应对实用干涉仪网格光学处理器的编程挑战

KAVEH RAHBARDAR MOJAVER,[1,*] BOKUN ZHAO,[1] EDWARD LEUNG,[2]S. MOHAMMAD REZA SAFAEE,[1] 以及 ODILE LIBOIRON-LADOUCEUR[1]

[1]加拿大蒙特利尔麦吉尔大学电气与计算机工程系[2]加拿大温哥华英属哥伦比亚大学电气与计算机工程系*hassan.rahbardarmojaver@mcgill.ca

摘要：我们展示了一种用于可编程光学处理器的新型马赫-曾德尔干涉仪（MZI）网格。该网格称为 Bokun 网格，是一种融合了先前拓扑结构 Diamond 和 Clements 特性的架构。与 Diamond 类似，Bokun 网格提供穿过每个独立马赫-曾德尔干涉仪的对角路径，从而能够直接进行相位监测。然而，与 Diamond 不同且与 Clements 类似，Bokun 网格保持最小光学深度，从而实现更好的可扩展性。借助监测功能，Bokun 网格的编程速度更快，提升了处理器的整体能效。得益于最优光学深度，Bokun 网格的性能相较于 Reck 和 Diamond 等深度更长的架构，对损耗和制造缺陷也更具韧性。采用高效的编程方案后，该架构可将能效提高 83%，同时在权重矩阵以 2 kHz 变化时保持相同的计算精度。

© 2022 Optica 出版集团，根据Optica 出版集团开放获取出版协议

1. 引言

基于干涉仪的可编程光学处理器是经典光子学和量子光子学中实现快速、节能计算的有前景结构 [1–3]。得益于光学固有的并行性，这些处理器能够高效执行模拟向量-矩阵乘法 [4]。可编程光学处理器还可在计算中执行乘加运算（MAC）[5] ，并在量子光子学中用作量子门 [6]。深度学习对计算能力的需求快速增长，正限制其发展 [7–8]，。采用硅光子（SiPh）技术制造的节能计算加速器是满足未来机器学习和深度学习应用计算需求的理想候选方案 [9–10]。

理想情况下，可编程光学处理器应能在制造完成后完全重新配置，这与电子领域现场可编程门阵列（FPGAs） [11–12]所提供的功能类似。然而，可编程光学处理器与电子 FPGAs 之间存在一个重大差异：前者是模拟的，而后者是数字的。模拟计算有诸多优势，主要在于能够减少计算所需的时间和复杂度。其缺点是，这些模拟构建模块对器件参数和偏置条件更加敏感。因此，制造偏差和动态误差会在可编程光学处理器中造成显著的计算误差和不准确性 [13–14]。此外，包括热串扰和电串扰在内的动态误差会使处理器性能急剧下降。克服动态误差的一种方法是采用原位编程 [15–16]。原位编程利用优化技术，找到移相器的最佳偏置点，以实现

特定权重矩阵。在原位编程中，处理器是在存在制造缺陷和动态误差的情况下进行编程的，因此，可以调节移相器的偏置以补偿这些误差。其缺点显而易见：编程需要耗费时间和能源。每当权重矩阵发生变化，每个处理器都必须进行一次耗时耗能的优化；随着矩阵尺寸增大，优化也会变得难得多。

第二种方案是异位编程，即先在外部计算出与特定权重矩阵对应的移相器偏置，然后将其应用于不同但相似的芯片。这种方法面临两项主要挑战。首先，应采用硬件纠错方案，以补偿诸如不平衡分光比等制造缺陷 [17]。其次，处理器应具备监测移相器相位设置的功能，以便对相位设置进行微调，从而补偿动态误差。可以考虑使用波导抽头或在线透明光电探测器，来监测处理器中的光功率以及多个移相器的状态 [18]。然而，这些方案往往会增加结构的插入损耗，从而限制其可扩展性。如果无需改变其他移相器的偏置，就能监测特定移相器在光路中施加的相移，将会更为理想。

在本研究中，我们首次提出了一种称为 Bokun 网格的架构，它能够在保持最小光路深度的同时实现直接相位监测。Bokun 网格是一种拓扑排列，融合了两种网格拓扑结构的特点：Clements 和 Diamond [19, 20]。通过提供监测功能，该架构可加快编程速度，提升处理器的整体能效。对于权重矩阵以 2 kHz 变化的 10×10 网格，与矩形网格相比，Bokun 的整体能效提高了 83%。凭借最佳光学深度，Bokun 网格的性能也使其在面对损耗和制造缺陷时的鲁棒性提高了三倍；相比之下，Reck 和 Diamond 等具有较长光学深度的架构则不及它。该网格用于 MNIST 分类任务的双层光学神经网络中 10×10 [20, 21]。

2. 基于 MZI 的光学处理器架构

图 1(a) 展示了基于马赫-曾德尔干涉仪（MZI）的可编程光学处理器的构建模块。该 MZI 由两个耦合器（也称为分束器/合束器）和两个移相器组成。对于固定的偏振态、耦合器的分光比为 50:50 且假设光传播无损时，2×2 构建模块的线性变换矩阵为：

$$\begin{bmatrix} O_{top} \\ O_{bottom} \end{bmatrix} = e^{j(\theta/2)} \begin{bmatrix} e^{j\varphi}\sin\left(\frac{\theta}{2}\right) & e^{j\varphi}\cos\left(\frac{\theta}{2}\right) \\ \cos\left(\frac{\theta}{2}\right) & -\sin\left(\frac{\theta}{2}\right) \end{bmatrix} \begin{bmatrix} I_{top} \\ I_{bottom} \end{bmatrix}, \quad (1)$$

其中，θ 为内部相移，用于改变输出光强；φ 为外部相移，用于定义输出光相位。I_{top}、I_{bottom}、O_{top} 和 O_{bottom}分别表示平面波在[22]输入端口和输出端口处的光电场分布。

理想的 N × N 多端口可重构 MZI 光学处理器是一种酉光学元件，由 n 个马赫-曾德尔干涉仪组成，这些干涉仪依据给定的网格拓扑彼此连接。该结构可表示为一个 N × N 酉矩阵，它由组成部分的马赫-曾德尔干涉仪的酉变换矩阵依次相乘实现。该过程根据马赫-曾德尔干涉仪在网格中的位置进行。酉矩阵保持变换向量的内积和范数不变，因此保持向量的长度和角度不变。酉矩阵在机器学习、人工智能和量子计算领域有着广泛应用。在深度学习中，矩阵乘法用于计算神经网络（NN）中神经元的激活值。具体来说，将输入数据与权重矩阵相乘，再加上偏置，从而得到输出。当我们使用光学处理器执行神经网络的向量矩阵乘法时，会使用 N 个输入端口输入样本的 d 个特征

（其中 $N = d$）。N 个输出端口构成 c 维输出向量，用于确定该样本经单层神经网络预测的类别的。在这项工作中，我们使用两个样本数据集：此前在 [20] 中介绍的多元高斯数据集，以及手写数字的 MNIST 数据集 [23]。我们比较这两个数据集得到的结果，以研究数据集对硬件性能的影响。预测类别由代表最高光功率的输出端口的索引决定。这与传统神经网络一致，其预测类别由数值最高的输出神经元指定 [24]。

图1（b）所示的 Reck 网格拓扑由 Reck 等人提出，[21], 由一个马赫-曾德尔干涉仪构成的三角网格组成。该结构可用于实现任意 N × N 阶酉矩阵，其中 n 个马赫-曾德尔干涉仪彼此连接成网格，并在输入端口处配备 N 个额外的移相器。事实上，N × N 阶 Reck 网格是一种通用的 N × N 阶酉变换结构，可用于实现任意 N × N 阶酉变换。马赫-曾德尔干涉仪的数量随矩阵规模呈二次增长，具体如下：

$$n = \frac{N(N-1)}{2}, \tag{2}$$

其中，N 表示对于输入端和输出端数量相同的结构，从第 i^{th} 个输入端到第 j^{th} 个输出端的光通道数量（$i, j \in N$）。Reck 的三角架构支持对网格进行顺序校准。换言之，Reck 架构使我们能够通过一条由已校准马赫-曾德尔干涉仪构成的路径，确保每个马赫-曾德尔干涉仪均已校准。

