arXiv:2602.01065v1 [eess.IV] 1 Feb 2026

面向可扩展空间变化高通量成像的坐标条件反卷积

Qianwan Yang，*IEEE* 学生会员，Zhixiong Chen，*IEEE* 学生会员，Jiaqi Zhang、Ruipeng Guo，*IEEE* 学生会员，Guorong Hu，*IEEE* 学生会员和 Lei Tian，*IEEE* 会员

摘要—采用紧凑型光学系统的宽视场荧光显微镜常因视场相关像差、渐晕和传感器截断而受到空间变化模糊的影响；同时，有限的传感器采样也使视场（FOV）与分辨率之间存在固有权衡。计算微型介观成像系统（CM^2）通过将多个子视图复用到单个传感器上来缓解采样限制，但会引入视图串扰，并使本已高度病态的逆问题因空间变化的点扩散函数（PSF）而更加复杂。以往基于学习的空间变化（SV）重建方法通常依赖具有固定输入尺寸的全局空间变化算子，因此其内存和训练成本会随着图像尺寸增大而迅速攀升。我们提出 SV-CoDe（空间变化坐标条件反卷积），这是一种可扩展的深度学习框架，可在 6.5 mm 视场内实现均匀的高分辨率重建。与传统方法不同，SV-CoDe 采用坐标条件卷积，对重建核进行局部自适应；因此可进行基于图像块的训练，使参数数量不再取决于视场大小。SV-CoDe 在仿真和实验测量中均实现了最佳图像质量，同时所需模型大小比以往基线少 10× ，训练数据也少 10×。该网络仅基于物理仿真进行训练，仍能稳健地泛化至微珠仿体、弱散射脑切片以及自由活动的 秀丽隐杆线虫。SV-CoDe 为校正紧凑型光学系统中的空间变化模糊提供了一种可扩展且具备物理感知能力的解决方案，并可轻松扩展到广泛的生物医学成像应用。

索引词—空间变化反卷积、多孔径成像、荧光显微镜、坐标条件网络。

一、引言

荧LUORESCENCE 光显微镜是研究生物结构及其动态变化的基础工具。为了突破台式仪器的局限，微型化荧光显微镜（微型显微镜）已成为一种有前景的发展方向

稿件创建于2025年12月。本项目得以实现
部分经费由美国国立卫生研究院（R01NS126596）和5022- ChanZuckerberg InitiativeDAF（硅谷社区基金会管理的建议捐赠基金）提供。作者感谢波士顿大学共享计算集群提供计算资源。（通讯作者：Lei Tian。）Qi

anwan Yang is with th工程系 f Electrical and C计算机工程 i-，波士顿大学，波士顿，马萨诸塞州 02215，美国（电子邮件：yaw@bu.edu）。
Zhixiong Chen 任职于电气与计算机工程系，
波士顿大学，波士顿，马萨诸塞州 02215，美国（电子邮箱：zhixiong@bu.edu）。
Jiaqi Zhang 任职于电气与计算机工程系，
波士顿大学，波士顿，马萨诸塞州 02215，美国（电子邮箱：jzhang@bu.edu）。
Ruipeng Guo 任职于电气与计算机工程系，波士顿大学，波士顿，马萨诸塞州 02215，美国（电子邮箱：rguo@bu.edu）。
Guorong Hu 任职于电气与计算机工程系，波士顿大学，波士顿，马萨诸塞州 02215，美国（电子邮箱：grhu@bu.edu）。
Lei Tian就职于波士顿大学电气与计算机工程系和生物医学工程系，美国马萨诸塞州波士顿02215（电子邮箱：leitian@bu.edu）。

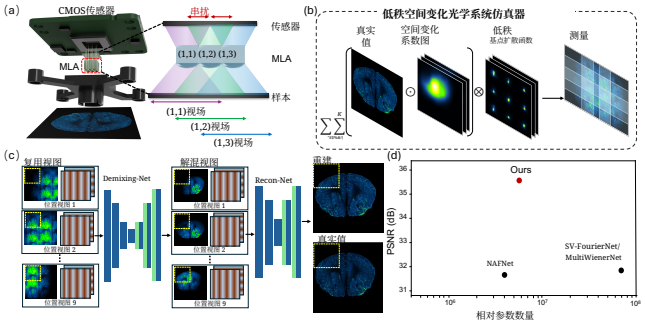


图 1. **系统概览。** (a) 多孔径微型显微镜以微透镜阵列作为唯一成像元件；每个微透镜捕获一个不同的子视场，而传感器记录的扩展视场中存在视间串扰。(b) 用于基于物理的数据合成的低秩 SV前向模型。模拟测量被划分为复用子视图，作为网络输入。(c) SV-CoDe 流程：复用子视图和归一化空间坐标被裁剪为图像块，并由带有 CoDe 块的视图相关 Demixing-Net 处理；随后，Recon-Net 执行 SV 反卷积，将各视图融合为宽视场图像。(d) SV-CoDe 通过轻量级 MLP，以坐标条件化空间注意力增强 NAFNet，从而以极低的内存开销实现 SV重建；与基线方法相比，它使用的参数大幅减少，同时取得更高的峰值信噪比。

