用于通过随机散射体传输信息的交错衍射网络

Yuhang Li[1,2], Yiyang Wu[1,2], Shiqi Chen[1,2], Xilin Yang[1,2], 和 Aydogan Ozcan[*,1,2,3]1加利福尼亚大学洛杉矶分校电气与计算机工程系，美国加利福尼亚州洛杉矶，邮编 90095。[2]加利福尼亚纳米系统研究所（CNSI），加利福尼亚大学洛杉矶分校，美国加利福尼亚州洛杉矶。[3]加利福尼亚大学洛杉矶分校生物工程系，美国加利福尼亚州洛杉矶，邮编 90095。[*]通讯联系人：Aydogan Ozcan。电子邮箱：ozcan@ucla.edu

摘要

通过随机散射体传输光学信息是一项至关重要但极具挑战性的任务。在本研究中，我们提出了一种用于通过随机且未知散射体传输信息的级联衍射光学网络，该网络通过一系列物理交错嵌入散射介质中的无源结构层实现。这些交错衍射层经过优化，可在无需数字计算的情况下减轻散射过程的影响。我们根据多个物理参数对这一全光学系统的性能进行了量化评估，包括衍射处理器的深度、衍射层的物理布局以及散射介质的统计特性。为了进一步提升通过散射介质进行信息传输的性能和鲁棒性，我们还开发了一种混合（光学-数字）系统，将衍射处理器与联合训练的数字神经网络相结合。结果表明，即使输入物体信息受到未知的随机旋转、平移和缩放，该系统仍能实现更高的重建保真度。我们还利用在可见光谱范围内制备的多层衍射系统对该系统进行了实验验证，证明其能够可靠地通过随机散射层恢复信息。我们的数值和实验结果展示了交错衍射处理器架构通过体积扩散介质恢复光学信息的能力，并表明其可应用于生物医学成像、电信和遥感领域。

引言

通过体积散射介质（如生物组织或大气雾）进行成像或信息传输，长期以来一直是光学科学领域的一项重大挑战[1–6]。当光在此类复杂介质中传播时，会经历多重散射事件，使波前发生混乱，破坏空间信息，并将清晰图像转化为看似随机的散斑图样。克服这一根本性限制对于众多应用至关重要，包括深层组织成像、遥感和水下导航[1、2、7–10]。当已知散射介质的传输矩阵时，计算方法原则上可以恢复原始图像。然而，在实践中，准确且定期地测量这一不断变化的传输矩阵通常是不可行的[11]。其他方法，例如波前调控和自适应光学[1, 12–17]，能够提供强大的解决方案，但通常受限于对复杂主动反馈系统的依赖、较慢的运行速度以及有限的视场。各种新兴的计算方法也可以对生成的散斑图样进行数字处理，以恢复隐藏信息；然而，这些方法本质上受到数据采集/传输延迟和数字处理延迟，以及数字计算功耗的限制[5, 18–26]。对于亟需低延迟、低功耗信息恢复的实时应用而言，这些限制可能难以接受。

在此，我们提出了一种交错式衍射光学网络，如**图 1**所示，该网络利用一系列无源结构层，通过复杂体积散射体以全光方式传输信息。利用深度学习优化的可训练衍射层，物理交错地排列在随机散射介质中。信息恢复过程完全在光学域内进行，通过散射场在衍射处理器中的传播实现。我们通过多种数值模型验证了该框架的有效性，系统分析了关键物理参数的影响，包括衍射网络的深度、随机散射介质的统计特性以及衍射层的物理布局。数值盲测结果验证了我们方法的可行性：衍射网络能够持续恢复任意选取的未见物体信息，而这些信息此前被随机且未知的体积散射体所遮蔽。更进一步，我们设计了一种用于通过体积散射体进行光学信息传输的光学-数字混合系统，并在多种条件下评估了其鲁棒性，

包括输入物体的随机旋转、平移和缩放，证实了混合模型对于输入端此类未知变化的稳健性能。除数值分析外，我们还利用为可见光制造的多层衍射系统对该方法进行了实验验证，成功实现了通过随机散射体的信息恢复。我们相信，这些用于通过散射介质进行信息传输的交错衍射网络有望在生物医学成像、遥感和自由空间通信等领域找到多种应用。

结果

使用交错衍射网络通过散射体成像

图1a展示了交错式衍射光学网络的示意图。该网络经过训练，可重建被体积散射体遮挡的物体。为模拟随机体积散射介质，我们将 M 个具有随机且彼此独立的相位分布的薄散射体级联排列，并使其间隔固定的轴向距离。在每个散射体平面之间，我们插入了 K 个衍射层，旨在随着散射波前在散射介质中传播，逐步对其进行校正。在训练阶段，我们使用手写数字作为振幅输入物体[27],，光场经过散射体及后续衍射层传播后，在输出平面形成强度图样。为增强网络通过复杂体积介质成像时的泛化能力，我们在每个训练轮次中引入了 n 个随机散射体（**图1b**）。我们使用角谱法对自由空间传播进行数值建模，并据此设计和训练衍射网络；详见**方法**部分。通过误差反向传播迭代更新每个衍射层中特征的相位值，以最大化网络输出强度与真实目标图像之间的皮尔逊相关系数（PCC）（详情请参见**方法** 部分）。经过100个训练轮次后，训练结束；在此期间，交错衍射处理器接触了总计 $N = 100n$ 种不同的体积散射体实现。完成这次训练后，交错衍射处理器的参数即固定，并接受盲测。在测试阶段，我们使用MNIST测试集中的此前未见过的输入物体评估网络性能，这些物体被全新且此前未见过的随机体积散射体遮挡。**图1c**展示了衍射层优化后的相位分布。训练后的衍射层呈现复杂图案，包括密集排列的类微透镜相位结构，这些结构有助于

成像；周围的空间相位特征则通过将能量耦合到输出视场之外，帮助减轻随机散射体引起的空间失真[28]。这些优化层共同发挥作用，解扰被随机散射体扭曲的光，从而帮助在输出平面形成更清晰的输入物体图像。

图2比较了两种从头开始训练、用于透过体积散射体成像的衍射架构：一种是交错衍射网络，将衍射层置于散射体积内、每个扩散器单元之后（**图2a**）；另一种是非交错基线设计，将所有衍射层都置于散射体积之外（**图2b**）。**图2c**展示了不同手写数字和光栅目标的代表性测试结果。值得注意的是，训练过程中并未包含这类光栅目标；它们作为外部测试集，用于展示网络对新型物体的泛化能力。对于未见过的／新的随机散射体，交错架构始终能够保留物体的整体结构，生成更清晰的数字笔画，并使光栅之间的分离更加清楚（更多结果见**影片S1**）。相比之下，将衍射层全部集中放置在随机散射体积之外，会导致明显的散斑图样和结构损失。作为参考，在没有任何衍射层的情况下透过体积散射体传播，会造成更严重的散斑畸变，如**图2c**所示。这些结果表明，将优化的衍射层分布在散射体积内，可在每个随机散射体之后逐步校正畸变，并显著提高系统对随机散射体变化的鲁棒性。

优化衍射层数量的影响

我们研究了衍射网络深度对通过体积扩散器的成像性能的影响，方法是改变每个扩散器单元内的衍射层数量K，同时保持随机散射体之间的轴向距离恒定（**图3a**）。**图3b**所示的定量结果表明，对于已知和未见/新的测试散射体，图像重建保真度均随着K 从2层增加到5层衍射层而单调提高；此处，已知扩散器是指训练过程中遇到的扩散器，而未见散射体则是此前从未见过的。在新的体积扩散器上取得的可比性能证明了衍射网络的泛化能力，表明它学习了支配光在散射介质中传播的底层物理原理，而不是

仅仅记忆特定示例。此外，当K 从2增加到3时，观察到最显著的性能提升。这些发现也在**图3c**中得到可视化。在没有衍射层的情况下，输出是无法识别的散斑图样。当每个单元有两层衍射层时，数字的整体形状开始显现，尽管存在一定模糊。进一步将每个扩散器单元的衍射层数量增加到$K = 4$ 和$K = 5$ 时，增强了更精细的特征，如笔画连续性和对比度，从而证实了全光学重建数据中所见的改进。总体而言，这些结果表明，增加模型容量[29,30] 增强了网络对体积随机散射的鲁棒性。