图1（c）所示的 Diamond 网格由 Shokraneh 等人提出。与 Reck 网格和 Clements 网格相比，它额外使用了 $(N-1) \times (N-2)/2$ 个马赫-曾德尔干涉仪，总数为：

$$n = (N-1)^2. \tag{3}$$

虽然额外增加马赫-曾德尔干涉仪会带来更高的损耗，并使系统更容易受到相位不确定性的影响，但与 Reck 网格相比，该网格的对称性更高，因此能够应对损耗不平衡。此外，通过额外的马赫-曾德尔干涉仪在所构建的网格中增加自由度，还能抵消相位不确定性带来的影响。Diamond 网格中额外马赫-曾德尔干涉仪的输出波导未连接，因此可以从其输出端排除干涉的相消部分，并最优地调节输出端的光功率水平。

图 2 c 所示的 Clements 网格由 Clements 等人提出，使用的马赫-曾德尔干涉仪数量与 Reck 网格相同 [19]。尽管 Reck 网格和 Clements 网格中的马赫-曾德尔干涉仪总数相等，但 Clements 网格的光学深度更短，因此插入损耗更低。在 Clements 架构中，每个输入信号都会在最早可能的位置与其最近邻交叉，从而缩短光学深度。这与 Reck 网格不同，在 Reck 网格中，底部的输入信号必须传播一段距离后才能与其他信号相互作用。8 × 8 Clements 拓扑的网格深度（最长路径上连续马赫-曾德尔干涉仪的数量）为 8 个马赫-曾德尔干涉仪，而 Reck 网格为 13 个。Clements 拓扑的缺点是校准和编程复杂。与 Reck 网格和 Diamond 网格不同，Clements 结构并非三角形结构，因此校准颇具挑战性。在下一节中，我们将展示三角形结构和对角路径如何有助于实现更精确的校准和编程。

在这项工作中，我们提出了一种新型 Bokun 网格，它在保持三角形结构的同时实现了较短的光学深度，而这种三角形结构对于准确的校准和编程至关重要。事实上，Bokun 网格是一种截断菱形网格，其中间的光学输入/输出端口用作主光路。它也可以视为 Clements 网格的扩展版本，在结构的顶部和底部增加了额外的马赫-曾德尔干涉仪，以形成三角形，并为每个马赫-曾德尔干涉仪提供一条对角输入/输出路径。Bokun 网格中的马赫-曾德尔干涉仪数量为：

$$n = \frac{N(N+n/2-2)}{2}. \tag{4}$$

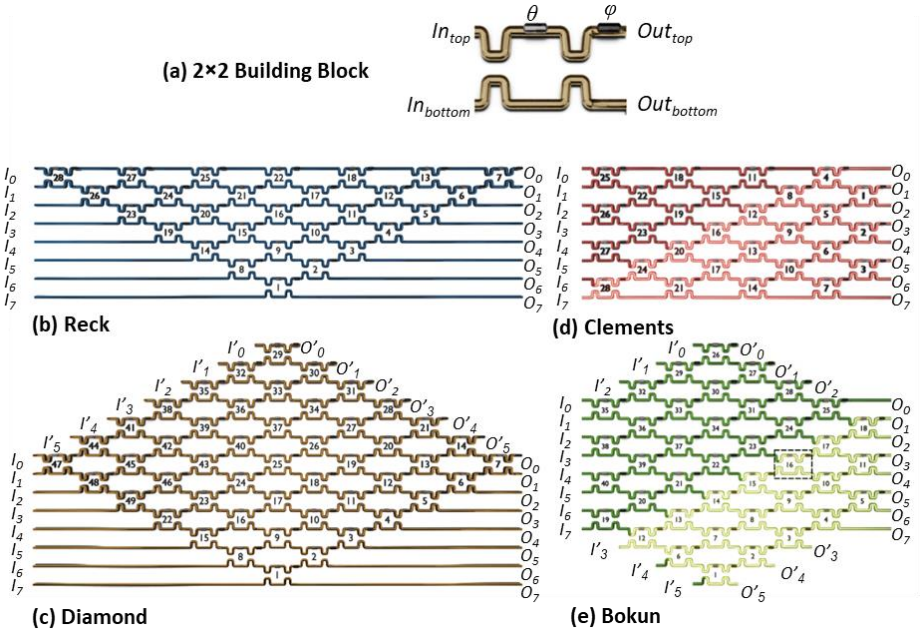

图1。（a）处理器的2 × 2 构建模块。（b）Reck、（c）Diamond、（d）Clements，以及本文提出的 I Bokun 网格中的8 × 8 基于MZI的光学处理器。Reck 是主要的干涉架构，采用三角架构，支持顺序校准方案。Diamond 是 Reck 的对称版本，额外包含 21 个马赫-曾德尔干涉仪。Clements 缩短了网格深度，并使各路径中的马赫-曾德尔干涉仪数量在最小值和最大值方面更加对称。Bokun 网格是 Clements 的扩展版本，额外包含 12 个马赫-曾德尔干涉仪和 12 个辅助光学输入/输出端口，以缓解校准/编程难题。如第 3 节所述，若存在一种方式能够使网格中的光仅通过某个马赫-曾德尔干涉仪的一个输入端照射，并使该干涉仪之后通往某个输出端的所有马赫-曾德尔干涉仪保持暗态（零光），则该马赫-曾德尔干涉仪可独立访问。Bokun 网格中被照亮的部分展示了如何仅向I'_3 输入光，并在O_1 检测光，同时使其余所有输入端保持暗态，从而监测 MZI-16 的相位设置。在这种情况下，MZI-16 的顶部输入端以及 MZI-17 和 MZI-18 的次级输入端均保持零光，因而可以独立监测 MZI-16 的相位设置。该图也说明了 Clements 网格为何无法做到这一点。在 Clements 网格中，经过 I_7 的光会到达 MZI-9 的两个输入端以及后续的马赫-曾德尔干涉仪，因此 Clements 中的 MZI-9 无法独立访问。使用其他任何输入端时情况也相同。在这四种网格中，Bokun 的深度最短（与 Clements 相同），路径中的马赫-曾德尔干涉仪数量也最均衡（最小值为=7，最大值为=8），且其所有马赫-曾德尔干涉仪均可独立访问。

光学处理器可以利用其 N 个马赫-曾德尔干涉仪实现一个酉矩阵，方法是使用组成部分的马赫-曾德尔干涉仪的逆变换矩阵，每个矩阵都定义在一个 N 维希尔伯特空间 [21] 上。通过在输入端口注入光，使其在网格中的光学元件之间发生场相互作用，即可对表示样本的输入向量执行矩阵乘法。输出向量是输入向量与酉矩阵相乘的结果。

3. 光学处理器的校准与编程

使用可编程光学处理器的第一步是进行校准。通过校准，我们可以确定移相器的偏置电压与所施加相移之间的关系。理论上，相似的移相器具有相同的相位/电压关系。然而在实践中，由于误差主要源自制造工艺变化 [25]，即使是在同一芯片上制造的相似移相器，其相位/电压关系也会有所不同。可编程光学处理器属于模拟器件，对相位设置非常敏感，因此在使用处理器之前，需要对每个移相器单独进行校准。在第 4 节中，我们将看到可编程光学处理器的相位误差如何降低分类

光学神经网络（ONN）的准确率。本节将首先讨论如何校准单个马赫-曾德尔干涉仪（MZI），它是2 × 2 构建模块。接下来，我们将进一步讨论如何对更大的网格进行系统级校准。

3.1 单个马赫-曾德尔干涉仪的校准

图 2（a）展示了单个马赫-曾德尔干涉仪的校准过程。我们首先校准移相器 θ，并从一个输入端口注入连续波（CW）光；本例中选择顶部输入端，即，输入端$_{top}$。随后，我们扫描θ 偏置电压，并测量选定输出端的光功率。我们选择直通态，因此在本次测量中选择顶部输出端（输出端$_{top}$）。交叉态的讨论类似。根据公式 (1)，可以求得从输入端到输出端口的光电场分布。聚焦于 输入端$_{top}$ 到输出端$_{top}$的路径，我们写为：

$$O_{top} = e^{j(\theta/2)}\left[e^{j\varphi}\sin\left(\frac{\theta}{2}\right)I_{top} + e^{j\varphi}\cos\left(\frac{\theta}{2}\right)I_{bottom}\right], \tag{5}$$

