arXiv:2301.09994v1 [physics.optics] 24 Jan 2023

具有原子非线性的光学卷积神经网络

MINGWEI YANG,[1,2*] ELIZABETH ROBERTSON,[1,2] LUISA ESGUERRA,[1,2] KURTBUSCH,[3,4] 和 JANIK WOLTERS[1,2]

[1]德国航空航天中心，光学传感器系统研究所，*Rutherfordstraße 2, 12489* 柏林，德国。[2]柏林工业大学，*Straße des 17. Juni 135, 10623* 柏林，德国。[3]柏林洪堡大学，物理研究所，理论光学与光子学工作组，*12489* 柏林，德国。[4]马克斯·玻恩研究所，*12489* 柏林，德国。[*]*mingwei.yang@dlr.de*

摘要： 模拟光学功能元件具有高度并行性、快速处理速度和低功耗，因此为实现神经形态计算机硬件提供了颇具前景的途径。例如，通过利用经过适当设计的光学装置的傅里叶变换特性，可以实现卷积神经网络的模拟光学实现。然而，如何高效地为此类神经网络实现光学非线性，仍然是一项挑战。在本研究中，我们报告了一种三层光学卷积神经网络的实现与表征；其线性部分基于 4f 成像系统，而光学非线性则通过铯原子蒸气池的吸收轮廓实现。该系统对手写数字数据集 MNIST 进行分类，准确率为 83.96%，与相应的仿真结果吻合良好。因此，我们的结果证明，在低功耗神经网络架构中利用原子非线性是可行的。

© 2023 Optica出版集团，依据 Optica开放获取出版协议

1. 引言

近年来，卷积神经网络（CNN）已成为计算机视觉任务中的关键方法，其应用范围从凝聚态物理 [1] 和粒子物理 [2] 等基础研究，延伸至自动驾驶 [3] 和癌症检测 [4]。随着卷积神经网络日益普及，人们开始高度关注其相较于更简单网络架构的能耗。具体而言，卷积神经网络所需的推理时间中，约有~ 80%用于执行卷积 [5]，因此，用于计算卷积的节能计算范式已成为活跃的研究领域。凭借其固有的并行性、实现GHz调制速度的潜力，以及较低的能耗（仅使用无源元件时），自由空间光学实现已被视为进行卷积模拟计算的一种颇具吸引力的方案 [6, 7]。事实上，在人工神经网络这一更广泛的领域中，基于衍射材料 [8],、空间光调制器（SLM） [9–13], 、环形谐振器 [14], 、马赫-曾德尔干涉仪阵列 [15, 16]以及波分复用技术 [17]的线性光学实现均已得到验证。更多信息请参阅近期的综述 [18–20]，以及 Miscuglio等人近期展示的卷积层设计 [21]。然而，如何以最高效率实现神经网络所需的非线性，仍是一个悬而未决的问题。最近，Zuo等人利用超冷气体中的电磁诱导透明，展示了一种光学非线性 ^{87}Rb原子 [22]。Ryou等人则通过在铷热蒸气中实现可饱和吸收非线性，避免了使用超冷原子所带来的额外开销

