VAMOS-OCTA：用于修复运动受损OCT血管成像体积数据的血管感知多轴正交监督

Nick DiSanto[a]、Ehsan Khodapanah Aghdam[a]、Han Liu[b]、Jacob Watson[c]、Yuankai K. Tao[c]、Hao Li[a]和Ipek Oguz[a]

[a]计算机科学系，范德比尔特大学[b]数字技术与创新，
SiemensHealthineers[c]生物医学工程系，范德比尔特大学

arXiv:2602.00995v1 [cs.CV] 1 Feb 2026

摘要

手持式光学相干断层扫描血管成像（OCTA）可对不配合检查的受试者或儿童进行无创视网膜成像，但极易受到运动伪影影响，导致体积图像质量严重下降。三维采集期间的突然运动可能导致整个B扫描（横截面切片）中出现未采样的视网膜区域，从而在眼底正面投影中形成空白条带。我们提出了**VAMOS-OCTA**，这是一种利用血管感知多轴监督修复运动受损B扫描的深度学习框架。我们采用2.5D U-Net架构，将一组相邻B扫描作为输入，以重建受损的中心B扫描，并通过一种新颖的**血管感知多轴正交监督（VAMOS）**损失进行引导。该损失结合了血管加权强度重建与轴向和横向投影一致性，促使血管在原始B扫描中及各正交平面之间保持连续。不同于以往主要侧重于恢复眼底正面最大强度投影（MIP）的方法，VAMOS-OCTA能够同时提升横截面B扫描清晰度和体积投影准确度，即使面对严重运动受损也不例外。我们使用合成受损体积数据和真实受损体积数据训练模型，并通过感知质量和像素级准确度指标评估其性能。VAMOS-OCTA始终优于以往方法，生成的重建结果具有清晰的毛细血管、恢复的血管连续性以及干净的眼底正面投影。这些结果表明，多轴监督为恢复运动导致质量下降的三维OCTA数据提供了有力约束。源代码见https://github.com/MedICL-VU/VAMOS-OCTA。

关键词：光学相干断层扫描血管成像、视网膜成像、图像修复、深度学习、运动伪影校正、医学图像复原

1. 引言

光学相干断层扫描血管成像（OCTA）可提供活体微血管网络的高分辨率体积图像，是传统染料造影血管成像的一种无创替代方法。然而，对清醒受试者进行手持式OCTA成像时，特别容易受到眼球运动和操作者引起的位移所导致的运动伪影影响。[1]由于体积图像是逐切片采集的，即使是短暂的运动事件，也可能使整幅B扫描或连续的少量B扫描发生损坏，导致正面视图（如最大强度投影（MIP））中出现空白带。

虽然已有研究提出帧间配准[2]和渐进式采样[3]等运动校正方法，但基于配准的方法无法恢复整体运动事件导致的、未被采样的视网膜区域。这一局限促使研究者开发采集后图像修复方法，尝试根据相邻B扫描重建血管。[4,5]然而，现有复原方法存在明显且反复出现的失效模式。例如，二维生成模型单独使用时虽然视觉效果颇具说服力，但若在没有明确三维约束的情况下逐切片独立应用，可能会产生空间错位的重建结果。[6]此外，许多针对OCTA的复原方法侧重于投影域改进，[7–9]却未能保证局部B扫描保真度，还可能掩盖逐切片不一致的问题。

一种采集后图像修复方法 SOAD（自监督OCTA去噪）[10]引入了盲切片预测，采用强调高强度血管造影信号的血管加权损失。尽管该策略无需完美的真值或完全损坏体数据即可实现自监督学习，但使用

作者补充信息：（通信请联系 Nick DiSanto）Nick DiSanto：电子邮箱：nicolas.c.disanto@vanderbilt.edu

基于强度的损失的自监督模型已被证明会产生过度平滑的重建结果和模糊结果，导致精细细节丢失。[11,12]因此，在实践中仅强调血管强度是不够的，这促使我们采用一种约束更强的方法，针对单个 B扫描和*en face* 投影优化感知损失和基于特征的损失。

在本研究中，我们提出了**VAMOS-OCTA**（用于修复运动伪影光学相干断层扫描血管成像体数据的血管感知多轴正交监督），这是一种深度学习框架，旨在恢复手持式OCTA体数据中受损的B扫描，同时沿正交轴恢复血管。我们的主要贡献如下：

