

Получено: 27.06.2024 г. | Принято: 1.07.2024 г. | DOI: <https://doi.org/10.22184/1993-8578.2024.17.6.346.354>

Научная статья

НЕЙРОСЕТЕВАЯ МОДЕЛЬ ДЛЯ КОРРЕКТИРОВКИ ПРОЦЕССА ИССЛЕДОВАНИЯ КОЛЛОИДНЫХ НАНО- И МИКРОСТРУКТУР МЕТОДОМ АТОМНО-СИЛОВОЙ МИКРОСКОПИИ

Е.В.Панфилова¹, к.т.н., доц., ORCID: 0000-0001-7944-2765 / panfilova.e.v@bmstu.ru

А.Р.Ибрагимов¹, асс., ORCID: 0000-0001-9689-1837

Д.В.Францышин^{1, 2}, студ., инж., ORCID: 0009-0007-7493-8199

Аннотация. Важным этапом процесса формирования микро- и наноструктур являются операции контроля. Для оперативного контроля коллоидных нано- и микроструктурированных пленок используют атомно-силовую микроскопию, реализуемую методом амплитудно-модуляционного полуконтактного сканирования. Этот способ характеризуется сложностью и длительностью настроек режимов сканирования образцов. В данном проекте разработана нейронная сеть для автоматической оптимизации параметров процесса в ходе сканирования, что позволяет значительно ускорить процедуру контроля, повысить качество изображений и точность измерений.

Ключевые слова: наноструктуры, серебро, атомно-силовая микроскопия, частицы серебра

Для цитирования: Е.В. Панфилова, А.Р. Ибрагимов, Д. В. Францышин. Нейросетевая модель для корректировки процесса исследования коллоидных нано- и микроструктур методом атомно-силовой микроскопии. НАНОИНДУСТРИЯ. 2024. Т. 17. № 6. С. 346–354. <https://doi.org/10.22184/1993-8578.2024.17.6.346.354>

Received: 27.06.2024 | Accepted: 1.07.2024 | DOI: <https://doi.org/10.22184/1993-8578.2024.17.6.346.354>

Original paper

NEURAL NETWORK MODEL FOR ADJUSTING THE PROCESS OF STUDYING COLLOIDAL NANO- AND MICROSTRUCTURES USING ATOMIC FORCE MICROSCOPY

Е.В.Panfilova¹, Cand. of Sci. (Tech), Assistant Professor, ORCID: 0000-0001-7944-2765 / panfilova.e.v@bmstu.ru

А.Р.Ibragimov¹, Assistant, ORCID: 0000-0001-9689-1837

Д.В.Frantsisin^{1, 2}, Student, Eengineer, ORCID: 0009-0007-7493-8199

Abstract. An important stage in the process of formation of micro- and nanosystems is control operations. For operational monitoring of colloidal nano- and microstructured films, atomic force microscopy is used, implemented by the method of amplitude modulation semi-contact scanning. This method is characterized by the complexity and duration of setting the sample scanning parameters. In this project, a neural network has been developed to automatically optimize process parameters during scanning, which can significantly speed up the process and improve image quality and measurement accuracy.

Keywords: nanostructures, silver, atomic force microscopy

¹ Московский государственный технический университет имени Н.Э.Баумана (Национальный исследовательский университет), Москва, Россия / Bauman Moscow State Technical University (National Research university), Moscow, Russia

² ООО "Остек-ЭК", Москва, Россия / Ostek-EK LLC, Moscow, Russia



For citation: E.V. Panfilova, A.R. Ibragimov D.V. Frantsisin. Neural network model for adjusting the process of studying colloidal nano- and microstructures using atomic force microscopy. NANOINDUSTRY. 2024. Vol. 17. No. 6. PP. 346–354. <https://doi.org/10.22184/1993-8578.2024.17.6.346.354>.

ВВЕДЕНИЕ

Коллоидные нано- и микроструктуры находят практическое применение во множестве активно развивающихся областей науки и инженерного дела. Использование для формирования коллоидных структур диоксида кремния (SiO_2), диоксида титана (TiO_2), полистирольного латекса (PS) и ряда других материалов позволяет получать из них коллоидные фотонные кристаллы (КФК), являющиеся перспективным материалом для устройств фотоники, оптоэлектроники и лазерной техники [1]. В [2] описывается разнообразие отражающих дисплеев на основе природоподобных фотонно-кристаллических структур. В [3] представлен колориметрический датчик деформации на основе КФК, интегрированный деформируемым графеновым фотопреобразователем. В [4] предлагается концепция полностью оптических логических вентиляй на основе КФК, модулированных фотoluminesценцией перовскитных нанокристаллов.