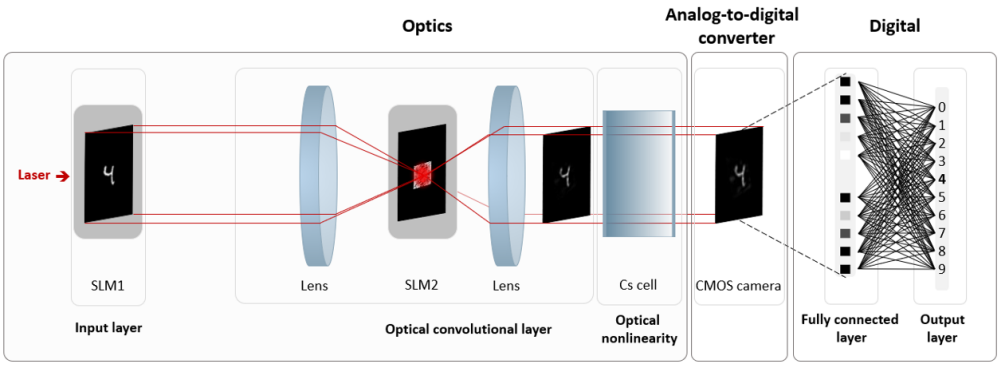

图 1. 本研究所用光学卷积网络架构的布局。

原子 [23]。实现神经形态应用所需光学非线性的其他机制包括相变材料（PCM） [17]，以及结合双光子吸收的克尔效应 [24]。

在本研究中，我们将铯原子蒸气的饱和吸收曲线形式的非线性引入基于自由空间空间光调制器的光学卷积装置中。如下文所示，该系统对手写数字数据集 MNIST [25] 的分类准确率达到 83.96%。作为多层光学神经网络实验开发中的关键部分，我们证明了铯原子蒸气能够有效提供光学非线性。铯只有一种稳定同位素，且室温下蒸气压为 $\sim 2 \cdot 10^{-6}$ Torr；铯 D 线具有优异的吸收特性，无需同位素纯化或耗能的池加热，即可产生显著的非线性。铯蒸气池的这种简便性尤为重要，因为我们开发该系统时着眼于空间应用。事实上，我们预计，具有非线性的光学神经网络有望用于卫星上的数据处理。处理复杂传感器数据的标准方法是使用人工神经网络；在地面上，这类神经网络由专用数字硬件（如图形处理器、张量流处理器等）提供支持。由于能耗、热管理和抗辐射能力方面的要求极为严苛，在轨数据处理可用的这些选项有限。然而，由于数据量巨大，数据传输以及在地面进行处理同样面临挑战。因此，能够在太空条件下运行的高性能计算机将十分理想，而光学计算机极具潜力，可弥补这一缺口，实现高能效的在轨机器学习。

2. 方法

本文展示了一种光学卷积神经网络（OCNN），其中线性运算和非线性均通过光学方式实现。我们搭建的 OCNN 包含一个输入层、一个光学卷积层、一个全连接层，后接一个输出层。卷积层后应用光学非线性 [图 1]。基于 4f 成像系统和卷积定理，OCNN 的输入与卷积核之间的卷积通过在傅里叶平面上进行逐点乘法以光学方式完成。CMOS 相机充当模数转换器。我们在计算机中实现数字全连接层，用以连接非线性激活后的特征图与输出层。我们基于实验装置对该系统进行仿真。在仿真中，OCNN 的卷积核和数字全连接层均经过预训练，并应用于实验。我们比较了仿真性能与实验结果。

我们使用 MNIST 数据集中的手写数字对系统进行训练和测试。输入

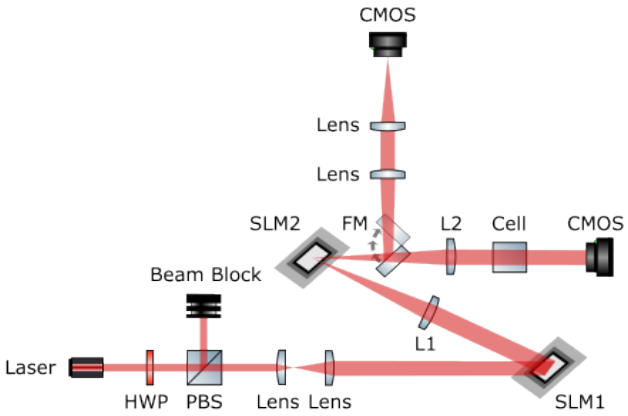

图 2. 实验装置示意图。M：反射镜，HWP：半波片，PBS：偏振分束器，L：透镜，FM：翻转镜。通过组合使用半波片和偏振分束器来控制光强。望远镜由焦距分别为 50 mm 和 100 mm 的透镜组成，可将光束扩展至直径 8 mm。

数据由基于数字微镜器件（DMD）的纯振幅空间光调制器编码为二维强度分布。这种电光转换通过控制 DMD 中的各个微镜来实现。这些反射镜可以在开启和关闭位置之间快速倾斜，并选择性地将入射光反射到光学卷积神经网络的光路中。一个微镜及其对应的存储单元构成 DMD 的一个像素。微镜阵列的大规模显示能力（1920×1080 像素）以及二值图像高达 10^4 Hz 的更新速率，原则上可实现高速复杂的多通道数据处理。

