TF-UNet：利用微米级光纤解析复杂散斑，实现512^2-矩阵图像的单次重建

Mingliang Xu[1,2]†、*Fangyuan Li*[2,3]†、冷雨欣[2,3], 李如心[2,3] 和何飞[2,3]*

Mingliang Xu[1]中国科学技术大学物理科学学院，中国安徽合肥 230026

Mingliang Xu、Fangyuan Li、冷雨欣、李如心、何飞[2]中国科学院强场激光科学与技术国家重点实验室、中国科学院上海光学精密机械研究所，中国上海 201800 电子邮箱：hefei@siom.ac.cn（F. H.）

Fangyuan Li、冷雨欣、李如心、何飞[3]中国科学院大学材料科学与光电工程中心，中国北京 100049

资助项目：国家自然科学基金委员会（项目编号：12388102）、张江实验室青年创新项目（项目编号：S20240005）、中国科学院“百人计划”及上海市科学技术委员会项目（项目编号：23560750200）。

关键词：光纤成像、图像重建、锥形光纤、深度学习、散斑解码

摘要： 锥形光纤（TFs）的直径从数百微米逐渐缩小至微米级。与传统平面光纤（FFs）相比，锥形光纤在均匀照明、高效远距离信号采集以及低侵入性方面具有显著优势，适用于高灵敏度生物传感、光遗传学和光动力疗法。然而，由于渐缩结构会引发模间耦合，导致输出散斑图样发生畸变，并给使用现有深度学习方法进行图像重建带来挑战，因此利用单根锥形光纤实现高保真单次成像仍未得到充分探索。在此，我们提出一种受物理机制启发的 TF-UNet 架构，通过分层分组多层感知机融合增强跳跃连接，从而有效捕获锥形光纤中模间耦合所导致的非局部跨尺度依赖。我们在平端光纤和锥形光纤上对该方法进行了实验验证，结果表明，TF-UNet 在保持具有竞争力的峰值信噪比（PSNR）的同时，在结构保真度和感知保真度方面均优于标准 U-Net 变体，且复杂度为二次。我们的研究为利用微米级超细光纤进行深度学习成像提供了一种前景广阔的方法，可在 512×512 重建矩阵上实现无扫描单次重建；此外，我们还在具有生物学意义的神经元和血管数据集上验证了该框架，可用于进行具有物理可解释性的表征。

(† Mingliang Xu 和 Fangyuan Li 对本项工作贡献相同。)

1. 引言

光纤组件，包括平端光纤、光纤束和梯度折射率透镜，在先进成像和传感中发挥着至关重要的作用，连接了精密光子学与生物医学工程。[1-6] 它们克服了传统内窥镜的若干关键局限，例如体积庞大和侵入性强，从而实现细胞级分辨率、实时深层组织成像以及动态生理监测。[7-9] 然而，在保持信号保真度、确保生物相容性和进一步微型化方面，仍然面临挑战。[10-12] 例如，平端光纤中有多种空间模式传播，会导致空间色散和模间耦合。[13] 平端光纤束常受数值孔径（NA）和空间分辨率的限制，这些限制源于像素化以及相邻光纤之间的串扰。基于梯度折射率透镜的内窥镜通常采用直径为数百微米的探针杆，虽已实现深层组织成像，但通常受限于体积庞大的外形和有限的视场，因此难以长期植入，且可能干扰周围的生物组织。[9] 即使是最近报道的一种“超细”扫描内窥镜，其探针杆直径也达到~110 μm，并且依赖复杂的波前整形或机械扫描，这会增加系统复杂性、提高对运动伪影的敏感性，并加大功耗。[12] 目前，使用芯径为<10 μm的单根光纤实现高分辨率单次成像，仍是一项重大挑战。近年来，具有超细尖端的锥形光纤（TF）已成为极具潜力的生物接口工具，可用于深脑光遗传调控、[14]深度分辨光纤光度法、[15] 无伪影光纤电极，[16] 以及用于小鼠脑代谢监测的体内拉曼光谱学。[17] 与光传递高度局域化的平端光纤（FF）相比，锥形光纤沿长度方向逐渐变细，[18] 从而能够在更大范围内实现更均匀的照明。然而，这种轴向变化几何结构会引发模间耦合，而模式振幅沿轴向的演变受局部传播常数失配 $\Delta\beta$支配。随着波导尺寸沿传播方向变化，不同模式会经历不同的有效折射率，导致其相位

速度出现分歧。这会导致同向传播的模式之间持续交换功率，破坏信号传输的稳定性。此外，模式场之间的空间重叠沿结构不断变化，进一步影响耦合动力学。在光纤光学或集成光子器件中，这一现象会通过加剧模态色散和串扰，降低系统性能，并限制带宽和传输效率。而在光纤成像重建中，它会削弱基于多模光纤的逆求解器（如传输矩阵方法和深度学习方法）的有效性，降低其在不同配置间的迁移能力。因此，需要能够捕捉锥形几何结构下非局部跨尺度依赖的几何感知反演技术。[3,19]

与此同时，人工智能驱动的计算光学正成为克服这些挑战的有力解决方案。针对从生物医学内窥镜到高保真图像传输的光纤应用，已提出多种图像重建方法，[4,20] 包括基于传输矩阵理论的方法、[21,22] 用于动态像差校正的实时自适应光学，以及深度学习驱动的解决方案。[23-35] 尽管取得了这些进展，传统注意力机制仍无法显式建模空变映射，这可能在强模间耦合条件下削弱鲁棒性。尽管基于U-Net的模型 [36] 已证明在浑浊介质中重建图像的有效性，但在复杂光场或强模间耦合条件下，其对非局部特征提取 [26,30,37] 的能力有限。尽管多层感知机通过全局空间混合能够有效建模非局部依赖，但其O(n2)计算复杂度对高分辨率散斑图像重建构成限制。[38] 由于锥形光纤中正向映射具有非局部、空变特性，现有方法难以捕获全局上下文信息。此外，以往大多数研究依赖于超过10,000个样本的数据集，或在简化的基准测试条件下运行，而实际部署则需要数据高效模型以及能够处理高分辨率输入的模型。

克服这些局限需要采用自适应重新校准策略、将空间上下文纳入学习框架，或开发能够显式考虑光纤内模式耦合与传播动力学空间变化的物理信息模型。在本研究中，我们提出TF-UNet，通过分层分组多层感知机融合增强跳跃连接，以适应锥形光纤所施加的空变映射。这些物理先验通过跳跃路径中的分组多层感知机融合以及正交性正则项来实现。分组多层感知机能够以通道高效的二次计算代价实现高阶、跨通道和空间映射，从而促进跳跃连接内的模式解耦。同时，该正则项促进与具有物理意义的模式分离相一致的去相关通道表示。通过使用来自平端光纤和锥形光纤的仅强度二值散斑—掩模对训练模型，并评估其结构相似性指数、多尺度结构相似性指数、学习感知图像块相似度、[39,40] 峰值信噪比性能和皮尔逊相关系数，我们通过实验证明，与U-Net基线相比，TF-UNet实现了更优的结构和感知质量，同时在显著降低内存消耗的情况下保持了具有竞争力的峰值信噪比水平。我们的研究结果表明，TF-UNet是利用超薄微米级光纤进行高保真图像重建的一种有前景的方法，支持其在未来稳健体内应用中的潜力。

2. 理论

如图1(a)所示，TF 被建模为一根阶跃折射率多模光纤，其纤芯半径 $a(s)$ 沿轴向坐标 s 平滑变化。局部锥角定义为 $\theta(s) = \arctan(da/ds)$。由于锥形端通常用于激发与收集，其锥形侧壁会导致传播模式因几何结构而发生叠加。[14-16,18,30] 这构成了一种与 s 和 θ 相关的波导几何结构，其中局部 V 数 $V(s) = {}^{2\pi a}{}_{(s)}\ \lambda$ 数值孔径 沿渐缩段变化。随着 $V(s)$ 变化，受支持的线偏振（LP）模式集合及其传播常数 $\{\beta_m(s)\}$ 也随之演变。初始模式组成和传播模式均具有空间依赖性，导致远端散斑

场呈现空变统计特性，即散斑图样的强度分布、相关特性和随机性会随光线从光纤近端入射的位置和方式而变化。因此，基于平稳性假设的标定或学习型逆模型–通常用于通过平端光纤进行成像或光学聚焦—在适用性方面存在根本局限。这些模型通常假设光纤的输入输出关系在不同输入条件下保持一致；然而，由于散斑场具有空变特性，此类假设仅在特定标定点附近狭窄的轴向和方位角范围内成立，无法可靠地泛化到不同的锥形光纤位置。 [4,21-23]

