

DOI:10.20033/j.1003-7241.(2026)01-0017-05

## 不同训练算法下光子神经网络鲁棒性能研究

陆鸣豪<sup>1</sup>, 陆云清<sup>1</sup>, 曹雯<sup>2</sup>, 刘美玉<sup>2</sup>, 邵晓锋<sup>2</sup>, 王瑾<sup>2</sup>

(1. 南京邮电大学 电子与光学工程、柔性电子(未来技术)学院, 江苏 南京 210003;

2. 南京邮电大学 通信与信息工程学院, 江苏 南京 210003)

**摘要:** 优化了训练算法和学习率组合以提高光子神经网络(optical neural network, ONN)对器件误差的鲁棒性能,同时确保其对数字图像的高精确识别。仿真搭建两种全连接 ONN 架构,即 GridNet 和 FFTNet,其中使用马赫曾德尔干涉仪(Mach-Zehnder interferometers, MZI)作为光子器件,并对含有器件误差的 ONN 进行了不同算法的训练,包括随机梯度下降(stochastic gradient descent, SGD)、均方根传递(root mean square prop, RMSprop)、适应性矩估计(adaptive moment estimation, Adam)和自适应梯度下降(adaptive gradient, Adagrad)。结果表明,在不同程度的器件误差下,FFTNet 型 ONN 比 GridNet 型 ONN 更鲁棒。具体来说,采用学习率为 0.005 的 RMSprop 和 Adam 算法以及学习率为 0.5 的 Adagrad 算法训练的 FFTNet 型 ONN 在数字图像识别精度和器件误差鲁棒性上表现最佳。优化训练算法和学习率的组合可以有效提高 ONN 的鲁棒性能。

**关键词:** 光子神经网络; 器件误差; 马赫曾德尔干涉仪; 梯度下降算法; 学习率

**中图分类号:** TP183 **文献标志码:** A **文章编号:** 1003-7241(2026)01-0017-05

## Performance robustness of optica neural networks under different training algorithms

LU Minghao<sup>1</sup>, LU Yunqing<sup>1</sup>, CAO Wen<sup>2</sup>, LIU Meiyu<sup>2</sup>, SHAO Xiaofeng<sup>2</sup>, WANG Jin<sup>2</sup>

(1. College of Electronics and Optical Engineering, Flexible Electronics (Future Technology), Nanjing University of Posts and Telecommunications, Nanjing 210003, Jiangsu, China; 2. College of Telecommunications & Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, Jiangsu, China)

**Abstract:** This paper optimizes the combination of training algorithms and learning rates to enhance the robustness of optical neural networks (ONN) against device errors while ensuring high-precision recognition of digital images. Two fully connected ONN architectures, namely GridNet and FFTNet, are simulated, employing mach-zehnder interferometers (MZI) as photonics devices. Different algorithms, including stochastic gradient descent (SGD), root mean square prop (RMSprop), adaptive moment estimation (Adam), and adaptive gradient (Adagrad), are employed to train ONNs with device errors. Results indicate that under varying degrees of device errors, FFTNet outperforms GridNet in robustness. Specifically, FFTNet trained with RMSprop and Adam algorithms at a learning rate of 0.005, and with Adagrad algorithm at a learning rate of 0.5, exhibits the highest performance in both digital image recognition accuracy and device error robustness. Therefore, optimizing the combination of training algorithms and learning rates effectively improves the robustness of ONNs.

**Keywords:** Optical Neural Network; device error; Mach-Zehnder interferometers; gradient descent algorithm; learning rate

近年来,光子神经网络(optical neural network, ONN)技术为人工智能芯片的发展带来了机遇。随着信号处理速度的提高,传统人工神经网络的存储器和处理器之间传输的速度不匹配,这导致了神经网络计算效率低的同时能耗也较高。而光学计算凭借高效能、低串扰、光速和大规模并行处理的潜力,为神经网络的数据传输速度和能耗的突破创造了机遇<sup>[1-3]</sup>。

ONN 是一种利用光学特性加速神经网络计算的技术。它利用光子元件的传输特性实现矩阵乘法,从而模拟神经网络线性层的矩阵计算。ONN 技术具有高速、低功耗、高并行度的优点,在图像处理<sup>[4]</sup>、语音处理和机器翻译等领域有着广泛的应用前景。