传统卷积过程由图像某个子区域与卷积核进行逐像素乘法并求和构成。卷积核会扫描整幅图像，并重复进行乘法和求和，最终得到与卷积核卷积后的图像。相比之下，光学卷积神经网络通过利用卷积定理$f(x) * h(x) = \mathrm{F}^{-1}\{\mathrm{F}[f(x)] \cdot \mathrm{F}[h(x)]\}$以及透镜的傅里叶变换性质 [26]来执行卷积过程。具体而言，输入 $f(x)$与卷积核$h(x)$的卷积（$*$）是二者傅里叶变换（$\mathrm{F}[f(x)], \mathrm{F}[h(x)]$）的逐点乘积（$\cdot$）的傅里叶逆变换（$\mathrm{F}^{-1}$）。通过用两个空间光调制器和两片透镜构建一个 4f系统，可以以光学、无源的方式实现输入的傅里叶变换、傅里叶空间中的点积，以及点积的傅里叶逆变换。因此，可以在第二片透镜的前焦平面观察到卷积后的图像。

在实验中，我们将铯蒸气池放置在卷积层之后，使卷积图案受到非线性吸收，从而在系统中引入光学非线性。CMOS 相机位于第二个透镜的前焦平面。相机拍摄图像并将其保存到计算机中。图 2 展示了实验装置的示意图。光源是配有无多普勒光谱装置的分布式反馈二极管激光器组件。波长经过精细调节并主动稳定在约 894 nm 的铯 D1线跃迁处（$6^2S_{1/2} \rightarrow 6^2P_{1/2}$）。激光随后耦合进入光纤并从中输出。使用半波片和偏振分束器调节光强。之后，两个透镜组成望远镜，将光束直径扩大

至约 8 mm。如此宽的准直光束足以覆盖 SLM1（DLP6500，德州仪器）的图案表面，其像素尺寸为 7.6 μm × 7.6 μm。计算机与 SLM1 相连并向其加载图案，因此，入射光束会被专门调制为二值化 MNIST 数据集的图像形状，并反射至光路中。对于所用的 SLM 型号，使用二进制数据时，理论上的最高图案速率可达 100 kHz。透镜（f = 250 mm，L1）与 SLM1 相距 250 mm。随后，将第二个相同的 SLM 放置在其后焦平面，使相应的傅里叶变换后的输入与所显示的傅里叶变换后的卷积核相乘。傅里叶图案的振幅调制点积随后由第二个透镜（f = 250 mm，L2）进行傅里叶逆变换，并在经 Cs 蒸气池非线性激活后，由 CMOS 相机（CS165MU- 1.6 MP 单色 CMOS 相机，Thorlabs，像素尺寸为 3.45 μm × 3.45 μm）捕获。因此，相机拍摄的图像就是输入图像与卷积核的非线性激活卷积。计算机收集所有此类处理后的图像，并将其转换为灰度值数组。每个数组都输入一个训练好的全连接层，该层通过矩阵乘法输出神经网络的预测结果。此外，还可以使用翻转镜将光束反射至第二台 CMOS 相机，以拍摄 SLM2 上显示的傅里叶图样。

如上所述，光学非线性受到了广泛关注。原子蒸气池因其无需真空且可在室温实验环境下工作的特点，成为颇具竞争力的选择。此外，由于激光是被动通过的，因此无需额外能量。输出强度 I 与输入光强 I_0 之间的关系为 [27]

$$I = I_0 \exp\left(\frac{-\mathrm{OD}_0}{1 + I_0/I_s}\right), \tag{1}$$

其中，I、I_0和 I_s 分别表示输出强度、输入光强和饱和强度。在 $I_0 = 0$ 处的光学深度为 $\mathrm{OD}_0 = N\sigma z$，其中 N 是单位体积内铯原子的数量，σ 表示相应的截面，z 为池长。当输入光强 I_0 达到饱和强度 I_s时，吸收会降低 50%。因此，输入输出关系呈现非线性形状。在实验中，相机将光强转换为由整数值构成的 8 位数组。为确保相应的仿真与实验一致，我们通过实验确定输入输出关系。为此，我们在 SLM1 上显示一个方形图案，用以表示 MNIST 数据集中亮像素的平均数量。在改变入射激光功率的同时，我们分别测量有 Cs 池和无 Cs 池时 CMOS 相机检测到的像素强度。图 3 展示了测得的非线性输入输出关系及其拟合结果。

