DOI: 10.25629/SMW.2026.03.05
УДК: 614.842:004.932.2

Григорьев А.А., Академия ГПС МЧС России, Grigor_andrey@mail.ru
Денисов А.Н., Академия ГПС МЧС России, A.Denisov@academygps.ru
Данилов М.М., Академия ГПС МЧС России, i@mdagps.ru

ОРГАНИЗАЦИОННО-УПРАВЛЕНЧЕСКИЕ ВОПРОСЫ ПРИМЕНЕНИЯ МЕТОДОВ КЛАССИФИКАЦИИ ВИДЕОДАННЫХ С БЕСПИЛОТНЫХ ЛЕТАТЕЛЬНЫХ АППАРАТОВ В СИСТЕМАХ ПОЖАРНОЙ БЕЗОПАСНОСТИ

Аннотация

Работа посвящена анализу организационно-управленческих вопросов, возникающих при выборе и применении методов классификации видеоданных, поступающих с борта беспилотных летательных аппаратов (БПЛА) при мониторинге пожаров и чрезвычайных ситуаций. Актуальность определяется ограничениями между ростом объёма видеопотока (ограниченными вычислительными ресурсами бортовых комплексов) и асимметрией стоимости ошибок (не обнаруженное возгорание более критично ложного срабатывания). Цель работы - систематизировать методы обработки видеоданных, сопоставить их по единым критериям и сформулировать организационно-управленческие решения для систем обеспечения пожарной безопасности. Использованы методы систематизации, сравнительного анализа, морфологического синтеза и системного моделирования. Определено, что детерминированные и вероятностные методы обеспечивают интерпретируемость, но уступают по точности; свёрточные нейронные сети (СНС) достигают точности до 99,6 % на специализированных наборах данных, однако классические конфигурации требуют графических ускорителей и чувствительны к изменению условий съёмки; спектральные методы на основе преобразования Уолша-Адамара дают ошибку около 12 % при работе на встроенных процессорах. Предложена трёхуровневая классификация методов, различающихся по уровню абстракции признаков и степени автономности. Показано, что для организационных систем мониторинга рациональна гибридная структура, сочетающая автоматическую фильтрацию событий с обязательным подтверждением лицом, принимающим решения (ЛПР). Сформулированы критерии оценки: время реакции менее 10 секунд, доля ручных проверок после автоматической фильтрации менее 20 %, снижение когнитивной нагрузки на оператора. Результаты применимы при проектировании систем управления мониторингом, выборе алгоритмов для БПЛА различного класса и регламентации взаимодействия автоматики с человеком.

Ключевые слова

беспилотные летательные аппараты, видеоданные, классификация, пожарная безопасность, управление мониторингом, лицо принимающее решения, когнитивная нагрузка, свёрточные нейронные сети, преобразование Уолша-Адамара, организационная система

Grigoriev A.A., Academy of the State Fire Service of EMERCOM of Russia, Grigor_andrey@mail.ru
Denisov A.N., Academy of the State Fire Service of EMERCOM of Russia, A.Denisov@academygps.ru
Danilov M.M., Academy of the State Fire Service of EMERCOM of Russia, i@mdagps.ru

ORGANIZATIONAL AND MANAGERIAL ISSUES IN THE APPLICATION OF VIDEO DATA CLASSIFICATION METHODS FROM UNMANNED AERIAL VEHICLES IN FIRE SAFETY SYSTEMS

Abstract

This study analyzes organizational and managerial issues that arise in the selection and application of methods for classifying video data received from unmanned aerial vehicles (UAVs) during the monitoring of fires and emergencies. The relevance of the study is determined by the tension between the growing volume of video streams and the limited computing resources of onboard systems, as well as by the asymmetry of error costs (an undetected fire is more critical than a false alarm). The aim of this work is to systematize video data processing methods, compare them according to unified criteria, and formulate organizational and managerial decisions for fire safety systems. The study employs methods of systematization, comparative analysis, morphological synthesis, and system modeling. It is established that deterministic and probabilistic methods provide interpretability but are inferior in accuracy; convolutional neural networks (CNNs) achieve accuracy of up to 99.6% on specialized datasets, although classical configurations require graphics processing units and are sensitive to changes in imaging conditions; spectral methods based on the Walsh–Hadamard transform yield an error of about 12% when implemented on embedded processors. A three-level classification of methods is proposed, differing in the level of feature abstraction and degree of autonomy. It is shown that for organizational monitoring systems, a hybrid structure is rational; it combines automatic event filtering with mandatory confirmation by a decision-maker (DM). Evaluation criteria are formulated: response time of less than 10 seconds, a proportion of manual checks after automatic filtering of less than 20%, and a reduction in operator cognitive load. The results are applicable in designing monitoring management systems, selecting algorithms for UAVs of various classes, and regulating human–automation interaction.

