

Научная статья
УДК 614.842.435
doi:10.34987/vestnik.sibpsa.2025.17.70.008

Прогнозирование ложных срабатываний дымовых пожарных извещателей с помощью нейронной сети

Ильдар Фанилевич Хафизов

Фаниль Шамилович Хафизов

Элина Фанисовна Рахматуллина

Арсений Владимирович Пермяков

Уфимский государственный нефтяной технический университет, Уфа, Россия

Автор, ответственный за переписку: Рахматуллина Элина Фанисовна,

rahmatullina_elina@mail.ru

Аннотация. В статье рассматривается задача прогнозирования ложных срабатываний дымовых пожарных извещателей с использованием рекуррентной нейронной сети LSTM. Цель исследования – разработка и тестирование модели, способной на основе временных данных различать истинные и ложные тревоги, что позволит снизить количество ложных вызовов пожарных служб и повысить надёжность систем пожарной безопасности. В рамках работы проведён эксперимент, в ходе которого собраны данные с лазерного датчика и двух извещателей (Н1 и Н2). Разработанная LSTM-модель обучалась на этих данных с использованием последовательностей длиной 50 шагов, а её точность оценивалась с помощью метрик MAE, MSE, RMSE и Ассигасу. Результаты показали, что предложенная модель достигает 99,5% точности для Н1 и 99,3% для Н2, что подтверждается низкими значениями ошибок: $MAE < 0,01$, $RMSE \approx 0,05$. По сравнению с существующими методами (ансамблевые модели, анализ временных рядов), предложенный подход использует исключительно временную динамику сигналов без необходимости в мультисенсорных данных, что делает его эффективным и легко интегрируемым в существующие системы. Полученные результаты подтверждают перспективность LSTM для детекции ложных тревог и указывают на возможность дальнейшего улучшения модели за счёт учёта дополнительных факторов (температура, влажность, скорость изменения концентрации дыма) и использования гибридных архитектур (CNN + LSTM).

Ключевые слова: Прогнозирование ложных срабатываний, дымовые пожарные извещатели, LSTM, нейронные сети, временные ряды, глубокое обучение, автоматизированные системы пожарной безопасности, точность предсказаний, машинное обучение, обнаружение аномалий

Для цитирования: Хафизов И.Ф., Хафизов Ф.Ш., Рахматуллина Э.Ф., Пермяков А.В. Прогнозирование ложных срабатываний дымовых пожарных извещателей с помощью нейронной сети // Сибирский пожарно-спасательный вестник. 2025. № 2 (37). С. 111-120. <https://doi.org/10.34987/vestnik.sibpsa.2025.17.70.008>.

Original article.

Prediction of false alarms of smoke detectors using a neural network

Ildar Fanilevich Hafizov

Fanil Shamilevich Hafizov

Elina Fanisovna Rahmatullina

Arseniy Vladimirovich Permyakov

Ufa State Petroleum Technical University, Ufa, Russia

Corresponding author: *Rakhmatullina Elina Fanisovna, rahmatullina_elina@mail.ru*

Abstract. The article addresses the problem of false alarm prediction in smoke fire detectors using a Long Short-Term Memory (LSTM) recurrent neural network. The objective of the study is to develop and test a model capable of distinguishing between true and false alarms based on temporal data, thereby reducing the number of false emergency responses and increasing the reliability of fire safety systems. As part of the research, an experiment was conducted, during which data were collected from a laser sensor and two fire detectors (H1 and H2). The developed LSTM model was trained on this dataset using 50-step sequences, and its accuracy was evaluated using the MAE, MSE, RMSE, and Accuracy metrics. The results demonstrated that the proposed model achieves 99,5% accuracy for H1 and 99,3% for H2, supported by low error values: $MAE < 0,01$, $RMSE \approx 0,05$. Compared to existing methods (ensemble models, time series analysis), the proposed approach relies exclusively on the temporal dynamics of signals without requiring multisensor data, making it efficient and easily integrable into existing fire detection systems. The obtained results confirm the potential of LSTM for false alarm detection and indicate possibilities for further model improvements by incorporating additional factors (temperature, humidity, rate of smoke concentration change) and utilizing hybrid architectures (CNN + LSTM).

