

8. Pan W., et. al. Adaptive randomness: a new population initialization method, *Math. problems in engineering*, 2014, Vol. 2014, 14 p.
9. Ahmad M., Isa N., Limb W., Ang K. Differential evolution with modified initialization scheme using chaotic oppositional based learning strategy, *Jour. Al. Engin.*, 2022, Vol. 61 (12), pp. 11835-11858.
10. Chib S., Greenberg E. Understanding the Metropolis–Hastings Algorithm, *Am Stat.*, 1995, Vol. 49 (4), pp. 327-335.
11. Chauveau D., Vandekerckhove P. Improving convergence of the Hastings-Metropolis algorithm with an adaptive proposal, *Scand. Jour. Stat.*, 2002, Vol. 29 (1), pp. 13-29.
12. Rodzin S., Rodzina O. New computational models for big data and optimization, *Proc. 9th Int. Conf. on Application of Information and Communication Technologies (AICT)*, 2015, pp. 3-7.
13. Rahnamayan S., Tizhoosh H., Salama M. A novel population initialization method for accelerating evolutionary algorithms, *Comput. Math. Appl.*, 2007, Vol. 53 (10), pp. 1605-1614.
14. Ahmad M., Isa N., Limb W., Ang K. Differential evolution with modified initialization scheme using chaotic oppositional based learning strategy, *Alexan. Engin. Jour.*, 2022, Vol. 61 (12), pp. 11835-11858.
15. Li Q., Bai Y., Gao W. Improved Initialization Method for Metaheuristic Algorithms: A Novel Search Space View, *IEEE Access.*, 2021, Vol. 9, pp. 158508-158539.
16. Cuevas E., Escobar H., Sarkar R., Eid H. A new population initialization approach method, *Applied Intelligence*, 2023, Vol. 53, pp. 16575-16593.
17. Wang H., Wu Z., Rahnamayan S. Enhanced opposition based differential evolution for solving high-dimensional continuous optimization problems, *Soft. Comput.*, 2011, Vol. 15 (11), pp. 2127-2140.
18. Rodzin S., Rodzina L. Theory of bionic optimization and its application to evolutionary synthesis of digital devices, *Proc. of IEEE East-West Design and Test Symposium (EWDTS)*, 2014, pp. 7027058.
19. Kureychik V.V., Rodzin S.I. Bioevristiki, inspirirovannye faunoy (obzor) [Bioheuristics inspired by fauna (review)], *Informatsionnye tekhnologii* [Information technologies], 2023, Vol. 29, No. 11, pp. 559-573.
20. Rodzin S.I., Skobtsov Yu.A., El'-Khatib S.A. Bioevristiki: teoriya algoritmy i prilozheniya: monografiya [Bioheuristics: theory, algorithms and applications: monograph]. Cheboksary: ID "Sreda", 2019, 224 p.

Родзин Сергей Иванович – Южный федеральный университет; e-mail: srodzin@sfedu.ru; г. Таганрог, Россия; кафедра математического обеспечения и применения ЭВМ; профессор.

Дерменжи Анастасия Игоревна – ООО «Видучи»; e-mail: dermenzhi-00@mail.ru; г. Москва, Россия; генеральный директор.

Rodzin Sergey Ivanovich – Southern Federal University; e-mail: srodzin@sfedu.ru; Taganrog, Russia; phone: +78634371673; the Department of Software Engineering; professor.

Dermenzhi Anastasia Igorevna – Viduchi LLC, e-mail: dermenzhi-00@mail.ru; Moscow, Russia; general manager.

УДК 004.932

DOI 10.18522/2311-3103-2025-1-56-65

А.В. Полтавский, Д.С. Поляниченко, Е.Р. Коломенская, М.А. Бугакова

АЛГОРИТМЫ ГЕНЕРАЦИИ И ОБРАБОТКИ SEM-ИЗОБРАЖЕНИЙ ДЛЯ ИДЕНТИФИКАЦИИ СВОЙСТВ БИОНЕОРГАНИЧЕСКИХ МАТРИЦ И МЕТОДЫ ИХ ВЕРИФИКАЦИИ

Одним из распространенных методов анализа характеристик материалов, получаемых в результате химического синтеза, является сканирующая электронная микроскопия (SEM), применение которой позволяет получить изображения с высоким разрешением и увеличением. В статье исследуются алгоритмы анализа изображений материалов, обладающих определенными свойствами (например, пористостью) – бионеорганических матриц. Пористые структуры представляют собой обширный класс материалов с широкой областью применения, включая сельское хозяйство, медицину, катализ и многое другое. Одна из важных сфер использования подобных структур – тканевая инженерия, в которой подобные каркасы необходимы для обеспечения восстановительных процессов тканей организма. И для каждого организма матрицы должны быть персонализированными, что требует выполнения трудоемкого процесса по подбору характеристик каркаса, применимого в конкретном случае. Эта задача в настоящее время частично решается применением технологий искусственного интеллекта для повышения точности или поддержки при-