目前 ONN 已经有多种实现方案,包括带微环谐振器的相干光学神经网络<sup>[5]</sup>和通过衍射光学实现的卷积网

收稿日期:2024-04-07;录用日期:2024-05-08

基金项目:国家自然科学基金(61575096)

作者简介:陆鸣豪(1999—),男,硕士,研究方向:基于光子芯片的人工智能网络技术。

通信作者:王瑾(1972—),男,博士,教授,研究方向:应用于下一代光网络的混合集成光子器件与技术、基于光子芯片的神经网络技术,以及有机和无机纳米光子材料与器件的基础研究、设计开发和制备。

引用本文:陆鸣豪,陆云清,曹雯,等. 不同训练算法下光子神经网络鲁棒性能研究[J]. 自动化技术与应用, 2026,45(1):17-21. (LU Minghao, LU Yunqing, CAO Wen, et al. Performance robustness of optica neural networks under different training algorithms[J]. Techniques of Automation and Applications, 2026,45(1):17-21.)

络<sup>[6]</sup>等。但是网络中存在的器件误差会导致性能的下降,即 ONN 的鲁棒性能较弱。已经有一些通过修改 ONN 的物理架构来减轻网络中器件误差带来的影响的方案。Shokraneh 等报道了一种基于 MZI 的金刚石网格架构,通过形成一个对称的结构来抵抗 ONN 中的器件误差<sup>[7]</sup>。Fang 等证明了在使用随机梯度下降算法训练时,FFTNet 型 ONN 对器件误差的鲁棒性较高<sup>[8]</sup>。Mojaver 等提出了一种 Bokun 网络架构,在保持最佳光学深度的前提下,对器件误差的鲁棒性能更强<sup>[9]</sup>。然而,这些方法需要额外的级联 MZI 或波导交叉来实现 MZI 之间的互联,从而增加了光学可编程处理器的尺寸和结构的复杂性。

为了实现神经网络的功能,ONN 需要经过反向传播式的训练,从而确定神经元最佳的连接权重即光子器件的传输特性。由于 ONN 的特殊性质,常用于电子神经网络的训练算法可能需要进行适应性调整才能在 ONN 中发挥最佳效果。此外,学习率的选择也可能因为 ONN 的特殊性而有所不同。由于光学计算的特性,权重更新的步长大小可能要根据光子器件的传输特性进行调整。然而,不同的训练算法和学习率组合对于 ONN 的训练效果和网络鲁棒性的影响尚未完全了解。因此,需要进一步研究和评估不同训练算法和学习率组合在 ONN 中的适用性和效果,以找到最佳的训练方法来提高 ONN 的鲁棒性能。

本文主要通过对训练算法的优化,在保障 ONN 对数

字图像高精度地识别的前提下提高 ONN 对器件误差的鲁棒性能。本文的主要研究内容如下:

1) 面向数字图像识别,使用 MZI 仿真搭建两种物理架构不同的 ONN—基于 Clements 算法的 GridNet<sup>[10]</sup> 和基于快速傅里叶变换算法 (fast fourier transform, FFT) 的 FFTNet<sup>[8]</sup>。

2) 在网络中引入不同程度的器件误差,分析 ONN 在不同训练算法和学习率组合下的性能表现。

## 1 ONN 架构与训练流程

### 1.1 ONN 架构

本文采用全连接前馈神经网络实现 ONN 的流程框架如图 1 所示。其中,ONN 包括两个隐藏层和一个输出层。每一层都由可编程的光学线性乘法器和一个非线性模块组成。线性乘法器构成了 ONN 的线性层,它通过奇异值分解 (singular value decomposition, SVD) 的方式用两个酉乘法器和对角线层实现。形式上,如果线性乘法器对应一个矩阵  $M$ ,那么由矩阵  $M$  表示的线性变换可以被 SVD 分解为

$$M = U\Sigma V^+ \quad (1)$$

式中,  $U$  和  $V$  是酉矩阵,  $\Sigma$  是对角矩阵。这个分解将线性变换分解为 3 个部分:  $U$  表示输入空间到一个中间空间的映射,  $\Sigma$  表示在中间空间进行缩放变换,  $V^+$  表示中间空间到输出空间的映射<sup>[11]</sup>。