Keywords: False alarm prediction, smoke fire detectors, LSTM, neural networks, time series, deep learning, automated fire safety systems, prediction accuracy, machine learning, anomaly detection

For citation: Khafizov I.F., Khafizov F.Sh., Rakhmatullina E.F., Permyakov A.V. Prediction of false alarms of smoke detectors using a neural network // Siberian Fire and Rescue Bulletin. 2025. № 2 (37). С. 111-120. (In Russ.) <https://doi.org/10.34987/vestnik.sibpsa.2025.17.70.008>.

Ложные срабатывания пожарных извещателей – серьёзная проблема, приводящая к отвлечению ресурсов и недоверию к системе. Статистика МЧС России за 2023 год [1] показывает, что неисправности и задержки в работе систем пожарной сигнализации приводят к значительным материальным потерям. Наибольший ущерб зафиксирован в случаях полной неисправности или задержки сигнала, достигая в среднем 1800 тыс. рублей на пожар. Максимальные средние потери возникают при полной неисправности системы или значительных задержках в передаче сигнала. Это чаще всего связано с конструктивными недостатками, ошибками при установке или отсутствием регулярного обслуживания систем пожарной безопасности [2,3].

Повышение чувствительности датчиков без интеллектуальной обработки сигнала лишь увеличивает число ложных тревог [4], поэтому в последние 5 лет ведутся активные исследования применения методов искусственного интеллекта – прежде всего нейросетей – для распознавания ложных срабатываний пожарных извещателей.

Авторы статьи [5] проанализировали сигналы оптического дымового датчика, уязвимого к пыли и парообразной влаге, и обучили 1-мерную свёрточную нейронную сеть (CNN-классификатор) для отличия реального задымления от помех. Предложенный ими подход позволил существенно повысить надёжность датчика (в более чем в 50% случаев удалось корректно идентифицировать пар как ложную тревогу, уменьшая число ложных срабатываний от пара).

В работе [6] предложен многопараметрический метод обнаружения пожара, основанный на ансамбле моделей машинного обучения и глубоких нейросетей. Анализируются данные от нескольких сенсоров (дым, температура, СО и др.), из которых извлекаются глубокие признаки. Метод использует комплексную модель EST-CNN, которая объединяет преимущества сверточных нейросетей (CNN) для эффективно выделения пространственных признаков и временных моделей (RNN, LSTM), которые анализируют динамические изменения. Это позволило существенно снизить ложные тревоги и повысить надёжность детекции по сравнению с одиночными датчиками. Благодаря комплексному подходу система стала устойчивее к аномалиям, обеспечивая более точное и стабильное обнаружение пожара.

В работе [4] протестированы архитектуры нескольких нейронных сетей LSTM, GRU, Bi-LSTM, LSTM-FCN, InceptionTime, Transformer и в результате показано, что рекуррентные сети (LSTM) лучше всего справляются с задачей классификации «пожар/норма». Валидационная точность Bi-LSTM и LSTM превысила 99%, при этом модели достигли очень низких уровней ложных тревог. Учёт временной динамики сигнала (например, характер роста концентрации дыма) оказался крайне полезен для фильтрации ложных срабатываний.

Исследование, проведенное в работе [7], посвящено применению искусственных нейронных сетей в системах обнаружения дыма. Авторы разработали модель на основе нейросети, которая достигла 100% точности в распознавании дыма. Работа охватывает вопросы предобработки данных, настройки гиперпараметров и оценки модели с использованием метрик precision, recall и F1-score.

