

УДК 004.032.26:614.84

ПРИМЕНЕНИЕ НЕЙРОСЕТЕВЫХ АЛГОРИТМОВ И МАШИННОГО ОБУЧЕНИЯ ДЛЯ АВТОМАТИЧЕСКОГО ОБНАРУЖЕНИЯ ПОЖАРОВ НА ВИДЕОПОТОКЕ

Емельянов Никита Алексеевич

Главное управление МЧС России по Красноярскому краю, г. Красноярск, Российская Федерация

Аннотация. Статья посвящена исследованию применения современных нейросетевых алгоритмов и машинного обучения для автоматического обнаружения признаков пожара на видеопотоке. В условиях роста требований к скорости реагирования и точности мониторинга возгораний традиционные системы, основанные на физических сенсорах, демонстрируют ряд ограничений. В связи с этим возрастающий интерес представляют интеллектуальные методы анализа изображений на основе компьютерного зрения и глубокого обучения. Рассмотрены ключевые архитектуры нейросетей, включая YOLOv3, YOLOv5, EfficientDet и FireNet, обладающие высокой точностью детекции объектов в режиме реального времени и адаптивностью к различным условиям съемки. Проведен сравнительный анализ моделей по таким критериям, как точность, полнота, скорость обработки (FPS), устойчивость к ложным срабатываниям и требования к вычислительным ресурсам. Приведены результаты практического применения нейросетевых решений в промышленных, муниципальных и распределенных IoT-системах. Показано, что внедрение нейросетей позволяет существенно сократить среднее время обнаружения пожара (до 5–10 с) и повысить надежность работы систем видеонаблюдения. В заключение рассмотрены перспективные направления развития технологий интеллектуальной пожарной безопасности, такие как мультисенсорная интеграция, обучение моделей на специализированных выборках и создание нормативной базы для сертификации подобных систем. Сделаны выводы о высоком потенциале нейросетевых подходов для обеспечения раннего выявления пожаров и минимизации ущерба.

Ключевые слова: видеомониторинг, компьютерное зрение, обнаружение пожара, сверточные нейросети, распознавание дыма, YOLOv5, FireNet

Для цитирования: Емельянов Н. А. Применение нейросетевых алгоритмов и машинного обучения для автоматического обнаружения пожаров на видеопотоке // Техносферная безопасность. 2025. № 3 (48). С. 13–23.

APPLICATION OF NEURAL NETWORK ALGORITHMS AND MACHINE LEARNING FOR AUTOMATIC FIRE DETECTION IN VIDEO STREAM

Nikita A. Emelyanov

Main Directorate of EMERCOM of Russia for Krasnoyarsk Territory, Krasnoyarsk, Russian Federation

Abstract. The article is devoted to studies of the application of modern neural network algorithms and machine learning for automatic detection of fire signs in a video stream. In the context of increasing requirements for response speed and accuracy of fire monitoring, traditional systems based on physical sensors demonstrate a number of limitations. In this regard, intelligent methods of image analysis based on computer vision and deep learning are of increasing interest. The key architectures of neural networks are considered, including YOLOv3, YOLOv5, EfficientDet and FireNet, which have high accuracy of object detection in real time and adaptability to various shooting conditions. A comparative analysis of the models is carried out according to such criteria as accuracy, completeness, processing speed (FPS), resistance to false positives and requirements for computing resources. The results of practical application of neural network solutions in industrial, municipal and distributed IoT systems are presented. It is shown that the implementation of neural networks can significantly reduce the average fire detection time (up to 5-10 seconds) and increase the reliability of video surveillance systems. In conclusion, promising areas of development of intelligent fire safety technologies are considered, such as multisensory integration, training models on specialized samples and the creation of a regulatory framework for certification of such systems. Conclusions are made about the high potential of neural network approaches for ensuring early detection of fires and minimizing damage.

Keywords: video monitoring, computer vision, fire detection, convolutional neural networks, smoke recognition, YOLOv5, FireNet

For Citation: Emelyanov N. A. Application of neural network algorithms and machine learning for automatic fire detection in video stream // Technospheric safety. 2025. № 3 (48). pp. 13–23.

Введение

Пожары продолжают оставаться одной из наиболее разрушительных и трудно прогнозируемых чрезвычайных ситуаций. Несмотря на активное развитие нормативной базы, автоматизации систем оповещения и тушения, потери от пожаров в жилом, промышленном и природном секторах остаются крайне высокими. Наиболее критичным фактором по-прежнему выступает время реагирования.