因此，从顶部输入端到顶部输出端的透射率为：

$$Transmission = \left(\frac{O_{top}}{I_{top}}\right)^2 = \left(\sin\left(\frac{\theta}{2}\right) + \cos\left(\frac{\theta}{2}\right)\frac{I_{bottom}}{I_{top}}\right)^2, \tag{6}$$

为实现精确校准，我们倾向于阻断底部输入端口（In$_{bottom}$），使光无法通过该端口。在此条件下，公式 (6) 中的 I_{bottom} 变为零，透射率与 $\sin^2\left(\frac{\theta}{2}\right)$ 成正比，并分别在 θ=0 和 θ=π，处达到最小值和最大值。我们使用 Ansys Lumerical Interconnect 模拟了不同条件下马赫-曾德尔干涉仪的透射率。图 2（b）中的黑色实线表示没有光进入 In$_{bottom}$ 时的理想情况。根据 θ=0 和 θ=π对应的偏置电压，我们对θ 移相器进行校准。

实际上，如果无法直接访问马赫-曾德尔干涉仪的输入端，则 In$_{bottom}$ 处可能存在微弱的光学干涉。考虑顶部和底部输入端口处的光功率 P$_{top}$ 和 P$_{bottom}$，以及为 Δ_{in} 的相对相移，将 $I_{top} = \sqrt{P_{top}}$和 $I_{bottom} = \sqrt{P_{bottom}}e^{j\Delta_{in}}$ 代入式 (6)，可得：

$$Transmission = \left(\sin\left(\frac{\theta}{2}\right) + \cos\left(\frac{\theta}{2}\right)\sqrt{\frac{P_{bottom}}{P_{top}}}\,e^{j\Delta_{in}}\right)^2, \tag{7}$$

方程7描述了 P$_{bottom}$ 和 Δ_{in} 对 In$_{top}$ 到 Out$_{top}$ 透射率的影响，因此也描述了 θ 校准误差。根据该方程，校准误差随 P$_{bottom}$ 增大，并在 Δ_{in}= 0、 π 时达到最大值。图3（b）比较了不同 P$_{bottom}$ 和 Δ_{in} 取值下，In$_{top}$ 到 Out$_{top}$ 的透射率随 θ 的变化。对于 P$_{bottom}$= -20 dBm 和 Δ_{in}=0，实现透射率最小值时的误差为 0.06 π。对于 P$_{bottom}$= -10 dBm，该误差分别增至 0.18π 和 -0.18π，对应于 Δ_{in}=0 和 π。在第4节中，我们将说明，移相器上 0.18π 的误差会使执行 MNIST任务的处理器的分类准确率降低约25%。图3(b)的仿真结果与方程（7）中的理论一致。需要指出的是，底部端口存在 -10 dBm 的干扰信号是一个合理的假设，尤其是考虑到前一级马赫-曾德尔干涉仪可能尚未完成校准 [26]。

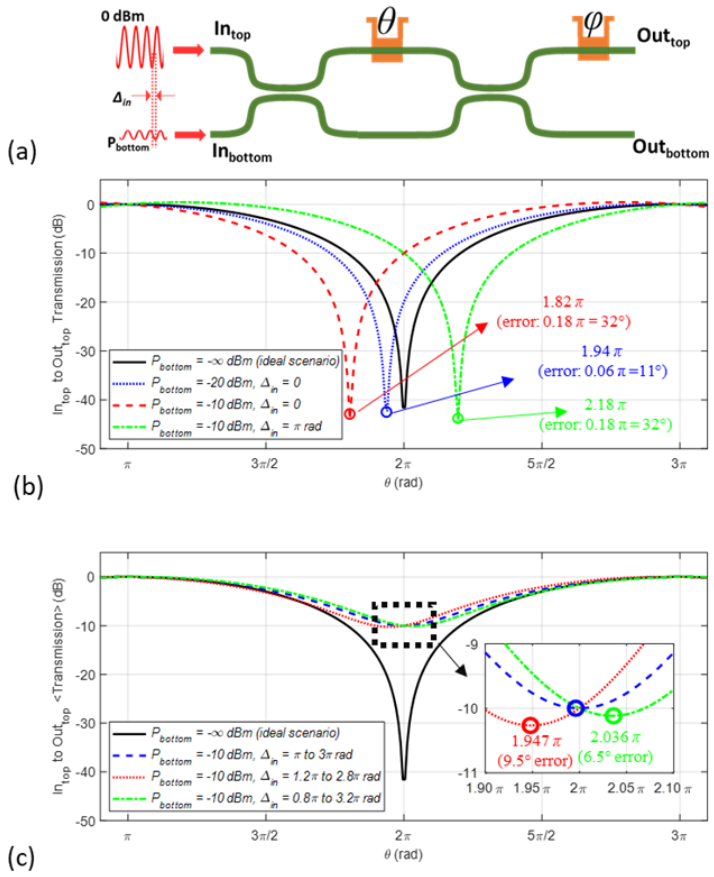

图 2. (a) 底部输入端存在干扰信号时的马赫-曾德尔干涉仪校准。(b) 不同输入端 In_{bottom}处干扰信号情况下，光传输相对于θ 的变化。当 In_{bottom} 为零时，校准是理想的。(c) 在输入端 In_{bottom}存在信号时，改变Δ_{in} 并对光传输取平均，可降低θ 校准误差，但会增加校准复杂度。

为消除 θ 校准期间 I_{bottom} 处干扰光的影响，Bandyopadhyay 等人讨论了一种实用方法，即对 Δ_{in} [17] 变化 2π 时的透射率取平均值。可以使用前一个马赫-曾德尔干涉仪模块的外部移相器来扫描 Δ_{in}。因此，平均透射率为：

$$\langle Transmission \rangle = \frac{1}{2\pi}\int_0^{2\pi}\left(\sin\left(\frac{\theta}{2}\right)+\cos\left(\frac{\theta}{2}\right)\sqrt{\frac{P_{bottom}}{P_{top}}}e^{j\Delta_{in}}\right)^2 d\Delta_{in} = \sin^2\left(\frac{\theta}{2}\right), \quad (8)$$

如图 2 (c) 所示，在完整的 2π Δ_{in}周期内取平均值时，透射率在 θ=0 和 θ=π处达到最小值和最大值，从而实现无误差的 θ 校准。为确保在 2π上取平均值，必须先校准控制 Δ_{in} 的前一个模块。若未能如此，则在与 2π 略有差异的周期内取平均值会导致校准误差：分别在 2π - 0.4π 和 2π + 0.4π上取平均值时，误差为 0.053 π 和 0.036 π。尽管平均值并非严格在 Δ_{in}的 2π 相移范围内计算，平均技术仍能显著减小校准误差。平均技术的缺点是会增加校准过程所需的时间并提高其复杂度。一个典型的热光移相器，其 $V_\pi \approx 2$ V [26] 需要 400 个测量点，才能以 0.01 V 的分辨率进行 2π 扫描。

采用平均技术后，在假设分辨率相同的情况下，对 θ 和 Δ_{in}进行二维扫描时，测量点数量将增至 1600 个。

现在，我们分析光路中后续马赫-曾德尔干涉仪在输出端产生的校准误差。图3 (a) 展示了 MZI-1（正在校准），它通过 MZI-2 与光电探测器相连。根据式 (7)，并假设 $\mathrm{In}_{bottom1}$ （端口标签见图3-a）处没有光，则 In_{top1} 到 Out_{top1} 的透射率为：

$$Transmission = \sin^2\left(\frac{\theta_1}{2}\right)\left(\sin\left(\frac{\theta_2}{2}\right) + \cos\left(\frac{\theta_2}{2}\right)\sqrt{\frac{P_{bottom_2}}{P_{top_2}}}\,e^{j\Delta_{in-2}}\right)^2, \tag{9}$$

其中，θ_1 和 θ_2 分别是 MZI-1 和 MZI-2 的内部相移，P_{top2} 和 $\mathrm{P}_{bottom2}$ 分别是第二个马赫-曾德尔干涉仪顶部和底部输入端口处的光功率，其相对相移为 Δ_{in-2}。理想情况下，我们希望透射率与 $\sin^2(\frac{\theta_1}{2})$ 成正比，从而分别在 $\theta_1 = 0$ 和 $\theta_1=\pi$处取得最小和最大透射率。然而，式 (9) 第二部分中的 P_{top_2} 和 Δ_{in-2} 是 θ_1 的函数，因而导致了校准误差。

