

ЭФФЕКТИВНОСТЬ МЕТОДОВ ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ ОБНАРУЖЕНИЯ ДЫМА: ВСЕСТОРОННИЙ ОБЗОР

М.С. Ситдилов, магистрант

Уфимский государственный нефтяной технический университет
(Россия, г. Уфа)

DOI:10.24412/2500-1000-2026-5-1-372-378

Аннотация. В этой статье рассматриваются современные методы глубокого обучения для определения дыма на цифровых изображениях. Объектами исследования стали архитектуры детекции YOLO (v5, v7, v8n), DeepLabv, трансформерные архитектуры (Swin Transformer, ViT) и архитектуры семантической сегментации (U-Net). Отдельно рассмотрен подход с использованием градиций серого, который позволил повысить точность классификации до 96,4% на спутниковых снимках, что актуально для последующей оценки плотности дыма по шкале Рингелмана. Предполагается, что включение в модель дополнительных данных (тип горючего материала, условия возгорания) может повысить точность обнаружения по аналогии с медицинской диагностикой, где одного снимка недостаточно для постановки точного диагноза.

Ключевые слова: YOLO; U-Net; глубокое обучение; обнаружение дыма; механизмы внимания; сегментация изображений; ResNet; bottleneck.

Обнаружение дыма на цифровых изображениях является важной задачей в системах раннего предупреждения пожаров, экологического мониторинга и промышленной безопасности [1]. Своевременное обнаружение дыма позволяет предотвратить распространение возгораний, минимизировать ущерб и сократить время реагирования экстренных служб. Традиционные методы обнаружения, основанные на датчиках дыма или тепла и камер, часто неэффективны на открытых пространствах и не обеспечивают раннего предупреждения из-за неточных измерений. Для обработки недостатков датчиков используется модель глубокого обучения. С развитием методов глубокого обучения и компьютерного зрения появились новые возможности для автоматического обнаружения дыма по изображениям с камер видеонаблюдения, беспилотников и спутников. В данном обзоре рассматриваются современные методы глубокого обучения для обнаружения дыма [2]. Постановка задачи определяется рядом факторов.

1. Масштаб возгорания – в зависимости от этого задача распадается на две подзадачи: обнаружение дыма при крупных пожарах и при небольших возгораниях. При этом обнаружение дыма на ранних стадиях малых пожаров может быть эффективно применены для обнаружения и в случае крупных пожаров.

2. Тип дыма – имеется в виду его происхождение: является ли он следствием пожара или возникает в результате иных технологических процессов на производстве. В зависимости от этого меняются цветовые характеристики и плотность дымового шлейфа.

3. Зона распространения дыма – также делит задачу на подзадачи в зависимости от типа территории: лесные массивы или зоны присутствия человека.

Перечисленные факторы указывают на необходимость применения универсального инструмента, способного обнаруживать дым независимо от условий. Наиболее эффективным инструментом для решения данной задачи являются использование модели глубокого обучения.

Актуальность работы обусловлена значимостью контроля промышленных выбросов, задымленности и смога, а также соблюдения экологических норм и предотвращения экологических нарушений. Развитие методов глубокого обучения и компьютерного зрения открывает новые возможности для создания автоматизированных систем мониторинга.

Целью данной работы является проведение обзора анализа современных методов глубокого обучения для обнаружения дыма на цифровых изображениях и введение сравнения точностей этих методов

FireNet – это фреймворк глубокого обучения, изначально разработанный путем обучения на наборе данных Landsat-8 для применения в области обнаружения действующих пожаров и горящей биомассы [3]. Авторы объединили оптические цвета (красный, зеленый и синий) с тепловыми показаниями, чтобы добиться более надежного и эффективного подхода. Кроме того, они применили остаточные и разделимые сверточные блоки, что позволило извлекать более глубокие признаки из изображений за счет использования уникальных матриц масок на этапе свертки. Экспериментальные результаты показали общую точность 97,35%, а также способность надежно обнаруживать небольшие действующие пожары. Используемый в их работе набор данных получен из лесных массивов Австралии и Северной Америки, тропических лесов Амазонки и Центральной Африки, где активно фиксируются лесные пожары.

В литературе предложено множество различных глубоких нейронных сетей для обнаружения огня и дыма. По сути, авторы использовали в этих моделях архитектуру UNet, но применяли её разные версии, например UNet, UNet++ и UNet3+ [4]. Предложенный

метод под названием «FireNet» и пять других структур были протестированы в качестве инструмента сегментации путем кодирования признаков огня и дыма. Для валидации предлагаемых подходов использовался набор данных из 1200 изображений, собранных из интернета и видеороликов, с соответствующей попиксельной разметкой дыма и огня. Эксперименты показали, что наилучший показатель IoU (метрика пересечения над объединением) в 88,33% достигается с помощью UNet++ с кодирующим инструментом EfficientNet.B0. В некоторых случаях, когда очаги возгорания невелики, наилучшую производительность демонстрирует UNet с FireNet. А если рассматривать сложность с точки зрения вычислительных затрат, то оптимальным выбором становится UNet3+ с FireNet в качестве энкодера.