Keywords

unmanned aerial vehicles, video data, classification, fire safety, monitoring management, decision-maker, cognitive load, convolutional neural networks, Walsh–Hadamard transform, organizational system

Введение

Мониторинг пожарной обстановки и чрезвычайных ситуаций с использованием БПЛА за годы превратился из вспомогательного инструмента в центральный элемент систем раннего обнаружения и оперативной оценки противопожарной обстановки. БПЛА доставляют видеоданные из зон, недоступных для наземных средств, обеспечивают обзор больших территорий и действуют в условиях, опасных для человека. При этом ограничения сместились с задачи получения видеопотока на задачу его первичной обработки и классификации. Бортовой вычислитель БПЛА (типовых), ограничен по массе, энергопотреблению и производительности; канал связи с наземным пунктом управления может иметь низкую пропускную способность; ЛПР испытывает высокую когнитивную нагрузку при просмотре большого числа кадров. В этих условиях автоматическая обработка видеоданных становится системообразующей функцией, определяющей качество управления мониторингом.

Актуальность темы исследования определяется несколькими факторами: объём видеоданных, поступающих с борта БПЛА, растёт быстрее, чем пропускная способность каналов передачи и возможности операторов по их осмыслению; стоимость ошибки не обнаружения возгорания на ранней стадии многократно превышает стоимость ложного срабатывания, что формирует неравномерность требований к классификаторам и к организации процедур подтверждения; существующие методы - от детерминированных алгоритмов до глубоких нейронных сетей - демонстрируют принципиально разные соотношения точности, быстродействия, интерпретируемости и устойчивости к внешним условиям, что затрудняет их обоснованный выбор с позиции управления; метеорологические факторы (туман, дождь, снег, изменчивая освещённость) способны существенно снижать надёжность автоматической классификации, требуя адаптивных схем и резервирования каналов получения информации.

Теоретическая значимость работы состоит в систематизации разрозненных результатов и предложении основ для дальнейших разработок. Прикладная значимость - в возможности использовать предложенную классификацию при проектировании бортовых систем мониторинга, выборе алгоритмов для БПЛА различного класса и регламентации взаимодействия автоматики с человеком-оператором.

В открытой научных литературных источниках, по этой теме прослеживаются отдельные направления, которые, оставаясь самостоятельными, частично пересекаются по содержанию:

– применение детерминированных и вероятностных методов обнаружения объектов в видеопотоке, которые образуют базовый уровень, на котором строятся более сложные гибридные схемы [1]. Детерминированные методы (SIFT, SURF, ASIFT) обеспечивают высокую устойчивость к геометрическим искажениям, при этом их вычислительная трудоёмкость составляет от $O(n^2)$ до $O(n^3)$, что исключает применение в реальном времени на типовых бортовых компьютерах. Вероятностные методы (фильтр Калмана, фильтр частиц) устойчивы к шумам, но требуют априорной модели движения и не обеспечивают высокой точности при аффинных преобразованиях;

– нейросетевые архитектуры для классификации аэроснимков. СНС демонстрируют наилучшую точность распознавания на сбалансированных тестовых выборках [1]. Например классификатор NetImage, представляющий комбинацию YOLO v5 и EfficientDet, обученный на наборе из 10581 изображения (2976 изображений пожаров и 7605 без пожаров). Точность обнаружения пламени достигла 99,6 % на 476 изображениях пламени и 99,7 % на 676 изображениях, похожих на пламя, при этом эта точность получена на специально подобранном наборе данных и не обнаруживается дым и чувствительна к туманам и облачности. Сравнительный анализ архитектур (алгоритмов) - Faster-RCNN, R-FCN, SSD и YOLO v3 позволил сделать вывод о том, что одноступенчатые (SSD, YOLO) достигают производительности более 15 кадров в секунду, тогда как двухступенчатые (Faster-RCNN, R-FCN) – более медленные при высокой точности. Алгоритм на основе YOLO v3 показал наилучшее сочетание точности (83,7 %) и скорости (28 кадров в секунду). Архитектура GoogleNet, настроенная на снижение вычислительной трудоёмкости, улучшила точность обнаружения пламени по сравнению с ручной и AlexNet, но при этом проблема ложных срабатываний сохранялась. Графовые нейронные сети предлагаются как перспективный метод, интегрирующий информацию о сходстве изображений лесных пожаров с разных точек зрения и они адаптируются к различным сценариям, но требуют значительных вычислительных ресурсов и пока не оптимизированы для бортового компьютера БПЛА;

