eFIN：用于全息成像中通用自动对焦和像素超分辨率的增强型傅里叶成像网络

Hanlong Chen、Luzhe Huang、Tairan Liu、Aydogan Ozcan*

摘要—深度学习技术的应用极大地提升了全息成像能力，改善了相位恢复和图像重建效果。本文介绍一种名为增强型傅里叶成像网络（eFIN）的深度神经网络，它是一种高度泛化的全息图重建框架，能够实现像素超分辨率和图像自动对焦。通过针对肺、前列腺和唾液腺组织切片以及帕帕尼科劳（Pap）涂片进行的全息显微成像实验，我们证明，eFIN具有出色的图像重建质量，并能外部泛化至训练阶段从未见过的新类型样本。该网络实现了宽广的自动对焦轴向范围**Δz ~ 350 μm**，并能够通过物理信息引导学习准确预测全息图的轴向距离。eFIN可实现 **3×** 像素超分辨率成像，并使重建图像的空间带宽积提升9倍，同时几乎没有性能损失，从而显著节省全息成像和数据处理所需的时间。我们的研究成果展现了eFIN在拓展全息成像应用边界方面的进展，例如在定量相位成像和无标记显微术中的应用。

索引词—数字全息术、深度学习、相位恢复、自动对焦、像素超分辨率、物理信息引导学习、计算成像、全息图重建

I. 引言

数字全息术近年来作为一种强大的显微成像工具，受到广泛关注。它能够重建样本的复光场，无需对样本进行染色、固定或标记 [1]–[11]。数字全息术的一项关键挑战是从记录的仅强度全息图中恢复缺失的相位信息。对此，可采用计算方法解决，例如基于物理波传播的迭代算法 [12]–[21] ，以及近年来兴起的深度神经网络。近期基于深度学习的方法利用神经网络，从一幅或多幅全息图中，通过一次前向推理重建复样本场。与传统方法相比，这些方法具有重建速度更快、信噪比更高、景深更大等优势 [22]–[44]。此外，这些方法还成功实现了内部泛化，即深度神经网络能够重建与训练期间使用的样本类型相同、但此前未见过的新物体的全息图。近期，Chen 等人提出了傅里叶成像网络（FIN），[45] 这是一种深度神经网络，利用空间傅里叶变换模块，通过全局感受野学习输入全息图与复样本场之间的映射关系。FIN 成功实现了外部泛化，能够重建训练期间从未见过的不同样本类型的新样本的全息图。然而，FIN 不具备自动对焦能力，这意味着单个训练完成的 FIN 网络只能利用在特定已知轴向距离处采集的全息图来重建样本的复场。

本文提出增强型傅里叶成像网络（eFIN），这是一种用于端到端相位恢复和全息图像重建的深度神经网络，可通过快速推理同时实现像素超分辨率和自动对焦。eFIN 源自 FIN，但其架构有显著不同：它在动态空间傅里叶变换（SPAF）模块中采用浅层 U-Net，并提供额外的自由度，使单个神经网络能够集成像素超分辨率和自动对焦功能。具体而言，eFIN 能够在宽广的轴向范围（Δz）350 μm 内进行自动对焦，并通过物理信息引导学习准确预测输入全息图的轴向距离，无需轴向距离真实值。此外，eFIN 在内部和外部泛化任务中均展现出更优的图像重建质量，并能够以最小的性能折损实现 3× 像素超分辨率（PSR），显著节省成像和数据处理所需的时间。换言之，eFIN 的训练目标是：（1）进行像素超分辨率全息图重建，以更高分辨率呈现输入样本的振幅图像和相位图像；（2）进行轴向自动对焦，因为样品到传感器的距离未知且因输入而异；（3）除相位恢复、全息图 PSR 重建和自动对焦外，还揭示输入全息图的轴向距离。

为通过实验验证 eFIN 的成功，我们使用

加利福尼亚大学洛杉矶分校的 Ozcan研究组感谢 NSF PATHS-UP 的支持。
* 通信作者：ozcan@ucla.eduH. Chen、L. Huang、T. Liu 和 A. Ozcan 任职于加利福尼亚大学洛杉矶分校电气与计算机工程系、生物工程系及加利福尼亚纳米系统研究所（CNSI），地址为美国加利福尼亚州洛杉矶市 90095；同时也隶属于加利福尼亚大学洛杉矶分校加利福尼亚纳米系统研究所，地址为美国加利福尼亚州洛杉矶市 90095（电子邮件：hanlong@g.ucla.edu；lzhuang0324@g.ucla.edu；liutr@g.ucla.edu；ozcan@ucla.edu）

人肺组织样本（组织病理切片）的全息图对其进行了训练，并盲测了其在宫颈涂片、人肺、前列腺和唾液腺组织切片上的推理、图像重建和自动对焦性能（这些样本在训练阶段均未曾出现）。eFIN 在像素超分辨率图像重建和自动对焦方面的卓越性能，代表着基于深度学习的全息成像领域的一项重大进展，为大幅提升高分辨率全息显微术的效率和速度创造了机会。eFIN 的多功能性还使其能够应用于各种非相干成像模态，是适用于广泛成像和显微成像应用的有前景工具。

II. 结果与讨论

A. eFIN 的架构

如图 1 所示，eFIN 是一种深度神经网络，可端到端地进行相位恢复和全息图像重建，并能够在宽轴向范围内自动对焦，还能实现像素超分辨率图像重建。此外，eFIN 中名为 Z-Net 的子网络经过训练，能够在没有任何先验信息的情况下，盲预测输入全息图的样本到传感器的轴向距离。

网络的输入是一系列低分辨率纯强度同轴全息图 [46]，这些全息图是在M 不同的样品到传感器距离下采集的，即 $z_1 \ldots, \ z_M$ （见方法部分）。网络输出为样本像素超分辨率重建复场的实部和虚部，以及相应输入全息图的样品到传感器距离。监督学习训练部分所用的高分辨率真实值（GT）复值图像，是通过迭代多高度相位恢复（MH-PR）算法 [17], [18]，利用在八个不同轴向距离（$M = 8$）下采集的像素超分辨率全息图获得的（见方法部分）。

B. eFIN 的像素超分辨率全息图重建与自动对焦性能

为展示 eFIN 的卓越性能，我们使用人肺组织样本训练了该网络（见方法部分）。在每次训练迭代中，向网络输入两幅低分辨率全息图（即 $M = 2, k = 3$），它们是在随机选取且未知的样本到传感器的轴向距离 z 处拍摄的；该距离范围涵盖从 300 μm 到 650 μm，且按递增顺序排列，其中 $k = 3$ 表示目标像素超分辨率因子，如图 2(a) 所示。换言之，每幅低分辨率同轴全息图的像素数都少了 $k^2 - fold$，因欠采样而导致分辨率损失；对于单位放大率全息片上显微镜 [47]，这相当于使用像素宽度/周期更大 $k - fold$ 的光电图像传感器，从而使像素数减少 $k^2 - fold$（例如图 2 中的 $k^2 = 9$）。