Активные исследования в этом направлении подкреплены и патентованием новых решений. Например, патент CN113362560A (2021) описывает метод фотоэлектрической дымовой сигнализации с применением нейросети для точного распознавания огневого дыма и игнорирования ложных факторов (пыль, пар и т.п.) [8].

Крупные производители систем безопасности также ведут разработки: так, компания Honeywell в 2023–2024 гг. получила ряд патентов на интеллектуальные аспирационные детекторы дыма, где встроенный анализ операций датчика и сложные алгоритмы с элементами ИИ помогают отфильтровать помехи и выдавать более надёжные предупреждения.

Многие из рассмотренных методов уже выходят за рамки лабораторий. Например, южнокорейский институт ETRI в 2025 году объявил о разработке «AI-сенсора» для фотоэлектрических извещателей, отличающего дым пожара от бытовых аэрозолей по спектру рассеянного света [9].

Таким образом, за последние пять лет сформировался явный тренд: пожарные извещатели нового поколения оснащаются интеллектуальными алгоритмами на основе нейросетей, что подтверждается как научными публикациями, так и патентами. Эти алгоритмы демонстрируют высокую эффективность (снижение ложных срабатываний при сохранении или улучшении времени обнаружения) и открывают путь к более надёжным системам пожарной сигнализации.

Все приведённые работы свидетельствуют о высокой эффективности нейросетевых методов – достигаются доли процента ложных срабатываний при уровне обнаружения >98–99%. Глубокие CNN хорошо выявляют пространственные шаблоны сигнала датчика, RNN (LSTM) анализируют временные зависимости, а ансамбли и мультисенсорные схемы позволяют учесть разнородные признаки пожара. Важный тренд – интеграция таких моделей непосредственно в устройства (за счёт оптимизации архитектуры), что подтверждается как экспериментальными установками, так и патентной активностью производителей.

В задачах обнаружения аномалий во временных рядах широко применяются различные архитектуры нейронных сетей:

Полносвязные сети (MLP) – классический вариант нейросетей, где каждый нейрон соединён со всеми нейронами следующего слоя. Используется для обработки данных фиксированной размерности, но плохо учитывает временную зависимость.

Свёрточные нейронные сети (CNN) – применяются для выявления локальных паттернов в данных, что позволяет эффективно обнаруживать короткие аномальные отклонения. Однако CNN не анализируют долгосрочные временные зависимости.

Рекуррентные сети (RNN) – специально разработаны для моделирования последовательностей, так как состояние сети обновляется на основе предшествующих значений. Однако стандартные RNN страдают проблемой исчезающего градиента, что затрудняет работу с длинными зависимостями.

Long Short-Term Memory (LSTM) и Gated Recurrent Units (GRU) – улучшенные версии RNN, которые используют механизмы «долгой» и «короткой» памяти. Эти сети способны обрабатывать длинные временные зависимости и являются одними из самых популярных решений в задачах детекции аномалий.

Существует несколько распространённых нейросетевых подходов к анализу аномалий:

Автоэнкодеры (Autoencoders, AE) – обучаются восстанавливать нормальные данные, а сильные расхождения между входными и восстановленными значениями указывают на аномалии.

Генеративно-сопоставительные сети (GANs) – могут обучаться на нормальных данных и выявлять аномалии по степени отличия от синтетически сгенерированных образцов.

LSTM для предсказания временных рядов – сеть обучается предсказывать следующее значение, а значительные отклонения от прогноза могут рассматриваться как аномалии.

Комбинированные архитектуры (CNN + LSTM, Transformer-based) – используют преимущества CNN (локальные закономерности) и LSTM (долгосрочные зависимости) для более точного обнаружения аномалий.

Преимущества и недостатки нейросетевых методов представлены в Табл.1.

