

# 多波长二值光学衍射神经网络

陈 龙<sup>1,2</sup>, 栾海涛<sup>2</sup>

<sup>1</sup>上海理工大学光电信息与计算机工程学院, 上海

<sup>2</sup>上海理工大学光子芯片研究院, 上海

收稿日期: 2024年8月2日; 录用日期: 2024年8月26日; 发布日期: 2024年8月30日

## 摘 要

随着人工智能的快速发展, 传统基于电子的计算受到摩尔定律的限制。衍射神经网络作为一种新兴的技术, 凭借其优越的鲁棒性, 已经在许多领域得到广泛应用。在这里, 我们提出了一种可以在多波长中泛用的光学衍射神经网络。该神经网络在多个波长的图像识别准确率都能保持在88%以上, 为处理各种环境下的光芯片提供可能。

## 关键词

衍射神经网络, 多波长, 光芯片

# Multi-Wavelength Binary Optical Diffraction Neural Network

Long Chen<sup>1,2</sup>, Haitao Luan<sup>2</sup>

<sup>1</sup>School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai

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

Received: Aug. 2<sup>nd</sup>, 2024; accepted: Aug. 26<sup>th</sup>, 2024; published: Aug. 30<sup>th</sup>, 2024

## Abstract

With the rapid development of artificial intelligence, traditional electronic-based computation is constrained by Moore's Law. Diffraction neural networks, as an emerging technology, have been widely applied in many fields due to their superior robustness. Here, we propose an optical diffraction neural network that can be used across multiple wavelengths. The image recognition accuracy of this neural network maintains over 88% across multiple wavelengths, providing possi-

文章引用: 陈龙, 栾海涛. 多波长二值光学衍射神经网络[J]. 建模与仿真, 2024, 13(5): 5013-5020.

DOI: 10.12677/mos.2024.135453

bilities for processing optical chips in various environments.

## Keywords

**Diffraction Neural Network, Multi-Wavelength, Optical Chip**

Copyright © 2024 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

随着人工智能和大数据技术的快速发展,为了打破摩尔定律的限制,光计算开始成为研究的热点。与传统的基于电子的计算相比,光计算有着高带宽、低能耗、抗干扰和高并行性等优势。这些特性使得光计算非常适合处理人工智能、信号处理、组合优化等复杂任务。

近年来,光学衍射神经网络(Diffractive Neural Network, DNN)因其独特的计算方式而受到研究者的关注[1]。DNN 通过自由空间中的光传播和衍射实现神经元链接,以光速进行线性乘法运算和求和运算,从而实现高效的光学机器学习。DNN 具有三维的物理架构,由多层衍射层级联构成,可以直接处理光学图像模拟信号。与之相比的是以硅光子技术实现的二维光学神经网络[2] [3],它需要先将数据时序化后再进行输入。因此,DNN 可以实现更高通量的光学数据处理。DNN 的独特优势使其已经被广泛用于图像识别[4] [5]、光学计算[6]-[8]、相位成像[9]和散射图像重建[10]-[12]等任务,而且由于光学系统的高带宽、高互联和内部并行处理能力[13]-[15],DNN 在处理大规模数据时显示出强大的鲁棒性[16] [17]。

然而,此前的 DNN 大多仅能工作于单一波长[18]-[20],使用其他波长的光源时会使得衍射层的相位调制发生变化,从而导致 DNN 失效。实现多波长工作,可以增加 DNN 的信息通道,从而进一步提高信息通量,因此具有重要意义。同时,目前的 DNN 是基于连续相位调制进行训练的,在实际制造当中,连续相位的 DNN 面临着如何制造和集成的技术难题。举例来说,可见光和近红外波段的 DNN 常用的实现方式是超表面技术[20]-[22]和传统半导体光刻刻蚀技术[23],它们均难以实现连续相位衍射层的制备。二值相位型 DNN 具有制造简单、鲁棒性和一致性更高的优势,因此更加适合于未来的大规模制造和应用。

