

УДК 004.855.5

ДЕТЕКТИРОВАНИЕ МИКРОЧАСТИЦ НА ВОССТАНОВЛЕННЫХ ГОЛОГРАФИЧЕСКИХ ИЗОБРАЖЕНИЯХ ОБЪЁМНОЙ СРЕДЫ С ПОМОЩЬЮ НЕЙРОННЫХ СЕТЕЙ

© Н. А. Кузьмин^{1,2}, Ю. Д. Арапов¹

¹Всероссийский научно-исследовательский институт автоматики им. Н. Л. Духова,
115516, Москва, ул. Луганская, 9, с1

²Национальный исследовательский ядерный университет «МИФИ»
115409, Москва, ш. Каширское, 31
E-mail: mr.nkuzmin@gmail.com

Представлены результаты исследования применения двух нейронных сетей для решения задач детектирования и классификации микрочастиц на изображениях, полученных при восстановлении модельных и экспериментальных голограмм аэрозольных сред с плотностью частиц $180\ 000\ \text{см}^{-3}$. Одна нейронная сеть обучена на базе данных изображений частиц, размеченных вручную, вторая — на базе данных, созданной с использованием алгоритмов автоматического распределения определённых частей изображений по классам. Проведено сравнение результатов работы двух нейронных сетей, и представлены способы их дальнейшего улучшения.

Ключевые слова: конструкционные материалы, микрочастицы, голография, детектирование, классификация, автоматизация, нейронная сеть, база данных, сегментация, U-net.

DOI: 10.15372/AUT20230309

Введение. Определение параметров распределения микрочастиц, таких как размеры, концентрация и пространственное распределение, имеет значение для проведения газодинамических экспериментов, в которых образцы конструкционных материалов подвергаются ударным и взрывным воздействиям, сопровождающимся пылением, отколами и образованием дисперсной фазы [1]. Оптическая регистрация распределения микрочастиц по координатам и размерам проводится с использованием различных методов, в том числе фотографического (метод теневой фотографии) [2–4], рентгенографического [5] и голографического [6–8]. В данной работе применяется голографический метод регистрации, так как голограммы сохраняют информацию о пространственном распределении объектов, и используется цифровая голография, позволяющая сократить время восстановления голограмм и обработки экспериментальных данных.

Таким образом, автоматизация процесса определения параметров распределения (в частности, размера и расположения) микрочастиц на восстановленных голографических изображениях представляет собой сложную и актуальную научно-техническую задачу. В настоящее время используются алгоритмические и нейросетевые методы автоматизации. Алгоритмические методы представляют собой измерение определённой величины (или величин), отслеживание её корреляции с искомыми параметрами и автоматизированное прогнозирование значений искомых параметров по измеряемым величинам [9]. В [10] отмечается меньшая точность и скорость работы алгоритмических методов относительно нейросетевых при классификации изображений, поэтому в качестве метода автоматизации в данной работе рассматривается нейросетевой метод, который уже зарекомендовал себя при решении схожих задач [11].

Цель работы заключается в исследовании возможности применения нейронной сети, обученной на модельных данных о дисперсной среде, для распознавания и классифика-




Рис. 1. Схема модели

ции микрочастиц на изображениях, восстановленных из модельных и экспериментальных голограмм.

Задачи исследования заключались в создании модели объёмной дисперсной среды, получении модельных голограмм, послойном восстановлении полученных голограмм, создании и сегментировании вручную базы данных модельных изображений, создании базы данных модельных изображений с автоматизированной сегментацией, обучении нейронных сетей на двух различных базах данных, использовании нейронных сетей для детектирования и классификации микрочастиц на модельных и экспериментальных изображениях и в сравнении полученных результатов.

Моделирование голографической регистрации дисперсной среды. Создана модель облака частиц, и по схеме, приведённой на рис. 1, проведён ряд расчётных экспериментов в программе Fresnel [12], направленных на получение модельной голограммы и её восстановление.