用于活体和可穿戴成像 [1]，，但在保持微米级空间分辨率的同时扩大其视场（视场）仍然具有挑战性 [2]。

现有的微型显微镜设计大致分为两类。无透镜成像通过将相位掩模置于传感器附近实现极致小型化，但由于缺乏聚焦能力，对比度会降低，且对荧光背景和散射的适应能力有限 [3], [4]。相比之下，多视图或多孔径配置通过捕获多个子视图保留聚焦能力，但要实现较大的视场，通常需要专用光学元件 [5] 或传感器阵列 [6]，，这些方案成本高且会牺牲紧凑性。我们实验室开发了计算迷你介观显微镜（CM^2） [7], [8]，，采用多视图原理，同时保持紧凑外形：将微透镜阵列直接置于单个图像传感器前方，并有意让子视图相互重叠，以最大限度地扩大可用视场（图 1(a) ）。

这种光学简化将负担从硬件转移到了计算上，使图像重建成为主要的性能瓶颈。由此产生的逆问题具有高度病态性：强烈的视图复用以及微透镜阵列的周期晶格，在测量数据中引入了大量歧义。更具挑战性的是，由于视场相关像差、渐晕以及有限

传感器尺寸所造成的截断，点扩散函数在整个视场范围内本质上呈现<style id='1'>空间变化</style>。因此，传统的平移不变（SI）卷积模型无法准确地对正向成像过程进行逆算，通常会产生伪影，并导致视场周边出现明显的分辨率下降。基于经典模型的方法通过迭代优化在一定程度上缓解了这些问题，但其较高的计算成本以及对人工调节正则化参数的敏感性，限制了可扩展性和鲁棒性。

因此，近期深度学习方法已成为一种很有前景的替代方案，能够提升空间变化（SV）反卷积的重建质量和速度。基于学习的空间变化反卷积方法通常遵循两种范式。第一种将空间变化近似为平移不变算子的线性组合 [9], [10], [11], [12]。尽管效果显著，这类方法通常需要全局感受野，才能合成传感器上的空间变化滤波器。因此，模型复杂度会随视场和空间变化程度（例如空间变化算子的有效秩）共同增长，导致内存消耗高，并受到固定输入尺寸的限制，从而制约其在高通量成像中的可扩展性。第二种范式使卷积本身依赖坐标 [13], [14], [15], [16], ，通过轻量级坐标条件化直接实现空间变化滤波。这种方法无需全局感受野即可局部调整重建卷积核，因此非常适合基于图块的处理。然而，在多孔径重建中，这种方法尚未得到充分探索；在该场景下，视图复用会使空间变化同时源于传感器全域场依赖性和镜头相关效应。在兼顾这两种空间变化的同时，保持高效、可扩展的逐图块推理，仍是一项尚待解决的挑战。

在此，我们提出 SV-CoDe，这是一种轻量且可扩展的框架，可联合执行视图感知空间变化解混与反卷积，以解决复用引起的串扰和场依赖模糊，如图1(c)所示。SV-CoDe 采用两阶段架构，先进行视图解混，再进行重建；两个阶段均由共享的 CoDe模块骨干网络构成，并基于高效的 NAF 风格设计 [17]。每个 CoDe 块通过引入轻量级 MLP，将由坐标导出的 位置编码映射为 SV 掩模，以坐标条件化操作取代空间不变卷积。

每次卷积后，预测得到的掩模会与特征图相乘，从而实现与 SV前向模型中的系数图相对应的位置依赖调制 [9]，同时仅引入可忽略不计的额外参数。在推理期间，这些掩模仅取决于空间坐标，因此可以预先计算并缓存，使运行时间接近标准卷积。该设计支持基于图像块的训练，同时保留全局空间变化特性，从而以极低的内存开销实现大视场重建。

仅使用基于物理的仿真进行训练，这些仿真采用我们先前开发的低秩空间变化正向模型 [9] (图1(b))，并经实验验证。与先前的空间变化网络相比（图1(d)），SV-CoDe 在 6.5毫米视场内实现了均匀、高质量的重建，同时将内存使用量降低了约 $10\times$。仿真结果表明，带位置编码的坐标门控骨干网络可在扩展视场内恢复高空间频率，并抑制 SI模型的典型伪影。补充实验进一步证明了模型在不同条件下具有稳健的泛化能力，包括在整个视场内保持一致的分辨率、适应粒子仿体中发射体密度的大幅变化，以及迁移至弱散射脑切片和自由活动的秀丽隐杆线虫。综上，这些示例凸显了 SV-CoDe 捕捉成像问题底层空间变化结构、并泛化至训练时未遇到的特定条件之外的能力。

凭借极低的额外开销和出色的可扩展性，SV-CoDe 为高通量、宽视场荧光成像提供了一种切实可行的方案，并且易于适配其他空间变化重建问题。

II. 方法

A. 基于物理的数据模拟

为避免大量采集实验数据的需求，我们使用低秩SV成像模型 [9]合成训练数据。每个仿真测量值都先补零至 4200×4200 像素，以补偿传感器裁剪；随后，根据微透镜阵列（MLA）中透镜的主光线坐标将其划分为子视图，得到尺寸为2400×2400 像素的子视图。训练期间，将多路复用的子视图裁剪成尺寸为 480×480、步长为 240×240 的重叠图像块，并沿通道维度堆叠，形成输入解混网络的 $480\times480\times9$，其中第三维对应九个视图。此过程会从每个完整测量值中生成 $16\times16=256$ 个图像块。

