

基于重参 U-Net 与联邦学习的息肉图像域泛化分割

黄柏雄¹

HUANG Boxiong

摘要

结直肠息肉的非同域分割对于早期结直肠癌筛查与医师诊断具有重要意义。然而，不同医疗中心采集的内镜图像在成像设备、光照条件、病灶形态及组织结构等方面存在明显差异，导致现有深度学习模型在跨域场景下泛化能力不足。针对上述问题，文章提出一种基于重参数化 U-Net 与联邦学习的息肉图像域泛化分割算法。该方法以重参数化 U-Net 作为基础分割模型，在训练阶段引入多分支卷积结构以增强多尺度特征表达能力，并在推理阶段通过重参数化耦合模型的多个分支，以此兼顾推理效率与精度。同时，结合联邦学习框架，在不共享原始数据的前提下实现多中心协同训练，并通过频域幅值模态与对比学习约束引导模型学习域不变结构特征。实验结果表明，在多个公开息肉数据集上的跨域测试中，所提方法在 Dice、IoU 及 HD95 等指标上均优于现有主流方法，具有良好的泛化性能与临床应用潜力。

关键词

息肉分割；联邦学习；域泛化；重参数化 U-Net；频域特征；对比学习

doi: 10.3969/j.issn.1672-9528.2026.02.035

0 引言

结直肠癌是全球范围内发病率和死亡率均居高不下的恶性肿瘤之一，而息肉作为结直肠癌的重要前驱病变，其早期发现与精准定位对疾病防治具有关键作用。随着计算机视觉和深度学习技术的发展，基于卷积神经网络的自动息肉分割方法已在辅助诊断中展现出广阔前景。

然而，现有方法大多依赖集中式训练范式，默认训练数据与测试数据分布一致。在实际临床应用中，不同医院、不同设备及不同采集条件所产生的内镜图像在颜色分布、纹理结构及病灶形态方面存在明显差异，因此对于未见域的图像模型不能完成较好的分割。此外，医疗数据涉及隐私与合规问题，难以进行跨中心集中共享，进一步制约了模型的泛化能力提升。

为解决上述问题，联邦学习通过参数共享替代数据共享，为多中心协同建模提供了可行途径。然而，传统联邦学习方法在面对显著域偏移时仍难以保证模型的跨域鲁棒性。与此同时，重参数化卷积结构通过在训练阶段引入多分支表示、在推理阶段进行结构折叠，为构建高效且高表达能力的分割网络提供了新的思路。

基于此，本文提出一种结合重参数化 U-Net 与联邦学习的息肉图像域泛化分割方法，通过频域辅助建模与对比学习约束进一步增强模型对跨域结构信息的建模能力。

1 相关工作

1.1 息肉图像分割方法

早期方法多依赖传统图像处理技术，如阈值分割、区域生长和形态学操作，但在复杂内镜场景下鲁棒性有限。随着深度学习的发展，U-Net 架构因其编码器-解码器结构及跳跃连接机制，在医学图像分割领域得到广泛应用。随后，大量改进模型相继提出，如 Attention U-Net^[1]、UNet++^[2]、ResUNet^[3] 等，通过引入注意力机制、多尺度特征融合和残差结构提升分割精度。然而，这类方法通常假设训练数据与测试数据同分布，在跨中心或跨设备场景下性能下降明显。

1.2 域泛化与跨数据集分割

针对训练与测试分布不一致的问题，域泛化方法逐渐受到关注。相关研究通过特征对齐、风格随机化、元学习等策略，试图学习域不变表示。例如，一部分方法采用对抗学习约束不同域之间的特征分布，而另一部分工作则通过元学习模拟域偏移过程，提高模型的快速适应能力。然而，这类方法通常依赖集中式数据训练，难以直接应用于隐私敏感的医疗场景。

1.3 联邦学习在医学影像中的应用

联邦学习在当下医疗隐私问题如此严重的情况下，成为有效的方法。王丹等^[4]提出的 FedAvg 算法奠定了联邦学习的基础，随后 FedProx^[5]、FedBN^[6] 等方法进一步针对数据异构问题进行了改进。在医学影像领域，已有研究将联邦学习应用于脑肿瘤分割、视网膜病灶检测及息肉分割等任务。然而，大多数方法主要关注隐私保护，对跨域泛化问题考虑不