ResNet-50 и U-Net используются для обнаружения и сегментации промышленного дыма с помощью спутниковых изображений. В частности, ResNet-50 использовался для классификации, а U-Net - для сегментации, сравнение между ResNet-50 и U-Net показано ниже [5].

Таблица 1. Сравнение результатов ResNet-50 и U-Net [5]

Функция	Классификация		Сегментация	
	ResNet-50		U-Net	
Модель	RGB изображения	Изображения в градациях серого	RGB изображения	Изображения в градациях серого
Набор данных				
Точность на обучении (%)	94,3	96,4	94	94
Потери на обучении	0,043	0,094	0,04	0,047
Точность на валидации (%)	93	96	93,4	93,3
Потери на валидации	0,05	0,077	0,053	0,1

Точность классификации ResNet-50 на изображениях в градациях серого достигла 96,4%, превысив показатель на RGB-изображениях (94,3%). Точность сегментации U-Net составила 94,0% как на RGB, так и на изображениях в градациях серого, значение IoU достигало 0,72. Различия в качестве сегментации между RGB и изображениями в градациях серого оказались незначительными. Практическая значимость работы заключается в том, что использование градаций серого повышает точность классификации без ухудшения качества сегментации, что актуально для

задач оценки плотности дыма по шкале Рингельмана, основанной на оттенках серого.

В отличие от подходов в [4-5], Deeplabv3+ была применена и протестирована на французском корсиканском датасете [6]. Модель Deeplab обучалась на RGB-изображениях из набора данных, который содержит как снимки в RGB, так и в инфракрасном (ИК) диапазоне. В ходе экспериментов использовались различные функции потерь, такие как Dice и Tversky, чтобы уменьшить проблемы, вызванные несбалансированностью наборов

данных. Для оценки подходов к глубокому обучению несколько показателей, таких как IoU, оценка F1 и стандартная точность используются. Значения показателей показали, что подход Deerlabv3 является очень эффективным и надежным алгоритмом в области обнаружения пожара и дыма. Процесс тонкой настройки используется для выбора наилучших значений гиперпараметров, что позволяет повысить точность модели. В работе авторы настраивали скорость обучения, тестируя различные значения на изображениях разного размера (600×600 и 300×300), чтобы обеспечить устойчивость предложенного подхода к изменению размеров входных данных. Начальная скорость обучения алгоритма

настраивалась (три значения: 0.001, 0.01 и 0.1).

В той же области, что и обнаружение дыма, собирается набор данных для обнаружения пламени и задымления (FASDD: Flame and Smoke Detection Dataset) [7]; согласно источникам изображений, авторы разделили набор данных FASDD на FASDD_CV, FASDD_UAV и FASDD_RS. Эти подмножества содержат изображения с земли, беспилотных летательных аппаратов и космических датчиков. Модель Swin Transformer реализовала и продемонстрировала эффективность обнаружения пожара, показав значения Map (Mean Average Precision) в 84,9%, 89,7% и 74,0% для соответствующих подмножеств данных [7]. На рисунке 1 показаны выборки из наборов данных.



Рис. 1. Пример из FASDD [7]

На следующем рисунке показано, как набор данных содержит различные наблюдения, такие как:

- 1) ближний и дальний виды огня и дыма;
- 2) в помещении и на улице;
- 3) днем и ночью;
- 4) огонь или не огонь;
- 5) дым или не дым.

Модуль FFS-YOLO на базе YOLOv7 предназначен для обнаружения пожара и задымления в промышленных зонах. Кроме того, модуль ResNet-SimAM Mix объединен со структурой bottleneck. Также измеряется задержка обнаружения, максимальное значение которой составляет 12 миллисекунд. Это означает, что при поступлении изображений на вход модели в реальном времени результат обнаруживается через 12 мс [10]. В данном случае измерение задержки обнаружения (12 мс) демонстрирует пригодность разработанного подхода для работы в реальном времени, что особенно важно для систем раннего оповещения о возгорании.