为首先展示其内部泛化能力，我们使用来自新患者肺组织样本的新低分辨率输入全息图，对训练后的 eFIN网络进行了测试。这些全息图此前未曾见过，且是在多种未知的 z 轴向距离组合下采集的；eFIN生成的像素超分辨全息图重建结果如图2(b)所示。作为比较，我们还在图2(c)中展示了MH-PR算法的结果。该算法使用相同的低分辨率全息图作为输入，但已知每张全息图的实际轴向距离（即z 值）。直接比较这些结果可以看出，在较大的样本至传感器轴向距离范围内，即使不知道全息图的 z 值，我们的eFIN模型仍能提供更高的全息图重建质量；也就是说，它能够同时进行像素超分辨率图像重建和自动对焦。此外，eFIN还能以很高的精度输出输入全息图的轴向位置（见图2b）。图2中的黄色放大区域进一步突显了eFIN卓越的全息图重建质量。

为更好地了解 eFIN 的优势，我们采用了图2中的相同模型权重，详细评估其性能。图3(a)总结了 eFIN 图像重建性能指标，包括振幅结构相似性指数（结构相似性指数）、相位结构相似性指数，以及轴向距离（z）预测的平均绝对误差（MAE）；评估涵盖内部泛化（使用与训练阶段相同类型、但来自新患者的样本进行测试）和外部泛化（使用此前从未见过的新类型样本进行测试）。在不知道输入低分辨率全息图的轴向距离，即 z_1 和 z_2的情况下，eFIN 能够利用在样本到传感器 z 距离为 300 μm 至 650 μm 的范围内随机采集的 $M = 2$ 张低分辨率同轴全息图（$k = 3$），稳健地重建样本复场，同时还能准确预测输入全息图的样本到传感器距离，适用于不同的 z 值组合。此外，eFIN 在像素超分辨率图像重建和自动对焦方面展现出卓越的外部泛化能力，成功重建了此前从未见过的不同类型样本（巴氏涂片、人前列腺和唾液腺组织切片）（见图3–4）。

为进一步对比 eFIN 与传统全息图重建方法的性能，我们还量化了 MH-PR算法的重建质量。在这种情况下，为了与 eFIN 进行公平比较，我们没有向 MH-PR 提供输入全息图准确的轴向距离（z 值）。相反，我们将两张分别在 $z_1 = 380\ \mu m$ $z_2 = 560$ μ 和 m 处采集的固定全息图，以及不同组合的可变轴向距离（z_1 和 z_2），输入 MH-PR算法，以模拟无法获取输入/采集全息图精确轴向距离的情形（这种情况十分常见，尤其是在相对廉价的全息成像硬件中）。如图3(b)所示，经典MH-PR算法无法利用不准确的全息图轴向距离准确重建样本场；作为对比，图3(a)展示了 eFIN 的自动对焦结果。

C. eFIN 重建性能随 PSR 因子（k）的变化

为进一步研究 eFIN 的 PSR 全息图重建

性能，我们分别训练了六个不同的 eFIN 网络，其 PSR 因子 k 从 1 到 6 不等。所有 eFIN 模型均仅使用人肺组织样本进行训练，输入为两个全息图（$M = 2$），这些全息图是在随机选取且未知的样品到传感器距离下采集的，距离范围为 300 μm 至 650 μm。对于 PSR 因子 $k = 3$，我们使用了与图 2 和图 3 中相同的模型权重。这六个不同的 eFIN 网络使用 z_1 和 z_2的不同组合进行测试，测试距离范围为 300 μm、400 μm、500 μm 和 600 μm；随后对人肺组织切片（内部泛化）以及巴氏涂片样本、人前列腺和唾液腺薄组织切片（外部泛化）进行了盲测。图 4(a) 绘出了平均结构相似性指数随目标 PSR 因子（k）变化的曲线，图 4(b) 则展示了重建后的样本场及其对应的图像指标。这些结果证实了 eFIN 出色的 PSR 性能，表明即使使用像素数比 $k = 1$ 情况少 $k^2 = 9$ 或 $k^2 = 16$ 倍的低分辨率输入全息图，重建质量也不会有明显下降（见图 4）。

D. eFIN 的模型大小和推理时间

我们在表 1 中比较了 eFIN、MH-PR 和标准 FIN 的模型大小及推理（图像重建）时间。通过在动态 SPAF 模块中采用浅层 U-Net，eFIN 能够根据输入特征动态生成经过优化的线性变换权重，而不是依赖固定且与输入无关的权重（详情请参见方法部分）。这显著减小了 eFIN 的模型大小，并使其具备自动对焦和像素超分辨率能力。然而，eFIN 中使用的 U-Net 组件需要更多计算时间，因此，与 FIN 相比，eFIN 的像素超分辨率图像推理时间（~0.85 s/mm²）略长，尽管其模型大小约为 FIN 的一半。

表 I

	可训练参数数量 参数	推理时间 (s/mm^2)
eFIN（M=2）	5.7M	0.85
FIN（M=2）	11.5M	0.51
MH-PR（M=2）	N/A	10.36

eFIN、FIN 和 MH-PR 的模型大小及图像重建（推理）时间对比，单位为每 1 mm² 样本视场所需的秒数。请注意，MH-PR 和 FIN 都需要预先知道输入全息图的轴向距离。

值得注意的是，eFIN 能够使用低分辨率输入全息图执行像素超分辨率和自动对焦，同时将图像质量损失降至最低，如图 4(a) 所示，PSR 因子为 $k = 1$、2 和 3。这使 eFIN 能够处理直接由 CMOS/CCD 成像器采集的原始全息图，并以亚像素级精度输出高分辨率样本场（相位和振幅）。相比之下，MH-PR 和 FIN 需要以具有已知轴向距离的像素超分辨率全息图作为输入，而生成这些全息图需要额外采集全息图并进行数据处理才能实现像素超分辨率。MH-PR 和 FIN 所需的这些额外全息图/图像采集和数据处理步骤，与表 1 报告的推理时间相比，耗时要长得多。

III. 方法

A. 样本制备与全息成像

本研究使用的人体样本来自本研究开始前收集的、已去除身份信息的现有样本。加州大学洛杉矶分校转化病理核心实验室（TPCL）收集并制备了前列腺、唾液腺和肺组织切片，加州大学洛杉矶分校病理学系则提供了巴氏涂片。为采集这些样本的原始全息图，研究使用了定制的无透镜同轴全息显微镜 [17], [46]，其光源孔径、样本和CMOS图像传感器按对应顺序垂直排列。照明光源为配备声光可调滤波器的宽带激光器（WhiteLase Micro，NKT Photonics），发射波长为530 nm，置于样本上方约10 cm处。CMOS图像传感器（IMX081，索尼）安装在六轴平台（MAX606，Thorlabs）上，与样本的距离设定在 300 μm至650 μm之间。其横向和轴向位移由计算机控制，计算机运行定制的LabVIEW程序以自动采集全息图。

B. 数据集预处理

为获得高分辨率目标（GT）复场，我们采用了迭代式 MH-PR 算法，该算法使用 M=8 像素超分辨率全息图（见图 2(a)），并结合自动对焦算法 [48]，为每幅采集的全息图提供估计的样本至传感器距离。该迭代算法在 100 次迭代内收敛。我们使用像素超分辨率算法 [49], 生成高分辨率全息图，将所得超分辨率全息图的有效像素尺寸减小至 0.37 μm。原始同轴全息图由编程控制的 6 轴机械扫描平台在具有亚像素偏移的 6×6 个横向位置自动采集。

