

УДК 620.22+004.89

Автоматическая количественная оценка фаз в SiC керамике с использованием средств машинного обучения

Каледин Алексей Владимирович ^{1,2}	kaledin@issp.ac.ru
Пещерова Светлана Михайловна ³	area.aiseo@gmail.com
Стрюков Дмитрий Олегович ¹	stryukov@issp.ac.ru
Шикунов Сергей Леонидович ^{1,2}	shikunov @issp.ac.ru
Курлов Владимир Николаевич ^{1,2}	kurlov59@gmail.com
Петрушин Илья Сергеевич ³	area.aiseo@gmail.com

¹ ИФТТ РАН, Черноголовка, Московская обл., Россия

² МГТУ им. Н.Э. Баумана, Москва, Россия

³ Иркутский государственный университет, Иркутск, Россия

Аннотация. В работе продемонстрирован способ автоматической сегментации фаз SiC, C и Si в карбидокремниевой керамике, полученной по технологии жидкофазного силицирования. Использованы снимки микроструктуры образцов с различной объемной долей фаз, полученные на оптическом микроскопе. Для формирования обучающей выборки подготовлены маски с помощью метода k-средних. Сверточная нейросеть архитектуры U-net была обучена на более чем 1000 снимках микроструктуры и продемонстрировала точность сегментации 94 %, а также величину средней погрешности менее ± 2 %.

Ключевые слова: силицированный графит, карбид кремния, кремний, графит, искусственный интеллект, нейронные сети, U-net, машинное обучение

Automatic Quantification of SiC Ceramics Using Machine Learning Approach

Kaledin Aleksei Vladimirovich ^{1,2}	kaledin@issp.ac.ru
Peshcherova Svetlana Mikhailovna ³	rea.aiseo@gmail.com
Stryukov Dmitry Olegovich ¹	stryukov@issp.ac.ru
Shikunov Sergei Leonidovich ^{1,2}	shikunov @issp.ac.ru
Kurlov Vladimir Nikolaevich ^{1,2}	kurlov59@gmail.com
Petrushin Ilia Sergeevich ³	area.aiseo@gmail.com

¹ Institute of Solid State Physics RAS, Chernogolovka, Moscow Region, Russia

² BMSTU, Moscow, Russia

³ Irkutsk State University, Irkutsk, Russia

Abstract. A machine learning approach for automated segmentation of SiC, C, Si phases in SiC ceramics is demonstrated. The ceramics are manufactured via liquid silicon infiltration of porous carbon preforms. Microstructure images of SiC ceramics with varying phase volume fractions obtained with an optical microscope were used for dataset. The dataset

masks were prepared using the k-means method. A U-net convolutional neural network had been trained over 1,000 microstructure images and demonstrated a segmentation accuracy of 94 % and an average error of less than ± 2 %.

Keywords: siliconized graphite, SiC ceramics, silicon, graphite, artificial intelligent, neural networks, U-net, machine learning

Введение. Карбидокремниевая (SiC) керамика широко применяется при изготовлении изделий в различных отраслях промышленности благодаря комбинации низкой плотности ($3,0\text{--}3,2\text{ г/см}^3$, высокой твердости ($25\text{--}30\text{ ГПа}$) и стойкости к окислению вплоть до $1600\text{ }^\circ\text{C}$ благодаря образованию защитного слоя SiO_2 [1–4]. Жидкофазное силицирование пористых заготовок либо из смеси SiC+C либо из чистого углерода позволяет получать изделия сложной геометрической формы благодаря возможности проводить механическую обработку до этапа силицирования [5–10]. Зачастую, оценка количественного соотношения фаз в таких материалах бывает необходима в условиях вновь разрабатываемой рецептуры или технологических процессов. Обычно, такой анализ проводят путем вытравливания остаточного кремния и выжигания непрореагировавшего углерода, либо по снимкам микроструктуры с помощью пороговой сегментации, производимой вручную или полуавтоматическими методами, имеющими крайне низкую точность. Подходы машинного обучения открывают новые возможности для автоматизированной оценки микроструктуры материалов, не только упрощая процесс и сокращая время затраты, но и позволяют увеличить точность количественных оценок тех или иных параметров и характеристик [11–19]. Однако, большинство работ сосредоточено на использовании результатов анализа дорогостоящих и недоступных для многих исследователей систем анализа, таких как томография и сканирующий электронный микроскоп. В данной работе предложен способ сегментации трех фаз в SiC керамике (SiC, C, Si) с помощью сверточной нейронной сети, обученной на массиве данных снимков микроструктуры, полученный на оптическом микроскопе.

Материалы и методы. Для получения пористой углеродной заготовки, необходимой для проведения жидкофазного силицирования были использованы порошки графита фракций $< 50\text{ мкм}$, $50\text{--}100\text{ мкм}$, $100\text{--}200\text{ мкм}$. Порошки получены путем дробления блоков графита (Технокарб, Челябинск, Российская Федерация). Смесь порошков и фенольного связующего перемешивали и прессовали в металлических пресс-формах для получения монолитной заготовки, которую подвергали высокотемпературной обработке. В результате, после частичного перехода в коксовый остаток и выгорания связующего, формировалась пористая структура. Заготовке придавали необходимую форму путем механической обработки и проводили жидкофазное силицирование. В процессе пропитки расплавом кремния при его взаимодействии с углеродом происходило образование SiC. Закапсулированный графит и остаточный свободный кремний также присутствуют в конечном материале, их объемная доля зависит от технологических параметров, а также размера частиц первичного графита.