Разнообразие применений коллоидных нано- и микроструктур ставит перед учеными множество задач и научных вызовов, связанных с прецизионностью объектов разработки. Классическими методами их контроля и исследования являются электронная и зондовая микроскопии. Однако диэлектрические материалы, используемые в КФК, ограничивают использование электронной микроскопии. Поэтому для неразрушающего контроля морфологии коллоидных нано- и микроструктурированных пленок используют зондовую атомно-силовую микроскопию (ACM), реализуемую методом амплитудно-модуляционного полуконтактного (прерывисто контактного) сканирования [5]. Метод позволяет оперативно осуществлять в атмосфере высокоточные измерения без предварительной подготовки образцов. Несмотря на наличие большого количества достоинств методу свойственно появление артефактов, появляющихся по причине наличия разнообразных шумов, конволюции зонда и образца, залипания зонда при взаимодействии с образцом и др. Возникновение многих проблем может являться следствием неправильно подобранных параметров сканирования, которые отличаются от образца к образцу. Текущие системы ACM позволяют осуществлять подбор параметров в автоматическом режиме, однако, данная опция подходит в основном для тривиальных исследований поверхностей без каких-либо особенностей. Поэтому для исследования хрупких образцов

INTRODUCTION

Colloidal nano- and microstructures find practical application in many actively developing areas of science and engineering. The use of silicon dioxide (SiO_2), titanium dioxide (TiO_2), polystyrene latex (PS), and a number of other materials for the formation of colloidal structures makes it possible to produce colloidal photonic crystals (CPCs), which are promising materials for photonics, optoelectronics, and laser devices [1]. In [2], a variety of reflective displays based on nature-like photonic crystal structures is described. In [3], a colorimetric strain sensor based on CFC integrated by a deformable graphene photoconverter is presented. In [4], a concept of all-optical logic gates based on CFCs modulated by photoluminescence of perovskite nanocrystals is proposed.

The variety of applications of colloidal nano- and microstructures poses many tasks and scientific challenges for scientists related to precision of development objects. The classical methods for their control and study are electron and probe microscopy. However, dielectric materials used in CFCs limit the use of electron microscopy. Therefore, for nondestructive control of morphology of colloidal nano- and microstructured films, probe atomic force microscopy (AFM) realised by amplitude-modulation semi-contact (intermittent contact) scanning is used [5]. The method allows rapid implementation of high-precision measurements in atmosphere without preliminary sample preparation. Despite a large number of advantages, this method is characterised by artefacts caused by various noises, probe and sample convolution, sticking of the probe when interacting with the sample, etc. The occurrence of many problems may result from incorrectly selected scanning parameters that differ from sample to sample. Occurrence of many problems can be a consequence of incorrectly selected scanning parameters, which differ from sample to sample. Current AFM systems allow automatic selection of parameters, however, this option is suitable mainly for trivial studies of surfaces without any features. Therefore, to study fragile samples with developed relief and to obtain the best results it is still necessary to select the correct scanning parameters "manually", which is a labour-intensive task requiring a high level of training and experience of the operator.

Currently, there are various methods to improve scanning efficiency, ranging from mathematical processing to development of fundamentally new elements of the system. In [6], an optimal set of scanning



с развитым рельефом и получения наилучших результатов по-прежнему требуется подбор корректных параметров сканирования "вручную", что является трудоемкой задачей, требующей высокого уровня подготовки и опыта у оператора.

В настоящее время существуют различные методы повышения эффективности сканирования, начиная от математической обработки до создания принципиально новых элементов системы. В работе [6] для функции системы зонд-образец вычисляется оптимальный набор параметров сканирования. В работе [7] экспериментальным путем выявляют зависимости износа зонда ACM на качество сканирования, затем получая оптимальные настройки параметров, которые могут облегчить износ зонда. В работе [8] описывается метод увеличения скорости сканирования в диапазоне сканирования в несколько десятков микрометров путем использования одночастотного управляющего сигнала и внедрением в систему нечеткого регулятора. Все большую популярность обретают нейросетевые алгоритмы, используемые для улучшения широкого круга производственных и исследовательских процессов. В работе [9] описываются применения нейросетевых моделей и алгоритмов для ACM, которые позволяют повысить эффективность процесса сканирования на основе характеристик изучаемых образцов. В ряде работ предлагаются осуществлять нейросетевую постобработку полученных результатов контроля [10], фильтрации изображений и подавления на них артефактов [11], сжатия количества точек при сканировании, с последующей их реконструкцией [12]. Нейросетевая модель, объединяющая в себе оба подхода, была представлена авторами ранее в работе [13], она позволяет подбирать индивидуальные параметры сканирования для образцов КФК на основе параметров, описывающих их свойства и методы формирования. Наибольший интерес представляют нейронные сети, которые позволяют в режиме реального времени корректировать параметры сканирования без какого-либо присутствия человека. Ведущие компании-разработчики атомно-силовых микроскопов уже начали внедрять такие нейронные сети (НС) в свое программное обеспечение: NanoScope Analysis компании BRUKER (США) [14], интеллектуальный программный модуль SCANTRONIC™ компании NT-MDT Spectrum Instruments (Россия) [5]. Названные модули, будучи предназначенными для большого круга пользователей, требуют для корректной работы знания свойств и характеристик исследуемых образцов, которые в рамках исследовательских лабораторий не всегда известны, что ограничивает их применимость. Поэтому в данной работе представлена

