

Особенности проектирования оптических дифракционных нейронных сетей

А. В. Коновалова, А. А. Попкова, Т. Г. Балуюн, А. А. Федянин¹⁾

Физический факультет, МГУ имени М. В. Ломоносова, 119991 Москва, Россия

Поступила в редакцию 18 октября 2025 г.

После переработки 25 ноября 2025 г.

Принята к публикации 26 ноября 2025 г.

В последнее время большое внимание уделяется поиску и реализации подходов, которые бы позволили повысить эффективность существующих методов вычислений или создать принципиально новые. Одним из перспективных направлений является переход от цифровых вычислительных схем к аналоговым, позволяющим на основе известных физических принципов проектировать высокопроизводительные специализированные архитектуры. В частности, физической системой, в которой можно реализовать структуру, аналогичную искусственной нейронной сети, является дифракционная нейронная сеть. Однако перенос вычислений на аналоговую платформу сопряжен с необходимостью точного подбора математической модели, адекватно учитывающей особенности физической реализации. В данной работе экспериментально тестируется корректность численного моделирования Фурье-дифракционной нейронной сети, а также численно исследуется влияние геометрии системы на точность итогового результата вычислений.

DOI: 10.7868/S3034576626010138

1. Введение. Активное развитие нейронных сетей (НС) и методов машинного обучения создает широкие возможности для их применения в различных отраслях науки и технологий [1–3]. В частности, машинное обучение открывает множество перспективных исследовательских задач в области фотоники [4], в том числе проектирование и оптимизацию оптических элементов и систем с использованием машинного обучения [5–7]. Кроме того, фотонные технологии позволяют создавать оптические ускорители для нейросетевых вычислений [8, 9]. Необходимость в последних обусловлена усложнением моделей НС и растущей потребностью в вычислительных ресурсах. Использование классических компьютеров для решения задач машинного обучения не является оптимальным решением, поскольку для архитектуры фон Неймана характерна ограниченная пропускная способность канала между процессором и памятью [10].

Для решения этих проблем рассматриваются аналоговые, в частности, оптические вычислительные устройства [11]. Они обладают рядом преимуществ перед электронными, такими как малые тепловые потери, высокое быстродействие и пропускная способность, простота реализации параллельных вычислений за счет использования различных степеней свободы, присущих световому сигналу (длина

волны, поляризация, мода) [12]. Построение оптических НС может не только способствовать ускорению и улучшению энергоэффективности вычислений, но и позволит создавать нейроморфные архитектуры, на аппаратном уровне отражающие распределенную структуру НС и принципиально отличающиеся от парадигмы фон Неймана [9, 13, 14].

Одной из распространенных конфигураций оптических нейроморфных систем в свободном пространстве является дифракционная нейронная сеть (ДНС) [15]. Будучи аналогом сверточных НС, такая архитектура представляется перспективной для использования в матричных вычислениях и при полностью оптической обработке изображений [16, 17]. В роли слоев ДНС выступают амплитудные и/или фазовые маски, параметры которых служат синаптическими весами, определяемыми в ходе обучения модели сети на компьютере. Данный подход обладает большой гибкостью и позволяет проектировать системы для конкретных задач, разнообразные по архитектуре [18] и методу модуляции сигнала [19, 20], многозадачные сети [21], а также активные НС с возможностью обучения непосредственно на оптическом столе [22].

При обучении ДНС необходимо учитывать ограниченную точность работы математических моделей, а также корректность их применения для описания физических явлений, происходящих в оптиче-

¹⁾e-mail: fedyanin@nanolab.phys.msu.ru

ской системе. Так, для моделирования распространения света в системе зачастую используется дискретное Фурье-преобразование, которое, с одной стороны, позволяет существенно повысить скорость расчетов, но также накладывает определенные ограничения на выбор параметров модельной системы, связанные с условиями его использования [23].

В данной работе рассматриваются дифракционные нейронные сети, работающие в Фурье-пространстве (ФДНС) [24]. Такая архитектура привносит в ДНС распространенный в оптике подход аналоговой Фурье-фильтрации [25, 26]. Экспериментально исследуется корректность моделирования элементов сети, а также проводится численный анализ влияния различных параметров ФДНС на точность ее работы.

2. Структура ФДНС. На рисунке 1 показана схема типичной ФДНС на примере сети, реша-

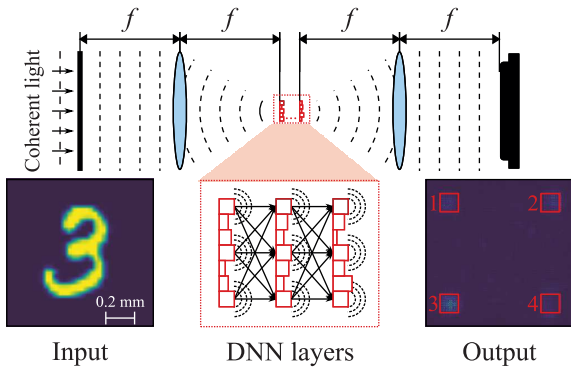


Рис. 1. (Цветной онлайн) Схема оптической ФДНС для задачи классификации

ющей задачу классификации рукописных цифр от 1 до 4. Входное изображение в системе формируется плоской световой волной, проходящей через амплитудную маску. Маска имеет профиль, повторяющий элемент из базы данных MNIST [27], и располагается в передней фокальной плоскости собирающей линзы. В задней фокальной плоскости формируется Фурье-образ исходного изображения, который, в свою очередь, обрабатывается серией дифракционных слоев. Изображение на выходе из ФДНС формируется второй собирающей линзой, совершающей обратное Фурье-преобразование. В выходной плоскости каждому из классов соответствует определенная область изображения (на рис. 1 выделены красными прямоугольниками). Целью обучения ФДНС является подбор геометрических параметров вычислительных слоев, обеспечивающих фокусировку излучения в область, соответствующую классу подаваемого изображения. В качестве вычислительных сло-

