

ОБНАРУЖЕНИЕ ЛЕСНЫХ ПОЖАРОВ С ИСПОЛЬЗОВАНИЕМ ТЕХНОЛОГИЙ ГЛУБОКОГО ОБУЧЕНИЯ (ОБЗОР ЗАРУБЕЖНОЙ ЛИТЕРАТУРЫ)

В. А. Усольцев¹, В. П. Часовских²

¹Уральский государственный лесотехнический университет
620100, Екатеринбург, Сибирский тракт, 37

²Уральский государственный экономический университет,
620144, Екатеринбург, ул. 8 Марта/Народной Воли, 62/45

¹Usoltsev50@mail.ru, <http://orcid.org/0000-0003-4587-8952>

²u2007u@ya.ru, <http://orcid.org/0000-0002-9454-9824>

Аннотация. По мере увеличения объема новых научных данных, новых идей и практических разработок возрастает риск отставания исследователей от текущего состояния науки и ее практических реализаций. Синтез информации в форме систематических обзоров направлен на решение этой проблемы и может значительно облегчить исследователям ориентацию в современном состоянии научной сферы. Стремительный прогресс в области получения научных данных привел к появлению огромного и постоянно растущего объема информации, что исключает возможность какой-либо «ручной» ее интерпретации. Извлекать ценные и представляющие интерес модели из пространственных баз данных сравнительно сложно из-за множества их типов, пространственных связей и автокорреляций по сравнению с обычными числовыми и категориальными данными. В связи с изменением климата по всему миру учащаются лесные пожары, обнаружение которых на ранних стадиях является эффективным способом минимизировать причиняемый ими ущерб. Современные технологии глубокого машинного обучения открывают новые возможности для раннего обнаружения лесных пожаров. Авторы подчеркивают сложность обработки пространственных данных традиционными методами из-за их многообразия и взаимосвязей, и показывают, что алгоритмы глубокого обучения могут эффективно решать эту задачу, помогая минимизировать экономический и экологический ущерб и угрозу человеческим жизням.

Ключевые слова: лесные пожары, раннее обнаружение, методы, алгоритмы и модели, глубокое машинное обучение.

Conifers of the boreal area. 2026, Vol. XLIV, No. 2, P. 22–51

FOREST FIRE DETECTION USING DEEP LEARNING TECHNOLOGIES (REVIEW OF FOREIGN LITERATURE)

V. A. Usoltsev¹, V. P. Chasovskikh²

¹Ural State Forest Engineering University
37, Siberian tract, Yekaterinburg, 620100, Russian Federation

³Ural State University of Economics
62/45, 8 Marta str./ Narodnaya Volya, Yekaterinburg, 620144, Russian Federation

¹Usoltsev50@mail.ru, <http://orcid.org/0000-0003-4587-8952>

²u2007u@ya.ru, <http://orcid.org/0000-0002-9454-9824>

Abstract. As the volume of new scientific data, new ideas and practical developments increases, the risk of researchers lagging behind the current state of science and its practical implementations increases. The synthesis of information in the form of systematic reviews is aimed at solving this problem and can significantly facilitate researchers' orientation in the current state of the scientific field. Rapid progress in the field of obtaining scientific data has led to the emergence of a huge and ever-growing amount of information, which excludes the possibility of any “manual” interpretation. It is relatively difficult to extract valuable and interesting models from spatial databases due to their many types, spatial relationships, and autocorrelations compared to conventional numerical and categorical data. Due to climate change, wildfires are increasing in frequency around the world, and detecting them at an early stage is an effective way to minimize the damage they cause. Modern deep machine learning technologies open up new opportunities for early detection of forest fires. The authors emphasize the complexity of processing spatial data using traditional methods due to their diversity and interrelationships, and show that deep learning algorithms can effectively solve this problem, helping to minimize economic and environmental damage and threat to human lives.

Keywords: forest fires, early detection, methods, algorithms and models, deep machine learning.

ВВЕДЕНИЕ

По мере увеличения объема новых научных данных, новых идей и практических разработок возрастает риск отставания исследователей от текущего состояния науки и ее практических реализаций. Синтез информации в форме систематических обзоров направлен на решение этой проблемы и может значительно облегчить исследователям ориентацию в современном состоянии научной сферы [45]. Стремительный прогресс в области получения научных данных привел к появлению огромного и постоянно растущего объема информации, что исключает возможность какой-либо «ручной» ее интерпретации. В контексте современного научного ландшафта парадигма извлечения знаний претерпела существенную трансформацию с момента концептуализации «Обнаружения знаний в базах данных» (Knowledge Discovery in Databases, KDD) в середине 1990-х годов [31; 100]. Интеграция передовых вычислительных подходов для превращения сырых данных в действенные инсайты сформировала фундамент мультидисциплинарной экосистемы исследований, эволюционировавшей в современную науку о данных (Data Science), охватывающую не только извлечение закономерностей, но и полный жизненный цикл работы с данными – от инженерии данных до интерпретируемого искусственного интеллекта. Таким образом, хотя фундаментальные принципы KDD сохраняют концептуальную значимость, эволюция вычислительных возможностей, источников данных и методологических подходов привела к формированию более комплексной и интегрированной дисциплины, адаптированной к экспоненциальному росту данных и вычислительным возможностям современной эпохи [17; 107].

Возникает необходимость в автоматизированном поиске пространственных знаний (spatial data) из огромного их количества, что сравнительно сложно из-за множества их типов, пространственных связей и автокорреляций по сравнению с обычными числовыми и категориальными данными [101]. Технологии интеллектуального анализа пространственных данных способствуют их пониманию, выявлению взаимосвязей между пространственными и непространственными переменными, определению закономерностей пространственного распределения конкретного явления, что помогает предвидеть тенденции изменения той или иной их структуры. Методы интеллектуального анализа пространственных данных включают визуальную интерпретацию и анализ, пространственный и атрибутивный запрос и отбор, характеристику, обобщение и классификацию, определение правил пространственных и непространственных ассоциаций, кластерный анализ и пространственную регрессию в дополнение к широкому спектру других областей [3].

В связи с изменением климата по всему миру учащаются лесные пожары, которые не только наносят серьезный экономический ущерб и разрушают экологическую среду, но и представляют большую угрозу жизни людей. Лесные пожары, ежегодно уничтожая сотни миллионов гектаров леса и другой растительности, рассматриваются как серьезная экологическая проблема [37; 88]. Лесные пожары обычно распро-

страняются быстро, и их оперативно контролировать довольно трудно. Время реагирования аварийно-спасательных служб существенно влияет на вызванные пожарами потери и последствия [9]. Поэтому практичным и эффективным способом минимизировать ущерб, причиняемый лесными пожарами, является обнаружение пожаров на их ранних стадиях с последующим быстрым реагированием для предотвращения распространения огня [3].

Современные разработки в области дистанционного зондирования, компьютерного зрения, машинного обучения и развитие микроэлектроники предоставляют новые методологии обнаружения лесных пожаров [113]. Наряду с методами видеосъемки дыма и пламени в инфракрасном и видимом диапазонах, проводятся обширные исследования наиболее репрезентативных систем обнаружения лесных пожаров, использующих цифровую обработку изображений [118]. В зависимости от способа сбора данных признаны три основных класса используемых методов, которые могут обнаруживать активные случаи задымления и пожара в режиме реального времени, а именно, наземные, бортовые и спутниковые. Такие методы, как правило, оснащены мультиспектральными, видимыми или сенсорными узлами в инфракрасном диапазоне, информация о которых обрабатывается с использованием методик глубокого машинного обучения [96].

Системы обнаружения на основе стационарных датчиков хорошо работают в закрытых помещениях, но их сложно использовать на открытой местности, учитывая высокую стоимость такой системы [130]. Кроме того, они не могут предоставлять важную визуальную информацию, которая могла бы помочь пожарным быстро оценить ситуацию на месте пожара. Инфракрасные или ультрафиолетовые детекторы легко поддаются воздействию окружающей среды [50], и, учитывая малую дальность обнаружения, они не подходят для работы на больших лесных пространствах. Спутниковое дистанционное зондирование [32] хорошо подходит для обнаружения крупномасштабных лесных пожаров, но не всегда может обнаружить небольшое локальное возгорание на ранней стадии.

Впечатленные развитием технологий компьютерного зрения, исследователи начали искать эффективную модель обнаружения пожара, основанную на обработке изображений. Была предложена модель RGB (Red, Green, Blue – красный, зеленый, голубой), основанная на измерении цветов для выделения пикселей пожара в видео-формате. Информация о цвете отвечала за выделение пикселей пожара, а динамическая информация использована для проверки того, является ли это реальным пожаром [18]. Для обнаружения мерцания пламени и идентификации его движущихся областей было применено двумерное пространственное вейвлет-преобразование. Этот метод, объединивший информацию о цвете и изменениях во времени, снизил количество ложных оповещений в реальных сценариях [114]. Была разработана система автоматического распознавания дыма в лидарных сигналах, полученных при небольших экспериментальных лесных пожарах с использованием нейросетевых алгоритмов [32]. На основе изображений в инфракрасном

диапазоне, визуальных образов и данных с датчиков, карт и моделей, объединенных для надежности процесса обнаружения, была разработана схема мультисенсорных систем раннего обнаружения лесных пожаров [77]. Был представлен усовершенствованный алгоритм обнаружения пожара, обеспечивающий повышенную чувствительность к мелким очагам возгораний, а также значительно снижающий частоту ложных оповещений. Для определения эффективности алгоритма применено теоретическое моделирование и регистрация с помощью усовершенствованного космического радиометра теплового излучения и отражения (ASTER) с высоким разрешением [35]. Представлен подход к снижению ложных оповещений в горячих точках лесных пожаров с использованием их географических координат. Чтобы выявить закономерности в динамике горячих точек и вычленивать ложные регистрации, исходя из предположения, что пожары обычно не распространяются по регулярной (прямолинейной) схеме, использованы кластеризация и преобразование Хафа. Для уменьшения ложных регистраций вследствие множества горячих точек, полученных на основе изображений NOAA, применен интеллектуальный анализ пространственных данных [110].

С использованием пространственной статистики была достигнута пространственная вариативность алгоритма обнаружения лесных пожаров на основе графов и методов обнаружения пространственных аномалий. Алгоритм показал более высокую точность по сравнению с продуктом MODISFire, предоставленным командой NASA MODIS. Было также показано, что обычный алгоритм построения точечной диаграммы неэффективен, поскольку он нечувствителен к небольшим пожарам, но и алгоритм построения точечной диаграммы Морана также был слабым из-за отсутствия численного критерия для оценки пространственных изменений [13].

Путем изучения различных видеорядов и изображений была предложена нечеткая цветовая модель с использованием статистического анализа. В сочетании с динамическим анализом модель позволяла хорошо различать пламя и пламя-подобные объекты [15]. Затем были проанализированы характеристики пожара, и предложен метод его обнаружения в режиме реального времени, основанный на скрытых марковских моделях, с помощью которого потенциальные пиксели пожара извлекались посредством обнаружения движущихся пикселей, проверки цвета пожара и кластеризации пикселей [111].

Был представлен алгоритм, основанный на автоматизированном развертывании сенсорной сети, что позволяло снизить потребление энергии сенсорными узлами и увеличить срок службы их сети [82]. Показана гибридная кластеризация с использованием k -средств на основе трех классификационных подходов, таких как нейронная сеть, Байесовский подход и дерево принятия решений, что обеспечивало обнаружение пожара с высокой точностью [76]. Предоставлена платформа, которая централизовала использование мобильных агентов в беспроводной сенсорной сети, что способствовало быстрому обнаружению лесных пожаров и их мониторингу с меньшим по-

треблением энергии [116]. Для обнаружения лесных пожаров была использована также система нечеткой логики в беспроводных сенсорных сетях. Алгоритм нечеткой логики был разработан с использованием пяти функций, таких, как температура, дым, освещенность, влажность среды и расстояние до объекта [10].

Представлена также апробированная система обнаружения пожара, основанная на оценке температуры зондируемой площади пожара. Для определения местоположения и включения сигнализации в случае пожара применен акустический дальномер [80]. Этими же авторами предложена новая система обнаружения пожара с использованием мультимедийной панели, которая позволяла выявлять и подтверждать факт пожара за меньшее время. Для обнаружения пожара использована мультимедийная платформа IMB 400 с получением изображения и запуском алгоритма фильтрации по изображению [81]. Предложен алгоритм обнаружения лесных пожаров в режиме реального времени, основанный на обработке изображений с применением двух методов сегментации пламени — по идентификации пикселей пламени и кластеризации по k -среднему значению [19]. С целью повышения эффективности процесса раннего обнаружения пожара предложен механизм, основанный на многоуровневом объединении данных [98].

Был представлен подход к обнаружению лесных пожаров с использованием различных методов интеллектуального анализа данных. В частности, применены прогнозные модели, основанные на данных ГИС и модели прогнозирования погоды по спутниковым данным Aladin и MODIS [106]. В работе были рассмотрены три различных набора данных, и для всех наборов показано, что создание пакетов и повышение эффективности деревьев решений дают наилучшие результаты с точки зрения точности [106]. Предложена также мобильная биологическая сенсорная система обнаружения лесных пожаров на ранней стадии, в которой животные используются в качестве мобильных биологических сенсоров. Алгоритм основан на существующих системах отслеживания животных, используемых в зоологических исследованиях [93].

Поскольку большинство алгоритмов были разработаны в видео-формате, что имело очевидные ограничения, был предложен новый метод обнаружения пожара «BowFire», который на неподвижных изображениях сочетал цветовые характеристики с распознаванием суперпиксельной текстуры [24]. В целом, большинство традиционных методов обнаружения возгораний, основанных на обработке изображений, были направлены на создание искусственных характеристик, таких как цвет, движение и текстура [128].

Был представлен полностью автоматизированный метод обнаружения лесных пожаров по спутниковым снимкам TIR на основе теории случайных полей (Random Field Theory — *математическая концепция, которая позволяет моделировать неопределенности физических свойств в непрерывных средах с учетом случайности и пространственной вариативности*). Результаты работы системы оценивались по показателям уровня значимости. Получены убедительные значения как частоты обнаружения, так и частоты

ложных регистраций, и предложена оценка направления распространения пожара [59].

Однако со временем человеческий интеллект стали заменять эффективные технологии глубокого обучения. Они лучше усваивали функции, чем люди, и извлекаемые ими функции содержали гораздо более глубокую семантическую информацию, чем созданные человеком. В последнее время машинное обучение превзошло традиционные возможности человека во многих областях и широко используется при обнаружении лесных пожаров. При этом применяется несколько методов: искусственная нейронная сеть, нейронная сеть с прямой связью, метод опорных векторов и дерево решений [71].

Искусственная нейронная сеть – это нелинейная динамическая система и схема работы человеческого мозга. Искусственные нейронные сети – это алгоритмы, основанные на обучении. Модели искусственной нейронной сети состоят из множества нейронов, сходных по функциям и структуре. Эти нейроны соединяются, образуя сеть, и используют алгоритм параллельной обработки. Искусственная нейронная сеть – это система, которая способна обучаться самостоятельно, а обучение представляет адаптивный процесс. Схема работает по принципу нейрона. Первая нейронная модель содержала два входа и один выход. Оба входа должны быть активны для корректного выхода. Значения весов для обоих входных данных были одинаковыми, а выходные данные – двоичными. На рис. 1 показана модель искусственной нейронной сети. Набор синапсов или соединительных звеньев характеризуется собственным весом. Сигнал x_p на входе синапса p , подключенного к нейрону k , умножается на синаптический вес w_{kp} . Сумматор используется для суммирования входных сигналов и функции активации для ограничения амплитуды выходного сигнала нейрона [71; 72].