训练数据集将自然的生物医学图像（细胞、脉管系统和脑组织切片）与合成荧光粒子仿体相结合，后者覆盖了广泛的发射体密度、尺寸和强度范围。为增强稳健性，使用经校准的混合泊松–高斯模型 [9]在训练过程中即时注入噪声。真实图像经过背景抑制和对比度归一化，随后进行人工筛选，以确保获得具有多样稀疏度级别和结构内容的高质量荧光数据集。基础数据集包含约1,307幅图像，共计产生105,867个图像块。训练期间，每个epoch随机抽取三分之一的图像块，约对应35,000个图像块。

与我们先前开发的SV-FourierNet [9]和 MultiWienerNet [10], 相比，所提出的逐图像块训练策略所需的训练对大约减少 $10\times$，同时在多样的测试样本上取得更高的结构相似性指数和峰值信噪比。在先前方法中，训练内存随测量尺寸线性增长，使得针对大视场的端到端优化难以实现。相比之下，我们基于图像块的训练方案将内存消耗与视场大小解耦，从而能够在任意大的视场上进行可扩展训练，并使该方法易于扩展到其他高通量成像应用。

B. SV-CoDe 网络设计

SV-CoDe 基于物理 SV前向模型设计，其中空间变化表示为线性

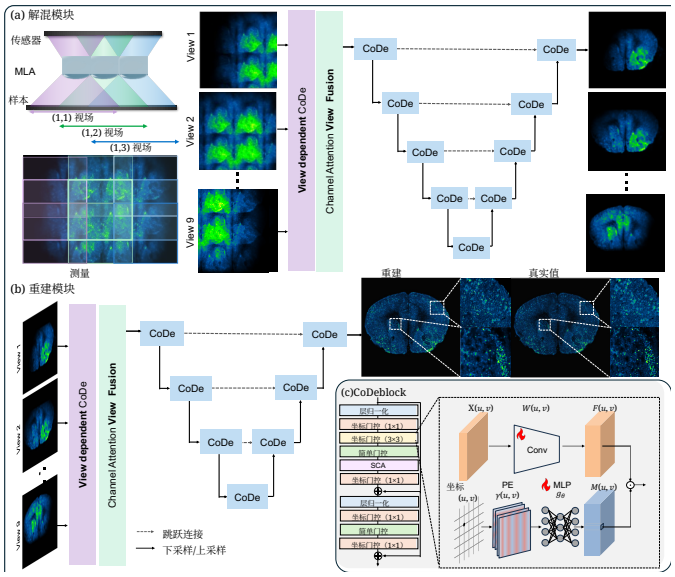


图2。**网络设计**。(a) 解混模块：利用主光线坐标将原始测量划分为微透镜子视图。每个子视图由视图依赖型 CoDe 块处理，生成的特征随后传入由共享 CoDe 块组成的 U-Net。(b) 重建模块：将解混后的子视图输入重建网络，该网络首先通过 CoDe 块执行镜头依赖型 SV 反卷积。随后，通道注意力融合不同视图的信息，再通过第二组 U-Net 生成宽视场、高分辨率重建结果。(c) *CoDe* 块：CoDe 块以坐标条件化操作取代 SI 卷积。如放大图所示，像素坐标 $(i,\ j)$经过位置编码后，由轻量级 MLP 映射为逐通道 SV 掩码，用于调制卷积后特征。

的 SV 卷积组合，并由系数图参数化。我们使用轻量级的坐标条件化函数近似该算子的逆算子，从而以极低的开销实现视图解混和位置感知反卷积。

该框架由两个模块组成：*Demixing-Net* 和*Recon-Net*，其两阶段结构与 [8]类似。根据主光线坐标将原始测量划分为九个子视图并堆叠，从而实现局部分块处理，无需全局感受野即可聚合传感器范围内的多视图信息。*Demixing-Net* 对这些多路复用的子视图图块进行处理，以抑制视图串扰，同时保留镜头特定内容（图2 (a)）。随后将解混后的子视图传入*Recon-Net*，通过 SV 反卷积校正镜头依赖型像差，并融合不同视图的信息，生成均匀的宽视场重建结果（图2(b)）。

两个模块遵循相同的设计：（i）用于镜头特定适配的视图依赖型 *CoDe* 块；（ii）通过逐视图池化聚合跨视图信息的通道注意力；以及（iii）用于 SV 视图融合、包含额外 CoDe 块的共享 U-Net 编码器–解码器。这种将镜头特定解复用与像差校正相结合，并共享 SV 融合的设计，能够减少内存消耗并稳定优化过程。

SV-CoDe 的核心构建模块是 CoDeblock。它沿用 NAFBlock 的拓扑结构 [17]，但将 *NAFBlock* 中的每个卷积替换为坐标门控（*Co- ordGate*） *[13]*。这保留了 NAFBlock 的高效性同时通过坐标条件掩码实现 SV 处理，如图 2(c) 所示。