在这里,我们提出了一种多波长工作的二值 DNN 的设计方法。通过多个损失函数进行多目标训练,最终实现了可以在 400 nm 和 800 nm 两个波长下同时工作的 DNN。该网络具有 2 层结构,每层之间间距为 3 cm,每层神经元数目  $256 \times 256$ ,它可以实现 Fashion-Modified National Institute of Standards and Technology (Fashion-MNIST)数据集[24]在两种波长(800 nm 和 400 nm)下的准确识别,其准确率都能够达到 88%以上。本文提出的设计方法可以用于不同波长的二值 DNN 设计,增加了 DNN 的信息通道,同时具有制备更加简单、鲁棒性更高的优势,有助于推动 DNN 的实际应用。


## 2. 用于多波长的 DNN

### 2.1. DNN 原理

图 1(a)是我们用于多波长 DNN 光学推理的示意图,表明它可以在多个波长下同时进行任务。如图 1(b)所示,DNN 模型主要分为三部分,分别为输入层,隐藏层和输出层,输入层是 Fashion-MNIST 数据集的振幅信息,通过角谱理论衍射传播至 DNN 隐藏层。具体衍射表达式为:

$$U(x, y, z) = \mathcal{F}^{-1} \{ A_0(f_x, f_y, 0) H(f_x, f_y) \} \quad (1)$$

式中  $H(f_x, f_y) = \begin{cases} e^{jkz\sqrt{1-(\lambda f_x)^2-(\lambda f_y)^2}} & \\ 0, & \text{other} \end{cases}$ , 是自由空间的传递函数。  $A_0(f_x, f_y, 0)$  表示输出光场的复振幅。



**Figure 1.** For DNN under multi-wavelength operation (a) DNN schematic; (b) network description of DNN physical processes  
**图 1.** 用于多波长工作下的 DNN (a) DNN 原理图; (b) DNN 物理过程的网络描述

我们的 DNN 设计流程如图 2 所示。首先, 我们使用 8000 张 Fashion-MNIST 数据集作为输入(每类图像 800 张), 每张的大小为  $256 \times 256$  像素, 单个像素的大小我们设置为  $8 \mu\text{m}$ 。输入层在自由空间中角谱衍射传播 10 cm, 到达隐藏的相位层, 相位层每层的间距为 2 cm。由于我们的 DNN 是一个多目标优化模型, 因此输入会在两个不同的波长下进行传播。在经过相位调制后, 再在自由空间中角谱衍射传播 3 cm, 得到输出平面。我们将两个任务的输出结果与训练的目标进行比较, 并利用公式 2 计算输出平面光强和目标之间的误差均方差, 从而得到两个损失函数。

$$E(\varphi_i^q) = \frac{1}{K} \sum_k (s_k^{M+1} - g_k^{M+1})^2 \quad (2)$$

式中  $K$  表示输出平面的测量点数。为了后续方便二值化, 我们 DNN 设计优化的范围控制在  $0 \leq \varphi_i^q \leq 2\pi$  的范围内, 求取  $\min_a E(\varphi_i^q)$ 。

然后, 我们对这两个损失函数进行加权求和, 权重需要根据网络最终输出情况进行调整, 本文中我们设置 800 nm 和 400 nm 的权重分别为 0.3 和 0.7。接下来, 我们将误差反向传播以迭代更新衍射网络, 根据目标特性定义损失函数来评估衍射神经网络的输出, 并采用随机梯度下降优化算法来迭代优化 DNN 的相位参数。应用误差反向传播训练 DNN, 需要计算损失函数对所有网络变量的梯度, 损失函数对第  $q$  层的误差梯度表达式为

$$\frac{\partial E(\varphi_i^q)}{\partial \varphi_i^q} = \frac{4}{K} \sum_k (s_k^{M+1} - g_k^{M+1}) \cdot \text{Real} \left\{ (m_k^{M+1})^* \frac{\partial m_k^{M+1}}{\partial \varphi_i^q} \right\} \quad (3)$$

式中:  $m_k^{M+1} = \sum_{k_1} n_{k_1,k}^M$  为前一层衍射网络神经元的相位因子,  $\frac{\partial m_k^{M+1}}{\partial \varphi_i^q}$  表示输出层复数光场对前面网络层的神经元相位值的梯度, **Real** 表示对复数光场取实部运算。在误差反向传播的每次迭代过程中, 将少量的训练数据输入到衍射神经网络中, 计算每个层的上述梯度, 并相应地更新 DNN。




