

# 集成光电突触的衍射神经网络非线性仿真研究

卢嘉英<sup>1,2</sup>, 陈希<sup>1,2\*</sup>

<sup>1</sup>上海理工大学智能科技学院, 上海

<sup>2</sup>上海理工大学光子芯片研究院, 上海

收稿日期: 2025年3月24日; 录用日期: 2025年4月17日; 发布日期: 2025年4月27日

## 摘要

衍射深度神经网络(diffraction deep neural network, D<sup>2</sup>NN)因其低能耗、高速度及优异的抗干扰性能, 在无透镜成像和图像分类等任务中表现出显著优势。然而, 由于缺乏非线性激活层, D<sup>2</sup>NN的泛化能力和拟合能力在复杂任务中受限。为此, 本文提出一种基于石墨烯纳米壁(graphene nanowalls, GNWs)光电突触的非线性衍射深度神经网络。通过在D<sup>2</sup>NN输出层引入GNWs光电突触, 利用其灵敏的光电响应生成与光强相关的非线性光电流, 从而实现新型激活函数super-softmax。数值模拟结果表明, 无论输出层是否进行归一化, super-softmax激活函数的性能均优于传统的softmax激活函数。在单层非线性D<sup>2</sup>NN (64 × 64神经元)用于MNIST手写数字识别任务时, 分类精度最高达95%。本研究为实现衍射深度神经网络的闭环在线学习提供了重要的理论支持。

## 关键词

衍射深度神经网络, 石墨烯纳米壁光电突触, 非线性激活函数

# Nonlinear Simulation of Diffraction Neural Networks Integrated with Optoelectronic Synapses

Jiaying Lu<sup>1,2</sup>, Xi Chen<sup>1,2\*</sup>

<sup>1</sup>School of Artificial Intelligence Science and Technology, University of Shanghai for Science and Technology, Shanghai

<sup>2</sup>Institute of Photonic Chips, University of Shanghai for Science and Technology, Shanghai

Received: Mar. 24<sup>th</sup>, 2025; accepted: Apr. 17<sup>th</sup>, 2025; published: Apr. 27<sup>th</sup>, 2025

\*通讯作者。

文章引用: 卢嘉英, 陈希. 集成光电突触的衍射神经网络非线性仿真研究[J]. 建模与仿真, 2025, 14(4): 848-857.  
DOI: 10.12677/mos.2025.144335

## Abstract

Diffraction deep neural network (D<sup>2</sup>NN) has shown significant advantages in tasks such as lensless imaging and image classification due to their low energy consumption, high speed, and excellent interference resistance. However, the lack of nonlinear activation layers limits the generalization and fitting capabilities of D<sup>2</sup>NN in complex tasks. To address this issue, this paper proposes a nonlinear diffraction deep neural network based on graphene nanowalls (GNWs) optoelectronic synapses. By introducing GNWs optoelectronic synapses into the output layer of the D<sup>2</sup>NN, their sensitive optoelectronic response is utilized to generate a nonlinear photocurrent that is dependent on light intensity, thereby realizing a novel activation function, super-softmax. Numerical simulation results demonstrate that the performance of the super-softmax activation function is superior to that of the traditional softmax activation function, regardless of whether the output layer is normalized. When applied to a single-layer nonlinear D<sup>2</sup>NN (64 × 64 neurons) for the MNIST handwritten digit recognition task, the classification accuracy reaches up to 95%. This study provides important theoretical support for achieving closed-loop online learning in diffraction deep neural networks.

