

Определение объемной доли первичных карбидов в микроструктуре композиционных покрытий с применением семантической сегментации

© 2023

Соболева Наталья Николаевна^{*1,2,3}, кандидат технических наук, старший научный сотрудник
Мушников Александр Николаевич^{1,4}, кандидат технических наук, научный сотрудник

¹Институт машиноведения имени Э.С. Горкунова Уральского отделения РАН, Екатеринбург (Россия)

²Институт физики металлов имени М.Н. Михеева Уральского отделения РАН, Екатеринбург (Россия)

*E-mail: soboleva@imach.uran.ru,
natashasoboleva@list.ru

³ORCID: <https://orcid.org/0000-0002-7598-2980>

⁴ORCID: <https://orcid.org/0000-0001-7073-6476>

Поступила в редакцию 14.06.2023

Принята к публикации 15.08.2023

Аннотация: В процессе формирования композиционных покрытий возможно частичное растворение упрочняющих частиц (чаще всего карбидов) в матрице, поэтому в ряде случаев выбор режима создания материала осуществляется с учетом объемной доли первичных, не растворившихся при нанесении покрытий карбидов. Широко используемые в настоящее время методы расчета объемной доли карбидов в структуре композиционных покрытий (ручной точечный метод и программы, реализующие классические методы машинного зрения) имеют ограничения по возможности автоматизации. Ожидается, что выполнение семантической сегментации с использованием сверточных нейронных сетей повысит как производительность процесса, так и точность определения карбидов. В работе проводилась многоклассовая семантическая сегментация, включающая классификацию на изображении пор и областей, не являющихся микроструктурой. Использовались две нейронные сети на основе DeepLab-v3, обученные с разными функциями потерь (IoU Loss и Dice Loss). Исходными данными были изображения различных размеров с электронного и оптического микроскопов, с карбидами сферической и угловатой формы темнее и светлее матрицы, в ряде случаев – с порами и областями, не относящимися к микроструктуре. В работе представлены изображения-маски, состоящие из четырех классов, созданные вручную и двумя обученными нейронными сетями. Показано, что сети распознают поры, области, не относящиеся к микроструктуре, и отлично сегментируют на изображениях карбиды сферической формы, независимо от их цвета относительно матрицы и наличия пор в структуре. Проведено сравнение доли карбидов в микроструктуре покрытий, определенной двумя нейронными сетями и ручным точечным методом.

Ключевые слова: композиционные покрытия; карбиды; оптическая микроскопия; растровая электронная микроскопия; семантическая сегментация; нейронные сети.

Благодарности: Работа выполнена в рамках государственных заданий ИМАШ УрО РАН по темам № АААА-А18-118020790147-4 и № АААА-А18-118020790148-1 и ИФМ УрО РАН по теме «Аддитивность» № 121102900049-1.

Микроскопические изображения получены с использованием оборудования ЦКП «Пластометрия» ИМАШ УрО РАН.

Статья подготовлена по материалам докладов участников XI Международной школы «Физическое материаловедение» (ШФМ-2023), Тольятти, 11–15 сентября 2023 года.

Для цитирования: 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.

ВВЕДЕНИЕ

В настоящее время промышленность предъявляет всё большие требования к прочности, износостойкости, живучести и другим эксплуатационным свойствам деталей машин и инструмента. Для решения задачи повышения трибологических свойств изделий постоянно ведется разработка новых износостойких материалов и покрытий, в том числе композиционных [1]. Одними из наиболее перспективных покрытий для работы в условиях абразивного износа являются композиционные материалы «карбид – металлическая матрица» [2–4].

Для успешного формирования композиционного покрытия необходимо, чтобы матрица имела относительно невысокую температуру плавления, а карбиды – высокую [5]. Таким образом, при создании материала

будет обеспечиваться наличие износостойкого наполнителя в виде исходных первичных частиц, не растворенных в матрице. Однако карбиды частично могут растворяться в матрице при создании композиционных покрытий [6–8], снижая тем самым их износостойкость [9]. В связи с этим, в ряде случаев при разработке технологии нанесения покрытия для получившихся опытных образцов не только проводят исследование состава и функциональных свойств, но и определяют объем крупных первичных упрочняющих частиц в микроструктуре материала.

В настоящее время стандартизованным методом определения объемной доли фаз является ручной точечный метод по ASTM E 562-02, представляющий собой трудоемкий процесс. Упрощение процесса возможно с помощью использования программ, реализующих

классические методы машинного зрения, например Sams, Thixomet, ImageJ, JMicroVision и др. [10; 11]. Однако в работе [12] показано, что использование классических методов машинного зрения имеет ряд ограничений, затрудняющих автоматизацию процесса.