Figure 2. Flowchart of the DNN training

图 2. DNN 训练流程图

## 2.2. 用于多波长的 DNN 仿真

经过 DNN 的训练, 对其进行离散二值化后得到如图 3 所示两层相位。





Figure 3. The training phase layers of DNN (a) layer 1; (b) layer 2

图 3. DNN 训练相位层结果(a) 第一层相位; (b) 第二层相位

我们在测试集中使用 2000 张图像(每种类型为 200 张图像)测试训练好的 DNN 网络。图 4 的结果显示, DNN 在两种波长情况下, 对 Fashion-MNIST 数据集识别的准确率分别为 91.5%和 91.4%。结果证明, 我们的训练的 DNN 网络可以在多种波长下同时工作, 具有较高的精度(>85%)。如图 4 所示, 当光学图像被输入到 DNN 中时, 输出层上相应的圈状区域将显示出最大的强度。我们注意到输入的光学图像没有被完全调制, 这是由于二元相位分布, 入射光无法得到充分调制, 导致衍射效率下降。从归一化信号中可以看出, DNN 具有相对较高的信噪比。与目标区域相比, 其他区域的光强明显较低。



**Figure 4.** The training results of DNN (a) the training results of 800 nm; (b) the training results of 400 nm  
**图 4.** DNN 输出结果(a) 800 nm 训练结果; (b) 400 nm 训练结果

## 2.3. 分析讨论

### 2.3.1. 对准误差的影响

衍射层之间的对准往往是衍射神经网络实验中最困难的点。我们也模拟了这一对准误差的影响。如图 5 所示, 大于 2~3 像素(大约 16~24  $\mu\text{m}$ )的偏移量才会导致精度的显著下降。现代双面光刻技术已经可以确保对准误差保持在 1~2  $\mu\text{m}$  的范围内, 因此该误差不会影响芯片的性能。

### 2.3.2. 波长误差的影响

由于激光器制作过程中的不确定性、温度变化、光学元件的磨损等, 可能会导致激光器输出的光波波长与设计或期望的波长之间存在一定的偏差。这一偏差对于某些应用来说可能是关键的, 特别是在需要高精度和稳定性的领域。

因此, 我们也对我们网络对波长的泛化性进行测试, 如图 6 所示, 可以看到网络在一定的波长幅度内, 仍然能够对网络进行一个精确的识别。但是, 在波长超过 $\pm 7$  nm 的变化范围时, 准确率就会有所下



降, 这一问题可以通过增加网络的复杂度来解决, 由一个双波长的神经网络逐渐变成三波长以至更多波长的神经网络, 最终实现一个宽谱神经网络。




Figure 5. The alignment error of DNN (a) 800 nm; (b) 400 nm  
图 5. DNN 对准误差(a) 800 nm 波长下; (b) 400 nm 波长下




Figure 6. The wavelength error of DNN (a) 400 nm; (b) 800 nm  
图 6. DNN 波长误差(a) 400 nm 波长下; (b) 800 nm 波长下

### 2.3.3. DNN 衍射层数的影响

当网络参数固定后为了验证 DNN 深度信息即层数对结果预测能力的影响, 本文分别使用 1 层、2 层、3 层和 4 层的 4 种深度信息对网络进行训练。经过 400 次的训练后, 最终得到不同层数下的识别准确率(如表 1 所示)。从 1 层增加到 3 层时候, 800 nm (400 nm)波长下对 Fashion-MNIST 数据集的识别准确率从 86.8% (88.9%)升到 90.4% (92.1%), 可见在所选取参数下, 衍射器件层数增加对神经网络信息处理能力是有正向影响的。但当层数增加到 4 层的时, 准确率不再升高, 这说明深度信息已经饱和, 再多的层数也不会使网络性能进一步提高, 甚至还会使得网络性能下降。因此认为, 网络在完成某项任务的时候所需要的神经元个数是存在最优值的, 少了不能实现好的约束结果, 多了在神经网络训练过程中会引入了冗余不可控自由度, 这可能造成神经网络性能下降。

