

## 对抗光学神经网络识别误差的渐进式训练方法

郭鹏星<sup>1,2</sup>, 游正容<sup>1,2</sup>, 侯维刚<sup>1,2\*</sup>, 郭磊<sup>1,2</sup><sup>1</sup>重庆邮电大学通信与信息工程学院, 重庆 400065;<sup>2</sup>重庆邮电大学智能通信与网络安全研究院, 重庆 400065

**摘要** 提出了一种渐进式训练方案来重新配置马赫-曾德尔干涉仪(MZI)前馈光学神经网络(ONN)的相移,从而对抗 MZI 的相位误差和分束器误差,提高识别准确率。为了验证所提方案,利用 Neuroptica Python 仿真平台搭建了 3 层 MZI-ONN 结构,并在考虑到 MZI 相位误差和分束器误差的情况下,利用 Iris 和 MNIST 数据集验证了所提方案的有效性。仿真结果表明:在 Iris 数据集下,对于 3 层 4×4 MZI-ONN 结构,所提方案的识别准确率能够提升 64.15 个百分点;在 MNIST 数据集下,对于 4×4、6×6、8×8 和 16×16 规模的 MZI-ONN,所提方案的识别准确率能够提升 2.00~37.00 百分点。所提方案极大地提高了 MZI-ONN 的抗误差性能,有助于未来大规模、高准确率 MZI-ONN 的实现。

**关键词** 光计算; 马赫-曾德尔干涉仪; 光学神经网络; 相位误差; 分束器误差; 渐进式训练; 抗误差

中图分类号 TN25

文献标志码 A

DOI: 10.3788/AOS231949

## 1 引言

神经网络在图像处理、自然语言处理等众多领域中引起了广泛的关注<sup>[1]</sup>。神经网络的实现依赖于具有快速、高度并行化功能的硬件加速器。然而,在电子瓶颈的约束下,电学硬件加速器的时钟频率、并行度、功耗和成本之间相互制约,这使得性能提升变得更加困难,难以应对运算数据量爆发式增长的需求<sup>[2]</sup>。近年来,有研究者提出通过将具有高带宽、高速率、低能耗、高并行性优点的光子技术应用到神经网络中所构建的光学神经网络(ONN),该方案可有效缓解传统电学计算硬件的带宽和功耗瓶颈<sup>[3]</sup>,有望成为传统电子计算架构的有效替代方案。

硅光子集成技术的快速发展为构建以马赫-曾德尔干涉仪(MZI)、微环谐振器等光学组件为基础单元的 ONN 提供了硬件基础<sup>[4-8]</sup>。其中,级联 MZI 具有可实现性较高且易于集成的优点,可以在光学领域实现神经网络训练和超高加速的推理<sup>[5-8]</sup>。2017 年,麻省理工学院 Shen 等<sup>[7]</sup>使用级联的 56 个 MZI 设计出可编程纳米光子处理器,该处理器能够实现两层全连接神经网络的线性运算,在识别 4 个元音方面的准确率达到 76.7%,比传统图形处理器的能效高 5 个数量级。2021 年,南洋理工大学在同样的 MZI 拓扑级联架构中增加了相位调控这一维度,使用可编程

幅度和相位的 MZI 结构实现了全连接的复数 ONN,该架构将识别 MNIST 数据集的准确率提升至 90.5%<sup>[8]</sup>。

然而,在光子芯片中,实现精确控制器件的性能及确保各部件的均匀性仍然存在挑战。基于 MZI 的 ONN(MZI-ONN)可制作光子神经网络加速器,由于芯片的制造存在缺陷,基于 MZI 的光子神经网络加速器中的 MZI 移相器和分束器不可避免地存在误差。这些误差会随着 MZI-ONN 结构规模的增大而积累,从而影响 ONN 的识别准确率<sup>[9]</sup>。现有的提高 MZI-ONN 识别准确率的优化方案主要有两种:1)从 MZI-ONN 的网格出发,通过改进 MZI 网格拓扑结构来对抗误差,但这种方案以增加网格大小和参数空间作为代价,增加了网络的复杂性<sup>[10-11]</sup>;2)从 MZI-ONN 的组件出发,通过局部校正 MZI-ONN 中单个光学器件的硬件误差直接优化带有误差的光子器件,但该方案通常需要消耗大量的时间,且需要额外的硬件支撑<sup>[12]</sup>。

本文提出了一种渐进式训练(PT)方案来对抗由光学器件误差引起的 MZI-ONN 识别准确率下降问题。所提 PT 方案结合遗传算法(GA)<sup>[13]</sup>和光子原位训练算法<sup>[14]</sup>,将完成训练后的权重映射到网格中来对抗 MZI 分束器误差和相位误差。由于 MZI-ONN 中的 MZI 通常按照矩形的排列方式级联<sup>[15]</sup>,PT 方案在一定

收稿日期: 2023-12-19; 修回日期: 2024-01-22; 录用日期: 2024-01-25; 网络首发日期: 2024-02-20

基金项目: 国家自然科学基金(62205043, 62222103, 62221005, 62071076, 62075024)、重庆市自然科学基金(CSTB2022NSC-QMSX1334)

