

Обзорная статья

УДК 004.85; DOI: 10.61260/2307-7476-2025-2-59-73

ПРОБЛЕМЫ ОБНАРУЖЕНИЯ ПОЖАРА ПО ВИДЕОИЗОБРАЖЕНИЮ: ОБЗОР ИССЛЕДОВАНИЙ

✉ Шкурат Данил Евгеньевич;
Матвеев Александр Владимирович.
Санкт-Петербургский университет ГПС МЧС России, Санкт-Петербург, Россия
✉ danielshkurat@gmail.com

Аннотация. Обнаружение пожара на ранних стадиях является важным фактором, способным обеспечить снижение ущерба экономике и экологии, а также уменьшения количества пострадавших. Несмотря на возрастающую популярность нейронных сетей как современного метода решения задач в сфере компьютерного зрения, в работах в данной предметной области часто возникают методологические проблемы, ведущие к снижению или полному обесцениванию практических результатов. Данное исследование посвящено поиску таких проблем среди имеющихся работ по обнаружению пожара. В первом разделе проведен контрастный анализ двух работ, в ходе которого были выделены 11 метакритериев для оценки качества исследований. Во втором разделе проведен обзор нескольких работ, посвященных обнаружению пожара в различных условиях, как «классическими» методами, так и с помощью сверточных нейронных сетей. Показана важность правильного выбора метрик, необходимость выбора модели как процесса, полноценного описания исходных данных.

Ключевые слова: компьютерное зрение, машинное обучение, искусственный интеллект, обнаружение объектов, нейронные сети, сверточные нейронные сети, каскадный детектор Хаара, раннее обнаружение пожара

Для цитирования: Шкурат Д.Е., Матвеев А.В. Проблемы обнаружения пожара по видеоизображению: обзор исследований // Природные и техногенные риски (физико-математические и прикладные аспекты). 2025. № 2 (54). С. 59–73. DOI: 10.61260/2307-7476-2025-2-59-73

Review article

FIRE DETECTION PROBLEMS FROM VIDEO IMAGES: A REVIEW OF RESEARCH

✉ Shkurat Danil E.;
Matveyev Alexander V.
Saint-Petersburg university of State fire service of EMERCOM of Russia, Saint-Petersburg, Russia
✉ danielshkurat@gmail.com

Abstract. Early fire detection is an important factor that can reduce economic and environmental damage and reduce the number of victims. Despite the growing popularity of neural networks as a modern method for solving problems in computer vision, methodological problems often arise in works in this subject area, leading to a decrease or complete devaluation of practical results. This study is devoted to finding such problems among existing works on fire detection. The first section contains a contrast analysis of two works, during which 11 meta-criteria were identified to assess the quality of studies. The second section contains an overview of several works devoted to fire detection in various conditions, both by «classical» methods and using convolutional neural networks. The importance of the correct choice of metrics, the need to choose a model as a process, and a full description of the source data are shown.

Keywords: computer vision, machine learning, artificial intelligence, object detection, neural networks, convolutional neural networks, Haar Cascades, early fire detection

For citation: Shkurat D.E., Matveyev A.V. Fire detection problems from video images: a review of research // Prirodnye i tekhnogennye riski (fiziko-matematicheskie i prikladnye aspekty) = Natural and man-made risks (physico-mathematical and applied aspects). 2025. № 2 (54). P. 59–73. DOI: 10.61260/2307-7476-2025-2-59-73

Введение

За 2024 г. в России произошло более 347 тыс. техногенных пожаров, приведших к гибели более 7,5 тыс. чел. [1]. За большую часть пожароопасного сезона произошло 10,1 тыс. лесных пожаров. Площадь, пройденная огнем, составила 7,7 млн га [2]. Пожары оказывают разрушительный эффект на экономику и экологию: по подсчетам Рослесхоза, годовой ущерб от лесных пожаров составляет порядка 20 млрд руб. [3]; оценка выброшенного углерода из-за крупных лесных пожаров за 2021 г. составляет 66,4 млн т [4]. Ранее обнаружение пожара снижает количество жертв, ущерб инфраструктуре, а также уменьшает вред экологии [5].

Задача обнаружения пламени до сих пор не утратила своей актуальности, несмотря на долгую историю проблемы и значительное количество исследований в данной предметной области. Так, в статье [6] представлен обзор 12 решений, включающих в себя различные модели нейронных сетей, решающих деревьев, нечеткой логики, метода опорных векторов, скрытых Марковских моделей и др., результаты сравнения данных моделей между собой. В качестве исходных данных использовались не только видеоизображения, но еще и состав газов, температура, ионизация и другие параметры, анализ которых производился не только традиционными методами, но и с помощью технологий машинного обучения. Однако авторы не комментируют приведенные метрики результатов использования данных методов, оставляя более глубокий анализ читателю.

Настоящее исследование сфокусировано на анализе статей, где для обнаружения пожара используется исключительно видеоизображение, без каких-либо других данных. В настоящем обзоре проводится критический анализ подходов к решению задачи обнаружения огня по видеоизображению. Цель исследования состоит в выявлении проблемы и ограничений решений, оценке устойчивости и применимости существующих методов в различных ситуациях, сравнение их между собой.

Работа состоит из двух разделов. В первом разделе проводится контрастный анализ двух работ, в ходе которого предлагается 11 метакритериев оценки качества результатов исследований. Во втором разделе анализируется несколько работ, рассматривающихся в порядке эволюции методов – от «классических» до «современных», использующих сверточные нейронные сети. В заключении расставлены акценты над наиболее значимыми проблемами и результатами как в решении конкретной задачи обнаружения пожара по видеосигналу, так и в более общей теме компьютерного зрения и машинного обучения.

Контрастный обзор работ, выделение метакритериев качества

К методам машинного обучения, в том числе и нейронным сетям, очень часто относятся как к «черному ящику», рассматривая входные факторы, выходной результат, а что происходит внутри – неважно. Эта абстракция не является злом сама по себе, тем более что в нейронных сетях мы действительно не можем сказать, какой нейрон за что отвечает, но в некоторых ситуациях «черный ящик» становится «золотым молотком», который неправильно применяют к неверно понятым задачам, что приводит в конечном счете к некорректно интерпретируемым результатам.

Рассмотрим, например, работу [7], посвященную обзору и сравнению сверточных нейронных сетей (далее CNN) для обнаружения лесных пожаров. В данной статье собраны самые распространенные ошибки, которые встречаются в подобного рода исследованиях.

В аннотации авторы используют непривычную для предметной области терминологию: «Машинное обучение используется для расчета (to calculate) изображений». Термин «расчет» или «вычисление» (calculate) используется крайне редко, но в этих случаях,

как правило, идет речь о других задачах, в которых есть свои, более привычные термины; здесь мы имеем в виду задачи обратной свертки (также известной как деконволюция или развертка, англ: «Deconvolution») или генерации (generation) новых изображений. Впрочем, нестандартная терминология – не такая уж большая проблема, в отличие от указанных далее.

