



Известия Саратовского университета. Новая серия. Серия: Математика. Механика. Информатика. 2025. Т. 25, вып. 1. С. 116–127

Izvestiya of Saratov University. Mathematics. Mechanics. Informatics, 2025, vol. 25, iss. 1, pp. 116–127 https://mmi.sgu.ru https://doi.org/10.18500/1816-9791-2025-25-1-116-127, EDN: UVLBDK

Научная статья УДК 004.932

# Разработка и анализ алгоритма обнаружения множественных экземпляров объекта на микроскопических изображениях с использованием численных методов

С. Ю. Ганигин, А. Н. Давыдов, А. С. Нечаев, В. В. Киященко

Самарский государственный технический университет, Россия, 443100, г. Самара, ул. Молодогвардейская, д. 244

**Ганигин Сергей Юрьевич**, доктор технических наук, заведующий кафедрой «Радиотехнические устройства», ganigin.s.yu@yandex.ru, https://orcid.org/0000-0001-5778-6516, SPIN: 5725-6961, AuthorID: 159277

**Давыдов Андрей Николаевич**, кандидат технических наук, доцент кафедры «Mexaника», davydov.an@samgtu.ru, https://orcid.org/0000-0002-7061-5460, SPIN: 7434-7987, AuthorID: 13419

**Нечаев Александр Сергеевич**, кандидат технических наук, доцент кафедры «Радиотехнические устройства», nechaev-as@mail.ru, https://orcid.org/0000-0002-0939-8292, SPIN: 4564-7570, AuthorID: 740145

**Киященко Виктория Витальевна**, младший научный сотрудник лаборатории «Цифровые двойники материалов и технологических процессов их обработки», vv.kiyashchenko@gmail.com, https://orcid.org/0000-0001-9710-2860, SPIN: 6752-8232, AuthorID: 1184376

**Аннотация.** В данной работе представлен метод обнаружения объектов на изображениях микроскопии, сфокусированный на поиске частиц. Основная цель исследования заключается в разработке алгоритма, способного эффективно находить множественные экземпляры объектов в различных сценариях, сохраняя при этом специфичность для структур интереса. Алгоритм базируется на использовании экстремальных областей в качестве кандидатов для обнаружения с последующей оценкой этих областей при помощи обученных параметров. Одним из ключевых элементов алгоритма является встроенное ограничение на неперекрытие, что позволяет ему эффективно обрабатывать кластеризацию частиц. Результаты экспериментов на различных наборах микроскопических данных подтверждают устойчивость метода к изменениям в интенсивности изображений, плотности и размеров частиц. Данный алгоритм является полезным инструментом для разработки методов обнаружения объектов на изображениях микроскопии и может быть применен в научных и медицинских исследованиях.

**Ключевые слова:** обнаружение объектов, изображения микроскопии, частицы, экстремальные области, ограничение на неперекрытие

**Благодарности:** Исследование выполнено при финансовой поддержке Министерства науки и высшего образования Российской Федерации в рамках государственного задания (проект № AAAA-A12-2110800012-0).

**Для цитирования:** *Ганигин С. Ю., Давыдов А. Н., Нечаев А. С., Киященко В. В.* Разработка и анализ алгоритма обнаружения множественных экземпляров объекта на микроскопических изображениях с использованием численных методов // Известия Саратовского университета. Новая серия. Серия: Математика. Механика. Информатика. 2025. Т. 25, вып. 1. С. 116–127. https://doi.org/10.18500/1816-9791-2025-25-1-116-127, EDN: UVLBDK

Статья опубликована на условиях лицензии Creative Commons Attribution 4.0 International (СС-ВУ 4.0)



Article

# Development and analysis of an algorithm for detecting multiple instances of an object in microscopic images using numerical methods

S. Yu. Ganigin, A. N. Davydov, A. S. Nechaev, V. V. Kiyashchenko<sup>™</sup>

Samara State Technical University, 244 Molodogvardeyskaya St., Samara 443100, Russia

**Sergey Yu. Ganigin**, ganigin.s.yu@yandex.ru, https://orcid.org/0000-0001-5778-6516, SPIN: 5725-6961, AuthorID: 159277

**Andrey N. Davydov**, davydov.an@samgtu.ru, https://orcid.org/0000-0002-7061-5460, SPIN: 7434-7987, AuthorID: 13419

**Alexander S. Nechaev**, nechaev-as@mail.ru, https://orcid.org/0000-0002-0939-8292, SPIN: 4564-7570, AuthorID: 740145

Victoria V. Kiyashchenko, vv.kiyashchenko@gmail.com, https://orcid.org/0000-0001-9710-2860, SPIN: 6752-8232, AuthorID: 1184376

**Abstract.** This paper presents a method for object detection in microscopy images, focusing on particle detection. The main objective of the research is to develop an algorithm capable of efficiently detecting multiple instances of objects in various scenarios, while maintaining specificity for structures of interest. The algorithm is based on using extremal regions as candidates for detection, followed by evaluating these regions with trained parameters. A key element of the algorithm is its built-in non-overlapping constraint, which enables effective handling of particle clustering. Experimental results on various microscopy datasets confirm the method's robustness to changes in image intensity, particle density, and size. The proposed algorithm serves as a valuable tool in the development of object detection methods for microscopy images and can be applied in both scientific and medical research.