1. 一种称为**VAMOS损失**的复合血管感知损失函数，将血管加权重建与解剖对齐投影约束相结合，以优先实现准确的血管恢复。2. 一种用于OCTA修复的双轴投影监督策略，利用轴向和横向投影，确保正交平面之间的一致性。3. 联合增强二维和三维表示，生成平滑的正面投影和感知上清晰锐利的B扫描，并使用质量和准确度指标进行评估。

这些贡献共同构建了一种稳健且具备解剖感知能力的图像修复框架，用于恢复运动伪影OCTA体数据，支持可靠的下游可视化和临床解读。我们的整体框架如图1所示。

2. 方法

2.1 数据

2.1.1 采集与预处理

我们使用自定义的手持式多模态OCT/OCTA探头，对清醒患者采集了7组高分辨率视网膜体扫描。该探头支持同时进行*en face*引导和配准OCT采集。[13] 首先以结构OCT形式采集体数据，每个位置均重复进行B扫描。随后，采用亚像素逐行配准进行轴向运动校正，再使用基于SVD的去相关算法生成OCTA体数据；该算法根据重复B扫描之间的时间强度变化提取血管造影对比度。生成的OCTA体数据为三维堆栈，共含1000个B扫描，每个B扫描的尺寸为 400×145 （横向 $\times$ 轴向），并裁剪至感兴趣的视网膜区域。数据集按5/1/1的比例划分为训练集、验证集和测试集，并在7个交叉验证折间轮换。

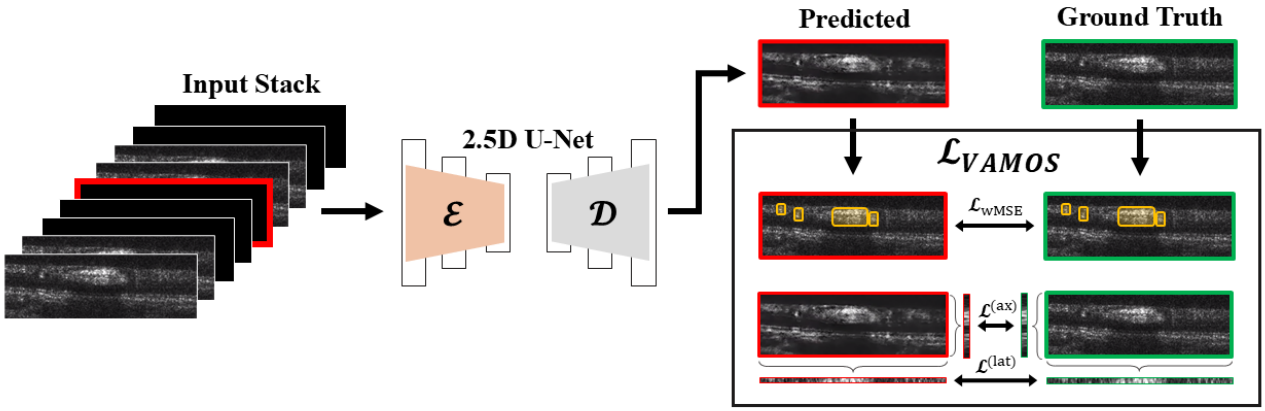


图1：VAMOS-OCTA框架概览。2.5D U-Net从相邻B扫描堆栈中重建中心目标B扫描。训练由所提出的VAMOS损失引导，该损失结合了血管加权重建与多轴正交监督。通过分别沿深度和横向维度对每个B扫描进行折叠，形成一维最大强度剖面和平均强度剖面，从而施加轴向和横向投影约束。

2.1.2 合成运动伪影模拟

为获取用于训练和评估的配对受损图像与真值数据，我们采用一种合成运动伪影策略，以模拟手持式OCTA采集中常见的整体运动事件。具体而言，对于每个待重建的目标B扫描，我们移除中心切片，并额外随机丢弃若干个相邻B扫描，以模拟整体运动事件造成的连续未采样视网膜区域。每个受损区块的大小从参数为 $p = 0.4$的几何分布中采样，并截断为最多6个切片。该分布使伪影过程倾向于产生短至中等长度的缺失，这与手持运动模式的经验观察相符。[14,15] 训练期间，每个训练轮次中都会针对每个目标B扫描动态应用此伪影过程，确保网络随时间观察到多样的运动模式和伪影配置。这可以避免对固定伪影模式过拟合，并增强模型应对不同伪影严重程度的鲁棒性。相比之下，验证和测试阶段使用固定的伪影掩码，以确保不同方法之间的比较一致且公平。