随后，将所得高分辨率全息图和目标复场（GT）裁剪为 512×512 个图像块，并划分为互不重叠的训练集、验证集和测试集；每种样本类型分别约包含 600、100 和 100 个视场。每个图像数据集仅包含来自不同患者的视场，以确保多样性。通过采用不同的 PSR 因子进行像素合并，生成低分辨率全息图，PSR 因子范围为 k=2 至 k=6。输入 eFIN 的低分辨率全息图按轴向距离递增的顺序排列。

C. 网络结构

eFIN网络结构如图 1(b) 所示。受 DenseNet 中密集块启发的密集连接 [50], 能够使信息从输入层高效流向输出层。每个动态 SPAF 组的输出张量都会被拼接，并馈入后续的动态 SPAF 组，从而逐步累积特征图，而非在整个网络中保持通道大小不变，进而

显著减少初始动态 SPAF 组中的参数数量。

eFIN 的动态 SPAF 模块采用浅层 U-Net [51] 为每个输入张量动态生成权重 W，而不是使用在测试阶段固定的可训练权重。首先使用二维快速傅里叶变换 (FFT) 将输入张量转换到空间频率域，并应用半窗尺寸 h 滤除高频信号。然后，执行线性变换：

$$F'_{j,u,v} = \sum_{i=1}^{c} F_{i,u,v} \cdot W_{j,u,v}$$

$$u, v = 0, \pm 1, \ldots, \pm h, \qquad j = 1, \ldots, c \tag{1}$$

其中，c 为通道数，$W \in \mathrm{R}^{c,\ 2h+1,\ 2h+1}$ 表示由 U-Net 动态生成的权重，$F \in \mathrm{C}^{c,\ 2h+1,\ 2h+1}$ 表示经过低通滤波器后的频率分量，而 F' 为变换后的信号。W 由将 F 的绝对值输入浅层 U-Net 生成。借助这一机制，eFIN 网络能够针对输入张量单独且独特地调整其权重，从而实现自动对焦和像素级超分辨率能力。

Z-Net（见图 1）是一种卷积神经网络，它接收所有动态 SPAF 模块中浅层 U-Net 的输出，并预测输入全息图（这些全息图被输入 eFIN 时所处的）未知轴向位置。我们没有通过监督学习向 Z-Net 提供用于训练的 z 真实值，而是设计了一种物理信息学习框架，旨在利用真实值复场和 Z-Net 预测的轴向位置 $\hat{z}$，最小化输入低分辨率全息图与传播场强度之间的差异（见图 1(a)）。与监督学习相比，我们的物理信息方法无需提供输入全息图轴向距离 z的真实值，也避免了训练中引入额外误差。

D. 网络实现

该网络使用 Python 中的 PyTorch 软件包 [52] 实现。训练损失如图 1(a)所示，由两部分组成：$Loss_s$ 和 $Loss_h$。$Loss_s$ 表示样本重建输出复场的监督损失，而$Loss_h$ 仅表示 Z-Net 的物理信息引导损失。

监督损失 $Loss_s$ 是 MAE 损失和傅里叶域 MAE（FDMAE）损失 [45], [53]的加权和：

$$Loss_s = \alpha L_{MAE} + \beta L_{FDMAE} \tag{2}$$

其中，α 和β 经经验设定为 2 和 0.007。上述两项可表示为：

$$L_{MAE} = \frac{\sum_{i=1}^{n} |y_i - \hat{y}_i|}{n} \tag{3}$$

$$L_{FDMAE} = \frac{\sum_{i=1}^{n} |\mathcal{F}(y)_i - \mathcal{F}(\hat{y})_i|}{n} \tag{4}$$

其中，y 为真实值，$\hat{y}$为网络的输出，n 为像素总数，F 表示二维 FFT 算子。

Z-Net 中的物理信息引导损失 $Loss_h$ 是输入低分辨率全息图与将真实值复场传播至 Z-Net 预测距离 $\hat{z}_i$ $i = 1, \ldots, M$ 所对应平面后生成的全息图之间的平均绝对误差之和，即，

$$Loss_h = \sum_{i=1}^{M} \left(\frac{\sum_{j=1}^{n} \left| x_{i,j} - PB(|FSP(y, \hat{z}_i)|, k)_j \right|}{n} \right) \tag{5}$$

其中，x为输入低分辨率全息图，y为样本的真实值复场，n 为像素总数，FSP 为自由空间传播操作，$PB(\cdot, k)$表示$k - fold$ 像素合并操作，M 为输入全息图的数量。

在训练阶段，我们使用配备 Intel W-2195 CPU 和 Nvidia RTX 2080 Ti GPU 的计算机。网络使用 Ada mW优化器 [54] 和余弦退火热重启学习率调度器 [55]进行迭代优化。我们使用验证集选择最佳模型，该验证集仅包含与训练集样本类型相同的样本。在测试阶段，eFIN网络在同一台计算机上使用单个 RTX 2080 Ti GPU 时，平均推理时间为 0.85 s/mm^2 。

致谢

加利福尼亚大学洛杉矶分校的Ozcan研究实验室感谢 NSF PATHS-UP 提供的支持。

参考文献

[1] S. S. Kou、L. Waller、G. Barbastathis 和 C. J. R. Sheppard，《用于定量相位成像的差分干涉相衬（TI-DIC）显微成像强度传输方法》，《光学快报》，第35卷，第3期，447–449页，2010年2月，doi: 10.1364/OL.35.000447。[2] V. Chhaniwal、A. S. G. Singh、R. A. Leitgeb、B. Javidi 和 A. Anand，《采用劳埃德镜的紧凑型数字全息显微镜定量相衬成像》，《光学快报》，第37卷，第24期，5127–5129页，2012年12月，doi: 10.1364/OL.37.005127。[3] M. H. Jericho、H. J. Kreuzer、M. Kanka 和 R. Riesenberg，《采用点光源数字内联全息显微术测量定量相位和折射率》，《应用光学》，第51卷，第10期，1503–1515页，2012年4月，doi: 10.1364/AO.51.001503。[4] T.-W. Su、L. Xue 和 A. Ozcan，《高通量无透镜三维追踪人类精子，揭示螺旋轨迹的罕见统计特征》，《美国国家科学院院刊》，第109卷，第40期，16018–16022页，2012年10月，doi: 10.1073/pnas.1212506109。A. Greenbaum、A. Feizi、N. Akbari 和 A. Ozcan，《利用像素超分辨片上显微术进行宽视场计算彩色成像》，《光学快报》，第21卷，第10期，12469–12483页，2013年5月，doi: 10.1364/OE.21.012469。[5] [6] A. Greenbaum 等，《利用无透镜片上显微术对病理切片进行宽视场计算成像》，《科学·转化医学》，第6卷，第267期，267ra175-

