

УДК 004.7

ВАРИАНТ ПОСТРОЕНИЯ СИСТЕМЫ РАСПОЗНАВАНИЯ УГРОЗ ПО ЗАПАХУ

Т.М. Татарникова^a, М.А. Елизаров^b

^a Санкт-Петербургский государственный университет аэрокосмического приборостроения, Санкт-Петербург, 190000, Российская Федерация

^b Санкт-Петербургский государственный экономический университет, Санкт-Петербург, 191023, Российская Федерация

Адрес для переписки: tm-tatarn@yandex.ru

Информация о статье

Поступила в редакцию 27.09.17, принята к печати 30.10.17

doi: 10.17586/2226-1494-2017-17-6-1092-1099

Язык статьи – русский

Ссылка для цитирования: Татарникова Т.М., Елизаров М.А. Вариант построения системы распознавания угроз по запаху // Научно-технический вестник информационных технологий, механики и оптики. 2017. Т. 17. № 6. С. 1092–1099. doi: 10.17586/2226-1494-2017-17-6-1092-1099

Аннотация

Предмет исследования. Предложено новое решение к построению системы детектирования угроз по запаху. Разработан алгоритм обучения нейронной сети, решающей задачу распознавания опасных веществ по запаху. Приведены результаты эксперимента по подбору гиперпараметров нейронной сети, ее архитектуры и тестирования.

Используемые подходы. Система детектирования представляет собой комплексное решение, позволяющее обеспечить безопасность жизни и деятельности человека путем обнаружения угроз по запаху. Комплексность решения реализуется выбором платформы технологии Интернета вещей и нейронной сети, решающей задачу распознавания.

Основные результаты. Предложен новый подход к построению системы детектирования угроз по запаху, что позволяет совершенствовать технологии обеспечения безопасности жизни и деятельности людей.

Продемонстрирована работоспособность предлагаемого решения на макете, что позволяет применять технологию Интернета вещей при реализации подобных систем и разворачивать их работу на любой территории, в том числе и труднодоступных участках. Продемонстрирована сходимость результатов обученной нейронной сети с тестовыми множествами концентрации опасных веществ в воздухе. **Практическая значимость.** Система детектирования угроз по запаху может быть полезна как элемент комплексного решения по обеспечению безопасности людей на любой территории в зависимости от поставленных задач. Система детектирования опасных веществ по запаху доведена до макета, позволяющего обнаруживать такие угрозы как утечка бензола, бутана, метана, пропана и возгорание на ранней стадии.

Ключевые слова

безопасность человека, детектирование угроз по запаху, система детектирования, Интернет вещей, макет системы, нейронная сеть, обучение с учителем, распознавание угроз

VARIANT OF ODOR SYSTEM FOR THREATS RECOGNITION

T.M. Tatarnikova^a, M.A. Elizarov^b

^a Saint Petersburg State University of Aerospace Instrumentation, Saint Petersburg, 190000, Russian Federation

^b Saint Petersburg State University of Economics, Saint Petersburg, 191023, Russian Federation

Corresponding author: tm-tatarn@yandex.ru

Article info

Received 27.09.17, accepted 30.10.17

doi: 10.17586/2226-1494-2017-17-6-1092-1099

Article in Russian

For citation: Tatarnikova T.M., Elizarov M.A. Variant of odor system for threats recognition. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2017, vol. 17, no. 6, pp. 1092–1099 (in Russian). doi: 10.17586/2226-1494-2017-17-6-1092-1099

Abstract

Subject of Research. The paper deals with a new design solution for the odor recognition system aimed at detecting threats. An algorithm for neural network training that solves the problem of recognizing dangerous substances by odor is developed. We present experiment results on the selection of neural network hyper parameters, its architecture and testing. **Methods.** The detection system is a comprehensive solution that gives the possibility to ensure the safety of life and human activity applying odor detection of threats. The solution complexity is realized by technology platform choice of the Internet of things

and the neural network that solves recognition problem. **Main Results.** We propose a new approach to creation of odor system for detecting threats that makes it possible to improve technologies for ensuring the safety of life and people's activities. The working capacity of the proposed solution is demonstrated on the layout. It shows the possibility to use the technology of the Internet of things at the system implementation stage and to deploy their work on any territory, including hard-to-reach areas. The convergence of the results of the trained neural network with test sets of concentrations of hazardous substances in the air is shown. **Practical Relevance.** The odor system for threats detection can be useful as an element of an integrated solution to ensure the safety of people on any territory, depending on the tasks assigned. The odor detection system for dangerous substances has been brought to the layout, which makes it possible to detect such threats as the leakage of benzene, butane, methane, propane and the ignition at an early stage.