扩散器深度与统计特性的影响

衍射处理器的性能也取决于随机散射体的特性。我们从两个方面评估了这种关系：随机散射介质的整体厚度（用扩散器单元的数量 M 表示），以及扩散器的内部统计特性（用相位相关长度 C 定义）。首先，我们通过改变扩散器单元数量 M，评估网络性能随散射厚度增加的变化，如**图4a**所示。**图4b**所示的定量结果揭示了一个权衡：体积散射体越厚，造成的畸变越严重；而衍射处理器越深，图像重建能力则越强。起初，随着 M 从 2 增至 3，重建性能略有提升，这可能是因为体积内优化的衍射层总数相应增加。然而，随着 M 进一步增大，图像重建保真度有所下降。这表明，超过某一临界点后，额外随机散射引入的畸变将超过新增衍射层的校正能力。**图4c**也展示了这一趋势，其中列出了扩散器单元数量不同时具有代表性的输出图像。衍射处理器能够通过 $M = 1$ 或 2 个单元成功重建输入测试数字；但当单元数量增加到 3 个和 4 个时，图像质量逐渐下降，噪声增多且特征丢失。不含衍射层时的输出也证实了这一挑战不断加剧：对于 $M = 1$，仍能辨认出数字的大致轮廓；而对于 $M \geq 2$，输出则变成了无法辨认的散斑图样。

接下来，我们研究了散射体的空间特性对光学图像重建性能的影响。我们针对相关长度各异的散射体训练并测试了衍射网络架构（$M =$

$2, K = 2$），C，如**图 5a**所示。参数C 近似定义了散射特征的平均“颗粒尺寸”；相关长度越大，散射效应越弱，图像重建问题也越简单（详情请参见**方法**部分）。**图 5b**证实了这一关系：随着散射器相关长度从 7.5 λ 增加至 15 λ，输出图像的皮尔逊相关系数单调上升。对于已知和新出现/未见过的随机散射体，重建保真度均有一致提升。我们还通过移除随机散射体，测试了使用不同相关长度训练的衍射网络，如**图 5b**中的绿色曲线所示。值得注意的是，使用较弱散射体（较大的 C）训练的模型在这项测试中也取得了更高的性能。这表明优化过程中存在一种权衡：体积散射较弱时，衍射网络的更多自由度可用于主要的图像重建任务；而散射较强时，则必须投入更多能力来滤除失真。**图 5c**展示了部分测试对象重建结果。当相关长度较小（例如 7.5λ）时，尽管体积散射较强，我们的系统仍能重建数字的基本形状，只是带有一些噪声。相比之下，相关长度较大时（例如 10 λ 和 12.5 λ），衍射处理器生成的目标对象图像明显更清晰、更准确。

连续衍射层之间的轴向间隔的影响

我们还研究了相邻平面（包括衍射层和散射体）之间的轴向间隔 d 对网络整体性能的影响。我们采用**图 6a**所示的架构，训练并测试了多个层间距离各不相同的衍射处理器。**图 6b**中绘制的定量结果表明，图像重建保真度对这一距离较为敏感。对于已知和新的随机散射体，输出皮尔逊相关系数在间隔最小时（6.7λ）达到最高；在中等间隔下显著下降，而间隔超过 20λ 后则趋于平稳。**图 6c**所示的图像重建结果直观地印证了这一性能趋势。最紧凑网络（d = 6.7λ）生成的图像最清晰，图像质量也最高。随着各层间距增大，输出图像中的噪声逐渐增多，结构细节也有所丢失，这与定量结果中最初出现的性能下降一致。

这些发现表明，优化层之间具有更大有效数值孔径的紧凑型衍射网络，能更有效地操控光波前，从而校正体积散射介质造成的随机失真。

Hybrid 用于增强图像重建性能的光学-数字系统

为进一步提升通过体积扩散器进行信息传输的保真度，尤其是针对强散射介质，我们还实现了一种光学-数字混合系统。如**图7a**中的示意图所示，该架构利用全光衍射处理器对散射光进行模拟预处理，从而在相机平面形成中间图像。所得预处理图像随后被输入联合训练的数字神经网络，以完成最终的数字处理与图像重建步骤。衍射层与数字网络均通过端到端反向传播进行协同优化，以最大化最终重建输出与目标信息之间的皮尔逊相关系数。

为证明这种混合方法的有效性，我们考虑了一种具有挑战性的配置，其中包含$M = 4$ 随机扩散器单元；在该配置下，仅靠全光衍射方案无法在其输出平面产生清晰图像。如**图7b**和 **Movie S2**所示，结果凸显了混合方法相对于全光衍射设计的优势。对于衍射光学网络与数字神经网络联合训练的混合模型，相机平面处的全光输出$O_{Optical}$ 显得模糊；然而，最终的混合输出$O_{Digital}$ 明显更为清晰，表明数字网络对经光学处理的信号具有强大的去噪能力。

此外，我们通过对从未见过的输入数字施加随机旋转、平移和缩放，评估了系统对输入扰动的鲁棒性。即使面对这些“攻击”输入，混合系统仍能成功恢复核心信息，并生成高保真图像重建；另请参见**Movie S2**。模拟处理与数字处理之间的协同作用，构建了一条鲁棒且高效的通道，可用于在复杂散射介质中传输信息。

交错衍射网络的实验验证

为了通过实验验证用于借助随机散射体进行信息传输的交错衍射网络，我们实现并训练了一个由两个随机相位扩散器交错连接的双层衍射系统；参见**图 8a**。在计算机仿真训练阶段，我们使用数千个不同的随机相位扩散器，并以 MNIST 手写数字图像作为训练数据集[27]，对光学衍射层和数字神经网络后端进行联合优化。在这一混合训练框架中，输入数字图像被表示为取值范围为 $[0,\pi]$ 的纯相位物体，而相应的目标图像则被归一化至 [0,1]。因此，该混合系统学习到了一种相位到强度变换，这是一种非线性变换。收敛后，整个结构（包括经过优化的衍射相位分布以及新的随机相位扩散器，后者在训练阶段从未使用过）通过双光子聚合光刻技术制备而成，形成整体式四层堆叠结构（详情请参见**方法**）。

实验装置和三维制造的多层结构如**图8b**所示，其中包括光学系统的照片和交错层的示意图。制造出的结构及其对应的数值相位分布见**图8c**，该图还展示了随机相位扩散器和优化的衍射层的显微图像，以及它们的数值相位分布。盲测期间，输入物体测试图案显示在空间光调制器（SLM）上，并通过光学方式投射到制造好的四层结构上。相机捕获由此产生的输出强度分布。制造好的堆栈由两个优化的衍射层组成，其间交错放置着两个随机生成的新相位扩散器，这些扩散器在训练期间从未使用过。整个实验过程中，结构在物理上保持固定，并使用此前未见过的输入物体评估泛化能力。在这些固定的散射条件下，共采集了2000次实验测量结果。**图8d**直接比较了数值预测结果与输出端CMOS图像传感器采集的实验图像。尽管制造和对准过程十分仔细，但由于模型不匹配、制造公差和各种缺陷，仿真与实验结果之间仍存在差异。将预训练数字后端直接应用于实验测量结果而不进行进一步适配时，重建质量明显下降，凸显了数值训练与物理实现之间的差距。这种性能下降表明有必要进行迁移学习。因此，将2000次实验测量结果划分为训练子集和测试子集，并设置不同的测试集

划分比例；测试集划分比例表示从完整数据集中留出用于测试且不参与参数更新的数据所占比例，其余数据则用于训练。对于每种划分配置，数字后端均使用相应的训练子集进行原位迁移学习，而光学衍射层在物理上保持不变。随后，在留出的测试集上评估重建性能，以量化泛化能力。

图8e展示了测试损失随测试集划分比例的变化。在所有测试的划分比例（0.05 – 0.9）下，交错衍射网络在不同数量的原位训练数据条件下，始终实现了较低的测试损失和稳定的成像性能。随着原位训练数据量减少，测试损失逐渐增加，反映出数字后端利用有限数据适应实验偏差的能力有所减弱。**图8f**所示的重建示例进一步证实了这些发现。在不同划分比例下，重建图像均与目标图像高度吻合，并保留了完整的物体结构。训练子集变小时，重建质量逐渐下降，恢复图像中出现了更加明显的结构失真。总之，这些结果通过实验验证了优化的交错衍射层的有效性，它们能够为随机散射过程提供结构化补偿。

讨论

在本工作中，我们提出了用于通过随机体积散射介质实现高保真信息传输的交错衍射处理器。通过在随机散射介质中交错布置优化的衍射层，该无源全光处理器能够学习抵消多重散射的影响，并恢复隐藏信息。这种交错架构使光学网络能够在传播过程中逐步校正光波前，而不是试图在输出平面对高度畸变的场进行数字重建。此外，我们还针对不同物理参数系统地表征了该系统的性能与局限性，包括网络深度、各层之间的物理间距，以及随机散射介质的统计特性。我们进一步证明，通过将全光处理器与联合训练的数字神经网络集成，系统的性能以及对输入变化的鲁棒性能够得到显著提升，从而形成一种强大的混合信息恢复系统。此外，除数值验证外，我们还利用一个

已制造的多层衍射系统对这一概念进行了实验验证。测量结果证实，在复杂的随机散射条件下能够实现可靠的信息恢复。这些实验结果证实了在散射介质中采用交错优化衍射层、实现结构化光学补偿的物理可行性。