**Keywords:** object detection, microscopy images, particles, extreme regions, restriction on non-concealment **Acknowledgements:** The research was carried out with the financial support of the Ministry of Science and Higher Education of the Russian Federation within the framework of the state task (project No. AAAAA12-2110800012-0).

**For citation:** Ganigin S. Yu., Davydov A. N., Nechaev A. S., Kiyashchenko V. V. Development and analysis of an algorithm for detecting multiple instances of an object in microscopic images using numerical methods. *Izvestiya of Saratov University. Mathematics. Mechanics. Informatics*, 2025, vol. 25, iss. 1, pp. 116–127 (in Russian). https://doi.org/10.18500/1816-9791-2025-25-1-116-127, EDN: UVLBDK This is an open access article distributed under the terms of Creative Commons Attribution 4.0 International License (CC-BY 4.0)

#### Введение

Микроскопические изображения являются важным инструментом во многих научных и медицинских исследованиях, позволяя исследователям изучать структуры и процессы на клеточном уровне. Однако анализ таких изображений представляет собой сложную задачу из-за их высокой разрешающей способности и сложной структуры. Проблемы анализа изображений, полученных с помощью микроскопа, описаны в работах [1–4].

Проблема обнаружения множественных экземпляров объектов на микроскопических изображениях является актуальной задачей в области компьютерного зрения и машинного обучения [5–7]. Она возникает в контексте разработки методов различных научных и медицинских исследований, таких как анализ клеток, тканей, биологических структур и других объектов микро- и наномасштаба.

Эффективное решение этой задачи принесет значительную пользу науке и медицине. Например, автоматизированные методы обнаружения и анализа микроскопических объектов



могут повысить скорость и точность исследований, а также помочь выявлять дефекты материалов или аномалии в биологических образцах с меньшим вмешательством человека.

В данной статье представлен алгоритм, основанный на машинном обучении, разработанный для обнаружения множественных экземпляров объекта на микроскопических изображениях. Этот метод достаточно универсален и может успешно работать в нескольких сценариях, таких как различные варианты микроскопии (например, СЭМ-микроскопия) или типы объектов на микроскопических изображениях (например, линии клеток или нерасплавленные частицы металла).

Недавние работы [8–10] показывают, что применение сверточных нейронных сетей может значительно улучшить результаты анализа изображений микроскопии. В данной работе процедура обучения разработана для того, чтобы научить модель распознавать объекты на изображениях с точечной аннотацией, где каждый объект интереса на обучающих изображениях аннотирован точкой (например, внутри каждой частицы). Используя только эту минимальную аннотацию, метод способен обучить модель таким образом, что объекты интереса могут быть обнаружены на других изображениях при условии сохранения аналогичной экспериментальной установки. Метод успешно протестирован на нескольких наборах данных микроскопии с точечными аннотациями и продемонстрировал превосходную точность обнаружения в нескольких сценариях, несмотря на различия между наборами данных.

# 1. Наборы данных

Микроскопические изображения играют критическую роль в научных исследованиях и медицинской диагностике. В данной работе используется четыре набора данных, охватывающих различные методы и условия визуализации.

Синтетическая микроскопия. Синтетический набор данных представляет собой эталон для сравнения методов обнаружения и подсчета объектов. Он состоит из 50 изображений частиц на флуоресцентной микроскопии, созданных с использованием генеративных моделей [11]. Этот набор данных содержит существенное перекрытие между объектами, что делает его сложным для методов обнаружения. Набор данных разделен на 30 изображений для обучения и 20 для тестирования, с несколькими случайными разбиениями для обучающего набора.

СЭМ-микроскопия поверхности покрытий из двухкомпонентных материалов. Этот набор данных представляет изображения, полученные с помощью сканирующего электронного микроскопа (СЭМ), сфокусированного на поверхности покрытий, состоящих из двухкомпонентных материалов, таких как никель и алюминий. Этот тип микроскопии широко используется в материаловедении и инженерии для изучения микроструктуры и характеристик поверхностей материалов. Набор данных содержит изображения с различными увеличениями и разрешениями, захватывающие различные аспекты структуры покрытий, такие как морфология поверхности, составные части и дефекты. Этот набор данных представляет интерес для оценки производительности алгоритмов обнаружения и сегментации объектов на микроскопических изображениях материалов.