2.2 有效性感知的 2.5D U-Net

为支持在动态运动引起的受损图像上进行体积修复，我们对标准 U-Net[16] 进行了改造，使其能够依据空间上下文重建目标 B扫描。具体而言，我们采用 2.5D架构，输入由相邻B扫描组成的序列，其中部分切片可能因模拟运动伪影而缺少采样的视网膜区域，并对序列中心的 B扫描进行图像修复。网络的输入是形状为 $(B,\ S,\ H,\ W)$ 的张量，其中 B 是批次大小，S 是输入序列中的 B扫描数量（为奇数，在我们的实验中设为 $S = 9$），$(H,\ W)$ 分别是每个 B扫描的轴向和横向尺寸。训练期间对每个序列施加的随机受损，使模型能够依靠有效且未受损的相邻切片，从部分缺失的上下文中学习。

该网络不需要完整无损的输入图像堆栈，也不需要显式的有效性掩码。相反，它会学习有选择地依赖有效的相邻B扫描，同时降低受损上下文的权重。通过在训练过程中接触多种受损模式，网络能够在上下文信息不完整的情况下稳健地进行图像修复。

2.3 VAMOS损失：血管感知多轴正交监督

我们框架的核心是VAMOS损失，旨在同时保留各个B扫描中的局部血管结构，以及体积投影中的整体解剖一致性。SOAD的加权重建损失虽旨在提高血管区域的准确性，但在严重运动导致图像受损时，对B扫描纹理和眼底投影的控制有限。为弥补这一局限，我们在血管加权重建的基础上加入投影监督，以约束正交平面之间的连续性。形式上，VAMOS损失定义如下：

$$\mathcal{L}_{\text{VAMOS}} = \mathcal{L}_{\text{wMSE}} + \lambda_{\text{proj}} \left(\mathcal{L}_{\text{MIP}}^{(ax)} + \mathcal{L}_{\text{MIP}}^{(lat)} + \mathcal{L}_{\text{AIP}}^{(ax)} + \mathcal{L}_{\text{AIP}}^{(lat)} \right) \tag{1}$$

该损失由血管加权均方误差（wMSE）重建损失，以及沿轴向和横向轴计算的最大强度投影（MIP）和平均强度投影（AIP）分布的L1投影损失组成。这些损失将在以下小节中详细介绍。在所有实验中，我们设定 $\lambda_{\text{proj}} = 3$，使投影一致性相较于逐像素重建占据更大的权重。

2.3.1 血管加权均方误差

为匹配整体强度，同时优先关注明亮的血管像素，我们采用 SOAD 提出的血管加权 L2 损失。[10] 令 $Y(x,\ z)$ 和 $\hat{Y}(x,\ z)$ 分别表示真值和重建的 OCTA B 扫描，其中 x 表示横向维度的索引，z 表示轴向（深度）维度的索引。血管加权重建损失定义如下：

$$\mathcal{L}_{\text{wMSE}} = \frac{1}{N} \sum_{x,z} w(x,z) \left[\hat{Y}(x,z) - Y(x,z) \right]^2, \quad \text{with} \quad w(x,z) = \underbrace{\alpha_w \left[\hat{Y}(x,z) \right]^{\gamma_w}}_{\text{prediction-based}} + \underbrace{\left[Y(x,z) \right]^{\gamma_w}}_{\text{target-based}} + c \tag{2}$$

此处，空间变化权重 $w(x,\ z) \geq 1$ 通过基于预测的项（抑制幻觉亮斑）、基于目标的项（强调真实血管）以及用于调节异常值的次线性指数来放大损失贡献。按照 SOAD，我们设定 $\alpha_w = 100$、$\gamma_w = \frac{1}{3}$ 和 $c = 0.5$。