给定特征图 $F \in \mathbb{R}^{C\times H\times W}$ 和归一化像素坐标 $\mathbf{r} = (u,\ v) \in [-1,1]^2$，我们构造位置编码 [18]，每个轴包含 L 个频带：

$$\gamma(\mathbf{r}) = \big[\ldots, \sin(2^k\pi u), \cos(2^k\pi u), \sin(2^{k+1}\pi v), \cos(2^{k+1}\pi v), \ldots\big]_{k=0}^{L-1}. \quad (1)$$

轻量级 MLP $g_{\theta,\ \ell}$ 仅利用位置编码生成逐通道、坐标条件化的掩码。对于每个微透镜 ℓ，掩码定义为

$$M_\ell(\mathbf{r}) = g_{\theta,\ell}\big(\gamma(\mathbf{r})\big).$$

在第一个视图依赖型 *CoDe* 块中，MLP 针对特定镜头单独设计，以捕获每个镜头的特性。在 U-Net 中后续的所有 CoDe 块里，所有镜头共用一个 MLP g_θ，以减少内存消耗，同时保留空间变化调制。

掩码在卷积之后应用于调制特征图，从而实现 SV 反卷积：

$$\mathrm{CoordGate}(F; M_\ell) = M_\ell \odot (W * F), \quad (2)$$

其中，W 表示卷积核，$*$ 表示卷积运算，$\odot$ 表示哈达玛积。该公式在保留标准卷积结构的同时，通过坐标条件掩码实现依赖位置的调制。

由于 $M_\ell\mathbf{r}$仅取决于空间坐标，因此可以在训练后预先计算掩码，并在推理时缓存。因此，每个 CoDe 层都可简化为标准卷积后接逐元素门控；与常规 NAFBlock 相比，额外延迟可以忽略不计。

两个阶段均使用复合损失进行联合监督，

$$\mathcal{L} = \mathcal{L}_{\text{demix}} + \mathcal{L}_{\text{recon}}, \qquad \mathcal{L}_{(\cdot)} = \alpha(1-\mathrm{SSIM}) + \beta\,\mathrm{MSE}, \quad (3)$$

其中，结构相似性指数用于提升结构保真度，均方误差用于确保强度准确性。权重 $\alpha, \beta \geq 0$ 用于平衡这两项，在所有实验中均设为 1.0。梯度通过 Demixing-Net 和 Recon-Net 进行端到端传播。

SV-CoDe 使用 PyTorch 实现，并采用 Adam 在模拟数据上训练，学习率采用余弦退火调度（批量大小为 4）。在单张 NVIDIA A40 GPU 上训练完整模型约需 48 小时。

III. 结果

A. SV-CoDe 实现最先进的重建质量为评估重建质量，我们在模拟数据和实验数据上（图 3）将 SV-CoDe 与 MultiWienerNet [10]、SV-FourierNet [9]，以及基于模型的 LSV-ADMM [9] 进行了基准比较。

在模拟细胞上（图 3(a)），SV-CoDe 的定量准确度最高，优于 SV-FourierNet、LSV-ADMM 和 MultiWienerNet。从定性结果来看，SV-CoDe 能够重建出更清晰的细胞边界和亚细胞特征，同时减少背景伪影，并在整个视场内保持保真度，表明其能有效补偿空间变化。

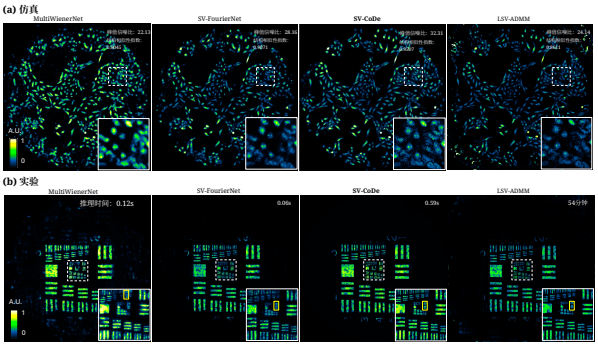


图 3. **基准测试结果**。(a)仿真（细胞）：SV-CoDe 的峰值信噪比/结构相似性指数最高，重建效果明显比 MultiWienerNet 和 SV-FourierNet 更清晰、伪影更少。插图展示了放大区域（白色虚线框）。(b) 实验（分辨率靶）：SV-CoDe、SV-FourierNet 和 LSV-ADMM 均能分辨最精细的元素（黄色框），其中 SV-CoDe 的对比度更高，伪影也少于其他方法。标注时间为单 GPU 上每帧的推理延迟。

在实验分辨率靶上（图 3(b)），与 Multi-WienerNet 相比，SV-CoDe 能够分辨最精细的线对（黄色方框），且对比度更高、鬼影伪影更少，同时达到与 SV-FourierNet 和 LSV-ADMM 相当的极限分辨率。在单个 GPU 上，每帧推理时间分别为：SV-FourierNet 0.06 秒、MultiWienerNet 0.12 秒、SV-CoDe 0.59 秒；迭代式 LSV-ADMM 的速度则慢了几个数量级。

尽管 SV-CoDe 在非迭代方法中的推理延迟最高，但其训练和推理均针对彼此独立的子视场进行，因此可以轻松实现数据并行，且通信开销极低。这种设计表明，只要有足够的多GPU计算能力和输入/输出带宽，就能实现显著且接近线性的吞吐量提升。