图 1 ONN 架构

Fig. 1 The architecture of ONN

ONN 中线性层的每个矩阵为  $A$  输入  $B$  输出,在图 1 中以  $A \times B$  的形式来表示。在数字图像识别任务中,ONN 的输入是由  $28 \times 28 = 784$  个像素点组成的图片。为了将实值输入转化为复值,本文将图片的上半部分和下半部分的像素点分别作为实部和虚部,从而将 784 维实值输入转化为 392 维复值<sup>[12]</sup>。最后输出层的输出共有 10 个值,每个值表示对应手写数字识别为 0 到 9 的概率。输出通过使用 Softmax 激活函数来确保输出值在 0 到 1 之间,并且所有输出值的总和为 1。Softmax 函数可以表示为

$$f(x_i) = \frac{e^{x_i}}{\sum_{j=1}^{10} e^{x_j}} \quad (i = 1, 2, \dots, 10) \quad (2)$$

其中  $x_1, x_2, \dots, x_{10}$  为 Softmax 层的输入值,输出值  $f(x_i)$  表示样本属于第  $i$  类的概率。对于 GridNet,它的输入维度为 392 个,输出维度为 10 个,即图中  $m = 392, n = 10$ 。对于 FFTNet,由于 FFT 算法的要求,其酉矩阵的输入维度必须为  $2^n$  个。因此在 392 个输入后,需要再补充 120 个 0 作为 FFTNet 的输入,即图中  $m = 512$ 。同样地,FFTNet 的输出层

中西矩阵  $U_3$  的输入维度也要满足同样的要求,因此图中  $n = 16$ 。

ONN 中的各 MZI 具有与网络中各神经元连接权重相对应的传输特性。通过采用特定的 MZI 连接方式,可以实现 ONN 中线性层的矩阵乘法操作。每个 MZI 由两个移相器和两个分束器构成,其结构如图 2 所示。其中 MZI 的外置移相器和内置移相器的相位分别表示为  $\varphi$  和  $\theta$ 。单个 MZI 对应一个  $2 \times 2$  的传输矩阵为

$$U_{\text{MZI}}(\theta, \varphi) = ie^{\frac{i\theta}{2}} \begin{pmatrix} e^{i\varphi} \sin \frac{\theta}{2} & \cos \frac{\theta}{2} \\ e^{i\varphi} \cos \frac{\theta}{2} & -\sin \frac{\theta}{2} \end{pmatrix} \quad (3)$$

本文主要采用两种 MZI 的连接方式实现 ONN,分别基于 Clements 算法和 FFT 算法。这两种网络中,对角线层 (Diagonal) 的 MZI 连接方式是相同的,但酉乘法器 MZI 的连接方式不同,如图 2 所示。以  $8 \times 4$  的线性乘法器为例,图中的每个椭圆形代表一个有两个输入端口和两个输出端口的 MZI。Diagonal 层有 8 个输入端口,但对角线层中

的每个 MZI 只使用上端口来传输数据,而每个 MZI 的下端口始终接收 0 作为输入。GridUnitary 和 FFTUnitary 分别是有 8 个输入端口的 GridNet 和 FFTNet 中的酉乘法器。

ONN 的每个线性层后还有一个非线性层。为了实现

ONN 中非线性层的功能,可以利用可饱和吸收来近似满足激活函数条件的特性<sup>[13]</sup>。本文使用 Softplus 函数来近似模拟可饱和吸收器的传输曲线,其函数定义为