Keywords

human security, odor threats detection, detection system, Internet of things, system layout, neural network, supervised learning, threat recognition

Введение

Безопасность и противодействие терроризму является одной из основных проблем современности и актуальных направлений деятельности государства и общества [1].

Одним из признаков, указывающим на возникновение такого типа угроз является запах. Существующие технологические решения обнаружения угроз террористического характера по запаху, например, детектор пороха в аэропорту или система «электронный нос» представляют собой портативные приборы локального назначения [2].

В настоящей работе предлагается технология построения системы детектирования веществ по запаху, основанная на концепции Интернета вещей (Internet of Things, IoT).

На концептуальном уровне система детектирования представляет собой разновидность беспроводной сенсорной сети с топологией типа «звезда» [3–6] и состоит из следующих типов узлов: сенсорный узел (СУ), шлюз, центральный узел (рис. 1).

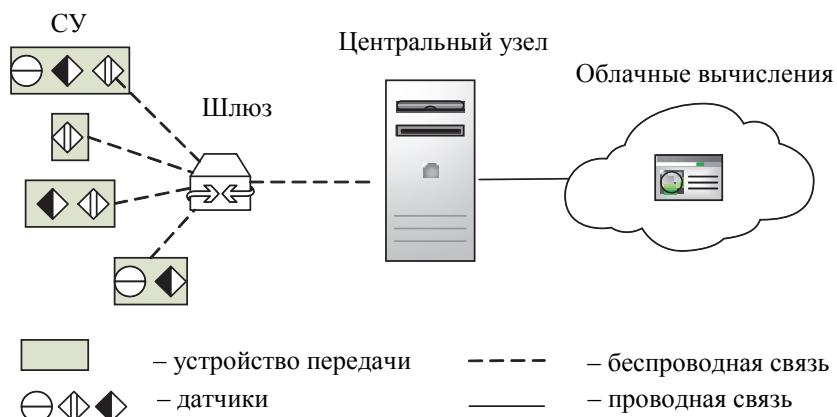


Рис. 1. Узлы системы детектирования

Сенсорное устройство представляет собой прибор передачи, к которому подключен один или несколько датчиков газа, позволяющих обнаруживать различные угрозы. Шлюз – это узел, выполняющий функции агрегации данных, поступающих от множества СУ с последующей их передачей на центральный узел и обеспечения связи между узлами системы [7, 8]. Взаимодействие между сенсорными узлами и шлюзом осуществляется по технологии Bluetooth, между шлюзом и центральным узлом – по Wi-Fi, соответственно шлюз должен поддерживать обе технологии [9, 10]. Центральный узел – это узел, выполняющий функции сервера [11–13], и представляет собой программное обеспечение на компьютере, реализующее доступ к веб-интерфейсу для оператора системы детектирования.

Предлагаемая система детектирования реализована в виде макета на платформе Genuino 101 и является цепью из сенсорного, агрегирующего и центрального устройств. Набор датчиков представлен полупроводниковыми датчиками серии MQ производства Winsen Electronics Technology Co Ltd: датчик MQ-3 реагирует на пары спирта, что позволяет детектировать такие угрозы как, например, утечка бензола на предприятии (бензол – крайне опасное летучее вещество, сильный канцероген и при больших концентрациях в воздухе взрывоопасен); датчик MQ-5 реагирует на природный газ (бутан, метан, пропан); датчик MQ-7 реагирует на монооксид углерода (угарный газ) и водород, что позволяет обнаруживать возгорания на ранней стадии. Программное обеспечение для СУ написано средствами Arduino IDE. Данные с датчиков собираются в аналоговом виде и представлены как числа от 0 до 1024. Передача данных происходит через Bluetooth low energy с помощью библиотеки Genuino 101 CurieBLE. Аппаратная реализация шлюза выполнена на платформе Intel Edison, поддерживающей технологии Bluetooth low energy и Wi-Fi, а программная средствами программной платформы Node.js. Центральное устройство реализовано как ло-

кальный сервер на компьютере [14, 15] средствами программной платформы Node.js. Кроме обработки поступающих данных сервер также обеспечивает работу простого веб-приложения оператора системы детектирования [16]. Основная функция сервера – распознавание запаха, представляющего опасность. Распознавание выполняется нейронной сетью, реализованная как приложение сервера [17]. Измерение концентрации вещества в воздухе реализуется изменением отношения Rs/Ro показаний датчика, где Rs – сопротивление датчика при определении им концентрации газа в окружающей среде, Ro – сопротивление датчика, измеренное при определенной концентрации детектируемого газа. Далее сигнал поступает на аналогово-цифровой преобразователь и подается на блок регистрации, где формируется входной вектор нейронной сети.