Возможным решением проблемы является использование нейронных сетей для сегментации изображений композиционных материалов. В таком случае выполняется семантическая сегментация – процесс понимания изображений на уровне пикселей [13], позволяющий разделить изображения на области, соответствующие семантическому классу из заранее определенного списка. Особенности классов изучаются нейронной сетью по заранее подготовленным маскам – размеченным разными цветами изображениям. Семантическая сегментация объединяет обнаружение объектов, распознавание формы и классификацию.

Использование сверточных нейронных сетей позволяет значительно повысить производительность семантической сегментации [14]. За последние несколько лет многие модели семантической сегментации на основе сверточных нейронных сетей достигли хорошей производительности в задачах сегментации изображений, например FCN, SegNet, RefineNet, U-net, PSPNet, DeepLab [13; 15; 16]. В модели DeepLab для получения карт сегментации реализуется архитектура, основанная на сверточной нейронной сети. Помимо обычных сверток, применяются разряженные ядра сверток, позволяющие учитывать больше пространственной информации без увеличения числа параметров [17]. Более современная и продвинутая версия DeepLab-v3 характеризуется значительным улучшением производительности при высокой точности сегментации [18].

В работе [12] проводили сегментацию частиц карбидов вольфрама WC в структуре NiCrBSi-покрытий с использованием сетей U-net и LinkNet. При этом решалась задача одноклассовой сегментации: определялись пиксели, принадлежащие или не принадлежащие карбидам. Авторы работы отмечают, что обученные модели имели тенденцию неправильно классифицировать поры как относящиеся к классу карбидов.

Цель работы – определение объемной доли первичных карбидов в микроструктуре композиционных материалов с использованием обученных нейронных сетей на основе DeepLab-v3 для семантической сегментации. Особенностью реализации является многоклассовая сегментация, включающая классификацию на изображении пор и областей, не являющихся микроструктурой.

МЕТОДИКА ПРОВЕДЕНИЯ ИССЛЕДОВАНИЯ

Исходными данными были изображения микроструктуры композиционных покрытий на основе никеля и железа с крупными первичными карбидами вольфрама, титана, хрома, полученные с использованием растрового электронного микроскопа Tescan VEGA II XMU и оптической системы микротвердомера Shimadzu HNV-G21DT. Использование двух разных методов позволило получить изображения с различными характеристиками: разные размеры (768×840 и 640×480 пикселей), форматы TIFF/JPG, карбиды на микрофотографиях светлее и темнее матрицы, наличие/отсутствие областей, не являю-

щихся микроструктурой (области с параметрами съемки и масштабной линейкой). Кроме того, изображения, полученные обоими способами, характеризовались наличием на некоторых из них пор, а также наличием двух типов карбидов: сферической и угловатой формы. Количество исходных изображений составило 41.

Для удобства работы все файлы были переведены в формат PNG. Вручную в MS Paint проводилась разметка набора данных (получение масок – эталонных изображений) с использованием четырех цветов: темно-серый цвет на изображении-маске – карбиды, черный – поры, белый – остальная часть микроструктуры, светло-серый – область, не являющаяся микроструктурой.

В качестве нейронной сети была взята реализация модели deeplabv3_resnet101 из библиотеки torchvision. В качестве основы модели deeplabv3_resnet101 используется предобученная на наборе данных Imagenet сеть для классификации изображений ResNet версии resnet101. По умолчанию количество идентифицируемых классов в сети DeepLab-v3 составляет 21. В работе проводилось переобучение головной части сети с заменой количества выходных слоев в последней свертке на 4 – по количеству идентифицируемых классов. На выходе сети получается вещественный тензор размера (B, C, H, W) , где B – размер мини-выборки (batch size), C – количество классов, H – высота изображения, W – ширина изображения.

Для обучения сети использовался оптимизатор Adam. По результатам предварительных тестов из традиционного для Adam диапазона скоростей обучения (learning rate) от 10^{-4} до 10^{-3} была выбрана скорость обучения $3 \cdot 10^{-4}$. Размер мини-выборки был равен 32. При этом на каждой эпохе обучения совершалось 80 обучающих и 20 проверочных итераций. Количество эпох составляло 20.

Были созданы две сети с одинаковыми параметрами за исключением функции потерь. Для одной сети функция потерь основывалась на метрике «расстояние Жаккара» (Jaccard distance), известной как IoU (Intersection over Union), а для другой – на метрике Сёренсена – Дайса (Dice) [19].