Также стоит обратить внимание на эту фразу: «Извлечение сложных взаимосвязей между данными выполняется с помощью нескольких методов машинного обучения, состоящих из сверточной нейронной сети (CNN) и других моделей CNN» [7]. Сверточная нейронная сеть – это сеть, в которой есть сверточный слой. Сверточные слои необходимы для выделения признаков (feature extraction) [8], в том числе и для признаков более высокого порядка (higher-order features). И уже, когда они были выделены, – они, вместе с другими признаками, если таковые имеются, используются в решении поставленной задачи – регрессии или классификации. Сам по себе сверточный слой этих задач не решает. Противопоставлять «CNN» – «другим моделям CNN» не имеет никакого смысла, это один и тот же метод машинного обучения. Можно сравнивать одну модель с другой, но метод от этого никак не поменяется. Эта же ошибка встречается и в разделе «CNN».

Также в аннотации было заявлено сравнение производительности алгоритмов и получение информации для оптимизации, но в работе по факту это не представлено.

В введении авторы аргументированно объясняют необходимость предупреждения лесных пожаров из-за их разрушительного воздействия на окружающую среду. Представлены данные, доступные для обработки, в результате которой можно обнаружить очаг пожара. Также указаны возможные дальнейшие действия в случае обнаружения пожара.

В разделе «CNN» обоснован выбор сверточных слоев для нейронной сети, указаны области их применения, а также дана биологическая справка и описано внутреннее устройство сверточных и пулинговых (pooling) слоев.

В разделе «Методология» авторы пишут про источники данных и о других моделях в одном предложении, из-за чего сложно проследить, откуда и что было взято. Отсутствие доступа к исходным данным – это большая проблема в научном сообществе вообще и в сфере искусственного интеллекта в частности. Авторы указали, что данные были расположены в открытых источниках, а именно на сайте правительства Канады [9] и геологической службы США [10], но ссылки указали только на главные страницы, а не на страницы с данными, что сильно затрудняет поиск. К сожалению, не удалось найти, какой именно набор данных использовали авторы, но на сайте Kaggle [11] был обнаружен по меньшей мере похожий датасет. Его автор указал страницу сайта правительства Канады, где он взял исходные данные, а также описал их преобразование: «фотографии со спутников были получены по координатам лесных пожаров, которые и были выложены на сайте правительства Канады в расширениях: .gpkg, .kml (.kmz), .fgdb/.gdb, то есть в форматах для геоинформационных систем (GIS)» [11]. Если авторы также изначально брали файлы для GIS, то им необходимо было бы указать об этом.

Авторы указали структуру своей нейронной сети, но структуру других моделей, с которыми будет сравниваться разработка, не были приложены, нет даже текстового описания различий между ними. Более того, в начале раздела указывалось, что модель взята из источника [12], но далее по тексту нет ее упоминания, а сравнение происходит с моделями из работ [13, 14], ссылки на которые были даны уже в заключении. Не были указаны гиперпараметры, такие как количество эпох и оптимизатор для обучения модели авторов. Также не указано, были ли предобучены сторонние модели изначально или их также обучали авторы на своих данных.

В табл. 1 данного исследования приведены значения функции ошибок и точность. Задача определения объектов (object detection problem) в классическом ее понимании – это решение двух задач: локализации (localization) и классификации (classification), следовательно, появляются две функции потери, которые могут быть объединены в одну. Например, если \mathcal{L}_c – функция потери классификации (например, softmax), а \mathcal{L}_l – функция потери локализации (например, L_2), то функцию потери определения объекта можно

объявить как $\mathcal{L} = \max \{\alpha \mathcal{L}_c; \beta \mathcal{L}_l\}$, где $\alpha, \beta > 0$. Какую функцию потерь использовали авторы – неизвестно, поэтому извлечь какую-либо информацию из ее значения в целом невозможно.

Выбор метрики в статье также не обоснован. Метрика а-точность¹ должна использоваться, когда классы сбалансированы (наблюдений одного класса не много больше наблюдений второго, примерно одинаковое количество) и когда правильность определения обоих классов одинаково важна для нас. Вполне допустимо сделать второе предположение, поскольку им может быть не известно, что лучше: вызвать бригаду пожарных на место, где не случится пожар, или упустить потенциальное возгорание. Выполнимость первого же условия авторы должны были указать, поскольку эта информация им известна. При обсуждении метрик в задачах классификации очень желательно указывать, что принимают за положительный класс, а что за негативный. Скорее всего, этот момент был опущен, поскольку подразумевалось, что пожар – это положительный класс, но явное указание облегчило бы понимание метрик для читателей. Метрика для оценки решения задачи локализации (e.g. IoU) не приведена вовсе.

Все ошибки, допущенные в разделе «Методология», полностью лишают смысла заключение. Без знания того, что используется в качестве функции потерь нельзя понять, почему снижение ее ошибки с 0,2894 до 0,1568 является значительным, в особенности при ухудшении значения метрики. Если исходные данные не сбалансированы, то а-точность может быть очень высокой, даже если модель всегда дает один и тот же результат. Стоит отметить то, что не указано на какой выборке были получены эти результаты, было ли вообще разделение на обучающую и тестовую? Снова подчеркнем, что заявленного сравнения производительности алгоритмов не было, как и рекомендаций по оптимизации.

Для сравнения рассмотрим работу [12], на которую ссылаются авторы прошлой статьи. Мы будем останавливаться только на важных, по мнению авторов, моментах, не следя четко структуре статьи, лишь кратко опишем ее.

В введении рассказывается об актуальности вопроса контроля лесных пожаров, использовании снимков со спутников для решения этой задачи, проводится небольшой экскурс в историю методов, включая современные, а именно CNN.

В разделе «Материалы» (Materials) описываются технические подробности спутника, а также выбранных данных. Далее обосновывается необходимость автоматической разметки и описываются три используемых в работе способа [15–17] авторазметки.

В главе «Методы» приведены преимущества CNN и глубокого обучения, описываются архитектуры нейронных сетей, а также условия, в которых они будут обучены и проверены.

В «Результатах и обсуждении» выбираются метрики и количество данных для обучения, проверки и тестирования. Далее результаты сравниваются с автоматически размеченными данными и с данными, размеченными людьми, а после делаются выводы о работе нейронных сетей.

В заключении, что очевидно, авторы кратко описывают итоги своей работы.

