

Автоматическое распознавание частиц на цифровых изображениях

Е. С. Опарин¹, М. А. Дзус¹✉, Н. Н. Давыдов¹, К. С. Хорьков¹

¹ Владимирский государственный университет имени Александра Григорьевича
и Николая Григорьевича Столетовых
ул. Горького, д. 87, г. Владимир 600026, Российская Федерация

✉ e-mail: dzus00@mail.ru

Резюме

Цель исследования – разработка и сравнение различных методов и алгоритмов для эффективного анализа частиц на основе их визуальных характеристик. Автоматическое распознавание частиц на цифровых изображениях является актуальной проблемой в области научных исследований. В работе рассматриваются два принципиально разных подхода – анализ градиентов оттенков серого и метод машинного обучения.

Методы. Методология исследования включает анализ изображений частиц, полученных осаждением из коллоидных растворов после лазерной абляции и изображений частиц порошка для селективного лазерного плавления. Материалы получены на электронном микроскопе Quanta 200 3D (FEI). Для анализа применяется бинаризация по пороговой яркости, методы распознавания контуров оператором Кенни и алгоритм Хафа для объединения точек границы в связанные контуры. Для сравнения использовано нейросетевое решение U-Net, для обучения нейросети был создан генератор датасета. В качестве данных для генерации используются вырезанные вручную изображения частиц порошка алюмелевого сплава и микро- и наночастиц различных металлов.

Результаты исследования показывают, что метод Хафа обеспечивает распознавание количества частиц на уровне 80%, а метод машинного обучения достигает 95%-ной точности распознавания формы частиц. Оба метода могут быть применены для анализа микро- и наночастиц, включая частицы неправильной формы.

Заключение. Выводы работы подтверждают, что нейронные сети являются оптимальным решением для автоматического распознавания частиц на цифровых изображениях. Однако для создания датасета достаточного объема необходимо разработать генератор размеченных изображений, что требует детального исследования предметной области.

Ключевые слова: автоматическое распознавание; микро- и наночастицы; цифровые изображения; обработка изображений; машинное обучение; алгоритмы распознавания.

Конфликт интересов: Авторы декларируют отсутствие конфликта интересов, связанных с публикацией данной статьи.

Для цитирования: Автоматическое распознавание частиц на цифровых изображениях / Е. С. Опарин, М. А. Дзус, Н. Н. Давыдов, К. С. Хорьков // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2024. Т. 14, № 1. С. 50–66. <https://doi.org/10.21869/2223-1536-2023-14-1-50-66>.

Поступила в редакцию 17.01.2024

Подписана в печать 14.02.2024

Опубликована 29.03.2024

Automatic Particle Recognition Based on Digital Image Processing

Egor S. Oparin, Maria A. Dzus, Nikolay N. Davydov, Kirill S. Khorkov

¹ Vladimir State University named after Alexander and Nikolai Stoletovs
87 Gorky Str., Vladimir 600026, Russian Federation

✉ e-mail: dzus00@mail.ru

Abstract

The purpose of the research is to develop and compare various methods and algorithms for effective particle analysis based on their visual characteristics. The purpose of this article is to develop and compare various methods and algorithms for effective particle analysis based on their visual characteristics. The paper considers two fundamentally different approaches: the analysis of grayscale gradients and the machine learning method.

Methods. The research methodology includes the analysis of particle images obtained by precipitation from colloidal solutions after laser ablation and images of powder particles for selective laser melting. The materials were obtained using a Quanta 200 3D electron microscope (FEI). For the analysis, threshold brightness binarization, contour recognition methods by the Kenny operator and the Hough algorithm are used to combine boundary points into connected contours. For comparison, the U-Net neural network solution was used, and a dataset generator was created to train the neural network. Hand-cut images of aluminum alloy powder particles and micro and nanoparticles of various metals are used as data for generation.

Results. The results of the study show that the Hough method provides recognition of the number of particles at the level of 80%, and the machine learning method achieves 95% accuracy in recognizing the shape of particles. Both methods can be used to analyze micro- and nanoparticles, including irregularly shaped particles.

