

<https://doi.org/10.21869/2223-1536-2024-14-1-8-23>



УДК 004.93

Анализ эффективности применения двухэтапных нейросетевых моделей для раннего обнаружения лесных пожаров

А. В. Киселев¹ ✉, Н. С. Брусенцев¹, Е. А. Кулешова¹

¹ Юго-Западный государственный университет
ул. 50 лет Октября, д. 94, г. Курск 305040, Российская Федерация

✉ e-mail: kiselevalexey1990@gmail.com

Резюме

Цель исследования – анализ эффективности двухэтапных нейросетевых моделей для решения задачи обнаружения лесных пожаров на изображениях, полученных с беспилотных летательных аппаратов.

Методы. Синтезирован тренировочный набор данных, предназначенный для обучения нейросетевых моделей с целью детекции и семантической сегментации лесных пожаров на изображениях. Для обучения использовались двухэтапные нейросетевые модели (Faster R-CNN, Mask RCNN ... Retina-Net). Обучение нейросетевых моделей проводилось в соответствии с едиными параметрами, установленными для всех моделей с целью обеспечения согласованности и общей основы экспериментов. Проведена оптимизация параметров моделей в процессе обучения для минимизации функции потерь классификации. Для синтеза тестовой выборки использовался видеоряд, охватывающий события лесных пожаров в Иркутской области, который был снят беспилотным летательным аппаратом. С использованием специально разработанного скрипта на языке программирования Python проведен процесс разбиения данного видеоряда на отдельные кадры, которые использовались в качестве тестового набора данных при оценке качества классификации обученных нейросетевых моделей.

Результаты. На основе анализа полученных значений показателя качества, а также визуального анализа на тестовом наборе данных, произведенного в рамках тестирования нейросетевых моделей, проведена оценка эффективности исследуемых моделей обнаружения лесных пожаров на изображениях. Для оценки качества бинарной классификации нейросетевых моделей использовался показатель качества Accuracy (точность классификации).

Заключение. Экспериментальные исследования на тестовом наборе данных показали, что модель Retina-Net демонстрирует наименьшую по сравнению с другими исследованными нейросетевыми моделями, но приемлемую результативность. Двухэтапные нейросетевые модели Faster R-CNN и Mask R-CNN демонстрируют близкие значения показателя точности классификации (0,9492 и 0,9521 соответственно), что позволяет рекомендовать их для использования в системах раннего обнаружения лесных пожаров.

© Киселев А. В., Брусенцев Н. С., Кулешова Е. А., 2024

Ключевые слова: лесные пожары; сверточная нейронная сеть; нейросетевые модели; классификация объектов на изображении; семантическая сегментация; бинарная классификация; оценка качества бинарной классификации.

Конфликт интересов: Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Киселев А. В., Брусенцев Н. С., Кулешова Е. А. Анализ эффективности применения двухэтапных нейросетевых моделей для раннего обнаружения лесных пожаров // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2024. Т. 14, № 1. С. 8–23. <https://doi.org/10.21869/2223-1536-2024-14-1-8-23>.

Поступила в редакцию 18.01.2024

Подписана в печать 16.02.2024

Опубликована 29.03.2024

Analysis of the Effectiveness of Using Two-Stage Neural Network Models for Early Detection of Forest Fires

Alexey V. Kiselev¹ ✉, Nikita S. Brusencev¹, Elena A. Kuleshova¹

¹ Southwest State University

50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

✉ e-mail: kiselevalexey1990@gmail.com

Abstract

The purpose of the research – analysis of the effectiveness of two-stage neural network models for solving the problem of detecting forest fires in images obtained from unmanned aerial vehicles.

Methods. A training dataset was synthesized for training neural network models for the purpose of detection and semantic segmentation of forest fires in images. Two-stage neural network models ("Faster R-CNN", "Mask RCNN" and "Retina-Net") were used for training. The neural network models were trained according to the same parameters set for all models in order to ensure consistency and a common basis for experiments. Optimization of model parameters during the training process was carried out to minimize the classification loss function. To synthesize the test sample, we used a video sequence covering the events of forest fires in the Irkutsk region, which was filmed by an unmanned aerial vehicle. Using a specially developed script in the Python programming language, the process of dividing this video sequence into separate frames was carried out, which were used as a test data set when assessing the quality of classification of trained neural network models.

Results. Based on the analysis of the obtained values of the quality criterion, as well as visual analysis on the test data set produced as part of testing neural network models, the effectiveness of the studied models for detecting forest fires in images was assessed. To assess the quality of binary classification of neural network models, the quality criterion "Accuracy" (classification accuracy) was used.

