

中图法分类号: TP391 文献标识码: A 文章编号: 1006-8961(XXXX)XX-0001-18

论文引用格式: Chen Zailiang, Liu Baicheng, Wu Wenjia, Shen Hailan, Liu Hui. Bias-correction guided contrastive consistency learning for semi-supervised MRI image segmentation [J/OL]. Journal of Image and Graphics, XXXX: 1-18. DOI: 10.11834/jig.260065. (陈再良, 刘佰成, 伍文佳, 沈海澜, 刘慧. 偏差矫正与对比学习协同的半监督MRI图像分割[J/OL]. 中国图象图形学报, XXXX: 1-18. DOI: 10.11834/jig.260065.) [DOI: 10.11834/jig.260065]

偏差矫正与对比学习协同的半监督MRI图像分割

陈再良¹, 刘佰成¹, 伍文佳¹, 沈海澜¹, 刘慧²

1. 中南大学计算机学院, 长沙 410083; 2. 中南大学湘雅医院, 长沙 410008

摘要: 目的 半监督学习在医学图像分割领域已取得显著进展。然而, 由于医学图像中普遍存在低对比度和组织边界模糊等问题, 模型在无标注数据上生成的伪标签往往包含不准确区域。在一致性训练过程中, 这些误差会被反复利用并逐步累积, 从而显著削弱模型的分割性能。磁共振成像(magnetic resonance imaging, MRI)图像中, 组织边界更加模糊、对比度更低, 使得上述问题进一步加剧。为解决这一问题, 本文提出了一种基于偏差矫正与对比学习的半监督MRI图像分割方法BC-Net。方法 具体而言, BC-Net通过设计一种偏差矫正机制, 对伪标签中置信度高但不可靠的偏差区域进行识别与修正, 并在一致性训练中对这些偏差区域赋予更高权重, 以有效缓解潜在错误的影响。同时, 针对高置信度且无偏差的区域, 引入对比学习策略, 以这些区域作为锚点进行采样, 从而提取更加有效的全局表示。上述双重策略使模型能够同时充分利用偏差区域与无偏差区域的信息, 显著提升分割能力。结果 本文在私有子宫内膜癌MRI数据集和两个公开MRI数据集上进行了大量实验, 与现有方法相比提升了分割性能, 验证了方法的有效性。结论 BC-Net能够同时充分利用偏差区域与无偏差区域的信息, 有效抑制伪标签偏置带来的负面影响, 显著提升半监督MRI图像分割的整体性能, 具有良好的应用前景。

关键词: 一致性训练; 对比学习; 偏差矫正; 半监督学习; 医学图像分割

Bias-correction guided contrastive consistency learning for semi-supervised MRI image segmentation

Chen Zailiang¹, Liu Baicheng¹, Wu Wenjia¹, Shen Hailan¹, Liu Hui²

1. School of Computer Science and Engineering, Central South University, Changsha 410083, China; 2. Department of Radiology, Xiang Ya Hospital, Central South University, Changsha 410008, China

Abstract: Objective Medical image segmentation plays a fundamental role in computer aided diagnosis by enabling accurate delineation of anatomical structures and pathological regions. Although fully supervised deep learning methods have achieved remarkable success in medical image segmentation, their performance strongly depends on large scale pixel wise annotations, which are costly, time consuming, and require substantial clinical expertise. Semi supervised learning has therefore emerged as a promising alternative by leveraging a small amount of labeled data together with abundant unlabeled data. Among existing semi supervised approaches, consistency-based methods have demonstrated strong performance by encouraging prediction consistency under different perturbations. However, in challenging medical imaging scenarios, particularly MRI images characterized by low contrast, blurred boundaries, and noise, pseudo labels generated during training often contain regions that are highly confident but unreliable. These biased pseudo labels may be repeatedly reinforced

收稿日期: 2026-01-29; 修回日期: 2026-05-09

基金项目: 国家自然科学基金项目(62541211)