在弱导引条件下，每个位置 s 处的线偏振模构成一个正交归一基，可沿渐缩段进行平行移动。几何影响源于横截面轮廓的逐渐变化：在锥度变化率的最低阶近似下，非对角耦合的尺度关系为 $\kappa mn(s) \propto a'(s)/a(s)\ \Omega mn(V(s))$，其中$\Omega mn(V(s))$ 是一个 O(1) 的无量纲重叠因子，它遵循方位角选择定则——具有相同方位角指标 l 的模式之间耦合最强，不过微小的不对称性可能会稍微放宽这一限制。随着半径增大，模式分支之间的传播常数间隔遵循幂律 $\Delta\beta mn(s) \propto a(s)^{-2}$ 逐渐减小；远离截止时，该间隔几乎不受数值孔径（NA）的影响。在扩径锥形光纤中，这两种尺度变化趋势彼此相反：κ增大，而Δβ 减小。二者之比定义了局部绝热参数 $\alpha(s)$；以模间传播常数间隔为参照衡量时，该参数随几何扰动强度增大。α 较小时表示绝热传输，而数值较大则表明存在以显著模式交换为特征的非绝热区域。

尽管非绝热耦合是在局部定义的，但它对图像形成的影响是累积的：我们将局部耦合率视为线密度，并沿传播路径积分，以获得渐缩段上的累积耦合度量。该度量朝大半径端增大——在该处，与 $a(s)$ 相关的几何因子

以及 $a'(s)$ 均较大——且还会受到谱因子的进一步增强，该因子随导模数量 M 的增加而增大。在模态截止阈值附近，较小的模间传播常数间隔（$\Delta\beta \to 0$）会增大耦合系数 κ_{mn}。此时，双模约化可采用朗道–齐纳跃迁模型，而该模型要求恰好在新模式出现的位置降低渐缩段的锥度变化率。当模态色散曲线接近包层光线时，与辐射模的耦合也会增强，从而削弱可逆性／反向传播保真度。

对于半径恒定的平端光纤，$a'(s) \equiv 0$，传播算符在局域模态基中实际上是对角的，从而抑制模间功率交换，并仅允许各导模沿程发生确定性的相位累积。相比之下，在 $a'(s) \neq 0$ 的锥形光纤中，导模之间以及导模向辐射模的耦合不可避免，并会沿光纤长度累积。因此，在端部孔径相同的情况下，光从锥形端注入、从平端收集的成像配置，天然比平端光纤中的配置稳定性更差，也更难求逆。其根本原因在于，局部耦合系数按 $\kappa \sim a'/a$ 的尺度变化，而模间传播常数失配按 $\Delta\beta \sim 1/a2$ 的尺度变化。**图 S1**定量比较了数值孔径相同的锥形光纤与平端光纤的累积耦合度量及其轴向密度（见**补充信息**）。

3. 实验

3.1. TF 散斑数据集构建

该数据集包含 13,440 对散斑–掩模（TF 和 FF 各 6,720 对），对应一个 512×512 重建矩阵。我们使用分层抽样从 ImageNet [41] 中随机抽取了 6,720 张自然图像，以确保类别平衡；对于每张选中的图像，均按照各自经过校准的采集流程分别采集一次 TF 散斑测量和一次 FF 散斑测量，因此 TF 和 FF 观测共享相同的底层目标。由于光场

强度与图像灰度之间存在非线性映射，且高灰度图像会使数字微镜器件（DMD）的加载时间呈指数增长，因此 ImageNet 实验采用二值灰度级，并按 8:1:1 的比例将数据集划分为训练集、验证集和测试集；每种光纤类型对应 5,376/672/672 对。预处理步骤包括：(1) 居中并裁剪，以最大限度保留正方形区域；(2) 双三次缩放，使图像尺寸与 DMD 的感兴趣区域（ROI）相匹配；(3) 生成二值掩模。使用 DMD-光纤耦合装置采集退化散斑图像：将每张预处理后的自然图像转换为单比特二值掩模，并通过强度阈值处理后显示在一台 2716×1600- 像素 DMD（HDSLM54D67，±17.5° 镜面倾角，中国）上，随后使用一枚 10× 物镜（数值孔径 = 0.25，工作距离 = 10.6 mm，奥林巴斯，日本）照射 TF 的锥形端（数值孔径 = 0.39，有效长度 = 2.5 mm，OptogeniX，意大利）。通过一枚 20× 物镜（数值孔径 = 0.40，工作距离 = 1.2 mm，奥林巴斯，日本）和一枚平凸透镜（f = 30 mm，Thorlabs，美国），使用 CMOS 相机（STC- MBA1002POE，3856×2764，Sentech，日本）捕获产生的输出散斑，并将曝光时间优化为 10 - 500 ms，以最大化信号强度。数据集按 8:1:1 的比例划分为训练集、验证集和测试集。

图1(a) 展示了利用锥形光纤进行图像重建的概念：一根尖端直径为5 μm的超细锥形光纤用于采集并传输自然图像，其输出端面产生的散斑图样用于借助我们提出的TF-UNet重建原始入射图像，该方法稍后将予以说明。 **图1(b)**给出了由连续波532纳米半导体激光器（Lighthouse Photonics，美国）照明的基于DMD的装置的原理图与实验系统。激光输出经准直并扩束，形成直径为9毫米的光束，随后照射工作于离轴闪耀模式的DMD。双胶合透镜（f = 150 mm）将调制光束中继至10×物镜，该物镜将图像图案耦合进入锥形光纤的锥形端。物镜的数值孔径经仔细选择，以与光纤的数值孔径（数值孔径= 0.39）相匹配，从而优化耦合效率与模式选择性之间的权衡。经锥形光纤传输后，输出光场形成复杂的

散斑图样，由一个由20×物镜（数值孔径 = 0.40）和平凸透镜（PCX，f = 30 mm）组成的4f成像系统收集，随后由CMOS相机捕获。

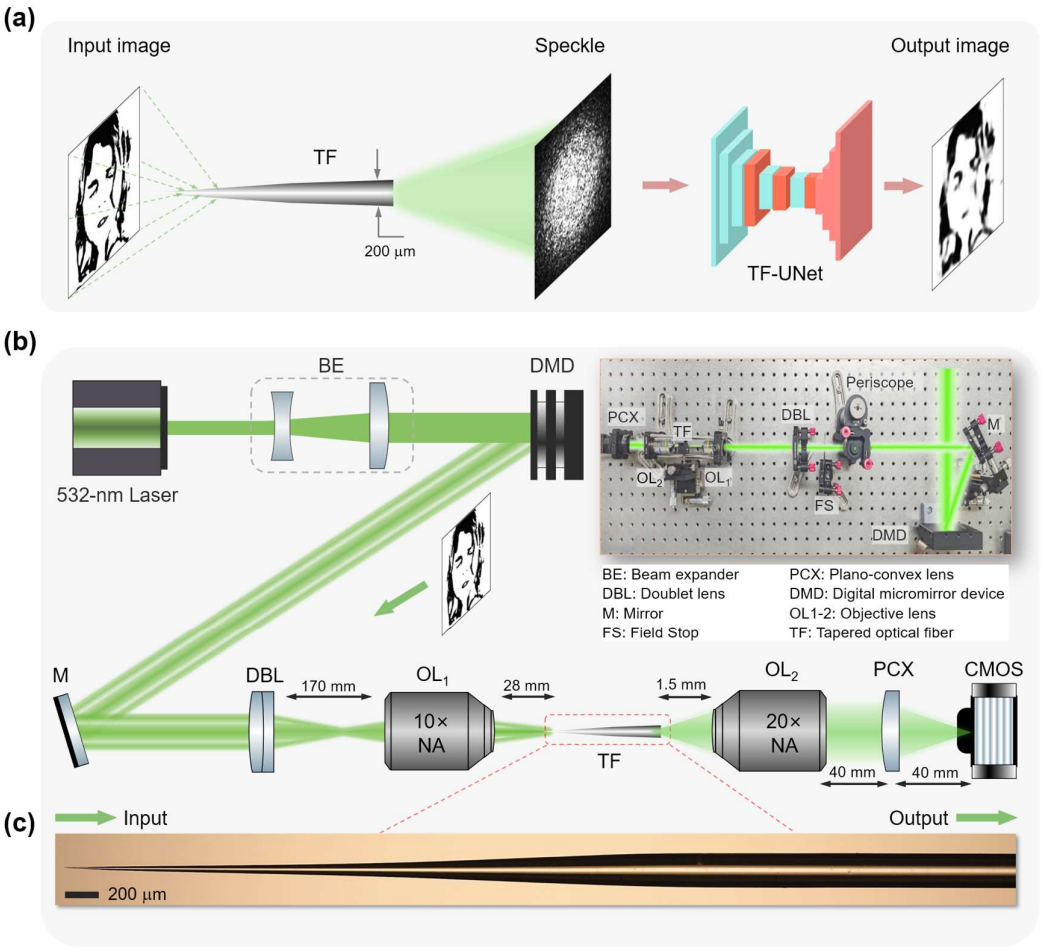


图1. 基于学习的锥形光纤图像重建示意图及实验装置。（a）图像数据集构建示意图和锥形光纤UNet（TF-UNet）架构。输入图像经锥形光纤传输后生成空间变化散斑图案，随后由TF- UNet解码，以重建原始图像。**（b）**数据采集的光学布局：532 nm激光束经过可选的扩束器后，照射到数字微镜器件（DMD）上，由其生成与自然图像对应的结构光图案。经调制的光通过由消色差双合透镜（DBL）和10× 物镜（OL_1）组成的成像系统中继传输，将图像投射到锥形光纤的锥形端。在输出端，由20× 物镜（OL_2）和平凸透镜（PCX）组成的中继耦合光学系统收集生成的散斑图样，并由CMOS相机捕获。插图展示了实验装置的照片