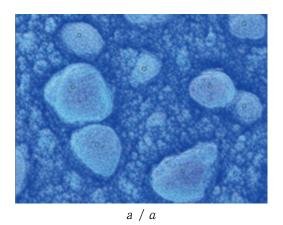
Набор данных дифференциальной интерференционной контрастной микроскопии (DIC). Этот набор данных содержит изображения, полученные с помощью дифференциальной интерференционной контрастной микроскопии (DIC). DIC-микроскопия — это метод, который обеспечивает высокий контраст изображений путем измерения изменений в интерференции света, прошедшего через образец. Это позволяет визуализировать даже тончайшие детали структуры образца, делая DIC-микроскопию полезной для изучения мельчайших структурных особенностей. Набор данных содержит изображения образцов, таких как биологические препараты и материалы с разными уровнями контраста и разрешениями.

**Слабая флуоресцентная молекулярная микроскопия.** Набор данных молекулярной микроскопии состоит из изображений, полученных в результате генерации набора данных о микробных колониях [12]. Он содержит 78 изображений с шумом и низким контрастом,



характерными для слабой флуоресценции, что создает дополнительные трудности для методов обнаружения. Набор данных также разделен на обучающий и тестовый наборы.

На рис. 1 представлены примеры образцов из разных наборов данных после проведения аннотирования. Показаны образцы из набора данных изображений слабой флуоресцентной микроскопии и СЭМ-микроскопии поверхности покрытий двухкомпонентных материалов.



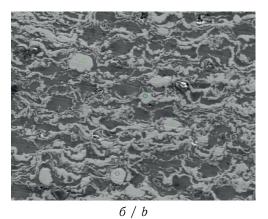


Рис. 1. Примеры аннотированных образцов из разных наборов данных: *а* — образец из набора слабой флуоресцентной молекулярной микроскопии; *б* — образец из набора СЭМ-микроскопии поверхности покрытий двухкомпонентных материалов (цвет онлайн)

Fig. 1. Examples of annotated samples from different datasets: *a* is the sample from a set of weak fluorescence molecular microscopy; *b* is the sample from a set of SEM microscopy of the surface of coatings of two-component materials (color online)

# 2. Постановка задачи и методология исследования

Метод обнаружения объектов на микроскопических изображениях начинается с создания набора перекрывающихся областей-кандидатов, которые затем подвергаются дальнейшему анализу для выбора подмножества наиболее подходящих областей на основе изученной оценки классификации и с учетом ограничения на перекрытие.

Для создания набора областей-кандидатов применяется алгоритм максимально стабильных экстремальных областей (MSER) к серому изображению. Этот алгоритм определяет экстремальные области как связные компоненты порогового изображения, где интенсивность всех пикселей внутри области ниже порогового значения. Пусть  $\mathcal{R} = \{R_1, R_2, \dots, R_N\}$  представляют собой потенциальный набор из N экстремальных областей, обнаруженных на изображении.

Выбор подходящих областей для дальнейшего анализа является нетривиальной задачей из-за необходимости учета ограничений на перекрытие и определения подходящих оценок классификации для каждой области. Задача выбора подходящих областей сводится к задаче максимизации суммарной оценки для выбранных областей с учетом ограничений на перекрытие.

#### 3. Вывод при наличии ограничения на перекрытие

Предположим, что каждой области  $R_i$  присваивается значение  $V_i$ , которое генерируется классификатором и указывает оценку соответствия этой области классу клеток, которые нужно обнаружить. Затем метод выбирает подмножество экстремальных областей таким образом, чтобы сумма оценок выбранных областей была максимальной, при условии, что выбранные области не перекрываются (ограничение на перекрытие).

Для формализации этой задачи оптимизации определяется набор бинарных индикаторных переменных  $\mathbf{y} = \{y_1, y_2, \dots, y_N\}$ , где  $y_i = 1$  означает, что область  $R_i$  выбрана. Тогда задача



оптимизации состоит в максимизации следующего функционала:

$$F(\mathbf{y}) = \max_{\mathbf{y} \in \mathcal{Y}} \sum_{i=1}^{N} y_i V_i, \tag{1}$$

где  $\mathcal{Y}-$  это множество подмножеств областей, не имеющих перекрытия. Это означает, что выбранные области  $R_i$  не пересекаются между собой.

Максимизация функционала (1) является NP-трудной задачей, что означает, что алгоритмы, способные решить эту задачу точно и за разумное время, известны не для всех возможных случаев. NP-трудные задачи включают в себя широкий класс оптимизационных проблем, где вычислительная сложность возрастает экспоненциально с увеличением размера входных данных.

В данном контексте NP-трудность функционала (1) связана с тем, что для каждого подмножества областей нужно проверить все возможные комбинации, чтобы найти наилучшее решение. При увеличении числа областей это становится вычислительно затратной задачей, которая может потребовать значительного времени для выполнения. Однако ее можно выполнить точно и эффективно, используя свойство вложенности пула областей.

