

С. Сингх, А.В. Прибыльский

АЛГОРИТМ КЛАССИФИКАЦИИ ПОЖАРООПАСНЫХ СИТУАЦИЙ НА ОСНОВЕ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ

Современные технологические требования и развивающаяся городская инфраструктура ставят задачу разработки методов распознавания и классификации пожароопасных ситуаций. Быстрое и эффективное распознавание начальных признаков возгорания становится жизненно важным аспектом обеспечения безопасности людей, а также материальных ценностей. В связи с этим разрабатываются, реализуются, тестируются и внедряются системы, способные автоматически распознавать и классифицировать пожароопасные ситуации. Классификация пожароопасных ситуаций позволяет определить степень опасности обнаруженных отклонений, что способствует к принятию более эффективных решений по предотвращению последствий пожаров и их признаков таких как, однократное кратковременное повышение температуры и уровня задымленности которое может указывать на выход из строя электрических компонентов, расположенных возле датчиков. Алгоритм классификации пожароопасных ситуаций разработан для комплекса взаимосвязанных датчиков, который в свою очередь, за счет своей структуры, позволяет обнаруживать даже малейший признака пожара. В рамках данного исследования приводится алгоритм классификации пожароопасных ситуаций на основе нейросетевых технологий. Приведено описание существующих классов пожароопасных ситуаций, а также критерии, по которым размечались данные по указанным классам. Проведено моделирование алгоритма на обучающей и тестовой выборках с приведением используемых параметров точности, формулой их расчетов, результатами классификации пожароопасных ситуаций. Проведено исследование влияния шага отсчета в выборке базы данных на параметры точности и время обучения нейронной сети. Разработанный алгоритм реализован на языке программирования Python в IDE PyCharm. Датасет для обучения и тестирования получены из реальных источников, содержащих информацию об обнаруженных пожароопасных ситуациях в метрополитенах, в которых установлен комплекс взаимосвязанных датчиков. Результаты моделирования алгоритма показали, что предложенный алгоритм обладает высокой точностью для предиктивной классификации пожароопасных ситуаций на реальных объектах.

Пожарный датчик; Python; параметры точности; нейронные сети; классификация; моделирование; разметка данных.

S. Singh, A.V. Pribylskiy

ALGORITHM FOR CLASSIFICATION OF FIRE HAZARDOUS SITUATIONS BASED ON NEURAL NETWORK TECHNOLOGIES

Modern technological requirements and developing urban infrastructure pose the task of developing methods for recognizing and classifying fire hazardous situations. Quickly and effectively recognizing the initial signs of a fire becomes a vital aspect of ensuring the safety of people as well as property. In this regard, systems are developed, implemented, tested and implemented that can automatically recognize and classify fire hazardous situations. Classification of fire hazardous situations allows you to determine the degree of danger of detected deviations, which contributes to making more effective decisions to prevent the consequences of fires and their signs, such as a one-time short-term increase in temperature and smoke level, which may indicate failure of electrical components located near the sensors. The algorithm for classifying fire hazardous situations is developed for a complex of interconnected sensors, which in turn, due to its structure, allows you to detect even the slightest sign of fire. Within the framework of this study, an algorithm for classifying fire hazardous situations based on neural network technologies is presented. A description of existing classes of fire hazardous situations is provided, as well as the criteria by which data for these classes were marked. The algorithm was modeled on training and test samples, presenting the accuracy parameters used, the formula for their calculations, and the results of classifying fire hazardous situations. A study was carried out of the influence of the sample step in the database sample on the accuracy parameters and training time of the neural network. The developed algorithm is implemented in the Python programming language in the PyCharm IDE. The dataset for training and testing was obtained from real sources containing information about detected fire hazardous situations in sub-

ways in which a complex of interconnected sensors is installed. The results of modeling the algorithm showed that the proposed algorithm has high accuracy for predictive classification of fire hazardous situations in real objects.

Fire sensor; simulink; detection signal; standard deviation; activation function; mathematical modeling.

