



---

## Современные методы глубокого обучения для обнаружения и прогнозирования лесных пожаров на основе данных с беспилотных летательных аппаратов

*Д.В. Вегера, А.С. Забавин*

*Тихоокеанский государственный университет, Хабаровск*

**Аннотация:** В статье рассматриваются современные подходы к прогнозированию и обнаружению лесных пожаров с использованием технологий машинного обучения и данных дистанционного зондирования. Особое внимание уделено применению алгоритмов компьютерного зрения, таких как сверточные нейронные сети и трансформеры, для детекции и сегментации очагов возгорания на снимках с беспилотных летательных аппаратов. Отмечается высокая эффективность гибридных архитектур и легковесных моделей для работы в реальном времени.

**Ключевые слова:** лесные пожары, прогнозирование, беспилотные летательные аппараты, глубокое обучение, сверточные нейронные сети, трансформеры, сегментация изображений.

### I. Введение

Почти две трети площади России занимают леса, общая площадь которых в 2021 году достигла 1,019 млрд гектаров. Ежегодно на этих территориях возникает от 9 до 35 тысяч лесных пожаров, которые охватывают от 500 тысяч до нескольких миллионов гектаров. Для восстановления лесного фонда с 2019 года в рамках федерального проекта «Сохранение лесов» высаживается приблизительно 1 млн гектаров саженцев в год [1].

Несмотря на то, что в мировом масштабе количество лесных пожаров за последние десятилетия сократилось благодаря усилинию мер борьбы и внедрению систем раннего обнаружения, экономике и инфраструктуре они по-прежнему наносят огромный ущерб.

Ключевым фактором в борьбе с этим явлением считается своевременное выявление первых признаков возгорания и оперативное реагирование специальных служб. В целях раннего обнаружения предлагается задействовать современные технологии, а именно - два вида беспилотных летательных аппаратов (БПЛА): дроны самолётного типа (с неподвижным крылом) и мультикоптеры.

Хотя область оперативного обнаружения пожаров с помощью анализа снимков местности в реальном времени несомненно является эффективным методом для выявления огня и его поведения, это часть более обобщенной задачи «Прогнозирования возникновения и предупреждения пожаров». Модели прогнозирования лесных пожаров можно условно разделить на три категории: моделирование атмосферы, модели мониторинга и прогнозирования, модели поведения огня [2].

Для построения систем предупреждения и тушения на практике мы должны иметь комплексную модель территорий природопользования чтобы эффективно распределять ресурсы и расписания полетов БПЛА в пожароопасных местах, данная работа сосредоточена на моделях возникновения и распространения.

## II. Прогнозирование возникновения пожаров

На текущий момент существуют различные методы прогнозирования возникновения пожаров, использующие в своей основе как наземный мониторинг, авиационный мониторинг так и космомониторинг 1 и 2 уровня.

В рамках наземного и авиа мониторинга организуются системы датчиков измеряющих в реальном времени климатические параметры как: минимальная суточная температура  $T_{\min}$ ; максимальная суточная температура  $T_{\max}$ ; среднесуточная влажность; суммарная суточная или годовая солнечная радиация (рис. 1); среднесуточная скорость ветра; суммарное количество осадков а также природоохранные статистические показатели территорий вроде темпов изменения лесов, их площади, факторы обезлесения территории, состав лесов и мелкодисперсного топлива в почве, нормализованного относительного индекса растительности (Normalized Difference Vegetation Index – NDVI).

Указанные параметры используются для прогноза пожароопасности методом опорных векторов (Support Vector Machine – SVM), который и сейчас в определенных случаях сохраняет свою эффективность. Метод опорных векторов

— это алгоритм классификации (пожароопасность зоны), который заключается в нахождении оптимальной разделяющей гиперплоскости, обеспечивающей максимальный зазор между классами.




