

Received: 06.04.2024

Revised: 29.07.2024

Accepted: 16.08.2024

DOI: 10.17804/2410-9908.2024.4.083-101

ANALYSIS OF METAL MICROSTRUCTURE BY NEURAL NETWORKS, EXEMPLIFIED BY SEGMENTATION OF CARBIDES IN COMPOSITE COATINGS

N. N. Soboleva

*Institute of Engineering Science, Ural Branch of the Russian Academy of Sciences,
34 Komsomolskaya St., Ekaterinburg, 620049, Russia*

*M. N. Mikheev Institute of Metal Physics, Ural Branch of the Russian Academy of Sciences,
18 S. Kovalevskoy St., Ekaterinburg, 620108, Russia*

 <https://orcid.org/0000-0002-7598-2980>  natashasoboleva@list.ru

Email: natashasoboleva@list.ru

Address for correspondence: ul. Komsomolskaya, 34, Ekaterinburg, 620049, Russia

Tel.: +7 (343) 362-3033

The use of artificial neural networks in metal science to solve image analysis problems, in particular segmentation or classification of metal microstructures, includes 6 main stages: problem definition, dataset collection, model selection, model training, model evaluation, and integration with an existing workflow. The paper discusses these stages in detail, provides an example of their implementation for semantic segmentation of microstructures of composite coatings containing coarse primary carbides. The separation of carbides by a neural network makes it possible to automate the process of determining their volume fraction in the coating structure.

Keywords: neural networks, image analysis, semantic segmentation, composite coatings, volume fraction

Acknowledgment

The work was performed under the state assignment for the IES UB RAS, theme No. 124020600045-0, and the IMP UB RAS, theme No. 121102900049-1 "Additivity". The equipment of the Plastometriya shared research facilities center of the IES UB RAS was used to obtain the microscopic images.

References

1. Saakov, D.V. Application of machine learning methods to optimize production processes in the metallurgical industry. *Innovatsii i Investitsii*, 2023, 5, 308–311. (In Russian).
2. Klyuev, A.V., Stolbov, V.Yu., Koptseva, N.V., and Efimova, Yu.Yu. Assessment of the strength characteristics of steels after thermomechanical treatment based on a neural network analysis of microstructures digital photographs. *Chernye Metally*, 2020, 6, 50–56. (In Russian).
3. Holm, E.A., Cohn, R., Gao, N., Kitahara, A.R., Matson, T.P., Lei B., and Yarasi S.R. Overview: computer vision and machine learning for microstructural characterization and analysis. *Metallurgical and Materials Transactions A: Physical Metallurgy and Materials Science*, 2020, 51 (12), 5985–5999. DOI: 10.1007/s11661-020-06008-4.
4. Gupta, S., Banerjee, A., Sarkar, J., Kundu, M., Sinha, S.K., Bandyopadhyay, N.R., and Ganguly, S. Modelling the steel microstructure knowledge for in-silico recognition of phases using machine learning. *Materials Chemistry and Physics*, 2020, 252, 123286. DOI: 10.1016/j.matchemphys.2020.123286.

5. Jang, J., Van, D., Jang, H., Baik, D.H., Yoo, S.D., Park, J., Mhin, S., Mazumder, J., and Lee, S.H. Residual neural network-based fully convolutional network for microstructure segmentation. *Science and Technology of Welding and Joining*, 2020, 25 (4), 282–289. DOI: 10.1080/13621718.2019.1687635.
6. Mulewicz, B., Korpala, G., Kusiak, J., and Prahl, U. Autonomous interpretation of the microstructure of steels and special alloys. *Materials Science Forum*, 2019, 949, 24–31. DOI: 10.4028/www.scientific.net/MSF.949.24.
7. DeCost, B.L., Francis, T., and Holm, E.A. Exploring the microstructure manifold: Image texture representations applied to ultrahigh carbon steel microstructures. *Acta Materialia*, 2017, 133, 30–40. DOI: 10.1016/j.actamat.2017.05.014.
8. De Albuquerque, V.H.C., Cortez, P.C., De Alexandria, A.R., and Tavares, J.M.R.S. A new solution for automatic microstructures analysis from images based on a backpropagation artificial neural network. *Nondestructive Testing and Evaluation*, 2008, 23 (4), 273–283. DOI: 10.1080/10589750802258986.
9. Kondo, R., Yamakawa, S., Masuoka, Y., Tajima, S., and Asahi, R. Microstructure recognition using convolutional neural networks for prediction of ionic conductivity in ceramics. *Acta Materialia*, 2017, 141, 29–38. DOI: 10.1016/j.actamat.2017.09.004.
10. Baskaran, A., Kautz, E.J., Chowdhary, A., Ma, W., Yener, B., and Lewis, D.J. Machine learning for microstructure characterization and materials design: a perspective. *JOM*, 2021, 73 (11), 3639–3657. DOI: 10.1007/s11837-021-04805-9.
11. Kovun, V.A. and Kashirina, I.L. Usage of U-Net and W-Net neural network architecture for steel sample metallographic analysis. *Vestnik VGU, Seriya Sistemnyi analiz i Informatsionnye Tekhnologii*, 2022, 1, 101–110. (In Russian). DOI: 10.17308/sait.2022.1/9205.
12. Wang, X.-d., Li, N., Su, H., and Meng, H.-m. Prior austenite grain boundary recognition in martensite microstructure based on deep learning. *Journal of Iron and Steel Research International*, 2023, 30, 1050–1056. DOI: 10.1007/s42243-023-00947-z.
13. Sharybin, S.I. *Avtomatizatsiya kontrolya kachestva funktsionalnykh materialov na osnove sredstv intellektualnoy podderzhki prinyatiya resheniy* [Automation of Quality Control of Functional Materials Based on Intellectual Decision Support Tools: Cand. Thesis]. Perm, 2015, 162 p. (In Russian).
14. Xie, L., Li, W., Fan, L., and Zhou, M. Automatic identification of the multiphase microstructures of steels based on ASPP-FCN. *Steel Research International*, 2023, 94, 2200204. DOI: 10.1002/srin.202200204.
15. Rose, D., Forth, J., Henein, H., Wolfe, T., and Qureshi, A.J. Automated semantic segmentation of NiCrBSi-WC optical microscopy images using convolutional neural networks. *Computational Materials Science*, 2022, 210, 111391. DOI: 10.1016/j.commatsci.2022.111391.
16. Sudyin, V.V. *Issledovanie osobennostey razrusheniya nizkolegirovannykh staley i ikh svarnykh soedineniy v intervale vyazko-khrupkogo perekhoda* [Investigation of the Features of Destruction of low-Alloy Steels and Their Welded Joints in the Interval of Ductile-Brittle Transition: Cand. Thesis]. Moscow, 2021, 189 p. (In Russian).
17. Krizhevsky, A., Sutskever, I., and Hinton, G.E. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 2017, 60 (6), 84–90. DOI: 10.1145/3065386.
18. Lukashik, D.V. Analysis of modern image segmentation methods. *Ekonomika i Kachestvo Sistem Svyazi*, 2022, 2 (24), 57–65. (In Russian).
19. Chen, Q., Zheng, C., Cui, Y., Lin, Y.-R., and Zinkle, S.J. A deep learning model for automatic analysis of cavities in irradiated materials. *Computational Materials Science*, 2023, 221, 112073. DOI: 10.1016/j.commatsci.2023.112073.
20. Hurtado, J.V. and Valada, A. Semantic scene segmentation for robotics. Ch. 12. In: *Deep Learning for Robot Perception and Cognition*, Academic Press, 2022, 279–311. DOI: 10.1016/B978-0-32-385787-1.00017-8.