## Keywords

Diffraction Deep Neural Network, Graphene Nanowalls Optoelectronic Synapses, Nonlinear Activation Function

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

传统冯·诺依曼架构由于存储单元和计算单元的分离,需要频繁进行数据传输,导致高能耗问题[1]。而神经形态计算将计算与存储集成于同一硬件单元,为计算架构的发展提供了一条新的路径。人工神经网络(artificial neural network, ANN)是一种受人脑结构启发的神经形态计算模型[2]-[4]。ANN 依赖激活函数来实现反向传播,以提供梯度用于更新权重。Softmax 作为 ANN 中常用的激活函数,对每个输入值施加指数函数,并通过所有指数值的总和进行归一化[5][6]。然而,由于 ANN 依赖电子路径进行计算,因此面临处理速度较慢、高能耗及物理限制等瓶颈问题[7]。

光学神经形态计算具有低能耗、高速信息传输以及强抗干扰能力,在神经形态计算领域展现出广阔的应用前景[8]-[10]。特别是,衍射深度神经网络(D<sup>2</sup>NN)利用光波在三维空间中传播的特性,实现无干扰且高度并行的信息传输,从而在深度学习过程中接近零能耗和零时延[11]-[13]。尽管 D<sup>2</sup>NN 具备诸多优势,但如何在其中集成激活函数仍然是一个巨大挑战。如果缺乏非线性机制,D<sup>2</sup>NN 每一层的输出仅是前一层输入的线性函数,难以有效学习数据中复杂和抽象的模式[14]-[16]。

近年来,人工光电突触被开发用于将光信号转换为电响应。这些突触具有记忆效应,在光刺激消失后仍能保持电响应,并且可以通过调节光强、波长等光学参数来调整记忆持续时间[17]-[24]。本文提出了一种基于石墨烯纳米壁(GNWs)的人工光电突触,并将其集成至 D<sup>2</sup>NN 以实现激活功能。GNWs 突触能够将光刺激转换为光电流信号,并表现出随光强增大呈指数增长的非线性光电流响应。值得注意的是,该指数增长的速率超过了传统 softmax 函数的增长速率。在 D<sup>2</sup>NN 进行手写数字分类任务时的仿真结果表明,相较于采用 softmax 进行激活的 D<sup>2</sup>NN,集成 GNWs 光电突触的网络性能显著提高。

## 2. 非线性 D<sup>2</sup>NN 建模方法

### 2.1. GNWs 光电突触性能测试


光电测量采用探针台和精密半导体参数分析仪(4200 SCS, Keithley)进行, 在-4 V 至 4 V 的偏置电压范围内完成检测。使用信号发生器控制的光纤激光器产生激光脉冲, 设置了七种不同的激光功率, 分别为 0.1 W/cm<sup>2</sup>、0.209 W/cm<sup>2</sup>、0.298 W/cm<sup>2</sup>、0.354 W/cm<sup>2</sup>、0.412 W/cm<sup>2</sup>、0.451 W/cm<sup>2</sup> 和 0.493 W/cm<sup>2</sup>。光电流值通过计算总电流值减去暗电流值获得。基于实验数据, 通过公式(1)拟合不同激光功率与对应光电流之间的关系:

$$y = ae^{bx} \quad (1)$$

其中,  $a$  为常数,  $b$  为指数系数。

### 2.2. 衍射神经网络模型建立

本文提出了一种新型的非线性衍射深度神经网络, 该架构由输入层、一层衍射层以及基于石墨烯纳米壁光电突触的非线性输出层组成, 如图 1(a)所示。手写数字选自修改版国家标准与技术研究所(MNIST)数据集。基于 D<sup>2</sup>NN 的识别过程在 Python 3.7.0 环境下进行模拟, 并采用 Google 开发的 TensorFlow 框架完成深度学习任务[25][26]。均方误差[27]被用作损失函数, 学习率设定为 0.001。反向传播训练采用随机梯度下降算法[28]实现。人工神经元与后续层神经元之间的连接关系基于瑞利-索末菲衍射方程[29]进行建模。



**Figure 1.** D<sup>2</sup>NN integrated with GNWs optoelectronic synapses. (a) Layered structure of the D<sup>2</sup>NN; (b) Schematic diagram of the GNWs optoelectronic synapse-based structure; (c) Nonlinear photocurrent response of the GNWs synapse; (d) Diffraction neural network using super-softmax and softmax activation functions

**图 1.** 集成 GNWs 光电突触的 D<sup>2</sup>NN。(a) D<sup>2</sup>NN 的层结构; (b) 基于 GNWs 光电突触的结构示意图; (c) GNWs 突触的非线性光电流响应; (d) 使用 super-softmax 和 softmax 激活函数的衍射神经网络图