Табл.1. Нейросетевые методы обработки сигналов пожарных извещателей

Подход	Преимущества	Недостатки
Классические методы (SVM, Isolation Forest, PCA)	Простота, высокая интерпретируемость, малые вычислительные затраты	Ограниченная способность выявлять сложные закономерности
MLP	Простота в реализации, хорошая работа на стационарных данных	Не учитывает временную структуру
CNN	Эффективность при анализе локальных аномалий	Плохо моделирует длинные временные зависимости
LSTM/GRU	Отлично выявляет аномалии с учётом временной зависимости	Требует больших вычислительных ресурсов, сложность настройки
AE/GAN	Хорошо подходит для безметочного обучения, работает на многомерных данных	Чувствительность к выбору гиперпараметров, необходимость большого объёма данных

Таким образом, нейросетевые методы превосходят классические алгоритмы в выявлении сложных зависимостей, но требуют больше данных, вычислительных мощностей и правильной настройки [10]. Выбор конкретной архитектуры зависит от типа данных, требований к точности и интерпретируемости результатов.

Архитектура модели LSTM для прогнозирования ложных срабатываний извещателей. Цель работы – прогнозирование ложных срабатываний дымовых извещателей с применением глубокого обучения. Задача может быть сформулирована в двух вариантах.

Вариант 1. Задача бинарной классификации:

$$\hat{y} = f(x, \theta), \hat{y} \in \{0, 1\}$$

где, x – вектор входных признаков (показания одного или нескольких датчиков, включая данные о задымлённости, температуре, влажности и др.);

θ – набор параметров модели (весов нейронной сети).

Если $\hat{y} = 1$, то система классифицирует событие как реальную тревогу, а $\hat{y} = 0$ – как ложное срабатывание.

Вариант 2. Задача прогноза вероятности:

$$p = P(\text{истинная тревога} | x; \theta) = f(x, \theta), \quad p \in [0, 1].$$

Решение принимается сравнением p с порогом τ , балансируя между чувствительностью (recall) и специфичностью (specificity). Если $p \geq \tau$, событие считается «пожаром», иначе «ложная тревога».

Точность системы определяется компромиссом между минимизацией ложных срабатываний и своевременным обнаружением реальных пожаров. В большинстве случаев более гибким вариантом является прогноз вероятности (вариант 2), позволяющий адаптировать порог тревоги. Однако при строгих требованиях к скорости работы предпочтительна бинарная классификация (вариант 1).

Для детекции ложных срабатываний дымовых извещателей могут применяться различные нейронные сети: MLP (многослойный персептрон) – подходит для статичных данных, но плохо учитывает временную структуру сигналов; CNN (сверточные сети) – способны анализировать одномерные временные ряды, выделяя локальные паттерны; RNN (рекуррентные сети, включая LSTM и GRU) – эффективно моделируют последовательности сигналов, сохраняя контекст изменений; CNN + LSTM – комбинированный подход, где CNN извлекает пространственные признаки, а LSTM анализирует их динамику.

LSTM является оптимальной архитектурой, так как:

- моделирует долгосрочные зависимости в данных;
- учитывает динамику изменений сенсоров;
- позволяет адаптивно изменять порог тревоги.

Опыт эксплуатации систем пожарных извещателей показывает, что ложное срабатывание может провоцироваться множеством факторов: обычным дымом от сигарет, паром от кипящей воды, пылью, повышенной влажностью и т. д. [11]. Следовательно, для корректного различения истинных возгораний и ложных факторов целесообразно учитывать не только показания датчика дыма, но и другие доступные параметры среды. В общем случае можно рассматривать следующие признаки:

Параметры дыма: $x_1(t), x_2(t), \dots, x_{d_1}(t)$. Например, интенсивность рассеянного света при различных углах, спектральные характеристики частиц, или просто «степень задымлённости», регистрируемая оптическим сенсором.

Температура (T): $x_{d_1+1}(t) = T(t)$. Резкое повышение температуры может свидетельствовать о настоящем пожаре, а её отсутствие – указать на возможное ложное срабатывание.

Влажность (H): $x_{d_1+2}(t) = H(t)$. Высокая влажность может приводить к образованию пара, что часто воспринимается извещателем как дым.