ев ФДНС используются фазовые маски, каждая из которых представляет собой массив $N \times N$ пикселей – правильных параллелепипедов различной высоты, играющих роль оптических нейронов. Согласно принципу Гюйгенса–Френеля, каждую точку дифракционного слоя можно рассматривать как источник вторичных волн, амплитуда и фаза которых определяются падающей волной $U(x, y)$ и комплексным коэффициентом пропускания слоя t в данной точке:

$$U'(x, y) = U(x, y) \cdot t(x, y). \quad (1)$$

В работе рассматривается только фазовая модуляция, поскольку коэффициент поглощения материала масок и их толщина малы, и предполагается, что поглощение не вносит существенного вклада в модуляцию сигнала. Поэтому коэффициент пропускания в модели будет иметь вид $t(x, y) = e^{i\phi(x, y)}$, где $\phi(x, y)$ – фазовая задержка, приобретаемая излучением при прохождении через маску. Изображение, получаемое на выходе из слоя НС, будет формироваться в результате интерференции вторичных волн, созданных дифракционным слоем. Задержки, вносимые каждым пикселем, определяют условия интерференции и могут рассматриваться как синаптические веса [12, 15].

Таким образом, с точки зрения сопоставления работы математической модели с реальной системой, необходимо рассмотреть следующие этапы:

- распространение света в оптической системе ФДНС;
- фокусировка света с помощью собирающей линзы;
- распространение света через фазовую маску.

Кроме того, заслуживают внимания ограничения, которые будут накладываться на математическую модель существующими технологиями изготовления и точностью работы электронных компонентов, в частности, чувствительностью системы детектирования, расположенной в выходной плоскости.

3. Расчет распространения излучения в пространстве. Для расчета распределения поля при распространении света на расстояние z воспользуемся его угловым спектром (пространственным Фурье-образом) [25]:

$$A\left(\frac{\alpha}{\lambda}, \frac{\beta}{\lambda}, 0\right) = \iint_{-\infty}^{+\infty} U(x, y, 0) e^{-i2\pi\left(\frac{\alpha}{\lambda}x + \frac{\beta}{\lambda}y\right)} dx dy, \quad (2)$$




Рис. 2. (Цветной онлайн) (а) – Фурье-образы круглой диафрагмы радиусом 900 мкм, сформированные линзами с различными фокусными расстояниями: расчет (верхний ряд) и эксперимент (нижний ряд). (б) – Сравнение расчетных (×) и экспериментальных (○) зависимостей радиуса кольца на Фурье-образе диафрагмы от номера кольца

где $U(x, y, 0)$ – пространственное распределение электромагнитного поля в плоскости входного изображения; λ – длина волны излучения; α, β – углы между волновым вектором \mathbf{k} и осями Ox, Oy соответственно. Величины $f_x = \frac{\alpha}{\lambda}$ и $f_y = \frac{\beta}{\lambda}$ являются пространственными частотами.

Угловые спектры в плоскостях, находящихся на расстоянии z , связаны между собой соотношением:

$$A\left(\frac{\alpha}{\lambda}, \frac{\beta}{\lambda}, z\right) = A\left(\frac{\alpha}{\lambda}, \frac{\beta}{\lambda}, 0\right) e^{i \frac{2\pi}{\lambda} \sqrt{1-\alpha^2-\beta^2} z}. \quad (3)$$

Отсюда можно найти распределение поля в плоскости z как:

$$U(x, y, z) = \mathcal{F}\left(\mathcal{F}(U(x, y, 0)) e^{i \frac{2\pi}{\lambda} \sqrt{1-\alpha^2-\beta^2} z}\right), \quad (4)$$

где \mathcal{F} – Фурье-преобразование. При численном моделировании распространения света используется быстрое преобразование Фурье (БПФ) [28]. Использование БПФ обуславливает выбор шага расчетной сетки: при использовании слишком большого шага может проявляться эффект наложения частот [23], искажающий получаемый Фурье-спектр, в то время как использование слишком мелкого шага существенно замедляет проведение расчетов. В рамках данной работы был выбран шаг, не превышающий нескольких длин волн излучения, что позволяет достичь компромисса между скоростью и точностью вычислений.