Характеристики нейронной сети и алгоритм ее обучения

Тип нейронной сети – многослойный персептрон. Количество слоев и нейронов в каждом слое определяется экспериментальным путем. Функция активации $f(x)$ нейрона – сигмоидальная:

$$f(x) = \frac{1}{1 + e^{-\alpha x}},$$

где x – значение сигнала, приходящего на вход нейрона; α – коэффициент, задающий угол наклона функции. Входами нейронной сети будут данные, поступающие от сенсорных устройств. Длина выходной последовательности равна количеству запахов, которые должна распознавать сеть, плюс один вектор для

неизвестного системе запаха. Алгоритм обучения нейронной сети – обучение с учителем. Процесс обучения состоит из предъявления на вход нейронной сети тренировочных сетов, представляющих собой образцы запахов.

Алгоритм обучения состоит из следующих шагов.

Шаг 1. Инициализация случайных значений весов нейронной сети.

Шаг 2. Запись тренировочного сета на вход нейронной сети.

Шаг 3. Запуск нейронной сети в режиме прямого прохода и запись полученной выходной последовательности.

Шаг 4. Определение ошибки отклонения (дельта) выходного слоя:

$$\delta_{\text{вых}} = (i - a) f'(x),$$

где i – целевые значения выходного слоя; a – полученные значения выходного слоя; $f'(x)$ – производная функции активации.

Шаг 5. Определение дельта всех скрытых слоев:

$$\delta_{\text{скр}} = f'(x) \sum_{i=1}^n w_i \delta_i,$$

где w_i – исходящий вес связи; δ_i – дельта слоя, связанного при помощи первого параметра.

Шаг 6. Расчет градиента $(j+1)$ слоя:

$$f_{j+1}^j = \delta_{j+1} i_j,$$

где δ_{j+1} – дельта $(j+1)$ слоя, для которого веса связи являются входными; i_j – значения j -го слоя для которого веса связи являются выходными.

Шаг 7. Корректировка веса:

$$\Delta w_i = Ef_w + \varphi \Delta w_{i-1},$$

где E – скорость обучения; f_w – градиент веса w ; φ – момент обучения; Δw_{i-1} – значение, на которое изменился вес на предыдущей итерации.

Шаг 8. Обновление веса:

$$w_i = w_{i-1} + \Delta w_i.$$

Шаг 9. Повторение шагов 2–9, пока сеть не обучится распознавать вещества по запаху с допустимым уровнем среднеквадратичной ошибки (MSE)

$$\text{MSE} = \frac{\sum_{j=1}^n (i_j - a_j)^2}{n},$$

где n – количество итераций (эпох) обучения; i_j – ожидаемый ответ.

Выбор архитектуры нейронной сети

Выбор архитектуры нейронной сети заключается в подборе гиперпараметров, таких как [18]:

- количество нейронов во входном I и выходном O слоях;
- количество скрытых слоев H ;

- количество нейронов в каждом из скрытых слоев;
- скорость обучения сети;
- момента обучения сети;
- количество эпох, в течение которых сеть будет проходить обучение.

По результатам экспериментов, представленным ниже, была построена нейронная сеть с архитектурой, которая приведена рис. 2. Согласно результатам экспериментов, нейронная сеть с такой архитектурой показала наименьшее значение MSE из других возможных.

Сеть состоит из 9 нейронов во входном слое I , одного скрытого слоя H , включающего в себя 12 нейронов, 4 нейрона в выходном слое O .

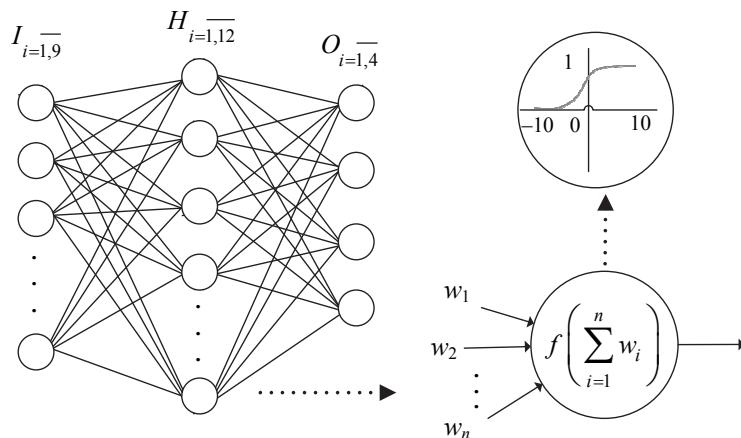


Рис. 2. Архитектура нейронной сети

Первая серия экспериментов проводилась с целью подбора значения скорости и момента обучения нейронной сети. В экспериментах участвовали нейронные сети со всеми комбинациями следующих гиперпараметров:

- количество нейронов во входном слое: {3, 5, 7, 9};
- количество нейронов в выходном слое: {2, 3, 4};
- количество скрытых слоев: 1;
- количество нейронов в скрытом слое: {4, 6, 8, 10, 12, 14};
- скорости обучения: { 10^{-5} , 10^{-4} , 10^{-3} , 0,01, 0,05, 0,1, 0,15, 0,5, 0,75};
- моменты обучения: { 10^{-7} , 10^{-6} , 10^{-5} , 10^{-4} , 10^{-3} , 0,01, 0,05, 0,1, 0,15, 0,5, 0,75};
- количество эпох: 100 000;
- нейроны смещения присутствуют.

На рис. 3 приведен график тенденции изменения MSE от момента обучения φ , из которого видно, что наименьшее конечное MSE получается для $\varphi=0,75$, однако разница между конечным и минимальным MSE гораздо выше, чем у $\varphi=0,5$. Это свидетельствует о том, что при $\varphi=0,75$ функция попала в локальный минимум. Таким образом, лучшим результатом является $\varphi=0,5$. Оно же будет являться коэффициентом корректировки весов на предыдущей итерации.

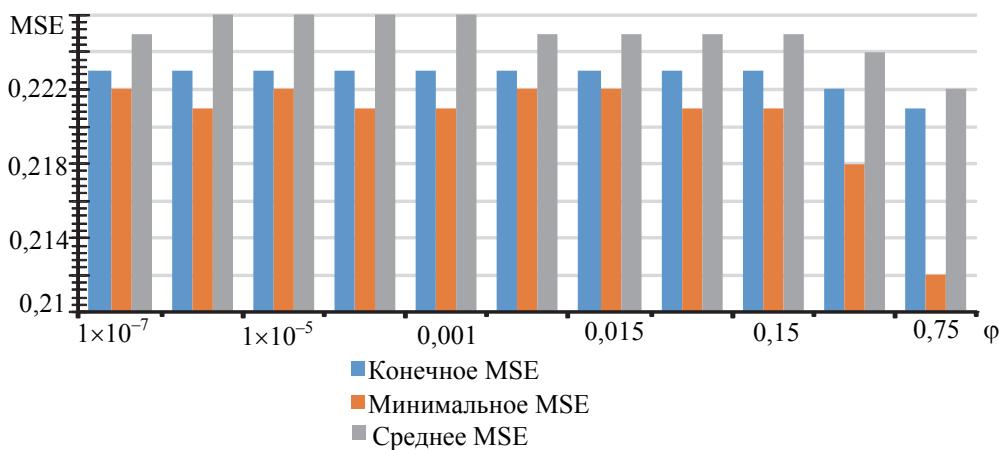


Рис. 3. Диаграмма зависимости среднего значения среднеквадратичной ошибки от момента обучения

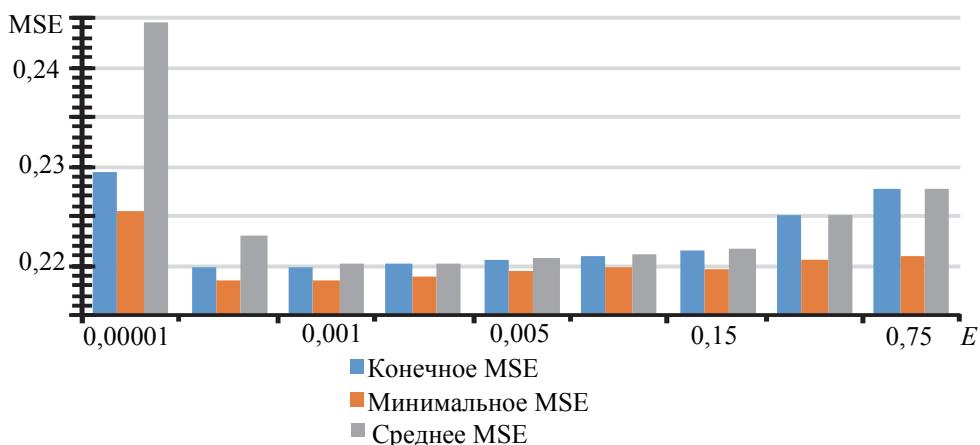


Рис. 4. Диаграмма зависимости среднего значения среднеквадратичной ошибки от скорости обучения