1. 重庆移通学院綦江校区公共大数据安全重庆重点实验室
重庆 401420

足，导致模型在未见中心上的性能仍然受限。

1.4 重参数化网络结构

近年来，重参数化技术在计算机视觉领域得到广泛研究。RepVGG^[7]、ACNet^[8]等工作表明，通过在训练阶段引入多分支结构、在推理阶段进行结构折叠。RCNU-Net 将重参数化思想引入医学图像分割领域，通过多尺度卷积和训练-推理结构分离策略，有效提升了息肉分割的精度与泛化能力。

2 方法

2.1 总体框架

在临床实际场景中，息肉图像通常来源于不同医疗中心，其成像设备、光照条件、分辨率及病灶分布均存在显著差异。这种跨中心数据分布不一致问题（domain shift）会严重影响集中式训练模型在未见域上的泛化性能。同时，医学数据受隐私保护与合规性约束，难以集中共享。因此，本文将息肉分割任务建模为联邦学习框架下的域泛化问题。

设系统中存在 K 个客户端（医疗中心），第 k 个客户端拥有本地数据集：

$$\mathcal{D}_k = \{(\mathbf{x}_i^k, \mathbf{y}_i^k)\}_{i=1}^{N_k} \quad (1)$$

式中： $\mathbf{x}_i^k \in \mathbb{R}^{C \times H \times W}$ 表示输入息肉图像； $\mathbf{y}_i^k \in \{0,1\}^{H \times W}$ 表示对应的二值分割标注。各客户端数据分布相互独立但不相同。

本文目标是在不共享原始数据的前提下，通过联邦训练学习一个具有跨域泛化能力的全局息肉分割模型，使其在未参与训练的目标域上仍能保持稳定、准确的分割性能。

为此，本文提出一种基于重参数化 U-Net 的联邦域泛化息肉分割方法，整体框架如算法 1 所示，主要由三个关键组成部分构成：

（1）重参数化 U-Net 主干网络，用于提升多尺度表征能力与推理效率；

（2）联邦域泛化训练策，通过跨客户端参数聚合学习域不变表示；

（3）区域感知对比约束与结构引导机制，增强模型对息肉边界与结构一致性的建模能力。

2.2 总体框架

本文方法整体框架如图 1 所示。




图 1 基于重参数化 U-Net 与联邦学习域泛化架构图

系统由多客户端本地训练模块、联邦参数聚合模块以及域泛化约束模块构成。每个客户端基于本地息肉数据训练重参数化 U-Net 模型，并引入频域辅助模态与对比学习损失；服务器端通过加权参数聚合生成全局模型，并周期性下发至各客户端。

算法 1 基于重参数化 U-Net 的联邦域泛化息肉分割算法

输入：多客户端息肉数据集 $\{\mathcal{D}_k\}_{k=1}^K$ ，其中每个客户端数据来自不同医疗中心； T 为联邦训练轮数； E 为本地训练轮数； η 为学习率； λ 为对比损失权重。

输出：具有域泛化能力的全局息肉分割模型 BestModel

1. 服务器初始化
2. 初始化全局模型参数 θ_0 ，并将其下发至所有客户端；
3. for 联邦训练轮次 $t = 1, 2, \dots, T$ do
4. for 每个客户端 $k = 1, 2, \dots, K$ 并行执行 do
5. 从数据集 $\mathcal{D}_k$ 中采样一批训练样本 (X, Y)
6. 构建多模态输入数据：
7. RGB 图像模态；
8. 频域幅值模态（傅里叶幅值谱）；
9. 结构引导掩码（轮廓与背景区域）；
10. 数据输入训练态重参数化 U-Net 网络；
11. 利用多分卷积模块进行前向传；
12. 获得分割预测结果 $\hat{Y}$ 及中间嵌入特征 $\mathbf{Z}$ ；
13. 计算 Dice 分割损失 L_{Dice} ；
14. 基于轮廓区域与背景区域构成正负样本对；
15. 计算对比学习损失 L_{Contrast} ；
16. 组合得到本地总损失：
17. $L = L_{\text{Dice}} + \lambda L_{\text{Contrast}}$ ；
18. 更新客户端本地模型参数 θ_k^t ；
19. end for
20. 服务器端接收所有客户端上传的本地模型参数；
21. 根据各客户端样本规模计算聚合权重 α_k ；
22. 执行加权模型聚合：
23. $\theta_{t+1} = \sum_{k=1}^K \alpha_k \theta_k^t$ ；
24. 更新全局模型参数，并同步至所有客户端；
25. end for

推理阶段：

- （1）对训练完成的全局模型进行结构重参数化；
- （2）将训练阶段的多分支卷积结构等效折叠为单分支卷积；
- （3）得到最终高效推理模型 BestModel。

