

DOI: 10.17586/1023-5086-2024-91-03-62-78

УДК 535.8 004.93

Нейросетевые методы в цифровой и компьютерной голографии. Обзор

Павел Аркадьевич Черёмхин^{1✉}, Дмитрий Андреевич Рымов²,
Андрей Сергеевич Свистунов³, Евгений Юрьевич Злоказов⁴,
Ростислав Сергеевич Стариков⁵

Национальный исследовательский ядерный университет «МИФИ», Москва, Россия

¹cheremhinpavel@mail.ru

<https://orcid.org/0000-0003-3556-2663>

²rymov.d.a@gmail.com

<https://orcid.org/0000-0003-0914-9736>

³svistunov.andrey.sergeevich@gmail.com

<https://orcid.org/0009-0004-5455-9181>

⁴ezlokazov@gmail.com

<https://orcid.org/0000-0003-1340-7734>

⁵rstarikov@mail.ru

<https://orcid.org/0000-0002-7369-1565>

Аннотация

Предмет исследования. Аналитический обзор применения актуальных нейросетевых методов для задач цифровой и компьютерной голографии, в том числе для восстановления амплитудно-фазовой информации с цифровых голограмм, характеристики голографируемых объектов, классификации объектов, приведения фазы волны к абсолютному виду, синтеза компьютерных голограмм и дифракционных оптических элементов и др. **Цель работы.** Систематизация новейших сведений о методах, основанных на использовании нейронных сетей, обеспечивающих преимущества и новые возможности в решении проблем, стоящих перед цифровой и компьютерной голографией. **Метод.** В основе рассмотренных в обзоре методов лежит обучение нейронных сетей методам голографии и их применение для конкретных задач компьютерной и цифровой голографии. В обучающий набор для парного обучения (с учителем) обычно входит набор изображений — идеально представленные объекты исследования (восстановленная амплитуда поля, отраженного от объекта, непрерывная фаза поля в интервале, большем чем 2λ , сечение трехмерной сцены и др.) и некоторые соответствующие им распределения интенсивности или фазы (например цифровые голограммы). В случае же непарного обучения (без учителя) сеть может быть обучена на не участвующих в исследовании или даже случайных объектах. По результатам обучения нейросеть может быть применена к решению задачи в конкретной постановке. **Основные результаты.** Представлен аналитический обзор работ по применению нейронных сетей в задачах голографии, основное внимание при написании обзора уделено новейшим публикациям по данной тематике. Приведены основные типы архитектур нейронных сетей, которые наиболее эффективно показали себя при решении задач области. Статьи, посвященные рассматриваемой теме, систематизированы по областям применения. Обсуждаются наиболее интересные, по мнению авторов настоящего обзора, результаты, достигнутые в данном направлении. **Практическая значимость.** Обзор будет полезен как исследователям, специализирующимся в областях компьютерной и цифровой голографии, так и читателям, работающим в смежных направлениях. Обзор позволит ознакомиться с актуальными нейросетевыми методами и техниками, используемыми при восстановлении информации с цифровых голограмм и при синтезе компьютерных голограмм и дифракционных элементов, а также узнать о возможностях и об особенностях практического применения таких методов. Представленные в обзоре сведения демонстрируют, что при решении ряда задач использование нейросетевых методов вместо методов, основанных на стандартных и классических подходах, позволяет получить значительное преимущество в скорости получения и/или информативных качествах искомого результата.

Ключевые слова: цифровая голография, компьютерная голография, нейронные сети, глубокое обучение, реконструкция изображения, дифракционный оптический элемент, восстановление фазы, архитектура U-Net, классификация объектов, распознавание изображений, генеративно-сопоставительная нейросеть, трехмерное поле частиц, приведение фазы волны к абсолютному виду, архитектура ResNet, оптико-цифровой синтез

Благодарность: работа выполнена при финансовой поддержке Российского научного фонда, грант № 23-12-00336.

Ссылка для цитирования: Черёмхин П.А., Рымов Д.А., Свистунов А.С., Злоказов Е.Ю., Стариков Р.С. Нейросетевые методы в цифровой и компьютерной голографии. Обзор // Оптический журнал. 2024. Т. 91. № 3. С. 62–78. <http://doi.org/10.17586/1023-5086-2024-91-03-62-78>

Коды OCIS: 090.1995, 110.4280, 230.5160, 090.1760

Neural-network-based methods in digital and computer-generated holography. A review

PAVEL A. CHEREMKHIN¹✉, DMITRY A. RYMOV², ANDREY S. SVISTUNOV³,
EVGENII YU. ZLOKAZOV⁴, ROSTISLAV S. STARIKOV⁵

National Research Nuclear University MEPhI (Moscow Engineering Physics Institute), Moscow, Russia

¹cheremhinpavel@mail.ru

<https://orcid.org/0000-0003-3556-2663>

²rymov.d.a@gmail.com

<https://orcid.org/0000-0003-0914-9736>

³svistunov.andrey.sergeevich@gmail.com

<https://orcid.org/0009-0004-5455-9181>

⁴ezlokazov@gmail.com

<https://orcid.org/0000-0003-1340-7734>

⁵rstarikov@mail.ru

<https://orcid.org/0000-0002-7369-1565>

Abstract

Subject of study. An overview of modern neural-network-based methods for digital and computer-generated holography. Relevant works on phase and amplitude reconstruction, media characterization, phase unwrapping, computer hologram generation and other topics were discussed. **Aim of study.** Modern neural-network-based methods for digital and computer-generated holography are investigated. **Method.** The methods discussed in this review are based on neural-networks and are developed for particular tasks in the field of holography. Training dataset for supervised learning usually contains a set of input images (digital holograms, wrapped phase, 3D scenes, etc.) and a set of target images (reconstructed scenes, unwrapped phase, 3D holograms, etc.) the network is supposed to learn to generate from the input images during training. In case of unsupervised learning, there is no need to prepare a set of target images, the training is based only on the input images and the transformations applied to them. **Main results.** An overview of the applications of neural networks in the field of holography is provided. The main focus is on the state-of-the-art works. Neural network architectures most commonly used in holography are discussed. Cited works are organized based on the particular applications. The most important results and achievements of neural-network-based methods for digital and computer-generated holography are discussed. **Practical significance.** This review may interest the researchers specializing in holography or adjacent fields. This review will familiarize the readers with the modern neural-network-based methods used in computer hologram generation, holographic image reconstruction as well as the particulars of their practical application. The data presented in this review demonstrates, that in some cases the use of neural-network-based methods can provide advantages in speed and/or quality when compared against conventional methods.

Keywords: digital holography, computer-generated holography, neural networks, deep learning, image reconstruction, diffractive optical element, phase retrieval, U-Net architecture, object classification, image recognition, generative adversarial neural network, 3D particle field, phase unwrapping, ResNet architecture, camera-in-the-loop

Acknowledgment: this work was supported by the Russian Science Foundation, grant № 23-12-00336.

For citation: Cheremkhin P.A., Rymov D.A., Svistunov A.S., Zlokazov E.Yu., Starikov R.S. Neural-network-based methods in digital and computer-generated holography. A review [in Russian] // Opticheskii Zhurnal. 2024. V. 91. № 3. P. 62–78. <http://doi.org/10.17586/1023-5086-2024-91-03-62-78>

OCIS codes: 090.1995, 110.4280, 230.5160, 090.1760

ВВЕДЕНИЕ

Цифровая и компьютерная голография являются одними из важнейших, перспективных и ориентированных на практическое применение методов исследований в оптике, фотонике и связанных с ними направлениях информационных технологий [1–3]. Они открывают уникальные возможности формирования и анализа пространственных световых распределений для оперативной и высокоинформативной характеристики объектов, их визуализации, воссоздания формы и параметров, создания трехмерных изображений и др.

Одним из инновационных и перспективных подходов к развитию методов голографии и дифракционной оптики стало применение нейронных сетей (НС) [4–5], данное направление получило значительное развитие, начиная с рубежа 2000–2010-х гг. Широко известно, что НС, идея которых была вдохновлена биологическими системами, показывают выдающиеся результаты при обработке изображений и при анализе данных. Применение же НС к задачам цифровой [6–12] и компьютерной [13–18] голографии открывает новые возможности для эффективного синтеза, восстановления и анализа световых распределений, а также для улучшения качества изображений, зарегистрированных в реальных, в том числе экстремальных, условиях. Появление целого ряда новейших работ, использующих нейросетевые методы при решении таких «чисто голографических» задач, свидетельствует как о росте интереса к исследованиям в данном направлении, так и о потенциальных возможностях и привлекательности их практических применений. В частности, НС успешно применены для анализа биологических объектов, например живых клеток, при восстановлении их изображений с цифровых голограмм (ЦГ) в системах цифровой голографической микроскопии, используемых для медико-биологических целей [19–20]; такой анализ может включать в себя сегментацию, распознавание объектов и мониторинг их динамики. Нейросети уже до-

статочно широко используются для восстановления фазовой информации из ЦГ [21–30], при этом могут быть полностью восстановлены комплексные световые поля в объектной плоскости [6–9, 31–39]. Нейросети позволяют в некоторых задачах восстанавливать трехмерные сцены из ЦГ, анализируя различные сечения сцены [12]. Используя НС, можно отслеживать поля мелких частиц, локализацию каждой частицы в пространстве или динамику их движения [10–11, 40–41]. Нейросети могут быть использованы для оперативного синтеза компьютерных голограмм (КГ) и дифракционных оптических элементов (ДОЭ), что применяется в задачах оптического формирования 2D и 3D сцен [13, 16, 42–50], при создании 3D дисплеев [1], оптических пинцетов [54], для фотостимуляции биологических нейронов [55] и др. Оптико-цифровой синтез КГ [15, 56–59] компенсирует неоднородности оптической системы и, например, снижает шумы и повышает яркость в голографических дисплеях [57, 59]. Ряд подобных примеров может быть продолжен.

Отмеченный быстрый прогресс в применении НС в задачах голографии нашел отражение в значительном числе публикаций по теме, в том числе содержащих и весьма подробный анализ рассматриваемого направления, например [4–5]. Задача же авторов настоящей обзорной статьи — показать, какие именно актуальные преимущества и возможности относительно стандартных подходов предоставляют НС для решения проблем, стоящих перед цифровой и компьютерной голографией. Для этого рассмотрены современные нейросетевые методы и техники, разработанные и примененные для задач голографии, также в обзоре будут представлены недавние примеры применения данной технологии в медицине, инженерии, научных исследованиях и других областях. При этом для демонстрации новейших успехов и значительного потенциала данного направления основное внимание уделено научным публикациям, выпущенным после 2020 г.

Целью работы является систематизация новейших сведений о методах, основанных на использовании НС, обеспечивающих преимущества и новые возможности в решении проблем, стоящих перед цифровой и компьютерной голографией в настоящее время.

1. О НЕКОТОРЫХ ОСОБЕННОСТЯХ ЦИФРОВОЙ И КОМПЬЮТЕРНОЙ ГОЛОГРАФИИ

Голография позволяет записывать, обрабатывать и восстанавливать информацию о распределении излучения за счет дифракции и интерференции опорной и предметной волн. В случае цифровой голографии в качестве регистратора получаемой интерференционной картины обычно служит цифровая камера, имеющая матричный тип фотосенсора. С зарегистрированной ЦГ изображение может быть восстановлено двумя способами. Во-первых, численно — за счет численного моделирования распространения излучения от плоскости голограммы до требуемого сечения объекта. Пример схемы регистрации ЦГ и последующего численного восстановления изображений с помощью НС представлен на рис. 1. Второй способ восстановления — оптический за счет вывода голограммы на физический носитель. В случае же компьютерной голографии расчет (синтез) голо-

граммы осуществляется на основе компьютерного моделирования процессов дифракции и интерференции. Синтезированная КГ выводится на физический носитель, освещение которого позволяет оптически восстановить 2D или 3D сцены. И в случае КГ, и в случае ЦГ в качестве физического носителя голограмм в наши дни, как правило, используются пространственно-временные модуляторы света, в настоящее время наиболее распространены жидкокристаллические и микрозеркальные модуляторы.

Суммарную интенсивность при интерференции когерентных между собой опорной $A(x, y)$ и объектной $B(x, y)$ волн можно представить в следующем виде:

$$\begin{aligned}
 H(x, y) &= |A(x, y) + B(x, y)|^2 = \\
 &= |A(x, y)|^2 + |B(x, y)|^2 + \\
 &+ A(x, y)B(x, y)^* + A(x, y)^* B(x, y),
 \end{aligned}
 \tag{1}$$

где $H(x, y)$ — голограмма (матрица со значениями голограммы), * — знак комплексного сопряжения, (x, y) — координаты в плоскости голограммы. В плоскости восстановленного с голограммы изображения будут присутствовать три дифракционных порядка. Первые два слагаемых отвечают за 0-й порядок — непродифрагировавшую часть световой волны, а третье и четвертое слагаемые отвечают за +1-й и -1-й порядки соответственно. +1-й порядок представляет собой действительное изображение объекта, а -1-й — мнимое [60]. В результате на восстановленном с голограммы поле помимо изображения объекта будут присутствовать неинформативные порядки дифракции, что снижает качество восстановления. Помимо этого, качество восстановленного изображения ухудшают оптические шумы, в первую очередь спекл-шумы [61], связанные с неидеальностью оптических элементов и неравномерностью распределения интенсивности излучения, оптические аберрации, шумы регистратора [62] и др. Эти факторы могут приводить также к снижению точности и объема данных о структуре объекта в голографии. Они являются особенно существенным негативным фактором в случае осевой схемы записи голограмм. Внеосевая схема [63] при регистрации ЦГ позволяет снизить влияние неинформативных порядков

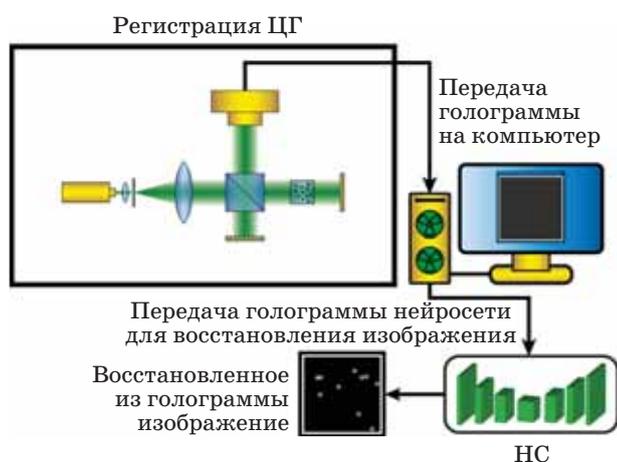


Рис. 1. Принципиальная схема регистрации ЦГ и нейросетевого восстановленного изображения с нее

Fig. 1. Optical registration of a digital hologram and its reconstruction using a neural network

за счет их пространственного разделения с информативным. Однако при этом снижается количество регистрируемой объектной информации. Для подавления влияния шумов при осевой схеме записи обычно регистрируется несколько голограмм [64], однако такие техники могут быть весьма сложны в применении. Другой вариант — это компьютерные методы обработки, основанные на длительных итеративных процедурах, регуляризованной инверсии, частотной фильтрации, вейвлет-анализе и др. [65].

Использование методов машинного обучения позволяет снизить влияние этих факторов [4]. В случае ЦГ может быть повышено качество восстановления [5], увеличена скорость регистрации за счет снижения числа снимков, снижено время обработки и получения результата. В случае КГ еще одной важной проблемой является вычислительная сложность алгоритмов синтеза. Так, существующие методы синтеза ДОЭ и КГ, как правило, основываются на итеративных алгоритмах, в основе которых лежит метод Герчберга–Сэкстона [66]. Такие алгоритмы из-за своей итеративности не позволяют оперативно синтезировать КГ, особенно в случае необходимости восстановления сцен высокого разрешения или 3D сцен, где требуется расчет набора сечений. Применение методов, основанных на использовании НС, позволит более оперативно синтезировать ДОЭ и КГ с качеством, не уступающим и иногда превосходящим традиционные методы [1, 15, 56–59].

2. ТИПЫ АРХИТЕКТУР НЕЙРОСЕТЕЙ ДЛЯ ЗАДАЧ ГОЛОГРАФИИ

2.1. Основные элементы нейросетей

При всем разнообразии предлагаемых архитектур нейросетей в задачах цифровой и компьютерной голографии фундаментальной для всех них является операция свертки, которая позволяет выделять признаки из изображений. На рис. 2а представлен пример работы сверточного слоя. Операция свертки является линейной, и поэтому несколько расположенных друг за другом сверточных слоев можно представить в виде единого блока.

Важнейшим функциональным параметром любой НС является функция активации [67]. Для НС глубокого обучения, содержащих

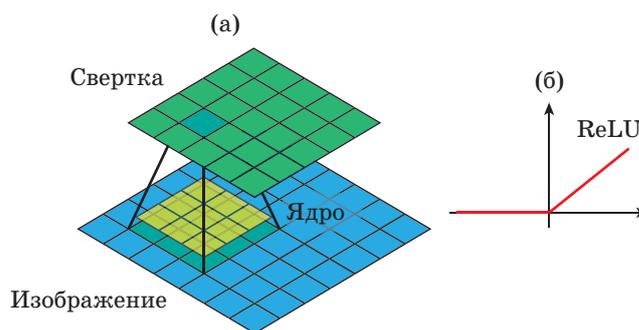


Рис. 2. Пример работы сверточного слоя НС (а) и график зависимости функции активации ReLU от выходного значения сверточного слоя (б)

Fig. 2. An example of (a) a convolution operation and (b) a ReLU activation function

множество слоев, часто используются функции активации типа ReLU, график зависимости которой от выхода нейрона сверточного слоя представлен на рис. 2б.

В процессе обучения внутренние параметры НС обновляются таким образом, чтобы минимизировать различия между изображением, созданным НС, и целевым изображением, заданным обучающим набором. Функция, по которой рассчитывается разница и которая минимизируется в процессе обучения, называется «функцией потерь». Для изображений в качестве функции потерь часто используют значение среднеквадратического отклонения.

2.2. Архитектура U-Net

Наибольшее распространение среди архитектур, используемых для задач голографии, дифракционной оптики, птихографии, когерентной дифракционной визуализации и других различных техник вычислительной фотографии, получила так называемая U-Net [68]. Это архитектура изначально была разработана для сегментации биологических изображений. Архитектура U-Net, представленная на рис. 3, имеет две части — энкодер и декодер. Энкодер сжимает и нормализует входные данные, декодер на основе этих данных создает итоговое изображение. Такая модель эффективно показала себя для решения широкого спектра задач, в частности, задач восстановления амплитуды и фазы с ЦГ [9–10, 24, 28, 40–41, 69–70], поэтому возникло большое количество различных ее модификаций. Также на рис. 3 приведены примеры

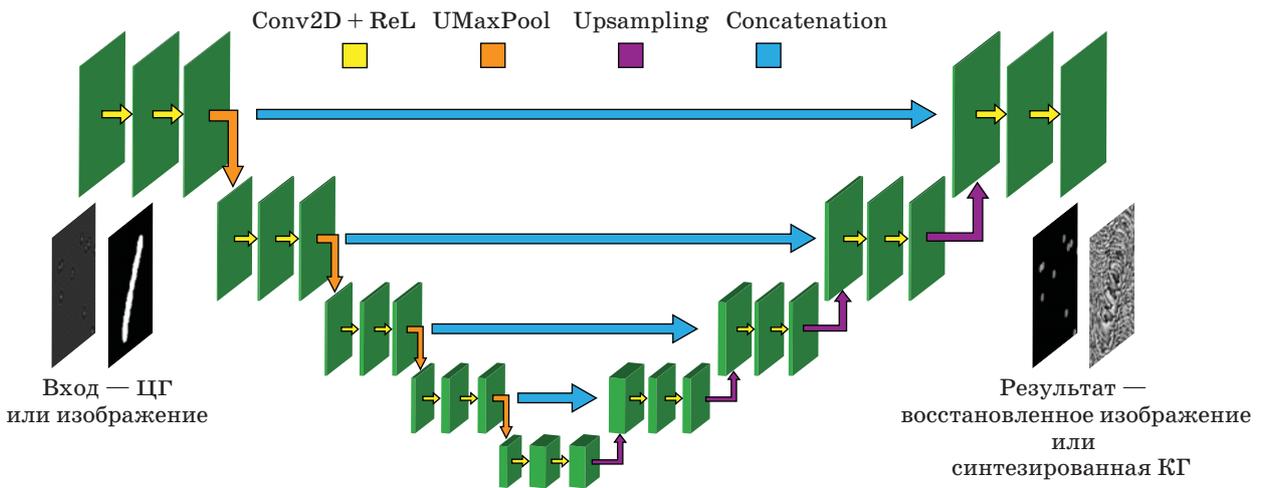


Рис. 3. Архитектура U-Net для восстановления изображений с ЦГ либо для синтеза КГ
Fig. 3. U-Net architecture for holographic image reconstruction or hologram generation

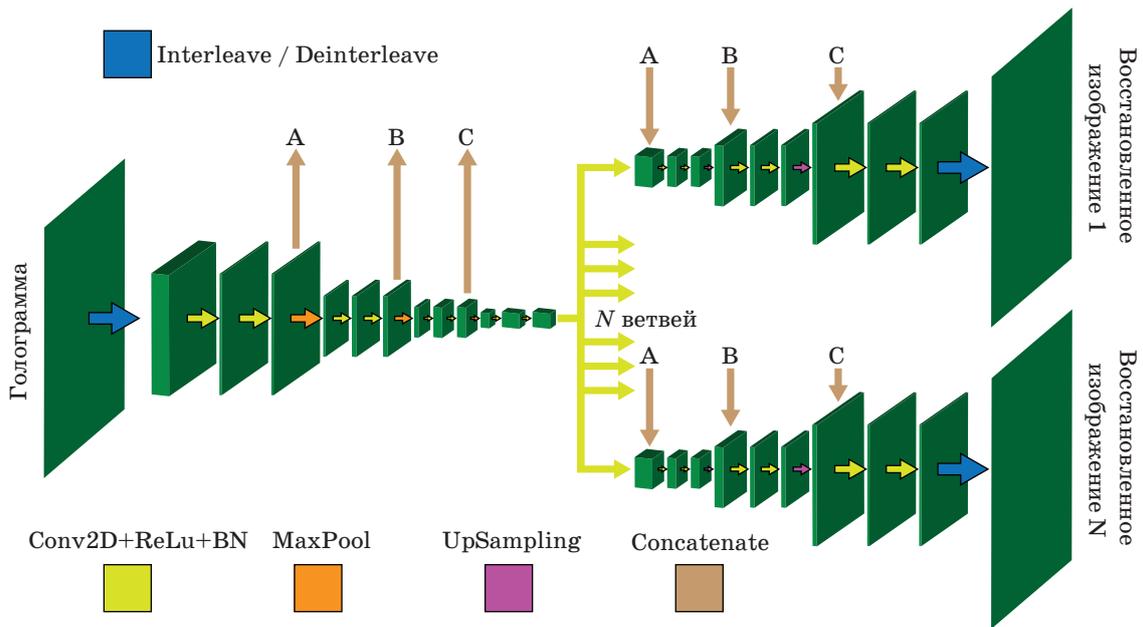


Рис. 4. Архитектура HoloForkNet для восстановления сечений 3D сцены с ЦГ
Fig. 4. HoloForkNet architecture for 3D scene cross-section reconstruction

некоторых типов объектов, которые могут быть рассмотрены нейросетевым подходом — ЦГ и восстановленное с нее изображение; голографируемое изображение и соответствующая ему КГ.

Большую популярность получили модификации НС U-Net, содержащие несколько ветвей декодера [12, 35, 38–39]. Такая модификация оказывается эффективной в случае восстановления нескольких различных объектов

с одной голограммы. Используя несколько ветвей декодера, можно разделить пути генерации этих объектов и тем самым улучшить итоговое качество восстановления каждого из них.

Другим вариантом использования нескольких ветвей декодера является предложенная недавно архитектура HoloForkNet [12], схема которой представлена на рис. 4. Каждой выходной ветви нейросети поставлено в соответствие одно сечение голографируемой 3D

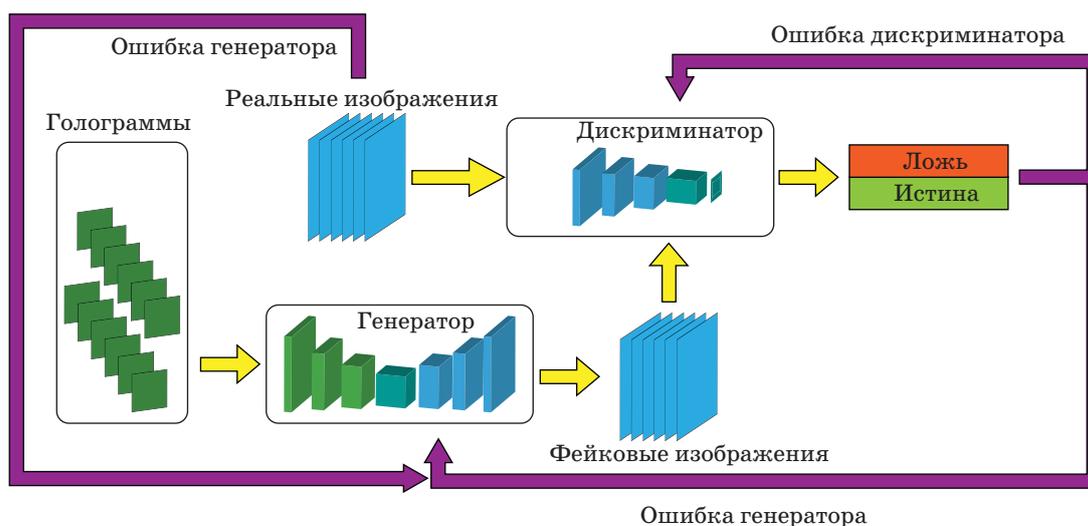


Рис. 6. Архитектура генеративно-сопоставительной сети
Fig. 6. Generative-adversarial network architecture

к реальным по мере обучения. Алгоритм работы в виде схемы представлен на рис. 6.

Генератором в ГСМ НС как правило являются сверточные НС, часто это U-Net или ее модификации. В качестве дискриминатора выступают также сверточные НС часто с добавлением в конце полносвязанных слоев. Таким образом энкодер на основе сверточных слоев выделяет существенные признаки из изображения, а полносвязанные слои на основе этого решают, является ли данное изображение реальным или сгенерированным.

2.5. Парное (с учителем) и непарное (без учителя) обучение

Все перечисленные выше модели обучаются на основе сопоставления пар изображений. Например, для задач восстановления изображений с ЦГ на вход НС при обучении подается голограмма, возможно, с некоторыми дополнительными данными, а на выходе НС ей в соответствие ставится восстановленное изображение амплитуды, фазы или другой информации, которая извлекается из голограммы. В процессе обучения НС генерирует изображения из голограмм и сопоставляет их с образцами, корректируя свои весовые коэффициенты для минимизации функции потерь. Такой метод обучения называется парным (методом с учителем), поскольку для каждой голограммы есть заранее известный конечный результат восстановления. В общем случае обучение

с учителем — это метод машинного обучения, заключающийся в использовании обучающего набора, состоящего из пар (входные данные — конечный результат). Таким образом модель обучается скрытым закономерностям, согласно которым построен обучающий набор, и в результате обучения становится способна с высокой точностью воспроизводить результат для данных схожего типа, которые не использовались в процессе обучения.

С одной стороны, такой подход прост в реализации и весьма понятен. Однако есть два существенных минуса в виде того, что такие модели имеют сравнительно небольшую способность к обобщению данных, т.е. если НС обучалась на конкретных объектах, например голограммах микрочастиц, то голограммы, содержащие другие объекты, например биологические ткани, она вряд ли сможет восстановить. Второй и главный недостаток — это сложность в подготовке и разметке набора данных.

Альтернативным подходом является обучение без учителя, или непарное обучение, т.е. метод, в котором заранее неизвестна пара (голограмма — восстановленное изображение). Обучение без учителя не требует использования обучающего набора, содержащего заранее подготовленный набор «правильных» результатов, которым модель обучается в процессе обучения. При синтезе голограмм это соответствует тому, что для обучения модели необяза-

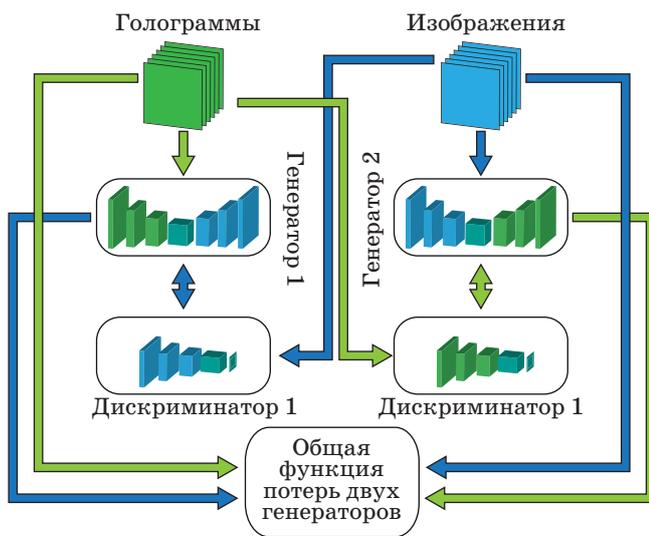


Рис. 7. Схема непарного обучения с двумя симметричными генеративно-сопоставительными нейросетями

Fig. 7. Unpaired training with two symmetrical generative adversarial networks

тельно заранее создавать набор голограмм, используя существующие методы. Модель в таком случае может обучаться за счет встраивания математического моделирования физических принципов голографии непосредственно в процесс обучения. Для восстановления информации с ЦГ можно использовать две генеративные сети, одна из которых будет синтезировать голограммы, а другая — синтезировать восстановленные изображения, причем голограммы и восстановленные изображения могут быть совершенно различных объектов. Так, в работе [27] используются голограммы латинских букв и восстановленные изображения арабских цифр. Схема работы НС приведена на рис. 7.

Помимо исследований с рассмотренными архитектурами НС, есть работы по применению капсульных [23] и рекуррентных [22] НС для задач восстановления изображений с голограмм.

3. ПРАКТИЧЕСКИЕ ПРИМЕНЕНИЯ НЕЙРОСЕТЕЙ В ГОЛОГРАФИИ

3.1. Восстановление амплитуды и фазы объектной волны

Популярной областью исследования применения НС является восстановление из ЦГ фазы

[21–30] или амплитуды и фазы комплексного поля в объектной плоскости [6–9, 31–39]. Такой метод восстановления оказывается особенно полезным в случае осевой схемы записи ЦГ, так как он позволяет восстановить информацию об объекте без зашумления неинформативными порядками дифракции и не требует сложной постобработки или регистрации нескольких голограмм.

Одна из первых реализаций данного подхода представлена в публикации [39], где НС обучалась на голограммах мышинных фагоцитов, зарегистрированных цифровым голографическим микроскопом. Данная архитектура получила название Y-Net и представляет собой модификацию архитектуры U-net. В качестве входных данных используются ЦГ, а результатом работы НС являются амплитуда и фаза поля в плоскости голографируемого объекта. Вся обучающая выборка состояла из 1664 голограмм, которые были разделены в соотношении 8/1/1 для обучения, проверки и тестирования соответственно. Позднее архитектура была модернизирована до 4-х ветвей декодера, которые использовались для восстановления амплитуды и фазы на двух длинах волн излучения [38]. Также на сегодняшний день предложены и модификации данного подхода, показывающие более качественные результаты. Например, архитектура Mimo-Net [35] содержит в себе дополнительные соединения по сравнению с Y-Net. Она позволила повысить качество восстановления амплитуды в тестах на 0,02 по показателю индекса структурного сходства (ИСС) на голограммах с разрешением 256×256 пикселей, однако почти не достигается улучшение при восстановлении фазы. На голограммах с разрешением 64×64 пикселя качество восстановления было улучшено более заметно — на 0,04 как для амплитуды, так и для фазы. В работе [8] предложен метод извлечения из ЦГ амплитуды и фазы только информативного порядка дифракции, которые в дальнейшем могут быть использованы для восстановления изображений объекта или сечений 3D сцены. На вход НС подается ЦГ, которая преобразуется на выходе в информацию об амплитуде и фазе.

К преимуществам нейросетевого восстановления амплитуды и фазы в сравнении с классическими методами можно отнести их устойчивость к неточностям юстировки оптических

систем, а также устойчивость к внесенным абберациям. Так, в работе [27] это продемонстрировано для восстановления фазы различных объектов. Особенно широко в настоящее время развивается восстановление объектной волны из голограмм биологических объектов (клеток и тканей), зарегистрированных с помощью голографических микроскопов [21, 24, 29, 73].

Важным шагом в направлении создания универсальной модели для восстановления амплитуды и фазы световых полей с голограмм стала GedankenNet [74]. В данной работе предложена модель с самоконтролируемым обучением, которая обучается исключительно на синтезированных данных, однако качественно проявляет себя на экспериментально записанных ЦГ. Таким образом модель демонстрирует способность к обобщению. Другим примером восстановления амплитудной или фазовой информации с ЦГ с помощью ГСМ НС является публикация [75], где предложена архитектура DHR-GAN. Она продемонстрировала высокое качество восстановления. Например, ИСС составил 0,775 для амплитудных и 0,859 для фазовых объектов. В работе [7] предложена архитектура FIN на основе сети с остаточными блоками, использующими преобразование Фурье (*SPAF Group*). Архитектура модифицирована [76] за счет изменения блоков и добавления дополнительных соединений между ними.

3.2. Восстановление трехмерных сцен и поля частиц

Цифровая голография активно применяется для регистрации полей микрочастиц. Поэтому еще одной задачей в восстановлении информации является определение положения частиц в пространстве, а также более общая задача — восстановление 3D сцен и параметров более сложных объектов.

Задачи с определением местоположения частиц [10–11, 40–41] можно разделить на восстановление с использованием только самой голограммы и восстановление с использованием дополнительных изображений. Например, в работе [11] на вход Dense-U-net подается только голограмма, из которой проводится восстановление поля частиц. Нейросеть обучалась на голограммах, синтезированных для 256 сечений 3D сцены, каждая из которых содержа-

ла как минимум одну частицу, случайно расположенную в данной плоскости. Плоскости располагались на расстоянии 8 мкм друг от друга. Расчет голограмм проводился с использованием скалярной теории дифракции в приближении распространения углового спектра плоских волн [77]. Следует отметить, что НС восстанавливала карту глубины, т.е. единственное изображение, в котором расположение объектов по оси, перпендикулярной плоскости голограммы, кодировалось уровнем яркости объекта на выходном изображении. Достигнута высокая точность восстановления по значению ИСС, составившему 0,992, для 100 частиц в голографируемой сцене. Однако в случае 200 и 300 объектов качество восстановления значительно снижается; авторы отмечают, что это связано в первую очередь с тем, что в этих случаях НС обучалась на меньшем количестве объектов и при изменении тренировочной выборки данные показатели можно увеличить.

Другой подход был продемонстрирован в публикации [10], где использовалась классическая архитектура U-Net, однако на вход НС помимо голограммы подаются еще два изображения — карта глубины и полный фазовый набег при распространении от объектной плоскости до плоскости регистрации. Результатом работы НС является восстановленное положение частиц, зашифрованное в двух изображениях — рендеринг расположения частиц и изображение проекций центров этих частиц. Такой подход, с одной стороны, позволяет более точно восстановить положение частиц. Так, при наибольшей концентрации в 1000 частиц в сцене получена 95%-ая точность восстановления их местоположения. С другой стороны, требуется дополнительная информация о сцене, что усложняет эксперимент.

Если расширять возможности восстановления поля частиц в сторону восстановления 3D сцен, содержащих в том числе крупные объекты, то подход с кодированием информации о глубине путем присвоения сечениям различных уровней яркости [78] оказывается чрезвычайно трудоемким для реализации. Это связано с тем, что изображения объектов могут накладываться друг на друга, в результате чего может теряться значительная часть информации. В таких случаях можно восполь-

зваться вариантом архитектуры HoloForkNet [12]. В этой архитектуре выход сети имеет разветвленную структуру, что позволяет из голограммы напрямую восстанавливать набор сечений исходной 3D сцены в большом разрешении.

3.3. Приведение фазы волны к абсолютному значению

Еще одно направление применения НС при восстановлении изображений с ЦГ — это приведение фазы волны к абсолютному значению [70, 79–80]. Диапазон изменения фазы в голографируемых объектах часто оказывается больше или существенно больше 2π . В таких случаях появляется необходимость ее развертывания.

Нейросетевые принципы восстановления фазы с использованием приведения фазы к абсолютному значению можно разделить на две группы: восстановление за один шаг, когда непосредственно из голограммы напрямую восстанавливается развернутая абсолютная фаза, и восстановление за два шага, когда сначала некоторым методом осуществляется восстановление фазы, после чего проводится развертка. Оба подхода на сегодняшний день были экспериментально реализованы. Так, в публикации [70] предлагается использовать архитектуру U-Net: сеть эффективно показывает себя в диапазоне от 0 до 70 рад.

В работе [80] рассматриваются оба способа приведения фазы к абсолютному значению. Обучение проводилось как на парах изображений (голограмма — абсолютная фаза), так и на парах (приведенная фаза — абсолютная фаза). В обоих случаях НС хорошо справлялась с поставленной задачей: ИСС оказался равен 0,938. Также показано, что при двухэтапной развертке фазы и целевой выборке, содержащей всего 50 изображений, модель работает достаточно эффективно: ИСС равен 0,816. При одноэтапной развертке фазы в аналогичных условиях ИСС оказывался выше — 0,827.

При приведении фазы к абсолютному виду часто необходимо проводить компенсацию aberrаций. Описывая aberrации полиномами Цернике, НС используется для нахождения коэффициентов Цернике [81]. Это позволяет восстанавливать вид aberrаций, компенсировать их, улучшая, таким образом, качество развертки фазы.

3.4. Классификация объектов

Классификация объектов [19–20, 82–83] распространена в ситуациях, когда необходимо разделить на классы, например клетки, зарегистрированные с помощью голографического микроскопа. Преимущество НС при решении данной задачи состоит в том, что они позволяют быстро и с высокой степенью точности классифицировать объекты, зарегистрированные на голограмме, без дополнительных манипуляций с самой голограммой. Это в перспективе предполагает возможность классификации объектов в реальном времени на голографическом видео. Например, в работе [20] показано, что классификация клеток напрямую с помощью НС происходит эффективнее и быстрее, чем при использовании метода, основанного на восстановлении фазы в плоскости классифицируемых объектов-клеток и классификации с использованием этой восстановленной фазы.

Пример использования НС для классификации объектов на заранее восстановленной 3D сцене представлен в публикации [73]. В данной работе была проанализирована возможность классификации объектов с помощью сети 3D-CNN. Такая модель показала себя более эффективно как в случае точной фокусировки восстановленного изображения на объекте, так и в случае небольшой расфокусировки.

3.5. Численный синтез голограмм

Нейросетевой синтез КГ и ДОЭ может обеспечить в первую очередь существенное ускорение расчетов в сравнении с существующими методами. Одной из первых современных работ, посвященных компьютерному синтезу ДОЭ с использованием НС, является публикация [42]. В данной работе НС обучалась синтезу голограмм 2D сцен. Для этого использовался предварительно созданный набор изображений и соответствующих им голограмм. Для обучения использовались изображения размером 64×64 пиксела. Обученная модель показала хорошее качество восстановленных изображений, сопоставимое с полученными при использовании алгоритма Герчберга–Сэкстона. Развитием данного подхода можно считать работы [43–45], в которых НС использовалась для синтеза голограмм 3D сцен. Главным отличием таких подходов является использо-

вание обучающего набора, основанного на голограммах, содержащих несколько сечений 3D сцены. В работе [51] предложено встраивать дополнительные этапы, использующие преобразование Фурье, в существующие архитектуры НС, что позволяет повысить качество реконструкции. Так, например, по сравнению со стандартной архитектурой U-Net добавление данных этапов при синтезе КГ 2D сцены увеличило ИСС с 0,765 до 0,935. Возможно рассмотрение и других особенностей пространственно-спектрального представления сигналов. Так, была предложена стратегия обучения, основанная на архитектуре U-Net и базисных функциях Фурье [46]. Получено повышение разрешения восстановленных изображений на основе анализа модуляционной передаточной функции системы. Подход, схожий с созданием КГ 3D сцен, был применен для синтеза голограмм цветных сцен [84]. Для создания голограмм использовались три объектных плоскости, каждая из которых соответствовала одному из цветовых каналов. Обученная модель достигла высокого качества восстановленных изображений: коэффициент корреляции составил 98,9%.

В подобных методах требовалось предварительное создание набора голограмм для обучения НС, т.е. парное обучение (с учителем). В случае непарного обучения (без учителя) не требуется заранее создавать набор исходных данных с применением существующих методов. Примерами работ, использующих непарное обучение, являются [13, 16, 18, 22–23, 49, 52–53]. В этих работах обучение НС происходит только с использованием наборов сечений 3D сцен, относительно которых в процессе обучения происходит расчет голограмм. Функция потерь в таком случае рассчитывается относительно изображений, восстановленных из голограмм, синтезируемых НС в процессе обучения. Например, были использованы две НС: одна используется для синтеза КГ и вторая — для моделирования расчета распространения излучения при восстановлении изображений с этих голограмм [52]. Модель показала свою эффективность при синтезе голограмм с разрешением 4К. Альтернативный подход был рассмотрен в работе [53], где использовались три НС: одна — для первичного синтеза комплексного поля на необходимом расстоянии и две последующие — для параллельного из-

влечения фазовой информации из компонент комплексного поля.

В рассмотренных методах использовался подход, заключающийся в формировании объемной сцены из набора 2D сечений. Альтернативным подходом к созданию КГ 3D сцен является использование 2D изображений, которые содержат информацию о глубине сцены (RGB-D изображений) [47–48, 50]. Такой подход позволяет эффективно создавать протяженные сцены с ощущением объема, поскольку разные части изображения фокусируются на разном расстоянии. Поскольку RGB-D изображения не требуют расчета множества сечений, то с их помощью можно получать КГ 3D сцены значительно быстрее, чем с помощью рассмотренных ранее методов. Так, в работе [50] создана модель, основанная на архитектуре ResNet, способная синтезировать ДОЭ с разрешением 1920×1080 пикселей с частотой 60 Гц. Для обучения использовались 4000 пар RGB-D изображений и соответствующих им голограмм.

Наибольшее на текущий момент разрешение было достигнуто в работах [17, 52], в которых были продемонстрированы модели, способные синтезировать ДОЭ с разрешением 3840×2160 пикселей в реальном времени.

3.6. Оптико-цифровой синтез голограмм

Качество оптического восстановления объектов всегда будет хуже, чем при численном моделировании. Это происходит за счет влияния факторов, возникающих в реальных оптических установках, таких как паразитное отражение от оптических компонентов, оптические aberrации, неравномерности освещенности и расположения компонентов и др. Более тонкий учет параметров конкретной экспериментальной установки может улучшить качество восстановления, однако это значительно усложняет процесс моделирования и расчета.

Для компенсации влияния данных факторов были разработаны оптико-цифровые методы синтеза КГ и ДОЭ, основанные на машинном обучении [15, 56–59]. Нейросетевой оптико-цифровой синтез обеспечивает возможность автоматической калибровки восстановления светового распределения за счет учета свойств оптической системы при обучении НС. Принципиальная схема обучения подобна схемам, использованным в работах [13, 49].

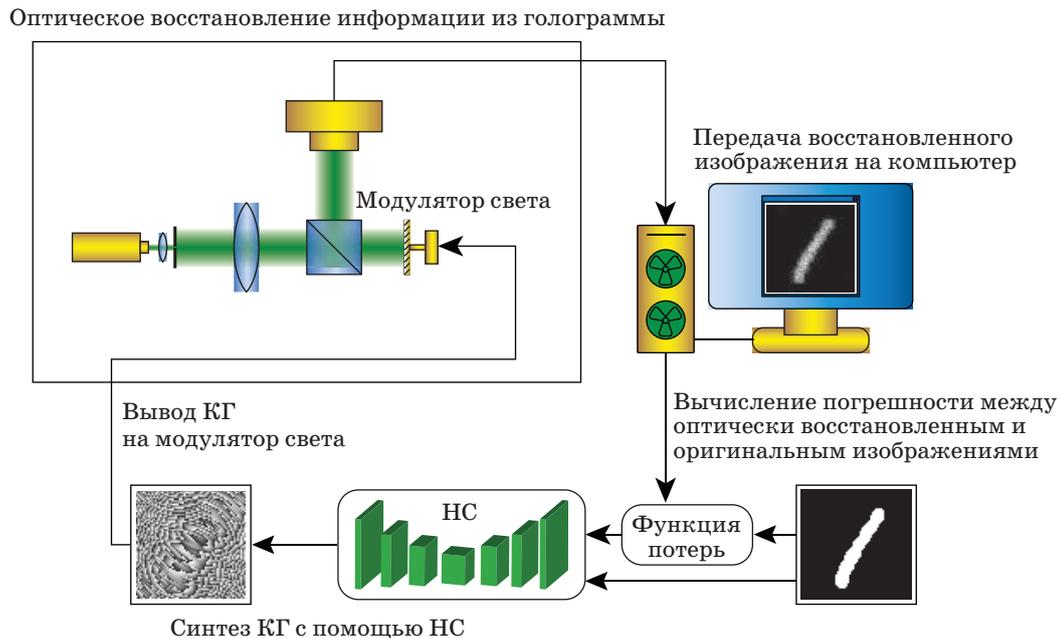


Рис. 8. Схема оптико-цифрового синтеза КГ на основе метода «*Camera-in-the-loop*»

Fig. 8. Computer hologram generation based on the “*Camera-in-the-loop*” approach

Однако в отличие от них, расчет функции потерь проводится относительно изображений, восстановленных в реальной оптической системе, после отображения синтезированных НС голограмм на пространственно-временные модуляторы света. Схема метода представлена на рис. 8. Данный подход, названный «*camera-in-the-loop*», имеет широкие возможности применения: например, снижение уровня спекл-шума в голографическом дисплее [57, 85] или повышение его яркости [59].

3.7. Некоторые другие задачи в области голографии

Нейросетевые методы в голографии развиваются и для решения других задач. Например, в работах [69, 80] удалось качественно выполнить компенсацию аберраций с использованием НС U-Net. В работе [86] полученное НС расстояние было верно определено с погрешностью до 1,2 мкм, посредством чего была выполнена автофокусировка. В работе [87] генеративная НС была использована для подавления спекл-шумов, с чем она справилась более эффективно, чем другие методы. В работе [88] НС позволила сжимать КГ, рассматривая центральные и периферийные области. В случае внеосевой схемы записи голограмм

существенной проблемой является нулевой порядок дифракции. В работе [89] ГСМ НС используется для фильтрации нулевого порядка дифракции в схеме с внеосевой записью голограмм, чтобы улучшить качество восстановленного изображения. Некогерентная голография с использованием НС [33, 90] имеет значительные перспективы в области создания систем на основе голографических дисплеев. Например, модель DeepНС [90] позволяет фильтровать шум зарегистрированных голограмм в некогерентном свете.

ЗАКЛЮЧЕНИЕ

Таким образом, как можно видеть, применение нейросетевых методов уже внесло значительный вклад в развитие цифровой и компьютерной голографии. Применение архитектур, таких как U-Net, ResNet и ГСМ НС, демонстрирует значительный потенциал улучшения качества и точности как синтеза голограмм, так и восстановления световых распределений с них. Одной из важных для практики областей является быстрое и качественное восстановление амплитуды и фазы голографически зарегистрированных комплексных полей. Эта возможность, несомненно, имеет значение в тех

сферах применения, где точность полученных изображений играет важную роль, например, в исследовании клеток и биологических тканей. Нейросетевая классификация объектов в сценах, формируемых голографическими методами, может значительно упростить анализ и интерпретацию данных, что позволит перейти к повышению эффективности автоматизации процессов во многих областях. Восстановление всей 3D сцены и приведение фазы волны к абсолютному значению предоставляют большой потенциал для улучшения визуализации и анализа сложных объектов и динамических процессов. Эти задачи подчас являются ключевыми в научных и инженерных исследованиях, а также при разработке новых методов виртуальной и дополненной реальности, например, при создании голографических дисплеев. Синтез КГ и ДОЭ расширяет возможности для более качественного оптиче-

ского формирования 3D изображений, в задачах фотостимуляции нейронов, при создании оптических пинцетов и др.

В целом, НС представляют собой мощный инструмент для голографии. Основными преимуществами применения нейросетевых методов в голографических задачах являются возможность существенного сокращения времени синтеза КГ и ДОЭ, существенное сокращение времени восстановления распределений интенсивности и фазы в ЦГ, а также увеличение доли «полезной» информации в формируемых и/или анализируемых световых распределениях. Дальнейшие исследования в этой области, по мнению авторов, будут направлены на снижение сложности и/или времени обучения НС, развитие непарного обучения, расширение возможности применения нейросетевых методов на более широкий класс объектов и задач.

СПИСОК ИСТОЧНИКОВ

1. Pi D., Liu J., Wang Y. Review of computer-generated hologram algorithms for color dynamic holographic three-dimensional display // *Light Sci. Appl.* 2022. V. 11. P. 231. <https://doi.org/10.1038/s41377-022-00916-3>
2. Ouyang W., Xu X., Lu W., et al. Ultrafast 3D nanofabrication via digital holography // *Nat. Commun.* 2023. V. 14. P. 1716. <https://doi.org/10.1038/s41467-023-37163-y>
3. Dorrah A.H., Bordoloi P., de Angelis V.S., et al. Light sheets for continuous-depth holography and three-dimensional volumetric displays // *Nat. Photon.* 2023. V. 17. P. 427–434. <https://doi.org/10.1038/s41566-023-01188-y>
4. Situ G. Deep holography // *Light: Advanced Manufacturing.* 2022. V. 3. № 2. P. 278–300. <https://doi.org/10.37188/lam.2022.013>
5. Zeng T., Zhu Y., Lam E.Y. Deep learning for digital holography: A review // *Opt. Exp.* 2021. V. 29. № 24. P. 40572–40593. <https://doi.org/10.1364/oe.443367>
6. Rivenson Y., Zhang Y., Günaydin H., et al. Phase recovery and holographic image reconstruction using deep learning in neural networks // *Light Sci. Appl.* 2018. V. 7. № 2. P. 17141. <https://doi.org/10.1038/lsa.2017.141>
7. Chen H., Huang L., Liu T., et al. Fourier imager Network (FIN): A deep neural network for hologram reconstruction with superior external generalization // *Light Sci. Appl.* 2022. V. 11. P. 254. <https://doi.org/10.1038/s41377-022-00949-8>
8. Рымов Д.А., Черёмхин П.А., Стариков Р.С. Нейросетевая реконструкция сцен с цифровых голограмм на основе извлечения амплитуды и фазы // *Оптический журнал.* 2022. Т. 89. № 9. С. 11–19. <https://doi.org/10.17586/1023-5086-2022-89-09-11-19>
Rymov D.A., Starikov R.S., Cheremkhin P.A. Neural-network-enabled holographic image reconstruction via amplitude and phase extraction // *J. Opt. Technol.* 2022. V. 89. № 9. P. 511–516. <https://doi.org/10.1364/JOT.89.000511>
9. Ju Y.-G., Choo H.-G., Park J.-H. Learning-based complex field recovery from digital hologram with various depth objects // *Opt. Exp.* 2022. V. 30. № 15. P. 26149–26168. <https://doi.org/10.1364/oe.461782>
10. Shao S., Mallery K., Kumar. S.S., et al. Machine learning holography for 3D particle field imaging // *Opt. Exp.* 2020. V. 28. № 3. P. 2987–2999. <https://doi.org/10.1364/oe.379480>
11. Wu Y., Wu J., Jin. S., et al. Dense-U-net: Dense encoder-decoder network for holographic imaging of 3D particle fields // *Opt. Commun.* 2021. V. 493. P. 126970. <https://doi.org/10.1016/j.optcom.2021.126970>
12. Svistunov A.S., Rymov D.A., Starikov R.S., et al. HoloForkNet: Digital hologram reconstruction via multi-branch neural network // *Appl. Sci.* 2023. V. 13. № 10. P. 6125. <https://doi.org/10.3390/app13106125>
13. Eybposh M.H., Caira N.W., Atisa M., et al. DeepCGH: 3D computer-generated holography using deep learning // *Opt. Exp.* 2020. V. 28. № 18. P. 26636–26650. <https://doi.org/10.1364/OE.399624>
14. Ishii Y., Shimobaba T., Blinder D., et al. Optimization of phase-only holograms calculated with scaled diffraction calculation through deep neural networks // *Appl. Phys. B.* 2022. V. 128. P. 22. <https://doi.org/10.1007/s00340-022-07753-7>
15. Kadis A., Mouthaan R., Dong D., et al. Binary-phase computer-generated holography using hardware-in-the-loop feedback // *OSA Imaging and App. Opt. Congress 2021 (3D, COSI, DH, ISA, pcAOP).* Washington, DC United States. July 19–23, 2021. P. DW5E.1. <https://doi.org/10.1364/DH.2021.DW5E.1>
16. Yu G., Wang J., Yang H., et al. Asymmetrical neural network for real-time and high-quality computer-generated holography // *Opt. Lett.* 2023. V. 48. № 20. P. 5351–5354. <https://doi.org/10.1364/OL.497518>

17. Zhong C., Sang X., Yan B., et al. Real-time high-quality computer-generated hologram using complex-valued convolutional neural network // *IEEE Trans. Vis. Comput. Graph.* 2023. P. 1–11. <https://doi.org/10.1109/TVCG.2023.3239670>
18. Zheng H., Peng J., Wang Z., et al. Diffraction model-driven neural network trained using hybrid domain loss for real-time and high-quality computer-generated holography // *Opt. Exp.* 2023. V. 31. № 12. P. 19931–19944. <https://doi.org/10.1364/OE.492129>
19. Delli P.M., Memmo P., Ciaparrone G., et al. Neuroblastoma cells classification through learning approaches by direct analysis of digital holograms // *IEEE Sel. Top. Quantum Electron.* 2021. V. 27. № 5. P. 1–9. <https://doi.org/10.1109/JSTQE.2021.3059532>
20. Dudaie M., Barnea I., Nissim N., et al. On-chip label-free cell classification based directly on off-axis holograms and spatial-frequency-invariant deep learning // *Sci. Rep.* 2023. V. 13. № 1. P. 12370. <https://doi.org/10.1038/s41598-023-38160-3>
21. Castaneda R., Trujillo C., Doblaz A. Video-rate quantitative phase imaging using a digital holographic microscope and a generative adversarial network // *Sensors.* 2021. V. 21. № 23. P. 8021. <https://doi.org/10.3390/s21238021>
22. Huang L., Liu T., Yang X., et al. Holographic image reconstruction with phase recovery and autofocusing using recurrent neural networks // *ACS Photonics.* 2021. V. 8. № 6. P. 1763–1774. <https://doi.org/10.1021/acsp Photonics.1c00337>
23. Zeng T., So H.K.-H., Lam E.Y. RedCap: Residual encoder-decoder capsule network for holographic image reconstruction // *Opt. Exp.* 2020. V. 28. № 4. P. 4876–4887. <https://doi.org/10.1364/oe.383350>
24. Di J., Wu J., Wang K., et al. Quantitative phase imaging using deep learning-based holographic microscope // *Front. Phys.* 2021. V. 9. P. 651313. <https://doi.org/10.3389/fphy.2021.651313>
25. Wang H., Lyu M., Situ G. eHoloNet: A learning-based end-to-end approach for in-line digital holographic reconstruction // *Opt. Exp.* 2018. V. 26. № 18. P. 22603–22614. <https://doi.org/10.1364/oe.26.022603>
26. Wang K., Song L., Wang C., et al. On the use of deep learning for phase recovery // *arXiv.* 2023. P. 2308.00942. <https://doi.org/10.48550/arXiv.2308.00942>
27. Yin D., Gu Z., Zhang Y., et al. Digital holographic reconstruction based on deep learning framework with unpaired data // *IEEE Photonics J.* 2020. V. 12. № 2. P. 1–12. <https://doi.org/10.1109/JPHOT.2019.2961137>
28. Wang S., Jiang X., Guo H., et al. Improved SNR and super-resolution reconstruction of multi-scale digital holography based on deep learning // *Opt. Commun.* 2023. V. 545. № 4. P. 129634. <https://doi.org/10.1016/j.optcom.2023.129634>
29. Wu Y., Luo Y., Chaudhari G., et al. Bright-field holography: Cross-modality deep learning enables snapshot 3D imaging with bright-field contrast using a single hologram // *Light Sci. Appl.* 2019. V. 8. № 1. P. 25. <https://doi.org/10.1038/s41377-019-0139-9>
30. Jaferzadeh K., Fevens T. HoloPhaseNet: Fully automated deep-learning-based hologram reconstruction using a conditional generative adversarial model // *Biomed. Opt. Exp.* 2022. V. 13. № 7. P. 4032–4046. <https://doi.org/10.1364/boe.452645>
31. Niknam F., Qazvini H., Latifi H. Holographic optical field recovery using a regularized untrained deep decoder network // *Sci. Rep.* 2021. V. 11. № 1. P. 10903. <https://doi.org/10.1038/s41598-021-90312-5>
32. Zhang Y., Andreas M.N., Vagovic P., et al. PhaseGAN: A deep-learning phase-retrieval approach for unpaired datasets // *Opt. Exp.* 2021. V. 29. № 13. P. 19593–19604. <https://doi.org/10.1364/oe.423222>
33. Horisaki R., Fujii K., Tanida J. Single-shot and lensless complex-amplitude imaging with incoherent light based on machine learning // *Opt. Rev.* 2018. V. 25. № 5. P. 593–597. <https://doi.org/10.1007/s10043-018-0452-1>
34. Xu Z., Zuo S., Lam E.Y. End-to-end learning for digital hologram reconstruction // *High-Speed Biomedical Imaging and Spectroscopy III: Toward Big Data Instrumentation and Management.* San Francisco, United States. January 27 – February 1, 2018. P. 36. <https://doi.org/10.1117/12.2288141>
35. Chen B., Li Z., Zhou Y., et al. Deep-learning multiscale digital holographic intensity and phase reconstruction // *Appl. Sci.* 2023. V. 13. № 17. P. 9806. <https://doi.org/10.3390/app13179806>
36. Li H., Chen X., Chi Z., et al. Deep DIH: Single-shot digital in-line holography reconstruction by deep learning // *IEEE Access.* 2020. V. 8. P. 202648–202659. <https://doi.org/10.1109/ACCESS.2020.3036380>
37. Chen X., Wang H., Razi A., et al. DH-GAN: A physics-driven untrained generative adversarial network for holographic imaging // *Opt. Exp.* 2023. V. 31. P. 10114–10135. <https://doi.org/10.1364/OE.480894>
38. Wang K., Kemao Q., Di J., et al. Y4-Net: A deep learning solution to one-shot dual-wavelength digital holographic reconstruction // *Opt. Lett.* 2020. V. 45. № 15. P. 4220. <https://doi.org/10.1364/ol.395445>
39. Wang K., Dou J., Kemao Q., et al. Y-Net: A one-to-two deep learning framework for digital holographic reconstruction // *Opt. Lett.* 2019. V. 44. № 19. P. 4765–4768. <https://doi.org/10.1364/ol.44.004765>
40. Shimobaba T., Takahashi T., Yamamoto Y., et al. Digital holographic particle volume reconstruction using a deep neural network // *Appl. Opt.* 2019. V. 58. № 8. P. 1900–1906. <https://doi.org/10.1364/AO.58.001900>
41. Shao S., Mallery K., Hong J. Machine learning holography for measuring 3D particle distribution // *Chem. Eng. Sci.* 2020. V. 225. P. 115830. <https://doi.org/10.1016/j.ces.2020.115830>
42. Horisaki R., Takagi R., Tanida J. Deep-learning-generated holography // *Appl. Opt.* 2018. V. 57. № 14. P. 3859–3863. <https://doi.org/10.1364/AO.57.003859>
43. Lee J., Jeong J., Cho J., et al. Deep neural network for multi-depth hologram generation and its training strategy // *Opt. Exp.* 2020. V. 28. № 18. P. 27137–27154. <https://doi.org/10.1364/OE.402317>
44. Zheng H., Hu J., Zhou C., et al. Computing 3D phase-type holograms based on deep learning method // *Photonics.* 2021. V. 8. № 7. P. 280. <https://doi.org/10.3390/photonics8070280>
45. Khan A., Zhijiang Z., Yu Y., et al. GAN-Holo: Generative adversarial networks-based generated holography using deep learning // *Complexity.* 2021. V. 2021. P. 1–7. <https://doi.org/10.1155/2021/6662161>
46. Zhu R., Chen L., Zhang H. Computer holography using deep neural network with Fourier basis // *Opt. Lett.* 2023. V. 48. № 9. P. 2333–2336. <https://doi.org/10.1364/OL.486255>
47. Yang D., Seo W., Yu H., et al. Diffraction-engineered holography: Beyond the depth representation limit of holographic displays // *Nat. Commun.* 2022. V. 13. № 1. P. 6012. <https://doi.org/10.1038/s41467-022-33728-5>

48. Shi L., Li B., Matusik W. End-to-end learning of 3D phase-only holograms for holographic display // *Light Sci. Appl.* 2022. V. 11. № 1. P. 247. <https://doi.org/10.1038/s41377-022-00894-6>
49. Horisaki R., Nishizaki Y., Kitaguchi K., et al. Three-dimensional deeply generated holography // *Appl. Opt.* 2021. V. 60. № 4. P. A323–A328. <https://doi.org/10.1364/AO.404151>
50. Shi L., Li B., Kim C., et al. Towards real-time photo-realistic 3D holography with deep neural networks // *Nature*. 2021. V. 591. № 7849. P. 234–239. <https://doi.org/10.1038/s41586-020-03152-0>
51. Dong Z., Xu C., Ling Y., et al. Fourier-inspired neural module for real-time and high-fidelity computer-generated holography // *Opt. Lett.* 2023. V. 48. № 3. P. 759–762. <https://doi.org/10.1364/OL.477630>
52. Liu K., Wu J., He Z., et al. 4K-DMDNet: Diffraction model-driven network for 4K computer-generated holography // *Opto-Electronic Adv.* 2023. V. 6. № 5. P. 220135 <https://doi.org/10.29026/oea.2023.220135>
53. Liu Q., Chen J., Qiu B., et al. DCPNet: A dual-channel parallel deep neural network for high quality computer-generated holography // *Opt. Exp.* 2023. V. 31. № 22. P. 35908–35921. <https://doi.org/10.1364/OE.502503>
54. Sun F., Zhu L., Wang W., et al. Three-dimensional dynamic optical trapping using non-iterative computer-generated holography // *Opt. Lasers Eng.* 2023. V. 164. P. 107500. <https://doi.org/10.1016/j.optlaseng.2023.107500>
55. Faini G., Tanese D., Molinier C., et al. Ultrafast light targeting for high-throughput precise control of neuronal networks // *Nat. Commun.* 2023. V. 14. № 1. P. 1888. <https://doi.org/10.1038/s41467-023-37416-w>
56. Peng Y., Choi S., Padmanaban N., et al. Neural holography with camera-in-the-loop training // *ACM Trans. Graph.* 2020. V. 39. № 6. P. 1–14. <https://doi.org/10.1145/3414685.3417802>
57. Peng Y., Choi S., Kim J., et al. Speckle-free holography with partially coherent light sources and camera-in-the-loop calibration // *Sci. Adv.* 2021. V. 7. № 46. P. eabg5040. <https://doi.org/10.1126/sciadv.abg5040>
58. Gopakumar M., Kim J., Choi S., et al. Unfiltered holography: Optimizing high diffraction orders without optical filtering for compact holographic displays // *Opt. Lett.* 2021. V. 46. № 23. P. 5822–5825. <https://doi.org/10.1364/OL.442851>
59. Chao B., Gopakumar M., Choi S., et al. High-brightness holographic projection // *Opt. Lett.* 2023. V. 48. № 15. P. 4041–4044. <https://doi.org/10.1364/OL.489617>
60. Pavillon N., Sekhar C.S., Kühn J., et al. Suppression of the zero-order term in off-axis digital holography through nonlinear filtering // *Appl. Opt.* 2009. V. 48. № 34. P. H186–H195. <https://doi.org/10.1364/AO.48.00H186>
61. Bianco V., Memmolo P., Leo M., et al. Strategies for reducing speckle noise in digital holography // *Light Sci. Appl.* 2018. V. 7. № 1. P. 48. <https://doi.org/10.1038/s41377-018-0050-9>
62. Cheremkhin P.A., Evtikhiev N.N., Krasnov V.V., et al. Shot noise and fixed-pattern noise effects on digital hologram reconstruction // *Opt. Lasers Eng.* 2021. V. 139. P. 106461. <https://doi.org/10.1016/j.optlaseng.2020.106461>
63. Leith E.N., Upatnieks J. Wavefront reconstruction with diffused illumination and three-dimensional objects // *JOSA.* 1964. V. 54. № 11. P. 1295–1301. <https://doi.org/10.1364/JOSA.54.001295>
64. Yamaguchi I., Zhang T. Phase-shifting digital holography // *Opt. Lett.* 1997. V. 22. № 16. P. 1268–1270. <https://doi.org/10.1364/OL.22.001268>
65. Momey F., Denis L., Olivier T., et al. From Fienup's phase retrieval techniques to regularized inversion for in-line holography: Tutorial // *JOSA. A.* 2019. V. 36. № 12. P. D62–D80. <https://doi.org/10.1364/JOSAA.36.000D62>
66. Gerchberg R.W., Saxton W.O. A practical algorithm for the determination of phase from image and diffraction plane pictures // *Optik.* 1971. V. 2. P. 237–246.
67. Ding B., Qian H., Zhou J. Activation functions and their characteristics in deep neural networks // 2018 Chinese Control and Decision Conf. (CCDC). Shenyang, China. June 9–11, 2018. P. 1836–1841. <https://doi.org/10.1109/CCDC.2018.8407425>
68. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional networks for biomedical image segmentation // *Lecture Notes in Computer Sci.* 2015. V. 9351. P. 234–241. https://doi.org/10.1007/978-3-319-24574-4_28
69. Nguyen T., Bui V., Lam V., et al. Automatic phase aberration compensation for digital holographic microscopy based on deep learning background detection // *Opt. Exp.* 2017. V. 25. № 13. P. 15043–15057. <https://doi.org/10.1364/oe.25.015043>
70. Wang K., Li Y., Kemao Q., et al. One-step robust deep learning phase unwrapping // *Opt. Exp.* 2019. V. 27. № 10. P. 15100–15115. <https://doi.org/10.1364/oe.27.015100>
71. He K., Zhang X., Ren S., et al. Deep residual learning for image recognition // 2016 IEEE Conf. Computer Vision and Pattern Recognition (CVPR). Las Vegas, United States. June 26 – July 1, 2016. P. 770–778. <https://doi.org/10.1109/CVPR.2016.90>
72. Pan X., Tewari A., Leimkühler T., et al. Drag your GAN: Interactive point-based manipulation on the generative image manifold // *Special Interest Group on Computer Graphics and Interactive Techniques Conf. Conf. Proc. Los Angeles, United States. August 6–10, 2023. P. 1–11. https://doi.org/10.1145/3588432.3591500*
73. Terbe D., Orzó L., Zarándy Á. Classification of holograms with 3D-CNN // *Sensors.* 2022. V. 22. № 21. P. 8366. <https://doi.org/10.3390/s22218366>
74. Huang L., Chen H., Liu T., et al. Self-supervised learning of hologram reconstruction using physics consistency // *Nat. Mach. Intell.* 2023. V. 5. № 8. P. 895–907. <https://doi.org/10.1038/s42256-023-00704-7>
75. Lu Z., Cao Y., Liu M., et al. Image-to-image translation for improved digital holographic reconstruction based on a generative adversarial network learning framework // *Opt. Laser Technol.* 2023. V. 166. P. 109654. <https://doi.org/10.1016/j.optlastec.2023.109654>
76. Chen H., Huang L., Liu T., et al. EFIN: Enhanced Fourier imager network for generalizable autofocusing and pixel super-resolution in holographic imaging // *IEEE Sel. Top. Quantum Electron.* 2023. V. 29. № 4. P. 1–10. <https://doi.org/10.1109/JSTQE.2023.3248684>
77. Verrier N., Atlan M. Off-axis digital hologram reconstruction: Some practical considerations // *Appl. Opt.* 2011. V. 50. № 34. P. H136–H146. <https://doi.org/10.1364/AO.50.00H136>
78. Ren Z., Xu Z., Lam E.Y. End-to-end deep learning framework for digital holographic reconstruction // *Advanced Photonics.* 2019. V. 1. № 1. P. 016004. <https://doi.org/10.1117/1.AP.1.1.016004>
79. Park S., Kim Y., Moon I. Automated phase unwrapping in digital holography with deep learning // *Biomed.*

- Opt. Exp. 2021. V. 12. № 11. P. 7064–7081. <https://doi.org/10.1364/boe.440338>
80. Park S., Kim Y., Moon I. Fast automated quantitative phase reconstruction in digital holography with unsupervised deep learning // Opt. Lasers Eng. 2023. V. 167. P. 107624. <https://doi.org/10.1016/j.optlaseng.2023.107624>
81. Huang L., Tang J., Yan L., et al. Wrapped phase aberration compensation using deep learning in digital holographic microscopy // Appl. Phys. Lett. 2023. V. 123. № 14. P. 141109. <https://doi.org/10.1063/5.0166210>
82. Zhang Y., Lu Y., Wang H., et al. Automatic classification of marine plankton with digital holography using convolutional neural network // Opt. Laser Technol. 2021. V. 139. P. 106979. <https://doi.org/10.1016/j.optlastec.2021.106979>
83. Kim S.-J., Wang C., Zhao B., et al. Deep transfer learning-based hologram classification for molecular diagnostics // Sci. Rep. 2018. V. 8. № 1. P. 17003. <https://doi.org/10.1038/s41598-018-35274-x>
84. Yolalmaz A., Yüce E. Comprehensive deep learning model for 3D color holography // Sci. Rep. 2022. V. 12. № 1. P. 2487. <https://doi.org/10.1038/s41598-022-06190-y>
85. Chen L., Zhu R., Zhang H. Speckle-free compact holographic near-eye display using camera-in-the-loop optimization with phase constraint // Opt. Exp. 2022. V. 30. № 26. P. 46649–46665. <https://doi.org/10.1364/OE.475066>
86. Cuenat S., Andréoli L., André A.N., et al. Fast autofocusing using tiny transformer networks for digital holographic microscopy // Opt. Exp. 2022. V. 30. № 14. P. 24730–24746. <https://doi.org/10.1364/OE.458948>
87. Fang Q., Xia H., Song Q., et al. Speckle denoising based on deep learning via a conditional generative adversarial network in digital holographic interferometry // Opt. Exp. 2022. V. 30. № 12. P. 20666–20683. <https://doi.org/10.1364/oe.459213>
88. Dong Z., Ling Y., Xu C., et al. Gaze-contingent efficient hologram compression for foveated near-eye holographic displays // Displays. 2023. V. 79. P. 102464. <https://doi.org/10.1016/j.displa.2023.102464>
89. Wang H., Li K., Jiang X., et al. Zero-order term suppression in off-axis holography based on deep learning method // Opt. Commun. 2023. V. 537. P. 129264. <https://doi.org/10.1016/j.optcom.2023.129264>
90. Yu H., Kim Y., Yang D., et al. Deep learning-based incoherent holographic camera enabling acquisition of real-world holograms for holographic streaming system // Nat. Commun. 2023. V. 14. № 1. P. 3534. <https://doi.org/10.1038/s41467-023-39329-0>

АВТОРЫ

Павел Аркадьевич Черёмхин — кандидат физико-математических наук, доцент, Национальный исследовательский ядерный университет «МИФИ», Москва, 115409, Россия; <https://orcid.org/0000-0003-3556-2663>; Scopus ID: 57191415216; cheremhinpavel@mail.ru

Дмитрий Андреевич Рымов — аспирант, Национальный исследовательский ядерный университет «МИФИ», Москва, 115409, Россия; <https://orcid.org/0000-0003-0914-9736>; Scopus ID: 57216746156; rymov.d.a@gmail.com

Андрей Сергеевич Свистунов — студент, Национальный исследовательский ядерный университет «МИФИ», Москва, 115409, Россия; <https://orcid.org/0009-0004-5455-9181>; Scopus ID: 58294940000; svistunov.andrey.sergeevich@gmail.com

Евгений Юрьевич Злоказов — доктор физико-математических наук, профессор Национального исследовательского ядерного университета «МИФИ», Москва, 115409, Россия; <https://orcid.org/0000-0003-1340-7734>; Scopus ID: 16320289100; ezlokazov@gmail.com

Ростислав Сергеевич Стариков — доктор физико-математических наук, профессор Национального исследовательского ядерного университета «МИФИ», Москва, 115409, Россия; <https://orcid.org/0000-0002-7369-1565>; Scopus ID: 6602213431; rstarikov@mail.ru

AUTHORS

Pavel A. Cheremkhin — PhD (Physics and Mathematics), Associate Professor, National Research Nuclear University MEPHI (Moscow Engineering Physics Institute), Moscow, 115409, Russia; <https://orcid.org/0000-0003-3556-2663>; Scopus ID: 57191415216; cheremhinpavel@mail.ru

Dmitry A. Rymov — PhD Student, National Research Nuclear University MEPHI (Moscow Engineering Physics Institute), Moscow, 115409, Russia; <https://orcid.org/0000-0003-0914-9736>; Scopus ID: 57216746156; rymov.d.a@gmail.com

Andrey S. Svistunov — Student, National Research Nuclear University MEPHI (Moscow Engineering Physics Institute), Moscow, 115409, Russia; <https://orcid.org/0009-0004-5455-9181>; Scopus ID: 58294940000; svistunov.andrey.sergeevich@gmail.com

Evgenii Yu. Zlokazov — Dr. Sci. (Physics and Mathematics), Professor, National Research Nuclear University MEPHI (Moscow Engineering Physics Institute), Moscow, 115409, Russia; <https://orcid.org/0000-0003-1340-7734>; Scopus ID: 16320289100; ezlokazov@gmail.com

Rostislav S. Starikov — Dr. Sci. (Physics and Mathematics), Professor, National Research Nuclear University MEPHI (Moscow Engineering Physics Institute), Moscow, 115409, Russia; <https://orcid.org/0000-0002-7369-1565>; Scopus ID: 6602213431; rstarikov@mail.ru

Статья поступила в редакцию 24.10.2023
Одобрена после рецензирования 08.12.2023
Принята к печати 28.01.2024

The article was submitted to the editorial office 24.10.2023
Approved after review 08.12.2023
Accepted for publication 28.01.2024