Предлагается модель с древовидной структурой, где каждый узел соответствует области, а связи родитель – потомок соответствуют отношению вложенности. Таким образом, пул областей может быть организован в виде набора деревьев (так называемый лес). Затем задача оптимизации (1) переписывается в виде задачи MRF с попарной древовидной структурой для вспомогательных переменных **z**:

$$F(\mathbf{z}) = \max_{\mathbf{z}} \left( \sum_{i|p(i)\neq 0} W_i(z_i, z_{p(i)}) + \sum_{i|p(i)=0} V_i(z_i) \right), \tag{2}$$

где p(i) отображает область  $R_i$  на ее родительскую область (0 для корневых областей в лесу),  $W_i(1,1)=0, W_i(1,0)=V_i$  и  $W_i(0,1)=-\infty$ .

MRF— это статистическая модель, которая используется для моделирования случайных полей, где величины, связанные с узлами графа, представляют случайные переменные [13]. В случае задачи обнаружения объектов на изображениях каждой области изображения соответствует узел в графе, и случайные переменные связаны с решением о выборе или отбрасывании каждой области.

Попарная древовидная структура означает, что узлы графа соединены только соседними узлами по дереву. В данном случае деревья представляют собой древовидную структуру, где каждая область связана с родительской областью (если она есть) и ее дочерними областями.

Переписывание задачи оптимизации (1) в виде задачи MRF с попарной древовидной структурой включает в себя переформулировку функционала таким образом, чтобы он мог быть представлен в виде суммы по всем узлам графа, учитывая взаимодействие между соседними узлами (областями) в соответствии с их древовидной структурой.

Задача оптимизации (2) формулируется как задача выбора наиболее подходящих областей-кандидатов для обнаружения объектов на микроскопических изображениях. Для решения этой задачи предлагается использовать древовидное динамическое программирование. Этот метод позволяет эффективно и точно найти оптимальное решение, учитывая ограничения на перекрытие областей.

Древовидное динамическое программирование основано на принципе разбиения задачи на более мелкие подзадачи и последующем объединении их оптимальных решений для получения оптимального решения исходной задачи.

# 4. Процесс обучения модели

Метод обучения модели для обнаружения объектов на микроскопических изображениях базируется на машинном обучении, где каждая область изображения оценивается линейным



классификатором. Для получения этих оценок используются данные обучения с точечными аннотациями.

#### Обучение с использованием бинарной классификации

Простым подходом является обучение бинарного классификатора, например, с использованием алгоритма машины опорных векторов (SVM).

Для начала определим набор данных для обучения. Пусть  $\mathbf{X}$  — матрица признаков, где каждая строка представляет собой признаковое описание одной области изображения, а  $\mathbf{g}$  — вектор меток, где каждый элемент соответствует метке класса (1 — положительный класс, 0 — отрицательный класс).

В случае обучения SVM каждая область на обучающих изображениях рассматривается отдельно. Пусть  $n_{ji}$  обозначает количество пользовательских точек в области j изображения i. Области, у которых  $n_{ji}=1$ , относятся к положительному классу, в то время как все остальные области относятся к отрицательному классу.

Обучение SVM заключается в поиске оптимальной гиперплоскости, разделяющей два класса, при этом максимизируется зазор между ними. Модель SVM затем определяет желаемый весовой вектор  $\mathbf{w}$ , который задает эту разделяющую гиперплоскость.

#### Структурированное обучение

Более обоснованным подходом является использование структурированной SVM, которая учитывает ограничение на непересекаемость областей. Этот подход позволяет учитывать взаимное расположение областей при обучении модели.

Структурированный метод SVM находит оптимальный весовой вектор  $\mathbf{w}$  минимизацией функции потерь  $L(\mathbf{w})$ , которая включает в себя регуляризацию и максимизацию разделения между классами, а также минимизацию потерь, связанных с непересекающимися областями. Регуляризация используется для предотвращения переобучения модели и улучшения ее обобщающей способности, она заключается в добавлении штрафа за большие значения параметров модели.

Математически этот подход может быть представлен как задача оптимизации. Пусть  $\mathbf{w}$  — вектор параметров модели, а  $\mathbf{X}$  и  $\mathbf{Q}$  — матрицы признаков и меток соответственно. Тогда задача минимизации функции потерь  $L(\mathbf{w})$  записывается следующим образом:

$$\min_{\mathbf{w}} L(\mathbf{w}) = \frac{1}{m} \sum_{i=1}^{m} \max(0, 1 - q_i \mathbf{w}^T \mathbf{x}_i) + \lambda ||\mathbf{w}||_2^2,$$

где m — количество обучающих примеров,  $\lambda$  — параметр регуляризации, а  $\|\mathbf{w}\|_2$  — норма вектора параметров модели  $\mathbf{w}$ .

Слагаемое  $\lambda \|\mathbf{w}\|_2^2$  штрафует модель за большие значения весовых коэффициентов, что способствует более устойчивой обученной модели.