尽管所提出的框架展现了通过体积扩散器进行成像的鲁棒性，但仍面临若干挑战。制造具有精确轴向对准的多层衍射系统存在实际困难，尤其是交错层数增加时。可通过疫苗策略缓解这些对准挑战，即在训练过程中注入失准扰动，帮助系统增强对这类误差的鲁棒性[31]。此外，将该方法扩展到更大的孔径或宽带运行也是一项挑战。可将这些光谱效应明确纳入训练损失函数，使网络能够针对多个波长联合优化性能[32,33]。在计算方面，使用更真实的散射模型或实验测得的散射体进行训练，或可进一步提升模型在实际场景中的泛化能力，但优化复杂度也会相应增加。

展望未来，所提出的交错衍射处理器框架有望应用于紧凑型成像系统、内窥成像或组织穿透成像，以及动态散射介质中的视觉成像。该框架还可扩展至多光谱或偏振敏感模态，或与混合架构结合，实现实时、节能的光学信息处理。

方法

混合光电系统的神经网络架构

我们为**图7-8**中所报告的光学-数字混合系统采用了一种紧凑的三级U-Net架构，该架构具有对称的编码器–解码器结构，并在对应层之间设有跳跃连接。每个卷积块由两个3×3 卷积层及随后的ReLU激活函数组成，同时分别使用2×2 最大池化和转置卷积进行下采样和上采样。在中间块中应用了Dropout（$p = 0.2$），以提高泛化能力。编码器逐步增加了

特征通道数（2、4、8），同时在每个阶段将空间分辨率降低至原来的二分之一。瓶颈块将特征维度扩展至16个通道，以捕获全局上下文。解码器与编码器相对应，通过学习得到的上采样恢复空间分辨率，并拼接跳跃特征以恢复精细细节。最后经过一个1×1 卷积及Sigmoid 激活，生成单通道输出 $O_{Digital}$。该轻量级网络包含约7.6k个可训练参数。所有权重均使用Kaiming 初始化方法进行初始化。

训练目标与评估

交错衍射网络经过训练，以在传感器平面重建目标图像I_{target}。损失函数定义为：

$$Loss\left(O, I_{target}\right) = 1 - \mathrm{PCC}\left(O, I_{target}\right)$$

其中皮尔逊相关系数的计算方式为：

$$\mathrm{PCC}\left(O, I_{target}\right) = \frac{\sum\left(O(x,y) - \overline{O}\right) \cdot \left(I_{target}(x,y) - \overline{I_{target}}\right)}{\sqrt{\sum\left(O(x,y) - \overline{O}\right)^2 \cdot \left(I_{target}(x,y) - \overline{I_{target}}\right)^2}}$$

其中$\overline{O}$ 和$\overline{I_{target}}$ 分别为输出O 与目标图像I_{target}的平均强度值。

训练实现

采用波长为$\lambda = 0.75\ mm$的相干单色照明，对含体积扩散器的交错衍射光学网络进行了数值模拟。该系统由K 个可训练衍射层与M 个随机相位扩散器交错组成，相邻平面之间的轴向间距设为d。在训练过程中，输入图像为灰度图像，并在送入网络之前被调整为 160×160 像素（$64\lambda \times 64\lambda$），随后按照前文所述的波传播步骤进行处理。每个衍射层由240×240 个可训练相位特征（$96\lambda \times 96\lambda$）组成，横向特征尺寸为~$0.5\lambda$。传感器平面的中心$160 \times 160$ 区域（$64\lambda \times 64\lambda$）用于损失函数计算。

混合交错衍射系统的实验训练是在$\lambda = 635\ \mathrm{nm}$ 波长的相干单色照明下进行的。制备的四层堆叠结构由两个优化的衍射层和两个随机相位扩散器交错组成（在

训练过程中从未使用）。每个可训练的衍射层由512 × 512 个相位特征组成，横向像素尺寸为4 μm。

在数据采集过程中，将尺寸为 256 × 256 的输入物体图样显示在空间光调制器（Pluto，8 μm 像素间距，HOLOEYE Photonics AG）上，并投射到制备好的结构上。输入相位图像编码在 $[0,\pi]$范围内，相应的目标图像强度图样则归一化至 [0,1]。随后，使用 CMOS相机在传感器平面记录得到的输出强度分布。由于实验任务是将仅含相位的输入物体映射为目标强度图像，因此该系统实现了相位到强度变换，对应一种固有的非线性映射。实验共使用 2,000 个输入物体图样，在固定散射条件下采集得到一个实验数据集。将采集到的强度图像裁剪至 400 × 400 像素后，再输入数字神经网络后端。对于每种训练集—测试集划分配置，数字后端均从数值预训练模型初始化，然后利用相应实验数据集的训练子集进一步优化，即采用原位迁移学习，而非从头训练；与此同时，光学衍射层保持物理固定。损失函数定义为数字重建的输出图像与相应真实目标图像之间的 $1 - PCC$ 。

交错网络使用 Python (v3.10.6) 和 PyTorch (v1.12, Meta Platforms Inc.) 进行训练，采用 Adam优化器，学习率为 1×10^{-3}。对于混合模型，除 U-Net 的训练学习率设为 1×10^{-4} 外，其余设置均相同。批量大小设为 32，训练进行了 100 训练轮次和 $n = 150$。衍射层的相位值初始化为零。训练在 GeForce GTX 3090 GPU（英伟达公司）上进行。每次训练通常需要 ~6 小时（数值模型）和 ~20 小时（实验模型），具体取决于网络深度和扩散器单元的数量。

纳米加工工艺

交错衍射网络和随机相位扩散器采用双光子聚合光刻（Quantum X shape, Nanoscribe GmbH）制造。制造流程包括精密打印和后续化学处理。衍射层在制造前被量化为 4 位相位深度。使用商用光刻胶 IP-DIP2（Nanoscribe GmbH）和 63 × 物镜（$NA = 1.4$），实现了 ~2 μm 的横向特征尺寸。

每个衍射层的打印时间约为 8 小时。

所有衍射层和随机相位扩散器均依次打印在同一片2英寸晶圆（2" JGS2熔融石英晶圆，MSE Supplies）上。制造过程首先在2英寸晶圆表面打印锚定菲涅尔透镜，以提供机械支撑和对准参考。每打印完一层或一个相位扩散器后，物镜沿横向平移，使多余树脂从打印结构上流走。结构周围的残留树脂用棉签小心去除，同时保持基底夹具固定，以维持位置精度。

为构建多层结构，由一块厚度为170 μm的玻璃盖玻片制备了两个薄垫片，并在其两面涂覆环氧粘合剂。这些垫片对称放置在打印结构的左右两侧，作为后续层的垂直支撑。随后在上方放置一片新的盖玻片，以确定层间间距。每个粘合界面贡献~$30-50\ \mu m$ 的厚度。每个衍射层与其相邻相位扩散器之间的总轴向间隔计算为（$40\ \mu m \times 2 + 170\ \mu m \times 2$），其中计入了环氧粘合剂层、玻璃垫片厚度以及打印各层所用的盖玻片。考虑到盖玻片玻璃的折射率（$n \approx 1.5$），层间有效光程估计为$40\mu m\ \times 2 + 170\ \mu m + 1.5 \times 170\ \mu m$。该距离被纳入数值训练模型，以确保仿真与制造之间的一致性。垫片放置完成后，加入新鲜树脂，并将系统返回至先前记录的横向坐标。在开始下一打印周期之前，沿z轴执行自动对焦。该过程重复三次，以完成带有随机相位扩散器的四层交错衍射结构。

制备完成后，样品依次经过一系列溶剂浴，以去除未聚合树脂并确保结构完整性。样品首先浸入丙二醇单甲醚乙酸酯（PGMEA）中5–10分钟，以溶解残留光刻胶。随后依次转入异丙醇（IPA）浴中5分钟，以及Novec 7100工程流体浴（甲氧基九氟丁烷，HFE-7100）中再浸泡5分钟。最终溶剂可实现快速干燥，无需氮气吹干，从而将多层结构所受的机械应力降至最低。

