

Выделение пламени и дыма на изображениях, полученных камерами БПЛА в системе раннего обнаружения лесных пожаров

А.Э. Беляев^{1а}, Е.А. Будевич^{1б}, Н.Р. Вычерова^{2с}

¹ Ухтинский государственный технический университет, ул. Первомайская, 13, Ухта, Республика Коми

² ООО «Газпром недра» ПФ «Вуктылгазгеофизика», ул. Моторная, 7а, Ухта, Республика Коми

^а belandre@yandex.ru, ^б nshol@ugtu.net, ^с nvycherova@ugtu.net

^а <https://orcid.org/0000-0002-3936-0076>, ^б <https://orcid.org/0000-0003-1072-7687>, ^с <https://orcid.org/0000-0001-9631-4300>

Статья поступила 10.10. 2022, принята 26.10.2022

В связи с глобальным потеплением увеличивается и риск возникновения пожаров. Количество лесных пожаров растет и будет расти дальше. Для лучшей поддержки противопожарных служб на местности предлагаем свою систему раннего обнаружения лесных пожаров. Поскольку лесные пожары во всем мире становятся все более частыми и серьезными, насущной необходимостью является разработка надежной, непрерывной и надежной системы обнаружения лесных пожаров, а подход на основе беспилотных летательных аппаратов (БПЛА) может устранить все ограничения существующих методов. Успешная реализация алгоритма обнаружения пожара, устойчивого к условиям окружающей среды и обладающего высокой точностью, в сочетании с безопасными стратегиями управления полетом БПЛА может сделать обнаружение лесных пожаров на основе БПЛА наиболее предпочтительным выбором. В настоящее время БПЛА оснащены разными средствами наблюдения, при необходимости дополнительно на них можно установить разного назначения приборы и датчики. По своим техническим характеристикам БПЛА могут находиться в рабочем (летном) состоянии от нескольких десятков минут до нескольких часов, что не может не сказываться на качестве получаемых результатов. Передача сигналов на сервер для обработки и аналитики ситуации в районе полета БПЛА также зависит от времени эксплуатации аппарата, поэтому надо уделять особое внимание техническому обслуживанию устройства. Немаловажным фактором в обработке данных, полученных с БПЛА, является качество изображения полученных данных.

Ключевые слова: обнаружение лесных пожаров; цветовые пространства; нейросети; беспроводная сенсорная сеть; глубокое обучение; БПЛА.

The release of flame and smoke in images obtained by UAV cameras in the forest fire early detection system

A.E. Belyaev^{1а}, E. A. Budevich^{1б}, N. R. Vycherova^{2с}

¹ Ukhta State Technical University; 13, Pervomayskaya St., Ukhta, Republic of Коми

² «Gazprom Nedra» LLC, «Vuktylgazgeofizika» PF; 7a, Motornaya St., Ukhta, Republic of Коми

^а belandre@yandex.ru, ^б nshol@ugtu.net, ^с nvycherova@ugtu.net

^а <https://orcid.org/0000-0002-3936-0076>, ^б <https://orcid.org/0000-0003-1072-7687>, ^с <https://orcid.org/0000-0001-9631-4300>

Received 10.10. 2022, accepted 26.10.2022

Due to global warming, the risk of fires is also increasing. The number of forest fires is growing and will continue to grow. To better support fire services on the ground, we offer our own system for early detection of forest fires. As forest fires around the world are becoming more frequent and serious, it is imperative to develop a reliable, continuous and reliable forest fire detection system, and a UAV-based approach can eliminate all the limitations of existing methods. The successful implementation of a fire detection algorithm that is resistant to environmental conditions and has high accuracy, combined with safe UAV flight control strategies, can make the detection of forest fires based on UAVs the most preferred choice. Currently, unmanned aerial vehicles are equipped with various means of observation, if necessary, devices and sensors can be installed on them for various purposes. According to their technical characteristics, UAVs can be in working (flight) condition from several tens of minutes to several hours, which cannot but affect the quality of the results obtained. The transmission of signals to the server for processing and analyzing the situation in the UAV flight area also depends on the time of operation of the device, therefore, special attention should be paid to the maintenance of the device. An important factor in the processing of data received from UAVs is the image quality of the received data.

Keywords: forest fire detection; color spaces; neural networks; wireless sensor network; deep learning; UAV.