Источник испускает излучение с длиной волны 532 нм и диаметром пучка 1 см, которое попадает на многослойную модель облака частиц, состоящую из 20 слоёв на расстоянии 0,1 мм друг от друга. Каждый слой имитирует нормальное распределение количества частиц в зависимости от их размера. После модели облака частиц излучение проходит через четырёхфокусную систему (из двух линз Л1 и Л2 с равным фокусным расстоянием 5 см) и попадает на экран голографии (ЭГ), где производится запись голограммы. Далее излучение проходит через обратную четырёхфокусную систему линз (Л3 и Л4) и попадает на приёмник. Размеры частиц облака: 5, 10, 15, 20, 25, 30, 35 и 40 мкм с максимумом распределения на 20 мкм. Общая концентрация частиц в модели $180\,000\text{ см}^{-3}$. Все расстояния между элементами модели указаны на рис. 1, расстояние до приёмника варьируется в зависимости от слоя, который требуется восстановить. Таким образом, была получена модельная голограмма и восстановлены все слои модели частиц в виде изображений размером 16384×16384 пикселей — максимальное разрешение, которое возможно сохранить из программы Fresnel.

На основе первых трёх восстановленных слоёв была создана база данных смоделированных частиц для обучения нейронной сети, поделённая на 8 классов по 166 изображений в классе, каждое изображение размером 128×128 пикселей. В базе данных находятся изображения, содержащие минимум одну частицу, как показано на рис. 2. При аугментации — процессе искусственного увеличения базы данных — общее количество изображений достигло 10624.










Нейронная сеть. Нейронные сети, используемые для решения задач детектирования и классификации, разделяются по архитектурам. Зачастую используются полносвязные, свёрточные [13], U-net [14] и другие [15] архитектуры. Для решения задачи классификации было обучено несколько полносвязных и свёрточных нейронных сетей, но точность



Рис. 2. Примеры сегментации: *a* — исходное изображение частицы размером 25 мкм, *a* — сегментированное изображение частицы размером 25 мкм, *b* — исходное изображение частицы размером 30 мкм, *b* — сегментированное изображение частицы размером 30 мкм

Таблица 1

Система кодирования классов по цветам

| Номер класса | Размер частиц, мкм | Кодирование в RGB | | | Цвет |
|--------------|--------------------|-------------------|-----|-----|---|
| | | R | G | B | |
| 1 | 5 | 100 | 0 | 0 |  |
| 2 | 10 | 0 | 100 | 0 |  |
| 3 | 15 | 0 | 0 | 100 |  |
| 4 | 20 | 200 | 0 | 0 |  |
| 5 | 25 | 0 | 200 | 0 |  |
| 6 | 30 | 0 | 0 | 200 |  |
| 7 | 35 | 100 | 100 | 0 |  |
| 8 | 40 | 0 | 100 | 100 |  |
| 9 | Фон | 100 | 0 | 100 |  |

классификации не превышала 40 %. Предположительно, это связано с тем, что часть изображений из базы содержала несколько частиц или неполные «разрезанные» частицы. Для улучшения полученных результатов была применена сегментация изображений — процесс разделения цифрового изображения на несколько сегментов (множество пикселей) с заданными характеристиками для более удобного анализа данных и обучения нейронных сетей [16]. Пример сегментированных изображений из базы данных приведён на рис. 2.

Каждый пиксель каждого изображения в базе данных был классифицирован в соответствии с табл. 1. Также при применении сегментации для обучения нейронной сети использовалась архитектура U-net (рис. 3).

Восстановленные из голографической картины слои рассекались на равные меньшие части для загрузки в нейронную сеть. Рассечение восстановленных слоёв производилось автоматически на изображения размером 128×128 пикселей с использованием алгоритма, реализованного на языке Python. Данный алгоритм рассекает большее исходное изображение на меньшие картины и сохраняет их в памяти ПК. Сортировка и сегментирование полученных изображений осуществлялись вручную, что занимало продолжительное время: для обработки первых трёх восстановленных из голограммы слоёв и получения 1328 изображений в базе и 1328 сегментированных изображений потребовалось около 100 ч.