Conclusion. The findings of the work confirm that neural networks are the optimal solution for automatic particle recognition in digital images. However, in order to create a dataset of sufficient volume, it is necessary to develop a generator of labeled images, which requires a detailed study of the subject area.

Keywords: automatic recognition; micro- and nanoparticles; digital images; image processing; machine learning; recognition algorithms.

Conflict of interest: The authors declares no conflict of interest related to the publication of this article.

For citation: Oparin E. S., Dzus, M. A. Davydov N. N., Khorkov K. S. Automatic Particle Recognition Based on Digital Image Processing. *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): 50–66. (In Russ.) <https://doi.org/10.21869/2223-1536-2024-14-1-50-66>.

Received 17.01.2024

Accepted 14.02.2024

Published 29.03.2024

Proceedings of the Southwest State University. Series: Control, Computer Engineering,
Information Science. Medical Instruments Engineering. 2024; 14(1): 50–66




Рис. 2. Блок-схема алгоритма преобразования Хафа для объектов на изображении

Fig. 2. The block diagram of the Hough transform algorithm for objects in the image

Данный метод эффективен для объектов определенных форм, таких как линии, круги или эллипсы, при этом объекты должны иметь четкие границы перепада пикселей для точного выделения краев.

Также классическим является метод препарирования сложных многосвязных плоских изображений (рис. 3). В качестве исходной информации предполагается массив контурных точек, полученных при минимизации изображения. Наиболее простыми и эффективными при реализации препарирования сложных изображений являются

принципы формирования односвязных контуров, основанные на сравнении по ряду критериев элементов дискретизации, описывающих исходную многосвязную геометрическую систему. Блок-схема данного метода представлена на картинке. Для реализации данного метода необходимо выполнить несколько этапов: 1) выбор опорной точки; 2) нахождение точки в поле поиска, ближайшей к опорной; 3) пересылка найденного в поле поиска элемента контура и массив точек формируемого односвязного контура.




Рис. 3. Блок-схема алгоритма обработки многосвязных плоских изображений

Fig. 3. Block diagram of the algorithm for processing multi-connected flat images

Для достижения лучших результатов зачастую изображения подвергаются предобработке различными фильтрами [10], производится бинаризация изображений [11]. При распознавании символов либо букв применяют поиск опорных точек либо разбиение области интереса на зоны фиксированным шагом [12]. Оба эти способа не применимы при распознавании частиц случайной формы.

В работе [13] представлены подходы к автоматическому распознаванию наложенных объектов с использованием сверточных нейронных сетей. Большинство задач распознавания решаются с

использованием языка Python и различных библиотек этого языка [14].

В статье [15] исследуется применение методов машинного обучения для автоматического распознавания и классификации различных объектов. Авторы предлагают использовать сверточные нейронные сети архитектуры U-Net для извлечения признаков и классификации объектов на основе изображений. Создается база данных (датасет), состоящая из пар изображений – оригинальное изображение и маска (рис. 4). Матрица размером ширины и высоты изображения, где элементы матрицы, – это 0, если пиксель относится к фону, или целое число n , если этот пиксель относится к объекту класса с номером n .




Рис. 4. Изображения, полученные методом машинного обучения: а – оригинальное; б – бинаризация; в – маска для датасета

Fig. 4. Images obtained by machine learning: а – original; б – binarization; в – mask for the data set

После создания датасета с выделенными классами по этой базе происходит обучение нейронной сети, т. е. составляется матрица весов, которая впоследствии будет использована при анализе нового входного изображения уже без маски. Это метод эффективен для распознавания простых объектов, в противном случае появляется необходимость в создании огромной базы данных, учитывающей все возможные классы и формы частиц, содержащей много тысяч изображений для классификации. Использование датасетов требуется при применении любого нейросетевого решения [16].

Также существуют и другие архитектуры нейронных сетей, для которых изображения в датасете не имеют масок, а размечаются текстовыми метками – названиями классов [17]. Практически в каждой для обучения используется метод обратного распространения ошибки [18].