Рис. 1. – Карта суммарной солнечной радиации РФ (по нормативам СП 370.1325800.2017)

Алгоритм SVM использует набор математических функций — ядер чтобы преобразовать пространства данных заданные множественными измерениями, как например упомянутые выше относительная влажность, суммарное солнечное излучение и другие. Выбранное «ядро» определяет функцию сходства между объектами в новом приведенном пространстве данных другой размерности. Впервые использование данного метода в контексте прогнозирования был предложен П. Кортез в своей работе "Метод интеллектуального анализа данных для прогнозирования лесных пожаров с использованием метеорологических данных" [3]. Данная работа, опубликованная в 2007 году, является важной отправной точкой, поскольку она заложила основы для систематического, управляемого данными прогнозирования пожаров. Авторы применили методы интеллектуального анализа данных, включая метод опорных векторов, для

прогнозирования риска возникновения пожара на основе метеорологических данных, предшествующим использованию сложных архитектур искусственных нейронных сетей (ИНС). Эта работа служит классическим тестом, с которым сравниваются все современные модели глубокого обучения, фокусирующиеся на оценке восприимчивости среды или вероятности возникновения пожара.

Помимо обозначенных моделей прогнозирования основанными на интерпретации данных, существуют системы спутникового мониторинга для определенных регионов и глобальные. Ключевой недостаток спутникового мониторинга, например, используя открытые данные спутников проекта Метеор M, КА TERRA (MODIS), LANDSAT, SENTINEL и PLANET, — это их скорость реагирования, реакция от 2x до 10 дней лишает возможности использовать полученные данные для оперативного реагирования, однако широкий охват территории и работа в мультиспектральном, гиперспектральном и лидарном диапазонах позволяют собрать огромные массивы данных.

Уже созданные аналитические системы мониторинга, основанные как на спутниковых данных, так и на метеоданных позволяют выявить некоторые глобальные закономерности, которые появляются на картах пожаров с течением времени, являются результатом естественных циклов дождей, засухи и молний. Например, интенсивное горение в самом сердце Южной Америки с августа по октябрь является результатом вызванных человеком пожаров, как преднамеренных, так и случайных, в тропических лесах Амазонки и Серрадо (экосистема пастбищ/саванн) на юге. Для прогнозирования лесных пожаров применяется широкий спектр математических моделей. Большое распространение получили подходы, основанные на физических законах распространения огня и учете данных о состоянии окружающей среды. Ярким примером служит модель Индекса Пожарной Погоды (Canadian Forest Fire Weather Index – FWI), созданная Канадской лесной службой. В ее основе лежит взаимосвязь метеорологических факторов и риска возникновения возгораний.

---

Модель оценивает пожарную опасность по шести параметрам, учитывающим влажность топлива и погодные условия. Первые три — это коды влажности для разных слоёв горючих материалов (мелких, средних и глубоких), которые возрастают при уменьшении содержания влаги. Следующие три — индексы, отражающие поведение огня: скорость распространения, количество доступного топлива и интенсивность фронта пожара. Их значения растут вместе с увеличением угрозы. Ниже представлена схема компонентов FWI (рис. 2) [2].




Рис. 2. – Части системы FWI

Код влажности мелкодисперсного топлива (Fine Fuel Moisture Code – FFMC) – представляет собой числовой показатель содержания влаги в мусоре и другом отвержденном мелкодисперсном топливе. Этот код является показателем относительной легкости воспламенения и воспламеняемости мелкодисперсного топлива.

Код засухи (Drought Code – DC) – это числовая оценка среднего содержания влаги в глубоких, компактных органических слоях. Этот код

является полезным индикатором воздействия сезонной засухи на лесное топливо и количество тлеющего вещества в глубоких слоях древесного угля и больших бревнах.

Код влажности Даффа (Duff Moisture Code – DMC) – это числовая оценка среднего содержания влаги в рыхло уплотненных органических слоях средней глубины. Этот код дает представление о расходе топлива при умеренных слоях пыли и древесном материале среднего размера.

Индекс накопления/наращивания (Build-Up Index – BUI) - представляет собой числовой рейтинг общего количества топлива, доступного для сгорания. Он основан на DMC и DC. BUI обычно менее чем в два раза превышает значение DMC, и в этом случае ожидается, что влага в слое DMC поможет предотвратить горение материала глубже в доступном топливе.

Индекс начального спреда/распространения (Initial Spread Index – ISI) - представляет собой числовой показатель ожидаемой скорости распространения огня. Он основан на скорости ветра и FFMC. Как и остальные компоненты системы FWI, ISI не учитывает тип топлива. Фактические нормы разброса варьируются в зависимости от типа топлива при одном и том же ISI.

Индекс пожарной погоды представляет собой числовой рейтинг интенсивности пожара. Он основан на индексах ISI и BUI и используется в качестве общего индекса пожарной опасности на всей лесной территории [4].