В настоящее время в мире предложено достаточно много инновационных методов для создания точной системы обнаружения пожара. Популярными системами обнаружения лесных пожаров, основанные на системах мониторинга спутниковых изображений, таких как MODIS (спектрорадиометр среднего разрешения) и

AVHRR (усовершенствованный радиометр очень высокого разрешения). Низкое разрешение спутников и большой период сканирования ограничивают эффективность спутникового обнаружения лесных пожаров [1–3; 19–20].

В работах [18; 20] предложена система обнаружения пожара на основе беспроводной сети с несколькими датчиками, в которой для обнаружения возгорания используются IP-камеры. IP-камеры нуждаются в прямой видимости связи с датчиками. Также эти IP-камеры для достаточно хорошего обзора должны быть размещены на большой высоте.

Существуют также системы, основанные на ЛИДАР — измерение обратного рассеяния лазерного луча частицами дыма. Ограничением этой системы является высокий уровень ложных срабатываний из-за климатических условий, например, близость тумана, чистых частиц, теней и т. д.

Многие исследователи проводили работу по раннему обнаружению возгорания с использованием беспроводной сенсорной сети (WSN). Например, в Южной Корее система идентификации лесных пожаров определяет температуру и влажность, а веб-приложение анализирует собранную информацию, отправленную датчиками. *Alper Rifat* использует тот же принцип WSN и предлагает алгоритм обнаружения пожара на основе температуры. Эти системы предназначены для обнаружения только по двум параметрам, температуре и влажности, однако могут существовать и другие параметры, которые могут влиять, например, ветер [7; 19; 21].

Эти системы пожарного наблюдения не обеспечивают своевременного обнаружения из-за длительного периода сканирования и не осуществляют постоянное наблюдение за лесной территорией. Учитывая упомянутые ограничения существующих систем, наиболее важным вопросом в системе обнаружения лесных пожаров является немедленное реагирование, чтобы свести к минимуму ущерб и потери. Следовательно, необходимо иметь масштабируемое решение, которое может обеспечивать обнаружение пожаров в режиме реального времени, обнаруживать лесные пожары на ранней стадии и

снижать количество ложных срабатываний.

Предлагаемая система использует методы машинного обучения. Функциональность искусственного интеллекта широко используется во всех секторах, таких как сельское хозяйство, здравоохранение и промышленность. Алгоритмы искусственного интеллекта могут обнаруживать отношения и модели, которые могут ускользнуть от нас. Таким образом, с помощью этих алгоритмов система может прогнозировать возгорание с высокой точностью.

Цветовые пространства. Пламя и дым в отдельности отличаются сильными, хотя и не уникальными цветовыми особенностями. Цвет пламени может быть красным, оранжевым или желтым, а цвет дыма — от беловато-серого до черновато-серого. Несмотря на эти широкие межклассовые и внутриклассовые вариации, цвет по-прежнему является одним из наиболее значимых признаков для выделения пламени и дыма. Как правило, изображения записываются в цветовом режиме RGB (R — красный, G — зеленый, B — голубой). На рис. 1 приведен пример аэрофотоснимка в цветовом режиме RGB, используемого для обучения классификатора, с последующим его представлением в каждом из трех каналов (см. рис. 2).



Рис. 1. Пример фотографии для обучения в цветовом режиме RGB



R

G

B

Рис. 2. Результат разбиения на каналы RGB

Рис. 2 демонстрирует один из недостатков использования цветового пространства RGB для обнаружения пламени и дыма. Можно заметить, что небо на заднем плане и пиксели пламени насыщены как в R-, так и в G-канале. Это связано с тем, что в цветовом пространстве RGB яркость и цветность не разделяются. Чтобы обойти данное ограничение, лучше

преобразовать изображения в цветовые пространства YCbCr, HSV или CIE Lab (CIE 1976 L*a*b*). На рис. 3 показано разбиение на цветовые каналы: Y, Cb, Cr; H, S, V; L, a и b. Видно, что цветовая информация о дыме и пламени выделяется в каналах Cb, Cr, H, S, a и b, в то время как в каналах Y, S и L выделяется яркость пламени.