2.3.2 多轴投影损失

为正则化三维中的血管分布，我们在两个正交轴上引入最大投影损失和平均投影损失：**轴向** 和 **横向**。

$$\mathcal{L}_{\text{MIP}}^{(\text{ax})} = \frac{1}{W}\sum_{x}\left|\max_{z}\hat{Y}(x,z) - \max_{z}Y(x,z)\right|, \quad \mathcal{L}_{\text{AIP}}^{(\text{ax})} = \frac{1}{W}\sum_{x}\left|\frac{1}{H}\sum_{z}\hat{Y}(x,z) - \frac{1}{H}\sum_{z}Y(x,z)\right|$$
$$\mathcal{L}_{\text{MIP}}^{(\text{lat})} = \frac{1}{H}\sum_{z}\left|\max_{x}\hat{Y}(x,z) - \max_{x}Y(x,z)\right|, \quad \mathcal{L}_{\text{AIP}}^{(\text{lat})} = \frac{1}{H}\sum_{z}\left|\frac{1}{W}\sum_{x}\hat{Y}(x,z) - \frac{1}{W}\sum_{x}Y(x,z)\right| \tag{3}$$

轴向投影约束深度积分血管连续性，直接影响正面视图的外观；而横向投影则对每个单独 B扫描内的血管分布进行正则化，从而减轻条带伪影。我们沿每个轴采用最大强度投影（MIP）和平均强度投影（AIP）损失。MIP 损失强调血管强度峰值，而 AIP 损失约束强度的整体分布，从而促进形成逼真的血管密度。

通过整合这些目标，VAMOS损失约束血管在正交轴上的强度和空间分布。血管加权项与基于投影的项协同作用，逐切片地确保体积一致性。与近期的跨视图投影细化方法类似，[17] 这种多轴监督引导重建趋向体积一致性，而无需显式进行三维建模。

3. 结果

3.1 定量性能

我们使用动态合成运动伪影，在 NVIDIA RTX 6000 Ada GPU（CUDA 12.4）上从头训练所有模型。测试期间使用固定的伪影掩码，并在所有方法中保持不变，以确保公平比较。由于逐像素指标在存在不确定性时往往偏向模糊结果，[20] 我们采用感知指标和边缘感知指标评估 B扫描，以捕捉锐度和血管细节。我们报告 LPIPS[18] 以衡量感知相似度，使用拉普拉斯模糊差异衡量锐度，并使用 Sobel梯度边缘保留率量化血管边界保留情况（表 1a）。对于 正面MIP 重建，我们使用逐像素准确度指标 L1、MIE、SSIM、NCC 和峰值信噪比来评估深度积分体积一致性，确保投影级解剖准确性（表 1b）。

我们的结果表明，SOAD有助于保持大血管，但更偏向平滑而非精细细节，因此在感知性能和边缘感知性能方面表现较弱。加入轴向投影监督可提升MIP质量，使SSIM和NCC取得显著增益，但对B扫描锐度的改善有限。相比之下，采用横向投影监督的VAMOS-OCTA在感知B扫描度量指标以及

表1：B扫描和MIP的定量性能。**粗体** 表示最佳性能。星号（*）表示相对于SOAD的统计学显著改进（$p < 0.05$，配对 t检验）。

方法	梯度 L1↓	LPIPS↓	拉普拉斯模糊差异↓	Sobel边缘 Pres↑	峰值信噪比↑
标准均方误差	0.045 ± 0.014	0.625 ± 0.199	0.023 ± 0.008	0.305 ± 0.220	27.036 ± 0.764
SOAD 加权均方误差（wMSE）[10]	0.044 ± 0.014	0.608 ± 0.202	0.023 ± 0.008	0.313 ± 0.219	**27.084 ± 0.712**
加权均方误差 + 轴向投影	0.042 ± 0.013*	0.565 ± 0.184*	0.020 ± 0.007	0.360 ± 0.204*	26.687 ± 0.739
加权均方误差 + 轴向 + 横向投影（**VAMOS-OCTA**）	**0.041 ± 0.013***	**0.510 ± 0.162***	**0.014 ± 0.005***	**0.427 ± 0.182***	26.122 ± 0.709

(a) 使用感知质量指标评估 B扫描重建性能：梯度L1、学习感知图像块相似度（LPIPS）、[18] 拉普拉斯模糊差异、Sobel边缘保留。

方法	L1↓	MIE↓	SSIM↑	NCC↑	峰值信噪比↑
标准均方误差	0.029 ± 0.003	0.028 ± 0.003	0.758 ± 0.011	0.808 ± 0.008	22.550 ± 0.818
SOAD 加权均方误差（wMSE）[10]	0.028 ± 0.003	0.029 ± 0.003	0.763 ± 0.008	0.812 ± 0.006	22.672 ± 0.717
加权均方误差 + 轴向投影	0.014 ± 0.002*	0.005 ± 0.004*	0.888 ± 0.008*	0.914 ± 0.006*	**28.168 ± 1.044***
加权均方误差 + 轴向 +横向投影（**VAMOS-OCTA**）	**0.013 ± 0.002***	**0.003 ± 0.003***	**0.895 ± 0.010***	**0.931 ± 0.007***	27.772 ± 0.865*