Введение. Современные технологические объекты такие как метрополитен или любое высокотехнологическое предприятие представляют собой совокупность технических систем различной сложности с высокими требованиями по обеспечению пожарной безопасности. Если раньше достаточно было обнаружить сам факт наличия пожара или его признаки в отслеживаемой области, то на сегодняшний день все чаще ставится задача, не только детектирование пожароопасной ситуации, но и её классификации. Текущие системы для классификации возникших отклонений используют операторов-экспертов способных, на основании собственного опыта определить класс ситуации. Поэтому в настоящий момент актуализируются задачи автоматизации процесса обнаружения и классификации аномалии пожароопасных ситуаций, с целью минимизации субъективного человеческого фактора внутри системы, тем самым ускорить и повысить эффективность принятия управленческого решения в случае возникновения нештатных ситуаций.

Решение этой задачи предлагается осуществить с помощью интеллектуальной информационной системы, которая способна осуществлять поддержку принятия решения на основе предиктивного анализа информации за короткий период времени и тем самым минимизируя влияние человеческого фактора. Интеллектуальные информационные системы используют различные методы и алгоритмы решения поставленных перед ними целей, среди этих методов решения все больше набирают популярность методы использующие нейронные сети. Ввиду своей идеи, последние имитируют нейронную систему человека, функцией памяти, что позволяет реализовать экспертное мышление, при наличии размеченной обучающей базы данных. В контексте классификации пожароопасных ситуаций, для получения корректных результатов работы нейронной сети, целесообразно при разметке обучающей базы данных использовать экспертное знание, таким образом классифицируя не только обнаруженные пожароопасные ситуации, но и ситуации, пропущенные в связи с человеческим фактором, например отсутствие оператора на рабочем месте в момент фиксации нештатной ситуации.

В работе термин «аномалия» соответствует по значению термину «пожароопасная ситуация», они оба определяются, как отклонение параметра или параметров датчика [1, 2] от типичных значений или отклонения функционального вида графика этих параметров от их типичного вида. Это значит, что обнаружение и классификация аномалий учитывает не только отклонения по значению, но и отклонения по функциональной форме, что может говорить об учетывании контекста анализируемых параметров [3–9].

Цель исследования заключается в представлении алгоритма на основе нейросетевых технологий, способного обнаруживать и классифицировать пожароопасные ситуации на фиксированные классы с заданными параметрами точности.

Алгоритм классификации. В работе для классификации используются нейросетевые технологии, которыми, в частности, являются рекуррентные нейронные сети (РНС) с долгосрочной памятью (LSTM).

Представим алгоритм классификации пожароопасных ситуаций на основе реализации с применением нейросетевых технологий [10, 11] на рис. 1.

Опишем подробнее алгоритм обучения разработанной нейронной сети:

1. Инициализация параметров: задание начальных значений для генератора случайных чисел и настройка зерна для генераторов случайных чисел модуля `python NumPy` и модуля `PyTorch`, это необходимо для повторяемости результатов обучения.
2. Чтение данных: загрузка данных датасета из CSV-файла и преобразование их в матрицу $m \times n$.
3. Нормализация данных [12–13]: преобразование данных в числовой формат с последующим применением метода нормализации входных данных посредством функции `MinMaxScaler` из модуля `sklearn`, повышающим устойчивость к вариациям данных, для более быстрой сходимости ошибки в ходе обучения нейронной сети.




Рис. 1. Структурная схема алгоритма классификации пожароопасных ситуаций на основе нейросетевых технологий

4. Подготовка данных для РНС: установка длины последовательности РНС и создание последовательности обучения [14].

5. Определение модели РНС: установка размера входных значений, т.е. количества параметров, используемых для обучения, установка размерности слоев сети, т.е. количества нейронов в скрытом слое сети, установка скрытых слоев РНС, установка количества выходов – задается количеством классифицируемых классов. Выбор критерия оптимизации Adam [15–16] и выбор функции потерь Cross-Entropy Loss [15–16], включение или выключение L2-регуляризации.