Рис. 3. Результат разбиения на каналы Y, Cb, Cr, V, S, H, L, a и b

Цветовое пространство HSV имитирует восприятие цвета человеческим глазом (H — оттенок, это чистый цвет пикселя; S — насыщенность, V — яркость). Цветовое пространство YCbCr: Y — компонент яркости; Cb — синий цвет, вычитаемый из яркости; Cr — красный цвет, вычитаемый из яркости. Точно так же

в цветовом пространстве CIE Lab: L — шкала измерения светлоты от 0 до 100; a — шкала от зеленого до красного цвета; b — шкала от синего до желтого.

Математические уравнения для преобразования RGB в HSV, YCbCr и CIE Lab следующие:

$$h = \begin{cases} 0, & \text{если } \max(R, G, B) = \min(R, G, B) \\ \left(60^\circ \times \frac{g - b}{\max(R, G, B) - \min(R, G, B)} + 0^\circ\right) \bmod 360^\circ, & \text{если } \max(R, G, B) = r \\ \left(60^\circ \times \frac{b - r}{\max(R, G, B) - \min(R, G, B)} + 120^\circ\right) \bmod 360^\circ, & \text{если } \max(R, G, B) = g \\ \left(60^\circ \times \frac{r - g}{\max(R, G, B) - \min(R, G, B)} + 240^\circ\right) \bmod 360^\circ, & \text{если } \max(R, G, B) = b \end{cases} \quad (1)$$

$$h = \begin{cases} 0, & \text{если } \max(R, G, B) = 0 \\ \frac{\max(R, G, B) - \min(R, G, B)}{\max(R, G, B)} = 1 - \frac{\min(R, G, B)}{\max(R, G, B)} \end{cases} \quad (2)$$

иначе:

$$v = \max(R, G, B) \quad (3)$$

$$Y = 0,299R + 0,587G + 0,114B \quad (4)$$

$$Cb = B - Y \quad (5)$$

$$Cr = R - Y \quad (6)$$

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0,412453 & 0,357580 & 0,180423 \\ 0,212671 & 0,715160 & 0,072169 \\ 0,019334 & 0,119193 & 0,950227 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (7)$$

$$L = \begin{cases} 116 \times \left(\frac{Y}{Y_n}\right)^{\frac{1}{3}} - 16, & \text{если } \frac{Y}{Y_n} > 0,008856 \\ 116 \times \frac{Y}{Y_n}, & \text{если } \frac{Y}{Y_n} \leq 0,008856 \end{cases} \quad (8)$$

$$a = 500 \times \left\{ \left(\frac{X}{X_n}\right)^{\frac{1}{3}} - \left(\frac{Y}{Y_n}\right)^{\frac{1}{3}} \right\} \quad (9)$$

$$b = 200 \times \left\{ \left(\frac{Y}{Y_n}\right)^{\frac{1}{3}} - \left(\frac{Z}{Z_n}\right)^{\frac{1}{3}} \right\} \quad (10)$$

где X_n, Y_n и Z_n — координаты цвета.

Для предлагаемого алгоритма идентификации областей пламени и дыма и отделения их от других ярких природных объектов из каждого блока получают средние значения цветовых пространств S_b, S_r, H, S, V , а и b . Наряду с этими функциями для идентификации небольших пикселей пламени, присутствующих в блоке, также извлекаются максимальные значения значений Y, S_r, H, S, a и b из каждого блока [5; 6; 8; 10; 12; 13; 15; 21].

Текстурные особенности. Хотя цветовые признаки и являются мощным инструментом выявления потенциальных блоков пламени и дыма, они также могут вызывать ложные срабатывания тревоги, обнаруживая в окружающей среде схожие по цвету объекты. Чтобы отделить эти объекты от пламени и дыма, необходимо выделить больше отличительных признаков. Как правило, дым и пламя имеют колеблющиеся значения пикселей в пределах заданной области, что обуславливает их грубую текстуру. С другой стороны, похожие цветные объекты, такие как красные, желтые или оранжевые цветы, красные автомобили, осенние листья, дорожные покрытия и т. д. имеют гладкую поверхность, а значения пикселей не колеблются так сильно. Таким образом, особенности

текстуры могут показать, имеет ли рассматриваемая область гладкую или шероховатую поверхность. Предлагается матрица совпадения уровней серого (GLCM) и локальный двоичный шаблон (LBP) качестве экстракторов текстурных признаков наряду с дисперсией в цветовом пространстве S_b .