Conclusion. Experimental studies on a test data set showed that the Retina-Net model demonstrates the lowest, but acceptable, performance compared to other studied neural network models. The two-stage neural network models "Faster R-CNN" and "Mask R-CNN" demonstrate similar classification accuracy values (0.9492 and 0.9521, respectively), which allows us to recommend them for use in early detection systems for forest fires.

Keywords: forest fires; convolutional neural network; neural network models; classification of objects in the image; semantic segmentation; binary classification; quality assessment of binary classification.

Conflict of interest: The Authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Kiselev A. V., Brusencev N. S., Kuleshova E. A. Analysis of the Effectiveness of Using Two-Stage Neural Network Models for Early Detection of Forest Fires. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie* = *Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2024; 14(1): 8–23. (In Russ.) <https://doi.org/10.21869/2223-1536-2024-14-1-8-23>.

Received 18.01.2024

Accepted 16.02.2024

Published 29.03.2024

Введение

Лесные пожары (ЛП) имеют широкий спектр негативных последствий и являются одной из наиболее актуальных экологических проблем современности. ЛП оказывают существенное воздействие на биоразнообразие, уничтожая флору и фауну, приводя к снижению популяций различных видов. Кроме того, уничтожение природных ресурсов ЛП наносит серьезный вред экономике [1].

Еще одним тревожным аспектом ЛП является их прямое воздействие на человеческую жизнь и здоровье. Задымление и выбросы токсичных веществ, создаваемые ЛП, значительно снижают качество воздуха, что приводит к отравлениям продуктами горения, а также к возникновению риска заболеваний дыхательной системы. Сам огонь также несет опасность для физического здоровья людей, включая возможность ожогов, травм и даже потери жизни [2].

Таким образом, можно сделать вывод, что ЛП являются сложной экологической проблемой, требующей комплексных усилий и междисциплинарного подхода для их предотвращения, контроля и борьбы, с помощью

разработки и внедрения эффективных стратегий пожарной безопасности [3].

Вмешательство человека в природные экосистемы сопровождается изменениями климата и повышением температур, что, в свою очередь, приводит к увеличению интенсивности и распространения ЛП [4].

В свете этих факторов раннее обнаружение и эффективная локализация ЛП становятся необходимостью. Разработка и внедрение передовых технологий и систем дистанционного зондирования, таких как спутниковые системы наблюдения и беспилотные летательные аппараты (БПЛА), позволяют повысить скорость и точность обнаружения ЛП, что, в свою очередь, позволяет ускорить оперативность реагирования [5].

Таким образом, повышение эффективности раннего обнаружения и локализации ЛП является ключевым аспектом в борьбе с ними. Постоянные исследования и инновационные подходы к мониторингу и борьбе с ЛП играют важную роль в сохранении природных ресурсов, защите биоразнообразия и обеспечении безопасности и благополучия человеческого общества [6].

Согласно статистическим данным за 2023 г., приведенным в [7], количество ЛП в России достигло рекордно высоких значений. Эти статистические данные подчеркивают нарастающую потребность в эффективных методах мониторинга и предупреждения ЛП для минимизации их разрушительного воздействия.

Традиционные методы обнаружения ЛП могут быть недостаточно эффективными, поэтому использование новых технологий представляет значительный потенциал для улучшения систем обнаружения ЛП [8].

Применение алгоритмов машинного обучения позволяет значительно повысить эффективность анализа видеоданных с БПЛА для раннего обнаружения и локализации ЛП [9].

В работе [10] описан метод обнаружения ЛП, основанный на объединении традиционных технологий обработки изображений и технологии сверточных нейронных сетей (Convolutional Neural Network, CNN), а также вводится подход адаптивного пула. Проведенные авторами эксперименты показывают, что метод сверточной нейронной сети (СНС), основанный на методе адаптивного пула, имеет лучшую производительность и более высокую скорость распознавания.

В работе [11] авторами предлагается методология обнаружения ЛП, основанная на методах компьютерного зрения и искусственного интеллекта. Для

решения проблем, связанных с длительным временем обучения СНС и неэффективностью предварительно обученных моделей при отсутствии достаточного объема данных, авторы предлагают метод трансферного обучения на предварительно обученных моделях, сопровождаемый использованием метода обучения без «забывания» (Learning without Forgetting). Этот подход предназначен для сохранения прежних способностей модели при новом обучении, предотвращая потерю ее классификационных навыков на исходных данных. Этот метод позволяет улучшить эффективность системы раннего обнаружения ЛП и снизить количество ложных срабатываний, что критически важно для оперативных мер по их ликвидации.

Также следует отметить исследование [12], посвященное проблеме выбора оптимизатора для обучения СНС при решении задачи классификации ЛП. Авторы провели анализ эффективности различных оптимизаторов при обучении СНС для классификации ЛП на изображениях.