При этом ограничения на непересекаемость областей могут быть инкорпорированы непосредственно в функцию потерь, что позволяет учитывать взаимное расположение областей при обучении модели. Предположим, что для каждой области  $R_i$  у нас есть бинарная переменная  $y_i$ , которая равна 1, если область  $R_i$  выбрана, и 0 в противном случае. Тогда модифицированная функция потерь может быть записана следующим образом:

$$L_{\text{mod}}(w,q) = L(w) + \alpha \sum_{i=1}^{N} (1 - q_i) L_{\text{mod}}(w,q),$$

где  $\alpha$  — это коэффициент, который регулирует влияние штрафа на нарушение ограничения на пересечение областей, а N — общее количество областей.

Таким образом, метод обучения модели для обнаружения объектов на микроскопических изображениях учитывает как классификационную способность, так и ограничения на перекрытие областей, что позволяет получить более точные результаты.



# 5. Обсуждение результатов работы и область их применения

В экспериментах использовался вектор признаков  $\mathbf{f}_{ji}$ , состоящий из различных дескрипторов, включающих размер, форму, цвет (или интенсивность) и информацию о локальном контексте областей.

Этот вектор признаков  $\mathbf{f}_{ji}$  позволяет представить каждую область изображения численно, учитывая ее характеристики, такие как размер, форма и цвет, а также информацию о ее окружении.

На рис. 2 представлены примеры результатов обнаружения объектов для варианта DIC-микроскопии с различными уровнями зашумленности.

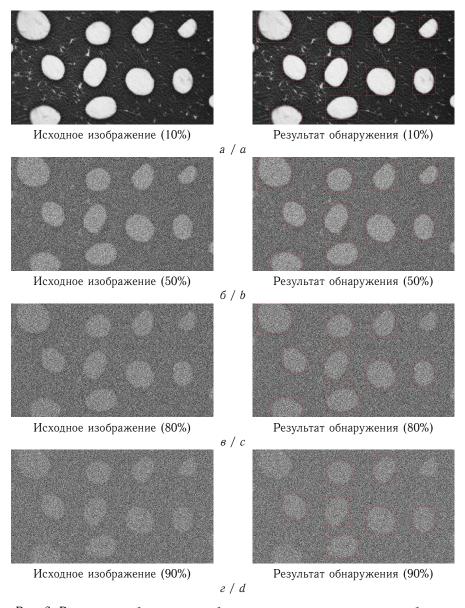


Рис. 2. Результаты обнаружения объектов на микроскопических изображениях с различным уровнем зашумленности: a-10%; b-50%; b-80%; b-80%;

Fig. 2. The results of detecting objects in microscopic images with different noise levels: a-10%; b-50%; c-80%; d-90%. On the left are the original images, on the right are the results of processing



Каждое изображение в левой части иллюстрирует исходное состояние, а справа — результаты после применения алгоритма. Метод демонстрирует свою эффективность даже при наличии значительного шума, однако при уровне зашумленности 90% наблюдается потеря некоторых экземпляров (рис. 2,  $\varepsilon$ ).

На рис. 3 показаны результаты обработки изображений СЭМ покрытий двухкомпонентных материалов с различной интенсивностью.

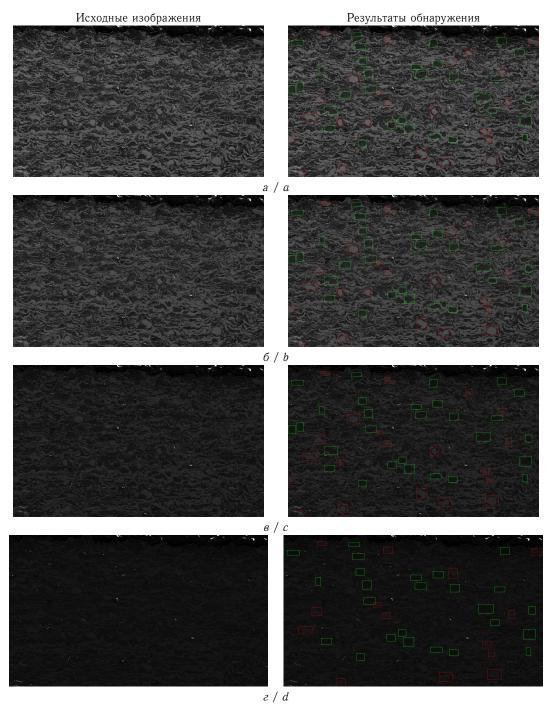


Рис. 3. Результаты обнаружения объектов на изображениях двухкомпонентных покрытий с различным уровнем интенсивности: a-90%; b-80%; b-40%; b-40%; b-40%. Слева представлены исходные изображения, справа — результаты обработки (цвет онлайн)

Fig. 3. The results of detecting objects in microscopic images with different noise levels: a-90%; b-80%; c-40%; d-10%. On the left are the original images, on the right are the results of processing (color online)