Нейронные сети прямой связи рассматриваются как каскадные сжатые линейные функции. Входные данные поступают в слой скрытых модулей, которые могут передаваться в слои более скрытых модулей,

которые в конечном итоге передаются на выходной уровень (рис. 2). Каждый из скрытых модулей является сжатой линейной функцией своих входных данных. Нейронные сети этого типа могут иметь на входе любые действительные числа, а на выходе они получают одно действительное число. Для регрессии характерно, что выходные модули являются линейной функцией их входных данных. Для классификации нужно, чтобы выходные данные были сигмоидной функцией от входных данных. Для скрытых слоев не обязательно, чтобы их выходные данные были линейной функцией их входных данных; добавление дополнительных слоев не дает дополнительной функциональности. Таким образом, выходные данные каждого скрытого модуля являются сжатой линейной функцией его входных данных [7]. С сетью связаны параметры всех линейных функций. Эти параметры настраиваются одновременно, чтобы минимизировать ошибку прогнозирования в обучающих примерах [7; 71].

Метод опорных векторов – это управляемая обучающая модель с соответствующими алгоритмами обучения, которые анализируют данные и сопоставляют их с образцом [95]. Модели с использованием метода опорных векторов являются близкими “родственниками” классических многослойных нейронных сетей восприятия (perception neural networks). Используя функцию ядра (kernel function), метод опорных векторов представляет собой альтернативный метод обучения для полиномиальных связей, радиальной базисной функции и многоуровневых классификаторов восприятия, в которых веса сети определяются путем решения задачи квадратичного программирования с линейными ограничениями, а не путем решения невыпуклой задачи неограниченной минимизации, как в стандартной обучающей нейронной сети. Алгоритм метода опорных векторов представлен на рис. 3. Однако в некоторых случаях объяснительная способность модели, построенной по методу опорных векторов, может быть довольно низкой [52].




Рис. 1. Модель искусственной нейронной сети [71]
Обозначения в тексте




Рис. 2. Архитектура нейронной сети прямой связи [7; 71]




Рис. 3. Алгоритм метода опорных векторов [71]

Дерево решений представляет машинное обучение в форме анализа множества переменных. Они позволяют прогнозировать, объяснять и классифицировать результат обнаружения лесных пожаров. Дерево решений классифицирует объекты, сортируя их вниз по дереву решений, от корня до некоторого конечного узла [8]. Конечным результатом является дерево решений, в котором каждая ветвь представляет возможный сценарий принятия решения и его выход (рис. 4). Однако в некоторых случаях объяснительная способность модели, построенной по методу дерева решений, может быть довольно низкой, до 16 % [52]. Анализ обнаружения пожара по ретроспективным метеословиям также показывает низкую объяснительную способность – около 2 % [52].

В отличие от нейронной сети прямой связи, для обработки изображений широко используются различные алгоритмы сверточной нейронной сети – модифицированного многослойного персептрона (линейного двоичного классификатора). Скрытые слои такой нейросети включают слои свертки (отсюда и название), объединяющие слои и полностью связанные слои, предназначенные для различных компонентов распознавания изображений. Здесь разные слои могут применять ядра свертки для извлечения из изображения ключевых объектов и объединения слоев в пул для обобщения (уменьшения выборки) этих объектов [11; 89]. Сверточные слои используют несколько математических моделей для критической оценки и анализа данных. Изображение, представлен-

ное в абстрактной форме, слои преобразуют в карту объектов. Это повторяется слой за слоем, имитируя работу нейронов головного мозга. Поскольку это полностью подключенная сеть, все выходные данные фильтруются и объединяются в единый вывод в выходном слое [74].

Способность сверточных нейронных сетей автоматически изучать и извлекать признаки из базовых графических данных делает их особенно подходящими для обнаружения лесных пожаров [85]. Благодаря практической работе сверточных нейронных сетей с большими массивами данных разрабатываются модели, способные точно идентифицировать возгорания и отличать их от других явлений, таких, как облака, дым и солнечные блики. Основным преимуществом использования этой системы является высокое временное и пространственное разрешение [102]. Разработка эффективной модели обнаружения лесных пожаров с использованием сверточной нейронной сети направлена на удовлетворение потребности в масштабируемых решениях, способных работать в режиме реального времени и в условиях ограниченных ресурсов. Такая модель может быть развернута на различных платформах, включая видеокамеры, БПЛА и спутниковые системы, обеспечивающие непрерывное наблюдение за лесными массивами [16]. Одной из основных задач при обнаружении лесных пожаров с использованием сверточной нейросети является оптимизация производительности модели и эффективности вычислений, особенно для развертывания на периферийных устройствах с ограниченной вычислительной мощностью, а также с ограниченной полосой пропускания.

Для обработки и анализа изображений лесных пожаров на основе глубоких сверточных нейросетей использовались методы трансферного обучения. Это определяет эффективное обучение и надежность, а увеличение объема данных способствует повышению надежности модели. При этом сверточные нейросети требуют значительных вычислительных мощностей и объема памяти, что может быть проблемой при развертывании в средах с ограниченными ресурсами [58]. Была также разработана технология трансферного обучения, основанная на сверточной нейросети на базе архитектуры Inception-v3. Этот метод включал в себя подготовку спутниковых снимков,

разделение наборов фотоданных, связанных с пожаром и без него, генерирование матрицы беспорядка (confusion matrix) для определения эффективности структуры и, наконец, выделение на спутниковых снимках областей, где произошел пожар, с использованием локальной бинарной схемы для снижения частоты ложных обнаружений [87].

Был представлен метод обнаружения лесных пожаров на основе алгоритма YOLOv3 для обработки изображений, полученных с БПЛА, позволяющих идентифицировать небольшие площади пожаров, которые бывает трудно идентифицировать с помощью других методов. Для подтверждения того, что предлагаемая система может повысить эффективность и точность выявления ранних лесных пожаров, было проведено множество тестирований с использованием самостоятельно сгенерированного набора данных о лесных пожарах и двух оригинальных видеозаписей для их мониторинга. Результаты экспериментов показали, что система может эффективно выявлять ранние очаги возгорания и функционировать в широком диапазоне пожарных ситуаций [46]. Для обнаружения лесных пожаров были объединены снимки с БПЛА и искусственные нейронные сети [20; 46]. Выполнен анализ пяти сверточных нейросетей на предмет обнаружения лесных пожаров с использованием фотоизображений, полученных с БПЛА, при высоком уровне точности [60]. На основе использования БПЛА и глубокого обучения был предложен метод обнаружения пожара в ориентации на повышение эффективности и точности поиска. Для гарантированной эффективности распознавания была использована крупномасштабная сеть YOLOv3. Изображения пожара, полученные с помощью беспилотника, передавались в режиме реального времени на наземную станцию для последующей обработки [47]. Разработан также метод обнаружения пожаров на основе новой архитектуры, использующей БПЛА, непрерывно патрулирующего возможные районы возгорания. Кроме того, на беспилотнике был применен метод искусственного интеллекта с возможностями бортовой обработки. Это позволило применить методологию компьютерного зрения для обнаружения и распознавания огня или дыма в соответствии с видеосигналом и/или изображением с камер беспилотника [57; 129].




Рис. 4. Схема метода дерева решений [71]

В работе [48] был предложен метод обнаружения лесных пожаров с использованием алгоритма YOLOv3, примененный к аэрофотоснимкам, полученным с БПЛА. Используя вычислительную мощност встроеного оборудования, алгоритм YOLOv3 применен для создания компактной сверточной нейронной сети. С помощью этого метода идентифицировано около 83 % объектов, и, как показали тесты, обнаружение происходило со скоростью более 3,2 кадров в секунду. Этот подход имел ряд преимуществ при использовании БПЛА для обнаружения лесных пожаров в режиме реального времени [48].

В обнаружении лесных пожаров помогают беспроводные сенсорные сети, отслеживающие внезапно меняющиеся динамические среды (например, возгорания леса) и выдающие соответствующие предупреждения [54; 71]. Иногда эти сети могут выдавать ложные оповещения. Пожар можно обнаружить по количеству дыма с помощью датчиков. Количество дыма от пожара сравнивается с пороговым значением, и если оно превышает это значение, то эпизод рассматривается как сценарий пожара. Изображения с повсеместно установленных камер видеонаблюдения поступают на обработку, что позволяет обнаружить пожар предельно оперативно и быстро его потушить [69]. Камера видеонаблюдения используется для записи видео с определенного места и подключена к мини-компьютеру, чтобы можно было вести постоянную видеозапись определенного участка. Видеоснимки обрабатываются кадр за кадром, и как только обнаруживается пожар, включается сигнализация [74]. В частности, был разработан тест на лесные пожары, и для обнаружения пожара применена быстрая локальная сверточная нейросеть (R-CNN) [92], алгоритм Yolo и детектор SSD (мультиблоковый детектор с одним каналом) [66]. Было установлено, что детектор SSD является лучшим с точки зрения эффективности, точности обнаружения и возможности раннего обнаружения пожара. Был также предложен улучшенный алгоритм «tiny-Yolo» с измененной архитектурой сети [125].

Быстрая сверточная нейросеть R-CNN была также применена для выявления пожаро-опасных и пожаро-неопасных областей на основе их пространственных характеристик, а для проверки надежности пожарной сигнализации использована долго- и кратковременная память [55]. Предложена модель обнаружения пожара на основе видео с применением быстрой нейросети R-CNN для генерации области-кандидата на возгорание для каждого кадра. Затем были рассчитаны структурное сходство и среднеквадратичная ошибка для определения сходства между соседними кадрами, а конечные области возгорания определены на основе пространственных и временных характеристик [61]. Была также предложена система обнаружения лесных пожаров на основе камер с помощью обучения передаче данных, в которой для повышения точности обнаружения пожара использовалась стратегия анализа на основе блоков. Чтобы обеспечить эффективность модели на периферийных устройствах, удалялись избыточные фильтры, которые имели низкую энергетическую импульсную характеристику [78]. Наконец,

для обработки изображений лесных пожаров был применен метод главных компонент с последующей передачей их в обучающую сеть [126].

Для обнаружения задымления в естественных растительных сообществах была использована быстрая сверточная нейросеть с учетом регионов (RCNN) с целью предотвратить автоматическое извлечение признаков при обнаружении задымления в видеоформате. Чтобы компенсировать отсутствие проверочной информации, создавалось изображение искусственного дыма путем введения имитационного или реального дыма на фоне лесного полога [131]. Были также представлены инновационные методы пространственной и временной сегментации видеообъектов и плотного оптического потока в рамках глубокого обучения, включающие пространственно-временные изображения дыма от пожаров [40]. Чтобы уменьшить количество атмосферных загрязнений, присутствующих на видеокдрах, и тем самым повысить точность результатов обнаружения, применена предварительная обработка темного канала. Просмотр видеозаписей перед проведением оценки сокращает время, затрачиваемое на сбор достоверных данных на местах. Тесты с использованием общедоступных наборов видеоданных показали, что предлагаемые подходы превосходят результаты предыдущих работ и являются устойчивыми в широком диапазоне площадей, подверженных лесным пожарам [40]. В работе [121], направленной на решение той же проблемы, предлагается инновационный метод, основанный на глубоком обучении и динамическом фоновом моделировании, позволяющий уменьшить количество ложных оповещений и обеспечить обнаружение лесного пожара в режиме реального времени. Для начальной фазы обнаружения дыма был выбран сетевой трафик SSD (Single Shot MultiBox Detector). Затем динамическая область видео была получена с помощью технологии динамического моделирования фона ViBe, которая учитывала кинетические свойства дыма. Наконец, ранние результаты обнаружения дыма были улучшены за счет использования динамической области для уменьшения количества ложных срабатываний. Обширное тестирование в различных реальных сценариях показало повышение точности обнаружения пожара на 30 % по сравнению с использованием твердотельного накопителя [121]. В работе [4] использовался детектор дыма на базе «сети глубоких предположений» (Deep Belief Network – DBN). С помощью этого метода одновременно выделялись и классифицировались зоны, свободные от дыма, и зоны, подверженные задымлению. После измерения скорости обнаруженного дыма, времени предварительной подготовки и точной настройки оценивалась эффективность предложенной развернутой системы его обнаружения. Лучшая система обнаружения дыма имела самую высокую скорость обнаружения и самое быстрое время предварительной подготовки и настройки [4].

С применением видео-формата была разработана система обнаружения лесных пожаров, основанная на вычислительной эффективной аддитивной глубокой нейросети AddNet. Эта сеть включала векторный

оператор без умножения, который выполнял только манипуляции со знаками и операции по произведению из mf -операторов, которые использовались для определения свертки и плотных переходов с обратной связью в сети AddNet [79].

Для выявления признаков, связанных с пожаром, была представлена усовершенствованная модель компьютерного зрения, которая сегментировала изображение на области и классифицировала каждую область для обнаружения объектов. Это обеспечивало высокую точность и раннее обнаружение, а также масштабируемость, применяемую к различным типам сверточных нейросетей. Ограничения заключались в том, что это требовало значительных вычислительных ресурсов, зависело от количества и качества исходных данных [25].

Для повышения производительности в задачах обнаружения лесных пожаров с использованием набора фактических данных была применена адаптированная и точно настроенная архитектура ResNet-50, известная своими глубокими слоями, которая применялась для предотвращения исчезающих градиентов и повышения эффективности обучения. Глубокие слои и переходные соединения ResNet-50 обеспечивали эффективное извлечение признаков, что имело решающее значение для точного обнаружения пожара в различных условиях. Архитектура ResNet-50 может быть сложной для реализации и тонкой настройки, что требует специальных знаний в области методов глубокого обучения [90].

За последние годы было разработано несколько перспективных спутниковых систем обнаружения лесных пожаров, характеризующихся надежностью, их высокой доступностью, быстрым исполнением и способностью контролировать очень большие площади [36]. Спутники собирают данные о лесных пожарах, используя многочисленные тепловые и оптические датчики для определения таких физических характеристик, как длина волны, интенсивность света или поляризация, для сбора визуальных данных об окружающей среде, а также радарные датчики [34]. В частности, была предложена система на основе сверточных нейросетей для классификации спутниковых снимков от NASA WorldView, MODIS и Google по двум классам (с возгораниями и без них), и получен средневзвешенный балл F1-score, составляющий около 98 % [117].

Спутниковые системы охватывают очень большую территорию и обеспечивают надежное соединение, на которое не влияют физические и погодные препятствия по сравнению с наземными системами. Спутниковые системы были применены для обнаружения лесных пожаров в режиме, близком к реальному времени. Они используют тепловые, оптические, обзорные и радарные датчики для получения точной информации, такой как температура, влажность, тип растительности, атмосферные условия, метеорологические и топографические данные, прошедшие пожары и результаты деятельности человека, предоставляя информацию о местоположении и интенсивности пожаров. Оптические датчики могут обнаруживать изменения в растительности и напочвенном покрове,

которые могут указывать на наличие дыма и пожара. Тепловые датчики могут распознавать тепловую энергию, выделяемую дымом и пламенем, и предоставлять информацию о температуре и интенсивности пожаров. Радиолокационные датчики передают и принимают сигналы, позволяющие видеть сквозь дым и облака, создавая изображения поверхности земли с высоким разрешением даже в ночных условиях. Затем эти данные обрабатываются с использованием математических моделей или методов искусственного интеллекта, таких как модели машинного и глубокого обучения, для обнаружения и мониторинга лесных пожаров. Орбиты, на которых находятся спутниковые системы, имеют три категории: геостационарная орбита (GEO), высота около 36 тыс. км, низкая околоземная орбита (LEO), высота до 2 тыс. км и полярная солнечно-синхронная орбита (SSO), высота от 200 до 1000 км [34].

Для обнаружения лесных пожаров на спутниковых снимках дистанционного зондирования в последние годы были разработаны методы обнаружения и сегментации пожаров на основе глубокого обучения. Оба метода показали интересные результаты по сравнению с традиционными методами машинного обучения. Кроме того, они были полезны для эффективного управления пожарами. Обнаружение пожара было направлено на определение его наличия (дыма, пламени или того и другого) и его классификацию (рис. 5), в то время как сегментация пожара – это процесс группировки похожих пикселей дыма или пламени на входном спутниковом изображении на основе таких их характеристик, как цвет, форма и текстура, и вывода результата на экран в виде маски (рис. 6).