нятия решения во время изготовления или анализа матрицы. Однако, часть работы в этом процессе все еще выполняется вручную и представляет из себя трудозатратную рутину для специалиста. В частности, процесс анализа SEM-изображений с целью вычисления характеристик полученного материала все еще представляет множество длительных этапов с использованием различных инструментов. При этом такие характеристики как пористость, извилистость, диффузность являются очень важным фактором для эксперта в процессе принятия решения о применимости изготовленной бионеорганической матрицы в каждом конкретном случае. Соответственно целью данного исследования является разработка комплекса алгоритмов для полностью автоматической обработки SEM-изображений. Также, исходя из поставленной цели, в рамках исследования можно выделить ряд задач: разработка алгоритмов для детекции объектов на изображении, разработка модели нейронной сети для уточнения результатов детекции, реализация алгоритмов вычисления характеристик пористого материала, а также проектирование и выполнение ряда верификационных испытаний для подтверждения качества выполненных вычислений. В результате проведенного исследования мы сделали некоторые выводы. В частности, подход, использующий генерацию синтетических данных, может существенно ускорить и упростить процесс обучения нейронной сети, а также повысить качество выходной модели. Далее мы заключили, что полученные алгоритмы могут полностью автоматизировать процесс анализа SEM-изображений с пористой структурой, а качество вычислений подтвердили с помощью ряда верификационных тестов. Полученные алгоритмы могут быть распространены на другие аналогичные задачи, связанные с проблемами анализа изображений и выявления необходимых признаков и характеристик.

SEM-изображения; пористость; выделение контуров; сегментация; диффузность; проницаемость; верификация; материалы; машинное обучение; морфология.

A.V. Poltavskiy, D.S. Polyanichenko, E.R. Kolomenskaya, M.A. Butakova

ALGORITHMS OF GENERATION AND SEM-IMAGES PROCESSING FOR PROPERTIES IDENTIFICATION OF BIOINORGANIC MATRICES AND METHODS OF THEIR VERIFICATION

Scanning electron microscopy (SEM) is one of the most common methods for analyzing the characteristics of materials obtained through chemical synthesis. The use of this method makes it possible to obtain images with high resolution and magnification. The article examines algorithms for image analysis of materials with specific properties, such as porosity – bioneorganic matrices. Scaffolds are a broad class of materials with a wide range of applications, including agriculture, medicine, catalysis, and many others. One of the important applications of such structures is tissue engineering, where such frameworks are necessary to ensure the regenerative processes of body tissues. And for each organism matrices must be personalized, which requires a laborious process of selecting the characteristics of the framework applicable in a particular case. This task is currently partially solved by the application of artificial intelligence technologies to improve accuracy or support decision making during matrix fabrication or analysis. However, some of the work in this process is still manual and represents a labor-intensive chore for the technician. In particular, the process of analyzing SEM images and characterizing the resulting material still involves many time-consuming steps using various tools. At the same time, such characteristics as porosity, tortuosity, and diffusivity are very important factors for an expert in the process of making a decision on the applicability of the fabricated bioinorganic matrix in each specific case. Accordingly, the purpose of this research is to develop a set of algorithms for processing SEM-images. Also based on the set goal within the framework of the research we can distinguish a number of issues: development of algorithms for detection of objects in the image, development of a neural network model for refining the detection results, implementation of algorithms for calculating the characteristics of porous material, as well as design and execution of a number of verification tests to confirm the quality of the performed calculations. As a result of our research, we drew some conclusions. In particular, we found that an approach using synthetic data generation significantly speeds up and simplifies the learning process of neural networks, as well as improves the quality of output models. We also found that the algorithms we developed can fully automate the analysis of SEM images with porous structures, and their quality was confirmed through a number of verification tests. These algorithms can be applied to other similar problems related to image analysis and identification of features and characteristics.

SEM images; porosity; contour selection; segmentation; diffusivity; permeability; verification; materials; machine learning; morphology.

Введение. Бионеорганические матрицы являются важным объектом изучения в материаловедении, биологии и медицине. В тканевой инженерии клетки помещают на пористый трехмерный каркас, который обеспечивает поддержку и направляет клетки к росту новых тканеподобных структур [1, 2]. Матрицы могут обеспечить платформу для высвобождения факторов роста и доставки лекарств в контролируемых условиях [3]. Эффективная конструкция матриц имеет важное значение для остеоинтеграции. Современные методы изготовления матриц позволяют получать пористые трехмерные конструкции с порами различных форм и размеров [4]. Каркасные материалы обладают сложной структурой, включающей взаимосвязанные поры и каркасные элементы, которые определяют их механические, химические и функциональные свойства [5, 6]. После изготовления матрицы, в первую очередь, необходимо определить ее качество и применимость для конкретного случая, так как свойства ткани, для поддержки которой создавалась матрица, являются уникальными для каждого конкретного случая. Соответственно, после каждого эксперимента необходимо пройти процесс вычисления характеристик полученного каркаса.