设置。(c) 用于 (b) 中图像重建的锥形光纤（数值孔径 = 0.39，作用长度 = 2.5 mm）的光学显微图。

3.2. TF-UNet 架构的构建

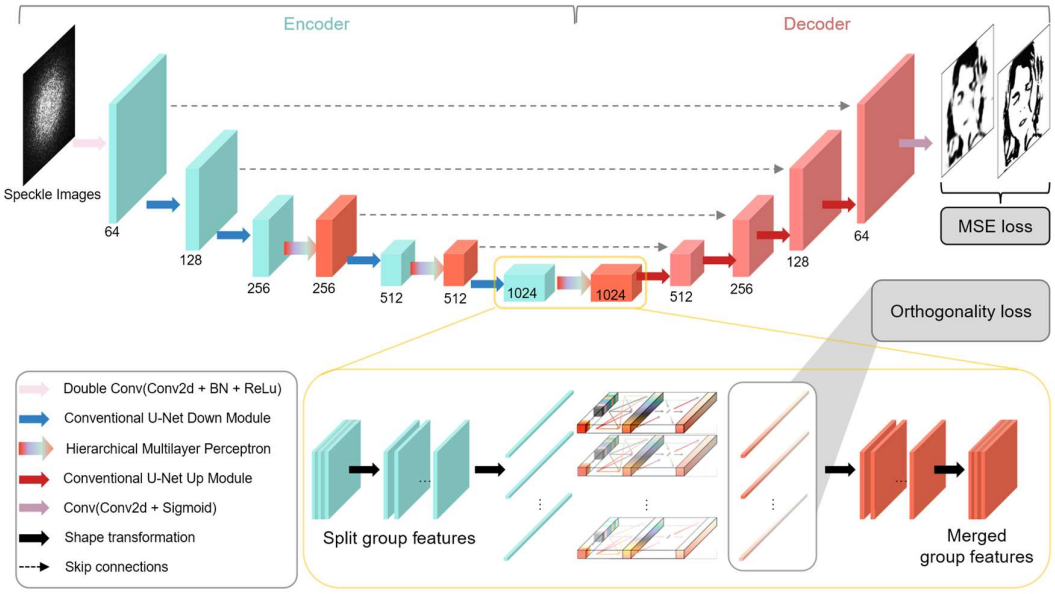


图 2. 用于解码空间变异散斑场的 TF-UNet 架构。采用具有四个尺度和跳跃连接（虚线箭头）的编码器–解码器主干网络处理输入散斑图像。下方的数字表示通道宽度。在瓶颈层，拆分–合并分组模块沿通道维度将通道拆分为若干组，对每组应用基于分层多层感知机的变换，以实现几何感知的非局部混合，然后拼接并投影各组输出，形成合并后的组特征。随后应用正交性正则项，确保组基彼此去相关，最后通过一次 1×1 卷积和 Sigmoid 激活生成重建结果。

我们提出了 TF-UNet，这是一种专为通过锥形光纤进行散斑重建而设计的 U-Net 架构，如图 2 所示。该设计借鉴了锥形光纤中的光传播动力学：轴向变化几何结构通过模间耦合，引发输入输出散斑映射的空间变异性。TF-UNet 通过在跳跃连接中加入基于分组多层感知机的分层特征融合模块，增强了跳跃连接。该设计实现了非局部的高阶跨尺度交互，使来自多个编码器阶段的富含几何信息的特征能够在解码器中融合之前交换信息。特征首先通过卷积层进行细化，随后由分组多层感知机模块处理，以实现跨通道与跨空间融合，从而有效捕捉几何相关依赖，并促进强耦合条件下的模式解耦。

通过将融合操作融入跳跃路径，TF-UNet 致力于捕捉高频细节并确保几何一致性，同时保留标准的编码器–解码器主干网络，以确保结果可复现。

具体而言，我们将分层分组多层感知机融合应用于跳跃路径，并在四个编码器尺度上采用分阶段分组方案（从浅到深：0/1/2/4，其中 0 表示在该尺度禁用融合）。该方案使通道混合能力与逐渐减小的特征图尺度相匹配，并可根据任务复杂度和重建矩阵大小进行调整。当分组设置为 1/1/1/1 时，该模块便退化为标准的非分组多层感知机。在每个插入点，编码器特征 $X \in \mathrm{R}^{B\times C\times H\times W}$ 被划分为 G 组$\{X^{(g)}\}_{g=1}^{G}$，每组包含 C_g 个通道。随后，每组 $X(g)$ 沿空间维度展平为长度为 $N = H \cdot W$ 的序列，得到 $X^{(g)} \in \mathrm{R}^{B\times C_g\times N}$；接着，两个共享的非线性层沿空间轴进行运算，每组

$$Z^{(g)} = \phi_2\left(W_2^{(g)}\phi_1\left(W_1^{(g)}X^{(g)}\right)\right) \quad (1)$$

其中，每个 ϕ_k 表示先进行层归一化，再经过 ReLU； $W_k^{(g)} \in \mathrm{R}^{N\times N}$表示在组 g 的 C_g 个通道间共享的空间非线性映射。所有组的输出都会重塑为 (H, W)，并沿通道维度拼接，形成供解码器使用的融合跳跃特征。每个块中，由于每个 G 组都使用一个在其通道间共享的 $N \times N$ 空间非线性映射，主要的参数和计算开销为 $\Theta(GN^2)$（两个线性层： $2GN^2$），而逐通道空间全连接映射的开销为 $\Theta(CN^2)$。因此，与逐通道基线相比，分组变体将参数数量和计算负载降至约 $(G/C)\times$ 。

为促进与模式解耦相一致的通道间去相关，我们在编码器的最深阶段引入正交损失。设 $F \in \mathrm{R}^{C\times N}$ 表示将空间维度展平后得到的均值归一化特征矩阵，其中$(N = H \cdot W)$，并将通道排列为行。我们计算通道间格拉姆矩阵

$$G = \frac{1}{N} FF^{\top} \in \mathbb{R}^{C \times C} \quad (2)$$

并将正交性定义为以下形式并最小化：

$$L_{\text{ortho}} = \|G - I_C\|_F^2 \quad (3)$$

其中，I_C 是 $C \times C$ 单位矩阵，$\| \cdot \|_F$ 表示弗罗贝尼乌斯范数。该损失促使各通道之间实现统计独立，从而强制去相关。

重建损失通过预测输出 $\hat{Y}$ 与真实值 Y 之间的均方误差（MSE）计算：

$$L_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^{n} \left\| \hat{Y}_i - Y_i \right\|_2^2 \quad (4)$$

总体目标函数结合了像素级精度与通道去相关：

$$L_{\text{total}} = L_{\text{MSE}} + \lambda L_{\text{ortho}} \quad (5)$$

其中，λ 控制正则化强度。

我们使用通过**图1(b)**所示装置采集的散斑图样和目标图像配对数据集，对模型进行端到端训练。网络通过最小化L_{total}，学习将畸变散斑映射为重建结果。基线方法（包括U-Net变体和面向FF的深度学习方法）采用相同的训练方案。模型在NVIDIA A100 80 GB GPU上训练60轮，批量大小为8，并使用随机梯度下降和ReduceLROnPlateau进行学习率调度。

3.3. 指标评估

除 PSNR (↑) 和 SSIM (↑) 外，我们还报告 MS-SSIM (↑)、LPIPS (↓) 和皮尔逊相关系数 CORR (↑)，以综合评估像素精度、感知保真度和全局统计一致性。所有指标均在固定且配准的感兴趣区域内，基于线性缩放图像计算（强度范围为 [0,1]）。对于解码由 TF 生成的散斑，我们采用互补指标来揭示这些权衡，而不是将其掩盖，因为较低的像素误差往往以牺牲纹理或导致跨尺度的结构漂移为代价。MS-SSIM 通过高斯金字塔

分解扩展了 SSIM，使其能够评估多个尺度上的粗结构和细节。它将最粗尺度的亮度 l_M 与各尺度 j 的对比度–结构乘积结合起来，形成加权几何平均

$$\mathrm{MS-SSIM}(x,\hat{x}) = l_M(x,\hat{x})^{\alpha_M} \prod_{j=1}^{M} mcs_j(x,\hat{x})^{\beta_j} \tag{6}$$

其中，指数在不同实现中均为固定且一致的。这种多尺度方法能够有效检测由模间耦合引起的跨尺度不一致性；模间耦合可能会对锥形光纤渐缩段传输区域的低频布局和高频边缘保真度产生不同影响。