На рис. 4 приведена диаграмма зависимости среднего значения MSE от скорости обучения E , из которой видно, что при $E=10^{-5}$ сеть имеет наибольшее значение MSE и наибольшую разницу между средним и конечным значением MSE. Это может свидетельствовать о том, что за заданное количество эпох сеть не успела обучиться. В диапазоне скорости обучения от 0,5 до 0,75 видно, что нейронная сеть дошла до одного из множества локальных минимумов, однако не смогла обучиться, так как из-за высокой скорости не смогла подобрать веса. Результаты эксперимента показали, что наилучшим выбором для скорости обучения являются значения 0,001–0,05.

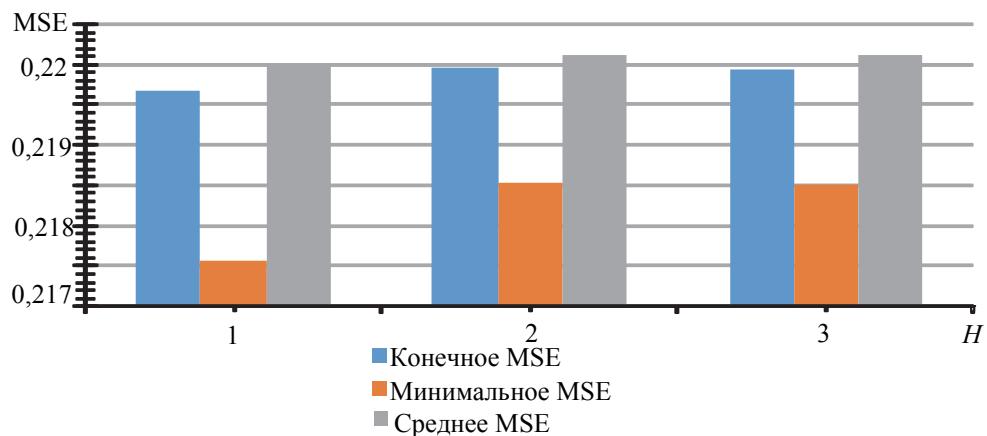


Рис. 5. Диаграмма зависимости среднего значения среднеквадратичной ошибки от количества скрытых слоев

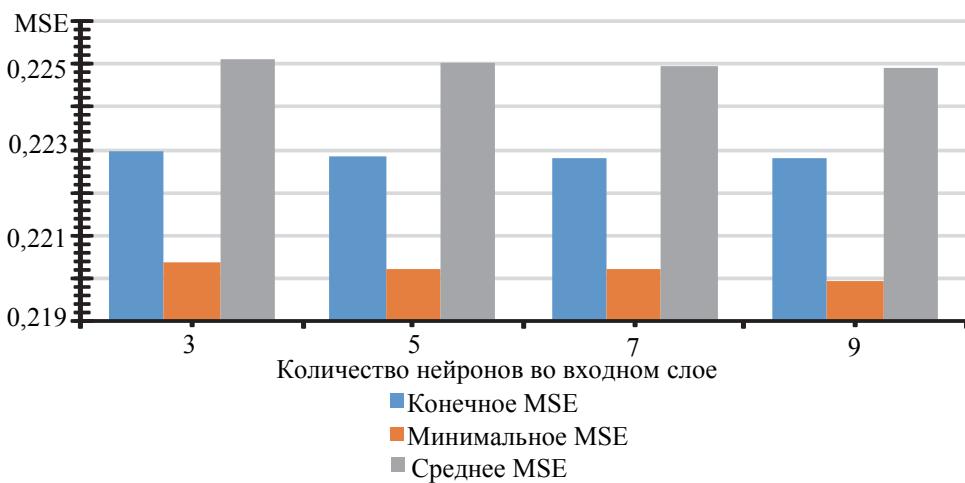


Рис. 6. Диаграмма зависимости среднеквадратичной ошибки от размера входного слоя

Целью второй серии экспериментов было подобрать количество скрытых слоев, количество нейронов в скрытых и входном слоях. На рис. 5 приведена диаграмма зависимости среднего значения MSE

от количества скрытых слоев, из которой видно, что в среднем конечная MSE оказалась ниже, чем у нейронов с большим количеством слоев, однако разница между минимальным и конечным достаточно велика, чтобы сказать, что сеть близка к обучению. При сравнении графиков двух и трех скрытых слоев видно, что разница приблизительно одинакова, что свидетельствует о том, что данная архитектура меньше подвержена попаданиям в локальные минимумы. Лучшим вариантом в конкретном эксперименте будет сеть с одним скрытым слоем.

