

Распознавание и классификация микроструктуры металлов и сплавов с использованием глубоких нейронных сетей

Г.В. Аристов¹, А.В. Клюев¹
kav-1@bk.ru|chacknoris128@ya.ru

¹Пермский национальный исследовательский политехнический университет, Россия

Исследуются возможности искусственных нейронных сетей третьего поколения в задачах распознавания микроструктуры материалов. Разработка новых методов распознавания микроструктуры металлов и сплавов является актуальной задачей для создания функциональных материалов. Новые методы открывают путь к построению высокоэффективных методов прогнозирования их физико-механических свойств. В работе предложена архитектура свёрточной нейронной сети (относится к сетям третьего поколения), способной к распознаванию элементов микроструктуры. Обучение и апробация сети выполнена на задаче распознавания наличия дендритных структур на снимках микрошлифов металлов. Достигнуты положительные результаты с точностью более 90%. Высокая достоверность полученных результатов говорит о перспективности применения нейронных сетей третьего поколения в задачах распознавания и классификации микроструктур металлов и сплавов.

Ключевые слова: распознавание, микроструктура материала, анализ микрошлифов, функциональные материалы.

Recognition and classification of microstructure of metals and alloys with the use of deep neural networks

G.V.Aristov¹, Klyuev A.V.¹
kav-1@bk.ru|chacknoris128@ya.ru

¹Perm State National Research Polytechnic University, Russia

The possibilities of artificial third generation neural networks in problems of microstructure material recognition are explored. The development of new methods for recognizing the microstructure of metals and alloys is an actual task for the creation of functional materials. New methods open the way to building highly effective methods for predicting their physico-mechanical properties. The architecture of a convolutional neural network (refers to third generation networks) capable of recognizing microstructure elements is proposed. Training and approbation of the network is performed on the task of recognizing the presence of dendritic structures on the images of microsections of metals. Positive results were achieved with an accuracy of more than 90%. High reliability of the obtained results testifies to the prospects of using third generation neural networks in problems of recognition and classification of microstructures of metals and alloys.

Keywords: recognition, microstructure of the material, analysis of microsections, functional materials.

1. Введение

Микроструктура металлов и сплавов оказывает существенное влияние на термомеханические свойства изделий и конструкций, изготовленных из них. Именно поэтому выяснение микроструктуры металлических изделий и конструкций при производстве и эксплуатации является одной из актуальных задач.

В настоящее время существует три основных метода проведения контроля качества материала: экспертный анализ, лабораторный контроль, неразрушающий контроль. У первых двух методов есть существенные недостатки, хотя они являются наиболее широко распространенными на практике. Кроме значительных затрат времени и средств на реализацию, лабораторные исследования могут нести частичное разрушение образцов изделий в ходе эксперимента. Недостаток способов оценки материала с помощью экспертного анализа заключается в возможных значительных ошибках, определенных субъективными мнениями экспертов.

Основными методами неразрушающего контроля качества являются: магнитный, электрический, вихретоковый, радиоволновой, тепловой, визуально-оптический, радиационный, акустический и контроль проникающими веществами.

Исследование особенностей методов неразрушающего и разрушающего контроля качества показывает, что результатами большинства этих методов являются снимки (изображения) объектов и их дефектных областей [11].

Поэтому современные методы и алгоритмы обработки цифровых изображений и технологии искусственных нейронных сетей могут быть успешно применены для автоматизации анализа снимков, получаемых посредством различных методов контроля качества.