4. Моделирование фокусировки света с помощью собирающей линзы. Для прямого и обратного Фурье-преобразования в оптической НС используются собирающие линзы. Чтобы получить поле $U'(x, y)$ непосредственно за линзой, необходимо

умножить распределение поля перед линзой $U(x, y)$ на вносимую фазовую задержку [25]:

$$U'(x, y) = U(x, y) \exp\left[-i \frac{\pi}{\lambda f} (x^2 + y^2)\right]. \quad (5)$$

В используемом приближении не учитывается тот факт, что апертура линзы имеет конечные размеры, и связанный с этим эффект виньетирования – затемнения изображения по мере удаления от оптической оси системы, – что не влияет на точность из-за конечных размеров области детектирования.

С целью проверки моделирования распространения света в пространстве и преобразования, осуществляемого линзой, были численно и экспериментально получены Фурье-образы круглой диафрагмы при помощи линз с различными фокусными расстояниями (100, 150 и 250 мм). Для этого была собрана экспериментальная установка, состоящая из источника излучения (диодного лазера с длиной волны 676 нм), системы линз для уширения пучка, при помощи которой обеспечивалось параллельное освещение, диафрагмы диаметром 900 мкм, собирающей линзы и камеры. Диафрагма располагалась в передней фокальной плоскости линзы; в задней фокальной плоскости размещалась камера, визуализирующая получаемое распределение интенсивности излучения. В рамках численного моделирования на диафрагму падала плоская волна. Модель диафрагмы была реализована следующим образом: излучение, проходящее через отверстие, сохраняло свою амплитуду и фазу; излучение, падающее на непрозрачную часть диафрагмы, полностью поглощалось. Распространение излучения от плоскости диафрагмы до линзы и от линзы до задней фокальной плоскости рассчитывалось по

формуле (4), фазовая задержка при прохождении линзы – по формуле (5).

Фурье-образ круглого отверстия представляет собой серию колец, размер которых зависит от радиуса исходного круга и от фокусного расстояния линзы, формирующей образ (рис. 2а). Для сравнения полученных в ходе расчета и эксперимента изображений были построены зависимости радиусов колец от их номера, считая от центра (рис. 2б). График показывает хорошее соответствие между Фурье-образами, полученными при помощи линз с одинаковыми фокусными расстояниями. Это позволяет сделать вывод о корректности использования данного метода для расчета распространения оптического сигнала через линзу в компьютерной модели ФДНС.

5. Моделирование распространения света через фазовую маску. В процессе обучения компьютерной модели НС определяется матрица фазовых задержек, вносимых нейронами дифракционного слоя. Для известного показателя преломления материала маски n_{res} на заданной длине волны λ фазовые задержки ϕ_i связаны с высотами пикселей d_i следующим образом:

$$d_i = \phi_i \cdot \frac{\lambda}{2\pi(n_{res} - n_{air})}, \quad (6)$$

где n_{air} – показатель преломления окружения маски. Характерные высоты пикселей маски с показателем преломления $n_{res} = 1.65$ составляют менее 1 мкм. Методом, обеспечивающим необходимое разрешение по высоте, может служить двухфотонная лазерная литография, хорошо зарекомендовавшая себя для изготовления фотонных устройств [29], в том числе оптического линейного перцептрона [30]. Главным преимуществом данной технологии в приложении к ДНС является возможность проводить быстрое прототипирование образцов с достаточным пространственным разрешением для видимого спектрального диапазона, что особенно перспективно при проектировании пассивных схем для решения конкретной задачи.

Для проверки результатов расчета распространения света через фазовую маску была выбрана простая система, представляющая собой одиночные фазовые щели – полоски материала, вносящие постоянный набег фазы – различных толщин. Экспериментальный образец был изготовлен на подложке из покровного стекла при помощи двухфотонной лазерной литографии [31] и представлял собой серию полосок шириной 4 мкм, толщина которых варьировалась в диапазоне от 0 до 1.2 мкм с шагом 0.1 мкм;

длина полосок составляла около 50 мкм, что позволяет считать систему одномерной.

На рисунке 3 показана картина распространения излучения при прохождении через фазовые щели,




Рис. 3. (Цветной онлайн) Картины дифракции света на фазовых щелях, вносящих фазовые задержки 90° (слева) и 270° (справа). Для каждой щели слева приведены результаты численного моделирования (цветное изображение – онлайн), эксперимента – справа

вносящие набег фаз, приближенно равные 90° и 270° . Изображения представляют собой набор срезов распределения интенсивности на разных расстояниях от исследуемого объекта. Экспериментально полученные срезы были извлечены из серии снимков, сделанных при перемещении образца вдоль оптической оси системы. Тем самым изменялось расстояние между фазовой щелью и объективом, что позволяло построить на матрице камеры распределение поля в плоскости, удаленной от щели на фиксированное расстояние. При численном моделировании принималось, что поле непосредственно перед образцом представляет собой плоскую волну, которая при прохождении через щель приобретает постоянную фазовую задержку; излучение, проходящее вне щели, остается без изменений. Поле на выбранном расстоянии от образца рассчитывалось по формуле (4). Из получаемых изображений, аналогично эксперименту, были извлечены срезы и сформированы картины распространения света.

Приведенные изображения показывают, что результаты эксперимента соответствуют численному моделированию. Также можно видеть, что при изменении фазового набег максимум интенсивности

в центре картины сменяется минимумом, что позволяет при помощи изменения толщины отдельного пикселя менять картину распределения излучения в районе следующего слоя НС. Данный механизм влияния фазовой задержки, вносимой пикселем, на интенсивность света, попадающего на пиксели следующего слоя, обуславливает роль толщины пикселя как синаптического веса оптического нейрона.

