

УДК 620.187

Оригинальная статья

АВТОМАТИЧЕСКИЙ АНАЛИЗ ИЗОБРАЖЕНИЙ МИКРОСКОПИИ С ПРИМЕНЕНИЕМ ОБЛАЧНОГО СЕРВИСА DLGRAM01

А.В. Матвеев¹, М.Ю. Машуков¹, А.В. Нартова^{2,1}, Н.Н. Санькова^{2,1}, А.Г. Окунев^{1,2}

¹ФГБАОУ ВО «Новосибирский национальный исследовательский государственный университет»

630090, Россия, Новосибирск, ул. Пирогова, 1

²ФГБУН «Институт катализа им. Г.К. Борескова Сибирского отделения Российской академии наук»

630090, Россия, Новосибирск, пр. Академика Лаврентьева, 5

matveev.nsu@mail.ru

DOI: 10.26456/pcascnn/2021.13.300

Аннотация: Исследование материалов методами микроскопии нередко включает стадию подсчета количества наблюдаемых объектов и определения их статистических параметров, для чего необходимо измерять сотни объектов. В работе описан облачный сервис DLgram01, который позволяет специалистам в области материаловедения, не имеющих навыков программирования, выполнять автоматизированную обработку изображений – определять количество и параметры (площадь, размер) изучаемых объектов. Сервис разработан с использованием новейших достижений в области глубокого машинного обучения, для обучения нейронной сети пользователю необходимо разметить несколько изучаемых объектов. Обучение нейронной сети производится автоматически за несколько минут. Важными особенностями сервиса DLgram01 является возможность корректировать результаты предсказания нейронной сети, а также получение детальной информации о всех распознанных объектах. Использование сервиса позволяет существенно сократить временные затраты на количественный анализ изображений, снизить влияние субъективного фактора, повысить точность анализа и его эргономичность.

Ключевые слова: микроскопия, распознавание, наночастицы, глубокие нейронные сети, искусственный интеллект.

1. Введение

В настоящее время в материаловедении использование различных методов микроскопии стало «золотым стандартом». Изучение свойств материалов невозможно без исследования их структуры и морфологических особенностей с привлечением микроскопии. Широкое распространение получили сканирующая и просвечивающая электронные микроскопии (СЭМ, ПЭМ), зондовые методы – сканирующая туннельная и атомно-силовая микроскопии (СТМ, АСМ) и др. Помимо качественного анализа изображений, зачастую необходимо проводить количественный анализ изучаемых объектов, определять их статистические параметры, например, количество объектов, размер отдельных объектов и средний размер, степень покрытия и т.д.

Характерные особенности обработки изображений

На рис. 1 а представлено типичное изображение наночастиц металла

в оксидной матрице носителя, полученное с помощью метода ПЭМ. Неоднородный фон, перекрытие проекций частиц и «утолщение» материала подложки усложняют идентификацию частиц. Для изображений СТМ (см. рис. 1 б) характерным является наличие шумов, в том числе выбросов и полос, а также градиентов интенсивности и т.д. Реализованные в широко-распространенных программных пакетах обработки изображений (WSxM [1], Gwyddion [2], ImageJ/Fiji [3]) процедуры автоматического определения объектов, основанные на пороговом поиске частей изображения с интенсивностью выше определенного пользователем значения, дают недостоверные результаты в случае изображений, содержащих шумы или градиенты интенсивности. Пример применения процедуры «flooding» в программе WSxM приведен на рис. 2.




Рис. 1. Примеры изображений наночастиц платины, а – метод ПЭМ; б – СТМ.




Рис. 2. Пример автоматического распознавания объектов на изображении СТМ: а – исходное изображение; б – результаты применения процедуры «flooding» в программе WSxM; в – гистограмма распределения по размерам 196 частиц, определенных процедурой «flooding», а также 377 частиц, измеренных оператором, по оси абсцисс масштаб представлен в логарифмическом масштабе.