parameters is calculated for the probe-sample system function. In [7], the AFM probe dependences wear on scanning quality are identified experimentally, then optimal parameter settings that can alleviate probe wear are obtained. In [8], a method of increasing the scanning speed in the scanning range of several tens of micrometres by using a single-frequency control signal and implementing a fuzzy controller in the system is described. Neural network algorithms are becoming increasingly popular and are used to improve a wide range of manufacturing and research processes. The paper [9] describes application of neural network models and algorithms for AFM, which allow to increase the scanning process efficiency based on the characteristics of the studied samples. In some works it is proposed to perform neural network post-processing of the obtained control results [10], filtering of images and suppression of artefacts [11], compression of the number of points during scanning, with their subsequent reconstruction [12]. A neural network model combining both approaches was presented by the authors earlier in [13]; it allows selecting individual scanning parameters for CPC samples on the basis of parameters describing their properties and methods of formation. Neural networks that allow real-time adjustment of scanning parameters without any human presence are of great interest. Leading companies-developers of atomic force microscopes have already started to implement such neural networks (NN) in their software: NanoScope Analysis by BRUKER (USA) [14], intelligent software module SCANTRONIC™ by NT-MDT Spectrum Instruments (Russia) [5]. The above modules, being intended for a wide range of users, require for correct operation knowledge of properties and characteristics of the ыегвшув samples, which are not always known within the framework of research laboratories, which limits their applicability. Therefore, this paper presents a neural network model to optimise the process of imaging the surface of colloidal nano- and microstructures by atomic force microscopy by adjusting the scanning parameters directly during the examination of the sample. The principle of the model is to process the real-time AFM image and adjust the scanning parameters until an optimal image is obtained by a feedback system.

METHODS AND MATERIALS

Photonic crystalline films of spherical silica and polystyrene particles were used as studied colloidal nano- and microstructures. The colloidal solution of silica was prepared by a modified Stober method on a controlled colloidal solution synthesis bench. The colloidal polystyrene particles were commercially available standard samples. The films were prepared on silicon and polyethylene terephthalate substrates



нейросетевая модель для оптимизации процесса получения изображений поверхности коллоидных нано- и микроструктур методом атомно-силовой микроскопии посредством настройки параметров сканирования непосредственно при исследовании образца. Принцип модели заключается в обработке изображения, получаемого на АСМ в режиме реального времени, и корректировке параметров сканирования до получения оптимального изображения по системе обратной связи.

МЕТОДЫ И МАТЕРИАЛЫ

В качестве исследуемых коллоидных нано- и микроструктур использовались фотонно-кристаллические пленки из сферических частиц диоксида кремния и полистирола. Коллоидный раствор диоксида кремния был получен модифицированным методом Штобера на стенде управляемого синтеза коллоидных растворов. Коллоидные частицы полистирола представляли собой коммерческие стандартные образцы. Пленки были сформированы на подложках из кремния и полиэтилентерефталат методами spin-coating и вертикального вытягивания с помощью оборудования, входящего в лабораторный комплекс для получения коллоидных фотонно-кристаллических структур [15].

Контроль образцов осуществлялся на атомно-силовом микроскопе Solver NEXT компании NT-MDT Spectrum Instruments (Россия) в полуконтактном режиме. Основными варьируемыми параметрами при сканировании являлись Set Point – уровень параметра взаимодействия зонда и поверхности, поддерживаемый обратной связью при сканировании, Gain – коэффициент усиления синхронного усилителя, Rate – скорость сканирования, Amplitude – амплитуда колебаний кантилевера в полуконтактном режиме. Параметр Points – количество точек сканирования – оставался неизменным для получения и был равен 512×512 . Разработка нейронной сети велась в среде Visual Studio Code с использованием языка Python 3.11.

Данные, полученные методом АСМ, обычно представляют собой массив данных, который может быть представлен в виде трехмерной модели. Для представления их НС все результаты сканирования сохранялись в виде двухмерных изображений поверхности с помощью встроенного программного обеспечения и представляли собой RGB-изображения размером 675×675 пикселей (рис.1). Каждое изображение фрагментировалось на левять частей размером 675×75 пикселей для имитации начального этапа сканирования. С целью сокращения объема данных без потери качества и информативности изображения были преобразованы в оттенки серого. В таком виде НС