Матрица совпадения уровней серого (GLCM). GLCM — один из самых популярных экстракторов текстур. GLCM формирует матрицу, в которой каждый элемент является представлением того, сколько раз пара значений серого (i, j) встречалась соседним образом. Например, GLCM с 256 уровнями серого сформирует матрицу 256×256 , где элемент в первом столбце первой строки будет представлять, сколько раз значения серого (0, 0) встречались в качестве соседей. Впоследствии второй столбец первой строки будет представлять, сколько раз значения пикселей (0, 1) встречались как соседние пары.

Предлагается из каждого блока сформировать четыре матрицы совпадения уровней серого с наблюдением за правыми, левыми, верхними и нижними соседями. Из каждой GLCM извлекаются три статистические характеристики, называемые контрастностью, однородностью и энергией. Контраст представляет собой локальную вариацию внутри блока, энергия представляет однородность, а однородность представляет плотность распределения GLCM (Partio et al. 2002). Это может быть математически представлено (Харалик и др., 1973):

$$\text{Контраст} = \sum_{i,j} |i - j|^2 p(i, j) \quad (11)$$

$$\text{Энергия} = \sum_{i,j} p(i, j) \quad (12)$$

$$\text{Гомогенность} = \sum_{i,j} \frac{p(i, j)}{1 + |i - j|} \quad (13)$$

Здесь i и j — строки и столбцы GLCM. Всего из каждого блока извлекается 12 функций GLCM для обучения и тестирования.

Локальный двоичный шаблон (LBP). LBP — еще один мощный экстрактор признаков текстуры, представленный Ojala и Pietikäinen (1999). В этом методе изображение делится на 3×3 окрестности, и к окрестности применяется пороговое значение в зависимости от значения серого центрального пикселя. Более высокие или равные значения от центрального пикселя устанавливаются равными 1, а более низкие значения устанавливаются равными нулю. Это создает бинарную окрестность 3×3 . Каждая двоичная цифра в последовательности по часовой стрелке или против часовой стрелки умножается на вес, а затем суммируется. Если рассматривать 8 соседних пикселей

от центрального пикселя, то LBP представляет собой 8-битное число, подразумевающее, что может быть 256 возможных шаблонов. Наконец, создается гистограмма закономерностей, обнаруженных по всему изображению. Математически расчет делается так:

$$LBP = \sum_{n=0}^{N-1} i(n)2^n \quad (14)$$

Реализация нейросети. На рис. 4 показана нейросеть с прямой связью, называемая многоуровневым перцептроном (MLP), который принимает вектор признаков и генерирует прогноз на выходе. В таких нейросетях доступны три типа слоев: входной слой, скрытые слои и выходной слой. Каждый слой содержит некоторое количество «нейронов». Количество нейронов во входных и выходных слоях совпадает с размером входного вектора объектов и выходных классов. Количество скрытых слоев и нейронов в каждом из скрытых слоев выбирают пользователи. Как видно на рис. 6, нейроны имеют «плотную» связь, т. е. взаимосвязаны с нейронами предыдущего и последующего слоев.




Рис. 4. Нейросеть с прямой связью

Математическая модель нейросети выглядит следующим образом:

$$Z^L = W^L A^{L-1} + b^L \quad (15)$$

где A^{L-1} — вектор признаков из предыдущего слоя (входные признаки, L — первый скрытый слой); W^L и b^L — весовая матрица и вектор смещения слоя L (обучаемые параметры нейросети).

Прежде чем выходной Z^L будет передан следующему уровню, выполняется операция, называемая активацией. Цель активации состоит в том, чтобы привнести нелинейность и гарантировать запуск только определенных нейронов при конкретных входах. Математическая модель операций активации, проводимых внутри слоя:

$$A^L = f(Z^L) \quad (16)$$

где A^L — конечный результат уровня, который затем передается на следующий.