Традиционные системы обнаружения, основанные на использовании датчиков температуры, дыма или открытого пламени, обладают рядом существенных ограничений. Они имеют ограниченный радиус действия, часто срабатывают с задержкой,

не способны дать информацию о типе или масштабах угрозы, а также подвержены ложным срабатываниям — например, в условиях задымления, перепадов температуры или работы техники. Кроме того, такие системы нередко существуют обособленно от видеонаблюдения и не обеспечивают визуальную верификацию происшествия.

На этом фоне возрастает интерес к использованию нейросетевых алгоритмов в системах визуального мониторинга. Такие модели способны в реальном времени распознавать признаки возгорания на видеопотоке, включая дым и пламя. Современные архитектуры, такие как YOLO и FireNet, демонстрируют высокую точность при оперативной скорости реагирования и низком уровне ложных срабатываний.

Целью данной статьи является обзор и сравнительный анализ современных нейросетевых моделей, применяемых для автоматического обнаружения пожаров по видеопотоку, с оценкой их эффективности, применимости и ограничений в контексте задач повышения пожарной безопасности.

Основная часть

1. Подходы к задаче видеодетекции пожаров

Задача автоматического выявления признаков пожара на видеопотоке относится к классу задач компьютерного зрения. Применяемые методы можно разделить на две группы: классические алгоритмы и методы, основанные на обучении.

Классические алгоритмы анализируют визуальные параметры изображения — изменение яркости, движение пикселей, доминирующие цветовые компоненты (красный, оранжевый), контурные особенности. Эти подходы не требуют предварительного обучения и легко реализуются, однако они крайне чувствительны к внешним помехам: солнечным бликам, отблескам фар, теням и движущимся объектам, не связанным с возгоранием. Это приводит к высокой частоте ложных срабатываний [1].

Нейросетевые методы используют обученные модели, способные различать пожар и визуально схожие объекты, опираясь на контекст видеопотока. Для обучения таких моделей применяются размеченные датасеты изображений и видеозаписей, содержащих фото и видео с дымом, пламенем, задымленностью, а также нейтральные кадры. Благодаря этому нейросети демонстрируют значительно более высокую точность и устой-

чивость к ложным срабатываниям по сравнению с классическими методами [2, 3].

2. Обзор нейросетевых архитектур и обучающих выборок

Нейросетевые архитектуры

Наиболее эффективными в задачах видеодетекции пожара считаются архитектуры, основанные на сверточных нейронных сетях (CNN), а также одностадийные детекторы объектов [4]:

- YOLO (You Only Look Once) — одна из наиболее популярных и результативных архитектур, реализующая одностадийный подход к распознаванию объектов. Модели последних поколений (YOLOv5, YOLOv8) обеспечивают высокую точность (до 92 %) при скорости обработки в реальном времени, что делает их подходящими для применения даже на потребительских GPU [5, 6].
- EfficientDet и MobileNet SSD — компактные архитектуры, ориентированные на энергоэффективность и возможность работы на мобильных или edge-устройствах. Они демонстрируют сбалансированные характеристики по точности (87–90 %) и скорости и особенно эффективны в задачах, где критичны ограничения по ресурсам [7].
- Vision Transformers (ViT) — относительно новый класс моделей, основанный на архитектуре трансформеров. ViT демонстрирует высокую точность, особенно при наличии большого объема обучающих данных, но требует значительно больше вычислительных ресурсов, чем CNN [8].

В зависимости от задачи модели могут решать:

- бинарную классификацию (наличие/отсутствие признаков пожара);
- детекцию с локализацией (указание координат огня);
- семантическую сегментацию, позволяющую выделять области пламени и оценивать их форму и распространение.

Обучение моделей обычно проводится с использованием фреймворков PyTorch или TensorFlow, часто с применением transfer learning — дообучения моделей на специализированных датасетах.

Качество работы моделей оценивается по следующим метрикам:

- Precision/Recall — точность и полнота обнаружения;
- F1-score — гармоническое среднее между ними;
- FPS (Frames Per Second) — число кадров в секунду, отражающее способность модели работать в режиме реального времени.