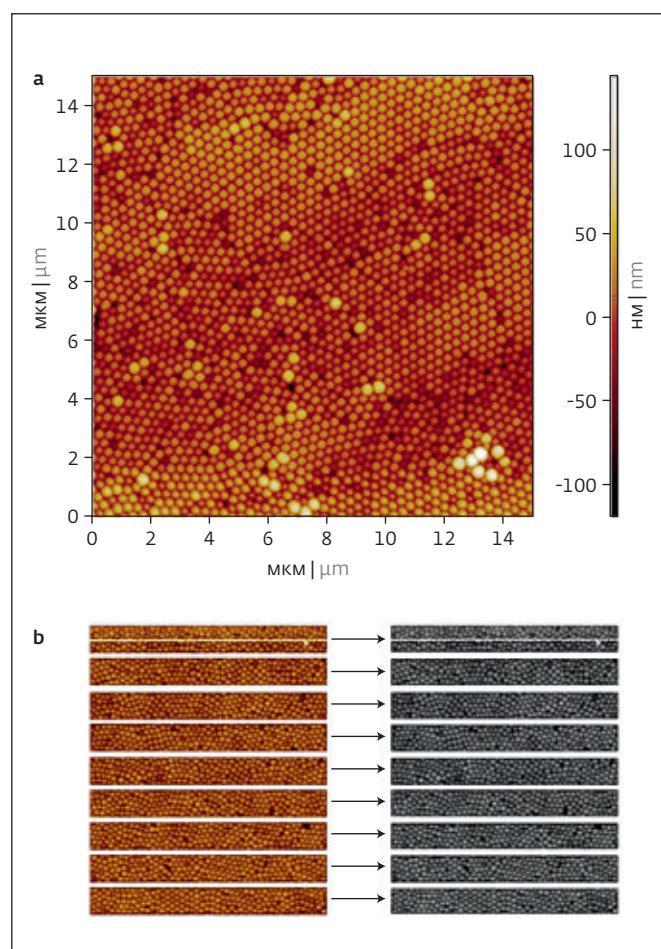


Рис.1. Изображение, подаваемое на вход нейронной сети:
а – исходное изображение; б – изображение после обработки
Fig.1. Image given to the neural network input: a – original image;
b – image after processing

by spin-coating and vertical pulling methods using equipment included in the laboratory complex to form the colloidal photonic crystal structures [15].

The samples were controlled on the atomic force microscope Solver NEXT of NT-MDT Spectrum Instruments (Russia) in semi-contact mode. The main variable parameters during scanning were Set Point – the level of the probe-surface interaction parameter supported by feedback during scanning, Gain – gain of the synchronous amplifier, Rate – scanning speed, Amplitude – amplitude of cantilever oscillations in the semi-contact mode. The parameter Points – number of scanning points remained unchanged for obtaining and was equal to 512×512 . The neural network was developed in the Visual Studio Code environment using the Python 3.11 language.

The data obtained by AFM method is usually an array of data that can be represented as a



получала данные о пикселе не в виде кортежа RGB, а в качестве единичного значения, соответствующего оттенку серого.

В процессе нормализации входных данных для нормализации и получения матрицы значений от 0 до 1 все значения пикселей делились на 255. В результате независимо от природы входного числа (пиксель или значение параметра процесса) его значение всегда находилось в одинаковых пределах, что позволило получить НС с более равномерными весами. Данные о параметрах сканирования подверглись нормализации по аналогичному принципу, таким образом, чтобы значение 0 соответствовало минимальному значению параметра из обучающей выборки, а 1 – максимальному.

Задача разработки и реализации нейронной сети усложнялась необходимостью сочетать обработку изображений и параметров процесса, что привело к наличию двух входных слоев у нейронной сети. Разработанная архитектура содержит 19 слоев с суммарным количеством варьируемых параметров более 43 миллионов. Структурно НС состоит из нескольких частей, которые выполняют выделение дефектов в изображении, анализ дефектов на изображении, анализ дефектов с учетом параметров процесса, при котором было получено изображение, и корректировка.

Выделение дефектов осуществляется после того, как изображение проходит чередующиеся слои свертки и подвыборки. Для уменьшения объема информации, ускорения процесса обучения и упрощения НС изображение проходит слои подвыборки, которые сжимают изображение в четыре раза после каждого слоя. В первой части разработанной НС присутствуют входной слой, четыре слоя свертки и четыре слоя подвыборки и технический слой для преобразования матрицы (рис. 2). Результатом прохождения изображением ядра свертки является признак, в первом слое свертки присутствует восемь признаков, то есть на каждую двухмерную матрицу (изображение), поступающее на вход слоя на выходе будет четыре изображения, где выделяются искомые признаки. В каждом следующем слое количество признаков увеличивается.

После выделения признаков реализуется процесс их анализа. В этой части НС происходит классификация выявленных дефектов и оценивается их влияние на параметры процесса. Для этого используется классическая MLP (multi-layer perceptron) архитектура, состоящая из шести слоев с количеством нейронов 512, 256, 64, 4, соответственно, где 2-й и 4-й слои – обнуляющие слои DropOut. В качестве функции активации нейронов был принят гиперболический тангенс.