Теперь рассмотрим детали, в первую очередь данные – авторы акцентируют внимание на том, что изображения со спутника имеют свою специфику, а именно то, что они не трехканальные (RGB), как обычные фотографии (а в случае Landsat-8 – 11-канальные). Авторы не рассматривают один из каналов (c8), поскольку у него пространственное разрешение (spatial resolution) отличается по сравнению с другими каналами. Данные были собраны со всего мира (исключая Антарктику) за август 2020 г. Выбор такого временного отрезка объясняют тем, что август и сентябрь наиболее критичные месяцы, когда пожары случаются на всех континентах (исключая Антарктиду). Из-за того, что не было серьезных

¹ Поскольку «accuracy» и «precision» имеют один и тот же устоявшийся перевод на русский: «точность», являясь при этом различными метриками, переводить их будем как «а-точность» и «р-точность» соответственно

ограничений на местность, то в данных есть и города, и горы, и тропические леса, то есть условия непостоянны и очень разнообразны, а потому итоговая сеть должна обладать высокой степенью генерализации. Поскольку настолько большой набор данных (8 194 изображений, размером 7600x7600 пикселей) невозможно разметить вручную, было решено использовать уже имеющиеся алгоритмы обнаружения пожара в пикселях по значениям каналов [16–18]. Затем изображения были разделены на более мелкие, размером 256x256 каждое, без перекрытий, получив таким образом 146 214 примеров. Полученный набор данных, объемом около 200 Гб, был выложен в свободный доступ. Для обучения, проверки и тестирования взяли 40, 10 и 50 % данных соответственно. Стоит отметить, что в данных присутствуют, как крупные пожары, так и группы мелких изолированных, а также примеры без пожаров (то есть полностью негативные).

Задача классификации была поставлена таким образом, что нужно было классифицировать не само изображение – есть на нем пожар или нет, а анализировать каждый пиксель – относится ли он к тому месту, где сейчас есть пожар или нет, тем самым создавая маску изображения.

Авторы предложили использовать три варианта архитектуры U-Net [18]:

1. U-Net (10c) – архитектура, использующая все 10 каналов (не считая отброшенного).

2. U-Net (3c) – использует только три канала: *c7*, *c6* и *c2*, была предложена в качестве эксперимента: возможно ли получить хорошие результаты при меньшем количестве полос, что ведет за собой экономию ресурсов, в том числе используемой памяти и занимаемом объеме пространства на ПЗУ.

3. U-Net-Light (3c) является облегченной версией U-Net (3c), попытка еще больше облегчить вычисления и сэкономить ресурсы.

Хоть изначально было построено несколько вариантов нейронных сетей, а потом из них отобрали три лучших, авторы не ставили цель найти оптимальную архитектуру нейронной сети, их целью было продемонстрировать, что сверточные нейронные сети способны воспроизводить результаты схожие получаемым с помощью устоявшихся алгоритмов. Поэтому факт отбракованных моделей не влияет на результаты, демонстрируемые нейронными сетями в целом. Имеющиеся нейронные сети могут быть улучшены и исследователи приводят предложения для последующих исследований.

Осуществили пятнадцать сценариев обучения нейронных сетей – по пять наборов данных на каждую из трех нейронных сетей. Первые три набора были получены, применяя описанные ранее алгоритмы, четвертый и пятый – это два из трех и пересечение трех соответственно. При проверке на тестовом наборе данных к этим методам автораметки можно будет относиться как к ансамблированным методам обучения. Пороговое значение для отнесения к позитивному или негативному классу был выбран один для всех случаев, авторы не проводили подбор этого гиперпараметра. Также важно отметить, что авторы указали характеристики ПК и операционную систему, на которой производилось обучение, количество эпох, оптимизатор и условия ранней остановки, а поскольку исходный код и данные находятся в открытом доступе, то каждый может повторить и/или оптимизировать обучение.

Прежде чем перейти к анализу результатов необходимо понять используемые метрики. Авторы выбрали F-score и IoU в смысле попиксельного предсказания, а не геометрического пересечения, подметили, что IoU в этом случае может быть выражено через F-score. Обосновали свой выбор тем, что это широко используемые метрики на соревнованиях по обнаружению объектов. Уточнили, что используют метрику по всему набору данных, а не среднее по пакетам. Объяснили, что из-за несбалансированности классов не стали использовать а-точность.

Практически для всех сценариев были получены одинаковые результаты, при этом наибольшая модель U-Net (10c) не всегда показывала наилучшие результаты, даже если сравнивать с облегченной архитектурой U-Net-Light (3c), из чего справедливо делается вывод, что каналы *c7*, *c6* и *c2* содержит большую часть информации для обнаружения пожаров. Была

подмечена обратная взаимосвязь метрики отклика и р-точности, но за исключением некоторых случаев разница между ними относительно небольшая. В свою очередь, отметим, что большая разница между метриками наблюдается, когда нейронные сети обучались на наборе данных размеченных Kumar-Roy алгоритмом или на пересечении трех методов, при том минимальная разница (хотя это не означает лучший результат) достигалась на трехканальной нейронной сети U-Net (3c).

После обучения нейронные сети проверили на вручную размеченных данных, при этом также проверялись три оригинальных метода разметки, чтобы можно было использовать эти результаты в качестве реферальных.

В целом отмечается снижение показателей метрики F-score, что объясняется смещением между ручной и автоматической разметкой. Нейросети, обученные на данных, размеченных с помощью алгоритмов Schroeder et al. и Kumar-Roy, показали большую полноту при этом без значительной потери р-точности, а в некоторых случаях выросла и она. У метода Murphy наблюдается низкая р-точность, но при этом большая полнота, а это означает, что этот метод относит большее число пикселей положительному классу, чем другие два метода, при этом у нейросетей, обученных на этом методе, наблюдается такое же поведение метрик.

Результаты нейронных сетей, обученных на ансамблированных моделях пересечения, совпали с ожидаемыми – получили наибольшую р-точность, но отклик значительно уменьшился, поскольку метод требует согласия всех трех моделей. Голосующая ансамблированная модель продемонстрировала лучшие результаты среди всех испытанных – большой отклик без уменьшения р-точности.

По мнению авторов, не хватает результатов от «чистых» ансамблированных моделей, поскольку нельзя сравнить разницу между ними и нейросетями, обученными на данных, размеченных этими моделями. Понятно, что у пересечения будет минимальный отклик, не больше, чем отклик у Kumar-Roy (равный 68,4), минимальный среди «чистых» моделей. Но представляется интересным понять, как сильно могут исправить показатели нейронные сети. Также любопытно было посмотреть на попарное пересечение методов ввиду наблюдаемой зависимости «высокая р-точность/меньший отклик» (и, наоборот, в случае Murphy). Возможно, объединив, скажем, Murphy и Schroeder et al., мы бы компенсировали низкую р-точность Murphy и небольшой отклик Schroeder. Тем более, если известно, что первый метод имеет тенденцию к ложно-положительным результатам, то ансамбль со взвешенным голосованием и нейронная сеть, обученная на размеченных такой моделью, показала бы лучшие результаты.

Авторы также уделили особое внимание отдельным примерам, где были обнаружены небольшие показатели метрик по сравнению с остальными. Так было замечено много ложноположительных предсказаний оригинальных методов. Дальнейший анализ показал, что проблема была не в совокупности условий, диктуемых методом, а в значениях порога классификации. Было также отмечено, что использование нейронных сетей снижает количество подобных ошибок.

Кратко перечислим, что было получено в ходе исследования и предоставлено для свободного доступа: набор данных размером более 200 Гб, большая часть размечена с помощью автоматической разметки, использующие эмпирические правила, для тестирования предлагаются данные, размеченные человеком, маски разметок, исходный код и модели нейронных сетей.