267ra175，2014年12月，doi: 10.1126/scitranslmed.3009850。[7] L. Tian 和 L. Waller，《LED阵列显微镜中的定量差分相衬成像》，《光学快报》，第23卷，第9期，11394–11403页，2015年5月，doi: 10.1364/OE.23.011394。[8] F. Merola 等，《数字全息断层流式细胞术》，《光：科学与应用》，第6卷，第4期，文章编号4，2017年4月，doi: 10.1038/lsa.2016.241。[9] Y. Park、C. Depeursinge 和 G. Popescu，《生物医学中的定量相位成像》，《自然·光子学》，第12卷，第10期，文章编号10，2018年10月，doi: 10.1038/s41566-018-0253-x。[10] G. Barbastathis、A. Ozcan 和 G. Situ，《深度学习在计算成像中的应用》，《Optica》，第6卷，第8期，921–943页，2019年8月，doi: 10.1364/OPTICA.6.000921。[11] B. J avidi 等，《数字全息术路线图 [特邀],》，《光学快报》，第29卷，第22期，35078–35118页，2021年10月，doi: 10.1364/OE.435915。[12] J. R. Fienup，《相位恢复算法：比较》，《应用光学》，第21卷，第15期，2758–2769页，1982年8月，doi: 10.1364/AO.21.002758。[13] M. R. Teague，《确定性相位恢复：格林函数解》，《美国光学学会杂志》，第73卷，第11期，1434–1441页，1983年11月，doi: 10.1364/JOSA.73.001434。[14] G. Yang、B. Dong、B. Gu、J. Zhuang 和 O. K. Ersoy，《非酉变换系统中相位恢复的Gerchberg–Saxton算法与Yang–Gu算法：比较》，《应用光学》，第33卷，第2期，209–218页，1994年1月，doi: 10.1364/AO.33.000209。[15] L. J. Allen 和 M. P. Oxley，《由离焦变化获得的一系列图像进行相位恢复》，《光学通信》第199卷，第1期，65–75页，2001年11月，doi: 10.1016/S0030-4018(01)01556-5。[16] S. Marchesini，《特邀文章：相位恢复迭代投影算法的统一评估》，《科学仪器评论》，第78卷，第1期，页码011301，2007年1月，doi: 10.1063/1.2403783。[17] A. Greenbaum 和 A. Ozcan，《利用基于像素超分辨率的多高度无透镜片上显微术对高密度样本进行无掩模成像》，《光学快报》，第20卷，第3期，3129–3143页，2012年1月，doi: 10.1364/OE.20.003129。[18] A. Greenbaum、U. Sikora 和 A. Ozcan，《利用基于多高度像素超分辨率的无透镜成像对高密度样本进行便携式宽视场显微成像》，《实验室芯片》，第12卷，第7期，1242–1245页，2012年3月，doi: 10.1039/C2LC21072J。[19] W. Luo、A. Greenbaum、Y. Zhang 和 A. Ozcan，《基于合成孔径的片上显微成像》，《光：科学与应用》，第4卷，第3期，文章编号3，2015年3月，doi: 10.1038/lsa.2015.34。[20] Y. Rivenson、Y. Wu、H. Wang、Y. Zhang、A. Feizi 和 A. Ozcan，《全息显微成像中的基于稀疏性的多高度相位恢复》，《科学报告》，第6卷，第1期，文章编号1，2016年11月，doi: 10.1038/srep37862。[21] W. Luo、Y. Zhang、Z. Göröcs、A. Feizi 和 A. Ozcan，《用于全息图像的传播相量法重建”，《科学报告》，第 6 卷，第 1 期，文章编号 1，2016年 3 月，doi: 10.1038/srep22738. [22] Y. Rivenson、Y. Zhang、H. Günaydın、D. Teng 和 A. Ozcan，“利用神经网络中的深度学习进行相位恢复和全息图像重建”，《光：科学与应用》，第 7 卷，第 2 期，页码 17141–17141，2018年 2 月，doi: 10.1038/lsa.2017.141. [23] H. Wang 、 M. Lyu 和 G. Situ，“eHoloNet：一种基于学习的端到端同轴数字全息重建方法”，《光学快报》，第 26 卷，第 18 期，页码 22603–22614，2018年 9 月，doi: 10.1364/OE.26.022603. [24] Y. Wu 等，“利用基于深度学习的自动对焦和相位恢复扩展全息成像的景深”，《Optica》，第 5 卷，第 6 期，页码 704–710，2018年 6 月，doi: 10.1364/OPTICA.5.000704. [25] A. Goy、K. Arthur、S. Li 和 G. Barbastathis，“利用深度学习实现低光子计数相位恢复”，《物理评论快报》，第 121 卷，第 24 期，页码 243902，2018年 12 月，doi: 10.1103/PhysRevLett.121.243902. [26] G. Zhang 等，“通过深度学习实现离轴数字全息显微术中的快速相位恢复”，《光学快报》，第 26 卷，第 15 期，页码 19388–19405，2018年 7 月，doi: 10.1364/OE.26.019388.[27] Z. Ren、Z. Xu 和 E. Y. Lam，“用于数字全息术的基于学习的非参数自动对焦”，《Optica》，第 5 卷，第 4 期，页码 337–344，2018年 4 月，doi: 10.1364/OPTICA.5.000337.[28] Y. Rivenson、Y. Wu 和 A. Ozcan，“全息术与相干成像中的深度学习”，《光：科学与应用》，第 8 卷，第 1 期，页码 85，2019年 9 月，doi: 10.1038/s41377-019- 0196-0.[29] T. Liu 等，“基于深度学习的彩色全息显微术”，《生物光子学》，第 12 卷，第 11 期，页码 e201900107，2019年，doi: 10.1002/jbio.201900107. [30] Y. Wu 等，“明场全息术：跨模态深度学习通过单幅全息图实现具有明场对比度的快照式三维成像”，《光：科学与应用》，第 8 卷，第 1 期，文章编号 1，2019年 3 月，doi: 10.1038/s41377-019-0139-9.[31] Y. Jo 等，“定量相位成像与人工智能：综述”，《IEEE量子电子学精选主题期刊》，第 25 卷，第 1 期，页码 1–14，2019年 1 月，doi: 10.1109/JSTQE.2018.2859234. [32] K. Wang 等，“Y-Net：用于数字全息重建的一对二深度学习框架”，《光学快报》，第 44 卷，第 19 期，页码 4765–4768，2019年 10 月，doi: 10.1364/OL.44.004765.[33] H. Byeon、T. Go 和 S. J. Lee，“基于深度学习的数字同轴全息显微术：通过扩展视场实现高分辨率”，《光学与激光技术》，第 113 卷，页码 77–86，2019年 5 月，doi: 10.1016/j.optlastec.2018.12.014. [34] Z. Ren、Z. Xu 和 E. Y. M. Lam，“用于数字全息重建的端到端深度学习框架”，《先进光子学》，第 1 卷，第 1 期，页码 016004，2019年 1 月，doi: 10.1117/1.AP.1.1.016004. [35] H. Li、X. Chen、Z. Chi、C. Mann 和 A. Razi，“Deep DIH：基于深度学习的单次数字同轴全息重建”，《IEEE开放获取期刊》，第 8 卷，