6. Размер пикселя фазовой маски. На вид распределения интенсивности электромагнитного поля за маской влияют не только толщины пикселей, но также их латеральные размеры. Изменение ширины фазовой щели приводит к изменению углов, характеризующих интерференционные максимумы и минимумы, что может быть использовано для изменения связности НС в целом [32]. Однако с точки зрения проектирования полноценной системы, геометрические параметры фазовых масок, в частности размер и количество пикселей, оказываются существенно ограничены методом изготовления. От соотношения между размерами изображения, попадающего на дифракционный слой, и величиной пикселей будет зависеть эффективность работы сети. Это обусловлено тем, что в обработке выделенного участка изображения будет участвовать разное количество оптических нейронов. В ФДНС на первый вычислительный слой подается Фурье-образ входного изображения, и его размер можно адаптировать для заданных параметров фазовых масок путем подбора фокусного расстояния линзы, осуществляющей преобразование Фурье. Для исследования влияния размера Фурье-образа на эффективность работы ДНС была выбрана модель двухслойной сети, обученной классификации цифр от 1 до 4. Были выбраны фазовые маски с размерами пикселей 4 и 10 мкм и латеральными размерами 20 и 8 пикселей соответственно, что позволяет сохранять общие размеры системы. Характерные масштабы Фурье-образов и масок в исследуемой системе представлены на рис. 4а.

На рисунке 4б приведены результаты обучения сетей с линзами, имеющими различные фокусные расстояния (размер входного изображения фиксирован). Видно, что при уменьшении фокусного расстояния и, следовательно, уменьшении Фурье-образа, точность классификации растет. Это может быть объяснено тем, что на фазовую маску попадает больше пространственных гармоник, и тем самым ДНС получает больше информации об исходном изображении. Однако при дальнейшем уменьшении фокусного расстояния точность начинает падать, так как разрешение фазовой маски становится недостаточ-

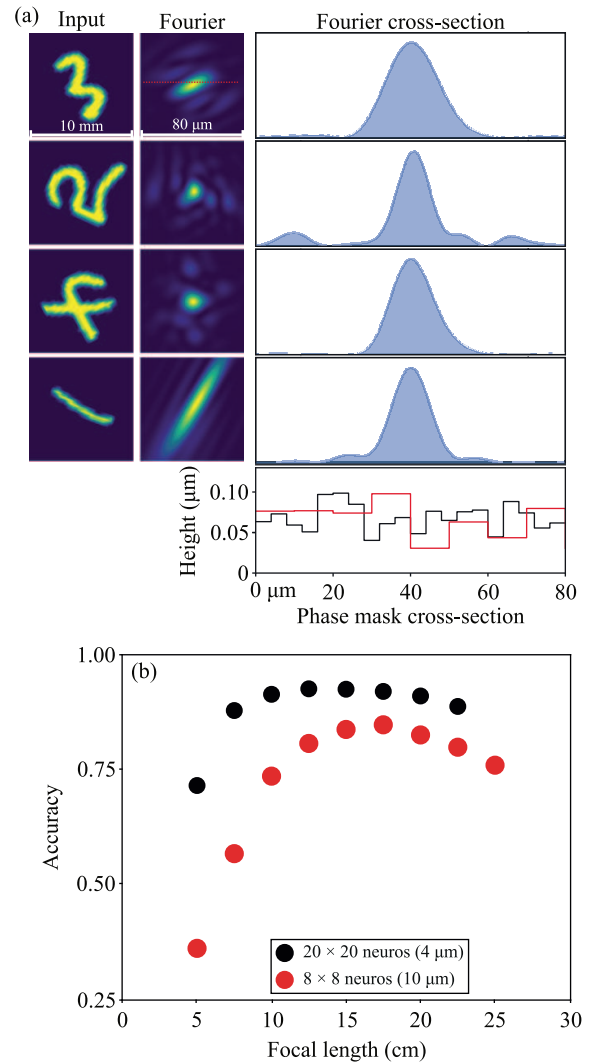


Рис. 4. (Цветной онлайн) (а) – Сравнение размеров Фурье-образов различных цифр ($f = 20$ см) и профиля фазовых масок. (б) – Зависимость точности классификации от фокусного расстояния линзы. Размер пикселя фазовой маски 20×20 нейронов составляет 4 мкм (черная кривая), 8×8 нейронов – 10 мкм (красная кривая)

ным для того, чтобы учитывались более мелкие детали Фурье-спектра, которые становятся мельче, чем пиксели маски. Это подтверждается тем, что при большей плотности пикселей в маске максимум точности смещен в сторону меньшего фокусного расстояния, чему соответствует меньший размер Фурье-образа.

Данный подход к учету размера пикселей вычислительных слоев на этапе проектирования оптической системы может быть также применен для ДНС в реальном пространстве. Это позволит подбирать параметры систем линз или объективов, используемых для формирования изображения в плоскости

входного слоя, исходя из особенностей изображений в решаемых задачах.