Здесь отображены объекты двух групп: частицы никеля, которые обведены зеленым цветом, и частицы алюминия, обведенные красным цветом. В данном примере разработанный алгоритм применялся для поиска и подсчета нерасплавленных частиц компонентов. Эти результаты подтверждают, что разработанный алгоритм успешно классифицирует объекты с различной плотностью и размерами. Также алгоритм может быть адаптирован для работы с различными материалами путем изменения параметров обнаруживаемых объектов (ширина, высота, цвет и т. д.). С интенсивностью изображения менее 40% наблюдается потеря некоторых экземпляров из поля видимости алгоритма. Метод успешно обнаруживает отдельные объекты в простых случаях, кластеры обычно отбрасываются, так как кандидатские области в них не соответствуют отдельным объектам.

Алгоритм чувствителен к форме объектов: для частиц, чья форма сильно отличается от круговой, его точность может снижаться. Тем не менее, алгоритм изначально разрабатывался для поиска объектов, схожих с круговыми формами. Для поиска объектов с более сложной или специфичной геометрией может потребоваться дополнительное обучение алгоритма, используя наборы данных с соответствующими объектами. Неправильные кандидатские области увеличивают сложность обучения.

В табл. 1 и 2 представлено сравнение результатов разработанного алгоритма с методами, основанными на пороговом значении и SIFT (Scale-Invariant Feature Transform), на наборах данных синтетической микроскопии и DIC-микроскопии соответственно.

Таблица 1 / Table 1

Сравнение результатов разработанного алгоритма с другими методами на наборе данных синтетической микроскопии

Comparison of the results of the developed algorithm with other methods based on a set of synthetic microscopy data

Метод	Точность	Полнота	F-мера
Метод на основе порогового значения	0.82	0.90	0.86
Разработанный метод	0.89	0.92	0.87
Метод SIFT	0.86	0.85	0.86

Таблица 2 / Table 2

Сравнение результатов разработанного алгоритма с другими методами на наборе данных DIC-микроскопии

Comparison of the results of the developed algorithm with other methods based on the DIC microscopy dataset

Метод	Точность	Полнота	F-мера
Метод на основе порогового значения	0.83	0.89	0.84
Разработанный метод	0.90	0.92	0.88
Метод SIFT	0.88	0.90	0.85

Данные алгоритмы, как и разработанный алгоритм, были реализованы на языке программирования Java. Для реализации алгоритмов были использованы такие библиотеки Java, как OpenCV, JavaCV и JAI. В частности, для метода SIFT был использован модуль OpenCV, который позволяет идентифицировать и сопоставлять ключевые точки на изображениях, устойчивые к масштабированию и вращению. OpenCV также использовалась для выполнения базовых операций по обработке изображений, таких как фильтрация, пороговая обработка и морфологическая трансформация. JavaCV использовалась для взаимодействия с алгоритмами компьютерного зрения и для реализации методов пороговой обработки. Сравнение было проведено по классическим мерам, используемым в машинном обучении [14].

В тестовой выборке данных использовались наборы данных синтетической микроскопии и DIC-микроскопии, что в сумме составило 90 изображений. Для тестовой выборки были определены статистические меры, такие как точность, полнота и F-мера. Точность измеря-



ет долю правильно обнаруженных объектов среди всех объектов, которые были отмечены алгоритмом как обнаруженые. Полнота измеряет долю объектов, которые были правильно обнаружены, среди всех объектов, реально присутствующих на изображении. F-мера является гармоническим средним между точностью и полнотой, что позволяет получить сбалансированную оценку эффективности алгоритма. Экспериментальные результаты показывают значительное улучшение точности и полноты по сравнению с другими методами. Однако необходимо отметить, что производительность на некоторых наборах данных может быть затронута неточными метками классов или другими факторами.

Таким образом, предложенный метод демонстрирует хорошие результаты в обнаружении и сегментации частиц на изображениях микроскопии, особенно на наборах данных, где перекрытие объектов встречается редко.

Результаты исследования вносят значительный вклад в различные области применения:

- автоматический анализ биомедицинских образцов, таких как ткани или клетки;
- контроль качества продукции в различных отраслях промышленности, таких как фармацевтика, сельское хозяйство и производство электроники;
- исследования в различных научных областях, таких как биология, физика и материаловедение, ускоряя процесс анализа данных и обнаружения интересующих объектов.

#### Заключение

Представленный метод обнаружения объектов на изображениях микроскопии, применяемый для обнаружения частиц, показывает хорошие результаты в различных сценариях. Экспериментальные данные демонстрируют его устойчивость к изменениям интенсивности изображения, плотности частиц и их размерам, что было подтверждено на различных наборах данных, включая синтетические изображения и данные DIC-микроскопии. Метод использует экстремальные области в качестве кандидатов для обнаружения и оценивает их с помощью обученных параметров. Встроенное ограничение на неперекрытие позволяет эффективно обрабатывать кластеризацию частиц, что продемонстрировано в результатах на изображениях с высокой плотностью объектов.