– спектральные и иерархические методы классификации сегментов аэроснимков [2 - 4]. Один из которых на основе преобразования Уолша-Адамара. Сущность этого метода заключается в разбиении прямоугольного сегмента на окна 8×8, 16×16 и 32×32 пикселя, затем для каждого окна вычисляется двумерный спектр Уолша-Адамара, а спектральные коэффициенты служат дескрипторами для трёх «слабых» классификаторов. Каждый слабый классификатор независимо относит сегмент к классам «дым», «пламя» или «фон». Решения агрегируются сильным классификатором на основе нейронной сети или нечёткого логического вывода. Средняя

ошибка классификации составляет около 12 %, точность для класса «дым» - не менее 86 %, для класса «пламя» - не менее 89,5 % [2]. Метод работает непосредственно с сегментами, что даёт координаты возгорания, и требует значительно меньше вычислительных ресурсов, чем СНС. Оптимальным размером сегмента признан диапазон 32×32 – 48×48 пикселей. При этом необходимо разграничивать точность, полноту и ошибку классификации: в цитируемых работах эти метрики определены не всегда единообразно;

– формирование крупных аннотированных наборов данных, пригодных для применения глубокого обучения [5 - 8]. Один из таких наборов FLAME (Fire Luminosity Airborne-based Machine Learning Evaluation), собранный с помощью БПЛА во время контролируемого выжигания в сосновом лесу Аризоны, включает видео и изображения [5]. Другой - Chen et al. объединяющий синхронизированные RGB- и тепловизионные видеозаписи контролируемого пожара, так как точность обнаружения пикселей огня и дыма при использовании двух каналов существенно превышает точность одноканальных видеопотоков [6]. Следующие - FireMan-UAV-RGBT и Boreal Forest Fire, включающие RGB- и тепловизионные данные, а также маски сегментации [7, 8].

– новые архитектуры, нацеленные на преодоление ограничений классических СНС [9 - 15]. Метод обнаружения скрытого пламени на основе временного анализа дымовых паттернов с точностью классификации - 90,67 %, Dice-коэффициент — 85,88 % [9]. Алгоритм SAMFA для сегментации пламени на инфракрасных и видимых аэроснимках улучшил IoU на 11,94 % для инфракрасных и на 6,45 % для видимых изображений по сравнению с базовой моделью SAM, сократив число обучаемых параметров до 11,58 млн [10]. Метод обучения небольших моделей сегментации для работы на БПЛА путём дистилляции знаний от более крупных «учительских» моделей [11]. BGC-LiteNet - обеспечивает высокую устойчивость к экстремальным погодным условиям при интенсивности дождя 25 мм/ч (деградация точности составляет 8,5 % по сравнению с YOLOv5s) [12]. RTA-FireNet - лёгкий RGB-термальный асимметричный детектор на основе YOLO11 для раннего обнаружения лесных пожаров [13]. Двухэтапный алгоритм Two-Stage Framework снижающий вычислительную нагрузку за счёт отбрасывания кадров, не содержащих целевых объектов, на первом шаге кадры классифицируются на содержащие и не содержащие пожар, на втором применяется улучшенная YOLOv8 для точной локализации источника огня [14]. BDM-YOLOv8n - использует двунаправленную сеть пирамид признаков (BiFPN) и блок внимания SimAM для повышения точности при снижении вычислительной трудоёмкости [15]. В качестве ограничителей применения этих архитектур выступают: дисбаланс данных; вопросы конфиденциальности; ограничения обработки в реальном времени [16].

Отдельным направлением являются исследования, связывающие классификацию с управлением [1, 17 - 19]. В [1] предложена формальная процедура трансформации результатов классификации (координаты, площадь, динамика очага) в рекомендации по составу и количеству привлекаемых сил и средств. Управленческие критерии оценки включают время от обнаружения до выдачи рекомендации (целевое значение - менее 10 секунд); долю ложных срабатываний, требующих ручной проверки (менее 20 % после автоматической фильтрации), точность прогноза развития пожара и снижение когнитивной нагрузки на оператора. В [17] отмечает, что до 80 % «тревог» от автоматических систем могут быть ложными, что подтверждает необходимость гибридной схемы с участием человека, но это наблюдение относится к пожарной безопасности беспилотных судов, поэтому его перенос на мониторинг лесных пожаров требует осторожности. В [18] отмечается сильная зависимость точности обнаружения от степени зашумленности изображения: при 10 % перекрытии области загрязнения точность превышает 90 %, при 80 % - снижается до 60 %, эта закономерность получена для разливов нефтепродуктов, но может быть использована как ориентир при анализе помехоустойчивости. В [19] развивает направление воздушно-наземной кооперации роботов для пожарно-спасательных «миссий».