2. Выбор метода распознавания

В качестве метода анализа цифровых снимков микрошлифов металла была выбрана свёрточная нейронная сеть. Свёрточные нейронные сети (СНС, Convolutional neural network (CNN)) - это специальная архитектура искусственных нейронных сетей (ИНС) третьего поколения, нацеленная на эффективное распознавание изображений. Такие сети принято называть глубокими в связи с наличием в них большого количества слоев. Например, в работе [5] упоминается исследование сверхглубокой сети, в которой более 1000 слоев. Большие успехи глубоких сетей в задачах классификации [3,5] и семантической сегментации [2,4] широко известны, но, к сожалению, авторам не известны работы, в которых CNN применяется для классификации микроструктуры в металлах и сплавах. Тем не менее, неглубокие нейронные сети второго поколения уже использовались ранее в таких задачах анализа микроструктуры как задачи определения объемного содержания фазы, анализа зерна, выявление дефектов сварных соединений [7,10,1].

Основная идея СНС заключается в том, что при обучении СНС на основе исследуемых изображений одного класса, она самостоятельно формирует наборы признаков

(так называемые карты признаков), которые в полной мере характеризуют этот самый класс, и в то же время, отделяют их от других изображений [6]. Всё это реализуется в сети, с помощью так называемых свёрточных слоёв, которые составляют карты признаков изображения, и слоёв подвыборки, которые уменьшают масштаб изображения. Чередование данных слоёв позволяет составить карты признаков, с помощью которых изображения классифицируются.

Данная технология была выбрана в связи с относительно низкой чувствительностью к искажениям входных сигналов по сравнению с другими методами распознавания изображений. Кроме того, авторы учли, что СНС показывает высокую степень точности в разнообразных задачах распознавания образов [9,13,12].

3. Архитектура сети и обучение

В рамках исследования была разработана и реализована система распознавания дендритных микроструктур на цифровых снимках микрошлифов. В системе распознавания была реализована модель свёрточной нейронной сети (рис. 1). Структура сети характеризовалась порядком расположения свёрточных слоёв и слоёв подвыборки.




Рис. 1. Архитектура свёрточной нейронной сети.

Входной слой служит для подачи изображения в сеть. Размер входного слоя 90×90=8100 нейронов, что соответствует размеру исследуемого изображения в пикселях. Далее идут 2 слоя свертки и 3 слоя подвыборки. Седьмой слой – полносвязный слой. Данный слой служит для обеспечения классификации, после того как выделены все карты признаков. Каждый нейрон этого слоя полностью связан только с одним признаком предыдущего слоя. На выходе слоя 1200 простых сигмоидальных нейронов. Последний слой является выходным и состоит из одного нейрона, полностью связанного со всеми нейронами предыдущего слоя. В сумме сеть составила 92821 нейронов и 6332400 связей между ними.

Значение на выходе нейрона свёрточного слоя вычисляется с помощью выражения:

$$y_k^{(i,j)} = f \left(\sum_{s=1}^K \sum_{t=1}^K \sum_{k=1}^L b_k + w_k^{(s,t,k)} x_{((i-1+s),(j-1+t),k)} \right)$$

$$i = \overline{1, w_{out}}, j = \overline{1, h_{out}}, s, t = \overline{1, K},$$

где $y_k^{(i,j)}$ – выходной сигнал (нейрон), $w_k^{(s,t,k)}$ – веса, матрица синаптических коэффициентов рецептивных плоскостей всех карт текущего слоя, $x^{(*)}$ – входной сигнал, область входной плоскости, покрываемая синаптической маской, K – размер рецептивной плоскости (синаптического фильтра), b_k – порог, нейронное смещение k -ой карты признаков – отражает увеличение или уменьшение входного сигнала подаваемого на функцию

активации, k – номер карты признаков, L – общее количество карт признаков в слое.

Значение на выходе нейрона слоя подвыборки вычисляется с помощью выражения:

$$y_k^{(i,j)} = \max \{ x^{(i+sq_a, j+sq_b)} \}, \quad \begin{matrix} i = \overline{1, w_{out}} \\ j = \overline{1, h_{out}} \\ a, b = \overline{1, 2} \end{matrix}$$

где $y_k^{(i,j)}$ – выходной сигнал (нейрон) k -ой карты признаков, $sq_a = (i, i - 1)$, $sq_b = (j, j - 1)$ – векторы с координатами элементов входной плоскости, $x^{(*)}$ – входной сигнал, область входной плоскости, покрываемая синаптической маской.