学习感知图像块相似度（LPIPS）在固定的深度特征空间中测量感知差异，而非在像素（RGB）空间中测量。令 $f_\ell(\cdot) \in \mathrm{R}^{H_\ell \times W_l \times C_l}$ 表示从预训练网络 ϕ 的第 l 层提取的冻结特征图（我们使用经过“lin”标定的 AlexNet）。ϕ 的输入会归一化到 $[-1,1]$ 范围，以匹配官方 LPIPS实现。在每个空间位置，特征会沿通道维度进行 L2归一化。随后，将平方差按通道加权求和，在空间位置上取平均，并在各层间汇总，以此计算 LPIPS 距离：

$$\mathrm{LPIPS}(x,\hat{x}) = \sum_{\ell} \frac{1}{H_\ell W_\ell} \sum_{h,w} \left\| \mathbf{w}_\ell \odot \left(\hat{f}_\ell(x)_{h,w} - \hat{f}_\ell(\hat{x})_{h,w} \right) \right\|_2^2 \tag{7}$$

其中，$\mathbf{w}_\ell \in \mathrm{R}_{\geq 0}^{C_\ell}$ 是通过官方校准学习得到的非负通道权重。数值越低表示相似度越高。由于采用了通道归一化和深层语义特征，与峰值信噪比或单尺度SSIM相比，LPIPS 对整体亮度或对比度变化不那么敏感，并且能更好地保留对纹理和边缘结构的判断。不过，它并不能完全消除光度变化的影响。

在TF特定物理约束下，使用包含6,720组散斑–真实值对的高分辨率数据集，将TF-UNet的重建性能与五种重要的U-Net变体进行比较：传统U-Net、[36] 循环残差增强型R2- UNet、[42] 混合注意力驱动TransUNet、[43] 基于生成模型的VQVAE2[44]以及MSMDFNet[26]。MSMDFNet代表了当前

FF图像重建领域的先进水平，而其他模型则涵盖了图像复原中的主要深度学习范式：CNN编码器-解码器架构、循环残差网络、Transformer增强模型和生成式离散潜变量模型，因此构成了均衡的基线。将这些基线模型用于TF图像重建时，可见其存在明显局限：R2-UNet的固定上下文循环能够捕捉短程变化，却无法建模由渐缩段几何形状引发的模间耦合所导致的长程几何相关性，并且对超参数调优较为敏感。TransUNet具备全局上下文感知能力，但受二次注意力复杂度和记忆限制，在512×512 重建矩阵下计算开销过大，因而难以解析细尺度的直径梯度相关性。相比之下，TF-UNet在跳跃路径中引入了基于MLP的增强型分层融合，从而能够学习跨尺度和非局部交互，并适应锥形光纤的几何耦合特性。本文报告的所有定量结果，均是在相同协议下使用不同随机种子和参数初始化进行五次独立训练与评估所得，并以均值± 标准差汇总。

3.4. 神经元与血管验证数据集的构建

此外，我们还构建了神经元和血管数据集，以评估在可行的采集预算下，所提出的框架能否应用于二值化 ImageNet 掩膜之外的数据。对于神经元数据，我们使用了一个深层皮层钙成像数据集，该数据集由一台自由活动式微型双光子显微镜（FHIRM-TPM 3.0）采集。[45] 从录制的视频中提取了 4,440 帧，将其统一缩放，并转换为 512 × 512 像素的灰度图像，每张图像量化为 64 个灰度级。我们使用 3,552 张图像进行训练，444 张进行验证，并使用来自独立视频的 444 帧进行测试，从而确保测试集与训练视频流在时间上不连续。按照当前配置，采集一幅神经元散斑测量图像（包括图样加载和 CMOS 曝光）每幅目标图像约需 1 分钟。

对于血管数据，我们使用了一个通过双光子显微成像获取的啮齿类脑脉管数据集（MiniVess），其中原始三维图像堆栈经过二值化处理，以突出显示血管结构。[46] 在预处理中，每个三维体沿深度方向划分为多个子体积。对于每个子体积，沿深度方向对切片进行投影，以生成二维血管图像。通过旋转增强，将数据集扩充至 4,000 张二值化血管图像，并按 3,200/400/400 的数量划分为训练集/验证集/测试集。对于这两个验证数据集，目标图像均显示在 DMD 上，并通过与 ImageNet 实验相同的光学链路和配准流程采集对应的散斑图样，从而生成配对的散斑-真值数据，以便在匹配的实验方案下训练和评估模型。

4. 结果

4.1. 使用锥形光纤进行图像重建

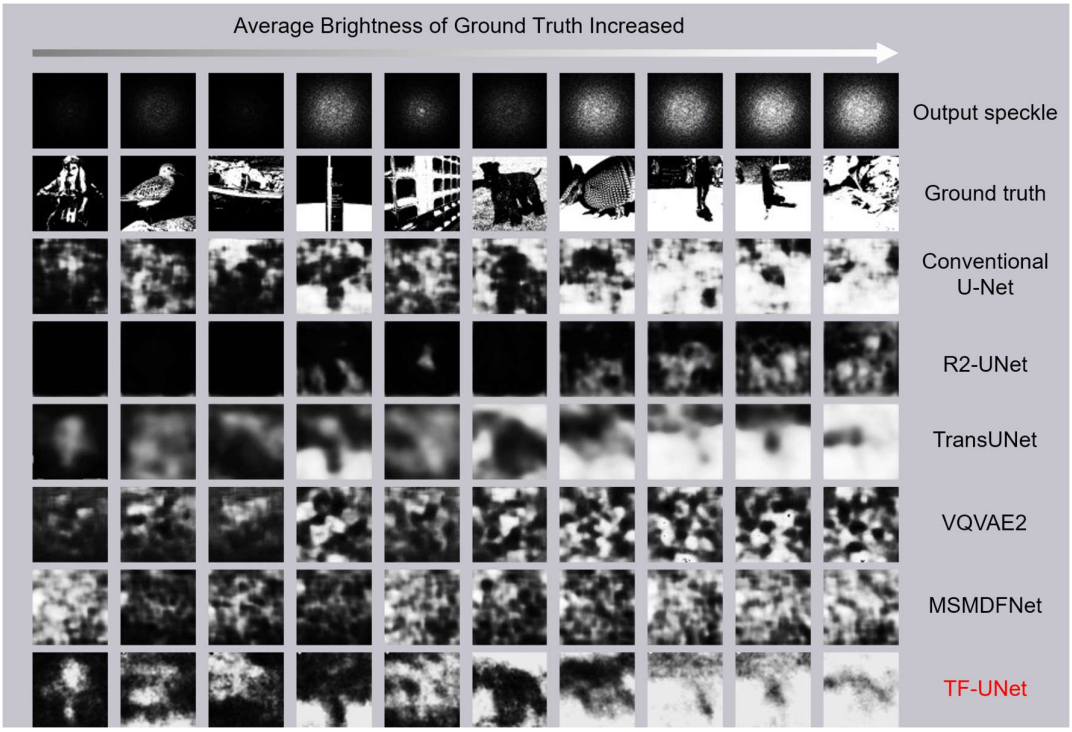


图3。 ImageNet 图像经锥形光纤传输后，采用多种神经网络方法进行重建的测试结果。测试样本根据平均灰度值按升序通过确定性采样排列。第1行：光纤输出端的原始散斑图样，图像质量严重下降。第2行：对应的真值图像。其余各行：UNet、R2-UNet、TransUNet 的重建结果，

分别为 VQVAE2 和 MSMDFNet。最后一行：使用所提出的 TF-UNet 进行重建。

如**图3**和**表1**所示，我们在 TF散斑–掩膜数据集上，使用峰值信噪比、结构相似性指数、多尺度结构相似性指数、学习感知图像块相似度和皮尔逊相关系数（相关系数）这五项指标，对 TF-UNet 与五种代表性架构（UNet、R2-UNet、TransUNet、VQVAE2 和 MSMDFNet）进行了基准测试。在渐缩段引起的空间变异前向映射下，所有方法均处于强耦合状态，这压缩了像素级评分的差异，使感知和结构层面的差异更加显著。TF-UNet 的结构相似性指数和多尺度结构相似性指数表现最佳；相关系数与 TransUNet 并列最佳（0.50）；峰值信噪比（9.17 dB，仅次于 TransUNet 的 9.63 dB）和学习感知图像块相似度（0.64，仅次于 R2-UNet 的 0.61）也具有竞争力。在基于卷积神经网络的基线方法中，UNet 在所有报告指标上的表现均稳定优于 MSMDFNet，而 VQVAE2 在此设置下的整体保真度最低。锥形光纤的轴向半径梯度会引入空变模间耦合（及泄漏），进而影响全局布局一致性和细尺度纹理的恢复。

作为背景对比，我们还在平切光纤（FF）上评估了相同的重建流程。平切光纤中的传播更接近稳态输入–输出映射，因此在相同实验方案下可能获得更高的重建评分。FF 的结果见**补充信息**（**图S4**和**表S4**）。

