

Оригинальная статья / Original article

<https://doi.org/10.21869/2223-1536-2021-11-4-85-105>



Автоматизированная система для классификации снимков видеопотоков

С. А. Филист¹ ✉, М. В. Шевцов², В. А. Белозеров³, Д. С. Кондрашов¹,
И. Н. Горбачев¹, Н. А. Корсунский¹

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

² Академия государственной противопожарной службы МЧС России
ул. Бориса Галушкина 4, г. Москва 129366, Российская Федерация

³ Курская областная многопрофильная клиническая больница
ул. Сумская 45а, г. Курск 305007, Российская Федерация

✉ e-mail: SFilist@gmail.ru

Резюме

Цель исследования – разработка автоматизированной системы мониторинга пожарной обстановки на основе анализа информации полученных с RGB-камер, установленных на борту дронов, посредством автономных интеллектуальных агентов (АИА) и моделей машинного обучения.

Методы. Метод классификации аэроснимков видеоряда при мониторинге пожарной обстановки в автономной территориальной единице предполагает их сегментацию на одинаковые прямоугольные сегменты заданного размера и отнесение их к одному из трех классов: дым, пламя, индифферентный класс. Для классификации сегментов используются «сильные» и «слабые» классификаторы. Для формирования дескрипторов для «слабых» классификаторов использовалось преобразование Уолша-Адамара. Дескрипторы вычисляются для трех «слабых» классификаторов. Сначала вычисляется преобразование Уолша-Адамара для окна всего сегмента, его спектральные коэффициенты используются для первого «слабого» классификатора. Затем вычисляются дескрипторы по двум окнам, размеры которых в два и в четыре раза меньше размеров исходного окна.

Результаты. Своевременное обнаружение очага пожара в стадии его развития позволяет снизить как материальные, так и людские потери. Поэтому разработка моделей, методов и алгоритмов управления системой мониторинга пожарной и медико-экологической безопасности, обеспечивающих повышение его эффективности за счет анализа видеоданных с беспилотных летательных аппаратов, является актуальной задачей.

© Филист С. А., Шевцов М. В., Белозеров В. А., Кондрашов Д. С., Горбачев И. Н., Корсунский Н. А., 2021

Классификатор состоит из трех независимо обучаемых нейронных сетей – «слабых» классификаторов. Для объединения выходов нейронных сетей используется простой блок усреднения по ансамблю. Разработано программное обеспечение для классификации аэроснимков, позволяющее формировать базу данных сегментов классов «дым» и «пламя», определять двумерный спектр Уолша-Адамара сегментов аэроснимков, обучать полносвязные нейронные сети и проводить разведочный анализ по исследованию релевантности двумерных спектральных коэффициентов.

Вывод. Экспериментальные исследования по классификации видеоданных, содержащих пламя и дым, показали среднее значение точности обнаружения дыма 86 %, а пламени – 89,5 %. Ошибки второго рода при обнаружении дыма в среднем составили 13 %, а при обнаружении пламени – 4,5%. Для настройки и валидации классификаторов использовались реальные данные с камер видеонаблюдения на открытых пространствах.

Ключевые слова: аэроснимок; пламя; дым; обнаружение пожара; сегментация снимка видеопоследовательности; алгоритм классификации снимка видеопоследовательности.

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

Для цитирования: Автоматизированная система для классификации снимков видеопотоков / С. А. Филлист, М. В. Шевцов, В. А. Белозеров, Д. С. Кондрашов, И. Н. Горбачев, Н. А. Корсунский // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2021. Т. 11, № 4. С. 85–105. <https://doi.org/10.21869/2223-1536-2021-11-4-85-105>

Поступила в редакцию 11.10.2021

Подписана в печать 08.11.2021

Опубликована 20.12.2021

Automated System For Classifying Images of Video Streams

Sergey A. Filist¹ ✉, Maxim V. Shevtsov², Vladimir A. Belozеров³,
Dmitry S. Kondrashov¹, Igor N. Gorbachev¹, Nikita A. Korsunsky¹

¹ Southwest State University
50 Let Oktyabrya str. 94, Kursk 305040, Russian Federation

² Academy of the State Fire Service of the Ministry of Emergency Situations of Russia
4 Boris Galushkin str., Moscow 129366, Russian Federation

³ Kursk Regional Multidisciplinary Clinical Hospital
45a Sumskaya str., Kursk 305007, Russian Federation

✉ e-mail: SFilist@gmail.ru

Abstract

The purpose of research is timely detection of a fire center in the stage of its development can reduce both material and human losses. Therefore, the development of models, methods and algorithms for managing the monitoring system of fire and medical and environmental safety, ensuring an increase in its efficiency through the analysis of video data from unmanned aerial vehicles, is an urgent task.

Methods. The method of classifying aerial photographs of a video sequence when monitoring a fire situation in an autonomous territorial unit assumes their segmentation into identical rectangular segments of a given size and assigning them to one of three classes: smoke, flame, indifferent class. The "strong" and "weak" classifiers are used to classify the segments. The Walsh-Hadamard transform was used to form descriptors for "weak" classifiers. Descriptors are calculated for three "weak" classifiers. First, the Walsh-Hadamard transform is calculated for the window of the entire segment and its spectral coefficients are used for the first "weak" classifier. Then descriptors are calculated for two windows, the sizes of which are two and four times smaller than the sizes of the original window.

Results. *Timely detection of a fire in the stage of its development can reduce both material and human losses. Therefore, the development of models, methods and algorithms for managing the fire and medical-environmental safety monitoring system, providing an increase in its efficiency through the analysis of video data from unmanned aerial vehicles, is an urgent task.*

The classifier consists of three independently trained neural networks - "weak" classifiers. To combine the outputs of neural networks, a simple ensemble averaging block is used. Software for classifying aerial images has been developed, which makes it possible to form a database of segments of "smoke" and "flame" classes, determine the two-dimensional Walsh-Hadamard spectrum of aerial image segments, train fully connected neural networks and conduct exploratory analysis to study the relevance of two-dimensional spectral coefficients.

Conclusion. *When conducting experimental studies on video sequences containing flame and smoke, the average value of smoke detection accuracy was 86%, flame - 89.5%. False positives for smoke detection averaged 13% and for flame detection 4.5%. To configure and validate the classifiers, we used real data from CCTV cameras in open spaces.*

Keywords: *aerial image; flame; smoke; fire detection; segmentation of a video sequence image; algorithm for classifying a video sequence image.*

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

For citation: Philist S. A., Shevtsov M. V., Belozеров V. A., Kondrashov D. S., Gorbachev I. N., Korsunsky N. A. Automated System For Classifying Images of Video Streams. *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.* 2021; 11(4): 85–105. (In Russ.) <https://doi.org/10.21869/2223-1536-2021-11-4-85-105>

Received 11.10.2021

Accepted 08.11.2021

Published 20.12.2021

Введение

Информация о многих физических процессах представляется в виде видеопотоков. Системы безопасности, наблюдения, навигационные, метеорологии и медицинской интроскопии являются областями анализа видеопотока. Одной из важных задач является выделение объекта в видеопотоке. С этой задачей связаны задачи слежения за объектом, сопоставления изображения с базой данных, поиск дубликатов изображений, соединения кадров [1].

Выделение снимков с пожаром из видеоряда с достаточной точностью и оперативностью является трудной задачей. Пожары имеют несколько стадий,

которые влияют на способы определения их дислокации по аэроснимкам. В процессе развития пожара наблюдаются фазы: дым, дым плюс пламя, пламя. Дискриминация сегментов с этими фазами позволит увеличить достоверность классификации видеоданных [1].