Supported by: National Natural Science Foundation of China(62541211)

during consistency training, leading to error accumulation and degraded segmentation performance. Moreover, most consistency-based methods treat pixels as independent units and fail to fully exploit spatial and semantic correlations that are critical for accurate boundary delineation. To address these limitations, this paper proposes a bias correction guided contrastive consistency learning framework, termed BC-Net, for semi supervised MRI image segmentation. **Method** BC-Net is built upon the CPS framework and consists of three key components: cross-view consistency training, a bias-correction guided pseudo label optimization module, and a high-confidence guided pixel-level contrastive learning module. First, two segmentation sub-networks with identical architectures but independent parameters are trained using cross pseudo supervision. For labeled data, standard supervised losses combining cross-entropy and Dice loss are applied. For unlabeled data, predictions from one sub-network are used as pseudo labels to supervise the other, enforcing consistency across different augmented views. To mitigate the adverse impact of biased pseudo labels, a Bias-Correction Guided Pseudo Label (BCGPL) module is introduced. Instead of directly trusting all pseudo labels, BCGPL explicitly identifies two types of high-confidence but unreliable biased regions commonly observed in MRI segmentation: (1) non-maximum connected component bias, where small isolated regions with high confidence do not correspond to true anatomical structures, and (2) prediction inconsistency bias, where different sub-networks produce conflicting predictions for the same pixel under different views. These biased regions are detected through connected component analysis and pixel-wise XOR operations between sub-network predictions. A dynamic confidence threshold is further employed to distinguish trustworthy predictions from potentially erroneous ones. During consistency training, higher weights are assigned to high-confidence biased regions, encouraging the network to focus on correcting these errors, while low-confidence or unbiased regions are treated with standard consistency constraints. This strategy enables iterative refinement of pseudo labels and effectively suppresses bias accumulation. To further enhance global semantic representation and exploit inter-pixel relationships, a High-Certainty-aware Pixel-level Contrastive Learning (HCPCL) module is incorporated. Unlike existing pixel-level contrastive learning methods that directly sample anchors from noisy pseudo labels, HCPCL selects anchor pixels exclusively from high-confidence, low-bias regions, referred to as high-certainty regions. These regions are more likely to align with true annotations and thus provide reliable supervision. Deep feature representations are projected into a low-dimensional embedding space, where pixel-level contrastive learning is performed using an InfoNCE loss. A dynamic class-wise memory queue is maintained to store representative features and construct diverse positive and negative sample sets. By leveraging high-certainty anchors and a memory-based contrastive strategy, HCPCL strengthens semantic consistency within target regions while improving discrimination between different anatomical structures. The overall training objective combines supervised loss on labeled data, bias-corrected consistency loss on unlabeled data, and pixel-level contrastive loss, enabling BC-Net to jointly improve pseudo label quality and feature representation learning in a unified framework. **Result** Extensive experiments were conducted on one private endometrial cancer MRI dataset and two public MRI datasets, namely ACDC and PROMISE12, under different labeled data ratios (10% and 20%). The proposed BC-Net was compared with a wide range of state-of-the-art semi-supervised segmentation methods, including MT, UAMT, CCT, CPS, URPC, SS-Net, DC-Net, BCP, SLC-Net, and PPC, using consistent network architectures and training protocols. Quantitative evaluation was performed using Dice coefficient, Jaccard index, Average Surface Distance (ASD), and 95% Hausdorff Distance (95HD). On the endometrial cancer MRI dataset, BC-Net consistently achieved the best performance across all metrics. With only 10% labeled data, BC-Net improved the Dice coefficient by 6.04% over the CPS baseline and significantly reduced boundary errors, outperforming even fully supervised U-Net trained with 20% labeled data. Similar trends were observed on the ACDC dataset, where BC-Net achieved competitive global segmentation accuracy while maintaining superior boundary precision. On the PROMISE12 dataset, which poses additional challenges due to extreme data scarcity and structural variability, BC-Net demonstrated strong robustness and delivered substantial improvements over competing methods, particularly in low-label settings. Ablation studies further validated the effectiveness of each component. The BCGPL module significantly reduced the number of biased pseudo label pixels during training, while the HCPCL module enhanced global semantic coherence and boundary accuracy. Additional experiments on bias type selection, anchor sampling strategies, and hyperparameter sensitivity confirmed that jointly correcting multiple bias types and sampling anchors from high-certainty regions are critical for optimal performance. Qualitative visualizations also demonstrated that BC-Net produces

more complete target regions and sharper boundaries, especially in low-contrast and ambiguous areas. **Conclusion** This paper presents BC-Net, a novel semi-supervised MRI image segmentation framework that integrates bias-correction guided pseudo label optimization with high-confidence guided contrastive consistency learning. By explicitly identifying and correcting high-confidence biased regions during consistency training, BC-Net effectively alleviates error accumulation caused by unreliable pseudo labels. Meanwhile, the proposed contrastive learning strategy leverages high-certainty regions to enhance global semantic representation and inter-pixel consistency, leading to more accurate and robust segmentation results. Extensive experimental results on multiple MRI datasets demonstrate that BC-Net consistently outperforms existing semi-supervised methods under limited annotation settings. The proposed framework provides an effective solution for reducing annotation dependency while improving segmentation accuracy and boundary precision, and shows strong potential for practical clinical applications in medical image analysis.