Процесс увеличения базы данных также возможно автоматизировать с помощью программы Fresnel и алгоритмов, реализованных на языке Python. При прохождении излучения через определённый слой частиц можно отключить их на этом слое, кроме частиц одного размера, а также все остальные слои и записать полученное изображение. Была написана программа на языке Python, которая автоматически классифицирует каждый

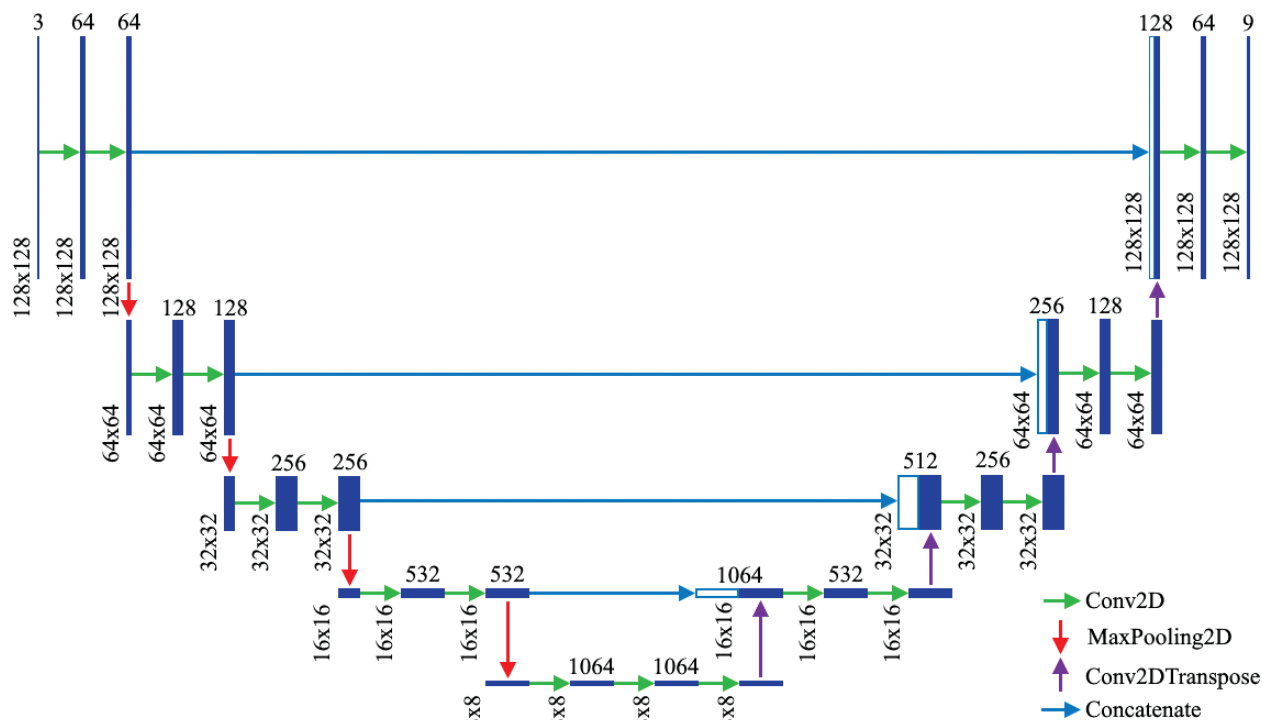


Рис. 3. Архитектура U-net

пиксель на описанных изображениях по табл. 1, используя лишь данные об интенсивности (в кодировке RGB). При обработке изображений каждого из 8 классов частиц, находящихся в одном слое, эти изображения объединялись в одно общее, которое назовём маской. Были созданы три маски для первых трёх восстановленных слоёв и установлено соответствие между масками и восстановленными изображениями. Затем также проводилась сортировка рассечённых изображений по классам. Данный подход представляет собой автоматизацию сегментации, занимающую большую часть времени при увеличении базы. Следует отметить, что существуют некоторые ограничения, накладываемые алгоритмами работы программы Fresnel, которые связаны со смещением координат центров частиц на восстановленных изображениях и на масках на 1 или 2 пикселя. Описанный подход невозможно реализовать в реальном эксперименте, однако он примерно в 25 раз ускоряет время обработки одного слоя восстановленной голографической картины в модельных экспериментах. Создание базы вручную в дальнейшем будем называть ручным методом увеличения (или создания) базы данных, а с использованием маски — масочным методом. Нейронную сеть, обученную на ручной базе данных, будем называть ручной нейронной сетью, а на масках — масочной нейронной сетью.