(b) 使用逐像素准确度指标评估 MIP 重建性能：L1、平均强度误差（MIE）、结构相似性指数（SSIM）、[19] 归一化互相关（NCC）、峰值信噪比（PSNR）。

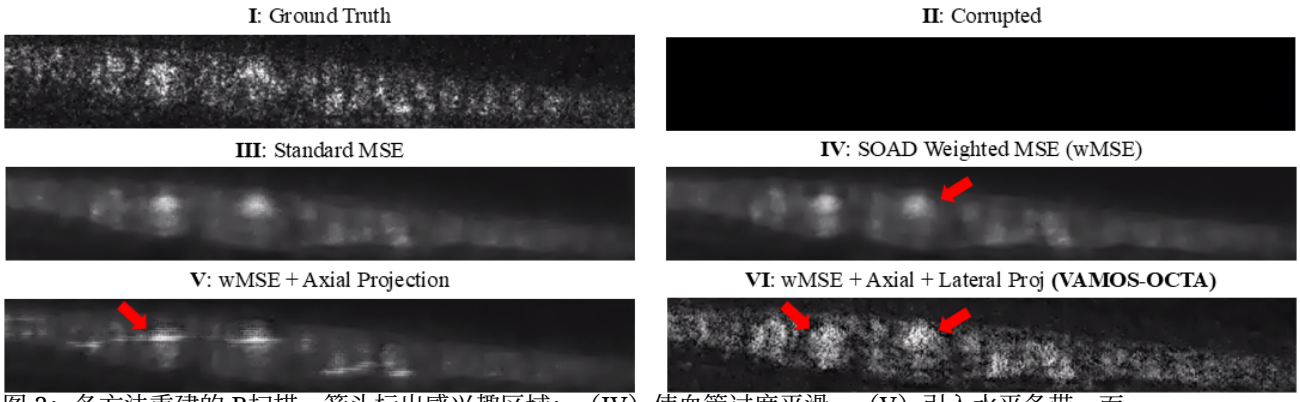


图 2：各方法重建的 B扫描。箭头标出感兴趣区域：（IV）使血管过度平滑，（V）引入水平条带，而 VAMOS-OCTA（VI）恢复了血管对比度和空间连续性。

投影精度。这证实，横向约束对于抑制条带伪影并保持真实的血管结构是必要的。几乎所有这些提升都具有统计显著性，且在所有交叉验证折中表现一致，这表明多轴监督能够稳健地提升定量性能，且没有任何取舍。

3.2 定性表现

图 2展示了不同方法的定性重建结果，对比了单个 B扫描及其对应的 *en face* 最大强度投影，这些结果由基线均方误差、SOAD、部分投影监督和完整的 VAMOS-OCTA 模型生成，且均存在严重运动导致的采样缺失。基线均方误差和 SOAD 的单个 B扫描重建结果过度平滑，并在最大强度投影中产生断裂的血管。引入轴向投影监督虽通过改善最大强度投影重建部分缓解了这些问题，但它会聚合深度方向的信息，因此无法充分约束轴向和横向轴上的血管。这导致出现水平条带伪影，破坏了 B扫描一致性。

相比之下，完整的 VAMOS-OCTA 模型同时采用轴向和横向投影监督，在 B 扫描和*en face* 最大强度投影上均带来了定性一致的改进。横向投影约束对逐层血管定位进行显式正则化，抑制条带伪影，并恢复相邻 B 扫描之间的连续性。因此，修复结果纹理清晰、血管分支逼真，并保留了其他方法所丢失的微血管连续性。VAMOS-OCTA 的图像修复质量在各层间也得以保持，从而生成*en face* 最大强度投影（图3），其结构连贯且没有残留缺失条带。