6. Обучение модели: настройка параметров обучения, задание размера мини-батчей, для оптимизации памяти во время обучения. Обучение модели на обучающих данных с использованием оптимизатора Adam и функции потерь Cross-Entropy Loss.

7. Распознавание и классификация данных: применение обученной модели к тестовым данным, что по сути является классификацией данных [17–18].

8. Отображение результатов: визуализация классифицированных данных в сравнении с реально существующими аномалиями с применением графических средств модуля matplotlib [18–20], расчет параметров точности. Более подробный расчет параметров точности можно получить в результате тестирования нейронной сети.

Упрощенная архитектура РНС представлена на рис. 2.




Рис. 2. Упрощенная архитектура рекуррентной нейронной сети классификации пожароопасных ситуаций на основе данных цифрового датчика

На рис. 2 упрощение связано с затруднением представлением полной архитектуры сети ввиду её масштабности, в частности не показываются все скрытые слои РНС [21].

Выбор классов. В рамках эксперимента осуществлялась классификация 13 пожароопасных ситуаций, нумерация классов начинается с 0:

0. Нормальные данные – аномалий в выделенном участке нет, либо они не могут быть обнаруженными с помощью данных из датчиков среднее значение температуры 10–40 градусов в зависимости от зоны размещения датчика, а значение задымленности 60 000–65 556 аналоговых отсчета.

1. Выход за пределы допустимой температуры вверх – плавное превышение температуры среднего значения на участке (10-40 градусов).

2. Выход за пределы допустимой температуры вниз - плавное снижение температуры среднего значения на участке (10-40).

3. Аномально высокие значения температуры – резкое и значительное повышение температуры более установленного значения (выше 55 градусов).

4. Выход за пределы допустимого значения задымленности вниз – плавное снижение задымленности ниже среднего значения на участке (задымленность ниже 60 000 отсчетов).

5. Дисперсия между датчиками дыма выходит за пределы определенного значения.

6. Аномальное резкое и короткое увеличение задымленности (задымленность ниже 40 000 отсчетов).

7. Выход значения температуры за определённый верхний предел, а задымленности за определённый нижний предел (температура 10-40 градусов, задымленность ниже 60 000 отсчетов).

8. Выход значения температуры за определённый нижний предел, а задымленности за определённый нижний предел (температура 10-40 градусов, задымленность ниже 60 000 отсчетов).

9. Температуры превышает критическое значение – критическое значение настраивается в зависимости от места установки (в диапазоне 40-55 градусов).

10. Высокая задымленность – задымленность выше определенного уровня (ниже 50 000 аналоговых отсчетов).

11. Температуры и дым значительно превышают норму (температуры выше 55 градусов задымленность ниже 50 000 аналоговых отсчетов).

12. Неисправность датчика – единичные значительные превышения температуры или задымленности (температура более 55 градусов и задымленность ниже 40 000 отсчетов).

Пример разметки данных представлен на рис. 3.

Дата_и_время	Темп1	Темп2	Задымленность1	Задымленность2	Задымленность2	Аномалия по темп	Аномалия по дыму	Классы
0	1	2	3	4	5	6	7	8
03.08.2022 0:55	42.79	46.79	60117	60118	60123	1	0	1
03.08.2022 0:55	42.8	46.78	60117	60118	60122	1	0	1
03.08.2022 0:55	42.82	46.78	60119	60120	60118	1	0	1
03.08.2022 0:55	42.79	46.78	60120	60120	60119	1	0	1
03.08.2022 0:55	42.79	46.8	60120	60119	60119	1	0	1
03.08.2022 0:55	42.82	46.79	60121	60121	60124	1	0	1
03.08.2022 0:55	42.82	46.74	60121	60121	60120	1	0	1
03.08.2022 0:55	42.79	46.78	60118	60118	60117	1	0	1
03.08.2022 0:55	42.81	46.76	60118	60118	60118	1	0	1
03.08.2022 0:55	42.84	46.74	60122	60123	60122	1	0	1
03.08.2022 0:55	42.78	46.76	60121	60122	60122	1	0	1
03.08.2022 0:55	42.84	46.74	60117	60119	60119	1	0	1
03.08.2022 0:55	42.84	46.81	60118	60120	60119	1	0	1
03.08.2022 0:55	42.79	46.75	60122	60119	60119	1	0	1
03.08.2022 0:55	42.82	46.79	60118	60119	60124	1	0	1
03.08.2022 0:55	42.79	46.79	60117	60123	60123	1	0	1