作为一种编程语言，我们采用 Python（3.8.5 版）与 PyTorch 框架（1.7.1 版）[28] 结合进行训练。这一组合具有自动微分函数，能够在反向传播过程中很好地支持我们自定义的非线性激活函数。与传统的卷积神经网络训练过程不同，为了适配光学装置，仿真中必须考虑不同的方法和额外步骤。OCNN 模型采用包含原子非线性的三层结构。MNIST 的原始图像尺寸为 28×28，但为方便实验，输入尺寸扩大为 256×256。此外，根据卷积定理，卷积核尺寸必须与输入尺寸相同，因此卷积核尺寸也设为 256×256。为实现与铯原子的有效相互作用，输入和卷积核均进行二值化。在 OCNN 模型中，卷积源于傅里叶变换后的输入与卷积核相乘结果的傅里叶逆变换。因此，我们在 PyTorch 机器学习框架中实现了自定义卷积层 [28]。由于我们直接在复数傅里叶空间 [29], 中初始化可学习的卷积核值，因此在训练过程中无需对卷积核进行傅里叶变换。实部由随机正值组成。由于纯振幅空间光调制器

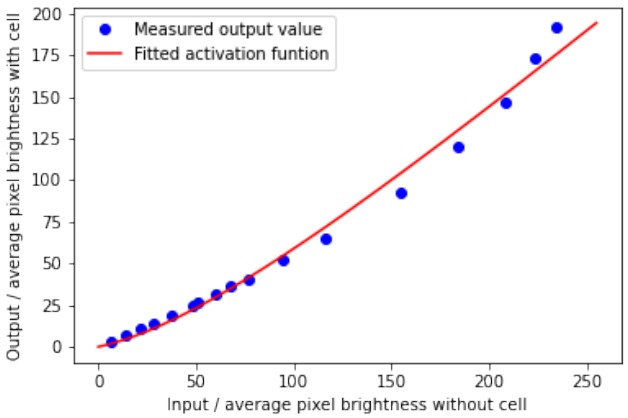

图 3. 测得的输入输出平均像素亮度及其对应的拟合曲线。将实验数据拟合到公式 (1)，得到 $OD_0 = 1.38$, $I_S = 62.31$ 像素亮度。坐标轴分别表示不含（输入）和含有（输出）蒸气池时图像的平均灰度值。

不处理相位信息，因此所有虚部值均设为零。第一步是对输入图像执行二维傅里叶变换，并在傅里叶空间中将其与卷积核相乘。尽管卷积核的实部值初始化为正值，但在训练过程中可能出现负值。因此，我们对卷积核应用修正线性单元（ReLU）函数，将负值替换为零。此外，我们确保输入光的傅里叶图样的像素位置与 SLM2 上卷积核结构的像素位置一一对应。然而，对于具有微米级像素的空间光调制器硬件而言，实验上很难实现精确匹配。因此，将 256×256 卷积核进行最大池化至 32×32，随后再放大恢复至 256×256。接下来，在傅里叶空间中执行逐元素乘法，之后进行傅里叶逆变换，得到 OCNN 在实空间中的特征图，其尺寸保持为 256×256。值得一提的是，为使光学图样以非线性方式激活，需要调节光强，使蒸气池的输入光强处于饱和强度附近的非线性区域内。特征图经过最大池化至 28×28 并展平为一维数组，然后由尺寸为 784×10 的全连接层 10×1 进一步处理特征图，并输出一个表示预测数字的数组。模型训练 5 个训练轮次，采用梯度下降优化算法，以 Softmax分类器作为损失函数，使用 Adam [30] 作为优化器，学习率为 0.001。

3. 结果

我们使用 MNIST 的 60,000 张训练图像对光学卷积神经网络进行训练，并根据 10,000 条测试数据确定相应的准确率。对于 MNIST测试集，光学卷积神经网络的仿真结果显示，采用铯吸收函数和 ReLU 函数作为非线性时，准确率分别为 92.6% 和 93.2%。与其他基于空间光调制器的光学网络系统相比，MNIST 数据集上的准确率相对较低 [11, 21], , 这是因为在光学卷积神经网络中，数据集经过了二值化处理，而且首次演示中仅使用了一个卷积层和单个卷积核，以便更好地复现训练结果。若整个网络中不使用任何非线性，准确率会降至 90.8%。作为对比，我们还训练了一个传统前馈模型（5 个训练轮次，学习率为 0.001）。该模型由一个全