Пять изображений с различными особенностями были выбраны для тестового набора. Остальные 36 изображений подвергли следующей обработке. Ввиду того, что нейронную сеть предпочтительно обучать на изображениях одного размера, был выбран размер 224×224 пикселя, соответствующий рекомендованному размеру для сети ResNet, на основе которой построена выбранная модель DeepLab-v3. Из исходных изображений и масок вырезались фрагменты 224×224 пикселя со случайным шагом от 50 до 65 пикселей по каждой оси. Затем исходные изображения были уменьшены в 2 раза, и процедура повторялась для уменьшенных изображений. Разделение полученных 3148 изображений на обучающий и проверочный наборы выполнялось случайным образом с соотношением 0,8:0,2.

Обученная модель позволяет построить маску по фотографии микроструктуры произвольного разрешения. Для этого программа нарезает исходное изображение на фрагменты 224×224 пикселя. В случае если размер (ширина или высота) исходного изображения не кратен 224, последний (по горизонтали или по вертикали) квадрат может иметь пересечение с предпоследним.

Каждый фрагмент по отдельности обрабатывается сетью, и затем маска всего изображения собирается в обратном порядке. Полученная в результате работы нейронной сети маска позволяет вычислить в процентах объемную долю содержания карбидов (пикселей темно-серого цвета) на изображении микроструктуры. При этом области, не относящиеся к микроструктуре (пиксели светло-серого цвета), вычитаются из расчета общей площади, занятой микроструктурой.

Сравнение доли карбидов в микроструктуре, определенной с помощью искусственного интеллекта, проводилось с использованием ручного точечного метода определения объемной доли фаз по ASTM E 562. Для этого на тестовые изображения наносилась сетка из 100 точек (рис. 1). Объемная доля карбидов считалась как отношение количества точек сетки, попавших на карбид, к общему количеству точек. В случае попадания точки на границу «карбид – матрица» она принималась относящейся к обеим фазам, поэтому ее вклад в расчет доли карбидов составлял 0,5.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

В таблице 1 представлены изображения микроструктуры, использованные в качестве тестовых, а также маски изображений с использованием четырех назначенных цветов, сформированные человеком (ручная разметка) и двумя нейронными сетями, обученными с разными функциями потерь: IoU Loss и Dice Loss.

Видно, что у нейронных сетей не возникло проблем с сегментацией областей, не занятых микроструктурой (светло-серый цвет на изображениях 1, 2 и 5). Сети также распознают поры (черный цвет на изображениях 4 и 5), причем если на изображении 5 карбиды светлее матрицы и пора визуально значительно отличается от них по цветовой гамме, то на изображении 4 карбиды

темнее матрицы и имеют, как и пора, сферическую форму, поэтому адекватное распознавание поры на этом изображении не было предсказуемым. Видно, однако, что сеть с Dice Loss приняла небольшую часть поры за часть карбида.

Сегментация искусственным интеллектом карбидов, занимающих на изображениях большой объем и характеризующихся различными визуальными особенностями, ожидаемо была выполнена с некоторыми ошибками. В их числе распознавание карбидов в местах их отсутствия (выделено штриховой окружностью на изображении 1 сети с Dice Loss) и, наоборот, нераспознавание части карбида (выделено штриховой окружностью на изображениях 2, 4 и 5), которое фиксировалось обеими сетями в одних и тех же местах. Анализ этой ошибки показал, что она связана с нарезкой исходных изображений на квадраты 224×224 пикселя и обработке их по отдельности. В этом случае небольшая крайняя часть карбида оказывалась на другом изображении, и сеть ее не распознавала. Вероятно, по этой же причине изображение 3 сегментировано с наибольшей ошибкой, так как на некоторых нарезанных изображениях крупный карбид занимал большую часть кадра.

В целом можно отметить хорошее распознавание пор обученными нейронными сетями и отличную сегментацию на изображениях карбидов сферической формы, независимо от их цвета относительно матрицы и наличия пор в структуре.

В таблице 2 рассчитана объемная доля карбидов в микроструктуре покрытий на тестовых изображениях. Видно, что расчет по ASTM показал неплохие результаты в сравнении с эталонным расчетом по ручной разметке, отличие составляет от 0,5 до 1,3 % объемной доли карбидов. Нейронная сеть с IoU Loss показала разницу с эталоном от 0,1 до 1,1 %, а с Dice Loss – от 0,1 до 0,6 % карбидов. Среднеквадратическая ошибка