В работе [13] авторами проведено исследование применения одноэтапных нейросетевых моделей (НМ) (на примере YOLOv3) для решения задачи обнаружения пожаров на аэрофотоснимках, полученных с БПЛА. Приводится подробное описание процедур конфигурирования набора данных и обучения одноэтапной НМ для обнаружения пожара на фото- и видеоизображениях.

В работе [14] авторами предложен улучшенный метод обнаружения дыма от ЛП, основанный на использовании СНС. Используя усовершенствованную СНС, авторы провели оптимизацию многозначных ядер свертки и внедрили стратегии пакетной нормализации для улучшения функций потерь, что способствовало увеличению эффективности и устойчивости модели. Эксперименты демонстрируют, что предложенная СНС автоматически изучает характеристики дыма на ранних стадиях ЛП с высокой точностью распознавания.

В работе [15] авторы представляют метод раннего обнаружения ЛП, используя подход сегментации на основе метода опорных векторов (Support Vector Machine) и две архитектуры СНС (VGG16 и ResNet50) на обучающем наборе данных.

В работе [16] авторы предлагают кэшированную СНС, направленную на ускорение обнаружения ЛП. Эта модель классифицирует входные изображения, основываясь на их сходстве с предыдущими изображениями, что повышает эффективность обнаружения.

В работе [17] предложенный авторами метод направлен на обнаружение пожаров в горных условиях и основан на применении СНС с использованием метода аугментации изображения. Также в рамках исследования проводится анализ воздействия аугментации изображения в различных пространственных областях на точность обнаружения пожаров.

Результаты исследования демонстрируют, что оптимизированная СНС, применяющая несколько различных методов аугментации изображения, способна повысить точность обнаружения ЛП по сравнению со СНС, в которой отсутствует аугментация данных.

В работе [18] авторы предлагают метод обнаружения ЛП с использованием глубокого обучения на основе модели SqueezeNet. Предложенный метод использует статические изображения из лесных районов с разными погодными условиями для классификации наличия или отсутствия пожара.

В работе [19] авторы подходят к проблеме ЛП, предлагая оптимизированный метод обнаружения на основе глубокого обучения. Рассматриваются архитектуры СНС для семантической сегментации изображений ЛП. Четыре модели семантической сегментации тщательно анализируются с использованием набора данных, содержащего снимки дистанционного зондирования ЛП, полученных с БПЛА.

В работе [20] авторы представляют метод обнаружения ЛП с использованием СНС, интегрированной в вычислительное устройство Raspberry Pi. В работе рассматривается проблема детекции ЛП, для ее решения предложена модель СНС, которая успешно интегрируется в аппаратное обеспечение Raspberry Pi. Этот подход позволяет обеспечить эффективное обнаружение ЛП с

минимальным использованием вычислительных ресурсов.

Таким образом, в контексте существующих исследований задача обнаружения и классификации объектов на изображении, в частности ЛП, ориентирована на применение и сравнение различных моделей нейронных сетей и оценку их эффективности в реальных условиях. Важным моментом является также оценка качества классификации, которая имеет непосредственное влияние в вопросе оперативного решения проблемы ранней локализации ЛП.

Материалы и методы

Задача обнаружения и классификации объектов на изображении представляет собой область машинного обучения, направленную на выявление присутствия или отсутствия объектов в определенной области на изображении. Эта задача включает в себя определение границ объекта в системе координат пикселей исходного изображения.

Для решения поставленной задачи был синтезирован тренировочный набор данных, предназначенный для обучения нейросетевых моделей (НМ) с целью детекции и семантической сегментации ЛП на изображениях. Данный набор данных был сформирован из 5915 фотографий, полученных из открытых источников, специально отобранных в соответствии с темой исследования.

Тренировочный набор данных был разделен на две ключевые части —

тренировочную и валидационную выборку. Такой подход обеспечивает возможность эффективного обучения НМ на разнообразных данных, а также последующей проверки качества классификации на независимой валидационной выборке.

Дополнительно к разделению на выборки была проведена аугментация данных с использованием различных техник, таких как изменение масштаба, повороты и отражения. Этот этап предназначен для обогащения данных и способствует увеличению разнообразия обучающего набора и улучшению обобщающей способности НМ.

Кроме того, тренировочный набор данных был модернизирован для обучения НМ, связанной с семантической сегментацией. Этот этап включал в себя дополнительную разметку данных с использованием сегментационных масок, что позволяет НМ выделять области ЛП на изображениях с высокой точностью.

Таким образом, описанный тренировочный набор данных представляет собой основной инструмент для обучения НМ, направленных на автоматическое обнаружение и сегментацию ЛП, а проведенные процессы разделения, аугментации и модернизации способствуют формированию разнообразного обучающего набора, позволяющего провести эффективное обучение.