Модели глубокого обучения использовались для анализа дыма и автоматического обнаружения очагов возгорания. Они способны распознавать закономерности в данных спутниковых снимков, соответствующие дымовым шлейфам и пожарам, и использовать эту информацию для выявления случаев возгорания по мере их появления. Для обнаружения и сегментации пожаров с использованием спутниковых данных были предложены многочисленные модели глубокого обучения. При анализе спутниковых изображений применены сверточные нейросети, предназначенные для выявления закономерностей в визуальных данных, а также для распознавания дымовых шлейфов и других признаков, связанных с пожаром. По данным японского геостационарного метеоспутника Himawari-8 [51] была разработана сверточная нейросеть, состоящая из трех сверточных слоев 3×3 , за каждым из которых следуют функция активации ReLU и слой максимального объединения, а также два полностью связанных слоя для обнаружения лесных пожаров. Используя 2157 спутниковых изображений с 93270 выборками без наличия пламени и с 7795 выборками с пламенем, предложенная сверточная нейросеть показала превосходную производительность, достигнув показателя F1-score 74 % по сравнению с методом «случайного леса», давшим 54 %. По данным обнаружения и распознавания 715 лесных пожаров на изображениях, полученных спутником KITSUNE CubeSat, была выполнена сравнительная

оценка сверточных нейромоделей MiniVGGNet, ShallowNet и LeNet [5], показавшая их точность соответственно 98 %, 95 % и 97 %. Для обнаружения лесных пожаров с использованием спутниковых снимков Landsat была предложена специальная оптимизированная сверточная нейросеть, интегрировавшая метод ALO (Antlion Optimization) в функцию активации PReLU и показавшая точность около 61 % [49]. Был представлен основанный на глубоком обучении метод активного обнаружения лесных пожаров под названием Fire-Net, включающий в себя остаточные, точечные или глубинные сверточные и многомасштабные сверточные блоки. Система Fire-Net была обучена с использованием 578 снимков со спутника Landsat-8 и протестирована на 144 снимках лесов Австралии, Центральной Африки, Бразилии и Чернобыльской зоны, достигнув показателей F1-score соответственно 97,6; 80,5; 97,0 и 97,2 % [99].

Был предложен облегченный вариант сверточной нейросети для обнаружения дыма под названием VIB_SD, объединивший начальную структуру, метод концентрации внимания и остаточное обучение. Нейросеть была обработана с использованием 1836 мультиспектральных изображений, основанных на данных Landsat 8 OLI и Landsat 5 TM и разделенных на три класса («чистый», «задымленный» и «иной») с горизонтальным и вертикальным обращениями в качестве методов увеличения объема обучающих данных. Результаты экспериментов показали, что добавление инфракрасного диапазона улучшило производительность на 6 % по сравнению с использованием только диапазона RGB (красный, зеленый, голубой), при этом точность составила 86,5 % [135]. Был предложен еще один метод обнаружения дыма, названный

DC-CMEDA (глубокая свертка и коррелированное выравнивание встроеного распределения по коллектору), состоящий из глубокой сверточной нейросети (ResNet-50) и продукта CMEDA в качестве усовершенствованного продукта MEDA (выравнивание встроеного распределения по коллектору). Сначала нейросеть ResNet-50 извлекала характеристики дыма из данных целевого и исходного доменов (спутниковых и видеоизображений), а затем с целью уменьшить смещение в исходной области и сделать ее более похожей на целевую был использован продукт CMEDA, и, наконец, в качестве выходных данных было показано наличие или отсутствие дыма. В ходе обучения DC-CMEDA было использовано 200 спутниковых снимков и 200 RGB-изображений, каждое из которых включало 100 изображений с дымом и 100 изображений без дыма. При преобразовании спутниковых изображений в видеоизображения метод DC-CMEDA достиг точности в 93,0 %, превзойдя современные методы А. Филоненко [33] и DC-ILSTM [124] соответственно на 2,5 % и 1,5 %. При переходе от видеоизображений к спутниковым снимкам метод DC-CMEDA также показал высокую точность – 89,5 %, превзойдя методы А. Филоненко и DC-ILSTM соответственно на 6,5 % и 4,0 % [123]. С использованием данных MODIS был предложен метод обнаружения дыма на сверточной нейросети и продукте SmokeNet. Представлен новый набор данных под названием USTC_SmokeRS, содержащий 6255 спутниковых снимков дыма и очень близких к дыму классов, таких как дымка, облака, туман и т. д. SmokeNet представляет модифицированный метод AttentionNet, который объединяет пространственное и канальное внимание с остаточными блоками и обеспечивает точность 92,7 % [6].




Рис. 5. Обнаружение лесного пожара на основе модели глубокого обучения [34]




Рис. 6. Сегментация лесного пожара на основе модели глубокого обучения [34]

Была представлена новая программа сверточной нейросети FireCNN для обнаружения пожаров на спутниковых снимках Himawari-8, состоящая из трех сверточных блоков и полностью связанного слоя. Каждый сверточный блок состоял из двух сверточных слоев, за каждым из которых следовала активация ReLU и слой максимального объединения. Нейросеть FireCNN была протестирована на наборе данных, содержащем 3646 негорючих точек и 1823 очага возгорания, и получена точность обнаружения 99,9 %, что выше, чем при использовании традиционных методов машинного обучения (пороговая обработка, метод опорных векторов и «случайный лес») [43].

Перечень методов и результатов обнаружения лесных пожаров можно было бы продолжить и дальше, поскольку в литературе они исчисляются сотнями. Однако это не даст детального представления о реализации упомянутых алгоритмов, как и не даст возможности какого-либо их синтеза в рамках журнальной статьи. Похожая ситуация сложилась на волне компьютерного бума в конце 1970-х годов при разработке имитационных моделей процессов, протекающих в лесных экосистемах [14; 38; 97; 105]. Каждая такая модель являлась математической записью представлений ее автора о способе действия исследуемого объекта. А поскольку как авторы, так и их индивидуальные видения различных аспектов функционирования лесных экосистем, исчислялись сотнями, то выполнить некий методологический синтез этих «видений» было практически невозможно.

Данная ситуация в нашем исследовании усугубляется как многократно возросшим объемом информации по фактическим данным о лесных пожарах, накопленным в соответствующих репозиториях, так и бесчисленным множеством алгоритмов и программных обеспечений, использованных при различных способах обнаружения лесных пожаров. Поэтому в нашем дальнейшем изложении основное внимание уделено описанию некоторых наиболее продвинутых алгоритмов глубокого обучения, реализованных при обнаружении лесных пожаров.

ОБНАРУЖЕНИЕ ЛЕСНЫХ ПОЖАРОВ С ПОМОЩЬЮ НЕЙРОСЕТЕЙ И ЦИФРОВОЙ КОЛОРИМЕТРИИ

За последние десятилетия были предприняты значительные усилия по разработке средств автоматического обнаружения лесных пожаров в трех основных направлениях: использование спутниковых данных, инфракрасных сканеров дыма и локальных датчиков (например, метеорологических). Для разработки эффективной системы обнаружения лесных пожаров на основе нечеткой логики была поставлена цель – извлечь ценную информацию из данных цветового пространства и использовать ее для определения местоположения лесных пожаров с помощью обработки изображений и методов искусственного интеллекта, что входит в область цифровой колориметрии [2; 3]. Ранее была представлена эффективная система для обнаружения лесных пожаров с использованием пространственных данных о лесном покрове. При разработке системы использовались методы обработки

изображений и искусственного интеллекта. Для сегментации и обнаружения пожара применены соответственно анизотропная диффузия и нечеткая логика. В процессе оценки использовались общедоступные пространственные данные. Нечеткие правила, полученные с использованием представленной системы, успешно выявляли лесные пожары в пространственных данных лесного покрова [2]. В данном разделе описаны концепции, используемые в представленной интеллектуальной системе для эффективного обнаружения лесных пожаров, такие, как цветовое пространство, сегментация анизотропной диффузии и искусственные нейронные сети с радиальными базисными функциями [3].

Преобразование цветового пространства. Цветовое пространство определяется как средство, с помощью которого выполняются спецификация, создание и визуализация цветов. Экран компьютера воспроизводит цвета на основе различных комбинаций красного, зеленого и синего излучения люминофора, необходимых для формирования цвета. Обычно цвет представлен тремя координатами или параметрами. Эти параметры иллюстрируют расположение цвета в цветовом пространстве. Преобразование цветового пространства определяется как преобразование цвета из одного источника в другой. Обычно преобразование цветового пространства выполняется, когда изображение, представленное в одном цветовом пространстве, преобразуется в другое цветовое пространство с целью сделать переведенное изображение максимально похожим на оригинал. В предлагаемой интеллектуальной системе изображения в цветовом пространстве RGB (красный, зеленый, голубой) преобразуются в цветовое пространство XYZ [3]. Цветовое пространство CIE XYZ – одно из первых математически определенных цветовых пространств, созданных Международной комиссией по освещению в 1931 году [103]. Любой цвет может быть сгенерирован как сочетание трех других цветов или «трестимулов», обычно это RGB для систем на базе телевизора или компьютера. Цветовое пространство XYZ определено таким образом, что все видимые цвета могут быть представлены с использованием только положительных значений, а значение Y равно яркости. Диаграмма цветности чрезвычайно нелинейна, поскольку вектор единичной величины, обозначающий разницу между двумя цветовыми оттенками, виден неравномерно. Для перевода значений RGB в определенном наборе основных цветов в CIE XYZ и обратно использовано матричное преобразование 3×3 . Уравнения для преобразования RGB в цветовое пространство XYZ имеют вид [3]:

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0,412453 & 0,357580 & 0,180423 \\ 0,212671 & 0,715160 & 0,072169 \\ 0,019334 & 0,119193 & 0,950227 \end{bmatrix} * \begin{bmatrix} R \\ G \\ B \end{bmatrix}. \quad (1)$$

Сегментация анизотропной диффузии. Сегментация изображения определяется как низкоуровневая задача обработки изображений, предназначенная для разделения изображения на идентичные области [28]. Результаты сегментации могут быть использованы

для идентификации интересующих областей и объектов в сцене, что очень полезно для последующего анализа изображения. Из-за того, что присущие множеству объектов свойства не только обладают нелинейной индивидуальной зависимостью, но и включают в себя зависимость между объектами R, G и B, сегментация цветного изображения более монотонна по сравнению с сегментацией серого изображения. В данной системе для сегментации изображений в пространственных данных применен подход анизотропной диффузии. Сегментация выполняется на изображении, преобразованном в цветовом пространстве XYZ. В литературе предлагается множество моделей линейной и нелинейной диффузии для сглаживания и сегментации изображений. Анизотропная диффузия улучшает реакцию алгоритмов обнаружения границ за счет ряда операций, а именно: сглаживания внутренней части изображения, чтобы акцентировать границы для сегментации, устранения ложных деталей и эффективного устранения шума на изображениях [94]. Процессы релаксации, реализующие анизотропную диффузию, как правило, не учитывают низкочастотные объекты, которые сложно рассеять без чрезмерной обработки изображения. Анизотропная диффузия при обработке изображений дискретизирует семейство непрерывных дифференциальных уравнений в частных производных [3].

Искусственные нейронные сети с радиальными базисными функциями. Как уже отмечалось выше, искусственные нейронные сети обладают способностями распознавать закономерности, управлять данными и обучаться. Наиболее значимым плюсом использования искусственных нейросетей является решение очень сложных задач, связанных с традиционными технологиями, без формулирования алгоритмического решения или использования очень сложного решения [68]. В конце 1980-х годов появился вариант искусственной нейронной сети с радиальными базис-

ными функциями (Radial Basis Functions), хотя их корни уходят в гораздо более ранние методы распознавания образов [115]. Нейросеть с радиальной базисной функцией (RBF) основана на контролируемом обучении. Сети RBF были предложены несколькими исследователями независимо один от другого [12; 73; 86] и представляют популярный вариант многослойного персептрона MLP. Сети RBF также отлично справляются с моделированием нелинейных данных и могут быть обучены за один этап, а не с использованием итеративного процесса, как в алгоритме MLP. Сеть RBF имеет структуру прямой связи, состоящую из одного скрытого уровня J локально настроенных модулей, которые полностью связаны с выходным уровнем из L линейных модулей. Все скрытые модули одновременно получают n-мерный вещественный входной вектор X. Основным отличием от MLP является отсутствие весов скрытых слоев [3].

Представленная интеллектуальная система обнаружения лесных пожаров использует пространственные данные, собранные в лесных регионах. При проектировании представленной интеллектуальной системы применена нейросеть с радиальной базисной функцией. Первоначально изображения с наличием пожаров преобразовывались из цветового пространства RGB в пространство XYZ. Преобразование цветового пространства из RGB в XYZ выполнялось с помощью уравнений (1). В результате получено изображение в цветовом пространстве RGB (рис 7, а) и соответствующее ему преобразованное изображение в цветовом пространстве XYZ (рис. 7, б).

Затем изображение, преобразованное в цветовом пространстве XYZ, сегментировалось с использованием анизотропной диффузии, что позволяло определить местоположение очагов возгорания. Результат анизотропной диффузионной сегментации показан на рис. 7, в.




Рис. 7. Результат работы представленной интеллектуальной системы:

а – ввод изображения; б – изображение, преобразованное в цветовом пространстве XYZ;

в – вывод анизотропной диффузионной сегментации; г – изображение обнаруженного пожара [3]

Области возгорания, полученные с помощью сегментации, использованы для обучения нейронной сети с радиальной базисной функцией. Нейронная сеть с радиальной базисной функцией обучалась с использованием значений цветового пространства XYZ пикселей, которые принадлежат областям возгорания. С помощью обученной нейронной сети определялось наличие лесных пожаров на изображении. Затем значения цветового пространства XYZ пикселей в сегментированных областях передавались в качестве входных данных в обученную нейронную сеть для определения наличия пожаров (рис. 7, з). Предложенная интеллектуальная система реализована в среде Matlab 7.4 [3].

Таким образом, в представленной интеллектуальной системе использованы изображения пространственных данных соответствующих лесных районов, полученные с помощью дистанционного зондирования. При проектировании системы применена нейросеть с радиальной базисной функцией. Для обучения нейросети использованы наборы пространственных изображений горящих лесов. Первоначально цифровые изображения пространственных данных о лесах преобразуются из цветового пространства RGB в пространство XYZ, и выполняется сегментация изображения в цветовом пространстве XYZ с помощью метода анизотропной диффузии. Значения цветового пространства XYZ для изображений пожаров, полученные в результате сегментации, передаются в качестве входных данных для обучения нейросети с радиальной базисной функцией. Для заданного значения пикселя в цветовом пространстве XYZ обученная нейросеть с радиальной базисной функцией определяет, соответствует ли этот пиксель области пожара или нет [3].

ИНТЕЛЛЕКТУАЛЬНАЯ МОДЕЛЬ ГЛУБОКОГО ОБУЧЕНИЯ ПРИ ОБНАРУЖЕНИИ ЛЕСНЫХ ПОЖАРОВ С ПОМОЩЬЮ ВСТРОЕННЫХ ДАТЧИКОВ

Последние достижения в области компьютерного зрения и методов глубокого обучения открывают путь к разработке новых инструментов для обнаружения и мониторинга лесных пожаров. Предложена интеллектуальная система обнаружения лесных пожаров и оповещения о них, использующая модель глубокого обучения IWFFDA-DL. Представленный метод нацелен на две основные функции: (1) наиболее раннее обнаружение пожара и (2) информирование соответствующих служб реагирования. Устройства обнаружения включают в себя датчики пламени, дыма и тепла; кроме того, подключена камера для подтверждения фактических изображений пожара. В зависимости от характера возгорания, диспетчер выполняет несколько одновременных операций: включает систему тушения, подает звуковой сигнал пожарной тревоги, информирует подразделения аварийно-спасательной службы, отключает электроснабжение и передает владельцу данные, включающие адрес объекта [1]. На рис. 8 показан общий рабочий процесс предложенного метода IWFFDA-DL.