Нейронные сети как перспективный метод обработки изображений

Наиболее перспективным подходом, обеспечивающим распознавание объектов на уровне высококвалифицированного специалиста, является применение методов искусственного интеллекта, основанных на глубоком машинном обучении. Активное применение глубокого машинного обучения для анализа изображений наблюдается в биологии [4-6]. В 2020 году появились бесплатные веб-сервисы для автоматического распознавания клеток Cellpose [7] и DeepCell Kiosk [8].

С 2016 г. глубокое обучение стало применяться для автоматического распознавания объектов в материаловедении. Например, ряд исследований был направлен на поиск дефектов в металлах, ряда специфических объектов на изображениях ПЭМ, СЭМ и др. [9-13]. Были достигнуты определенные результаты в области обработки ПЭМ-изображений с использованием нейронных сетей. В 2019 году авторы работ [14, 15] применили нейронные сети для поиска локализации круглых наночастиц на изображениях с равномерным и однородным шумом, размер частиц окончательно определялся путем фиттинга изображений частиц окружностями.

В 2019 году нами впервые были применены методы глубокого машинного обучения для автоматического распознавания наночастиц на изображениях, полученных с помощью СТМ [16]. В 2020 году на основе обученной нейронной сети мы разработали бесплатный веб-сервис ParticlesNN который может быть использован любым исследователем в мире [17].

Несмотря на появление бесплатных сервисов, таких как Cellpose, DeepCell Kiosk и ParticlesNN, предлагаемые подходы не предоставляют возможности пользователям, не имеющим навыков программирования, применять их для обучения нейронных сетей на своих специфических объектах, отличающихся по морфологии от тех, для которых описанные сервисы создавались, вынуждая прилагать значительные усилия и самостоятельно проходить классический путь обучения [18-20]. Целью нашей работы являлось создание сервиса, позволяющего специалистам в области материаловедения, не имеющим навыков программирования, выполнять автоматизированную обработку изображений, самостоятельно обучая глубокую нейронную сеть с использованием лишь нескольких размеченных объектов на собственных изображениях. Важными задачами при разработке сервиса являлись минимизация времени, необходимого для разметки, обучения нейронной сети и распознавания ею объектов, а также возможность корректировки результатов распознавания нейронной сети и получение информации о каждом распознанном объекте.

2. Описание работы облачного сервиса DLgram01

Общий алгоритм

На рис. 3 представлен реализованный алгоритм действия сервиса, содержащий следующие этапы обработки изображений: разметка объектов на изображении, загрузка данных в сервис, обучение нейронной сети, распознавание всех объектов на изображении, выгрузка результатов обработки изображения, корректировка распознанных объектов, статистическая обработка данных.




Рис. 3. Алгоритм действия сервиса DLgram01.

Разметка

Обучение нейронной сети в сервисе DLgram01 происходит на изображении с размеченными в программе LabelMe [21] объектами. Разметка объектов возможна полигонами, прямоугольниками или окружностями в двух режимах. Режим разметки «отдельных объектов» рекомендуется в случае монодисперсных либо находящихся на большом расстоянии друг от друга объектов. При разметке в режиме «группы объектов» на изображении выделяется прямоугольная область, обозначается как «кроп» и размечаются все объекты, которые находятся в кропе или частично пересекаются с ним. Режим рекомендуется в случаях, если на масштабах больше размера кропа изображение имеет однородный характер, нет объектов, превышающих характерный размер кропа.

Загрузка изображения в сервис и выгрузка результатов обработки изображения

В качестве платформы для интерфейса сервиса мы использовали

Telegram-мессенджер, который имеет следующие функциональные преимущества перед традиционным веб-форматом и другими мессенджерами:

а) наличие клиентов как в виде мобильного приложения, так и для настольных компьютеров;

б) возможность оперативной поддержки обратной связи с пользователями;

в) возможность загрузки изображения в полном формате, в отличие от мессенджеров WhatsApp и Viber.

Для работы с сервисом DLgram01 пользователь должен присоединиться к группе Nanoparticles [22] и загрузить файл с размеченными объектами в формате JSON программы LabelMe, указав параметры обучения и распознавания. Например, файл ABC.JSON с параметрами «-e 50 -a 8 -t 0.3».