В Российской Федерации подобные комплексные системы прогнозирования разрабатывают в основном в тестовом режиме в определенных регионах, а для картирования пожароопасных зон используется более простой и эмпирический комплексный показатель пожароопасный (КПО) разработанный еще в сороковые годы прошлого столетия.

### **III. Анализ моделей для прогнозирования поведения огня и распространения пожара с помощью снимков БПЛА**

---

Прогнозирование поведения огня разбивается на несколько подзадач. Первая - это задача обнаружения возгораний с использованием алгоритмов классификации, другая задача - это поиск областей интереса или локализация часто идет вместе с классифицированием. Последняя подзадача - задача семантической сегментации на изображениях и видеопотоках. Своевременное выявление возгораний позволяет минимизировать ущерб от них. Однако для построения такой системы раннего обнаружения огня - требуется создание новых автономных программ для анализа данных со стационарных и мобильных камер, включая устройства на беспилотных летательных аппаратах.

Исторически задачу выявления и прогнозирование поведения огня решали разными методами. Для распознавания возгорания применялись алгоритмы, такие как масштабно-инвариантное преобразование признаков (Scale-invariant feature transform – SIFT), которое находило устойчивые к изменению масштаба и поворота точки. В комбинации с SIFT метод гистограммы направленных градиентов (Histogram of Oriented Gradients – HOG), позволяет описывать форму объекта через распределение градиентов яркости. Полученные этими методами признаки передавались классическим алгоритмам машинного обучения, таким как метод опорных векторов, адаптивного бустинга (Adaptive Boosting – AdaBoost) и случайный лес. Для семантической сегментации использовались модели структурного предсказания, включая условные случайные поля (Conditional random fields - CRF) и марковские случайные поля (Markov Random Field – MRF). Несмотря на эффективность в условиях ограниченных вычислительных ресурсов, эти подходы требовали ручного проектирования признаков экспертами и не могли самостоятельно изучать сложные абстракции. Это приводило к неэффективности затрат человеческих ресурсов на настройку систем под конкретное окружение. В настоящее время доминирующим методом для распознавания и классификации изображений являются сверточные нейронные сети, которые лишены этих ограничений.

---

В ходе данного исследования были проанализированы наиболее перспективные архитектуры используемые для задачи распознавания очагов огня и его границ. Многие из рассматриваемых работ используют датасет «FLAME» (рис. 3) [5] для обучения моделей. Это обширный набор данных собранный исследователями Принстонского Университета в лесах штата Аризона используя снимки с БПЛА различных типов. Датасет содержит снимки как для классификации изображений с отсутствием возгорания и нет, так и для выявления области возгорания и направления огня. Однако, все-равно проблема нехватки качественных обучающих наборов в данной области стоит довольно остро, т.к. природа явления лесных пожаров сама по себе носит слабо контролируемый характер и затрагивает часто малозаселенные территории. Особенно актуален недостаток данных для редких случаев, таких как пожары в ночное время или в сложных погодных условиях. Этую проблему частично призвано решить использование генеративно-состязательных сетей (Generative Adversarial Network – GAN), которые в основном применяются для генерации синтетических данных.



Рис. 3. – Пример кадра из датасета FLAME [5]

В работе Г. Круза "Машинное обучение и обработка цвета для систем и алгоритмов обнаружения лесных пожаров и дыма" [6] - представлены подходы к идентификации лесных пожаров и задымления, базирующиеся на алгоритмах машинного обучения и анализе цветовых характеристик; авторами отмечается, что данные методы демонстрируют совокупную точность выше 90%. Особый акцент делается на возможность применения этих алгоритмов в мониторинговых комплексах с беспилотными летательными аппаратами. В обзоре [7] рассматриваются актуальные решения для детектирования дыма: исследования систематизированы в соответствии с типологией решаемых задач (классификация изображений, сегментация, детекция объектов). В рамках статьи [7] исследователями из индийского Универитета Беннетта также проводится сравнительный анализ методов обработки изображений, включая классические подходы, машинное и глубокое обучение, а также обсуждаются используемые датасеты и метрики оценки эффективности.