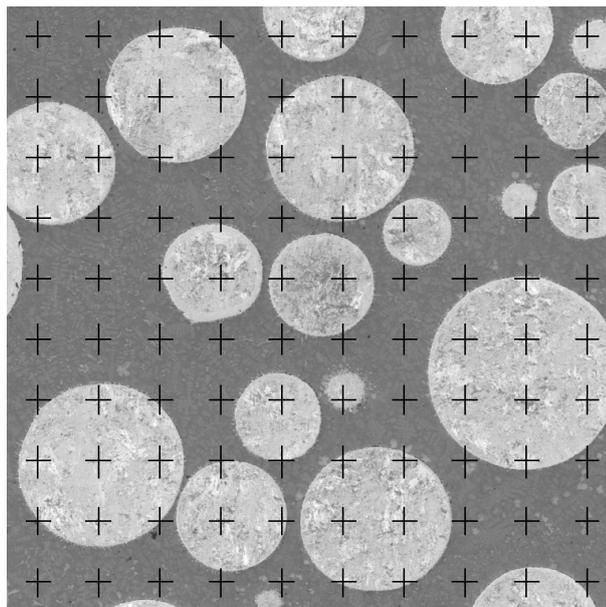


Рис. 1. Пример расчета доли карбидов в микроструктуре по ASTM E 562
Fig. 1. An example of determining the fraction of carbides in the microstructure according to ASTM E 562 test method

Таблица 1. Изображения микроструктуры из тестового набора и отображение масок, сформированных вручную и двумя нейронными сетями
 Table 1. Microstructure images from test set and imaging of masks created manually and by two neural networks

№	Изображение микроструктуры	Ручная разметка	Сеть с Loss=(1-IoU)	Сеть с Loss=(1-Dice)
1				
2				
3				
4				
5				

расчета доли карбидов по всему тестовому набору приведена в таблице 3. Расчет сетью с Dice Loss характеризовался наименьшим значением среднеквадратической ошибки (0,14), а расчет по ASTM – наибольшим (0,80).

Однако среднеквадратическая ошибка расчета доли карбидов не в полной мере отражает качество работы нейронной сети, так как не учитывает «двусторонние» ошибки сети: нахождение карбидов там, где они отсутствуют, и ненахождение там, где они должны быть.

Поэтому для нейронных сетей были определены также метрики IoU, Dice и MeanIoU, значения которых могут составлять от 0 до 1 и стремятся к 1 в случае наименьшей ошибки в сегментации областей. Несмотря на менее точное определение объемной доли карбидов в процентах (таблица 2), сеть с IoU Loss характеризуется максимальными значениями всех трех метрик (таблица 3), что связано с ее меньшими неточностями (по сравнению с сетью с Dice Loss) в сегментации самого «проблемного» изображения № 3 (таблица 1).

Таблица 2. Доля карбидов в микроструктуре покрытий, определенная различными методами, %
Table 2. The fraction of carbides in the microstructure of coatings determined by different methods, %

№ рисунка	Ручная разметка	Расчет по ASTM	Сеть с IoU Loss	Сеть с Dice Loss
1	15,8	16,5	15,7	15,6
2	48,4	49,0	48,5	48,5
3	36,6	35,5	37,7	37,2
4	28,5	28,0	27,9	28,3
5	36,2	37,5	36,6	36,7

Таблица 3. Среднеквадратическая ошибка, метрики IoU, Dice и MeanIoU для разных методов определения доли карбидов
Table 3. Mean square error, IoU, Dice, and MeanIoU metrics for different methods of determining the fraction of carbides

Метод определения доли карбидов	Среднеквадратическая ошибка	IoU	Dice	MeanIoU
Расчет по ASTM	0,80	–	–	–
Сеть с IoU Loss	0,37	0,958	0,979	0,952
Сеть с Dice Loss	0,14	0,956	0,977	0,945

ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ

Использование искусственного интеллекта обладает рядом недостатков, в частности необходимостью сбора и подготовки большого массива данных для обучения нейронной сети [20], а также подбора параметров обучения для более точной работы сети, причем многие из них выбираются только экспериментальным путем [21]. Таким образом, обучение нейронной сети и снижение ошибки сегментации ею карбидов занимает продолжительное время. Однако в дальнейшем сеть будет определять объемную долю карбидов на изображениях за доли секунд. Расчет ручным методом по ASTM занимает время меньше, чем обучение нейронной сети, но намного больше, чем расчет сетью после обучения, при этом нет предпосылок к снижению времени этой операции. Кроме того, «шаг» определения объемной доли по ASTM в случае сетки на 100 точек составляет 0,5 %, а в случае качественного обучения нейронной сети точность будет выше. В случае использования нейронных сетей также может быть снижена статистическая ошибка определения среднего содержания карбидов по всей площади покрытия, так как быстрый расчет позволяет увеличить количество анализируемых полей зрения.