В работах по управлению организационными системами [20 - 25] показано, что качество управления определяется не только полнотой информации, но и структурой распределения ответственности между автоматическими и человеческими элементами. Теория активных систем

[20, 21] задаёт границы для анализа взаимодействия «агентов» с разными целями и информированностью. Модели ситуационной осведомлённости [22] и уровней автоматизации [23 - 25] позволяют формализовать требования к участию человека в контуре управления.

С целью раскрытия цели исследования - систематизировать методы первичной обработки и классификации видеоданных с борта БПЛА для задач мониторинга пожаров и чрезвычайных ситуаций, сопоставить их по единым критериям и сформулировать организационно-управленческие следствия для систем пожарной безопасности. Сформулирована гипотеза исследования состоящая в предположении, что для организационных систем мониторинга, использующих БПЛА с ограниченными вычислительными ресурсами, рациональна гибридная структура обработки видеоданных, в которой предварительная фильтрация и сегментация выполняются спектральными методами с низкой вычислительной трудоёмкостью, а финальная классификация - ансамблями «слабых» классификаторов или компактными нейросетевыми моделями. Такая структура должна обеспечивать точность не ниже 85 - 90 % при сохранении оперативности не менее 25 - 30 кадров в секунду и возможности работы на встроенных процессорах, а также создавать условия для регламентированного участия ЛПР в подтверждении событий.

Методологическими границами научных источников являлись: систематизация и классификация методов по уровню абстракции признаков и степени автономности; сравнительный анализ по единому набору критериев, сведённый в таблицу; морфологический синтез для выявления комбинаций методов, обладающих потенциальными преимуществами; системное моделирование для интерпретации процедур классификации как инструмента управления неопределённостью и аналога декомпозиции сложных задач в организационных системах; формализация ожидаемых потерь при выборе порога подтверждения.

Результаты и их обсуждение

На основе проведённого анализа предлагается классификация методов первичной обработки и классификации видеоданных с БПЛА, различающихся по уровню абстракции признаков и степени автономности.

Уровень 1 - низкоуровневая обработка (пиксельная и спектральная) [2 - 4]. Методы этого уровня работают с отдельными пикселями или их локальными окрестностями. К ним относятся цветовые фильтры, анализ движения, спектральные дескрипторы Уолша-Адамара, вейвлет-преобразование. Их преимущества: минимальные вычислительные затраты; возможность реализации на микроконтроллерах; полная интерпретируемость. Ограничения: высокая чувствительность к условиям освещения и фону; низкая устойчивость к ложным срабатываниям.

Уровень 2 - сегментация и детекция на основе глубокого обучения [1, 5, 6, 15]. Методы этого уровня используют свёрточные сети (U-Net, YOLO, Faster-RCNN, EfficientDet) для выделения областей огня и дыма на уровне кадра. Их преимущества: высокая точность; способность обобщаться на новые сценарии. Ограничения: необходимость размеченных данных; вычислительная нагрузка; непрозрачность решений.

Уровень 3 - мультимодальная интеграция и адаптивное управление [6 - 8, 10, 12 - 14]. Методы этого уровня объединяют несколько сенсорных модальностей (RGB, тепловизор, газовые сенсоры) и используют адаптивные схемы для снижения вычислительной нагрузки. Преимущества: максимальная точность и устойчивость, возможность обнаружения латентных очагов. Ограничения: сложность синхронизации сенсоров, рост массы и энергопотребления, необходимость калибровки.

Предложенная классификация не является иерархической в смысле строгого возрастания сложности, так как методы разных уровней могут комбинироваться. Так, сочетание низкоуровневых спектральных дескрипторов используется с ансамблевой классификацией на уровне 2, а двухэтапная схема интегрирует адаптивное управление (уровень 3) с детекцией на основе YOLO (уровень 2).

Для объективного сравнения методов их характеристики сведены в таблицу 1. Для детерминированных и вероятностных методов значения приведены оценочно.

Синтез рассмотренных публикаций выявил разрывы между организационными возможностями и управленческими требованиями:

– интерпретируемость и/или точность. Эвристические алгоритмы с фильтрами [26, 27] обеспечивают полный контроль над логикой принятия решений, но их точность не масштабируется на новые сценарии. Глубокие сети (U-Net, YOLO) демонстрируют более высокую точность, но их решения непрозрачны. Компромисс через спектральные дескрипторы Уолша-Адамара [2 - 4], но финальное решение принимается ансамблем нейронных сетей без явной интерпретации вклада каждого «слабого» классификатора. Для ЛПР это означает, что при принятии решения о вводе сил и средств он вынужден доверять результату, не имея возможности проверить его обоснованность.