$$S(x) = \log(1 + e^x) \tag{4}$$

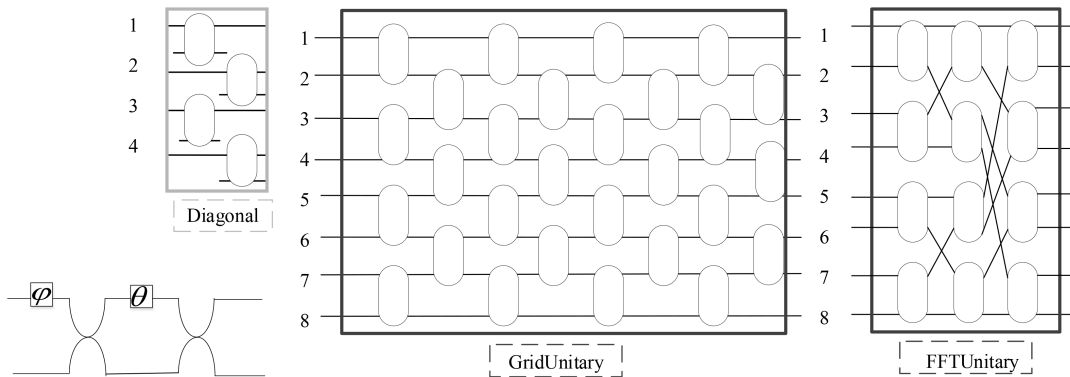


图 2 GridNet 和 FFTNet 的对角线层和各自的酉乘法器的结构(左下是 MZI 的结构示意图)

Fig. 2 Structures of the diagonal layer and their respective unitary multipliers for GridNet and FFTNet(The lower left is a schematic diagram of the MZI structure)

### 1.2 训练流程

本文主要研究分析随机梯度下降(stochastic gradient descent, SGD)<sup>[14]</sup>、均方根传递(root mean square prop, RMSprop)<sup>[15]</sup>、适应性矩估计(adaptive moment estimation, Adam)<sup>[16]</sup>和自适应梯度下降(adaptive gradient, Adagrad)<sup>[17]</sup> 4 种梯度下降算法对存在 MZI 器件误差的 ONN 的训练过程与能力,以及在不同学习率下对手写数字图像的识别性能。

本文中,ONN 的训练流程如图 3 所示。首先,通过损失函数计算前向传播输出的预测值与数据集中的期望值之间的损失。然后,利用反向传播将损失表达为网络中的参数即 MZI 的相位  $\varphi$  和  $\theta$  的函数,即损失函数。最后应用梯度下降算法对损失函数进行梯度计算,并沿着梯度下降方向更新 MZI 的相位参数,以使损失值降到局部最小值。由于梯度下降算法的数学过程各不相同,不同训练算法对存在误差的 MZI 相位的调整能力以及 ONN 对识别精确度的提高能力是不同的。

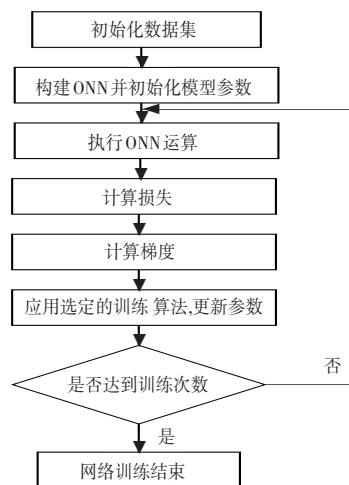


图 3 ONN 反向训练流程图

Fig. 3 Flowchart of backward training of ONN  
学习率是训练算法中一个重要的超参数,它决定了每

次 MZI 相位参数更新的步长大小。学习率的选择对 ONN 的训练效果和收敛速度具有重要影响。如果学习率设置得太小,模型的收敛速度会很慢,需要更多的迭代次数才能达到最优解。这可能导致训练时间过长或者陷入局部最优解。相反,如果学习率设置得太大,模型可能会在参数空间中跳过最优解,导致无法收敛或震荡。这种情况下,损失函数可能发生剧烈波动,甚至无法收敛到较低的损失值。因此,在 ONN 的训练中需要根据不同的训练算法和网络模型进行调整,以获得较好的训练效果和收敛速度。