Рис. 3. Пример разметки данных классов

На рис. 3 во второй строке 0-8, номер столбцов соответственно. В первом столбце приведено время отсчета, 2 и 3 параметры температуры, 4-6 параметры задымленности, 7 – аномалии по температуры, 8 – аномалии по задымленности, 9 общие класс аномалии.

Результаты тестирования модели. Тестирование алгоритма предиктивной классификации выполнялось на языке программирования Python в IDE PyCharm. Оценка точности сети осуществлялась по трем параметрам: общая точность системы, точность обнаружения аномалий, ошибка обнаружения. Дополнительно ошибки обнаружения подразделяются на необнаруженные аномалии и ложные аномалии. Рассмотрим подробнее каждый из параметров.

Общая точность системы представляет собой общую эффективность классификации всех классов, включая как нормальные, так и аномальные ситуации.

Формула общей точности (Accuracy) выглядит следующим образом:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}, \quad (1)$$

где TP (True Positives) – количество верно классифицированных аномалий;

TN (True Negatives) – количество верно классифицированных нормальных ситуаций;

FP (False Positives) – количество нормальных ситуаций, неправильно классифицированных как аномалии;

FN (False Negatives) – количество аномальных ситуаций, неправильно классифицированных как нормальные.

Точность обнаружения аномалий, этот параметр измеряет способность системы обнаруживать аномалии(пожароопасные ситуации).

Формула точности обнаружения аномалий выглядит так:

$$Precision = \frac{TP}{TP + FP},$$

Ошибка обнаружения включают в себя необнаруженные аномалии (False Negatives) и ложные аномалии (False Positives).

Формула ошибки обнаружения (Detection Error) может быть представлена как:

$$Detection\ Error = \frac{FN}{TP + TN + FP + FN}. \quad (2)$$

Необнаруженные аномалии (False Negatives) – это количество аномальных ситуаций, которые были неправильно классифицированы как нормальные.

Ложные аномалии (False Positive) – это количество нормальных ситуаций, которые были неправильно классифицированы как аномалии.

Чтобы посчитать соотношение необнаруженных аномалий и ложных аномалий, которые являются составляющими ошибки обнаружения, можно использовать следующие формулы:

$$\begin{aligned} ignored &= \frac{FN}{total - total * reacted} \\ fake &= \frac{FP}{total - total * reacted} \end{aligned} \quad (3)$$

где total – общее количество отсчетов, ignored – доля необнаруженных аномалий, fake – доля ложных аномалий.

Требования к параметрам точности алгоритма классификации представлены в табл. 1

Таблица 1

Требования параметров точности

Accuracy, %	Presicion, %	Detection Error, %	ignored, %	fake, %
Не менее 90	Не менее 85	Не более 15	нет	нет

Тестирование обученной нейронной сети. В процессе тестирования нейронной сети используются две базы данных.

Первая обучающая выборка данных, содержит разделение данных по 5 параметрам: температура вне датчика, температура внутри датчика и три параметра задымленности, за основу взятые реальные данные обнаруженных аномалий в метрополитенах в местах установки комплекса взаимосвязанных датчиков. Всего в обучающую выборку вошло 126 дней, в каждом из дне содержатся метки обнаруженных аномалий, разделенных на классы. Каждый день состоит примерно из 18 часов ежесекундно записанных параметров. С целью снижения времени обучения и снижению риска возникновения переобучения, данные в базу данных заполнялись не ежесекундно, а с промежутком 5 секунд, т.к. эмпирически было выяснено, что при таком шаге заполнения показатели точности алгоритма практически не изменяются, в то время как время обучения существенно сокращается, этот эксперимент приведен в таблице, в качестве данных использовались данные первой выборки.