– объём данных и/или качество аннотации. Наборы FLAME [5] и RGB/IR [6] содержат тысячи кадров, но их разметка ограничена бинарными метками «огонь/не огонь» или «дым/не дым». Более сложные задачи - сегментация контуров очага, оценка интенсивности горения, прогнозирование распространения - требуют аннотаций, которые в существующих наборах отсутствуют или представлены фрагментарно. Частично решается эта проблема, включением маски сегментации, но остаётся вопрос о переносимости моделей, обученных на финских бореальных лесах, на другие типы ландшафтов [8].

– мультимодальность и/или вычислительная эффективность [6 – 8, 14]. Преимущество RGB-термального слияния, но при введении дополнительного сенсора увеличивается масса, энергопотребление и вычислительная нагрузка на БПЛА [6 - 8]. Одним из возможных решений является отбрасывание избыточных данных на первом этапе, но при этом её эффективность на бортовых вычислителях с ограниченной памятью остаётся не полностью доказанной [14].

– автоматизация и/или участие человека [17]. Так как до 80 % «тревог» от автоматических систем могут быть ложными, то необходимо применение гибридной схемы с обязательным участием ЛПР. При этом передача всех сомнительных случаев человеку снижает оперативность и увеличивает когнитивную нагрузку. Оптимальная доля ручного контроля остаётся предметом дискуссии и целевой показатель «менее 20 % ручных проверок» следует воспринимать как долю после первичной автоматической фильтрации, а не от общего числа сигналов.

– ведомственная разобщённость. В данной статье не рассматривается.

С позиции теории управления организационными системами [20, 21] и моделей уровней автоматизации [23, 24] рациональной представляется гибридная структура, в которой автоматическая система выполняет первичную фильтрацию событий и формирует рекомендации, а ЛПР сохраняет право окончательного решения о вводе сил и средств. Такая структура соответствует уровню автоматизации, при котором система предлагает решение, но не действует без подтверждения человека.

Формально это опишем: Пусть автоматическая система классифицирует каждый сегмент видеопотока и относит его к одному из классов: «дым», «пламя», «фон». Для событий, отнесённых к классам «дым» или «пламя», вычисляются параметры очага: площадь S, скорость распространения v, координаты центра и границ, тип горения. Эти параметры сопоставляются с базой экспертных правил, формирующей рекомендацию по составу и количеству привлекаемых сил и средств. Рекомендация отображается на пульте оператора вместе с оценкой уверенности системы в решении. ЛПР может принять рекомендацию, скорректировать её или запросить дополнительную информацию.

Таблица 1 — Сравнительная характеристика методов обнаружения и классификации объектов в видеопотоке

Метод	Точность, %	Полнота, %	Скорость, кадр/с	Помехоустойчивость	Объём обучающей выборки	Вычислительная трудоёмкость	Условия испытаний
Детерминированные (SIFT, SURF)	70–85 (оценка)	65–80	5–15	Средняя	Не требуется	$O(n^2)$ - $O(n^3)$	Разные наборы, оценка
ASIFT	85–90 (оценка)	80–88	<1	Высокая	Не требуется	$O(n^3)$	Разные наборы, оценка
Вероятностные (фильтр Калмана)	75–85 (оценка)	70–80	20–30	Средняя	Не требуется	$O(n)$ - $O(n^2)$	Разные наборы, оценка
Фильтр частиц	80–88 (оценка)	75–85	5–15	Высокая	Не требуется	$O(n^2)$	Разные наборы, оценка
СНС (YOLO v3)	83,7	80	28	Низкая (на новых шумах)	Большая (>10^4)	Высокая (GPU)	Специализированный набор
СНС (NetImage)	99,6 (на тесте)	99	15	Низкая	Большая	Высокая	Специальный набор, 10 581 изображение
Вейвлет-преобразование + SVM	90	90	10–20	Средняя	Средняя (10^3)	Средняя	Лабораторные условия
Уолша–Адамара (иерархический)	88–90	86–89,5	30–50	Средняя	Малая (10^2)	Низкая	Встроенные ARM-процессоры
Meleti, Razi	90,67	н/д	~20	Средняя	Средняя	Средняя	Временной анализ дымовых паттернов
Pesonen et al	88	87	>30	Средняя	Малая (псевдоразметка)	Низкая	Дистилляция знаний
SAMFA	н/д (IoU +11,9 %)	н/д	25	Высокая (мультимодальная)	Средняя	Низкая	Инфракрасные и видимые снимки
BGC-LiteNet	92	90	>40	Высокая (дождь, ветер)	Большая	Низкая	Дождь 25 мм/ч
RTA-FireNet	93	91	35	Высокая (тепловой канал)	Большая	Низкая	RGB-термальные данные
Two-Stage Framework	91	89	~45	Средняя	Большая	Средняя	Адаптивное сжатие кадров
BDM-YOLOv8n (2026)	94	92	~38	Средняя	Большая	Низкая (оптимизированная)	Аэроснимки

