

УДК 004.932.2

DOI: [10.26102/2310-6018/2023.40.1.027](https://doi.org/10.26102/2310-6018/2023.40.1.027)

Модель распознавания дыма на открытой местности с использованием сверточной и рекуррентной нейронной сети

Д.А. Шестаков[✉], Г.В. Шагрова, В.Г. Струкова, В.А. Доронин

Северо-Кавказский Федеральный Университет, Ставрополь, Российская Федерация
dimas_1_on@mail.ru[✉]

Резюме. Своевременное обнаружение источника возгорания является важным вопросом защиты людей, животных и обширных территорий от пожаров. Актуальность исследования обусловлена тем, что существующие системы визуального обнаружения дыма имеют ряд недостатков, которые не позволяют эффективно применять их на практике. Система наблюдения должна полагаться на визуальные характеристики, и часто ошибочно определяет туман и облака как дым. Целью исследования является повышение эффективности обнаружения дыма за счет использования усовершенствованной модели детектора дыма на основе нейронной сети «You-Only-Look-Once» и классификатора с долговременной кратковременной памятью (LSTM). Основными задачами исследования являются: структурное описание предлагаемой модели обнаружения дыма, математическое описание обучаемой модели и проведение сравнительного анализа с существующими моделями нейронных сетей. Путем изменения структуры LSTM достигается уменьшение количества слоев и ячеек, сохраняется производительность исходной LSTM. Предложенный метод обеспечивает уменьшение количества параметров в несколько раз и более быстрое время обработки на используемом наборе данных. В статье приводятся результаты производительности систем искусственного интеллекта для сравнительного анализа кандидатов нейронных сетей в модель распознавания дыма.

Ключевые слова: обнаружение дыма, обнаружение возгораний, классификация объектов, нейронные сети, обработка изображений.

Для цитирования: Шестаков Д.А., Шагрова Г.В., Струкова В.Г., Доронин В.А. Модель распознавания дыма на открытой местности с использованием сверточной и рекуррентной нейронной сети. *Моделирование, оптимизация и информационные технологии.* 2023;11(1). URL: <https://moitvvt.ru/ru/journal/pdf?id=1282> DOI: 10.26102/2310-6018/2023.40.1.027

Smoke recognition model in an open area using a convolutional and recurrent neural network

D.A. Shestakov[✉], G.V. Shagrova, V.G. Strukova, V.A. Doronin

North Caucasian Federal University, Stavropol, Russian Federation
dimas_1_on@mail.ru[✉]

Abstract. Timely detection of the source of ignition is an important issue of protecting people, animals and vast territories from fires. The relevance of this study is due to the fact that the existing visual smoke detection systems have a number of disadvantages that do not allow them to be effectively applied in practice. The surveillance system must rely on visual characteristics and often mistakenly identifies fog and clouds as smoke. The aim of this study is to increase the efficiency of smoke detection by using an advanced smoke detector model based on the "You-Only-Look-Once" neural network and a classifier with long-term short-term memory (LSTM). The main objectives of the study are structural description of the proposed smoke detection model, mathematical description of the trained model and comparative analysis with existing neural network models. By changing the structure of the LSTM, a reduction in the number of layers and cells is achieved, and the performance of the original LSTM is maintained. The proposed method provides a reduction in the number of parameters by several times and a faster

processing time on the data set used. The article presents the results of the performance of artificial intelligence systems for a comparative analysis of neural network candidates in the smoke recognition model.

Keywords: smoke detection, fire detection, object classification, neural networks, image processing.

For citation: Shestakov D.A., Shagrova G.V. Strukova V.G. Doronin V.A. Smoke recognition model in an open area using a convolutional and recurrent neural network. *Modeling, Optimization and Information Technology*. 2023;11(1). URL: <https://moitvvt.ru/ru/journal/pdf?id=1282> DOI: 10.26102/2310-6018/2023.40.1.027 (In Russ.).