**Table 1.** The effect of the number of diffraction layers on the accuracy  
**表 1.** 衍射层数对准确率的影响

| 层数 | 准确率(800 nm) | 准确率(400 nm) |
|----|-------------|-------------|
| 1  | 86.8%       | 88.9%       |
| 2  | 88%         | 90%         |
| 3  | 90.4%       | 92.3%       |
| 4  | 91.3%       | 92.1%       |

2.3.4. 多任务训练精度

在我们的研究中，我们仍需要验证多任务训练是否显著优于单任务训练。为此，我们特别关注了在双任务训练框架下，仅执行一个任务时对训练效果的影响。我们的假设是，多任务训练能够提高认知灵活性和任务切换能力，从而在处理复杂或同时出现的任务时表现出更高的效率。

如表 2 所示，当只进行单波长情况下训练时，训练得到的结果就在另外的波长情况下无法识别出目标图像。这一结果表明，多任务训练显著优于单任务训练。

**Table 2.** Multi-task training accuracy  
**表 2.** 多任务训练精度

|     | 仅训练 800 nm |        | 仅训练 400 nm |        |
|-----|------------|--------|------------|--------|
|     | 800 nm     | 400 nm | 800 nm     | 400 nm |
| 准确率 | 92%        | 19%    | 1%         | 94%    |

3. 结论

在本项工作中，我们提出了一种可以用于多波长下工作的二值 DNN，能够在两种不同波长(800 nm 和 400 nm)情况下做到精确识别 Fashion-MNIST 数据集。我们考虑了多种可能存在的误差情况，如 DNN 对准误差、波长误差，发现 DNN 具有鲁棒性，能够在一定程度的误差下，依然保持良好的准确率。为了探究神经网络深度对 DNN 的影响，我们测试了 1~4 层衍射层 DNN 对于数据集的识别准确率，发现神经网络的深度信息是存在饱和的。未来，本工作的研究成果可能在光通信、光计算等领域显示出巨大潜力，同时也为人工智能光学芯片的研究做好铺垫。

基金项目

基金项目：国家重点研发计划(2022YFB2804301)。

参考文献

[1] 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>

[2] Mennel, L., Symonowicz, J., Wachter, S., Polyushkin, D.K., Molina-Mendoza, A.J. and Mueller, T. (2020) Ultrafast Machine Vision with 2D Material Neural Network Image Sensors. *Nature*, **579**, 62-66. <https://doi.org/10.1038/s41586-020-2038-x>

[3] Teng, C., He, W., Du, W., Wu, J. and Wang, Z. (2023) Nonlinear Absorption of 2D Materials and Their Application in Optical Neural Networks. *Journal of the Optical Society of America B*, **40**, 2007-2012. <https://doi.org/10.1364/josab.482672>

[4] Bai, B., Li, Y., Luo, Y., Li, X., Çetintaş, E., Jarrahi, M., *et al.* (2023) All-Optical Image Classification through Un-