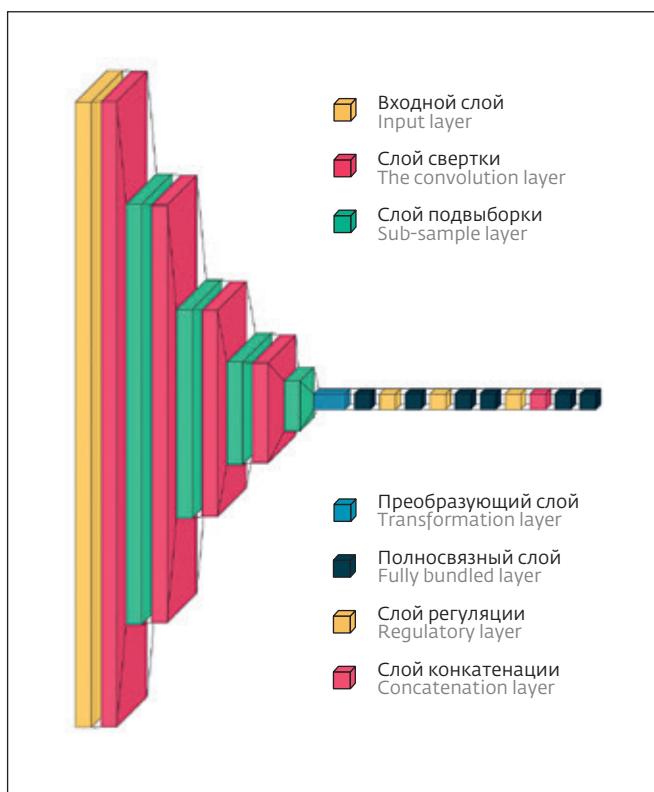


Рис.2. Структура нейронной сети

Fig.2. Neural network structure

three-dimensional model. To represent their NN, all scan results were saved as 2D surface images using inbuilt software and were RGB images of 675×675 pixels (Fig.1). Each image was fragmented into 9 parts of 675×75 pixels to simulate the initial scanning step. In order to reduce the amount of data without loss of quality and informativeness, the images were converted to shades of grey. In this form, the NN received data about a pixel not as an RGB tuple, but as a single value corresponding to a shade of grey.

During the input data normalisation process, all pixel values were divided by 255 to normalise and produce a matrix of values from 0 to 1. As a result, regardless of the nature of the input number (pixel or process parameter value), its value was always within the same limits, resulting in a NN with more uniform weights. The scan parameter data were normalised using a similar principle, so that a value of 0 corresponded to the minimum parameter value from the training sample and 1 to the maximum.

The task of neural network design and implementation was complicated by the need to combine image and process parameter processing, which led to presence of two input layers in the neural network. The developed architecture contains 19 layers with the

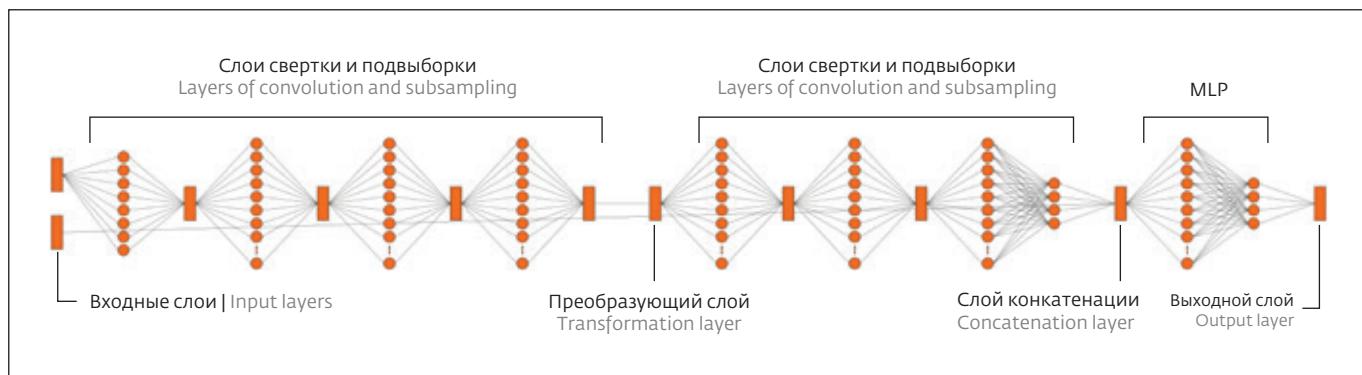


Рис.3. Архитектура нейронной сети
Fig.3. Neural network architecture

В последнюю часть НС подаются параметры процесса, при которых было получено изображение. Эта часть сети реализуется, как и предыдущая, на основе MLP архитектуры с количеством нейронов в слоях 32, 4, а первые два слоя являются входным слоем и техническим слоем конкатенации.

Суммарное количество связей в разработанной нейронной сети составляет 43427108 единиц. Все веса нейросетевой модели занимают около 498 Мб памяти. Изображение нейронной сети с указанием типов слоев и связей между ними показано на рис.3.

В процессе обучения нейронной сети использовался алгоритм обратного распространения ошибки. После каждого прохода по сети обратное распространение выполняет проход в обратную сторону и регулирует параметры модели (веса и смещения). Параметры, выбранные для обучения, приведены в табл.1.

Для ускорения обучения был использован метод мини-выборки, и параметры НС обновлялись после прохождения целой мини-выборки. За счет этого удалось снизить время обучения с 8,5 ч до 20 мин. Ошибка на обучающей выборке составила около 8%, на выборке валидации – около 20%, на тестовой – 8,5%.

РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

Зависимость ошибки на обучающей выборке и ошибки на выборке валидации можно увидеть на рис.4. Ошибка падает с увеличением эпох, учитывая плавность графика можно утверждать, что гиперпараметры НС подобраны корректно, то есть нейронная сеть сходима.

Научный интерес представляет понимание того, как разработанная НС воспринимает изображение. Алгоритмически была извлечена информация, содержащая измененные нейронной сетью изображения (Рис.5). Можно заметить,

total number of varying parameters more than 43 million. Structurally, NN consists of several parts that perform defect extraction in the image, defect analysis in the image, defect analysis taking into account the process parameters in which the image was acquired, and correction.

Defect extraction is performed after the image passes alternating convolution and subsampling layers. To reduce the amount of information, speed up the learning process and simplify NN, the image passes through subsampling layers that compress the image by a factor of 4 after each layer. The first part of the developed NN contains an input layer, 4 convolution layers and 4 subsampling layers and a technical layer for matrix transformation (Fig.2). The result of passing the image of the convolution kernel is a feature, in the first convolution layer there are 8 features, i.e. for each two-dimensional matrix (image) coming to the input layer at the output will be 4 images, where the desired features are selected. In each next layer the number of features increases.

Таблица 1. Параметры обучения
Table 1. Training parameters

Тип ошибки Error type	Среднее отклонение от искомого значения Mean deviation from the desired value
Алгоритм оптимизации Optimisation algorithm	Адаптивная оценка момента Adaptive moment estimation AdaM
Количество эпох Number of periods	150
Размер мини-выборки Mini-sample size	35

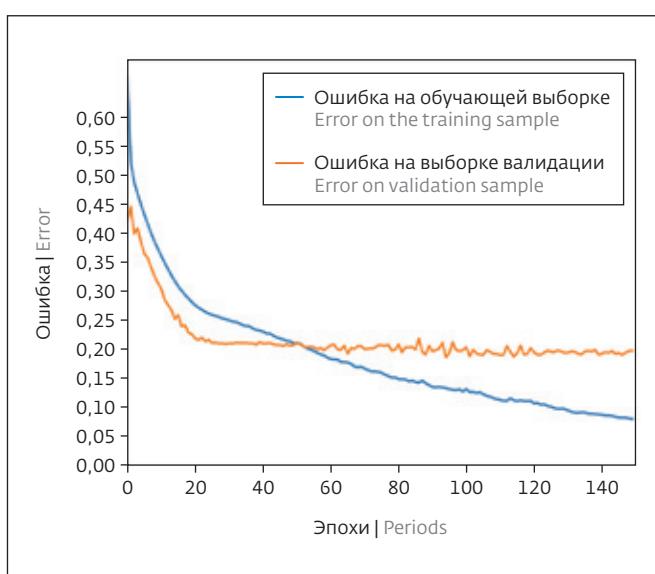


Рис.4. Зависимость ошибки разработанной нейронной сети от количества эпох

Fig.4. Dependence of the error of an algorithmic neural network on the number of periods

что на финальном слое свертки на изображениях выделяются именно дефекты, а изображение без дефектов является менее ярким, что свидетельствует о меньшей степени активации нейронов. Изображение на рис.5 (и) уже не содержит элементов полученного на вход изображения. При этом НС выделила те участки, которые в ходе анализа посчитала наиболее важными и перевела информацию из концептуально-качественной в аналитическо-количественный формат. Уменьшение разрешения изображения связано с прохождением слоев пулинга.

Для анализа качества работы нейронной сети был выполнен анализ изображений с артефактами и без них. В обоих случаях процент ошибки составил менее 5% для каждого из параметров. В табл.2 представлены результаты этого тестирования НС.

ВЫВОДЫ

Для предупреждения появления артефактов на АСМ-изображенияхnano- и микроструктур, в частности коллоидных фотонно-кристаллических пленок, рационально выполнять корректировку параметров сканирования образцов с использованием искусственного интеллекта. Хорошие результаты анализа и выявления признаков формируемых изображений показала глубокая нейронная сеть, содержащая слои свертки, подвыборки и регуляризации, дополненная сетью с архитектурой многослойного персептрона, отвечающей

After feature extraction, the process of their analysis is implemented. In this part of NN the detected defects are classified and their influence on the process parameters is evaluated. For this purpose, the classical MLP (multi-layer perceptron) architecture is used, consisting of 6 layers with the number of neurons 512, 256, 64, 4, respectively, where the 2nd and 4th layers are DropOut nulling layers. A hyperbolic tangent was adopted as activation function of the neurons.

The last part of NN is fed with the process parameters at which the image was acquired. This part of the network is realised, like the previous one, on the basis of MLP architecture with the number of neurons in layers 32, 4, and the first two layers are the input layer and the technical concatenation layer.

The total number of links in the developed neural network is 43427108 units. All weights of the neural network model occupy about 498 MB of memory. The image of the neural network with indication of the types of layers and connections between them is shown in Fig.3.