通信作者: houwg@cqupt.edu.cn

的迭代次数中,按 MZI 排列方式逐步确定每一列 MZI 的相位。在确定好相位的基础上考虑 MZI 的相位误差和分束器误差。再次开始迭代后,采用未确定的移相器相位值抵消固定 MZI 的相位误差和分束器误差。经过反复训练直到网格的最后一列,此时采用 PT 方案得到的相位值能够有效对抗不理想光子器件的组件误差,从而提高 MZI-ONN 的识别准确率。所提方案的特点为在不改变 MZI-ONN 拓扑结构的情况下降低了光学元件带来的不精确性,且无需增加额外的硬件成本。最终,利用 Neuroptica Python 仿真平台对所提方案进行验证。由 MNIST 数据集的仿真结果可知,在具有 3 层线性单元、168 个移相器的 MZI-ONN 中,考虑器件的实际误差,使用所提方案可以将识别准确率从 49.25% 提升到 86.25%,对比提高了 37.00 个百分点。在 Iris 数据集的仿真任务中,可以将准确率从 32.50% 提升到 96.65%,对比提高了 64.15 百分点。

## 2 MZI-ONN 基本原理及误差分析

本章描述了 MZI-ONN 的组成结构,并对不精确组件的相位误差和分束器误差进行分析。

### 2.1 基于 MZI 的 ONN 结构

典型的基于前馈神经网络构建的 MZI-ONN 结构如图 1(a)所示,该网络包含输入层、隐藏层和输出层,其中隐藏层包括线性部分( $W_i, i=1, 2, 3$ )和非线性部分( $f_i, i=1, 2, 3$ )<sup>[16]</sup>。线性部分是以  $2 \times 2$  MZI 为基础单元按照矩形的排布方式级联实现的,如图 1(b)所示。矩形的排布方式可以使光传播线路更加对称,且缩短最长链路的长度,从而减少光传播的路径损耗和误差<sup>[17]</sup>。典型的  $2 \times 2$  MZI 如图 1(c)所示,它由两个可调光子移相器和两个 3 dB 定向耦合器组成。其中,移相器分为内移相器(相位为  $\theta$ )和外移相器(相位为  $\varphi$ ),分别位于 MZI 的内上臂和外上臂,并在输入光信号之间获得不同程度的干涉。其中内部移相器控制 MZI 输出端的功率,外部移相器控制 MZI 输出端的相对相位。

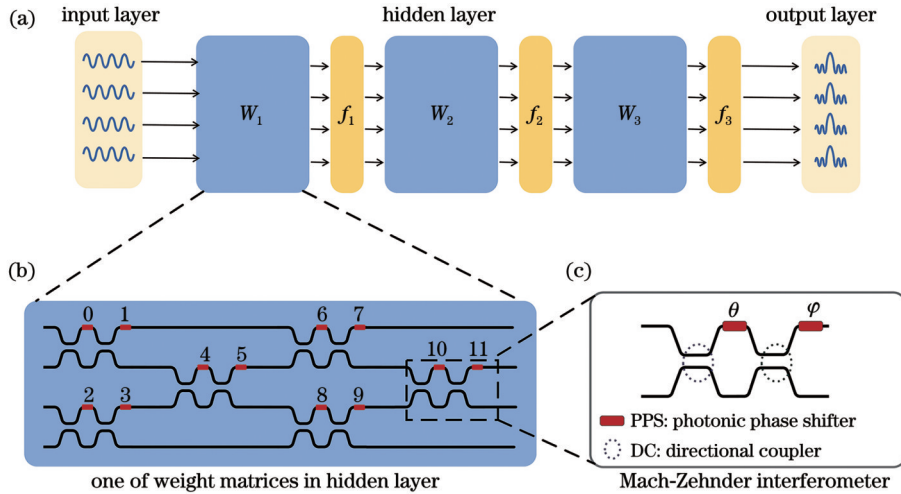


图 1 MZI-ONN 结构组成图。(a) MZI-ONN 结构;(b)基于矩形排列的 MZI 阵列光干涉单元;(c)典型的  $2 \times 2$  MZI  
Fig. 1 Structural composition diagram of MZI-ONN. (a) MZI-ONN structure; (b) rectangularly arranged MZI array-based optical interference unit; (c) typical  $2 \times 2$  MZI

根据移相器在干涉臂上的位置,可以得到  $2 \times 2$  MZI 的传输矩阵<sup>[18]</sup>,具体表达式为

$$T_{\max}(\theta, \varphi) = j \exp\left(j \frac{\theta}{2}\right) \begin{bmatrix} \exp(j\varphi) \sin(\theta/2) & \exp(j\varphi) \cos(\theta/2) \\ \cos(\theta/2) & -\sin(\theta/2) \end{bmatrix}. \quad (1)$$

由 MZI 的传输矩阵可知,通过改变  $\theta$  和  $\varphi$  可以实现在二次酉群中的任意旋转。将多个二维酉矩阵旋转后再相乘即可表征一个高阶的酉矩阵。利用奇异值分解(SVD)理论可以将一个矩阵表示为酉矩阵(MZI 级联的阵列)和对角矩阵相乘。例如,Shen 等<sup>[7]</sup>首先在计算机上对元音数据进行训练并得到权重矩阵,然后使用 SVD 算法对权重矩阵进行分解,得到两个酉矩阵和

一个三角矩阵,最后使用 Reck 等<sup>[17]</sup>提出的三角分解算法得到 MZI 的相位集合。通过配置级联 MZI 的相位来表示权重矩阵,并与输入的光信号实现矩阵乘法。由于神经网络中存在大量的矩阵乘法,这种在光路中实现的乘法从原则上来说并不消耗能量,因此光学计算架构具有极高的能效。