Механизм обучения СНС называется «обучение с учителем», что подразумевает следующее: на вход СНС вместе с обучающим множеством подается правильный ответ распознавания. Таким образом, СНС с каждым новым элементом обучающего множества, корректирует весовые коэффициенты, исходя из разницы значений между фактическим ответом и тем, который дал «учитель». Для измерения качества распознавания используется функция среднеквадратичной ошибки. Корректировка весовых коэффициентов происходит с помощью метода обратного распространения ошибки. Начальные значение весовых коэффициентов были выбраны случайными величинами с нормальным распределением.




Рис. 2. Примеры снимков обучающей выборки.

В качестве инструмента использовался фреймворк Caffe. Перед обучением сети ее веса задавались случайным образом. Предобученная сеть не использовалась, ввиду особенности рассматриваемой задачи.

Обучение сети было выполнено с помощью обучающего множества объемом 3122 изображений. На рис.2 представлены характерные снимки из базы обучающего множества. Например, на снимке, расположенной в последнем ряду вторым справа, хорошо различима дендритная структура. Обучающее множество

было сформировано на основе микрофотографий проекта DoITPoMS (Dissemination of IT for the promotion of Materials Science) Кембриджского университета. Тестовый набор составил 500 изображений. Для того чтобы увеличить обучающие множество и точность распознавания, над оригинальными изображениями шлифов проводились различные операции обработки: зашумление, отражение, искажение.

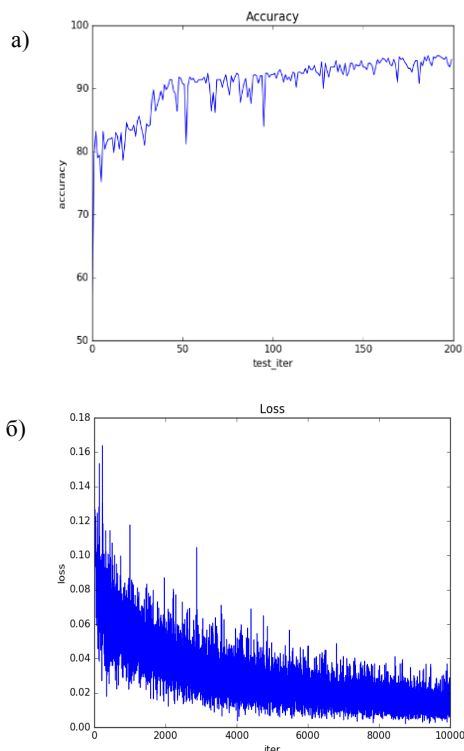


Рис. 3. Процесс обучение СНС: а) изменения точности, б) изменения функции ошибки.

Обучение сети длилось более 10000 итераций. В результате обучения сети из изображений были выделены карты признаков на каждом слое свёртке. Расчёт точности приводился каждые 50 итераций и равен проценту верно распознанных изображений из тестовой выборки. На рис.3,а представлен график изменения точности в процессе обучения. Значение 200 по оси абсцисс эквивалентно 10000-ам итераций. На момент окончания обучения точность распознавания сети достигла значения 94.6%. На рис.3,б представлена зависимость изменения функции ошибки от номера итерации.

Полученную точность классификации можно сравнить с точностью методов решения близкой задачи – задачи классификации текстур (распознавания поверхности материалов). В работе [8] исследуются несколько современных детекторов, включая многомасштабные, на известных наборах данных KTH-TIPS2 и FMD. Максимальная точность, которую удается достичь с помощью предложенного авторами детектора S3C (Spike-and-Slab Sparse Coding), составляет не более 72%.