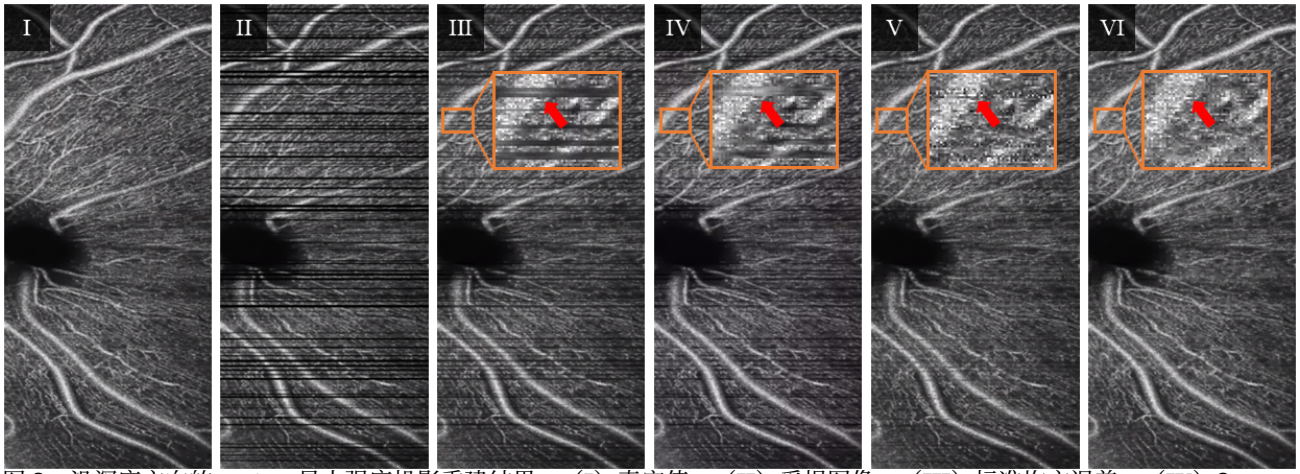


图 3：沿深度方向的 *en face* 最大强度投影重建结果。（**I**）真实值，（**II**）受损图像，（**III**）标准均方误差，（**IV**）SOAD加权均方误差，（**V**）加权均方误差 + 轴向，（**VI**）VAMOS-OCTA。放大图突出显示了（**III**）、（**IV**）和（**V**）未能去除伪影的区域，而 VAMOS-OCTA（**VI**）恢复了平滑、逼真的投影，并重现了血管（箭头所示）。

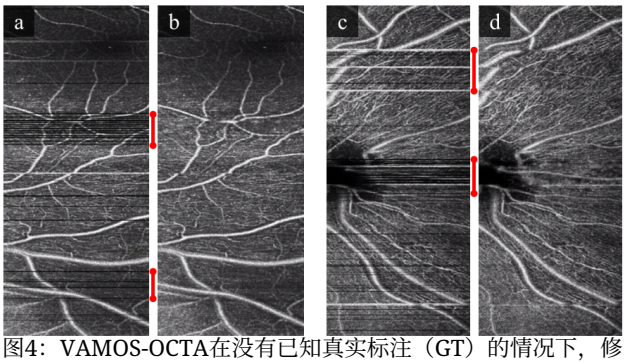


图4：VAMOS-OCTA在没有已知真实标注（GT）的情况下，修复了含有真实运动伪影的体数据。(a、c)为真实场景中的受损图像，(b、d)为对应的图像修复结果，其中红色条标出了明显的运动区域。

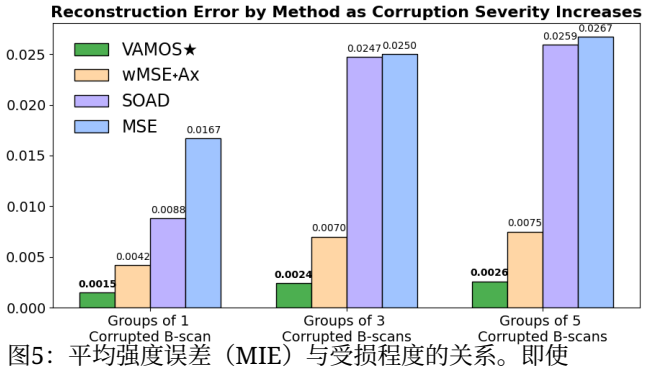


图5：平均强度误差（MIE）与受损程度的关系。即使OCTA体数据严重劣化，VAMOS（绿色）仍能保持较低误差，而随着缺失的B扫描增多，其他方法的误差则急剧上升。

这些定性观察与表1中报告的定量趋势直接吻合。轴向投影监督主要改善投影域指标，而要同时恢复视觉上清晰的 B 扫描和体积结构，则需要多轴监督。我们还将 VAMOS-OCTA 应用于真实运动受损体积（图4）以及连续未采样区域逐渐增大的体积（图5），以进一步评估其鲁棒性；这两种情况下模型均保持了出色的性能。这些改进无需显式三维建模即可实现，表明正交投影约束能够有效地在 2.5D光学相干断层扫描血管成像修复中保证体积一致性。