Обучение НМ проводилось в соответствии с едиными параметрами, установленными для всех моделей с целью

обеспечения согласованности и общей основы экспериментов. Параметры обучения были тщательно выбраны для оптимальной сходимости и высокого качества результатов.

Для обучения использовались двухэтапные (Faster R-CNN, Mask RCNN и Retina-Net) НМ. Каждая НМ была настроена на решение задачи детекции ЛП.

Параметры обучения:

1. Максимальное количество итераций обучения было установлено на уровне 2000, который является достаточным для эффективного обучения.

2. Оценка НМ на тестовом наборе данных выполнялась периодически – каждые 200 итераций, что позволяет оценить прогресс и качество обучения в процессе выполнения эксперимента.

3. Базовая скорость обучения была установлена на уровне 0,001, что обеспечивает стабильность и конвергенцию в процессе оптимизации весов НМ.

4. Количество изображений в пакете было установлено равным 64, что обеспечивает баланс между высокой информативностью и эффективностью обучения.

5. Использовался двоичный формат масок, что позволяет эффективно представлять пространственную информацию о местоположении объектов на изображениях.

Проведена оптимизация параметров НМ в процессе обучения для мини-

мизации функции потерь (ФП) классификации. В бинарной классификации используется двоичная ФП, которая определяется как

$$f(\hat{y}, y) = \begin{cases} 1, & \hat{y} \neq y, \\ 0, & \hat{y} = y, \end{cases} \quad (1)$$

где \hat{y} – рассматриваемый элемент; y – эталонный элемент класса.

Таким образом, потери определяются появлением двух взаимоисключающих состояний выхода НМ.

ФП Loss Box Regression применяется для измерения расхождения между предсказанными координатами ограничивающих рамок и их истинными значениями. Для определения достоверности местоположения ограничивающей рамки используется отношение площадей ограничивающих рамок (Intersection over Union, IoU):

$$IoU = \frac{S(A \cap B)}{S(A \cup B)}, \quad (2)$$

где A и B – предсказанная ограничивающая рамка и настоящая ограничивающая рамка соответственно; $IoU = 0$, если A и B не пересекаются; $IoU = 1$ – в случае идеального наложения.

Высокие значения данной ФП могут свидетельствовать о недостаточной точности определения координат ограничивающих рамок НМ. Графическое представление ФП Loss Box Regression, полученных в ходе обучения двухэтапных НМ, изображено ниже (рис. 1).




Рис. 1. ФП Loss Box Regression для двухэтапных моделей

Fig. 1. Loss Box Regression function for two-stage models

Функция общих потерь для двухэтапных НМ (total_loss) представляет собой сумму всех компонентов потерь в процессе обучения. Функция отражает

общую эффективность НМ, учитывая как потери классификации, так и потери регрессии (рис. 2).




Рис. 2. Функция общих потерь для двухэтапных моделей

Fig. 2. Total loss function for two-stage models

Результаты и их обсуждение

После обучения НМ был проведен ряд экспериментов на тестовой выборке. Тестовая выборка представляет собой видеоряд, снятый БПЛА, который охватывает события ЛП в Иркутской области. С использованием специально разработанного скрипта на

языке программирования Python был проведен процесс разбиения данного видеоряда на отдельные кадры. Эти кадры использовались в качестве тестового набора данных при оценке качества классификации обученных НМ. Данный подход позволил систематизировать и стандартизировать тестовые

данные и обеспечить надежные исходные материалы для оценки алгоритмов обнаружения ЛП.

Рассмотрим визуализацию результатов обнаружения ЛП, полученных НМ Retina-Net (рис. 3).



Рис. 3. Результаты обнаружения НМ Retina-Net

Fig. 3. Detection results of the neural network model Retina-Net

Визуализация результатов обнаружения ЛП, полученных НМ Faster R-CNN, представлена ниже (рис. 4).

Рассмотрим визуализацию результатов обнаружения ЛП, полученных НМ Mask R-CNN (рис. 5).