连接层构成，其大小为 784×10，准确率为 80.5%。

使用单独仿真的卷积核和全连接层，分别直接测试有、无蒸气池两种情况下的实验分类准确率。图4(a)展示了仿真生成和实验采集的特征图示例。在不使用蒸气池时，光学卷积神经网络（OCNN）装置在测试数据上的准确率为70.72%。在装置中加入铯蒸气池后，性能提升至71.84%。混淆矩阵表明，实验结果在预测数字“1”“5”和“8”时存在明显误差 [图4(b)]。准确率相对较低是由实验误差造成的。为补偿这些误差，我们使用经过光学系统处理的全部10,000条测试数据训练一个映射矩阵。利用该线性映射修改全连接层，即使用实验数据重新训练该层。如混淆矩阵所示，训练后的映射矩阵显著减少了错误预测 [图4(c)]。通过这一训练，准确率

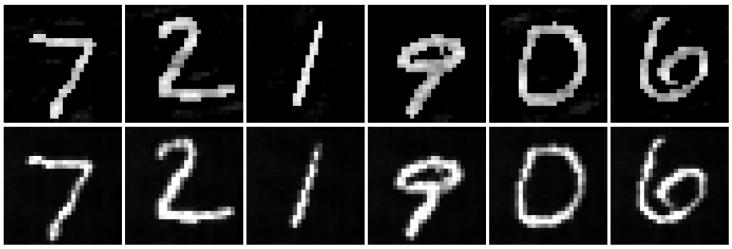

(a)

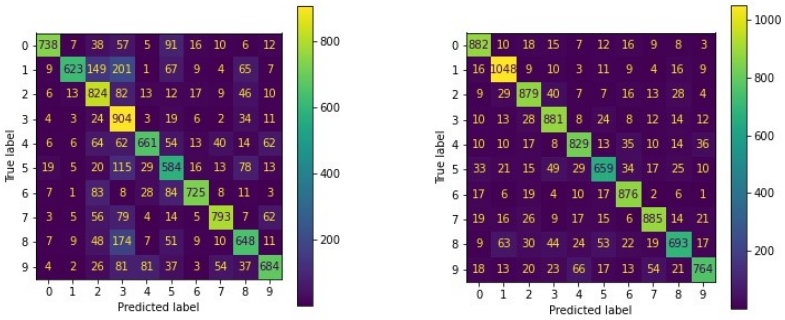

(b) (c)

图 4. 特征图和混淆矩阵的可视化。(a) 仿真（第一行）和实验（第二行）的特征图示例。(b) MNIST 分类的实验混淆矩阵。(c) 使用训练得到的映射矩阵进行 MNIST 分类的混淆矩阵。

非线性	铯蒸气	ReLU	无非线性
仿真	92.6%	93.2%	90.8%
OCNN（无映射矩阵）	71。84%	70.72%	45.59%
OCNN（带映射矩阵）	83.96%	91.9%	89。3%

表1. OCNN 预测准确率汇总。针对每种情况分别训练每个卷积核。无非线性表示除相机固有的非线性外，不添加额外的非线性。

在有、无蒸气池的情况下，准确率分别提升至83.96%和91.9%。作为比较，不添加任何额外非线性的光学卷积神经网络准确率为89.3%，这表明相机引入的非线性是有效的。表1总结了准确率结果。重新训练映射矩阵后，实验分类性能与仿真结果吻合良好。我们认为，光学系统的性能略低，原因如下：1）由于相机的动态范围和模数转换精度有限，像素值的分布无法准确匹配理论值。2）显示在SLM2上的傅里叶变换后的输入图像与卷积核图像无法完全重叠。3）光学元件的光学误差导致的畸变和像差也会影响实验结果。

4. 结论

总之，我们展示了一种具有原子非线性的光学卷积神经网络。该系统的线性部分由空间光调制器和透镜构成的4f系统组成，光学非线性则由铯蒸气池实现。该光学卷积神经网络装置在识别MNIST手写数字数据集时，预测准确率达到83.96%，与仿真结果（92.6%）基本一致。原子蒸气池的有效性表明，它在为其他拓扑结构的神经网络提供光学非线性激活函数方面具有巨大潜力。此外，它也是多层光学神经网络中极具吸引力的候选方案：多个空间光调制器和蒸气池串联时，光束可被动获得非线性输出特性，无需额外的能量来源。此外，该方案的运算复杂度也相对较低；在进一步集成时，原子蒸气池还可以由半导体可饱和吸收镜（SESAM）取代 [31]。