### 2.2 误差分析

MZI-ONN 误差的主要来源是定向耦合器的分束器误差和移相器的相位误差。理想的定向耦合器具有 50:50 的分束比。然而,在制造过程中存在误差,因此会引起相移的不确定性,分束器的实际传输矩阵会发生变化。假设利用分束器误差  $a$  来描述 50:50 分束器偏离理想的行为,则  $2 \times 2$  MZI 的传输矩阵将由式(1)改写为

$$\left\{ \begin{aligned} \mathbf{T}'_{\max}(\theta, \varphi, a) &= \begin{pmatrix} b_{11} & b_{12} \\ b_{21} & b_{22} \end{pmatrix} \\ b_{11} &= \exp[j(\theta + \varphi)] \cos^2(\pi/4 + a) - \\ &\quad \exp(j\varphi) \sin^2(\pi/4 + a) \\ b_{12} &= j \exp(j\varphi) \cos(\pi/4 + a) \sin(\pi/4 + a) \times \\ &\quad [\exp(j\theta) + 1] \\ b_{21} &= j \cos(\pi/4 + a) \sin(\pi/4 + a) [\exp(j\theta) + 1] \\ b_{22} &= \cos^2(\pi/4 + a) - \exp(j\theta) \sin^2(\pi/4 + a) \end{aligned} \right. \quad (2)$$

一方面,由于每个 MZI 中都存在分束器误差,且随着 MZI-ONN 规模的增大,分束器误差逐渐累积。另一方面,MZI 上的移相器中存在由干涉臂之间微观变化引起的静态相位误差和动态相位误差。动态相位误差对 ONN 的影响比静态相位误差的影响要小得多<sup>[8]</sup>。因此,主要考虑 MZI 网格中静态相位误差和分束器的误差。

由于含组件误差的传输矩阵  $\mathbf{T}'_{\max}(\theta, \varphi, a)$  会偏离其目标矩阵,引起 MZI 阵列产生次酉性。因此使用保真度(Fidelity;  $F$ )作为品质因子来量化零误差的目标酉矩阵  $\mathbf{U}_{\text{exp}}$  和由不精确组件导致的偏离酉矩阵  $\mathbf{U}$  之间的接近度<sup>[7]</sup>,其表达式为

$$F(\mathbf{U}_{\text{exp}}, \mathbf{U}) = \left| \frac{\text{Tr}(\mathbf{U}^\dagger \mathbf{U}_{\text{exp}})}{N} \right|^2, \quad (3)$$

式中:  $\text{Tr}(\mathbf{U}^\dagger \mathbf{U}_{\text{exp}})$  为目标矩阵的迹;  $\mathbf{U}^\dagger$  为偏离酉矩阵的共轭转置;  $N$  为目标酉矩阵的大小。  $F(\mathbf{U}_{\text{exp}}, \mathbf{U})$  在 0~1 范围内变化,  $F$  越接近于 1, 则实际的酉矩阵偏离量越小, 相似性越高。 当且仅当  $\mathbf{U}^\dagger = \mathbf{U}_{\text{exp}}$  时,  $F(\mathbf{U}_{\text{exp}}, \mathbf{U}) = 1$ 。

为了探究分束器误差和相位误差对不同规模的 MZI 矩形网格(RM)保真度的影响,在 Neurophox<sup>[19]</sup> 光子仿真平台中搭建了规模分别为  $4 \times 4$ 、 $6 \times 6$ 、 $8 \times 8$  和  $16 \times 16$  的 MZI 阵列。使用高斯分布的分束器误差  $\sigma_{\text{BS}}$  和移相器误差  $\sigma_{\text{PS}}$  模拟组件误差,这两个变量相互独立。首先随机生成  $N \times N$  的 10 个 Haar 随机酉矩阵 ( $N=4, 6, 8, 16$ ), 然后通过 Clements 矩形分解算法得到 MZI 阵列的相移集合,再将得到的相移映射到对应的 MZI 网格上。随后每个 MZI 阵列执行 100 次蒙特卡罗迭代,再计算这 10 个 RM 的平均保真度作为其中一个采样点的保真度。在每一次迭代中,每个 MZI 对应的参数  $a, \theta(\varphi)$  在高斯分布  $(\sigma_{\text{PS}}, \sigma_{\text{BS}})$  中选择。此时在 0~0.1 范围内分别平均采样 20 个点模拟误差,得到图 2 的仿真结果。由图 2 可知,随着网格规模的增大,  $\sigma_{\text{PS}}$  和  $\sigma_{\text{BS}}$  的平均保真度逐渐降低,导致 MZI-ONN 线性层




图 2 当分束器误差和移相器误差独立变化时不同规模 RM 的平均保真度。(a)  $4 \times 4$  RM; (b)  $6 \times 6$  RM; (c)  $8 \times 8$  RM; (d)  $16 \times 16$  RM  
Fig. 2 Average fidelity of RM of different scales when beam splitter error and phase shifter error vary independently. (a)  $4 \times 4$  RM; (b)  $6 \times 6$  RM; (c)  $8 \times 8$  RM; (d)  $16 \times 16$  RM



执行带有误差的矩阵乘法。在所有的 RM 中,当  $\sigma_{PS}$  小于 0.08 rad、 $\sigma_{BS}$  小于 0.04 dB 时,其平均保真度可以保持在 90% 以上;而当  $\sigma_{PS}$  大于 0.08 rad 且  $\sigma_{BS}$  大于 0.08 dB 时,其平均保真度下降到 80% 以下。

