

УДК 004.89

ИСМАГУЛОВ С.Е., студент гр. ПИ416 (ЮГУ)
 ДОЛМАТОВА М.А., студент гр. ПИ416 (ЮГУ)
 ЛЕЙКО Е.А., студент гр. ПИ416 (ЮГУ)

Научный руководитель ШЕВЧЕНКО А.С., к.ф.-м.н., доцент (ЮГУ)
 г. Ханты-Мансийск

**ПРИМЕНЕНИЕ АНСАМБЛЕВЫХ МЕТОДОВ МАШИННОГО
ОБУЧЕНИЯ К СИСТЕМАМ ВИДЕОНАБЛЮДЕНИЯ ДЛЯ
ОТСЛЕЖИВАНИЯ ПОЖАРОВ**

Пожары на предприятиях и заводах представляют серьезную угрозу, вызывая не только непосредственные риски для персонала, но и цепные реакции в производственных процессах. Инциденты часто возникают из-за хранения опасных материалов, включая химикаты, краски и удобрения, что усиливает риск неконтролируемого распространения огня и токсичных веществ. По данным МЧС России, общее количество пожаров в последние годы сокращается, однако независимые источники фиксируют рост числа возгораний на промышленных объектах. Так, в 2023 году зарегистрировано 939 случаев. Это на 125,7% больше, чем в 2022 году, где показатель составил 416 пожаров. А за первые четыре месяца 2024 года отмечено 262 инцидента, что составляет около 30% от показателя 2023 года [4, 11].

Промышленные пожары способствуют загрязнению окружающей среды через выбросы токсичных веществ, включая металлы, полихлорированные ароматические углеводороды, диоксины и фураны. Экономические последствия выражаются в падении ВВП на 0,11-0,18% в пострадавших регионах и снижении занятости на 15% в совокупности за три года. В глобальном масштабе пожары выделяют около 8 млрд тонн углекислого газа ежегодно, усугубляя климатические изменения [6]. В Сибири пожары вызывают деградацию экосистем, утрату биоразнообразия и превращение углеродных стоков в источники выбросов. С начала 2000-х площадь возгораний в восточной Сибири выросла на 40% [10].

Текущие технологии видеофиксации и мониторинга пожаров основаны на системах видеонаблюдения, интегрирующих машинное обучение для анализа изображений и видео. Принцип работы типичной системы: камеры фиксируют видео, модель машинного обучения анализирует кадры на наличие огня или дыма, при их обнаружении генерируется сигнал тревоги. Для наглядности можно представить схему, представленную на рисунке 1 [1, 9].

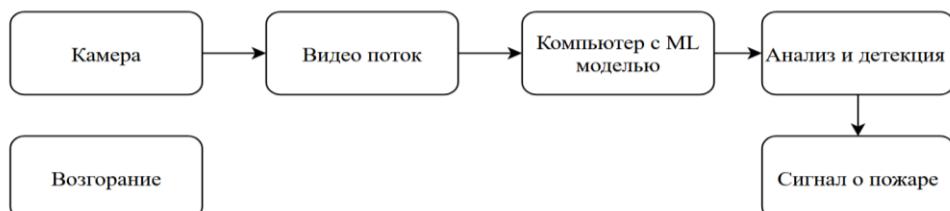


Рисунок 1. Схема функционирования системы видеонаблюдения для выявления возгораний

Однако существующие системы имеют недостатки, такие как ложные срабатывания из-за фоновой активности и пропуски в условиях низкой видимости, например, при тумане или изменяющемся освещении. Обзоры указывают на ограниченность данных для обучения, что снижает обобщаемость моделей с ложными срабатываниями до 51,3% в некоторых случаях [1].

Цель данной работы – повышение точности обнаружения пожаров за счет применения ансамблевых методов машинного обучения. Предлагаемый подход фокусируется на анализе источников пожара с разных ракурсов.

Существующие подходы к видеообнаружению пожаров можно разделить на три основные группы, т.к. традиционные методы основываются на анализе ручных признаков – цвета, текстуры, формы и движения. Для выделения пламени и дыма применяются цветовые модели (например, RGB), текстурные дескрипторы (например, SIFT) и методы анализа движения. Классификация выполняется алгоритмами вроде SVM или Adaboost [3,5]. Методы, использующие нейронные сети, применяют глубокое обучение для автоматического извлечения признаков и анализа видео без ручной настройки. Гибридные модели комбинируют CNN (Convolutional Neural Network), LSTM (Long Short-Term Memory) и Transformer для объединения пространственно-временных признаков и снижения числа ложных тревог.

Одиночные модели, включая традиционные алгоритмы и простые CNN, плохо устойчивы к условиям съёмки: изменения освещения, туман, движение камеры или фоновые объекты могут вызывать высокий уровень ложных срабатываний (до 51,3%). В сложных средах они переобучаются на ограниченных датасетах и пропускают малые или ранние пожары. Ансамблевые подходы предлагаются для минимизации указанных проблем [3,5].