На снимке видеокadra дым и пламя представляют динамическую структуру с пространственными и временными свойствами. Пространственными особенностями дыма и пламени является цвет, прозрачность, турбулентность. Принято, что в качестве дескрипторов для определения координат источника возгорания используется температурная карта, полученная посредством тепловизора или инфракрасной камеры. Однако

на инфракрасных камерах пожарами будут выглядеть места с высокой температурой воздуха, а некоторые участки поверхности будут приняты за источники тепла только из-за особенностей отражения света. К тому же такие камеры существенно дороже. Поэтому при использовании в мониторинге пожарной обстановки дронов, входящих в автоматизированную систему мониторинга пожарной обстановки, на их борту для поиска очага пожара целесообразно устанавливать RGB-камеры, которые используются для съёмки всего района, а фотографии затем анализируются посредством автономных интеллектуальных агентов (АИА)¹, построенных на основе моделей машинного обучения [2; 3; 4; 5].

Материалы и методы

Для анализа RGB-изображений в настоящее время широко используются сверточные нейронные сети (СНС) различной архитектуры. Однако у них имеются два существенных недостатка, которые препятствуют их использованию в автоматизированной системе оценки пожарной обстановки. Первый недостаток связан с большим потоком видеоданных, поступающих с видеокамер дрона на СНС в процессе мониторинга. Это обстоятельство не позволяет удовлетворить требования по оперативности анализа снимков. Второй недостаток

СНС связан с тем, что СНС классифицирует снимок в целом, тогда как на пульте лица, принимающего решение (ЛПР), необходимо передать координату возгорания, т. е. классификация снимка должна осуществляться сегментарно, что снижает преимущества СНС при решении этой задачи [6].

Поэтому для классификации аэроснимков при мониторинге пожарной обстановки будем использовать полносвязные нейронные сети, а для повышения оперативности классификации снимок предварительно сегментируется на прямоугольные сегменты одинакового размера и для каждого сегмента принимается решение о возможности присутствия в нем дыма или пламени [7; 8; 9; 10].

Алгоритм классификации снимков видеоряда от беспилотного летательного аппарата

Классификация снимков видеоряда предполагает классификацию всего снимка или его частей (сегментов). При этом предполагается возможность двухэтапной классификации, при которой на первом этапе определяется только наличие интереса к данному снимку или сегменту (класс ROI или класс НЕ ROI), а на втором этапе выносится окончательное решение по вопросу принадлежности снимка или сегмента к конкретному

1. Кудрявцев П. С. Методы и алгоритмы дифференциальной диагностики легочных заболеваний на основе анализа спектров

локальных окон рентгенограмм грудной клетки: дис. ... канд. техн. наук. Курск, 2017. 152 с.

классу. При этом возникают трудности как на первом, так и на втором уровне классификации [4; 10].

Для решения поставленных в работе задач используются методы классификации на основе «сильных» и «слабых» классификаторов [5; 11]. Для формирования дескрипторов для «слабых» классификаторов было предложено использовать преобразование Уолша-Адамара.

На рисунке 1 представлена схема алгоритма, посредством которой реализуется предлагаемый метод классификации аэроснимков. Алгоритм может работать со снимками видеоряда, хранящимися в файлах на диске компьютера или в Интернете, а также поступающими непосредственно с видеокамеры беспилотного летательного аппарата (БПЛА).

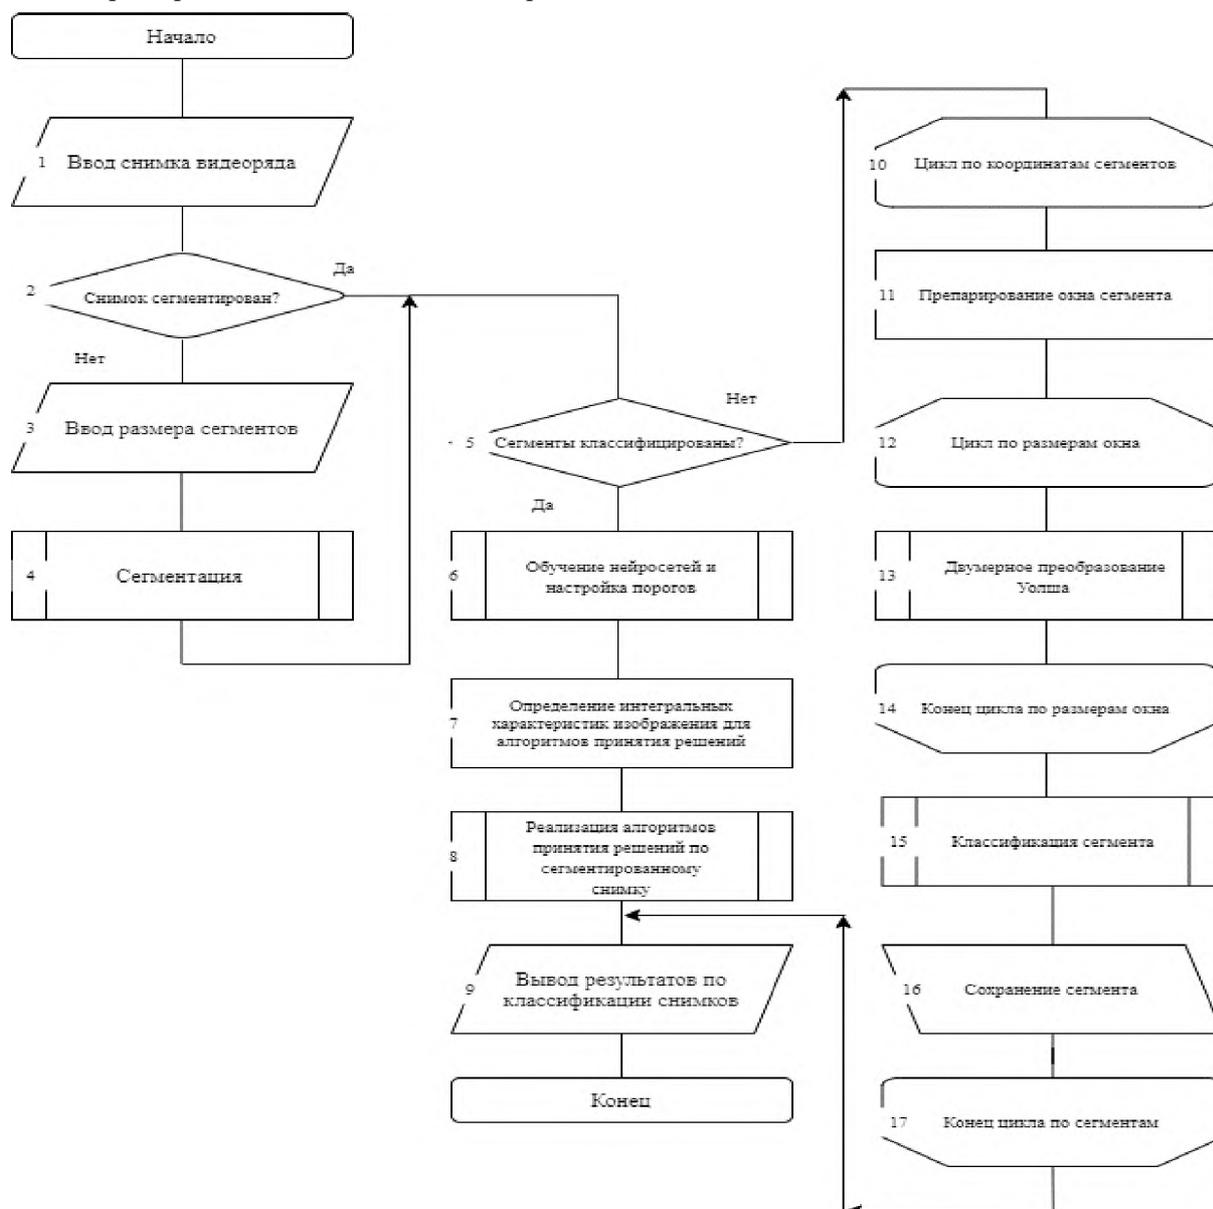


Рис. 1. Схема алгоритма классификации снимков видеоряда

Fig. 1. Scheme of the algorithm for classifying images of a video sequence

Алгоритм имеет две ветви, организованные посредством блока 5. Первая ветвь работает с уже классифицированными сегментами и осуществляет настройку параметров нейронной сети, которая используется в качестве классификатора сегментов (блоки 6, 7, 8 и 9). Вторая ветвь алгоритма предназначена непосредственно для классификации сегментов (блоки 10...17).