Контрастный анализ двух анализируемых публикаций позволяет выделить набор признаков, который демонстрирует понимания исследователями используемых ими методов, а также оценить качество полученных ими результатов в рамках проводимых исследований (таблица). Наличие или отсутствие одного или пары признаков еще не повод делать вывод о качестве исследования, но комплексный анализ по всему множеству признаков уже может позволить оценить то или иное исследование. Отметим, что первая работа [7] была выбрана не для создания контраста на фоне второй [8], а лишь по причине того, что в ней встречаются наиболее распространенные ошибки, характерные для подобного рода исследований.

Таблица

Метакритерии оценки исследований

Признак	Некачественная	Качественная
Терминология	Редко встречающаяся, размытое значение	Распространенная, общепринятая
Доступ к данным	Источник пустой или его нет вовсе	Доступ к данным открыт; указано к кому обратиться для их получения; указано как получить самостоятельно
Контекст задачи	Только объяснение актуальности задачи и классификация, к какому типу данная задача относится	Помимо доказательства актуальности указывается, чем данная задача отличается от ей подобных, какие требования успешного ее решения (например, максимизация р-точности важнее а-точности), какие у этой задачи специфические трудности, в том числе при решении с использованием других методов и технологий
Представление данных	Не описано, названо лишь расширение или общий формат данных	Описывается преобразование исходных данных в матричный, векторный или иной вид, пригодный для выбранного метода машинного обучения
Выбор признаков	Не проводится, используются все или не объясняется вовсе	Предлагается несколько вариантов, описывается ожидание от того или иного признака
Обработка данных	Не проводится; По-умолчанию стандартизуются ² ; Пропуски и выбросы удаляются или игнорируются	Выбор метода масштабирования аргументируется; Метод устранения пропусков (в том числе игнорирование или удаление) выбирается на основе количества данных и частоты пропусков, важности признаков и выбора метода решения задачи, подобная работа проводится и с выбросами (если применимо); Производится статистический анализ (например, построение диаграмм рассеяния, в том числе парных)
Разделение набора данных	Не описано; Обучение идет на всех данных; Разделено только на обучающую и валидационную выборку; «Подсматривание» в тестовую выборку (например, просмотр описательной статистики)	Разделение на три выборки: обучающую, валидационную и проверочную; В случае малого количества данных – это указывается и учитывается в дальнейшем анализе; Обсуждается необходимость стратификации разделения
Выбор модели	Указывается только метод решения, входные и выходные данные; Выбранная архитектура нейросети не комментируется; Гиперпараметры указаны без комментариев или не приведены вовсе; процесс выбора модели не описан, если вообще был; выбирается только одна модель	Выбор метода решения объясняется, причем можно выбрать несколько для последующего сравнения друг с другом; Гиперпараметры приведены, если не было процесса выбора модели, то это указывается и объясняется почему (чаще всего для удобства сравнения различных моделей); Предлагается несколько вариантов моделей, результаты которых потом сравнивают между собой, а также с ожидаемыми

² Необходимость стандартизировать данные встречается настолько часто, что это кажется неотъемлемой частью подготовки данных, тем не менее, есть методы, для которых нельзя проводить масштабирование, например, метод решающих деревьев [19], а также есть случаи, когда необходимо использовать другой метод масштабирования [20], например, min-max. Такие ситуации встречаются даже при использовании линейной регрессии, где масштабирование исходных данных (или его отсутствие) не влияет на результат

Признак	Некачественная	Качественная
Функция потери	MSE ³ (если применимо под тип задачи); Не уточняется (особенно плохо в случае необходимости комбинированной функции потерь)	Выбирается в зависимости от решаемой задачи минимизации; Оговаривается, есть ли дополнительные ограничения (например, скорость отклика)
Метрики	Выбор метрик не объяснен; Из описания данных невозможно понять правомерность применения метрики	Выбор метрики зависит от типа решаемой задачи, имеющихся данных, а также от поставленной цели; Уточняется, если имеются отличия от более привычного понимания метрики (например, попиксельная IoU, вместо геометрической); Уточняется, почему та или иная метрика, применяемая к типу решаемой задачи, не может быть использована в данном случае
Выводы	Констатируется исключительно успешность применения метода для решения поставленной задачи	Результат сравнивается с ожидаемым; даются комментарии, какие предположения оправдались, какие нет, анализируется почему; Анализируются примеры, на которых модель выдала большую ошибку, выдвигается предположения о причинах и возможности дальнейшего усовершенствования; Результаты сравниваются с другими методами (в том числе вне области машинного обучения)

Обзор исследований по видеобнаружению пожара

Работа [22] посвящена «классическим» методам обнаружения объектов. Авторы предложили свою четырехэтапную модель и сравнили ее с другими классическими методами, а именно:

- обобщенная цветовая модель (generic color model) [23];
- метод, основывающийся на видеосенсорах и методе опорных векторов [24];
- метод, основывающийся на компьютерном зрении для обнаружения огня и пламени в реальном времени [25];
- вероятностный подход для видеообнаружения огня [26].

Предлагаемый авторами метод состоит из последовательного объединения четырех этапов. Здесь под словом «последовательное» мы имеем в виду, что этот подход не является ансамблированной моделью, данные проходят от первого этапа к последнему, а он и только он уже делает вывод о наличии или отсутствии огня. На первом этапе находятся движущиеся области, используя модель гауссовой смеси (GMM). Обратим внимание, что авторы учли тот факт, что когда огонь горит уже какое-то время, то данный метод может не замечать движения в центре пламени, для заполнения пустот они также использовали GMM. После выделения областей производится цветовой анализ. Авторы замечают, что детектор пламени, основанный исключительно на анализе цвета, будет часто давать ложноположительные результаты. Из выбранных движущихся регионов, подходящих по цвету, выделяются (при наличии) признаки огня. К ним относят следующие: случайность области (1) – размеры области огня случайно изменяется от кадра к кадру, неровность поверхности (2) – в оттенках серого интенсивность свечения пикселей огня неравномерная, неровность контура (3) и оценка движения на основе шаблонов (4). После этого используется метод опорных векторов, который делает предсказание, используя выделенные признаки как входные данные. Таким образом, первые два этапа уменьшают область поиска (опять же, последовательно – сначала

³ MSE настолько часто используется, что часто забывают о ситуациях, когда предпочтительнее другие функции потерь [21], например MAE, в случаях распределения ошибки линейной регрессии по закону Лапласа

выделяются движущиеся объекты, а потом оставляют только подходящие по цвету), третий выделяет признаки из ограниченной области, после чего производится анализ.

Отдельно стоит отметить метрики оценки. Для каждого метода они приведены в отдельности для каждого видео, а также оценено среднее их значение. Указаны они в процентном соотношении истинно положительных (TPR) и ложноположительных (FPR) для видео с присутствием положительного класса и в процентном соотношении истинно отрицательных (TNR) и ложноотрицательных (FNR) для негативных индивидов. Поскольку количество кадров в каждом видео также известно, то можно перейти к абсолютным показателям, после чего вычислить любую интересующую нас метрику классификации. Для доказательства значимости улучшения, что предложенный метод работает лучше других, авторы используют критерий Уилкоксона над TPR и TNR, попарно сравнивая свой алгоритм с чужими.