对于MNIST分类这一具体任务，非线性的影响有限。然而，我们的结果表明，具有非线性的光学卷积神经网络在一般机器学习问题中具有巨大潜力。从理论上讲，当图像尺寸和卷积核尺寸均为 10^6 、二值分辨率允许的最高图案速率为 10^4 Hz时，其性能可达到每秒 $10^6 \times 10^6 \times 10^4 = 10 \times 10^{15}$ 次运算（OPS）。届时，瓶颈将包括硬件的分辨率和更新速率、接口的传输速率等。作为比较，谷歌最新发布的先进 TPU v4 芯片，运算能力最高可达 $\sim 275 \cdot 10^{12}$ OPS。就光学卷积神经网络的功耗而言，激光器和相机合计仅需约 2 W，而两台空间光调制器则需要约 10 W。所用计算机的功耗约为 50 W。然而，原子非线性使实现具有全光训练 [32], 的多层光学神经网络成为可能，因此未来或可省去计算机。此外，空间光调制器的功耗主要来自切换。因此，预计在此类多层光学神经网络中提供连接性的众多准静态空间光调制器对功耗的影响可以忽略不计，功耗主要由输入空间光调制器决定。因此，我们预计，多层光学神经网络能够大幅提升计算性能，同时不会显著增加能耗，从而使具有原子非线性的光学神经网络成为传统硬件的有吸引力的替代方案。

经费支持。 本研究由德国研究联合会（DFG，德国研究基金会）资助——项目编号 445183921。E.R. 感谢亥姆霍兹—爱因斯坦柏林国际数据科学研究生院（HEIBRiDS）提供的资助。