В настоящее время этот процесс выполняется в полуавтоматическом режиме на основе экспертных знаний и аналитических выводов. Для детального анализа пор широко применяются изображения, полученные методом сканирующей электронной микроскопии (SEM). Этот метод позволяет исследовать микро- и наноструктуры с высокой точностью, обеспечивая визуализацию пористых структур и ключевых элементов матриц [7]. Для правильного анализа каркаса необходимо пройти через ряд процессов. Например, найти и зафиксировать поры на изображении, произвести расчет пористости, а также выходящие характеристики (извилистость, диффузность и т.п.). Однако сложная и неоднородная структура бионеорганических матриц существенно затрудняет процесс анализа, формируя дополнительные издержки в ходе исследования. Кроме этого, изучение каждой матрицы – это процесс достаточно рутинный для эксперта, поэтому нередки и ошибки вычислений.

С очередным этапом развития технологий искусственного интеллекта вопрос автоматизации и интеллектуализации процесса анализа бионеорганических матриц стал особенно актуальным. Современные алгоритмы машинного обучения предоставляют новые возможности для более точного анализа и характеристики таких структур [8, 9]. Мы также ранее поднимали тему достижений искусственного интеллекта в области тканевой инженерии в работе [10]. Наибольшая активность сейчас наблюдается в рамках процесса исследования SEM-изображений, так как он несет в себе большую рутинную трудоемкость и в первую очередь требует оптимизации. Однако, для достижения значительного прогресса в этой области необходимо решить ряд проблем результирующих изображений: шум, неоднородность освещения и сложные формы структур. Традиционные методы обработки включают фильтрацию шума, выравнивание контраста и пороговую сегментацию. Тем не менее, эти методы часто оказываются недостаточными для сложных и неоднородных структур бионеорганических матриц. Последние исследования в этой сфере показывают существенный прогресс в разрешении этих проблем.

Так, например, в исследовании [11] предложена вычислительная структура для точного обнаружения и анализа наночастиц на SEM-изображениях. Используя библиотеки Python, такие как OpenCV, SciPy и Scikit-Image, авторы применили комбинацию методов пороговой обработки, дилатации и эрозии для улучшения результатов обработки изображений. Этот подход продемонстрировал высокую точность в идентификации наночастиц, включая те, которые не были отмечены при ручной разметке. В работе [12] предложена новая ансамблевая модель глубокого обучения для точной классификации и обнаружения различных категорий дефектов на SEM-изображениях. Авторы обучили модели RetinaNet с различными архитектурами ResNet и VGGNet в качестве основы и сравнили их точность и производительность при обнаружении дефектов, таких как мостики, разрывы и обрушения линий. Предложенный ансамблевый метод продемонстрировал улучшение среднего показателя точности (mAP) для наиболее сложных классов дефектов. Также авторами в исследовании [13] предложен автоматизированный подход на основе глубокого обучения для эффективной локализации и классификации дефектов на SEM-изображениях. Они разработали архитектуру SEMI-CenterNet, обученную на SEM-изображениях дефектов полупроводниковых пластин, что позволило улучшить вычислительную эффективность по сравнению с предыдущими методами.

При этом все еще актуален вопрос полноценной автоматизации и актуализации непосредственно процесса анализа. Все текущие исследования в первую очередь развивают качество и точность отдельных его частей, таких как детекция пор, вычисление извилистости и так далее. Но использование этих решений все еще остается в рамках полуавтоматического процесса и требует полноценного экспертного вмешательства, соответственно не исключая рутины и снимая лишь часть нагрузки с исследователя.

Для решения задачи полноценной автоматизации мы предлагаем подход, основанный на использовании авторского алгоритмического комплекса. Мы разработали ряд алгоритмов и связали их в виде единого комплекса для работы с бионеорганическими матрицами. Этот метод позволяет полностью переложить рутинную нагрузку на автоматические вычисления, при этом сохранив экспертную ответственность за принятие решения для обеспечения максимального качества результата анализа конкретной матрицы.

Также мы разработали и применили ряд методов верификации для нашего программного комплекса и провели тестирование как каждого алгоритма, так и в целом всей системы, в результате которого сделали заключение о достаточном качестве всей системы для решения задач анализа бионеорганических матриц в автоматическом режиме.

1. Архитектура предложенного подхода. Разработанный комплекс можно разделить на 2 наиболее важных алгоритмических блока:

- 1) система детекции пор и преобразования данных SEM-изображения;
- 2) алгоритмическая модель для вычисления основных и дополнительных характеристик бионеорганических матриц.