Наряду с наземными системами видеонаблюдения, для обнаружения пожаров широко применяются спутниковые технологии, позволяющие осуществлять мониторинг больших территорий. В работе [11] представлен анализ эффективности спутниковых систем мониторинга и алгоритмов обработки данных для обнаружения пожаров. Проанализированы традиционные методы наблюдения и современные технологии, такие как искусственный интеллект и машинное обучение. Для решения задачи обнаружения лесных пожаров по данным дистанционного зондирования была разработана сверточная нейросетевая модель. Для обучения и тестирования модели были использованы данные о пожарах со спутника «Арктика-М» за 2023 год. Точность обучения модели на тестовой выборке составляет 99,4%. Модель также была протестирована на данных за 2024 год. Результаты апробации показали, что точность прогнозной модели составляет 98%, что достаточно для применения в задачах обнаружения лесных пожаров с использованием данных дистанционного зондирования земли со спутника «Арктика-М» [11]. Настраиваемые гиперпараметры и соответствующие диапазоны для модели сверточной нейронной сети приведены ниже:

1) количество Conv2D и MaxPooling2D слоев: [1-3];

2) количество фильтров: [16, 32, 64, 128];

3) размер ядра Conv2D слоя: [3-6];

4) размер окна MaxPooling2D слоя: [2-3];

5) количество полносвязных слоев: [1-3];

6) количество нейронов на полносвязном слое: [64, 128, 256, 512];

7) функция активации в полносвязной части: [relu, tanh, sigmoid];

8) оптимизатор [adam, rmsprop, SGD].

В результате работы алгоритма поиска наилучшие показатели метрики точности (99,4%) показала модель со следующей архитектурой

- Conv2D(32, (3, 3), activation='relu')

- MaxPooling2D((2, 2))

- Conv2D(64, (3, 3), activation='relu')

- MaxPooling2D((2, 2))

- Conv2D(128, (3, 3), activation='relu')

- MaxPooling2D((2, 2))

- Conv2D(128, (3, 3), activation='relu')

- MaxPooling2D((2, 2))

- Flatten()

- Dense(512, activation='relu')

- Dense(1, activation='sigmoid')

В контексте обеспечения безопасности сотрудников МЧС России, работающих на месте вызова, особое значение приобретает изучение дымообразующей способности строительных материалов. Недостаточная изученность этого вопроса затрудняет прогнозирование степени опасности для персонала. В связи с этим авторы [12] сформулировали алгоритм создания базы данных изображений дыма, образующегося при горении различных веществ и материалов, составляющих основную горючую нагрузку в помещениях объектов различного функционального назначения, и предложен классификатор изображений дыма в зависимости от пожарной нагрузки. Приведен пример описания структуры базы данных, формируемой на основе существующих имитационных моделей и программных продуктов [12].

В таблице 2 приведено сравнение основных архитектур и результатов, методы были сравнены по критериям точности.

Таблица 2. Сравнительный анализ исследований по обнаружению дыма

Исследование	Архитектура	Метрики
[5]	ResNet-50 + U-Net	96,4% классификация, 94% сегментация
	DeepLabv3	94,22% точность 71,56 IoU
[7]	Swin transformer	84,9 – 89,7% mAP
[8]	EfficientNet + YOLOv5	99% точность
[9]	YOLOv7	86,4% AP
[10]	FFS-YOLO	92% mAP
[13]	YOLOv5	92,5% mAP
[14]	YOLOv8n	95,6% mAP
[15]	YOLOv5s + ViT	66,4% mAP

Сравнение показывает, что все модели могут достичь высокой точности обнаружения, но с определенной точки зрения существует другой подход, который может быть более эффективным. Его ключевая идея заключается в использовании специально разработанной остаточной сети (ResNet) с блоками «Bottleneck». Эта архитектура более эффективна, чем стандартные модели, позволяя извлекать сложные признаки из изображений, оставаясь при этом вычислительно доступной. Потому что архитектура с блоками Bottleneck и остаточными связями позволяет сети проходить через большее количество слоёв без потери информации. Это даёт возможность выделять более сложные признаки на изображениях. В отличие от архитектур YOLOv8n и DeepLabv3+, которые работают исключительно с визуальными данными, архитектура на основе ResNet с блоками Bottleneck позволяет интегрировать дополнительные типы входной информации, такие как температура и влажность. Это становится критически важным в условиях зимнего тумана, когда визуальное обнаружение дыма затруднено, а ложные срабатывания учащаются. Добавление невидимых параметров компенсирует недостаток информации от камеры и повышает надёж-

ность модели. Таким образом, несмотря на высокие показатели mAP у YOLOv8n (95.6%), выбор ResNet с Bottleneck обусловлен не максимальной точностью на изображениях, а возможностью создания гибридной системы, устойчивой к сложным погодным условиям. DeepLabv3+ также остаётся перспективным кандидатом, особенно в связке с MobileNetV3, и может рассматриваться для сравнения в будущих работах.