Обучающие и тестовые датасеты

Для обучения и валидации моделей применяются открытые датасеты, содержащие видеоматериалы и изображения с пожарами, дымом и нейтральными сценами. Наиболее распространенные:

- FIRESENSE — крупный датасет, включающий видеозаписи с камер наблюдения, преимущественно уличных, в различных погодных и световых условиях. Используется для обучения моделей в условиях естественной среды [2].
- Corsican Fire Dataset — содержит разнообразные сцены с открытым пламенем, дымом и их сочетаниями. Применяется в задачах бинарной классификации и объектной локализации [3].
- FireNet Dataset, FMDS — специализированные наборы данных, разработанные

для обучения моделей обнаружения пожаров в закрытых помещениях (здания, склады, ангары). Отличаются высоким качеством разметки и широким набором сценариев задымления [9].

Использование разнообразных по структуре и сложности датасетов позволяет моделям обобщать полученные знания и адаптироваться к новым условиям в реальных системах видеонаблюдения.

3. Сравнительный анализ нейросетевых моделей для видеодетекции пожаров

Выбор подходящей архитектуры нейросети для задач видеомониторинга во многом зависит от условий эксплуатации, требований к точности, скорости обработки и доступных ресурсов.

Для объективной оценки эффективности нейросетевых моделей, применяемых в системах автоматического обнаружения пожаров, используются несколько ключевых метрик. Каждая из них отражает определенный аспект поведения модели и помогает подобрать решение под конкретные условия эксплуатации [10]:

- Точность (Accuracy) — доля правильно классифицированных кадров по отношению ко всем проанализированным кадрам.
- Полнота (Recall) — показывает, какую долю реальных пожаров модель сумела правильно обнаружить.
- Точность распознавания (Precision) — доля корректных детекций пожара среди всех случаев, когда модель «считала», что пожар есть.
- F-мера — объединенная метрика, которая рассчитывается как гармоническое среднее между precision и recall:

$$F = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

(1)

F-мера дает взвешенную оценку качества модели в условиях, когда необходимо одновременно минимизировать как пропуски реальных возгораний, так и ложные срабатывания. В задачах пожарной безопасности эта метрика особенно важна, т. к. упор делается не только на надежность, но и на своевременность реагирования [10].

- FPS (Frames Per Second) — количество кадров в секунду, которое может обрабатывать модель.

В таблице представлены обобщенные характеристики наиболее популярных моделей, полученные на основе анализа данных из открытых исследований и сравнительных испытаний [4–8].

Таблица

Сравнительные характеристики нейросетевых моделей, применяемых для обнаружения пожаров

Table

Comparative characteristics of neural network models used for fire detection

Модель Model	Точность Accuracy	F-мера F-score	Ложные тревоги False alarms	Скорость обработки (FPS)	Особенности применения Specifics
YOLOv5	до 92 % up to 92 %	91 %	4–6 %	45–60	Системы видеонаблюдения, мобильные GPU Surveillance systems, mobile GPUs
YOLOv4	до 95 % up to 95 %	94 %	4 %	30–45	Промышленный контроль, автономные станции Industrial monitoring, autonomous stations
YOLOv3	до 88 % up to 88 %	86 %	6–8 %	25–35	Пилотные проекты, дроны, исследовательские цели Pilot projects, drones, research tasks
EfficientDet D0	87–90 %	86–89 %	5–8 %	25–40	Edge-устройства, системы с ограниченными ресурсами Edge devices, resource-limited systems
FireNet	84–88 %	82 %	8–12 %	15–25	IoT, устройства с малым объемом памяти IoT, low-power devices

Как видно из данных приведенной таблицы, наилучшие результаты по совокупности параметров демонстрируют модели семейства YOLO —особенно версии v4 и v5. Они обеспечивают высокий уровень точности, при этом сохраняя скорость, необходимую для работы в условиях реального времени. Это делает их предпочтительными для использо-

вания в интегрированных системах безопасности на объектах с высоким уровнем риска.

4. Архитектура системы видеодетекции на основе нейросетей

Для реализации автоматического распознавания признаков возгорания в реальных

условиях применяется модульный подход, позволяющий интегрировать нейросетевые модели в существующие системы видеонаблюдения или создавать автономные решения, работающие в режиме реального времени. Структурно такая система состоит из нескольких ключевых блоков:

- источник видеосигнала — видеокамера, беспилотный летательный аппарат (БПЛА) или мобильное устройство, обеспечивающее потоковое изображение;
- модуль предварительной обработки — выполняет масштабирование, нормализацию и фильтрацию изображений, подготавливает данные для подачи в модель;
- нейросетевая модель — основное ядро системы, реализующее функцию детекции. В зависимости от архитектуры

(YOLO, FireNet, EfficientDet и др.) модель может выполнять бинарную классификацию, детекцию объектов или сегментацию области пожара;

- модуль принятия решения — осуществляет логическую обработку результатов модели;
- интерфейс оповещения — отправка сигнала оператору, автоматическое включение пожарной сигнализации, запись события в лог или передача данных на сервер.