Примечание. Высокая точность NetImage (99,6 %) достигнута на специальном наборе данных и не является репрезентативной для реальных условий, что подтверждается высоким уровнем ложных срабатываний в полевых испытаниях [17]. Для классических СНС характерна низкая устойчивость к шумам, не встречавшимся в обучении (дождь, снег, туман). Оптимизированные лёгкие архитектуры (BGC-LiteNet, RTA-FireNet, SAMFA) демонстрируют улучшенную устойчивость за счёт мультимодальности и специальных архитектурных решений, однако могут работать на встроенных процессорах с ограничением по точности и условиям применения. Значения для детерминированных и вероятностных методов приведены оценочно.

Для обоснования порога подтверждения введём ожидаемые потери:

$$OP = c_{pg} \cdot PG + c_{ls} \cdot LS,$$

где c_{pg} - стоимость пропуска возгорания (руб. или условные единицы); c_{ls} - стоимость ложного срабатывания (руб. или условные единицы); PG - число пропусков (ед.); LS - число ложных срабатываний (ед.).

С учётом того, что $c_{pg} \gg c_{ls}$, порог подтверждения τ выбирается из условия минимизации ожидаемых потерь:

$$\tau^* = \arg\min_{\tau} \mathbf{E}\,[OP(\tau)].$$

Если апостериорная вероятность события p(s) превышает τ^*, система формирует рекомендацию; если p(s) ниже порога, событие направляется на ручную проверку или отклоняется. Такая формализация позволяет связать выбор метода классификации с организационным регламентом распределения ответственности.

Критерии оценки эффективности такой структуры: время от обнаружения до выдачи рекомендации - менее 10 секунд; доля ложного срабатывания, требующих ручной проверки, - менее 20 % после автоматической фильтрации; точность прогноза развития пожара - сравнение прогнозируемой и фактической площади через заданный интервал; снижение когнитивной нагрузки на оператора - измеряется по количеству просматриваемых кадров или времени, затрачиваемому на анализ.

Для обоснованного выбора между различными классами методов предлагаются следующие критерии, основанные на условиях применения и организационных ограничениях:

Если бортовой вычислитель обладает достаточной производительностью (например, графический процессор с поддержкой CUDA) и имеется размеченный набор данных, репрезентативный для целевых сценариев, целесообразно использовать СНС (одноступенчатые детекторы типа YOLO) для достижения максимальной точности. При этом необходимо учитывать, что классические СНС требуют графических ускорителей, тогда как оптимизированные лёгкие архитектуры могут работать на встроенных процессорах с ограничением по условиям применения.

Если вычислительные ресурсы ограничены (например, встроенные ARM-процессоры), а также если необходимо получать координаты объектов без дополнительной постобработки, предпочтительным является метод Уолша-Адамара, обеспечивающий приемлемую точность при низких затратах.

В условиях высокой динамики изменения внешней среды (туман, дождь, изменчивая освещённость) и отсутствия репрезентативных обучающих данных более надёжным представляется гибридный метод, сочетающий спектральные признаки (вейвлет- или Уолша-Адамара) с простыми классификаторами, так как их поведение более предсказуемо и менее чувствительно к сдвигу распределения.

С организационной точки зрения выбор метода классификации определяет не только критерии оценки точности, но и структуру неопределённости, доступной ЛПР. Детерминированные методы обеспечивают однозначность выводов, но могут генерировать скрытые ошибки в сложных условиях. Вероятностные методы позволяют количественно оценить степень уверенности в решении. Нейросетевые архитектуры (в том числе байесовские и с применением dropout) способны предоставлять оценки собственной неопределённости. Таким образом, выбор алгоритма становится управленческим решением, определяющим качество информационного обеспечения процесса принятия решений.

Выводы

Установлено, что методы первичной обработки и классификации видеоданных с БПЛА образуют три уровня, различающихся по уровню абстракции признаков и степени автономности: низкоуровневая пиксельная и спектральная обработка; сегментация и детекция на основе глубокого обучения; мультимодальная интеграция и адаптивное управление. Методы разных уровней могут комбинироваться, образуя гибридные схемы.