In the process of training the neural network, the error back propagation algorithm was used. After each pass through the network, back propagation performs a backward pass and adjusts the model parameters (weights and biases). The parameters selected for training are given in Table 1.

To speed up the training, a mini-sampling method was used and the NN parameters were

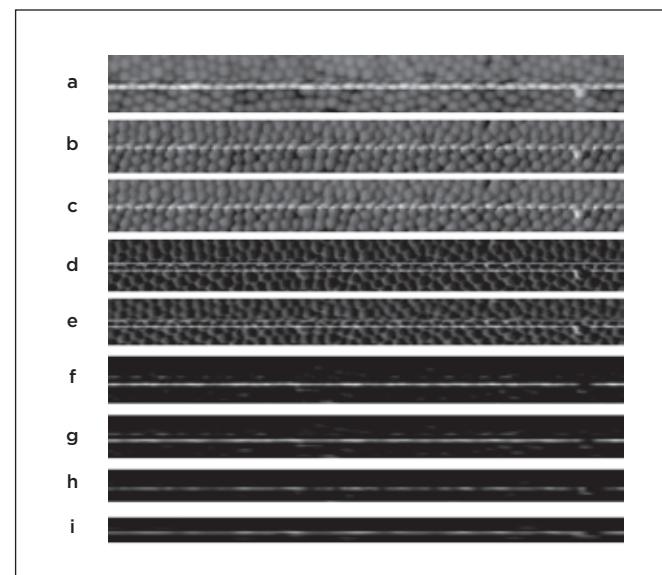


Рис.5. Трансформация изображения при прохождении слоев НС (a – начальное изображение, i – конечное изображение)

Fig.5. Image transformation when passing through NN layers (a – initial image, i – final image)



Таблица 2. Результаты тестирования НС

Table 2. Results of NS testing

Параметр сканирования Scanning parameter	Образец без артефактов Sample w/o artefacts		Образец с артефактами Sample with artefacts	
	Требуемое значение корректировки Required adjustment value	Выход НС NS output	Требуемое значение корректировки Required adjustment value	Выход НС NS output
Заданная точка Set Point	0	-2,10	7,59	8,040
Gain Результат	0	0,09	-0,55	-0,529
Скорость Rate	0	0,01	0,20	0,197
Амплитуда Amplitude	0	-0,10	-0,80	0,734

за анализ входных параметров (режимов) процесса. Такая модель способна выдавать качественные корректировки параметров сканирования в требуемых ситуациях. Ошибка обобщения при обработке АСМ-изображений в этом случае не превышает 5%. Полученные результаты и наработки могут быть использованы в лабораторных исследованиях, а также при разработке метрологической документации.

ИНФОРМАЦИЯ О РЕЦЕНЗИРОВАНИИ

Редакция благодарит анонимного рецензента (рецензентов) за их вклад в рецензирование этой работы, а также за размещение статей на сайте журнала и передачу их в электронном виде в НЭБ eLIBRARY.RU.

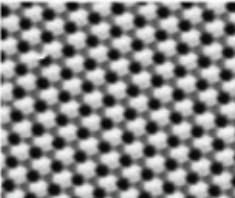
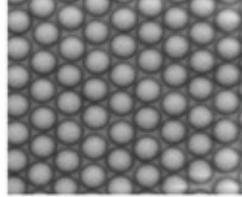
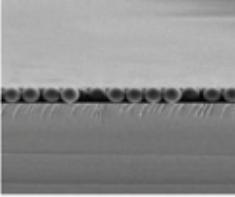
Декларация о конфликте интересов. Авторы заявляют об отсутствии конфликтов интересов или личных отношений, которые могли бы повлиять на работу, представленную в данной статье.

ЛИТЕРАТУРА / REFERENCES

- Панфилова Е.В. Перспективные методы формирования планарных наноструктур // Наноинженерия. Машиностроение. 2014. № 8. С. 29–33.
- Liu Y. et al. Bioinspired reflective display based on photonic crystals // Interdisciplinary Materials. 2024. Vol. 3. No. 1. PP. 54–73.
- Snapp P. et al. Colloidal photonic crystal strain sensor integrated with deformable graphene photo-transducer // Advanced Functional Materials. 2019. Vol. 29. No. 33. P. 1902216.

updated after passing an entire mini-sample. This reduced the training time from 8.5 hours to 20 minutes. The error on the training sample was about 8%, on the validation sample about 20%, and on the test sample 8.5%.