为了分析组件误差对 ONN 识别性能的影响,将对 MZI-ONN 结构的线性层中只有单个酉网格而无对角单元的情况进行验证。首先利用 Neuroptica<sup>[20]</sup> 光子仿真平台搭建了一个含有 3 个隐藏层的 MZI-ONN 结构,其中每一隐藏层由一个  $6 \times 6$  RM 和一个非线性单元组成。随后在仿真平台中使用光子原位训练方案得出 RM 中的理想相位配置。使用高斯分布的  $\sigma_{BS}$ 、 $\sigma_{PS}$  模拟组件误差,计算整个 MZI-ONN 结构在 MNIST 数据集中测试图像的推理精度,其仿真结果如图 3 所示。仿真显示了当 MZI-ONN 结构组件同时被引入内外移相器误差  $\sigma_{PS}$  ( $\sigma_{\theta} = \sigma_{\varphi}$ ) 和分束器误差  $\sigma_{BS}$  时光子神经网络模型识别准确率的变化。在理想无误差情况下 ( $\sigma_{\theta} = \sigma_{\varphi} = \sigma_{BS} = 0$ ),该模型的识别准确率为 90%,随着误差的增大,识别准确率急剧降低。相对于分束器误差,整个 MZI-ONN 结构对移相器误差更为敏感,当  $\sigma_{PS}$  大于 0.08 rad 时,识别准确率有明显的下降;而当  $\sigma_{BS}$  大于 0.60 dB 时,识别准确率才有较大变化。




图 3 带有组件误差的  $6 \times 6 \times 3$  MZI-ONN 结构对 MNIST 数据集的识别准确率

Fig. 3 Recognition accuracy of  $6 \times 6 \times 3$  MZI-ONN structure with component error for MNIST dataset

### 3 对抗分束器和移相器误差的渐进式训练方案

在 MZI-ONN 中,每个神经元由一个 MZI 实现,通过在 MZI 的不同分支上引入不同的相位值来调整干涉效应,从而实现权重的模拟。MZI-ONN 正常训练得到的相位是理想的、无损的,但实际存在的相位误差和分束器误差会使 MZI-ONN 的识别准确率下降<sup>[21]</sup>。研究表明,通过调整 MZI 上下臂的相位值可以补偿器件制造缺陷所产生的相位误差和分束器误差<sup>[22]</sup>。为此,提出一种考虑 MZI 的分束器误差和相位误差的 PT 方案,将经过 PT 方案处理后得到的相位值重新映

射到 MZI-ONN 中,以此提高其抗误差性能。

PT 方案的执行过程如表 1 所示,在每一轮迭代(每轮 100 次)的训练中固定一系列相位,将固定好的相位称为“固定相位”,其余的相位称为“自由相位”。PT 方案的核心思想是将固定相位的误差添加到网络模型中并参与后续的训练,然后使用不断更新自由相位来弥补固定相位的误差。因此,PT 方案的关键在于如何固定相位,以及何时添加相位误差。相位固定具体实施方案:在每一次相位更新前保存所有的原始相位值到集合  $D$ ,将使用光子原位训练或者 GA 更新的相位保存到集合  $P$ 。根据 MZI 的排列规律和迭代次数得到需要固定的移相器所在的位置索引  $c$ ,在刚固定好的相位中添加误差的移相器所在列的位置索引  $w$ ,在固定相位过程中将集合  $D$  中位置索引为  $c$  的相位值替换到更新后的对应位置的相位值列表  $P$  中。如图 1(b) 所示,以  $4 \times 4$  的 MZI-ONN 为例,其中移相器的索引按照从左到右、从上到下的顺序进行排列,即移相器的索引集合为  $\{0, 1, 2, \dots, 11\}$ 。每经过 100 次迭代就更新一

表 1 渐进式训练算法

Table 1 Progressive training algorithm

Algorithm 1: progressive training algorithm

Input: input features  $N$ , maximum iterations  $M$ , phase before normal training for each iteration  $D = \{d_1, d_2, \dots, d_M\}$ , phase after normal training for each iteration  $P = \{p_1, p_2, \dots, p_M\}$   
Output: best phase  $p_M$

```

1 for  $m=1$  to  $M$ 
2    $d=d_m; p=p_m; k=\text{int}(m+1/100)$ 
3   if  $k\%2=0$  and  $k\neq 0$  then
4      $c=(2N-2)*k/2; d=c-N+2$ 
5   else if  $k\%2\neq 0$  and  $k\neq 0$  then
6      $c=(2N-2)*(k+1)/2; d=c-N$ 
7   else
8      $c=0; d=0$ 
9   end if
10   $p[0:c]=d[0:c]; w=\text{range}(d, c)$ 
11  if  $(m+1)\%100=0$  and  $m\neq 0$  then
12    for  $i$  in  $w$  do
13       $P[i]=\text{round}(1)$ 
14    end for
15  else
16    break from line 2
17  end if
18 end for
19 return  $p_M$ 

```

列 MZI 的相位值,  $4 \times 4$  的 MZI 网格总共有 4 列 MZI, 因此迭代总次数为 400。经过前 98 次迭代收敛后可以得到一组相位值, 此时将索引值  $c$  为  $\{0, 1, 2, 3\}$  的相位值保存为固定相位, 固定好的相位是无损的。当进行第 99 次迭代时, 满足表 1 第 11 行中的“下一次迭代为 100 的倍数”条件时, 将带误差的相位值添加到已固定的索引值  $c$  为  $\{0, 1, 2, 3\}$  的相位中并参与后续训练。再次开始训练后, 只需通过更新索引为  $\{4, 5, 6, \dots, 11\}$  的自由相位来抵消前面元件携带的误差。在第二轮的迭代中, 经第 198 次迭代后得到第二列的固定相位, 此时固定相位索引  $c$  为  $\{4, 5\}$ ; 在第 199 次迭代时将误差加到已经固定好的相位中继续后续的训练。同理, 在之后的第  $N$  轮训练中第  $N - 1$  列的相位值已是带有误差的固定相位, 重复每 100 次迭代固定一列相位直到最后一列。至此采用 PT 方案得到的相位值可有效对抗不理想光子器件导致的不精确性。