在训练过程中, 通过不断优化衍射层的相位分布, 使网络性能达到最优。当输入数字“6”时, 输出层对应数字“6”区域的光强达到最大值。石墨烯纳米壁光电突触由 Si 层、SiO<sub>2</sub> 层、金电极及石墨烯纳米壁组成, 其结构如图 1(b)所示。输入携带数据信息的相干光经过衍射层调制后, 传输至由光电突触组成的非线性输出层。光电突触根据接收到的光强生成按指数分布的光电流, 如图 1(c)所示, 其中光强与光电流的关系由公式(1)确定。使用光电突触拟合的指数函数构造新的输出层非线性激活函数, 我们称之为 super-softmax, 可以用于手写数字识别任务。该函数定义如下:

$$\text{super-softmax}(x_i) = \frac{e^{bx_i}}{\sum_{j=1}^n e^{bx_j}} \quad (2)$$

$b$  的参数值使用公式(1)确定。设有一个长度为  $n$  的向量  $x = [x_1, x_2, \dots, x_n]$ , 这是神经网络输出的未归一化得分向量。其中,  $x_i$  是向量  $x$  中的第  $i$  个元素,  $\sum_{j=1}^n e^{bx_j}$  是对所有得分取指数后的总和。super-softmax 函数用于将神经网络输出的原始得分转换为一个概率分布, 所有输出值的总和为 1。这意味着每个输出值  $\text{super-softmax}(x_i)$  都在  $[0, 1]$  范围内, 并且代表了该类别的概率。对于分类任务, super-softmax 可以提供每个类别的相对置信度。

Super-softmax 的工作机制可以通过其数学表达式来理解: super-softmax 通过对每个得分  $x_i$  进行指数运算来放大较大值, 并且由于指数函数的单调性, 它会强调相对较大的值。对于某些得分, 指数函数会使其变得更显著, 而其他较小的得分则相对被“压制”。计算 super-softmax 时, 我们首先计算所有得分的指数和(即分母部分), 然后用每个得分的指数除以这个总和, 确保输出的概率总和为 1。这种归一化操作意味着, 如果某个类别的得分远大于其他类别, 那么它的概率值会接近 1, 其他类别的概率则趋近于 0。如果所有类别的得分差异较小, super-softmax 则会产生一个相对平衡的概率分布。

尽管 super-softmax 函数本身没有显式的参数需要选择, 但其在神经网络中的使用和输出层的表现受一些超参数的影响。这些超参数的选择对最终的性能有重要影响。首先是学习率, super-softmax 通常与梯度下降算法结合使用, 因此学习率的选择对模型的训练非常重要。如果学习率过大, 梯度下降可能会不稳定, 导致无法收敛; 学习率过小则可能导致训练速度过慢。其次可能存在梯度消失的问题。在使用 super-softmax 时, 由于指数函数的存在, 网络在反向传播过程中可能会遇到梯度爆炸或梯度消失的问题, 尤其是在输入值较大的时候。为了缓解这一问题, 通常需要对输入进行适当的规范化。

为进行对比分析, 输出层还采用了传统的 softmax 函数作为激活函数来生成对比结果, 如图 1(d)所示。Softmax 函数定义如下:


$$\text{softmax}(x_i) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \quad (3)$$

### 3. 结果与讨论

#### 3.1. GNWs 光电突触的非线性光电流响应

图 2(a)显示了基于 GNWs 的人工光电突触的正视 SEM 图像。两个金电极的宽度为 300  $\mu\text{m}$ , 高度为 640  $\mu\text{m}$ , 电极间距为 70  $\mu\text{m}$ 。金电极通过 GNWs 互连(图 2(b)), 为了模拟人脑的工作机制, 金电极分别对应轴突和树突端, GNWs 充当囊泡, 而光生电子/空穴类比于神经递质。当施加激光脉冲时, 突触光电流响应被激发。