为减小这一误差，第一种解决方案是设置 $\theta_2 = \pi$ （MZI-2 处于直通态），使公式 (9) 中的余弦项等于零。这样，In_{top2} 处的光会直接到达 Out_{top2}，而不与 $\mathrm{In}_{bottom2}$ 处的光发生干涉。图 4 (b) 中的红色虚线表示这一情形。难点在于，θ_2 的任何变化都会转化为 θ_1 校准中的误差。第二种解决方案是阻断 MZI ($P_{bottom_2} = 0$) 的底部输入端口。根据公式 (9)，透射率为 $\sin^2(\frac{\theta_1}{2})\sin^2(\frac{\theta_2}{2})$；当 θ_2 为常数时，该值与 $\sin^2(\frac{\theta_1}{2})$ 成正比。请注意，在这种情况下，无需将 θ_2 精确设为 π 或 0。只要 θ_2 保持不变，MZI-2 就会在 In_{top1} 与 Out_{top2} 之间起到恒定光衰减的作用，将一部分信号分流至 $\mathrm{Out}_{bottom2}$。图 3 (b) 中的蓝色点线表示这一情形。

如果 $P_{bottom_2} \neq 0$ 和 $\theta_2 \neq \pi$，MZI-2 会给 MZI-1 的校准带来误差。如图 4(b) 中绿色点划线所示，对于 $P_{bottom_2} = -10\ dBm$，θ_2 中的 0.1 π 误差会转化为 θ_1 校准中的 0.02 π 误差。根据上述讨论，要精确校准马赫-曾德尔干涉仪，应使后续级所有马赫-曾德尔干涉仪的第二个输入端口保持为零。

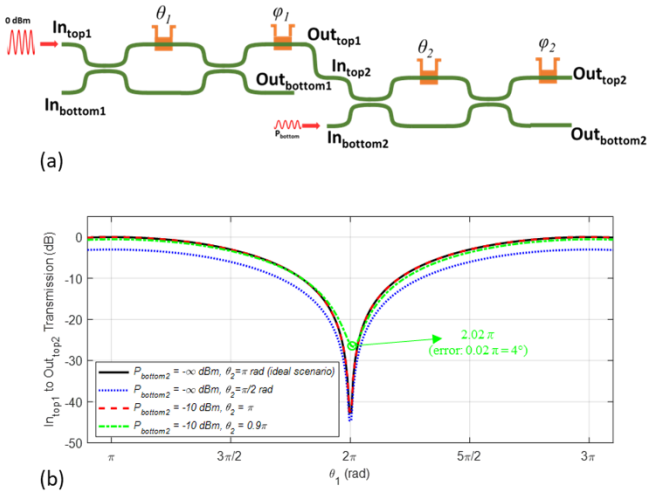

图 3。（a）存在次级马赫-曾德尔干涉仪连接至其输出端时的马赫-曾德尔干涉仪校准。（b）在 $\mathrm{In}_{bottom2}$ 处干扰信号的不同条件下，光传输随 θ_1 的变化。当 $\mathrm{In}_{bottom2}$ 为零或 $\theta_2 = \pi$时，校准是理想的

T外部移相器 φ 设定从马赫-曾德尔干涉仪输出端射出的光的输出相位，因此，其校准需要测量信号的相位。这可以通过使用多个横电（TE）模式或对光进行相干检测来实现 [27]。对于移相器 φ 的校准，在待校准马赫-曾德尔干涉仪输入端以及所有后续马赫-曾德尔干涉仪处，干扰信号的影响与我们对移相器 θ的讨论类似。通常，将马赫-曾德尔干涉仪及所有后续马赫-曾德尔干涉仪的一个输入端置零，有助于精确校准 θ 和 φ 移相器。这是干涉仪网格中对角光路的主要优势，下一节将对此进行讨论。

3.2 校准干涉仪网格

要校准图1所示的马赫-曾德尔干涉仪网格，我们需要逐个校准各个马赫-曾德尔干涉仪。正如上一节所述，在网格中校准某个马赫-曾德尔干涉仪时，理想情况下，我们需要将该干涉仪的一个输入端以及后续级中所有马赫-曾德尔干涉仪的一个输入端置零。由于对角路径贯穿这些网格中的每个马赫-曾德尔干涉仪，这对于 Diamond 和 Bokun 架构中的所有马赫-曾德尔干涉仪都可行；然而，Reck 和 Clements 架构无法提供这种方式。

要校准 Bokun 网格，我们先从 MZI-1 开始，将光照射到 I'_5，并将 O'_5 连接到探测器。当光无法通过 I_7, I'_3, 和 I'_4, 时，我们便能确保 MZI-1 的顶部输入端为零。接下来，我们校准 MZI-2：将光照射到 I'_5, ，使 MZI-1 处于交叉态，并将探测器连接到 O'_4。保持 I_2, I_3, I_4, I_5, I_6, I_7, 和 I'_4 处于暗态，即可确保 MZI-2 的顶部输入端为零。我们按照图 2 中由 MZI 编号标示的顺序，以类似方式继续校准所有马赫-曾德尔干涉仪。Bokun 网格的菱形架构提供了一条从输入端通往输出端、并经过每个马赫-曾德尔干涉仪的对角路径（从西南到东北，或从西北到东南）。沿这条对角路径，同时保持所有其他输入端处于暗态，可确保该马赫-曾德尔干涉仪及其后续通往输出端的所有马赫-曾德尔干涉仪都有一个输入端为零。图 2 展示了作为中间干涉仪之一的 MZI-16 的校准过程。我们将光照射到 I'_3, ，并使 MZI 12、13、14、15、17、18 均处于交叉态。请注意，得益于这条对角路径，MZI-16 以及紧随其后的两个马赫-曾德尔干涉仪（MZI-17 和 MZI-18）各有一个输入端为零。因此，Bokun 网格的菱形架构可以独立校准每个马赫-曾德尔干涉仪，而不会产生相位误差累积。Diamond 网格的校准过程与此基本相似。

图 2 所示 Reck 网格中的马赫-曾德尔干涉仪可按列出的顺序进行校准。由于 Reck 网格具有三角形拓扑，在校准某个马赫-曾德尔干涉仪时，总能将一个输入端设为零。例如，校准 MZI-22 时，通过向 I_4, 施加输入，将 MZI-19、MZI-20 和 MZI-21 设为交叉态，并使 I_0, I_1, I_2,和 I_3 保持无光，即可确保 MZI-22 的顶部端口无输入。这有助于消除马赫-曾德尔干涉仪校准中的输入误差。然而，在 Reck 网格中，我们未必能确保朝向输出端的连续马赫-曾德尔干涉仪有一个输入端为零。以校准 MZI-22 为例，无论我们选择经过 MZI-18、MZI-13 和 MZI-7 的输出路径，还是选择通往其他输出端口的路径，所有马赫-曾德尔干涉仪的次级输出端都可能出现由 I_4产生的干涉信号。尽管 Reck 的三角形结构保证了在校准 MZI-22 时，MZI-18、MZI-13 和 MZI-7 已经校准，但它们的相位设置存在的任何误差都会转化为 MZI-22 的校准误差。如上一节所述，待校准马赫-曾德尔干涉仪输入端的干涉光产生的误差，比连续马赫-曾德尔干涉仪造成的误差更严重。因此，Reck 校准对相位误差相当稳健。Reck 的缺点是光学深度较大且不均衡，如第 2 节所述。

Clements 的校准过程更为复杂。Clements 架构采用矩形形状设计，使每个输入信号都能在最早的可能位置与其最近邻交叉，从而使网格的光学深度最小。然而，较短的光学深度是以更复杂、且在某些情况下不够准确的校准为代价的。[17] 中详细讨论了 Clements 校准。校准从最后一级开始，因为这一级可以直接接触输出端，然后按照图 2 所列的顺序向输入端推进。我们从 MZI-1 开始，选择其顶部输入端至顶部输出端的路径进行校准。此时