Сравнение полученных результатов. Две нейронные сети с архитектурой U-net были обучены на базах данных, созданных вручную и с использованием масок. Для обучения нейронной сети с сегментацией также использовалась специальная функция точности — Dice_coef [17], которая вместо количества верных ответов по отношению к количеству неверных ответов отображает точность сегментирования изображений нейронной сетью по следующей формуле:

$$\text{Dice_coef} = 2 \frac{S_{\text{кл}} \cap S_{\text{на вых}}}{S_{\text{кл}} \cup S_{\text{на вых}}}.$$

Функция Dice_coef является увеличенным в 2 раза отношением площади пересечения к площади объединения для сегментированного изображения из базы и изображения, сегмен-

Таблица 2

Сравнение результатов работы ручной и масочной нейронных сетей

| Параметры сравнения | Ручная нейронная сеть | Масочная нейронная сеть |
|----------------------------------|-----------------------|-------------------------|
| Детектировано частиц | 174 | 178 |
| Классифицировано частиц | 170 | 168 |
| Точность детектирования | 96,1 % | 98,3 % |
| Точность классификации | 97,7 % | 94,3 % |
| Ошибочно детектированные частицы | 1 | 0 |

тированного нейронной сетью. Таким образом, если изображения полностью идентичны, то $Dice_coef = 1$. Если совпадает половина пикселей, то $Dice_coef = 0,5$. Значения $Dice_coef$ после обучения: 0,96 — для ручной и 0,97 — для масочной нейронных сетей. Данная функция точности имеет особенность, связанную с тем, что бóльшую часть пикселей на каждом изображении из базы данных составляют пиксели фона. Это приводит к росту влияния фона на качество классификации. Также по значениям $Dice_coef$ невозможно судить об артефактах, присутствующих на изображениях, обработанных нейронной сетью. Таким образом, отдельно были посчитаны точности детектирования и классификации для ручной и масочной нейронных сетей. Частица считалась детектированной, если в результате работы нейронной сети её пиксели были отнесены к какому-либо классу (кроме фона), и классифицированной, если нейронная сеть верно классифицировала бóльшую её часть. Из общей базы изображений была выделена отдельная проверочная выборка изображений, в которой каждое изображение содержало минимум одну частицу. Общее количество частиц на изображениях в проверочной выборке 181. Результаты сравнения работы двух нейронных сетей на модельных данных из описанной проверочной выборки приведены в табл. 2.

Точность детектирования масочной нейронной сети превышает точность детектирования ручной нейронной сети на 2,2 %, что является существенным преимуществом при решении задачи детектирования и в дальнейшем задачи нахождения центра частицы. Точность классификации, в свою очередь, на 3,4 % выше у ручной нейронной сети, однако количество верно классифицированных частиц отличается лишь на 2 штуки. Различия в точности классификации преимущественно заключаются в лучшей точности детектирования масочной нейронной сетью. Следует отметить, что ручная нейронная сеть также определила зашумлённую область на одном изображении как частицу, что создаёт дополнительную ошибку 0,5 % детектирования. Подобных сбоев при работе с масочной нейронной сетью не наблюдалось. На рис. 4 приведены примеры работы ручной и масочной нейронных сетей: верхние изображения — результат работы нейронной сети, нижние изображения — исходные изображения из базы данных. Для наглядности частицы на исходных изображениях были обведены кружками. Классификация на приведённых примерах выполнялась верно за исключением одного случая.