Таким образом, рассмотренные источники показывают, что в данной области существует несколько подходов и методов для распознавания и классификации различных объектов. Приведенные методы чаще включают в себя использование нейронных сетей для целей классификации и анализ текстур, градиентов яркости для целей подсчета

объектов по контурам. Вторые имеют меньшую вычислительную сложность и чаще используются для распознавания в видеопотоке [19].

Одним из примененных методов являлся анализ текстур. Данный метод имеет наименьшую применимость для изображений, полученных с помощью растрового электронного микроскопа, так как они уже имеют градиенты серых оттенков. Распознавание частиц происходит неправильно.

На рисунке 5 каждый цвет контура показывает границы объектов. Видно, что границы пикселей не совпадают с контурами объектов.




Рис. 5. Реализация метода анализа текстур и градиентов серого


Fig. 5. Implementation of the method for analyzing textures and gray gradients

Для оптимизации был использован алгоритм объединения (рис. 3). Необходимо выполнить несколько этапов для формирования односвязного контура из контуров, которые представлены выше (рис. 5). С этой целью были использованы параметры, представленные в таблице 1, необходимые для реализации алгоритма Хафа.


Таблица 1. Параметры алгоритма Хафа

Table 1. Parameters of the Hough algorithm

Параметр	Значение
Пикселей между центрами кругов	1
Минимальное расстояние между центрами	20
Минимальный порог	10
Максимальный порог	30
Минимальный радиус частиц	25
Максимальный радиус частиц	40



а



б

Рис. 6. Результат распознавания алгоритмом Хафа с изменяемыми параметрами:
а – исходное изображение; б – результат программы, определено 115 частиц

Fig. 6. The result of recognition by the Hough algorithm with variable parameters:
а – the original image; б – the result of the program, 115 particles are determined




Рис. 7. Результат распознавания одиночной частицы на изображении с помощью алгоритма Хафа с изменяемыми параметрами: *а* – исходное изображение; *б* – результат программы, определена 1 частица

Fig. 7. The result of recognizing a single particle in the image using Hough's algorithm with variable parameters: *a* – the original image; *b* – the result of the program, 1 particle is determined

Выявлены недостатки метода сложных многосвязных плоских изображений: требуется тщательное изучение структуры изображения, оценка возможных образующихся форм. Для каждой формы необходим алгоритм ее определения. В показанном случае был использован только алгоритм Хафа для поиска исключительно сферических частиц. В общем случае для каждого изображения необходимо подбирать изменяемые параметры для эффективного распознавания. В показанном на рисунке 6, б случае удовлетворительно определено только количество частиц с точностью около 80%, многие частицы несферической

формы были классифицированы алгоритмом Хафа как круги.

Результаты и их обсуждение

В качестве примера использования метода машинного обучения была использована архитектура нейронной сети, разработанная для сегментации изображений U-Net [20]. Она применяется для задач сегментации, когда требуется выделить определенный объект или область изображения. При ручной разметке датасета выделялись границы искоемых частиц и осуществлялось обучение нейронной сети по нескольким изображениям, результаты распознавания представлены ниже (рис. 8).




Рис. 8. Результат распознавания с ручной разметкой для архитектуры U-Net:
а – изображение, на котором происходило обучение;
б – изображение, не участвовавшее в обучении

Fig. 8. The result of recognition with manual markup for the U-Net architecture:
а – the image on which the training took place;
б – an image that was not involved in the training

На рисунке 8 показано, что при первичном использовании датасета из 2 изображений размером 1000x1000 пикселей и примерно 50 размеченных частиц каждого класса (круг, овал, бесформенная частица) нейронная сеть частично может выполнить поставленную задачу – с удовлетворительной точностью посчитано количество частиц. Определение формы частиц оценивается как неудовлетворительное, и дальнейший анализ на основе выявленных контуров невозможен.

Выявленные недостатки нейронной сети U-Net: зависимость от наличия большого объема размеченных данных, создание которого является сложным и затратным процессом; неэффективность в случае сильного несоответствия размеров объектов.

