

基于张量分解与斯皮尔曼对齐的多源域自适应方法

王成前

苏州大学 江苏 苏州 215021

【摘要】：多源域自适应旨在利用多个不同来源的数据来协同提升模型在无标签目标域上的分割表现，但如何有效融合异构特征并抑制跨域过程中的负迁移效应，仍是当前该领域的难点与挑战。本文提出了一种基于张量分解与斯皮尔曼对齐的多源域自适应分割算法（TS-MDA）。该算法以具备全局感知能力的 U-Mamba 为骨干网络以捕捉宏观解剖结构表征，并结合张量低秩分解思想在参数空间重构线性投影层；在深层特征处理上，算法构建对比学习以实现跨域语义对齐，并通过分组向量量化精炼深层表征。本文在公开眼底 OCT 数据集上全面的对比实验评估。

【关键词】：OCT 图像；多源域自适应；图像分割；张量分解；表征学习

DOI:10.12417/2705-0998.26.10.045

1 引言

OCT 图像分割能够实现视网膜生理结构及微小病灶的像素级定位与轮廓勾画。在临床应用中，高精度的分割算法能对眼科疾病进行动态三维量化测算，驱动眼科影像评价体系由“主观定性”向“客观精准定量”跨越。基于深度学习的 AI 模型凭借端到端的自适应特征提取能力，现已成为全面提升 OCT 图像分割精度与效率的主流范式。

然而，深度学习模型的跨设备泛化性缺失严重制约了其临床落地应用。由于不同医疗中心采用的扫描设备在光学硬件和成像协议上存在显著差异，导致生成的 OCT 图像在灰度分布、对比度及伪影特征上表现出明显的域偏移（DomainShift）现象。为了打破这一局限，研究者们提出了域适应（DA）等迁移策略。其中，无监督域适应（UDA）通过引入目标域无标签数据进行联合训练，有效规避了医学影像像素级标注成本高昂的瓶颈。

鉴于此，本文聚焦于视网膜 OCT 图像在跨设备、多中心部署时的泛化难题，深入探讨了多源域自适应在眼底图像分割中的理论与应用。针对现有方法在复杂解剖结构对齐上的局限性，本文结合深度学习基础理论，提出了一种应用于 OCT 图像的多源域自适应分割方法。

2 方法

基于张量分解与斯皮尔曼对齐的多源域自适应分割算法（TS-MDA）的网络架构如图 2-1 所示。




图 2-1 TS-MDA 算法整体结构图

2.1 频域路由与张量分解

为了感知目标域与源域风格的亲和力，本文首先构建了对数欧几里得频域路由器（LESR）。对于输入的图像 x ，可以描述为：

$$x_{sf} = \text{Concat} \left(x, \text{Norm} \left(\log \left(\mathcal{F}_{\text{shift}}(|\text{FFT}(x)|) \right) \odot \right. \right. \quad (2-1)$$

$$\left. M_1 + \epsilon \right))$$

其中 x 为输入图像， $\mathcal{F}_{\text{shift}}(\cdot)$ 表示频域中心化操作， M_1 为低通掩码， ϵ 为避免数值不稳定的极小常数， $\odot$ 为逐元素相乘运算， x_{sf} 为拼接后的结果。

x_{sf} 经过卷积层后被映射至协方差流形，将其展平为向量后送入最后由 MLP 构成的路由头。在推理阶段，输入目标域图像，经过 Softmax 生成路由权重 α_i ，用于后续任务。

为了赋予 Mamba 感知多域知识的能力，本文将张量 CP 分解理论应用于 Mamba 块的输入线性投影阶段，利用低秩约束强制在特征进入 SSM 之前完成初步的去噪与结构化提纯，使模型能更准确地聚焦于跨域共享的解剖结构。

具体来说，CPMamba 层将庞大的多域输入线性层权重张

量转化为由投影矩阵 U, V 与域系数词典 D 构成的动态重构算子。对于源域输入特征 $X_{src_n} \in \mathbb{R}^{C \times L}$ 与目标域输入特征 $X_{tgt} \in \mathbb{R}^{C \times L}$ ，其 CP 线性映射过程如下：

$$X'_{src_n} = U((VX_{src_n}) \odot d_n) \quad (2-2)$$

$$X'_{tgt} = U((VX_{tgt}) \odot (\sum_{n=1}^N \alpha_{r,n} \cdot d_n)) \quad (2-3)$$

其中， $V \in \mathbb{R}^{R \times C}$ 为输入投影矩阵，负责将输入的原始高维特征 X 投影至一个 R 维的共享低秩子空间； $D = \{d_1, d_2, \dots, d_N\} \in \mathbb{R}^{N \times R}$ 为域因子矩阵， d_n 代表了第 n 个源域在低秩空间中的域特征基底； $U \in \mathbb{R}^{C_{Exp} \times R}$ 为输出投影矩阵，将在低秩空间中完成重组后的特征映射回目标语义空间， C_{Exp} 为输入线性层的输出维度。