校准 MZI-1 时，该结构无法在保持此 MZI 底部输入端无光的同时，向其顶部输入端照射光。来自网格输入端的光会经过多个未经校准的马赫-曾德尔干涉仪后到达 MZI-1。因此，使用上一节讨论的对输入相位取平均的技术来校准 MZI-1，以减轻底部输入端干涉光的影响。最后一级的马赫-曾德尔干涉仪校准完成后，校准过程便继续对这些网格拓扑结构中更前面的各级进行。

3.2 移相器状态的编程与监测

编程是指设置所有马赫-曾德尔干涉仪的偏置，以实现所需权重矩阵的过程。与仅在可编程光学处理器制造完成后进行一次的校准不同，每当权重矩阵发生变化时，都需要重新编程。因此，不应忽视编程所需的时间和能耗。在原位编程中，通过梯度下降等优化技术设置马赫-曾德尔干涉仪的偏置 [15, 16]。在异位编程中，针对特定权重矩阵所需的偏置点会在外部计算，再应用于其他类似芯片。无论采用哪种技术，每当权重矩阵发生变化时，都必须对处理器重新编程。因此，编程时间必须短于权重矩阵变化最高频率的倒数。这限制了光学处理器在静态或权重矩阵低频变化任务中的应用。将权重矩阵应用于移相器后，移相器之间的热串扰会造成动态误差，从而降低处理器的精度。必须重新调整马赫-曾德尔干涉仪的偏置，以补偿相邻移相器产生的热串扰。如果处理器包含波导抽头或在线透明光电探测器，用于监测每个马赫-曾德尔干涉仪的相位设置，并构成用于设置移相器偏置的闭环系统，编程就能更快速、更准确。然而，波导抽头和在线光电探测器往往会增加结构的插入损耗，并提高系统的复杂性 [11, 18]。因此，如果架构能够通过主要光学输入/输出端口，在不改变其他移相器偏置的情况下，直接监测特定移相器所施加的相移，将会非常有利。Bokun 网格的对角架构具备这一功能。

让我们回到图1所示 Bokun 网格中的 MZI-16 示例。我们之前展示过，只要向 I'_3, 施加光，同时让所有其他输入端保持暗态，MZI-16 以及沿通往 O_1 方向后续的所有马赫-曾德尔干涉仪都会有一个暗的光学输入端。我们在图1中以示意方式展示了这一情形：向 I'_3注入光，使图示结构亮起。如第3.1节所述，在保持除 MZI-16 以外所有马赫-曾德尔干涉仪的偏置不变时，I'_3 到 O_1的透射率与 $\sin^2\left(\frac{\theta_{MZI-16}}{2}\right)$ 成正比。当在 Diamond 网格上实现特定权重矩阵时，我们可以在不改变其他马赫-曾德尔干涉仪偏置的情况下监测 θ_{MZI-16} 。由于这一特性，我们称 MZI-16 可独立访问。在实现权重矩阵后，如果需要监测特定移相器施加的相移，这一特性就非常有用。由于无需改变其他马赫-曾德尔干涉仪的状态，我们能够在其他马赫-曾德尔干涉仪产生热串扰的情况下监测 MZI-16 的状态。如果不存在一条经过 MZI-16、连接某个输入端与某个输出端的对角路径，这确实是不可行的。得益于 Bokun 的菱形结构，其中的所有马赫-曾德尔干涉仪都可独立访问。

在 Clements 中，只有位于两条对角线上的马赫-曾德尔干涉仪可独立访问。例如，图1说明了为什么 MZI-9 作为非对角线MZI无法独立访问。如果我们将光注入 I_7 并监测 O_3, , MZI-9 的两个输入端以及后续通向输出端的马赫-曾德尔干涉仪都会被照亮。在 Clements 上实现权重矩阵后，若要监测 MZI-9 所施加的精确相移，我们需要更改 MZI-12 的配置，并将其设为交叉态，以消除 MZI-9 的上方输入端。我们还必须将 MZI-5 和 MZI-2 设为直通态，使 I_7 到 O_3 的传输路径等于 θ_{MZI-9} 的正弦平方函数。类似地，在 Reck 中，只有外侧的马赫-曾德尔干涉仪

对角线上的马赫-曾德尔干涉仪可独立访问。然而，Diamond 与 Bokun 类似，其所有马赫-曾德尔干涉仪均可独立访问。

表1比较了图1所示四种网格的特性。Diamond 和 Bokun 的所有马赫-曾德尔干涉仪均可独立访问，因此更易于编程，且编程精度更高。与 Diamond 相比，Bokun 的主要改进在于网格深度更短。实际上，Bokun 是一种截短的 Diamond 网格，其中我们将中心的光学输入/输出端口用作主光路。我们还移除了两侧的马赫-曾德尔干涉仪，以尽可能减小光学深度。Bokun 网格也可以看作是在顶部和底部增加了额外马赫-曾德尔干涉仪的互补型 Clements 网格。这些马赫-曾德尔干涉仪对于提供对角路径以及增加可独立访问的马赫-曾德尔干涉仪数量至关重要。Bokun 的另一项优势是不同光路中的马赫-曾德尔干涉仪数量均衡（在 8 × 8 结构中，最少为七个，最多为八个）。马赫-曾德尔干涉仪数量均衡，因此插入损耗也均衡，这是网格的一项重要特性，尤其适用于量子应用 [19]。与 Diamond 类似，Bokun 的不足之处是马赫-曾德尔干涉仪和光学输入/输出端口数量较多。需要指出的是，尽管马赫-曾德尔干涉仪数量增加会扩大网格的占用面积，但 Bokun 中的额外马赫-曾德尔干涉仪（与 Diamond 不同）不在主光路上，因此网格深度仍能保持最小。

表1. 不同**8 × 8** 网格的架构特征

Mesh	总数 MZIs	可独立访问的马赫-曾德尔干涉仪	网格深度	最小↔最大马赫-曾德尔干涉仪每条路径
Reck [21]	28	13（46%）	13	1↔13
Diamond [20]	49	49（100%）	13	1↔13
Clements [19]	28	14（50%）	8	4↔8
Bokun（本研究）	40	40（100%）	8	7↔8

4. 光学神经网络中的网格性能

为了比较基于 Reck、Clements、Diamond 和 Bokun 网格的光学处理器的性能，我们模拟了它们用作光学神经网络时的表现。图 4 展示了传统单层数字神经网络。输入端（IN）是构成数据集单个样本的特征，它们通过节点 X 输入神经网络。随后，向量 X 与权重矩阵 W 相乘，再经过非线性激活函数 $f()$，得到最终向量 $\hat{\boldsymbol{Y}}$ 。因此，单层神经网络的方程为：

$$\hat{Y} = f(Z) = f\,(W.X) \tag{10}$$

通过寻找最大参数，对向量 $\hat{\boldsymbol{Y}}$ 进行处理，以确定样本的预测类别。如果网络正在进行反向传播 [28], ，则可以将其 $\hat{\boldsymbol{Y}}$ 与真实值向量 Y 进行比较；出于分类目的，Y 通常是独热编码向量 [29]。假设特征数量等于类别数量。将这两个向量 $\hat{\boldsymbol{Y}}$ 与 Y 进行比较后，会得到一个损失函数 L，例如均方误差 [30] 或分类交叉熵 [31]。计算出损失函数值后，便会计算相对于权重矩阵的梯度。随后，对网络进行梯度下降以优化权重矩阵。接着，可以使用上一节所述的光学处理器构建得到的权重矩阵 W。

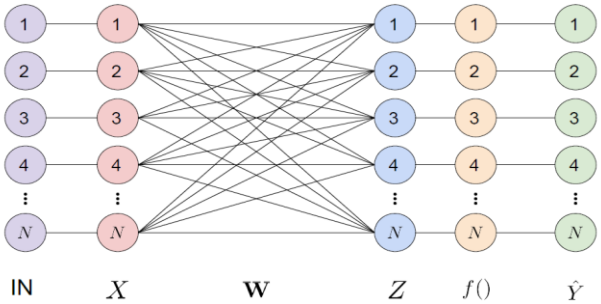

图 4. 一个 N × N 单层神经网络示例，输入 N 个特征，并输出 N 种可能的类别。

本研究使用两个数据集，以确保比较具有足够的普遍性，并避免网格因所用数据集的特定特性而受到偏袒。第一个数据集是 [20]中介绍的线性可分高斯数据集。使用该数据集，传统单层神经网络可达到 100% 的分类准确率 [32]。第二个数据集是 MNIST [23]。

