковников Н. М., Кипяткова И. С. Аналитический обзор интегральных систем распознавания речи // *Тр. СПИИРАН*. 2018. № 58. С. 77–110.
17. Воевода А.А., Романников Д.О. Синтез нейронной сети для решения логико-арифметических задач // *Тр. СПИИРАН*. 2018. № 58. С. 77–110.
18. Winkler D.A. Neural networks as robust tools in drug lead discovery and development // *Mol Biotechnol*. 2004. Vol. 27. P. 139–167.
19. Wang X., Cao W. Non-iterative approaches in training feed-forward neural networks and their applications // *Soft Comput*. 2018. Vol. 22. P. 3473–3476.
20. Wójcik P.I., Kurdziel M. Training neural networks on high-dimensional data using random projection // *Pattern Anal Applic*. 2019. Vol. 22. P. 1221–1231.
21. Брежнева Е.О. Многофакторное моделирование функции преобразования металллоксидных датчиков СО // *Датчики и Системы*. 2012. №4. С.64-69.
22. Swingler K. *Applying neural networks: A practical guide*. London: Academic Press, 1996. 345 p.
23. Drägerwerk AG & Co. KGaA: официальный сайт. URL: https://www.draeger.com/ru_ru/Safety/Portable-Gas-Detectors (дата обращения: 20.12.2021)

Информация об авторах

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

Ботиков Константин Алексеевич, студент кафедры Космического приборостроения и систем связи, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: botikov.03@mail.ru

Поляков Николай Владимирович, студент кафедры Космического приборостроения и систем связи, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: nikera2016@mail.ru