表1. 不同神经网络深度学习范式下锥形光纤图像重建性能的定量比较。与基线方法 UNet、R2-UNet、TransUNet、VQVAE2 和 MSMDFNet 相比，所提出的 TF-UNet 性能更优或具有竞争力。所有结果均为五次独立运行的平均值，并以均值± 标准差的形式报告。最佳结果以红色突出显示（↑最高，↓最低），次佳结果以橙色突出显示。

	峰值信噪比 ↑	结构相似性指数 ↑	多尺度结构相似性指数 ↑	学习感知图像块相似度 ↓	相关系数 ↑
UNet	8.98±0.45	0.18±0.02	0.22±0.02	0.69±0.03	**0.39±0.02**
R2-UNet	5.5±0.30	**0.22±0.02**	0.18±0.01	**0.61±0.02**	0.10±0.01
TransUNet	**9.63±0.32**	**0.22±0.01**	**0.31±0.02**	0.67±0.03	**0.50±0.03**

VQVAE2	6.24±0.13	0.12±0.01	0.13±0.01	0.75±0.03	0.04±0.01
MSMDFNet	6.43±0.29	0.14±0.01	0.13±0.01	0.72±0.04	0.03±0.01
TF-UNet	**9.17±0.27**	**0.24±0.02**	**0.32±0.02**	**0.64±0.05**	**0.50±0.03**

与使用平端光纤进行重建相比，TF-UNet 在 TF图像重建中实现了良好的平衡：在结构相似性指数/多尺度结构相似性指数上排名第一，在学习感知图像块相似度上排名第二（0.64，而 R2-UNet 为 0.61），并列获得最佳相关系数（与 TransUNet 均为 0.50 ），尽管各项指标的整体性能均有所下降。这些结果表明，TF-UNet 能够稳健应对 TF诱导的非均匀模态间耦合、轴向模式变化和空间异质性，同时可靠地保留结构细节和感知质量。

4.2. 神经元与脉管成像数据的生物学验证

具有毫米级可植入有效长度的锥形光纤已广泛应用于动物脑生物接口。[14-18] 这主要是因为与传统平面光纤相比，它们的侵入性极低，因此能够在啮齿动物中实现长期稳定的深脑接口。如**图4(a)**所示，锥形直径可降低光纤与神经组织之间的机械失配，从而最大限度地减少慢性免疫反应和胶质瘢痕——这些都是坚硬且体积庞大的植入物常见的问题。[47-49] 这使TF能够长期保持在神经元附近，确保稳定的光传递和信号采集。这种设计还有助于精准靶向海马体、丘脑和黑质等深部脑结构；这些区域对于研究记忆、睡眠调节和帕金森病至关重要，却难以通过传统光学成像方法进行观察。我们初步提出使用TF进行小鼠深部脑的微创植入式生物成像重建，如**图4(a)**中的概念验证示意图所示。为验证TF-UNet对生物样本的适用性，我们将相同的TF采集与重建流程应用于64灰度级小鼠脑钙成像和脉管系统数据集，重点考察形态恢复及其对下游生物学读出的影响。

如**图4(b)所示，**与传统UNet相比，TF-UNet在钙成像重建中生成的神经元形态连贯性显著更高。实际分析的关键并非孤立亮斑的清晰度，而是网络能否恢复完整、连续的神经元结构，从而稳定地定义区域。UNet重建结果呈碎片化且形态不完整，而TF-UNet则保留了更连续、易于解读的神经元形态及灰度强度变化。为评估其物理可解释性，我们测量了标注强度剖面的半高全宽（FWHM），在一个典型示例中，TF-UNet的测量值为~15 μm。凭借良好的形态恢复效果，TF-UNet还能对钙事件进行详细的时间序列分析（**图4(c- d)**）。它在不同时间点保持一致的空间形态，因此能够稳定定义单个神经元的感兴趣区域，并可靠地提取钙信号轨迹。代表性的$\Delta F/F_0$ 轨迹显示，TF-UNet能够紧密跟随多个神经元的真实时间波动（**图4(d)**）。我们使用重建曲线与真实$\Delta F/F_0$ 曲线之间的余弦相似度量化轨迹级一致性；在相同实验方案下，皮尔逊相关系数达到0.81。这些结果表明，TF-UNet重建能够支持通过TF进行钙成像，其中可靠的形态恢复对于还原强度动态至关重要。我们还在一个脉管系统数据集上测试了TF-UNet（**图4(e)**）：TF-UNet从TF输出散斑中重建出连通的血管网络，且具有清晰的连续性，并能够分辨数十微米尺度的精细血管结构（代表性示例分别标注为20 μm、15 μm和15 μm）。这些测试结果表明，学习到的逆映射能够迁移至源自ImageNet的先验之外、具有结构化特征的生物形态。

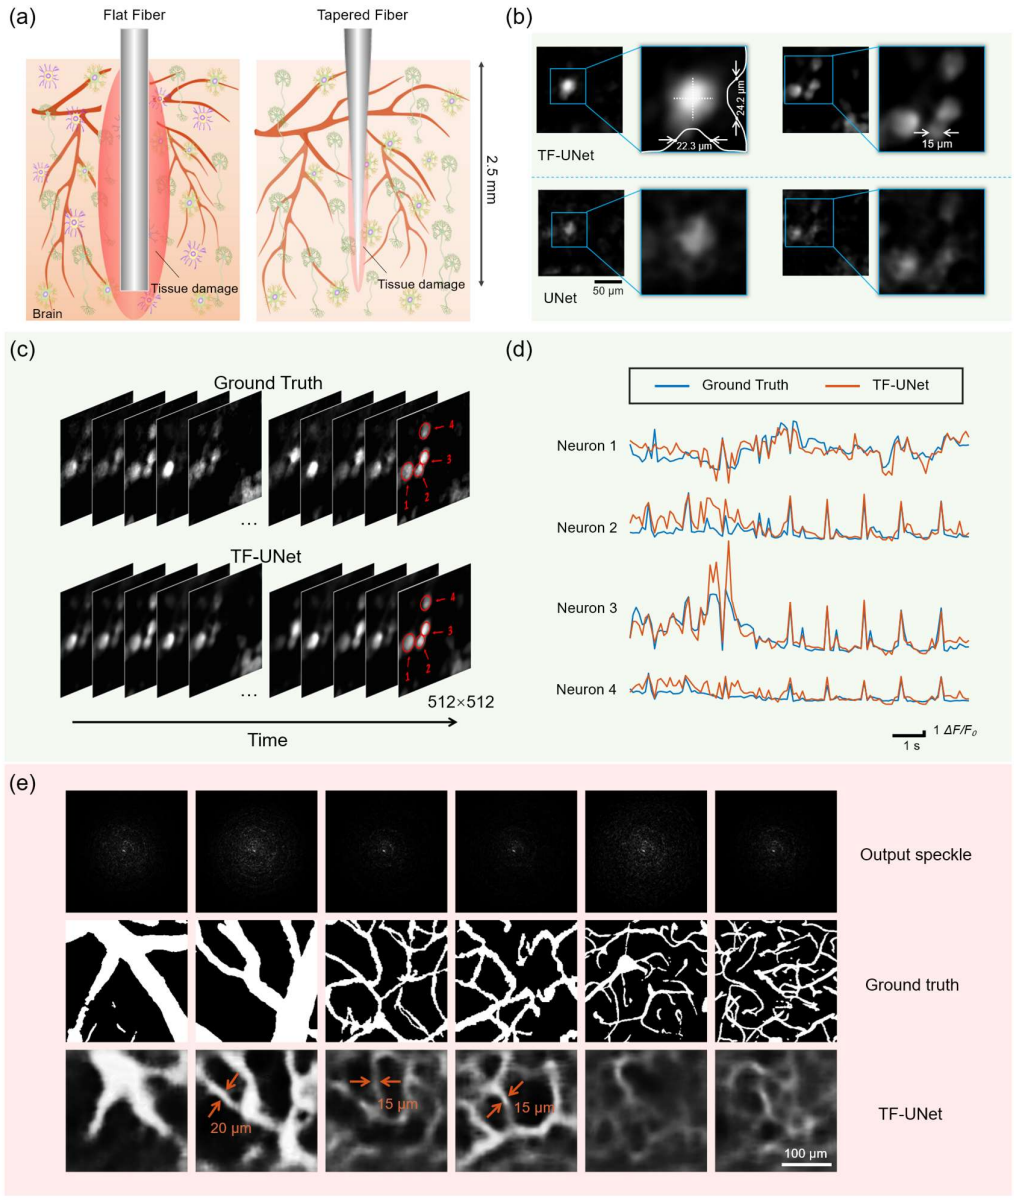


图4。 TF UNet在啮齿动物脑钙成像和脉管系统数据上的生物学验证。（**a**）使用平端光纤（FF）和锥形光纤（TF）进行小鼠深脑成像的概念验证比较。TF引起的组织损伤区远小于FF引起的损伤区，从而能够实现慢性稳定的深脑神经元与血管成像。（**b**）使用TF-UNet和传统UNet从TF输出散斑中获得的代表性钙成像重建结果。插图突出显示了与典型的、约为~15 μm且可分辨的单个神经元结构之间的紧密形态连续性。（**c**）示例时间序列（512×512），展示真实值帧以及TF - UNet进行的时间序列重建。红色圆圈和数字标出了钙事件的代表性感兴趣区域。（**d**）如（**c**）所示，提取的真实值（蓝色）和TF-UNet重建（橙色）神经元活动的钙信号轨迹（$\Delta F/F_0$）。（**e**）TF-UNet模型在脉管系统数据集上的验证。TF输出散斑（顶部）、真实值血管图像19