Key words: consistency training; contrastive learning; bias correction; semi-supervised learning; medical image segmentation

0 引言

医学图像分割是计算机辅助诊断系统中的一项基础且关键的步骤,对器官和病灶进行精确分割能够为医生的早期评估和诊断提供更加可靠的依据(Zhang等,2025)。基于深度学习的监督方法依赖于充足且精确的人工标注,从而能够获得优异的分割性能(Qureshi等,2023)。然而,标注数据的获取通常成本高昂,不仅需要大量时间投入,还依赖于专业的临床知识,这使得大规模、高质量的标注数据集难以获得。因此,半监督学习被引入医学图像分割任务中,通过结合少量有标注数据与大量无标注数据,在很大程度上缓解了标注数据不足的问题(Quali等,2020;Yang等,2022;Jiao等,2023;Shen等,2023;Xiong等,2024)。

近年来,一致性正则化因在医学图像分割任务中展现出优异性能而逐渐成为研究热点。该类方法通过约束模型在不同输入扰动下的预测结果保持一致,以充分挖掘无标注数据中的潜在信息,其实现方式包括参数关联的方法(如均值教师模型(mean teacher, MT)(Tarvainen和Valpola,2017)),以及采用相互独立子网络的方法(如交叉伪监督学习(cross pseudo supervision, CPS)(Chen等,2021))。然而,MT方法高度依赖有限的有标注数据,容易产生过拟合问题,而CPS通过引入子网络之间的结构多样性,降低了对标注数据的依赖,一定程度上缓解了过拟合风险。然而,这类方法在很大程度上依赖于无标注数据的利用方式。在半监督学习中,模型通常需要借助伪标签为无标注数据提供监督信号。在实际

训练过程中,模型往往会产生带有偏差的高置信度伪标签,这些偏差容易被不断强化,从而对模型性能产生不利影响。

在医学图像分割中,受限于图像对比度低、组织边界模糊等固有挑战,模型在训练过程中往往生成质量较低的伪标签,从而进一步加剧数据中高置信度偏差对模型训练的负面影响(Ding等,2023;Jiang和Li,2024)。已有方法(如UAMT(Yu等,2019)、FixMatch(Sohn等,2020)和AC-MT(Xu等,2023))通过引入不确定性度量或基于熵的策略来提升伪标签质量。然而,这些方法在非最大连通区域以及模糊边界区域中仍可能放大偏差,导致训练过程中错误信息的持续累积。上述挑战在磁共振成像(magnetic resonance imaging, MRI)中表现得尤为突出。相较于其他医学影像模态,MRI图像的组织对比度更低、边界模糊程度更高,且常伴有磁场不均匀导致的伪影,这使得高置信度偏差区域在MRI数据中更为常见且难以有效甄别。

为了解决上述问题,本文在CPS框架基础上提出了一种基于偏差矫正的伪标签模块(bias-correction guided pseudo label, BCGPL)。BCGPL在一致性训练过程中对偏差区域赋予更高权重,以有效修正高置信度伪标签偏差。该模块主要针对两类特定偏差:一是出现在非最大连通区域中的高置信度非主体预测偏差,二是由不同增强视角引起的不一致区域中的高置信度预测偏差。

尽管上述方法能够在一定程度上缓解伪标签中的高置信度偏差问题,但基于一致性的半监督方法通常将每个像素视为相互独立的个体,从而忽略了医学图像分割中至关重要的空间与语义相关性(Lei

等,2022;Pan 等,2025)。为了解决这一问题,一些研究引入对比学习以增强像素之间的依赖关系(Wang 等,2021;Zhong 等,2021;Wu 等,2023;Li 等,2025)。然而,基于低质量伪标签进行锚点采样可能会引入噪声,进而降低模型性能。近期工作(Wang 等,2022;Basak 和 Yin,2023)通过预测概率分布的熵来估计不确定性,但此类度量往往难以识别高置信但不可靠的偏差。相比之下,高确定性区域通常更接近真实标注且不包含显著偏差,因此可作为更加可靠的锚点样本,从而有效避免偏差特征的引入。