总体而言，SV-CoDe实现了最先进的重建质量，并在整个视场内保持均匀性能，同时保留轻量级的空间变化参数化，相对于先前的空间变化网络显著降低了内存占用。

*B. SV-CoDe*组件的消融研究

我们使用来自两类代表性物体类别的模拟数据，评估SV-CoDe两个关键组件——坐标门控（CG）和位置编码（PE）——的贡献：一类是密集标记的细胞簇，另一类是具有介观结构的神经元标记脑切片。我们比较三种变体：去除坐标门控（无坐标门控）、去除位置编码（无位置编码）以及完整模型。

在解混阶段（图4(a)），去除坐标门控会使SV-CoDe退化为采用SI卷积的NAFNet，从而产生残余背景，在视场边缘最为明显，因为传感器截断导致该处点扩散函数变化最强（红色箭头）。相比之下，无位置编码 取得了与完整模型相当的解混性能。

差异在重建之后变得更加明显（图4(b)）。若无坐标门控，解混过程中引入的伪影会通过视图融合传播并放大，产生周边-eral重影，并且图像质量向视场边缘下降（红色箭头）。在没有位置编码的情况下，网络表现出频谱偏差，从而抑制精细结构，导致精细

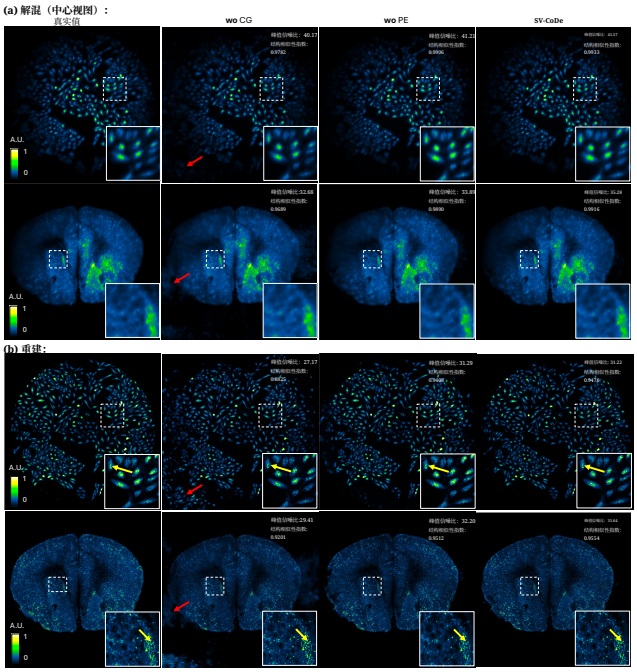


图4. **坐标门控（坐标门控）与位置编码（位置编码）的消融**。(a) 中心视角解混。各列依次为真实值、无坐标门控、无位置编码以及所提出的 SV-CoDe。去除坐标门控会留下残余背景，尤其是在视场边缘附近；由于传感器截断，该处空间变化最为显著（红色箭头）。无位置编码与完整的 SV-CoDe 解混质量相当。(b)最终重建。尽管单独的中心视角解混会受到严重周边像差和渐晕的影响，重建阶段仍能恢复精细细节，并有效扩展可用视场。无坐标门控的模型会将解混伪影传播至重建结果（红色箭头），而去掉位置编码则会因频谱偏差导致分辨率明显降低（黄色箭头）。通过利用坐标门控进行 SV 反卷积，SV-CoDe 抑制了周边重影，并取得最高的视觉保真度，与真实值高度吻合。

特征（黄色箭头）。完整的SV-CoDe结合坐标门控与位置编码，在两种样本类型上均与真实值最为一致，在抑制周边伪影的同时保留高频细节，并在整个视场内保持均匀的图像质量。

综合来看，这些结果表明两个组件发挥着互补作用：CG 提供校正视场相关像差所需的空间变化，而 PE 则能够在整个空间范围内准确恢复高频细节。因此，两者结合对于在宽视场内实现高分辨率 SV重建至关重要。

C. 宽视场内分辨率一致性的实验验证

为评估整个视场内分辨率的均匀性，我们在涵盖中心和周边的多个位置对荧光分辨率靶标进行了成像，并使用 SV-CoDe 重建测量结果（图5）。顶行显示不同视场位置的完整重建结果，底行则展示白色虚线框所示区域的放大视图。在所有位置，能够分辨的最精细线对（黄色框）均相同；无论视场中心还是边缘，垂直和水平方向的分辨率均一致，为 $7.8\,\mu$m。这些结果

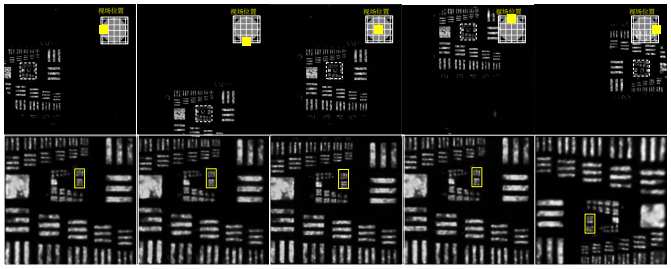


图5. **分辨率表征**。在视场内多个位置放置荧光分辨率靶标后的重建结果（插图：黄色方框标示靶标位置）。上排：不同视场位置处的重建结果。下排：白色虚线区域的放大图；黄色方框标示可分辨的最精细线对。SV-CoDe 在不同视场位置处保持均匀的分辨率。