Neuroptica 由 [33], 的作者编写，是一个用 Python 编写的基于 MZI 的光神经网络仿真平台。它提供了多种抽象层级，用于训练和仿真光神经网络。其最低层级的功能支持操控马赫-曾德尔干涉仪中移相器和耦合器的排列与属性，而最高层级的功能则提供类似 Keras 的应用程序编程接口（API）。该库支持通过反向传播训练基于 MZI 的光神经网络 [15, 21]。需要注意的是，用于光神经网络的反向传播算法必须一路反向传播至马赫-曾德尔干涉仪的相位，而不能仅传播至矩阵权重。因此，该反向传播算法采用伴随电场法 [22] ，以便对网格的酉变换矩阵进行原位优化。该库包含 Reck 网格和 Clements 网格。不过，它不包含 Diamond 网格和 Bokun 网格；后两者是在此基础上添加的，以支持对本研究所考察类型的网格进行训练和仿真。Diamond 网格和 Bokun 网格已添加到克隆的代码库 Neuroptica：迈向光子神经网络的实用实现代码库 [34] 中。

我们测试了图 2 所示网格在两种主要误差源——相位不确定性和光学损耗——存在时的性能。每个可重构 MZI 中移相器的相位不确定性，对于基于MZI的光学处理器的实验编程至关重要。移相器的相位不确定性会影响相应 MZI 输出端的光功率分光比。移相器中的相位误差会扰乱其输出端口处的相对相位。因此，相位不确定性会降低所实现光学神经网络的分类准确率。在本研究中，相位不确定性由正态分布随机变量（N（0， σ））表示。相位不确定性受多种因素影响，包括移相器之间的热串扰、施加到移相器的偏置电压中的信号噪声，以及波导尺寸变化。因此，移相器中的相移在数学上定义为

$$\Theta_{actual} = \Theta_{optim} + N(0, \sigma_\Theta^2) \tag{11}$$

其中，Θ_{optim} 是最优的θ 或φ 相位，而σ_Θ 是任一相位的标准差。每次矩阵乘法后都会重新计算此相位不确定性，以模拟噪声的动态变化。

两个性能指标（FoM）用于衡量每种网格拓扑在应对相位不确定性和损耗方面的质量。为获得这些性能指标，首先对光学神经网络进行训练，然后在不同实验条件下对验证数据集进行分类。性能指标定义了光学神经网络模拟结果中达到 75% 分类准确率的区域面积。如果考虑相位不确定性（即所有被视为 σ_θ 和 σ_ϕ 的情况），

性能指标的单位为弧度平方（rad²）。另一方面，如果变化的参数同时包括组成部分的马赫-曾德尔干涉仪的损耗和相位不确定性 σ_θ 和 σ_ϕ，则性能指标的单位为分贝乘以弧度（dB.rad）。在这种情况下，我们假设 σ_θ 等于 σ_ϕ。这两个性能指标可用于研究光学神经网络'应对实际不确定性的能力。这项分析包含随机成分（例如，损耗会因制造质量以及马赫-曾德尔干涉仪在芯片上的位置而变化）。因此，验证数据集中的每个样本都会重复测试多次，并取分类准确率的平均值。

图5（a-d）展示了10 × 10 网格应对θ 和φ 相位不确定性的能力。该图给出了马赫-曾德尔干涉仪损耗为 0 dB 时对高斯数据集进行分类的仿真结果。仿真参数的详细信息见补充材料。在所有网格中，准确率都会随着相位不确定性的增大而下降，但 Clements 和 Bokun 对相位误差的鲁棒性更强。Clements 和 Bokun 的光学深度较短，这是其对相位不确定性鲁棒性提升的主要原因。图5（e-h）展示了网格对相位不确定性的容忍度（$\sigma_\theta = \sigma_\phi$），以及对组成部分的马赫-曾德尔干涉仪损耗的耐受能力。与另外两种网格相比，光学深度较短的 Clements 和 Bokun 具有更好的损耗容差。具有对称结构的 Diamond 在损耗容差方面的表现相对优于 Reck。

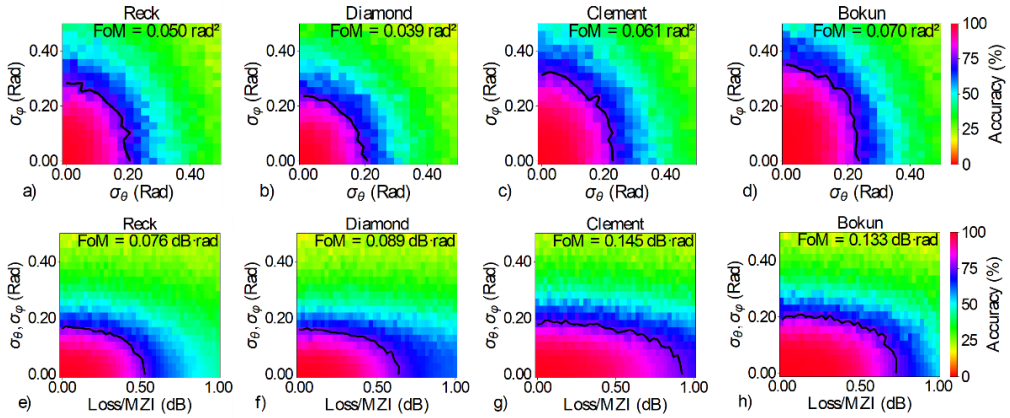

图5. 10 × 10 光学神经网络对高斯数据集的分类准确率。（a）—（d）基于 Reck、Diamond、Clements 和 Bokun 网格拓扑结构，展示了在每个马赫-曾德尔干涉仪损耗为 0 dB 时，θ 和φ 相位不确定性变化下的结果。（d）—（f）展示了分类准确率 $\sigma_\theta = \sigma_\phi$ 以及对马赫-曾德尔干涉仪损耗的耐受能力。等高线（黑线）表示性能指标，即分类准确率高于 75% 的区域。

图 6（a–d）展示了在存在 θ 和 φ 相位误差时，基于所展示的四种架构的双层 10 × 10 MNIST 分类器的分类准确率。在 MNIST 分类任务中，由于分类问题更复杂，我们使用双层网络来提高分类准确率。单层 10 × 10 分类器的仿真结果也见补充材料。与高斯数据集的情况类似，Clements 和 Bokun 对相位误差的鲁棒性更强。图 6（e–h）展示了存在相位误差和损耗时的分类准确率。具有最小光学深度的 Clements 和 Bokun 对光学损耗的鲁棒性更强，其性能指标分别为 0.081 dB·rad 和 0.049 dB·rad。然而，随着插入损耗增加，Reck 和 Diamond 的分类准确率会下降，导致性能指标降低，分别为 0.018 dB·rad 和 0.019 dB·rad。

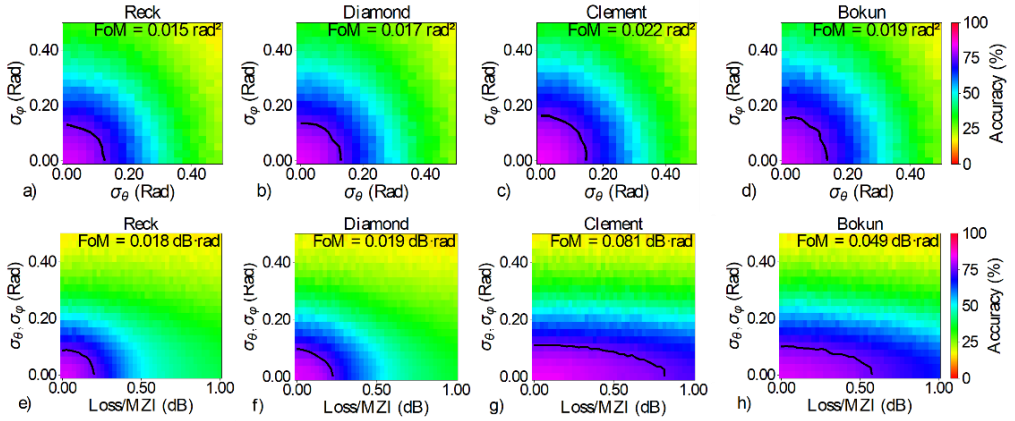

图6. MNIST 数据集上双层10 × 10 光学神经网络的分类准确率。(a)—(d)分别基于 Reck、Diamond、Clements 和 Bokun 网格拓扑结构，展示了在每个马赫-曾德尔干涉仪损耗为 0 dB 时，θ 和φ 相位不确定性变化下的分类准确率。(d)—(f)展示了 $\sigma_\theta = \sigma_\phi$ 以及对马赫-曾德尔干涉仪损耗的耐受性对应的分类准确率。等高线表示性能指标，代表分类准确率高于 75% 的区域。

