

ИНТЕЛЛЕКТУАЛЬНАЯ КЛАССИФИКАЦИЯ ПОЖАРООПАСНЫХ СИТУАЦИЙ НА ОСНОВЕ ДАННЫХ ИЗ КОМПЛЕКСА ВЗАИМОСВЯЗАННЫХ ДАТЧИКОВ

В исследовании проводится сравнение методов интеллектуальной классификации пожароопасных ситуаций на основе данных из комплекса взаимосвязанных датчиков. Рассматриваются интеллектуальные классификаторы на основе машинного обучения, статистического анализа и деревьев принятия решения с целью выявления методов, обладающих самым высоким соотношением точности к значению производительности, вычисленной с помощью F-меры, для дальнейшего использования в системе прогнозирования и классификации пожароопасных ситуаций. Проведенный анализ точности и производительности приведенных методов, показал, что наиболее точным и производительными методами оказались Random forest classifier и RNN с LSTM слоями обладающих соотношением точности к производительности 119.99 и 123.30 соответственно.

Классификация, нейронные сети, дерево решений, пожарный датчик, точность, статистический метод.

Singh Sanni, Pribylsky Alexey Vasilievich

INTELLIGENT CLASSIFICATION OF FIRE HAZARDOUS SITUATIONS BASED ON DATA FROM A COMPLEX OF INTERCONNECTED SENSORS

The study compares approaches to intelligent classification of fire hazardous situations based on data from a set of interconnected sensors. Intelligent classifiers based on machine learning, statistical analysis and decision trees are considered in order to identify methods with the highest ratio of accuracy to performance value calculated using F-measure for further use in the system for predicting and classifying fire hazardous situations. An analysis of the accuracy and performance of the above methods showed that the most accurate and productive methods were Random forest classifier and RNN with LSTM layers, with an accuracy to performance ratio of 119.99 and 123.30, respectively.

Classification, neural networks, decision tree, fire sensor, accuracy, statistic method.

Введение. Современные технологические объекты, такие как метрополитен и высокотехнологические предприятия, представляют собой сложные системы с высокими требованиями к пожарной безопасности. Ранее разработанные системы, обладали функцией обнаружения пожаров и их признаков, однако на сегодняшний день тенденции меняются в сторону не только обнаружения признаков пожара, но и их классификация. Современные системы часто полагаются на операторов-экспертов для определения пожароопасной ситуации на основе данных из пожарных датчиков, а также экспертного опыта. Это является еще одной причиной важности автоматизации процесса обнаружения и классификации пожароопасных ситуаций, чтобы минимизировать субъективный человеческий фактор и повысить эффективность принятия решений в нештатных ситуациях.

Для решения этой задачи предлагается использовать методы и алгоритмы из области интеллектуальных информационных системы, которые могут поддерживать принятие решений на основе предиктивного анализа данных, что минимизирует влияние человеческого фактора. В контексте классификации пожароопасных ситуаций, для повышения точности работы интеллектуальных методов классификации целесообразно использовать экспертные знания при создании обучающей базы данных. Это позволяет учитывать не только обнаруженные ситуации, но и те, которые могли быть пропущены из-за человеческого фактора, например, отсутствия оператора в момент возникновения нештатной ситуации или простой халатности со стороны человека. Достижение высокой точности и оперативности в классификации пожароопасных ситуаций, используются комплексы взаимосвязанных датчиков, которые собирают данные о состоянии окружающей среды.

Сравнение исследуемых интеллектуальных классификаторов осуществляется по параметрам точности и производительности, это позволяет определить, насколько эффективно предложенное решение справляется с задачей классификации пожароопасных ситуаций.

Описание комплекса взаимосвязанных датчиков. Конструктивно датчик состоит из 14 элементов [1], 8 из которых датчики температуры, 3 ультрафиолетовых датчика дыма, 3 инфракрасных датчика дыма исполненных в металлическом корпусе. Упомянутые датчики контролируется и настраивается дистанционно в режиме реального времени в том числе чувствительность и пороговые значения. Датчик выполнен таким образом,

чтобы воспринимать дым вокруг себя со всех возможных направлений [1,2], что позволяет обнаруживать дым значительно раньше стандартных пожарных датчиков по изменению плотности дыма в разных точках пространства [3]. Математическая модель датчика более подробно рассмотрена в статье [4].