На вход блока 10 поступает изображение, сегментированное на сегменты одинаковых размеров. Сегментация входного изображения на эти сегменты осуществляется в блоках 3 и 4. Размеры сегментов задаются ЛПР в блоке 3. В блоке 10 задается цикл просмотра сегментов изображения. При необходимо-

сти в блоке 11 осуществляется препарирование сегментов изображения. После этого в цикле (блоки 12...14) осуществляется вычисление дескрипторов (преобразование Уолша) для классификатора сегмента.

Дескрипторы вычисляются для трех «слабых» классификаторов [12; 13]. Сначала вычисляется преобразование Уолша – Адамара для всего окна, и его спектральные коэффициенты используются для первого «слабого» классификатора. Затем (в следующем цикле блоков 12...14) вычисляются дескрипторы по окнам, размеры которых в два раза меньше размеров исходного окна, и т. д.

Сущность такой классификации поясняет рисунок 2.

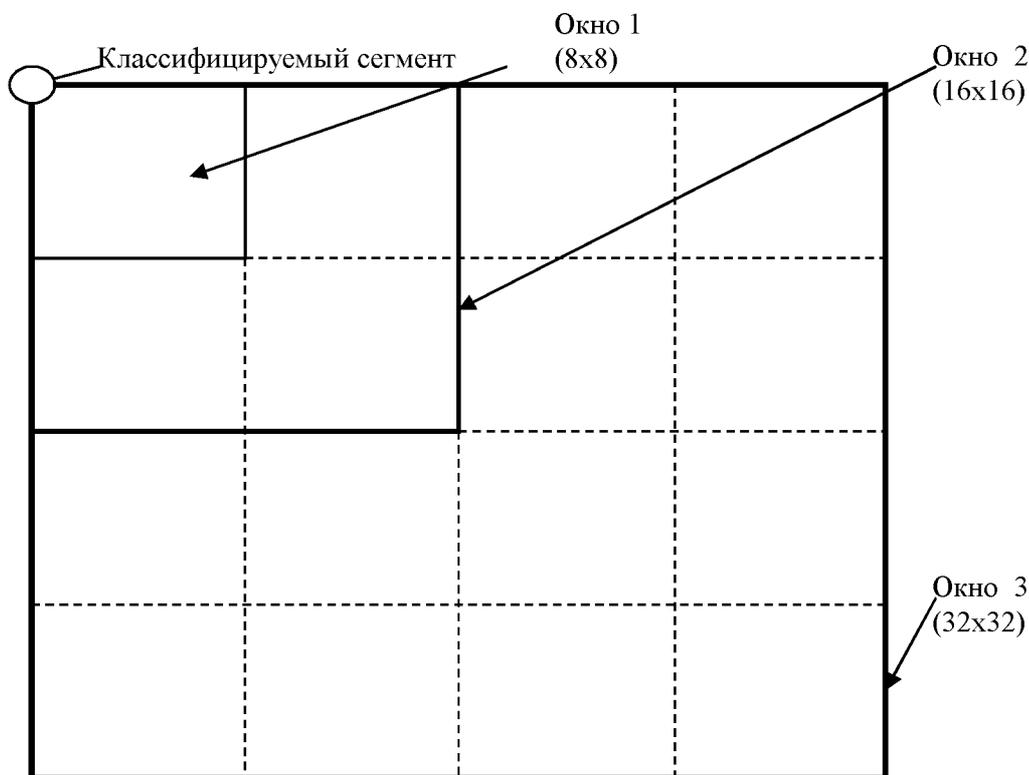


Рис. 2. Вложенные спектральные окна для классификации сегмента снимка

Fig. 2. Nested spectral windows for image segment classification

Например, если исходное окно сегмента имеет размер 32x32 пикселя, то в следующем цикле дескрипторы вычисляются в четырех окнах размером 16x16 пикселей, а в следующем цикле – в 16 окнах размером 8x8 пикселей. Однако в каждом цикле получаем одинаковое количество дескрипторов, что позволяет построить «слабые» классификаторы с унифицированной структурой.

После классификации сегмента он отправляется в базу данных (блок 16), а результат его классификации выводится на терминальное устройство (блок 9). Координаты сегментов записываются в специальные структуры данных, и также устанавливается флаг-признак классифицированного сегмента.

Перед определением спектров Уолша в окнах сегмента в блоке 13 осуществляется предварительная обработка изображения сегмента (блок 11). Этот блок может быть отключен на глобальном уровне, если «сырые» данные уже подвергались предварительной обработке или в ней нет необходимости. Как показали предварительные исследования, использование блока 11 улучшает качество работы классификатора более чем на 10%.

Если сегмент не был классифицирован, то тогда происходит процесс препарирования окна сегмента (блок 11), или взвешивание исходного изображения в скользящем окне в текущих координатах (цифровая фильтрация скользящим окном [2]). Затем по содержимому окна сегмента осуществляют расчеты дву-

мерного преобразования Уолша – Адамара и другие необходимые расчеты. Так как в сегменте нами определено несколько «слабых» классификаторов, то во внешнем цикле предусмотрен внутренний цикл (блоки 12...14), в котором также могут быть свои внутренние циклы по вычислению двумерной плоскости Уолша – Адамара для каждого типоразмера окна. Для классификации каждого сегмента необходимо определить преобразование Уолша – Адамара в трех типоразмерах окон, образуемых в сегменте согласно схеме (см. рис. 2). Преобразования Уолша – Адамара определяются в теле цикла, организованного блоками 12, 13 и 14. Размеры окон кратны степени числа два для обеспечения работы алгоритма преобразования Уолша. Цикл по размерам окна является внутренним циклом для цикла по координатам сегментов снимка – внешний цикл (блоки 10...17). Классификация осуществляется во внешнем цикле (блок 15).

Внутри цикла по «слабым» классификаторам производится вычисление их дескрипторов, тем самым формируются входные векторы для «слабых» классификаторов. После получения этих векторов информативных признаков они подаются на входы «слабых» классификаторов, выходы которых возвращают числа – коэффициенты уверенности в нулевой гипотезе, которые подаются на вход «сильного» классификатора, на основе работы которого происходит классификация сегмента. Информация о

классификации сохраняется в специальных структурах данных, которые могут быть прочитаны для уточнения классификации. На этом заканчиваются циклы по сегментам снимка и по размерам окна (по «слабым» классификаторам).

Ветвь алгоритма из блоков 6...9 предназначена для обучения нейронных сетей, выполняющих роль классификаторов на всех иерархических уровнях, на основе подтвержденной и новой информации по классификации сегментов снимков. Также настраиваются пороги классификаторов (подбираются функции активации для нейронных сетей). В завершении работы алгоритма осу-

ществляются вывод и запись результатов классификации сегментов и настроек нейронных сетей.

Результаты и их обсуждение

Программно-алгоритмическое обеспечение синтеза «слабых» классификаторов

Для синтеза «слабых» классификаторов по спектральной плоскости было разработано программное обеспечение (ПО). За основу ПО взята структура ПО, предложенная в [14]. Модульная структура ПО представлена на рисунке 3. ПО написано на языке Python 3.10.0 для Windows 7.