7. Учет чувствительности детектора. Важным параметром НС, определяющим результат обучения, является функция потерь L . Если для обучения сети используется перекрестная энтропия [2], интенсивность излучения, попадающего на детекторы, мало отличается от интенсивности фоновой засветки, что затрудняет измерения. При использовании в качестве функции потерь среднего квадрата ошибок излучение фокусируется в целевые области детекторов, однако точность классификации снижается. Для того чтобы воспользоваться преимуществами обеих функций, введем их линейную комбинацию:

$$L = \alpha_{MSE/CE} \cdot L_{MSE} + L_{CE}, \quad (7)$$

где L_{MSE} – средний квадрат ошибок, L_{CE} – перекрестная энтропия, $\alpha_{MSE/CE}$ – масштабный коэффициент.

Для выбора оптимального соотношения между двумя функциями введем безразмерную величину Quality, учитывающую как точность предсказания, так и контраст между интенсивностями в целевой и нецелевой областях детектора. Определим данную характеристику как:

$$\text{Quality} = \frac{T_l - F_l}{\max(T_l - F_l)} \cdot \frac{A - \min(A)}{\max(A) - \min(A)}, \quad (8)$$

где A – точность классификации, T_l – суммарная интенсивность излучения, попадающего в целевой детектор, F_l – среднее значение суммарной интенсивности на нецелевых детекторах; максимальные и минимальные значения величин выбираются из значений, получаемых на тестовом фрагменте базы данных.

Вид функции Quality исследован на примере однослойной сети для бинарной классификации. Такая система не позволяет решать более сложные задачи с приемлемой точностью, однако обеспечивает возможность явно отследить влияние функции потерь на вид распределения интенсивности в выходной плоскости системы. Зависимость параметра Quality от коэффициента $\alpha_{MSE/CE}$ показана на рис. 5а. Данный параметр имеет максимум при значении $\alpha_{MSE/CE} = 10^5$, при котором точность классификации начинает спадать и составляет 95 % при хорошей локализации света в детекторы. На рисунке 5b приведены характерные картины распределения интенсивности в плоскости детекторов, соответствующие преобладающему вкладу перекрестной энтропии ($\alpha_{MSE/CE} \leq 10^3$) слева и увеличению роли среднего квадрата ошибок ($\alpha_{MSE/CE} \geq 10^5$) справа.

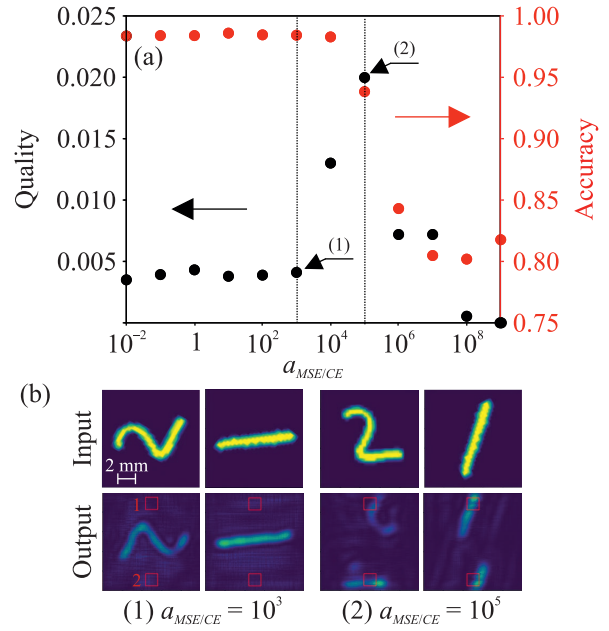


Рис. 5. (Цветной онлайн) (а) – Зависимость параметра Quality и точности классификации от выбора функции потерь. (б) – Пример работы сети для разных значений соотношения между средним квадратом ошибок и кросс-энтропией в функции потерь, соответствующих пунктирным линиям (1) и (2) на рис. (а)

На изображениях прослеживаются описанные выше особенности работы ФДНС, обучаемых с использованием одной из двух рассматриваемых функций потерь.

8. Учет дискретизации по высоте. При обучении модели ДНС фазовые задержки, вносимые вычислительными слоями, могут меняться непрерывно. В то же время любой процесс изготовления подразумевает конечную точность: минимальный шаг изменения высот пикселей фазовых масок (шаг дискретизации) будет ограничен.

Чтобы оценить влияние ограниченной точности изготовления вычислительных слоев на работу сети, были выбраны несколько фазовых масок, обеспечивающих различную точность решения задачи бинарной классификации в однослойной сети. С данными масками была проведена валидация модели сети для различных шагов дискретизации: значения фазовых задержек, вносимых пикселями дифракционного слоя, были округлены до ближайших дискретных значений при выбранном шаге (рис. 6а), затем на валидационной выборке была оценена точность классификации с полученной маской (рис. 6б). Видно, что в широком диапазоне значений шага дискретизации фазы (от 0 до $\pi/2$) точность меняется мало. При дальнейшем увеличении шага дискрети-

зации точность бинарной классификации резко падает до 0.5, что соответствует случайному угадыванию. Наблюдаемое поведение может быть проинтерпретировано при помощи результатов моделирования дифракции света на одиночном пикселе. Величина вносимой фазовой задержки влияет на распределение поля позади пикселя, причем максимум сигнала в центре картины сменяется минимумом при величине фазовой задержки порядка π . Таким образом, при увеличении шага дискретизации возрастает доля пикселей, для которых в результате округления меняется характерное распределение поля за ними. Однако для шага, не превышающего $\pi/2$, доля таких пикселей невелика, что обеспечивает определенную свободу в выборе метода изготовления за счет ограниченных требований к его разрешению.