页码 202648–202659，2020年，doi: 10.1109/ACCESS.2020.3036380.[36] I. Moon、K. Jaferzadeh、K. Jaferzadeh、Y. Kim 和 B. Javidi，“利用条件生成对抗网络在伽博全息术中实现无噪声定量相位成像”，《光学快报》，第 28 卷，第 18 期，页码 26284– 26301，2020年 8 月，doi: 10.1364/OE.398528. [37] T. Zeng、H. K.-H. So 和 E. Y. Lam，“RedCap：用于全息图像重建的残差编码器-解码器胶囊网络”，《光学快报》，第 28 卷，第 4 期，页码 4876– 4887，2020年 2 月，doi: 10.1364/OE.383350. [38] T. Liu 等，“基于深度学习的全息偏振显微术”，《ACS 光子学》，第 7 卷，第 11 期，页码 3023–3034，2020年 11 月，doi: 10.1021/acsphotonics.0c01051. [39] M. Deng、S. Li、A. Goy、I. Kang 和 G. Barbastathis，“学习合成：低光子计数下的稳健相位恢复”，《光：科学与应用》，第 9 卷，第 1 期，文章编号 1，2020年 3 月，doi: 10.1038/s41377-020-0267-2. [40] D. Yin 等，“基于深度学习框架和非配对数据的数字全息重建”，《IEEE 光子学期刊》，第 12 卷，第 2 期，页码 1–12，2020年 4 月，doi: 10.1109/JPHOT.2019.2961137.[41] L. Huang、T. Liu、X. Yang、Y. Luo、Y. Rivenson 和 A. Ozcan，“利用循环神经网络进行相位恢复与自动对焦的全息图像重建”，《ACS 光子学》，第 8 卷，第 6 期，页码 1763–1774，2021年 6 月，doi: 10.1021/acsphotonics.1c00337. [42] X. Yang 等，“基于生成对抗网络的低采样率傅里叶单像素成像的高成像质量”，《光学与激光工程》，第 140 卷，页码 106533，2021年 5 月，doi: 10.1016/j.optlaseng.2021.106533. [43] T. Shimobaba 等，“深度学习计算全息术：综述”，《光子学前沿》，第 3 卷，2022年，访问日期：2023年 1 月 7 日。[在线]。可访问：https://www.frontiersin.org/articles/10 8 54391 3389 2022 . /fphot..[44] D. Pirone 等，“通过深度学习加速全息流式细胞术中的三维断层图像重建”，《实验室芯片》，第 22 卷，第 4 期，页码 793–804，2022年 2 月，doi: 10.1039/D1LC01087E. [45] H. Chen、L. Huang、T. Liu 和 A. Ozcan，“傅里叶成像网络（FIN）：一种具有卓越外部泛化能力的全息图重建深度神经网络”，《光：科学与应用》，第 11 卷，第 1 期，文章编号 1，2022年 8 月，doi: 10.1038/s41377-022-00949-8。

[46] A. Greenbaum 等，“无透镜成像：片上宽视场显微镜的成就与尚存挑战”，《自然·方法》，第 9 卷，第 9 期，文章编号 9，2012年 9 月，doi：10.1038/nmeth.2114。[47] O. Mudanyali 等，“基于无透镜非相干全息术的紧凑、轻便且经济的显微镜，用于远程医疗应用”，《实验室芯片》，第 10 卷，第 11 期，第 1417–1428 页，2010 年 5 月，doi：10.1039/C000453G。[48] Y. Zhang、H. Wang、Y. Wu、M. Tamamitsu 和 A. Ozcan，“稳健全息自动对焦的边缘稀疏性准则”，《光学快报》，第 42 卷，第 19 期，第 3824–3827 页，2017年 10 月，doi：10.1364/OL.42.003824。[49] Y. Wu、Y. Zhang、W. Luo 和 A. Ozcan，“用于复用全息彩色成像的去马赛克像素超分辨率”，《科学报告》，第 6 卷，第 1 期，文章编号 1，2016年 6 月，doi：10.1038/srep28601。[50] G. Huang、Z. Liu、L. van der Maaten 和 K. Q. Weinberger，“密集连接卷积网络”，发表于 IEEE计算机视觉与模式识别会议论文集，2017，4700 4708 07，第 – 页。2023 [ ] 访问日期：1月 。在线。可访问：https://openaccess.thecvf.com/content_cvpr_2017/html/Huang _ _ _ _ _2017 Densely Connected Convolutional CVPR paper.html [51] O. Ronneberger、P. Fischer 和 T. Brox，“U-Net：用于生物医学图像分割的卷积网络”，载于《医学图像计算与计算机辅助干预》– MICCAI 2015，Cham，2015年，第 234–241 页。doi：10.1007/978-3-319-24574-4_28。[52] A. Paszke 等，“PyTorch：一种命令式风格的高性能深度学习库”，载于《神经信息处理系统进展》，2019年，第 32 卷。访问日期：2023年 1 月 7 日。[在线]。可访问：https://proceedings.neurips.cc/paper/2019/hash/bdbca288 fee7f92f2bfa9f7012727740-Abstract.html[53] L. Huang、H. Chen、T. Liu 和 A. Ozcan，“GedankenNet：利用物理一致性进行全息图重建的自监督学习”。arXiv，2022年 9 月 17 日。doi：10.48550/arXiv.2209.08288。[54] I. Loshchilov 和 F. Hutter，“解耦权重衰减正则化”。arXiv，2019年 1 月 4 日。doi：10.48550/arXiv.1711.05101。[55] I. Loshchilov 和 F. Hutter，“随机梯度下降热重启：带热重启的随机梯度下降”。arXiv，2017年 5 月 3 日。doi：10.48550/arXiv.1608.03983。