2.3 数据处理

输入息肉图像为：

$$X \in \mathbb{R}^{C \times H \times W}, C=3 \quad (2)$$

首先对原始 RGB 图像进行尺寸归一化与强度标准化。

随后, 基于快速傅里叶变换构建频域幅值模态:

$$F = \log(1 + |\mathcal{F}(\text{Gray}(X))|) \quad (3)$$

式中: $\mathcal{F}(\cdot)$ 表示二维傅里叶变换。频域模态用于刻画图像的全局结构分布, 有助于缓解跨域光照与纹理差异带来的影响。

2.4 重参数化 U-Net 分割网络

在编码器与解码器的卷积模块中, 引入多分支卷积结构, 包括 3×3 、 1×1 卷积及恒等映射分支。训练阶段, 网络输出可表示为:

$$Y = \sum_{i=1}^K W_i \times X \quad (4)$$

在完成了训练内容之后, 通过重参方法将多分支权重无损整合为单一类型权重:

$$W_{eq} = \sum_{i=1}^K W_i \quad (5)$$

重参数方法保证了模型的性能, 同时满足了不额外引入算力的需求。

2.5 联邦学习与域泛化策略

如图 2 所示, 共有 N 个客户端, 第 n 个客户端在本地数据集 $\mathcal{D}_n$ 上更新模型参数 θ_n 。服务器端通过加权平均方式进行参数聚合:

$$\theta^{(t+1)} = \sum_{n=1}^N \alpha_n \theta_n^{(t)} \quad (6)$$

式中: α_n 与客户端样本规模相关。




图 2 域泛化策略示意图

为增强域泛化能力, 本文在特征空间引入对比学习约束, 通过轮廓区域与背景区域的嵌入向量构建正负样本对, 促使模型学习域不变的结构表征。

2.6 损失函数设计

总体损失函数由 Dice 损失与对比损失共同构成:

$$\mathcal{L} = \mathcal{L}_{\text{Dice}} + \lambda \mathcal{L}_{\text{Cont}} \quad (7)$$

式中: λ 为权重系数。该设计在保证区域分割精度的同时, 加强了对边界与结构信息的建模。

3 实验与分析

3.1 定量实验结果分析

如表 1 所示, 为验证方法在跨域息肉分割中的效果, 本文在多个公开数据集上进行了实验, 并采用单域外验证策略评估模型的泛化能力。评价指标包括 Dice 系数、IoU 以及 Hausdorff Distance 95% (HD95), 其中 Dice 与 IoU 用于衡量区域重叠程度, HD95 反映分割边界的空间误差。

表 1 模型在息肉图像上的定量实验结果

方法	Dice/% ↑	IoU/% ↑	HD95/px ↓
U-Net	84.32	74.15	18.46
UNet++	86.74	77.85	15.64
nnU-Net	88.12	79.66	14.32
FedAvg	87.03	78.21	15.87
FedDG	89.21	81.05	13.41
本文方法	90.18	82.67	12.92

实验结果表明, 与传统 U-Net 以及现有联邦学习分割方法相比, 本文方法在未见域上的 Dice 和 IoU 均取得显著提升。尤其在边界复杂、形态变化显著的息肉样本中, HD95 指标显著降低, 说明所提出方法在保持整体分割精度的同时, 能够更准确地定位息肉轮廓。这一优势主要得益于重参数化 U-Net 所带来的多尺度特征表达能力, 以及频域辅助与对比学习约束对域不变结构信息的有效建模。

3.2 消融实验分析

如表 2 所示, 为验证各模块对整体性能的贡献, 本文设计了多组消融实验。首先, 在不引入重参数化结构的情况下, 模型在未见域上的 Dice 和 IoU 明显下降, 说明多分支重参数化卷积在提升特征表达和泛化能力方面发挥了关键作用。其次, 移除频域幅值模态后, 模型在跨中心测试中的性能稳定性显著降低, 表明频域信息有助于缓解不同采集设备和光照条件带来的域偏移问题。

表 2 本文模型在息肉数据集上的消融实验

配置	重参数化	频域模态	对比学习	Dice/%↑	IoU/%↑	HD95 ↓
Baseline	×	×	×	87.46	78.92	15.38
重参数化	✓	×	×	89.73	81.06	13.84
频域模态	✓	✓	×	90.65	82.14	12.97
对比学习	✓	×	✓	90.11	81.63	12.41
本文模型	✓	✓	✓	90.18	82.67	12.92

此外,当移除对比学习约束,仅采用 Dice 损失进行训练时,模型在边界区域的 HD95 指标显著上升,说明对比学习在增强轮廓与背景区分能力方面具有重要意义。综合来看,各模块在性能提升中相互协同,共同构成了一个鲁棒的联邦域泛化息肉分割框架。