Для масок, дискретизированных по фазовым задержкам с шагом x , точность классификации сети (A_{est}) может быть оценена как:

$$A_{est} = A_{max} - \left(A_{max} - \frac{1}{2} \right) \cdot \left(\frac{e^{2x} - 1}{e^{2\pi} - 1} \right). \quad (9)$$

Данная аппроксимация была выбрана исходя из следующих соображений: максимальная точность A_{max} наблюдается при отсутствии дискретизации; минимальным значением для бинарной классификации является 0.5, что соответствует случайному угадыванию, и в полученных зависимостях достигается для шага дискретизации около π . Таким образом, можно считать известными точки $(A_{max}, 0)$ и $(0.5, \pi)$, а характер спада хорошо описывается экспоненциальной зависимостью. На рисунке 6b оценки для различных масок обозначены сплошными кривыми. Из графика видно, что предлагаемая аппроксимация соответствует численному моделированию. Такой способ оценки падения точности может быть удобен при выборе экспериментальных параметров, исходя из разрешения используемого метода изготовления.

Искажение высот пикселей фазовых масок в системе может возникать не только из-за ограниченной точности метода изготовления, но также под влиянием случайных процессов. Для проверки устойчивости работы ФДНС к подобным эффектам рассмотрим изменение точности решения задачи классификации при варьировании высоты отдельного пикселя на случайную величину. Тогда фазовую задержку ϕ_i , вносимую пикселем, можно выразить как:

$$\phi_i = \phi_i^{model} + \Delta\phi_i, \quad (10)$$

где ϕ_i^{model} – значение фазовой задержки, полученное при обучении компьютерной модели; $\Delta\phi_i$ – фазовый

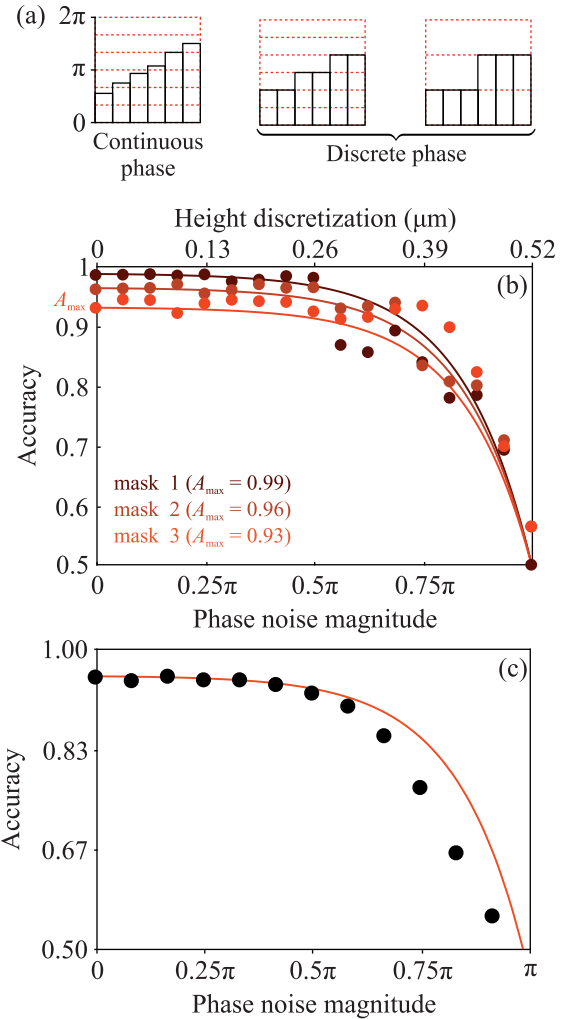


Рис. 6. (Цветной онлайн) (a) – Схематическое изображение идеи дискретизации. (b) – Зависимость точности классификации от шага дискретизации пикселей фазовой маски по высоте и фазе для различных масок. (c) – Зависимость точности классификации от амплитуды фазового шума. Точками показаны результаты численного моделирования, кривыми – аппроксимации по формуле (9)

шум. Для фазового шума, величина которого распределена равномерно на интервале $[-\Delta\phi^{max}, +\Delta\phi^{max}]$, зависимость точности классификации от амплитуды $\Delta\phi^{max}$ будет иметь вид, представленный на рис. 6c. Влияние, оказываемое случайным фазовым шумом на точность классификации, сходно с влиянием дискретизации высот пикселей: при отклонениях фазы в пределах $\pi/2$ точность снижается незначительно, в интервале от $\pi/2$ до π наблюдается резкий спад. Количественные характеристики этого спада, однако, существенно зависят от типа распределения шума, что указывает на важность учета специфики возникающих погреш-

ностей при проектировании реальных устройств. Полученные результаты позволяют заключить, что для сохранения функциональности сети на уровне, близком к теоретическому максимуму, изготовление фазовых масок должно обеспечивать точность формирования набег фазы на отдельном пикселе порядка $\pi/4$.