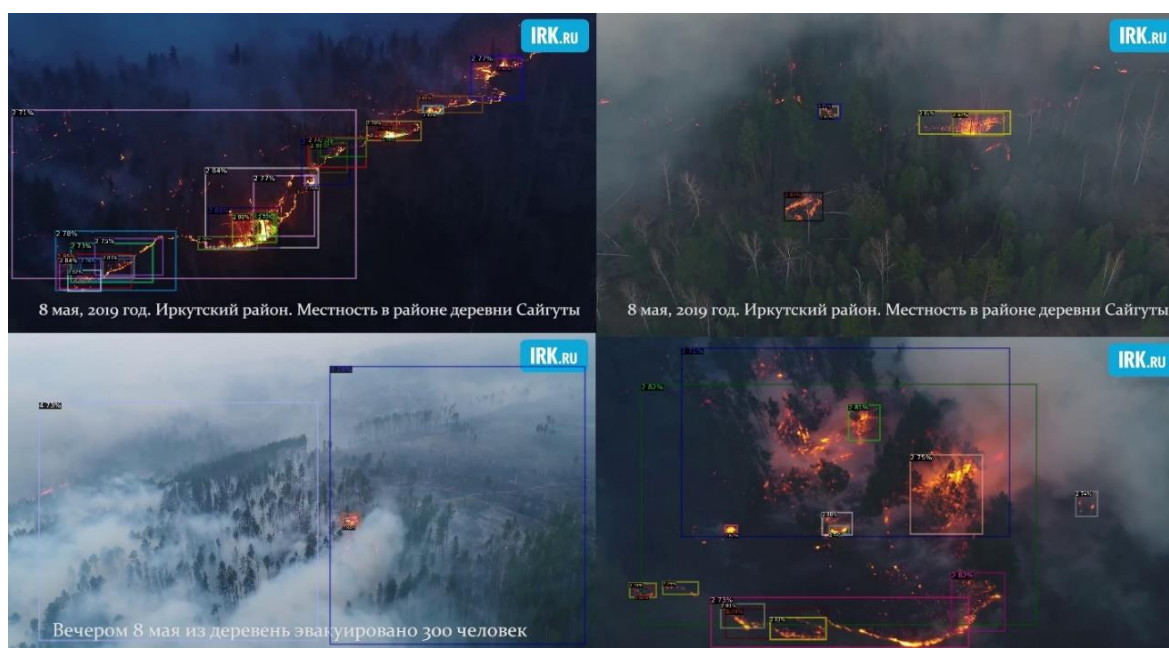


Рис. 4. Результаты обнаружения НМ Faster R-CNN

Fig. 4. Detection results of the neural network model Faster R-CNN



Рис. 5. Результаты сегментации NM Mask R-CNN

Fig. 5. Detection results of the neural network model Mask R-CNN

Показатель качества классификации должен выбираться таким образом, чтобы он зависел как от ошибок первого, так и второго рода, а недопустимо большие ошибки хотя бы одного вида снижали бы показатель качества классификации к недопустимым значениям [21].

Для оценки качества бинарной классификации по обучающей выборке $\{(x_i, y_i)\}_{i=1}^N$ при $y_i \in \{0,1\}$ НМ, которые по объекту x предсказывают принадлежность класса $f(x) \in \{0,1\}$, использовался показатель качества Accuracy (точность классификации). Данный показатель определяется следующим образом:

$$Accuracy(y, \hat{y}) = \frac{1}{N} \sum_{i=1}^N [y_i = f(x_i)]. \quad (3)$$

Рассмотрим графическое представление оценки качества классификации с

помощью показателя качества Accuracy для двухэтапных НМ (рис. 6).

На основе анализа полученных значений показателя качества, а также визуального анализа на тестовом наборе данных, произведенного в рамках тестирования НМ, можно сделать вывод о степени эффективности исследуемых моделей для обнаружения ЛП на изображениях. При углубленном рассмотрении результатов тестирования установлено, что модель Retina-Net демонстрирует наименьшие значения показателя точности классификации (0,879) по сравнению с другими исследованными НМ. Визуальный анализ результатов классификации с помощью НМ Retina-Net подтверждает ее наименьшую, но приемлемую результативность.




Рис. 6. Результаты оценки качества классификации двухэтапных моделей

Fig. 6. Results of assessing the quality of classification of two-stage models

НМ Faster R-CNN и Mask R-CNN демонстрируют близкие значения показателя точности классификации (0,9492 и 0,9521 соответственно), что также подтверждается визуальным анализом результатов классификации на тестовых изображениях.

Выводы

Синтезирован тренировочный набор данных, предназначенный для обучения двухэтапных НМ (Faster R-CNN, Mask RCNN и Retina-Net) с целью детекции и семантической сегментации ЛП на изображениях. Проведена оптимизация параметров моделей в процессе обучения для минимизации функции потерь классификации.

Проведен ряд экспериментов на тестовой выборке, синтезированной с

помощью специально разработанного скрипта.

Проведен анализ эффективности двухэтапных НМ для обнаружения ЛП на изображениях, полученных с БПЛА. Для оценки эффективности обнаружения ЛП на изображениях использовался показатель качества Accuracy (точность классификации). Экспериментальные исследования на тестовом наборе данных показали, что модель Retina-Net демонстрирует наименьшую по сравнению с другими исследованными НМ, но приемлемую результативность. Двухэтапные НМ Faster R-CNN и Mask R-CNN демонстрируют близкие значения показателя точности классификации (0,9492 и 0,9521 соответственно), что позволяет рекомендовать их для использования в системах раннего обнаружения ЛП.