（中间），以及 TF-UNet 重建结果（底部）；标注示例展示了毛细血管尺度下连通血管结构的重建。

表 2. 使用不同深度学习架构在 Neuron数据集上进行图像重建的性能定量比较。与 UNet、R2UNet、TransUNet、VQVAE2 和 MSMDFNet 等强基线模型相比，TF-UNet 的结构相似性指数和学习感知图像块相似度最佳，同时在峰值信噪比/多尺度结构相似性指数/相关系数方面也具有竞争力。所有结果均为五次独立运行的平均值，并报告了方差。最佳结果以红色标示（↑最高，↓最低），次优结果以橙色标示。

	峰值信噪比 ↑	结构相似性指数 ↑	多尺度结构相似性指数 ↑	学习感知图像块相似度 ↓	相关系数 ↑
Unet	20.369 ± 0.272	0.661 ± 0.006	0.719 ± 0.009	0.358 ± 0.009	0.696 ± 0.023
R2-UNet	17.912 ± 0.197	0.443 ± 0.016	0.590 ± 0.009	0.445 ± 0.010	0.326 ± 0.022
TransUNet	**24.651 ± 0.294**	**0.715 ± 0.004**	**0.809 ± 0.010**	**0.289 ± 0.005**	**0.865 ± 0.013**
VQVAE2	19.202 ± 0.210	0.539 ± 0.013	0.662 ± 0.010	0.394 ± 0.010	0.527 ± 0.023
MSMDFNet	20.299 ± 0.302	0.665 ± 0.006	0.769 ± 0.009	0.321 ± 0.010	0.784 ± 0.021
我们的方法 TF-UNet	**22.616 ± 0.220**	**0.765 ± 0.011**	**0.773 ± 0.009**	**0.285 ± 0.020**	**0.860 ± 0.015**

总体而言，**图4**中的结果支持两点结论：(i) TF-UNet设计适用于灰度生物对比度，在这种情况下，结构完整性（而不仅仅是逐像素保真度）至关重要；(ii) 在TF诱导的空间变异耦合作用下，TF-UNet能够充分保留形态，从而实现对时间依赖性荧光动力学的恢复，这也为其在未来基于TF的功能生物成像场景中的应用提供了依据。

4.3. 性能、光子覆盖敏感性、尺度与重建矩阵比较

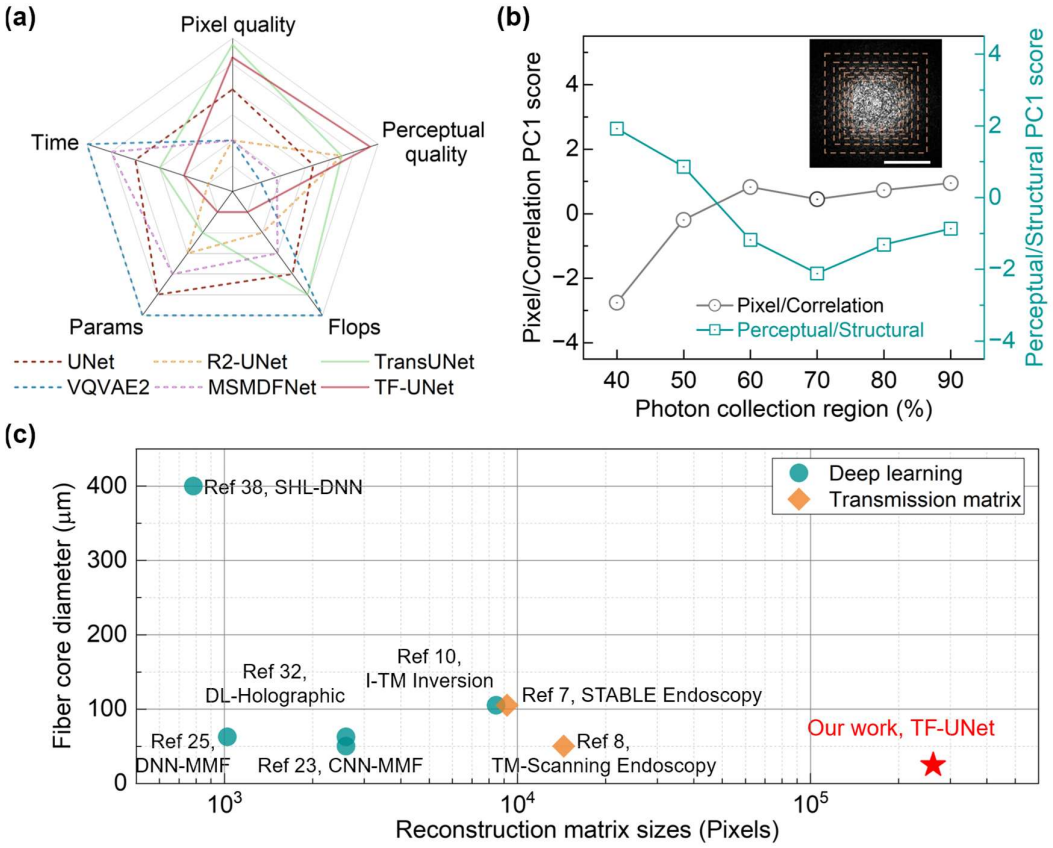


图5. 现有方法与所提出的 TF-UNet 在网络性能、光子覆盖敏感性、重建矩阵尺寸和纤芯轮廓方面的比较评估。(a) UNet、R2-UNet、TransUNet、VQ-VAE2、MSMDFNet 和 TF-UNet 在像素/相关系数及感知/结构指标上的雷达图基准比较，同时展示效率（浮点运算次数、参数量、推理时间）。**(b)**以嵌套孔径展示光子覆盖水平（40–90%）。主成分分析得到的 PC1 捕捉了指标随覆盖水平的变化。**(c)** 示意图展示了不同重建方法的重建矩阵尺寸和纤芯尺寸。

图5(a)展示了雷达图，总结了模型在准确率和效率两个维度上的排名。准确率维度由两类指标——像素指标和感知得分——的第一主成分（PC1）得出，并以综合度量表示。效率包括三个方面：乘加运算（浮点运算次数）、参数数量和推理时间。这些指标的得分经过反向处理，使较大的值对应较高的效率。TF-UNet

准确率最高（像素 = 5.25；感知 = 5.67），且效率排名第一或接近第一（反向得分：1.00、1.00、2.00），浮点运算次数为 2762.88 GFlops，参数量为 172.66 M个参数，推理时间为 1.504 秒。

为了更好地理解光子收集区域如何影响 TF 成像中的重建，我们进一步分析了逐像素指标和感知指标，并以严谨的方式将它们结合起来。我们将这些指标分为两类：逐像素指标（PSNR 和相关系数）以及感知指标（结构相似性指数、多尺度结构相似性指数和学习感知图像块相似度）。聚合前，我们对所有指标按半径进行 z分数标准化。我们对学习感知图像块相似度进行变换，使其数值越大始终表示质量越好。对于每一组指标，我们对指标-半径矩阵进行主成分分析，并将第一主成分（PC1）用作综合得分（**图5(b)**）。随着累积光子覆盖率从 40% 增至 90%，像素 PC1 稳步上升，而感知 PC1 则在接近 ≈70% 覆盖率处明显降至最低点。这种非单调性源于环带边际贡献机制：采样孔径从明亮的纤芯向外扩展时，首先纳入一个中半径环带，其中存在强烈的非绝热模间耦合和高度空变的正向映射，导致局部对比度和协方差失配，从而降低感知质量（$\Delta Q(r) < 0$）。超出这一范围后，辐照度和纹理迅速衰减，使 $\Delta Q(r) \to 0$，从而减弱先前的负面影响，并使感知 PC1 回升。相比之下，PSNR 这类由均方误差主导的指标受益于对低方差边缘像素进行平均，这解释了像素 PC1 为何持续上升。这些结果表明，应采用高光子效率的空间自适应采集与学习策略——例如，采用耦合感知注意力，以及由 PC1 引导的损失重加权，以突出信息密集核心区域，同时对中半径高耦合区域进行正则化。 **图5(c)** 对比了不同代表性方法的重建矩阵尺寸（N×N 像素）与光纤芯径。此前的报告集中在28×28–120×120 像素（784–14,400 像素），光纤/光纤束芯径为 50–400 μm；而采用锥形光纤的 TF-UNet 覆盖 20–200 μm 的芯径，并在微米级纤芯下达到 512×512 像素（262,144 像素）。