9. Заключение. В рамках данной работы экспериментально проверены расчеты распространения света через элементы Фурье-дифракционной нейронной сети, тем самым показана корректность используемых приближений и возможность применения описанной математической модели. Для одиночного оптического нейрона – пикселя дифракционного слоя – был проиллюстрирован физический смысл аналогии между синаптическим весом нейрона и фазовой задержкой, вносимой пикселем.

Проведенный в работе анализ влияния геометрии ФДНС на точность классификации позволяет учитывать воздействие различных параметров оптической системы на эффективность работы сети при проектировании. Перспективным направлением дальнейших исследований может стать поиск зависимости связности ДНС от геометрических параметров системы дифракционных слоев, а также длины волны используемого излучения. Такая оценка может быть полезна как с точки зрения возможности проектирования сетей с заданной связностью, так и для экономии вычислительных ресурсов при обучении.

Также в работе была проведена попытка оценить влияние на качество работы сети факторов, характерных для реальной оптической системы. В частности, показано снижение точности классификации в сети с дискретно меняющимися высотами пикселей фазовых масок, и приведен простой метод оценки точности для выбранного шага дискретизации. Продемонстрировано влияние выбора функции потерь на характер распределения интенсивности излучения в плоскости детекторов. Приведенный анализ не исчерпывает всех факторов, связанных с переходом от моделирования к эксперименту. В частности, для случая многослойных ДНС следует учитывать возможные неточности, связанные с позиционированием дифракционных слоев. Внедрение в ФДНС алгоритмов обучения, позволяющих повысить устойчивость системы к латеральному сдвигу [33], и проверка их влияния на эффективность работы сети могут являться следующим шагом в исследовании данной темы.

Авторы выражают благодарность К. Р. Сафронову за помощь в разработке программного обеспечения для моделирования ФДНС.

Финансирование работы. Исследование выполнено за счет гранта Российского научного фонда # 25-12-00355 и при поддержке некоммерческого Фонда развития науки и образования “Интеллект”.

Конфликт интересов. Авторы данной работы заявляют, что у них нет конфликта интересов.

1. C. M. Bishop, “Neural networks and their applications”, *Rev. Sci. Instrum.* **65**, 1803 (1994).
2. I. Goodfellow, Y. Bengio, and A. Courville, *Deep learning* (MIT press, Cambridge, 2016).
3. O. I. Abiodun, A. Jantan, A. E. Omolara, K. V. Dada, N. A. E. Mohamed, and H. Arshad, “State-of-the-art in artificial neural network applications: A survey”, *Heliyon* **4**, e00938 (2018).
4. G. Genty, L. Salmela, J. M. Dudley, D. Brunner, A. Kokhanovskiy, S. Kobtsev, and S. K. Turitsyn, “Machine learning and applications in ultrafast photonics”, *Nat. Photonics* **15**, 91 (2021).
5. К. Р. Сафронов, В. О. Бессонов, А. А. Федянин, “Оптимизация многослойных фотонных структур с помощью искусственных нейронных сетей для получения заданного оптического отклика”, *Письма в ЖЭТФ* **114**, 360 (2021) [K. R. Safronov, V. O. Bessonov, and A. A. Fedyanin, “Optimization of multilayer photonic structures using artificial neural networks to obtain a target optical response”, *JETP Lett.* **114**, 321 (2021)].
6. А. А. Попкова, А. А. Федянин, “Сверточные нейронные сети для предсказания морфологических и нелинейно-оптических свойств тонких пленок квазидвумерных материалов”, *Письма в ЖЭТФ* **118**, 513 (2023) [A. A. Popkova and A. A. Fedyanin, “Convolutional neural networks for predicting morphological and nonlinear optical properties of thin films of quasi-two-dimensional materials”, *JETP Lett.* **118**, 502 (2023)].
7. E. Kuprikov, A. Kokhanovskiy, K. Serebrennikov, and S. Turitsyn, “Deep reinforcement learning for self-tuning laser source of dissipative solitons”, *Sci. Rep.* **12**, 7185 (2022).
8. Г. А. Колосов, А. С. Шорохов, А. А. Федянин, “Численное моделирование фотонного тензорного ядра для аппаратного ускорения оптических матрично-векторных вычислений”, *Письма в ЖЭТФ* **120**, 970 (2024) [G. A. Kolosov, A. S. Shorokhov, and A. A. Fedyanin, “Numerical simulation of a photonic tensor core for the hardware acceleration of the optical matrix–vector multiplication”, *JETP Lett.* **120**, 932 (2024)].
9. B. J. Shastri, A. N. Tait, T. Ferreira de Lima, M. A. Nahmias, H. T. Peng, and P. R. Prucnal, “Principles of neuromorphic photonics”, in *Unconventional Computing* (Springer, N.Y., 2018), p. 83.