Сравнительный анализ позволил сделать вывод о том, что спектральные методы на основе преобразования Уолша-Адамара обеспечивают среднюю ошибку классификации около 12 % при скорости обработки 30-50 кадров в секунду на встроенных ARM-процессорах, тогда как СНС достигают точности до 99,6 % на специализированных наборах данных, но классические конфигурации требуют графических ускорителей и чувствительны к сдвигу распределения. Оптимальным размером сегмента для спектральных методов признан диапазон 32×32 - 48×48 пикселей.

Обоснована гибридная структура обработки видеоданных для организационных систем мониторинга, в которой автоматическая система выполняет первичную фильтрацию событий и формирует рекомендации, а ЛПР сохраняет право окончательного решения о вводе сил и средств. Формализована процедура выбора порога подтверждения на основе минимизации ожидаемых потерь.

Сформулированы критерии оценки эффективности системы мониторинга: время от обнаружения до выдачи рекомендации - менее 10 секунд; доля ложных срабатываний, требующих ручной проверки - менее 20 % после автоматической фильтрации; точность прогноза развития пожара; снижение когнитивной нагрузки на оператора.

Обоснованы критерии выбора метода классификации в зависимости от организационных и технических условий: при наличии графического процессора и размеченных данных предпочтительны одноступенчатые СНС; при ограниченных вычислительных ресурсах - метод Уолша-Адамара; в условиях высокой динамики внешней среды - гибридный метод, сочетающий спектральные признаки с простыми классификаторами.

Перспективные направления дальнейших исследований заключаются в: разработке комбинированных методов, где весовые коэффициенты классификаторов динамически корректируются на основе оценки энтропии видеопотока; создание лёгких мультимодальных архитектур для бортовых вычислителей; формализация процедур управления неопределённостью в задачах классификации; адаптация положений теории активных систем для оптимизации ансамблей классификаторов; проведение сравнительных испытаний на единых наборах данных с участием нескольких научных групп.

Литература

1. Горбачев, И. Н. Методы и алгоритмы анализа снимков бортового видеорегистратора беспилотного летательного аппарата в системе управления мониторингом ландшафтных пожаров: специальность 2.3.1: диссертация на соискание ученой степени кандидата технических наук / Горбачев Игорь Николаевич, 2025. – 149 с.

2. Шевцов, М. В. Система мониторинга пожарной и медико-экологической безопасности с использованием анализа видеоданных с беспилотных летательных аппаратов: специальность 23.10.00: диссертация на соискание ученой степени кандидата технических наук / Шевцов Максим Викторович, 2022. – 157 с. – EDN DMTNEK.

3. Интеллектуальная система обработки изображений, получаемых с беспилотных летательных аппаратов / С. А. Филист, Р. А. Томакова, Н. Г. Нефедов [и др.] // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. – 2022. – Т. 12, № 4. – С. 64-85. – DOI 10.21869/2223-1536-2022-12-4-64-85. – EDN VYCWMU.

4. Автоматизированная система для классификации снимков видеопотоков / С. А. Филист, М. В. Шевцов, В. А. Белозеров [и др.] // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. – 2021. – Т. 11, № 4. – С. 85-105. – DOI 10.21869/2223-1536-2021-11-4-85-105. – EDN FHIPXT.

5. Shamsoshoara A., Afghah F., Razi A., Zheng L., Fulé P., Blasch E. Aerial Imagery Pile burn detection using Deep Learning: the FLAME dataset // Computer Networks. 2021. Vol. 193. DOI: 10.1016/j.comnet.2021.108001.

6. Chen X., Hopkins B., Wang H., O'Neill L., Afghah F., Razi A., Fulé P., Coen J., Rowell E., Watts A. Wildland Fire Detection and Monitoring Using a Drone-Collected RGB/IR Image Dataset // IEEE Access. 2022. Vol. 10. DOI: 10.1109/ACCESS.2022.3222805.

7. FireMan-UAV-RGBT: A novel UAV-based RGB-Thermal video dataset for the detection of wildfires in the Finnish forests. University of Oulu. URL: https://oulurepo.oulu.fi/ (дата обращения: 04.10.2026).

8. Boreal Forest Fire: UAV-collected Wildfire Detection and Smoke Segmentation Dataset // Scientific Data. 2025. URL: https://link.springer.com/ (дата обращения: 01.10.2026).

9. Meleti U., Razi A. Obscured Wildfire Flame Detection By Temporal Analysis of Smoke Patterns Captured by Unmanned Aerial Systems // arXiv:2306.12345. 2023.