Система детекции при этом является наиболее сложной и объемной задачей. Она должна решать основополагающую проблему анализа – качественную детекцию пор и извлечение первичных морфологических характеристик для дальнейшей передачи в математическую модель. При этом сама модель нейронной сети должна быть гибкой и легко масштабируемой.

Придерживаясь этой концепции, мы выполнили поиск набора данных, достаточного для обеспечения нужных нам технических характеристик системы. В частности, мы исследовали набор, представленный авторами в работе [14]. Однако, все обработанные нами данные не могли обеспечить достаточную точность модели. SEM-изображения, представленные в наборах, имели слишком мало отличий друг относительно друга, а следовательно, не могли полностью описать характеризующее признаковое пространство для качественной детекции.

Для решения задачи недостатка данных мы решили использовать метод, основанный на использовании синтетических данных для обучения модели. Этот подход был описан и апробирован нами в цикле статей [15–17]. Для создания результирующей обучающей выборки в рамках детекции по на SEM-изображениях было решено разработать генератор.

2. Генерация SEM-изображений. Разработка специального генератора позволит получить относительно бесконечное количество результирующих изображений, которые при этом будут достаточно отклонены друг от друга. При этом такой подход позволит обеспечить масштабируемость проекта, так как программные алгоритмы легко адаптируемы под задачу, в отличие от реальных данных.

Для достижения достаточного качества обучающего набора необходимо разработать модель данных, которая в достаточной степени охватит рассматриваемое множество признаков. Важнейшая часть подобной модели – формализация математических свойств генерируемых данных. В качестве свойств использовались специальные параметры, пригодные для применения в Евклидовом пространстве, которые могут принимать случайную величину (если быть точными – псевдослучайную). Комбинация таких параметров позволит изменять генерируемые данные, тем самым позволяя достигнуть достаточной ширины области данных. В результате была разработана аналитическая модель, состоящая из 7-ми основных величин.

Используя параметры для каждой генерируемой поры, стало возможным задавать фактор уникальности, который состоит из комбинации параметров и их величин. С помощью всего 7-ми допущенных характеристик появилась возможность оперирования

25-ю случайными параметрами в заданном диапазоне множества вещественных чисел. При этом их комбинации улучшают полноту данных, увеличивая число элементов множества допустимых значений, так как для каждой поры возможно задавать от 0 до 7 определенных модификаторов.

Прототип полученной аналитической модели реализован с помощью программной среды для создания компьютерной графики Blender с использованием пакета для написания программного кода Blender Python API.

Генерируемые поры без определенной четкой формы соответствуют реальным данным. Также, зачастую, во время генерации создаются случайные отклонения за пределами признакового пространства, то есть некоторые формы пор не могут встречаться в реальных экспериментах. В рамках обучающих данных модели – это хорошая практика, так как такие не соответствующие реальным сгенерированные виды пор симулируют частные случаи сложной идентификации, если пора, например, частично разрушена, или возможно перекрытие.

3. Обучение модели нейронной сети для детекции объектов. В рамках данного исследования не было необходимости в модели с измененной сложной архитектурой слоев, так как мы подготовили вспомогательный алгоритм сегментации контуров пор. Однако, крайне необходимо было реализовать качественную модель для разрешения ситуаций неочевидных детекций, которые пропускаются алгоритмом. Опираясь на наше прошлое исследование [18], было принято решение об обучении модели одноэтапного детектора YoloV7 на предобработанной выборке из синтетических данных. В ходе предварительной конфигурации параметров модели были выбраны оптимальные гиперпараметры, а также подтверждено точное количество данных для обучающей выборки – 4300 изображений. Набор такого объема оказался достаточным, так как в конце обучения функция точности выходила на стабильное плато, при этом ошибка сохраняла тренд стремления к 0. После выполнения итогового обучения модель показала достаточно высокие метрики и на тестовых примерах правильно детектировала необходимые поры.

4. Алгоритмическая модель вычисления характеристик пористых материалов. Вторым важным этапом в создании алгоритмического комплекса является разработка набора алгоритмов, которые позволят вычислять в автоматическом режиме морфологические характеристики бионеорганической матрицы. Именно по этим результатам эксперт сможет сделать заключение о применимости полученного каркаса в конкретном случае. Для вычисления всех характеристик были использованы данные от модели и вспомогательных алгоритмов, полученных на первом этапе работы всей системы. И первая основополагающая характеристика – пористость.

4.1. Пористость материала – это важная морфологическая характеристика, которая определяет долю объема или площади пор в общей структуре материала. Для её вычисления с использованием SEM-изображений мы использовали адаптированный алгоритм бинаризации. Так как в результате работы системы у нас есть данные по детектированным порам, мы можем сделать контрастными области внутри и за пределами пор, а далее уже вычислить количество белых пикселей, соответствующих пористой области, и общее количество пикселей изображения. Пористость на основе анализа изображений рассчитывается как отношение площади пор к общей площади. Этот подход позволяет точно оценить пористость двумерных изображений, что имеет важное значение для изучения структуры материала.