Диаграмма, приведенная на рис. 6, показывает зависимости MSE от размера входного слоя, из которой можно определить необходимое число нейронов во входном слое для лучшего обучения. Результаты говорят о том, что MSE не сильно зависит от количества нейронов во входном слое, однако, чем их больше, тем по большему числу признаком сеть будет способна распознать объект.

На рис. 7 приведена диаграмма зависимости среднего значения MSE от количества нейронов в скрытом слое, из нее видно, что конечное значение MSE на всех экспериментах было приблизительно равным. В таком случае следует обратить внимание на минимальное значение MSE. Таким образом, по результатам второго эксперимента следует выбирать между шестью и четырнадцатью нейронами.

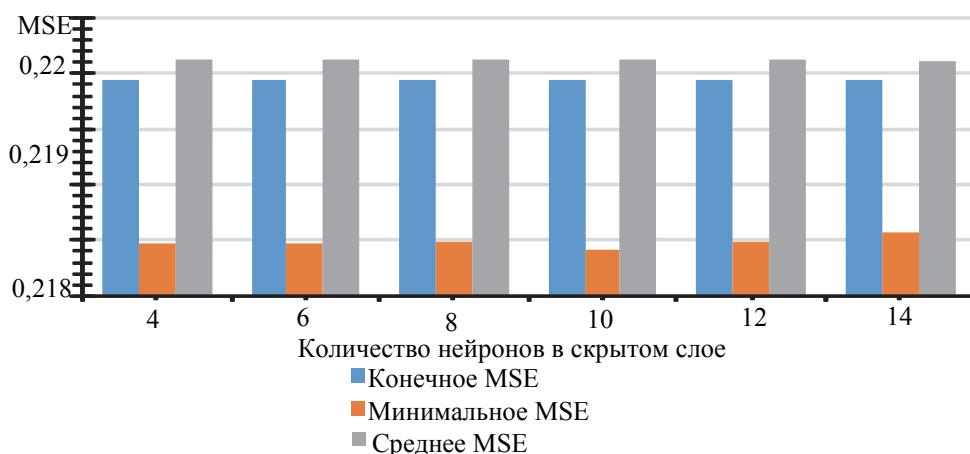


Рис. 7. Диаграмма зависимости среднего значения среднеквадратичной ошибки от количества нейронов в скрытом слое

Тестирование нейронной сети

Следующим этапом является тестирование, которое позволяет определить качество обучения сети [19]. Тестирование нейронной сети происходит на тестовых сетях. Тестовые сети представляют собой специально подготовленные последовательности, отображающие значение на выходе нейронной сети при немного уменьшенной концентрации вещества.

В таблице приведены значения тренировочных сетов, которые использовались при обучении нейронной сети.

Вещество	Концентрация, мг/л	Тестовые сети, Rs/Ro	Тренировочные	MSE, %
Метан	0,98	0,953576739	0,934567318	0,0176
Метан	0,95	0,925571325	0,934567318	0,4249
Метан	0,91	0,944998448	0,934567318	0,4718
Угарный газ	0,98	0,613585345	0,592465487	0,3408
Угарный газ	0,95	0,590015396	0,592465487	0,4966
Угарный газ	0,91	0,601478379	0,592465487	0,2504
Хлор	0,98	0,221434676	0,213243545	0,0161
Хлор	0,95	0,204423444	0,213243545	0,4831
Хлор	0,91	0,210278622	0,213243545	0,4845
Неизвестный	0,02	0,024312478	0,024312478	0,0094

Таблица. Тестовые выборки нейронной сети

По результатам, представленным в таблице, можно сделать вывод, что при подаче на вход вещества из базы знаний, но с концентрацией меньшей на 2–9%, на сеть подаются входные значения, близкие по величине с тренировочными сетами. Значение MSE не превышает одного процента.

Заключение

Предложенный в работе подход к построению системы детектирования опасных веществ по запаху на базе платформы Интернета вещей по технологии исполнения является новым решением в области разработки физических систем безопасности.

Система детектирования может найти применение во многих отраслях, таких как экология, безопасное производство, охранные системы и многих других.

Разработанный макет системы детектирования опасных веществ по запаху демонстрирует функциональные возможности предлагаемого решения и позволяет обнаруживать такие угрозы как утечка бензола, бутана, метана, пропана и возгорания на ранней стадии.