2.2 语义对齐与向量量化

SSAM 其核心在于利用软 Spearman 相关矩阵刻画跨域鲁棒的语义表示，并引入语义对比学习与动态损失加权机制。

构建输入特征的斯皮尔曼相关矩阵 $K \in \mathbb{R}^{C \times C}$ 后，首先是样本级的语义对比学习。对于给定的目标域特征，模块首先计算其相关矩阵 K_{tgt} 与所有源域样本相关矩阵 $\{K_{src,j}\}_{j=1}^{n_{src}}$ 的 L_2 距离， n_{src} 为所有源域样本的数量。通过在度量空间搜索语义最接近的源域样本为其正样本。随后，在投影头映射后的嵌入空间中，利用对比学习对齐损失约束特征分布。

其次是带有最低权重保障的动态加权机制。模块将目标域样本与各个源域池的平均语义距离进行负对数处理，并通过 Softmax 转换为各源域的加权系数 w_{Dyn} 。

分组向量量化模块 (GVQ) 的设计初衷是利用离散化瓶颈效应，实现特征的结构化对齐，增强跨域特征的稳定性。特征图 F 每个像素的特征向量经过量化后，得到特征图 F_q 。

参考文献：

- [1] HeJ, JiaX, ChenS, et al. Multi-sourcedomainadaptationwithcollaborativelearningforsemanticsegmentation[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021: 11008-11017.
- [2] MaJ, LiF, WangB. U-mamba: Enhancing long-range dependency for biomedical image segmentation[C]//International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer Nature Switzerland, 2024.
- [3] PengX, BaiQ, XiaX, et al. Moment matching for multi-sourcedomainadaptation[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. 2019: 1406-1415.
- [4] HuS, LiaoZ, XiaY. Domain specific convolution and high frequency reconstruction based unsupervised domain adaptation for medical image segmentation[C]//International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer Nature Switzerland, 2022: 650-659.
- [5] PeiC, WuF, YangM, et al. Multi-sourcedomainadaptationfor medical image segmentation[J]. IEEE transactions on medical imaging, 2023, 43(4):

3 实验结果

为了验证算法的有效性，本文将在公开眼底积液分割数据集 RETOUCH^[7] 上进行实验验证。本节将 TS-MDA 算法与几种先进算法进行了比较，包括 DRT^[8]、DoCR^[4]、StandardGAN^[9]、M3SDA^[3]、MCLS^[1]、M2CD^[5] 和 DRO^[6]。实验结果如表 3-1 所示。

表 3-1 RETOUCH 数据集对比实验分割精度

Methods	Domain1	Domain2	Domain3	mDice
UpperBound	81.82	82.16	86.17	83.39
DoCR	70.83	71.34	76.87	73.01
DRT	72.01	70.91	77.70	73.54
M2CD	72.96	72.87	79.96	75.26
StandardGAN	75.64	74.10	78.99	76.24
M3SDA	76.00	75.27	81.18	77.48
MCLS	77.64	77.07	82.15	78.96
DRO	77.97	77.73	83.57	79.76
TS-MDA	80.29	80.71	85.63	82.21

4 结论

针对域偏移现象制约临床实用化的迫切需求，本文深入研究了现有的域适应理论、特征解耦与先进的表征学习技术，将研究视角聚焦于更具挑战性且贴近真实医疗场景的多源域自适应任务。以此为切入点，本文从张量分解、语义对齐等维度出发，提出了一种新颖的多源域自适应分割方法，并在公开多域眼底 OCT 图像数据集上进行了充分的实验验证。实验结果表明，该算法相较于现有主流方法实现了分割精度和 Dice 系数的进一步提升，展现出极强的跨域能力。

1640-1651.

- [6] KimS,JoSH,HaW,etal.DistributionallyRobustClassificationforMulti-sourceUnsupervisedDomainAdaptation[C]//InternationalConferenceonLearningRepresentations.2026.
- [7] BogunovićH,VenhuizenF,KlimschaS,etal.RETOUCH:TheretinalOCTfluid detectionandsegmentationbenchmarkandchallenge[J].IEEEtransactionsonmedicalimaging,2019,38(8):1858-1874.
- [8] LiY,YuanL,ChenY,etal.Dynamictransferformulti-sourcedomainadaptation[C]//ProceedingsoftheIEEE/CVFCongressonComputerVisionandPatternRecognition.2021:10998-11007.
- [9] TasarO,TarabalkaY,GirosA,etal.StandardGAN:Multi-sourcedomainadaptationforsemanticsegmentationofveryhighresolutionssatelliteimagesbydatastandardization[C]//ProceedingsoftheIEEE/CVFCongressonComputerVisionandPatternRecognitionWorkshops.2020:192-193.