### 4 仿真结果及分析

本章利用 Neuroptica 光子仿真平台搭建基于 MZI 的光子神经网络来验证所提方案的有效性。Neuroptica 是一个灵活的芯片级仿真平台, 允许在模拟芯片上操作各个移相器的排列以及修改其属性, 可通过堆叠网络层来设计 MZI-ONN; 可为 MZI-ONN 中的每个 MZI 分配不同的相位不确定性, 从而模拟每个 MZI 的不同校准精度。同时, 仿真平台中包含 Iris、MNIST 等多种数据集。将所设计的优化算法编写成优化器后连入该仿真平台, 可在不同数据集中测试所提算法的目标识别功能, 从而交叉对比所提算法的分类精度、训练效率等性能。

#### 4.1 MZI-ONN 分束器误差对识别精度的影响

由文献 [12] 可知, MZI 中两个定向耦合器中产生分束器误差  $\alpha$  范围为  $0 \sim 0.10$ 。为了探究不同分束器误差对 MZI-ONN 识别准确率的影响, 本节仿真了不同规模 MZI-ONN 中分束器误差  $\alpha$  分别为 0.05、

0.10、0.15、0.20 时对应的识别准确率, 仿真结果如图 4 所示。从图 4 可以看出, 在只考虑分束器误差的情况下, 当  $\alpha$  小于 0.05 时, 识别准确率变化较小, 而当  $\alpha$  大于 0.10 时, 识别准确率发生明显变化且迅速下降。

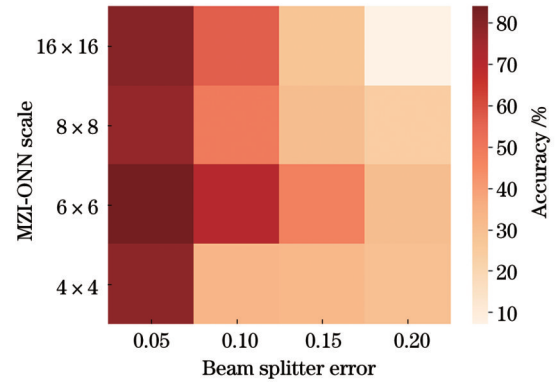


图 4 各分束器误差下不同规模 MZI-ONN 的识别准确率  
Fig. 4 Recognition accuracy of MZI-ONN at different scales under different beam splitter errors

#### 4.2 所提渐进式训练方案的抗误差性能仿真结果及分析

搭建了  $4 \times 4 \times 3$  MZI-ONN 的架构, 验证所提 PT 方案在 Iris 数据集中的有效性。在本仿真中, 首先通过训练得到的理想的相位值, 并将理想相位值保留到小数点后一位, 此时的相位误差为相位值与理想相位值之间的差值, 分束器误差  $\alpha$  为 0.10。损失函数为分类交叉熵函数, 仿真结果如图 5(a) 所示。理想情况下, 在 Iris 数据集中对 MZI-ONN 进行训练, 得到的损失函数最小值为 0.10, 识别准确率为 97.91%。在已经训练好的无损网络中添加实际相位误差和分束误差后, 采用 PT 方案对 MZI-ONN 重新进行训练, 得到的损失函数最小值为 0.14, 准确率为 96.68%。由此可知, 所提 PT 方案能够有效抵消误差对 MZI-ONN 识别准确率造成的影响。图 5(b) 和图 5(c) 分别为使用 PT 方案前后的混淆矩阵, 通过对比可以得到, 如果不进行误差优化,

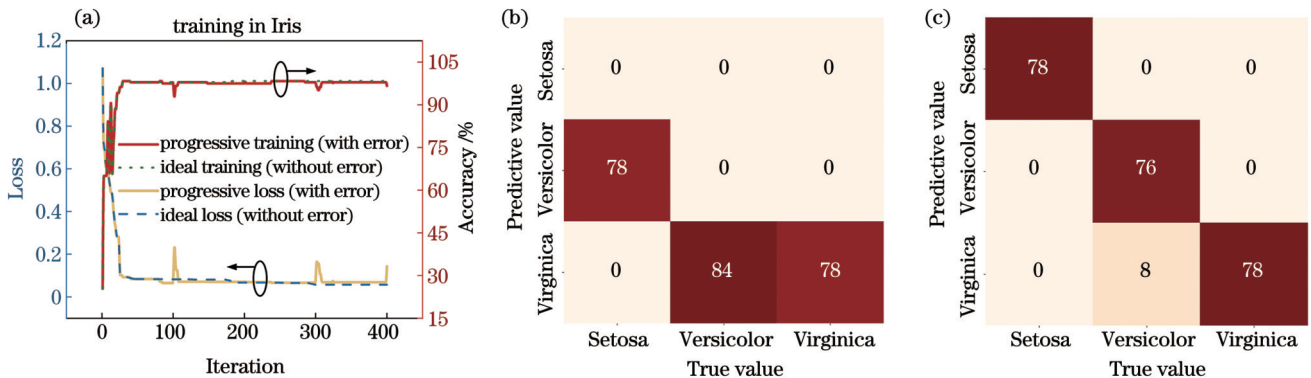


图 5  $4 \times 4 \times 3$  MZI-ONN 的仿真结果。(a) Iris 数据集中正常训练和经过 PT 方案优化后得到的准确率和损失; (b) 带有组件误差的混淆矩阵; (c) 经 PT 方案优化后的混淆矩阵  
Fig. 5 Simulation results of  $4 \times 4 \times 3$  MZI-ONN. (a) Accuracy and loss in Iris dataset after normal training and PT scheme optimization; (b) confusion matrix with component error; (c) confusion matrix after PT scheme optimization