21. Xu, H. and Huang, H. Plasma remelting and injection method for fabricating metal matrix composite coatings reinforced with tungsten carbide. *Ceramics International*, 2022, 48, 2645–2659. DOI: 10.1016/j.ceramint.2021.10.048.
22. ASTM E 562–02. Standard test method for determining volume fraction by systematic manual point count.
23. <https://siams.com/>
24. Kazakov, A.A. and Kiselev, D. Industrial application of thixomet image analyzer for quantitative description of steel and alloy's microstructure. *Metallography, Microstructure, and Analysis*, 2016, 5, 294–301. DOI: 10.1007/s13632-016-0289-6.
25. Schneider, C.A., Rasband, W.S., and Eliceiri, K.W. NIH Image to ImageJ: 25 years of image analysis. *Nature Methods*, 2012, 9, 671–675. DOI: 10.1038/nmeth.2089.
26. <https://jmicrovision.github.io/>
27. Jacobs, R. Deep learning object detection in materials science: current state and future directions. *Computational Materials Science*, 2022, 211, 111527. DOI: 10.1016/j.commatsci.2022.111527.
28. Benjdira, B., Bazi, Y., Koubaa, A. and Ouni, K. Unsupervised domain adaptation using generative adversarial networks for semantic segmentation of aerial images. *Remote Sensing*, 2019, 11, 1369. DOI: 10.3390/rs11111369.
29. Wang, M., Wu, F., and Zhao, J. A comprehensive research and strategy of transfer learning for image segmentation. In: *Lecture Notes on Data Engineering and Communications Technologies book series*, Springer, Cham, 2021, 88, 1394–1406. DOI: 10.1007/978-3-030-70665-4_152.
30. Aristov, G.V. and Klyuev, A.V. Recognition and classification of the microstructure of metals and alloys using deep neural networks. In: *Trudy XXVII Mezhdunarodnoj konferentsii po kompyuternoy grafike i mashinnomu zreniyu* [Proceedings of the 27th International Conference on Computer Graphics and Machine Vision GraphiCon, Perm, September 24–28, 2017]. PGNIU Publ., Perm, 2017, pp. 180–183. (In Russian).
31. Poletaeva, N.G. Classification of systems machine learning. *Vestnik Baltijskogo Federalnogo Universiteta im. I. Kanta. Seriya: Fiziko-Matematicheskie i Tekhnicheskie Nauki*, 2020, 1, 5–22. (In Russian).
32. <https://habr.com/ru/companies/smartengines/articles/264677>
33. Lozhkin, I.A., Dunaev, M.E., Zaitsev K.S., and Garmash, A.A. Augmentation of image sets for training neural networks in solving semantic segmentation problems. *International Journal of Open Information Technologies*, 2023, 11 (1), 109–117. (In Russian).
34. Soboleva, N. and Mushnikov, A. Improving the accuracy of semantic segmentation of carbides in the microstructure of composite coatings by the neural network. *Materials Today Communications*, 2024, 38, 108276. DOI: 10.1016/j.mtcomm.2024.108276.
35. Sikorsky, O.S. Overview of convolutional neural networks for image classification problem. *Novye Informatsionnye Tekhnologii v Avtomatizirovannykh Sistemakh*, 2017, 20, 37–42. (In Russian).
36. Ronneberger, O., Fischer, P., and Brox, T. U-Net: convolutional networks for biomedical image segmentation. In: N. Navab, J. Hornegger, W. Wells, A. Frangi, eds. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, Lecture Notes in Computer Science series, vol. 9351, Springer, Cham, 2015. DOI: 10.1007/978-3-319-24574-4_28
37. Badrinarayanan, V., Kendall, A., and Cipolla, R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39, 2481–2495. DOI: 10.1109/tpami.2016.2644615.
38. Long, J., Shelhamer, E., and Darrell, T. Fully convolutional networks for semantic segmentation. In: *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, MA, Boston, USA, 2015, IEEE, 2015, 3431–3440. DOI: 10.1109/cvpr.2015.7298965.