Таблица 2

Изменения параметров точности и времени обучения при различных шаге отсчетов данных

Шаг	Accuracy, %	Presicion, %	Detection Error, %	ignored, %	fake, %	Время обучения,с
1	99	91	9	71.65	28.35	10566
5	99	91	9	71.65	28.35	8755
10	92	86	11	77.25	22.75	6102
30	83	79	12	85.76	24.24	4652
60	75	72	15	90.22	9.78	2712

Вторая выборка данных состоит из тестовых данных их структура и подход к формированию базы данных аналогичный, отличается только размер выборки, он составляет 60 дней.

Результат моделирования представлен на рис. 3-5.




Рис. 4. График классификации данных из первой выборки




Рис. 5. График классификации данных из второй выборки

Полученные параметры точности приведены в табл. 3.

Таблица 3

Параметры точности по двум выборкам данных

Номер выборки	Accuracy, %	Presicion, %	Detection Error, %	ignored, %	fake, %
1	99	91	9	71.65	25.35
2	98.65	97.36	2.64	63.45	36.55

Приблизительно один из участков график классификации данных из первой выборки представлен на рис. 6




Рис. 6. График классификации данных на выделенном участке

Обсуждение. Анализируя полученные параметры точности после моделирования алгоритма с требованиями, поставленными в таблице, можно сделать вывод, что предложенный алгоритм классификации соответствует поставленным требованиям: accuracy (общая точность) не менее 90%, precision (точность обнаружения) не менее 85%, detection error (ошибка обнаружения) не более 15%. На обучающей выборке полученный следующие параметры точности: общая точность 99%, точность обнаружения 91%, ошибка обнаружения 9%, что не ниже поставленных требований. На тестовой выборке: общая точность 98.65%, точность обнаружения 97.36%, ошибка обнаружения 2.64%, что также не ниже поставленных требований. Исходя из полученных результатов предложенный алгоритм классификации, можно использовать для классификации данных получаемых из комплекса взаимосвязанных датчиков.

Полученные отклонения по значениям точности могут возникать из-за следующих проблем: несовершенство архитектуры нейронной сети, недостаточный размер обучающей выборки, недостаточное обучение и неправильный выбор гиперпараметров архитектуры нейронной сети. Анализ и решение этих проблем будет представлено в следующей публикации.

Заключение. Алгоритм классификации пожароопасных ситуаций с помощью нейросетевых может использоваться в качестве автоматической или автоматизированной системы классификации аномалий. Применение этого алгоритма повысит не только повысить эффективность принятия решения при обнаружении пожароопасной ситуации, но и позволяет распознавать аномалии, которые ранее не распознавались комплексом взаимосвязанных датчиков.