MZI-ONN 的识别准确率将明显下降,仅为 32.50%; 但由于 PT 方案可以抵消 MZI 本身带来的分束器误差和移相器误差,因此保证了 ONN 的识别效果。

搭建了  $6 \times 6 \times 3$  MZI-ONN 的架构,验证所提方案在 MNIST 数据集中的有效性。首先,在理想情况下, MZI-ONN 的识别准确率为 90.33%, 损失函数值收敛到 0.34, 仿真结果如图 6(a) 所示。其次,在训练的相位

值中考虑了实际相位误差和分束器误差对 MZI-ONN 的影响,仿真得到的混淆矩阵如图 6(b) 所示,300 个手写数字样本中只有 196 个能够被正确识别,识别准确率降至 65.33%。采用所提出的 PT 方案后,得到的识别准确率为 87.66%, 损失函数值收敛到 0.36, 混淆矩阵如图 6(c) 所示,说明 PT 方案可有效提升 MZI-ONN 的识别准确率。

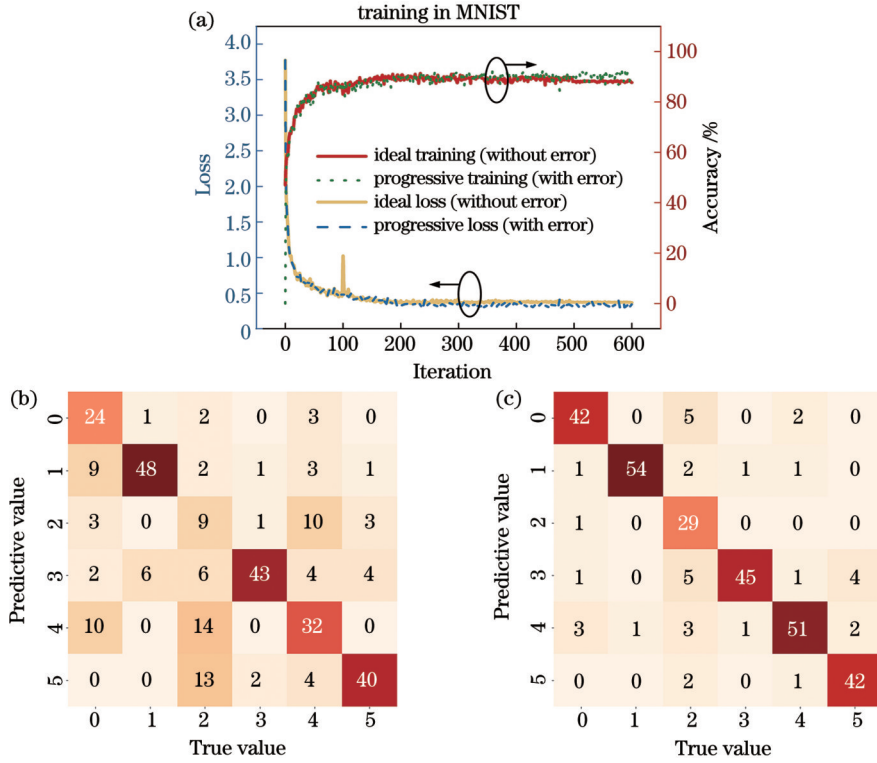


图 6  $6 \times 6 \times 3$  MZI-ONN 的仿真结果。(a) MNIST 数据集中正常训练和经过 PT 方案优化后得到的准确率和损失; (b) 带有组件误差的混淆矩阵; (c) 经 PT 方案优化后的混淆矩阵

Fig. 6 Simulation results of  $6 \times 6 \times 3$  MZI-ONN. (a) Accuracy and loss in MNIST dataset after normal training and PT scheme optimization; (b) confusion matrix with component error; (c) confusion matrix after PT scheme optimization

最后,分别在理想情况以及存在误差和使用 PT 方案优化后的情况下,在 MNIST 数据集中对不同规模的 MZI 网络进行仿真,得到的识别精确度结果如图 7 所示。由图 7 可知,对于不同规模的 MZI-ONN,所提 PT

方案都能够有效抵消误差给识别准确率带来的影响。

### 4.3 误差分析及方案对比

表 2 为所提 PT 方案与传统 GA 方案、采用冗余矩形网格 (RRM) 的误差纠正方案<sup>[10]</sup>, 以及硬件优化方案<sup>[12]</sup> 的对比结果。从表 2 可以看出,传统的 GA 训练方案在输入 8 个特征的 MNIST 数据集下识别准确率提高了 32.40 个百分点,而所提 PT 方案在同样的规模下识别准确率提高了 37.00 百分点,所提 PT 方案识别准确率的提高更为明显。值得注意的是,GA 训练方案<sup>[13]</sup> 使用的是 200 个不精确芯片中的平均准确率,且考虑的误差范围较小,因此 PT 方案相对于 GA 方案具有更好的适应性。基于 RRM 的误差纠正方案是通过添加额外的可调 MZI 克服组件误差来恢复 MZI 酉矩阵的保真度。当 MZI 数量增加一倍时, MZI 表示的酉矩阵收敛误差下降 5 个数量级。但是这种误差优化是以额外增加 MZI 元件作为代价的。硬件优化方案<sup>[12]</sup> 利用检测器在每个干涉仪的输出端口进行相干检测,并对组件误差