39. Zhao, H., Shi, J., Qi, X., Wang, X., Jia, J. Pyramid scene parsing network. In: *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, HI, Honolulu, USA, 2017, IEEE, 2017, 6230–6239. DOI: 10.1109/cvpr.2017.660.
40. Lin, G., Milan, A., Shen, C., and Reid, I. RefineNet: multi-path refinement networks for high-resolution semantic segmentation. In: *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, HI, Honolulu, USA, 2017, IEEE, 2017, 5168–5177. DOI: 10.1109/cvpr.2017.549.
41. Chen, L.C., Papandreou, G., Kokkinos, I., Murphy, K., and Yuille, A.L. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40 (4), 834–848. DOI: 10.1109/TPAMI.2017.2699184.
42. Chen, L.C., Papandreou, G., Schroff, F., and Adam, H. Rethinking atrous convolution for semantic image segmentation, 2017, 1706.05587. DOI: 10.48550/arXiv.1706.05587.
43. Soboleva, N.N. and Mushnikov, A.N. Determination of the volume fraction of primary carbides in the micro-structure of composite coatings using semantic segmentation. *Frontier Materials & Technologies*, 2023, 3, 95–102. DOI: 10.18323/2782-4039-2023-3-65-9.
44. Yamashita, R., Nishio, M., Do, R.K.G., and Togashi, K. Convolutional neural networks: an overview and application in radiology. *Insights into Imaging*, 2018, 9, 611–629. DOI: 10.1007/s13244-018-0639-9.
45. Vik, K.V., Druki, A.A., Grigoriev, D.S., and Spitsyn, V.G. Application of deep learning neural networks for solving the problem of forest fire segmentation on satellite images. *Vestnik Tomskogo Gosudarstvennogo Universiteta. Upravlenie, Vychislitel'naja Tekhnika i Informatika*, 2021, 55, 18–25. (In Russian). DOI: 10.17223/19988605/55/3.
46. Keskar, N., Mudigere, D., Nocedal, J., Smelyanskiy, M., and Tang, P. On large-batch training for deep learning: generalization gap and sharp minima, 2016, arXiv:1609.04836v2. DOI: 10.48550/arXiv.1609.04836.
47. Xu H., He, H., Zhang, Y., Ma, L., and Li, J. A comparative study of loss functions for road segmentation in remotely sensed road datasets. *International Journal of Applied Earth Observation and Geoinformation*, 2023, 116, 103159. DOI: 10.1016/j.jag.2022.103159.
48. Emelianov, V., Zhilenkov, A., Chernyi, S., Zinchenko, A., and Zinchenko, E. Application of artificial intelligence technologies in metallographic analysis for quality assessment in the shipbuilding industry. *Heliyon*, 2022, 8 (8), e10002. DOI: 10.1016/j.heliyon.2022.e10002.
49. Raketov, K.V., Israilev, N.Yu., Kazachkov, A.O., Zablotskaya, E.Yu., Rod, I.A., Ryabkov, M.S., Isachenko, A.V., and Shamiryan, D.G. Automated defect detection system in MEMS production. *Nanoindustriya*, 2018, 11, 7–8 (86), 542–548. (In Russian). DOI: 10.22184/1993-8578.2018.11.7-8.542.548.
50. <https://axalit.ru>
51. Matveev, A.V., Nartova, A.V., Sankova, N.N., and Okunev, A.G. DLgram cloud service for deep-learning analysis of microscopy images *Microscopy Research and Technique*, 2024, vol. 87 (5), pp. 991–998. DOI: 10.1002/jemt.24480.
52. https://t.me/nanoparticles_nsk
53. Soboleva, N.N. RF Software Registration Certificate No. 2023660789, 2023.

Подана в журнал: 06.04.2024
УДК 620.186:004.855.5
DOI: 10.17804/2410-9908.2024.4.083-101

АНАЛИЗ МИКРОСТРУКТУРЫ МЕТАЛЛА НЕЙРОННЫМИ СЕТЯМИ НА ПРИМЕРЕ СЕГМЕНТАЦИИ КАРБИДОВ В КОМПОЗИЦИОННЫХ ПОКРЫТИЯХ

Н. Н. Соболева

*Федеральное государственное бюджетное учреждение науки Институт машиноведения
им. Э. С. Горкунова Уральского отделения Российской академии наук,
ул. Комсомольская, 34, Екатеринбург, 620049, Россия
Федеральное государственное бюджетное учреждение науки
Институт физики металлов им. М. Н. Михеева Уральского отделения Российской академии наук,
ул. С. Ковалевской, 18, Екатеринбург, 620137, Россия*

 <https://orcid.org/0000-0002-7598-2980>  natashasoboleva@list.ru

Электронная почта: natashasoboleva@list.ru
Адрес для переписки: ул. Комсомольская, 34, Екатеринбург, 620049, Россия
Тел.: +7 (343) 362-30-33

Использование искусственных нейронных сетей в металловедении для решения задач анализа изображений, в частности сегментации или классификации микроструктур металлов, включает в себя 6 основных этапов: определение проблемы, составление набора данных, выбор модели, обучение модели, оценка модели, интеграция с существующим рабочим процессом. В статье подробно рассмотрены эти этапы, приводится пример их реализации для семантической сегментации микроструктур композиционных покрытий, содержащих крупные первичные карбиды. Выделение карбидов нейронной сетью позволяет автоматизировать процесс определения их объемной доли в структуре покрытий.

Ключевые слова: нейронные сети, анализ изображений, семантическая сегментация, композиционные покрытия, объемная доля

1. Введение

В настоящее время методы машинного обучения широко используются в различных отраслях промышленности, так как позволяют автоматизировать производственные процессы, улучшить качество продукции и снизить затраты на производство [1]. Современные методы машинного обучения применяют и в металловедении [2–4]. Так, в последнее время было проведено много исследований, использующих алгоритмы машинного обучения для классификации микроструктур [5–7], их количественного анализа [8], открытия новых материалов, обладающих полезными свойствами [9], и т. д.

При применении искусственных нейронных сетей в металловедении каноничной является цепочка из 6 этапов: определение проблемы, составление набора данных, выбор модели, обучение модели, оценка модели, интеграция с существующим рабочим процессом [10].

Однако исследовательские статьи в основном не нацелены на подробное описание методологии решения задачи, при этом в них используется специальная терминология, сложная для специалистов в области металловедения, не использующих нейронные сети в работе. Поэтому целью статьи является адаптация методологических подходов, используемых специалистами в области машинного обучения, к решению задачи металловедения на примере сегментации карбидов в композиционных покрытиях.

2. Этап 1: определение цели

Задачи металловедения, решаемые с использованием нейронных сетей, условно можно разделить на два класса по типу обрабатываемых данных. В первом случае происходит анализ изображений. Во втором случае реализуется работа нейросети с иными данными, устанавливаются взаимосвязи составов, структур и свойств, что в итоге позволяет прогнозировать эти характеристики, тем самым решая задачи оптимизации.

Настоящая работа посвящена анализу изображений. Он может включать в себя как выделение границ объектов, что, в частности, позволит определить границы зерен [11, 12], так и выделение самих объектов, что позволит распознавать структурные составляющие [13, 14], выделять вторую фазу [15], различать хрупкий/вязкий излом [16] и т. д. В результате решаются задачи классификации или сегментации.

Классификация изображений – это задача категоризации целого объекта. Например, в наборе изображений ImageNet [17] каждому изображению присваивается класс, независимо от того, является ли соответствующая информация только подмножеством изображения. При анализе изображений микроструктур в результате классификации возможно, например, отделить фотографии микроструктур без карбидов от фотографий микроструктур с карбидами (табл. 1, левый столбец).