Расчет точности и производительности. Для расчета точности и производительности модели, использовались следующие параметры [5-6]: точность обучающей выборки P_{train} , точность на тестовой выборке P_{test} , производительность V_{sec} и соотношение точности к производительности R_{pv} [7-8].

Точность обучающей выборки и тестовой выборки [9] рассчитывается по одной формуле, за исключением, того, что в первом случае используются данные из обучающей выборки, а во втором случае тестовые данные:

$$P_{train} = \frac{TP + TN}{TP + TN + FP + FN'} \quad (1)$$

$$P_{test} = \frac{TP + TN}{TP + TN + FP + FN'}$$

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.

Формула производительности:

$$V_{sec} = \frac{sample_size}{t_{end} - t_{start}}, \quad (2)$$

sample_size – размер классифицируемой выборки;

t_{start} – время начала выполнения модели, секунды;

t_{end} – время окончания выполнения модели, секунды.

Соотношение точности к производительности с помощью F-меры с порогом точности, чем выше это значение, тем более точная система при сохранении высокой производительности:

$$R_{pv} = \begin{cases} \frac{(1 + \beta^2) * P_{test} * V_{sec}}{\beta^2 * P_{test} + V_{sec}}, & \text{если } P_{test} \leq T \\ \frac{(1 + \beta^2) * P_{test} * (W_p * V_{sec})}{\beta^2 * (W_p * V_{sec}) + P_{test}}, & \text{если } P_{test} > T \end{cases}, \quad (3)$$

где β – параметр, определяющий вес точности по отношению к производительности, в работе принят равным 2;

T – порог точности;

W_p – дополнительный вес производительности, если точность превышает порог T , равен 2, если производительность больше 10000 и равен 0.1 если производительность меньше 10000.

Выборка данных. В процессе тестирования использовались две выборки данных обучающая и тестирующая. Первая выборка 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 за 126 прошедших дней. Вторая тестирующая выборка имеет аналогичный предыдущей состав, но количество прошедших дней в этой выборке равно 60.

Кроме того, обе выборки имеют метки пожароопасных ситуаций, зарегистрированных на реальных объектах и размеченных с использованием экспертных знаний.

Тестирование моделей. После моделирование 13 моделей классификации в IDE PyCharm с использованием модулей [10-11] skikit-learn, tensorflow, numpy, matplotlib получены следующие показатели точности и производительности (табл. 1).

Таблица 1

Показания точности различных моделей классификации

Модель	Точность на обучающей выборке, %	P_{test} , %	V_{sec} , Значений/сек	R_{pv}
Random forest classifier	99	96	198 599	119.99
Метод опорных векторов SVC	93	90.8	58	23.10
Логистическая регрессия	81	0	10 000 000	0
KNeighborsClassifier (К Ближайших средних)	95	61	15950	76.18
Гауссовский наивный байесовский	78.38	61	2 138 326	76.25
Градиентный бустинг	96.6	64	128 930	79.99
AdaBoost классификатор	96	85	90.509	31.74

BaggingClassifier	99.7	57	669104	71.25
ExtraTreesClassifier	99.9	62	46735	77.47
VotingClassifier	94.3	63	44225	78.72
StackingClassifier	98.5	21.66	60015	27.07
HistGradientBoostingClassifier	96.55	52	772738	65.00
RNN (Recurrent Neural Network) with LSTM	99	98.65	196 555	123.30

Пример работы классификатора представлен на рис. 1.

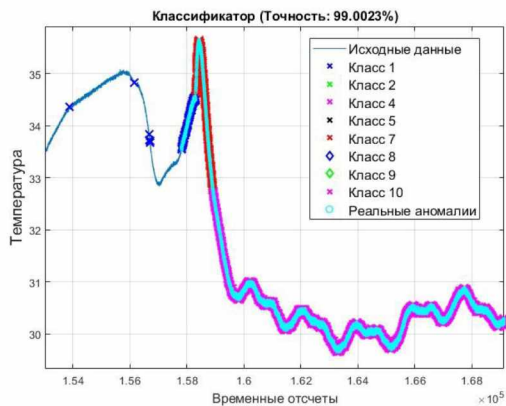


Рис. 1. Пример работы классификатора

На рис. 1, представлен график изменения температуры во времени с нанесенными на него метками реальных пожароопасных ситуаций (реальные аномалии) и распознанных пожароопасных ситуаций (класс и соответствующий ему номер).