图 2(c)展示了在 0.45 W/cm<sup>2</sup> 激光脉冲下的光电流响应, 结果表明 1 秒脉冲可产生 0.105  $\mu\text{A}$  的光电流。在脉冲关闭后, 光电流逐渐衰减, 表明该器件具备记忆特性。



**Figure 2.** Optoelectronic properties of GNWs artificial synapses. (a) Front view SEM image of the GNWs optoelectronic synapse; (b) High-resolution SEM image of the synapse; (c) Photocurrent response to a single pulse within 1 second under a laser power of 0.45 W/cm<sup>2</sup>; (d) Fitted exponential relationship between laser power and photocurrent

**图 2.** 基于 GNWs 人工突触的光电特性。(a) GNWs 光电突触正视 SEM 图；(b) 突触的高分辨率 SEM 图像；(c) 在 0.45 W/cm<sup>2</sup> 的激光功率下，1 秒内对单个脉冲的光电流响应；(d) 激光功率和光电流之间的拟合指数关系

测量了不同激光功率下的光电流响应。在 0.1 W/cm<sup>2</sup> 至 0.49 W/cm<sup>2</sup> 的激光功率范围内，光电流从 0.024 μA 增加到 0.134 μA。实验结果表明，人工光突触可通过提高光功率从短时记忆(short term memory, STM)向长时记忆(long term memory, LTM)转变[30]。此外，激光功率密度与光电流之间的关系可用指数函数  $y = 0.013 * e^{4.64x}$  拟合，如图 3(d)所示。更重要的是，该指数函数表明公式(1)中的参数  $b$  值为 4.64，突触的光电转换特性表现出比 softmax 函数更强的非线性。


### 3.2. 输出层非线性 D<sup>2</sup>NN 仿真结果

在本研究中，我们将 super-softmax 函数应用于 D<sup>2</sup>NN 的输出层，来完成 0~9 十个手写数字的识别任务。其计算过程如图 3(a)所示。该过程始于输入数字数据通过衍射层调制，在输出层生成对应于数字 0~9 的光强值  $Y_1, Y_2, \dots, Y_{10}$ 。这些值分别通过了 super-softmax 函数与 softmax 函数处理，生成最终的输出值。在模型训练过程中，采用随机梯度下降算法对这些概率进行反向传播，并优化网络权重。经过多次迭代，模型收敛至最优状态，实现对输入数据的有效识别。

在不同衍射层神经元数量下进行了基于 D<sup>2</sup>NN 的仿真实验，并将识别准确率结果呈现在图 3(b)中。对于 16 × 16 神经元的 D<sup>2</sup>NN，使用 softmax 非线性激活函数时的准确率为 0.25，而使用 super-softmax 函数后，准确率提高至 0.59，相较而言提升了 34%。对于 32 × 32 神经网络，使用 softmax 函数时的准确率为 0.64，而使用 super-softmax 函数后，准确率提高至 0.90。然而，在较大规模的神经网络(48 × 48, 64 × 64 和 80 × 80)中，当输出值过大时，会出现数值溢出问题，进而影响损失函数的计算[31]。此外，



图 3(c)展示了在不同神经元数量下, 衍射层的相位调制分布。在较大规模的神经网络( $48 \times 48$ ,  $64 \times 64$  和  $80 \times 80$ )中, 由于网络停止运算, 未能得到相位分布。实验结果表明, 在  $D^2NN$  输出层使用 uper-softmax 作为非线性激活函数, 在人工智能识别任务中具有显著优势。



**Figure 3.** Handwritten digit recognition results of the nonlinear  $D^2NN$ . (a) Computation process of the  $D^2NN$  with super-softmax activation function in the output layer; (b) Recognition accuracy of the  $D^2NN$  using softmax and super-softmax activation functions; (c) Phase distribution of the diffraction layer under different numbers of neurons

**图 3.** 非线性  $D^2NN$  的手写数字识别结果。(a) 输出层采用 super-softmax 激活函数  $D^2NN$  的计算过程; (b) 采用 softmax 和 super-softmax 函数的  $D^2NN$  识别准确率; (c) 不同神经元下衍射层的相位分布