5. 讨论与结论

我们提出了 TF-UNet，利用单根微米级锥形光纤进行单次成像重建，其中轴向变化几何结构会产生复杂的散斑图样。我们的研究表明，将物理启发式融合直接整合到 U-Net 架构的跳跃连接中，是应对计算成像中空变模间耦合挑战的一种强大而有效的策略。通过将光传播的物理模型嵌入网络的信息流中，该架构能够内在地遵循基础光学原理，在提高重建精度的同时保持计算效率。这种方法不仅提升了图像复原任务中的 PSNR 和结构相似性指数等定量性能指标，也增强了定性保真度，尤其是在存在复杂几何相关畸变的区域；传统卷积网络难以对这类畸变建模。[24,30,28,33,36,39]

与采用相干光纤束、[3,2,5,50] 直径数百微米的梯度折射率透镜[6,9,12,51] 或超薄全息/扫描内窥镜[4,8] 的传统基于光纤的技术相比，我们的方法另辟蹊径，通过免除主动扫描或波前控制的需求，实现宽场成像——这些特性对于植入式生物成像和传感应用至关重要。与早期的光纤成像网络相比，[23,25,27,28,31,34] TF-UNet 在跳跃路径中引入物理启发式融合，以处理锥形光纤的空间变化、非局部传递，从而在 512×512 pixel 处实现更高的逐像素精度和感知保真度，同时保持可部署的效率。

尽管具有这些优势，本研究仍存在若干限制，制约了当前的研究范围。首先，监督和评估均在单一的532纳米波长下进行，且仅采用强度测量，这不可避免地忽略了有价值的相位信息和多光谱线索，而这些信息和线索本可帮助模型更好地理解样本的底层物理性质。例如，相位衬度通常包含关键的结构细节——尤其是在透明或弱散射样本中，而这些细节仅凭强度图像无法观察到。由于仅依赖强度数据，模型可能无法捕捉折射率或内部形态的细微变化，从而可能限制其在复杂生物学或材料科学应用中的准确率。此外，使用532纳米单色光源限制了光谱多样性，降低了识别异质样本中

各组成部分时的对比度和特异性。许多生物分子在不同波长下具有独特的吸收或散射特性，因此，多波长照明能够更好地区分强度相似但光谱响应不同的结构。加入干涉旁路通道，例如数字全息或定量相位成像，可实现直接的相位测量，弥补缺失相位信息的问题。[17,11] 这能丰富训练信号并提高参数可辨识性，尤其是在不同配置会产生相似强度输出的复杂逆问题中。将监督框架扩展至纳入多光谱输入和输出，可引入更多物理多样性，提升模型性能。当前数据集主要依据自然图像统计构建，无法捕捉生物医学影像独特的微结构和光谱特征。基于此类先验训练的模型，在需要精确定位和组织分类的医学扫描中往往表现不佳。因此，评估应纳入离体和体内数据，并使用固定且经过空间配准的感兴趣区域，以确保跨模态对齐、便于与真值标注直接比较、提高可复现性，并支持跨组织类型和成像条件的纵向分析。

除了指标提升之外，本研究还提出了一项可迁移的原则——协同设计神经模块与光学传播，以应对计算光学中的空变逆问题。将物理机制与数据驱动建模相结合，可构建更准确、更具适应性的系统，减少重新标定，并提升泛化能力。这种方法在散射受限条件下的深层组织荧光显微术中颇具前景，可实现紧凑、高效利用硬件的配置，同时具备高分辨率，且仅需极少的照明或标记；同样也适用于天文学、遥感和工业检测。[52-54]

致谢

本研究获得国家自然科学基金委员会（项目编号：12388102）、张江实验室青年创新项目（项目编号：S20240005）、中国科学院“百人计划”及上海市科学技术委员会项目（项目编号：23560750200）的资助。

利益冲突

作者声明不存在利益冲突。

参考文献

[1] D. R. Sparta、A. M. Stamatakis、J. L. Phillips 等人，“用于长期光遗传学操控神经回路的可植入光纤的构建”，《自然·实验方案》7，编号 1（2012）：12–23。https://doi.org/10.1038/nprot.2011.413

[2] A. Orth、M. Ploschner、E. R. Wilson、I. S. Maksymov 和 B. C. Gibson，“光纤束：超纤薄光场成像探针”，Science Advances 5，编号 4（2019）：eaav1555。https:/doi.org/10.1126/sciadv.aav1555

[3] B. A. Flusberg、E. D. Cocker、W. Piyawattanametha 等人，“光纤荧光成像”，《自然·方法》2，编号 12（2005）：941–950。https://doi.org/10.1038/Nmeth820

[4] Choi, Y.、C. Yoon、M. Kim 等，《利用单根多模光纤实现无扫描宽场内窥成像》，《物理评论快报》109，第20期（2012）：203901。https:/doi.org/10.1103/PhysRevLett.109.203901

[5] Xie, T. Q.、D. Mukai、S. G. Guo、M. Brenner 和 Z. P. Chen，《基于光纤束的光学相干断层成像，》，《光学快报》30，第14期（2005）：1803–1805。https://doi.org/Doi10.1364/Ol.30.001803

[6] Barretto, R. P. J.、B. Messerschmidt 和 M. J. Schnitzer，《荧光成像与高分辨率微透镜》，《自然·方法》6，第7期（2009）：511–512。https://doi.org/10.1038/nmeth.1339

[7] Wen, Z.、Z. Y. Dong、Q. L. Deng 等，“用于体内光场编码内窥成像的单根多模光纤”，《自然·光子学》17，第8期（2023）：679–687。https://doi.org/10.1038/s41566-023-01240-x

[8] Vasquez-Lopez, S. A., R. Turcotte, V. Koren 等，《使用微创多模光纤实现体内深部脑区成像的亚细胞空间分辨率》，Light-Science & Applications 7，第 1 期（2018）：110。https://doi.org/10.1038/s41377-018-0111-0

[9] Barretto, R. P. J., T. H. Ko, J. C. Jung 等，《利用荧光显微内窥镜检查深部脑区疾病进展的延时成像》，《自然医学》17，第 2 期（2011）：223–228。https://doi.org/10.1038/nm.2292

[10] Caramazza, P.、O. Moran、R. Murray-Smith 和 D. Faccio，《通过多模光纤传输自然场景图像》，《自然·通讯》10，第 1 期（2019）：2029。 https://doi.org/10.1038/s41467-019-10057-8

[11] Choi, W.、M. Kang、J. H. Hong 等，《用于未染色生物组织显微成像的柔性超薄全息内窥镜》，《自然·通讯》13，第 1 期（2022年）。https://doi.org/10.1038/s41467-022-32114-5

[12] Stiburek, M.、P. Ondrácková、T. Tucková 等，《110 μm 薄型内窥显微镜：用于深脑活体观察神经元连接、活动和血流动力学》，《自然·通讯》14，第 1 期（2023）：603–614。https://doi.org/10.1038/s41467-023-36889-z

[13] Cao, H., T. Čižmár, S. Rotter 等，《控制多模光纤中的光传播：成像、光谱学及其他应用》，《光学与光子学进展》15，第 2 期（2023）：524–612。https://doi.org/10.1364/AOP.484298

[14] Pisanello, F., G. Mandelbaum, M. Pisanello 等，《通过单根锥形光纤对空间受限或大范围脑区进行动态照明》，《自然·神经科学》20，第 8 期（2017）：1180–1188。https://doi.org/10.1038/nn.4591

[15] Pisano, F., M. Pisanello, S. J. Lee 等，《通过单个锥形光纤植入体进行深度分辨光纤光度法》，《自然·方法》16，第 11 期（2019）：1185–1192。https://doi.org/10.1038/s41592-019-0581-x

[16] Spagnolo, B., A. Balena, R. T. Peixoto 等，“用于在小范围脑区实现伪影更少的光电神经接口，” Nature Materials 21，no. 7（2022年）：826–835。 https://doi.org/10.1038/s41563-022-01272-8

[17] Pisano, F., M. Masmudi-Martin, M. S. Andriani 等人，“振动光纤光度测量：无标记、无报告基因的微创拉曼光谱

深入小鼠脑”，《自然·方法》22卷，第2期（2025年）：371–379。
https://doi.org/10.1038/s41592-024-02557-3

[18] Balena, A., M. Bianco, M. S. Andriani 等，《用于体内神经接口的非平面渐缩光纤制造，以整合光学信号和电信号》
，《自然·实验方案》，第 7 期（2025年）：1768–1809。
https://doi.org/10.1038/s41596-024-01105-9

[19] Ntziachristos, V.，《超越显微镜：生物学光学成像的新前沿》，《自然·方法》2010 年，第 8 期（2010）：603–614。
https://doi.org/10.1038/nmeth.1483