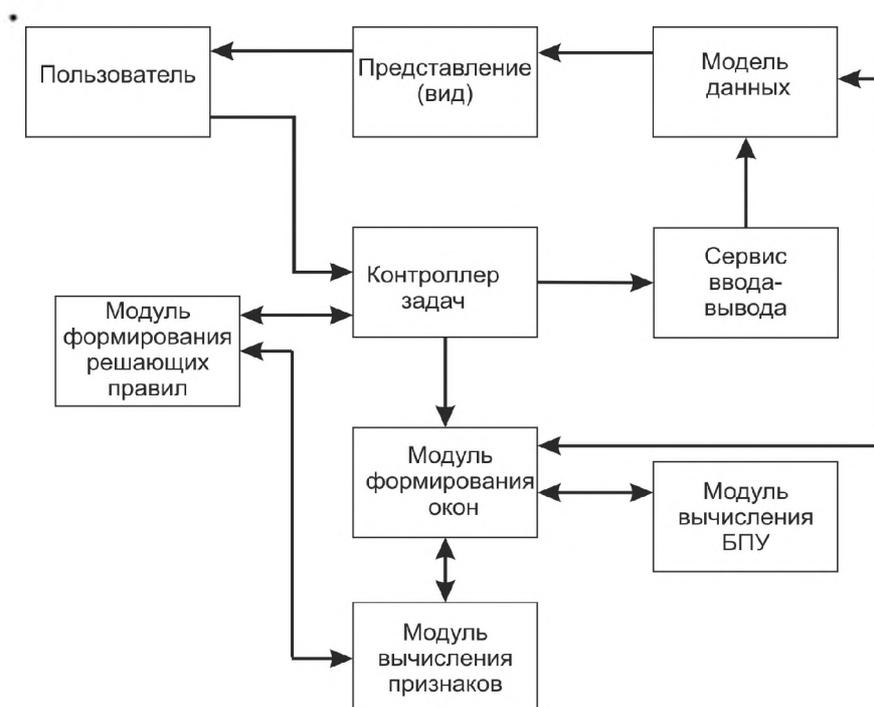


Рис. 3. Модульная структура программного обеспечения синтеза «слабых» классификаторов

Fig. 3. Modular structure of software for constructing "weak" classifiers

Основой ПО является модуль управления (контроллер задач), который взаимодействует с ЛПП. Для хранения обра-

ботанных данных предусмотрено хранилище данных – «Модель данных». В хранилище данных хранятся исходные и промежуточные изображения, а также

вычисляемые дескрипторы и параметры обученных классификаторов. Исходное изображение загружается с помощью сервиса ввода-вывода, представленного в виде всплывающих и раскрывающихся окон, что обеспечивает ЛПР возможность загружать снимки наиболее популярных форматов (таких, как jpeg, png и др.). Сервис ввода-вывода используется также для селекции релевантных спектральных коэффициентов в окнах трех типоразмеров, что позволяет сформировать векторы информативных признаков «слабых» классификаторов значительно меньшей размерности.

Для обучения классификаторов использовалась база данных, содержащая сегменты дискриминируемых классов. Размеры сегментов задавались 32x32 пикселя. Программное обеспечение построено так, что сегменты могут быть любого размера. Однако настройка классификатора требует одинаковых размеров сегментов.

Спектральные коэффициенты Уолша, по которым осуществляется идентификация интересующего нас класса, формируют входные векторы «слабых» классификаторов (дескрипторы). Координаты спектральных коэффициентов, принимающих участие в формировании входного вектора «слабого» классификатора, будем называть локализацией «слабого» классификатора.

На рисунке 4 представлен интерфейс ПО для создания базы данных (БД)

обучающих и контрольных выборок. Исходный снимок разбивается на сегменты квадратной формы с размерами кратными двум. Затем ЛПР устанавливает флажок индикатора класса (на рис. 4 это класс «пламя»), и указателем «мыши» помечает тот сегмент, который относится к данному классу. Помеченные сегменты отправляются в папку БД, в которой хранятся сегменты данного класса.

Основные вычислительные процедуры реализованы следующими решающими модулями:

- модуль вычисления преобразования Уолша – Адамара;
- модуль формирования окон внутри сегмента;
- модуль селекции дескрипторов;
- модуль формирования решающих правил (синтеза классификатора). Модуль формирования окон из исходного сегмента выделяет окна с заданными параметрами (размерами, локализацией). Эти окна подаются в модуль вычисления преобразования Уолша – Адамара. По вычисленным двумерным спектрам Уолша осуществляется формирование дескрипторов для обучающих выборок или для классификатора сегмента. Результаты вычисления спектра Уолша-Адамара в окнах сегмента через интерфейс доступны ЛПР. На рисунке 5 представлено интерфейсное окно ПО.

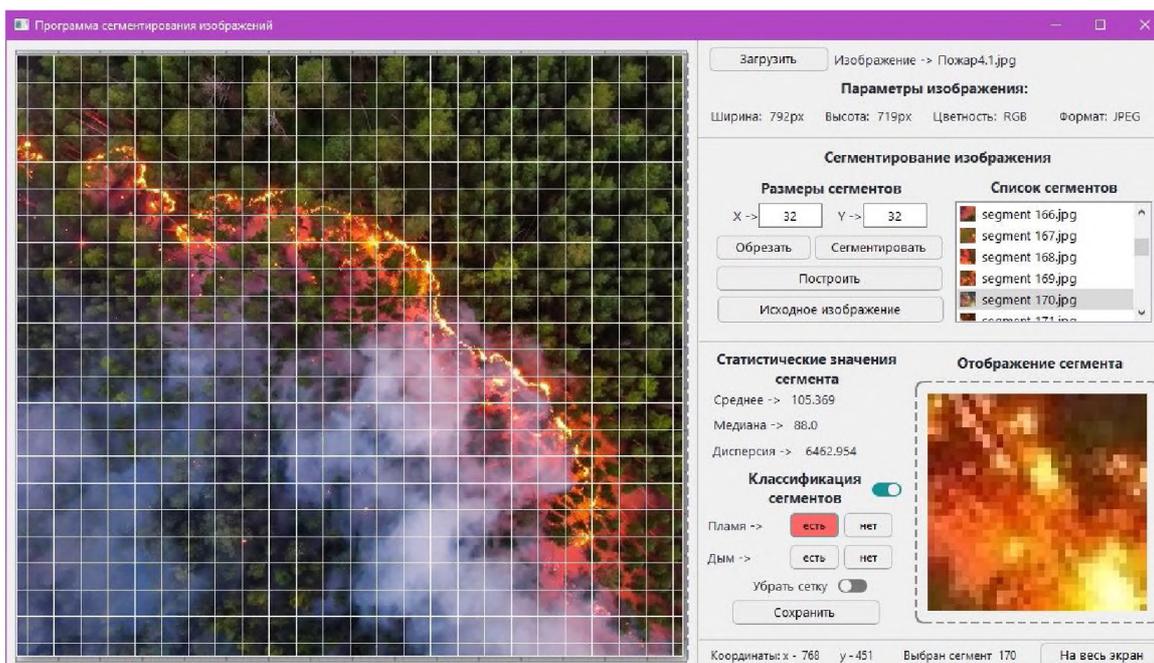


Рис. 4. Интерфейс программного обеспечения для создания базы данных обучающих выборок