В исследовании [8] проводится анализ ключевых подходов к обработке изображений для задач детектирования пожарных очагов, при этом в качестве наиболее перспективного направления выделяется применение сверточных нейронных сетей. Отдельное внимание в работе [8] уделяется анализу существующих наборов данных, пригодных для обучения ИНС решению задач идентификации огня и дыма. Также в статье затрагивается проблема нехватки разнородных данных, обозначенная выше.

В свою очередь, работа [9] сфокусирована на эмпирической оценке влияния различных факторов на эффективность семантической сегментации изображений пожаров. В рамках исследования проводится компаративный анализ, рассматривающий комбинации современных архитектур глубокого обучения, функций потерь и модальностей исходных данных (видимый спектр, инфракрасные каналы, мультиспектральные представления). Авторами [9] была реализована методика обучения трех продвинутых сетевых архитектур с

---

вариацией трех функций потерь и четырьмя типами изображений, что позволило выполнить сравнительное исследование 36 различных конфигураций с целью выявления параметров, вносящих наибольший вклад в качество сегментации.

В публикации [10] предложен метод детектирования пожарных очагов в видеопотоке, основанный на применении сверточной нейронной сети, модифицированной слоем пространственного пирамидального пулинга (SPP). Используемая архитектура позволяет проводить обучение без предварительной разметки данных на специализированном датасете и обеспечивает точную идентификацию областей возгорания, варьирующихся в масштабе. По результатам экспериментальной верификации, данный подход демонстрирует устойчивую эффективность в сегментации пламени независимо от его размеров, достигая значения F1-меры 93,3 % при учете разнообразия пропорций объектов. F1-мера представляет собой комплексный метрический показатель, используемый для оценки эффективности классификационных моделей, в частности нейронных сетей. Данная метрика вычисляется как гармоническое среднее между точностью и полнотой, что позволяет получить сбалансированную оценку в условиях неравномерного распределения классов. Она является ключевым инструментом для комплексного анализа производительности модели, синтезируя информацию о двух типах классификационных ошибок (первого и второго рода).

В исследовании [11] представлен систематизированный ретроспективный анализ развития методов детектирования дымовых признаков в видеоданных. Рассматривается эволюция подходов, базирующихся на таких характеристиках, как динамика движения, свойства полупрозрачности, цветовые модели, морфология, текстурные и фрактальные дескрипторы. Авторами [11] также предлагается гибридная архитектура, комбинирующая СНС с долгосрочной краткосрочной памятью (Long Short-Term Memory – LSTM), предназначенная для классификации видеокадров и показавшая высокие метрики точности.

---

Значительный пласт исследований базируется на проекте YOLO. Это семейство сверточных нейронных сетей, основанных на архитектуре GoogLeNet, в которых авторам единую сеть, которая выполняет детекцию объекта вместе с его классификацией. В работе [12] для решения задачи детектирования дыма используется архитектура сверточной нейронной сети на базе CSPDarknet53, являющегося основным компонентом фреймворка YOLO, также снабжённая SPP-слоем. Отмечается, что архитектуры семейства YOLO обеспечивают одновременное выполнение задач локализации областей интереса и классификации объектов. Согласно результатам, представленным авторами [12], предложенный подход достигает значения F1-меры 97,9% при производительности 32 кадра в секунду, что соответствует требованиям систем обнаружения в реальном времени. А именно - модель в процессе обучения формирует навык точного определения координат объектов с возвратом информации о классе и уровне достоверности предсказания [12].

В работе [13] описывается система детектирования пожаров в реальном времени, построенная на усовершенствованной версии модели YOLOv5 (модификация 5s). Данная модель осуществляет автоматическую идентификацию и локализацию пламени и дыма на различных стадиях их развития, демонстрируя среднюю точность mAP@0.5 на уровне 80,6% при скорости обработки около 31 кадра в секунду. Авторы [13] акцентируют внимание на том, что показатель mAP служит ключевым критерием при выборе архитектуры искусственной нейронной сети для конкретной прикладной задачи, поскольку он отражает способность модели корректно детектировать объекты целевого класса задаваемого этой задачей.

В исследованиях [14-16] основное внимание сфокусировано на разработке облегчённых моделей, предназначенных для встраиваемых систем. В работе [15] применяется архитектура MobileNetV3, демонстрирующая точность 90% на специализированном наборе данных при размере модели 21,4 МБ и

---

производительности до 29,5 кадров в секунду. В свою очередь, исследование [14] также использует MobileNetV3, отмечая, что количество параметров данной модели ( $\approx 2,64$  млн) на 95,9% меньше по сравнению с YOLOv4, что обеспечивает существенное преимущество в требованиях к объёму памяти и скорости обработки. Оба подхода ориентированы на развертывание в системах бортовой обработки данных БПЛА и демонстрируют высокую эффективность для задач обнаружения пожаров в реальном времени.

В работе [16] же в свою очередь предложен метод детектирования лесных пожаров на основе облегчённой модификации YOLOv4, где базовая сеть заменена на MobileNetV3. Данная оптимизация позволила сократить количество параметров на 62,78% (23,7 млн. вместо 64) и ускорить процесс вывода почти в три раза. При достигнутой метрике mAP@0.5, равной 66,7%, разработанное решение обеспечивает возможность реальноременного обнаружения пожарных очагов и сопутствующих объектов на устройствах с ограниченными вычислительными ресурсами.

В исследовании [17] авторы модифицируют стандартную свёрточную нейронную сеть, заменяя полносвязный выходной слой на операцию глобального усредняющего пулинга (Global Average Pooling – GAP). Данная архитектурная адаптация способствует снижению риска переобучения и повышает быстродействие сети. Дополнительно, на вход модели подаются расширенные наборы признаков, включающие цветовые и текстурные дескрипторы, полученные путём преобразований в различные цветовые пространства и выделения граничных характеристик. В рамках экспериментального исследования в [17] достигнута точность классификации сцен, составляющая 89,9%.

В исследовании [18] проводится анализ современных методов глубокого обучения, включая визуальные трансформеры. Для решения задач детектирования и семантической сегментации лесных пожаров на основе

---

аэрофотоснимков, полученных с помощью БПЛА, авторами [18] предлагается ансамблевый метод классификации пожарных очагов, комбинирующий две признанные свёрточные архитектуры — EfficientNet-B5 и DenseNet-201, — для идентификации и категоризации зон возгорания соответственно. В рамках решения задачи сегментации используются две трансформерные архитектуры, TransFire и TransUNet, а также легковесная сегментационная сеть EfficientSeg, основанная на U-Net с использованием блоков MobileNetV3. Данные модели обеспечивают пиксельную сегментацию областей горения и точное определение границ пламени.

Экспериментальные результаты, представленные в [18], подтверждают эффективность предложенного подхода: ансамблевая модель EfficientNet-B5 + DenseNet-201 достигла точности классификации 85,12 %. При решении же задачи сегментации модели на основе визуальных трансформеров показали наивысшие результаты. TransUNet продемонстрировал точность и F1-меру на уровне 99,9 %, а TransFire — 99,84 % и 99,81 % соответственно. Архитектура TransUNet, изначально разработанная для задач медицинской визуализации [29] и сочетающая U-Net с визуальными трансформерами (Vision Transformers – ViT). Она была адаптирована авторами [18] для детекции пожарных очагов.

Визуальные трансформеры, лежащие в основе TransUNet, представляют собой современный класс архитектур, в которых изображение разбивается на токены, обрабатываемые с помощью механизма самовнимания [19]. Такой подход позволяет модели учитывать глобальные длинные контекстные зависимости между различными участками изображения — например, выявлять взаимосвязь между очагом пламени и дымовым шлейфом на значительном расстоянии, что является ограничением для традиционных сверточных сетей, оперирующих локальными паттернами.

Модель EfficientSeg показала точность 99,6 % и F1 99,7 %. Оценки авторов [18] позволяют заключить, что трансформерные архитектуры TransUNet и

---

TransFire превосходят по качеству глубокие CNN-модели в задачах сегментации пожаров, особенно в сложных сценариях с малыми площадями возгорания или наличием дыма.

Существенным этапом развития методов детектирования стал учет временной размерности анализа. Учитывая динамическую природу процесса горения, основанного на временном развитии, анализ изолированного видеокадра признается недостаточным. Для моделирования динамических характеристик пожарного очага в научных работах [21, 22] применяются рекуррентные нейронные сети (Recurrent Neural Network – RNN), в частности упомянутые ранее LSTM а также с управляемым рекуррентным блоком (Gated Recurrent Units – GRU), которые часто интегрируются в гибридные архитектурные решения. В таких моделях сверточные нейронные сети выполняют экстракцию пространственных признаков из отдельных кадров, тогда как рекуррентные компоненты осуществляют анализ временной последовательности этих признаков. Данные гибридные архитектуры (например, CNN-LSTM) позволяют детектировать не только статические визуальные паттерны пламени, но и реконструировать его динамические параметры — траекторию движения, скорость распространения и изменение геометрических характеристик, что существенно повышает достоверность идентификации.

### Заключение

Таким образом, анализ источников на текущий момент показывает, что современные подходы к обнаружению пожаров активно используют глубокие модели и их комбинации. Классические методы выделения цветовых и текстурных признаков дополняются сверточными нейронными сетями и трансформерами, что позволяет достичь высокой точности (до 85–90 % в классификации и 99 %+ в сегментации) при приемлемой скорости. Можно выделить три ключевых направления:

1. **Специализация архитектур** под тип задачи: классификация (EfficientNet, DenseNet), детекция (YOLO-семейство), сегментация (U-Net, TransUNet).

2. **Переход к гибридным и трансформерным моделям**, способным эффективно моделировать как локальные признаки, так и глобальный контекст.

3. **Оптимизация под встроенные устройства**, включая разработку легковесных моделей (MobileNetV3, EfficientSeg, YOLO-tiny) и использование современных инструментов развёртывания (TensorRT, ONNX [22]).

Перспективными направлениями являются объединение различных архитектур в ансамбли, применение лёгких моделей для БПЛА и использование распределённых вычислений для масштабируемой обработки данных. Для задачи локализации объектов в рамках высокой скорости, доминирующей стала семья моделей "You Only Look Once", в частности, YOLOv3 и YOLOv5 [21, 23]. Эти модели отличаются высокой скоростью работы, что делает их идеальными для систем реального времени, например, на беспилотниках или в системах мониторинга. Для задачи семантической сегментации, целью которой является создание пиксельно-точной карты горящей территории, стандартом де-факто стало использование архитектуры U-Net и ее модификаций, таких как F-Net, EfficientNet. Архитектура "энкодер-декодер" U-Net позволяет эффективно восстанавливать изображение с высокой точностью, что критически важно для оценки масштаба пожара. Данная работа выполнена в рамках технологического проекта БАС-27 СТП-1 программы Приоритет ФБГОУ ВО ТОГУ.

## Литература

1. Лесные пожары в России. «Антирекорды» и территории распространения. Информационное агентство России «ТАСС», 2022. URL: [tass.ru/info/15559017](https://tass.ru/info/15559017).
2. Родионов А.М., Иванов С. А. Анализ современных моделей и информационных систем при прогнозировании и мониторинге лесных

- пожаров // Экономика. Информатика. 2023. №4. URL: [researchgate.net/publication/377869080\\_Analiz\\_sovremennyh\\_modelej\\_i\\_informacionnyh\\_sistem\\_pri\\_prognozirovaniyu\\_i\\_monitoringu\\_lesnyh\\_pozarov](https://researchgate.net/publication/377869080_Analiz_sovremennyh_modelej_i_informacionnyh_sistem_pri_prognozirovaniyu_i_monitoringu_lesnyh_pozarov).
3. Cortez, P., Morais, A., A Data Mining Approach to Predict Forest Fires using Meteorological Data // New Trends in Artificial Intelligence, Proceedings of the 13th EPIA 2007 — Portuguese Conference on Artificial Intelligence. 2007. pp. 512-523.
  4. Kudláčková L., Bartošová L. and etc., Global use of the Canadian Fire Weather Index: A review // Environmental Research Letters. – 2024. – Vol.14(1). pp. 100-114.
  5. Shamsoshoara A., Afghah F., Razi A. and etc. The Flame Dataset: Aerial Imagery Pile Burn Detection Using Drones (UAVS) // IEEE DataPort is a research data platform. 2021. URL: [ieee-dataport.org/openaccess/flame-dataset-aerial-imagery-pile-burn-detectionusing-drones-uavs](https://ieee-dataport.org/openaccess/flame-dataset-aerial-imagery-pile-burn-detectionusing-drones-uavs).
  6. Cruz H., Gualotuña T. and etc., Machine Learning and Color Treatment for the Forest Fire and Smoke Detection Systems and Algorithms, a Recent Literature Review // Advances in Intelligent Systems and Computing. Springer, 2021. Vol.1326. pp. 512-523.
  7. Chaturvedi S., Khanna P. and etc., A Survey on Vision-Based Outdoor Smoke Detection Techniques for Environmental Safety // SPRS Journal of Photogrammetry and Remote Sensing. 2022. Vol.185. pp. 158-187. DOI: [10.1016/j.isprsjprs.2022.01.013](https://doi.org/10.1016/j.isprsjprs.2022.01.013).
  8. Geetha S., Abhishek C.S. and etc., Machine Vision Based Fire Detection Techniques // Fire Technology. 2021. Vol.57. pp. 591-623.
  9. Ciprián-Sánchez J.F., Ochoa-Ruiz G. and etc., Assessing the Impact of the Loss Function, Architecture and Image Type for Deep Learning-Based Wildfire Segmentation // Applied Sciences. 2021. Vol.11(15). pp. 281-299.