4.2. Анализ диффузности. Диффузность материала вычисляется с помощью анализа распределения интенсивности пикселей внутри пор на одном SEM-изображении. Для этого оценивалась однородность распределения интенсивности в пористой области: чем равномернее интенсивность, тем меньше препятствий для прохождения молекул или жидкостей через материал. Для каждой поры определяется среднее значение интенсивности, дисперсия и коэффициент вариации (CV), а также оценивается взаимосвязь полученных показателей с реальными транспортными свойствами. В качестве обобщенного выражения используются следующие соотношения:

$$\mu = \frac{1}{N} \sum_{j=1}^N I_j; \quad CV = \frac{\sqrt{\frac{1}{N} \sum_{j=1}^N (I_j - \mu)^2}}{\mu}; \quad D_{eff} = D_0 \frac{\varepsilon}{1 + kCV},$$

где I_j – интенсивность пикселя, μ – средняя интенсивность, N – число пикселей в поре, D_0 – базовый коэффициент диффузии для непористого материала, ε – пористость, k – эмпирический коэффициент, отражающий вклад неоднородности структуры в «трудно-проходимость» поровых каналов. Такая модель позволяет проводить количественный учёт влияния морфологических особенностей материала на его диффузные свойства, обеспечивая более объективную интерпретацию экспериментальных данных и обоснованные выводы о влиянии пористой структуры на эффективность транспортных процессов.

4.3. Расчет проницаемости на основе геометрических параметров пор. Проницаемость материала – это его способность пропускать жидкости или газы через поры. Она определяется геометрическими параметрами пористых структур, включая их размер, форму и связанность. Так как границы пор уже известны, то сначала рассчитываются размеры пор и их средние значения. Также анализируется степень связанности пор для оценки их способности к транспортировке жидкостей. На основе эмпирических формул, учитывающих пористость ε , средний размер пор d_p и связанность ζ вычисляется коэффициент проницаемости K . Чаще всего применяют обобщённую зависимость:

$$K = k_0 \frac{\varepsilon^3 d_p^2 \zeta}{\tau(1 - \varepsilon)^2},$$

где k_0 – эмпирическая константа, а τ – показатель извилистости пор. Этот показатель широко используется для оценки поведения материалов в условиях реального применения, таких как фильтрация или транспорт жидкостей.

5. Верификация методом сравнения масок сегментации. В ходе исследования мы получили набор алгоритмов, который позволяет вычислять основные характеристики пористости. Однако несмотря на то, что на аналитическом уровне алгоритмы показывают достаточно достоверные результаты, необходимо провести комплексную верификацию для подтверждения качества выходных данных. Это важно для обеспечения достаточного уровня достоверности результатов работы алгоритмов. Необходимо, чтобы на тестовых данных результаты комплекса соотносились с экспертным заключением. Успешное прохождение подобных тестов гарантирует качество системы в целом и достаточный уровень готовности для конечного пользователя.

Методы верификации позволяют количественно сопоставить результаты анализа с эталонными данными, выявить возможные ошибки и предложить пути для улучшения. Верификация направлена как на проверку точности сегментации, так и на оценку корректности расчёта морфологических и функциональных характеристик.

Одним из наиболее распространённых методов верификации, который мы использовали в своем исследовании, является сравнение масок сегментации, сгенерированных алгоритмом, с эталонными масками, разметка которых выполнена вручную. Для этого используются метрики, такие как коэффициент подобия Dice и IoU (Intersection over Union), которые дают количественную оценку точности совпадения сегментированных областей.

Коэффициент Dice рассчитывается по формуле:

$$D(A, B) = \frac{2|A \cap B|}{|A| + |B|},$$

где A и B – рассматриваемые области на изображениях, $|A \cap B|$ – площадь пересечения, а $|A|$ и $|B|$ – площадь каждого множества в отдельности. Значение $D(A, B) \rightarrow 1$ при максимальном сходстве двух множеств, и равно 0 при полном отсутствии пересечений.

Метрика IoU используется для оценки точности сегментации, определяя степень перекрытия предсказанной и эталонной областей. Она вычисляется как отношение площади пересечения двух масок к площади их объединения. IoU широко применяется в компьютерном зрении, особенно в задачах семантической сегментации, поскольку позволяет количественно измерить точность модели независимо от масштаба изображений. В отличие от Dice, IoU более чувствителен к небольшим ошибкам на границах объектов, поскольку объединение учитывает как ложные срабатывания, так и пропущенные пиксели. Метрика IoU рассчитывается по следующей формуле:

$$IoU(A, B) = \frac{|A \cap B|}{|A \cup B|},$$

где A – предсказанная маска, B – эталонная разметка, $A \cap B$ – количество пикселей в области пересечения, а $A \cup B$ – количество пикселей в объединённой области. Значение IoU принимает диапазон от 0 до 1. В задачах компьютерного зрения обычно пороговое значение IoU для корректного детектирования объектов устанавливается в диапазоне 0.5–0.75, в зависимости от требований к точности модели.