Уязвимым местом является быстродействие алгоритма, а именно 1,486 с на кадр. Самый медленный из сравниваемых почти на 22 % быстрее, а самый быстрый – превосходит в четыре раза. Авторы не считают такую скорость проблемной, поскольку есть вычислительные мощности достаточные для функционирования алгоритма, а значит в данных условиях стоит сосредоточиться именно на точности, а не скорости отклика. Мы же отметим, что поскольку алгоритм состоит из нескольких этапов, то знание среднего времени обработки на кадр малоинформативно. Так как, например, если первые два этапа (сужающие) выполняются значительно быстрее выделения признаков и анализа, то возможно, что последние два будут выполняться настолько долго, что результат уже не будет иметь смысла, при этом среднее время анализа будет казаться приемлемым.

Работа [27] посвящена не раннему обнаружению пожара, а использованию системы распознавания объектов для поиска пути роботом, находящимся в уже горящем здании – тот должен построить путь к наибольшему очагу, поскольку он считается приоритетным. Были реализованы и сравнены два метода обнаружения очагов огня: с помощью каскадного детектора Хаара и нейронных сетей.

При анализе литературы авторы заметили, что при наличии поблизости других ярких объектов рядом с огнем точность определения снижается, а на простых фонах – наоборот, повышается. Из этого авторы сделали вывод, что важно не иметь ярких объектов во время обнаружения огня, тем самым проигнорировав проблему ложноположительных срабатываний, а не попытались ее решить.

При описании выбора модели каскадного классификатора Хаара авторы указали два параметра – коэффициент масштаба (scale factor), равный 1,01, уменьшающий исходное изображение на 1 % для того, чтобы «гарантировать обнаружение пожара алгоритмом», а также минимальное количество соседей (minNeighbours), равное 10, для «обеспечения высококачественных обнаружений» [27]. Авторы не комментируют, как именно гарантируется обнаружение огня после уменьшения размера изображения, ведь вместе с тем уменьшается и количество пикселей, а значит и информации для анализа. Обычно размер уменьшают для увеличения быстродействия, теряя при этом в точности. Найти баланс позволяет процесс выбора модели, который, к сожалению, не был описан. Со вторым параметром ситуация схожая. Возможно, авторы под «высококачественным обнаружением» имели в виду попытку защититься от ложноположительных срабатываний, но выбор данного значения также не был обоснован.

Необходимо отметить, что для каждого метода был использован свой набор данных. Если набор данных для обучения нейронной сети выложен в свободный доступ [28], то о датасете для обучения детектора Хаара мы знаем только то, что было использовано 519 изображений, 372 из которых – негативные примеры. Вышел несбалансированный набор, но авторы сослались на эмпирическое правило⁴, которое рекомендует для успешного обучения

⁴ Применение эмпирических правил зачастую не является ошибкой, поскольку зачастую они основаны на известных фактах о моделях и методах. Но выбор конкретного значения параметра модели, как правило, не относят к эмпирическим правилам, поскольку при решении разных задач, пусть даже одного типа, оптимальные значения параметров отличаются. Случай ошибочного применения эмпирических правил можно найти в сноске 2 и 3

использовать негативных примеров в два раза больше положительных. В свободном доступе вместо заявленных 533 изображений находится только 502, при этом они разбиты на тренировочную и валидационную выборку в соотношении 412 к 90. Тестовый набор данных также не был представлен. Но изображений, представленных в статье, не оказалось в датасете нейронной сети, так что можем предположить, что для этих целей был подготовлен отдельный набор.

Набор со свободным доступом также несбалансирован – там отсутствуют негативные классы. Исходя из постановки задачи, было бы логично собирать примеры огня в закрытых помещениях, но авторы составили обучающую и валидационную выборку из нескольких категорий (рисунок), наибольшую из которых составляют горящие машины. Из-за такого подхода модель может получить нежелательный сдвиг, проверить который можно только с помощью тестовой выборки с данными, приближенными к задаче.

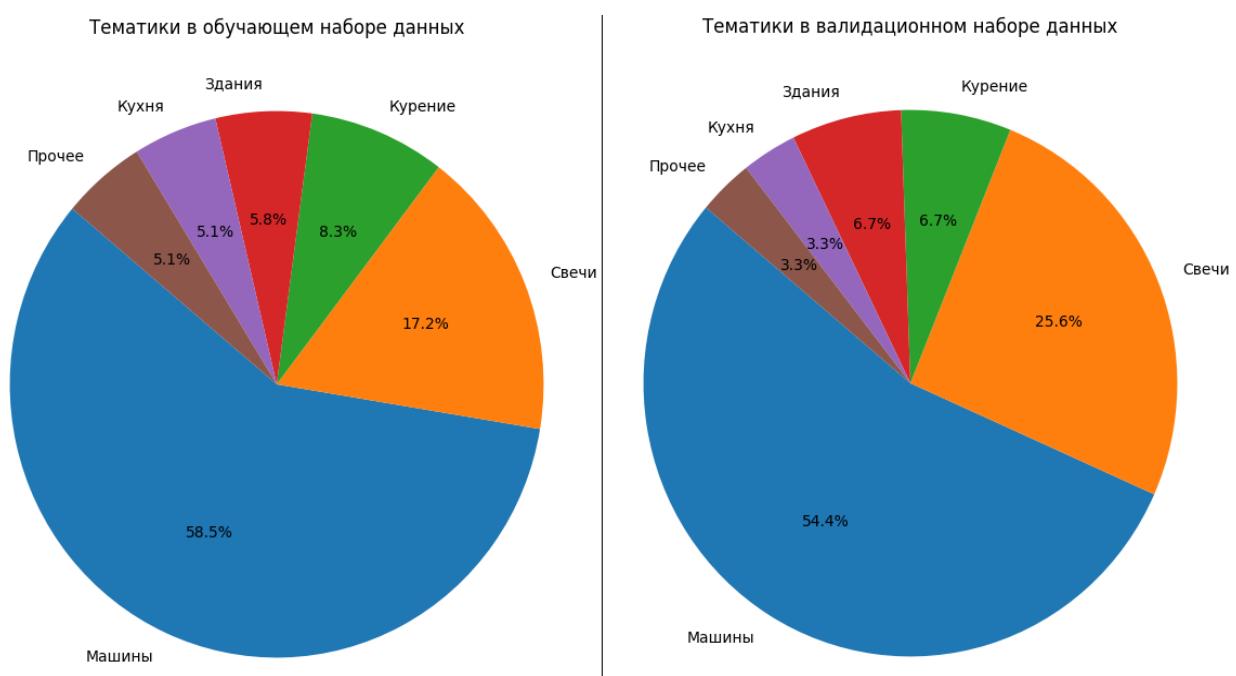


Рис. Тематики в обучающем и валидационном наборе данных

В заключение отмечено, что ресурсов Raspberry Pi недостаточно для работы системы обнаружения в реальном времени. В этом случае авторам логично было бы предоставить несколько вариантов моделей нейронных сетей и оценить соотношение качества моделей и возможности применения в реальном времени.