Данные с помощью чат-бота передаются на сервер Высшего колледжа информатики НГУ (ВКИ НГУ) для их обработки нейронной сетью. Аналогично, чат-бот пересылает данные пользователю после проведения обучения и распознавания нейронной сетью объектов на изображении в виде файла в формате JSON программы LabelMe.

Нейронная сеть

В работе сервиса DLgram01 используется нейронная сеть Cascade Mask-RCNN с X-101-64×4d-FPN бэкбоном, которая ранее показала лучшие результаты по распознаванию наночастиц на изображениях СТМ [17] по сравнению с нейронной сетью U-net [23]. Нейронная сеть функционирует на графическом сервере HPE Apollo 6500 Gen10 с восемью карточками NVIDIA Tesla V-100, расположенном в ВКИ НГУ.

Параметры обучения нейронной сети

Для достижения лучшего результата обучения пользователь может подобрать самостоятельно наиболее подходящие для его задач параметры обучения нейронной сети.

Количество эпох обучения, указывается как «- e ...». Одна эпоха состоит из одного полного цикла тренировки нейронной сети. Чем больше размечено объектов, тем меньшее количество эпох требуется для обучения. Если размечено 10–20 объектов, то для обучения достаточно 100 эпох. Увеличение количества эпох приводит к увеличению времени для обучения.

Для минимизации усилий, необходимых для разметки большого количества объектов, в последнее время активно развиваются методы

аугментации, использующие различные способы искусственного увеличения размеченных данных: операции с цветом (корректировка цветовых каналов, изменение контрастности или яркости), геометрические операции (поворот изображения, отражение изображения и т.д.) и другие операции. Значение параметра аугментации, например, «-a 8» увеличивает количество размеченных объектов в 8 раз.

Порог срабатывания

При распознавании обученной нейронной сетью каждому объекту присваивается «степень доверия», число от 0 до 1. При указании параметра, например, «-t 0.3» пользователю представляются все объекты, степень доверия которых выше 0,3.

Распознавание объектов обученной нейронной сетью

В случае, если у пользователя есть несколько изображений с аналогичными объектами, то достаточно обучить нейронную сеть на одном из изображений. Например, для обучения использовался файл ABC.JSON. Загружая остальные в исходном графическом формате, пользователю достаточно указать обозначение набора параметров обученной сети и порог срабатывания, например, «-n ABC -t 0.3».

Корректировка распознанных объектов

Важной особенностью сервиса DLgram01 является возможность корректировки пользователем результатов распознавания объектов нейронной сетью. Для этого необходимо открыть полученный файл в формате JSON в программе LabelMe и провести корректировку контуров – добавить пропущенные, удалить ошибочно распознанные и т.п.

Получение статистических данных по объектам

Другой отличительной особенностью сервиса DLgram01 является получение исходной статистической информации по обнаруженным нейронной сетью объектам. Для этого в программе LabelMe необходимо нажать кнопку «Calculate stat», после чего в директории расположения исходного файла ABC.JSON, формируется файл ABC.CSV в формате программы Excel с информацией по каждому объекту – его площадью и проекционному диаметру, определяемому как $d = (4S / \pi)^{0.5}$, где S – площадь объекта.

3. Пример обработки изображения. Анализ результатов

На рис. 4 представлен пример обработки сервисом DLgram01 СТМ-изображения палладиевых наночастиц [17]. Параметры обучения: 100

эпох, аугментация 8 и порог срабатывания 0,3. На рис. 4 а показано исходное изображение. На рис. 4 б – изображение с размеченными пользователем прямоугольным кропом и 16 полигонами, пересекающимися с кропом. На рис. 4 в представлены результаты распознавания наночастиц сетью, обученной на 16 объектах рис. 4 б. На рис. 4 г приведено исходное изображение с размеченными оператором 172 частицами.