Содержание газов: $x_{d_1+3}(t), x_{d_1+4}(t), \dots$. Если имеются датчики CO (угарный газ), CO₂, углеводородов и т. д., то их показания важны для оценки типа горения или его отсутствия.

Дополнительные параметры:

- скорость изменения (градиент) $\frac{dx_i(t)}{dt}$ – часто более информативна, чем абсолютное значение показателя;
- скользящее среднее, скользящее стандартное отклонение и т. д. за некоторый промежуток времени.

По набору параметров вектора $x(t) = [x_1(t), x_1(t), \dots, x_1(t)]^T$ можно сформировать последовательность на каждом временном шаге t :

$$\mathcal{D} = \{(x(t), y(t)): t \in [1, N]\}$$

где, T – символ транспонирования матрицы (вектора), означающий, что выражение в скобках записано в виде строки, а после транспонирования становится столбцом;

$y(t)$ – метка (истинное срабатывание/ложное).

По набору этих входных данных обучается модель $f(\cdot; \theta)$.

где, f – функция, представляющая модель,

(точка) – символическое обозначение для входных данных, указывающее, что функция f принимает на вход определённые данные;

θ – набор параметров модели, которые настраиваются в процессе обучения.

Для корректной работы нейронной сети необходимо выполнить предварительную обработку (предобработку) данных, которая включает: удаление выбросов и пропусков, шумоподавление, нормализацию, а также агрегирование во временные окна. Для рекуррентных сетей выбирается длина временного окна L , в пределах которого анализируется динамика признаков (например, $X_t = \{x(t - L + 1), \dots, x(t)\}$). Эта процедура позволяет фокусироваться на поведении сигнала за последние L шагов, что особенно важно для LSTM-архитектуры.

Все это обеспечивает консистентность и высокое качество входных данных для модели, позволяя нейронной сети точнее обнаруживать паттерны, соответствующие реальному или ложному пожару.

Алгоритм процесса обработки первичного сигнала для LSTM показан на Рис.1. Диаграмма описывает общий конвейер (pipeline) обработки данных для задач детекции ложных срабатываний, где ключевым элементом является LSTM для учёта временной динамики признаков.

Модель стенда для исследования изменения интенсивности (мощности) лазерного луча при прохождении сквозь объём с задымлённой средой приведена на Рис.2. Источник горения (ИГ) расположен внизу и обеспечивает задымление внутреннего пространства для эксперимента. В верхней части камеры установлены дымовые извещатели (Н1, Н2).

На выходе фотоприёмника получен временной сигнал, отражающий динамику задымления (Рис.3). Шумовые искажения и кратковременные возмущения вызывают ложные срабатывания, датчик реагирует на кратковременные помехи.

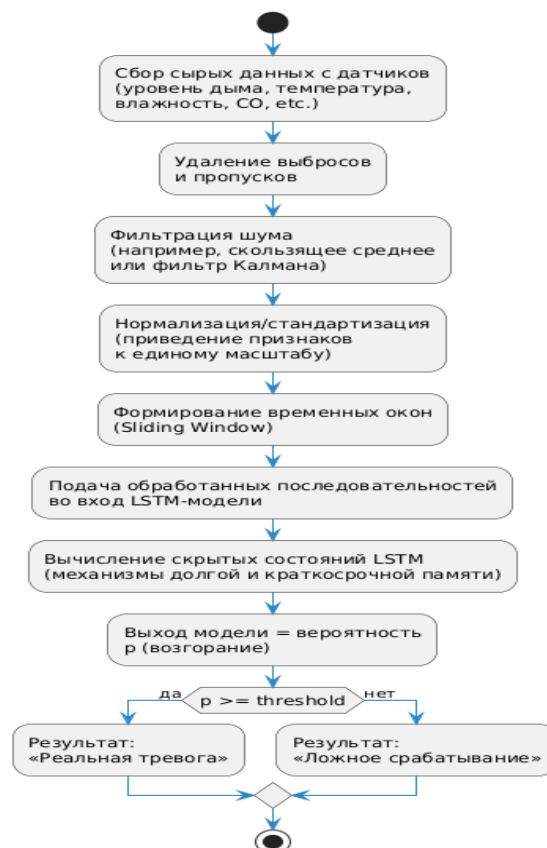


Рис.1. Алгоритм работы модели LSTM




Рис.2. Модель стенда для исследования




Рис.3. Сигнал лазерного датчика (на фотоприемнике)