Для распознавания опасных веществ по запаху предложена нейронная сеть, архитектура которой выбрана экспериментальным путем под известное (заданное) количество распознаваемых запахов, максимальная ошибка обучения составила 0,5%.

Литература

1. Р 78.36.026-2012. Рекомендации по использованию технических средств обнаружения, основанных на различных физических принципах, для охраны огражденных территорий и открытых площадок. Москва, 2012. 182 с.
2. Долгополов Н.В., Яблоков М.Ю. «Электронный нос» – новое направление индустрии безопасности // Мир и безопасность. 2007. № 3. С. 54–59.
3. Hersent O., Boswarthick D., Elloumi O. *The Internet of Things: Key Applications and Protocols*. Willey, 2012. 370 p.
4. Recommendation Y.2060. Overview of Internet of Things. Geneva: ITU-T, 2012. 22 p.
5. Кутузов О.И., Татарникова Т.М. Инфокоммуникационные сети. Моделирование и оценка вероятностно-временных характеристик. СПб.: ГУАП, 2015. 381 с.
6. Кутузов О.И., Татарникова Т.М. Моделирование систем и сетей телекоммуникаций. СПб.: РГГМУ, 2012. 134 с.
7. Tatarnikova T., Kolbanev M. Statement of a task corporate information networks interface centers structural synthesis // IEEE EUROCON 2009. St. Petersburg, 2009. Art. 5167903. P. 1883–1887. doi: 10.1109/EURCON.2009.5167903
8. Кутузов О.И., Сергеев В.Г., Татарникова Т.М. Коммутаторы в корпоративных сетях. Моделирование и расчет. СПб.: Судостроение, 2003. 170 с.
9. Татарникова Т.М. Структурный синтез центра сопряжения корпоративных сетей // Информационно-управляющие системы. 2015. № 3. С. 92–98. doi: 10.15217/issn1684-8853.2015.3.9
10. Татарникова Т.М., Елизаров М.А. Модель оценки временных характеристик при взаимодействии в сети Интернета вещей // Информационно-управляющие системы. 2017. №2. С. 44–50. doi: 10.15217/issn1684-8853.2017.2.44
11. Богатырев В.А., Богатырев С.В. Резервированная передача данных через агрегированные каналы в сети реального времени // Известия высших учебных заведений. Приборостроение. 2016. Т. 59. № 9. С. 735–740. doi: 10.17586/0021-3454-2016-59-9-735-740
12. Богатырев В.А., Кармановский Н.С., Попцова Н.А., Паршутина С.А., Воронина Д.А., Богатырев С.В. Имитационная модель поддержки проектирования инфокоммуникационных резервированных систем // Научно-технический вестник информационных технологий, механики и оптики. 2016. Т. 16. № 5(105). С. 831–838. doi: 10.17586/2226-1494-2016-16-5-831-838
13. Богатырев В.А. Оптимальное резервирование системы разнородных серверов // Приборы и системы. Управление, контроль, диагностика. 2007. № 12. С. 30–36.
14. IEEE Std 802.11-2007. IEEE Standard for Information Technology-Telecommunications and information exchange between systems - Local and metropolitan area network - Specific requirements Part 11: Wireless LAN Medium Access Control (MAC) and Physical Layer (PHY) specifications. IEEE, 2007. 1232 p.
15. Recommendation Y.2063. Framework of the WEB of Things. Geneva, ITU-T, 2012, 30 p.