Рис. 4. Пример обработки СТМ-изображения палладиевых наночастиц: а – исходное изображение; б – кроп и 16 контуров, пересекающихся с кропом, размеченных пользователем для обучения нейронной сети; в – 169 наночастиц, предсказанных обученной нейронной сетью, 16 из которых определены ошибочно (контуров черного цвета); г – изображение с размеченными оператором 172 частицами, белым цветом

обозначены контуры, не имеющие аналогов среди предсказанных нейронной сетью.

Из 169 частиц, предсказанных нейронной сетью, 16 не имеют аналогов на разметке оператора (ложноположительные объекты). Кроме того, 20 частиц не были обнаружены сетью (ложноотрицательные объекты). Рассчитанные параметры «точности» (precision) и отзыва (recall) [17] нейронной сети составляют 0,91 и 0,88 соответственно. По вышеописанной процедуре была осуществлена корректировка результатов, предсказанных нейронной сетью: пользователем были удалены контуры, ошибочно предсказанные сетью и добавлены пропущенные частицы. Результаты распределения частиц по размерам, а также средние значения размера и стандартные отклонения приведены в Таблице 1 и на рис. 5. Видно, что распознавание нейронной сетью в автоматическом режиме дает высокую точность определения размера частиц, которую можно еще больше повысить, проводя последующую незначительную дообработку полученных результатов.

Таблица 1. Результаты обработки изображения, представленного на рис. 4 а.

Метод определения размера частиц	Среднее значение проекционного диаметра, пиксели	Стандартное отклонение	Точность определения размера, %
Оператор	33,19	0,55	
Предсказанные нейронной сетью	33,96	0,55	97,6
После корректировки пользователем	33,10	0,53	99,7




Рис. 5. Гистограмма распределения частиц по размерам, рассчитанная по результатам разметки оператора (круглые символы), предсказания нейронной сетью (квадратные символы) и коррекции пользователем (треугольные символы).

3. Заключение

Разработанный облачный сервис DLgram01 является универсальным методом, с помощью которого можно проводить автоматический подсчет количества объектов и их параметры. Для использования сервиса не требуется владения специальными навыками программирования. Сервис реализован на базе новейших достижений в области глубокого машинного обучения. Обучение нейронной сети производится автоматически за несколько минут. Использование сервиса позволяет как минимум на порядок сократить временные затраты на количественный анализ изображений, снизить влияние субъективного фактора, повысить точность анализа и его эргономичность.

Работа выполнена при финансовой поддержке РФФИ (проект № 22-23-00951) с использованием оборудования ЦКП «Национальный центр исследования катализаторов»; доступ к базам данных предоставлен ИК СО РАН (проект № АААА-А21-121011390011-4).

Библиографический список:

1. **Horcas, I.** WSXM: a software for scanning probe microscopy and a tool for nanotechnology / I. Horcas, R. Fernández, J.M. Gómez-Rodríguez et al. // Review of Scientific Instruments. – 2007. – V. 78. – I. 1. – P. 013705-1-013705-8. DOI: 10.1063/1.2432410.
2. **Nečas, D.** Gwyddion: an open-source software for SPM data analysis / D. Nečas, P. Klapetek // Central European Journal of Physics. – 2012. – V. 10. – I. 1. – P. 181-188. DOI: 10.2478/s11534-011-0096-2.
3. **Schindelin, J.** Fiji: an open-source platform for biological-image analysis / J. Schindelin, I. Arganda-Carreras, E. Frise et al. // Nature Methods. – 2012. – V. 9. – I. 7. – P. 676-682. DOI: 10.1038/nmeth.2019.
4. **Moen, E.** Deep learning for cellular image analysis / E. Moen, D. Bannon, T. Kudo et al. // Nature Methods. – 2019. – V. 16. – I. 12. – P. 1233-1246. DOI: 10.1038/s41592-019-0403-1.
5. **Caicedo, J.** Nucleus segmentation across imaging experiments: the 2018 Data Science Bowl / J. Caicedo, A. Goodman, K. Karhohs et al. // Nature Methods. – 2019. – V. 16. – I. 12. – P. 1247-1253. DOI: 10.1038/s41592-019-0612-7.
6. **Yi, J.** Pixel-wise neural cell instance segmentation / J. Yi, P. Wu, D.J. Hoepfner, D. Metaxas // 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018), 4-7 April 2018, Washington, DC, USA. – 2018. – P. 373-377. DOI: 10.1109/ISBI.2018.8363596.
7. **Stringer, C.** Cellpose: a generalist algorithm for cellular segmentation / C. Stringer, M. Michaelos, M. Pachitariu // Nature Methods. – 2021. – V. 18. – I. 1. – P. 100-106. DOI: 10.1038/s41592-020-01018-x.
8. **Bannon, D.** DeepCell Kiosk: scaling deep learning-enabled cellular image analysis with Kubernetes / D. Bannon, E. Moen, M. Schwartz et al. // Nature Methods. – 2021. – V. 18. – I. 1. – P. 43-45. DOI: 10.1038/s41592-020-01023-0.
9. **Fu, G.** Deep-learning-based approach for fast and robust steel surface defects classification / G. Fu, P. Sun, W. Zhu et al. // Optics and Lasers in Engineering. – 2019. – V. 121. – P. 397-405. DOI: 10.1016/j.optlaseng.2019.05.005.
10. **Zhu, H.** Deep learning-based classification of weld surface defects / H. Zhu, W. Ge, Z. Liu // Applied Sciences. – 2019. – V. 9. – I. 16. – Art. № 3312. – 10 p. DOI: 10.3390/app9163312.
11. **Liu, Y.** Periodic surface defect detection in steel plates based on deep learning / Y. Liu, K. Xu, J. Xu // Applied Sciences. – 2019. – V. 9. – I. 15. – Art. № 3127. – 14 p. DOI: 10.3390/app9153127.
12. **Feng, S.** Using deep neural network with small dataset to predict material defects / S. Feng, H. Zhou, H. Dong // Materials & Design. – 2019. – V. 162. – P. 300-310. DOI: 10.1016/j.matdes.2018.11.060.
13. **Modarres, M.H.** Neural network for nanoscience scanning electron microscope image recognition / M.H. Modarres, R. Aversa, S. Cozzini et al // Scientific Reports. – 2017. – V. 7. – Art. № 13282. – 12 p. DOI: 10.1038/s41598-017-13565-z.

14. **Oktay, A.B.** Automatic detection, localization and segmentation of nano-particles with deep learning in microscopy images / A.B. Oktay, A. Gurses // *Micron*. – 2019. – V. 120. – P. 113-119. DOI: 10.1016/j.micron.2019.02.009.
15. **Zhang, F.** Spherical nanoparticle parameter measurement method based on Mask R-CNN segmentation and edge fitting / F. Zhang, Q. Zhang, Z. Xiao, J. Wu, Y. Liu // In: *Proceedings of the 8th International Conference on Computing and Pattern Recognition (ICCPR'19)*, 23-25 October 2019, Beijing, China. – New York: Association for Computing Machinery, 2019. – P. 205-212. DOI: 10.1145/3373509.3373590.
16. **Okunev, A.G.** Recognition of nanoparticles on scanning probe microscopy images using computer vision and deep machine learning / A.G. Okunev, A.V. Nartova, A.V. Matveev // In: *Proceedings of the International Multi-Conference on Engineering, Computer and Information Sciences (SIBIRCON)*, 21-27 October 2019 Novosibirsk, Russia. – Piscataway, NJ: IEEE Publishing, 2019. – P. 0940-0943. DOI: 10.1109/SIBIRCON48586.2019.8958363.
17. **Okunev, A.G.** Nanoparticle recognition on scanning probe microscopy images using computer vision and deep learning / A.G. Okunev, M.Y. Mashukov, A.V. Nartova, A.V. Matveev // *Nanomaterials*. – 2020. – V. 10. – I. 7. – Art. № 1285. – 16 p. DOI: 10.3390/nano10071285.
18. **Boiko, D.A.** Deep neural network analysis of nanoparticle ordering to identify defects in layered carbon materials / D.A. Boiko, E.O. Pentsak, V.A. Cherepanova, E.G. Gordeev, V.P. Ananikov // *Chemical Science*. – 2021. – V. 12. – I. 21. – P. 7428-7441. DOI: 10.1039/D0SC05696K.
19. **Davletshin, A.** Detection of framboidal pyrite size distributions using convolutional neural networks / A. Davletshin, L.T. Ko, K. Milliken, et al. // *Marine and Petroleum Geology*. – 2021. – V. 132. – Art. № 105159. – 24 p. DOI: 10.1016/j.marpetgeo.2021.105159.
20. **Monchot, P.** Deep learning based instance segmentation of titanium dioxide particles in the form of agglomerates in scanning electron microscopy / P. Monchot, L. Coquelin, K. Guerroudj et al. // *Nanomaterials*. – 2021. – V. 11. – I. 4. – Art. № 968. – 17 p. DOI: 10.3390/nano11040968.
21. **Wada, K.** Labelme: image polygonal annotation with python / K. Wada. – Режим доступа: www.url:https://github.com/wkentaro/labelme. – 17.08.2021.
22. Телеграм-канал Nanoparticles. – Режим доступа: www.url:https://t.me/nanoparticles_nsk. – 17.08.2021.
23. **Liz, M.F.** Using computer vision and deep learning for nanoparticle recognition on scanning probe microscopy images: modified U-net approach / M.F. Liz, A.V. Nartova, A.V. Matveev, A.G. Okunev // In: *Proceedings of the 2020 Science and Artificial Intelligence Conference (S.A.I.ence)*, 14-15 November 2020, Novosibirsk, Russia. – Piscataway, NJ: IEEE Publishing, 2020. – P. 13-16. DOI: 10.1109/S.A.I.ence50533.2020.9303184.