为了更清楚地了解分类准确率与移相器相位设置之间的关系，我们可以通过以下公式将移相器的相位误差转换为温度误差 [34]:

$$\Delta\Theta = \frac{2\pi L}{\lambda_0}\frac{dn}{dT}\Delta T \tag{12}$$

其中，ΔΘ 是相位误差（针对θ 或φ 移相器），L 是移相器长度，λ_0 是波长，dn/dT 是移相器的热光系数，ΔT 是温度变化误差。根据公式 12 可知，对于典型的 100 μm 长移相器，其热光系数为 1.8 × 10^{-4} K^{-1}，温度变化 2.7 K 会导致 1550 nm 波长下相移变化 0.2 rad。类似的移相器需要约 43 K 的温度变化才能产生π 相移。由于移相器之间存在热串扰，在相邻移相器（相距仅几微米）的温度可能变化高达 43 K 时，将某个移相器的温度维持在 ±2 K 范围内颇具挑战。此外，波导侧壁粗糙度等制造偏差也会增加相位误差。

5. 能效讨论

一个 N × N 干涉仪网格的能耗（单位为每次运算焦耳数）可计算为 [36]:

$$E_{static}(J/Op) = \frac{n \times P_{PS}}{N^2\, VR} \tag{13}$$

其中，n 是网格中的移相器总数，P_{PS} 是移相器的功率耗散，VR 是输入向量进行乘法运算的速率。我们考虑 VR 为 10 GOp/s。尽管基于干涉仪的光处理器执行模拟向量矩阵乘法，但输入向量主要以特定速率变化，因此计算速度受输入向量到达速度的限制。图7 (a) 比较了四种不同光处理器结构的能耗：Reck、Diamond、Clements 和 Bokun。我们考虑绝缘体上硅 (SOI) 平台上热光移相器 (TOPS) 的功率耗散为 20 mW/π [25, 35]。假设相位均匀分布，TOPS 的平均功耗为 $P_\pi/2$，其中 P_π 是实现π 相移所需的功率。如图7 (a) 所示，移相器数量较少的 Reck 和 Clements 结构在静态权重矩阵情况下效率更高，而 Diamond 和 Bokun 由于移相器数量较多，能耗也更高。

式 13 所示的能耗并不包含编程阶段耗散的能量。该公式仅适用于使用静态权重矩阵的情况，此时，与计算所需时间/能量相比，编程所需的时间/能量可以忽略不计。不过，如果权重矩阵变化得更频繁，我们就必须将编程阶段的能量耗散考虑在内。假设权重矩阵以f_w的频率变化，而我们花费t_{Prog}的时间进行编程。考虑编程所耗能量后，修正后的能耗为：

$$E_{total} = \frac{\frac{1}{f_w} - t_{prog}}{\frac{1}{f_w}} E_{static} = \left(1 - f_w . t_{prog}\right) E_{static} \quad (14)$$

采用更快的编程方法以及提高移相器速度可缩短 t_{Prog}，并降低总能耗。依赖于在芯片上执行优化技术的原位编程会增加 t_{Prog}，从而增加 E_{total}。图7 (b) 比较了四种网格的 E_{total}。对于 Reck 和 Clements，我们假设采用反向传播编程方法，执行 200 次迭代 [16]。由于缺乏监测选项，异位编程（即预定义权重矩阵编程）在这些网格上不可行。对于 Diamond 和 Bokun，我们考虑采用异位编程，每 10 次迭代/马赫-曾德尔干涉仪监测一次马赫-曾德尔干涉仪状态，并重新调整其偏置。编程时间基于 TOPS 中 2.2 μs 的传输时间进行估算 [35]。每次迭代的理论光学训练时间需要考虑 TOPS 传输时间与电子延迟中的最大值 [37]。鉴于 TOPS 的响应速度较慢，我们可以忽略电子延迟。电子设备所需的功耗未计入公式 (14)。我们假设，与功耗较高的 TOPS 相比，电子设备的功耗可以忽略不计。更准确的 E_{total} 估算可以将电子能耗直接加到 E_{static}中。加入电子设备的功耗会改变图 7 (b) 的尺度，但趋势基本保持不变。从图 7 可以看出，对于 Clements，能耗从静态权重矩阵下的 450 fJ/Op 增加到权重矩阵以 2 kHz 变化时的 3750 fJ/Op。而对于 Bokun，得益于该架构提供的监测功能，能耗仅从 610 fJ/Op 略微增加至 638 fJ/Op。Diamond 网格在训练过程中同样可以节省能量；然而，如图 5–6 所示，其更长的光学深度会导致其在存在光学插入损耗和相位误差时性能下降。

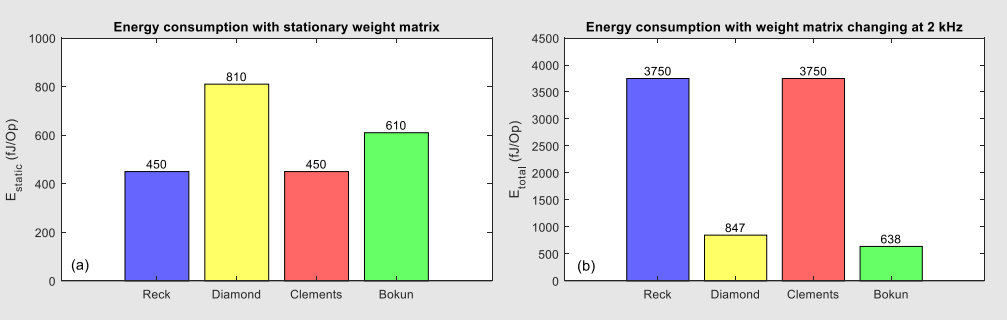

图 7. 单次操作的能耗：(a) 编程时；(b) 未编程时。

6. 总结：Bokun 网格，

本文提出的 Bokun 网格是一种拓扑排列，融合了先前用于光学处理器的两种处理器拓扑结构 Diamond 和 Clements 的特性。与 Diamond 一样，Bokun 提供了一条贯穿每个马赫-曾德尔干涉仪的对角路径，从而能够进行相位监测。借助这一监测选项，Bokun 的编程速度更快，提升了处理器的整体能效。与 Diamond 不同，Bokun 保持了最小光学深度，因此对损耗和制造工艺缺陷更具韧性。