Такая архитектура (рис. 1) обеспечивает масштабируемость, независимость от конкретного оборудования и возможность адаптации под различные сценарии: от городской инфраструктуры до лесных массивов и промышленных объектов.




Рис. 1. Архитектура системы видеодетекции пожара на основе нейросетей

Fig. 1. Architecture of a fire video detection system based on neural networks

5. Практические примеры применения

Реализация нейросетевых систем для автоматического обнаружения пожаров уже получила подтверждение в ряде прикладных и исследовательских проектов как в России, так и за рубежом.

Пример 1. YOLOv3 на базе Darknet (Россия)

В исследовании [5] использовалась модель YOLOv3 для распознавания возгораний на изображениях и видеокдрах, полученных с различных точек съемки (уровень глаз, дроны, вертолеты). Для обучения применялась выборка из 1539 изображений, извлеченных из видеоматериалов, снятых в Австралии, Австрии, Бразилии, Китае и Украине. Выборка была разбита на тренировочную (1176),

валидационную (182) и тестовую (181) подмножества.

Обучение проводилось с использованием фреймворка Darknet, на языке Python с библиотеками OpenCV и NumPy. Были получены следующие метрики:

- Precision — до 70 %;
- Recall — около 58 %;
- F-мера — 53 %;
- средняя точность (mAP) — 48,12 %;
- FPS — 25–30 при использовании GPU [5].

Данный пример подтвердил эффективность даже относительно простой архитектуры при наличии достаточно качественного и разнообразного обучающего набора.

Примеры работы обученной модели при обработке видеофайла и изображений приведены на рис. 2 и 3 соответственно.



Рис. 2. Пример работы программы на видеофайле
Fig. 2. An example of how the program works on a video file



Рис. 3. Пример работы программы на изображении
Fig. 3. An example of how the program works in the image

Пример 2. YOLOv5 в промышленных системах видеонаблюдения

YOLOv5 применяется в ряде промышленных решений, в т. ч. в энергетике и нефтехимии, где необходимо оперативное реагирование на возгорания в зонах с высокой плотностью оборудования. В проектах, описанных в [1, 6], YOLOv5 достигала точности до 92 % и скорости обработки до 60 кадров в секунду. Благодаря гибкой архитектуре модель дообучалась на локальных данных, что позволяло снижать количество ложных срабатываний до уровня 4–6 %.

Интеграция проводилась в виде модулей, встроенных в системы видеонаблюдения, с возможностью автоматического формирования тревожных событий при превышении порога уверенности классификатора.

Пример 3. FireNet на edge-устройствах

FireNet, разработанная как легкая модель для IoT-среды, применяется в логистических центрах, складах и помещениях без устойчивого интернет-соединения. В исследовании [2] модель работала на устройстве Raspberry Pi с применением локального видеопотока и обеспечивала:

- точность — до 88 %;
- скорость — 15–20 FPS;
- уровень ложных срабатываний — 8–12 %.

Главным преимуществом FireNet остается возможность автономной работы и низкое потребление ресурсов, что делает ее применимой в edge-инфраструктуре [2, 7].

Таким образом, практические примеры подтверждают, что выбор модели напрямую зависит от условий эксплуатации: производительности оборудования, сценариев применения и требований к автономности. При этом нейросетевые решения, особенно YOLOv5 и FireNet, уже сегодня демон-

стрируют высокую эффективность и пригодность к промышленной интеграции.

6. Практические примеры применения

Внедрение нейросетевых алгоритмов в системы противопожарного мониторинга открывает широкие возможности для повышения эффективности обнаружения возгораний. Вместе с тем, как и любая быстро развивающаяся технология, данный подход сопряжен с рядом как перспективных направлений, так и объективных ограничений.