В качестве оптимизации использования нейронной сети был создан генератор обучающего датасета. Генератор представляет собой необходимый инструмент, который автоматически создает синтетические данные для использования в машинном обучении на основе реализации алгоритма, представленного на рисунке 9. Из входных данных, вырезанных «вручную» отдельных частиц разных форм (рис. 10), генерируются изображения 1000×1000 пикселей с разным количеством частиц. Объекты располагаются в случайных местах изображения с применением операций поворота и масштаба (рис. 11). Также генератор автоматически создает маску для каждого изображения.




Рис. 9. Блок-схема алгоритма генератора обучающего датасета

Fig. 9. Block diagram of the algorithm of the training dataset generator




Рис. 10. Частицы, использованные в генераторе датасета

Fig. 10. Particles used in the dataset generator




Рис. 11. Создаваемые генератором изображения

Fig. 11. Images created by the generator

Преимущества использования генератора обучающего датасета:

1. Экономия времени и ресурсов. Генератор датасета автоматически создает данные, что позволяет избежать необходимости собирать или размечать данные вручную.

2. Увеличение разнообразия данных. Генератор позволяет создавать данные с различными характеристиками, что помогает повысить разнообразие и состав датасета. Это особенно полезно, когда требуется обучить модель на данных разных типов или различных вариаций определенных параметров.

3. Контроль над параметрами данных. Генератор дает возможность

настраивать параметры создаваемых данных, такие как распределение, шум, корреляция.

Однако следует учитывать главный недостаток генераторов – возможная неправдоподобность данных. Генераторы обучающих датасетов могут создавать данные, которые не всегда соответствуют реальным объектам. Важно тщательно проверять создаваемые данные и удостовериться в их достоверности и применимости для конкретной задачи. Результат распознавания после обучения нейронной сети на сгенерированных синтетических данных показан ниже (рис. 12).




Рис. 12. Результат распознавания на реальном изображении после обучения только на синтетических данных

Fig. 12. Recognition result on a real image after training only on synthetic data

Выводы

Разработаны методы анализа изображений на основе распознавания контуров и алгоритма Хафа, на основе нейросетового решения U-Net. В качестве исходных данных взяты изображения с растрового электронного микроскопа Quanta 200 3D (FEI) – частицы порошка алюминия для селективного лазерного плавления, а также частицы, образованные осаждением коллоидных растворов после абляции лазерным излучением различных металлов. Оптимальным способом

признаются нейронные сети, но для создания датасета достаточного объема требуется создать правдоподобный генератор размеченных изображений, что требует тщательного анализа предметной области.

Результатом получилось распознавание количества частиц методом Хафа на 80% и 95% распознавания форм методом машинного обучения. Оба приведенных метода могут применяться для анализа микро- и наночастиц, в т. ч. неправильной формы.

Список литературы

1. Гуляев П. В., Шелковников Е. Ю., Ермолин К. С. Обработка и распознавание изображений реперных отметок для локализации зонда в сканирующем туннельном микроскопе // Химическая физика и мезоскопия. 2018. Т. 20, № 3. С. 437–445.