Ансамблевые методы машинного обучения представляют собой подходы, где несколько базовых моделей объединяются для улучшения общей производительности по сравнению с использованием одиночных моделей. Комбинация нескольких слабых моделей позволяет создать сильную модель, которая минимизирует ошибки, связанные с переобучением, недообучением или шумом в данных. Это достигается через агрегацию предсказаний — например, голосование, усреднение или использование метамодели.

Среди ансамблей выделяется три основных подхода: параллельное обучение (bagging) на подвыборках данных с последующей агрегацией их результатов, последовательное обучение (boosting) с акцентом на ошибках предыдущих моделей и stacking, при котором предсказания базовых моделей подаются на вход метамодели, выполняющей итоговую классификацию. В контексте обнаружения пожаров в системах видеонаблюдения эти методы применяются для анализа видео с целью повышения точности детекции огня и дыма, особенно в условиях изменяющейся среды, такой как туман, освещение или разные ракурсы камер.

В задачах видеообнаружения пожаров ансамблевые методы объединяют признаки из последовательных кадров или различных источников, что повышает устойчивость и точность распознавания. Так, в модели Ensemble ResNetV2 предсказания нескольких ResNet извлекаются из последних слоёв (pooling и fully connected), классифицируются с помощью SVM (Support Vector Machine), а затем

агgregируются методом IHMV (Iterative Hard Majority Voting), обеспечивая точность 99,15% на датасетах изображений пожаров. Аналогично, в системе на основе YOLOv5 и EfficientDet ансамбль объединяет локальные детекторы с глобальным классификатором EfficientNet, снижая число ложных срабатываний [7,8].

Преимущества ансамблей в системах видеонаблюдения заключаются в способности обрабатывать данные с разных ракурсов и из разных источников, снижая тем самым количество ложных срабатываний и пропусков. В многокамерных системах ансамбли объединяют признаки, полученные под разными углами, повышая устойчивость к помехам – туману, дыму или фоновому движению. Например, модель GXLD сокращает параметры на 92,6%, достигая mAP 87,47% при 56 FPS. Ансамбли уменьшают ошибки одиночных моделей, обеспечивая точность до 98,91% при голосовании, что особенно важно для работы в реальном времени. В мультимодальных системах (например, RGB + IR) повышается точность детекции на 2–10%. Облегчённые варианты YOLO с 3,99 млн параметров дополнительно снижают вычислительную нагрузку, что делает ансамбли эффективными для edge-устройств [2].

Пример архитектуры системы видеообнаружения пожаров, представленный на рисунке 2, включает несколько камер, передающих поток данных на этап предобработки, далее – на ансамбль моделей для анализа и генерации сигнала тревоги. Камеры фиксируют изображение с разных ракурсов и в разных спектрах. Видео разделяется на кадры, после чего признаки извлекаются базовыми моделями и объединяются с помощью voting или stacking. При превышении порога уверенности формируется тревожный сигнал. В фреймворке FLAME такая схема дополняется вычитанием фона и отслеживанием движений, достигая F-Score 93,66% при задержке 9,17 с [1].

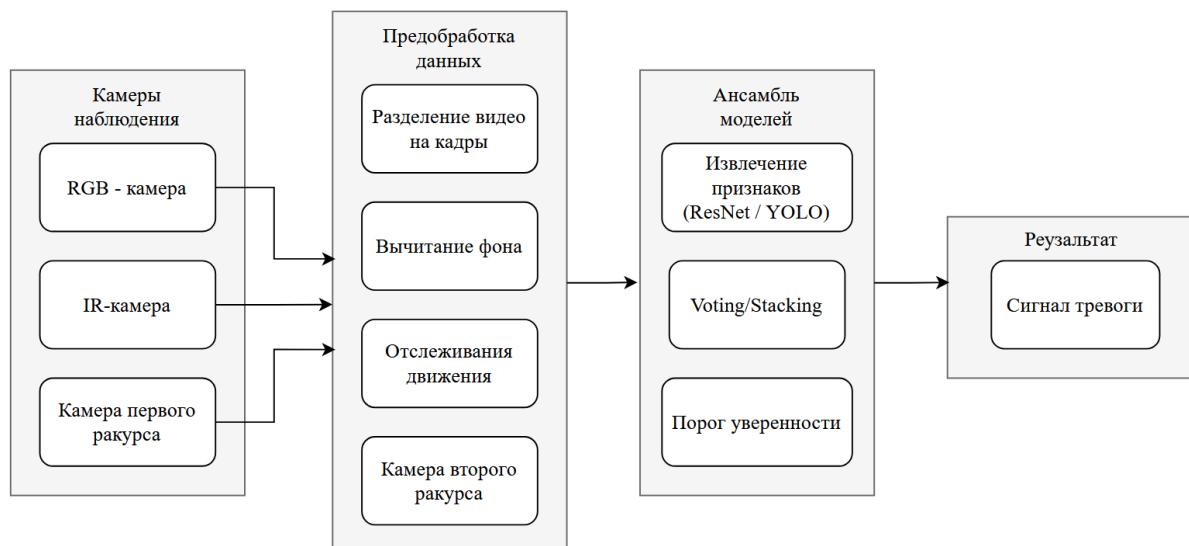


Рисунок 2. Архитектура ансамблевой системы для предсказания возникновения пожаров