Датчики являются основным источником входных данных, а для объединения сигналов, полученных от датчиков, подключены цифровые камеры. Благодаря интеграции функционирования этих двух устройств разработан интеллектуальный метод точного обнаружения пожара. Модули системы мобильной связи GSM и интегрированной сенсорной системы (ISS), а также модули обработки изображений, объединены в единое целое с помощью микроконтроллера. В представленной модели беспроводную передачу данных обеспечивает подключение через Wi-Fi. Всем интегрированным сенсорным системам на данной территории присвоены номера, которые используются микроконтроллером для определения точного местоположения пожара. Чтобы запустить метод объединения нескольких данных, микроконтроллер устанавливает пороговое значение. Он анализирует сенсорную информацию, чтобы создать оптимальную схему восприятия для выявления возможных пожаров. На основе результатов обработки изображений система определяет приоритетность результатов и передает их в службу экстренного реагирования [1].

Эффективное обнаружение лесного пожара основано на применении модели ACNN-BLSTM. Для извлечения характеристик и повышения точности прогноза сверточная нейронная сеть, сеть BLSTM и эффективный канал привлечения внимания (Effective Channel Attention – ECA) интегрированы в единую структуру, что представляет собой новый сетевой метод прогнозирования временных рядов под названием ACNN-BLSTM. «*Attention mechanism*» – механизм привлечения внимания, позволяющий модели фокусироваться на наиболее релевантных частях входных данных, учитывая весь контекст. В данном случае сосредоточить внимание модели на горящем участке леса – ключевой способ улучшить способность модели выделить горящий участок из лесного полога [67]. Согласно представленному методу происходит автоматическое обучение, а также извлечение локальных характеристик и характеристик с длительной памятью, из временных рядов путем полного использования данных для минимизации сложности моделей. Кроме того, отлажен канал привлечения внимания к дополнительным существенным характеристикам. На рис. 9 показана структура алгоритма BLSTM.

Для выполнения задач прогнозирования использован плотностный метод (dense method), содержащий множество полностью связанных (fully connected) слоев. В данном случае сверточная нейросеть использована для эффективного извлечения характеристик данных. По сравнению со структурой обычной нейросети, сверточная нейросеть имеет локальную связь между нейронами, что снижает количество параметров на уровне соединений. В частности, она включает в себя часть связи между $n-1$ слоем и n -слоем сверточной нейронной сети. Для более точного прогнозирования использована структура BLSTM, которая применяется как в прямом, так и в обратном направлениях для всех обученных последовательностей. Для предоставления полных контекстных данных всех точек последовательности сети LSTM связаны с аналогичным выходным уровнем [1].




Рис. 8. Общий процесс предложенного метода IWFFDA-DL [1].

Показатели адекватности: Precision – точность как доля объектов, действительно принадлежащих к положительному классу, среди всех объектов, которые модель отнесла к положительному классу: $\text{Precision} = TP / (TP + FP)$; Recall – полнота как доля объектов положительного класса, которые модель правильно идентифицировала среди всех объектов положительного класса в тестовой выборке: $\text{Recall} = TP / (TP + FN)$; Accuracy – точность (правильность) – степень совпадения измеренного значения величины со стандартным значением; F-score – (F-оценка) объединяет «precision» и «recall» через формулу гармонического среднего: $F = 2 \times (\text{precision} \times \text{recall}) / (\text{precision} + \text{recall})$ (F-score учитывает как ложноположительные, так и ложноотрицательные результаты, что делает её особенно ценной для несбалансированных наборов данных); ROC – рабочая характеристика приемника как всесторонняя оценка эффективности классификатора (см. текст); MAE – абсолютная средняя ошибка; RAE – относительная средняя ошибка. Обозначения TP, FN и FP указывают соответственно на идеальную, недостаточную и чрезмерную идентификацию [39; 104]




Рис. 9. Структура модели BLSTM; на схеме LSTM означает «Long Short Term Memory» – долго- и кратковременную память [1]

Процесс управления вниманием (СА) обладает огромным потенциалом для повышения эффективности глубокой сверточной нейросети. Чтобы избежать чрезмерной подгонки метода и сократить время расчета, был создан облегченный компонент с минимальной сложностью под названием «эффективный канал привлечения внимания» (Effective Channel Attention – ECA). Система ECA может определять не только веса для всех каналов, но и корреляцию между ними. В данных временных рядов больший вес присваивается ключевому признаку, а меньший – несущественному признаку [23]. Таким образом, ECA работает с данными, которые повышают чувствительность сети к существенным признакам. У системы ECA есть приоритет для реализации глобального усредненного пула (Global Average Pooling – GAP) каналов. Затем ECA использует все каналы и k -блилежащих каналов для получения локальных перекрестных соединений. ECA увеличивает вес канала, выполняя быструю 1D сверточную обработку в виде:

$$\omega = \sigma(C1D_k(y)), \quad (2)$$

где $C1D$ относится к одномерной сверточной системе, а k означает размер ее ядра. Чтобы избежать ручного изменения k , система ECA использует способ адаптивного отображения размера каналов для определения значения k . Поскольку размер ядра k одномерной сверточной функции прямо пропорционален размеру канала C , эквивалентная связь определена как

$$C = \varphi(k) = 2^{(\gamma * k - b)}. \quad (3)$$

Таким образом, чтобы обеспечить размер канала C , размер ядра k корректируемо определяется следующим образом:

$$k = \psi(C) = \left\lfloor \frac{\log_2(C)}{\gamma} + \frac{b}{\gamma} \right\rfloor \text{odd}, \quad (4)$$

где $\lfloor \text{odd} \rfloor$ обозначает соседнее нечетное число. Параметры γ и b имеют значения [2] и [1] соответственно. Примечательно, что канал с высокой размерностью имеет больший диапазон, а канал с минимальной размерностью – меньший диапазон взаимодействия с нелинейным отображением [1].

Для оптимального выбора гиперпараметра, используемого в модели ACNN-BLSTM, применен упомянутый на рис. 8 алгоритм BFO – новый метод оптимизации, основанный на моделировании некоторых природных явлений (в частности, группового поиска пищи бактериями), разработанный К. Пассино в 2002 году [83]. Алгоритм BFO стал эффективным методом оптимизации, который обеспечивает более высокую скорость сходимости, а также точность, применяемую в ряде приложений в режиме реального времени. Метод BFO стимулируется эффективностью хемотаксиса виртуальных бактерий, которые движутся навстречу (в направлении) или в сторону (не в направлении) от определенного сигнала, делая меньший шаг при поиске питательных веществ в пространстве [22].

Для идентификации все кадры проходят процесс обнаружения объектов на основе алгоритма YOLOv3, и представленный способ может передавать данные пользователю через GSM-модем. Это беспроводное устройство, разработанное для передачи данных с компьютера с использованием общей службы радиосвязи (GPRS) и систем GSM. Для активации передачи требуется SIM-карта модуля идентификации абонента и международный идентификационный номер мобильного устройства (IMEI) для идентификации адресата. Данные о состоянии системы наблюдений передаются в хранилище данных для анализа причины пожара. После получения сигналов от микроконтроллера GSM-модем пересылает SMS-сообщения службе реагирования, чтобы она могла предпринять соответствующие действия [1].

Эффективность прогнозирования пожара с помощью метода IWFFDA-DL оценена путем экспериментальной проверки. Результаты проанализированы с использованием набора данных, который включает три класса пожарного состояния, а именно нормальный, потенциальный и экстремальный. При нормальном состоянии температура составляет менее 55 °C, пламя менее 180 мкм, а дым менее 50 дБ/м. При потенциальном состоянии значение температуры составляет от 55 °C до 65 °C, пламени – от 180 до 190 мкм, а дыма – от 50 до 150 дБ/м. При экстремальном пожароопасном состоянии температура превышает 65 °C, пламя превышает 190 мкм, а дым превышает 150 дБ/м [1].

Согласно экспериментальной проверке модели методика IWFFDA-DL показала превосходные результаты во всех прогонах. Например, в ходе первого прогона показатели «precision», «recall», «accuracy», F-score и ROC (см. подпись к рис. 8) составили соответственно 0,965, 0,939, 0,989, 0,951 и 0,986, а по завершении последнего, десятого прогона – соответственно 0,979, 0,995, 0,996, 0,987 и 0,999. Посредством ROC (Receiver Operating Characteristic) как рабочей характеристики приемника получена комплексная оценка эффективности классификатора:

$$ROC = \frac{P(x | \text{positive})}{P(x | \text{negative})}, \quad (5)$$

где $P(x|C)$ обозначает условную вероятность того, что запись данных имеет классовую метку C . Кривая ROC отображает результаты классификации от наиболее позитивной классификации к наиболее негативной [104].

Общий анализ результатов классификации по методу IWFFDA-DL в ходе десяти прогонов модели с использованием различных показателей адекватности показал, что метод IWFFDA-DL имеет высокую эффективность классификации по различным классам. Анализ кривой четких рабочих характеристик приемника (ROC) по методу WFTDA-DL показал, что он способен обеспечить повышенную производительность при значении ROC до 0,999.

Таким образом, предложенная модель глубокого обучения IWFFDA-DL включает в себя интегрированную сенсорную систему, объединяющую множество датчиков и выступающую в качестве основного

источника входных данных для обнаружения лесного пожара. Для идентификации наличия пожара применена модель сверточной нейронной сети с двунаправленной долго- и кратковременной памятью (ACNN-BLSTM). Для настройки гиперпараметров модели ACNN-BLSTM использован алгоритм оптимизации поиска пищи бактериями (BFO). При обнаружении пожара модем глобальной системы мобильной связи (GSM) передает сообщения службе реагирования для принятия необходимых мер. Выполненный комплекс симуляций показал, что предложенная модель обеспечивает повышенную производительность при значении ROC до 0,999 [1].

ОБНАРУЖЕНИЕ ЛЕСНЫХ ПОЖАРОВ С БЕСПИЛОТНЫХ ЛЕТАТЕЛЬНЫХ АППАРАТОВ

Многие из существующих систем обнаружения пожара основаны на дымовой и тепловой сигнализации. Основным недостатком сигнализации с датчиками дыма и тепла является то, что одного модуля недостаточно для мониторинга всех потенциально пожароопасных мест. Даже если они будут установлены повсеместно, этого недостаточно для надежного обнаружения. По мере увеличения количества датчиков также многократно возрастает стоимость обнаружения пожаров.

Лесные пожары можно обнаруживать с помощью систем визуального наблюдения, которые могут быть установлены на беспилотных летательных аппаратах (БПЛА) для регулярного сканирования площадей, подверженных пожарам. Предлагаемая система может выдавать последовательные и высокоточные оповещения о пожаре в течение нескольких секунд. Это снижает затраты, поскольку для обеспечения работы всей сети видеонаблюдений достаточно всего одного программного обеспечения. Реальная задача состоит в том, чтобы свести к минимуму ошибки при обнаружении пожара и отправке оповещений. Предлагаемая структура использует преимущества сверточной нейронной сети, которая получает входные данные, предварительно обрабатывает их и объединяет с использованием области предложений. Затем алгоритм обнаружения объектов на основе регионов в нейросети классифицирует эти предложения на пожарные и не пожарные в интересующем регионе с помощью сверточных слоев [74].

Сверточная нейронная сеть состоит из сверточных слоев и отличается от других алгоритмов обнаружения объектов способностью генерировать интересующую область на исходном изображении с помощью фильтров преобразования изображений, называемых сверточными ядрами, в то время как другие алгоритмы для построения модели используют взвешенные суммы и веса соединений. Количество созданных карт объектов будет равно количеству ядер. Цвет пикселя на картах объектов соответствует точкам активации. Белые пиксели на карте объектов – это точки на исходном изображении с сильными точками активации. Серые пиксели представляют слабые точки активации, а черные пиксели представляют сильные отрицательные точки активации. Область пламе-

ни на исходном изображении красновато-оранжевая, поэтому сверточное ядро изменяет цвет пикселей на белый. Каждый нейрон в сверточной нейронной сети получает входные данные от ограниченной части предыдущего слоя. На рис. 10 представлена базовая архитектура сверточной нейросети, где в качестве входных данных представлены изображения пламени. Затем слои сети придают изображению абстрактную форму, удаляя все фоновые шумы, и выделяют объект, который необходимо обнаружить.




Рис. 10. Архитектура сверточной нейросети [74]

Данные представлены в виде видеок кадров, которые получены с камер видеонаблюдения, но для простоты использования для обучения и тестирования используются специально созданные видеоролики. Соответствующие кадры с пламенем и без него затем сохраняются, а набор данных делится на обучающий и тестовый. Следующий этап построения качественной модели глубокого обучения включает предварительную обработку данных, которые фильтруются и обрабатываются или просто приводятся в соответствие с пользовательскими требованиями. Удаляются из кадра также шумы и другие нежелательные объекты. Алгоритм запрашивает соответствующие данные, в противном случае он может привести к нежелательным результатам [74].

Чтобы нейронная сеть могла точно обнаружить возгорание, ей необходимо знать особенности огня применительно к компьютерному зрению. Признаки пожара легко распознаются человеческим глазом. Огонь излучает красноватый цвет; при различных обстоятельствах он имеет форму и движение в зависимости от того, какой использован горючий материал. В данном случае для обнаружения используются форма, цвет и движение огня и дыма, которые извлекаются из разных кадров в обучающем наборе. Затем извлеченные признаки передаются в сеть для построения модели. Эта модель представляет собой набор пороговых значений, которые помогают сети точно обнаруживать возгорание. Модель извлекает уроки из выявленных признаков и устанавливает стандарт для анализа новых входных данных [74].

Поскольку важно добиться необходимой точности и проверить, работает ли система, необходима валидация модели глубокого обучения. Процесс валидации выполнялся с использованием другого набора видеок кадров, который полностью отличался от набора

данных, предоставленного для построения модели. Согласно результатам тестирования, система с помощью тестового набора достигла точности около 93 % [74].

Возможности использования видеокадров с БПЛА при обнаружении пожара с помощью глубокого обучения являются инновационными. Предложенная система может быть усовершенствована путем интеграции беспроводных датчиков с системой видеонаблюдения посредством БПЛА для дополнительной защиты и точности. Алгоритм демонстрирует большие перспективы в адаптации к различным условиям. Из-за ограничений традиционных методов, методы глубокого обучения, которые в последнее время стали популярны в приложениях для обработки изображений и распознавания образов в процессе автоматического обнаружения лесных пожаров, позволяют эффективно решить проблему. В этом исследовании предполагаемые очаги возгорания, не обнаруженные во время наблюдения за лесными пожарами, были классифицированы, а их изображения были выделены для улучшения распознавания. Систематически анализировались и сравнивались несколько методов выделения признаков, при этом типы объектов задавались вручную. После создания нейросетевой модели были тщательно подобраны оптимальная скорость обучения и количество итераций для точного обнаружения пламени. Обучение проводилось с использованием установленного набора образцов изображений пламени, что позволило разработать надежную обучающую модель. Была проведена оценка точности модели по сравнению с другими моделями, и ее превосходная производительность (около 0,86) подтвердила эффективность предложенного подхода [74].

Полученные результаты показывают перспективность использования сверточных нейронных сетей для обнаружения пожара посредством БПЛА по сравнению с другими нейронными сетями. Система интеллектуально объединяет несколько обучающих данных для расчета и снижения частоты ложных оповещений при полностью подключенной сети. Затем эти данные передаются в алгоритм принятия решений для определения того, есть пожар или нет. Несмотря на незначительные ошибки обнаружения на некоторых изображениях, общая производительность и статистика являются вполне приемлемыми. Единственным недостатком является некоторая медлительность, поскольку для получения результатов требуется большая вычислительная мощность. Количество ложных срабатываний может быть уменьшено за счет дополнительной очистки данных [74].