## 2 结果与分析

本文首先比较了在不同学习率下 4 种训练算法对理想情况下(即器件误差为零)的 GridNet 和 FFTNet 的识别精确度,具体结果如表 1 和表 2 所示。当学习率为  $5 \times 10^{-4}$  时,4 种算法训练下的 GridNet 的识别精确度都在 0.87 以上;当学习率为 0.005 时,4 种算法训练下的 FFTNet 的识别精确度都在 0.90 以上。然而,当初始学习率为 0.5 时,除了 Adagrad 算法的其他 3 种算法训练下两种网络的识别精确度都在 0.1 左右。这是因为学习率设置过大而导致网络中参数更新的幅度太大,参数会在对应损失值极小点的附近抖动,即网络不能收敛而导致识别精确度很低。与它们不同的,此时的 Adagrad 算法训练下的两种网络识别精确度可以达到约 0.97。这是因为 Adagrad 算法的学习率会随着训练次数的增加而减小,从而让网络收敛达到一个较好的识别精确度。但是,当初始学习率从 0.5 减小到  $5 \times 10^{-5}$  时,Adagrad 算法训练下两种网络的识别精确度逐渐降低。同样的情况也发生在当初始学习率从 0.05 减小到  $5 \times 10^{-5}$  时的 SGD 算法。当然,因为 SGD 算法在训练的过程中学习率不会发生变化,SGD 算法训练下两种网络识别精确度的下降速度小于 Adagrad 算法的情况。因此,

SGD 算法更适合不同学习率下的 ONN 的训练。RMSprop 算法和 Adam 算法的学习率是动态变化的,能够根据历史梯度信息自适应地调整,但是对初始学习率的要求较高。特别地,在 GridNet 中 RMSprop 算法的初始学习率要设置为  $5 \times 10^{-4}$  或  $5 \times 10^{-5}$ 。而在 FFT 型 ONN 中 RMSprop 算法的初始学习率要设置为 0.005、 $5 \times 10^{-4}$  或  $5 \times 10^{-5}$ 。

表 1 GridNet 在不同学习率的 4 种训练算法下的识别精确度

Tab. 1 Recognition accuracy of GridNet with four training algorithms under different learning rates

学习率训练算法	识别精确度				
	0.5	0.05	0.005	$5 \times 10^{-4}$	$5 \times 10^{-5}$
SGD	0.098	0.965	0.950	0.915	0.691
RMSprop	0.091	0.093	0.094	0.957	0.937
Adam	0.101	0.151	0.854	0.954	0.938
Adagrad	0.970	0.967	0.948	0.873	0.528

表 2 FFTNet 在不同学习率的 4 种训练算法下的识别精确度

Tab. 2 Recognition accuracy of FFTNet with four training algorithms under different learning rates

学习率训练算法	识别精确度				
	0.5	0.05	0.005	$5 \times 10^{-4}$	$5 \times 10^{-5}$
SGD	0.091	0.950	0.914	0.699	0.229
RMSprop	0.101	0.153	0.954	0.950	0.910
Adam	0.101	0.901	0.963	0.952	0.910
Adagrad	0.966	0.950	0.909	0.423	0.161

本文接下来比较了在不同训练算法下 GridNet 和 FFTNet 对 MZI 器件误差的鲁棒性能。本文通过将均值为 0、标准偏差为  $\sigma_{ps}$  和  $\sigma_{bs}$  的高斯噪声分别均匀添加到每个 MZI 内置移相器的相位 ( $\theta$ ) 和外置移相器的相位 ( $\varphi$ ) 上来模拟 MZI 的器件误差。为了方便观察和比较,本文设置  $\sigma_{ps} = \sigma_{bs}$ , 它们的值从 0 到 0.02。根据前面的观察,本文分别测试了学习率为  $5 \times 10^{-4}$  时 GridNet 和学习率为 0.005 时 FFTNet 经过 4 种算法训练后的识别精确度,结果分别如图 4 (a) 和图 4 (b) 所示。从图中可以看出,当 GridNet 中 MZI 的器件误差  $\sigma_{ps}$  和  $\sigma_{bs}$  从 0 增大到 0.005 左

右时,4 种算法训练下的网络识别精确度缓慢下降;但当器件误差增大到 0.005 以上时,随着器件误差的增大,网络的识别精确度迅速下降;当器件误差增大到 0.02 时,网络的识别精确度下降到 0.1 左右。相反,当 FFTNet 中 MZI 的器件误差从 0 增大到 0.02,4 种算法训练下网络的识别精确度下降幅度很小,小于 0.05。此外,本文中 GridNet 每次训练的平均时间约为 40 min, FFTNet 每次训练的平均时间约为 2 min。因此 FFTNet 凭借训练时间短、鲁棒性强等优势是替代 GridNet 的一种很好的网络架构选择。