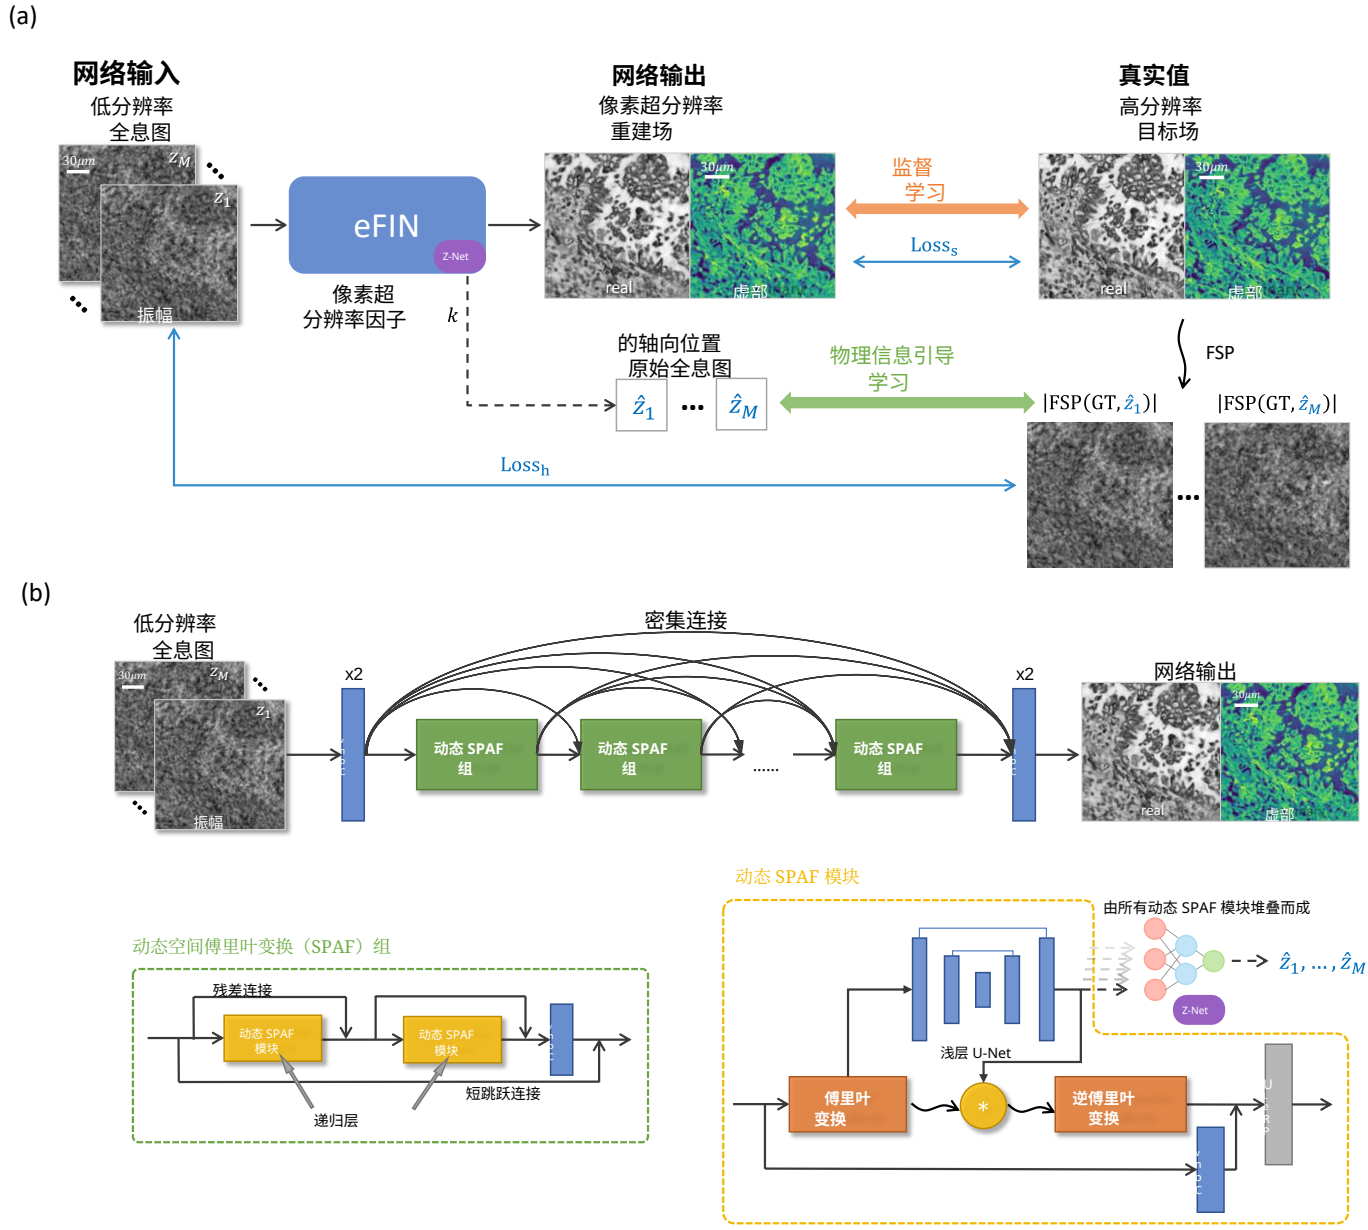


图 1. eFIN 的全息图重建与自动对焦框架。(a) 在不同的样品到传感器距离 z_i、 $i = 1$、...、 M 处采集输入低分辨率全息图。$Loss_s$ 是根据真实目标场推导出的监督损失函数，而 $Loss_h$ 由物理信息引导学习生成，仅应用于 Z-Net。(b) eFIN网络的架构，其中 Z-Net 是 eFIN 的一个子网络。所有动态 SPAF 模块中 U-Net 的输出都会被收集并输入 Z-Net，以预测输入全息图的轴向距离（$\hat{z}$）。