Fig. 4. Software interface for creating a database of training samples

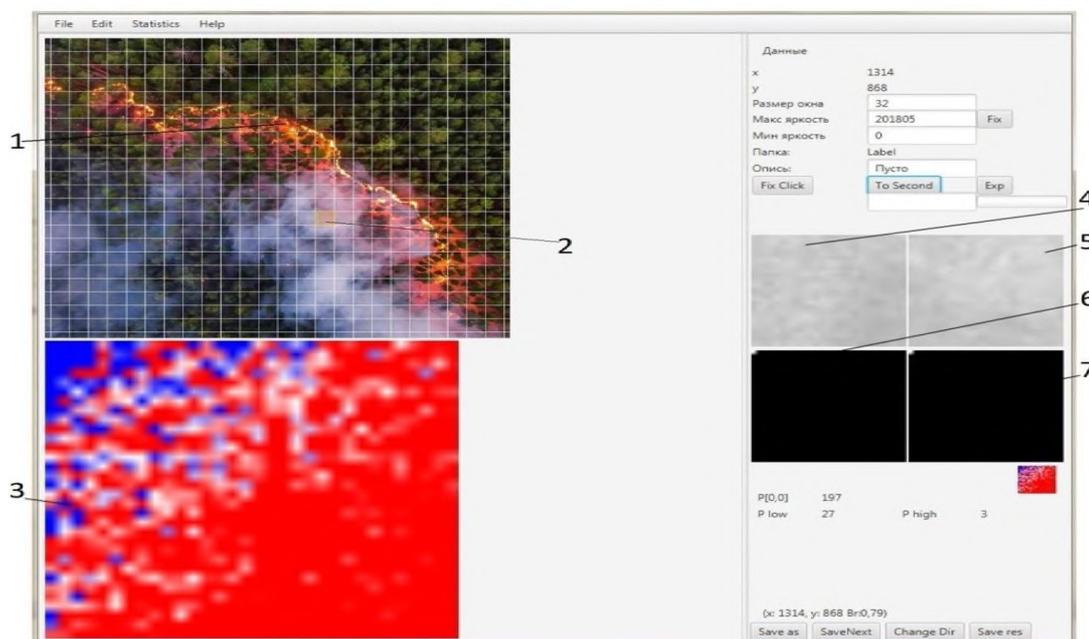


Рис. 5. Основные элементы интерфейса: 1 – исходное окно класса 1; 2 – исходное окно класса 2; 3 – разность между спектрами Уолша в окне № 1 и в окне № 2 для поиска информативных спектральных коэффициентов; 4 – окно № 1; 5 – окно № 2; 6 – спектр Уолша окна № 1; 7 – спектр Уолша окна № 2

Fig. 5. The main interface elements: 1 – the initial window of class 1; 2 – the initial window of class 2; 3 – the difference between the Walsh spectra in window No. 1 and in window No. 2 for searching for informative spectral coefficients; 4 – window No. 1; 5 – window No. 2; 6 – Walsh spectrum of window No. 1; 7 – Walsh spectrum of window No. 2

В этом интерфейсном окне из исходного снимка вырезаны сегмент № 1 (класс интереса) и сегмент № 2 – индифферентный класс, рассчитаны их двумерные спектры Уолша – Адамара (показаны в окнах 6 и 7, а изображения самих сегментов показаны в окнах 4 и 5). Окно № 2 по размеру совпадает с размерами окна № 1, поэтому мы можем сопоставлять их спектры для оценки распределения энергии по частотам (группа из четырех изображений справа на рис. 5). По найденной разности между спектром в окне № 1 и спектром в окне № 2 (окно 3 на рис. 5) можем осуществить поиск информативных спектральных составляющих для «слабых» классификаторов класса интереса. В результате технология поиска дескрипторов для «слабого» классификатора состоит в анализе спек-

тральных коэффициентов Уолша в окнах, содержащих морфологические компоненты искомого класса и нахождении их отличий от спектральных коэффициентов в окнах, не содержащих таких морфологических компонент. Цель поиска – селективировать только значимые спектральные коэффициенты двумерного спектрального разложения в окне по пороговому и информационному критериям. Например, на рисунке 6 показано окно (б) размером 32x32 пикселя, содержащее сегмент снимка класса «пламя», и соответствующий спектр Уолша – Адамара этого фрагмента представлен на рисунке (в).

На рисунке 7 показано окно сегмента размером 32x32 пикселя (б), содержащее сегмент того же снимка (а) индифферентного класса, которому соответствует спектр Уолша – Адамара (в).

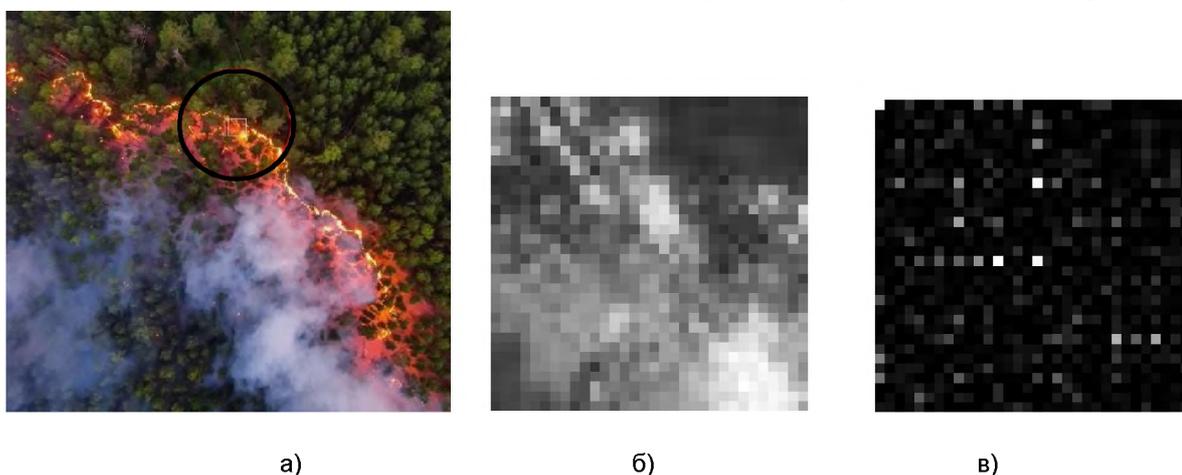


Рис. 6. Аэроснимок с сегментом класса «пламя»: а – дислокация сегмента (указана окружностью); б – соответствующее содержимое сегмента класса «пламя»; в – двумерный спектр Уолша этого сегмента

Fig. 6. Aerial view of a segment of the class "flame": а – the dislocation of the segment (indicated by a circle); б – the corresponding contents of the segment of the class "flame"; в – the two-dimensional Walsh spectrum of this segment

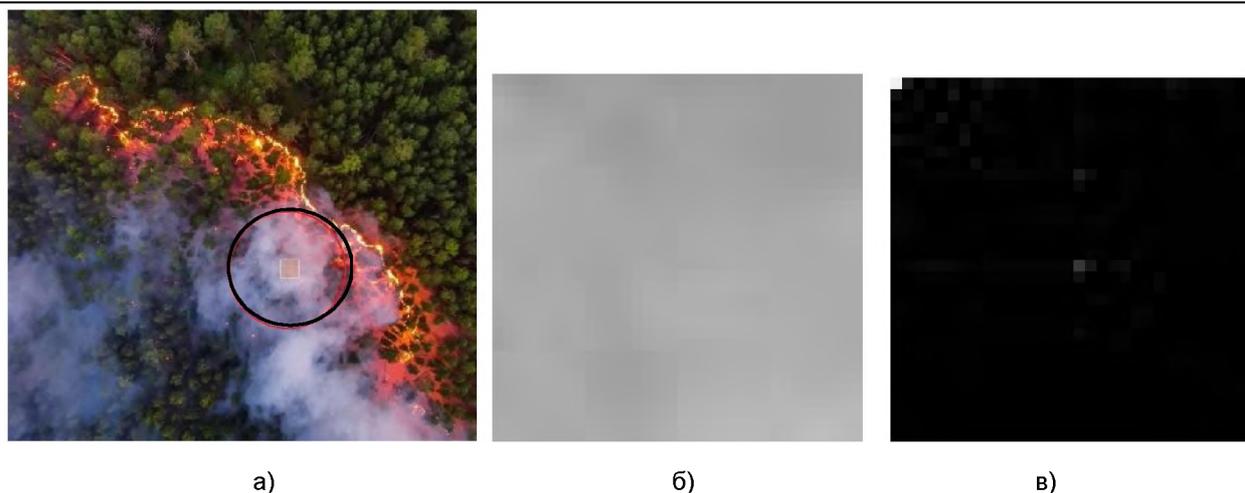


Рис. 7. Аэроснимок с сегментом индифферентного класса: а – дислокация сегмента (указана окружностью); б – соответствующее содержимое сегмента индифферентного класса; в – двумерный спектр Уолша этого сегмента

Fig. 7. Aerial view of an indifferent class segment: а – segment dislocation (indicated by circle); б – the corresponding contents of the segment of the indifferent class; в – the two-dimensional Walsh spectrum of this segment

Модель классификатора и оценка качества классификации морфологических образований на аэроснимках

Основной задачей, поставленной в исследовании, является дискриминация сегментов с морфологическими образованиями «пламя», «дым» и индифферентного класса.