为解决数值溢出问题并进一步提高识别准确率, 在非线性激活函数中引入了归一化过程。其计算过程如图 4(a)所示。首先,  $D^2NN$  的衍射层在输出层生成对应于数字 0~9 的光强值。然后, 这些值按照公式

$$z_i = \left( \frac{x_i}{\max(x_1, x_2, x_3, \dots, x_{10})} \right)^2$$


进行归一化处理, 归一化后的值分别通过 super-softmax 非线性函数和 softmax

非线性函数进行转换, 以生成最终的输出值并优化识别性能。基于归一化过程的识别准确率在  $16 \times 16$ 、 $32 \times 32$ 、 $48 \times 48$ 、 $64 \times 64$  和  $80 \times 80$  神经元数量下的结果如图 4(b)所示, 图 4(c)则展示了相应的相位调制分布。归一化过程有效限制了指数函数的输入数据范围, 成功避免了溢出问题并确保了网络的稳定性。此外, 归一化后的 super-softmax 函数在识别准确率方面明显优于归一化 softmax 函数。

在  $64 \times 64$  神经元的网络中, softmax 和 super-softmax 函数的准确率分别为 0.912 和 0.951, 性能提升最高。图 5(a)为  $64 \times 64$  神经网络的识别准确率曲线, 图 5(b)、图 5(c)分别为此网络使用两种激活函数下的混淆矩阵结果图。图 6 展示了  $64 \times 64$  神经网络对 0~9 十个数字的识别结果图, 可以看出, 在输入数字对应的输出位置上, 输出光强最大, 证明网络很好地识别了输入数据。


为了验证集成 GNWs 光电突触形成的非线性激活函数——super-softmax 函数的性能, 我们将其分别应用于前馈神经网络(Artificial Neural Network, ANN)和具有时间序列处理能力的递归神经网络(Recurrent

Neural Network, RNN)。在具体实现中, 我们在含有单层隐藏层( $64 \times 64$  神经元)的三种网络架构中, 验证了归一化后的 super-softmax 函数的效果。仿真结果表明, super-softmax 函数在这三种网络架构中的表现均优于传统 softmax 函数, 如表 1 所示, 进一步展示了其在神经网络中的潜力和优势。



**Figure 4.** Handwritten digit recognition results of the nonlinear D<sup>2</sup>NN with normalized activation function. (a) Computation process of the D<sup>2</sup>NN with normalized Super-Sigmoid activation function in the output layer; (b) Recognition accuracy of the D<sup>2</sup>NN using Softmax and Super-Sigmoid activation functions; (c) Phase distribution of the diffraction layer under different numbers of neurons

**图 4.** 具有归一化激活函数的非线性 D<sup>2</sup>NN 手写数字识别结果。(a) 输出层采用归一化后 super-softmax 激活函数 D<sup>2</sup>NN 的计算过程; (b) 采用 softmax 和 super-softmax 函数的 D<sup>2</sup>NN 识别准确率; (c) 不同神经元下行衍射层的相位分布



**Figure 5.** Recognition accuracy of the nonlinear D<sup>2</sup>NN with  $64 \times 64$  neurons. (a) Accuracy variation curve of the D<sup>2</sup>NN using normalized Softmax and Super-Sigmoid functions; (b) Confusion matrix of the D<sup>2</sup>NN with Softmax activation function; (c) Confusion matrix of the D<sup>2</sup>NN with Super-Sigmoid activation function

**图 5.**  $64 \times 64$  神经元数量下非线性 D<sup>2</sup>NN 的识别准确率。(a) 采用归一化 softmax 和 super-softmax 函数的 D<sup>2</sup>NN 的准确率变化曲线; (b) 具有 softmax 激活函数的 D<sup>2</sup>NN 混淆矩阵; (c) 具有 super-softmax 激活函数的 D<sup>2</sup>NN 的混淆矩阵

## 4. 总结

本论文提出了一种将 D<sup>2</sup>NN 与人工光电突触集成以实现非线性激活函数的方案。使用的 GNWs 光电突触, 通过增加光功率, 可以实现短时记忆(STM)到长时记忆(LTM)的转换。激光功率密度与光电流之间