Извещатель Н1 с порогом 0,7 зафиксировал 3 ложные тревоги, отличающиеся короткой продолжительностью, а извещатель Н2 с более высоким порогом 0,8 зафиксировал 5 ложных тревог, что свидетельствует о высокой чувствительности к шумам. Полученные результаты показывают, что изменение порога срабатывания влияет на частоту ложных тревог.

При разработке модели LSTM для прогнозирования ложных срабатываний пожарных извещателей была выбрана многослойная архитектура с двумя рекуррентными слоями. Первый слой LSTM содержит 50 нейронов и настроен с параметром `return_sequences=True`, что позволяет передавать полные выходные последовательности следующему слою. Второй LSTM-слой также содержит 50 нейронов, но возвращает только финальное состояние. Для предотвращения переобучения используется метод регуляризации Dropout с коэффициентом 0.2, который случайным образом отключает 20% нейронов на этапе обучения. Выходной слой модели представлен полносвязным нейроном с функцией активации sigmoid, формирующей вероятность ложной тревоги. В качестве функции потерь используется binary cross-entropy, оптимизация параметров осуществляется с помощью Adam. Размер минибатча составляет 32, а обучение проводится в течение 10 эпох. Обучение модели проводили на экспериментальных данных, что позволило учитывать динамику изменений и корректно классифицировать события, снижая вероятность ложных срабатываний.

Результаты работы LSTM-модели по предсказанию ложных срабатываний представлены на Рис.4. Модель хорошо обучается: точность достигла 99.5% для Н1 и 99.3% для Н2. Значения метрик ошибки свидетельствует о высокой точности предсказания:

Метрики Н1: MAE = 0.008872, MSE = 0.002985, RMSE = 0.054636

Метрики Н2: MAE = 0.009264, MSE = 0.003212, RMSE = 0.056676

Таким образом, предложенная модель успешно справляется с задачей детекции ложных тревог, демонстрируя высокую точность предсказаний.

Анализ известных работ показал, что для фильтрации ложных тревог часто используют ансамблевые методы, совмещая CNN и RNN для обработки сигналов нескольких сенсоров, или применяют алгоритмы на основе анализа сходства временных рядов. В отличие от этих подходов, предложенная в данной работе модель LSTM работает исключительно на основе временной динамики сигналов. Это делает её более компактной, устойчивой к шуму и легко интегрируемой в существующие системы, снижая вычислительные затраты по сравнению с обычными классификаторами. Разработанный подход позволяет гибко адаптировать алгоритм детекции и снижать количество ложных тревог.

Результаты исследования показывают, что модель LSTM может использоваться для повышения надёжности автоматизированных систем пожарной безопасности. Включение в дальнейшем дополнительных параметров, таких как температура, влажность и скорость изменения концентрации дыма, может повысить точность модели.