Так как в классифицируемый сегмент вписываются окна трех типоразмеров – 8×8 , 16×16 , 32×32 пикселя, в которых вычисляются двумерные спектры Уолша, то имеем три вида обучающих выборок, каждый пример в которых характеризуется векторами одинаковой размерности. Следовательно, для каждой из трех обучающих выборок строим свой классификатор, который принимает независимое решение по отношению сегмента к определенному классу.

Решение этих трех классификаторов агрегируется также независимым классификатором, построенным на основе технологий обучаемых нейронных сетей или нечеткого логического вывода [5; 7; 11; 14]. Один из примеров структуры такого классификатора представлен на рисунке 8.

Особенностью данной структуры является то, что три автономных агента на нижнем иерархическом уровне используют одни и те же «сырые» данные и формируют на основе их анализа векторы дескрипторов одинаковой размерности: вектор X_1 – это спектральные коэффициенты 16 окон размером 8×8 ; вектор X_2 – спектральные коэффициенты четырех окон размером 16×16 ; вектор X_3 – спектральные коэффициенты в окне 3 (см. рис. 2) размером 32×32 пикселя.

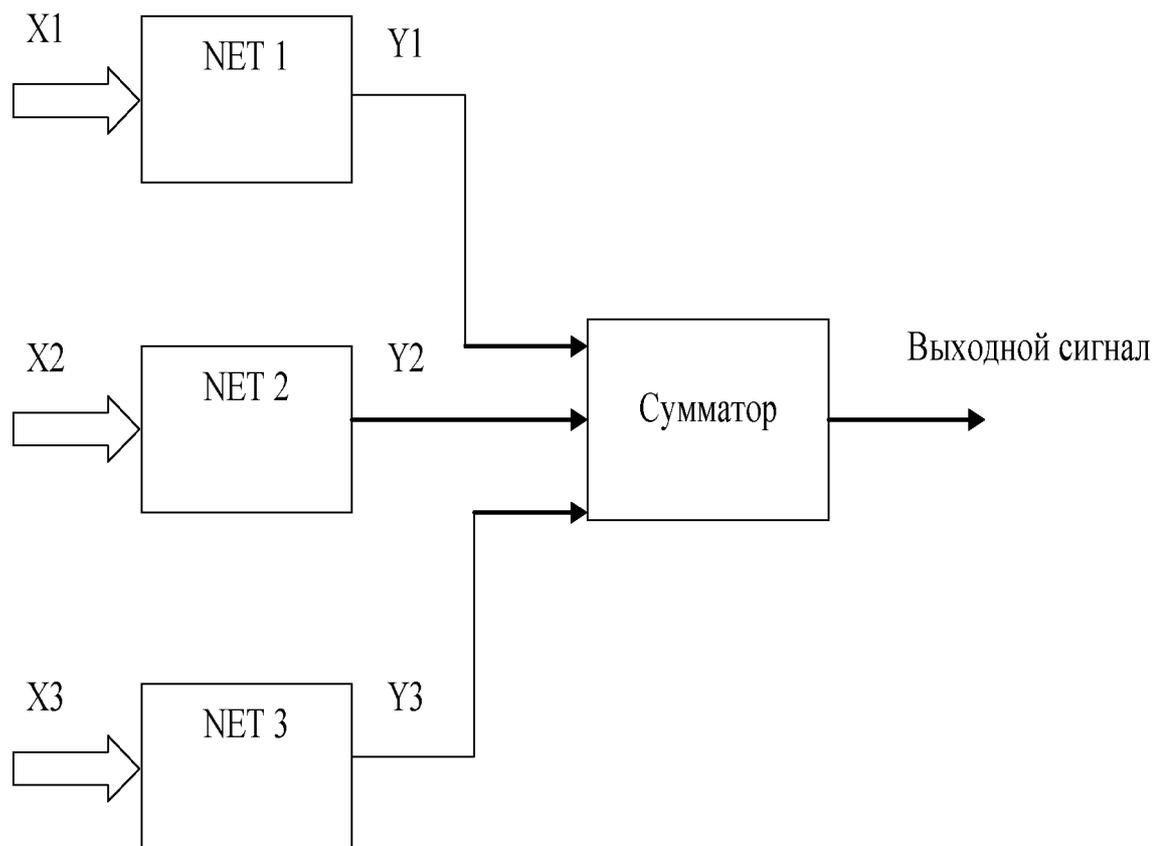


Рис. 8. Структурная схема нейросетевого классификатора сегмента

Fig. 8. Block diagram of the segment classifier

При формировании векторов $X_1 \dots X_3$ их компоненты нормируются на среднюю яркость в сегменте снимка, по спектральным коэффициентам которого формируются входные векторы «слабых» классификаторов. Это обусловлено тем, что наибольшая энергия двумерного спектра Уолша соответствует нулевой строке или нулевому столбцу, так как их элементы были получены в результате взвешивания изображения сегмента с нулевой функцией Уолша, которая равна единице. Нулевой

спектральный коэффициент, расположенный в верхнем левом углу спектральной плоскости Уолша, равен средней яркости изображения в окне сегмента.

Для проведения экспериментальных исследований были использованы видеопоследовательности из баз данных Bilkent [15]. Кадры некоторых использованных снимков из видеороликов и их свойства приведены в таблице 1.

Целью экспериментальных исследований был анализ показателей качества

классификации классификаторов снимков с сегментами класса «дым» и «пламя». При этом возгорание считалось обнаруженным, если хотя бы один искомый сегмент класса «дым» или «пламя» найден на аэроснимке. Обучающая выборка видеоизображений (кадров видеопоследовательностей) включает в себя 2000 примеров. Количество сегментов класса «пламя» в обучающей выборке для видеопоследовательностей с пламенем составило 7000, класса «дым» – 5000, индифферентный класс – 6500. Общая продолжительность видеопоследовательностей составила около 20 мин.

Для оценки качества работы предложенного метода использованы показатели: точность – TR (рассчитывается как отношение сегментов, класс которых определен правильно, к общему числу классифицируемых сегментов), чувствительность (показатель ошибок первого рода) – S (отношение правильно классифицированных сегментов заданного класса к общему числу сегментов этого класса в контрольной выборке – характеризует ложно отрицательное срабатывание решающего правила); специфичность (показатель ошибок второго рода) – Sp (отношение правильно классифицированных сегментов индиффе-

рентного класса к общему числу сегментов этого класса в контрольной выборке – характеризует ложноположительное срабатывание решающего правила).

В контрольную выборку видеопоследовательностей входили снимки, на которых присутствовали сегменты различных классов (табл. 1). На некоторых снимках имелся сложный динамический фон, который отражался на классифицируемых сегментах. На некоторых кадрах присутствовали одновременно классы сегментов «пламя» и «дым», например Bilkent\controlled2 кадр 101 и Bilkent\fire1 кадр 439. Если хотя бы один из сегментов снимка был отнесен к классу «пламя», то снимок определялся как снимок с пламенем.

В таблице 2 приведены результаты экспериментальных исследований показателей качества классификации двух альтернативного классификатора, настроенного на дискриминацию класса «пламя» и индифферентного класса.

В таблице 3 приведены результаты экспериментальных исследований показателей качества классификации при обнаружении дыма в сегментах аэроснимков. Как и при обнаружении пламени, сегменты снимков видеоряда разделены на две группы: сегменты, содержащие дым, и без него (индифферентный класс).