References:

1. Horcas I., Fernández R., Gómez-Rodríguez J.M. et al. WSXM: a software for scanning probe microscopy and a tool for nanotechnology, *Review of Scientific Instruments*, 2002, vol. 78, issue 1, pp. 013705-1-013705-8. DOI: 10.1063/1.2432410.
2. Nečas D., Klapetek P. Gwyddion: an open-source software for SPM data analysis, *Central European Journal of Physics*, 2012, vol. 10, issue 1, pp. 181-188. DOI: 10.2478/s11534-011-0096-2.
3. Schindelin J., Arganda-Carreras I., Frise E. et al. Fiji: an open-source platform for biological-image analysis, *Nature Methods*, 2012, vol. 9, issue 7, pp. 676-682. DOI: 10.1038/nmeth.2019.
4. Moen E., Bannon D., Kudo T., Graf W., Covert M., Van Valen D. Deep learning for cellular image analysis, *Nature Methods*, 2019, vol. 16, issue 12, pp. 1233-1246. DOI: 10.1038/s41592-019-0403-1.
5. Caicedo J., Goodman A., Karhohs K. et al. Nucleus segmentation across imaging experiments: the 2018 Data Science Bowl, *Nature Methods*, 2019, vol. 16, issue 12, pp. 1247-1253. DOI: 10.1038/s41592-019-0612-7.
6. Yi J., Wu P., Hoepfner D.J., Metaxas D. Pixel-wise neural cell instance segmentation, *2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)*, 4-7 April 2018, Washington, DC, USA, 2018, pp. 373-377. DOI: 10.1109/ISBI.2018.8363596.
7. Stringer C., Michaelos M., Pachitariu M. Cellpose: a generalist algorithm for cellular segmentation, *Nature Methods*, 2021, vol. 18, issue 1, pp. 100-106. DOI: 10.1038/s41592-020-01018-x.
8. Bannon D., Moen E., Schwartz M. et al. DeepCell Kiosk: scaling deep learning-enabled cellular image analysis with Kubernetes, *Nat Methods*, 2021, vol. 18, issue 1, pp. 43-45. DOI: 10.1038/s41592-020-01023-0.
9. Fu G., Sun P., Zhu W. et al. Deep-learning-based approach for fast and robust steel surface defects classification, *Optics and Lasers in Engineering*, 2019, vol. 121, pp. 397-405. DOI: 10.1016/j.optlaseng.2019.05.005.
10. Zhu H., Ge W., Liu Z. Deep learning-based classification of weld surface defects, *Applied Sciences*, 2019, vol. 9, issue 16, art. no 3312, 10 p. DOI: 10.3390/app9163312.