Дальнейшие исследования предполагают реализацию нейросетевой модели обнаружения пожароопасных ситуаций, с применением различных архитектур нейронных сетей, с целью выявления более эффективных по параметрам точности и быстродействия процесса классификации пожароопасных ситуаций посредством нейросетевых технологий.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Саутин И.Г. Противопожарная защита: технологии и решения // Транспорт, Противопожарная защита. Пожарная автоматика. Средства спасения. – 2018.
2. Саутин И.Г. Особое мнение. Можно ли доверить свою жизнь дымовому пожарному извещателю? // Алгоритм безопасности. – 2019. – № 6.
3. Ермилов А.В., Смирнов В.А. Развитие интеллектуальной составляющей управленческой компетентности начальника караула пожарно-спасательной части // Технологии техносферной безопасности. – 2017. – № 3. – С. 178-185.
4. Полежаев П.В. [и др.]. Пожары и пожарная безопасность в 2020 году: стат. сб. / под общ. ред. Д.М. Гордиенко. – М.: ВНИИПО, 2021. – 112 с.
5. Зайцев А.В. Достоверность и своевременность обнаружения пожара, и как их учесть в нормах на СПС // Алгоритм безопасности. – 2016. – № 2.
6. Иванов А.Н., Викман А.В., Уткин О.В. Применение нечеткой логики для оценки вероятности выполнения пожарными извещателями функции основного назначения // Природные и техногенные риски (физико-математические и прикладные аспекты). – 2019. – № 4 (32). – С. 48-52.
7. Проневич О.Б., Шубинский И.Б. Автоматизированная система прогнозирования пожарной безопасности объектов железнодорожного транспорта на основе оценки рисков // Надежность. – 2019. – 19 (1). – С. 48-54. – Режим доступа: <https://doi.org/10.21683/1729-2646-2019-19-1-48-54>. (дата обращения 25.01.23).
8. Иванов А.Н. К вопросу об оценке эффективности пожарной автоматики // Пожарная безопасность: современные вызовы. Проблемы и пути решения: Матер. Всерос. науч.-практ. конф. – СПб.: Ун-т ГПС МЧС России, 2021.
9. Преснов А.И. [и др.]. Пожарная техника: учеб.: в 2-х ч. Ч. 2. – СПб.: Ун-т ГПС МЧС России, 2016. – 404 с.
10. Рассел Джесси. Ассоциативная память на нейронных сетях. – М.: VSD, 2018. – 804 с.
11. Solovyeva E. Types of recurrent neural networks for non-linear dynamic system modelling // Proceedings of 2017 XX IEEE International Conference on Soft Computing and Measurements (SCM2017). – St. Petersburg: Saint-Petersburg Electrotechnical University «LETI». Russia, St. Petersburg, May 24–26, 2017. – P. 1-4.

12. Wang, Z., Yan, W., Oates, T. Time series classification from scratch with deep neural networks: A strong baseline // In: 2017 International Joint Conference on Neural Networks. – IJCNN, IEEE, 2017. – P. 1578-1585.
13. Kate R.J. Using dynamic time warping distances as features for improved timeseries classification // Data Min. Knowl. Discov. – 2016. – 30 (2). – P. 283-312.
14. Peng Y., Kondo N., Fujiura T., Suzuki T., Ouma S., Yoshioka H., Itoyama E., et al. Dam behavior patterns in Japanese black beef cattle prior to calving: Automated detection using LSTM-RNN // Comput. Electron. Agric. – 2020. – 169. – 105178.
15. Rahman A., Smith D., Little B., Ingham A., Greenwood P., Bishop-Hurley G. Cattle behaviour classification from collar, halter, and ear tag sensors // Inform. Process. Agric. – 2018. – 5 (1). – P. 124-133.
16. Abandah G., Abdel-Karim A. Accurate and fast recurrent neural network solution for the automatic diacritization of Arabic text // Jordan. J. Comp. Inform. Technol. – 2020. – 6 (2). – P. 103-121.
17. Géron A. Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems. – O'Reilly Media, 2019.
18. Google TensorFlow, TensorFlow. – <https://www.tensorflow.org/>. – 2024 (дата обращения: 22.01.2023).
19. Graves A., Mohamed A.R., Hinton G. Speech recognition with deep recurrent neural networks // In: 2013 IEEE International Conference on Acoustics, Speech and Signal Processing. – 2013. – P. 6645-6649.
20. PyTorch documentation. <https://pytorch.org/docs/stable/index.html> (дата обращения: 21.01.2023)
21. Candelaria M.D.E., Chua N.M.M., Kee S.-H. Evaluation of Heat-Induced Damage in Concrete Using Machine Learning of Ultrasonic Pulse Waves, Materials (Basel). – 2022. – 15 (22). – 7914. – <https://doi.org/10.3390/ma15227914>.