Также обе нейронные сети были проверены на изображении, полученном при проведении реальных экспериментов. Размер частиц на этом изображении не соотносится с размерами частиц из классов, задаваемых нейронной сетью, поэтому точность классификации определить невозможно. Точность детектирования составила 70 % для ручной нейронной сети и 58 % для масочной нейронной сети. Пример работы нейронных сетей с экспериментальными изображениями приведён на рис. 5. Отметим, что ручная нейронная сеть с более высокой точностью детектировала частицы на экспериментальных данных, а также приблизительно выделяла контуры этих частиц, а масочная нейронная сеть детектировала лишь примерное расположение её центральной части. Для наглядности на рис. 5 цвета корректировались.

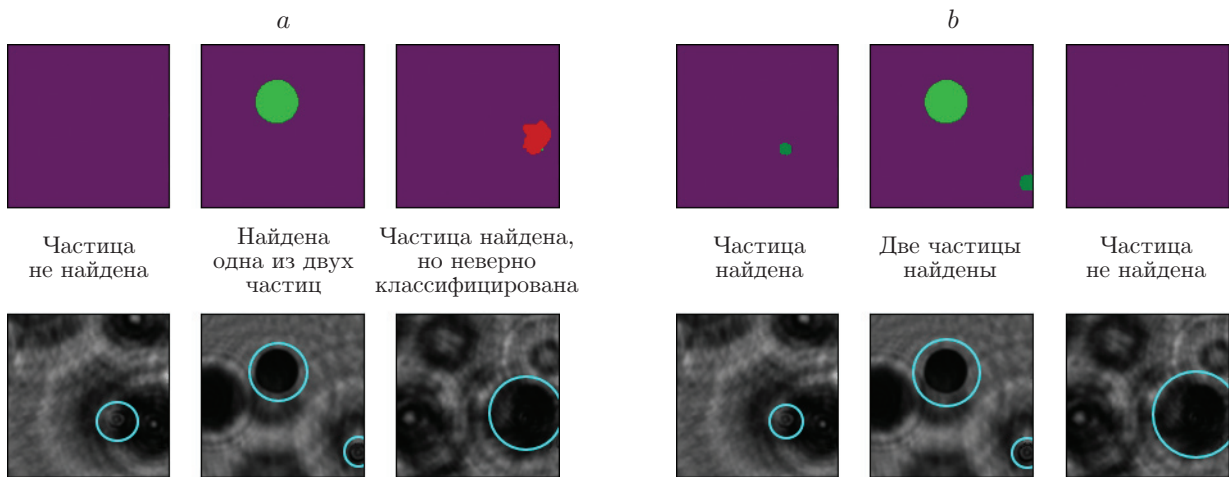


Рис. 4. Результаты работы нейронных сетей на модельных данных: *a* — ручная нейронная сеть, *b* — масочная нейронная сеть




Рис. 5. Результаты работы нейронных сетей на экспериментальных данных: *a* — ручная нейронная сеть, *b* — масочная нейронная сеть

Заключение. В данной работе представлен нейросетевой метод автоматизации определения параметров микрочастиц: размеров и расположения на изображениях, восстановленных из голограмм. Были обучены две нейронные сети на базах данных, созданных вручную и при использовании маски. При сравнении результатов, полученных с помощью представленных нейронных сетей, было выявлено, что точности детектирования и классификации на модельных данных приблизительно совпадают, но на экспериментальных данных точность детектирования нейронной сети, обученной на базе данных, которая создана вручную, на 12 % больше. Достигнута точность детектирования частиц на восстановленной экспериментальной голограмме 70 % с помощью нейронной сети, обученной на модельных данных. Это свидетельствует о высоком потенциале применения подобных нейронных сетей для обработки экспериментальных данных. Также отметим перспективы развития обеих баз данных: база данных, созданная вручную, показывает лучшие результаты на экспериментальных изображениях, однако её дополнение является длительным процессом, в то время как увеличение базы данных, созданной с использованием маски, происходит намного быстрее.

Создание алгоритма подсчёта количества частиц на изображении, увеличение точности детектирования нейронной сети, а также создание возможности определения точности классификации на экспериментальных данных позволит улучшить качество работы ней-

ронной сети. Итоговым результатом работы станет создание программного обеспечения, способного определить количество частиц, координаты их центров и смоделировать пространственное распределение частиц по полученным голографическим изображениям. Созданное программное обеспечение будет применяться при проведении газодинамических экспериментов по определению свойств конструкционных материалов.