В данной статье обнаружение пламени является всего лишь шагом к выбору направления движения, при этом учитывается только размер видимого пламени и не рассматриваются случаи, когда пламя частично перекрыто. Это может привести к неверному выбору приоритетного очага со всеми последствиями такого выбора. Также формула выбора конечной точки не учитывает, что очаг пламени может не на полу, а на определенной высоте. Если камера фиксирована, то во время пути в «оптимальную точку» пламя окажется выше видимости камеры, а если подвижна, то при отсутствии видимости пола будет неверно рассчитана координата y .

Работа [29] также посвящена обнаружению лесных пожаров. Здесь детально описаны трудности наблюдения лесных пожаров, чего не было в исследованиях [7, 12, 15–17], которые (кроме [7]) опирались больше на технические особенности изображений со спутников. Хоть пламя обладает легко различимыми свойствами, такими как цвет, мерцание, увеличение размеров во времени и светимость, в контексте лесных пожаров возникают трудности из-за перекрытия кронами, – пока пламя не дойдет до них – его будет

не видно, что мешает раннему обнаружению. Дым, который заметен раньше пламени, может отличаться по цвету в зависимости от типа горючего и температуры, а также на него влияет скорость и направление ветра, в добавок его можно перепутать с туманом, облаками, паром, а также трудно обнаружить в ночных условиях. Обнаружение с помощью тепловых датчиков более устойчиво относительно свечения и перекрытия кронами, но оно дорогое и дает ложноположительные срабатывания из-за солнечных отражений и других горячих объектов.

В статье авторы также уделили внимание истории решений проблемы, где упоминались решения на основе эвристических правил, нечеткой логики, извлечения частоты мерцания и с использованием нейронных сетей. В обзоре литературы авторы также затронули тему цветовых пространств (RGB, HSI, YCbCr), их влияние на решение.

Для анализа были использованы изображения сжатые до разрешения 240×320 пикселей, которые впоследствии разделили на блоки размером 16×16 пикселей без перекрытий. Таким образом, каждое изображение было разбито на 300 блоков, которые будут анализировать нейросеть. Так увеличивается скорость предсказания одного экземпляра (блока) и увеличивается количество данных для обучения (из 20 изображений было получено 6 000 индивидов).

Авторы для упрощения вычислений отказались от анализа частоты мерцания, роста и движения, а также из-за того, что все эти параметры изменяются во времени, в то время как они хотели добиться анализа только по одному изображению. Для анализа они извлекают из блоков каналы Cb, Cr, H и S, а также текстурные признаки (texture extraction) с помощью матрицы совместной встречаемости уровней серого⁵ (GLCM – gray level co-occurrence matrix).

Хоть визуально можно оценить примерное количество индивидов положительных или отрицательного классов, но для более объективной оценки точности (как качества модели, а не как метрики) необходимо знать количество индивидов каждого экземпляра. Также не было указано, использовалась ли валидационная выборка, и если да, то каков ее размер.

Также стоит обратить внимание на то, что если на изображении присутствует дым и/или пламя, то модель обнаружит хотя бы один индивид из этих классов (далее будем иметь в виду, что оба положительны). Это, безусловно, хорошее свойство модели, но когда мы переходим от индивидов-блоков к индивидам-изображениям, возникает проблема маленькой выборки, поскольку количество индивидов для тестирования не указано, только продемонстрировано пять изображений. Учитывая, что для обучения использовали всего лишь 20 изображений, вполне вероятно, что и тестовая выборка была небольшой. Отклик⁶ отрицательного класса 87,4 % означает, что частота ложноположительных⁷ 12,6 %. Именно поэтому значимость данного свойства модели сомнительна, поскольку вероятность хотя бы одного ложноположительного срабатывания довольно высока, а так как на представленных изображениях нет чисто негативных индивидов, то нельзя оценить, как модель будет работать при отсутствии положительных классов.

Вообще ложноотрицательные срабатывания представляют особый интерес, поскольку матрица ошибок не была приведена и поэтому неизвестно, как часто один положительный класс путают с другим и оба – с отрицательным.

Заключение

В результате контрастного сравнения было получено 11 метапризнаков качества научных работ в сфере искусственного интеллекта, машинного обучения и обнаружения объектов в частности. Отмечены наиболее распространенные ошибки, возникающие из-за недостаточного понимания сущности работы методов машинного обучения.

⁵ Другой перевод: «матрица смежностей»

⁶ Авторы пишут «true positive rate» (он же recall) для фона, хоть для отрицательного класса корректнее использовать «true negative rate»

⁷ Относительно отклика корректнее было бы написать ложноотрицательных, но по своей сути они являются ложноположительными.

В представленном далее обзоре исследований, посвященных обнаружению пожара в различных условиях, особое внимание было уделено обоснованию выбора метрик, поскольку от этого зависит корректная работа модели и ее применимость вообще, в то время как за неудачным выбором может стоять попытка сфальсифицировать положительные результаты работы. Также затронут вопрос важности полноценного описания набора данных, в том числе указание сбалансированности датасета, а также способов преобразования исходных данных в формат, подходящий для машинного обучения. Обосновано, что процесс выбора модели должен быть именно процессом, а не заготовленным набором гиперпараметров.

Отмечен стремительный рост популярности сверточных нейронных сетей в задачах обнаружения объекта, но вместе с тем классические методы еще не признаются окончательно устаревшими и продолжают использоваться, дополняя модели, основанные на нейронных сетях.