Демонстрация процесса валидации представлена на рис. 5, а-г, где (а) показаны исходные данные SEM-изображения, (б) синим цветом обозначена эталонная разметка, (в) красным выделены области, предсказанные алгоритмом, а (г) фиолетовые области отражают их совпадение. Такой подход позволяет наглядно оценить точность сегментации, выявить расхождения между эталоном и алгоритмом, а также количественно определить качество работы модели.




Рис. 1, а-г. Процесс валидации

В результате мы получили достаточно высокие показатели верификации по данным метрикам, представленные в табл. 1.

Таблица 1

Сравнение масок сегментации метриками Dice и IoU

Тип масок	Dice, усредненный результат	IoU, усредненный результат
Синтетические данные	0.9403	0.9032
SEM-изображения с явно выраженной структурой пор	0.9114	0.8564
SEM-изображения со слабо выраженной структурой пор	0.8412	0.7621

6. Оценка точности расчета характеристик. После сегментации пористых структур выполняется расчёт их морфологических и функциональных характеристик, таких как пористость, проницаемость, извилистость и диффузность. Для оценки точности этих параметров результаты сравниваются с эталонными значениями, полученными из экспериментальных данных или ручного анализа.

Анализ ошибок включает детальное изучение причин расхождений между предсказанными и истинными значениями. Для нашего комплекса мы взяли несколько конкретных SEM-изображений. Далее мы произвели автоматический расчет характеристик, а затем на этом же примере провели аналитические расчеты с привлечением эксперта. Результаты по представленному изображению приведены в табл. 2.

Таблица 2

Рассчитанные характеристики материала в автоматическом и ручном режимах

Характеристика	Автоматически	Экспертным способом
Пористость, %	21.9	21.12
Извилистость	1,6	1,5
Проницаемость, м ² /с	$1,3 \times 10^{-14}$	$1,1 \times 10^{-14}$
Диффузность, м ² /с	$7,5 \times 10^{-7}$	$7,0 \times 10^{-7}$

Сравнив выходные данные, а также опираясь на исследования [19, 20], мы сделали вывод о высоком уровне сходства характеристик, вычисленных автоматически и ручным (экспертным) способом и, соответственно, об успешном прохождении проверки.

Заключение. Новизна проведенного исследования заключается в разработанном подходе, позволяющем автоматизировать и интеллектуализировать процесс анализа бионеорганических матриц. Для этого используется алгоритмический комплекс и вспомогательная модель компьютерного зрения.

В ходе работ был получен ряд результатов. Во-первых, был применен ранее представленный подход к обучению модели с помощью синтетических данных, и, соответственно, разработан генератор и сформирован обучающий набор данных. Далее качественно обучена модель компьютерного зрения на основе алгоритма одноэтапного детектора YOLOv7. Во-вторых, был разработан ряд алгоритмов для вычисления ключевых характеристик бионеорганической матрицы в автоматическом режиме по данным алгоритмов детекции.

Далее весь алгоритмический комплекс прошел ряд тестов на верификацию для подтверждения качества выходных данных и обеспечения достаточной точности вычислений. Верификация прошла успешно. Наконец, весь комплекс был поделен на 2 системных модуля:

1. Система детекции пор и преобразования данных SEM-изображения.
2. Алгоритмическая модель для вычисления основных и дополнительных характеристик бионеорганических матриц.

В данном исследовании есть ряд ограничений. Так, комплекс ограничен только данными SEM-изображений, некоторые характеристики сейчас не могут быть вычислены автоматически, и все еще должны рассчитываться вручную. Также пока нет алгоритмов проверки зависимостей. Все характеристики в какой-то степени зависимы друг от друга, и если эта зависимость явно нарушается, то необходимо проводить дополнительные изыскания на предмет поиска проблем. На текущий момент ответственность за подобные случаи лежит на эксперте, выполняющим анализ. Также отсутствуют алгоритмы верификации и проверки решения в реальном времени. Все значения характеристик вычисляются без опоры на некоторую базу эталонов или знаний. То есть система не может сказать, насколько вычисленные характеристики актуальны для текущего образа каркаса в конкретном случае.

Основное направление дальнейших исследований – это развитие данного комплекса алгоритмов в полноценную систему принятия решений по всему циклу экспериментов с бионеорганическими матрицами. На следующем этапе мы планируем внедрить комплекс проверки вычисленных характеристик, а затем систему предиктивных вычислений на основе нейро-нечеткой модели, чтобы можно было предсказать входные параметры для изготовления по требуемым выходным.

Работа поддержана Российским научным фондом в рамках гранта № 23-21-00331, <https://rscf.ru/project/23-21-00331/> (дата обращения 20.11.2024) и выполнена в Южном федеральном университете (Ростов-на-Дону, Российская Федерация).