补充信息：交错衍射网络的前向模型通过

体积扩散器

参考文献

1. Ji, N., Milkie, D. E. & Betzig, E. 利用瞳孔分割自适应光学，在生物组织中实现高分辨率成像。自然方法 **7**, 141–147 (2010). 2. Jang, M. 等 散斑去相关与基于光学相位共轭 (OPC) 的浑浊抑制在动态散射介质中的关系：活体小鼠皮肤研究。《生物医学光学快报》 **6**, 72 (2015). 3. Tan, R. T. 根据单幅图像判断恶劣天气下的能见度。载于*2008*年*IEEE*计算机视觉与模式识别会议 1–8 (2008). doi:10.1109/CVPR.2008.4587643. 4. Ntziachristos, V. 超越显微镜：生物学中的光学成像前沿。自然方法**7**, 603–614 (2010). 5. Bertolotti, J. 等 通过不透明散射层进行非侵入式成像。自然 **491**, 232–234 (2012). 6. Horisaki, R., Okamoto, Y. & Tanida, J. 通过散射介质进行单次曝光非侵入式三维成像。《光学快报》，*OL* **44**, 4032–4035 (2019). 7. LOPES, A., NEZRY, E., TOUZI, R. & LAUR, H. 合成孔径雷达图像中的结构检测与统计自适应散斑滤波。国际遥感杂志 **14**, 1735–1758 (1993). 8. Bucher, E. A. 用于穿越厚云层通信的光脉冲传播计算机模拟。《应用光学》，*AO* **12**, 2391–2400 (1973). 9. Jaffe, J. S., Moore, K. D., McLean, J. & Strand, M. P. 水下光学成像：现状与展望。海洋学 **14**, 64–75 (2015). 10. Schettini, R. & Corchs, S. 水下图像处理：复原与图像增强方法的最新进展。*EURASIP*高级信号处理期刊 **2010**, 1–14 (2010). 11. Kim, M., Choi, W., Choi, Y., Yoon, C. & Choi, W. 散射介质的传输矩阵 an

d

其在生物光子学中的应用。《光学快递》 **23**, 12648 (2015).

12. Wang, K. 等 针对散射组织中高分辨率活体成像的直接波前传感。《自然-通讯》 **6**, 7276 (2015). 13. Li, J. 等 在宽场显微术中使用扩展源波前传感器的共轭自适应光学。*Optica, OPTICA* **2**, 682–688 (2015). 14. Vellekoop, I. M. & Mosk, A. P. 通过不透明强散射介质聚焦相干光。《光学快报》, *OL* **32**, 2309–2311 (2007). 15. Horstmeyer, R., Ruan, H. & Yang, C. 借助引导星辅助波前调控方法，将光聚焦到生物组织中。《自然-光子学》 **9**, 563–571 (2015). 16. Nixon, M. 等 通过全光反馈实时调控散射介质中的波前。《自然-光子学》 **7**, 919–924 (2013). 17. Yang, J. 等 基于多像素编码数字微镜器件的快速波前整形实现抗散射光聚焦。《光：科学与应用》 **10**, 149 (2021). 18. Feng, S., Kane, C., Lee, P. A. & Stone, A. D. 无序介质中相干波传输的相关性与涨落。《物理评论快报》 **61**, 834–837 (1988). 19. Edrei, E. & Scarcelli, G. 基于记忆效应的反卷积显微术，实现通过散射介质的超分辨率成像。《科学报告》 **6**, 33558 (2016). 20. He, H., Guan, Y. & Zhou, J. 通过与已知物体进行相关处理，实现薄浑浊层后的图像复原。《光学快递》, *OE* **21**, 12539–12545 (2013). 21. Qiao, H. 等 用于层析相位显微术的基于 GPU 的深度卷积神经网络，采用 l1 拟合与正则化。《生物医学光学杂志》 **23**, 1–7 (2018). 22. Barbastathis, G., Ozcan, A. & Situ, G. 论深度学习在计算成像中的应用。*Optica, OPTICA* **6**, 921–943 (2019). 23. Li, S., Deng, M., Lee, J., Sinha, A. & Barbastathis, G. 使用密集连接卷积网络透过玻璃扩散片成像。*Optica* **5**, 803 (2018). 24. Jiang, S., Guo, K., Liao, J. & Zheng, G. 通过神经网络建模和 TensorFlow 求解傅里叶叠层成像问题。《生物医学光学快报》, *BOE* **9**, 3306–3319 (2018).

25. Li, Y.、Xue, Y.与Tian, L. 深度散斑相关：一种面向透过散射介质实现可扩展成像的深度学习方法。*Optica* **5**，1181（2018）。26. Yang, M. 等 深度混合散射图像学习。*J. Phys. D: Appl. Phys.* **52**，115105（2019）。27. Deng, L. 面向机器学习研究的MNIST手写数字图像数据库[网络精选]。*IEEE*信号处理杂志 **29**，141–142（2012）。28. Luo, Y. 等 无需计算机的计算成像：以光速看穿随机散射体。*eLight* **2**，4（2022）。29. Kulce, O.、Mengu, D.、Rivenson, Y.与Ozcan, A. 衍射表面的全光信息处理能力。*Light Sci Appl* **10**，25（2021）。30. Kulce, O.、Mengu, D.、Rivenson, Y.与Ozcan, A. 利用衍射表面实现任意线性变换的全光合成。*Light Sci Appl* **10**，196（2021）。31. Mengu, D. 等 抗错位衍射光学网络。纳米光子学 **9**，4207–4219（2020）。32. Shen, C.-Y. 等 利用多层衍射光学处理器的晶圆级纳米制造实现宽带单向可见光成像。*Light Sci Appl* **14**，267（2025）。33. Shen, C.-Y. 等 采用波长复用衍射的多平面定量相位成像

e

光学处理器。*AP* **6**，056003（2024）。34. Lin, X. 等. 基于衍射深度神经网络的全光机器学习。*Science* **361**，1004–1008（2018）。