Перспективные направления развития:

- Мультимодальные системы: объединение видеодетекции с тепловизорами, акустическими датчиками и газоанализаторами позволит повысить надежность и снизить вероятность ложных срабатываний.
- Интеграция с беспилотными платформами (БПЛА): использование дронов с установленными нейросетевыми модулями позволяет проводить мониторинг труднодоступных территорий: лесов, карьеров, промышленных зон.
- Самообучающиеся системы (continual learning): разработка моделей, способных адаптироваться к новым условиям без полной переобучаемости, является перспективным направлением для работы в нестабильных или уникальных средах.
- Облачные и edge-решения: перенос вычислений в распределенные системы (edge computing) с частичной обработкой в облаке дает гибкость масштабирования и снижает нагрузку на локальное оборудование.

Ограничения и проблемы:

- Отсутствие национальных стандартов и сертификации: в России на данный

момент отсутствуют официально утвержденные методики испытаний и сертификации ИИ-систем детекции пожаров. Это ограничивает внедрение в ответственные объекты.

- Зависимость от качества видеопотока: нейросетевые модели чувствительны к искажениям изображения — плохое освещение, низкое разрешение и сжатие сигнала могут снизить точность детекции.
- Необходимость обширной и релевантной обучающей выборки: недостаток качественно размеченных российских датасетов снижает универсальность моделей, особенно в условиях отечественной архитектуры зданий и климата.
- Ресурсоемкость моделей: высокоточные модели требуют значительных вычислительных ресурсов для обучения, что может ограничить их применение в маломощных системах и автономных устройствах.

Таким образом, несмотря на очевидную эффективность нейросетевых решений, их широкомасштабное внедрение требует как технической доработки, так и создания нормативно-правовой и методической базы. Устранение перечисленных барьеров станет ключом к формированию новой генерации интеллектуальных систем противопожарной безопасности.

Заключение

Нейросетевые технологии, применяемые для автоматического обнаружения признаков пожара на видеопотоке, демонстрируют высокую эффективность и практиче-

скую применимость в системах мониторинга различных масштабов — от промышленных объектов до распределенных IoT-решений. Проведенный обзор архитектур (YOLOv3/v4/v5, EfficientDet, FireNet) и сопоставление их характеристик показали, что современные модели способны достигать точности до 95 %, снижать уровень ложных срабатываний до 4–6 % и обеспечивать обработку в режиме реального времени (до 60 FPS).

Практические примеры реализации таких решений подтвердили, что нейросети успешно решают задачи как детекции, так и локализации пожаров, а в некоторых случаях — и сегментации. Легкие модели (например, FireNet) демонстрируют хорошую применимость в условиях ограниченных ресурсов и автономной работы.

Тем не менее широкое внедрение этих решений сдерживается рядом ограничений: отсутствием национальных стандартов и сертификаций, недостатком локальных датасетов, а также требовательностью к качеству видеопотока. Устранение этих барьеров в ближайшие годы станет важной задачей для научного сообщества и разработчиков систем безопасности.

Таким образом, нейросетевые методы обнаружения пожаров следует рассматривать не как альтернативу традиционным средствам, а как мощное дополнение, повышающее надежность, скорость и интеллектуальный уровень систем противопожарной защиты. В условиях стремительного развития искусственного интеллекта именно такие решения становятся фундаментом для построения адаптивных, масштабируемых и самонастраивающихся систем техносферной безопасности.

СПИСОК ИСТОЧНИКОВ

1. Mahmoud, H., Alharbi, A., Alghamdi, N. Time-Efficient Fire Detection Convolutional Neural Network Coupled with Transfer Learning // *Intelligent Automation & Soft Computing*. 2022. Vol. 31 (3). pp. 1393–1403.
2. FireNet: A specialized lightweight fire & smoke detection model for real-time IoT applications / A. Jadon et al. // *Measurement*. 2019. Vol. 188. P. 110390.
3. Zhang, D., Chen, Y. Lightweight Fire Detection Algorithm Based on improved YOLOv5 // *International Journal of Advanced Computer Science and Applications (IJACSA)*. 2024. Vol. 15.
4. You Only Look Once: Unified, Real-Time Object Detection / J. Redmon et al. URL: <https://arxiv.org/abs/1506.02640> (date of application: 26.03.2025).
5. Дамдынчап Ч. А., Шарапов А. А. Применение нейронных сетей для распознавания дыма и пожара на изображениях // *Сибирский государственный университет геосистем и технологий*. 2021. № 2. С. 38–43. URL: <https://www.elibrary.ru/item.asp?id=47252055> (дата обращения: 23.03.2025).
6. Fire detection using deep learning methods / A. Bayegizova et al. // *International Journal of Electrical and Computer Engineering (IJECE)*. 2024. Vol. 14 (1). pp. 547–555.
7. Fire Detection Using Deep Learning / G. Suhas et al. // *International Journal of Progressive Research in Science and Engineering (IJECE)*. 2020. Vol. 1 (5). pp. 1–5. URL: <https://journal.ijprse.com/index.php/ijprse/article/view/141> (date of application: 26.03.2025).
8. Калиев Д. И., Швец О. Я. Сверточные нейронные сети для решения задач обнаружения пожаров по данным аэрофотосъемки // *Программные системы: теория и приложения*. 2022. Т. 13, № 1. С. 195–213.
9. Redmon, J., Farhadi, A. YOLOv3: An Incremental Improvement. URL: <https://arxiv.org/abs/1804.02767> (date of application: 26.03.2025).
10. Goodfellow I., Bengi Y., Courville A. Deep Learning. MIT Press, 2016. 800 p. URL: <https://www.deeplearningbook.org> (date of application: 26.03.2025).