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Sultana N. Mechanical and biological properties of scaffold materials, *Functional 3D Tissue Engineering Scaffolds*, 2018, pp. 1-21.
2. Mosalaganti S., Kosinska A., Siggel M., Taniguchi R., Zimmerli C., Hagen W., Beck M. AI-based structure prediction empowers integrative structural analysis of human nuclear pores, *Science*, 2022, Vol. 376, No. 6598.
3. Laldinhari S., Akriti T., Jugal B., Punuri J.B. Various manufacturing methods and ideal properties of scaffolds for tissue engineering applications, *Smart Materials in Manufacturing*, 2023, Vol. 1, pp. 100011.
4. Chen M., Jiang R., Deng N., Zhao X., Li X. Natural polymer-based scaffolds for soft tissue repair, *Front. Bioeng. Biotechnol.*, 2022.
5. Nahannoghadam A., Asemani M., Goodarzi V., Barough S. In vivo investigation of PCL/PHBV/Hydroxyapatite Nanocomposite Scaffold in Regeneration of Critical-sized Bone Defects, *Fibers Polym.*, 2021, Vol. 22, No. 9, pp. 2507-2516.
6. Rezaee S., Shahrokhian S. Facile synthesis of petal-like NiCo/NiO-CoO/nanoporous carbon composite based on mixed-metallic MOFs and their application for electrocatalytic oxidation of methanol, *Applied Catalysis B: Environmental*, 2019, Vol. 244, pp. 802-813.
7. Lanaro M., McLaughlin M., Simpson M., Buenzli P., Wong C., Allenby M., Woodruff M. A quantitative analysis of cell bridging kinetics on a scaffold using computer vision algorithms, *Acta Biomaterialia*, 2021, Vol. 136, pp. 429-440.
8. Wan H., Huang X., Junpeng W., Zhang Z. Importance of appropriate segmentation in pore structure analysis of coral reef limestone from CT images, *Marine Georesources & Geotechnology*, 2023, Vol. 42, No. 4, pp. 327-347.
9. Shi X., Misch D., Vranjes-Wessely S. A comprehensive assessment of image processing variability in pore structural investigations: Conventional thresholding vs. machine learning approaches, *Gas Science and Engineering*, 2023, Vol. 115, pp. 205022.
10. Kolomenskaya E., Butova V., Poltavskiy A., Soldatov A., Butakova M. Application of Artificial Intelligence at All Stages of Bone Tissue Engineering, *Biomedicines*, 2023, Vol. 12, No. 1, pp. 76.
11. Wright A. S., Youmans N. P., Araya E. F. V. Recursive Detection and Analysis of Nanoparticles in Scanning Electron Microscopy Images, 2023.
12. De Ridder V., Dey B., Dehaerne E., Halder S., Gendt S., Waeyenberge B. SEMI-CenterNet: A Machine Learning Facilitated Approach for Semiconductor Defect Inspection, 2023.
13. Kim Y.-H., Vijayavenkataraman S., Cidonio G. Biomaterials and scaffolds for tissue engineering and regenerative medicine, *BMC Methods*, 2024, Vol. 1, No. 1.
14. Aversa R., Modarres M., Cozzini S., Ciancio R., Chiusole A. The first annotated set of scanning electron microscopy images for nanoscience, *Sci Data*, 2018, Vol. 5, No. 1.
15. Polyanichenko D.S., Chernov A.V., Kartashov O.O., Alexandrov A.A., Butova V.V., Butakova M.A. Intelligent Detection of the Nanomaterials Spatial Structure with Synthetic Electron Microscopy Images, *2022 XXV International Conference on Soft Computing and Measurements (SCM)*, 2022.
16. Kartashov O.O., Chapek S.V., Polyanichenko D.S., Belyavsky G.I., Alexandrov A.A., Butakova M.A., Soldatov A.V. Online Microfluidic Droplets Characterization Using Microscope Data Intelligent Analysis, *BDCC*, 2023, Vol. 7, No. 1, pp. 7.
17. Alexandrov A.A., Kartashov O.O., Polyanichenko S.S., Nebaba A.N., Polyanichenko D.S., Butakova M.A. Intelligent Analysis of Optical Microscopy Images for Microfluidic Synthesis Results, *2023 XXVI International Conference on Soft Computing and Measurements (SCM)*, 2023, pp. 297-300.
18. Poltavskiy A., Kolomenskaya E., Belyavsky G., Butova V., Butakova M. Synthesis and Analysis of Porous Frame Structures Images Using Machine Learning Methods, *Lecture Notes in Networks and Systems*, 2024, pp. 389-401.
19. Yuan L., Liu Z., Tian C., Yan Z., Yu J., Hou X., Zhu Q. Structure and properties of Al₂O₃-bonded porous fibrous YSZ ceramics fabricated by aqueous gel-casting, *Ceramics International*, 2021, Vol. 47, No. 18, pp. 250-265.
20. Rosentreter H., Walther M., Lerch A. Partial Desalination of Saline Groundwater: Comparison of Nanofiltration, Reverse Osmosis and Membrane Capacitive Deionisation, *Membranes*, 2021, Vol. 11, No. 2, pp. 126.