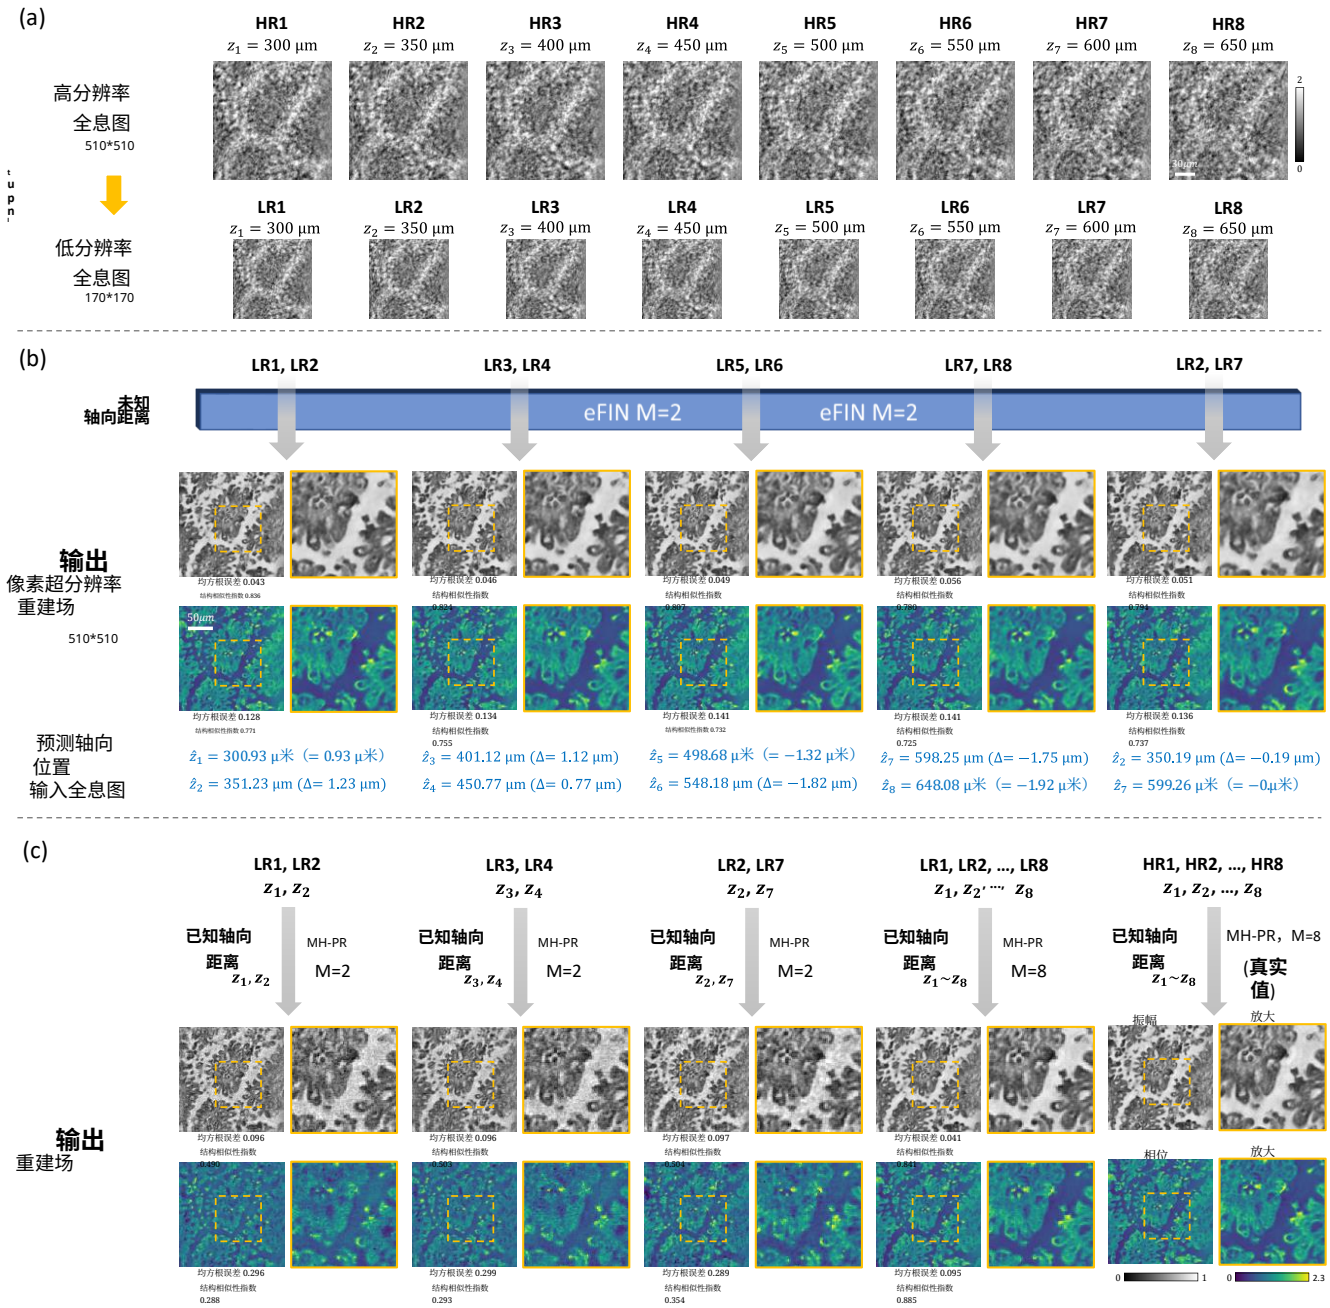


图2. eFIN的像素超分辨全息图重建和自动对焦性能。(a) 低分辨率输入全息图通过3× 下采样（采用像素合并）获得。(b) 使用训练好的eFIN网络（$M = 2$）生成输出复值场，像素超分辨率因子为$k = 3$。(c) MH-PR算法使用相同的低分辨率输入全息图（$M = 2$）生成的输出复值场，即使利用了输入全息图的已知轴向距离，重建结果的质量仍较低。