Однако основным ограничением метода является необходимость наличия хотя бы одной кандидатской области, соответствующей каждому экземпляру объекта интереса. Это предположение может нарушаться в случае перекрытия объектов, что приводит к низкой производительности в наборах данных с существенным перекрытием экземпляров. Кроме того, улучшение процедур определения кандидатских областей на основе точечных аннотаций может повысить эффективность метода в дальнейших исследованиях.

#### Список литературы

- 1. *Puchkov E.* Image analysis in microbiology: A review // Journal of Computer and Communications. 2016. Vol. 4, iss. 15. P. 8–32. https://doi.org/10.4236/jcc.2016.415002
- 2. Spahn C., Gomez-de-Mariscal E., Laine R. F., Pereira P. M., Chamier L., Conduit M., Pinho M. G., Jacquemet G., Holden S., Heilemann M., Henriques R. DeepBacs for multi-task bacterial image analysis using open-source deep learning approaches // Communications Biology. 2022. Iss. 5. Art. 688. https://doi.org/10.1038/s42003-022-03634-z
- 3. Su P.-T., Liao C.-T., Roan J.-R., Wang S.-H., Chiou A., Syu W.-J. Bacterial colony from two-dimensional division to three-dimensional development // PloS ONE. 2023. Vol. 7, iss. 11. Art. e48098. https://doi.org/10.1371/journal.pone.0048098
- 4. Замятин Д. А., Поротников А. В., Щапова Ю. В., Вотяков С. Л. JPD-анализ микроскопических изображений в исследовании структурно-химической неоднородности зерен природного циркона // Минералы: строение, свойства, методы исследования. 2014. Вып. 6. С. 26–27. EDN: YMSLCU
- 5. *Полищук С. В., Смехун Я. А.* Анализ элекронно-микроскопических изображений с использованием спектральных характеристик // Международный научно-исследовательский журнал. 2014. Вып. 4–1 (23). С. 65–67. EDN: SCQPCB
- 6. Беляева Л. А., Шурыгина О. В., Юхимец С. Н., Петрова А. А., Миронов С. Ю., Ратенкова Н. В., Кулакова О. В., Бовтунова С. С. Автоматизированный и ручной анализ спермы: сравнительная



- характеристика // Морфологические ведомости. 2022. Т. 30, вып. 4. С. 9–15. https://doi.org/10. 20340/mv-mn.2022.30(4).704, EDN: JGHSAW
- 7. Wei X., Liu Yo., Song Q., Zou J., Wen Zh., Li J., Jie D. Microscopic hyperspectral imaging and an improved detection model based detection of Mycogone perniciosa chlamydospore in soil // European Journal of Agronomy. 2024. Vol. 152. Art. 127007. https://doi.org/10.1016/j.eja.2023.127007
- 8. *Khan S., Sajjad M., Abbas N., Escorcia-Gutierrez J., Gamarra M., Khan M.* Efficient leukocytes detection and classification in microscopic blood images using convolutional neural network coupled with a dual attention network // Computers in Biology and Medicine. 2024. Vol. 174. Art. 108146. https://doi.org/10.1016/j.compbiomed.2024.108146
- 9. Han Zh., Huang H., Lu D., Fan Q., Ma Ch., Chen X., Gu Q., Chen Q. One-stage and lightweight CNN detection approach with attention: Application to WBC detection of microscopic images // Computers in Biology and Medicine. 2023. Vol. 154. Art. 106606. https://doi.org/10.1016/j.compbiomed.2023.106606
- 10. Ван Ц. И., Воронов В. И. Анализ результатов компьютерной томографии головного мозга с помощью сверточной нейронной сети // DSPA: Вопросы применения цифровой обработки сигналов. 2020. Т. 10, вып. 1. С. 32–40. EDN: OFBSSY
- 11. Sun M., Wang W., Zhu X., Liu J. Reparameterizing and dynamically quantizing image features for image generation // Pattern Recognition. 2024. Vol. 146. Art. 109962. https://doi.org/10.1016/j.patcog.2023.109962
- 12. *Pawlowski J., Majchrowska S., Zhu X., Golan T.* Generation of microbial colonies dataset with deep learning style transfer // Scientific Reports. 2022. Vol. 12. Art. 5212. https://doi.org/10.1038/s41598-022-09264-z
- 13. Panic B., Borovinsek M., Vesenjak M., Oman S., Nagode M. A guide to unsupervised image segmentation of mCT-scanned cellular metals with mixture modelling and Markov random fields // Materials and Design. 2024. Vol. 239. Art. 112750. https://doi.org/10.1016/j.matdes.2024.112750
- 14. Franti P., Mariescu-Istodor R. Soft precision and recall // Pattern Recognition Letters. 2023. Vol. 167. P. 115–121. https://doi.org/10.1016/j.patrec.2023.02.005