4. Заключение

В рамках исследования была разработана структура свёрточной нейронной сети, произведено ее обучение для распознавания дендритной микроструктуры. Получены результаты распознавания на тестовой выборке снимков. Высокая достоверность полученных результатов говорит о перспективности применения СНС в задачах классификации микроструктур.

5. Поддержка

Исследование проводилось при финансовой поддержке Министерства образования и науки РФ в рамках проекта RFMEFI58617X0055.

6. Литература

- [1] Gang Wang, T. Warren Liao Automatic identification of different types of welding defects in radiographic images // NDT&E International. 2002. 35. pp 519–528.
- [2] Sithichok Chaichulee, Mauricio Villarroel, João Jorge, Carlos Arteta, Gabrielle Green, Kenny McCormick, Andrew Zisserman, Lionel Tarassenko, Multi-Task Convolutional Neural Network for Patient Detection and Skin Segmentation in Continuous Non-Contact Vital Sign Monitoring // Automatic Face & Gesture Recognition (FG 2017) 2017 12th IEEE International Conference on, 2017. pp. 266-272
- [3] Szegedy C., Liu W., Jia Y., Sermanet P., Reed S., Anguelov D, Erhan D., Vanhoucke V., Rabinovich A. Going deeper with convolutions // Proceedings of the IEEE conference on computer vision and pattern recognition. 2015. P.1-9
- [4] Jonathan Long, Evan Shelhamer, Trevor Darrell Fully convolutional networks for semantic segmentation // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2015. pp. 3431-40
- [5] K. He, X. Zhang, S. Ren, J. Sun Deep Residual Learning for Image Recognition// Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) — DC, USA: IEEE Computer Society Washington, 2016 — С. 2342—2354.
- [6] Le Cun Y., Bengio Y. Convolution networks for images, speech and time series // The handbook of brain theory and neural networks. 1998. V. 7. № 1. pp. 225 – 258.
- [7] Victor Hugo C de Albuquerque, Auzuir Ripardo de Alexandria, Paulo César Cortez, João Manuel RS Tavares, Evaluation of multilayer perceptron and self-organizing map neural network topologies applied on microstructure segmentation from metallographic images // NDT & E International, Vol.42(7), 2009, pp. 644-651.
- [8] Wenbin Li, Mario Fritz Learning Multi-Scale Representations for Material Classification // German Conference on Pattern Recognition, 2014, pp. 757-764
- [9] Друки А.А. Применение свёрточных нейронных сетей для выделения и распознавания автомобильных номерных знаков на изображениях со сложным фоном // Интеллектуальные системы. Известия Томского политехнического университета. 2014. Т. 324. № 5 С. 85 – 92.
- [10] Емельянов В.А. Моделирование нейронных сетей распознавания металлографических изображений для диагностики состояния сталей // Электротехнические и компьютерные системы. № 12 (88), 2013, С. 125-131.
- [11] Ермаков А.А., Орлов А.А., Садыков С.С., Стародубов Д.Н. Методы и алгоритмы обработки и анализа дефектоскопических и металлографических снимков. Владимир: Изд-во Владимир, гос. ун-та, 2008, 112 с.
- [12] Макаренко А. А., Калайда В.Е. Методика локализации изображения лица для систем видео контроля на основе нейронных сетей // Известия Томского политехнического университета. 2006. Т. 309. № 8. С. 113 – 118.
- [13] Солдатова О.П., Гаршин А.А. Применение свёрточных нейронных сетей для распознавания рукописных цифр // Компьютерная оптика том 34. № 2. 2010. С.252 – 259.

Об авторах

Клюев Андрей Владимирович, к.ф.-м.н., доцент кафедры «Вычислительная математика и механика» Пермского национального исследовательского политехнического университета. Его e-mail: kav-1@bk.ru.

Аристов Григорий Валерьевич, магистр, кафедра «Вычислительная математика и механика» Пермского национального исследовательского политехнического университета. Его e-mail: chacknotis128@ya.ru.