Сети, обученные в настоящей работе, характеризуются хорошим распознаванием пор и отличной сегментацией карбидов сферической формы независимо от метода получения изображения (оптический/электронный микроскоп) и могут быть успешно использованы в настоящее время для оценки объемной доли сферических карбидов в микроструктуре покрытий.

Существуют некоторые проблемы с сегментацией карбидов угловатой формы, которые могут быть связаны как с меньшим количеством изображений с карбидами такого типа в обучающей сети, так и с тем, что на тестируемых изображениях такие карбиды были крупными (относительно общей площади изображения) и поэтому неадекватно оценивались сетями, обученными на небольших (224×224 пикселя) фрагментах изображений.

Решением этих проблем может стать как расширение набора данных, в частности добавление изображений с угловатыми карбидами и ситуаций, где карбид занимает большую часть кадра, так и изменение параметров обучения сети: обучение на изображениях большего размера, тестирование других функций потерь, варьирование размера мини-выборки, скорости обучения и т. д.

ОСНОВНЫЕ РЕЗУЛЬТАТЫ И ВЫВОДЫ

Показана принципиальная возможность использования двух нейронных сетей на основе DeepLab-v3, обученных с разными функциями потерь (IoU Loss и Dice Loss), для семантической сегментации карбидов в микроструктуре композиционных покрытий и последующего расчета их объемной доли. Сети распознают поры, области, не относящиеся к микроструктуре, и отлично сегментируют на изображениях карбиды сферической формы, независимо от их цвета относительно матрицы и наличия пор в структуре.

Значения объемной доли карбидов, определенные обоими сетями, отличались от эталонных значений на меньшие величины, чем значения, рассчитанные ручным точечным методом по ASTM. Сеть с IoU Loss характеризуется максимальными значениями всех метрик IoU, Dice и MeanIoU по сравнению с сетью с Dice Loss, что свидетельствует о меньшей ошибке в сегментации областей.

Главной проблемой сетей стала сегментация крупного карбида угловатой формы, что может быть решено путем расширения набора данных и изменения параметров обучения нейронной сети.