Ансамбли демонстрируют устойчивое преимущество по сравнению с одиночными моделями: точность достигает 98,91%, а количество ложных

срабатываний снижается на 30–70% благодаря объединению предсказаний и мультиакурсному анализу. Использование нескольких камер в сочетании с предобработкой изображений, включая defogging, позволяет достичь mAP около 87% при скорости 56 кадров в секунду. Это содействует в повышении пожарной безопасности и снижении экономического и экологического ущерба, который ежегодно составляет миллиарды рублей и напрямую связан со значительными выбросами углекислого газа.

Применение ансамблей позволяет минимизировать ложные тревоги, улучшить надёжность раннего обнаружения и сократить время реакции систем наблюдения. Перспективы дальнейших исследований связаны с оптимизацией работы ансамблей в реальном времени, интеграцией с IoT-платформами и разработкой мультиакурсных датасетов для климатических условий России. Это создаёт основу для адаптивных систем видеомониторинга с онлайн-обучением и автоматическим управлением пожаротушением.

Список литературы:

1. Gragnaniello, D. FLAME: fire detection in videos combining a deep neural network with a model-based motion analysis // Greco A., Sansone C. [et al.] // Neural Computing and Applications. – 2025. – Vol. 37. – P. 6181–6197. – DOI: <https://doi.org/10.1007/s00521-024-10963-z>.
2. Huang, J. Real-Time Forest Fire Detection by Ensemble Lightweight YOLOX-L and Defogging Method // Z. He, Y. Guan, H. Zhang // Sensors. – 2023. – Vol. 23, № 4. – Art. 1894. – DOI: <https://doi.org/10.3390/s23041894>.
3. Jin, C. Video Fire Detection Methods Based on Deep Learning: Datasets, Methods, and Future Directions // T. Wang, T. Alhusaini // Fire. – 2023. – Vol. 6, № 8. – Art. 315. – DOI: <https://doi.org/10.3390/fire6080315>.
4. Kelley, D. I. State of Wildfires 2024–2025 [Электронный ресурс] // Earth System Science Data. C. A. Burton, Di Giuseppe F. [et al.] // 2025. – Vol. 17. – P. 5377. – DOI: 10.5194/essd-17-5377-2025. – URL: <https://essd.copernicus.org/articles/17/5377/2025/essd-17-5377-2025.html> (дата обращения: 06.11.2025).
5. Kumari, K. Review of Fire Detection and Localization Techniques in Video Surveillance Applications // M. Ahmed // Oriental Institute of Science & Technology. – [Б.м.]. – P. 35–39. URL: <https://indicajournal.net/volume-5-issue-1-2024/> (дата обращения: 06.11.2025).
6. Martin, D. Environmental impact of fire // M. Tomida, B. Meacham // Fire Science Reviews. – 2016. – Vol. 5. – Art. 5. – DOI: <https://doi.org/10.1186/s40038-016-0014-1>.
7. Sengul, D. Automated accurate fire detection system using ensemble pretrained residual network // P. D. Barua, H. Kutlu, [et al.] // Expert Systems with Applications. – 2022. – Vol. 203. – Art. 117407. – DOI: <https://doi.org/10.1016/j.eswa.2022.117407>. – URL: <https://www.sciencedirect.com/science/article/pii/S0957417422007497> (дата обращения: 06.11.2025).
8. Xu, R. Forest Fire Detection System Based on Ensemble Learning // H. X. Lin, K.A. Lu, [et al.] // Forests. – 2021. – URL: <https://api.semanticscholar.org/CorpusID:233928738> (дата обращения: 06.11.2025).

9. Yang, W. Deep Learning Method for Real-Time Fire Detection System for Urban Fire Monitoring and Control // Y. Wu, S. K. K. Chow // International Journal of Computational Intelligence Systems. – 2024. – Vol. 17. – Art. 216. – DOI: <https://doi.org/10.1007/s44196-024-00592-8>.
10. High carbon emissions from wildfires in the Russian Arctic [Электронный ресурс] // Copernicus Atmosphere Monitoring Service: сайт. – URL: <https://atmosphere.copernicus.eu/high-carbon-emissions-wildfires-russian-arctic> (дата обращения: 06.11.2025).
11. Russia [Электронный ресурс] // Global Forest Watch: сайт. – URL: <https://www.globalforestwatch.org/dashboards/country/RUS/?category=fires> (дата обращения: 06.11.2025).