Рис.4. Результаты работы LSTM-модели по предсказанию ложных срабатываний

Список источников

1. Пожары и пожарная безопасность в 2023 году: информационно-аналитический сборник / авторский коллектив: Гончаренко В.С., Чечетина Т.А., Сибирко В.И., Надточий О.В., Полехин П.В., Козлов А.А., Грибанов А.М.; рец.: Соколов С.В. – Балашиха: ФГБУ ВНИИПО МЧС России, 2024. – 110 с.
2. Танклевский Л.Т., Бабинов И.А., Танклевский А.Л. Об оценке достоверности обнаружения возгорания // Проблемы управления рисками в техносфере. – 2021. – № 3 (59). – С. 28-33. – EDN JVMNBY.
3. Пиреева В.С., Рахматуллина Э.Ф., Пермяков А.В. Влияние концентрации дымовых частиц на обнаружение возгорания // Технические и технологические системы: материалы XV Международной научной конференции «ТТС-24» (20–22 ноября 2024 года) / ФГБОУ ВО «КубГУ», ФГК ВОУ ВО «КВВАУЛ им. А.К. Серова». Краснодар: Издательский Дом – Юг, 2024. – С.150-153.

4. Kim Y., Heo Y., Jin B., Bae Y. Real-Time Fire Classification Models Based on Deep Learning for Building an Intelligent Multi-Sensor System. *Fire* – 2024, – № 7, p. 329. <https://doi.org/10.3390/fire7090329>.
5. Liu, Ming & Zhou, Hongbin & Ren, Yupeng & Lu, Wei. (2020). A Deep Learning Approach to Reduce False Alarms for Optical Smoke Detectors. *Journal of Physics: Conference Series*. 1631. 012032. 10.1088/1742-6596/1631/1/012032.
6. Xu, Fang et al. Embedded Spatial-Temporal Convolutional Neural Network Based on Scattered Light Signals for Fire and Interferential Aerosol Classification. *Sensors (Basel, Switzerland)* vol. 24,3 0. 25 Jan. 2024, doi:10.3390/s24030778.
7. Al-Rayes, M. R. M., Abu-Naser, S. S. Smoke Detectors Using ANN [Электронный ресурс] // *International Journal of Academic Engineering Research (IJAER)*. – 2023. – Т. 7, № 10. – С. 1–9. – Режим доступа: www.ijeais.org/ijaer, свободный.
8. Photoelectric smoke sensing detection method for accurately identifying fire smoke: пат. CN113362560A Китай / Zhang Hongying, Feng Yong, Zhang Guangbiao, Zhang Peng, Wang Jianjun, Lin Yuxin, Zhang Xiaoshuang, Qu Wu, He Guotang, Li Yong; заявитель Bengbu Ei Fire Electronics Co Ltd. – № CN202110593735.XA; заявл. 28.05.2021; опубл. 07.09.2021. – URL: <https://patents.google.com/patent/CN113362560A>.
9. National Research Council of Science and Technology. AI sensor cuts false alarms in smoke detectors [Электронный ресурс] // *TechXplore*. – 2025. – 4 февраля. – URL: <https://techxplore.com/news/2025-02-ai-sensor-false-alarms-detectors.html>.
10. Рахматуллина Э.Ф., Пермяков А.В., Хафизов И.Ф., Хафизов Ф.Ш. Прогнозирование значений пожарного риска с помощью машинного обучения и анализа временных рядов // *Нефтегазовое дело*. – 2024. – № 5. – С. 6-20.
11. Рахматуллина Э.Ф., Пермяков А.В. Исследование ложных срабатываний автоматических установок пожарной сигнализации на объектах с массовым пребыванием людей // *Материалы 75-й научно-технической конференции студентов, аспирантов и молодых ученых УГНТУ*. – Уфа: Издательство УГНТУ, 2024. – С. 82.