表明 SV-CoDe 的 SV 反卷积能够有效补偿视场相关像差和渐晕，从而在整个视场内实现均匀的高分辨率成像。

D. 不同密度粒子幻影实验演示

我们使用不同密度的荧光微球幻影，评估从仿真到实验的泛化能力。将商用 $10\,\mu$m 荧光微球分散在酒精中，制备覆盖整个视场的稀疏和致密粒子仿体。原始测量（插图）呈现出明显的视图复用和视场相关像差。

图 6(a) 展示了稀疏幻影的结果（从左至右：宽场真值、SV-CoDe重建和叠加图）。视场中心和边缘的放大视图证实，重建出的粒子在整个视场内均能保持一致的大小和形状，边缘未见明显退化。图 6(b) 展示了密度更高的幻影；尽管原始测量中的重叠和串扰有所增加，SV-CoDe 仍能高保真地恢复大多数粒子，且叠加图中的图像依然对齐良好。放大区域再次表明，中心和边缘的重建效果相当。

综上，这些结果表明，仅使用模拟数据训练的 SV-CoDe 能够稳健地迁移至涵盖广泛物体密度的实验测量，同时保持空间分辨率并避免密度相关伪影。

E. 弱散射脑组织实验演示

我们在一张固定的弱散射小鼠脑切片上评估了 SV-CoDe，该切片含有 GFP 标记神经元（图 7）。我们使用台式宽场（WF，0.1 NA）显微镜对同一切片进行成像，并将其作为真实值。SV-CoDe 重建了整张脑切片，同时保留标记结构的双侧组织结构，且分辨率与 WF 相当。在放大区域中，神经元特征与 WF 图像高度吻合，同时呈现出更高的局部对比度。尽管仅使用模拟数据进行训练，SV-CoDe 仍能泛化

稳健地应用于这一实验上颇具挑战、散射较弱的样本，恢复密集和

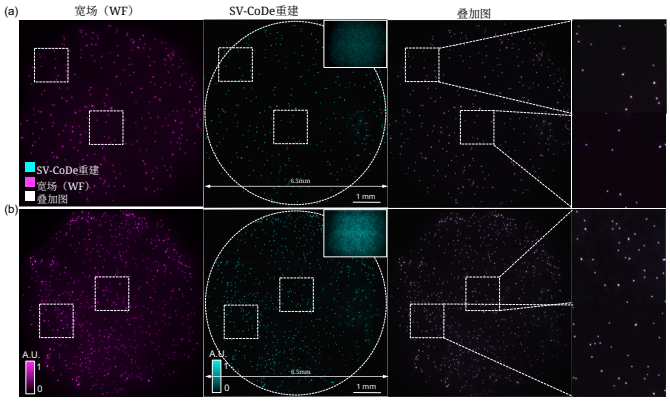


图 6. **不同密度荧光颗粒的成像**。在两种密度下成像的荧光微珠仿体（上：稀疏；下：密集）。从左至右：宽场真值（洋红色）、由复用测量得到的 SV-CoDe重建（青色）以及叠加图。白色虚线框标示了选取用于放大的区域，分别位于视场中心和边缘。对于不同的密度和视场位置，SV-CoDe 均能准确恢复微珠的位置和大小，展现出在广泛物体密度范围内的稳健性能。

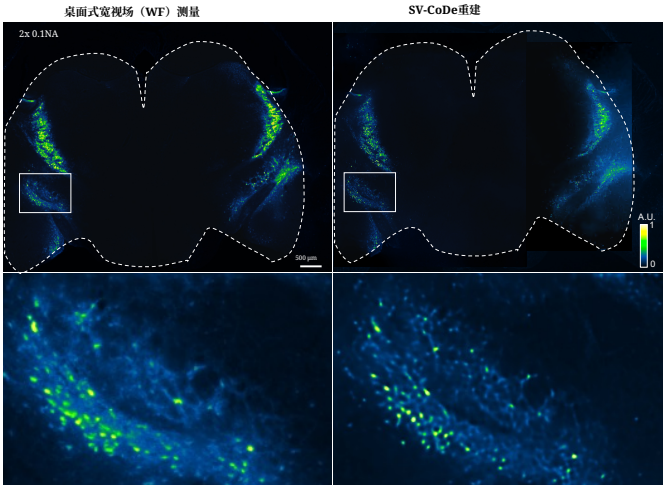


图 7. **弱散射脑组织成像**。左：固定小鼠脑切片的台式宽场（WF，0.1 NA）图像，切片中含有 GFP标记神经元，用作真实值；虚线表示组织边界。右：通过单次复用采集获得的 SV-CoDe重建，与 WF 图像在整个视场范围内高度吻合。下：框选区域的放大视图，SV-CoDe 能够准确恢复神经元结构，并增强局部对比度。