10. T. Ferreira De Lima, B.J. Shastri, A.N. Tait, M.A. Nahmias, and P.R. Prucnal, "Progress in neuromorphic photonics", *Nanophotonics* **6**, 577 (2017).
11. T. J. Naughton and D. Woods, *Optical computing, in Unconventional Computing* (Springer, N.Y., 2018), p. 57.
12. А. И. Мусорин, А. С. Шорохов, А. А. Чежегов, Т. Г. Балуян, К. Р. Сафронов, А. В. Четвертухин, А. А. Грунин, А. А. Федянин, "Подходы фотоники для реализации нейроморфных вычислений", *Успехи физических наук* **193**, 1284 (2023) [A.I. Musorin, A.S. Shorokhov, A.A. Chezhegov, T.G. Baluian, K.R. Safronov, A.V. Chetvertukhin, A.A. Grunin, and A.A. Fedyanin, "Photonics approaches to the implementation of neuromorphic computing", *Phys.-Uspekhi* **66**, 1211 (2023)].
13. H. J. Caulfield, J. Kinser, and S. K. Rogers, "Optical neural networks", *Proc. IEEE* **77**, 1573 (2002).
14. C. Huang, V. J. Sorger, M. Miscuglio et al. (Collaboration), "Prospects and applications of photonic neural networks", *Adv. Phys.: X* **7**, 1981155 (2022).
15. X. Lin, Y. Rivenson, N. T. Yardimci, M. Veli, Y. Luo, M. Jarrahi, and A. Ozcan, "All-optical machine learning using diffractive deep neural networks", *Science* **361**, 1004 (2018).
16. H. Chen, S. Lou, Q. Wang, P. Huang, H. Duan, and Y. Hu, "Diffractive deep neural networks: theories, optimization, and applications", *Appl. Phys. Rev.* **11**, 021332 (2024).
17. Z. Li, F. Liu, W. Yang, S. Peng, and J. Zhou, "A survey of convolutional neural networks: analysis, applications, and prospects", *IEEE Trans. Neural Netw. Learn. Syst.* **33**, 6999 (2021).
18. H. Dou, Y. Deng, T. Yan, H. Wu, X. Lin, and Q. Dai, "Residual D²NN: training diffractive deep neural networks via learnable light shortcuts", *Opt. Lett.* **45**, 26882691 (2020).
19. M. Miscuglio, Z. Hu, S. Li, J. K. George, R. Capanna, H. Dalir, P. M. Bardet, P. Gupta, and V. J. Sorger, "Massively parallel amplitude-only Fourier neural network", *Optica* **7**, 1812 (2020).
20. T. Fujita, H. Sakaguchi, J. Zhang, H. Nonaka, S. Sumi, H. Awano, and T. Ishibashi, "Magneto-optical diffractive deep neural network", *Opt. Express* **30**, 36889 (2022).
21. Z. Duan, H. Chen, and X. Lin, "Optical multi-task learning using multi-wavelength diffractive deep neural networks", *Nanophotonics* **12**, 893 (2023).
22. T. Zhou, L. Fang, T. Yan, J. Wu, Y. Li, J. Fan, H. Wu, X. Lin, and Q. Dai, "In situ optical backpropagation training of diffractive optical neural networks", *Photonics Res.* **8**, 940 (2020).
23. R. C. Gonzalez and R. E. Woods, *Digital Image Processing* (Pearson Education, N.Y., 2002).
24. T. Yan, J. Wu, T. Zhou, H. Xie, F. Xu, J. Fan, L. Fang, X. Lin, and Q. Dai, "Fourier-space diffractive deep neural network", *Phys. Rev. Lett.* **123**, 023901 (2019).
25. J. W. Goodman, *Introduction to Fourier optics* (Roberts and Company Publishers, Englewood, Colorado, 2005).
26. V. V. Yushkov, V. A. Sitnyansky, A. S. Shorokhov, and A. A. Fedyanin, "Analog optical correlation augmented by Mie-resonant metasurfaces", *ACS Photonics* **11**, 2506 (2024).
27. Y. LeCun, C. Cortes, and C. Burges, MNIST handwritten digit database (2010).
28. R. E. Blahut, *Fast Algorithms for Digital Signal Processing* (Addison-Wesley Pub. Co., Boston, 1985).
29. H. Wang, W. Zhang, D. Ladika et al. (Collaboration), "Two-photon polymerization lithography for optics and photonics: fundamentals, materials, technologies, and applications", *Adv. Funct. Mater.* **33**, 2214211 (2023).
30. E. Goi, X. Chen, Q. Zhang, B. P. Cumming, S. Schoenhardt, H. Luan, and M. Gu, "Nanoprinted high-neuron-density optical linear perceptrons performing near-infrared inference on a CMOS chip", *Light Sci. Appl.* **10**, 40 (2021).
31. T. G. Baluian, D. I. Pechkurova, A. V. Konovalova, A. A. Popkova, and A. A. Fedyanin, "Free-space and solid-matrix-media diffraction neural network masks made by two-photon lithography", *Proc. SPIE* **13234**, Advanced Laser Processing and Manufacturing VIII, 132340A (2024).
32. H. Chen, J. Feng, M. Jiang, Y. Wang, J. Lin, J. Tan, and P. Jin, "Diffractive deep neural networks at visible wavelengths", *Engineering* **7**, 1483 (2021).
33. D. V. Soshnikov, L. L. Doskolovich, G. A. Motz, E. V. Byzov, E. A. Bezus, D. A. Bykov, and N. L. Kazanskiy, "Designing robust diffractive neural networks with improved transverse shift tolerance", *J. Opt. Soc. Am. A* **42**, 699 (2025).