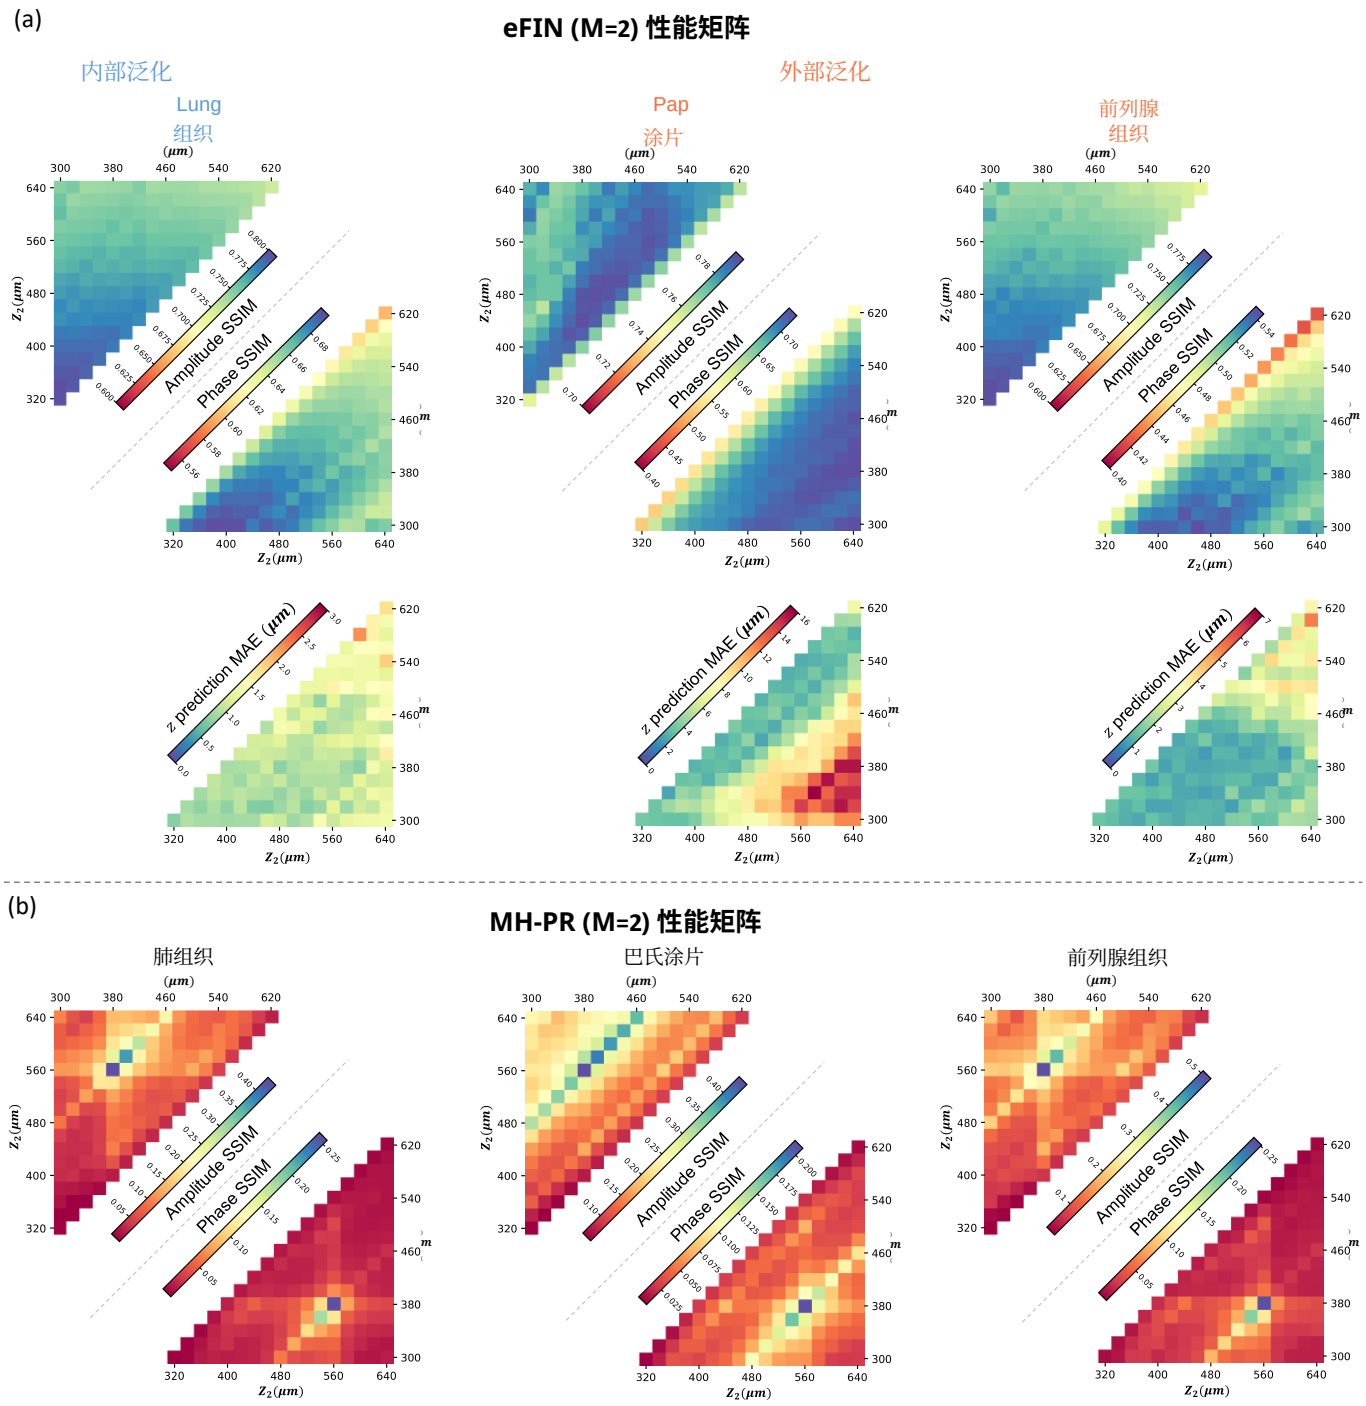


图 3. eFIN 和 MH-PR 的图像重建性能。(a) 使用 eFIN 网络 ($M = 2, k = 3$) 重建的复值场的振幅和相位结构相似性指数，以及预测轴向距离的平均绝对误差。(b) MH-PR算法 ($M = 2$) 在输入不同 z距离组合时的图像重建性能矩阵；输入低分辨率全息图则是在固定的 $z_1 = 380$ μm 和 $z_2 = 560$ μm 处采集的。

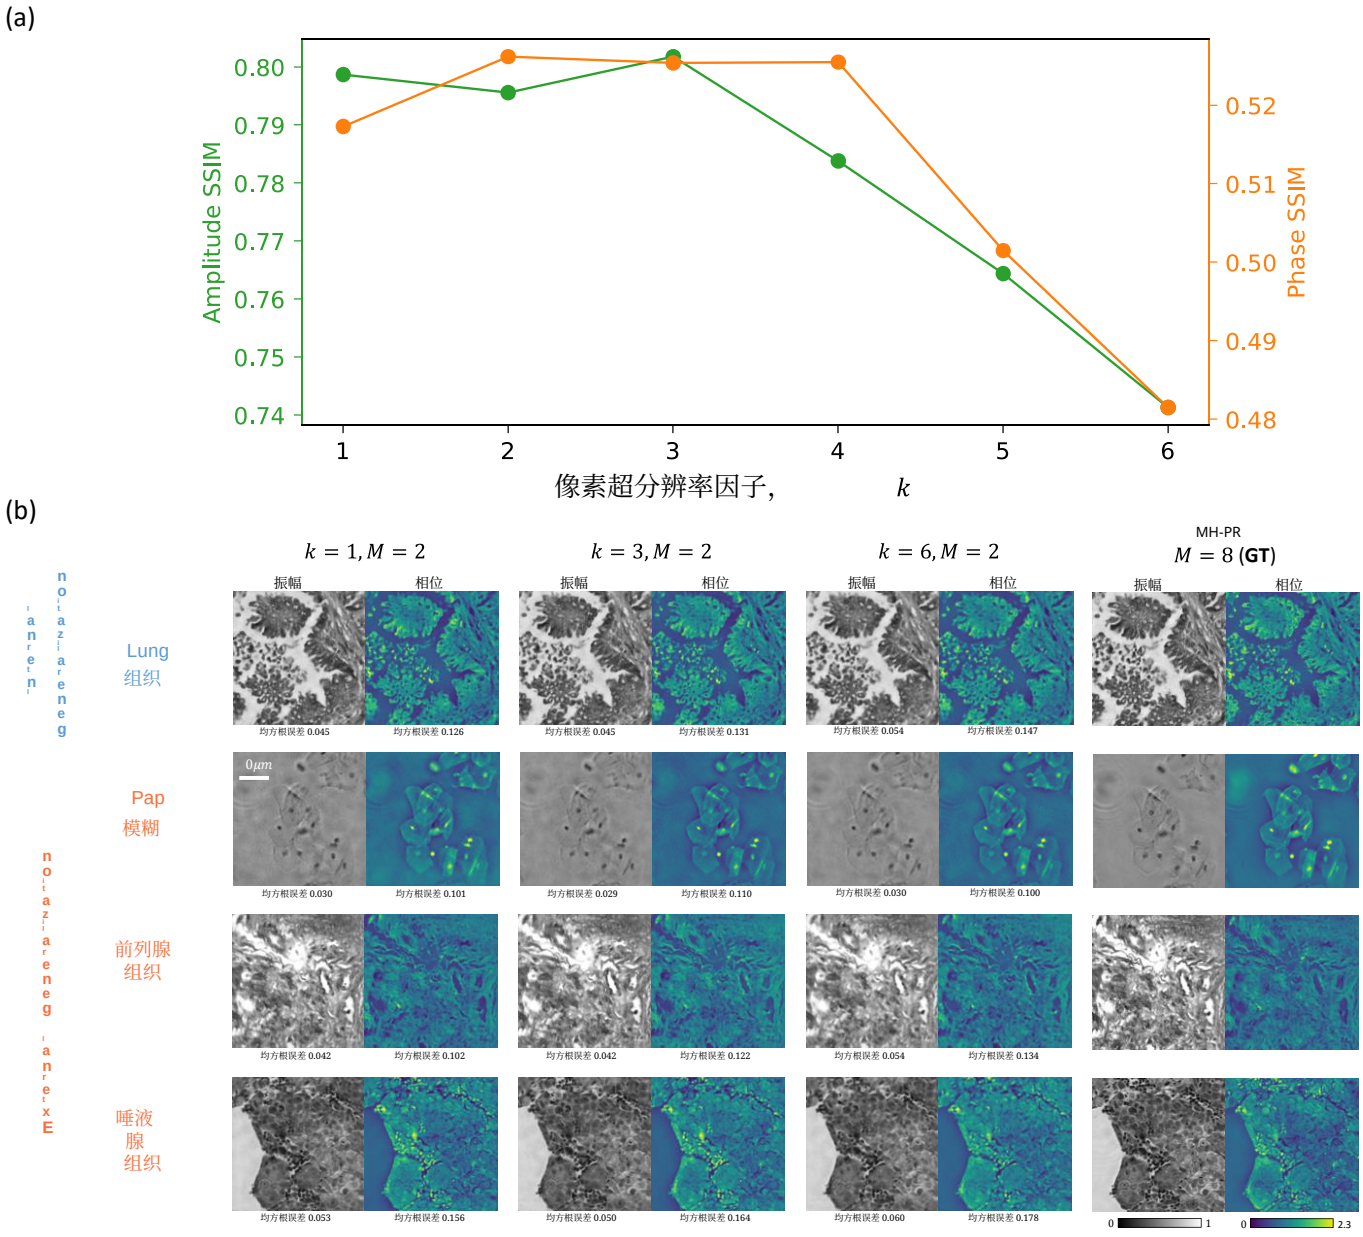


图 4. eFIN 的全息图重建性能随 PSR 因子 (k) 的变化。 针对每个 PSR 因子 k，使用人肺组织样本训练了一个独立的 eFIN 模型 ($M = 2$)。(a) 在不同轴向距离组合下采集的不同类型样本，其重建样本场的振幅和相位部分的平均结构相似性指数。(b) eFIN 重建样本场的可视化结果。每个样本的真实值由 MH-PR算法获得，该算法使用了在 8 个不同样品到传感器的距离下采集的 $M = 8$ 像素超分辨率全息图。