REFERENCES

1. Sautin I.G. Protivopozharnaya zashchita: tekhnologii i resheniya [Fire protection: technologies and solutions], Transport, Protivopozharnaya zashchita. Pozharnaya avtomatika. Sredstva spaseniya [Transport, Fire protection. Fire automatics. Rescue means], 2018.
2. Sautin I.G. Osoboe mnenie. Mozhno li doverit' svoyu zhizn' dymovomu pozharnomu izveshchatel'yu? [Special opinion. Can you trust your life to a smoke alarm?], Algoritm bezopasnosti [Security algorithm], 2019, No. 6.
3. Ermilov A.V., Smirnov V.A. Razvitie intellektual'noy sostavlyayushchey upravlencheskoy kompetentnosti nachal'nika karaula pozharo-spasatel'noy chasti [Development of the intellectual component of managerial competence of the chief of the guard of the fire and rescue unit], Tekhnologii tekhnosfernoy bezopasnosti [Technosphere safety technologies], 2017, No. 3, pp. 178-185.
4. Polekhin P.V. [i dr.]. Pozhary i pozharnaya bezopasnost' v 2020 godu: Sb. statey [Fires and fire safety in 2020: stat. ed.], under general ed. D.M. Gordienko. Moscow: VNIPO, 2021, 112 p.
5. Zaytsev A.V. Dostovernost' i svoevremennost' obnaruzheniya pozhara, i kak ikh uchest' v normakh na SPS [Reliability and timeliness of fire detection, and how to take them into account in the standards for fire protection systems], Algoritm bezopasnosti [Safety Algorithm], 2016, No. 2.
6. Ivanov A.N., Vikman A.V., Utkin O.V. Primenenie nechetkoy logiki dlya otsenki veroyatnosti vypolneniya pozharnymi izveshchatel'nyimi funktsii osnovnogo naznacheniya [Application of fuzzy logic to assess the probability of fire detectors performing their main function], Prirodnye i tekhnogennye riski (fiziko-matematicheskie i prikladnye aspekty) [Natural and man-made risks (physical, mathematical and applied aspects)], 2019, No. 4 (32), pp. 48-52.
7. Pronevich O.B., SHubinskiy I.B. Avtomatizirovannaya sistema prognozirovaniya pozharnoy bezopasnosti ob"ektov zheleznodorozhnogo transporta na osnove otsenki riskov [Automated system for predicting fire safety of railway transport facilities based on risk assessment], Nadezhnost' [Reliability], 2019, 19 (1), pp. 48-54. Available at: <https://doi.org/10.21683/1729-2646-2019-19-1-48-54>. (data obrashcheniya 25.01.23).
8. Ivanov A.N. K voprosu ob otsenke effektivnosti pozharnoy avtomatiki [On the issue of assessing the effectiveness of fire automatics // Fire safety: modern challenges], Pozharnaya bezopasnost': sovremennye vyzovy. Problemy i puti resheniya: materialy Vseros. nauch.-prakt. konf. [Fire safety: modern challenges. Problems and solutions: materials of the All-Russian Scientific and Practical Conference]. Saint Petersburg: Un-t GPS MCHS Rossii, 2021.
9. Presnov A.I. [i dr.]. Pozharnaya tekhnika: ucheb. [Firefighting equipment: textbook]: in 2nd part. Part 2. Saint Petersburg: Un-t GPS MCHS Rossii, 2016, 404 p.
10. Rassel Dzhessi. Assotsiativnaya pamyat' na neyronnykh setyakh [Associative memory on neural networks]. Moscow: VSD, 2018, 804 p.