[20] Lee, C. P., A. Yariv, A. Gover 等，《图像信息的直接传输
于多模光纤中*》，《美国光学学会杂志》66，第 4 期（1976）：306–311。 https://doi.org/10.1364/JOSA.66.000306

[21] Popoff, S. M., G. Lerosey, R. Carminati 等，《测量传输
矩阵在光学中的应用：研究和控制无序介质中的光传播》，《物理评论快报》104，第 10 期（2010）：100601。
https://doi.org/10.1103/PhysRevLett.104.100601

[22] Nadakuditi, R. R., E. Michielssen, M. N’Gom 等，《通过从无参考光学系统获取传输矩阵实现
多模光纤中的模式控制》，《光学快报》43，第 3 期（2018）：419–422。https://doi.org/10.1364/OL.43.000419

[23] Rahmani, B., D. Loterie, G. Konstantinou 等，《多模光纤
利用深度学习网络进行传输，《光：科学与应用》7, no. 1 (2018): 69.
https://doi.org/10.1038/s41377-018-0074-1

[24] Gao, H., H. Hu, Y. Zhang, W. Zhang, and T. Yan, “利用物理辅助深度学习透过多模光纤成像”，Optics & Laser Technology 167, no. — (2023): 109761. https://doi.org/10.1016/j.optlastec.2023.109761

[25] Moser, C., E. Kakkava, N. Borhani, 等，“学习透过多模光纤成像
光纤》，Optica 5，第 8 期（2018）：960–966。https://doi.org/10.1364/OPTICA.5.000960

[26] Liu, K.、L. Zhang、R. Xu 等，《基于多尺度卷积和多维注意力机制的多模光纤散斑图像重建》，Current Optics and Photonics 8，第 5 期（2024年）：463–471。https://doi.org/10.3807/COPP.2024.8.5.463

[27] Jin, C., B. Liu, W. Huang 等，《基于小型训练数据集的多模光纤深度学习图像传输》，Optics Express 30，第 4 期（2022年）：5657–5672。https://doi.org/10.1364/OE.450999

[28] Liu, J., D. Xiong, B. Xu 等，《通过 MITM-Unet框架实现多模光纤成像的高保真图像重建》，Optics Express 33，第 3 期（2025年）：5866–5876。https://doi.org/10.1364/OE.546689

[29] Zhang, H., D. Shen, L. Zhang 等，《基于深度学习的单根多模光纤内窥成像》，Optics Communications 583，期号 —（2025年）：131748。https://doi.org/10.1016/j.optcom.2025.131748

[30] Pisano, F., L. Piscopo, M. Kazemzadeh, 等，《浑浊介质中图像传输非局域性的揭示》，Optics Express 32，第15期（2024年）：26414–26433。https://doi.org/10.1364/OE.521581

[31] Hu, S., F. Liu, B. Song, 等，《大范围温度变化下基于并行神经网络的小型训练集多模光纤图像重建》，Optics & Laser Technology 175，第—期（2024年）：110815。https://doi.org/10.1016/j.optlastec.2024.110815

[32] Kakkava, E., B. Rahmani, N. Borhani, 等，《利用深度学习通过多模光纤成像：散斑图样强度与全息记录的影响》，Optical Fiber Technology 52，第—期（2019）：101985。https://doi.org/10.1016/j.yofte.2019.101985

[33] Li, Y., Y. Xue, L. Tian 等，“深度散斑相关：一种通过散射介质实现可扩展成像的深度学习方法”，Optica 5，第 10 期（2018）：1181–1190。https://doi.org/10.1364/OPTICA.5.001181

[34] Su, L., T. Zhao, P. Fan 等，《多模光纤内部高度可变性与随机性的深度学习》，Optics Express 27，第 15 期（2019）：20241–20258。https://doi.org/10.1364/OE.27.020241

[35] Yang, M., Z.-H. Liu, Z.-D. Cheng 等，《深度混合散射图像学习》，《物理学D辑：应用物理》52，第 11 期（2019）：115105。https://doi.org/10.1088/1361-6463/aafa3c

[36] Ronneberger, O.、P. Fischer 和 T. Brox，“用于生物医学图像分割的 U-Net：卷积网络”，《计算机科学讲义》9351，第—期（2015）：234–241。https://doi.org/10.1007/978-3-319-24574-4_28

[37] Nawaz, A.、U. Akram、A. A. Salam 等，“用于脑肿瘤分割和生存预测集成模型”，2021 年工业机器人与自动化国际会议（ICRAI），第—期（2021）：1–6。https://doi.org/10.1109/ICRAI54018.2021.9651367

[38] Zhu, Changyan、Eng Aik Chan、You Wang 等，“通过具有简单神经网络架构的多模光纤进行图像重建”，《科学报告》11，第 1 期（2021）：896。https://doi.org/10.1038/s41598-020-79646-8

[39] Wang, Z.、A. C. Bovik、H. R. Sheikh和E. P. Simoncelli，“图像质量评价：从误差可见性到结构相似性”，《IEEE图像处理汇刊》第13卷第4期（2004年）：600–612。https://doi.org/10.1109/TIP.2003.819861

[40] Zhang, R.、P. Isola、A. A. Efros、E. Shechtman和O. Wang，“深度特征作为感知度量的不合理有效性”，2018年IEEE/CVF计算机视觉与模式识别会议，期号—（2018年）：586–595。https://doi.org/10.1109/CVPR.2018.00068

[41] Deng, J.、W. Dong、R. Socher等，“ImageNet：一个大尺度层次化图像数据库”，2009年IEEE计算机视觉与模式识别会议，期号—（2009年）：248–255。https://doi.org/10.1109/CVPR.2009.5206848

[42] Alom, M. Z., C. Yakopcic, M. Hasan, T. M. Taha, 和 V. M. Asari，《用于医学图像分割的循环残差U-Net》，《医学成像杂志》6，第 1 期（2019）：014006。 https://doi.org/10.1117/1.JMI.6.1.014006

[43] Chen, J., J. Mei, X. Li 等，《TransUNet：重新思考 U-Net架构从 Transformer 的视角设计医学图像分割，

《医学图像分析》97卷，无期号（2024年）：103280。

https://doi.org/10.1016/j.media.2024.103280

[44] Razavi, A., A. van den Oord, and O. Vinyals, 《生成多样且高保真的图像与 VQ-VAE-2》，《神经信息处理系统进展》第 32 卷，第 — 期（2019）：14866–14876。https://doi.org/10.5555/3454287.3455618

[45] Wu, R., C. Zhao, S. Qiu, 等, 《一种多用途微型双光子显微镜用于多色深脑成像》，《自然·方法》第 22 卷，第 9 期（2025年）：1935–1943。https://doi.org/10.1038/s41592-025-02780-6

[46] Poon, C., P. Teikari, M. F. Rachmali, 等, 《一个啮齿动物基于体内多光子荧光显微镜成像的脑血管系统，” Scientific Data 10, no. 9 (2023): 141. https://doi.org/10.1038/s41597-023-02048- 8

[47] Xu, M., Z. Zhu, H. Ma, et al., “微创皮质内神经电极的极端制造，” International Journal of Extreme Manufacturing 8, no. 2 (2026): 022009. https://doi.org/10.1088/2631-7990/ae2579

[48] Kozai, T. D. Y., N. B. Langhals, P. R. Patel, et al., “超小型可植入复合微电极具有生物活性表面的长期神经接口，” Nature Materials 11, no. 12 (2012): 1065–1073. https://doi.org/10.1038/nmat3468

[49] Luan, L., X. Wei, Z. Zhao 等人，“超柔性纳米电子探针形成可靠的无胶质瘢痕神经整合”，Science Advances 3，第 2 期（2017）：e1601966。https://doi.org/10.1126/sciadv.1601966

[50] Altmann, Y., A. Karam-Eldaly, R. R. Thomson 等人，“相干光纤束中芯间耦合的表征与建模”，Optics Express 25，第 10 期（2017）：11932–11943。https://doi.org/10.1364/OE.25.011932

[51] Accanto, N., F. G. C. Blot, A. Lorca-Cámara 等：《用于自由活动小鼠神经元快速活动成像和精确光遗传光刺激的柔性双光子光纤内窥镜》，Neuron 111，第 2 期（2023）：176–189.e6。https://doi.org/10.1016/j.neuron.2022.10.030

[52] Guo, Y., Y. Hao, S. Wan 等：《利用视频速率宽视场波前传感器直接观测大气湍流》，《自然·光子学》18，第 9 期（2024年）：935–943。https://doi.org/10.1038/s41566-024-01466-3[53] Gao, P., Yuan, C.：《通过合成孔径提升数字全息显微术分辨率：综述》，《光：先进制造》3，第 1 期（2022年）：105–120。https://doi.org/10.37188/lam.2022.006[54] Osten, W., Pedrini, G.：《全息无损检测与实验应力分析55年：未来是否仍有进步空间？》，《光：先进制造》3，第 1 期（2022年）：121–136。https://doi.org/10.37188/lam.2022.008