Литература

1. Богуш Р.П., Тычко Д.А. Алгоритм комплексного обнаружения дыма и пламени на основе анализа данных

Одними из самых популярных функций активации являются сигмовидная, гиперболический тангенс и выпрямленная линейная единица (ReLU). Выбираем выпрямленную линейную единицу:

$$ReLU(x) = \max(x, 0) \quad (17)$$

Наконец, на выходном уровне реализована функция активации под названием софтмакс (*softmax*). Софтмакс берет вектор чисел и создает вероятностное распределение выходных классов. Математическая софтмакс записывается:

$$A_i^L = \frac{e^{z_i^L}}{\sum_{j=1}^n e^{z_j^L}} \quad (18)$$

где A_i^L — выход i -го нейрона в слое L ; Z_i^L — i -е значение слоя L ; n — общее количество нейронов в слое L .

Функция активации софтмакс в выходном слое генерирует вероятность того, к какому классу принадлежит блок.

Прежде чем нейронную сеть можно будет внедрить для тестирования, ее необходимо обучить. Реализовать «контролируемый» алгоритм машинного обучения (ANN), в котором необходимо знать метку достоверности всех обучающих данных. Итак, нейросеть делает прогноз, используя «прямой проход», когда обработанные данные с одного уровня передаются на следующий уровень. Процесс же обучения нейросети протекает в обратном направлении — начиная с выходного слоя и возвращаясь к первому скрытому слою. Этот процесс называется обратным распространением [4; 9; 11; 12; 14].

Во время обратного распространения прогнозируемый результат сравнивается с истинным значением с использованием функции потерь. Наиболее распространенными функциями стоимости являются среднеквадратическая ошибка, потеря перекрестной энтропии и т. д. [16–21]. Значение функции потерь показывает, насколько точно сеть может делать прогнозы на обучающем наборе. Затем на основе значения функции потерь сеть корректирует значения весов и смещений.

Заключение. Предлагается новый метод обнаружения лесных пожаров с использованием сигнатур пламени и дыма. Новизна заключается в использовании обеих сигнатур для обнаружения пожара. При этом обеспечивается непрерывная и надежная работа наряду с использованием многопространственного локального бинарного шаблона, который извлекает LBP-уровни серого, насыщенности и цветовых каналов Сб-Сг в сочетании с использованием максимальных значений цвета в блоках изображения для идентификации малых пикселей пламени. Использование данной системы на БПЛА позволяет значительно увеличить эффективность мониторинга лесных пожаров в режиме реального времени.

систем видеонаблюдения // Доклады Белорусского гос. ун-та информатики и радиоэлектроники. 2015. № 6 (92). С. 63-71.