Полтавский Артем Владимирович – Южный федеральный университет; e-mail: poltavsky@sfedu.ru; г. Ростов-на-Дону, Россия; Международный исследовательский институт интеллектуальных материалов ЮФУ; аспирант.

Поляниченко Дмитрий Сергеевич – Научно-исследовательский и проектно-конструкторский институт информатизации, автоматизации и связи на железнодорожном транспорте АО «НИИАС», Ростовский филиал; e-mail: d.polyanichenko@vniias.ru; г. Ростов-на-Дону, Россия; главный специалист.

Коломенская Екатерина Романовна – Южный федеральный университет; e-mail: kolomenskaya@sfedu.ru; г. Ростов-на-Дону, Россия; Международный исследовательский институт интеллектуальных материалов ЮФУ; инженер.

Бутакова Мария Александровна – Научно-исследовательский и проектно-конструкторский институт информатизации, автоматизации и связи на железнодорожном транспорте АО «НИИАС», Ростовский филиал; e-mail: m.butakova@vniias.ru; г. Ростов-на-Дону, Россия; д.т.н.; профессор; г.н.с.

Poltavskiy Artem Vladimirovich – Southern Federal University; e-mail: poltavsky@sfedu.ru; Rostov-on-Don, Russia; the International Research Institute of Intelligent Materials of the Southern Federal University; post-graduate student.

Kolomenskaya Ekaterina Romanovna – Southern Federal University; e-mail: kolomenskaya@sfedu.ru; Rostov-on-Don, Russia; The International Research Institute of Intelligent Materials of the Southern Federal University; engineer.

Polyanichenko Dmitry Sergeevich – JSC NIIS; e-mail: d.polyanichenko @vniias.ru; Rostov-on-Don, Russia; team lead.

Butakova Maria Aleksandrovna – JSC NIIS; e-mail: m.butakova@vniias.ru; Rostov-on-Don, Russia; dr. of eng. sc.; professor; chief researcher.

УДК 004.942, 654.924.56

DOI 10.18522/2311-3103-2025-1-65-81

С. Сингх, А.В. Прибыльский, Е.Ю. Косенко

РАЗРАБОТКА И ИССЛЕДОВАНИЕ АЛГОРИТМОВ ПРОГНОЗИРОВАНИЯ ПОЖАРООПАСНЫХ СИТУАЦИЙ

Раннее обнаружение пожароопасных ситуаций является критически важным аспектом обеспечения безопасности, так как позволяет минимизировать риск материальных и человеческих потерь. Заблаговременное выявление угроз способствует сохранению материальных ценностей, уменьшению времени на их восстановление и, что важнее, спасению человеческих жизней. В связи с этим, предлагается новый подход к прогнозированию пожароопасных ситуаций: алгоритм обучения модели прогнозирования пожароопасных ситуаций, а также алгоритм прогнозирования пожароопасных ситуаций, которые разрабатываются на моделях машинного обучения таких как рекуррентные нейронные сети, случайный лес, оптимизационные деревья, авторегрессионные нейронные сети и т.д. В исследовании предлагается рассмотреть алгоритмы прогнозирования пожароопасных ситуаций, разработанных на основе анализа существующих алгоритмов прогнозирования, включая методы на основе машинного обучения, статистические модели и симуляционные подходы, учитывая их преимущества и недостатки, показатели точности. Результаты исследования разработанных алгоритмов показывают, что они способны с точностью 93.33% предсказывать значение температуры снаружи датчика на основе тестовых данных с комплекса взаимосвязанных пожарных датчиков, с ошибками MAE = 1.72, MSE = 2.95 в нештатном режиме на тестовых данных, и с точностью 92.85% температура внутри датчика, ошибки MAE = 1.66, MSE = 2.75. Точность на тестовых данных в штатном режиме для температуры снаружи составили 96.27%, ошибки MAE = 1.22, MSE = 1.48, а точность прогнозирования температуры внутри составила 96.16%, ошибки MAE = 1.24, MSE = 1.53. Для тестовой выборки в 500 000 отсчетов, ошибки спрогнозированной температуры снаружи составили: MAE = 1.82, а MSE = 3.31, а точность составили 91.78%. Ошибки спрогнозированной температуры внутри (temp2_inside) составили: MAE = 1.89, а MSE = 3.57, а точность составили 91.35%.

Пожарный датчик; Python; алгоритм прогнозирования; алгоритм обучения; прогнозирования; анализ алгоритмов прогнозирования.