Введение

Среди различных стихийных бедствий, вызванных глобальным потеплением, пожары имеют более высокий риск, чем другие стихийные бедствия, и наносят больший ущерб имуществу, жизни людей и экосистемам. Для решения этой проблемы были проведены исследования автоматизированных систем мониторинга пожаров. Наиболее эффективным устройством, с точки зрения точности и стоимости, при обнаружении пожаров является использование камеры [1, 2]. В этом исследовании предлагается алгоритм, который может различать фактический дым от лесных пожаров и дымоподобные явления, такие как облака, туман и дым из трубы, в дневное время посредством анализа изображения в реальном времени с использованием методов глубокого обучения.

Модель

Обнаружение возгораний с использованием систем видеонаблюдения во многих исследованиях все чаще предпринималось с помощью сверточной нейронной сети (CNN), которая является производным алгоритмом DNN для распознавания изображений. Эти исследования на основе нейронных сетей показали лучшую производительность, чем существующие функции ручной работы и методы, основанные на машинном обучении [3, 4]. В этой статье рассматривается раннее обнаружение дыма при возгорании с помощью двух процессов: обнаружения дыма-кандидата сверточной нейронной сетью и проверки на достоверность при помощи облегченной структуры LSTM сети.

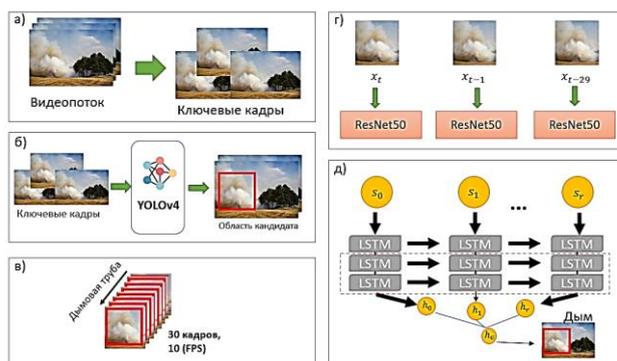


Рисунок 1 – Общая процедура обнаружения дыма от возгораний на открытых участках: (а) Извлечение ключевого кадра, (б) обнаружение кандидатов дыма, (в) конфигурация дымовой трубы, (г) извлечение пространственных признаков и (д) верифицированный дым от пожара на основе малой кратковременной памяти облегченной (LSTM)

Figure 1 – General procedure for detecting smoke from fires in open areas: (a) keyframe extraction, (b) smoke candidate detection, (c) chimney configuration, (d) extraction of spatial features, and (e) verified smoke from a fire based on small short-term lightweight memory (LSTM)

На первом шаге модели происходит сбор ключевых кадров путем разницы в движении между предыдущим ключевым кадром и текущим кадром. С этой целью сначала применяется сглаживание по Гауссу для удаления шума кадра, и кадр делится на $n \times n$ участков. Разница в значении вычисляется для каждого участка между предыдущим ключевым кадром и текущим кадром [3, 6], и если в одном или нескольких локальных участках происходит перемещение, превышающее определенное пороговое значение, текущий входной кадр устанавливается в качестве ключевого кадра, как показано на Рисунке 1а. В противном случае вводится следующий кадр. Этот процесс повторяется до тех пор, пока не будет обнаружен следующий ключевой кадр, и когда ключевой кадр обнаруживается, применяется постобработка для нахождения дыма. Во время предварительной обработки области-кандидаты дыма извлекаются только из ключевых кадров, используя детектор на основе CNN. По итогу наличие пожара определяется с помощью постобработки на основе LSTM [5]. Следовательно, целью детектора областей-кандидатов на основе CNN является обнаружение достаточного количества областей-кандидатов, включая реальный дым и дымоподобные объекты; сведение к минимуму недостающих областей; передача их для последующей обработки. Чтобы сконструировать детектор, подходящий для дыма на открытых участках, мы сравнили и оценили различные недавно предложенные детекторы объектов на основе CNN, такие как Detectron 2, RetinaNET, YOLOv4 darknet.

На видео, записываемом камерой наблюдения, могут быть видны различные типы облаков и тумана, которые очень похожи на дым от пожара. Следовательно, чтобы отличить их от настоящего дыма, необходимо учитывать временное движение дыма, которое изменяется под действием ветра или воспламеняющегося материала. С этой целью в данном исследовании область-кандидат дыма ключевого кадра сначала обнаруживается с использованием YOLOv4, а затем строится дымовая труба с использованием кадров предыдущих 3 (сек) в той же позиции, что и соответствующая область-кандидат, которая имеет такое же количество кадров, предложенных [6]. На основе дымовой трубы область дыма пожара проверяется с помощью постобработки с учетом пространственно-временных характеристик.

При построении дымовой трубы, если собрать все кадры, к примеру за предыдущие 3 секунды и использовать их для LSTM, то производительность LSTM может ухудшиться, потому что движение малозаметное из-за медленной скорости распространения дыма. Поэтому, чтобы сократить время обработки и применить эффективную проверку дыма, достаточно извлечь только 10 кадров в секунду (fps) вместо того, чтобы использовать все кадры для дымовой трубы. Поскольку тонкое движение дыма может быть упущено, в этом исследовании в дымовой трубе хранится в общей сложности 30 кадров со скоростью 10 кадров в секунду в течение 3 секунд с учетом времени обработки и использования памяти. После построения дымовой трубы все кадры в дымовой трубе нормируются на размер 216×216 , что является входным размером ResNet50 для извлечения признаков.

Чтобы извлечь больше достоверных признаков из изображений, в дымовой трубе применяется тонко настроенный ResNet50 [7] для каждой области дымовой трубы, для чего переводим дымовую трубу в набор функций, устойчивых к проверке дыма. Модель ResNet50 была предварительно обучена с использованием набора данных ImageNet. Стоит отметить, что модель ResNet50 подверглась реконструкции путем добавления в нее двух полносвязных слоев (FC) вместо классификатора верхнего уровня для классификации. Данные полносвязные слои имеют выходные размеры 2048 и 1024 соответственно, за ними размещаются слой отсева, чтобы свести к минимуму переобучение.

Недавно было представлено несколько алгоритмов рекуррентной нейронной сети (RNN), которые могут анализировать информацию о временных рядах. Например, LSTM, Bi-LSTM и вентильный рекуррентный блок (GRU) [8]. Однако, поскольку дым на открытой местности имеет отчетливую характеристику распространения с течением времени, необходимо рассмотреть только прямое соединение в LSTM. В эксперименте по сравнению производительности базовый LSTM показал лучшую производительность, чем GRU и Bi-LSTM, тем самым возгорание проверялось на основе прямого LSTM.

Более глубокая модель LSTM хорошо работает в крупномасштабном непрерывном распознавании данных благодаря своей способности к обучению. Однако по мере увеличения количества слоев есть недостаток, заключающийся в том, что обучение становится трудным, а объем памяти и время тестирования увеличиваются из-за многочисленных параметров. Следовательно, для обнаружения дыма в реальном времени необходим дополнительный алгоритм для облегчения глубокой модели LSTM при сохранении производительности классификации.

В этом исследовании модель взаимодействия полного LSTM (LSTM-1) и облегченного LSTM (LSTM-2) используется для разработки неглубокой модели LSTM за счет уменьшения веса при сохранении эффективности классификации дыма глубокой модели LSTM. Такая структура строит глубокую и широкую модель с высокой производительностью на основе большого количества обучающих данных и глубоких слоев и строит более мелкую модель с равной производительностью. Благодаря этому процессу неглубокий LSTM имеет преимущество в уменьшении веса модели при сохранении производительности существующей модели. На Рисунке 2 изображена структура взаимодействия трехслойной и однослойной модели LSTM в процессе обучения.

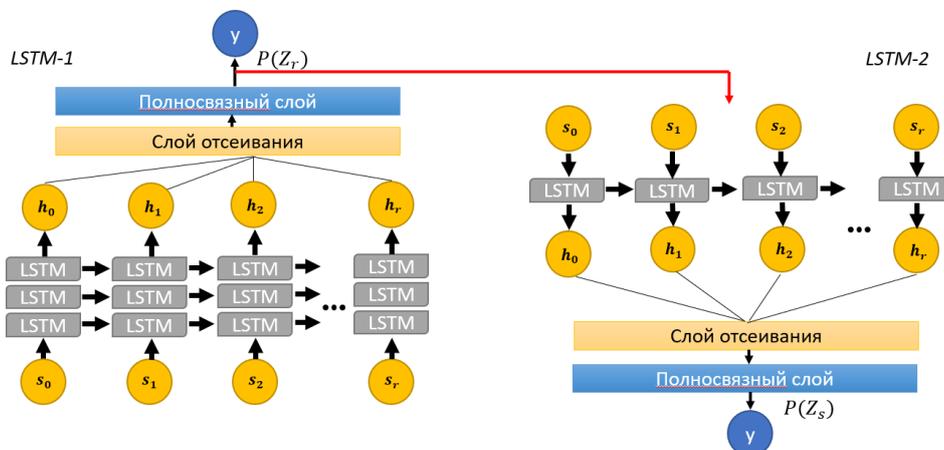


Рисунок 2 – Предлагаемая структура взаимодействия (LSTM-1)–(LSTM-2)
Figure 2 – Proposed interaction structure (LSTM-1)–(LSTM-2)

Вычисления

Учебный набор данных дыма разделен на наборы данных A для обучения моделей LSTM-1 и более крупный набор данных B для обучения моделей LSTM-2. Для обучения модели LSTM-1 в качестве основы для компонента обучения предоставляется обучающий набор A .

$$A = \{(x_i, y_i) | i = 1, 2, \dots, N\}, \quad (1)$$

где $x_i = (x_{i1}, x_{i2}, \dots, x_{iM})$ – входной вектор с размерностью M (1024) и $y_i = \{g_1, g_2, \dots, g_C\}$ это скаляр (C – количество классов и имеет два класса), представляющий класс,

отмеченный экспертом. Набор данных A , помеченный скаляром 1 (дым)/0 (не дым), называется «жесткой меткой». LSTM-1 затем обучается минимизировать ошибку классификации, используя помеченный обучающий набор A . Обученный набор данных B затем вводится в LSTM-1, который обучается с использованием соответствующих жестких меток. В отличие от обучающего набора данных A , каждый образец набора данных B применяется к LSTM-1 для вычисления вектора вероятности класса в соответствии с результатами уравнения (3) и перемаркировки исходного набора данных B . После того, как все образцы, включенные в набор данных B , были обучены, новый набор данных B^* строится как:

$$B^* = \{(x_i^*, p_i^*, \hat{y}_i) | i = 1, 2, \dots, N^*\}. \quad (2)$$

Новый набор данных B^* транскрибируется с классовой вероятностью p_i^* , который называется «мягкой меткой», а жесткая метка класса \hat{y}_i помечается экспертом [9]. Для создания высокопроизводительного LSTM-1 были применены глубокие LSTM состоящие из трех слоев, где каждый модуль LSTM состоит из 128 ячеек, как показано на Рисунке 2. Чтобы определить количество ячеек с оптимальной производительностью в LSTM, количество ячеек на слой было кратно увеличено с 32 до 1024 с использованием метода Cao et al [4].

Модель LSTM-1 должным образом предоставляет свои собственные способности к обучению LSTM-2, и эта способность может быть предоставлена через значение вероятности для каждого класса. Однако некоторые вероятности выходных данных класса LSTM-1 близки к нулю, и, таким образом, информация может быть доставлена неправильно во время обучения с обратным распространением. Следовательно, чтобы смягчить значение вероятности для каждого класса, гиперпараметр «температура» (T) добавляется к существующей функции softmax следующим образом [8]:

$$P(z_i) = \frac{\exp\left(\frac{z_i}{T}\right)}{\sum_j \exp\left(\frac{z_j}{T}\right)}, \quad (3)$$

где z_j – значение логита. Если $T = 1.0$, мы получаем стандартную функцию softmax. По мере увеличения T распределение вероятностей, создаваемое функцией softmax, становится более плавным, предоставляя больше информации о классе, который, по мнению LSTM-1, больше похож на предсказанный класс. В этом исследовании $T = 2.0$ было установлено путем ссылки на [10].

Чтобы сделать LSTM-2 легче, чем LSTM-1, используется один слой LSTM, а количество ячеек в каждом модуле LSTM составляет 24. При обучении LSTM-2 используется набор данных B^* , состоящий из мягких меток, а функция потерь, используемая для обучения модели, выглядит следующим образом.

$$\mathcal{L}_{total} = \alpha \cdot \mathcal{L}_{CE}(P(z_s), \hat{y}) + (1 - \alpha) \cdot \mathcal{L}_{CE}(P(z_s), P(z_r)), \quad (4)$$

где \mathcal{L}_{CE} представляет собой перекрестную потерю энтропии, а $P(z_s)$ и $P(z_r)$ представляют результат вероятности каждого LSTM-2 и LSTM-1. Первый член в уравнении (4) представляет собой перекрестную энтропию между метками жесткого класса \hat{y} и выходом $P(z_s)$ LSTM-2, а второй член представляет собой перекрестную энтропию между выходом $P(z_s)$ LSTM-2 и выходом $P(z_r)$ LSTM-2. Параметр α – это регулируемое значение, которое поддерживает баланс между двумя условиями и устанавливается равным 0,5 для этого исследования. Таким образом, в процессе обучения используя уравнение (4), LSTM-2 применяет меньше параметров, чем LSTM-1, но достигает почти такой же эффективности обучения.

Сравнительный анализ

Чтобы доказать эффективность предлагаемого метода, измеряется объективная производительность с помощью нескольких сравнительных экспериментов. С этой целью сравнивается эффективность обнаружения дыма пожаров с помощью различных алгоритмов сравнения и предложенного метода [11]. Кроме того, сравнивая производительность и размер моделей LSTM-1 и LSTM-2, доказываем, что предлагаемая модель LSTM-2 сохраняет производительность при уменьшении размера.

Тестовый набор данных для обучения и тестирования детектора состоял из следующих собираемых данных, Таблица 1.

Таблица 1 – Подробная видео конфигурация тестового набора данных
Table 1 – Detailed video configuration of the test dataset

Тип	Имя	Разрешение	Число кадров	FPS	Описание	Время года
Дым	True1	1280*720	563	25	На открытой местности	Зима
	True2		1036		Дым от лесных пожаров (мал)	Весна
	True3		896		Дым на полях (мал)	Осень
	True4		1523		Дым от лесных пожаров (бол)	Лето
	True5		1325		Дым на полях (бол)	Лето
Не дым	Облака1	1280*720	551	25	Облака средние	Лето
	Туман1		867		Сильный туман	Зима
	Туман2		1371		Слабый туман	Зима
	Пыль б.1		966		Пылевая буря	Лето
	Облака2		785		Облака большие	Осень

Эксперименты проводились с использованием процессора Intel Core i5-8400 и графического процессора NVIDIA GeForce GTX 970 под управлением Microsoft Windows 10. Данный метод был реализован на Keras для TensorFlow. Обучение детектора YOLOv4, используемого в предлагаемом методе, было точно настроено с использованием весов, предварительно обученных с помощью базы данных ImageNet. Кроме того, YOLOv4 был изменен на девять anchors с учетом формы дыма от лесных пожаров. Обучение YOLOv4 проводилось с использованием скорости обучения 0,003, batch_size = 64 и 100 epochs на основе входного изображения 416×416×3. Дымовая труба была извлечена вокруг предполагаемой области дыма из 30 кадров, сгенерированных в течение 3 с со скоростью 10 кадров в секунду. Дымовая труба была подана в ResNet50 + LSTM. Применяемый здесь ResNet50 использует веса, предварительно обученные с помощью ImageNet, и настраивается путем добавления двух полносвязных слоев с

отсегом 0,5 и функцией активации ReLu. В Таблице 2 приведены результаты сравнительной оценки производительности новейших детекторов объектов на базе CNN. Согласно показателям YOLOv4 показал самое быстрое время обработки и высокую скорость отзыва.

Основные формулы, используемые для вычисления: F1-score (F1-счет), Precision (Точность), Recall (Полнота), TP, FP, FN, TPR и TNR – можно найти в открытом доступе.

Таблица 2 – Сравнительный анализ методов обнаружения объектов: Yolov4, RetinaNet, Detectron 2

Table 2 – Comparative analysis of object detection methods: Yolov4, RetinaNet, Detectron 2

Метод	F1-счет (%)	Точность (%)	Полнота (%)	TP (%)	FP (%)	FN(%)	Затраченное время (сек)
YOLOv4	67.98	52.54	96.26	50.57	45.67	1.96	0.010
RetinaNet	47.13	31.29	95.46	30.74	67.49	1.46	0.085
Detectron 2	58.25	41.38	98.36	45.21	64.03	0.75	0.347

Для нахождения оптимальной модели для LSTM-1 были проведены измерения производительности LSTM, Bi-LSTM и GRU моделей, чтобы найти оптимальную из них для детектора дыма. Используемые в эксперименте модели состояли из трех слоев, а количество ячеек в каждом модуле было унифицировано как 128. В Таблице 3, показано сравнение производительности трех моделей кандидатов в LSTM-1 с использованием четырех показателей. Глубокая модель LSTM показала наилучшую производительность 89,32 %.

Таблица 3 – Сравнительный анализ производительности LSTM, Bi-LSTM, GRU в качестве выбора оптимальной модели для LSTM-1

Table 3 – Comparative analysis of the performance of LSTM, Bi-LSTM, GRU as a choice of the optimal model for LSTM-1

Модель	F1-счет (%)	Точность (%)	Полнота (%)	TPR (%)	TNR (%)
ResNet50+LSTM	89.32	88.61	90.05	90.05	79.53
ResNet50+Bi-LSTM	88.73	90.29	87.22	87.22	85.25
ResNet50+GRU	89.19	89.41	88.97	88.97	82.29

Аналогичный тест проводится для модели LSTM-2, с использованием одного слоя и 24 ячеек.

Таблица 4 – Сравнение производительности облегченных моделей LSTM, Bi-TSTM, GRU с одним слоем, в качестве выбора оптимальной модели LSTM-2.

Table 4 – Comparison of the performance of lightweight models LSTM, Bi-TSTM, GRU with one layer as a choice of the optimal model LSTM-2.

Модель	F1-счет (%)	Точность (%)	Полнота(%)	TPR (%)	TNR (%)
ResNet50+LSTM (One layer)	88.78	88.93	88.64	88.64	82.35
ResNet50+Bi-LSTM (One layer)	85.64	86.17	85.12	85.12	80.11
ResNet50+GRU (One layer)	85.66	86.12	85.20	85.20	80.35

В качестве третьего эксперимента происходит сравнительный анализ модели LSTM-1 и LSTM-2 по полученным результатам: количество параметров и время обработки. Таким образом, доказывается, действительно ли облегченная модель стала лучше и быстрее при той же производительности.

Таблица 5 – Сравнение моделей LSTM-1 и LSTM-2

Table 5 – Comparison of LSTM-1 and LSTM-2 models

Модель	Ячеек	F1-счет (%)	Количество параметров	Затраченное время (сек.)
LSTM-1	128	89.32	736887	0.157
LSTM-2	24	88.78	87145	0.143

Заключение

В данном исследовании был предложен подход использования YOLOv4 и облегченной модели, базирующейся на LSTM, с использованием структуры LSTM-1-LSTM-2. Предлагаемый метод сокращает количество ненужных операций системы обнаружения дыма за счет обнаружения ключевых кадров, содержащих значительное движение, а не всего кадра. Кроме того, за счет применения YOLOv4 только к ключевому кадру было сокращено время предварительной обработки для обнаружения потенциальной области дыма и генерации дымовой трубы для анализа временных рядов. По итогу, на основе сравнительного анализа результатов, предложенная модель LSTM-2 позволит уменьшить количество параметров модели и сократить время обработки, сохраняя при этом производительность, аналогичную производительности исходного глубокого LSTM.

СПИСОК ИСТОЧНИКОВ

1. Балонин Н.А., Сергеев М.Б. *Беспроводные персональные сети*. Санкт-Петербург: ГУАП; 2012. 60 с.
2. Заяц А.М., Логачев А.А. Информационная система мониторинга лесов и лесных пожаров с использованием беспроводных сенсорных сетей. *Известия Санкт-*

- Петербургского государственного лесотехнического университета им. С.М. Кирова*. 2016;3:241–254.
3. Пятибратов А.П. *Вычислительные машины, сети и телекоммуникационные системы*. 2-е изд., перераб. и доп. М.: Финансы и статистика; 2004. 508 с.
 4. Ходаков В.Е., Жарикова М.В. *Лесные пожары: методы исследования*. Херсон: ЧП Гринь Д.С.; 2011. 470 с.
 5. Cao Y., Yang F., Tang Q., Lu X. An Attention Enhanced Bidirectional LSTM for Early Forest Fire Smoke Recognition. *IEEE Access*. 2019;7:154732–154742. DOI: 10.1109.
 6. Cetin A.E., Dimitropoulos K., Gouverneur B., Grammalidis N., Günay O., Habiboglu Y.H., Töreayind B.U., Verstockt S. Video fire detection – review. *Digital Signal Processing*. 2013;23(6):1827–1843. DOI: 10.1016.
 7. Chen Y., Zhang Y., Xin J., Wang G., Mu L., Yi Y., Liu H., Liu D. UAV Image-based Forest Fire Detection Approach Using Convolutional Neural Network. *In Proceedings of the 14th IEEE Conference on Industrial Electronics and Applications*. 2019:2118–2123. DOI: 10.1109/ICIEA.2019.8833958.
 8. Jiao Z. A Deep Learning Based Forest Fire Detection Approach Using UAV and YOLOv3. *1st International Conference on Industrial Artificial Intelligence (IAI)*. 2019:1–5. DOI: 10.1109/ICIAI.2019.8850815.
 9. Hinton, G., Vinyals, O., Dean, J. Distilling the Knowledge in a Neural Network. *ArXiv*. 2015:1503.02531.
 10. Gotthans J., Gotthans T., Marsalek R. Deep convolutional neural network for fire detection. *30th International Conference Radioelektronika (RADIOELEKTRONIKA)*. 2020;1:1–6. DOI: 10.1109/RADIOELEKTRONIKA49387.2020.9092344.
 11. Wu S., Zhang L. Using Popular Object Detection Methods for Real Time Forest Fire Detection. *11th International Symposium on Computational Intelligence and Design (ISCID)*. 2018;4:280–284. DOI: 10.1109/ISCID.2018.00070.

REFERENCES

1. Balonin N.A., Sergeev M.B. *Besprovodnye personal'nye seti*. Sankt-Peterburg: GUAP; 2012. 60 p. (In Russ.).
2. Zajac A.M., Logachev A.A. Informacionnaja sistema monitoringa lesov i lesnyh pozharov s ispol'zovaniem besprovodnyh sensorynyh setej. *Izvestija Sankt-Peterburgskogo gosudarstvennogo lesotekhnicheskogo universiteta im. S.M. Kirova*. 2016;3:241–254. (In Russ.).
3. Pjatibratov A.P. *Vychislitel'nye mashiny, seti i telekommunikacionnye sistemy*. 2-e izd., pererab. i dop. M.: Finansy i statistika; 2004. 508 p. (In Russ.).
4. Hodakov V.E., Zharikova M.V. *Lesnye pozhary: metody issledovanija*. Herson: ChP Grin' D.S.; 2011. 470 p. (In Russ.).
5. Cao Y., Yang F., Tang Q., Lu X. An Attention Enhanced Bidirectional LSTM for Early Forest Fire Smoke Recognition. *IEEE Access*. 2019;7:154732–154742. DOI: 10.1109.
6. Cetin A.E., Dimitropoulos K., Gouverneur B., Grammalidis N., Günay O., Habiboglu Y.H., Töreayind B.U., Verstockt S. Video fire detection – review. *Digital Signal Processing*. 2013;23(6):1827–1843. DOI: 10.1016.
7. Chen Y., Zhang Y., Xin J., Wang G., Mu L., Yi Y., Liu H., Liu D. UAV Image-based Forest Fire Detection Approach Using Convolutional Neural Network. *In Proceedings of the 14th IEEE Conference on Industrial Electronics and Applications*. 2019:2118–2123. DOI: 10.1109/ICIEA.2019.8833958.

8. Jiao Z. A Deep Learning Based Forest Fire Detection Approach Using UAV and YOLOv3. *1st International Conference on Industrial Artificial Intelligence (IAI)*. 2019:1–5. DOI: 10.1109/ICIAI.2019.8850815.
9. Hinton, G., Vinyals, O., Dean, J. Distilling the Knowledge in a Neural Network. *ArXiv*. 2015:1503.02531.
10. Gotthans J., Gotthans T., Marsalek R. Deep convolutional neural network for fire detection. *30th International Conference Radioelektronika (RADIOELEKTRONIKA)*. 2020;1:1–6. DOI: 10.1109/RADIOELEKTRONIKA49387.2020.9092344.
11. Wu S., Zhang L. Using Popular Object Detection Methods for Real Time Forest Fire Detection. *11th International Symposium on Computational Intelligence and Design (ISCID)*. 2018;4:280–284. DOI: 10.1109/ISCID.2018.00070.

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Шестаков Дмитрий Алексеевич, Dmitry Alekseevich Shestakov, аспирант кафедры информационных систем и технологий, Северо-Кавказский Федеральный Университет, Ставрополь, Российская Федерация.
e-mail: dimas_1_on@mail.ru

Шагрова Галина Вячеславовна, Galina Vyacheslavovna Shagrova, доктор физико-математических наук, профессор кафедры информационных систем и технологий, профессор кафедры информатики, Северо-Кавказский Федеральный Университет, Ставрополь, Российская Федерация.
e-mail: shagrovagv@mail.ru

Струкова Виктория Геннадьевна, Victoria Gennadievna Strukova, аспирант кафедры информационных систем и технологий, Северо-Кавказский Федеральный Университет, Ставрополь, Российская Федерация.
e-mail: vivata.21@mail.ru
ORCID: [0000-0002-1689-784X](https://orcid.org/0000-0002-1689-784X)

Доронин Вадим Александрович, Vadim Aleksandrovich Doronin, аспирант кафедры информационных систем и технологий, Северо-Кавказский Федеральный Университет, Ставрополь, Российская Федерация.
e-mail: v-d0r0n1n@yandex.ru

Статья поступила в редакцию 09.12.2022; одобрена после рецензирования 21.02.2023; принята к публикации 16.03.2023.

The article was submitted 09.12.2022; approved after reviewing 21.02.2023; accepted for publication 16.03.2023.