**Figure 6.** Energy distribution of the nonlinear D<sup>2</sup>NN for the recognition of ten handwritten digits 0~9 with 64 × 64 neurons  
**图 6.** 64 × 64 神经元数量下非线性 D<sup>2</sup>NN 对 0~9 十个手写数字识别的能量分布图

**Table 1.** Performance of super-softmax function in different networks  
**表 1.** Super-softmax 函数在不同网络下的性能

|               | 准确率(ANN) | 准确率(RNN) | 准确率(D <sup>2</sup> NN) |
|---------------|----------|----------|------------------------|
| Softmax       | 91.1%    | 89.4%    | 91.2%                  |
| Super-softmax | 94.3%    | 93.3%    | 95.1%                  |

的关系可通过指数函数  $y = ae^{bx}$  进行建模, 其中  $b$  的计算值为 4.64。随后, 我们构建了一个具有非线性激活函数的 D<sup>2</sup>NN, 并利用基于 GNWs 的突触阵列作为输出层。经过衍射层处理的光强值通过 super-softmax 非线性函数  $y_i = \frac{e^{4.64x_i}}{\sum_{j=1}^n e^{4.64x_j}}$  进行转换, 以用于反向传播和权重优化。在 16 × 16 和 32 × 32 神经网络中, 由于较高的非线性特性, 采用 super-softmax 函数的手写数字识别性能优于采用 softmax 函数  $y_i = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}}$  的情况。然而, 在更大规模神经网络中, 识别准确率因数值溢出问题而下降。为了解决该问题, 在非线性和



活函数中引入归一化处理, 归一化公式为  $z_i = \left( \frac{x_i}{\max(x_1, x_2, x_3, \dots, x_{10})} \right)^2$ 。在  $64 \times 64$  神经网络中, 归一

化 softmax 和归一化 super-softmax 的识别准确率分别达到 0.912 和 0.951。利用光电突触阵列实现的 super-softmax 激活函数, 为光计算技术提供了一种有前景的解决方案, 在图像识别、模式识别和数据密集型计算等应用场景中具有广阔的应用潜力。