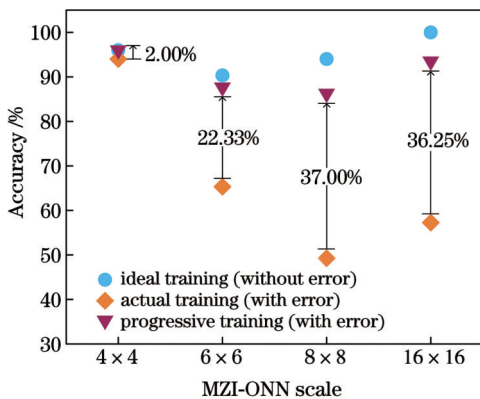


图 7 不同 MZI-ONN 规模下的识别准确率

Fig. 7 Recognition accuracy at different MIZ-ONN scales



表 2 不同优化方案的对比  
Table 2 Comparison of different optimization schemes

Training scheme	Network size	Dataset	Number of MZI	Number of detector used to detect error	Accuracy improvement / (percentage point)
GA training <sup>[13]</sup>	4	Iris	6	1	23.10
	8	MNIST	28	1	32.40
Progressive training	4	Iris	6	1	64.15
	8	MNIST	28	1	37.00
	16	MNIST	128	1	36.25
RRM <sup>[10]</sup>	16	MNIST	256	1	Matrix error decreases by five orders of magnitude
Hardware correction <sup>[12]</sup>	16	MNIST	128	128	Matrix error decreases by an order of magnitude

进行校正,该方案可以将 MZI 代表的矩阵误差降低一个数量级。但是端口检测过多也会增加额外的硬件成本,然而在 PT 方案中,仅用一个探测器就能够检测其中一个 MZI 的分束器误差。因此,PT 方案可以在不增加硬件成本、不改变拓扑网格结构和参数的情况下提高 ONN 的识别准确率,具有更好的抗误差性能。

## 5 结 论

提出了一种对抗 MZI-ONN 识别误差的 PT 方案。其可以在不改变拓扑网格结构和参数的情况下提高 ONN 的识别准确率,且无需额外的硬件成本。仿真结果表明,针对不同规模的 MZI-ONN,采用所提方案后能够有效提升系统的识别准确率,且识别结果与无误差时相近,有效提升 MZI-ONN 的抗误差能力。

### 参 考 文 献

- [1] 栾海涛, 陈希, 张启明, 等. 人工智能纳米光子学: 光学神经网络与纳米光子学[J]. 光学学报, 2021, 41(8): 0823005.  
Luan H T, Chen X, Zhang Q M, et al. Artificial intelligence nanophotonics: optical neural networks and nanophotonics[J]. Acta Optica Sinica, 2021, 41(8): 0823005.
- [2] 郭鹏星, 刘志远, 侯维刚, 等. 相变材料辅助的光子卷积神经网络加速器[J]. 光学学报, 2023, 43(4): 0415001.  
Guo P X, Liu Z Y, Hou W G, et al. Photonic convolutional neural network accelerator assisted by phase change material[J]. Acta Optica Sinica, 2023, 43(4): 0415001.
- [3] Cheng J W, Zhou H L, Dong J J. Photonic matrix computing: from fundamentals to applications[J]. Nanomaterials, 2021, 11(7): 1683.
- [4] Guo P X, Zhou N J, Hou W G, et al. StarLight: a photonic neural network accelerator featuring a hybrid mode-wavelength division multiplexing and photonic nonvolatile memory[J]. Optics Express, 2022, 30(20): 37051-37065.
- [5] 符庭钊, 孙润, 黄禹尧, 等. 片上集成光学神经网络综述[J]. 中国激光, 2024, 51(1): 0119002.  
Fu T Z, Sun R, Huang Y Y, et al. Review of on-chip integrated optical neural networks[J]. Chinese Journal of Lasers, 2024, 51(1): 0119002.
- [6] Wei M L, Li J Y, Chen Z Q, et al. Electrically programmable phase-change photonic memory for optical neural networks with nanoseconds in situ training capability[J]. Advanced Photonics, 2023, 5(4): 046004.
- [7] Shen Y C, Harris N C, Skirlo S, et al. Deep learning with

coherent nanophotonic circuits[J]. Nature Photonics, 2017, 11: 441-446.