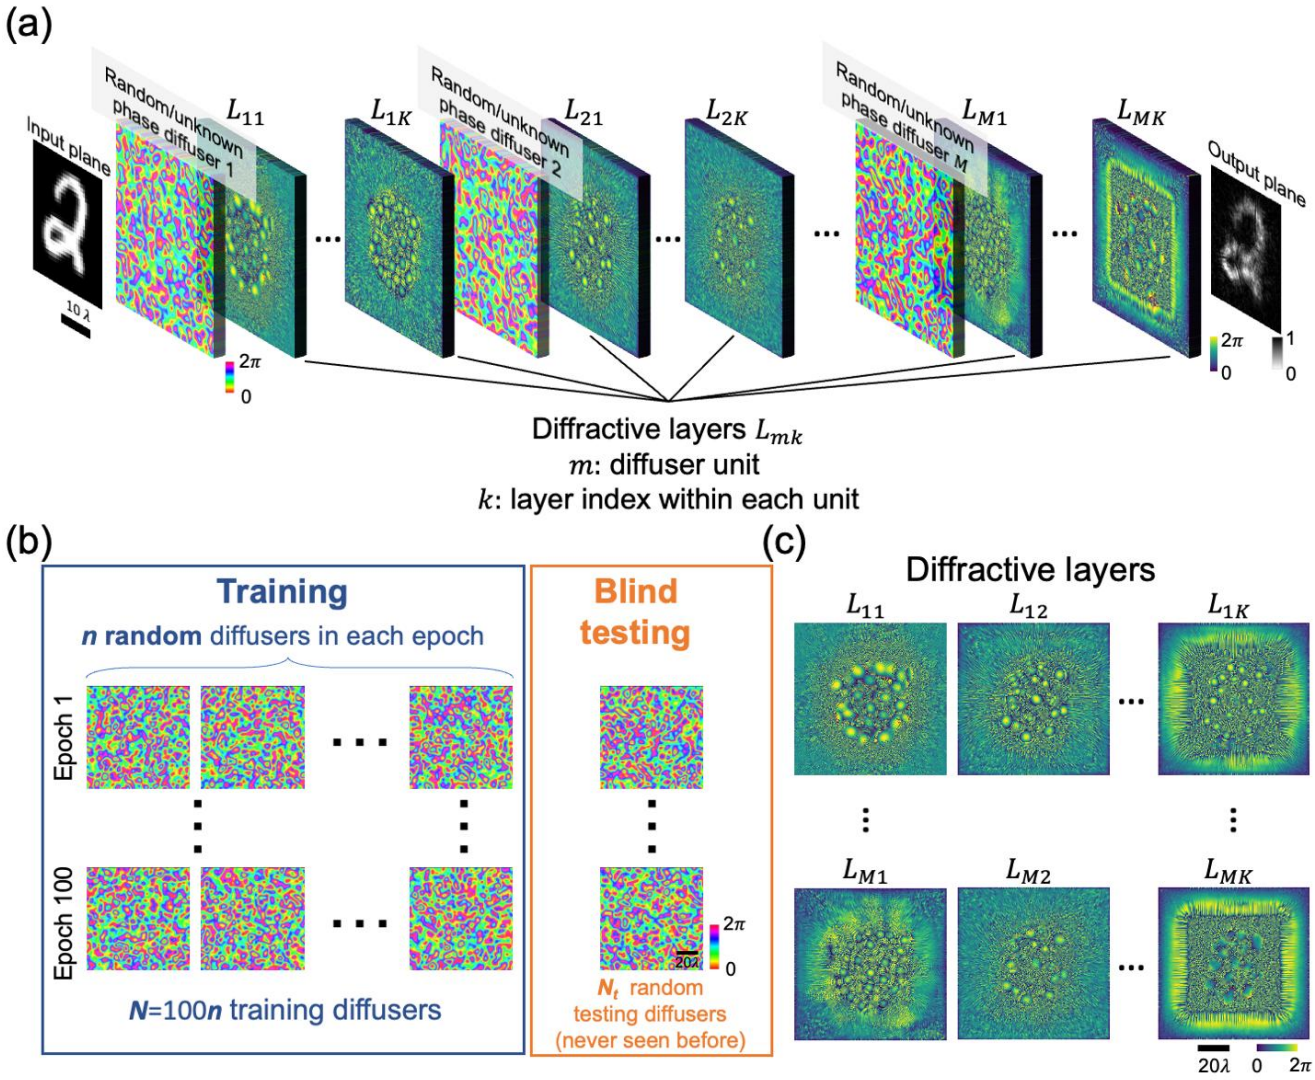

图 1. 用于穿过体积散射体成像的交错衍射网络的设计与训练。 **(a)** 衍射成像系统的概念示意图。体积散射体会扰乱来自输入物体的光波前，并由 M 个彼此独立且未知的随机散射平面建模。在各平面之间放置 K 个可训练衍射层，以逐步校正失真。**(b)** 所提出的交错衍射网络的训练与盲测策略。**(c)** 衍射层优化后的相位分布。

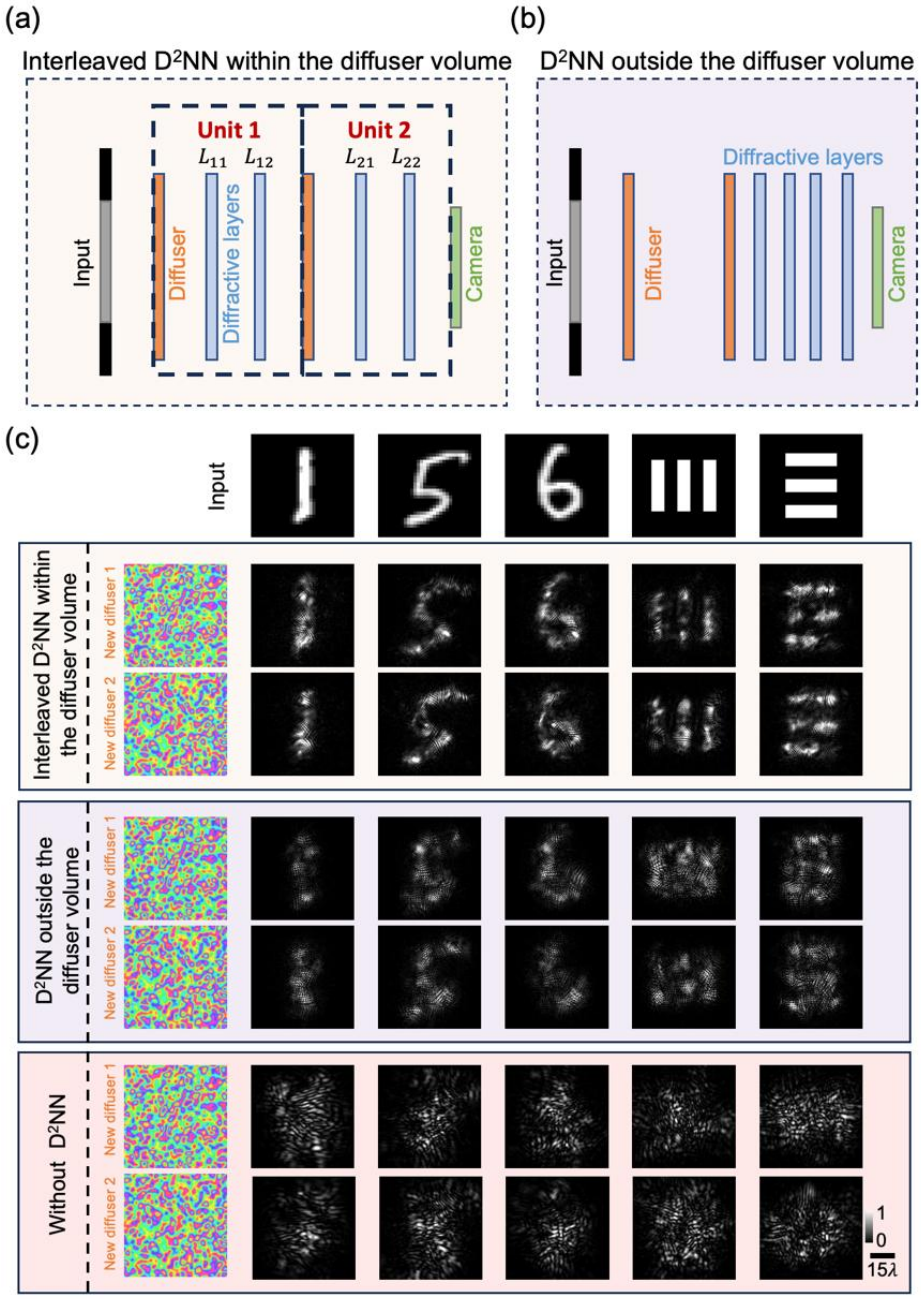

图2. 交错与非交错衍射网络架构在通过体积随机扩散器成像时的比较。 散射体积内的**(a)**交错衍射网络（D²NN）示意图，以及散射体积外的**(b)**衍射网络示意图。**(c)**通过新的随机散射体对手写数字和光栅目标进行成像后得到的全光学重建结果，比较交错、非交错以及不基于衍射网络的模型的性能。