Таблица 1. Примеры тестовых снимков из базы данных Bilkent

Table 1. Examples of test snapshots from the Bilkent database

Описание тестовой видеопоследовательности	Образец кадра	Описание тестовой видеопоследовательности	Образец кадра
Bilkent\controlled1 кадр 203 Разрешение, пиксели: 320x240 Количество кадров: 260 Объекты на видео: пламя		Dyntex\649h920 кадр 261 Разрешение, пиксели: 320x240 Количество кадров: 707 Видео без дыма и пламени	
Bilkent\controlled2 кадр 101 Разрешение, пиксели: 320x240 Количество кадров: 246 Объекты на видео: пламя, дым		Dyntex\ForestFire1 кадр 105 Разрешение, пиксели: 320x240 Количество кадров: 218 Объекты на видео: пламя, дым	
Bilkent\controlled3 кадр 85 Разрешение, пиксели: 320x240 Количество кадров: 208 Объекты на видео: пламя		Dyntex\6ammi00 кадр 108 Разрешение, пиксели: 320x240 Количество кадров: 664 Объекты на видео: пламя	
Bilkent\fire1 кадр 439 Разрешение, пиксели: 320x240 Количество кадров: 708 Объекты на видео: пламя, дым		Dyntex\55fc410 кадр 108 Разрешение, пиксели: 320x240 Количество кадров: 250 Объекты на видео: дым	
Bilkent\forest1 кадр 129 Разрешение, пиксели: 320x240 Количество кадров: 200 Объекты на видео: пламя, дым		Bilkent\Smoke_Manavgat_Raw кадр 2941 Разрешение, пиксели: 320x240 Количество кадров: 6046 Объекты на видео: дым	
Dyntex\647b610, кадр 98 Разрешение, пиксели: 320x240 Количество кадров: 250 Видео без дыма и пламени		Bilkent\sorgun1 кадр 509 Разрешение, пиксели: 320x240 Количество кадров: 609 Объекты на видео: дым	

Таблица 2. Показатели эффективности метода для класса «пламя»**Table 2.** Indicators of the effectiveness of the method for the "flame" class

Класс	S, %	Sp, %	TR, %	Кол-во сегментов
Пламя	89,5	95,5	89,5	280
Инди́фферентный	95	90		320

Таблица 3. Показатели эффективности метода для класса «дым»**Table 3.** Indicators of the effectiveness of the method for the class "smoke"

Класс	S, %	Sp, %	TR, %	Кол-во сегментов
Дым	86	87	86,2	300
Инди́фферентный	85	86		320

Критерием достоверности классификации считали *результат исследования аэроснимка*, выполненный двумя ЛПР.

Выводы

Итак:

1. Разработан метод классификации морфологических образований на аэроснимках, полученных при мониторинге АТЕ посредством БПЛА. Метод основан на определении дескрипторов выделенных прямоугольных сегментов заданных размеров посредством определения спектров Уолша – Адамара в трех типоразмерах окон, сформированных в этом сегменте. Метод позволяет настраивать (обучать) классификаторы на обнаружение заданных классов морфологических образований на снимках видеоданных, полученных с видеокамер БПЛА.

2. Выбраны критерии качества классификации морфологических образований на аэроснимках видеоряда. На основе выбранных критериев качества сегментации проведена апробация классификаторов по дискриминации сегментов класса «пламя» и класса «дым» и сегментов инди́фферентного класса.

3. Экспериментальные исследования по классификации снимком из видеоряда классификаторами, построенными на основе предлагаемого метода, показали среднее значение ошибок первого рода при обнаружении дыма в сегменте аэроснимка 14 %, а пламени – 10,5 %. Ошибки второго рода при обнаружении дыма в среднем составили 13 %, а при обнаружении пламени – 4,5%. Таким образом, предложенный метод классификации сегментов снимков видеоряда показал высокое качество классификации при дискриминации сегментов классов «пламя» и «дым».

Список литературы

1. Anna V. Pyataeva and Oleg E. Bandeev. Video Based Flame and Smoke Detection // Journal of Siberian Federal University. Engineering & Technologies. 2019. Vol. 12(5). P. 542-554.
2. Томакова Р. А., Емельянов С. Г., Филист С. А. Интеллектуальные технологии сегментации и классификации биомедицинских изображений: монография / Юго-Зап. гос. ун-т. Курск, 2012. 222 с.
3. Автоматические классификаторы сложно структурируемых изображений на основе мультиметодных технологий многокритериального выбора / М. В. Дюдин, И. В. Зуев, С. М. Чудинов [и др.] // Вопросы радиоэлектроники. Серия: Системы и средства отображения информации и управления спецтехникой (СОИУ). 2015. Вып. 1. С. 130–141.
4. Автоматизированная система для классификации заболеваний молочной железы по рентгеновским маммографическим снимкам / А. Р. Дабагов, И. А. Малютина, Д. С. Кондрашов [и др.] // Прикаспийский журнал: управление и высокие технологии. 2019. № 4 (48). С. 10-24.
5. Филист С. А., Шаталова О. В., Ефремов М. А. Гибридная нейронная сеть с макрослоями для медицинских приложений // Нейрокомпьютеры. Разработка, применение. 2014. № 6. С. 35–39.
6. An Automated System for Classification of Radiographs of the Breast / A. R. Dabagov, V. A. Gorbunov, S. A. Filist, I. A. Malyutina, D. S. Kondrashov // Biomedical Engineering. 2020. Vol. 53, no. 6. P. 425-428. <https://doi.org/10.1007%2Fs10527-020-09957-7>.
7. Метод классификации сложноструктурируемых изображений на основе самоорганизующихся нейросетевых структур / О. В. Шаталова, А. А. Кузьмин, К. Д. А. Кассим [и др.] // Радиопромышленность. 2016. № 4. С. 57-65.
8. Hybrid Intelligent Models for Chest X-Ray Image Segmentation / S. A. Filist, R. A. Tomakova, S. V. Degtyarev, A. F. Rybochkin // Biomedical Engineering. 2018. Vol. 51, no. 5. P. 358-363. <https://doi.org/article/10.1007/s10527-018-9748-5>.
9. Многослойные морфологические операторы для сегментации сложноструктурируемых растровых полутоновых изображений / А. Р. Дабагов, И. А. Малютина, Д. С. Кондрашов [и др.] // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика, медицинское приборостроение. 2019. Т. 9, № 3. С. 44-63.
10. Метод каскадной сегментации рентгенограмм молочной железы / С. А. Филист, А. Р. Дабагов, Р. А. Томакова, И. А. Малютина, Д. С. Кондрашов // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2019. Т. 9, № 1 (30). С. 49-61.

11. Малютин И. А., Кузьмин А. А., Шаталова О. В. Методы и алгоритмы анализа рентгенограмм грудной клетки, использующие локальные окна в задачах обнаружения патологий // Прикаспийский журнал: управление и высокие технологии. 2017. № 3(39). С. 131-138.

12. Моделирование морфологических образований на рентгенограммах грудной клетки в интеллектуальных диагностических системах медицинского назначения / П. С. Кудрявцев, А. А. Кузьмин, Д. Ю. Савинов, С. А. Филист, О. В. Шаталова // Прикаспийский журнал: управление и высокие технологии. 2017. № 3 (39). С. 109-120.

13. Формирование признакового пространства для задач классификации сложно-структурируемых изображений на основе спектральных окон и нейросетевых структур / К. Д. А. Кассим, А. А. Кузьмин, О. В. Шаталова [и др.] // Известия Юго-Западного государственного университета. 2016. № 4(67). С. 56-68.

14. Томакова Р. А., Филист С. А., Дураков И. В. Программное обеспечение автоматической классификации рентгенограмм грудной клетки на основе гибридных классификаторов // Экология человека. 2018. № 6. С. 59-64.

15. Bilkent database // Bilkent SPG. URL: <http://signal.ee.bilkent.edu.tr/Visi-Fire/Demo/FireClips/> (дата обращения: 10.09.2021).

References

1. Anna V. Pyataeva and Oleg E. Bandeev. Video Based Flame and Smoke Detection. *Journal of Siberian Federal University. Engineering & Technologies*, 2019, vol. 12(5), pp. 542-554.