В результате проведённого анализа установлено, что комбинированная архитектура ResNet с блоками Bottleneck и U-Net обеспечивает более высокую устойчивость модели к внешним условиям (туман, осадки, низкая освещённость) за счёт интеграции дополнительных данных – температуры и влажности. Это позволяет повысить точность обнаружения дыма в сложных погодных условиях, где стандартные визуальные модели дают сбои. Предложенная связка может быть использована при разработке мобильного приложения для оценки плотности дыма по шкале Рингельмана, а также в системах раннего оповещения о пожарах на промышленных объектах. В перспективе архитектура может быть адаптирована для работы с другими типами сенсорных данных.

Библиографический список

1. Болдырев Н.Д. и др. Современные подходы к мониторингу и прогнозированию природных пожаров: обзор и концепция автономной системы на базе БПЛА // Известия ЮФУ. Технические науки. – 2025. – № 6. – С. 58-80.
2. Емельянов Н.А. Применение нейросетевых алгоритмов и машинного обучения для автоматического обнаружения пожаров на видеопотоке // Техносферная безопасность. – 2025. – № 3 (48). – С. 13-23.
3. Seydi S. T. et al. Fire-Net: A Deep Learning Framework for Active Forest Fire Detection // Journal of Sensors. – 2022. – Т. 2022. – № 1. – С. 8044390.
4. Eskandari A. et al. Fire and Smoke Segmentation using FireNet Combined with UNet3 // International journal of engineering, transactions a: basics. – 2025. – Т. 38. – № 10. – С. 2357-2368.
5. Balasundaram A. et al. U-net inspired deep neural network-based smoke plume detection in satel-

lite images // Computers, Materials, & Continua. – 2024. – Т. 79. – № 1. – С. 779.

6. Harkat H., Nascimento J.M.P., Bernardino A. Fire detection using residual deeplabv3+ model // 2021 Telecoms Conference (ConfTELE). – IEEE, 2021. – С. 1-6.

7. Wang M. et al. An open flame and smoke detection dataset for deep learning in remote sensing based fire detection // Geo-spatial Information Science. – 2025. – Т. 28. – № 2. – С. 511-526.

8. Chitram S., Kumar S., Thenmalar S. Enhancing fire and smoke detection using deep learning techniques // Engineering Proceedings. – 2024. – Т. 62. – № 1. – С. 7.

9. Kim S.Y., Muminov A. Forest fire smoke detection based on deep learning approaches and unmanned aerial vehicle images // Sensors. – 2023. – Т. 23. – № 12. – С. 5702.

10. Phan D.T. et al. Vision-based early fire and smoke detection for smart factory applications using FFS-YOLO // 2023 IEEE 25th International Workshop on Multimedia Signal Processing (MMSP). – IEEE, 2023. – С. 1-6.

11. Маглинец Ю.А. Автоматизация процесса обнаружения лесных пожаров по данным дистанционного зондирования Арктика-М // Международный научно-исследовательский журнал. – 2024. – № 10 (148). – С. 80.

12. Шевцов М.В. Интеллектуальный анализ процессов дымообразования на пожарах: новые подходы на основе ИИ-технологий // Вестник Дагестанского государственного технического университета. Технические науки. – 2025. – Т. 52. – № 2. – С. 159-168.

13. Wan A., Wu Z., Khalil A.L.B. Deep learning-based intelligent visual inspection for defect detection in smoke sensor manufacturing // Next Research. – 2025. – Т. 2. – № 3. – С. 10042.

14. Zhang Z., Tan L., Robert T.L.K. An improved fire and smoke detection method based on YOLOv8n for smart factories // Sensors. – 2024. – Т. 24. – № 15. – С. 4786.

15. Safarov F. et al. Fire and smoke detection in complex environments // Fire. – 2024. – Т. 7. – № 11. – С. 389.

EFFECTIVENESS OF DEEP LEARNING METHODS FOR SMOKE DETECTION: A COMPREHENSIVE REVIEW

M.S. Sitdikov, *Graduate Student*
Ufa State Petroleum Technological University
(Russia, Ufa)

Abstract. *This article examines modern deep learning methods for detecting smoke in digital images. The objects of study were the YOLO detection architectures (v5, v7, v8n), DeepLabv, transformer architectures (Swin Transformer, ViT), and semantic segmentation architectures (U-Net). A grayscale approach is separately considered, which increased classification accuracy to 96.4% on satellite images, which is relevant for subsequent assessment of smoke density using the Ringelmann scale. It is assumed that incorporating additional data (combustible material type, fire conditions) into the model can improve detection accuracy, similar to medical diagnostics, where a single image is insufficient for an accurate diagnosis.*

Keywords: *smoke detection; deep learning; YOLO; U-Net; attention mechanisms; image segmentation; ResNet; bottleneck.*