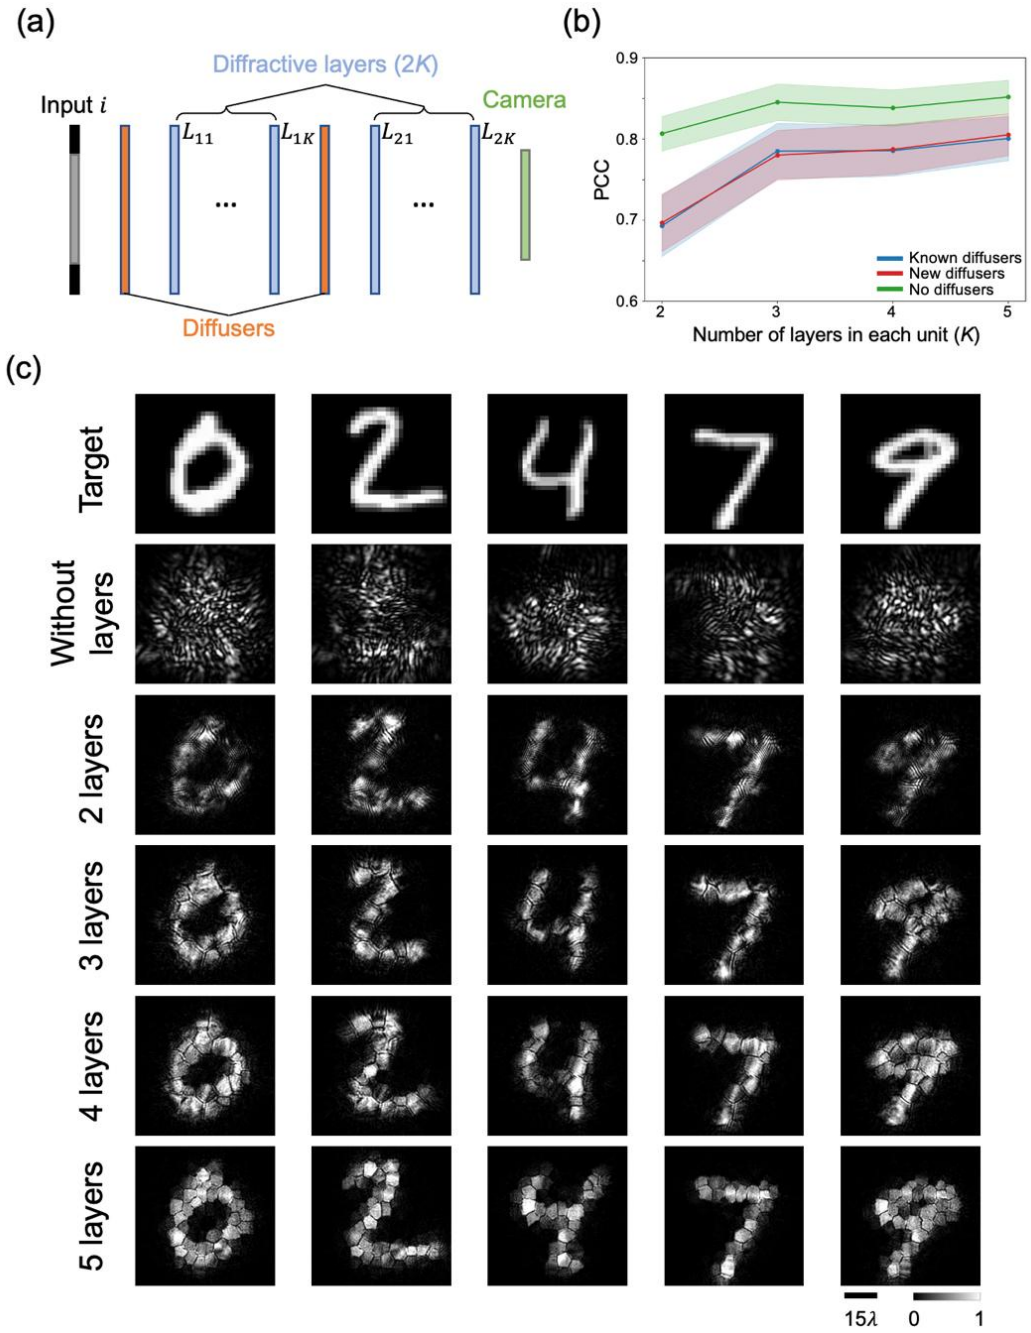

图 3. 增加可训练衍射层可提升经由体积随机扩散器成像的性能。 **(a)** 含有两个扩散器单元的交错衍射网络示意图，其中每个单元中的衍射层数量 (K) 各不相同。 **(b)** 相对于真值物体计算的皮尔逊相关系数值随衍射层数量 K 的变化。已知扩散器是指训练阶段使用过的扩散器，而新扩散器则是在训练期间从未见过的扩散器。 **(c)** 新物体经由新随机散射体传播、未使用衍射层以及使用 $K = 2 - 5$ 个衍射层时的测试结果。

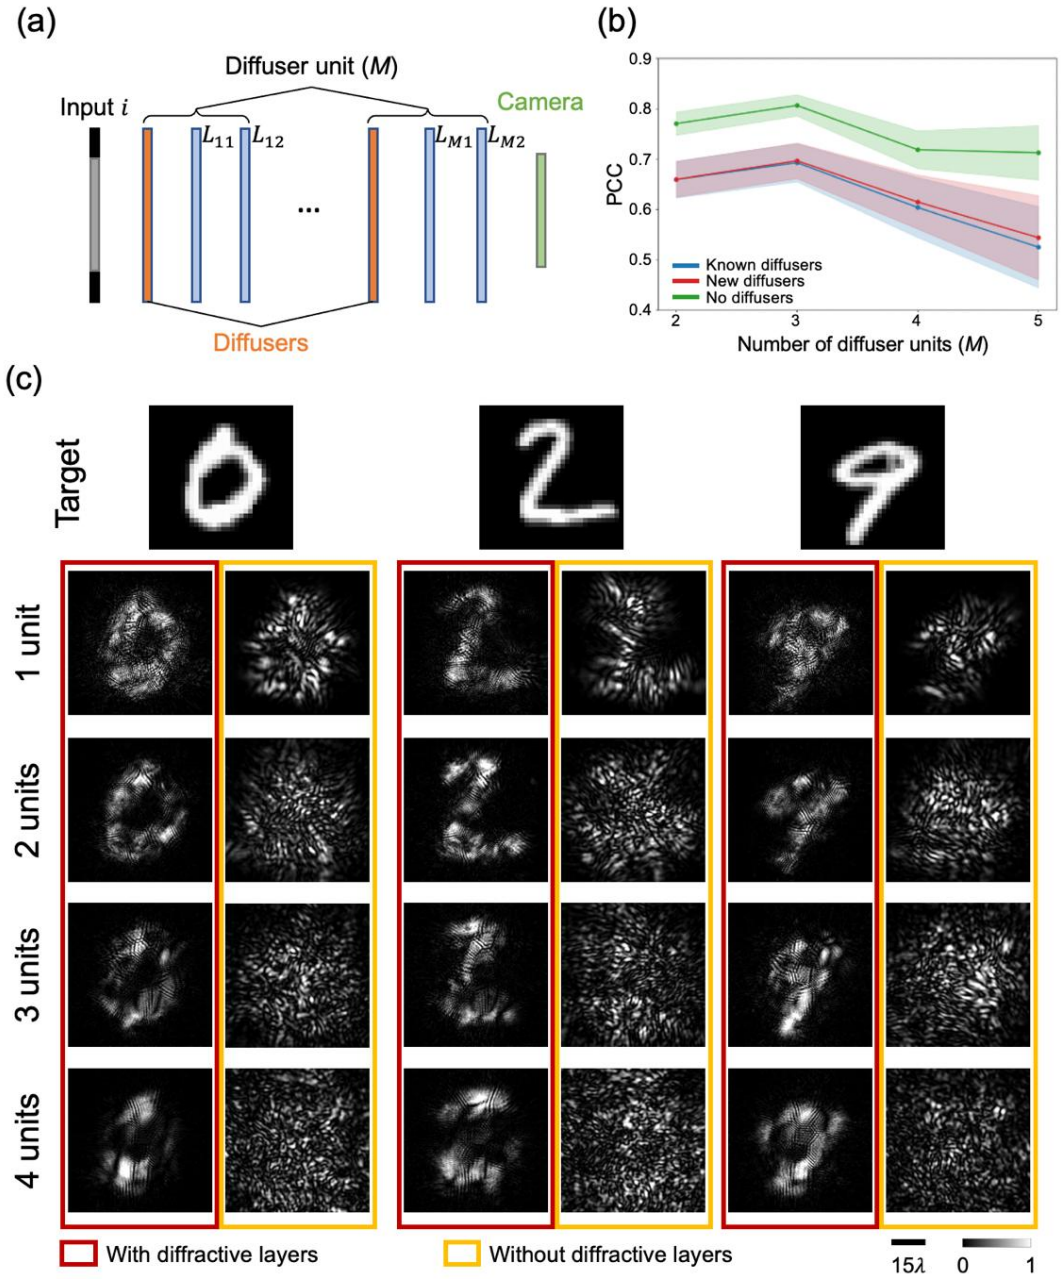

图4. 独立散射器单元数量对成像性能的影响。

(a) 具有不同数量扩散器单元的交错架构示意图，M。**(b)** 使用不同数量扩散器单元训练的衍射网络的输出PCC值，分别采用已知散射体、新散射体和无扩散器进行评估。**(c)** 代表性物体重建，展示增加M 对输出图像质量的影响。