2. Tomakova R. A., Emelyanov S. G., Philist S. A. *Intellectual'nye tekhnologii segmentatsii i klassifikatsii biomeditsinskikh izobrazhenii* [Intelligent technologies for segmentation and classification of biomedical images]. Kursk, Southwest State University Publ., 2012. 222 p.

3. Dyudin M. V., Zuev I. V. Chudinov S. M., eds. *Avtomatizirovannaya sistema dlya klassifikatsii zabolevaniy molochnoi zhe-lezy po rentgenovskim mammograficheskim snimkam* [Automatic classifiers of complexly structured images based on multi-method technologies of multicriteria choice]. *Voprosy radioelektroniki. Seriya: Sistemy i sredstva otobrazheniya informa-tsii i upravleniya spetstekhniki (SOIU) = Problems of Radio Electronics. Series: Systems and Means of Information Display and Control of Special Equipment (SOIU)*, 2015, is. 1, pp. 130–141.

4. Dabagov A. R., Malyutina I. A., Kondrashov D. S., eds. *Gibridnaya neironnaya set' s makrosloyami dlya meditsinskikh prilozhenii* [Automated system for the classification of breast diseases by x-ray mammographic images]. *Neirokomp'yutery. Razrabotka, primeneniye = Caspian Journal: Management and High Technologies*, 2019, no. 4 (48), pp. 10-24.

5. Philist S. A., Shatalova O. V., Efremov M. A. Gibrnidnaya neironnaya set' s makrosloyami dlya meditsinskikh prilozhenii [Hybrid neural network with macro layers for medical applications]. *Neirokomp'yutery. Razrabotka, primenenie = Neurocomputers. Development, Application*, 2014, no. 6, pp. 35–39.

6. Dabagov A. R., Gorbunov V. A., Filist S. A., Malyutina I. A., Kondrashov D. S. An Automated System for Classification of Radiographs of the Breast. *Biomedical Engineering*, 2020, vol. 53, no. 6, pp. 425-428. <https://doi.org/10.1007/s10527-020-09957-7>

7. Shatalova O. V., Kuzmin A. A., Kasim K. D. A., eds. Metod klassifikatsii slozhnostrukturiruemykh izobrazhenii na osnove samoorganizuyushchikhsya neurosetevykh struktur [Method of classification of complex structured images based on self-organizing neural network structures]. *Radiopromyshlennost' = Radio Industry*, 2016, no. 4, pp. 57-65.

8. Filist S. A., Tomakova R. A., Degtyarev S. V., Rybochkin A. F. Hybrid Intelligent Models for Chest X-Ray Image Segmentation. *Biomedical Engineering*, 2018, vol. 51, no. 5, pp. 358-363. <https://doi.org/article/10.1007/s10527-018-9748-5>

9. Dabagov A. R., Malyutina I. A., Kondrashov D. S., eds. Mnogosloynnye morfologicheskie operatory dlya segmentatsii slozhnostruk-turiruemykh rastrovyykh polutonovykh izobrazhenii [Multilayer morphological operators for segmentation of complex structured raster half-tone images]. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwestern State University. Series: Management, Computer Engineering, Computer Science. Medical Instrumentation*, 2019, vol. 9, no. 3, pp. 44-63.

10. Filist S. A., Dabagov A. R., Tomakova R. A., Malyutina I. A., Kondrashov D. S. Metod kaskadnoi segmentatsii rentgenogramm molochnoi zhelezy [Method of cascade segmentation of breast radiographs]. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwestern State University. Series: Management, Computer Engineering, Computer Science. Medical Instrumentation*, 2019, vol. 9, no. 1 (30), pp. 49-61.

11. Malyutina I. A., Kuzmin A. A., Shatalova O. V. Metody i algoritmy analiza rentgenogramm grudnoi kletki, ispol'zuyushchie lokal'nye okna v zadachakh obnaruzheniya patologii [Methods and algorithms for analyzing chest radiographs using local windows in pathology detection tasks]. *Prikaspiiskii zhurnal: upravlenie i vysokie tekhnologii = Caspian Journal: Management and High Technologies*, 2017, no. 3(39), pp. 131-138.

12. Kudryavtsev P. S., Kuzmin A. A., Savinov D. Yu., Filist S. A., Shatalova O. V. Modelirovanie morfologicheskikh obrazovaniy na rentgenogrammakh grud-noi kletki v intellektual'nykh diagnosticheskikh sistemakh meditsinskogo naznacheniya [Modeling of morpho-

logical formations on chest radiographs in intelligent diagnostic medical systems]. *Pri-kaspiiskii zhurnal: upravlenie i vysokie tekhnologii = Caspian Journal: Management and High Technologies*, 2017, no. 3 (39), pp. 109-120.

13. Kassim K. D. A., Kuzmin A. A., Shatalova O. V., eds. Formirovanie priznakovogo prostranstva dlya zadach klassifikatsii slozh-nostrukturiruemyykh izobrazhenii na osnove spek-tral'nykh okon i neirosetevykh struktur [Formation of a feature space for classification prob-lems of complex structured images based on spectral windows and neural network structures]. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University*, 2016, no. 4(67), pp. 56-68.

14. Tomakova R. A., Filist S. A., Durakov I. V. Programmnoe obespechenie avtomatich-eskoi klassifikatsii rentgenogramm grudnoi kletki na osnove gibridnykh klassifikatorov [Soft-ware for automatic classification of chest radiographs based on hybrid classifiers]. *Ekologiya cheloveka = Human Ecology*, 2018, no. 6, pp. 59-64.

15. Bilkent database. Available at: <http://signal.ee.bilkent.edu.tr/VisiFire/Demo/Fire-Clips/>. (accessed 10.09.2021)

Информация об авторах / Information about the Authors

Филист Сергей Алексеевич, доктор технических наук, профессор кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: sfilist@gmail.com

Sergey A. Filist, Dr. of Sci. (Engineering), Professor of the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation, e-mail: sfilist@gmail.com

Шевцов Максим Викторович, аспирант, Академия Государственной противопожарной службы МЧС России, г. Москва, Российская Федерация, e-mail: shevtsovmv@mail.ru

Maxim V. Shevtsov, Post-Graduate Student, Academy of the State Fire Service of the Ministry of Emergency Situations of Russia, Moscow, Russian Federation, e-mail: shevtsovmv@mail.ru

Белозеров Владимир Анатольевич, кандидат медицинских наук, ведущий специалист, Курская областная многопрофильная клиническая больница, г. Курск, Российская Федерация, e-mail: b9102107495@yandex.ru, ORCID: 0000-0003-2028-746X

Vladimir A. Belozеров, Cand. of Sci. (Medical), Leading Specialist, Kursk Regional Multidisciplinary Clinical Hospital, Kursk, Russian Federation, e-mail: b9102107495@yandex.ru, ORCID: 0000-0003-2028-746X

Кондрашов Дмитрий Сергеевич, аспирант,
Юго-Западный государственный университет,
г. Курск, Российская Федерация,
e-mail: kondrashov012@mail.ru

Dmitry S. Kondrashov, Post-Graduate Student,
Southwest State University, Kursk, Russian
Federation,
e-mail: kondrashov012@mail.ru

Горбачев Игорь Николаевич, аспирант,
Юго-Западный государственный университет,
г. Курск, Российская Федерация,
e-mail: Gorbachev.agps@yandex.ru

Igor N. Gorbachev, Post-Graduate Student,
Southwest State University, Kursk,
Russian Federation,
e-mail: Gorbachev.agps@yandex.ru

Корсунский Никита Александрович, аспирант,
Юго-Западный государственный университет,
г. Курск, Российская Федерация,
e-mail: cor.nick2013@yandex.ru

Nikita A. Korsunsky, Post-Graduate Student,
Southwest State University, Kursk, Russian
Federation,
e-mail: cor.nick2013@yandex.ru