СПИСОК ЛИТЕРАТУРЫ

- Savraj R.A., Gladkovsky S.V., Lepikhin S.V., Kolobylin Yu.M. Approaches to the development of wear-resistant laminated metal composites // *Diagnostics, Resource and Mechanics of materials and structures*. 2021. № 5. P. 24–35. DOI: [10.17804/2410-9908.2021.5.24-35](https://doi.org/10.17804/2410-9908.2021.5.24-35).
- Соболева Н.Н., Николаева Е.П., Макаров А.В., Мalygina И.Ю. Влияние добавки карбида хрома на структуру и абразивную износостойкость NiCrBSi покрытия, сформированного лазерной наплавкой // *Вектор науки Тольяттинского государственного университета*. 2020. № 1. С. 68–76. DOI: [10.18323/2073-5073-2020-1-68-76](https://doi.org/10.18323/2073-5073-2020-1-68-76).
- Прибытков Г.А., Калита В.И., Комлев Д.И. и др. Твердость и износостойкость плазменных покрытий, напыленных СВС-композиционными порошками TiC + Ti-связка // *Упрочняющие технологии и покрытия*. 2019. Т. 15. № 8. С. 359–364. EDN: [MROUSQ](https://www.mrousoq.com).
- Makarov A.V., Soboleva N.N., Malygina I.Yu., Osintseva A.L. The tribological performances of a NiCrBSi – TiC laser-clad composite coating under abrasion and sliding friction // *Diagnostics, Resource and Mechanics of materials and structures*. 2015. № 3. P. 83–97. DOI: [10.17804/2410-9908.2015.3.083-097](https://doi.org/10.17804/2410-9908.2015.3.083-097).
- Nurminen J., Näkki J., Vuoristo P. Microstructure and properties of hard and wear resistant MMC coatings deposited by laser cladding // *International Journal of Refractory Metals and Hard Materials*. 2009. Vol. 27. № 2. P. 472–478. DOI: [10.1016/j.ijrmhm.2008.10.008](https://doi.org/10.1016/j.ijrmhm.2008.10.008).
- Enrici T.M., Dedry O., Boschini F., Tchuindjang J.T., Mertens A. Microstructural and Thermal Characterization of 316L+WC Composite Coatings obtained by Laser Cladding // *Advanced Engineering Materials*. 2020. Vol. 22. № 12. Article number 2000291. DOI: [10.1002/adem.202000291](https://doi.org/10.1002/adem.202000291).
- Deschuyteneer D., Petit F., Gonon M., Cambier F. Processing and characterization of laser clad NiCrBSi/WC composite coatings – Influence of microstructure on hardness and wear // *Surface and Coatings Technology*. 2015. Vol. 283. P. 162–171. DOI: [10.1016/j.surfcoat.2015.10.055](https://doi.org/10.1016/j.surfcoat.2015.10.055).
- Zhang Z., Liu H.X., Zhang X.W., Ji S.W., Jiang Y.H. Dissolution Behavior of WC Reinforced Particles on Carbon Steel Surface during Laser Cladding Process // *Advanced Materials Research*. 2012. Vol. 430–432. P. 137–141. DOI: [10.4028/www.scientific.net/AMR.430-432.137](https://doi.org/10.4028/www.scientific.net/AMR.430-432.137).
- Xu H., Huang H. Plasma remelting and injection method for fabricating metal matrix composite coatings reinforced with tungsten carbide // *Ceramics International*. 2022. Vol. 48. № 2. P. 2645–2659. DOI: [10.1016/j.ceramint.2021.10.048](https://doi.org/10.1016/j.ceramint.2021.10.048).
- 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](https://doi.org/10.1007/s13632-016-0289-6).
- 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](https://doi.org/10.1038/nmeth.2089).
- Rose D., Forth J., Henein H., Wolfe T., Qureshi A.J. Automated semantic segmentation of NiCrBSi-WC optical microscopy images using convolutional neural networks // *Computational Materials Science*. 2022. Vol. 210. Article number 111391. DOI: [10.1016/j.commatsci.2022.111391](https://doi.org/10.1016/j.commatsci.2022.111391).
- 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 book series*. 2021. Vol. 88. P. 1394–1406. DOI: [10.1007/978-3-030-70665-4_152](https://doi.org/10.1007/978-3-030-70665-4_152).
- Benjdira B., Bazi Y., Koubaa A., Ouni K. Unsupervised domain adaptation using generative adversarial networks for semantic segmentation of aerial images // *Remote Sensing*. 2019. Vol. 11. № 11. Article number 1369. DOI: [10.3390/rs11111369](https://doi.org/10.3390/rs11111369).
- Chen L.C., Papandreou G., Kokkinos I., Murphy K., 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. Vol. 40. P. 834–848. DOI: [10.1109/TPAMI.2017.2699184](https://doi.org/10.1109/TPAMI.2017.2699184).
- Long J., Shelhamer E., Darrell T. Fully convolutional networks for semantic segmentation // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2015. P. 3431–3440. DOI: [10.1109/CVPR.2015.7298965](https://doi.org/10.1109/CVPR.2015.7298965).
- Емельянов А.В. Анализ методов семантической сегментации изображений на основе нейронных сетей // *Математические методы в технике и технологиях – ММТТ*. 2019. Т. 12-1. С. 195–201. EDN: [GCGRLL](https://www.gcgrrll.com).
- Chen L.C., Papandreou G., Schroff F., Adam H. Rethinking Atrous Convolution for Semantic Image Segmentation // *arXiv:1706.05587*. 2017. DOI: [10.48550/arXiv.1706.05587](https://doi.org/10.48550/arXiv.1706.05587).
- Xu H., He H., Zhang Y., Ma L., Li J. A comparative study of loss functions for road segmentation in remotely sensed road datasets // *International Journal of Applied Earth Observations and Geoinformation*. 2023. Vol. 116. Article number 103159. DOI: [10.1016/j.jag.2022.103159](https://doi.org/10.1016/j.jag.2022.103159).
- Расторгуев Д.А., Севастьянов А.А. Разработка цифрового двойника процесса течения на основе машинного обучения // *Вектор науки Тольяттинского государственного университета*. 2021. № 1. С. 32–41. DOI: [10.18323/2073-5073-2021-1-32-41](https://doi.org/10.18323/2073-5073-2021-1-32-41).
- Вик К.В., Друки А.А., Григорьев Д.С., Спицын В.Г. Применение нейронных сетей глубокого обучения для решения задачи сегментации лесных пожаров на

спутниковых снимках // Вестник Томского государственного университета. Управление, вычислительная техника и информатика. 2021. № 55. С. 18–25. DOI: [10.17223/19988605/55/3](https://doi.org/10.17223/19988605/55/3).