СПИСОК ЛИТЕРАТУРЫ

1. **Arapov Y. D., Dvornichenko M. E., Kamenev V. G. et al.** Three-wave holography of polydispersed aerosol // *Opt. Eng.* 2020. **59**, N 10. 102420.
2. **Огородников В. А., Михайлов А. Л., Ерунов С. В. и др.** Характеристики ударно-индуцированных пылевых потоков с поверхности образцов из свинца и меди при давлении в ударной волне 45–50 ГПа и разгрузке в вакуум // *ЖЭТФ*. 2019. **156**, вып. 3 (9). С. 474–482.
3. **Михайлов А. Л., Огородников В. А., Сасик В. С. и др.** Экспериментально-расчётное моделирование процесса выброса частиц с ударно-нагруженной поверхности // *ЖЭТФ*. 2014. **145**, вып. 5. С. 892–905.
4. **Огородников В. А., Иванов А. Г., Михайлов А. Л. и др.** О выбросе частиц со свободной поверхности металлов при выходе на неё ударной волны и методах диагностики этих частиц // *Физика горения и взрыва*. 1998. **34**, № 5. С. 103–107.
5. **Князев А. В., Сулейманов Е. В.** Основы рентгенофазного анализа. Нижний Новгород: Нижегородский государственный университет им. Н. И. Лобачевского, 2005. С. 3–16.
6. **Гендин В. Г., Гуров И. П.** Цифровая голографическая микроскопия: современные методы регистрации голограмм микрообъектов // *Научно-технический вестн. информационных технологий, механики и оптики*. 2012. **12**, № 3 (79) С. 19–27.
7. **Водзинский А. И., Соيفер В. А., Храмов А. Г.** Исследование пространственных ансамблей частиц с применением метода числовой голографии // *Матер. 9 Всесоюз. шк. по голографии*. Тбилиси, 1977. С. 182–190.
8. **Бразовский В. В., Вагнер В. А., Евстигнеев В. В. и др.** Голографический метод исследования дисперсионного состава аэрозоля // *Горизонты образования*. 2009. № 8. С. 1–9.
9. **Mallery K., Hong J.** Regularized inverse holographic volume reconstruction for 3D particle tracking // *Opt. Express*. 2019. **27**, N 13. P. 1–6.
10. **Shao S., Mallery K., Kumar S., Hong J.** Machine Learning Holography for 3D Particle Field Imaging / University of Minnesota. Preprint. 2019. P. 1–15. DOI: 10.1364/OE.379480.
11. **Золотухин Ю. Н., Котов К. Ю., Нестеров А. А. и др.** Отслеживание объекта в видеопотоке с помощью свёрточной нейронной сети // *Автометрия*. 2020. **56**, № 6. С. 100–106. DOI: 10.15372/AUT20200611.
12. **Malyutin A., Serov R., Chulkin A. et. al.** Fresnel. URL: www.wavesimsoft.ru (дата обращения: 14.10.2022).
13. **Сиротенко М.** Применение нейросетей в распознавании изображений. 2009. URL: <https://habr.com/ru/post/74326/> (дата обращения 14.10.2022).
14. **Глек П.** U-net: нейросеть для сегментации изображений. 2018. URL: <https://neurohive.io/ru/vidy-nejrosetej/u-net-image-segmentation/> (дата обращения 14.10.2022).
15. **Новые архитектуры нейронных сетей.** URL: <https://habr.com/ru/post/498168/> (дата обращения 14.10.2022).
16. **Shapiro L. G., Stockman G. C.** Computer Vision. New Jersey: Prentice-Hall, 2001. P. 279–325.
17. **Fedorov A.** Сегментация изображений с помощью U-net (UNET) на Keras. 2020. URL: <https://www.bizkit.ru/2020/01/09/16203/> (дата обращения 14.10.2022).

Поступила в редакцию 09.12.2022

После доработки 26.12.2022

Принята к публикации 17.02.2023