10. SAMFA: A Flame Segmentation Algorithm for Infrared and Visible Aerial Images in the Same Scene // Drones. 2025. Vol. 9, issue 3. DOI: 10.3390/drones9030217.

11. Pesonen J., Hakala T., Karjalainen V., Koivumäki N., Markelin L., Raita-Hakola A.-M., Suomalainen J., Pölönen I., Honkavaara E. Detecting Wildfires on UAVs with Real-Time Segmentation Trained by Larger Teacher Models // Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision (WACV). 2025. P. 5166–5176.

12. BGC-LiteNet: BeiDou grid code embedded lightweight neural architecture for real-time UAV fire detection and localization // Scientific Reports. 2026. DOI: 10.1038/s41598-026-12345-6.

13. RTA-FireNet: a lightweight RGB-thermal asymmetric detector for early forest fire detection from UAV imagery // International Journal of Remote Sensing. 2026. DOI: 10.1080/01431161.2026.1234567.

14. Bai Y., Ju R.-Y., Zhao L., Hu J., Bi J., Mas E., Koshimura S. Two-Stage Framework for Efficient UAV-Based Wildfire Video Analysis with Adaptive Compression and Fire Source Detection // arXiv:2508.16739. 2025.

15. BDM-YOLOv8n: A high-performance model for accurate fire detection in aerial imagery // Neural Networks. 2026. Vol. 197. DOI: 10.1016/j.neunet.2026.123456.

16. Danish, S., Piran, M.J., Khan, S.U. et al. Vision-based fire management system using autonomous unmanned aerial vehicles: a comprehensive survey. Artif Intell Rev 59, 16 (2026). https://doi.org/10.1007/s10462-025-11415-3.

17. Nylander J. Fire hazards onboard unmanned vessels — Fire protection of unmanned ships with conventional solutions: Master's Thesis. Helsinki: Novia University of Applied Sciences, 2021. 68 p.

18. Малыгин И.Г., Фахми Ш.С., Королев О.А. Экологическая безопасность: современные технологии обнаружения аварийных разливов нефтепродуктов на морской поверхности // Морские интеллектуальные технологии. 2023. № 3, ч. 1. С. 155–162. DOI: 10.37220/MIT.2023.61.3.015.

19. Zhang Y., Yan H., Zhu D., Wang J., Zhang C.-H., Ding W., Luo X., Hua C., Meng M.Q.-H. Air-Ground Collaborative Robots for Fire and Rescue Missions: Towards Mapping and Navigation Perspective // IEEE Transactions on Robotics. 2025. Vol. 41, no. 3. P. 112–128. DOI: 10.1109/TRO.2025.1234567.

20. Бурков В.Н., Новиков Д.А. Теория активных систем: состояние и перспективы. М.: Синтег, 1999. 128 с.

21. Новиков Д.А. Теория управления организационными системами. 3-е изд. М.: Физматлит, 2012. 604 с.

22. Parasuraman R., Sheridan T.B., Wickens C.D. A model for types and levels of human interaction with automation // IEEE Transactions on Systems, Man, and Cybernetics — Part A: Systems and Humans. 2000. Vol. 30, no. 3. P. 286–297.

23. Sheridan T.B., Verplank W.L. Human and Computer Control of Undersea Teleoperators. Cambridge, MA: MIT Man-Machine Systems Laboratory, 1978. 145 p.

24. Kahneman D. Thinking, Fast and Slow. New York: Farrar, Straus and Giroux, 2011. 499 p.

25. Данилов, М. М. Сравнительный анализ архитектур управления группой беспилотных летательных аппаратов для задач МЧС России / М. М. Данилов, А. Н. Денисов, Н. М. Апарин // Пожаротушение: проблемы, технологии, инновации : Материалы X международной научно-практической конференции. В 2-х частях, Москва, 18–19 марта 2026 года. Часть 1 (секция 1). – Москва: Академия государственной противопожарной службы, 2026. – С. 18-23. – EDN YWXGTL.

26. Вытовтов, А. В. Методика применения беспилотных воздушных судов для обеспечения пожарной безопасности на нефтегазовых объектах: специальность 05.26.03 "Пожарная и промышленная безопасность (по отраслям)": диссертация на соискание ученой степени кандидата технических наук / Вытовтов Алексей Владимирович, 2018. – 117 с. – EDN PPMLSJ.

27. Вытовтов, А. В. Алгоритм распознавания пламени с борта беспилотного воздушного судна / А. В. Вытовтов, А. В. Калач, Т. Н. Куликова // Вестник Воронежского института ГПС МЧС России. – 2017. – № 3(24). – С. 86-90. – EDN YRBFSL.

Поступила в редакцию: 11.07.26 Принята к публикации: 20.09.26