ОБНАРУЖЕНИЕ ЛЕСНЫХ ПОЖАРОВ С ИСПОЛЬЗОВАНИЕМ СПУТНИКОВЫХ СИСТЕМ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ

Методы компьютерного зрения становятся всё более перспективными при обработке данных орбитальных снимков с использованием сверточных нейронных сетей [42]. На примере водно-болотных угодий Бразилии предложен подход, основанный на новых методах обнаружения лесных пожаров с использова-

нием изображений камеры WFI китайско-бразильского спутника CBERS 04A. Спутник CBERS 04A оснащен мультиспектральной и панхроматической камерами с широким спектром обзора WPM, мультиспектральной камерой MUX и широкоугольной камерой для формирования изображений WFI. Время сканирования датчика WFI составляет пять дней, что позволяет осуществлять активный мониторинг пожаров с высоким пространственным разрешением (55 м). При таком подходе аннотировалась только одна точка, что облегчало задачу маркировки, которая отнимала много времени и позволяла уменьшить влияние аннотации в виде ограничивающих рамок, поскольку дымовые шлейфы имели разные размеры [42].

В общей сложности были идентифицированы 775 дымовых шлейфов. Набор данных был помечен вручную одной точкой у основания каждого столба дыма, свидетельствующего о наличии горящего объекта (рис. 11). Дымовые шлейфы и активный пожар рассматривались как синонимы. Кроме того, дым от активного пожара имеет форму конуса, поэтому при нескольких различных вариантах рассеивания дыма помечался наземный его источник с целью обучить нейросети распознавать эти различные варианты. Метки точек для дымового шлейфа включали их координаты, поскольку были привязаны к базам данных с сетевыми ресурсами. Для каждой точки наземной метки создавалась ограничивающая рамка, поскольку для большинства методов обнаружения объектов требовался прямоугольник, а не точка. Чтобы избежать субъективной идентификации дымового шлейфа, которая может варьировать в зависимости от количества дыма, выбрасываемого в атмосферу, были применены переменные значения размера ограничивающей рамки – от 10 до 50 пикселей [42].



Рис. 11. Ручные метки возгораний (красные точки) и ограничивающие рамки размером от 10 до 50 пикселей [42]

Такие методы, как новая локализация границ с учетом боковой ориентации (SABL – Side-Aware Boundary Localization) [120], адаптивный отбор обучающей выборки (ATSS – Adaptive Training Sample Selection) [133], варифокальная сеть (VarifocalNet) [134] и вероятностное назначение привязки (якоря) (PAA – Probabilistic Anchor Assignment) [56] до настоящего времени при орбитальном дистанционном зондировании не применялись. В предложенном подходе сравнивались перечисленные подходы, а также

быстрые нейросети R-CNN [91] и RetinaNet [65], отражающие современное состояние дистанционного обнаружения лесных пожаров. Кроме того, они включали в себя такие методы обнаружения объектов, как основанные на привязке, без привязки, одноступенчатые и двухступенчатые [42].

Быстрая нейросеть R-CNN [91] – это двухэтапная сверточная нейросеть, состоящая из магистральной сети и сети региональных предложений (RPN), которая разделяет сверточные функции с сетью обнаружения и работает как модуль механизма привлечения внимания, который генерирует ограничивающие рамки-кандидаты (якорные рамки). В сети RPN генерируются привязочные блоки с различными соотношениями сторон и масштабами, и сеть обнаружения оценивает каждый привязочный блок с помощью аннотированных ограничивающих блоков. Сеть обнаружения основана на быстрой нейросети R-CNN, которая получает привязки и карту объектов в качестве входных данных и возвращает класс и местоположение ограничивающих рамок. Привязка считается положительным обнаружением (или положительным образцом), если значение пересечения при объединении (IoU) превышает пороговое значение, обычно равное 0,5 (*IoU* – *Intersection over Union* – метрика для оценки качества обнаружения и сегментации объектов, которая измеряет степень перекрытия между предсказанным и реальным объектами. Чем ближе *IoU* к 1, тем точнее модель локализует объект). Таким образом, метрика IoU вычисляет степень перекрытия между рамкой привязки и аннотированной ограничивающей рамкой. В данной работе создана функциональная пирамида сетей (FPN) [64] поверх сети ResNet50 в качестве магистральной [42].

Сеть RetinaNet [65] представляет одноступенчатый метод обнаружения объектов, состоящий из двух основных блоков: FPN и Focal Loss. Блок FPN [64] представляет современную сверточную нейросеть, использующую пирамидальную иерархию объектов для их масштабирования. Потеря фокуса устраняет классовый дисбаланс между положительными (прямоугольники-кандидаты, чья метрика IoU превышает пороговое значение) и отрицательными (прямоугольники-кандидаты, чья IoU меньше порогового значения) выборками, вызванный перегрузкой отрицательных ограничивающих контуров, поскольку наиболее достоверными выборками являются положительные. В данной работе сформирована пирамида сетей FPN [64] поверх сети ResNet50 [42].

Был предложен адаптивный отбор обучающей выборки (ATSS), который отбирает некоторую совокупность положительных и отрицательных выборок в соответствии со статистическими характеристиками [133]. Исходя из близости к центру определения истинности данных, k якорей (anchors) выбираются в качестве положительных кандидатов в соответствии со значением IoU. Обучающая выборка ATSS с ResNet50 и FPN [64] рассмотрена в качестве основы, но сначала отбирались $k = 9$ якорных ячеек в качестве положительных кандидатов [42].

Вслед за [65], их последователи [134] предложили варифокальную сеть (VarifocalNet), которая сочетает

в себе полностью сверточное одноступенчатое обнаружение объектов (Fcos) [112] и метод ATSS, представленные в виде ограничивающего контура в форме звезды, и новую функцию потерь, названную варифокальной потерей. Изменение фокусного расстояния уменьшает вклад отрицательных выборок благодаря динамически регулируемому коэффициенту масштабирования и асимметрично увеличивает вклад положительных выборок (у которых значение IoU выше). Представление объекта в виде ограничивающего контура в форме звезды использует девять фиксированных точек выборки [26]. Форма звезды может отображать геометрию ограничивающего контура и информацию о близлежащих объектах, что позволяет уточнить изначально сгенерированные грубые ограничивающие контуры без потери эффективности. В данной работе построена пирамида сетей FPN [64] поверх сети ResNet50 с теми же параметрами алгоритма ATSS [42].

На основе алгоритма ATSS предложен метод PAA с новой стратегией назначения якорей [56] и с расширением таких опций, как отбор положительных обнаружений на основе их конкретной вероятности [132], статистика якорных метрик IoU [133] или оценка чистоты якорей [53; 62]. При назначении привязки (якоря) может учитываться гибкое количество положительных (или отрицательных) значений не только на основе метрики IoU, но и на основе вероятности того, что присвоение может быть подтверждено моделью. Другими словами, это означает, насколько алгоритм находит значимой привязку к целевому объекту (который может быть не с самой высокой IoU), чтобы назначить его в качестве положительного обнаружения. Таким образом, модель дает оценку, которая указывает как на классификационные, так и на локализационные качества. Оценки используются для определения вероятностного распределения положительных и отрицательных выборок, затем на основе положительных выборок назначение привязки превращается в задачу оценки максимального правдоподобия, где параметрами являются привязочные оценки. В данной работе построена пирамида сетей FPN поверх сети ResNet50 и использован метод PAA с архитектурой ATSS [42].

Продукт SABL [120] представляет оригинальный способ точного определения местоположения ограничивающего прямоугольника, основанный на аннотации, сделанной вручную. Этот подход основан на двухступенчатом детекторе. На первом этапе выполняется агрегация объектов интересующей области (RoI – Region of Interest) для получения дополнительных объектов. Второй этап включает в себя двухэтапную схему группирования. На первом этапе выполняется грубая оценка каждой границы по сегментам, а затем выполняется регресс для точной локализации. На втором этапе, начиная со второй ступени, вычисляется средняя достоверность оцененных групп, что также помогает скорректировать классификационные баллы и еще больше повысить производительность. Метод SABL применяется к одно- или двухэтапным системам. В данной работе построена пирамида сетей FPN поверх сети ResNet50 с помощью двухступенчатой сети Cascade-RCNN [42].




Рис. 12. Схема рабочего процесса предлагаемого метода [42]

Были сгенерированы участки размером 256×256 пикселей с использованием 49 изображений CBERS 04A WFI. Для обучения, валидации и тестирования было использовано в общей сложности 775 выборок (patches). Также были применены пятикратные повторности к процессу перекрестной проверки. На рис. 12 представлен обобщенный рабочий процесс предложенного метода. Методы компьютерного зрения, основанные на сверточных нейросетях, были разработаны с использованием таких эталонных баз данных, как ImageNet [27], PASCAL VOC [29] и MS COCO [63]. В обсуждаемой работе для процесса обучения была инициализирована основа всех методов обнаружения объектов с помощью предварительно подготовленных весов из базы данных ImageNet. Основой, используемой во всех моделях, была сеть ResNet-50. Применен оптимизатор стохастического градиентного спуска с импульсом, равным 0,9, и размером пакета, равным 2. Использован тестовый набор с целью настроить скорость обучения и количество периодов и снизить риск переобучения. Эмпирическим путем оценена скорость обучения (0,0001; 0,001 и 0,01) и было обнаружено, что сходимость функции потерь лучше при 0,001 и количестве эпох, равном 6. В процессе теста выбраны наиболее достоверные прогнозы с пороговым баллом, равным 0,5, а также применен метод немаксимального подавления (Non Max Suppression – NMS) (для уменьшения количества обнаружений с сильным перекрытием) с пороговым значением метрики IoU, равным 0,6. Таким образом, учитывая пять вариантов обучения, пять размеров ограничивающих рамок и шесть методов, было построено 150 моделей [42].

Предложенное приложение было разработано с использованием фреймворка (*framework – программная платформа, определяющая структуру программной системы*) MMDetection framework [21] на платформе Google Colaboratory. Процедуры обучения и тестирования проводились с использованием графического процессора Intel®a NVIDIA Tesla P100 PCIe, содержащего 80 ядер CUDA (Compute United Device Architecture) и 16 ГБ графической памяти [42].

Методы обнаружения объектов обычно оценивались на основе расстояния между ограничивающими рамками (прогнозируемое в сравнении с оценочным). Однако в данной работе результаты оценивались, основываясь на расстоянии между обозначенными и расчетными точками (центр расчетных ограничивающих рамок), поскольку внимание сосредотачивалось на положении активного пламени. Было принято пороговое значение расстояния для оценки истинно положительного (TP), ложно положительного (FP) и

ложноотрицательного (FN) значений, а также критериев «precision», «recall» и F1-score, формулы которых приведены в надписи к рис. 8. Центр прогнозируемых ограничивающих прямоугольников внутри радиуса покрытия от центра определения истинности (расстояние до которого меньше порогового значения) считается истинно положительным (TP), в противном случае – ложно положительным (FP). Стоит отметить, что предсказанный ограничивающий прямоугольник может принадлежать ко многим точкам истинно положительного определения (TP), поскольку его центр находится в пределах радиуса от центра определения истинности. Ложно отрицательное определение (FN) наблюдается, когда ограничивающий прямоугольник определения истинности не охватывает ни один из предсказанных ограничивающих прямоугольников. Варифокальная сеть (VarifocalNet) показала самый высокий средний балл F1-score, достигающий 0,81 при пороговом расстоянии, равном 20 пикселям (1100 м), а самые низкие значения F1-score дал адаптивный отбор обучающей выборки ATSS [42].

На рис. 13 показано изменение среднего показателя F1-score для каждого оцененного размера ограничивающей рамки, а точки представляют собой вычисленное значение для каждого метода ее построения. Видно, что объекты с ограничивающими рамками размером 10×10 пикселей дают наихудшие значения F1-score, что происходит из-за недостатка информации о дымовом шлейфе внутри этих крошечных рамок для обучения методам обнаружения.




Рис. 13. Изменение оценки F1-Score при увеличении ограничивающей рамки от 10 до 50 пикселей [42]

Наилучшие результаты достигаются при использовании рамок размером 30 и 40 пикселей с наибольшим средним значением F1-score, и эти значения стабилизируются между 30 и 50 пикселями. Когда

ограничивающие рамки увеличиваются более чем на 50 пикселей, перекрытие возрастает, и в процессе обучения учитывается больше нерелевантной информации вокруг дымовых шлейфов, что может запутать алгоритмы изучения интересующих объектов [42].

Для оценки качественных результатов была визуально проанализирована эффективность методов обнаружения дымовых шлейфов в различных условиях, таких как наличие небольших по площади дымовых шлейфов, круглых дымовых шлейфов, не подверженных распространению ветром (почти ортогональное рассеивание), дымовых шлейфов над тонким слоем облаков (что может вызвать путаницу в пиксельной характеристике), облаков в формате шлейфа, небольших плотных облаков и перекрывающихся шлейфов дыма от разных источников [42].

Положительные результаты всех методов варьируют от простого обнаружения с четкими границами дыма и хорошей контрастностью фона (рис. 14) до сложной идентификации при перекрывающемся покрытии дымом и облаками (рис. 15). Более того, по некоторым методам были выполнены очень сложные обнаружения возгораний при умеренном облачном покрытии и множественных дымовых шлейфах или даже такие обнаружения, которые могли вызвать сомнения у операторов-специалистов.

Таким образом, предложен метод глубокого обучения, основанный на обнаружении точек активных пожаров на спутниковых снимках водно-болотных угодий Бразилии. На изображениях базы данных CBERS 4A WFI были оценены шесть методов, в том числе широко используемые нейросети R-CNN и RetinaNet. Поскольку столбы дыма помечались точками вручную, были проведены обширные эксперименты, в результате которых было создано 150 моделей. Показано, что наилучшую способность обнаружения пожара обеспечивали ограничивающие рамки размером 30 и 40 пикселей и что самый высокий показатель F1-score показала варифокальная сеть (VarifocalNet), за которой следуют RetinaNet, SABL и R-CNN. Метод адаптивного отбора обучающей выборки (ATSS) показал наихудшую среднюю производительность.

Предложенный метод глубокого обучения, основанный на обнаружении дымовых шлейфов (или активных очагов возгорания) по данным дистанционного зондирования дает многообещающие результаты и может стать полезным дополнительным подходом к идентификации дымовых шлейфов по другим базам данных о лесных пожарах с более высоким пространственным разрешением [42].




Рис. 14. Простое обнаружение пожаров благодаря хорошему контрасту фона и границ дыма (красные кружки для определения истинности и зеленые кружки для прогнозирования) [42]




Рис. 15. Затрудненное обнаружение из-за наложения облаков и дыма (для определения истинности – красные кружки, для прогнозирования – зеленые кружки) [42]

АНСАМБЛЕВЫЙ МЕТОД ГЛУБОКОГО ОБУЧЕНИЯ ПРИ ОБНАРУЖЕНИИ ЛЕСНЫХ ПОЖАРОВ

Вследствие многообразия форм, текстур и цветов очагов возгорания традиционный метод обработки изображений в значительной степени основан на искусственных характеристиках, которые не всегда применимы ко всем лесным сценариям. Для решения этой проблемы применяется технология глубокого обучения, позволяющая адаптивно изучать и извлекать информацию о лесных пожарах. Однако возможности лишь отдельных обучающих блоков недостаточны для решения сложных задач. Кроме того, отдельный обучающий блок обычно настроен на регистрацию локальной информации, но не может самостоятельно обнаруживать пожары в различных сценариях и игнорирует глобальную информацию, что может привести к ложным оповещениям [128].