2. Кириченко А.А. Основы теории искусственных нейронных сетей. Издательская система Ridero, 2020. 222 с.
3. Красильников Н.Н. Цифровая обработка 2D- и 3D-изображений. СПб.: «БХВ-Петербург», 2011. 608 с.
4. Крюкова М.С., Фахми Ш.С. Сегментация полутоновых изображений лесных пожаров на основе дисперсионного анализа // Вестн. С.-Петерб. ун-та Гос. противопожарной службы МЧС России». 2019. № 3. С. 103-111.
5. Лукьяница А.А., Шишкин А.Г. Цифровая обработка видеоизображений. М.: «Ай-Эс-Эс Пресс», 2009. 518 с.
6. Ильясов Б.Г., Макарова Е.А., Закеева Е.Ш., Габдуллина Э.Р. Методы искусственного интеллекта в программных приложениях. Уфа, 2021. 153 с.
7. Астратов О.С., Смирнов В.М., Филатов В.Н. Обнаружение лесных пожаров по видеоизображениям // Научная сессия ГУАП: сб. докл. (9-13 апр. 2018 г.). СПб., 2018. С. 7-11.
8. Кузнецов А.О., Мусалимов В.М., Саенко А.П., Трамбичкий К.В. Применение алгоритмов анализа изображений для обнаружения пожаров // Изв. высш. учеб. заведений. Приборостроение. 2012. Т. 55. № 6. С. 51-56.
9. Пятаева А.В. Сегментация областей задымления на видеопоследовательности // Сибирский аэрокосмический журнал. 2016. Т. 17. № 3. С. 625-630.
10. Васюков В.Н., Зайцева А.Ю., Бондаренко В.В. Система раннего обнаружения лесных пожаров - архитектура и алгоритмы // Доклады АН ВШ РФ. 2015. № 2 (27). С. 43-56.
11. Antoine C. Detection of forest fires using artificial intelligence. Année académique: 2021. 153 p.
12. Sakr G., Elhajj I., Mitri G., Wejinya U. Artificial intelligence for forest fire prediction // Environmental Science, Computer Science 2010 IEEE. ASME International Conference on Advanced Intelligent Mechatronics, 2010. P. 1311-1316.
13. Khan S., Rahmani H., Shah S.A.A., Bennamoun M. A guide to convolutional neural networks for computer vision // Synth. Lect. Comput. 2018. Vis. 8 (1): 1-207.
14. Zhang J., Zhu H., Wang P., Ling X. Att squeeze u-net: A lightweight network for forest fire detection and recognition. IEEE Access, 9. 2021. P. 10858-10870.
15. Kinaneva D., Hristov G., Raychev J., Zahariev P. Early Forest Fire Detection Using Drones and Artificial Intelligence // Conference: 2019 42nd International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO). P. 1060-1065.
16. Anim Hossain F.M., Youmin M. Zhang, Masuda Akter Tonima. Forest fire flame and smoke detection from UAV-captured images using fire-specific color features and multi-color space local binary pattern // Journal of Unmanned Vehicle Systems. 30 June 2020. P. 285-309.
17. Bogush R.P., Tychko D.A. Algorithm of complex detection of smoke and flame based on the analysis of data from video surveillance systems // Doklady Belorusskogo gos. un-ta informatiki i radioelektroniki. 2015. № 6 (92). P. 63-71.
18. Kirichenko A.A. Fundamentals of the Theory of Artificial Neural Networks. Izdatel'skaya sistema Ridero, 2020. 222 p.
19. Krasil'nikov N.N. Digital processing of 2D and 3D images. SPb.: «BHV-Peterburg», 2011. 608 p.
20. Kryukova M.S., Fahmi SH.S. Segmentation of halftone images of forest fires on the basis of dispersion analysis // Vestnik Saint-Petersburg university of State fire service of EMERCOM of Russia. 2019. № 3. P. 103-111.
21. Luk'yanica A.A., SHishkin A.G. Digital processing of video images. M.: «Aj-Es-Es Press», 2009. 518 p.
22. Il'yasov B.G., Makarova E.A., Zakieva E.SH., Gabdullina E.R. Methods of artificial intelligence in software applications. Ufa, 2021. 153 p.
23. Astratov O.S., Smirnov V.M., Filatov V.N. Detection of forest fires by video images // Nauchnaya sessiya GUAP: sb. dokl. (9-13 apr. 2018 g.). SPb., 2018. P. 7-11.
24. Kuznecov A.O., Musalimov V.M., Saenko A.P., Trambickij K.V. Application of image analysis algorithms for fire detection // Journal of Instrument Engineering (Izv. vyssh. ucheb. zaved. Priborostroenie). 2012. V. 55. № 6. P. 51-56.
25. Pyataeva A.V. Segmentation of areas of smoke on video sequences // Siberian Aerospace Journal. 2016. V. 17. № 3. P. 625-630.
26. Vasyukov V.N., Zajceva A.YU., Bondarenko V.V. The system of early detection of forest fires - architecture and algorithms // Doklady AN VSH RF. 2015. № 2 (27). P. 43-56.
27. Antoine C. Detection of forest fires using artificial intelligence. Année académique: 2021. 153 p.
28. Sakr G., Elhajj I., Mitri G., Wejinya U. Artificial intelligence for forest fire prediction // Environmental Science, Computer Science 2010 IEEE. ASME International Conference on Advanced Intelligent Mechatronics, 2010. P. 1311-1316.
29. Khan S., Rahmani H., Shah S.A.A., Bennamoun M. A guide to convolutional neural networks for computer vision // Synth. Lect. Comput. 2018. Vis. 8 (1): 1-207.
30. Zhang J., Zhu H., Wang P., Ling X. Att squeeze unet: A light-weight network for forest fire detection and recognition. IEEE Access, 9. 2021. P. 10858-10870.
31. Kinaneva D., Hristov G., Raychev J., Zahariev P. Early Forest Fire Detection Using Drones and Artificial Intelligence // Conference: 2019 42nd International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO). P. 1060-1065.
32. Anim Hossain F.M., Youmin M. Zhang, Masuda Akter Tonima. Forest fire flame and smoke detection from UAV-captured images using fire-specific color features and multi-color space local binary pattern // Journal of Unmanned Vehicle Systems. 30 June 2020. P. 285-309.

References