10. Cheng Y., Chen K., Bai H. and etc, An Efficient Fire Detection Algorithm Based on Multi-Scale Convolutional Neural Network // Fire and Materials. 2021. 12 p.
  11. Favorskaya M.N. Early Smoke Detection in Outdoor Space: State-of-the-Art, Challenges and Methods // Advances in Selected Artificial Intelligence Areas. Learning and Analytics in Intelligent Systems. Springer, 2021. Vol.24. pp. 450-467.
  12. Huo Y., Zhang Q., Jia Y. and etc., A Deep Separable Convolutional Neural Network for Multiscale Image-Based Smoke Detection // Fire Technology. 2022. Vol.58. pp. 191-205.
  13. Miao J., Zhao G., Gao Y. and etc. Fire Detection Algorithm Based on Improved YOLOv5 // International Conference on Control, Automation and Information Sciences (ICCAIS). 2021. pp. 776-781.
  14. Wang S., Zhao J., Ta N. and etc. A Real-Time Deep Learning Forest Fire Monitoring Algorithm Based on an Improved Pruned Kd Model // Journal of Real-Time Image Processing. Springer, 2021. Vol.18, № 6. pp. 2319-2329.
  15. Li Y., Zhang W., Liu Y. and etc. A Visualized Fire Detection Method Based on Convolutional Neural Network Beyond Anchor // Applied Intelligence. Springer, 2022. Vol.52. pp. 13280-13295.
  16. Wang S. and etc. Forest Fire Detection Based on Lightweight Yolo // 2021 33rd Chinese Control and Decision Conference (CCDC). 2021. pp. 1560-1565.
  17. Cai Y., Guo Y., Li Y. and etc. Fire Detection Method Based on Improved Deep Convolution Neural Network // 2019 8th International Conference on Computing and Pattern Recognition (ICCP '19). 2019. Association for Computing Machinery, New York, NY. USA. pp. 466-470.
  18. Ghali R., Akhloufi M.A., Mseddi W.S. Deep Learning and Transformer Approaches for UAV-Based Wildfire Detection and Segmentation // Sensors. MDPI, 2022. Vol.22(5). p. 1977.
-

19. Wu B., Xu C., Dai X. and etc. Visual Transformers: Token-based Image Representation and Processing for Computer Vision, 2020 URL: arxiv.org/abs/2006.03677.
20. Saleh A. Forest fire surveillance systems: A review of deep learning methods // Heliyon. 2024. Vol.10, Issue 1. p. e23127. URL: sciencedirect.com/science/article/pii/S2405844023103355.
21. Vasconcelos R. N. Fire Detection with Deep Learning: A Comprehensive Review // Land. 2024. Vol.13(10). pp. 91-98.
22. Public API for `tf.keras.applications` namespace. TensorFlow API Documentation, 2022 URL: tensorflow.org/api\_docs/python/tf/keras/applications.
23. Ismail N. D. A Systematic Literature Review of Vision-Based Fire Detection // Jurnal Kejuruteraan (UKM). 2025. Vol.37(1). pp. 191-218. DOI: 10.17576/jkukm-2025-37-1-13.