ЛАБОРАТОРИЯ НАНО- И МИКРОСТРУКТУР
кафедры «Электронные технологии в машиностроении»
МГТУ им. Н. Э. Баумана

- ◆ Синтез коллоидных частиц диоксида кремния
- ◆ Изготовление образцов коллоидных фотонно-кристаллических плёнок и фиброневых структур
- ◆ Разработка лабораторных стендов
- ◆ Микроскопические и спектрофотометрические исследования

panfilova.e.v@bmstu.ru

 @NanoSelf_bot



4. Wang Y. et al. All-optical logic gates based on hierarchical photonic crystal modulated photoluminescence of perovskite nanocrystals // Science China Technological Sciences. 2023. Vol. 66. No. 9. PP. 2735–2742.
5. Быков В.А. и др. Зондовая микроскопия и спектроскопия: приборы, техника и технология измерений // Взаимодействие сверхвысокочастотного, терагерцового и оптического излучения с полупроводниковыми микро- и наноструктурами, метаматериалами и биообъектами. 2019. С. 29–32.
6. Giessibl F.J. et al. Calculation of the optimal imaging parameters for frequency modulation atomic force microscopy // Applied Surface Science. 1999. Vol. 140. No. 3–4. PP. 352–357.
7. Xue B. et al. Study on effects of scan parameters on the image quality and tip wear in AFM tapping mode // Scanning: The Journal of Scanning Microscopies. 2014. Vol. 36. No. 2. PP. 263–269.
8. Wang Y. et al. Improving the scanning speed of atomic force microscopy at the scanning range of several tens of micrometers // Ultramicroscopy. 2013. Vol. 124. PP. 102–107.
9. Giergiel M. et al. AFM image analysis of porous structures by means of neural networks // Biomedical Signal Processing and Control. 2022. Vol. 71. P. 103097.
10. Vekinis A.A., Constantoudis V. Neural network evaluation of geometric tip-sample effects in AFM measurements // Micro and Nano Engineering. 2020. Vol. 8. P. 100057.
11. Kocur V. et al. Correction of AFM data artifacts using a convolutional neural network trained with synthetically generated data // Ultramicroscopy. 2023. Vol. 246. P. 113666.
12. Sun M. et al. Fast AFM Imaging Based on Neural Network Compressed Sensing // 2022 IEEE 24th International Workshop on Multimedia Signal Processing (MMSP). IEEE. 2022. PP. 1–5.
13. Panfilova E.V., Ibragimov A.R., Mozer K.V. Neural network module for tuning an atomic force microscope in the study of photonic crystal films // Journal of Physics: Conference Series. IOP Publishing. 2020. Vol. 1571. No. 1. P. 012004.
14. Yablon D. et al. Deep learning to establish structure property relationships of impact copolymers from AFM phase images // Mrs Communications. 2021. Vol. 11. PP. 962–968.
15. Панфилова Е.В., Дюбанов В.А., Ибрагимов А.Р., Шрамко Д.Ю. Лабораторный комплекс для получения коллоидных фотонно-кристаллических структур. Ч. 1 // НАНОИНДУСТРИЯ. 2024. Т. 17. № 3–4. С. 190–199. <https://doi.org/10.22184/1993-8578.2024.17.3-4.190.198>

RESULTS AND DISCUSSION

The dependence of the error on the training sample and the error on the validation sample can be seen in Fig.4. The error decreases with increasing periods, taking into account the smoothness of the graph, we can say that the hyperparameters of NN are selected correctly, i.e. the neural network converges.

It is of scientific interest to understand how the developed NN perceives an image. Algorithmically extracted information containing images modified by the neural network (Fig.5). It can be seen that in the final convolution layer, it is the defects that stand out in the images, while the image without defects is less bright, indicating a lower degree of neuronal activation. The image in Fig.5 (and) does not contain elements of the image received as input. At the same time, the NN selected those areas that it considered the most important during the analysis and translated the information from conceptual-qualitative to analytical-quantitative format. Decrease in image resolution is associated with the passage of pooling layers.

To analyse quality of neural network performance, images with and without artefacts were analysed. In both cases the error percentage was less than 5% for each of the parameters. Table 2 presents the results of this NN testing.

CONCLUSIONS

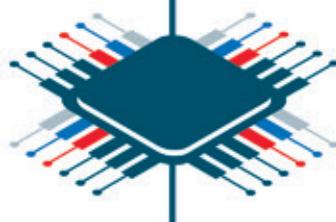
To prevent artefacts in AFM images of nano- and microstructures, in particular colloidal photonic-crystalline films, it is rational to adjust the sample parameters scanning using artificial intelligence. A deep neural network containing convolution, subsampling and regularisation layers, supplemented by a network with multilayer perceptron architecture responsible for the analysis of input parameters (modes) of the process, has shown good results in analysing and detecting the features of the formed images. Such a model is able to produce qualitative adjustments of the scanning parameters in the required situations. The generalisation error in processing AFM images in this case does not exceed 5%. The obtained results and developments can be used in laboratory studies, as well as in the development of metrological documentation.

PEER REVIEW INFO

Editorial board thanks the anonymous reviewer(s) for their contribution to the peer review of this work. It is also grateful for their consent to publish papers on the journal's website and SEL eLibrary eLIBRARY.RU.

Declaration of Competing Interest. The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

rus-elektronika.ru



ЭЛЕКТРОНИКА РОССИИ

Выставка электронной продукции
российского производства

26|27|28
НОЯБРЯ
2024 МОСКВА
Крокус Экспо



Забронируйте стенд на выставке:

+7 (812) 401 69 55, electron@mvk.ru



Организатор:



Официальная поддержка:



Партнеры:

