

Оптическая классификация изображений на различных длинах волн с использованием спектральных дифракционных нейронных сетей

Г.А. Мотз^{1,2}, Д.В. Сошников^{1,2}, Л.Л. Досколович^{1,2}, Е.В. Бызов^{1,2}, Е.А. Безус^{1,2}, Д.А. Быков^{1,2}

¹ Институт систем обработки изображений, НИЦ «Курчатовский институт»,
443001, Россия, г. Самара, ул. Молодогвардейская, д. 151;

² Самарский национальный исследовательский университет имени академика С.П. Королёва,
443086, Россия, г. Самара, Московское шоссе, д. 34

Аннотация

Предложен метод расчета дифракционной нейронной сети (ДНС) для решения различных задач классификации изображений на различных длинах волн. В рамках метода задача расчета ДНС формулируется как задача минимизации функционала, зависящего от функций высот микрорельефа дифракционных оптических элементов, образующих ДНС, и представляющего ошибку решения заданных задач классификации на расчетных длинах волн. Для производных функционала получены явные выражения, и на этой основе сформулирован градиентный метод расчета дифракционной нейронной сети. С использованием предложенного градиентного метода рассчитаны ДНС для решения трех различных задач классификации изображений на трех длинах волн. Представленные результаты моделирования работы рассчитанных ДНС демонстрируют хорошие рабочие характеристики предложенного метода.

Ключевые слова: задача классификации изображений, дифракционная нейронная сеть, каскадный дифракционный оптический элемент, дифракционный микрорельеф, скалярная теория дифракции, оптимизация, градиентный метод.

Цитирование: Мотз, Г.А. Оптическая классификация изображений на различных длинах волн с использованием спектральных дифракционных нейронных сетей/ Г.А. Мотз, Д.В. Сошников, Л.Л. Досколович, Е.В. Бызов, Е.А. Безус, Д.А. Быков // Компьютерная оптика. – 2025. – Т. 49, № 2. – С. 187-199. – DOI: 10.18287/2412-6179-CO-1536.

Citation: Motz GA, Soshnikov DV, Doskolovich LL, Byzov EV, Bezus EA, Bykov DA. Optical classification of images at different wavelengths using spectral diffractive neural networks. *Computer Optics* 2025; 49(2): 187-199. DOI: 10.18287/2412-6179-CO-1536.

Введение

В последние годы наблюдается большой интерес к разработке структур фотоники для оптических вычислений и оптической обработки информации. Указанные структуры рассматриваются в качестве перспективной элементной базы, призванной обеспечить дальнейшее развитие вычислительных систем за счет создания альтернативы электронным компонентам или дополнения к ним [1–4]. В качестве одного из наиболее перспективных и быстро развивающихся направлений в области оптической обработки информации рассматриваются оптические нейронные сети [5–9], и в особенности дифракционные нейронные сети, выполненные в виде каскада последовательно расположенных фазовых дифракционных оптических элементов (ДОЭ) [10–26]. Следует отметить, что ДОЭ (как одиночные, так и каскадные) имеют долгую историю и широко применяются при решении большого класса задач по преобразованию и фокусировке лазерного излучения [27–33]. Кроме того, уже с шестидесятых годов прошлого века ДОЭ применялись в различных задачах оптической обработки информации, включающих распознавание и классификацию объектов методами согласованной фильтрации [34–37]. Новый всплеск интереса к при-

менению ДОЭ для оптического решения задач классификации связан с применением нейросетевого подхода, предложенного в 2018 году в основополагающей работе [10], в которой впервые было продемонстрировано применение каскадных ДОЭ для оптического решения задач машинного обучения. На основе ряда аналогий между каскадом ДОЭ и «обычными» нейронными сетями в указанной статье был предложен термин «дифракционная нейронная сеть» (ДНС) и теоретически и экспериментально продемонстрирована возможность оптического решения задач классификации с помощью каскадных ДОЭ. В последующих работах было рассмотрено применение ДНС (или каскадных ДОЭ) для решения различных задач классификации [11–15, 17, 25, 26], распознавания объектов и видео [13, 15], выделения главного объекта на изображении (англ. salient object detection) [11], имитации функций изображающих систем [22], реализации операций матричного умножения, а также различных математических преобразований, описываемых линейными операторами [12, 18, 20, 21]. В качестве потенциальных преимуществ ДНС перед «обычными» (цифровыми) искусственными нейронными сетями выделяются высокое быстродействие (вычисления выполняются «со скоростью света») и низкое энергопотребление [10, 12, 13].

Основным методом расчета ДНС является стохастический градиентный метод, а также основанные на нем «улучшенные» методы 1-го порядка [38]. Интересно отметить, что указанные методы стали широко применяться и показали свою эффективность и в «традиционных» для ДНОЭ задачах формирования лазерных пучков с заданными характеристиками (англ. beam shaping) [39, 40].

В большинстве работ ДНС рассчитываются для работы с излучением одной заданной длины волны. В то же время большой научный и практический интерес представляет задача расчета ДНС, предназначенных для работы с излучением нескольких различных длин волн. Далее будем называть такие ДНС спектральными ДНС или спектральными каскадными ДНОЭ. Спектральные ДНС могут использоваться для обработки спектральной информации, осуществлять параллельное решение различных задач машинного обучения на различных длинах волн, изменять функциональность (решаемую задачу) в зависимости от длины волны падающего излучения и т.д. В частности, в работах [23, 24] рассмотрен расчет ДНС для спектральной фильтрации и анализа спектрального состава падающего излучения. В работах [21, 22] были рассмотрены спектральные ДНС для оптической реализации различных линейных преобразований на различных длинах волн (каждое преобразование осуществляется на своей длине волны), а также для формирования мультиспектральных изображений. Одной из основных задач, в которой ДНС продемонстрировали высокую эффективность, является задача оптической классификации. Насколько известно авторам настоящей работы, задача расчета спектральных ДНС для решения различных задач классификации на различных длинах волн является недостаточно исследованной в настоящее время. Действительно, несмотря на то, что решение задач классификации с использованием излучения нескольких различных длин волн было рассмотрено в недавних работах [25, 26], излучение различных длин волн в этих работах использовалось только для улучшения качества решения одной фиксированной задачи классификации. При этом решение различных задач классификации на различных длинах волн в [25, 26] не рассматривалось.

В настоящей работе рассмотрен градиентный метод расчета спектральной ДНС (спектрального каскадного ДНОЭ) для решения нескольких различных задач классификации на нескольких различных длинах волн. В рамках метода задача расчета спектральной ДНС сформулирована как задача минимизации функционала, зависящего от функций высот дифракционного микрорельефа каскадного ДНОЭ и представляющего ошибку решения заданных задач классификации на расчетных длинах волн. Для производных функционала ошибки по функциям высот

дифракционного микрорельефа получены явные и компактные выражения. С использованием предложенного градиентного метода рассчитаны спектральные ДНС для решения следующих трех задач: задачи классификации рукописных цифр из базы данных MNIST на длине волны 457 нм, задачи классификации предметов одежды из базы данных Fashion MNIST на длине волны 532 нм и задачи классификации десяти рукописных букв латинского алфавита от А до J (строчных и прописных) из базы данных EMNIST при длине волны 633 нм. Представленные результаты расчета и моделирования спектральных ДНС демонстрируют хорошие рабочие характеристики предложенного метода.

1. Задача расчета спектральных ДНС для решения различных задач классификации

Рассмотрим задачу расчета спектральной ДНС (каскадного ДНОЭ), предназначенной для решения различных задач классификации P_q , $q=1, \dots, Q$ на различных длинах волн λ_q , $q=1, \dots, Q$, так что каждая задача классификации решается на «своей» длине волны. Будем считать, что каскадный ДНОЭ состоит из n фазовых ДНОЭ, расположенных в плоскостях $z=f_1, \dots, z=f_n$ ($0 < f_1 < \dots < f_n$) и задаваемых функциями высоты дифракционного микрорельефа $h_1(\mathbf{u}_1), \dots, h_n(\mathbf{u}_n)$, где $\mathbf{u}_j = (u_j, v_j)$ – декартовы координаты в плоскостях $z=f_1, \dots, z=f_n$ (рис. 1).

Опишем сначала требуемое функционирование ДНС на одной длине волны $\lambda_q \in \{\lambda_1, \dots, \lambda_Q\}$. Будем считать, что во входной плоскости $z=0$ последовательно генерируются амплитудные изображения объектов из N_q различных классов, соответствующих задаче классификации P_q . Каждое сгенерированное изображение освещается плоской волной с длиной волны λ_q . Обозначим $w_{0,q,j}(\mathbf{u}_0)$ комплексную амплитуду сформированного таким образом светового поля во входной плоскости. Здесь и далее нижние индексы u комплексной амплитуды поля $w_{0,q,j}(\mathbf{u}_0)$ обозначают индекс плоскости, в которой она записана, индекс длины волны (или соответствующей ей задачи классификации) и класс сформированного изображения.

Сформированное при $z=0$ световое поле $w_{0,q,j}(\mathbf{u}_0)$ распространяется через каскадный ДНОЭ в выходную плоскость $z=f_{n+1}$. Будем считать, что распространение в свободном пространстве (между ДНОЭ) описывается интегралом Френеля–Кирхгофа скалярной теории дифракции, а прохождение светового поля через ДНОЭ описывается в приближении тонкого оптического элемента как умножение на функцию комплексного пропуска (ФКП) ДНОЭ. ФКП m -го ДНОЭ зависит от длины волны и при длине волны λ_q имеет вид:

$$T_{m,q}(\mathbf{u}_m) = \exp\{i\varphi_{m,q}(\mathbf{u}_m)\} = \exp\{i\gamma_q h_m(\mathbf{u}_m)\}, \quad (1)$$

где $\varphi_{m,q}(\mathbf{u}_m)$ – фазовая функция ДОО (формируемый ДОО фазовый набег) при длине волны λ_q , $\gamma_q = (2\pi/\lambda_q)(n(\lambda_q) - 1)$, $n(\lambda_q)$ – показатель преломления материала ДОО.

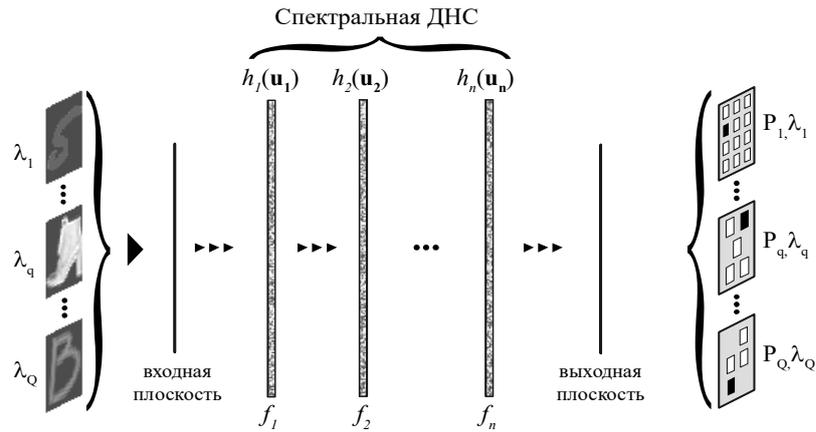


Рис. 1. Геометрия задачи расчета ДНС для решения различных задач классификации на различных длинах волн

При сделанных допущениях распространение входного пучка $w_{0,q,j}(\mathbf{u}_0)$ из начальной плоскости $z=0$ через каскадный ДОО в выходную плоскость $z=f_{n+1}$ описывается следующей рекуррентной формулой, выражающей поле в m -й плоскости $w_{m,q,j}(\mathbf{u}_m)$ через поле в $(m-1)$ -й плоскости $w_{m-1,q,j}(\mathbf{u}_{m-1})$, падающее на ДОО с ФКП $T_{m-1,q}(\mathbf{u}_{m-1})$:

$$w_{m,q,j}(\mathbf{u}_m) = C_{q,m} \iint w_{m-1,q,j}(\mathbf{u}_{m-1}) T_{m-1,q}(\mathbf{u}_{m-1}) \times \exp\left\{i \frac{\pi}{\lambda_q d_m} (\mathbf{u}_m - \mathbf{u}_{m-1})^2\right\} d^2 \mathbf{u}_{m-1}, \quad (2)$$

$m = 1, \dots, n + 1,$

где $C_{q,m} = (i\lambda_q d_m)^{-1} \exp\{i2\pi d_m / \lambda_q\}$, $d_m = f_m - f_{m-1}$ – расстояния между плоскостями. При этом при расчете полей $w_{1,q,j}(\mathbf{u}_1)$, падающих на 1-й ДОО ($m = 1$ в формуле (2)), следует положить $T_{0,q}(\mathbf{u}_0) \equiv 1$.

Будем считать, что в выходной плоскости $z=f_{n+1}$ заданы N_q пространственно разделенных «целевых областей» $G_{q,k}$, $k = 1, \dots, N_q$, соответствующих N_q различным классам задачи P_q . При каждом входном изображении в данных областях формируется некоторое распределение «энергий» $E_{q,k}$, $k = 1, \dots, N_q$, соответствующее интегралам от сформированного распределения интенсивности $I_{n+1,q,j}(\mathbf{u}_{n+1}) = |w_{n+1,q,j}(\mathbf{u}_{n+1})|^2$ по данным областям:

$$E_{q,k} = \iint I_{n+1,q,j}(\mathbf{u}_{n+1}) \chi_{q,k}(\mathbf{u}_{n+1}) d^2 \mathbf{u}_{n+1}, \quad (3)$$

$k = 1, \dots, N_q,$

где $\chi_{q,k}(\mathbf{u}_{n+1})$ – индикаторная функция множества $G_{q,k}$. Для решения задачи классификации P_q требуется, чтобы при «входном сигнале» $w_{0,q,j}(\mathbf{u}_0)$, соответствующем изображению объекта j -го класса, каскадный ДОО формировал такое распределение интенсивности в выходной плоскости, для которого максимум из формируемых энергий $E_{q,k}$, $k = 1, \dots, N_q$ достигается в соответствующей целевой области $G_{q,k}$ [10, 12].

Мы описали требуемое функционирование ДНС на одной длине волны λ_q . Задачу расчета ДНС для

решения различных задач классификации P_q , $q = 1, \dots, Q$ на различных длинах волн λ_q , $q = 1, \dots, Q$ можно сформулировать как задачу расчета таких функций высоты дифракционного микрорельефа $h_1(\mathbf{u}_1), \dots, h_n(\mathbf{u}_n)$ каскадного ДОО, что при любой длине волны $\lambda_q \in \{\lambda_1, \dots, \lambda_Q\}$ и любом входном сигнале, соответствующем изображению объекта задачи P_q , решаемой на данной длине волн, каскадный ДОО обеспечивает формирование светового поля, для которого максимум энергии достигается в целевой области, соответствующей классу входного изображения. Отметим, что в приведенной постановке входные сигналы на различных длинах волн во входной плоскости могут формироваться как последовательно, так и в «параллельном» режиме. В последнем случае мы будем считать, что во входной плоскости формируются одновременно Q входных изображений (полей) на расчетных длинах волн $\lambda_1, \dots, \lambda_Q$.

2. Градиентный метод расчета спектральных ДНС

Для решения описанной задачи расчета каскадного ДОО будем использовать стохастический градиентный метод в «идеологии» нейронных сетей. Приведем сначала общее описание метода. Будем считать, что для расчета (обучения) каскадного ДОО используется обучающая выборка $S = \cup S_q$, состоящая из обучающих выборок S_q для рассматриваемых задач классификации P_q , $q = 1, \dots, Q$. Каждая обучающая выборка S_q содержит набор входных распределений (комплексных амплитуд полей), формируемых из изображений объектов задачи P_q на длине волны λ_q . На каждом шаге метода из обучающей выборки S случайным образом выбирается набор распределений (т.н. батч, от англ. batch), для него рассчитываются производные функционала ошибки $\varepsilon(h_1, \dots, h_n)$, зависящего от функций высот дифракционного микрорельефа и описывающего требуемое (описанное выше) функционирование

ДНС, и далее осуществляется шаг по направлению антиградиента. Поскольку математические ожидания производных, рассчитанных по батчу, пропорциональны производным функционала, рассчитанным по всей выборке, то такой подход соответствует методу стохастического градиента. Без ограничения общности будем считать, что батч соответствует следующему набору входных распределений: $w_{0,q,j}(\mathbf{u}_0)$, $q = 1, \dots, Q$, $j = 1, \dots, N_q$. Таким образом, мы предполагаем, что батч содержит $N_1 + N_2 + \dots + N_Q$ входных распределений и для каждого $q \in \{1, \dots, Q\}$ включает N_q изображений объектов различных классов из обучающей выборки S_q , сформированных на соответствующей ей длине волны λ_q . Для описания вычислений, выполняемых для батча, запишем функционал ошибки в явном виде. Пусть ошибка классификации входного пучка $w_{0,q,j}(\mathbf{u}_0)$, соответствующего объекту j -го класса из задачи P_q , представляется некоторым функционалом ошибки $\varepsilon_{q,j}(h_1, \dots, h_n)$. Поскольку классификация осуществляется на основе анализа распределения энергий $E_{q,k}$ по областям $G_{q,k}$, вычисляемых по формуле (3), то функционал $\varepsilon_{q,j}(h_1, \dots, h_n)$ в общем случае должен иметь вид

$$\varepsilon_{q,j}(h_1, \dots, h_n) = D_{q,j}[E_{q,1}, \dots, E_{q,N_q}], \quad (4)$$

где $D_{q,j}[E_{q,1}, \dots, E_{q,N_q}]$ – некоторая функция, описывающая отклонение формируемого распределения энергий (3) от требуемого распределения, при котором энергия сконцентрирована в требуемой j -й целевой области. Тогда функционал ошибки для батча, содержащего распределения $w_{0,q,j}(\mathbf{u}_0)$, $q = 1, \dots, Q$, $j = 1, \dots, N_q$, можно представить в виде суммы указанных функционалов

$$\varepsilon(h_1, \dots, h_n) = \sum_{q=1}^Q \sum_{j=1}^{N_q} \varepsilon_{q,j}(h_1, \dots, h_n). \quad (5)$$

Для функционала (5) несложно рассчитать производные Фреше $\delta\varepsilon(h_1, \dots, h_n) / \delta h_m$. Действительно, поскольку функционал (5) равен сумме функционалов, то его производные имеют вид

$$\frac{\delta\varepsilon(h_1, \dots, h_n)}{\delta h_m} = \sum_{q=1}^Q \sum_{j=1}^{N_q} \frac{\delta\varepsilon_{q,j}(h_1, \dots, h_n)}{\delta h_m}, \quad (6)$$

$m = 1, \dots, n.$

Вычислим производную $\delta\varepsilon_{q,j} / \delta h_m$ в (6). Для этого запишем приращение функционала $\varepsilon(h_1, \dots, h_n)$, вызванное приращением Δh_m функции высоты микрорельефа h_m m -го ДОЭ:

$$\begin{aligned} \Delta_m \varepsilon_{q,j}(h_1, \dots, h_n) &= \\ &= \varepsilon_{q,j}(h_1, \dots, h_m + \Delta h_m, \dots, h_n) - \varepsilon_{q,j}(h_1, \dots, h_m, \dots, h_n). \end{aligned} \quad (7)$$

Следуя работе [19], данное приращение можно представить в виде следующего скалярного произведения:

$$\begin{aligned} \Delta_m \varepsilon_{q,j}(h_1, \dots, h_n) &= \\ &= 2 \operatorname{Re} \left[\iint (\Delta_m w_{n+1,q,j}(\mathbf{u}_{n+1})) F_{n+1,q,j}^*(\mathbf{u}_{n+1}) d^2 \mathbf{u}_{n+1} \right] = (8) \\ &= 2 \operatorname{Re} \langle \Delta_m w_{n+1,q,j}(\mathbf{u}_{n+1}), F_{n+1,q,j}(\mathbf{u}_{n+1}) \rangle, \end{aligned}$$

где $\Delta_m w_{n+1,q,j}(\mathbf{u}_{n+1})$ – приращение комплексной амплитуды, вызванное приращением высоты Δh_m , угловые скобки обозначают скалярное произведение функций, а функция $F_{n+1,q,j}(\mathbf{u}_{n+1})$ имеет вид

$$F_{n+1,q,j}(\mathbf{u}_{n+1}) = w_{n+1,q,j}(\mathbf{u}_{n+1}) \left(\sum_{k=1}^{N_q} \chi_{q,k}(\mathbf{u}_{n+1}) \frac{\partial D_{q,j}}{\partial E_{q,k}} \right). \quad (9)$$

Отметим, что оператор, описывающий прямое распространение светового поля через набор фазовых ДОЭ (см. формулы (2)), а также оператор обратного распространения поля являются унитарными и сохраняют скалярное произведение [16]. Используя свойство сохранения скалярного произведения, представим приращение (8) функционала ошибки в виде

$$\begin{aligned} \Delta_m \varepsilon_{q,j}(h_1, \dots, h_n) &= \\ &= 2 \operatorname{Re} \langle \operatorname{Pr}_{f_{n+1} \rightarrow f_m^*}(\Delta_m w_{n+1,q,j}), \operatorname{Pr}_{f_{n+1} \rightarrow f_m^*}(F_{n+1,q,j}) \rangle, \end{aligned} \quad (10)$$

где $\operatorname{Pr}_{f_{n+1} \rightarrow f_m^*}$ – оператор обратного распространения поля из выходной плоскости $z = f_{n+1}$ в плоскость $z = f_m^+$, расположенную непосредственно за плоскостью расположения m -го ДОЭ. Отметим, что обратное распространение поля, как и прямое, описывается интегралом Френеля–Кирхгофа (см. формулы (2)). При этом в отличие от прямого распространения расстояние распространения берется со знаком минус, а «обратное прохождение» пучка через фазовый ДОЭ описывается умножением комплексной амплитуды пучка на комплексно-сопряженную ФКП ДОЭ [19]. Заметим, что поскольку $\operatorname{Pr}_{f_{n+1} \rightarrow f_m^*}(\Delta_m w_{n+1,q,j}) = \Delta_m (w_{m,q,j} T_{m,q})$, где $w_{m,q,j}(\mathbf{u}_m) T_{m,q}(\mathbf{u}_m)$ – комплексная амплитуда поля непосредственно за плоскостью m -го ДОЭ при прямом распространении, то приращение (10) может быть преобразовано к виду

$$\begin{aligned} \Delta_m \varepsilon_{q,j}(h_1, \dots, h_n) &= \\ &= 2 \operatorname{Re} \langle \Delta_m (w_{m,q,j} T_{m,q}), F_{m,q,j} \rangle = \\ &= 2 \operatorname{Re} \iint w_{m,q,j}(\mathbf{u}_m) \Delta T_{m,q}(\mathbf{u}_m) F_{m,q,j}^*(\mathbf{u}_m) d^2 \mathbf{u}_m. \end{aligned} \quad (11)$$

Поскольку

$$\begin{aligned} \Delta T_{m,q} &= \exp\{i\gamma_q (h_m + \Delta h_m)\} - \exp\{i\gamma_q h_m\} = \\ &= T_{m,q} i\gamma_q \Delta h_m + o(\Delta h_m), \end{aligned} \quad (12)$$

где $\gamma_q = (2\pi / \lambda_q)(n(\lambda_q) - 1)$, то главная линейная часть приращения (11) может быть записана в виде

$$\begin{aligned} \delta_m \varepsilon_{q,j}(h_1, \dots, h_n) &= -2\gamma_q \iint \Delta h_m(\mathbf{u}_m) \times \\ &\times \operatorname{Im}[w_{m,q,j}(\mathbf{u}_m) T_{m,q}(\mathbf{u}_m) F_{m,q,j}^*(\mathbf{u}_m)] d^2 \mathbf{u}_m = \\ &= -2\gamma_q \langle \Delta h_m, \operatorname{Im}[w_{m,q,j} T_{m,q} F_{m,q,j}^*] \rangle. \end{aligned} \quad (13)$$

Согласно (13), производная Фреше функционала (4) имеет вид

$$\frac{\delta \varepsilon_{q,j}(h_1, \dots, h_n)}{\delta h_m} = -2\gamma_q \operatorname{Im}[w_{m,q,j}(\mathbf{u}_m) T_{m,q}(\mathbf{u}_m) F_{m,q,j}^*(\mathbf{u}_m)]. \quad (14)$$

Таким образом, расчет градиента функционала для батча осуществляется по формулам (6), (14). Отметим, что вместо градиентного метода можно использовать «улучшенные» методы оптимизации 1-го порядка, например, метод адаптивной оценки моментов (англ. Adaptive Moment Estimation, ADAM) [38].

Выше функционал $\varepsilon(h_1, \dots, h_n)$, описывающий ошибку классификации объекта j -го класса в задаче P_q , был представлен в общем виде (4), где $D_{q,j}[E_{q,1}, \dots, E_{q,N_q}]$ – некоторая функция ошибки, зависящая от распределения энергий (3), формируемых при функциях h_1, \dots, h_n . Рассмотрим пример конкретного вида функционала. Для классификации входного изображения j -го класса необходимо, чтобы энергия $E_{q,j}$ в требуемой области $G_{q,j}$ имела «большое» значение E_{\max} , а энергии в остальных областях были близки к нулю. Соответственно, в качестве функционала ошибки для распознавания входного распределения j -го класса можно, например, использовать следующий квадратичный функционал [19]:

$$\varepsilon_{q,j}(h_1, \dots, h_n) = \sum_{k=1}^{N_q} (E_{q,k} - E_{\max} \delta_{k,j})^2, \quad (15)$$

где $\delta_{k,j}$ – символ Кронекера. Производные функционала (15) рассчитываются по общей формуле (14), где, согласно (9), функция $F_{m,q,j}(\mathbf{u}_m)$ вычисляется через обратное распространение поля

$$F_{n+1,q,j}(\mathbf{u}_{n+1}) = 2w_{n+1,q,j}(\mathbf{u}_{n+1}) \sum_{k=1}^{N_q} \chi_{q,k}(\mathbf{u}_{n+1}) (E_{q,k} - E_{\max} \delta_{k,j}). \quad (16)$$

Отметим, что при расчете каскадного ДОЭ функции высот дифракционного микрорельефа $h_1(\mathbf{u}_1), \dots, h_n(\mathbf{u}_n)$ обычно предполагаются заданными в некотором интервале $[0, h_{\max})$, где h_{\max} – максимальная высота дифракционного микрорельефа, которая обычно выбирается из требований технологии, используемой для изготовления ДОЭ. Наличие ограничений $0 \leq h_m(\mathbf{u}_m) \leq h_{\max}$, $m = 1, \dots, n$, делает задачу расчета каскадного ДОЭ задачей условной оптимизации. Для учета указанных ограничений в итерационный процесс расчета функций высот дифракционного микрорельефа следует ввести оператор проекции на множество функций ограниченной высоты

$$\operatorname{Pr}(h) = \begin{cases} 0, & h < 0, \\ h, & h \in [0, h_{\max}), \\ h_{\max}, & h \geq h_{\max}. \end{cases} \quad (17)$$

В частности, введение в градиентный метод расчета каскадного ДОЭ оператора (17) соответствует методу проекции градиента, в котором расчет следующих приближений функций высот осуществляется по формуле

$$h_m^k(\mathbf{u}_m) = \operatorname{Pr}\left(h_m^{k-1}(\mathbf{u}_m) - t \frac{\delta \varepsilon}{\delta h_m}(\mathbf{u}_m)\right), \quad m = 1, \dots, n, \quad (18)$$

где индекс k обозначает номер итерации, а t – шаг градиентного метода.

3. Примеры расчета спектральных ДНС

Рассмотрим расчет спектральной ДНС для решения трех различных задач классификации P_q , $q = 1, 2, 3$, на следующих трех длинах волн: $\lambda_1 = 457$ нм, $\lambda_2 = 532$ нм, $\lambda_3 = 633$ нм. В качестве решаемых задач выберем следующие: задачу классификации рукописных цифр из базы данных MNIST [41] при длине волны $\lambda_1 = 457$ нм (задача P_1), задачу классификации предметов одежды из базы данных Fashion MNIST [42] при $\lambda_2 = 532$ нм (задача P_2) и, наконец, задачу классификации десяти рукописных букв латинского алфавита от А до J (строчных и прописных) из базы данных EMNIST [43] при $\lambda_3 = 633$ нм (задача P_3). Отметим, что каждая из выбранных задач содержит объекты 10 классов, т.е. $N_1 = N_2 = N_3 = 10$.

При расчете ДНС будем использовать следующие параметры. В качестве входных изображений объектов для задач классификации P_q , $q = 1, 2, 3$, будем использовать изображения из указанных баз данных [41–43], представленные в стандартной библиотеке PyTorch [44]. Входные изображения будем задавать на сетке 56×56 отсчетов с шагом $d = 10$ мкм. Отметим, что в используемых базах данных изображения объектов имеют размер 28×28 пикселей. Для задания этих изображений на сетке 56×56 они были интерполированы по ближайшему значению. Расстояния от входной плоскости до 1-го ДОЭ, расстояния между ДОЭ и расстояния от последнего ДОЭ до выходной плоскости будем считать одинаковыми и равными 160 мм. Функции высоты микрорельефа в плоскостях расположения ДОЭ зададим на сетках 512×512 с шагом 10 мкм. В этом случае размер стороны апертуры каждого ДОЭ составляет 5,12 мм. Максимальную высоту дифракционного микрорельефа выберем равной $h_{\max} = 6$ мкм. Отметим, что ДОЭ с такой высотой могут быть изготовлены по стандартной технологии прямой лазерной записи [45, 46]. В качестве показателей преломления материала ДОЭ для простоты будем использовать одинаковые значения $n(\lambda_1) = n(\lambda_2) = n(\lambda_3) = 1,46$, которые тем не менее с хорошей точностью соответствуют показателю преломления плавленого кварца на расчетных длинах волн.

Будем считать, что изображения объектов из различных задач классификации P_q , $q = 1, 2, 3$ формируются во входной плоскости $z = 0$ последовательно.

При этом каждое изображение из задачи P_q освещается нормально падающей плоской волной с длиной волны λ_q . Поскольку каждая из рассматриваемых задач P_q содержит объекты 10 классов, которые, как мы предположили, формируются во входной плоскости $z = 0$ последовательно, то в выходной плоскости достаточно использовать один набор из 10 целевых областей $G_k, k = 1, \dots, 10$ для всех трех задач. В этом случае ДНС будет позволять за счет изменения длины волны λ_q падающего излучения изменять решаемую задачу классификации. Целевые области, в которых должны формироваться максимумы энергии для входных изображений различных классов, показаны на рис. 2 и соответствуют квадратам с размером стороны 0,25 мм, где цифрами 0, ..., 9 отмечены номера классов. Отметим, что классы 0, ..., 9 соответствуют цифрам 0, ..., 9 в задаче P_1 , различным предметам одежды (T-shirt/top, Trouser, Pullover, Dress, Coat, Sandal, Shirt, Sneaker, Bag, Ankle boot) в задаче P_2 и буквам от А до J в задаче P_3 .

Отметим, что описанная выше геометрия задачи, предполагающая последовательное формирование изображений объектов из различных задач классификации и один набор целевых областей для всех решаемых задач классификации, может также быть применена и для параллельного решения задач классификации $P_q, q = 1, 2, 3$. В этом случае аналогично работе [21] следует предположить, что в оптической схеме, реализующей решение задач классификации, помимо ДНС, присутствуют дополнительные оптические элементы, осуществляющие мультиплексирование входных пучков с различными длинами волн во входной плоскости и демultipлексирование выходного распределения поля по различным спектральным каналам, соответствующим расчетным длинам волн.

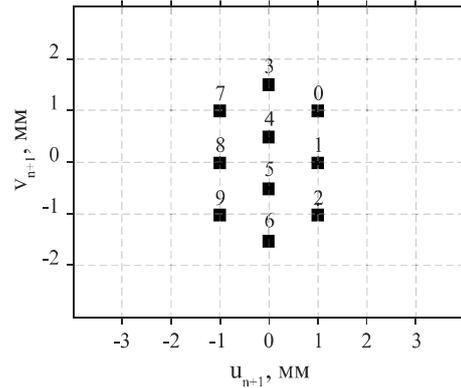


Рис. 2. Целевые области для рассматриваемых задач классификации (цифрами отмечены номера классов)

Сначала с использованием разработанного градиентного метода (5), (6), (14–18) была рассчитана ДНС, состоящая из одного ДОЭ. Отметим, что расчет производных функционалов ошибки осуществлялся численно с использованием метода углового спектра [47, 48]. Для расчета ДОЭ использовалась обучающая выборка S , содержащая 60000 изображений цифр из базы данных MNIST, 60000 изображений предметов одежды из базы данных Fashion MNIST и 48000 изображений рукописных букв из базы данных EMNIST. Расчет ДОЭ проводился с обучением по батчу, каждый батч содержал 30 случайно выбранных изображений из S . В качестве начальной функции высоты микрорельефа использовалась реализация случайного процесса белого шума с равномерным распределением значений в диапазоне $[0, h_{max})$. При расчете ДОЭ было сделано 40 эпох, что потребовало около 4 часов расчета на графической карте NVIDIA RTX 30600 12 Gb. Функция высоты микрорельефа рассчитанного ДОЭ показана на рис. 3а.

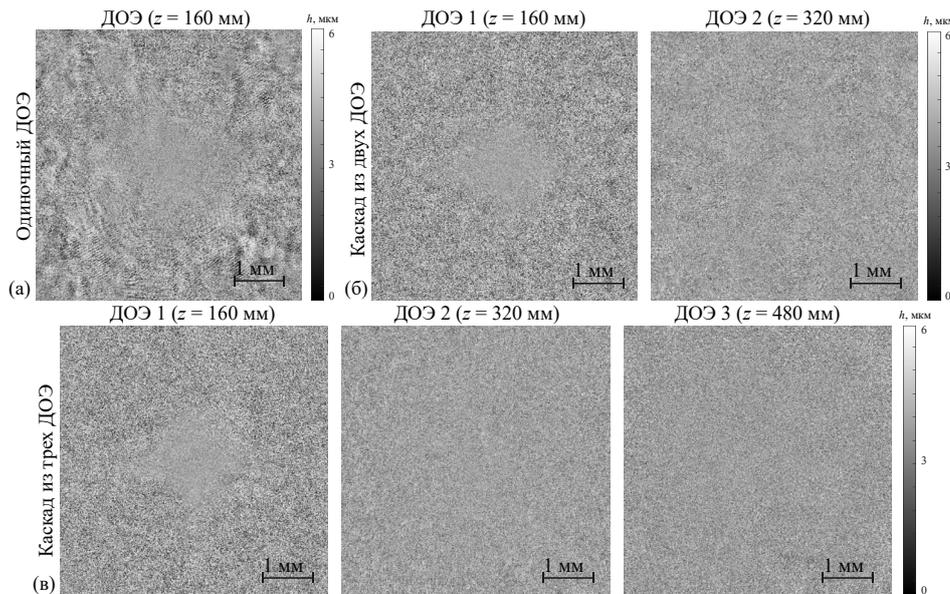


Рис. 3. Функции высоты микрорельефа одиночного ДОЭ (а), каскада из двух ДОЭ (б) и каскада из трех ДОЭ (в) для последовательного решения трех задач классификации на трех длинах волн

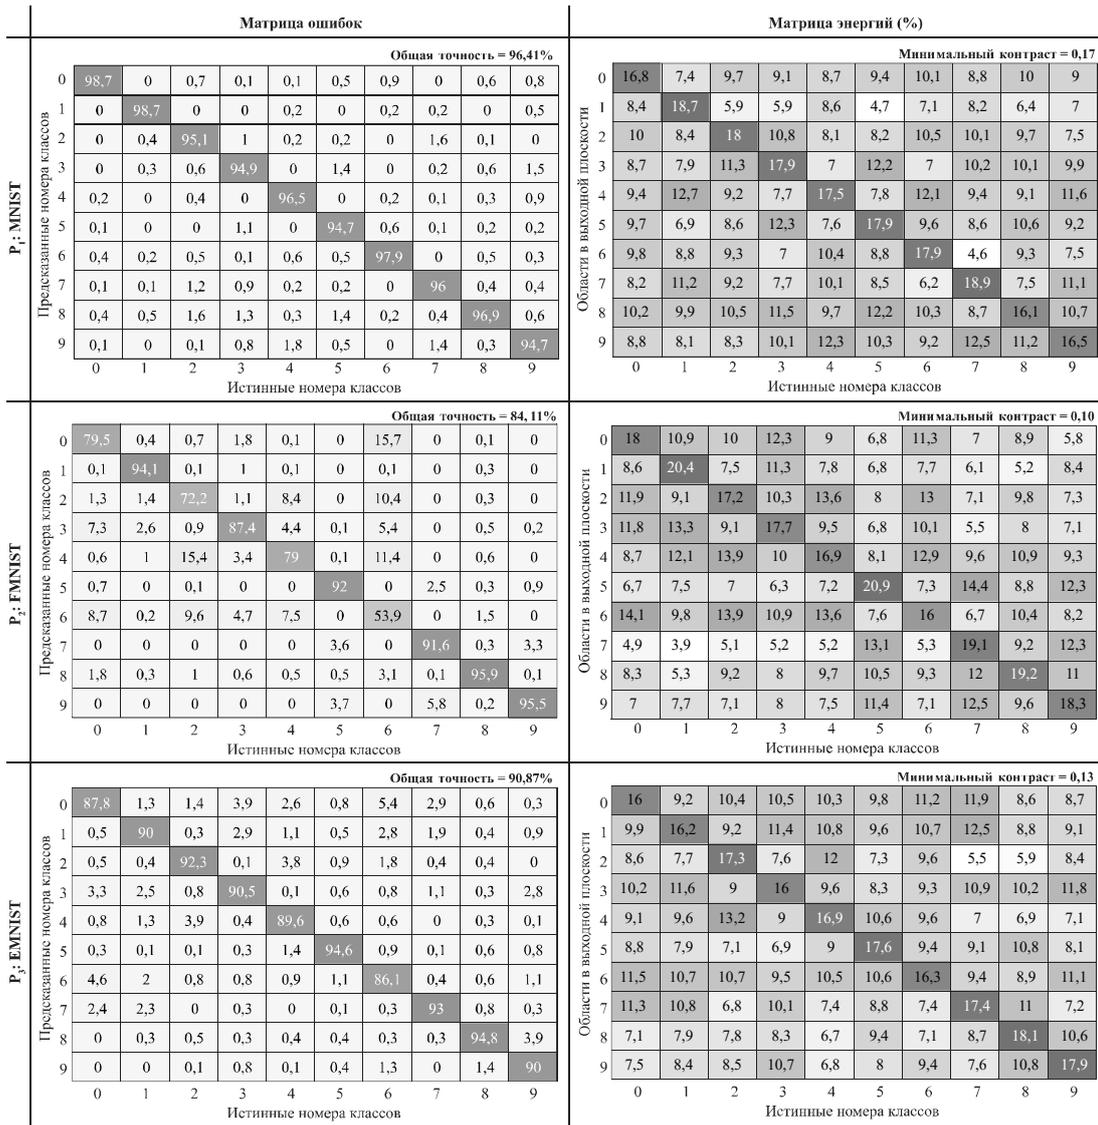


Рис. 4. Матрицы ошибок и матрицы энергий для задач $P_q, q = 1, 2, 3$ для одиночного ДОО

После процесса обучения выполнялось тестирование работы рассчитанного ДОО на тестовой выборке, содержащей по 10000 изображений для задач P_1, P_2 и 8000 изображений для задачи P_3 (изображения тестовой выборки не входили в обучающую выборку). Для описания результатов тестирования введем величины $\bar{\epsilon}_{q,j,k}$, представляющие доли (в процентах) объектов j -го класса из задачи P_q , которые в процессе тестирования были распознаны как элементы k -го класса. Рассчитанные по тестовой выборке проценты распознаваний $\bar{\epsilon}_{q,j,k}$ представлены в левой части рис. 4 в виде т.н. матриц ошибок для всех трех задач $P_q, q = 1, 2, 3$. При этом диагональные элементы указанных матриц $\bar{\epsilon}_{q,j,j}, j = 1, \dots, 10$, равные долям правильно распознанных объектов j -го класса среди всех объектов этого класса в тестовой выборке, могут рассматриваться как точности классификации объектов различных классов в задаче P_q . Отметим, что в англоязычной литературе по нейронным сетям величины $\bar{\epsilon}_{q,j,j}$ носят название “recall”. Можно видеть, что в за-

даче P_1 (задача классификации рукописных цифр из базы данных MNIST) точности классификации изменяются от 94,7% для цифр «5» и «9» до 98,7 для цифр «0» и «1». В задаче P_2 (задача классификации предметов одежды из базы данных Fashion MNIST) точности классификации варьируются в значительно более широких пределах от 53,9% для объектов класса 6 (Shirt) до 95,9% для объектов класса 8 (Bag). Отметим, что «провал» в точности классификации для объектов 6-го класса (Shirt) обусловлен схожестью этих объектов с объектами классов 0, 2 и 4 (T-shirt/top, Pullover, Coat). Этот эффект схожести проявляется также для классов 0, 2 и 4, но снижение точности классификации для этих классов является не таким большим. Отметим, что указанные особенности соответствуют результатам других работ, в которых рассматривается эта задача классификации [10, 17]. Для задачи P_3 (задача классификации 10 букв из базы данных EMNIST) точности классификации изменяются от 86,1% для объектов класса 6 (строчные и

прописные буквы “g”) до 94,8% для объектов класса 8 (строчные и прописные буквы “i”). Над матрицами ошибок указаны общие точности классификации (т.е. отношение числа всех правильно распознанных объектов из задачи P_q к общему числу объектов из данной задачи в тестовой выборке). Отметим, что в англоязычной литературе определяемые таким образом общие точности носят название “accuracy”. Общие точности классификации для задач P_1, P_2, P_3 составили 96,41%, 84,11% и 90,87% соответственно.

Помимо точности классификации, важной характеристикой является формируемое ДОЭ распределение энергий по целевым областям. Обозначим $\bar{E}_{q,j,k}$ среднюю энергию, рассчитанную по тестовой выборке, которая попадает в k -ую целевую область для входных объектов j -го класса из задачи P_q . Средние значения энергий в виде т.н. матриц энергий показаны в правой части рис. 4 для всех трех задач

$P_q, q = 1, 2, 3$. При практическом применении ДОЭ важной характеристикой является значение контраста, показывающее, насколько энергия в области рассматриваемого класса превышает энергию в областях других классов. Назовем контрастом для объектов j -го класса в задаче P_q следующую величину:

$$K_{q,j} = \frac{\bar{E}_{q,j,j} - \max_{k \neq j} \bar{E}_{q,j,k}}{\bar{E}_{q,j,j} + \max_{k \neq j} \bar{E}_{q,j,k}}. \tag{19}$$

По мнению авторов статьи, для устойчивого выделения «истинных максимумов» энергий при экспериментальной реализации ДНС необходимо, чтобы при теоретическом расчете значения $K_{q,j}$ превосходили по крайней мере 0,1. Над матрицами энергий приведены минимальные значения контрастов $K_{min,q} = \min_j K_{q,j}$, которые для рассматриваемых задач $P_q, q = 1, 2, 3$ составили 0,17, 0,10 и 0,13 соответственно.

		Матрица ошибок										Матрица энергий (%)											
P ₁ : MNIST	Предказанные номера классов	Общая точность = 97,86%										Минимальный контраст = 0,17											
		0	99	0	0,5	0	0,1	0,4	0,8	0	0,5	0,8	0	18,3	6,8	8,7	7,6	7,4	8,3	10,2	7,7	8,6	7,5
		1	0	99,4	0,1	0	0,1	0	0,2	0,2	0	0,5	1	6,8	17,6	8,3	7,8	8,4	6,2	8,1	8,1	7,6	6,8
		2	0	0,3	97,6	0,3	0,4	0	0	0,9	0,2	0,1	2	10,5	9,3	18,4	10,7	8,6	8,4	10,8	11,7	10,1	7,8
		3	0,1	0	0,3	97,9	0	0,6	0,1	0,2	0,4	0,7	3	8,5	8,6	11,9	18,6	7,1	12,2	7,5	11	11	10
		4	0	0	0,2	0	97,6	0	0,2	0,1	0,3	0,7	4	8	11,9	8	7,2	18,3	7,5	11,6	8,7	8,6	12,4
		5	0	0	0,1	0,4	0	97,6	0,4	0	0,2	0	5	9,7	6,3	8,1	12	7,5	19,1	10	8,2	10,2	8,7
		6	0,4	0,1	0,1	0	0,5	0,3	98,2	0	0,2	0,1	6	10,4	8,8	9,1	6,5	9,7	8,6	18	4,5	8,5	6,8
		7	0,2	0	0,4	0,5	0,1	0,2	0	97,6	0,3	0,3	7	8,5	11,9	9	8,3	10,6	8,2	6,4	19,2	7,5	11,8
		8	0,3	0,3	0,8	0,3	0,2	0,4	0	0,2	97,5	0,6	8	10,1	10,6	10,7	11,2	9,6	11,8	9,5	8,3	17	10,9
9	0	0	0	0,6	1	0,2	0	0,9	0,3	96,1	9	9,2	8,2	7,8	10,1	12,8	9,7	7,9	12,6	10,9	17,3		
		Истинные номера классов										Истинные номера классов											
P ₂ : FMNIST	Предказанные номера классов	Общая точность = 86,93%										Минимальный контраст = 0,11											
		0	84,1	0,4	1,5	2,6	0	0,1	14,1	0	0	0	0	17,1	11,9	10	12	9,3	7,6	11,3	7,4	9,4	7,4
		1	0	96,5	0	0,7	0	0	0,1	0	0,1	0	1	10,2	19,5	9,5	11,3	9,6	5,4	9,3	4,8	6,8	5,8
		2	1,1	0,2	75,5	0,9	7,4	0	9,8	0	0,5	0	2	11,2	9,2	16,3	9,1	13	7,6	12,4	7,1	10,3	7,1
		3	3,5	2	1	88,2	3,3	0	2,9	0	0,5	0,1	3	11,9	12,7	9,5	16,8	9,6	5,4	10,3	4,7	7,3	5,6
		4	0,7	0,6	14,8	4	83,3	0	11,8	0	0,2	0	4	9,1	12,2	13,1	11,1	16,2	7,6	12,6	7,3	10,9	7,6
		5	0,4	0	0	0	0	95,3	0	2,2	0,2	0,5	5	6,3	6,4	7,1	6,7	7,2	22,4	6,9	15	10,1	14,3
		6	9	0,1	6,5	3	5,5	0	59,1	0	1,6	0,1	6	13,7	8,8	13,1	10,9	13	7,4	15,7	7	10,4	7,9
		7	0	0	0	0	0	2,8	0	95,4	0,5	3,8	7	5,6	5,8	5,1	6,8	5,7	13	5,5	20,4	8,6	13,7
		8	1,2	0,2	0,7	0,6	0,5	0,1	2,2	0	96,4	0	8	8,9	6,9	10	8,5	10,3	11,1	9,9	12,5	17,6	11,6
9	0	0	0	0	0	1,7	0	2,4	0	95,5	9	6	6,6	6,3	6,8	6,1	12,5	6,1	13,8	8,6	19		
		Истинные номера классов										Истинные номера классов											
P ₃ : FMNIST	Предказанные номера классов	Общая точность = 93,07%										Минимальный контраст = 0,12											
		0	92,4	0,9	0,8	3,4	1,9	0,4	4,9	2,3	0,5	0,4	0	15,9	9,4	10,2	10,8	10,4	9,7	11,5	11,7	8,3	9,5
		1	0,1	93,4	0,4	1,5	0,6	0,3	2,9	1,3	0,3	0,4	1	9,8	16,3	8,9	11,7	10,9	9,3	10,7	12,3	9,2	9,1
		2	0,5	0	94,3	0,4	2,9	0,4	0,9	0,5	0,4	0	2	8,8	7,8	17,3	7,7	12,5	7,5	8,7	6,2	7,5	7,9
		3	1,5	1,4	0,5	92,8	0	0,4	0,5	1,1	0,3	2	3	10,1	11,5	9,1	16,2	9	7,3	9,2	10,8	10,1	11,7
		4	0,8	0,8	3,1	0,3	92,8	0,4	0,8	0	0,3	0,1	4	9,2	9,8	13,5	8,6	17	11,1	9,4	7,6	6,6	6,8
		5	0,8	0,1	0	0,3	0,9	96,6	1,4	0,4	0,4	0,6	5	8,8	8	7,5	7	9,3	17,3	9,6	9,2	10,4	8
		6	2,4	1,3	0,8	0,3	0,4	0,8	87,5	0,1	0,5	0,8	6	11,3	10,9	10,5	9,5	10	10,7	16,3	9,3	8,3	10,9
		7	1,6	2	0	0,3	0	0,3	0	94,1	0,4	0,1	7	10,9	10,7	6,7	10	7,6	9	7,6	16,8	11	6,9
		8	0	0,3	0,3	0,1	0,5	0,4	0,1	0,3	95,3	3,9	8	7,8	7,7	8,2	8	7,3	8,9	8	9,1	16,7	10,9
9	0	0	0	0,9	0,1	0,3	1,1	0	1,9	91,8	9	7,4	7,9	8,1	10,5	6	9,2	9	7	11,9	18,3		
		Истинные номера классов										Истинные номера классов											

Рис. 5. Матрицы ошибок и матрицы энергий для задач $P_q, q = 1, 2, 3$, для каскада из двух ДОЭ

Далее была рассчитана спектральная ДНС, состоящая из двух ДОЭ. Функции высоты микрорельефа

рассчитанных ДОЭ показаны на рис. 3б. Полученные по результатам тестирования матрицы ошибок и мат-

рицы энергий для трех рассматриваемых задач показаны на рис. 5. При этом общие точности классификации и значения минимального контраста составляют 97,86% и 0,17 (задача P_1), 86,93% и 0,11 (задача P_2) и 93,07% и 0,12 (задача P_3). Можно видеть, что каскад из двух ДОЭ, по сравнению с одиночным ДОЭ, обладает лучшими рабочими характеристиками. В частности, увеличение общей точности классификации, достигнутое при переходе к каскаду из двух ДОЭ, составляет 1,45% (задача P_2), 2,82% (задача P_2), 2,2% (задача P_3). При этом минимальный контраст практически не изменился.

Наконец, была рассчитана спектральная ДНС, состоящая из трех ДОЭ (рис. 3в). Полученные по результатам тестирования матрицы ошибок и матрицы

энергий для задач показаны на рис. 6. При этом общие точности классификации и значения минимального контраста для каскада из трех ДОЭ составляют 97,89% и 0,20 (задача P_1), 89,75% и 0,11 (задача P_2) и 93,22% и 0,19 (задача P_3). Отметим, что достигнутые точности классификации являются высокими и превышают значения, приведенные в других работах для ДНС, работающих на одной длине волны. Например, в работах [10, 12, 14] теоретические точности в задаче классификации цифр из базы данных MNIST, полученные для ДНС, состоящих из 5 и более ДОЭ и работающих на одной длине волны, составили 91,75%, 92,28% и 91,57% соответственно. Указанные точности значительно меньше достигнутой точности в 97,89% для спектральной ДНС из трех ДОЭ.

		Матрица ошибок										Матрица энергий (%)												
P_1 : MNIST	Предказанные номера классов	Общая точность = 97,89%																						
		0	99	0	0,4	0	0	0,3	0,7	0	0,4	0,6	0	15,5	9,4	9,4	9,4	9,4	9,4	9,5	9,2	9,5	9,4	
		1	0	98,9	0,1	0	0,2	0	0,2	0,5	0,1	0,2	1	9,3	15,7	9,4	9,4	9,4	9,2	9,4	9,4	9,2	9,4	9,4
		2	0,2	0,3	96,6	0,4	0,5	0,2	0,1	1	0,6	0,1	2	9,6	9,4	15,3	9,7	9,4	9,4	9,5	9,5	9,6	9,6	9,4
		3	0	0	0,5	97,4	0	1	0	0,2	0,5	0,6	3	9,3	9,3	9,5	15,1	9,3	9,7	9,3	9,4	9,6	9,6	9,5
		4	0	0,2	0,1	0	97,9	0	0,1	0,2	0,5	1	4	9,5	9,4	9,4	9,4	15,4	9,5	9,4	9,6	9,5	9,8	9,8
		5	0	0	0	1	0	97	0,8	0,2	0,3	1	5	9,4	9,4	9,3	9,7	9,3	15,2	9,5	9,4	9,6	9,6	9,4
		6	0,4	0,5	0,2	0	0,4	0,6	98,1	0	0,1	0	6	9,4	9,4	9,4	9,4	9,4	9,4	15,5	9,3	9,4	9,4	9,3
		7	0,1	0,1	0,6	0,8	0	0,3	0	96,9	0,5	0,7	7	9,4	9,4	9,5	9,2	9,4	9,4	9,3	15,4	9,4	9,4	9,6
		8	0,2	0,1	1,6	0,3	0,2	0,3	0	0,3	96,7	0,3	8	9,3	9,3	9,4	9,3	9,4	9,5	9,3	9,3	14,8	9,4	9,4
9	0,1	0	0	0,2	0,8	0	0	0	0,7	0,2	95,6	9	9,3	9,3	9,4	9,4	9,6	9,3	9,3	9,5	9,4	14,8	14,8	
		Истинные номера классов										Истинные номера классов												
P_2 : FMNIST	Предказанные номера классов	Общая точность = 89,75%																						
		0	87,6	0,2	3,1	2,3	0,1	0	14,1	0	0,2	0	0	14,5	9,4	9,7	9,6	9,4	9,4	10,4	9,4	9,4	9,4	9,4
		1	0,6	97,9	0,2	0,6	0	0	0,2	0	0,2	0	1	9,3	15,7	9,4	9,6	9,5	9,4	9,4	9,4	9,4	9,5	9,5
		2	1,6	0,2	81,6	0,8	7,2	0	7,9	0	0,5	0	2	9,6	9,3	13,8	9,4	10,1	9,3	10	9,1	9,4	9,3	9,3
		3	1,8	0,9	1,6	89,9	3,1	0	2,8	0	0,3	0	3	9,6	9,5	9,6	14,7	9,7	9,4	9,6	9,4	9,4	9,4	9,4
		4	0,4	0,3	8,3	2,8	84,6	0	7,1	0	0,2	0	4	9,4	9,5	10	9,5	13,7	9,3	9,9	9,4	9,4	9,3	9,3
		5	0,2	0	0,1	0	0	97,3	0,1	0,5	0,2	0,5	5	9,4	9,3	9,4	9,3	9,4	15,3	9,4	9,7	9,4	9,6	9,6
		6	6,4	0,3	4,8	3,2	4,6	0,1	66,7	0,1	0,6	0,1	6	9,9	9,4	10	9,7	10	9,4	13	9,4	9,4	9,3	9,3
		7	0,2	0	0	0	0,1	1,8	0	97,3	0,3	2,3	7	9,4	9,3	9,3	9,3	9,4	9,6	9,4	15,2	9,4	9,5	9,5
		8	1,2	0,2	0,3	0,4	0,3	0	1	0	97,5	0	8	9,5	9,3	9,5	9,5	9,5	9,4	9,6	9,4	15,2	9,4	9,4
9	0	0	0	0	0	0,8	0,1	2,1	0	97,1	9	9,4	9,3	9,3	9,4	9,3	9,5	9,3	9,6	9,5	15,3	15,3		
		Истинные номера классов										Истинные номера классов												
P_3 : FMNIST	Предказанные номера классов	Общая точность = 93,22%																						
		0	92	0,9	0,6	2,8	1,1	0,3	3,3	2	0,1	0	0	14,4	9,4	9,5	9,7	9,4	9,4	9,8	9,7	9,2	9,4	9,4
		1	0	93,1	0,3	1,5	0,5	0,3	2,3	1,3	0,3	0,5	1	9,3	14,7	9,3	9,7	9,4	9,4	9,6	9,8	9,4	9,4	9,4
		2	1	0,1	93,9	0,6	3,8	0,1	1,6	0,4	0,4	0	2	9,5	9,4	14,8	9,4	10	9,4	9,6	9,2	9,5	9,4	9,4
		3	1,6	1,3	0,3	92,4	0	0,4	0,3	0,4	0	1,9	3	9,7	9,6	9,4	14,5	9,4	9,2	9,4	9,6	9,4	9,7	9,7
		4	0,9	1	3,8	0,1	92,9	0,6	0,8	0,3	0,1	0	4	9,4	9,5	10,1	9,4	14,7	9,7	9,5	9,4	9,5	9,1	9,1
		5	0,8	0,1	0,1	0,4	0,9	96,1	1,3	0	0,3	0,4	5	9,5	9,3	9,3	9,4	9,6	14,9	9,6	9,5	9,5	9,5	9,5
		6	1,5	0,9	0,6	0,5	0,4	0,9	89,6	0,1	0,4	1,4	6	9,8	9,6	9,6	9,4	9,5	9,6	14,4	9,4	9,3	9,6	9,6
		7	2	2	0	0,4	0	0	0	95	0,5	0,1	7	9,7	9,8	9,3	9,5	9,4	9,5	9,3	14,7	9,5	9,3	9,3
		8	0,1	0,3	0,4	0,3	0,5	0,8	0,1	0,4	95,5	4	8	9,3	9,4	9,4	9,3	9,4	9,5	9,3	9,4	15	9,8	9,8
9	0,1	0,4	0,1	1,1	0	0,6	0,9	0,3	2,5	91,8	9	9,4	9,3	9,3	9,7	9,2	9,4	9,5	9,3	9,7	14,8	14,8		
		Истинные номера классов										Истинные номера классов												

Рис. 6. Матрицы ошибок и матрицы энергий для задач P_q , $q = 1, 2, 3$, для каскада из трех ДОЭ

Для иллюстрации работы каскада из трех ДОЭ на рис. 7 приведены конкретные примеры входных изображений из задач классификации P_q , $q = 1, 2, 3$, и соответствующие им распределения энергий (3), формируемые ДНС в выходной плоскости.

Для удобства сравнения рабочих характеристик всех рассчитанных ДНС в левой части табл. 1 приведены общие точности классификации и значения минимального контраста для ДНС из одного ДОЭ и каскадов из двух и трех ДОЭ. Можно видеть, что

каскад из трех ДОЭ, по сравнению с каскадом из двух ДОЭ, имеет лучшие значения минимального контраста и заметно лучшую общую точность классификации для задачи P_2 (точность классификации возросла с 86,93 % до 89,75 %). При этом точности

классификации для задач P_1, P_3 практически не изменяются. Отметим, что дальнейшее увеличение числа ДОЭ фактически не увеличивает точность распознавания, но по-прежнему несколько улучшает значения контраста.

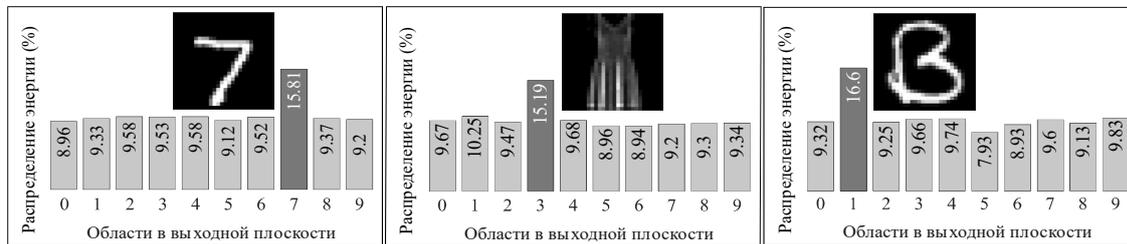


Рис. 7. Примеры входных изображений (цифра «7», объект «Dress» и буква «В») из задач $P_q, q = 1, 2, 3$, и формируемые распределения энергии в целевых областях для каскада из трех ДОЭ

В завершение настоящего параграфа интересно сравнить рабочие характеристики трех рассчитанных спектральных ДНС (рис. 3) с рабочими характеристиками «обычных» ДНС, решающих три те же самые задачи классификации, но при одной длине волны. Данные ДНС были рассчитаны градиентным методом при длине волны $\lambda_1 = 457$ нм и при указанных выше параметрах. Значения общей точности классификации и минимального контраста для рассчитанных обычных ДНС (для краткости не показаны в статье), состоящих из одного, двух и трех ДОЭ, приведены в правой части табл. 1. Из сравнения левой и правой частей таблицы можно

видеть, что спектральные ДНС имеют заметно лучшие рабочие характеристики. В частности, для одиночного ДОЭ, рассчитанного при фиксированной длине волны 457 нм, снижение точности по сравнению со спектральным одиночным ДОЭ составляет 3,72 % (задача P_1), 2,15 % (задача P_2) и 5,97 % (задача P_3). Лучшие рабочие характеристики спектральных ДНС, работающих с излучением трех различных длин волн, объясняются тем, что формируемые спектральными ДОЭ фазовые набегги на различных длинах волн (см. формулу (1)) являются различными, что дает дополнительные степени свободы при оптимизации.

Табл. 1. Общая точность и минимальный контраст для рассчитанных спектральных ДНС, а также ДНС, работающих на одной фиксированной длине волны

Задачи классификации	Спектральные ДНС			ДНС, работающие при фиксированной длине волны 457 нм		
	Длина волны (нм)	Общая точность (%)	Мин. контраст	Общая точность (%)	Мин. контраст	
		Одиночный ДОЭ			Одиночный ДОЭ	
P_1 (MNIST)	457	96,41	0,17	92,69	0,12	
P_2 (Fashion MNIST)	532	84,11	0,10	81,96	0,07	
P_3 (EMNIST)	633	90,87	0,13	84,90	0,10	
		Каскад из двух ДОЭ			Каскад из двух ДОЭ	
P_1 (MNIST)	457	97,86	0,17	95,19	0,19	
P_2 (Fashion MNIST)	532	86,93	0,11	86,73	0,10	
P_3 (EMNIST)	633	93,07	0,12	88,78	0,14	
		Каскад из трех ДОЭ			Каскад из трех ДОЭ	
P_1 (MNIST)	457	97,89	0,20	95,25	0,19	
P_2 (Fashion MNIST)	532	89,75	0,11	86,91	0,10	
P_3 (EMNIST)	633	93,22	0,19	89,30	0,15	

Заключение

Рассмотрено решение нескольких различных задач классификации изображений на нескольких различных длинах волн с помощью спектральной дифракционной нейронной сети, состоящей из набора фазовых ДОЭ. Для расчета спектральной ДНС разработан градиентный метод. В рамках метода задача

расчета ДНС сформулирована как задача минимизации функционала, зависящего от функций высот дифракционного микрорельефа ДОЭ, образующих ДНС, и представляющего ошибку решения заданных задач классификации на расчетных длинах волн. Для производных функционала получены явные и компактные выражения. С использованием предложенного градиентного метода рассчитаны спектральные ДНС для решения

следующих трех задач: задачи классификации рукописных цифр из базы данных MNIST на длине волны 457 нм (задача P_1), задачи классификации предметов одежды из базы данных Fashion MNIST на длине волны 532 нм (задача P_2) и задачи классификации десяти рукописных букв латинского алфавита от А до J (строчных и прописных) из базы данных EMNIST при длине волны 633 нм (задача P_3). Представленные результаты расчета и моделирования спектральных ДНС демонстрируют их хорошие рабочие характеристики и подтверждают хорошую работоспособность предложенного метода. В частности, рассчитанный каскад из трех ДОЭ обеспечивает решение задач классификации P_1, P_2, P_3 с точностями в 97,89%, 89,75% и 93,22% соответственно.

Благодарности

Работа выполнена при поддержке Министерства науки и высшего образования Российской Федерации (государственное задание Самарскому университету, проект FSSS-2024-0016) в части разработки градиентного метода расчета спектральных ДНС и его применения для решения различных задач классификации и при поддержке государственного задания НИЦ «Курчатовский институт» в части создания программных средств для моделирования работы каскадных ДОЭ.

References

- [1] Silva A, Monticone F, Castaldi G, Galdi V, Alù A, Engheta N. Performing mathematical operations with metamaterials. *Science* 2014; 343(6167): 161-163. DOI: 10.1126/science.1242818.
- [2] Zhou Y, Zheng H, Kravchenko II, Valentine J. Flat optics for image differentiation. *Nat Photonics* 2020; 14(5): 316-323. DOI: 10.1038/s41566-020-0591-3.
- [3] Estakhri NM, Edwards B, Engheta N. Inverse-designed metastructures that solve equations. *Science* 2019; 363(6433): 1333-1338. DOI: 10.1126/science.aaw2498.
- [4] Kitayama KI, Notomi M, Naruse M, Inoue K, Kawakami S, Uchida A. Novel frontier of photonics for data processing –Photonic accelerator. *APL Photonics* 2019; 4(9): 090901. DOI: 10.1063/1.5108912.
- [5] Shen Y, Harris N, Skirlo S, et al. Deep learning with coherent nanophotonic circuits. *Nature Photon* 2017; 11: 441-446. DOI: 10.1038/nphoton.2017.93.
- [6] Harris NC, Carolan J, Bunandar D, Prabhu M, Hochberg M, Baehr-Jones T, Fanto ML, Smith AM, Tison CC, Alsing PM, Englund D. Linear programmable nanophotonic processors. *Optica* 2018; 5(12): 1623-1631. DOI: 10.1364/OPTICA.5.001623.
- [7] Zhu HH, Zou J, Zhang H, et al. Space-efficient optical computing with an integrated chip diffractive neural network. *Nat Commun* 2022; 13: 1044. DOI: 10.1038/s41467-022-28702-0.
- [8] Zhang H, Gu M, Jiang XD, et al. An optical neural chip for implementing complex-valued neural network. *Nat Commun* 2021; 12: 457. DOI: 10.1038/s41467-020-20719-7.
- [9] Zhang J, Wu B, Cheng J, Dong J, Zhang X. Compact, efficient, and scalable nanobeam core for photonic matrix-vector multiplication. *Optica* 2024; 11(2): 190-196. DOI: 10.1364/OPTICA.506603.
- [10] Lin X, Rivenson Y, Yardimci NT, Veli M, Luo Y, Jarrahi M, Ozcan A. All-optical machine learning using diffractive deep neural networks. *Science* 2018; 361(6406): 1004-1008. DOI: 10.1126/science.aat8084.
- [11] Yan T, Wu J, Zhou T, Xie H, Xu F, Fan J, Fang L, Lin X, Dai Q. Fourier-space diffractive deep neural network. *Phys Rev Lett* 2019; 123(2): 023901. DOI: 10.1103/PhysRevLett.123.023901.
- [12] Zhou T, Fang L, Yan T, Wu J, Li Y, Fan J, Wu H, Lin X, Dai Q. *In situ* optical backpropagation training of diffractive optical neural networks. *Photon Res* 2020; 8(6): 940-953. DOI: 10.1364/PRJ.389553.
- [13] Zhou T, Lin X, Wu J, et al. Large-scale neuromorphic optoelectronic computing with a reconfigurable diffractive processing unit. *Nat Photonics* 2021; 15: 367-373. DOI: 10.1038/s41566-021-00796-w.
- [14] Chen H, Feng J, Jiang M, Wang Y, Lin J, Tan J, Jin P. Diffractive deep neural networks at visible wavelengths. *Engineering* 2021; 7(10): 1483-1491. DOI: 10.1016/j.eng.2020.07.032.
- [15] Ferdman B, Saguy A, Xiao D, Shechtman Y. Diffractive optical system design by cascaded propagation. *Opt Express* 2022; 30(15): 27509-27530. DOI: 10.1364/OE.465230.
- [16] Zheng S, Xu S, Fan D. Orthogonality of diffractive deep neural network. *Opt Lett* 2022; 47(7): 1798-1801. DOI: 10.1364/OL.449899.
- [17] Zheng M, Shi L, Zi J. Optimize performance of a diffractive neural network by controlling the Fresnel number. *Photon Res* 2022; 10(11): 2667-2676. DOI: 10.1364/PRJ.474535.
- [18] Wang T, Ma SY, Wright LG, et al. An optical neural network using less than 1 photon per multiplication. *Nat Commun* 2022; 13: 123. DOI: 10.1038/s41467-021-27774-8.
- [19] Soshnikov DV, Doskolovich LL, Motz GA, Byzov EV, Bezus EA, Bykov DA, Mingazov AA. Design of cascaded diffractive optical elements for optical beam shaping and image classification using a gradient method. *Photonics* 2023; 10(7): 766. DOI: 10.3390/photonics10070766.
- [20] Kulce O, Mengü D, Rivenson Y, Ozcan A. All-optical synthesis of an arbitrary linear transformation using diffractive surfaces. *Light Sci Appl* 2021; 10: 196. DOI: 10.1038/s41377-021-00623-5.
- [21] Li J, Gan T, Bai B, Luo Y, Jarrahi M, Ozcan A. Massively parallel universal linear transformations using a wavelength-multiplexed diffractive optical network. *Advanced Photonics* 2023; 5(1): 016003. DOI: 10.1117/1.AP.5.1.016003.
- [22] Mengü D, Tabassum A, Jarrahi M, et al. Snapshot multispectral imaging using a diffractive optical network. *Light Sci Appl* 2023; 12: 86. DOI: 10.1038/s41377-023-01135-0.
- [23] Luo Y, Mengü D, Yardimci NT, et al. Design of task-specific optical systems using broadband diffractive neural networks. *Light Sci Appl* 2019; 8: 112. DOI: 10.1038/s41377-019-0223-1.
- [24] Zhu Y, Chen Y, Dal Negro L. Design of ultracompact broadband focusing spectrometers based on diffractive optical networks. *Opt Lett* 2022; 47(24): 6309-6312. DOI: 10.1364/OL.475375.
- [25] Shi J, Chen Y, Zhang X. Broad-spectrum diffractive network via ensemble learning. *Opt Lett* 2022; 47(3): 605-608. DOI: 10.1364/OL.440421.
- [26] Feng J, Chen H, Yang D, Hao J, Lin J, Jin P. Multi-wavelength diffractive neural network with the weighting

- method. Opt Express 2023; 31(20): 33113-33122. DOI: 10.1364/OE.499840.
- [27] Fienup JR. Phase retrieval algorithms: a comparison. Appl Opt 1982; 21(15): 2758-2769. DOI: 1364/AO.21.002758.
- [28] Soifer VA, Kotlyar VV, Doskolovich LL. Iterative methods for diffractive optical elements computation. London: Taylor & Francis Ltd; 1997. ISBN: 0-7484-0634-4.
- [29] Ripoll O, Kettunen V, Herzig HP. Review of iterative Fourier transform algorithms for beam shaping applications. Opt Eng 2004; 43(11): 2549-2556. DOI: 10.1117/1.1804543.
- [30] Latychevskaia T. Iterative phase retrieval in coherent diffractive imaging: practical issues. Appl Opt 2018; 57(25): 7187-7197. DOI: 10.1364/AO.57.007187.
- [31] Deng X, Chen RT. Design of cascaded diffractive phase elements for three-dimensional multiwavelength optical interconnects. Opt Lett 2000; 25(14): 1046-1048. DOI: 10.1364/ol.25.001046.
- [32] Gülses AA, Jenkins BK. Cascaded diffractive optical elements for improved multiplane image reconstruction. Appl Opt 2013; 52(15): 3608-3616. DOI: 10.1364/AO.52.003608.
- [33] Wang H, Piestun R. Dynamic 2D implementation of 3D diffractive optics. Optica 2018; 5(10): 1220-1228. DOI: 10.1364/OPTICA.5.001220.
- [34] Armitage JD, Lohmann AW. Character recognition by incoherent spatial filtering. Appl Opt 1965; 4(4): 461-467. DOI: 10.1364/AO.4.000461.
- [35] Caulfield HJ, Maloney WT. Improved discrimination in optical character recognition. Appl Opt 1969; 8(11): 2354-2356. DOI: 10.1364/AO.8.002354.
- [36] Caulfield HJ, Weinberg MH. Computer recognition of 2-D patterns using generalized matched filters. Appl Opt 1982; 21(9): 1699-1704. DOI: 10.1364/AO.21.001699.
- [37] Casasent D, ed. Optical data processing: Applications. Berlin, New York: Springer-Verlag; 1978. DOI: 10.1007/BFb0057980.
- [38] Kingma DP, Ba J. Adam: A method for stochastic optimization. arXiv Preprint. 2015. Source: <https://arxiv.org/abs/1412.6980>. DOI: 10.48550/arXiv.1412.6980.
- [39] Shi J, Wei D, Hu C, Chen M, Liu K, Luo J, Zhang X. Robust light beam diffractive shaping based on a kind of compact all-optical neural network. Opt Express 2021; 29(5): 7084-7099. DOI: 10.1364/OE.419123.
- [40] Buske P, Völl A, Eisebitt M, Stollenwerk J, Holly C. Advanced beam shaping for laser materials processing based on diffractive neural networks. Opt Express 2022; 30(13): 22798-22816. DOI: 10.1364/OE.459460.
- [41] Lecun Y, Bottou L, Bengio Y, Haffner P. Gradient-based learning applied to document recognition. Proc IEEE 1998; 86(11): 2278-2324. DOI: 10.1109/5.726791.
- [42] Xiao H, Rasul K, Vollgraf R. Fashion-mnist: a novel image dataset for benchmarking machine learning algorithms. arXiv Preprint. 2017. Source: <https://arxiv.org/abs/1708.07747>. DOI: 10.48550/arXiv.1708.07747.
- [43] Cohen G, Afshar S, Tapson J, Schaik A. EMNIST: Extending MNIST to handwritten letters. 2017 Int Joint Conf on Neural Networks (IJCNN) 2017: 2921-2926. DOI: 10.1109/IJCNN.2017.7966217.
- [44] PyTorch – an optimized tensor library for deep learning using GPUs and CPUs. 2024. Source: <https://pytorch.org/>.
- [45] Doskolovich LL, Mingazov AA, Byzov EV, Skidanov RV, Ganchevskaya SV, Bykov DA, Bezus EA, Podlipnov VV, Porfirev AP, Kazanskiy NL. Hybrid design of diffractive optical elements for optical beam shaping. Opt Express 2021; 29(20): 31875-31890. DOI: 10.1364/OE.439641.
- [46] Doskolovich LL, Skidanov RV, Bezus EA, Ganchevskaya SV, Bykov DA, Kazanskiy NL. Design of diffractive lenses operating at several wavelengths. Opt Express 2020; 28(8): 11705-11720. DOI: 10.1364/OE.389458.
- [47] Schmidt JD. Numerical simulation of optical wave propagation with examples in MATLAB. Bellingham: SPIE; 2010. ISBN: 978-0-8194-8326-3.
- [48] Cubillos M, Jimenez E. Numerical simulation of optical propagation using sinc approximation. J Opt Soc Am A 2022; 39(8): 1403-1413. DOI: 10.1364/JOSAA.461355.

Сведения об авторах

Мотз Георгий Александрович, в 2022 году окончил бакалавриат Самарского национального исследовательского университета имени академика С.П. Королёва по специальности «Прикладная математика и информатика». E-mail: motzga@mail.ru

Сошников Даниил Вадимович, в 2022 году с отличием окончил бакалавриат Самарского национального исследовательского университета имени академика С.П. Королёва по специальности «Прикладная математика и информатика». E-mail: soshnikov.d.v@mail.ru

Досколович Леонид Леонидович, в 1989 году с отличием окончил Куйбышевский авиационный институт (КуАИ, ныне – Самарский национальный исследовательский университет имени академика С.П. Королёва) по специальности «Прикладная математика». Доктор физико-математических наук (2001 год), профессор, главный научный сотрудник лаборатории дифракционной оптики отделения «Институт систем обработки изображений – Самара» Курчатовского комплекса кристаллографии и фотоники федерального государственного бюджетного учреждения «Национальный исследовательский центр «Курчатовский институт»» и ведущий научный сотрудник НИИ-35 Самарского университета, профессор кафедры технической кибернетики Самарского университета. Специалист в области нанофотоники, дифракционной оптики, неизображающей оптики. E-mail: leonid@ipsiras.ru

Бызов Егор Владимирович, 1988 года рождения. В 2014 году с отличием окончил обучение в магистратуре Самарского государственного аэрокосмического университета имени академика С.П. Королёва (СГАУ, ныне Самарский национальный исследовательский университет имени академика С.П. Королева) по направлению

«Прикладная математика и физика». Кандидат физико-математических наук (2022 год), старший научный сотрудник НИЛ-35 Самарского университета и научный сотрудник лаборатории дифракционной оптики отделения «Институт систем обработки изображений – Самара» Курчатовского комплекса кристаллографии и фотоники федерального государственного бюджетного учреждения «Национальный исследовательский центр «Курчатовский институт»». Область научных интересов: методы расчетов формирующей неизображающей оптики для светодиодов. E-mail: egor.byzov@gmail.com

Безус Евгений Анатольевич в 2009 году с отличием окончил Самарский государственный аэрокосмический университет имени академика С.П. Королёва (СГАУ) по специальности «Прикладная математика и информатика». Кандидат физико-математических наук (2012 г.), старший научный сотрудник НИЛ-35 Самарского университета и лаборатории дифракционной оптики отделения «Институт систем обработки изображений – Самара» Курчатовского комплекса кристаллографии и фотоники федерального государственного бюджетного учреждения «Национальный исследовательский центр «Курчатовский институт»», доцент кафедры технической кибернетики Самарского университета. Области научных интересов: нанофотоника, плазмоника, электромагнитная теория дифракции. E-mail: evgeni.bezus@gmail.com

Быков Дмитрий Александрович, в 2009 году с отличием окончил Самарский государственный аэрокосмический университет имени академика С.П. Королёва (СГАУ, ныне – Самарский национальный исследовательский университет имени академика С.П. Королёва) по специальности «Прикладная математика и информатика». Доктор физико-математических наук (2017 г.), старший научный сотрудник лаборатории дифракционной оптики отделения «Институт систем обработки изображений – Самара» Курчатовского комплекса кристаллографии и фотоники федерального государственного бюджетного учреждения «Национальный исследовательский центр «Курчатовский институт»» и ведущий научный сотрудник НИЛ-35 Самарского университета, профессор кафедры технической кибернетики Самарского университета. Области научных интересов: оптика резонансных дифракционных структур, электромагнитная теория дифракции, неизображающая оптика. E-mail: bykovd@gmail.com

ГРНТИ: 29.31.15

Поступила в редакцию 09 апреля 2024 г. Окончательный вариант – 03 июня 2024 г.

Optical classification of images at different wavelengths using spectral diffractive neural networks

G.A. Motz ^{1,2}, D.V. Soshnikov ^{1,2}, L.L. Doskolovich ^{1,2}, E.V. Byzov ^{1,2}, E.A. Bezus ^{1,2}, D.A. Bykov ^{1,2}

¹Image Processing Systems Institute, NRC “Kurchatov Institute”,
443001, Samara, Russia, Molodogvardeyskaya 151;

²Samara National Research University, 443086, Samara, Russia, Moskovskoye Shosse 34

Abstract

A solution of several different problems of image classification at several different wavelengths using a diffractive neural network (DNN) consisting of sequentially located phase diffractive optical elements (DOEs) is considered. To solve the classification problems, the problem of calculating the DNN is formulated as that of minimizing a functional that depends on the functions of the DOE diffractive microrelief heights - which form a DNN - and represents an error in solving the classification problems in question at the operating wavelengths. Explicit expressions are obtained for the functional derivatives and on this basis, a gradient method for calculating the DNN is formulated. Using the proposed gradient method, DNNs are calculated intended for solving three different problems of image classification at three different wavelengths. The presented simulation results of the calculated DNNs demonstrate their good performance characteristics and confirm the good performance of the proposed method.

Keywords: image classification problem, diffractive neural network, cascaded diffractive optical element, diffractive microrelief, scalar diffraction theory, optimization, gradient method.

Citation: Motz GA, Soshnikov DV, Doskolovich LL, Byzov EV, Bezus EA, Bykov DA. Optical classification of images at different wavelengths using spectral diffractive neural networks. *Computer Optics* 2025; 49(2): 187-199. DOI: 10.18287/2412-6179-CO-1536.

Acknowledgements: This work was partly funded by the RF Ministry of Science and Higher Education under the government project FSSS-2024-0016 of Samara University (Development of the gradient method for calculating spectral DNSs and its application for solving different classification problems) and a government project of NRC “Kurchatov Institute” (development of the software for simulating the cascaded DOE operation).

Authors' information

Georgy Alexandrovich Motz, graduated (2022) from Samara National Research University with a major in Applied Mathematics and Computer Science. E-mail: motzga@mail.ru

Daniil Vadimovich Soshnikov, graduated with honors (2022) from Samara National Research University with a major in Applied Mathematics and Computer Science. E-mail: soshnikov.d.v@mail.ru

Leonid Leonidovich Doskolovich graduated with honors (1989) from S.P. Korolyov Kuibyshev Aviation Institute (presently, Samara National Research University), majoring in Applied Mathematics. He received his Doctor in Physics & Maths (2001) degree from Samara State Aerospace University. Principal researcher at the Image Processing Systems Institute, NRC “Kurchatov Institute” and leading researcher at Samara University, and a professor at Technical Cybernetics department of Samara University. His leading research interests include nanophotonics, diffractive optics, and nonimaging optics. E-mail: leonid@ipsiras.ru

Egor Vladimirovich Byzov (b. 1988) graduated with honors (2014) from Samara State Aerospace University named after S.P. Korolyov (now – Samara National Research University named after academician S.P. Korolyov), majoring in Applied Mathematics and Physics. Candidate in Physics and Mathematics (2022). Currently he is a senior researcher at the Samara University and a researcher at the Diffractive Optics Laboratory of Image Processing Systems Institute, NRC “Kurchatov Institute” and an associate professor at Technical Cybernetics department of Samara University. Research interests: design methods of nonimaging optics for LEDs. E-mail: egor.byzov@gmail.com

Evgeni Anatolievich Bezus graduated with honors (2009) from Samara State Aerospace University (SSAU), majoring in Applied Mathematics and Computer Science. Candidate in Physics and Mathematics (2012). Currently he is a senior researcher at the Samara University and at the Diffractive Optics Laboratory of the Image Processing Systems Institute, NRC “Kurchatov Institute” and an associate professor at Technical Cybernetics department of Samara Univer-

sity. His current research interests include nanophotonics, plasmonics and electromagnetic diffraction theory. E-mail: evgeni.bezus@gmail.com

Dmitry Alexandrovich Bykov graduated with honors (2009) from Samara State Aerospace University (SSAU), majoring in Applied Mathematics and Computer Science. Doctor of Physics and Mathematics (2017). Senior researcher at the Diffractive Optics Laboratory of the Image Processing Systems Institute, NRC “Kurchatov Institute” and leading researcher at the Samara University, and a professor at Technical Cybernetics department of Samara University. His current research interests include optics of resonant diffractive structures, electromagnetic diffraction theory, and nonimaging optics. E-mail: bykovd@gmail.com

Received April 09, 2024. The final version – June 03, 2024.