稀疏区域中的精细神经元信号，并在整个组织中保持均匀的视觉质量。

F. 对自由移动的秀丽隐杆线虫进行实验演示。我们通过成像自由移动的秀丽隐杆线虫群体，在大规模动态样本上评估了 SV-CoDe。图 8(a) 中的全视场对比显示，SV-CoDe重建结果与同步采集的宽场（WF）真实值高度一致，并准确恢复了中央和周边区域的蠕虫。在 t=0、30 和 60 毫秒时对两个代表性区域进行的时间放大图（图 8(b)）表明，该方法在运动和对比度变化的情况下仍表现稳健。与 WF 相比，SV-CoDe 能以更高的局部对比度分辨蠕虫身体，同时可靠地捕捉到较暗的幼体

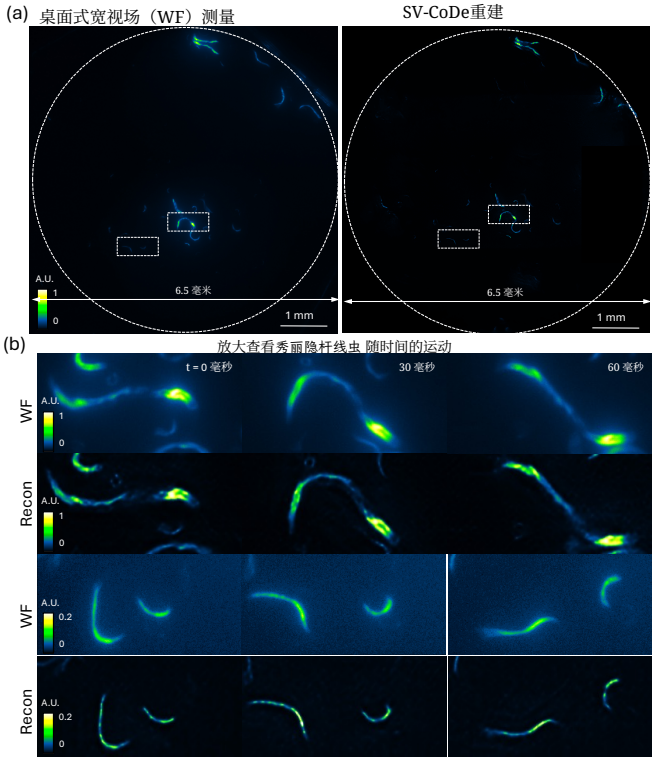


图 8. **对自由活动的** 秀丽隐杆线虫**进行成像。(a)** 台式宽场（WF）测量与SV-CoDe重建的全视场对比；白框标出了用于时间放大图的区域。**(b)** 两个代表性区域在 t=0、30 和 60 毫秒时的放大序列。SV-CoDe 能稳健地泛化至动态生物场景，在运动状态下恢复高对比度成年秀丽隐杆线虫和低对比度幼虫的信号。

动物，以及较亮的成体。这些结果表明，尽管 SV-CoDe 仅使用模拟数据训练，却能稳健地泛化至动态生物场景，在宽阔视场内实现均匀、高保真的重建。

IV. 结论

我们提出了 SV-CoDe，这是一种可扩展框架，用于多孔径荧光显微镜中的空间变化、坐标条件反卷积。其核心思路是以轻量级坐标条件卷积取代全局且依赖视场的空间变化算子，从而实现镜头感知自适应和分块训练，同时使模型复杂度与视场大小脱钩。这种设计能够在宽视场范围内实现均匀的高分辨率重建，同时将内存占用和计算开销降至最低。

大量消融研究和实验验证了该方法的有效性。坐标门控提供了校正视场相关像差、抑制传感器截断引起伪影所需的空间变化，而位置编码则缓解了频谱偏差并改善了高频恢复。这些组件共同构成了一种高效且具有物理可解释性的算子，能够捕捉成像系统的主要 SV结构，并支持在整个视场内实现稳健重建。

SV-CoDe 达到了出色的基准性能，在重建质量方面始终优于此前基于学习的空间变化方法，同时避免了依赖视场的参数化方式，并且在推理时比基于模型的迭代方法快几个数量级。该框架将重建分解为相互独立的子视场，同时保留全局空间变化特性，在提高数据利用效率、减少参数数量的同时实现了高保真度，因此非常适用于高通量成像场景。

尽管 SV-CoDe 完全基于物理仿真进行训练，但它仍能稳健地泛化至不同样本的实验测量，包括涵盖多种发射体密度的微珠仿体、弱散射脑组织，以及自由活动的秀丽隐杆线虫。这些结果表明，将 SV结构显式嵌入网络设计，有助于模型可靠地迁移至训练期间未遇到的特定条件之外。

展望未来，有几种拓展方向值得探索。坐标条件化的形式可自然地扩展至体积和深度感知重建，为实现可扩展的三维空间变化反卷积提供了途径，而无需采用全局算子。SV-CoDe 也兼容互补的采集策略，例如事件式传感 [19] 或结构光照 [20]，这些策略可能进一步提升低对比度或强散射条件下的稳健性和光学切片能力。从更广泛的角度看，CoDeblock 为位置依赖型信息融合提供了一种通用抽象，也可能适用于其他计算成像系统，例如多相机阵列 [21] 和光场成像 [22]。总之，这些方向使 SV-CoDe 成为面向下一代宽场和高通量成像的灵活且具备物理感知能力的构建模块。