2. Многопоточная архитектура программного обеспечения обработки многоканальных медицинских сигналов / М. Б. Мяснянкин, А. А. Кузьмин, В. В. Серебровский, Е. А. Алдохин // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2022. Т. 12, № 2. С. 76–97.
3. Аллаберганов А. А. Метод распознавания текстовой информации из цифровой формы (изображение), определение очередности нанесения реквизитов // Закон и право. 2020. № 4. С. 187–193.
4. Гундин А. А., Гундина М. А., Чешкин А. Н. Обработка цифровых изображений при дефектоскопии поверхностей промышленных объектов // Наука и техника. 2016. Т. 15, № 3. С. 225–232.
5. Лапко А. В., Лапко В. А. Непараметрические алгоритмы оценивания состояний природных объектов // Автометрия. 2018. Т. 54, № 5. С. 33–38. <https://doi.org/10.15372/AUT20180504>.
6. Арлазаров В. В., Булатов К. Б., Усков А. Б. Модель системы распознавания объектов в видеопотоке мобильного устройства // Труды Института системного анализа Российской академии наук. 2018. Спецвыпуск. С. 73–82.
7. Борзов С. М., Потатуркин О. И. Исследование эффективности спектрально-пространственной классификации данных гиперспектральных наблюдений // Автометрия. 2017. Т. 53, № 1. С. 32–42.
8. Inception-v4, Inception-Resnet and the impact of residual connections on learning / C. Szegedy, S. Ioffe, V. Vanhoucke [et al.] // Proceedings of the AAAI Conference on Artificial Intelligence. San Francisco, California, USA: AAAI Press, 2017. P. 4278–4284.
9. Automatic Detection and Counting of Circular Shaped Overlapped Objects Using Circular Hough Transform and Contour Detection / Jianjun Ni, Zubair Khan, Shihao Wang, Kang Wang, Syed Kamran Haider // 12th World Congress on Intelligent Control and Automation (WCICA). Guilin, China: IEEE, 2016. P. 2902–2906.
10. Конаныхин А. Ю., Конаныхина Т. Н., Панищев В. С. Методы улучшения выделенной области изображения при быстросействующей обработке символьной информации // Известия Юго-Западного государственного университета Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2021. Т. 11, № 4. С. 106–116.
11. Местецкий Л. Непрерывная морфология бинарных изображений. Фигуры, скелеты, циркуляры. М.: Физматлит, 2009. 286 с.
12. Распознавание символьной информации для автоматизации производственных процессов / В. С. Панищев, М. И. Труфанов, О. Г. Добросердов, О. О. Хомяков //

Известия Юго-Западного государственного университета. 2021. Т. 25, № 1. С. 122–137. <https://doi.org/10.21869/2223-1560-2021-25-1-122-137>.

13. Hybrid Neural Network Architecture for Multi-Label Object Recognition using Feature Fusion / Divya Meena S., Veeramachaneni Gayathri Siva Sameeraja, Nagineni Sai Lasya, Mada Sathvika, Veluru Harshitha, J. Sheela // *Procedia Computer Science*. 2022. N 215. P. 78–90.

14. Manaswi N. K. *Deep Learning with Applications Using Python*. New York, USA: Springer Science – Business Media, 2018. 219 p.

15. PDAtt-Unet: Pyramid Dual-Decoder Attention Unet for COVID-19 infection segmentation from CT-scans / F. Bougourzi, C. Distant, F. Dornaika, A. Taleb-Ahmed // *Medical Image Analysis*. 2023. N 86 (17). P. 102797.

16. Low-cost automated whole smear microscopy screening system for detection of acid fast bacilli / Y. N. Law, H. Jian, N. W. S. Lo [et al.] // *PLoS One*. 2018. N 1 (13). P. 1–8.

17. Полковникова Н. А. Нейросетевые системы автоматического распознавания морских объектов // *Эксплуатация морского транспорта*. 2019. № 4. С. 207–219. <https://doi.org/10.34046/aumsuomt94/29>.

18. Абдулкадиров Р. И., Ляхов П. А. Новый подход к обучению нейронных сетей с помощью натурального градиентного спуска с импульсом на основе распределений дирихле // *Компьютерная оптика*. 2023. № 1. С. 160–170.

19. Попов Г. А., Попова Т. А. Сравнение алгоритмов распознавания объектов // *Инновация в информатике*. 2020. Т. 14, № 2. С. 21–25.

20. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation // *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. Cham: Springer, 2015. P. 234–241. https://doi.org/10.1007/978-3-319-24574-4_28.

References

1. Gulyaev P. V., Shelkovnikov E. Yu., Ermolin K. S. Obrabotka i raspoznavanie izobrazhenij reперnyh otmetok dlya lokalizacii zonda v skaniruyushchem tunnel'nom mikroskope [Image processing and recognition of reference marks for probe localization in a scanning tunneling microscope]. *Himicheskaya fizika i mezoskopiya = Chemical Physics and Mesoscopy*, 2018, vol. 20, no. 3, pp. 437–445.