## References

1. Lesnye pozhary v Rossii. «Antirekordy» i territorii rasprostraneniya. Informacionnoe agentstvo Rossii «TASS» [Forest fires in Russia. "Anti-records" and distribution territories. Russian News Agency "TASS"], 2022. URL tass.ru/info/15559017.
2. Rodionov A.M., Ivanov S. A. Analiz sovremennoy modeley i informacionnyh sistem pri prognozirovaniy i monitoringe lesnyh pozharov Ekonomika. Informatika. 2023. №4. URL researchgate.net/publication/377869080\_Analiz\_sovremennoy\_modeley\_i\_informacionnyh\_sistem\_pri\_prognozirovaniy\_i\_monitoringe\_lestyh\_pozharov.
3. Cortez, P., Morais, A., A Data Mining Approach to Predict Forest Fires using Meteorological Data New Trends in Artificial Intelligence, Proceedings of the

- 13th EPIA 2007 Portuguese Conference on Artificial Intelligence. 2007. pp. 512-523.
4. Kudláčková L., Bartošová L. and etc., Environmental Research Letters. 2024. Vol.14(1). pp. 100-114.
  5. Shamsoshoara A., Afghah F., Razi A. and etc. The Flame Dataset Aerial Imagery Pile Burn Detection Using Drones (UAVS) IEEE DataPort is a research data platform. 2021. URL [ieee-dataport.org/openaccess/flame-dataset-aerial-imagery-pile-burn-detectionusing-drones-uavs](http://ieee-dataport.org/openaccess/flame-dataset-aerial-imagery-pile-burn-detectionusing-drones-uavs).
  6. Cruz H., Gualotuña T. and etc., Advances in Intelligent Systems and Computing. Springer, 2021. Vol.1326. pp. 512-523.
  7. Chaturvedi S., Khanna P. and etc., SPRS Journal of Photogrammetry and Remote Sensing. 2022. Vol.185. pp. 158-187.
  8. Geetha S., Abhishek C.S. and etc., Fire Technology. 2021. Vol.57. pp. 591-623.
  9. Ciprián-Sánchez J.F., Ochoa-Ruiz G. and etc., Applied Sciences. 2021. Vol.11(15). pp. 281-299.
  10. Cheng Y., Chen K., Bai H. and etc, Fire and Materials. 2021. 12 p.
  11. Favorskaya M.N. Advances in Selected Artificial Intelligence Areas. Learning and Analytics in Intelligent Systems. Springer, 2021. Vol.24. pp. 450-467.
  12. Huo Y., Zhang Q., Jia Y. and etc., Fire Technology. 2022. Vol.58. pp. 191-205.
  13. Miao J., Zhao G., Gao Y. and etc. Fire Detection Algorithm Based on Improved YOLOv5 International Conference on Control, Automation and Information Sciences (ICCAIS). 2021. pp. 776-781.
  14. Wang S., Zhao J., Ta N. and etc. Journal of Real-Time Image Processing. Springer, 2021. Vol.18, № 6. pp. 2319-2329.
  15. Li Y., Zhang W., Liu Y. and etc. Applied Intelligence. Springer, 2022. Vol.52. pp. 13280-13295.
  16. Wang S. and etc. Forest Fire Detection Based on Lightweight Yolo 2021 33rd Chinese Control and Decision Conference (CCDC). 2021. pp. 1560-1565.
-

17. Cai Y., Guo Y., Li Y. and etc. Fire Detection Method Based on Improved Deep Convolution Neural Network 2019 8th International Conference on Computing and Pattern Recognition (ICCP '19). 2019. Association for Computing Machinery, New York, NY. USA. pp. 466-470.
18. Ghali R., Akhloufi M.A., Mseddi W.S. Sensors. MDPI, 2022. Vol.22(5). p. 1977.
19. Wu B., Xu C., Dai X. and etc. Visual Transformers Token-based Image Representation and Processing for Computer Vision, 2020. URL arxiv.org/abs/2006.03677.
20. Saleh A. Heliyon. 2024. Vol.10, Issue 1. p. e23127. URL sciencedirect.com/science/article/pii/S2405844023103355.
21. Vasconcelos R. N. Land. 2024. Vol.13(10). pp. 91-98.
22. Public API for `tf.keras.applications` namespace. TensorFlow API Documentation, 2022. URL tensorflow.org/api\_docs/python/tf/keras/applications.
23. Ismail N. D. Jurnal Kejuruteraan (UKM). 2025. Vol.37(1). pp. 191-218.

**Дата поступления: 18.11.2025**

**Дата публикации: 6.02.2026**