11. Liu Y., Xu K., Xu J. Periodic surface defect detection in steel plates based on deep learning, *Applied Sciences*, 2019, vol. 9, issue 15, art. no. 3127, 14 p. DOI: 10.3390/app9153127.
12. Feng S., Zhou H., Dong, H. Using deep neural network with small dataset to predict material defects, *Materials & Design*, 2019, vol. 162, pp. 300-310. DOI: 10.1016/j.matdes.2018.11.060.
13. Modarres M.H., Aversa R., Cozzini S. et al. Neural network for nanoscience scanning electron microscope image recognition, *Scientific Reports*, 2017, vol. 7, art. no 13282, 12 p.. DOI: 10.1038/s41598-017-13565-z.
14. Oktay A.B., Gurses A. Automatic detection, localization and segmentation of nano-particles with deep learning in microscopy images, *Micron*, 2019, vol. 120, pp. 113-119. DOI: 10.1016/j.micron.2019.02.009.
15. Zhang F., Zhang Q., Xiao Z., Wu J., Liu Y. Spherical nanoparticle parameter measurement method based on Mask R-CNN segmentation and edge fitting, *Proceedings of the 8th International Conference on Computing and Pattern Recognition (ICCPR'19)*, 23-25 October 2019, Beijing, China. New York, Association for Computing Machinery, 2019, pp. 205-212. DOI: 10.1145/3373509.3373590.
16. Okunev A.G., Nartova A.V., Matveev A.V., Recognition of nanoparticles on scanning probe microscopy images using computer vision and deep machine learning, *Proceedings of the International Multi-Conference on Engineering, Computer and Information Sciences (SIBIRCON)*, 21-27 October 2019, Novosibirsk, Russia, Piscataway, NJ, IEEE Publishing, 2019, pp. 0940-0943. DOI: 10.1109/SIBIRCON48586.2019.8958363.
17. Okunev A.G., Mashukov M.Y., Nartova A.V., Matveev A.V. Nanoparticle recognition on scanning probe microscopy images using computer vision and deep learning, *Nanomaterials*, 2020, vol. 10, issue 7, art. no. 1285, 16 p. DOI: 10.3390/nano10071285.
18. Boiko D.A., Pentsak E.O., Cherepanova V.A., Gordeev E.G., Ananikov V.P. Deep neural network analysis of nanoparticle ordering to identify defects in layered carbon materials, *Chemical Science*, 2021, vol. 12, issue 21, pp. 7428-7441. DOI: 10.1039/D0SC05696K.
19. Davletshin A., Ko L.T., Milliken K. et al. Detection of framboidal pyrite size distributions using convolutional neural networks, *Marine and Petroleum Geology*, 2021, vol. 132, art. no 105159, 24 p. DOI: 10.1016/j.marpetgeo.2021.105159.
20. Monchot P., Coquelin L., Guerroudj K. et al. Deep learning based instance segmentation of titanium dioxide particles in the form of agglomerates in scanning electron microscopy, *Nanomaterials*, 2021, vol. 11, issue 4, art. № 968, 17 p. DOI: 10.3390/nano11040968.
21. Wada K. Labelme: image polygonal annotation with python. – Access mode: [www.url: https://lammps.sandia.gov](https://lammps.sandia.gov). – 17.08.2021.
22. Telegram channel Nanoparticles. – Access mode: [www.url: https://t.me/nanoparticles_nsk](https://t.me/nanoparticles_nsk). – 17.08.2021.
23. Liz M.F., Nartova A.V., Matveev A.V., Okunev A.G., Using computer vision and deep learning for nanoparticle recognition on scanning probe microscopy images: modified U-net approach, *Proceedings of the 2020 Science and Artificial Intelligence conference (S.A.I.ence)*, 14-15 November 2020, Novosibirsk, Russia, Piscataway, NJ, IEEE Publishing, 2020, pp. 13-16. DOI: 10.1109/S.A.I.ence50533.2020.9303184.