进一步,本文分析了在合适的初始学习率下不同训练算法对存在 MZI 相位误差的 FFTNet 识别精确度的影响,如图 5 所示。在合适的初始学习率下,4 种训练算法都可以将无误差的 FFTNet 的识别精确度训练到 0.9 以上。如图 5 (c) 所示,当初始学习率为 0.05 时,Adam 算法训练下 FFTNet 对器件误差的鲁棒性最强,但识别精确度较差。当初始学习率为 0.005 时,RMSprop 算法和 Adam 算法训练下 FFTNet 对器件误差的鲁棒性高于 SGD 和 Adagrad 算法。初始学习率为  $5 \times 10^{-4}$  和  $5 \times 10^{-5}$  的 RMSprop 和 Adam 算法训练下 FFTNet 的鲁棒性低于 0.05 和 0.005 的初始学习率。值得一提的是,如图 5 (d) 所示,在 Adagrad 算法中,初始学习率为 0.5 训练的 FFTNet 同样有很强的鲁棒性。综上,采用初始学习率为 0.005 时的 RMSprop 算法和 Adam 算法以及初始学习率为 0.5 时的 Adagrad 算法,训练后的 FFTNet 型 ONN 不仅识别精确度高而且对器件误差的鲁棒性强。

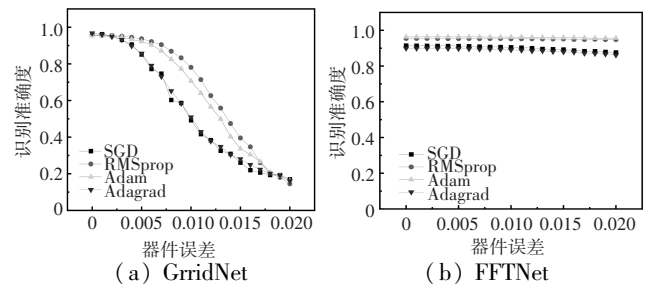


图 4 不同算法训练下的识别精确度随器件误差变化曲线

Fig. 4 The variation curve of the recognition accuracy of with the component error under different training algorithms

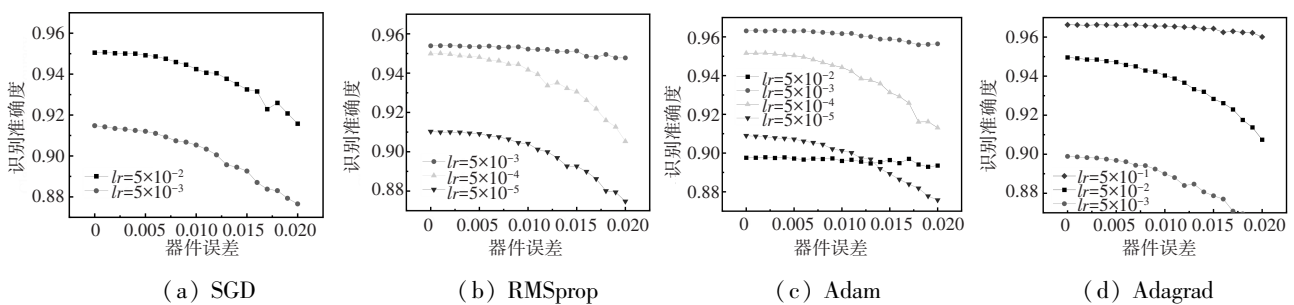


图 5 不同算法训练下 FFTNet 的识别精确度随器件误差变化曲线 ( $lr$  表示学习率)

Fig. 5 The variation curve of the recognition accuracy of FFTNet with the component error under different training algorithms (where  $lr$  represents the learning rate)

### 3 结论

本文使用光学器件 MZI 仿真搭建了 GridNet 型和 FFTNet 型两种光子神经网络,研究了 SGD、RMSprop、Adam 和 Adagrad 4 种训练算法以及它们的初始学习率对具有器件误差的 ONN 识别手写数字图像性能的影响。本文首先比较了器件误差为零的 ONN 在不同初始学习率的 4 种训练算法下的识别精确度,得到了 4 种算法训练 ONN 的合适的学习率。接着,比较了 4 种算法训练的 GridNet 和 FFTNet 对 MZI 器件误差的鲁棒性。实验结果表明,FFTNet 凭借训练时间短、鲁棒性强等优势是替代 GridNet 的一种很好的网络架构选择。之后,本文重点分析了在合适的初始学习率下不同的训练算法对存在 MZI 相位误差的 FFTNet 识别精确度的影响。