致谢

本文 作者感谢 Simon G eoffroy-Gagnon 在本项目第一阶段于 2021 年配置 Neuroptica。 本项目的第一阶段。

参考文献

1. F. Shokraneh、M. S. Nezami 和 O. Liboiron-Ladouceur，《4 × 4 可重构 MZI 线性光学处理器的理论与实验分析》，《光波技术期刊》，第 38 卷第 6 期，第 1258–1267 页，2020 年 3 月。2. L. De Marinis、M. Cococcioni、O. Liboiron-Ladouceur、G. Contestabile、P. Castoldi 和 N. Andriolli，《光子集成可重构线性处理器作为神经网络加速器》，《应用科学》，第 11 卷第 13 期，第 6232 页，2021 年 7 月。3. R. Hamerly、A. Sludds、L. Bernstein、M. Prabhu、C. Roques-Carmes、J. Carolan、Y. Yamamoto、M. Soljacic 和 D. Englund，《迈向大规模光子神经网络加速器》，载于 2019 年 IEEE 国际电子器件会议（IEDM），第 22.8.1–22.8.4 页，2019 年。4. D. A. B. Miller，《自配置通用线性光学元件》，Photonics Res.，第 1 卷第 1 期，第 1–15 页，2013 年。5. M. A. Nahmias、T. F. de Lima、A. N. Tait、H. Peng、B. J. Shastri 和 P. R. Prucnal，《用于神经网络的光子乘累加运算》，载于 IEEE《量子电子学专题期刊》，第 26 卷第 1 期，第 1–18 页，2020 年 1–2 月，文章编号 7701518。6. C. Taballione、T. A. W. Wolterink、J. Lugani、A. Eckstein、B. A. Bell、R. Grootjans、I. Visscher、J. J. Renema、D. Geskus、C. G. H. Roeloffzen、I. A. Walmsley、P. W. H. Pinkse 和 K. Boller，《基于氮化硅波导的可编程量子光子处理器》，载于光学/激光科学前沿会议，论文 JTu3A.58，2018 年 9 月。7. N. C. Thompson、K. Greenewald、K. Lee 和 G. F. Manso，《深度学习的收益递减：改进的代价正变得难以为继》，载于《IEEE 频谱》，第 58 卷第 10 期，第 50–55 页，2021 年 10 月。8. Y. Shen、N. C. Harris、S. Skirlo、M. Prabhu、T. Baehr-Jones、M. Hochberg、X. Sun、S. Zhao、H. Larochelle、D. Englund 和 Marin Soljačić，《基于相干纳米光子电路的深度学习》，《自然·光子学》，第 11 卷，第 441–446 页，2017 年。9. Q. Cheng、J. Kwon、M. Glick、M. Bahadori、L. P. Carloni 和 K. Bergman，《面向深度学习的硅光子学协同设计》，载于 IEEE会议录，第 108 卷第 8 期，第 1261–1282 页，2020 年 8 月。10. D. Pérez、I. Gasulla、J. Capmany 和 R. A. Soref，《用于可编程光子处理器的可重构晶格网格设计》，Opt. Express，第 24 卷，第 12093–12106 页，2016 年。11. W. Bogaerts、D. Pérez、J. Capmany、D. A. B. Miller、J. Poon、D. Englund、F. Morichetti 和 A. Melloni，《可编程光子电路》，《自然》，第 586 卷，第 207–216 页，2020 年。12. N. C. Harris、J. Carolan、D. Bunandar、M. Prabhu、M. Hochberg、T. Baehr-Jones、M. L. Fanto、A. M. Smith、C. C. Tison、P. M. Alsing 和 D. Englund，《线性可编程纳米光子处理器》，《光学》，第 5 卷，第 1623 页，2018 年。13. M. Nikdast、G. Nicolescu、J. Trajkovic 和 O. Liboiron-Ladouceur，《芯片级硅光子互连：制造不均匀性的形式化研究》，载于《光波技术期刊》，第 34 卷第 16 期，第 3682–3695 页，2016 年 8 月。14. S. Banerjee、M. Nikdast 和 K. Chakrabarty，《表征存在缺陷时的相干集成光子神经网络》，载于《光波技术期刊》，2022 年，doi: 10.1109/JLT.2022.3193658。15. S. Pai、B. Bartlett、O. Solgaard 和 D. A. B. Miller，《通用酉光子器件上的矩阵优化》，Phys. Rev. Appl. 11，064044，2019 年。16. T. W. Hughes、M. Minkov、Y. Shi 和 S. Fan，《通过原位反向传播和梯度测量训练光子神经网络》，《光学》，第 5 卷第 7 期，第 864 页，2018 年。17. S. Bandyopadhyay、R. Hamerly、D. Englund，《可编程光子学的硬件纠错》，《光学》，第 8 卷第 10 期，第 1247–1255 页，2021 年。18. F. Morichetti、S. Grillanda、M. Carminati、G. Ferrari、M. Sampietro、M. J. Strain、M. Sorel 和 A. Melloni，《通过非接触式波导导电性监测实现非侵入式片上光观测》，IEEE《量子电子学专题期刊》，第 20 卷第 4 期，第 292–301 页，2014 年。19. W. R. Clements、P. C. Humphreys、B. J. Metcalf、W. S. Kolthammer 和 I. A. Walmsley，《通用多端口干涉仪的优化设计》，《光学》，第 3 卷，第 1460 页，2016 年。20. F. Shokraneh、S. Geoffroy-gagnon 和 O. Liboiron-Ladouceur，《Diamond 网格：一种耐受相位误差与损耗、用于光学神经网络的现场可编程 MZI 光学处理器》，Optics Express，第 28 卷第 16 期，第 23495–23508 页，2020 年。21. M. Reck、A. Zeilinger、H. J. Bernstein 和 P. Bertani，《任意离散酉算符的实验实现》，《物理评论快报》，第 73 卷第 1 期，第 58 页，1994 年。22. F. Shokraneh、S. Geoffroy-Gagnon 和 O. Liboiron-Laouceur，《高性能可编程 MZI 光学处理器》，载于《面向高性能计算及更广领域的硅光子学》，第 335–365 页，CRC 出版社，2021 年。23. Y. LeCun、C. Cortes、NS C. J. C. Borges，《MNIST 手写数字数据库》，http://yann.lecun.com/exdb/mnist 24. B. Yegnanarayana，《人工神经网络》。印度德里：PHI Learning 私人有限公司，2009 年。

25. A. Mirza, A. Shafiee, S. Banerjee, K. Chakrabarty, S. Pasricha 和 M. Nikdast，“制造不均匀性下基于相干MZI的纳米光子神经网络的表征与优化”，发表于 IEEE纳米技术汇刊，第 21 卷，第 763–771 页，2022。26. A. Das, H. R. Mojaver, G. Zhang 和 O. Liboiron-Ladouceur，“基于低损耗构建模块实现无损运行的可扩展SiPh-InP混合开关”，发表于 IEEE光子学技术快报，第 32 卷，第 21 期，第 1401–1404 页，2020 年 11 月。27. K. R. Mojaver 和 O. Liboiron-Ladouceur，“多横模集成硅基光学处理器中的片上光学相位监测”，发表于 IEEE《量子电子学专题期刊》，第 28 卷，第 6 期，第 1–7 页，2022 年 11 月。28. Y. Lecun, L. Bottou, Y. Bengio 和 P. Haffner，“应用于文档识别的基于梯度的学习”，IEEE会议录，第 86 卷，第 2278 页，1998。29. F. Pedregosa 等，“Scikit-learn：Python中的机器学习”，机器学习研究期刊，第 12 卷，第 2825 页，2011。30. C. J. Willmott 和 K. Matsuura，“评估平均模型性能时平均绝对误差（MAE）优于均方根误差（RMSE）的优势”，气候研究，第 30 卷，第 1 期，第 79 页，2005。31. K. Hu, Z. Zhang, X. Niu, Y. Zhang, C. Cao, F. Xiao 和 X. Gao，“利用改进的交叉熵损失函数和多尺度卷积神经网络分割彩色眼底图像中的视网膜血管”，神经计算，第 309 卷，第 179 页，2018。32. J. G. Carbonell, R. S. Michalski 和 T. M. Mitchell，“机器学习概述”，机器学习，第 1 卷，第 3–23 页，1983。33. I. A. D. Williamson, T. W. Hughes, M. Minkov, B. Bartlett, S. Pai 和 S. Fan，“适用于光学神经网络的可重编程电光非线性激活函数”，IEEE《量子电子学专题期刊》，第 26 卷，第 1 期，第 1–12 页，2020。34. S. Geoffroy-Gagnon，“Neuroptica：迈向光子神经网络的实用实现”，https://github.com/Xoreus/neuroptica，2020。35. M. Jacques, A. Samani, E. El-Fiky, D. Patel, Z. Xing 和 D. V. Plant，“SOI平台上热光相移器设计的优化与热串扰的缓解”，Opt. Express，第 27 卷，第 10456–10471 页，2019。36. M. A. Al-Qadasi, L. Chrostowski, B. J. Shastri, S. Shekhar，“硅光子加速器的扩展：挑战与机遇”，APL Photonics，第 7 卷，第 2 期，第 020902 页，2022。37. T. Zhou, L. Fang, T. Yan, J. Wu, Y. Li, J. Fan, H. Wu, X. Lin 和 Q. Dai，“衍射光学神经网络的原位光学反向传播训练”，Photonic Research，第 8 卷，第 6 期，第 940–953 页，2020。