References

1. R 78.36.026-2012 *Recommendations on the Use of Detection Technology, based on Various Physical Principles, for the Protection of Fenced Areas and Open Spaces*. Moscow, 2012, 182 p. (In Russian)
2. Dolgopolov N.V., Yablokov M.Yu. Electronic nose - a new direction of the security industry. *Mir i Bezopasnost'*, 2007, no. 3, pp. 54–59. (In Russian)
3. Hersent O., Boswarthick D., Elloumi O. *The Internet of Things: Key Applications and Protocols*. Willey, 2012, 370 p.
4. *Recommendation Y.2060*. Overview of Internet of Things. Geneva, ITU-T, 2012, 22 p.
5. Kutuzov O.I., Tatarnikova T.M. *Infocommunication Networks. Simulation and Evaluation of Probability-Time Characteristics*. St. Petersburg, SUAI Publ., 2015, 381 p. (In Russian)
6. Kutuzov O.I., Tatarnikova T.M. *Modelling of Systems and Telecommunication Networks*. St. Petersburg, RGGMU Publ., 2012, 134 p. (In Russian)
7. Tatarnikova T., Kolbanev M. Statement of a task corporate information networks interface centers structural synthesis. *IEEE EUROCON 2009*. St. Petersburg, 2009, art. 5167903, pp. 1883–1887. doi: 10.1109/EURCON.2009.5167903
8. Kutuzov O.I., Sergeev V.G., Tatarnikova T.M. *Switches in the Corporate Networks. Simulation and Calculation*. St. Petersburg, Sudostroenie Publ., 2003, 170 p. (In Russian)
9. Tatarnikova T.M. Structural synthesis of an interface center for corporate networks. *Informatsionno-Upravlyayushchie Sistemy*, 2015, no. 3, pp. 92–98. (In Russian) doi: 10.15217/issn1684-8853.2015.3.9
10. Tatarnikova T.M., Elizarov M.A. Model of estimating temporal characteristics of IoT Network interaction. *Informatsionno-Upravlyayushchie Sistemy*, 2017, no. 2, pp. 44–50. (In Russian) doi: 10.15217/issn1684-8853.2017.2.44
11. Bogatyrev V.A., Bogatyrev S.V. Redundant data transmission using aggregated channels in real-time network. *Journal of Instrument Engineering*, 2016, vol. 59, no. 9, pp. 735–740. doi: 10.17586/0021-3454-2016-59-9-735-740
12. Bogatyrev V.A., Karmanovsky N.S., Poptcova N.A., Parshutin S.A., Voronina D.A., Bogatyrev S.V. Simulation model for design support of infocomm redundant systems. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2016, vol. 16, no. 5, pp. 831–838. (In Russian) doi: 10.17586/2226-1494-2016-16-5-831-838
13. Bogatyrev V.A. An optimum backup execution for the heterogeneous server system. *Instruments and Systems: Monitoring, Control, and Diagnostics*, 2007, no. 12, pp. 30–36. (In Russian)
14. IEEE Std 802.11-2007. IEEE Standard for Information Technology-Telecommunications and information exchange between systems - Local and metropolitan area network - Specific requirements Part 11: Wireless LAN Medium Access Control (MAC) and Physical Layer (PHY) specifications. IEEE, 2007, 1232 p.
15. *Recommendation Y.2063*. Framework of the WEB of Things. Geneva, ITU-T, 2012, 30 p.

- Geneva: ITU-T, 2012. 30 p.
16. Bonomi F., Mulito R., Zhu J., Addepalli S. Fog computing and its role in the internet of things // Proc. 1st ACM Mobile Cloud Computing Workshop. Helsinki, 2012. P. 13–15. doi: 10.1145/2342509.2342513
 17. Kellmereit D., Obodovski D. The Silent Intelligence: The Internet of Things. DND Ventures, 2013. 166 p.
 18. Тархов Д.А. Нейросетевые модели и алгоритмы. Справочник. М.: Радиотехника, 2014. 352 с.
 19. Рутковская Д., Пилинский М., Рутковский Л. Нейронные сети, генетические алгоритмы и нечеткие системы. М.: Горячая линия-Телеком, 2013. 384 с.
 16. Bonomi F., Mulito R., Zhu J., Addepalli S. Fog computing and its role in the internet of things. *Proc. 1st ACM Mobile Cloud Computing Workshop*. Helsinki, 2012, pp. 13–15. doi: 10.1145/2342509.2342513
 17. Kellmereit D., Obodovski D. *The Silent Intelligence: The Internet of Things*. DND Ventures, 2013, 166 p.
 18. Tarkhov D.A. *Neural Network Models and Algorithms. Handbook*. Moscow, Radiotekhnika Publ., 2014, 352 p. (In Russian)
 19. Rutkovskaya D., Pilin'skii M., Rutkovskii L. *Neural Networks, Genetic Algorithms and Fuzzy Systems*. Moscow, Goryachaya Liniya-Telekom, 2013, 384 p.

Авторы

Татарникова Татьяна Михайловна – доктор технических наук, доцент, профессор, Санкт-Петербургский государственный университет аэрокосмического приборостроения, Санкт-Петербург, 190000, Российская Федерация, tm-tatarn@yandex.ru

Елизаров Максим Анореевич – аспирант, Санкт-Петербургский государственный экономический университет, Санкт-Петербург, 191023, Российская Федерация, elizarovmaks@gmail.com

Authors

Tatiana M. Tatarnikova – D.Sc., Associate Professor, Professor, Saint Petersburg State University of Aerospace Instrumentation, Saint Petersburg, 190000, Russian Federation, tm-tatarn@yandex.ru

Maxim A. Elizarov – postgraduate, Saint Petersburg State University of Economics, Saint Petersburg, 191023, Russian Federation, elizarovmaks@gmail.com