## 参考文献

- [1] Yao, P., Wu, H., Gao, B., Tang, J., Zhang, Q., Zhang, W., *et al.* (2020) Fully Hardware-Implemented Memristor Convolutional Neural Network. *Nature*, **577**, 641-646. <https://doi.org/10.1038/s41586-020-1942-4>
- [2] Woźniak, S., Pantazi, A., Bohnstingl, T. and Eleftheriou, E. (2020) Deep Learning Incorporating Biologically Inspired Neural Dynamics and In-Memory Computing. *Nature Machine Intelligence*, **2**, 325-336. <https://doi.org/10.1038/s42256-020-0187-0>
- [3] Zhang, Q., Yu, H., Barbiero, M., Wang, B. and Gu, M. (2019) Artificial Neural Networks Enabled by Nanophotonics. *Light: Science & Applications*, **8**, Article No. 42. <https://doi.org/10.1038/s41377-019-0151-0>
- [4] Thompson, R.F. (1986) The Neurobiology of Learning and Memory. *Science*, **233**, 941-947. <https://doi.org/10.1126/science.3738519>
- [5] Li, J., Mengu, D., Yardimci, N.T., Luo, Y., Li, X., Veli, M., *et al.* (2021) Spectrally Encoded Single-Pixel Machine Vision Using Diffractive Networks. *Science Advances*, **7**, eabd7690. <https://doi.org/10.1126/sciadv.abd7690>
- [6] Zhou, Y., Zhao, X., Xu, J., Chen, G., Tat, T., Li, J., *et al.* (2024) A Multimodal Magnetoelastic Artificial Skin for Underwater Haptic Sensing. *Science Advances*, **10**, eadj8567. <https://doi.org/10.1126/sciadv.adj8567>
- [7] Markram, H., Muller, E., Ramaswamy, S., Reimann, M.W., Abdellah, M., Sanchez, C.A., *et al.* (2015) Reconstruction and Simulation of Neocortical Microcircuitry. *Cell*, **163**, 456-492. <https://doi.org/10.1016/j.cell.2015.09.029>
- [8] Zhang, H., Gu, M., Jiang, X.D., Thompson, J., Cai, H., Paesani, S., *et al.* (2021) An Optical Neural Chip for Implementing Complex-Valued Neural Network. *Nature Communications*, **12**, Article No. 457. <https://doi.org/10.1038/s41467-020-20719-7>
- [9] Wang, T., Ma, S., Wright, L.G., Onodera, T., Richard, B.C. and McMahon, P.L. (2022) An Optical Neural Network Using Less than 1 Photon per Multiplication. *Nature Communications*, **13**, Article No. 123. <https://doi.org/10.1038/s41467-021-27774-8>
- [10] Bernstein, L., Sludds, A., Panuski, C., Trajtenberg-Mills, S., Hamerly, R. and Englund, D. (2023) Single-Shot Optical Neural Network. *Science Advances*, **9**, eadg7904. <https://doi.org/10.1126/sciadv.adg7904>
- [11] Lin, X., Rivenson, Y., Yardimci, N.T., Veli, M., Luo, Y., Jarrahi, M., *et al.* (2018) All-Optical Machine Learning Using Diffractive Deep Neural Networks. *Science*, **361**, 1004-1008. <https://doi.org/10.1126/science.aat8084>
- [12] Ranno, L., Gupta, P., Gradkowski, K., Bernson, R., Weninger, D., Serna, S., *et al.* (2022) Integrated Photonics Packaging: Challenges and Opportunities. *ACS Photonics*, **9**, 3467-3485. <https://doi.org/10.1021/acsp Photonics.2c00891>
- [13] Goi, E., Schoenhardt, S. and Gu, M. (2022) Direct Retrieval of Zernike-Based Pupil Functions Using Integrated Diffractive Deep Neural Networks. *Nature Communications*, **13**, Article No. 7531. <https://doi.org/10.1038/s41467-022-35349-4>
- [14] Dong, C., Cai, Y., Dai, S., Wu, J., Tong, G., Wang, W., *et al.* (2023) An Optimized Optical Diffractive Deep Neural Network with Orelu Function Based on Genetic Algorithm. *Optics & Laser Technology*, **160**, Article ID: 109104. <https://doi.org/10.1016/j.optlastec.2022.109104>
- [15] Fang, T., Li, J., Zhang, X. and Dong, X. (2021) Classification Accuracy Improvement of the Optical Diffractive Deep Neural Network by Employing a Knowledge Distillation and Stochastic Gradient Descent B-Lasso Joint Training Framework. *Optics Express*, **29**, 44264-4474. <https://doi.org/10.1364/oe.446890>
- [16] Pour Fard, M.M., Williamson, I.A.D., Edwards, M., Liu, K., Pai, S., Bartlett, B., *et al.* (2020) Experimental Realization of Arbitrary Activation Functions for Optical Neural Networks. *Optics Express*, **28**, 12138-12148. <https://doi.org/10.1364/oe.391473>
- [17] Yu, J., Yang, X., Gao, G., Xiong, Y., Wang, Y., Han, J., *et al.* (2021) Bioinspired Mechano-Photonic Artificial Synapse Based on Graphene/MoS<sub>2</sub> Heterostructure. *Science Advances*, **7**, eabd9117. <https://doi.org/10.1126/sciadv.abd9117>
- [18] Park, H., Kim, H., Lim, D., Zhou, H., Kim, Y., Lee, Y., *et al.* (2020) Retina-Inspired Carbon Nitride-Based Photonic Synapses for Selective Detection of UV Light. *Advanced Materials*, **32**, Article ID: 1906899. <https://doi.org/10.1002/adma.201906899>