Поэтому интеграция различных обучающих блоков может значительно повысить надежность модели и эффективность обнаружения. В этой связи предложен новый метод обнаружения лесных пожаров, основанный на коллективном обучении [128], когда два отдельных детектора объектов YOLOv5 и EfficientDet [109] интегрированы для параллельного обнаружения пожара. Эти два обучающих блока работают синергетически при обнаружении различных типов лесных пожаров, тем самым повышая точность обнаружения. Детекторы объектов настроены на фиксацию только того, что похоже на пламя, и не учитывают все изображение целиком. В этом случае объекты, похожие на пламя, влияют на результаты обнаружения. Для решения этой проблемы в модель включен классификатор изображений EfficientNet [108], роль которого заключается в том, чтобы позволить модели в полной мере использовать преимущества глобальной информации. Окончательные результаты обнаружения выводятся с помощью стратегии принятия решений в соответствии с результатами обучающих блоков,

что значительно повышает точность обнаружения и уменьшает количество ложных оповещений [128].

Чтобы обучающие блоки могли справиться с различными видами лесных пожаров (наземными, пристовальными и верховыми), были собраны изображения из нескольких общедоступных наборов данных о пожарах: BowFire, FD-dataset, ForestryImages и VisiFire. После ручной фильтрации был создан единый интегрированный набор данных о лесных пожарах, содержащий 10581 изображение, в том числе 2976 изображений лесных пожаров и 7605 изображений, не связанных с пожарами [128]. Репрезентативные образцы итоговых наборов данных показаны на рис. 16–18.

YOLOv5 представляет современный детектор объектов, который работает в режиме реального времени и основан на предыдущих версиях YOLOv1–YOLOv4. Постоянные улучшения позволили достичь наилучших результатов в двух официальных наборах данных для обнаружения объектов: Pascal VOC [30] и Microsoft COCO [63]. Сетевая архитектура YOLOv5 показана на рис. 19. YOLOv5 выбран в качестве детектора объектов, поскольку включает в DarkNet межэтапную частную сеть (cross stage partial network – CSPNet) [122] и имеет CSPDarkNet в качестве его основы. Частная сеть CSPNet решает проблемы повторяющейся информации о градиенте в крупномасштабных системах и интегрирует изменения градиента в карту объектов, тем самым уменьшая параметры и количество модельных операций в секунду, что не только обеспечивает скорость и точность вывода, но и сокращает размер модели. В задаче обнаружения лесных пожаров скорость и точность обнаружения являются обязательными, а компактный размер модели определяет эффективность ее вывода на периферийных устройствах с ограниченными ресурсами, и это, во-первых. Во-вторых, в детекторе YOLOv5 применена сеть агрегации последовательностей (PANet) [119] в качестве средства ускорения потока информации.




Рис. 16. Репрезентативные изображения лесных пожаров, включающие:

а – наземный пожар-1; б – наземный пожар-2; в – горящий ствол; г – горящий лесной полог [128]




Рис. 17. Типичные изображения обычных насаждений в наборах данных без признаков пожара, включающие обычные лесные сцены (а–г) [128]




Рис. 18. Репрезентативные изображения (а–г) в наборах данных, не связанные с пожарами, но содержащие огнеподобный объект, например, изображение солнца [128]

Сеть PANet использует новую структуру функциональной пирамидальной сети (new feature pyramid network – FPN) с расширенным восходящим каналом, которая улучшает распространение низкоуровневых функций. В то же время адаптивное объединение объектов, которое связывает сетку объектов и все их уровни, используется для того, чтобы полезная информация на каждом уровне объектов передавалась непосредственно в следующую подсеть. PANet улучшает использование точных сигналов локализации в нижних слоях, что, очевидно, может повысить точность местоположения объекта.

Наконец, в-третьих, головка YOLOv5, а именно слой YOLO, генерирует три различных размера (18×18 , 36×36 , 72×72) карт объектов для достижения многомасштабного прогнозирования, позволяющего модели

обрабатывать малые, средние и крупные объекты. Лесной пожар обычно развивается от мелкомасштабного (наземного) до среднемасштабного (приствольного), и затем до крупномасштабного (верхового). Многомасштабное обнаружение позволяет модели отслеживать изменения размеров в процессе развития пожара [128].

Применено новое семейство детекторов объектов EfficientDet, разработанное Google, которое неизменно обеспечивает более высокую эффективность по сравнению с известным техническим уровнем при множественных ограничениях по ресурсам. Подобно YOLOv5, EfficientDet также обеспечивает получение замечательных результатов в задачах Pascal VOC и Microsoft COCO и широко используется в реальных приложениях [128]. Сетевая архитектура EfficientDet показана на

рис. 20. В семействе детекторов EfficientDet в качестве основы использована самая современная сеть EfficientNet [108], благодаря чему модель обладает достаточными возможностями для изучения многочисленных особенностей различных лесных пожаров. Кроме того, в качестве основы для простого и быстрого объединения многомасштабных объектов применена усовершенствованная технология PANet, получившая название «двунаправленная функциональная пирамидальная сеть» (bi-directional feature pyramid network – Bi-FPN). В сети Bi-FPN вводятся обучаемые значения весов, позволяющие сети изучать важность различных входных характеристик, и многократно применяется комбинирование многомасштабных характеристик в направлениях сверху-вниз и снизу-вверх. По сравне-

нию с PANet, сеть Bi-FPN обладает лучшими характеристиками при меньшем количестве параметров и сбоев. В то же время, различные стратегии объединения функций предоставляют различную семантическую информацию, что приводит к различным результатам обнаружения. Наконец, подобно EfficientNet, архитектура EfficientDet интегрирует метод комплексного масштабирования, который равномерно масштабирует разрешение, глубину и ширину одновременно для всех магистральных, функциональных сетей и сетей прогнозирования блоков/классов, что обеспечивает максимальную точность и эффективность при ограниченных вычислительных ресурсах. С увеличением количества доступных ресурсов точность будет постоянно повышаться [128].



Рис. 19. Сетевая архитектура YOLOv5, включающая три блока:

(1) – магистраль: CSPDarknet, (2) – горловина: PANet и (3) головка: Yolo Layer.

Данные сначала вводятся в CSPDarknet для извлечения объектов, а затем передаются в PANet для их объединения. Наконец, Yolo Layer выводит результаты обнаружения (класс, оценка, местоположение, размер). BottleNeck – узкое горлышко [128]




Рис. 20. Сетевая архитектура Efficient Det, включающая три блока:

(1) магистраль: EfficientNet, (2) горловина: Bi-FPN, (3) головка.

Как и в YOLOv5, данные сначала поступают в EfficientNet для извлечения признаков, а затем передаются в Bi-FPN для их объединения. Наконец, блок «головка» выводит результаты обнаружения (класс, оценка, местоположение, размер) [128]




Рис. 21. Сетевая архитектура EfficientNet



Рис. 22. Структура предлагаемой модели.

Три программы глубокого обучения работают параллельно. Два детектора объектов YOLOv5 и EfficientDet интегрированы для выполнения задачи обнаружения объектов, а классификатор EfficientNet отвечает за распознавание того, содержит ли изображение горящие элементы. Окончательные результаты выявления возгораний определяются на основе решений трех программ глубокого обучения [128]

Применена новая эффективная сеть EfficientNet, предложенная Google. Компания применила новую стратегию масштабирования модели, а именно метод комплексного масштабирования, с целью сбалансировать глубину сети, ее ширину и разрешение изображений для повышения точности при ограниченном бюджете ресурсов. Благодаря этому сеть EfficientNet в задаче классификации изображений ImageNet превзошла по точности другие популярные сети, такие как ResNet [41], DenseNet [44] и ResNext [127]. Сетевая архитектура EfficientNet показана на рис. 21. Сеть EfficientNet обеспечивает наилучшее соотношение между точностью и эффективностью в третьем модуле обучения, играющем наиболее важную роль. Она отвечает за изучение всего изображения в процессе обнаружения, а это означает, что его решения напрямую определяют конечные результаты. При этом она должна быть высокоэффективной, иначе это приведет к замедлению работы всей модели [128].

Программа может выводить карту объектов с глубокой семантической информацией после того, как входные данные пройдут через многоуровневую сеть [128].

В реальных задачах по обнаружению лесных пожаров приходится работать с различными их видами, такими как наземные (низовые), приствольные и верховые. Эти пожары различаются по форме, текстуре и даже цвету пламени, что создает большие трудности для отдельных обучаемых модулей при выделении эффективных признаков. Установлено, что YOLOv5 лучше распознает пожары на большой площади, но

иногда пропускает мелкие возгорания. Между тем, несмотря на то, что сеть EfficientDet не чувствительна к пожарам на большой площади, она может выполнять дополнительные функции обнаружения. Поэтому объединение усилий этих двух эффективных обучающих модулей с разными характеристиками для совместной работы по обнаружению повышает точность обнаружения [128].

Другая проблема заключается в том, что возможности детектора объектов ограничены. Он распознает только область пожара, которая является всего лишь локальным рисунком всего изображения, но игнорирует фон. В результате детектор может воспринимать огнеподобные объекты (например, изображение солнца), как пожары, что приводит к ложным оповещениям. Поэтому для управления процессом обнаружения необходима эффективная сеть, которая дает полное представление обо всем изображении.

Чтобы решить две вышеупомянутые проблемы и убедиться в том, что предлагаемая модель устойчива к различным сценариям, для совместного принятия решений были объединены три модуля глубокого обучения (three deep learners) (рис. 22). Первый и второй обучающие модули YOLOv5 и EfficientDet действуют как детекторы объектов, обнаруживая места возгорания на изображениях и генерируя соответствующие блоки. Затем применен алгоритм немаксимального подавления (non-maximum suppression algorithm) [75] для устранения избыточных блоков и сохранения блоков с максимальной степенью достоверности. Третий обучающий модуль сети EfficientNet

действует как бинарный классификатор, отвечающий за изучение всего изображения целиком с целью определить, содержит ли оно горящие объекты. Наконец, результаты обнаружения объектов и классификации изображений передаются в модуль стратегии принятия решений, в котором, результаты обнаружения объектов сохраняются, если считается, что изображение содержит пожароопасные объекты. В противном случае они игнорируются [128].

Модель оценена с использованием критериев Microsoft COCO, которые широко используются в задачах обнаружения объектов. Однако пламя – это особый объект, который отличается формой, текстурой и цветом. Ограничивающая рамка, генерируемая детекторами объектов, может незначительно отличаться от исходной, что влияет на расчет средней точности, но детекторы успешно определяют зоны возгорания. Поэтому для более всесторонней оценки моделей введены два дополнительных показателя, а именно, точность кадра (FA) и частота ложных срабатываний (FPR). Изображение, которое детектор пропускает как пожаро-подобный объект, относится к ложным кадрам (FF), в противном случае – к истинным кадрам (FT). Если детектор распознает какой-либо похожий на пламя объект как пожар, этот сигнал считается ложно положительным (FP), в противном случае – истинно положительным (TP). При этом FA рассчитывается на тестовом наборе, содержащем 476 лесных изображений, а FPR рассчитывается на наборе данных, не связанных с пожарами, содержащем 641 изображение с объектами, похожими на пламя (например, изображение солнца). FA и FPR могут быть рассчитаны как формулы (6) и (7) соответственно:

$$FA = \frac{FT}{FT + FF} \times 100, \quad (6)$$

$$FPR = \frac{FP}{FP + TP} \times 100. \quad (7)$$

Для трех блоков: YOLOv5, EfficientDet и EfficientNet были применены различные стратегии обучения. Детекторы объектов YOLOv5 и EfficientDet были обучены на 2381 изображении лесных пожаров и протестированы на 476 их изображениях. Классификатор изображений EfficientNet обучен на 2381 изображении лесных пожаров и 5804 изображениях, не связанных с пожарами, и протестирован на 476 изображениях лесных пожаров и 1160 изображениях, не связанных с пожарами. При этом изображения без пламени содержали обычные изображения и изображения с объектами, похожими на пламя (изображение солнца). Каждая модель создана с помощью Pytorch и обучена на NVIDIA GTX 2080TI [84].

Предложенная модель сопоставлена с типичными одноступенчатыми детекторами объектов. Несмотря на то, что YOLOv5 и EfficientDet являются наиболее мощными детекторами в этой задаче, нельзя игнорировать высокую частоту ложных срабатываний и пропусков обнаружения. Благодаря их интеграции в два обучающих блока все показатели оценки значительно улучшились, но процент ложных срабатываний уве-

личился до 51,6 %, поскольку ложные срабатывания поступают как от YOLOv5, так и от EfficientDet. Под влиянием третьего блока EfficientNet частота ложных срабатываний снижена до 0,3 %. После введения третьего блока некоторые показатели адекватности несколько снизились, поскольку блок EfficientNet ошибочно обрабатывает некоторые изображения пламени как не связанные с пожаром, а затем игнорирует результаты обнаружения объекта. Предполагается, что стоит пожертвовать небольшим снижением средней точности ради существенного снижения частоты ложных срабатываний. Таким образом, предложенная модель с тремя обучающими блоками превосходит другие типичные детекторы объектов по параметрам адекватности. Комплексные усовершенствования повышают производительность модели при обнаружении различных типов лесных пожаров: небольших пожаров, пожаров среднего масштаба, крупномасштабных, наземных, пристовольных, верховых пожаров, а также ночных возгораний [128].

По сравнению с возгораниями неподвижных объектов, лесной пожар является динамичным объектом [70]. Различные формы, размеры, текстуры и цвета лесных пожаров делают развитие пожара сложным процессом и создают большие трудности при его обнаружении. Поэтому важно, чтобы детекторы были чувствительны к различным видам пожаров. После проведенных экспериментов сделан вывод, что ни один детектор не может справиться со всеми видами пожаров, имея соответствующие преимущества и недостатки. Детектор YOLOv5 отлично справляется с обнаружением пожаров на большой площади, но часто пропускает небольшие возгорания. EfficientDet – это более точный детектор по сравнению с YOLOv5; несмотря на то, что он плохо справляется с пожарами на большой площади, он может обнаруживать пожары, которые не удастся обнаружить блоку YOLOv5, а это означает, что он является хорошим «партнером» для последнего. Предложенная модель, эффективно объединяя решения этих двух мощных блоков, повышает эффективность обнаружения на 2,5–10,9 %. Значительное повышение средней точности и среднего быстродействия для малых, средних и крупных пожаров делает модель более чувствительной к изменениям размера очагов возгорания, тем самым повышая эффективность обнаружения различных типов лесных пожаров [128].

Другая проблема заключается в том, что частота ложных срабатываний улучшенной модели (с двумя обучающими блоками) становится выше: с 22,6 % до 51,6 %, поскольку модель объединяет и результаты ложных обнаружений каждого в отдельности. Для решения проблемы использованы 8185 выборки, содержащих 2381 изображение лесного пожара, и 5804 изображения, не связанные с пожаром (содержащие изображения, похожие на огонь, и изображения обычного леса), для обучения третьего блока EfficientNet. Достаточное количество обучающих наборов позволило блоку EfficientNet продемонстрировать хорошую способность различать горящие и пламя-подобные объекты с точностью 99,6 % на 476 изображениях пожаров и с точностью 99,7 % на 676 пламя-

подобных изображениях. С помощью лидирующего блока EfficientNet устранены ложные результаты обнаружения, а частота ложноположительных результатов снижена до 0,3 %. Примечательно, что объединение с EfficientNet снижает показатели адекватности примерно на 1 %, что связано с тем, что блок EfficientNet ошибочно игнорирует два изображения, содержащих среднemasштабные и крупномасштабные объекты пожара [128].