4. 讨论与结论

在这项工作中，我们提出了**VAMOS-OCTA**，这是一种多轴正交监督框架，用于修复由手持成像系统采集、受运动伪影影响的OCTA体数据。通过在血管加权重建中加入轴向和横向投影约束，VAMOS-OCTA能够在运动引起严重采样缺失的情况下，生成视觉上清晰的B扫描和结构连贯的眼底平面最大强度投影（MIP）。

本研究的一个核心见解是，明确约束正交投影，比单独采用基于强度的重建更能有效地进行体积正则化。尽管血管加权损失总体上有助于恢复高强度区域，但对重建血管的结构控制有限。引入基于投影的监督后，模型可以约束血管沿深度方向及切片之间的聚合方式，避免出现虽满足局部逐像素目标、却违背全局连续性的结构。轴向投影与横向投影各自发挥着互补作用，至关重要：轴向监督提高了深度积分后血管的可见性，而横向监督改善了切片间结构，并抑制条带伪影。

我们还证明了，对每个B扫描施加强有力的二维约束可以产生体积一致性，这表明体积一致性并不一定只能来源于显式的三维架构。相反，在损失层面施加经过精心设计的几何约束，即使基于二维或2.5D表示进行处理，也能够诱导出一致的三维结构。这与近期通过迭代切片生成[21] 和多视图细化来提升三维一致性的研究相一致。[22] 更广泛地说，我们的结果为体积医学成像中的图像修复与复原研究[23–25] 不断扩展的成果体系作出了贡献，进一步凸显了空间上下文和跨切片监督的重要性。本研究确立了正交投影约束作为实现体积光学相干断层扫描血管成像复原的有效策略，并为解决其他基于切片的三维成像模态中的运动伪影提供了一个具有普适性的框架。