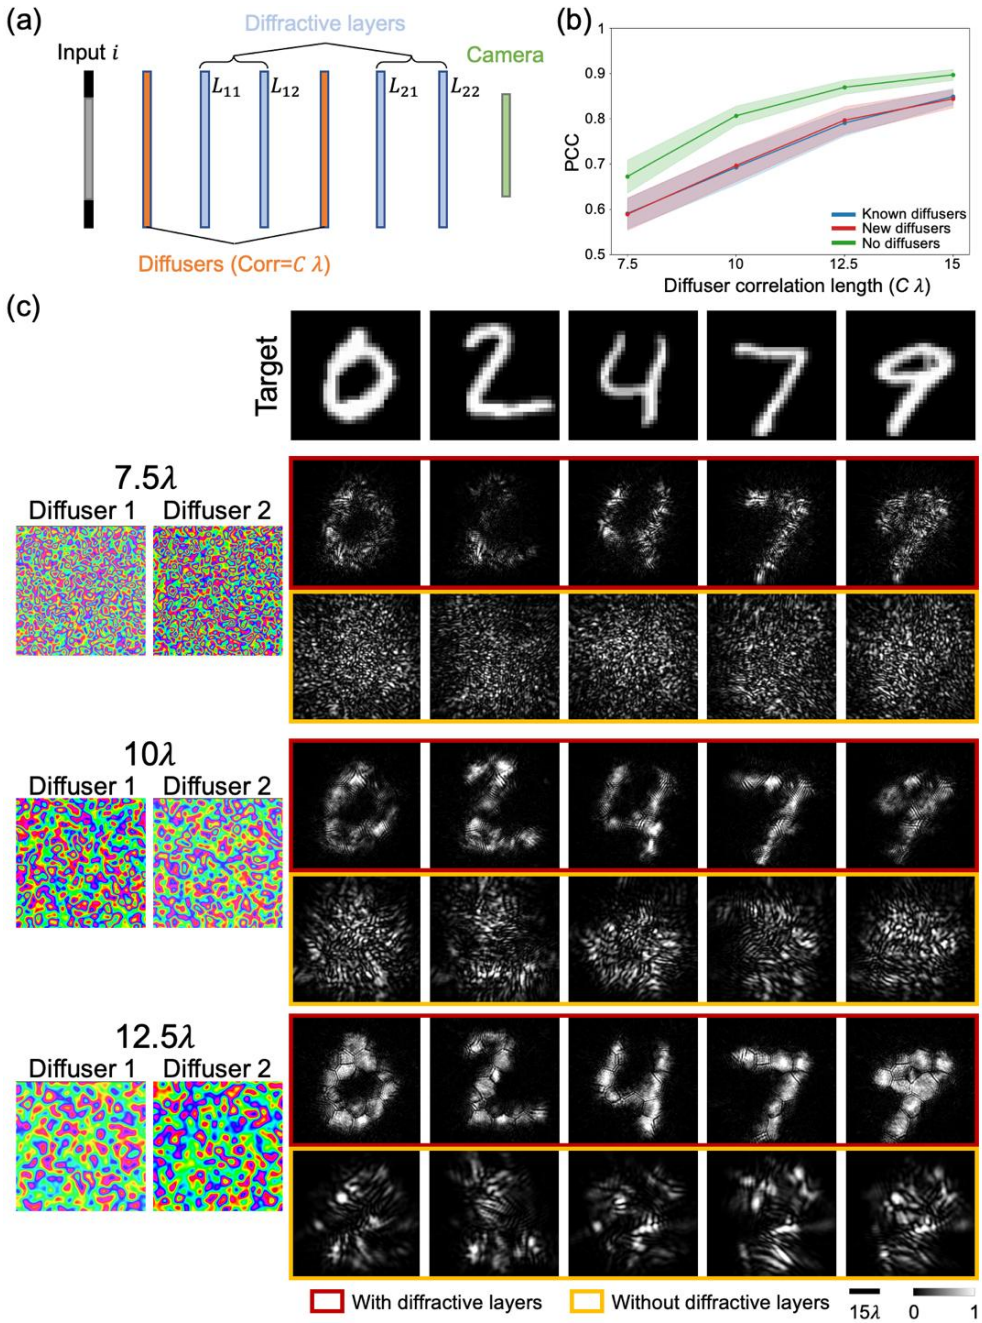

图 5. 扩散器相关长度对成像性能的影响。 **(a)**具有两个扩散器单元的交错衍射网络示意图，其中扩散器相关长度设为 C $(in\ units\ of\ \lambda)$。 **(b)**使用已知扩散器、新扩散器和无扩散器评估的、采用不同扩散器相关长度 C 训练的衍射网络的输出 PCC值。 **(c)**不同扩散器相关长度下的代表性重建结果（ C =7.5λ, 10λ, 12.5λ）。红色方框表示具有优化的衍射层的系统，黄色方框则显示未使用衍射层时的输出。

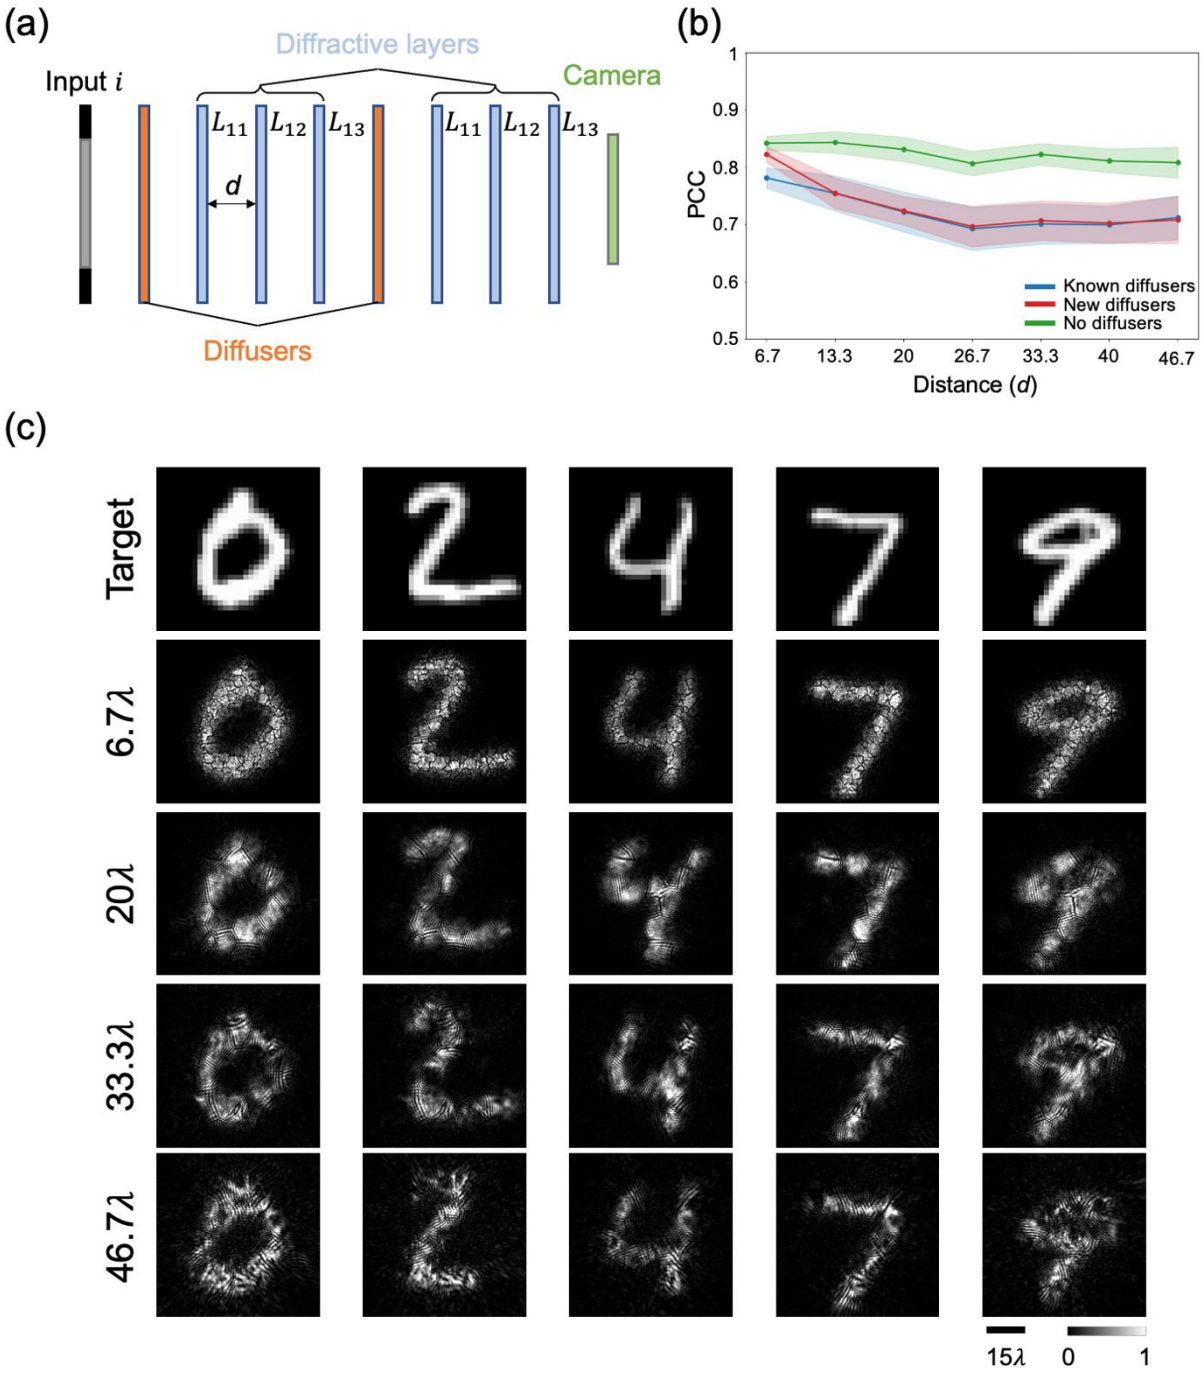

图 6. 衍射层之间的轴向间隔对成像性能的影响。 **(a)**具有 $M = 2$ 个扩散器单元和$K = 3$ 个衍射层的交错衍射网络示意图，其中相邻平面之间的轴向距离 (d) 经过了变化。 **(b)**采用已知、全新和无扩散器的情况进行评估时，使用不同平面间距训练的衍射网络的PCC值。 **(c)** 不同 d 的重建结果（ $6.7\lambda - 46.7\lambda$ ）。