В отношении времени задержки блоки Yolo превосходят EfficientDet и SSD. Благодаря превосходной скорости логического вывода блоки Yolo широко используются в реальных приложениях, но результаты экспериментов показывают, что они не способны обеспечить удовлетворительную производительность в задачах обнаружения лесных пожаров. Задержка блока EfficientDet составляет 65,6 мс, что более чем вдвое больше, чем у YoloV5 (28,0 мс), но EfficientDet превосходит YoloV5 более чем на 5 % по быстродействию обнаружения. Эти три функции YoloV5 (28,0 мс), EfficientDet (65,6 мс) и EfficientNet (31,3 мс) были объединены параллельно, чтобы убедиться, что предложенная модель может достичь наилучшей производительности без каких-либо дополнительных задержек. Конечная задержка модели (по совокупности трех обучающих блоков) составляет 66,8 мс, что показывает, что был достигнут компромисс между производительностью обнаружения и эффективностью, и что модель применима для решения задач обнаружения пожаров в режиме реального времени. Результаты экспериментов показали, что по сравнению с другими популярными детекторами объектов предложенная модель обеспечивает наилучшее соотношение между средней точностью, средним откликом, частотой ложных срабатываний, точностью кадра и задержкой. Значительные улучшения позволяют модели эффективно работать в реальных лесных условиях [128].

ЗАКЛЮЧЕНИЕ

В связи с изменением климата по всему миру учащаются лесные пожары, которые не только наносят серьезный экономический ущерб и разрушают экологическую среду, но и представляют большую угрозу жизни людей. Обнаружение пожаров на ранних стадиях является эффективным способом минимизировать причиняемый ими ущерб. Современные разработки в области глубокого машинного обучения предоставляют новые возможности обнаружения лесных пожаров. В обзоре показано современное состояние проблемы глубокого обучения путем краткого перечня публикаций последних лет, а также дано более детальное описание алгоритмов глубокого обучения на примере некоторых продвинутых исследований. В частности, показаны возможности обнаружения лесных пожаров с помощью нейросетей и цифровой колориметрии, описана интеллектуальная модель глубокого обучения при обнаружении лесных пожаров с помощью встроенных датчиков, даны алгоритм обнаружения лесных пожаров с беспилотных летательных аппаратов и с использованием спутниковых систем дистанционного зондирования, описан ансамблевый метод глубокого обучения при обнаружении лесных пожаров.

Авторы благодарят Николая Ивановича Плюху за техническую помощь при подготовке статьи.

The authors would like to thank Nikolai Ivanovich Plyukha for his technical assistance in preparing the article.

БИБЛИОГРАФИЧЕСКИЕ ССЫЛКИ

1. Almasoud A. S. Intelligent deep learning enabled wild forest fire detection system // *Computer Systems Science & Engineering*. 2023. Vol. 44 (2). P. 1485–1498.
2. Angayarkkani K., Radhakrishnan N. Efficient forest fire detection system: A spatial data mining and image processing based approach // *International Journal of Computer Science and Network Security*. 2009. Vol. 9 (3). P. 100–107.
3. Angayarkkani K., Radhakrishnan N. An intelligent system for effective forest fire detection using spatial data // *International Journal of Computer Science and Information Security*. 2010. Vol. 7(1). P. 202–208.
4. Aslan S., Gudukbay U., Toreyin B. U. et al. Early wildfire smoke detection based on motion-based geometric image transformation and deep convolutional generative adversarial networks // *IEEE International Conference on Acoustics, Speech and Signal Processing. Proceedings*, 2019. P. 8315–8319.
5. Azami M. H., Orger N. C., Schulz V. H. et al. Earth observation mission of a 6U CubeSat with a 5-meter resolution for wildfire image classification using convolution neural network approach // *Remote Sensing*. 2022. Vol. 14. Article 1874.
6. Ba R., Chen C., Yuan J. et al. SmokeNet: Satellite smoke scene detection using convolutional neural network with spatial and channel-wise attention // *Remote Sensing*. 2019. Vol. 11. Article 1702.
7. Bahrepour M., Meratnia N., Havinga P. J. M. Sensor fusion-based event detection in wireless sensor networks // *6th Annual International Conference: Mobile and Ubiquitous Systems: Networking & Services, MobiQuitous*, 2009. P. 1–8.
8. Bahrepour M., Meratnia N., Poel M. et al. Distributed event detection in wireless sensor networks for disaster management // *International Conference on Intelligent Networking and Collaborative Systems*, 2010. P. 507–512.
9. Barmpoutis P., Papaioannou P., Dimitropoulos K. et al. A review on early forest fire detection systems using optical remote sensing // *Sensors*. 2020. Vol. 20 (22). Article 6442.
10. Bolourchi P., Uysal S. Forest fire detection in wireless sensor network using fuzzy logic // *Fifth International Conference on Computational Intelligence, Communication Systems and Networks, IEEE*, 2013. P. 83–87.
11. Borowiec M. L., Dikow R. B., Frandsen P. B. et al. Deep learning as a tool for ecology and evolution // *Methods in Ecology and Evolution*. 2022. Vol. 13 (8). P. 1640–1660.
12. Broomhead D. S., Lowe D. Multivariate functional interpolation and adaptive networks // *Complex Systems*. 1988. Vol. 2. P. 321–355.
13. Byun Y. G., Huh Y., Yu K. et al. Evaluation of graph-based analysis for forest fire detections //

Proceedings of World Academy of Science, Engineering and Technology. 2007. Vol. 10. P. 617–622.

14. Canonizado J. A. Simulation of selective forest management regimes // *The Malaysian Forester*. 1978. Vol. 41 (2). P. 128–142.

15. Çelik T., Özkaramanlı H., Demirel H. Fire and smoke detection without sensors: Image processing based approach // *Proceedings of the IEEE 15th European Signal Processing Conference (EUSIPCO 2007)*, Poznan, Poland, 2007. P. 1794–1798.

16. Chaitanya P. S., Reddy K. V. N., Madhavi G. Effective search of color-spatial image using semantic indexing // *International Journal of Computer Science, Engineering and Applications*. 2012. Vol. 2. P. 9–19.

17. Chasovskikh V. P., Usoltsev V. A., Koch E. V. Natural and artificial intelligence as a tool for data transformation: monograph. Yekaterinburg: USUE, 2025. 352 p. (In Russian). (https://elar.usfeu.ru/bitstream/123456789/14231/1/Chasovskikh_25.pdf).

18. Chen T. H., Wu P. H., Chiou Y. C. An early fire-detection method based on image processing // *Proceedings of the IEEE International Conference on Image Processing (ICIP 2004)*, Singapore, 2004. P. 1707–1710.

19. Chen R., Luo Y., Alsharif M. R. Forest fire detection algorithm based on digital image // *Journal of Visual Communication and Image Representation*. 2013. Vol. 18 (2). P. 176–185.

20. Chen Y., Zhang Y., Xin J. et al. A UAV-based forest fire detection algorithm using convolutional neural network // *Proceedings of the 2018 37th Chinese Control Conference (CCC)*, Wuhan, China, 25–27 July 2018; IEEE: Piscataway, NJ, USA, 2018. P. 10305–10310.

21. Chen K., Wang J., Pang J. et al. MMDetection: Open MMLab detection toolbox and benchmark // *arXiv*, 2019. Article 1906.07155.

22. Chen H., Zhang Q., Luo J. et al. An enhanced bacterial foraging optimization and its application for training kernel extreme learning machine // *Applied Soft Computing*. 2020. Vol. 86 (11). Article 105884.

23. Chen Y., Fang R., Liang T. et al. Stock price forecast based on CNN-BiLSTM-ECA model // *Scientific Programming*. 2021. Vol. 2021 (1). P. 1–20.

24. Chino D. Y., Avalhais L. P., Rodrigues J. F. et al. BowFire: Detection of fire in still images by integrating pixel color and texture analysis // *Proceedings of the 28th SIBGRAPI Conference on Graphics, Patterns and Images*. Salvador, Brazil, 26–29 August, 2015. P. 95–102.

25. Chopde A., Magon A., Bhatkar S. Forest fire detection and prediction from image processing using RCNN // *Proceedings of the 7th World Congress on Civil, Structural, and Environmental Engineering*, 2022. P. 10–12.

26. Dai J., Qi H., Xiong Y. et al. Deformable convolutional networks // *Proceedings of the IEEE International Conference on Computer Vision*, Venice, Italy, 22–29 October, 2017. P. 764–773.

27. Deng J., Dong W., Socher R. et al. ImageNet: A large-scale hierarchical image database // *Proceedings of the 2009 IEEE Conference on Computer Vision and Pattern Recognition*, Miami, FL, USA, 20–25 June 2009; IEEE: Piscataway, NJ, USA, 2009. P. 248–255.

28. Duda R. O., Hart P. E. Pattern classification and scene analysis. New York: John Wiley & Sons, 1973. 482 p.

29. Everingham M., Van Gool L., Williams C. K. et al. The pascal visual object classes (voc) challenge // *International Journal of Computer Vision*. 2010. Vol. 88. P. 303–338.

30. Everingham M., Eslami S. A., Van Gool L. et al. The pascal visual object classes challenge: A retrospective // *International Journal of Computer Vision*. 2015. Vol. 111. P. 98–136.

31. Fayyad U. M., Piatetsky-Shapiro G., Smyth P. From data mining to knowledge discovery: An overview // *Advances in Knowledge Discovery and Data Mining*. Menlo Park: AAAI Press, 1996. P. 1–34.

32. Fernandes A. M., Utkin A. B., Lavrov A. V. et al. Development of neural network committee machines for automatic forest fire detection using lidar // *Pattern Recognition*. 2004. Vol. 37. P. 2039–2047.

33. Filonenko A., Kurnianggoro L., Jo K. H. Smoke detection on video sequences using convolutional and recurrent neural networks // *Proceedings of the Computational Collective Intelligence (ICCCI 2017)*, Nicosia, Cyprus, 27–29 September, 2017. P. 558–566.

34. Ghali R., Akhloufi M. A. Deep learning approaches for wildland fires using satellite remote sensing data: Detection, mapping, and prediction // *Fire*. 2023. Vol. 6. Article 192.

35. Giglio L., Descloitres J., Justice C. O. et al. An enhanced contextual fire detection algorithm for MODIS // *Remote Sensing of Environment*. 2003. Vol. 87. P. 273–282.

36. Giglio L., Schroeder W., Justice C. O. The collection 6 MODIS active fire detection algorithm and fire products // *Remote Sensing of Environment*. 2016. Vol. 178. P. 31–41.

37. González J. R., Palahí M., Trasobares A. et al. A fire probability model for forest stands in Catalonia (north-east Spain) // *Annals of Forest Science*. 2006. Vol. 63. P. 169–176.

38. Goulding C. J. Validation of growth models used in forest management // *New Zealand Journal of Forestry*. 1979. Vol. 24 (1). P. 108–124.

39. Goutte C., Gaussier E. A probabilistic interpretation of precision, recall and F-score, with implication for evaluation // *Advances in Information Retrieval*. 2005. Vol. 3408. P. 345–359.

40. Gupta T., Liu H., Bhanu B. Early wildfire smoke detection in videos // *25th International Conference on Pattern Recognition*. Milan, Italy, January 10–15, 2021. P. 8523–8530.

41. He K., Zhang X., Ren S. et al. Deep residual learning for image recognition // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2016)*, Las Vegas, NV, USA, 26 June–1 July, 2016. P. 770–778.

42. Higa L., Marcato J. Jr., Rodrigues T. et al. Active fire mapping on Brazilian Pantanal based on deep learning and CBERS 04A imagery // *Remote Sensing*. 2022. Vol. 14. Article 688.

43. Hong Z., Tang Z., Pan H. et al. Active fire detection using a novel convolutional neural network

based on Himawari-8 satellite images // *Frontiers in Environmental Science*. 2022. Vol. 10. Article 102.

44. Huang G., Liu Z., Van Der Maaten L. et al. Densely connected convolutional networks // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2017)*, Honolulu, Hawaii, 21–26 July, 2017. P. 4700–4708.

45. Ivanova N., Ivanova S., Ivanchikov S. et al. Evaluating the effectiveness of Google Scholar, ScienceDirect, Mendeley, and eLibrary for interdisciplinary research // *South-East European Forestry*. 2025. Vol. 16(2). P. 227–238.

46. Jiao Z., Zhang Y., Xin J. et al. A deep learning based forest fire detection approach using UAV and YOLOv3 // *Proceedings of the 2019 1st International Conference on Industrial Artificial Intelligence (IAI)*, Shenyang, China, 22–26 July 2019; IEEE: Piscataway, NJ, USA, 2019. P. 1–5.

47. Jiao Z., Zhang Y., Mu L. et al. A YOLOv3-based learning strategy for real-time UAV-based forest fire detection // *2020 Chinese Control and Decision Conference (CCDC)*, Hefei, China, 2020. P. 4963–4967.

48. Kaabi R., Sayadi M., Bouchouicha M. et al. Early smoke detection of forest wildfire video using deep belief network // *4th International Conference on Advanced Technologies For Signal and Image Processing*, Sousse, Tunisia, March 21–24, 2018. P. 1–6.

49. Kalaivani V., Chanthiya P. A novel custom optimized convolutional neural network for a satellite image by using forest fire detection // *Earth Science Informatics*. 2022. Vol. 15. P. 1285–1295.

50. Kang D., Kim E., Moon P. et al. Design and analysis of flame signal detection with the combination of UV/IR sensors // *Journal of the Korea Society of Computer and Information*. 2013. Vol. 14. P. 45–51.

51. Kang Y., Jang E., Im J. et al. A deep learning model using geostationary satellite data for forest fire detection with reduced detection latency // *GIScience & Remote Sensing*. 2022. Vol. 59. P. 2019–2035.

52. Kansal A., Singh Y., Kumar N. et al. Detection of forest fires using machine learning technique: A Perspective // *Third International Conference on Image Information Processing*, Wagnaghat, India, 21–24 December, 2015. P. 241–246.

53. Ke W., Zhang T., Huang Z. et al. Multiple anchor learning for visual object detection // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Seattle, WA, USA, 14–19 June, 2020. P. 10206–10215.

54. Kilaru S. Analytical models for collaborative autonomous mobile robot solutions in fulfillment centers // *Applied Mathematical Modelling*. 2021. Vol. 91. P. 438–457.

55. Kim B., Lee J. A video-based fire detection using deep learning models // *Applied Science*. 2019. Vol. 9. Article 2862.

56. Kim K., Lee H. S. Probabilistic anchor assignment with iou prediction for object detection // *Proceedings of the Computer Vision–ECCV 2020: 16th European Conference*, Glasgow, UK, 23–28 August 2020; *Proceedings, Part XXV 16*; Springer: Berlin/Heidelberg, Germany, 2020. P. 355–371.

57. Kinaneva D., Hristov G., Raychev J. et al. Early forest fire detection using drones and artificial intelligence // *2019 42nd International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*, Opatija, Croatia, 2019. P. 1060–1065.

58. Kumari P. L., Abid Z., Jamberi K. et al. Robust forest fire detection using deep convolutional neural networks // *International Journal of Scientific Methods in Computational Science and Engineering*. 2024. Vol. 1(1). P. 49–57.

59. Lafarge F., Descombes X., Zerubia J. Forest fire detection based on Gaussian field analysis // *Proceedings of European Signal Processing Conference (EUSIPCO)*, Poznan, Poland, September, 2007. P. 447–451.

60. Lee W., Kim S., Lee Y. T. et al. Deep neural networks for wild fire detection with unmanned aerial vehicle // *Proceedings of the 2017 IEEE international conference on consumer electronics (ICCE)*, Taipei, Taiwan, 12–14 June 2017; IEEE: Piscataway, NJ, USA, 2017. P. 252–253.

61. Lee Y., Shim J. False positive decremented research for fire and smoke detection in surveillance camera using spatial and temporal features based on deep learning // *Electronics*. 2019. Vol. 8. Article 1167.

62. Li H., Wu Z., Zhu C. et al. Learning from noisy anchors for one-stage object detection // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Seattle, WA, USA, 14–19 June, 2020. P. 10588–10597.