Список литературы

1. Сибиркина А. Р., Лихачев С. Ф. О лесных пожарах в лесах Челябинской области за 2018-2021 годы и анализ требований к воспроизводству лесов в лесохозяйственном регламенте // Лесной вестник. 2023. Т. 27, № 5. С. 60–73. <https://doi.org/10.18698/2542-1468-2023-5-60-73>.
2. Yang L., Yusheng S. Estimates of Global Forest Fire Carbon Emissions Using FY-3 Active Fires Product // Atmosphere. 2023. Vol. 14, N 10. P. 1575. <https://doi.org/10.3390/atmos14101575>.
3. Ecological Impact of Forest Fires and Subsequent Restoration in Chile / V. Luz [et. al.] // Resources. 2018. Vol. 7, N 2. P. 26. <https://doi.org/10.3390/resources7020026>.
4. Конькова Ю. М. Лесные пожары как фактор утраты функций лесных экосистем // Новости науки в АПК. 2021. № 2. С. 111–13. <https://doi.org/10.25930/2218-855x/029.2.2021>.
5. Ковалев Р. Н., Еналеева-Бандура И. М., Никончук А. В. Оценка влияния пожаров на лесные экосистемы с учетом уровня развития лесотранспортной сети // Известия вузов. Лесной журнал. 2021. № 4. С. 131–149. <https://doi.org/10.37482/0536-1036-2021-4-131-149>.
6. Евдокименко М. Д., Кривобоков Л. В., Петренко А. Е. Лесозэкологические последствия ландшафтных пожаров в Забайкалье // Вестник Томского государственного университета. Биология. 2022. № 58. С. 153–180. <https://doi.org/10.17223/19988591/58/8>.
7. РБК (РосБизнесКонсалтинг). URL: <https://www.rbc.ru/rbcfreenews/64dcd6519a79472d7611c76f?ysclid=lowv68ywr7525405056> (дата обращения: 22.12.2023).
8. Метод и алгоритм автономного планирования траектории полета беспилотного летательного аппарата при мониторинге пожарной обстановки в целях раннего обнаружения источника возгорания / Р. А. Томакова, С. А. Филист, А. Н. Брежнева [и др.]. // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2023. Т. 13, № 1. С. 93–110. <https://doi.org/10.21869/2223-1536-2023-13-1-93-110>.
9. Интеллектуальная система обработки изображений, получаемых с беспилотных летательных аппаратов / С. А. Филист, Р. А., Томакова Н. Г. Нефедов [и др.]. // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2022. Т. 12, № 4. С. 64–85. <https://doi.org/10.21869/2223-1536-2022-12-4-64-85>.
10. Yuanbin W., Langfei D., Jieying R. Forest fire image recognition based on convolutional neural network // Journal of Algorithms & Computational Technology. 2019. Vol. 13. P. 1–11. <https://doi.org/10.1177/1748302619887689>.

11. Forest fire and smoke detection using deep learning-based learning without forgetting / V. E. Sathishkumar [et. al.] // *Fire Ecology*. 2023. Vol. 19, N 9. <https://doi.org/10.1186/s42408-022-00165-0>.
12. Журавлева Н. А. Выбор оптимизатора для обучения сверточной нейронной сети: задача классификации лесных пожаров // *StudNet*. 2022. № 5. С. 4722–4737.
13. Шарапов А. А., Дамдынчап Ч. А. Применение нейронных сетей для распознавания дыма и пожара на изображениях // *Интерэкспо Гео-Сибирь*. 2021. № 2. С. 38–43.
14. Xiaofang S., Liping S., Yinglai H. Forest fire smoke recognition based on convolutional neural network // *J. For. Res.* 2021. N 32. P. 1921–1927. <https://doi.org/10.1007/s11676-020-01230-7>.
15. Environmental harm mitigation based on early forest fire detection using Deep CNN / R. I. Bendjillali [et. al.] // *The second International Conference on Energy Transition and Security*. Adrar, Algeria, 2023.
16. Nguyen T. L., Afanasiev D. A., Nguyen T. H. Segmentation of Forest Fire Images Based on Convolutional Neural Networks // *International Journal of Artificial Intelligence*. 2021. N 19. P. 21–35.
17. Forest Fire Detection Method Based on Convolutional Neural Network with Data Augmentation Optimization / L. Qilin [et. al.] // *Proceeding of 2022 International Conference on Wireless Communications, Networking and Applications (WCNA 2022)*. P. 769–776. https://doi.org/10.1007/978-981-99-3951-0_84.
18. An Efficient Model for Forest Fire Detection using Deep Convolutional Neural Networks / B. Anjanadevi [et. al.] // *International Journal on Recent and Innovation Trends in Computing and Communication*. 2023. Vol. 11, N 10. P. 177–181. <https://doi.org/10.17762/ijritcc.v11i10s.7617>.
19. Ziqi W., Tao P., Zhaoyou L. Comparative Research on Forest Fire Image Segmentation Algorithms Based on Fully Convolutional Neural Networks // *Forests*. 2022. Vol. 13, N 7. P. 1133. <https://doi.org/10.3390/f13071133>.
20. Forest Fire Detection and Prediction System Using Deep Learning and IOT / P. Deshmukh [et. al.] // *Soft Computing for Security Applications*. 2023. Vol. 1449. P. 813–828. https://doi.org/10.1007/978-981-99-3608-3_56.
21. Модели латентных предикторов в интеллектуальных системах прогнозирования состояния живых систем / А. В. Киселев, О. В. Шаталова, З. У. Протасова [и др.] // *Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение*. 2020. Т. 10, № 1. С. 114–133.