#### References

- 1. Puchkov E. Image Analysis in Microbiology: A Review. *Journal of Computer and Communications*, 2016, vol. 4, iss. 15, pp. 8–32. https://doi.org/10.4236/jcc.2016.415002
- 2. Spahn C., Gomez-de-Mariscal E., Laine R. F., Pereira P. M., Chamier L., Conduit M., Pinho M. G., Jacquemet G., Holden S., Heilemann M., Henriques R. DeepBacs for multi-task bacterial image analysis using open-source deep learning approaches. *Communications Biology*, 2022, iss. 5, art. 688. https://doi.org/10.1038/s42003-022-03634-z
- 3. Su P.-T., Liao C.-T., Roan J.-R., Wang S.-H., Chiou A., Syu W.-J. Bacterial colony from two-dimensional division to three-dimensional development. *PloS ONE*, 2023, vol. 7, iss. 11, art. e48098. https://doi.org/10.1371/journal.pone.0048098
- 4. Zamyatin D. A., Porotnikov A. V., Shchapova Yu. V., Votyakov S. L. JPD-analysis of microscopic images in the study of structural and chemical heterogeneity of natural zircon grains. *Mineraly: stroenie, svoystva, metody issledovaniya* [Mineraly: Structure, Properties, Research Methods], 2014, iss. 6, pp. 26–27 (in Russian). EDN: YMSLCU
- 5. Polishchuk S. V., Smekhun Ya. A. Electron microscopic images analysis using spectral characteristics. *Mezhdunarodnyy nauchno-issledovatel'skiy zhurnal* [International Scientific Research Journal], 2014, iss. 4–1 (23), pp. 65–67 (in Russian). EDN: SCQPCB
- 6. Belyaeva L. A., Shurygina O. V., Yukhimets S. N., Petrova A. A., Mironov S. Yu., Ratenkova N. V., Kulakova O. V., Bovtunova S. S. Automated and manual semen analysis: The comparative characteristics. *Morphological Newsletter*, 2022, vol. 30, iss. 4, pp. 9–15 (in Russian). https://doi.org/10.20340/mv-mn.2022.30(4).704, EDN: JGHSAW
- 7. Wei X., Liu Yo., Song Q., Zou J., Wen Zh., Li J., Jie D. Microscopic hyperspectral imaging and an improved detection model based detection of Mycogone perniciosa chlamydospore in soil. *European Journal of Agronomy*, 2024, vol. 152, art. 127007. https://doi.org/10.1016/j.eja.2023.127007
- 8. Khan S., Sajjad M., Abbas N., Escorcia-Gutierrez J., Gamarra M., Khan M. Efficient leukocytes detection and classification in microscopic blood images using convolutional neural network coupled with a dual attention network. *Computers in Biology and Medicine*, 2024, vol. 174, art. 108146. https://doi.org/10.1016/j.compbiomed.2024.108146
- 9. Han Zh., Huang H., Lu D., Fan Q., Ma Ch., Chen X., Gu Q., Chen Q. One-stage and lightweight CNN detection approach with attention: Application to WBC detection of microscopic images.



- Computers in Biology and Medicine, 2023, vol. 154, art. 106606. https://doi.org/10.1016/j.compbiomed.2023.106606
- 10. Wang Ts. I., Voronov V. I. Analysis of the results of computed tomography of the brain using a convolutional neural network. *DSPA: Voprosy primeneniya tsifrovoy obrabotki signalov* [DSPA: Issues of Digital Signal Processing Application], 2020, vol. 10, iss. 1, pp. 32–40 (in Russian). EDN: OFBSSY
- 11. Sun M., Wang W., Zhu X., Liu J. Reparameterizing and dynamically quantizing image features for image generation. *Pattern Recognition*, 2024, vol. 146, art. 109962. https://doi.org/10.1016/j.patcog.2023.109962
- 12. Pawlowski J., Majchrowska S., Zhu X., Golan T. Generation of microbial colonies dataset with deep learning style transfer. *Scientific Reports*, 2022, vol. 12, art. 5212. https://doi.org/10.1038/s41598-022-09264-z
- 13. Panic B., Borovinsek M., Vesenjak M., Oman S., Nagode M. A guide to unsupervised image segmentation of mCT-scanned cellular metals with mixture modelling and Markov random fields. *Materials and Design*, 2024, vol. 239, art. 112750. https://doi.org/10.1016/j.matdes.2024.112750
- 14. Franti P., Mariescu-Istodor R. Soft precision and recall. *Pattern Recognition Letters*, 2023, vol. 167, pp. 115–121. https://doi.org/10.1016/j.patrec.2023.02.005

Поступила в редакцию / Received 10.04.2024 Принята к публикации / Accepted 15.11.2024 Опубликована / Published 28.02.2025