Таблица 1

Пример классификации и семантической сегментации изображения микроструктуры композиционного покрытия



Сегментация относится к задаче разделения изображения на области (сегменты), принадлежащие одному и тому же объекту, и последующей классификации частей изображения. Таким образом, в результате сегментации распознается не только наличие объектов (карбидов) на изображении, но и занимаемое ими место на картинке. Существуют различные виды сегментации, например паноптическая, экземплярная [18], но в металловедении зачастую решается задача семантической сегментации, например: отделить карбиды на изображении структуры композиционного покрытия от остальной части микроструктуры, при этом нет необходимости отличать один карбид от другого (табл. 1, правый столбец). Семантическая сегментация классифицирует каждый пиксель и группирует вместе пиксели, принадлежащие одному и тому же объекту на изображении [19]. Модели семантической сегментации выдают

семантическое предсказание, которое содержит категории объекта, местоположения и формы всех элементов изображения, включая фон [20].

Решение задачи семантической сегментации карбидов в структуре композиционных покрытий позволит оценить объемную долю первичных карбидов в микроструктуре материала. Определение объемной доли первичных карбидов поможет выбрать такой режим наплавки, который обеспечивает сохранение наибольшего их количества в покрытии, так как это влияет на работоспособность покрытий в условиях абразивного изнашивания [21].

3. Возможные варианты решения задачи

До начала использования нейронной сети целесообразно проанализировать иные способы решения задачи.

Так, стандартизованным методом определения объемной доли второй фазы в микроструктуре является ручной точечный метод по ASTM E 562-02 [22]. Частично автоматизированным является использование программ, реализующих классические методы машинного зрения, например Siam [23], Thixomet [24], ImageJ [25], JMicroVision [26] и т. п. Однако использование этих методов может приводить к ошибкам из-за различной интерпретации результатов разными людьми и не масштабируется для больших размеров набора данных [27].

Новейшим способом определения объемной доли карбидов в микроструктуре покрытий является проведение семантической сегментации с использованием нейронных сетей, что позволит полностью автоматизировать процесс [15]. До того как программирование глубоких нейронных сетей получило широкое распространение, исследование алгоритмов семантической сегментации надолго застопорилось из-за низкой точности традиционных алгоритмов анализа изображений, основанных на ручном извлечении признаков [28]. Однако с появлением высокоописательных средств извлечения признаков, таких как сверточные нейронные сети, и усовершенствованием графических процессоров, которые обеспечивают огромную вычислительную мощность, необходимую для использования сверточных нейронных сетей, исследования в области семантической сегментации совершили крупный прорыв [29].

4. Этап 2: составление набора данных

Этап 2 – составление набора данных – является одним из самых трудоемких в случае отсутствия готового набора данных.

Некоторые исследователи загружают использованные в их работе наборы данных в открытые репозитории, оставляя ссылку на них в соответствующих публикациях. Например, в работе [15] содержится ссылка (<https://data.mendeley.com/datasets/2wmbc95xy9/1>) на набор изображений с оптического микроскопа для сегментации карбидов вольфрама в структуре композиционных материалов NiCrBSi–WC.

В работе [30] обучающее множество было сформировано из микрофотографий веб-ресурса DoITPoMS (Dissemination of IT for the promotion of Materials Science) Кембриджского университета, содержащего около 900 изображений микроструктур. Доступ к ним осуществляется по адресу: <https://www.doitpoms.ac.uk/>. Однако использование данного набора для решения практических задач затруднительно ввиду большого разнообразия представленных структур и малого количества изображений для каждого отдельного состояния, что препятствует выделению общих признаков при работе нейронной сети.

Таким образом, для решения конкретной практической задачи необходимо составлять собственный набор данных.

Существует три метода машинного обучения: с учителем, без учителя, с подкреплением [31]. В металловедении при сегментации микроструктур обучение нейронной сети обычно происходит с учителем, то есть на вход нейронной сети вместе с обучающим множеством (изображениями) подается правильный ответ распознавания. При обучении сеть кор-

ректирует весовые коэффициенты, исходя из разницы значений между фактическим ответом и ответом, данным «учителем» [30]. В связи с этим необходимы предварительно размеченные изображения. При этом при решении задач классификации (определения морфологического класса) достаточно одной метки на изображение, а при решении задач семантической сегментации (фазовой сегментации для количественного анализа) разметкой является одна метка на пиксель [10].

В задаче сегментации карбидов в композиционных покрытиях карбиды могут быть округлой или угловатой формы, выглядеть темнее или светлее матрицы на микрофотографиях; в структуре покрытий могут присутствовать поры; на изображениях могут быть участки, не относящиеся к микроструктуре (область с параметрами съемки); изображения могут быть разных размеров. Чтобы одна и та же нейронная сеть могла работать со всеми этими случаями, для ее обучения необходимо создать такой набор данных, который содержит в себе все те особенности, с которыми мы можем столкнуться при анализе.

На тех изображениях, где карбиды темнее матрицы и присутствуют поры, автоматизированные программы, решающие задачу сегментации по градиенту цветов, могут ошибочно принимать поры за карбиды. Области с параметрами съемки обычно предварительно отрезаются от изображения, однако в задуманной реализации работы нейронной сети эта область должна распознаваться сетью и вычитаться из общей площади изображения при последующем расчете объемной доли карбидов в структуре, что обеспечит максимальную автоматизацию процесса анализа. Таким образом, для автоматизации и снижения доли ошибок целесообразным является решение задачи многоклассовой сегментации, где сеть будет выделять также поры и области, не относящиеся к микроструктуре.

Были подготовлены изображения с оптического и электронного микроскопов, содержащие все эти особенности (рис. 1). Затем выполнялась ручная разметка изображений на 4 класса. Были созданы так называемые маски изображений (Ground Truth Images), на которых красный цвет соответствует нахождению в этой области карбидов, зеленый – пор, желтый соответствует части изображения, не относящейся к микроструктуре, белый – остальной части микроструктуры (рис. 2).

Состав обучающей базы, то есть количество изображений, на которых будет обучаться нейронная сеть, может оказывать на качество получающейся системы распознавания большее влияние, чем все остальные факторы [32]. Поэтому необходимо расширение набора данных. Это можно сделать путем увеличения количества исходных изображений (но для этого необходимо получить микрофотографии и подготовить «маски») или используя прием, называемый аугментацией.

Аугментация позволяет расширить набор данных путем геометрических преобразований (поворот на определенный или произвольный угол, отражение по оси или зеркальное, сдвиг части изображения относительно другой, уменьшение/увеличение изображения, вырезание части изображения) или путем преобразований на уровне пикселей (зашумление, изменение яркости, насыщенности, контрастности, применение фильтров и другие методы) [33]. Также можно применять различные комбинации, например, вырезать часть изображения, отразить его и изменить его яркость.