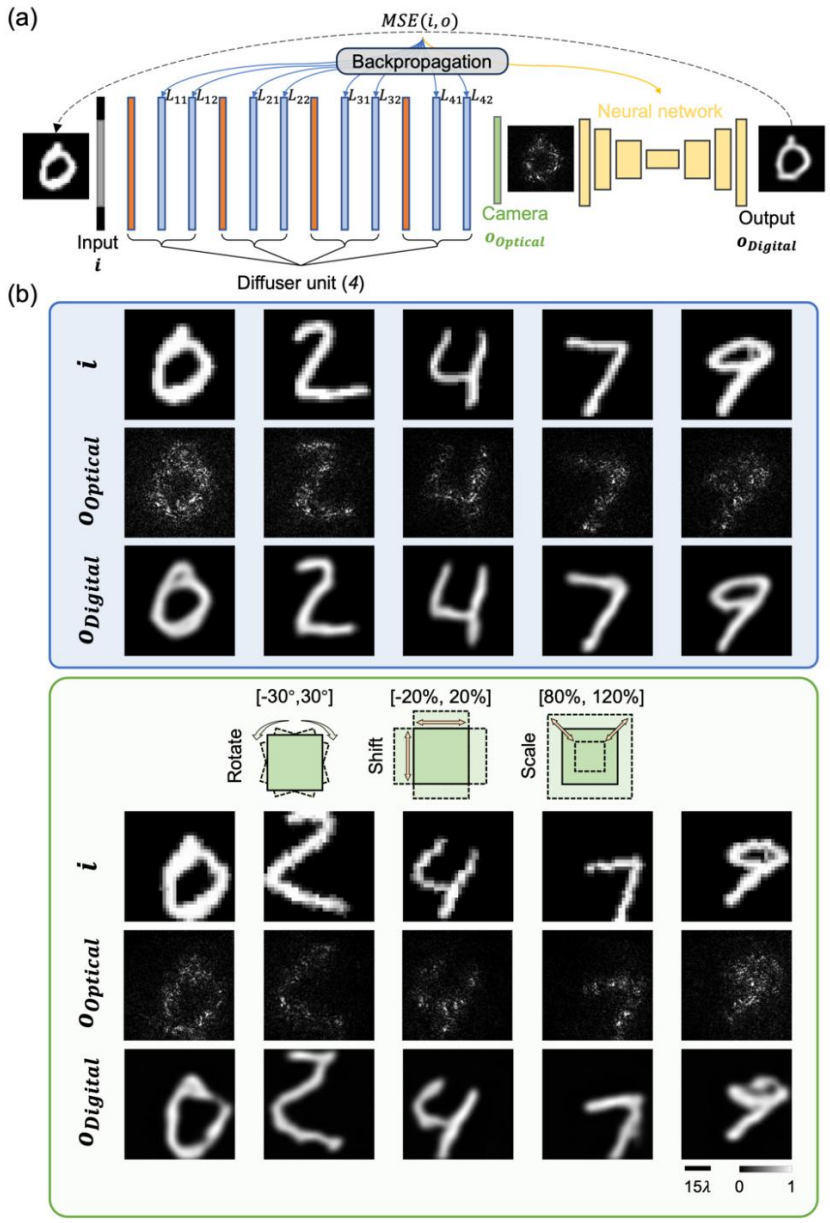

图 7. 混合光学-数字交错衍射网络，用于光学信息传输。 **(a)** 混合系统示意图。交错衍射网络执行物理预处理，在相机上形成中间图像，随后由神经网络以数字方式重建最终的高保真输出。光学和数字组件均以端到端方式联合优化。 **(b)** 通过四个扩散器单元（$M = 4$）比较全光学输出与混合输出；另见 **Movie S2**。对于复杂的散射条件（蓝框），混合网络显著提高了图像重建保真度。绿框展示了混合系统对输入扰动的鲁棒性，包括输入物体的随机旋转、横向平移和缩放。

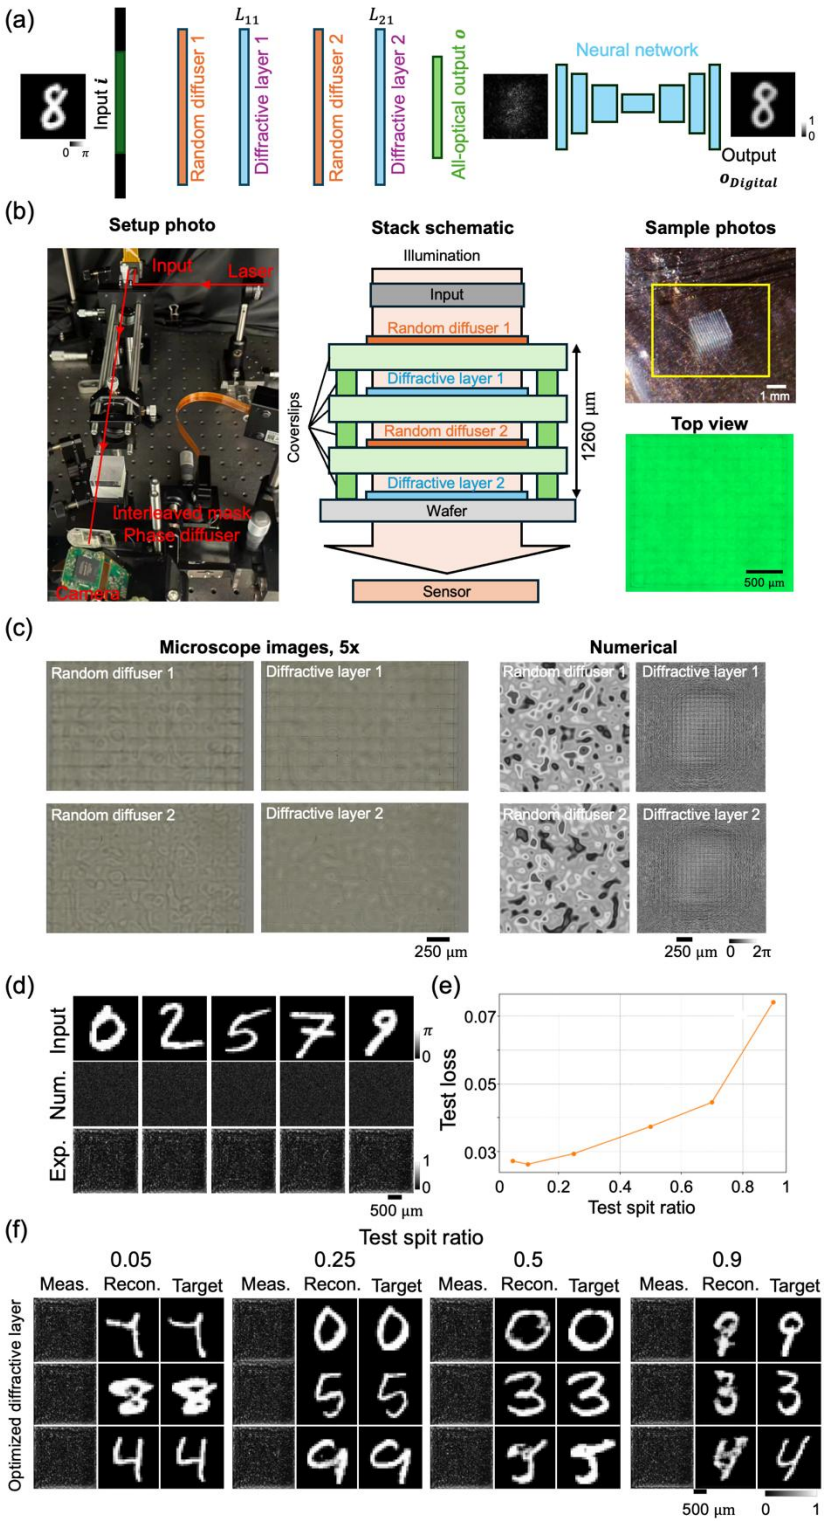

图8. 交错衍射网络的实验测试。 (a) 示意图

用于训练的光学-数字混合系统。两个优化的衍射层与两个随机相位扩散器交错排列（计算机仿真训练期间从未使用）。光学

输出强度随后由数字神经网络后端进一步处理。**(b)**实验装置照片及三维制造层堆叠示意图。制备的四层堆叠结构（两层随机相位扩散器与两层空间优化衍射层交错排列）由显示在空间光调制器上的输入物体照明，并由 CMOS 相机记录输出强度，以进行数字重建。图中还展示了样品照片和三维制造结构的俯视显微图像。 **(c)** 图中展示了制备的随机相位扩散器和优化衍射层的显微图像（5 × 物镜），以及相应的数值相位分布。**(d)**CMOS图像传感器处数值输出与实验测量结果的比较。上排：输入数字。中排：数值预测的输出强度。下排：实验测得的 CMOS 强度分布。**(e)** 优化的交错衍射掩模的测试损失随测试集划分比例的变化。**(f)** 不同测试集划分比例下具有代表性的实验测量结果（Meas.）、数字重建结果（Recon.）和真实目标（Target）。实验中，输入相位图像定义在 $[0,\pi]$ 范围内，相应的目标图像则归一化至 [0,1]。