Полученные образцы керамики шлифовали на порошках карбида бора (последовательность зернистости порошков: P120, P150, P320, P600, P1500) с последующей полировкой на алмазных порошках 10 мкм, 5 мкм and 1 мкм. Снимки микроструктуры были получены на оптическом микроскопе Olympus BX-51 в отраженном свете (размер изображений 3488×2616 пикселей, 8-битное RGB пространство).

Для каждого типа керамики было подготовлено не менее 300 снимков. Для быстрой первичной разметки использовался метод k-средних в Lab-пространстве. Семантическую сегментацию проводили с помощью компактной четырехступенчатой U-net нейросети — четыре уровня энкодера и симметричный декодер. На вход подается патч 3×256×256. Каналы идут по степени детализации: от 64 до 1024. Функция потерь — кросс-энтропия, метод оптимизации — Adam, функция активации — ReLU.

Результаты. На рис. 1 показаны три репрезентативные микроструктуры SiC керамики, полученные на порошках графита <50 мкм, 50–100 мкм и 100–200 мкм при двух увеличениях.




Рис. 1. Микроструктуры SiC керамики, полученной на порошке графита < 50 мкм, 50–100 мкм, 100–200 мкм на увеличении × 50 (а, б, в) и на увеличении × 100 (г, д, е). Черный — углерод, серый — SiC, светло-серый — кремний

Уровни серого у SiC и Si могут частично перекрываться из-за неравномерности обработки бликов и дрейфа освещения. Для минимизации фотометрических эффектов ко всем изображениям применяли одинаковую предварительную обработку: нормализацию интенсивности к нулевому среднему и единичной дисперсии, CLAHE (clip-limit 2.0), билатеральное сглаживание 3×3 и легкую резкость.

Обучение нейросети производили 40 эпох с ранней остановкой: как только метрика стабилизируется на валидации и перестает улучшаться, обучение

останавливается. Стабилизация происходила на уровне 94 %, процесс прерывался автоматически. Итоговая средняя точность сегментации по пикселям — 94 %, средняя уверенность модели — 0,88. Разработанный алгоритм выдает на выходе размеченное изображение и количественную оценку объемной доли каждой фазы. Результаты работы алгоритма приведены на рис. 2.




Рис. 2. Маска фазы остаточного углерода (а), маска SiC (б), маска свободного кремния (в), изначальное изображение микроструктуры (г), результат сегментации (д)

Обсуждение. Преобразование изображений обучающей выборки в Lab-пространство обоснованно тем, что в таком случае разделяется яркость и цвет изображения. Это важно ввиду непостоянства интенсивности освещения, цветовых оттенков изображений и качества поверхности шлифа. Перед кластеризацией гистограмма нормализуется, убирается фоновый шум. Архитектура U-net была выбрана ввиду наличия в материале тонких и четких межфазных границ. Кроме того, использование U-net не требует ручного подбора фильтров, а также она менее чувствительна к артефактам, чем другие методы. Примечательно, что в областях где присутствует большое количество самой светлой фазы — остаточного кремния, алгоритм поддерживает связность тонких «шеек», избегая ложного слияния SiC с C в тени. Это возможно в том числе благодаря использованию U-net архитектуры, здесь она имеет преимущество перед классическими методами оценки, имеющих системную ошибку. Программная реализация на Python/PyTorch с бесшовной сборкой и автоматическим подсчетом фазовых долей обеспечивает высокую производительность: 0,3–0,6 с на кадр на RTX 3060 или 3–6 с на 8-ядерном CPU, что

дает ускорение процесса анализа более чем на порядок по сравнению с ручной разметкой или пороговой сегментацией.

Заключение.

1. Разработан способ количественной оценки фаз в трехфазной SiC керамике, полученной путем жидкофазного силицирования пористых углеродных заготовок, с помощью сверточной нейронной сети архитектуры U-net.

2. Обучающая выборка была сформирована на основе оптических снимков микроструктуры, что является более доступным способом по сравнению с томографией и рентгенографией.

3. Предложенный подход с применением компьютерного зрения позволяет оперативно сегментировать трехфазную SiC керамику, существенно сокращая время анализа (0,3–0,6 с на снимок) при использовании графического ускорителя RTX 3060.