Список литературы

1. РИА новости. В МЧС назвали число погибших при пожарах в 2024 году в России // РИА новости. 2024. URL: <https://ria.ru/20250212/mchs-1998813971.html> (дата обращения: 30.04.2025).
2. Федеральное агентство лесного хозяйства. Рослесхоз: в 2024 количество лесных пожаров сократилось в 1,5 раза в сравнении со среднепятилетними значениями // Федеральное агентство лесного хозяйства. 2024. URL: <https://rosleshoz.gov.ru/news/federal/rosleskhoz-v-2024-kolichestvo-lesnykh-pozharov-sokratilos-v-1-5-raza-v-sravnenii-so-srednepyatiletnimi-znacheniyami-n11213/> (дата обращения: 30.04.2025).
3. Терра Тех. Жаркое лето 2022: лесные пожары Центрального федерального округа // Терра Тех. 2022. URL: <https://geonovosti.terratech.ru/ecology/zharkoe-leto-2022-lesnye-pozhary-tsentrального-federalnogo-okruga/> (дата обращения: 30.04.2025).
4. Ершов Д.В., Сочилова Е.Н. Количественные оценки прямых пирогенных эмиссий углерода в лесах России по данным дистанционного мониторинга 2021 года // Вопросы лесной науки. 2022. Т. 5. № 4. С. 68–85. DOI: 10.31509/2658-607x-202254-117. EDN ZMZGMU.
5. Беломестных А., Малыхин А., Пешков А. Анализ пожарной опасности в жилом секторе Российской Федерации // Вестник Восточно-Сибирского института МВД России. 2009. № 4 (51). С. 71–79. EDN UGYWYX.
6. Kakde A., Arora N., Sharma D. Fire Detection System Using Artificial Intelligence Techniques // International Journal of Research in Engineering. 2018. Vol. 8. № 11. P. 1–5.
7. Abdurazak K.A., Duisek B.E. Overview and comparison of convolutional neural networks in fire detection // Научный аспект. 2023. Vol. 20. № 5. P. 2500–2505. EDN SZOJBK.
8. Gradient-based learning applied to document recognition / Yu. Lecun [et al.] // Proceedings of the IEEE. 1998. Vol. 86. № 11. P. 2278–2324. DOI: 10.1109/5.726791.
9. Government of Canada. Open Government Portal // Government of Canada. 2024. URL: <https://open.canada.ca/en> (дата обращения: 18.03.2025).
10. United States Geological Survey. United States Geological Survey // United States Geological Survey. 2024. URL: <https://www.usgs.gov/> (дата обращения: 18.03.2025).
11. Wildfire Prediction Dataset (Satellite Images). 2024. URL: <https://www.kaggle.com/datasets/abdelghaniaaba/wildfire-prediction-dataset> (дата обращения: 18.03.2025).
12. Active fire detection in Landsat-8 imagery: A large-scale dataset and a deep-learning study / G. H. de Almeida Pereira [et al.] // ISPRS Journal of Photogrammetry and Remote Sensing. 2021. Vol. 178. P. 171–186. DOI: 10.1016/j.isprsjprs.2021.06.002.
13. Murphy J.H. An overview of convolutional neural network architectures for deep learning // Microway Inc. 2016.
14. Roy P., Kumar A. Convolutional Neural Network for Text: A Stepwise Working Guidance // SSRN Electronic Journal. 2021. DOI: 10.2139/ssrn.3973041.

15. Active fire detection using Landsat-8/OLI data / W. Schroeder [et al.] // Remote Sensing of Environment. 2016. Vol. 185. P. 210–220. DOI: 10.1016/j.rse.2015.08.032.
16. HOTMAP: Global hot target detection at moderate spatial resolution / S.W. Murphy [et al.] // Remote Sensing of Environment. 2016. Vol. 177. P. 78–88. DOI: 10.1016/j.rse.2016.02.027.
17. Kumar S.S., Roy D.P. Global operational land imager Landsat-8 reflectance-based active fire detection algorithm // International Journal of Digital Earth. 2018. Vol. 11. № 2. P. 154–178. DOI: 10.1080/17538947.2017.1391341.
18. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation // Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. Cham: Springer International Publishing, 2015. P. 234–241. DOI: 10.1007/978-3-319-24574-4_28.
19. Hastie T., Tibshirani R., Friedman J. The Elements of Statistical Learning: Data Mining, Inference, and Prediction / 2nd ed. New York, NY, USA: Springer, 2009 (Springer Series in Statistics).
20. García S., Luengo J., Herrera F. Data Preprocessing in Data Mining. Vol. 72. New York, NY, USA: Springer, 2015 (Intelligent Systems Reference Library).
21. Saldiva de André C. D., Elian S.N. A Comparison of the Estimators of the Scale Parameter of the Errors Distribution in the L1 Regression // Open Journal of Statistics. 2022. Vol. 12. № 2. P. 261–276. DOI: 10.4236/ojs.2022.122018.
22. Xuan Truong T., Kim J.-M. Fire flame detection in video sequences using multi-stage pattern recognition techniques // Engineering Applications of Artificial Intelligence. 2012. Vol. 25. № 7. P. 1365–1372. DOI: 10.1016/j.engappai.2012.05.007.
23. Çelik T., Demirel H. Fire detection in video sequences using a generic color model // Fire Safety Journal. 2009. Vol. 44. № 2. P. 147–158. DOI: 10.1016/j.firesaf.2008.05.005.
24. Ko B.C., Cheong K.-H., Nam J.-Y. Fire detection based on vision sensor and support vector machines // Fire Safety Journal. 2009. Vol. 44. № 3. P. 322–329. DOI: 10.1016/j.firesaf.2008.07.006.
25. Computer vision based method for real-time fire and flame detection / B. Töreyin [et al.] // Pattern Recognition Letters. 2006. Vol. 27. P. 49–58. DOI: 10.1016/j.patrec.2005.06.015.
26. Borges P.A., Izquierdo E. Probabilistic Approach for Vision-Based Fire Detection in Videos // Circuits and Systems for Video Technology, IEEE Transactions on. 2010. Vol. 20. P. 721–731. DOI: 10.1109/TCSVT.2010.2045813.
27. Ramasubramanian S., Muthukumaraswamy S., Sasikala A. Fire Detection using Artificial Intelligence for Fire-Fighting Robots // 2020 4th International Conference on Intelligent Computing and Control Systems (ICICCS). United States: IEEE, 2020. P. 180–185. DOI: 10.1109/ICICCS48265.2020.9121017.
28. FireNET dataset. 2024. URL: <https://github.com/OlafenwaMoses/FireNET/releases> (дата обращения: 20.03.2025).
29. Wildfire Flame and Smoke Detection Using Static Image Features and Artificial Neural Network / F.M.A. Hossain [et al.] // 1st International Conference on Industrial Artificial Intelligence (IAI). 2019. P. 1–6. DOI: 10.1109/ICIAI.2019.8850811.

References

1. RIA novosti. V MCHS nazvali chislo pogibshih pri pozharah v 2024 godu v Rossii // RIA novosti. 2024. URL: <https://ria.ru/20250212/mchs-1998813971.html> (data obrashcheniya: 30.04.2025).
2. Federal'noe agentstvo lesnogo hozyajstva. Rosleskhoz: v 2024 kolichestvo lesnyh pozharov sokratilos' v 1,5 raza v sravnenii so srednepyatletnimi znacheniyami // Federal'noe agentstvo lesnogo hozyajstva. 2024. URL: <https://rosleshoz.gov.ru/news/federal/rosleskhoz-v-2024-kolichestvo-lesnykh-pozharov-sokratilos-v-1-5-raza-v-sravnenii-so-srednepyatletnimi-znacheniyami-n11213/> (data obrashcheniya: 30.04.2025).
3. Terra Tekh. Zharkoe leto 2022: lesnye pozhary Central'nogo federal'nogo okruga // Terra Tekh. 2022. URL: <https://geonovosti.terratech.ru/ecology/zharkoe-leto-2022-lesnye-pozhary-tsentrального-federalnogo-okruga/> (data obrashcheniya: 30.04.2025).