REFERENCES

- Savrai R.A., Gladkovsky S.V., Lepikhin S.V., Kolobylin Yu.M. Approaches to the development of wear-resistant laminated metal composites. *Diagnostics, Resource and Mechanics of materials and structures*, 2021, no. 5, pp. 24–35. DOI: [10.17804/2410-9908.2021.5.24-35](https://doi.org/10.17804/2410-9908.2021.5.24-35).
- Soboleva N.N., Nikolaeva E.P., Makarov A.V., Malygina I.Yu. The influence of chromium carbide additive on the structure and abrasive wear resistance of the NiCrBSi coating formed by laser cladding. *Vektor nauki Tolyattinskogo gosudarstvennogo universiteta*, 2020, no. 1, pp. 68–76. DOI: [10.18323/2073-5073-2020-1-68-76](https://doi.org/10.18323/2073-5073-2020-1-68-76).
- Pribytkov G.A., Kalita V.I., Komlev D.I. et al. Hardness and wear resistance of plasma coatings sprayed by SHS-TiC + Ti-binder composite powders. *Uprochnyayushchie tekhnologii i pokrytiya*, 2019, vol. 15, no. 8, pp. 359–364. EDN: [MROUSQ](https://elibrary.ru/mrousq).
- Makarov A.V., Soboleva N.N., Malygina I.Yu., Osintseva A.L. The tribological performances of a NiCrBSi – TiC laser-clad composite coating under abrasion and sliding friction. *Diagnostics, Resource and Mechanics of materials and structures*, 2015, no. 3, pp. 83–97. DOI: [10.17804/2410-9908.2015.3.083-097](https://doi.org/10.17804/2410-9908.2015.3.083-097).
- Nurminen J., Näkki J., Vuoristo P. Microstructure and properties of hard and wear resistant MMC coatings deposited by laser cladding. *International Journal of Refractory Metals and Hard Materials*, 2009, vol. 27, no. 2, pp. 472–478. DOI: [10.1016/j.ijrmhm.2008.10.008](https://doi.org/10.1016/j.ijrmhm.2008.10.008).
- Enrici T.M., Dedry O., Boschini F., Tchuindjang J.T., Mertens A. Microstructural and Thermal Characterization of 316L+WC Composite Coatings obtained by Laser Cladding. *Advanced Engineering Materials*, 2020, vol. 22, no. 12, article number 2000291. DOI: [10.1002/adem.202000291](https://doi.org/10.1002/adem.202000291).
- Deschuyteneer D., Petit F., Gonon M., Cambier F. Processing and characterization of laser clad NiCrBSi/WC composite coatings – Influence of microstructure on hardness and wear. *Surface and Coatings Technology*, 2015, vol. 283, pp. 162–171. DOI: [10.1016/j.surfcoat.2015.10.055](https://doi.org/10.1016/j.surfcoat.2015.10.055).
- Zhang Z., Liu H.X., Zhang X.W., Ji S.W., Jiang Y.H. Dissolution Behavior of WC Reinforced Particles on Carbon Steel Surface during Laser Cladding Process. *Advanced Materials Research*, 2012, vol. 430–432, pp. 137–141. DOI: [10.4028/www.scientific.net/AMR.430-432.137](https://doi.org/10.4028/www.scientific.net/AMR.430-432.137).
- Xu H., Huang H. Plasma remelting and injection method for fabricating metal matrix composite coatings reinforced with tungsten carbide. *Ceramics International*, 2022, vol. 48, no. 2, pp. 2645–2659. DOI: [10.1016/j.ceramint.2021.10.048](https://doi.org/10.1016/j.ceramint.2021.10.048).
- 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, pp. 294–301. DOI: [10.1007/s13632-016-0289-6](https://doi.org/10.1007/s13632-016-0289-6).
- Schneider C.A., Rasband W.S., Eliceiri K.W. NIH Image to ImageJ: 25 years of image analysis. *Nature Methods*, 2012, vol. 9, pp. 671–675. DOI: [10.1038/nmeth.2089](https://doi.org/10.1038/nmeth.2089).
- Rose D., Forth J., Henein H., Wolfe T., Qureshi A.J. Automated semantic segmentation of NiCrBSi-WC optical microscopy images using convolutional neural networks. *Computational Materials Science*, 2022, vol. 210, article number 111391. DOI: [10.1016/j.commatsci.2022.111391](https://doi.org/10.1016/j.commatsci.2022.111391).
- 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 book series*, 2021, vol. 88, pp. 1394–1406. DOI: [10.1007/978-3-030-70665-4_152](https://doi.org/10.1007/978-3-030-70665-4_152).
- Benjdira B., Bazi Y., Koubaa A., Ouni K. Unsupervised domain adaptation using generative adversarial networks for semantic segmentation of aerial images. *Remote Sensing*, 2019, vol. 11, no. 11, article number 1369. DOI: [10.3390/rs11111369](https://doi.org/10.3390/rs11111369).
- Chen L.C., Papandreou G., Kokkinos I., Murphy K., 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, vol. 40, pp. 834–848. DOI: [10.1109/TPAMI.2017.2699184](https://doi.org/10.1109/TPAMI.2017.2699184).
- Long J., Shelhamer E., Darrell T. Fully convolutional networks for semantic segmentation. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2015, pp. 3431–3440. DOI: [10.1109/CVPR.2015.7298965](https://doi.org/10.1109/CVPR.2015.7298965).
- Emelyanov A.V. Analysis of image semantic segmentation methods based on neural networks. *Matematicheskie metody v tekhnike i tekhnologiyakh – MMTT*, 2019, vol. 12-1, pp. 195–201. EDN: [GCGRLL](https://elibrary.ru/gcgrll).
- Chen L.C., Papandreou G., Schroff F., Adam H. Rethinking Atrous Convolution for Semantic Image Segmentation. *arXiv:1706.05587*, 2017. DOI: [10.48550/arXiv.1706.05587](https://doi.org/10.48550/arXiv.1706.05587).
- Xu H., He H., Zhang Y., Ma L., Li J. A comparative study of loss functions for road segmentation in remotely sensed road datasets. *International Journal of Applied Earth Observations and Geoinformation*, 2023, vol. 116, article number 103159. DOI: [10.1016/j.jag.2022.103159](https://doi.org/10.1016/j.jag.2022.103159).
- Rastorguev D.A., Sevastyanov A.A. Development of turning process digital twin based on machine learning. *Vektor nauki Tolyattinskogo gosudarstvennogo universiteta*, 2021, no. 1, pp. 32–41. DOI: [10.18323/2073-5073-2021-1-32-41](https://doi.org/10.18323/2073-5073-2021-1-32-41).
- Vik K.V., Druki A.A., Grigorev D.S., 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'naya tekhnika i informatika*, 2021, no. 55, pp. 18–25. DOI: [10.17223/19988605/55/3](https://doi.org/10.17223/19988605/55/3).