Список источников

- [1] Roy J., Chandra S., Das S., Maitra S. Oxidation behaviour of silicon carbide — a review. *Reviews on Advanced Materials Science*, 2014, vol. 38 (1), pp. 29–39.
- [2] Ruys A.J. *Silicon Carbide Ceramics: Structure, Properties and Manufacturing*. Elsevier Series in Advanced Ceramic Materials. Elsevier, Amsterdam, 2023, 586 p.
- [3] Carter C.B., Norton M.G. *Ceramic Materials: Science and Engineering*. Springer, New York, 2013, 862 p. <https://doi.org/10.1007/978-1-4614-3523-5>
- [4] Grinchuk P., Tretyak M.S., Chuprasov V.V. Thermal protection material on the base of silicon-carbide ceramics. *IOP Conference Series: Materials Science and Engineering*, 2020, vol. 709 (4), art. no. 044112. <https://doi.org/10.1088/1757-899X/709/4/044112>
- [5] Zhou Y., Sha W., Liu Y., Lyu Y., Huang Y. Influence of carbon source on microstructural and mechanical properties of high-performance reaction bonded silicon carbide. *Materials*, 2022, vol. 15 (15), art. no. 5250. <https://doi.org/10.3390/ma15155250>
- [6] Li W., Zhang G., Cui C., Bao J., Guo C., Xu C. et al. Structure evolution and properties modification for reaction-bonded silicon carbide. *Materials*, 2022, vol. 15 (24), art. no. 8721. <https://doi.org/10.3390/ma15248721>
- [7] Liu R. et al. Effect of gradation on thermal and mechanical properties of reaction bonded silicon carbide ceramics. *International Journal of Applied Ceramic Technology*, 2025, vol. 22, art. no. 14964. <https://doi.org/10.1111/ijac.14964>
- [8] Filonov K.N., Kurlov V.N., Klassen N.V., Samoilov V.M. New shaped ceramics based on silicon carbide. *Bulletin of the Russian Academy of Sciences: Physics*, 2009, vol. 73 (10), pp. 1377–1379. <https://doi.org/10.3103/S1062873809100165>
- [9] Xue R., Wang J., Chen Y., Zhang Z., Xiao Z., Xia H. A hybrid graphite powder for reserving higher carbon content of self-lubrication graphite/SiC composites by RMI. *Journal of the American Ceramic Society*, 2023, vol. 106 (10), pp. 6317–6329. <https://doi.org/10.1111/jace.19241>
- [10] Lui S. et al. High-temperature and high-pressure tribological properties of siliconized graphite for water-lubricated thrust bearing application in main coolant pump. *Lubricants*, 2024, vol. 12 (5), art. no. 159. <https://doi.org/10.3390/lubricants12050159>
- [11] Ershov A.E., Shikunov S.L., Kurlov V.L. Method of calculating the phase composition of SiC–Si–C materials obtained by silicon infiltration of carbon matrices. *Technical Physics*, 2017, vol. 62 (6), pp. 903–910. <https://doi.org/10.1134/S106378421706009315>
- [12] Shikunov S.L., Kurlov V.N. SiC-based composite materials obtained by siliconizing carbon matrices. *Technical Physics*, 2017, vol. 62 (12), pp. 1869–1876. <https://doi.org/10.1134/S1063784217120222>

- [13] Strohmamm T., Bugelnig K., Breitbarth E., Wilde F., Steffens T., Germann H., Requena G. Semantic segmentation of synchrotron tomography of multiphase AL–SI alloys using a convolutional neural network with a pixel-wise weighted loss function. *Scientific Reports*, 2019, vol. 9, art. no. 19611. <https://doi.org/10.1038/s41598-019-56008-7>
- [14] Hirabayashi Y., Iga H., Ogawa H., Tokuta S., Shimada Y., Yamamoto A. Deep learning for three-dimensional segmentation of electron microscopy images of complex ceramic materials. *npj Computational Materials*, 2024, vol. 10, art. no. 46. <https://doi.org/10.1038/s41524-024-01226-5>
- [15] Aksoy D., Xin H.L., Rupert T.J., Bowman W.J. Human perception-inspired grain segmentation refinement using conditional random fields. *arXiv*, 2024. <https://doi.org/10.48550/arXiv.2312.09968>
- [16] Zhang K., Apley D.W., Chen W., Liu W.K., Brinson L.C. A framework for supervised and unsupervised segmentation and classification of materials microstructure images. *arXiv*, 2025. <https://doi.org/10.48550/arXiv.2502.07107>
- [17] Della Mea G.B., Ovalle C., Laiarinandrasana L., Decenciere E., Dokřadal P. Physics informed self-supervised segmentation of elastic composite materials. *Computer Methods in Applied Mechanics and Engineering*, 2024, vol. 432, art. no. 117355. <https://doi.org/10.1016/j.cma.2024.117355>
- [18] Ragone M., Shahabazian-Yassar R., Mashayek F., Yurkiv V. Deep learning modeling in microscopy imaging: A review of materials science applications. *Progress in Materials Science*, 2023, vol. 138, art. no. 101165. <https://doi.org/10.1016/j.pmatsci.2023.101165>
- [19] Baskaran A., Kautz E.J., Chowdhary A. et al. Adoption of image driven machine learning for microstructure characterization and materials design: A perspective. *JOM*, 2021, vol. 73, pp. 3639–3657. <https://doi.org/10.1007/s11837-021-04805-9>