References

1. Fires and Fire Safety in 2023: Information and Analytical Collection / Authors: Goncharenko V.S., Chechetina T.A., Sibirko V.I., Nadtochiy O.V., Polekhin P.V., Kozlov A.A., Gribanov A.M.; Reviewer: Sokolov S.V. – Balashikha: FSBI VNIPO EMERCOM of Russia, 2024. – 110 p.
2. Tanklevsky L.T., Babikov I.A., Tanklevsky A.L. On the Assessment of Fire Detection Reliability // *Problems of Risk Management in the Technosphere*. – 2021. – No. 3(59). – P. 28-33. – EDN JVMNBY.
3. Pireeva V.S., Rakhmatullina E.F., Permyakov A.V. Influence of Smoke Particle Concentration on Fire Detection // *Technical and Technological Systems: Proceedings of the XV International Scientific Conference “TTS-24” (November 20–22, 2024)* / Kuban State Technological University, KVVU named after A. K. Serov. – Krasnodar: Publishing House – South, 2024. – P. 150-153.
4. Kim Y., Heo Y., Jin B., Bae Y. Real-Time Fire Classification Models Based on Deep Learning for Building an Intelligent Multi-Sensor System. *Fire* 2024, 7, 329. <https://doi.org/10.3390/fire7090329>.
5. Liu, Ming & Zhou, Hongbin & Ren, Yupeng & Lu, Wei. A Deep Learning Approach to Reduce False Alarms for Optical Smoke Detectors. *Journal of Physics: Conference Series*. 2020, 1631, 012032. <https://doi.org/10.1088/1742-6596/1631/1/012032>.
6. Xu, Fang et al. Embedded Spatial-Temporal Convolutional Neural Network Based on Scattered Light Signals for Fire and Interferential Aerosol Classification. *Sensors (Basel, Switzerland)*, 2024, 24(3), 0. <https://doi.org/10.3390/s24030778>.
7. Al-Rayes M. R. M., Abu-Naser, S. S. Smoke Detectors Using ANN [Electronic Resource] // *International Journal of Academic Engineering Research (IJAER)*. – 2023. – 7(10). – P. 1–9. Available at: www.ijeais.org/ijaer.
8. Photoelectric smoke sensing detection method for accurately identifying fire smoke: Patent CN113362560A China / Zhang Hongying, Feng Yong, Zhang Guangbiao, Zhang Peng, Wang

Jianjun, Lin Yuxin, Zhang Xiaoshuang, Qu Wu, He Guotang, Li Yong; Applicant: Bengbu Ei Fire Electronics Co Ltd. – No. CN202110593735.XA; Filed: 28.05.2021; Published: 07.09.2021. Available at: <https://patents.google.com/patent/CN113362560A>.

9. National Research Council of Science and Technology. AI sensor cuts false alarms in smoke detectors [Electronic Resource] // TechXplore. 2025, February 4. Available at: <https://techxplore.com/news/2025-02-ai-sensor-false-alarms-detectors.html>.

10. Rakhmatullina E.F., Permyakov A.V., Khafizov I.F., Khafizov F.Sh. Forecasting Fire Risk Values Using Machine Learning and Time Series Analysis // Oil and Gas Business. — 2024. — No. 5. — P. 6-20.

11. Rakhmatullina E.F., Permyakov A.V. Study of False Alarms of Automatic Fire Alarm Systems in Facilities with High Population Density // Proceedings of the 75th Scientific and Technical Conference of Students, Postgraduates, and Young Scientists of UGNTU. – Ufa: UGNTU Publishing House, 2024. – P. 82.

Информация об авторах

И.Ф. Хафизов – доктор технических наук

Ф.Ш. Хафизов – доктор технических наук

Э.Ф. Рахматуллина – аспирант

А.В. Пермяков – кандидат технических наук, доцент

Information about the author

I.Sh. Khafizov – Holder of an Advanced Doctorate (Doctor of Science)

F.Sh. Khafizov – Holder of an Advanced Doctorate (Doctor of Science)

E.F. Rakhmatullina – postgraduate

A.V. Permyakov – Ph.D. of Engineering Sciences, docent

Вклад авторов: все авторы сделали эквивалентный вклад в подготовку публикации. Авторы заявляют об отсутствии конфликта интересов.

Contribution of the authors: the authors contributed equally to this article. The authors declare no conflicts of interests.

Статья поступила в редакцию 15.04.2025, одобрена после рецензирования 07.05.2025, принята к публикации 07.06.2025.

The article was submitted 15.04.2025, approved after reviewing 07.05.2025, accepted for publication 07.06.2025.