Аугментация позволяет многократно расширить набор данных. При этом каждое такое аугментированное изображение является для сети новым, и результаты ее обучения улучшаются. Важно отметить, что при применении аугментации ее необходимо проводить и для «масок» изображений, так как правильный ответ при обучении в этом случае тоже изменится относительно исходного изображения.

Пример применения аугментации для структуры композиционного покрытия приведен на рис. 3 и 4.




Рис. 1. Часть набора данных из изображений микроструктур композиционных покрытий




Рис. 2. Соответствующий рисунку 1 размеченный набор изображений




Рис. 3. Пример аугментации путем геометрических преобразований изображения структуры композиционного покрытия




Рис. 4. Пример нарезки изображения структуры композиционного покрытия на фрагменты фиксированного размера [34]

5. Этап 3: выбор модели

Для решения задач классификации и сегментации изображений в основном используют сверточные нейронные сети, так как они имеют специальную архитектуру, нацеленную на распознавание изображений [30]. При обучении на изображениях одного класса сверточные нейронные сети самостоятельно формируют карты признаков, с помощью которых изображения классифицируются [30].

Существует большое количество уже разработанных сетей для решения задач анализа изображений. Так, для классификации используются нейронные сети AlexNet, ConvNeXt, DenseNet, EfficientNet, Inception (GoogLeNet), MaxVit, MNASNet, MobileNet, RegNet, ResNet, SqueezeNet, VGG и другие [35], для сегментации – U-Net (или Unet) [36], SegNet [37], FCN [38], PSPNet [39], RefineNet [40], DeepLab [41] и другие. При необходимости можно создать собственную сеть.

Для построения нейронной сети, сегментирующей карбиды в структуре композиционных покрытий, использовали фреймворк PyTorch. За основу была взята предобученная модель deeplabv3_resnet101 [42] из библиотеки torchvision. Количество выходных слоев в последней свертке сети было заменено на 4, по количеству идентифицируемых классов [43].

6. Этап 4: обучение модели

При обучении сети существуют различные параметры и гиперпараметры, в табл. 2 приведен их список для сверточной нейронной сети. Параметры – это переменные, которые автоматически оптимизируются в процессе обучения, а гиперпараметры – это переменные, которые необходимо задать заранее [44].

Таблица 2

Список параметров и гиперпараметров в сверточной нейронной сети [44]

	Параметры	Гиперпараметры
Сверточный слой	Ядра	Размерность ядра фильтра, форма ядра фильтра, шаг перемещения, отступ, функция активации
Подвыборочный слой	Нет	Метод подвыборки, размер фильтра, шаг перемещения, отступ
Полносвязный слой	Веса	Количество весов, функция активации
Другие		Архитектура модели, оптимизатор, скорость обучения, функция потерь, размер мини-выборки, эпохи, регуляризация, инициализация весов, разделение набора данных

Основной операцией, осуществляемой при работе сверточной нейронной сети, является свертка. Свертка используется для извлечения признаков, при этом небольшой массив чисел, называемый ядром, применяется к входным данным, представляющим собой массив чисел, называемый тензором. Поэлементное произведение между каждым элементом ядра и входным тензором вычисляется в каждом местоположении тензора и суммируется для получения выходного значения в соответствующем положении выходного тензора, называемого картой объектов. Эта процедура повторяется с применением нескольких ядер для формирования произвольного количества карт объектов, которые представляют разные характеристики входных тензоров. Таким образом, разные ядра можно рассматривать как разные средства извлечения признаков. Двумя ключевыми гиперпараметрами, определяющими операцию свертки, являются размер и количество ядер (табл. 2) [44].

Как правило, архитектура и различные параметры нейронной сети выбираются экспериментальным путем. Это обусловлено тем, что сверточные нейронные сети содержат большое количество параметров, и на сегодняшний день не существует строго формализованных правил подбора этих параметров и структуры сети в целом [45].

Если используется известная сеть, то большинство гиперпараметров уже определены архитектурой сети. Фактически мы выбираем скорость обучения (learning rate), функцию по-

терь (loss function), размер мини-выборки (mini-batch size), эпохи (epochs), разделение набора данных (dataset splitting).

Перед началом обучения модели проводится разделение набора изображений на три класса. Первый – обучающий (тренировочный) набор, на этих изображениях сеть обучается, происходит настройка параметров модели (весов между нейронами). Второй – проверочный набор (валидационный), изображения из него сеть не видит, на них не учится, но они используются для проверки результатов тренировки модели в процессе обучения и настройки гиперпараметров. Третий набор – тестовый, для непредвзятой оценки работы модели: это те изображения, которые сеть не видела и по ним не подстраивала никакие параметры. Иногда не выделяют изображения в тестовый набор, оценивая работу сети по метрикам, полученным на валидационном наборе, но это зачастую некорректно, так как результат в таком случае будет лучше, чем для тестового набора.

Обычно набор данных разделяют так, чтобы отнести 80 % изображений к обучающему набору, 20 % – к проверочному. Для тестового набора отдельно готовят несколько изображений, при этом желательно, чтобы эти изображения включали все возможные признаки, чтобы можно было удостовериться, что сеть научилась выделять их все.

Тестовый набор изображений микроструктуры композиционных покрытий, использованный в работе [43], показан на рис. 5. В него были включены изображения с различными характеристиками: разные размеры изображений, форматы TIFF или JPG, карбиды сферической или угловатой формы, карбиды светлее или темнее матрицы, наличие или отсутствие пор, наличие или отсутствие областей, не являющихся микроструктурой (области с параметрами съемки и масштабной линейкой).




Рис. 5. Пример тестового набора изображений микроструктуры композиционных покрытий [43]

В случае если обучение проводится на большом количестве изображений, они разбиваются на пакеты, или батчи (batch), так как оперативной или видеопамати может быть недостаточно для вмещения всего набора данных. Традиционно считается, что качество обучения лучше при увеличении размера мини-выборки (mini-batch size), поэтому выбирают максимальный размер мини-выборки (количество изображений, на которых сеть будет обучаться одновременно), доступный на используемом устройстве. Однако в работе [46] показано, что

при использовании чрезмерно большого размера мини-выборки существует тенденция к ухудшению обобщающей способности сети, то есть способности показывать правильные результаты на новых изображениях, которые не были использованы для обучения сети.

После того как все изображения будут проанализированы нейросетью один раз (то есть мы достигнем конца набора данных), пройдет одна эпоха (epoch) обучения. Затем выполняется случайная перетасовка примеров, чтобы каждый мини-пакет в следующую эпоху отличался от предыдущего. При использовании большого количества эпох возможно явление «переобучения» нейронной сети, когда сеть просто запоминает правильный вывод для каждого входного сигнала. В таком случае точность распознавания на обучающем наборе растет, но модель не приобретает способности к обобщению, и работа сети на валидационном и тестовом наборах ухудшается.