结果表明,当初始学习率为 0.005 时,RMSprop 和 Adam 算法训练下 FFTNet 对器件误差的鲁棒性高于 SGD 和 Adagrad 算法。具体地,采用学习率为 0.005 时的 RMSprop 算法和 Adam 算法以及学习率为 0.5 时的 Adagrad 算法,训练后的 FFTNet 型 ONN 不仅识别精确度高,而且对器件误差的鲁棒性强。因此,优化训练算法和学习率的组合可以有效地提高 ONN 的鲁棒性能。

### 参考文献

- [1] SHASTRI B J, TAIT A N, FERREIRA DE LIMA T, et al. Photonics for artificial intelligence and neuromorphic computing [J]. Nature Photonics, 2021, 15(2):102-114.
- [2] WU J, LIN X, GUO Y, et al. Analog optical computing for artificial intelligence[J]. Engineering, 2022(10): 133-145.
- [3] LI C, ZHANG X, LI J, et al. The challenges of modern computing and new opportunities for optics[J]. Photonix, 2021, 2(1):20.
- [4] WANG T, SOHONI M M, WRIGHT L G, et al. Image sensing with multilayer nonlinear optical neural networks [J]. Nature Photonics, 2023, 17(5):408-415.
- [5] WANG J, RODRIGUES S P, DEDE E M, et al. Microring-based programmable coherent optical neural networks [J]. Optics Express, 2023, 31(12):18871-18887.
- [6] ZHU H H, ZOU J, ZHANG H, et al. Space-efficient optical computing with an integrated chip diffractive neural network [J]. Nature communications, 2022, 13(1):1044.
- [7] SHOKRANEH F, GEOFFROY-GAGNON S, LIBOIR ON-LADOUCEUR O. The diamond mesh, a phase-error-and loss-tolerant field-programmable MZI-based optical processor for optical neural networks [J]. Optics Express, 2020, 28(16):23495-23508.
- [8] FANG M Y S, MANIPATRUNI S, WIERZYNSKI C, et al. Design of optical neural networks with component imprecisions [J]. Optics Express, 2019, 27(10):14009-14029.
- [9] MOJAVER K H R, ZHAO B, LEUNG E, et al. Addressing the programming challenges of practical interferometric mesh based optical processors [J]. Optics Express, 2023, 31(15):23851-23866.
- [10] CLEMENTS W R, HUMPHREYS P C, METCALF B J, et al. Optimal design for universal multi-port interferometers [J]. Optica, 2016, 3(12):1460-1465.
- [11] ZHANG X M, YUNG M H. Low-depth optical neural networks [J]. Chip, 2022, 1(1):100002.
- [12] ZHANG H, GU M, JIANG X D, et al. An optical neural chip for implementing complex-valued neural network [J]. Nature communications, 2021, 12(1): 457.
- [13] RYOU A, WHITEHEAD J, ZHELJEZNYAKOV M, et al. Free-space optical neural network based on thermal atomic nonlinearity [J]. Photonics Research, 2021, 9(4):B128-B134.
- [14] LU K, GUO X. Efficient training of unitary optical neural networks [J]. Optics Express, 2023, 31(24):39616-39623.
- [15] VANGETY N, DEY K, ROY S. Transfer learning convolutional neural network for weight classification in a plastic optical fiber [J]. Journal of Optical Communications, 2025, 45(S1):s1239-s1250.
- [16] BERNSTEIN L, SLUDDS A, PANUSKI C, et al. Single-shot optical neural network [J]. Science Advances, 2023, 9(25): 7904.
- [17] ZOHREVAND A, IMANI Z. An empirical study of the performance of different optimizers in the deep neural networks [C]//2022 International Conference on Machine Vision and Image Processing (MVIP). [S. l.]: IEEE, 2022:1-5.