- 
- [19] Seo, S., Lee, J., Lee, R., Kim, T.H., Park, S., Jung, S., *et al.* (2021) An Optogenetics-Inspired Flexible Van Der Waals Optoelectronic Synapse and Its Application to a Convolutional Neural Network. *Advanced Materials*, **33**, Article ID: 2102980. <https://doi.org/10.1002/adma.202102980>
  - [20] Huang, X., Li, Q., Shi, W., Liu, K., Zhang, Y., Liu, Y., *et al.* (2021) Dual-Mode Learning of Ambipolar Synaptic Phototransistor Based on 2D Perovskite/Organic Heterojunction for Flexible Color Recognizable Visual System. *Small*, **17**, Article ID: 2102820. <https://doi.org/10.1002/sml.202102820>
  - [21] Li, Y., Wang, J., Yang, Q. and Shen, G. (2022) Flexible Artificial Optoelectronic Synapse Based on Lead-Free Metal Halide Nanocrystals for Neuromorphic Computing and Color Recognition. *Advanced Science*, **9**, Article ID: 2202123. <https://doi.org/10.1002/adv.202202123>
  - [22] He, K., Liu, Y., Yu, J., Guo, X., Wang, M., Zhang, L., *et al.* (2022) Artificial Neural Pathway Based on a Memristor Synapse for Optically Mediated Motion Learning. *ACS Nano*, **16**, 9691-9700. <https://doi.org/10.1021/acsnano.2c03100>
  - [23] Islam, M.M., Krishnaprasad, A., Dev, D., Martinez-Martinez, R., Okonkwo, V., Wu, B., *et al.* (2022) Multiwavelength Optoelectronic Synapse with 2D Materials for Mixed-Color Pattern Recognition. *ACS Nano*, **16**, 10188-10198. <https://doi.org/10.1021/acsnano.2c01035>
  - [24] Kim, M. and Lee, J. (2020) Synergistic Improvement of Long-Term Plasticity in Photonic Synapses Using Ferroelectric Polarization in Hafnia-Based Oxide-Semiconductor Transistors. *Advanced Materials*, **32**, Article ID: 1907826. <https://doi.org/10.1002/adma.201907826>
  - [25] Gregory, W., MacEachern, R., Takao, S., Lawrence, I.R., Nab, C., Deisenroth, M.P., *et al.* (2024) Scalable Interpolation of Satellite Altimetry Data with Probabilistic Machine Learning. *Nature Communications*, **15**, Article No. 7453. <https://doi.org/10.1038/s41467-024-51900-x>
  - [26] Pang, B., Nijkamp, E. and Wu, Y.N. (2019) Deep Learning with Tensorflow: A Review. *Journal of Educational and Behavioral Statistics*, **45**, 227-248. <https://doi.org/10.3102/1076998619872761>
  - [27] Wang, Z., Chen, J. and Hoi, S.C.H. (2021) Deep Learning for Image Super-Resolution: A Survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **43**, 3365-3387. <https://doi.org/10.1109/tpami.2020.2982166>
  - [28] Kim, T., Oh, J., Kim, N.Y., Cho, S. and Yun, S. (2021) Comparing Kullback-Leibler Divergence and Mean Squared Error Loss in Knowledge Distillation. *Proceedings of the 30th International Joint Conference on Artificial Intelligence*, Montreal, 19-27 August 2021, 2628-2635. <https://doi.org/10.24963/ijcai.2021/362>
  - [29] Burch, J. and Di Falco, A. (2018) Surface Topology Specific Metasurface Holograms. *ACS Photonics*, **5**, 1762-1766. <https://doi.org/10.1021/acsp Photonics.7b01449>
  - [30] Li, R., Dong, Y., Qian, F., Xie, Y., Chen, X., Zhang, Q., *et al.* (2023) CsPbBr<sub>3</sub>/Graphene Nanowall Artificial Optoelectronic Synapses for Controllable Perceptual Learning. *Photonix*, **4**, Article No. 4. <https://doi.org/10.1186/s43074-023-00082-8>
  - [31] Blanchard, P., Higham, D.J. and Higham, N.J. (2020) Accurately Computing the Log-Sum-Exp and Softmax Functions. *IMA Journal of Numerical Analysis*, **41**, 2311-2330. <https://doi.org/10.1093/imanum/draa038>