11. Solovyeva E. Types of recurrent neural networks for non-linear dynamic system modeling, *Proceedings of 2017 XX IEEE International Conference on Soft Computing and Measurements (SCM2017)*. St. Petersburg: Saint-Petersburg Electrotechnical University «LETI». Russia, St. Petersburg, May 24–26, 2017, pp. 1-4.
12. Wang, Z., Yan, W., Oates, T. Time series classification from scratch with deep neural networks: A strong baseline, *In: 2017 International Joint Conference on Neural Networks. IJCNN, IEEE, 2017*, pp. 1578-1585.
13. Kate R.J. Using dynamic time warping distances as features for improved timeseries classification, *Data Min. Knowl. Discov.*, 2016, 30 (2), pp. 283-312.
14. Peng Y., Kondo N., Fujiura T., Suzuki T., Ouma S., Yoshioka H., Itoyama E., et al. Dam behavior patterns in Japanese black beef cattle prior to calving: Automated detection using LSTM-RNN, *Comput. Electron. Agric.*, 2020, 169, 105178.
15. Rahman A., Smith D., Little B., Ingham A., Greenwood P., Bishop-Hurley G. Cattle behaviour classification from collar, halter, and ear tag sensors, *Inform. Process. Agric.*, 2018, 5 (1), pp. 124-133.
16. Abandah G., Abdel-Karim A. Accurate and fast recurrent neural network solution for the automatic diacritization of Arabic text, *Jordan. J. Comp. Inform. Technol.*, 2020, 6 (2), pp. 103-121.
17. Géron A. Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems. O'Reilly Media, 2019.
18. Google TensorFlow, TensorFlow. Available at: <https://www.tensorflow.org/>. 2024 (accessed 22 January 2023).
19. Graves A., Mohamed A.R., Hinton G. Speech recognition with deep recurrent neural networks, *In: 2013 IEEE International Conference on Acoustics, Speech and Signal Processing* 2013, pp. 6645-6649.
20. PyTorch documentation. Available at: <https://pytorch.org/docs/stable/index.html> (accessed 21 January 2023).
21. Candelaria M.D.E., Chua N.M.M., Kee S.-H. Evaluation of Heat-Induced Damage in Concrete Using Machine Learning of Ultrasonic Pulse Waves, *Materials (Basel)*, 2022, 15 (22), 7914. Available at: <https://doi.org/10.3390/ma15227914>.

Статью рекомендовал к опубликованию д.т.н., профессор Ю.А. Кравченко.

Сингх Санны – Южный федеральный университет; e-mail: singkh@sfedu.ru; г. Таганрог, Россия; тел.: +79885751350; кафедра систем автоматического управления; аспирант.

Прибыльский Алексей Васильевич – e-mail: apribylsky@sfedu.ru; тел.: +79885619718; кафедра систем автоматического управления; к.т.н.; доцент.

Singh Sanni – Southern Federal University; e-mail: singkh@sfedu.ru; Taganrog, Russia; phone: +79885751350; the Department of Automatic Control Systems; graduate student.

Pribylskiy Alexey Vasilievich – e-mail: apribylsky@sfedu.ru; phone: +79885619718; the Department of Automatic Control Systems; cand. of eng. sc.; associate professor.

УДК 007.519.816

DOI 10.18522/2311-3103-2024-3-147-158

С.И. Родзин, А.В. Боженюк, Е.В. Нужнов

МЕТОД МНОГОКРИТЕРИАЛЬНОГО ГРУППОВОГО ПРИНЯТИЯ РЕШЕНИЙ В ЧРЕЗВЫЧАЙНОЙ СИТУАЦИИ С ИСПОЛЬЗОВАНИЕМ НЕЧЕТКИХ КОЛЕБЛЮЩИХСЯ МНОЖЕСТВ*

При возникновении чрезвычайной ситуации необходимо принять эффективные экстренные меры. Известно, что аварийное событие обладает характеристиками ограниченности времени и информации, вредоносности и неопределенности, а лица, принимающие решения, часто ограничены в рациональности в условиях неопределенности и риска. Психологическое поведение людей следует учитывать в реальных процессах принятия решений. Принятие решений в чрезвычайных ситуациях является актуальной задачей и предметом исследовательских интересов. В этой статье представ-

* Исследование выполнено за счет гранта Российского научного фонда № 22-71-10121, <https://rscf.ru/project/22-71-10121/> в Южном федеральном университете.