4. Ershov D.V., Sochilova E.N. Kolichestvennye ocenki pryamyh pirogennyh emissij ugleroda v lesah Rossii po dannym distancionnogo monitoringa 2021 goda // Voprosy lesnoj nauki. 2022. T. 5. № 4. S. 68–85. DOI: 10.31509/2658-607x-202254-117. EDN ZMZGMU.
5. Belomestnyh A., Malyhin A., Peshkov A. Analiz pozharnoj opasnosti v zhilom sektore Rossijskoj Federacii // Vestnik Vostochno-Sibirskogo instituta MVD Rossii. 2009. № 4 (51). S. 71–79. EDN UGYWYX.
6. Kakde A., Arora N., Sharma D. Fire Detection System Using Artificial Intelligence Techniques // International Journal of Research in Engineering. 2018. Vol. 8. № 11. P. 1–5.
7. Abdurazak K.A., Duisek B.E. Overview and comparison of convolutional neural networks in fire detection // Nauchnyj aspekt. 2023. Vol. 20. № 5. P. 2500–2505. EDN SZOJBK.
8. Gradient-based learning applied to document recognition / Yu. Lecun [et al.] // Proceedings of the IEEE. 1998. Vol. 86. № 11. P. 2278–2324. DOI: 10.1109/5.726791.
9. Government of Canada. Open Government Portal // Government of Canada. 2024. URL: <https://open.canada.ca/en> (data obrashcheniya: 18.03.2025).
10. United States Geological Survey. United States Geological Survey // United States Geological Survey. 2024. URL: <https://www.usgs.gov/> (data obrashcheniya: 18.03.2025).
11. Wildfire Prediction Dataset (Satellite Images). 2024. URL: <https://www.kaggle.com/datasets/abdelghaniaaba/wildfire-prediction-dataset> (data obrashcheniya: 18.03.2025).
12. Active fire detection in Landsat-8 imagery: A large-scale dataset and a deep-learning study / G. H. de Almeida Pereira [et al.] // ISPRS Journal of Photogrammetry and Remote Sensing. 2021. Vol. 178. P. 171–186. DOI: 10.1016/j.isprsjprs.2021.06.002.
13. Murphy J.H. An overview of convolutional neural network architectures for deep learning // Microway Inc. 2016.
14. Roy P., Kumar A. Convolutional neural network for text: a stepwise working guidance // SSRN Electronic Journal. 2021. DOI: 10.2139/ssrn.3973041.
15. Active fire detection using Landsat-8/OLI data / W. Schroeder [et al.] // Remote Sensing of Environment. 2016. Vol. 185. P. 210–220. DOI: 10.1016/j.rse.2015.08.032.
16. HOTMAP: Global hot target detection at moderate spatial resolution / S.W. Murphy [et al.] // Remote Sensing of Environment. 2016. Vol. 177. P. 78–88. DOI: 10.1016/j.rse.2016.02.027.
17. Kumar S.S., Roy D.P. Global operational land imager Landsat-8 reflectance-based active fire detection algorithm // International Journal of Digital Earth. 2018. Vol. 11. № 2. P. 154–178. DOI: 10.1080/17538947.2017.1391341.
18. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation // Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. Cham: Springer International Publishing, 2015. P. 234–241. DOI: 10.1007/978-3-319-24574-4_28.
19. Hastie T., Tibshirani R., Friedman J. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. 2nd ed. New York, NY, USA: Springer, 2009 (Springer Series in Statistics).
20. García S., Luengo J., Herrera F. Data Preprocessing in Data Mining. Vol. 72. New York, NY, USA: Springer, 2015 (Intelligent Systems Reference Library).
21. Saldiva de André C. D., Elian S.N. A Comparison of the Estimators of the Scale Parameter of the Errors Distribution in the L1 Regression // Open Journal of Statistics. 2022. Vol. 12. № 2. P. 261–276. DOI: 10.4236/ojs.2022.122018.
22. Xuan Truong T., Kim J.-M. Fire flame detection in video sequences using multi-stage pattern recognition techniques // Engineering Applications of Artificial Intelligence. 2012. Vol. 25. № 7. P. 1365–1372. DOI: 10.1016/j.engappai.2012.05.007.
23. Çelik T., Demirel H. Fire detection in video sequences using a generic color model // Fire Safety Journal. 2009. Vol. 44. № 2. P. 147–158. DOI: 10.1016/j.firesaf.2008.05.005.
24. Ko B.C., Cheong K.-H., Nam J.-Y. Fire detection based on vision sensor and support vector machines // Fire Safety Journal. 2009. Vol. 44. № 3. P. 322–329. DOI: 10.1016/j.firesaf.2008.07.006.

25. Computer vision based method for real-time fire and flame detection / B. Töreyin [et al.] // Pattern Recognition Letters. 2006. Vol. 27. P. 49–58. DOI: 10.1016/j.patrec.2005.06.015.
26. Borges P.A., Izquierdo E. Probabilistic Approach for Vision-Based Fire Detection in Videos // Circuits and Systems for Video Technology, IEEE Transactions on. 2010. Vol. 20. P. 721–731. DOI: 10.1109/TCSVT.2010.2045813.
27. Ramasubramanian S., Muthukumaraswamy S., Sasikala A. Fire Detection using Artificial Intelligence for Fire-Fighting Robots // 2020 4th International Conference on Intelligent Computing and Control Systems (ICICCS). United States: IEEE, 2020. P. 180–185. DOI: 10.1109/ICICCS48265.2020.9121017.
28. FireNET dataset. 2024. URL: <https://github.com/OlafenwaMoses/FireNET/releases> (data obrashcheniya: 20.03.2025).
30. Wildfire Flame and Smoke Detection Using Static Image Features and Artificial Neural Network / F.M.A. Hossain [et al.] // 1st International Conference on Industrial Artificial Intelligence (IAI). 2019. P. 1–6. DOI: 10.1109/ICIAI.2019.8850811.

Информация о статье:

Статья поступила в редакцию: 06.05.2025; одобрена после рецензирования: 30.05.2025; принята к публикации: 02.06.2025

Information about the article:

The article was submitted to the editorial office: 06.05.2025; approved after review: 30.05.2025; accepted for publication: 02.06.2025

Сведения об авторах:

Шкурат Данил Евгеньевич, аспирант Санкт-Петербургского университета ГПС МЧС России (196105, Санкт-Петербург, Московский пр., д. 149), e-mail: danilshkurat@gmail.com

Матвеев Александр Владимирович, заведующий кафедрой прикладной математики и безопасности информационных технологий Санкт-Петербургского университета ГПС МЧС России (196105, Санкт-Петербург, Московский пр., д. 149), кандидат технических наук, доцент, SPIN-код: 5778-8821, e-mail: fcvega_10@mail.ru

Information about the authors:

Shkurat Danil E., postgraduate student of Saint-Petersburg university of State fire service of EMERCOM of Russia (196105, Saint-Petersburg, Moskovsky ave., 149), e-mail: danilshkurat@gmail.com

Matveyev Alexander V., the head of the department of applied mathematics and information technology security of Saint-Petersburg university of State fire service of EMERCOM of Russia (196105, Saint-Petersburg, Moskovsky ave., 149), candidate of technical sciences, associate professor, SPIN: 5778-8821, e-mail: fcvega_10@mail.ru