При сегментации карбидов в структуре композиционных покрытий проводилось обучение головной части сети (model.classifier), а остальные веса модели были заморожены. В последней свертке количество выходных слоев соответствовало количеству идентифицируемых классов (по умолчанию их 21, для решения поставленной задачи это значение было изменено на 4).

При постобработке выхода сети считали, что пиксель может относиться только к одному классу. Поэтому для класса с максимальной вероятностью вероятность отнесения пикселя к этому классу принимали за 1, а для остальных классов устанавливали вероятность 0.

При обучении нейронной сети использовали оптимизатор Adam. Обучение ограничили 1000 эпохами, скорость обучения варьировали от 10^{-4} до 10^{-1} , размер мини-выборки – от 2 до 384 [34].

7. Этап 5: оценка модели

Следующий этап – оценка модели, проверка качества обучения. Выбор подходящего показателя оценки важен для получения объективной оценки обученной модели [10]. Существует большое количество различных метрик, используемых для оценки работы нейронной сети. Выбор показателя зависит от таких факторов, как специфика предметной области, размер набора данных, распределение данных между различными классами-кандидатами и т. д. [10]. При этом некорректно сравнивать модели, оцененные с использованием разных показателей.

Рассмотрим некоторые наиболее распространенные показатели для оценки эффективности классификации или сегментации микроструктуры металла.

Accuracy (достоверность, доля правильных ответов): $(TP + TN) / (TP + TN + FP + FN)$.

Precision (точность): $TP / (TP + FP)$.

Recall (полнота): $TP / (TP + FN)$.

IoU – Intersection-Over-Union (Jaccard Index) (объединение над пересечением, коэффициент Жаккарда): $TP / (TP + FP + FN)$.

Dice (F1 Score) (Dice-Sørensen coefficient) (коэффициент Дайса): $2TP / (2TP + FP + FN)$.

Показатели основаны на следующих понятиях:

TP – True Positives – истинно положительные значения – данные с меткой класса Y, которые были правильно классифицированы как класс Y;

TN – True Negatives – истинно отрицательные значения – данные, не относящиеся к классу Y, которые не были классифицированы как класс Y;

FP – False Positives – ложноположительные результаты – данные, не относящиеся к классу Y, которые были неправильно классифицированы как класс Y;

FN – False Negatives – ложноотрицательные результаты – данные, относящиеся к классу Y, которые не были классифицированы как класс Y.

Метрики могут принимать значения от 0 до 1; соответственно, чем ближе к 1, тем лучше качество обучения. Иногда их переводят в проценты.

Визуальное представление метрик Accuracy, Precision, Recall, IoU, Dice при различном соотношении TP, TN, FP и FN представлено на рис. 6.




Рис. 6. Пример расчета метрик Accuracy, Precision, Recall, IoU, Dice при решении задач с различными показателями TP (True Positives), TN (True Negatives), FP (False Positives) и FN (False Negatives)

Приведенные выше метрики хорошо работают при бинарной классификации. Если классов несколько (например, многоклассовая сегментация), то применяют MeanIoU, MeanDice и т. п., которые оценивают метрики для всех классов и считают среднее по ним значение.

Ни одна функция потерь не работает идеально с точки зрения всех критериев оценки в каждом наборе данных. В результате крайне важно выбрать функцию потерь, которая наилучшим образом соответствует целям исследования, таким как получение оптимальных результатов или сосредоточение внимания либо на точности, либо на полноте [47].

Проверка качества семантической сегментации карбидов в микроструктуре композиционных покрытий проводилась с использованием метрики MeanIoU и, соответственно, функции потерь 1-MeanIoU.

8. Этап 6: интеграция с рабочим процессом

Заключительный этап – интеграция с рабочим процессом. На этом этапе необходимо вернуться к исходной цели и создать возможности использования обученной нейронной сети для ее достижения.

В ряде случаев это осуществляют созданием программного обеспечения, использующего нейронные сети, обученные для работы с изображениями структур. Так, авторы [48] разработали программное обеспечение, определяющее марку стали, размер и количество

зерен, соотношение феррита и перлита и т. д. В работе [49] сообщается о создании автоматизированной системы детектирования дефектов литографии. Создатели использованного в [49] программного обеспечения сообщают [50] о возможности анализа включений графита в чугуне и решения прочих задач металловедения. Авторы [51] разработали облачный сервис обработки изображений микроструктур DLgram, использующий мессенджер Telegram в качестве интерфейса [52], позволяющий пользователям дообучить нейросеть под конкретную задачу.

В задаче сегментации карбидов в структуре композиционных покрытий выделение карбидов нейронной сетью является средством для достижения цели – расчета их объемной доли. Это можно сделать через отношение количества пикселей изображения, соответствующих карбидам (красные участки на рис. 7), к общему числу пикселей за вычетом зон, не входящих в микроструктуру (желтые участки на рис. 7).




Рис. 7. Результат сегментации изображений микроструктуры композиционных покрытий из тестового набора, представленного на рис. 5

Была зарегистрирована программа для ЭВМ «Определение объемной доли карбидов в структуре композиционных покрытий с помощью сверточной нейронной сети» [53].

9. Заключение

На примере сегментации микроструктур композиционных покрытий рассмотрены этапы использования нейронных сетей для анализа изображений структуры металлов: определение проблемы, составление набора данных, выбор модели, обучение модели, оценка модели, интеграция с существующим рабочим процессом. Семантическая сегментация крупных первичных карбидов нейронной сетью позволяет автоматизировать процесс определения их объемной доли в структуре покрытий.

Благодарность

Работа выполнена в рамках государственного задания ИМАШ УрО РАН по теме № 124020600045-0 и ИФМ УрО РАН по теме «Аддитивность» № 121102900049-1. Микроскопические изображения получены с использованием оборудования ЦКП «Пластометрия» ИМАШ УрО РАН.