63. Lin T.Y., Maire M., Belongie S. et al. Microsoft COCO: Common objects in context // *Proceedings of the European Conference on Computer Vision*, Zurich, Switzerland, 6–12 September 2014; Springer: Berlin/Heidelberg, Germany, 2014. P. 740–755.

64. Lin T.Y., Dollár P., Girshick R. et al. Feature pyramid networks for object detection // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, HI, USA, 21–26 July, 2017a. P. 2117–2125.

65. Lin T.Y., Goyal P., Girshick R. et al. Focal loss for dense object detection // *Proceedings of the IEEE International Conference on Computer Vision*, Venice, Italy, 22–29 October, 2017b. P. 2980–2988.

66. Liu W., Anguelov D., Erhan D. et al. SSD: Single shot multibox detector // *Proceedings of the European Conference on Computer Vision (ECCV 2016)*, Amsterdam, The Netherlands, 8–16 October, 2016. P. 21–37.

67. Liu Y., Shao Z., Hoffmann N. Global attention mechanism: Retain information to enhance channel-spatial interactions // *ArXiv*, 2021. Article 2112.05561.

68. Maiellaro P. A., Cozzolongo R., Marino P. Artificial neural networks for the prediction of response to interferon plus ribavirin treatment in patients with chronic hepatitis C // *Current Pharmaceutical Design*. 2004. Vol. 10 (17). P. 2101–2109.

69. Mao W., Wang W., Dou Z. et al. Fire recognition based on multi-channel convolutional neural network // *Fire Technology*. 2018. Vol. 54 (2). P. 531–554.

70. Merino L., Caballero F., Martínez-de-Dios J. R. et al. An unmanned aircraft system for automatic forest fire

monitoring and measurement // *Journal of Intelligent and Robotic Systems*. 2012. Vol. 65. P. 533–548.

71. Mittal A., Sharma G., Aggarwal R. Forest fire detection through various machine learning techniques using mobile agent in WSN // *International Research Journal of Engineering and Technology*. 2016. Vol. 3 (6). P. 702–706.

72. Mohindru P., Khanna V., Singh R. Forest fire detection: Various approaches // *International Journal of Emerging Science and Engineering*. 2013. Vol. 1 (6). P. 68–70.

73. Moody J., Darken C. J. Fast learning in networks of locally tuned processing units // *Neural Computation*. 1989. Vol. 1 (2). P. 281–294.

74. Naresh, Himasri B., Sowmya N. et al. Forest fire detection using convolutional neural networks // *International Journal of Emerging Technologies and Innovative Research*. 2024. Vol. 11 (10). P. 9–16.

75. Neubeck A., Van Gool L. Efficient non-maximum suppression // *Proceedings of the 18th International Conference on Pattern Recognition (ICPR 2006)*, Hong Kong, China, 20–24 August, 2006. P. 850–855.

76. Oladimeji M. O., Turkey M., Ghavami M. et al. A new approach for event detection using k-means clustering and neural networks // *International Joint Conference on Neural Networks (IJCNN)*, 2015. P. 1–5.

77. Ollero A., Martinez de Dios J. R., Arrue B. C. Integrated systems for early forest-fire detection // *III International Conference on Forest Fire Research, 14th Conference on Fire and Forest Meteorology*. Vol. 2. Luso, 16/20 November, 1998. P. 1977–1988.

78. Pan H., Badawi D., Cetin A. E. Computationally efficient wildfire detection method using a deep convolutional network pruned via Fourier analysis // *Sensors*. 2020a. Vol. 20. Article 2891.

79. Pan H., Badawi D., Zhang X. et al. Additive neural network for forest fire detection // *Signal Image and Video Processing*. 2020b. Vol. 14 (4). P. 675–682.

80. Pande V., Elmannai W., Elleithy K. Optimized algorithm for fire detection over WSN using Micaz motes // *25th international conference on computers and their applications in industry and engineering (CAINE-2012)*, New Orleans, Louisiana, USA, 2012. P. 1–6.

81. Pande V., Elmannai W., Elleithy K. Classification and detection of fire on WSN using IMB400 multimedia sensor board // *IEEE Long Island Systems, Applications and Technology Conference*. Farmingdale State College, State University of New York, 2013. P. 1–6.

82. Pandita A., Upadhyay P. K. Reducing energy consumption of nodes using force based auto deployment of wireless sensor networks // *International Conference and Workshop on Computing and Communication (IEMCON)*, 2015. P. 1–7.

83. Passino K. M. Biomimicry of bacterial foraging for distributed optimization and control // *IEEE Control Systems Magazine*. 2002. Vol. 22 (3). P. 52–67.

84. Paszke A., Gross S., Massa F. et al. Pytorch: An imperative style, high-performance deep learning library // *Proceedings of the Neural Information Processing Systems (NIPS 2019)*, Vancouver, BC, Canada, 8–14 December, 2019. P. 8026–8037.

85. Pavani V., Lakshmi S. K., Vyshnavi P. A. et al. Students community portal using machine learning // *IEEE Second International Conference on Electronics and Renewable Systems (ICEARS)*. Tuticorin, India, 2023. P. 1109–1113.

86. Poggio T., Girosi F. Regularization algorithms for learning that are equivalent to multilayer networks // *Science*. 1990. Vol. 247. P. 978–982.

87. Priya R. S., Vani K. Deep learning based forest fire classification and detection in satellite images // *Proceedings of the 11th International Conference on Advanced Computing*, 2019. P. 61–65.

88. Rauste Y. Forest fire detection with satellites for forest fire control // *Proceedings of the XVIII Congress of the International Society for Photogrammetry and Remote Sensing*. 1996. Vol. 31 (B7). P. 584–588.

89. Rawat W., Wang Z. Deep convolutional neural networks for image classification: a comprehensive review // *Neural Computation*. 2017. Vol. 29 (9). P. 2352–2449.

90. Reis H. C., Turk V. Detection of forest fire using deep convolutional neural networks with transfer learning approach // *Applied Soft Computing*. 2023. Vol. 143. Article 110362.

91. Ren S., He K., Girshick R. et al. Faster R-CNN: Towards real-time object detection with region proposal networks // *Advances in Neural Information Processing Systems*. 2015. Vol. 28. P. 91–99.

92. Ren S., He K., Girshick R. et al. Faster R-CNN: Towards real-time object detection with region proposal networks // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2016. Vol. 39. P. 1137–1149.

93. Sahin Y. G. Animals as mobile biological sensors for forest fire detection // *Sensors*. 2007. Vol. 7. P. 3084–3099.

94. Sapiro G. Chromaticity diffusion // *Proceedings of International Conference on Image Processing 2000*. Vol. 2. Vancouver, BC, Canada, 2000. P. 784–787.

95. Sathik M. M., Mohamed M. S., Balasubramanian A. Fire detection using support vector machine in wireless sensor network and rescue using pervasive devices // *International Journal of Advanced Networking and Applications*. 2010. Vol. 2 (2). P. 636–639.

96. Sathya K., Rajalakshmi M. RDA-CNN: Enhanced super resolution method for rice plant disease classification // *Computer Systems Science and Engineering*. 2022. Vol. 42(1). P. 33–47.

97. Schneider T. W., Alder D. Die Behandlung von Kiefernbeständen in Nordwestdeutschland anhand eines systemorientierten Simulationsmodells // *Forstarchiv*. 1979. No. 9. P. 184–195; No. 10. P. 220–223.

98. Sekkas O., Hadjieftymiades S., Zervas E. A multi-level data fusion approach for early fire detection // *2nd International Conference on Intelligent Networking and Collaborative Systems, INCoS 2010*, Thessaloniki, Greece, 24–26 November, 2010. P. 1–5.

99. Seydi S. T., Saeidi V., Kalantar B. et al. Fire-Net: A deep learning framework for active forest fire detection // *Remote Sensing*. 2022. Vol. 14 (9). Article 2214.

100. Shanmuganathan S. From data mining and knowledge discovery to big data analytics and knowledge

extraction for applications in science // *Journal of Computer Science*. 2014. Vol. 10 (12). P. 2658–2665.

101. Shekhar S., Zhang P., Huang Y. et al. Trends in spatial data mining. In: Kargupta H., Joshi A. (eds.). *Data Mining: Next Generation Challenges and Future Directions*. AAAI/MIT Press, 2003. P. 357–380.

102. Sirisha A., Chaitanya K., Sesha K. V. et al. Intrusion detection models using supervised and unsupervised algorithms – A comparative estimation // *International Journal of Safety and Security Engineering*. 2021. Vol. 11(18). P. 51–58.

103. Smith T., Guild J. The C.I.E. colorimetric standards and their use // *Transactions of the Optical Society*. 1931. Vol. 33 (3). P. 73–134.

104. Sokolova M., Japkowicz N., Szpakowicz S. Beyond accuracy, F-score and ROC: A family of discriminant measures for performance evaluation, AI 2006. In: A. Sattar, B.-H. Kang (eds.). *Advances in Artificial Intelligence*. Berlin, Heidelberg: Springer, 2006. P. 1015–1021.

105. Solomon A. M., Delcourt H. R., West D. C. et al. Testing a simulation model for reconstruction of prehistoric forest-stand dynamics // *Quaternary Research*. 1980. Vol. 14 (3). P. 275–293.

106. Stojanova D., Panov P., Kobler A. et al. Learning to predict forest fires with different data mining techniques // *Conference on Data Mining and Data Warehouses (SiKDD 2006)*, Ljubljana, Slovenia, 2006. P. 255–258.

107. Tadesse T., Brown J. F., Hayes M. J. A new approach for predicting drought-related vegetation stress: Integrating satellite, climate, and biophysical data over the U.S. central plains. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2005. Vol. 59 (4). P. 244–253.

108. Tan M., Le Q. EfficientNet: Rethinking model scaling for convolutional neural networks // *Proceedings of the International Conference on Machine Learning (ICML 2019)*, Long Beach, CA, USA, 9–15 June, 2019. P. 6105–6114.

109. Tan M., Pang R., Le Q. V. EfficientDet: Scalable and efficient object detection // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2020)*, Washington, DC, USA, 14–19 June, 2020. P. 10781–10790.

110. Tay S. C., Hsu W., Lim K. H. Spatial data mining: Clustering of hot spots and pattern recognition // *Proceedings. 2003 IEEE International Geoscience and Remote Sensing Symposium*. Vol. 6, 2003. P. 3685–3687.

111. Teng Z., Kim J. H., Kang D. J. Fire detection based on hidden Markov models // *International Journal of Control, Automation and Systems*. 2010. Vol. 8. P. 822–830.

112. Tian Z., Shen C., Chen H. et al. Fcos: Fully convolutional one-stage object detection // *Proceedings of the IEEE/CVF International Conference on Computer Vision*, Seoul, Korea, 27–28 October, 2019. P. 9627–9636.

113. Toledo-Castro J., Caballero-Gil P., Rodríguez-Pérez N. et al. Forest fire prevention, detection, and fighting based on fuzzy logic and wireless sensor networks // *Hindawi Complexity*. 2018. Vol. 1. Article ID1639715.

114. Töreyn B. U., Dedeoglu Y., Güdükbay U. et al. Computer vision based method for real-time fire and flame detection // *Pattern Recognition Letters*. 2006. Vol. 27. P. 49–58.

115. Tou J. T., Gonzalez R. C. *Pattern recognition principles*. Reading, MA: Addison-Wesley Publishing Company, 1974. 377 p.

116. Trivedi K., Srivastava A. K. An energy efficient framework for detection and monitoring of forest fire using mobile agent in wireless sensor networks // *IEEE International Conference on Computational Intelligence and Computing Research*, 2014. P. 393–422.

117. Vani K. Deep learning based forest fire classification and detection in satellite images // *Proceedings of the 2019 11th International Conference on Advanced Computing (ICoAC)*, Chennai, India, 8–20 December 2019; IEEE: Piscataway, NJ, USA, 2019. P. 61–65.

118. Venkateswaran N., Umadevi K. Hybridized wrapper filter using deep neural network for intrusion detection // *Computer Systems Science and Engineering*. 2022. Vol. 42 (1). P. 1–14.

119. Wang K., Liew J. H., Zou Y. et al. PANet: Few-shot image semantic segmentation with prototype alignment // *Proceedings of the IEEE International Conference on Computer Vision (ICCV 2019)*, Seoul, Korea, 20–26 October, 2019. P. 9197–9206.

120. Wang J., Zhang W., Cao Y. et al. Side-aware boundary localization for more precise object detection // *Proceedings of the European Conference on Computer Vision*, Glasgow, UK, 23–28 August 2020; Springer: Berlin/Heidelberg, Germany, 2020a. P. 403–419.

121. Wang Y., Liu X., Li M. et al. Deep convolution and correlated manifold embedded distribution alignment for forest fire smoke prediction // *Computing and Informatics*. 2020b. Vol. 39. P. 318–339.

122. Wang C. Y., Mark Liao H. Y., Wu Y. H. et al. CSPNet: A new backbone that can enhance learning capability of CNN // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2020)*, Washington, DC, USA, 14–19 June, 2020c. P. 390–391.

123. Wang G., Li J., Zheng Y. et al. Forest smoke detection based on deep learning and background modeling // *IEEE International Conference on Power, Intelligent Computing and Systems*. 2020d. P. 112–116.

124. Wei X., Wu S., Wang Y. Forest fire smoke detection model based on deep convolution long short-term memory network // *Journal of Computer Applications*. 2019. Vol. 39. P. 2883–2887.

125. Wu S., Zhang L. Using popular object detection methods for real time forest fire detection // *Proceedings of the 11th International Symposium on Computational Intelligence and Design (ISCID 2018)*, Hangzhou, China, 8–9 December, 2018. P. 280–284.

126. Wu S., Guo C., Yang J. Using PCA and one-stage detectors for real-time forest fire detection // *Journal of Engineering*. 2020. Vol. 2020. P. 383–387.

127. Xie S., Girshick R., Dollár P. et al. Aggregated residual transformations for deep neural networks // *Proceedings of the IEEE Conference on Computer Vision*

and Pattern Recognition (CVPR 2016), Las Vegas, NV, USA, 26 June–1 July, 2016. P. 1492–1500.

128. Xu R., Lin H., Lu K. et al. A forest fire detection system based on ensemble learning // *Forests*. 2021. Vol. 12. Article 217.

129. Yuan C., Zhang Y., Liu Z. A survey on technologies for automatic forest fire monitoring, detection, and fighting using unmanned aerial vehicles and remote sensing techniques // *Canadian Journal of Forest Research*. 2015. Vol. 45 (7). P. 783–792.

130. Zhang F., Zhao P., Thiyaalingam J. et al. Terrain-influenced incremental watchtower expansion for wildfire detection // *Science of the Total Environment*. 2018a. Vol. 654. P. 164–176.

131. Zhang Q., Lin G., Zhang Y. et al. Wildland forest fire smoke detection based on faster R-CNN using synthetic smoke images // *Procedia Engineering*. 2018b. Vol. 211 (3). P. 441–446.

132. Zhang X., Wan F., Liu C. et al. FreeAnchor: Learning to match anchors for visual object detection // arXiv 2019, arXiv:1909.02466.

133. Zhang S., Chi C., Yao Y. et al. Bridging the gap between anchor-based and anchor-free detection via adaptive training sample selection // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Seattle, WA, USA, 14–19 June, 2020. P. 9759–9768.

134. Zhang H., Wang Y., Dayoub F. et al. VarifocalNet: An *iou*-aware dense object detector // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, New Orleans, LA, USA, 19–24 June, 2021. P. 8514–8523.

135. Zhao L., Liu J., Peters S. et al. Investigating the impact of using IR bands on early fire smoke detection from Landsat imagery with a lightweight CNN model // *Remote Sensing*. 2022. Vol. 14. Article 3047.

© Усольцев В. А., Часовских В. П.. 2026

Поступила в редакцию 04.02.2026

Принята к печати 27.04.2026