REFERENCES

1. Mahmoud, H., Alharbi, A., Alghamdi, N. Time-Efficient Fire Detection Convolutional Neural Network Coupled with Transfer Learning // *Intelligent Automation & Soft Computing*. 2022. Vol. 31 (3). pp. 1393–1403.
2. FireNet: A specialized lightweight fire & smoke detection model for real-time IoT applications / A. Jadon et al. // *Measurement*. 2019. Vol. 188. P. 110390.
3. Zhang, D., Chen, Y. Lightweight Fire Detection Algorithm Based on improved YOLOv5 // *International Journal of Advanced Computer Science and Applications (IJACSA)*. 2024. Vol. 15.
4. You Only Look Once: Unified, Real-Time Object Detection / J. Redmon et al. URL: <https://arxiv.org/abs/1506.02640> (date of application: 26.03.2025).
5. Damdynchap, Ch. A., Sharapov, A. A. Application of neural networks for smoke and fire detection in images // *Siberian State University of Geosystems and Technologies*. 2021. № 2. pp. 38–43. URL: <https://www.elibrary.ru/item.asp?id=47252055> (date of application: 26.03.2025).

6. Fire detection using deep learning methods / A. Bayegizova et al. // International Journal of Electrical and Computer Engineering (IJECE). 2024. Vol. 14 (1). pp. 547–555.
7. Fire Detection Using Deep Learning / G. Suhas et al. // International Journal of Progressive Research in Science and Engineering (IJECE). 2020. Vol. 1 (5). pp. 1–5. URL: <https://journal.ijprse.com/index.php/ijprse/article/view/141> (date of application: 26.03.2025).
8. Kaliev, D. I., Shvets, O. Ya. Convolutional neural networks for solving fire detection problems based on aerial photography data // Software Systems: Theory and Applications. 2022. Vol. 13, № 1. pp. 195–213.
9. Redmon, J., Farhadi, A. YOLOv3: An Incremental Improvement. URL: <https://arxiv.org/abs/1804.02767> (date of application: 26.03.2025).
10. Goodfellow, I., Bengio, Y., Courville, A. Deep Learning. MIT Press, 2016. 800 p. URL: <https://www.deeplearningbook.org> (date of application: 26.03.2025).

ИНФОРМАЦИЯ ОБ АВТОРЕ

Емельянов Никита Алексеевич, инженер отдела организации службы пожарно-спасательных подразделений управления организации пожаротушения и проведения аварийно-спасательных работ Главного управления МЧС России по Красноярскому краю (660049, Российская Федерация, Красноярский край, г. Красноярск, просп. Мира, д. 68); Scopus Author ID: 7003537835; ResearcherID: U-2907-2019; ORCID: 0000-0001-7234-1339; e-mail: yemelyanovna@24.mchs.gov.ru

INFORMATION ABOUT THE AUTHOR

Nikita A. Emelyanov, Engineer, Department of Organization of Fire and Rescue Units, Department of Firefighting and Emergency Rescue Operations, Main Directorate of the EMERCOM of Russia for Krasnoyarsk Territory, Russian Federation (68 Mira St., Krasnoyarsk, 660049, Russian Federation); Scopus Author ID: 7003537835; ResearcherID: U-2907-2019; ORCID: 0000-0001-7234-1339; e-mail: yemelyanovna@24.mchs.gov.ru

Поступила в редакцию 14.05.2025
Одобрена после рецензирования 20.05.2025
Принята к публикации 15.09.2025