Литература

1. Сааков Д. В. Применение методов машинного обучения для оптимизации производственных процессов в металлургической промышленности // Инновации и инвестиции. – 2023. – №. 5. – С. 308–311.
2. Оценка прочностных характеристик сталей после термомеханической обработки на основе нейросетевого анализа цифровых фотографий микроструктур / А. В. Ключев, В. Ю. Столбов, Н. В. Копцева, Ю. Ю. Ефимова // Черные металлы. – 2020. – №. 6. – С. 50–56.
3. Overview: computer vision and machine learning for microstructural characterization and analysis / E. A. Holm, R. Cohn, N. Gao, A. R. Kitahara, T. P. Matson, B. Lei, S. R. Yarasi // Metallurgical and Materials Transactions A: Physical Metallurgy and Materials Science. – 2020. – Vol. 51 (12). – P. 5985–5999. – DOI: 10.1007/s11661-020-06008-4.
4. Modelling the steel microstructure knowledge for in-silico recognition of phases using machine learning / S. Gupta, A. Banerjee, J. Sarkar, M. Kundu, S. K. Sinha, N. R. Bandyopadhyay, S. Ganguly // Materials Chemistry and Physics. – 2020. – Vol. 252. – P. 123286. – DOI: 10.1016/j.matchemphys.2020.123286.
5. Residual neural network-based fully convolutional network for microstructure segmentation / J. Jang, D. Van, H. Jang, D. H. Baik, S. D. Yoo, J. Park, S. Mhin, J. Mazumder, S. H. Lee // Science and Technology of Welding and Joining. – 2020. – Vol. 25 (4). – P. 282–289. – DOI: 10.1080/13621718.2019.1687635.
6. Autonomous interpretation of the microstructure of steels and special alloys / B. Mulewicz, G. Korpala, J. Kusiak, U. Pahl // Materials Science Forum. – 2019. – Vol. 949. – P. 24–31. – DOI: 10.4028/www.scientific.net/MSF.949.24.
7. DeCost B. L., Francis T., Holm E. A. Exploring the microstructure manifold: Image texture representations applied to ultrahigh carbon steel microstructures // Acta Materialia. – 2017. – Vol. 133. – P. 30–40. – DOI: 10.1016/j.actamat.2017.05.014.
8. A new solution for automatic microstructures analysis from images based on a backpropagation artificial neural network / V. H. C. De Albuquerque, P. C. Cortez, A. R. De Alexandria, J. M. R. S. Tavares // Nondestructive Testing and Evaluation. – 2008. – Vol. 23 (4). – P. 273–283. – DOI: 10.1080/10589750802258986.
9. Microstructure recognition using convolutional neural networks for prediction of ionic conductivity in ceramics / R. Kondo, S. Yamakawa, Y. Masuoka, S. Tajima, R. Asahi // Acta Materialia. – 2017. – Vol. 141. – P. 29–38. – DOI: 10.1016/j.actamat.2017.09.004.
10. Machine learning for microstructure characterization and materials design: a perspective / A. Baskaran, E. J. Kautz, A. Chowdhary, W. Ma, B. Yener, D. J. Lewis // JOM. – 2021. – Vol. 73 (11). – P. 3639–3657. – DOI: 10.1007/s11837-021-04805-9.
11. Ковун В. А., Каширина И. Л. Использование нейронных сетей U-Net и W-Net в металлографическом анализе образцов стали // Вестник ВГУ. Серия «Системный анализ и информационные технологии». – 2022. – № 1. – С. 101–110. – DOI: 10.17308/sait.2022.1/9205.
12. Prior austenite grain boundary recognition in martensite microstructure based on deep learning / X.-d. Wang, N. Li, H. Su, H.-m. Meng // Journal of Iron and Steel Research International. – 2023. – Vol. 30. – P. 1050–1056. – DOI: 10.1007/s42243-023-00947-z.

13. Шарыбин С. И. Автоматизация контроля качества функциональных материалов на основе средств интеллектуальной поддержки принятия решений : дис. ... канд. техн. наук : 05.13.06. – Пермь, 2015. – 162 с.
14. Automatic identification of the multiphase microstructures of steels based on ASPP-FCN / L. Xie, W. Li, L. Fan, M. Zhou // *Steel Research International*. – 2023. – Vol. 94. – 2200204. – DOI: 10.1002/srin.202200204.
15. Automated semantic segmentation of NiCrBSi-WC optical microscopy images using convolutional neural networks / D. Rose, J. Forth, H. Henein, T. Wolfe, A. J. Qureshi // *Computational Materials Science*. – 2022. – Vol. 210. – P. 111391. – DOI: 10.1016/j.commatsci.2022.111391.
16. Судьин В. В. Исследование особенностей разрушения низколегированных сталей и их сварных соединений в интервале вязко-хрупкого перехода : дис. ... канд. техн. наук : 01.04.07. – Москва, 2021. – 189 с.
17. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet classification with deep convolutional neural networks // *Communications of the ACM*. – 2017. – Vol. 60 (6). – P. 84–90. – DOI: 10.1145/3065386.
18. Лукашик Д. В. Анализ современных методов сегментации изображений // *Экономика и качество систем связи*. – 2022. – № 2 (24). – С. 57–65.
19. A deep learning model for automatic analysis of cavities in irradiated materials / Q. Chen, C. Zheng, Y. Cui, Y.-R. Lin, S. J. Zinkle // *Computational Materials Science*. – 2023. – Vol. 221. – 112073. – DOI: 10.1016/j.commatsci.2023.112073.
20. Hurtado J. V., Valada A. Semantic scene segmentation for robotics // *Deep Learning for Robot Perception and Cognition*. – Academic Press, 2022. – Ch. 12. – P. 279–311. – DOI: 10.1016/B978-0-32-385787-1.00017-8.
21. Xu H., Huang H. Plasma remelting and injection method for fabricating metal matrix composite coatings reinforced with tungsten carbide // *Ceramics International*. – 2022. – Vol. 48. – P. 2645–2659. – DOI: 10.1016/j.ceramint.2021.10.048.
22. ASTM E 562–02. Standard test method for determining volume fraction by systematic manual point count.
23. <https://siams.com/>
24. Kazakov A. A., Kiselev D. Industrial Application of thixomet image analyzer for quantitative description of steel and alloy's microstructure // *Metallography, Microstructure, and Analysis*. – 2016. – Vol. 5. – P. 294–301. – DOI: 10.1007/s13632-016-0289-6.
25. Schneider C. A., Rasband W. S., Eliceiri K. W. NIH Image to ImageJ: 25 years of image analysis // *Nature Methods*. – 2012. – Vol. 9. – P. 671–675. – DOI: 10.1038/nmeth.2089.
26. <https://jmicrovision.github.io/>
27. Jacobs R. Deep learning object detection in materials science: current state and future directions // *Computational Materials Science*. – 2022. – Vol. 211. – 111527. – DOI: 10.1016/j.commatsci.2022.111527.
28. Unsupervised domain adaptation using generative adversarial networks for semantic segmentation of aerial images / B. Benjdira, Y. Bazi, A. Koubaa, K. Ouni // *Remote Sensing*. – 2019. – Vol. 11. – 1369. – DOI: 10.3390/rs11111369.
29. Wang M., Wu F., Zhao J. A Comprehensive research and strategy of transfer learning for image segmentation // *Lecture Notes on Data Engineering and Communications Technologies (LNDECT)*. – Springer, 2021. – Vol. 88. – P. 1394–1406. – DOI: 10.1007/978-3-030-70665-4_152.
30. Аристов Г. В., Ключев А. В. Распознавание и классификация микроструктуры металлов и сплавов с использованием глубоких нейронных сетей // *Труды 27-й Международной конференции по компьютерной графике и машинному зрению (GRAPHI-CON 2017)*, Пермь, 24–28 сентября 2017 г. – ПГНИУ, 2017. – С. 180–183.