Determination of the volume fraction of primary carbides in the microstructure of composite coatings using semantic segmentation

© 2023

Natalia N. Soboleva*^{1,2,3}, PhD (Engineering), senior researcher
Aleksandr N. Mushnikov^{1,4}, PhD (Engineering), researcher

¹Institute of Engineering Science of the Ural Branch of RAS, Yekaterinburg (Russia)

²M.N. Mikheev Institute of Metal Physics of the Ural Branch of RAS, Yekaterinburg (Russia)

*E-mail: soboleva@imach.uran.ru,
natashasoboleva@list.ru

³ORCID: <https://orcid.org/0000-0002-7598-2986>

⁴ORCID: <https://orcid.org/0000-0001-7073-6476>

Received 14.06.2023

Accepted 15.08.2023

Abstract: In the process of formation of composite coatings, partial dissolution of strengthening particles (most often carbides) in the matrix is possible; therefore, in some cases, the material creation mode is chosen taking into account the volume fraction of primary carbides not dissolved during coating deposition. The methods currently widely used for calculating the volume fraction of carbides in the structure of composite coatings (manual point method and programs implementing classical computer vision methods) have limitations in terms of the possibility of automation. It is expected that performing semantic segmentation using convolutional neural networks will improve both the performance of the process and the accuracy of carbide detection. In the work, multiclass semantic segmentation was carried out including the classification on the image of pores and areas that are not a microstructure. The authors used two neural networks based on DeepLab-v3 trained with different loss functions (IoU Loss and Dice Loss). The initial data were images of various sizes from electron and optical microscopes, with spherical and angular carbides darker and lighter than the matrix, in some cases with pores and areas not related to the microstructure. The paper presents mask images consisting of four classes, created manually and by two trained neural networks. The study shows that the networks recognize pores, areas not related to the microstructure, and perfectly segment spherical carbides in images, regardless of their color relative to the matrix and the presence of pores in the structure. The authors compared the proportion of carbides in the microstructure of coatings determined by two neural networks and a manual point method.

Keywords: composite coatings; carbides; optical microscopy; scanning electron microscopy; semantic segmentation; neural networks.

Acknowledgements: The work was carried out within the state assignment to the Institute of Engineering Science, UB RAS on the topics No. AAAA-A18-118020790147-4 and No. AAAA-A18-118020790148-1 and the Institute of Metal Physics, UB RAS on the topic “Additivity” No. 121102900049-1.

Microscopic images were obtained using the equipment of the “Plastometry” Core Facility Center of the IES UB RAS.

The paper was written on the reports of the participants of the XI International School of Physical Materials Science (SPM-2023), Togliatti, September 11–15, 2023.

For citation: Soboleva N.N., Mushnikov A.N. Determination of the volume fraction of primary carbides in the microstructure of composite coatings using semantic segmentation. *Frontier Materials & Technologies*, 2023, no. 3, pp. 95–102. DOI: 10.18323/2782-4039-2023-3-65-9.