- known Random Diffusers Using a Single-Pixel Diffractive Network. *Light: Science & Applications*, **12**, Article No. 69. <https://doi.org/10.1038/s41377-023-01116-3>
- [5] Traore, B.B., Kamsu-Foguem, B. and Tangara, F. (2018) Deep Convolution Neural Network for Image Recognition. *Ecological Informatics*, **48**, 257-268. <https://doi.org/10.1016/j.ecoinf.2018.10.002>
  - [6] Kazanskiy, N.L., Butt, M.A. and Khonina, S.N. (2022) Optical Computing: Status and Perspectives. *Nanomaterials*, **12**, Article 2171. <https://doi.org/10.3390/nano12132171>
  - [7] McMahon, P.L. (2023) The Physics of Optical Computing. *Nature Reviews Physics*, **5**, 717-734. <https://doi.org/10.1038/s42254-023-00645-5>
  - [8] Wu, J., Lin, X., Guo, Y., Liu, J., Fang, L., Jiao, S., *et al.* (2022) Analog Optical Computing for Artificial Intelligence. *Engineering*, **10**, 133-145. <https://doi.org/10.1016/j.eng.2021.06.021>
  - [9] Zhou, J., Pu, H. and Yan, J. (2024) Spatiotemporal Diffractive Deep Neural Networks. *Optics Express*, **32**, 1864-1877. <https://doi.org/10.1364/oe.494999>
  - [10] Barbastathis, G., Ozcan, A., Situ, G. (2019) On the Use of Deep Learning for Computational Imaging. *Optica*, **6**, 921-943. <https://doi.org/10.1364/OPTICA.6.000921>
  - [11] Ozcan, A., Rivenson, Y., Wu, Y., *et al.* (2022) Method and System for Phase Recovery and Holographic Image Reconstruction Using a Neural Network. Google Patents US20190294108A1.
  - [12] Wu, Y., Rivenson, Y., Zhang, Y., Wei, Z., Günaydin, H., Lin, X., *et al.* (2018) Extended Depth-of-Field in Holographic Imaging Using Deep-Learning-Based Autofocusing and Phase Recovery. *Optica*, **5**, 704-710. <https://doi.org/10.1364/optica.5.000704>
  - [13] Almeida, V.R., Barrios, C.A., Panepucci, R.R. and Lipson, M. (2004) All-Optical Control of Light on a Silicon Chip. *Nature*, **431**, 1081-1084. <https://doi.org/10.1038/nature02921>
  - [14] Wetzstein, G., Ozcan, A., Gigan, S., Fan, S., Englund, D., Soljačić, M., *et al.* (2020) Inference in Artificial Intelligence with Deep Optics and Photonics. *Nature*, **588**, 39-47. <https://doi.org/10.1038/s41586-020-2973-6>
  - [15] 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>
  - [16] 成科, 胡晓楠, 贺瑜, 等. 基于光学衍射神经网络的完美涡旋光轨道角动量识别[J]. 量子电子学报, 2022, 39(2): 262-271.
  - [17] Heng, X., Gan, J., Zhang, Z., Li, J., Li, M., Zhao, H., *et al.* (2018) All-Fiber Stable Orbital Angular Momentum Beam Generation and Propagation. *Optics Express*, **26**, 17429-17436. <https://doi.org/10.1364/oe.26.017429>
  - [18] Goi, E. and Gu, M. (2024) Perspective on Photonic Neuromorphic Computing. In: Gu, M., Goi, E., Wang, Y., Wan, Z., Dong, Y., Zhang, Y. and Yu, H., Eds., *Neuromorphic Photonic Devices and Applications*, Elsevier, 353-375. <https://doi.org/10.1016/b978-0-323-98829-2.00009-8>
  - [19] 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. 7532. <https://doi.org/10.1038/s41467-022-35349-4>
  - [20] Qian, C., Lin, X., Lin, X., Xu, J., Sun, Y., Li, E., *et al.* (2020) Performing Optical Logic Operations by a Diffractive Neural Network. *Light: Science & Applications*, **9**, Article No. 59. <https://doi.org/10.1038/s41377-020-0303-2>
  - [21] Liu, C., Ma, Q., Luo, Z.J., Hong, Q.R., Xiao, Q., Zhang, H.C., *et al.* (2022) A Programmable Diffractive Deep Neural Network Based on a Digital-Coding Metasurface Array. *Nature Electronics*, **5**, 113-122. <https://doi.org/10.1038/s41928-022-00719-9>
  - [22] Luo, X., Hu, Y., Ou, X., Li, X., Lai, J., Liu, N., *et al.* (2022) Metasurface-Enabled on-Chip Multiplexed Diffractive Neural Networks in the Visible. *Light: Science & Applications*, **11**, Article No. 158. <https://doi.org/10.1038/s41377-022-00844-2>
  - [23] Chen, H., Feng, J., Jiang, M., Wang, Y., Lin, J., Tan, J., *et al.* (2021) Diffractive Deep Neural Networks at Visible Wavelengths. *Engineering*, **7**, 1483-1491. <https://doi.org/10.1016/j.eng.2020.07.032>
  - [24] Xiao, H., Rasul, K. and Vollgraf, R. (2017) Fashion-MNIST: A Novel Image Dataset for Benchmarking Machine Learning Algorithms. arXiv: 170807747. <https://doi.org/10.48550/arXiv.1708.07747>