致谢。 我们感谢 G. Gallego 就光学卷积神经网络架构所进行的讨论。

利益冲突声明。 作者声明不存在利益冲突 。

数据可用性。 本文所呈现结果的基础数据目前未公开 is 时间，但可根据合理请求向作者获取。

参考文献

1. J. Carrasquilla 和 R. G. Melko，“机器学习物质相”，Nat. Phys. **13**，431–434（2017）。2. A. Radovic、M. Williams、D. Rousseau、M. Kagan、D. Bonacorsi、A. Himmel、A. Aurisano、K. Terao 和 T. Wongjirad，“粒子物理学能量与强度前沿的机器学习”，Nature **560**，41–48（2018）。3. H. Fujiyoshi、T. Hirakawa 和 T. Yamashita，“基于深度学习的自动驾驶图像识别”，IATSS Res. **43**，244–252（2019）。4. R. Yamashita、M. Nishio、R. K. G. Do 和 K. Togashi，“卷积神经网络：概述及其在放射学中的应用”，Insights into Imaging **9**，611–629（2018）。5. X. Li、G. Zhang、H. H. Huang、Z. Wang 和 W. Zheng，“基于 GPU 的卷积神经网络性能分析”，载于 *2016* 年第 *45* 届国际并行处理会议（*ICPP*），（2016），第 67–76 页。6. H. J. Caulfield 和 S. Dolev，“未来超级计算为何需要光学”，Nat. Photonics **4**，261–263（2010）。7. H. J. Caulfield、J. Kinser 和 S. K. Rogers，“光学神经网络”，Proc. IEEE **77**，1573–1583（1989）。8. X. Lin、Y. Rivenson、N. T. Yardimci、M. Veli、Y. Luo、M. Jarrahi 和 A. Ozcan，“利用衍射深度神经网络进行全光机器学习”，Science **361**，1004–1008（2018）。9. J. Chang、V. Sitzmann、X. Dun、W. Heidrich 和 G. Wetzstein，“采用优化衍射光学器件进行图像分类的混合光电卷积神经网络”，Sci. reports **8**，1–10（2018）。10. J. Spall、X. Guo、T. D. Barrett 和 A. I. Lvovsky，“完全可重构的相干光学向量矩阵乘法”，Opt. Lett. **45**，5752–5755（2020）。11. T. Zhou、X. Lin、J. Wu、Y. Chen、H. Xie、Y. Li、J. Fan、H. Wu、L. Fang 和 Q. Dai，“利用可重构衍射处理单元实现大规模神经形态光电子计算”，Nat. Photonics **15**，367–373（2021）。12. S. A. Goorden、J. Bertolotti 和 A. P. Mosk，“使用数字微镜器件实现基于超像素的空间振幅和相位调制”，Opt. express **22**，17999–18009（2014）。13. J. Bueno、S. Maktoobi、L. Froehly、I. Fischer、M. Jacquot、L. Larger 和 D. Brunner，“大规模光子循环神经网络中的强化学习”，Optica **5**，756–760（2018）。14. A. N. Tait、M. A. Nahmias、B. J. Shastri 和 P. R. Prucnal，“广播与权重：用于可扩展光子脉冲处理的集成网络”，J. Light. Technol. **32**，3427–3439（2014）。15. Y. Shen、N. C. Harris、S. Skirlo、M. Prabhu、T. Baehr-Jones、M. Hochberg、X. Sun、S. Zhao、H. Larochelle、D. Englund 和 M. Soljačić，“利用相干纳米光子电路进行深度学习”，Nat. Photonics **11**，441–446（2017）。16. H. Zhou、Y. Zhao、Y. Wei、F. Li、J. Dong 和 X. Zhang，“一体化硅光子偏振处理器”，Nanophotonics **8**，2257–2267（2019）。17. J. Feldmann、N. Youngblood、C. D. Wright、H. Bhaskaran 和 W. H. Pernice，“具有自学习能力的全光脉冲神经突触网络”，Nature **569**，208–214（2019）。18. X. Sui、Q. Wu、J. Liu、Q. Chen 和 G. Gu，“光学神经网络综述”，IEEE Access **8**，70773–70783（2020）。19. J. Cheng、H. Zhou 和 J. Dong，“光子矩阵计算：从基础到应用”，Nanomaterials **11**（2021）。20. L. De Marinis、M. Cococcioni、P. Castoldi 和 N. Andriolli，“光子神经网络：综述”，IEEE Access **PP**，1–1（2019）。21. M. Miscuglio、Z. Hu、S. Li、J. K. George、R. Capanna、H. Dalir、P. M. Bardet、P. Gupta 和 V. J. Sorger，“大规模并行纯振幅傅里叶神经网络”，Optica **7**，1812–1819（2020）。22. Y. Zuo、B. Li、Y. Zhao、Y. Jiang、Y.-C. Chen、P. Chen、G.-B. Jo、J. Liu 和 S. Du，“具有非线性激活函数的全光神经网络”，Optica **6**，1132–1137（2019）。23. A. Ryou、J. Whitehead、M. Zhelyeznyakov、P. Anderson、C. Keskin、M. Bajcsy 和 A. Majumdar，“基于热原子非线性的自由空间光学神经网络”，Photon. Res. **9**，B128–B134（2021）。24. C. Mesaritakis、A. Kapsalis 和 D. Syvridis，“基于 InGaAsP 环形谐振器的全光储备池计算系统，用于光网络中的高速识别和光路由”，载于 量子传感与纳米光子器件 *XII*，第 9370 卷（SPIE，2015），第 608–614 页。25. Y. LeCun，“手写数字的 MNIST 数据库”，http://yann. lecun. com/exdb/mnist/（1998）。26. J. W. Goodman，“傅里叶光学导论”，《傅里叶光学导论》，第 3 版，J. W. Goodman 著。美国科罗拉多州恩格尔伍德：Roberts & Co. Publ.，2005 **1**（2005）。27. C. J. Foot，《原子物理学》，第 7 卷（OUP Oxford，2004）。28. https://pytorch.org/。29. H. Pratt、B. Williams、F. Coenen 和 Y. Zheng，“FCNN：傅里叶卷积神经网络”，载于 机器学习与知识发现数据库联合欧洲会议，（Springer，2017），第 786–798 页。30. D. P. Kingma 和 J. Ba，“Adam：一种随机优化方法”，arXiv 预印本 arXiv:1412.6980（2014）。31. A. Dejonckheere、F. Duport、A. Smerieri、L. Fang、J.-L. Oudar、M. Haelterman 和 S. Massar，“基于吸收饱和的全光储备池计算机”，Opt. express **22**，10868–10881（2014）。32. X. Guo、T. D. Barrett、Z. M. Wang 和 A. Lvovsky，“通过非线性单元对神经网络进行反向传播，实现全光训练”，Photonics Res. **9**，B71–B80（2021）。