4 总结与反思

本文针对多中心结肠息肉图像在成像设备、数据分布及标注风格等方面存在显著域差异且在隐私约束条件下难以集中训练的问题,提出了一种基于重参数化 U-Net 的联邦域泛化息肉分割方法。该方法在联邦学习框架下引入域泛化思想,通过多客户端协同优化全局模型参数,在不共享原始数据的前提下有效提升模型在未知中心数据上的泛化能力,为隐私保护场景下的医学图像分割提供了一种可行且高效的解决方案。

在模型结构层面,本文以 U-Net 为基础,引入重参数化卷积模块作为核心骨干网络。通过在训练阶段采用多分支卷积结构以增强特征表达能力,并在推理阶段将多分支结构等效折叠为单一路径,实现了模型表达能力与推理效率之间的有效平衡。同时,结合 RCNU-Net 中对多尺度特征建模与边界感知的设计思想,模型能够更加充分地利用息肉区域与背景之间的结构差异,有效缓解传统 U-Net 在复杂肠道环境中易出现边界模糊与漏检的问题。

在学习策略层面,本文将联邦学习与元学习机制相结合,通过构建内外循环优化过程,使模型能够在各客户端本地快速适应域内分布变化,同时在全局聚合阶段学习具有跨域鲁棒性的共享表示。此外,引入基于轮廓感知的对比学习约束,将息肉边界区域与背景区域在嵌入空间中进行显式区分,有效提升了模型对息肉形态与结构细节的辨识能力。实验结果表明,该策略在 Dice、IoU 及 HD95 等多项评价指标上均显著优于传统联邦学习方法及不考虑域泛化的对比方法,尤其在未见中心数据上表现出更加稳定和一致的分割性能。

在多个公开息肉数据集上的对比实验和消融实验进一步验证了本文方法的有效性。结果显示,重参数化 U-Net 结构、联邦域泛化策略以及轮廓驱动对比损失在整体性能提升中均发挥了关键作用,各模块之间具有良好的协同效应。同时,模型在保持较高分割精度的同时,并未显著增加推理阶段的计算开销,具备较好的实际部署潜力。

尽管本文方法在多中心息肉分割任务中取得了较为理想的结果,但仍存在一定局限性。例如,当前方法主要针对二维图像进行建模,尚未充分利用序列或三维上下文信息;此外,客户端数量及数据规模对联邦优化过程的影响仍有待进

一步系统研究。未来工作将重点探索三维或时序建模在联邦域泛化场景下的应用,并尝试引入更加自适应的客户端权重分配策略和不确定性建模机制,以进一步提升模型在复杂临床环境中的鲁棒性与可靠性。

参考文献:

- [1] 项晓扬,王明涛,多化琼.引入卷积块注意力模块的 Attention U-Net 木材表面裂纹检测方法 [J]. 林业工程学报, 2024, 9(4): 140-146.
- [2] 刘阳洋,耿国华,刘鑫达,等.改进 U-Net++ 的瓷器文物显微气泡分割 [J]. 西北大学学报(自然科学版), 2025, 55(1): 129-138.
- [3] 苏斐,王光辉,史艳霞,等.融合通道注意力机制的 ResUnet 作物病斑分割模型 [J]. 中国农机化学报, 2024, 45(8): 228-233.
- [4] 王丹,吴腾,于振华,等.基于联邦学习的代价敏感卷积神经网络分类方法 [J]. 西安科技大学学报, 2025, 45(3): 591-606.
- [5] 周天阳,杨磊.基于 Edge-TB 的联邦学习中客户端选择策略和数据集划分研究 [J]. 计算机科学, 2024, 51(S1): 626-631.
- [6] 张明晗,张国梁.基于聚类的个性化联邦学习鲁棒性研究 [J]. 科技创新与应用, 2025, 15(10): 66-70.
- [7] 胡益博,杨舒鹏,马思雨,等.一种基于 RepVGG 的图像分类方法 [J]. 长江信息通信, 2024, 37(4): 146-148.
- [8] DING X H, GUO Y C, DING G G, et al. ACNet: strengthening the kernel skeletons for powerful cnn via asymmetric convolution blocks[C]//Proceedings of the IEEE/CVF international conference on computer vision. Piscataway: IEEE, 2019: 1911-1920.

【作者简介】

黄柏雄(1997—),男,四川达州人,硕士研究生,研究方向:医学图像处理。

(收稿日期:2025-12-22 修回日期:2026-02-05)