参考文献

[1] D. Aharoni、B. S. Khakh、A. J. Silva和P. Golshani，“我们所能看见的全部光：微型化显微术的新时代”，《自然-方法》，第16卷，第1期，第11–13页，2019。[2] J. Park、D. J. Brady、G. Zheng、L. Tian和L. Gao，“高空间带宽积生物光学成像系统综述”，《先进光子学》，第3卷，第4期，第044 001–044 001页，2021。[3] V. Boominathan、J. T. Robinson、L. Waller和A. Veeraraghavan，“无透镜成像的最新进展”，《*Optica*》，第9卷，16，2021 1，1期，第–页。[4] J. Wu、Y. Chen、A. Veeraraghavan、E. Seidemann和J. T. Robinson，“利用无透镜显微镜对头部无约束雄性非人灵长类进行介观钙成像”，《自然-通讯》，第15卷，第1期，第1271页，2024。[5] J. Hu和W. Yang，“用于大视场成像的超透镜阵列微型化显微镜”，《光学通讯》，第555卷，130231，2024，第 页。[6] J. Tanida、T. Kumagai、K. Yamada、S. Miyatake、K. Ishida、T. Morimoto、N. Kondou、D. Miyazaki和Y. Ichioka，“束缚光学薄观测模块（TOMBO）：概念与实验验证”，《应用光学》，第40卷，第11期，第1806–1813页，2001。[7] Y. Xue、I. G. Davison、D. A. Boas和L. Tian，“基于计算迷你介观显微镜的单次三维宽场荧光成像”，《科学进展》，第6卷，第43期，第eabb7508页，2020。[8] Y. Xue、Q. Yang、G. Hu、K. Guo和L. Tian，“深度学习增强的计算迷你介观显微镜”，《*Optica*》，第9卷，第9期，第1009–1021页，2022。[9] Q. Yang、R. Guo、G. Hu、Y. Xue、Y. Li和L. Tian，“利用傅里叶神经网络在计算多孔径微型显微镜中实现宽场高分辨率重建”，《*Optica*》，第11卷，871，2024 6，860期，第–页。[10] K. Yanny、K. Monakhova、R. W. Shuai和L. Waller，“用于快速空间变化去卷积的深度学习”，《*Optica*》，第9卷，99，2022 1，96期，第–页。

[11] J. Wu、V. Boominathan、A. Veeraraghavan和J. T. Robinson，“实时深度学习辅助无透镜显微镜”，《生物医学光学快报》，第14卷，第8期，第4037–4051页，2023。[12] F. Tian、B. Mattison和W. Yang，“Deepinminiscope：深度学习驱动的物理信息集成微型显微镜”，《科学进展》，第11卷，第37期，第eadr6687页，2025。[13] S. Howard、P. Norreys和A. D¨opp，“CoordGate：在卷积神经网络中高效计算空间变化卷积”，*arXiv*预印本*arXiv:2401.04680*，2024。[14] R. Liu、J. Lehman、P. Molino、F. Petroski Such、E. Frank、A. Sergeev和J. Yosinski，“卷积神经网络的一个耐人寻味的失效及CoordConv解决方案”，《神经信息处理系统进展》，第31卷，2018。[15] J. Wei、Y. Liu、J. Wu和L. Cao，“基于薄饼透镜与深度学习的轻薄相机”，《光学快报》，第49卷，第17期，第4851–4854页，2024。[16] S. Fu、W. Shi、T. Luo、Y. He、L. Zhou、J. Yang、Z. Yang、J. Liu、X. Liu、Z. Guo 等，“场依赖深度学习实现高通量全细胞三维超分辨成像”，《自然-方法》，第20卷，第3期，第459–468页，2023。[17] L. Chen、X. Chu、X. Zhang和J. Sun，“图像复原的简单基线”，载于欧洲计算机视觉会议。Springer，2022，第17–33页。[18] B. Mildenhall、P. P. Srinivasan、M. Tancik、J. T. Barron、R. Ramamoorthi和R. Ng，“NeRF：将场景表示为用于视图合成的神经辐射场”，《*ACM*通讯》，第65卷，106，2021 1，99期，第–页。[19] R. Guo、X. Pan、Q. Deng、A. Ahmed、Q. Yang、J. Greene、T. Li、S. Y. Chan、Z. Chen、G. Hu 等，“用于超快生物成像的双通道事件显微术”，*bioRxiv*，第2025–11页，2025。[20] J. Mertz，“采用平面或结构光照的光学切片显微术”，《自然-方法》，第8卷，第10期，第811–819页，2011。[21] D. J. Brady、M. E. Gehm、R. A. Stack、D. L. Marks、D. S. Kittle、D. R. Golish、E. Vera和S. D. Feller，“多尺度十亿像素摄影”，《自然》，第486卷，第7403期，第386–389页，2012。[22] I. Ihrke、J. Restrepo和L. Mignard-Debise，“光场成像原理：简要回顾25年研究”，《*IEEE*信号处理杂志》，第33卷，第5期，第59–69页，2016。