References

1. Sibirskina A. R., Lihachev S. F. O lesnyh pozharah v lesah Chelyabinskoy oblasti za 2018–2021 gody i analiz trebovaniy k vosproizvodstvu lesov v lesokhozyajstvennom reglamente [On forest fires in the forests of the Chelyabinsk region for 2018–2021 and analysis of requirements for forest reproduction in forest management regulations]. *Lesnoj vestnik = Forest Bulletin*, 2023, vol. 27, no. 5, pp. 60–73. <https://doi.org/10.18698/2542-1468-2023-5-60-73>
2. Yang L., Yusheng S. Estimates of Global Forest Fire Carbon Emissions Using FY-3 Active Fires Product. *Atmosphere*, 2023, vol. 14, p. 1575. <https://doi.org/10.3390/atmos14101575>
3. Luz V., eds. Ecological Impact of Forest Fires and Subsequent Restoration in Chile. *Resources*, 2018, vol. 7, no. 2, p. 26. <https://doi.org/10.3390/resources7020026>
4. Konkova Yu. M. Lesnyye pozhary, kak faktor utraty funktsiy lesnykh ekosistem [Forest fires as a factor in the loss of functions of forest ecosystems]. *Novosti nauki v APK = Science News in the Agro-Industrial Complex*, 2021, vol. 2, pp. 111–113. <https://doi.org/10.25930/2218-855x/029.2.2021>
5. Kovalev R. N., Enaleeva-Bandura I. M., Nikonchuk A. V. Ocenka vliyaniya pozharov na lesnye ekosistemy s uchetom urovnya razvitiya lesotransportnoy seti [Assessment of fire impact on forest ecosystems taking into account the level of forest transportation network development]. *Izvestiya vuzov. Lesnoj zhurnal = Proceedings from Universities. Forestry Journal*, 2021, vol. 4, pp. 131–49. <https://doi.org/10.37482/0536-1036-2021-4-131-149>
6. Evdokimenko M. D., Krivobokov L. V., Petrenko A. E. Lesoekologicheskie posledstviya landshaftnykh pozharov v Zabajkal'e [Forest-ecological consequences of landscape fires in Transbaikalia]. *Vestnik Tomskogo gosudarstvennogo universiteta. Biologiya = Bulletin of Tomsk State University. Biology*, 2020, no. 58, pp. 153–180. <https://doi.org/10.17223/19988591/58/8>
7. RBK (RosBiznesKonsalting) [RBC (RosBusinessConsulting)]. Available at: <https://www.rbc.ru/rbcfreenews/64dcd6519a79472d7611c76f?ysclid=lowv68ywr7525405056>. (accessed 22.12.2023)
8. Tomakova R. A., Filist S. A., Brezhneva A. N., eds. Metod i algoritm avtonomnogo planirovaniya trayektorii poleta bespilotnogo letatel'nogo apparata pri monitoringe pozharnoy obstanovki v tselyakh rannego obnaruzheniya istochnika vozgoraniya [Method and algorithm for autonomous planning of the flight path of an unmanned aerial vehicle when monitoring fire conditions for the purpose of early detection of a fire source]. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravleniye, vychislitel'naya tekhnika, informatika. Meditsinskoye priborostroyeniye = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*, 2023, vol. 13, no. 1, pp. 93–110. <https://doi.org/10.21869/2223-1536-2023-13-1-93-110>