致谢

本工作部分得到美国国立卫生研究院资助项目 R01-EY033969 以及范德比尔特大学研究与教育高级计算中心的支持。

参考文献

[1] Anvari, P., Ashrafkhorasani, M., Habibi, A., 和 Falavarjani, K. G., “光学相干断层扫描血管成像中的伪影,” Journal of Ophthalmic & Vision Research 16(2), 271 (2021).[2] Yang, J., Liu, L., Campbell, J. P., Huang, D., 和 Liu, G., “手持式光学相干断层扫描血管成像,” Biomedical Optics Express 8(4), 2287–2300 (2017).[3] Lebed, E., Mackenzie, P. J., Sarunic, M. V., 和 Beg, M. F., “利用压缩采样实现快速体积 OCT 图像采集,” Optics Express 18(20), 21003–21012 (2010).[4] Lin, Z., Zhang, Q., Lan, G., Xu, J., Qin, J., An, L., 和 Huang, Y., “深度学习用于由重复扫描与相邻 OCT 扫描生成运动伪影抑制 OCTA 图像,” Mathematics 12(3), 446 (2024).[5] Li, A., Du, C., 和 Pan, Y., “基于深度学习的光学相干断层扫描血管成像运动校正,” Journal of Biophotonics 14(12), e202100097 (2021).[6] Zhu, L., Xue, Z., Jin, Z., Liu, X., He, J., Liu, Z., 和 Yu, L., “Make-a-Volume：利用潜扩散模型进行跨模态三维脑部 MRI 合成,” 载于 [医学图像计算与计算机辅助干预国际会议], 592–601, Springer (2023).[7] Cao, J., Xu, Z., Xu, M., Ma, Y., 和 Zhao, Y., “用于光学相干断层扫描血管成像图像质量提升的两阶段框架,” Frontiers in Medicine 10, 1061357 (2023).[8] Wang, J., Hormel, T. T., Bailey, S. T., Hwang, T. S., Huang, D., 和 Jia, Y., “信号衰减补偿型投影分辨 OCT 血管成像,” Biomedical Optics Express 14(5), 2040–2054 (2023).[9] Kadomoto, S., Uji, A., Muraoka, Y., Akagi, T., 和 Tsujikawa, A., “通过深度学习增强光学相干断层扫描血管成像中视网膜微血管的可视化,” Journal of Clinical Medicine 9(5), 1322 (2020).[10] Li, Z., Ren, J., Zou, Z., Garigapati, K., Du, C., Pan, Y., 和 Ling, H., “清醒脑三维光学相干断层扫描血管成像的自监督去噪与整体运动伪影去除,” 载于 [医学图像计算与计算机辅助干预国际会议], 601–611, Springer (2024).[11] Zhang, K., Zuo, W., Chen, Y., Meng, D., 和 Zhang, L., “超越高斯去噪器：用于图像去噪的深度 CNN 残差学习,” IEEE Transactions on Image Processing 26(7), 3142–3155 (2017).[12] Lin, H., Su, X., Zeng, Z., Xing, C., 和 Yin, J., “Speckle2Self：利用注意力机制学习合成孔径雷达图像的自监督去斑,” Remote Sensing 17(23), 3840 (2025).[13] Watson, J. J., Xu, R., Hecht, R., 和 Tao, Y., “ 结合手持式光谱编码相干断层扫描与反射测量的床旁广角视网膜 OCTA 拼接,” 载于 [Optical Coherence Tomography and Coherence Domain Optical Methods in Biomedicine XXIX], PC1330507, SPIE (2025).[14] Hormel, T. T., Huang, D., 和 Jia, Y., “光学相干断层扫描血管成像中的伪影与伪影去除,” Quantitative Imaging in Medicine and Surgery 11(3), 1120 (2021).[15] Ni, S., Liang, G. B., Ng, R., Ostmo, S., Jia, Y., Chiang, M. F., Huang, D., Skalet, A. H., Young, B. K., Campbell, J. P., 等, “用于儿童视网膜成像的全视网膜手持式 OCT 血管成像,” Biomedical Optics Express 15(5), 3412–3424 (2024).[16] Ronneberger, O., Fischer, P., 和 Brox, T., “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国际会议], 234–241, Springer (2015).[17] Radhakrishna, C., Chintalapati, K. V., Kumar, S. C. H. R., Sutrave, R., Mattern, H., Speck, O., N¨urnberger, A., 和 Chatterjee, S., “SpockMIP：以最大强度投影作为损失、增强连续性的磁共振血管造影图像血管分割,” arXiv 预印本 arXiv:2407.08655 (2024).[18] Zhang, R., Isola, P., Efros, A. A., Shechtman, E., 和 Wang, O., “深层特征作为感知度量的非凡有效性,” 载于 [IEEE 计算机视觉与模式识别会议论文集], 586–595 (2018).[19] Wang, Z., Bovik, A. C., Sheikh, H. R., 和 Simoncelli, E. P., “图像质量评估：从误差可见性到结构相似性,” IEEE Transactions on Image Processing 13(4), 600–612 (2004).[20] Terven, J., Cordova-Esparza, D.-M., Romero-Gonz´alez, J.-A., Ram´ırez-Pedraza, A., 和 Ch´avez-Urbiola, E., “深度学习中损失函数与度量指标的综合综述,” Artificial Intelligence Review 58(7), 195 (2025).

[21] Jeong, J., Kim, K. D., Nam, Y., Cho, K., Kang, J., Hong, G.-S., and Kim, N.,“使用结合相邻切片和强度校准网络的扩散模型生成具有12位深度的高分辨率三维CT”，载于 [医学图像计算与计算机辅助干预国际会议], 366–375, Springer（2023）。[22] Shi, Z., Huo, D., Zhou, Y., Min, Y., Lu, J., and Zuo, X.,“Imfine：通过几何引导的多视图细化实现三维修复”，载于 [计算机视觉与模式识别会议论文集], 26694–26703（2025）。[23] Santos, J. C., Tom´as Pereira Alexandre, H., Seoane Santos, M., and Henriques Abreu, P.,“深度学习在医学图像修复中的作用：系统综述”，《ACM 医疗保健计算汇刊》**6**(3)，1–24（2025）。[24] Wang, J., Larson, K. E., and Oguz, I.,“利用合成萎缩进行自监督脑脊液修复，以提高皮层表面分析准确性验证的效果”，arXiv 预印本 arXiv:2303.05777（2023）。[25] Zhang, H., Bakshi, R., Bagnato, F., and Oguz, I.,“基于边缘先验的稳健多发性硬化病灶修复”，载于[国际医学影像机器学习研讨会], 120–129，Springer（2020）。