31. Полетаева Н. Г. Классификация систем машинного обучения // Вестник Балтийского федерального университета им. И. Канта. Серия «Физико-математические и технические науки». – 2020. – № 1. – С. 5–22.
32. <https://habr.com/ru/companies/smartengines/articles/264677>
33. Аугментация наборов изображений для обучения нейронных сетей при решении задач семантической сегментации / И. А. Ложкин, М. Е. Дунаев, К. С. Зайцев, А. А. Гармаш // International Journal of Open Information Technologies. – 2023. – Vol. 11 (1). – P. 109–117.
34. Soboleva N., Mushnikov A. Improving the accuracy of semantic segmentation of carbides in the microstructure of composite coatings by the neural network // Materials Today Communications. – 2024. – Vol. 38. – P. 108276. – DOI: 10.1016/j.mtcomm.2024.108276.
35. Сикорский О. С. Обзор свёрточных нейронных сетей для задачи классификации изображений // Новые информационные технологии в автоматизированных системах. – 2017. – № 20. – С. 37–42.
36. Ronneberger, O., Fischer, P., Brox, T. U-Net: convolutional networks for biomedical image segmentation // Medical Image Computing and Computer-Assisted Intervention (MICCAI 2015). Lecture Notes in Computer Science series / ed. by N. Navab, J. Hornegger, W. Wells, A. Frangi. – Cham : Springer, 2015. – Vol. 9351. – DOI: 10.1007/978-3-319-24574-4_28.
37. Badrinarayanan V., Kendall A., Cipolla R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2017. – Vol. 39. – P. 2481–2495. – DOI: 10.1109/tpami.2016.2644615.
38. Long J., Shelhamer E., Darrell T. Fully convolutional networks for semantic segmentation // IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, MA, USA, 2015. – IEEE, 2015. – P. 3431–3440. – DOI: 10.1109/cvpr.2015.7298965.
39. Pyramid scene parsing network / H. Zhao, J. Shi, X. Qi, X. Wang, J. Jia // IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, 2017. – IEEE, 2017. – P. 6230–6239. – DOI: 10.1109/cvpr.2017.660.
40. RefineNet: multi-path refinement networks for high-resolution semantic segmentation / G. Lin, A. Milan, C. Shen, I. Reid // IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, 2017. – IEEE, 2017. – P. 5168–5177. – DOI: 10.1109/cvpr.2017.549.
41. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs / Chen L. C., Papandreou G., Kokkinos I., Murphy K., Yuille A. L. // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2018. – Vol. 40, No. 4. – P. 834–848. – DOI: 10.1109/TPAMI.2017.2699184.
42. Rethinking atrous convolution for semantic image segmentation / L. C. Chen, G. Papandreou, F. Schroff, H. Adam. – 2017. – arXiv:1706.05587. – DOI: 10.48550/arXiv.1706.05587.
43. Соболева Н. Н., Мушников А. Н. Определение объемной доли первичных карбидов в микроструктуре композиционных покрытий с применением семантической сегментации // Frontier Materials & Technologies. – 2023. – № 3. – С. 95–102. – DOI: 10.18323/2782-4039-2023-3-65-9.
44. Convolutional neural networks: an overview and application in radiology / R. Yamashita, M. Nishio, R. K. G. Do, K. Togashi // Insights Imaging. – 2018. – Vol. 9. – P. 611–629. – DOI: 10.1007/s13244-018-0639-9.
45. Применение нейронных сетей глубокого обучения для решения задачи сегментации лесных пожаров на спутниковых снимках / К. В. Вик, А. А. Друки, Д. С. Григорьев, В. Г. Спицын // Вестник Томского государственного университета. Управление, вычислительная техника и информатика. – 2021. – № 55. – С. 18–25. – DOI: 10.17223/19988605/55/3.
46. On large-batch training for deep learning: generalization gap and sharp minima / N. Keskar, D. Mudigere, J. Nocedal, M. Smelyanskiy, P. Tang. – 2016. – arXiv:1609.04836. – DOI: 10.48550/arXiv.1609.04836.

47. A comparative study of loss functions for road segmentation in remotely sensed road datasets / H. Xu, H. He, Y. Zhang, L. Ma, J. Li // International Journal of Applied Earth Observation and Geoinformation. – 2023. – Vol. 116. – P. 103159. – DOI: 10.1016/j.jag.2022.103159.
48. Application of artificial intelligence technologies in metallographic analysis for quality assessment in the shipbuilding industry / V. Emelianov, A. Zhilenkov, S. Chernyi, A. Zinchenko, E. Zinchenko // Heliyon. – 2022. – Vol. 8. – P. e10002. – DOI: 10.1016/j.heliyon.2022.e10002.
49. Об автоматизированной системе детектирования дефектов на МЭМС-производстве / К. В. Ракетов, Н. Ю. Израилев, А. О. Казачков, Е. Ю. Заблоцкая, И. А. Род, М. С. Рябков, А. В. Исаченко, Д. Г. Шамирян // Наноиндустрия. – 2018. – Т. 11, № 7–8 (86). – С. 542–548. – DOI: 10.22184/1993-8578.2018.11.7-8.542.548.
50. <https://axalit.ru>
51. DLgram cloud service for deep-learning analysis of microscopy images / A. V. Matveev, A. V. Nartova, N. N. Sankova, A. G. Okunev // Microscopy Research and Technique. – 2024. – Vol. 87 (5). – P. 991–998. – DOI: 10.1002/jemt.24480.
52. https://t.me/nanoparticles_nsk
53. Свидетельство о регистрации программы для ЭВМ № 2023660789 Рос. Федерация. Определение объемной доли карбидов в структуре композиционных покрытий с помощью сверточной нейронной сети : № 2023660261 : регистрация 24.05.2023 : опубл. 24.05.2023 / Соболева Н. Н.