2. Myasnyankin M. B., Kuzmin A. A., Serebrovskiy V. V., Aldokhin E. A. Mnogopotochnaya arhitektura programmogo obespecheniya obrabotki mnogokanal'nyh medicinskih signalov [Multithreaded software architecture for processing multicameral medical signals]. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Medicinskoe priborostroenie = Proceedings of the Southwest*

State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering, 2022, vol. 12, no. 2, pp. 76–97.

3. Allaberganov A. A. Metod raspoznavaniya tekstovoj informacii iz cifro-voj formy (izobrazhenie), opredelenie ocherednosti naneseniya rekvizitov [The method of recognizing textual information from a digital form (image), determining the order of application of details]. *Zakon i pravo = Law and Law*, 2020, no. 4, pp. 187–193.

4. Gundin A. A., Gundina M. A., Cheshkin A. N. Obrabotka cifrovyyh izobrazhenij pri defektoskopii poverhnostej promyshlennykh ob"ektov [Processing of digital images during flaw detection of surfaces of industrial objects]. *Nauka i tekhnika = Science and Technology*, 2016, vol. 15, no. 3, pp. 225–232.

5. Lapko A. V., Lapko V. A. Neparametricheskie algoritmy ocenivaniya sostoyanij prirodnykh ob"ektov [Nonparametric algorithms for determining the position of primary objects]. *Avtometriya = Autometry*, 2018, vol. 54, no. 5, pp. 33–38. <https://doi.org/10.15372/AUT20180504>

6. Arlazarov V. V., Bulatov K. B., Uskov A. B. Model' sistemy raspoznavaniya ob"ektov v videopotoke mobil'nogo ustrojstva [Model of the object recognition system in the video stream of mobile device]. *Trudy Instituta sistemnogo analiza Rossijskoj akademii nauk = Proceedings of the Institute of System Analysis of the Russian Academy of Sciences*, 2018, special is., pp. 73–82.

7. Borzov S. M., Potaturkin O. I. Issledovanie effektivnosti spektral'no-prostranstvennoj klassifikacii dannykh giperspektral'nykh nablyudenij [Investigation of the effectiveness of spectral-spatial classification of hyperspectral observation data]. *Avtometriya = Autometry*, 2017, vol. 53, no. 1, pp. 32–42.

8. Segedi S., Ioffe S., Vanhoek V., eds. Inception-v4, Inception-Resnet and the influence of residual connections on learning. Proceedings of the AAAI conference on Artificial intelligence. San Francisco, California, USA, AAAI Press Publ., 2017, pp. 4278–4284.

9. Jianjun Ni, Zubair Khan, Shihao Wang, Kang Wang and Syed Kamran Haider. Automatic detection and counting of overlapping circular objects using circular Hough transform and contour detection. 12th World Congress on Intelligent Control and Automation (WCICA). Guilin, China, IEEE Publ., 2016. pp. 2902–2906.

10. Konanykhin A. Yu., Konanykhina T. N., Panishchev V. S. Metody uluchsheniya vydelennoj oblasti izobrazheniya pri bystrodejstvuyushchej obrabotke simvol'noj informacii [Methods of improving the divided image area with high-speed processing of symbolic information]. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Medicinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*, 2021, vol. 11, no. 4, pp. 106–116.