Original paper

AUTOMATIC ANALYSIS OF MICROSCOPY IMAGES USING THE DLGRAM01 CLOUD SERVICE

A.V. Matveev¹, M.Y. Mashukov¹, A.V. Nartova^{2,1}, N.N. Sankova^{2,1}, A.G. Okunev^{1,2}

¹*Novosibirsk State University, Novosibirsk, Russia*

²*Boriskov Institute of Catalysis SB RAS, Novosibirsk, Russia*

DOI: 10.26456/pcascnn/2021.13.300

Abstract: The study of materials by microscopy often includes counting the number of observed objects and determining their statistical parameters, for which it is necessary to measure hundreds of objects. The created DLgram01 cloud service allows specialists in the field of materials science who do not have programming skills to perform automated image processing – to determine the number and parameters (area, size) of the objects under study. The service is developed using the latest achievements in the field of deep machine learning. To train a neural network, the user needs to label only several objects. The neural network is trained automatically in a few minutes. Important features of the DLgram01 service are the ability to adjust the results of neural network prediction, as well as obtaining detailed information about all recognized objects. Using the service allows to significantly decrease the time for quantitative image analysis, reduce the influence of the subjective factor, increase the accuracy of the analysis and its ergo-intensity.

Keywords: *microscopy, recognition, nanoparticles, deep neural networks, artificial intelligence.*

Матвеев Андрей Викторович, к.х.н., заведующий лабораторией глубокого машинного обучения в физических методах ФГБАОУ ВО «Новосибирский национальный исследовательский государственный университет»

Машуков Михаил Юрьевич, старший научный сотрудник лаборатории глубокого машинного обучения в физических методах ФГБАОУ ВО «Новосибирский национальный исследовательский государственный университет»

Нартова Анна Владимировна, к.х.н., доцент кафедры химии твердого тела ФГБАОУ ВО «Новосибирский национальный исследовательский государственный университет», старший научный сотрудник лаборатории исследования поверхности ФГБУН «Институт катализа им. Г.К. Борескова Сибирского отделения Российской академии наук»

Санькова Наталья Николаевна, младший научный сотрудник отдела нетрадиционных каталитических процессов ФГБУН «Институт катализа им. Г.К. Борескова Сибирского отделения Российской академии наук», младший научный сотрудник лаборатории интеллектуальных и аддитивных методов синтеза материалов ФГБАОУ ВО «Новосибирский национальный исследовательский государственный университет»

Окунев Алексей Григорьевич, к.х.н., директор Высшего колледжа информатики ФГБАОУ ВО «Новосибирский национальный исследовательский государственный университет», старший научный сотрудник группы темплатного синтеза ФГБУН «Институт катализа им. Г.К. Борескова Сибирского отделения Российской академии наук»

Andrey V. Matveev – Ph. D., Head of the Laboratory of Deep Machine Learning in Physical Methods, Novosibirsk State University

Mikhail Y. Mashukov – Senior Researcher, Laboratory of Deep Machine Learning in Physical Methods, Novosibirsk State University

Anna V. Nartova – Ph. D., Docent, Department of Solid State Chemistry, Novosibirsk State University, Senior Researcher of the Laboratory of Surface Science, Boreskov Institute of Catalysis SB RAS

Natalia N. Sankova, Junior Researcher, Department of Nontraditional Catalytic Processes, Boreskov Institute of Catalysis SB RAS, Junior Researcher, Laboratory of Intelligent and Additive Methods of Materials Synthesis, Novosibirsk State University

Alexey G. Okunev, PhD, Director of the Higher College of Informatics, Novosibirsk State University, Senior Researcher, Template Synthesis Group, Boreskov Institute of Catalysis SB RAS

Поступила в редакцию/received: 10.09.2021; после рецензирования/revised: 05.11.2021; принята/accepted 12.11.2021.