Выводы. Исходя из полученных значений точности, производительности и соотношение точности к производительности, можно сделать вывод, что наиболее предпочтительными моделями являются Random forest classifier с параметрами: $P_{test} = 96\%$, $V_{sec} = 198\ 599$ значений/сек, $R_{pv} = 119.99$ и RNN с параметрами: $P_{test} = 98.65\%$, $V_{sec} = 196\ 555$ значений/сек, $R_{pv} = 123.30$. Соответственно данные модели можно использовать в исследовании и разработки системы прогнозирования и классификации пожароопасных ситуаций.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Саутин И. Г.* Противопожарная защита: технологии и решения // Транспорт, Противопожарная защита. Пожарная автоматика. Средства спасения, 2018 г.
2. *Саутин И. Г.* Особое мнение. Можно ли доверить свою жизнь дымовому пожарному извещателю? // Алгоритм безопасности 2019, №6.
3. *Ермилов А.В.* Развитие интеллектуальной составляющей управленческой компетентности начальника караула пожарно-спасательной части / А.В. Ермилов, В.А. Смирнов.
4. *Сингх С., Прибыльский А.В.* Синтез системы сверхбыстрого обнаружения пожароопасных ситуаций на основе комплекса взаимосвязанных датчиков // Известия ЮФУ. Технические науки. // 2024. №1
5. *Fedorov A., Bytinskaya T., Lukyanenko A., Hung T.D.* Trends in the development of automatic fire detectors. Technol. Technosphere Saf. 2009, 23, 111–114. Available online: <https://cyberleninka.ru/article/n/tendentsii-razvitiya-avtomaticheskikh-pozharnykh-izveschateley-1> (accessed on 20 December 2023).
6. *Petrov A.E., Fedorov A.V., Kochegarov A.V., Lomaev E.N., Preobrazhenskiy A.P.* The Analysis of Network Models for the Design of Industrial and Fire Safety Systems for Oil Refineries. IOP Conf. Ser. Earth Environ. Sci. 2021, 808, 012024
7. *Rahman A., Smith D., Little B., Ingham A., Greenwood P., Bishop-Hurley G.,* 2018. Cattle behaviour classification from collar, halter, and ear tag sensors. Inform. Process. Agric. 5 (1), 124–133.
8. *Иванов А.Н.* К вопросу об оценке эффективности пожарной автоматики // Пожарная безопасность: современные вызовы. Проблемы и пути решения: материалы Всерос. науч.-практ. конф. СПб.: С.-Петербург. ун-т ГПС МЧС России, 2021.
9. Пожарная техника: учеб.: в 2-х ч. / А.И. Преснов [и др.]. СПб.: С.-Петербург. ун-т ГПС МЧС России, 2016. Ч. 2. 404 с.
10. Skicit-learnt документация. href = <https://scikit-learn.org/stable/> (Дата обращения 21.05.24)
11. TensorFlow документация. href = <https://www.tensorflow.org/guide/keras?hl=ru> (Дата обращения 21.05.24).

Сингх Сани, аспирант Южного федерального университета, Россия, город Таганрог, улица Петровская 68, 347900, телефон: +7 (988) 575-13-50, email: singkh@sfedu.ru.

Прибыльский Алексей Васильевич, доцент Южного федерального университета, Россия, город Таганрог, телефон +7 988 561-97-18, email: apribylsky@sfedu.ru.

Singh Sanni, post-graduate student of Southern Federal University, 347900, Russia, city Taganrog, 68 Petrovskaya street, phone: +7 (988) 575-13-50, email: singkh@sfedu.ru.

Pribylsky Alexey Vasilievich, docent of Southern Federal University, Russia, city Taganrog, phone: +7 (988) 561-97-18, email: apribylsky@sfedu.ru.