9. Filist S. A., Tomakova R. A., Nefedov N. G., eds. Intellectual'naya sistema obrabotki izobrazheniy, poluchayemykh s bespilotnykh letatel'nykh apparatov [Intelligent system for processing images received from unmanned aerial vehicles]. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravleniye, vychislitel'naya tekhnika, informatika. Meditsinskoye priborostroyeniye = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*, 2022, vol. 12, no. 4, pp. 64–85. <https://doi.org/10.21869/2223-1536-2022-12-4-64-85>
10. Yuanbin W., Langfei D., Jieying R. Forest fire image recognition based on convolutional neural network. *J. of Algorithms & Computational Technology*, 2019, vol. 13, pp. 1–11. <https://doi.org/10.1177/1748302619887689>
11. Sathishkumar V. E., eds. Forest fire and smoke detection using deep learning-based learning without forgetting. *Fire Ecology*, 2023, vol. 19, no. 9. <https://doi.org/10.1186/s42408-022-00165-0>
12. Zhuravleva N. A. Vybory optimizatora dlya obucheniya svertochnoy neyronnoy seti: zadacha klassifikatsii lesnykh pozharov [Optimizer selection for training convolutional neural network: forest fire classification task]. *StudNet*, 2022, no. 5, pp. 4722–4737.
13. Sharapov A. A., Damdynchap Ch. A. Primeneniye neyronnykh setej dlya raspoznavaniya dyma i pozhara na izobrazheniyah [Application of neural networks for recognizing smoke and fire in images]. *Interekspo Geo-Sibir' = Interexpo Geo-Siberia*, 2021, no. 2, pp. 38–43.
14. Xiaofang S., Liping S., Yinglai H. Forest fire smoke recognition based on convolutional neural network. *J. For. Res.*, 2021, no. 32, pp. 1921–1927. <https://doi.org/10.1007/s11676-020-01230-7>
15. Bendjillali R. I., eds. Environmental harm mitigation based on early forest fire detection using Deep CNN. The Second International Conference on Energy Transition and Security. Adrar, Algeria, 2023.
16. Nguyen T. L., Afanasiev D. A., Nguyen T. H. Segmentation of Forest Fire Images Based on Convolutional Neural Networks. *International Journal of Artificial Intelligence*, 2021, no. 19, pp. 21–35.
17. Qilin L., eds. Forest Fire Detection Method Based on Convolutional Neural Network with Data Augmentation Optimization. Proceeding of 2022 International Conference on Wireless Communications, Networking and Applications (WCNA 2022), pp. 769–776. https://doi.org/10.1007/978-981-99-3951-0_84
18. Anjanadevi B., eds. An Efficient Model for Forest Fire Detection using Deep Convolutional Neural Networks. *International Journal on Recent and Innovation Trends in Computing and Communication*, 2023, vol. 11, no. 10, pp. 177–181. <https://doi.org/10.17762/ijritcc.v11i10s.7617>

19. Ziqi W., Tao P., Zhaoyou L. Comparative Research on Forest Fire Image Segmentation Algorithms Based on Fully Convolutional Neural Networks. *Forests*, 2022, vol. 13, no. 7, pp. 1133. <https://doi.org/10.3390/f13071133>
20. Deshmukh P., eds. Forest Fire Detection and Prediction System Using Deep Learning and IOT. *Soft Computing for Security Applications*, 2023, vol. 1449, pp. 813–828. https://doi.org/10.1007/978-981-99-3608-3_56
21. Kiselev A. V., Shatalova O. V., Protasova Z. U., eds. Modeli latentnykh prediktorov v intellektual'nykh sistemakh prognozirovaniya sostoyaniya zhivyykh sistem [Models of latent predictors in intelligent systems for predicting the state of living systems]. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravleniye, vychislitel'naya tekhnika, informatika. Meditsinskoye priborostroyeniye = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*, 2020, vol. 10, no. 1, pp. 114–133.

Информация об авторах / Information about the Authors

Киселев Алексей Викторович, кандидат технических наук, доцент кафедры вычислительной техники, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: kiselevalexey1990@gmail.com, ORCID: 0000-0001-7228-0281

Alexey V. Kiselyov, Candidate of Sciences (Engineering), Associate Professor of the Department of Computer Engineering, Southwest State University, Kursk, Russian Federation, e-mail: kiselevalexey1990@gmail.com, ORCID: 0000-0001-7228-0281

Брусенцев Никита Сергеевич, студент кафедры вычислительной техники, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: brusencev2001@yandex.ru, ORCID: 0009-0008-7805-2819

Nikita S. Brusencev, Student of the Department of Computer Engineering, Southwest State University, Kursk, Russian Federation, e-mail: brusencev2001@yandex.ru, ORCID: 0009-0008-7805-2819

Кулешова Елена Александровна, кандидат технических наук, доцент кафедры информационной безопасности, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: lena.kuleshova.94@mail.ru, ORCID: 0000-0002-8270-564X

Elena A. Kuleshova, Candidate of Sciences (Engineering), Associate Professor of the Department of Information Security, Southwest State University, Kursk, Russian Federation, e-mail: lena.kuleshova.94@mail.ru, ORCID: 0000-0002-8270-564X