11. Mestetsky L. Nepreryvnaya morfologiya binarnykh izobrazhenij. Figury, skelety, sirkulyary [Continuous morphology of binary images. Figures, skeletons, circulars]. Moscow, Fizmatlit Publ., 2009. 286 p.
12. Panishchev V. S., Trufanov M. I., Dobroserdov O. G., Khomyakov O. O. Raspoznavanie simvol'noj informacii dlya avtomatizacii proizvodstvennykh processov [Recognition of symbolic information for automation of production processes]. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University*, 2021, no. 25(1), pp. 122–137. <https://doi.org/10.21869/2223-1560-2021-25-1-122-137>
13. Divya Meena S., Viramachaneni Gayatri Shiva Samiraja, Nagineni Sai Lasya, Mada Satvika, Veluru Harshita, J. Shila. Architecture of a hybrid neural network for recognizing objects with multiple labels using feature fusion. *Procedia Computer Science*, 2022, no. 215, pp. 78–90.
14. Manasvi N. K. Deep learning using Python applications. New York, USA, Springer Science – Business Media Publ., 2018. 219 p.
15. Bougourzi F., Distant C., Dornaika F., Taleb-Ahmed A. PDAtt-Unet: Pyramid Dual-Decoder Attention Unet for COVID-19 infection segmentation from CT-scans. *Medical Image Analysis*, 2024, no. 86(17), p. 102797.
16. Law Y. N., Jian H., Lo N. W. S., eds. Low-cost automated whole smear microscopy screening system for detection of acid fast bacilli. *PLoS One*, 2018, no. 1 (13), pp. 1–8.
17. Polkovnikova N. A. Nejrosetevye sistemy avtomaticheskogo raspoznavaniya morskikh ob"ektov [Neural network systems for automated recognition of marine objects]. *Ekspluatatsiya morskogo transporta = Encyclopedia of Marine Transport*, 2019, no. 4, pp. 207–219. <https://doi.org/10.34046/aumsuomt94/29>
18. Abdulkadirov R. I., Lyakhov P. A. Novyj podhod k obucheniyu nejronnykh setej s pomoshch'yu natural'nogo gradientnogo spuska s impul'som na osnove raspredelenij dirihle [A new approach to training neural networks using natural gradient descent with an impulse based on Dirichlet distributions]. *Komp'yuternaya optika = Computer Optics*, 2023, no. 1, pp. 160–170.
19. Popov G. A., Popova T. A. Sravnenie algoritmov raspoznavaniya ob"ektov [Comparison of object recognition algorithms]. *Innovatsiya v informatike = Innovation in Computer Science*, 2020, vol. 14, no. 2, pp. 21–25.
20. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional networks for segmentation of biomedical images. Medical image processing and computer intervention – MICCAI 2015. Cham, Springer Publ., 2015, pp. 234–241. https://doi.org/10.1007/978-3-319-24574-4_28

Информация об авторах / Information about the Authors

Опарин Егор Сергеевич, аспирант, ассистент кафедры физики и прикладной математики, Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых, г. Владимир, Российская Федерация, e-mail: oparines@vlsu.ru, ORCID: 0009-0001-6154-906X

Egor S. Oparin, Post-Graduate Student, Assistant of the Department of Physics and Applied Mathematics, Vladimir State University named after Alexander and Nikolai Stoletovs, Vladimir, Russian Federation, e-mail: oparines@vlsu.ru, ORCID: 0009-0001-6154-906X

Дзус Мария Александровна, аспирант, Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых, г. Владимир, Российская Федерация, e-mail: dzus00@mail.ru, ORCID: 0009-0003-8071-8150

Maria A. Dzus, Post-Graduate Student, Vladimir State University named after Alexander and Nikolai Stoletovs, Vladimir, Russian Federation, e-mail: dzus00@mail.ru, ORCID: 0009-0003-8071-8150

Давыдов Николай Николаевич, доктор технических наук, профессор, Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых, г. Владимир, Российская Федерация, e-mail: n.n.davydov@mail.ru, ORCID: 0009-0003-3392-818X

Nikolay N. Davydov, Doctor of Sciences (Engineering), Professor, Vladimir State University named after Alexander and Nikolai Stoletovs, Vladimir, Russian Federation, e-mail: n.n.davydov@mail.ru, ORCID: 0009-0003-3392-818X

Хорьков Кирилл Сергеевич, кандидат физико-математических наук, директор Института прикладной математики, физики и информатики, Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых, г. Владимир, Российская Федерация, e-mail: khorkov@vlsu.ru, ORCID: 0000-0002-5402-0846

Kirill S. Khorkov, Candidate of Sciences (Physics and Mathematics), Director of the Institute of Applied Mathematics, Physics and Computer Science, Vladimir State University named after Alexander and Nikolai Stoletovs, Vladimir, Russian Federation, e-mail: khorkov@vlsu.ru, ORCID: 0000-0002-5402-0846