- [8] 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.
- [9] Zhu Y, Zhang G L, Li B, et al. Countering variations and thermal effects for accurate optical neural networks[C]// Proceedings of the 39th International Conference on Computer-Aided Design, November 2, 2020, Virtual Event, USA. New York: ACM Press, 2020: 152.
- [10] Pai S, Bartlett B, Solgaard O, et al. Matrix optimization on universal unitary photonic devices[J]. Physical Review Applied, 2019, 11(6): 064044.
- [11] Shokraneh F, Geoffroy-Gagnon S, Liboiron-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.
- [12] Bandyopadhyay S, Hamerly R, Englund D. Hardware error correction for programmable photonics[J]. Optica, 2021, 8(10): 1247-1255.
- [13] Shao R, Zhang G, Gong X. Generalized robust training scheme using genetic algorithm for optical neural networks with imprecise components[J]. Photonics Research, 2022, 10(8): 1868-1876.
- [14] Hughes T W, Minkov M, Shi Y, et al. Training of photonic neural networks through in situ backpropagation[J]. Optica, 2018, 5(7): 864-871.
- [15] Clements W R, Humphreys P C, Metcalf B J, et al. Optimal design for universal multiport interferometers[J]. Optica, 2016, 3(12): 1460-1465.
- [16] Lin X, Rivenson Y, Yardimci N T, et al. All-optical machine learning using diffractive deep neural networks[J]. Science, 2018, 361(6406): 1004-1008.
- [17] Reck M, Zeilinger A, Bernstein H J, et al. Experimental realization of any discrete unitary operator[J]. Physical Review Letters, 1994, 73(1): 58-61.
- [18] Shokraneh F, Nezami M S, Liboiron-Ladouceur O. Theoretical and experimental analysis of a 4×4 reconfigurable MZI-based linear optical processor[J]. Journal of Lightwave Technology, 2020, 38(6): 1258-1267.
- [19] Pai S. Neurophox[EB/OL]. [2023-12-18]. <https://github.com/solgaardlab/neurophox>.
- [20] Geoffroy-Gagnon S. Neurooptica[EB/OL]. [2023-12-18]. <https://github.com/fancompute/neurooptica>.
- [21] Hughes T, Veronis G, Wootton K P, et al. Method for computationally efficient design of dielectric laser accelerator structures[J]. Optics Express, 2017, 25(13): 15414-15427.
- [22] Deng H Q, Khajavikhan M. Parity-time symmetric optical neural networks[J]. Optica, 2021, 8(10): 1328-1333.

# Progressive Training Scheme for Recognition Error of Optical Neural Networks

Guo Pengxing<sup>1,2</sup>, You Zhengrong<sup>1,2</sup>, Hou Weigang<sup>1,2\*</sup>, Guo Lei<sup>1,2</sup>

<sup>1</sup>*School of Communications and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China;*

<sup>2</sup>*Institute of Intelligent Communication and Network Security, Chongqing University of Posts and Telecommunications, Chongqing 400065, China*

## Abstract

**Objective** The optical neural network (ONN) based on the Mach-Zehnder interferometer (MZI) has widespread applications in recognition tasks due to its high speed, easy integration, scalability, and insensitivity to external environments. However, errors resulting from manufacturing defects in photonic devices accumulate as the ONN scale increases, consequently diminishing recognition accuracy. To address the decreased accuracy caused by MZI phase errors and beam splitter errors in the MZI-based ONN (MZI-ONN), we introduce a progressive training scheme to reconfigure the phase shift of the MZI feedforward ONN.

**Methods** Due to the cascaded arrangement of MZIs in MZI-ONN (Fig. 1), the progressive training scheme gradually determines the phase of each column within a certain number of iterations. Based on determining the phase, the phase error and beam splitter error carried by the MZI are considered. After starting the iteration again, the phase value of the undetermined phase shifter is utilized to offset the phase error and beam splitter error carried by the fixed MZI. This training process is repeated until the last column of the grid, and the phase values obtained by progressive training can counteract the inaccuracies caused by imperfect photonic devices, thereby improving the recognition accuracy of MZI-ONN. Importantly, this progressive training scheme reduces inaccuracies caused by optical components without altering the topology of MZI-ONN.

**Results and Discussions** We employ the Neuroptica Python simulation platform to construct a cascaded MZI-ONN and validate the efficacy of the proposed training scheme. The error range of the MZI phase shifter is set between 0.05 and 0.10, with a fixed beam splitter error value of 0.10. Results demonstrate that the proposed progressive training scheme based on the Iris dataset enhances the recognition accuracy of a three-layer  $4 \times 4$  MZI-ONN from 32.50% to 96.65% (Fig. 5). During the application in the MNIST dataset, the accuracy of three-layer ONNs with grid scales of  $4 \times 4$ ,  $6 \times 6$ ,  $8 \times 8$ , and  $16 \times 16$  is elevated by 2.00%, 22.33%, 37.00%, and 36.25%, respectively (Fig. 7), significantly improving the error-resistance performance of the ONN. To substantiate the advantages of the proposed method, we compare the proposed progressive training optimization scheme with traditional genetic algorithm (GA) training, the error correction scheme using a redundant rectangular grid (RRM), and a hardware optimization scheme. Notably, compared with the RRM-based error correction scheme and hardware optimization scheme, the proposed scheme exhibits the capability to conserve more MZI units and detectors. Furthermore, while the traditional GA training scheme enhances the recognition accuracy of the Iris dataset with four features and the MNIST dataset with eight features by 23.10% and 32.40%, respectively, the proposed scheme achieves improvements of 64.15% and 37.00% under the same scale (Table 2). In a comprehensive evaluation, this scheme enhances the recognition accuracy of the ONN without augmenting hardware costs and demonstrates superior error-resistance performance.

**Conclusions** We introduce a progressive training scheme designed to alleviate recognition errors in MZI-ONN. The scheme improves the recognition accuracy of the ONN without modifying the topology grid structure and parameters, thus causing no additional hardware costs. To validate the effectiveness of this scheme, we conduct simulations by adopting the Neuroptica Python simulation platform as a proof of concept. The error parameters of photon devices are pre-trained, and the MZI-ONN phase is fixed based on the number of iterations. Subsequent phases are then utilized to compensate for errors introduced by the fixed phase. Simulation analyses are performed on ONNs of scales  $4 \times 4$ ,  $6 \times 6$ ,  $8 \times 8$ , and  $16 \times 16$ , which demonstrates that the proposed progressive scheme can enhance the recognition accuracy of MZI-ONN by up to 64.15% with an average increase of 39.93%, improving the error-resistant performance of MZI-ONN.

**Key words** optical computing; Mach-Zehnder interferometer; optical neural networks; phase error; beam splitter error; progressive training; error resistance