基于上述分析,本文提出了一种用于半监督医学 MRI 分割的基于偏差矫正与对比一致性学习的方法 BC-Net。首先,为了提升伪标签质量,本文引入了一种偏差矫正机制,在一致性训练过程中重点关注潜在的高置信度偏差区域,从而有效修正伪标签中的偏差。此外,为了充分利用像素之间的精确上下文信息,本文引入对比学习以增强网络的全局表征能力,并提出了一种基于伪标签高确定性区域的锚点采样策略,从而实现目标区域的精细分割。

本文的主要贡献如下:

1)提出了一种用于半监督 MRI 图像分割的基于偏差矫正的对比一致性学习方法 BC-Net,并设计了有效的偏差矫正机制。

2)提出了 BCGPL 模块,在一致性训练过程中重点关注两类高置信但不可靠的偏差区域,从而有效缓解训练中的偏差问题。

3)为了充分利用像素间的精确上下文信息,提出了高确定性引导的对比学习模块(high-certainty-aware pixel-level contrastive learning, HCPCL),以增强网络对全局语义信息的建模能力。

4)在三个医学图像数据集上的实验结果表明,所提出的方法在分割性能上优于现有方法,验证了其有效性。

1 本文方法

1.1 整体网络架构

在 CPS 框架的基础上,本文提出了一种基于偏差矫正与对比学习的半监督 MRI 图像分割方法。其整体网络架构如图 1 所示,主要由三个关键模块组成:基于交叉视图的一致性训练网络、基于偏差矫正引导的伪标签优化模块,以及基于高确定性引导的

像素级对比学习模块。本文采用两个独立子网络进行交叉监督一致性训练,这两个子网具有相同的架构但不共享参数。为了利用子网之间的多样性来从未标记数据中学习信息特征,标记数据和未标记数据同时进行弱增强和强增强分别输入到两个子网络中,获得输出预测并计算相关损失。接下来,本文将对基于交叉视图的一致性训练、基于偏差矫正引导的伪标签优化方法以及基于高确定性区域引导的像素级对比学习方法进行具体介绍。

1.2 基于交叉视图的一致性训练

在 CPS 框架的基础上,本文针对 MRI 图像分割任务的特点对其进行改进,整体结构对比如图 2 所示。相比原始 CPS 方法,本文从数据增强策略和伪标签利用方式两个方面进行了优化:一方面,引入更适用于 MRI 图像的数据增强方式以提升模型对输入扰动的鲁棒性;另一方面,结合后续提出的偏差矫正引导的伪标签优化模块和高确定性引导的像素级对比学习模块,进一步提升未标记数据的利用效率。

1.2.1 数据增强

在一致性训练中,数据增强用于构建同一图像的不同视图,从而约束模型在不同扰动下保持预测一致性。给定输入图像 X ,本文首先通过随机旋转和随机翻转生成其弱增强版本 X^w ,在此基础上,进一步引入色彩抖动操作(通过随机改变图像的亮度、对比度、饱和度和色调)以生成强增强版本 X^s 。

1.2.2 有监督训练

对于标记数据 X^l ,使用真实标签 Y^l 作为监督信号计算有监督的损失 L_{sup} ,以训练分割模型的两个子网络 f_1 和 f_2 ,该损失计算如公式(1)所示:

$$\begin{aligned} L_{seg} &= \frac{1}{2} \times (L_{ce} + L_{dice}) \\ L_{sup} &= L_{seg}(P_1^l, Y^l) + L_{seg}(P_2^l, Y^l) \end{aligned} \quad (1)$$

式中, L_{seg} 表示分割损失,包括了交叉熵损失 L_{ce} 和 Dice 损失 L_{dice} , P_1^l 是经过子网络 f_1 得到的预测结果, P_2^l 是经过子网络 f_2 得到的预测结果。

1.2.3 伪标签生成与一致性训练

对于未标记的数据 X^u ,首先将其分别输入两个子网络 f_1 和 f_2 得到对应的预测结果 P_1^u 和 P_2^u ,然后通过 argmax 操作从而生成初始伪标签 \hat{Y}_1^u 和 \hat{Y}_2^u 。在 CPS 框架中,采用交叉伪监督机制进行训练,即利用子网络 f_1 生成的伪标签 \hat{Y}_1^u 来监督子网络 f_2 同时利用

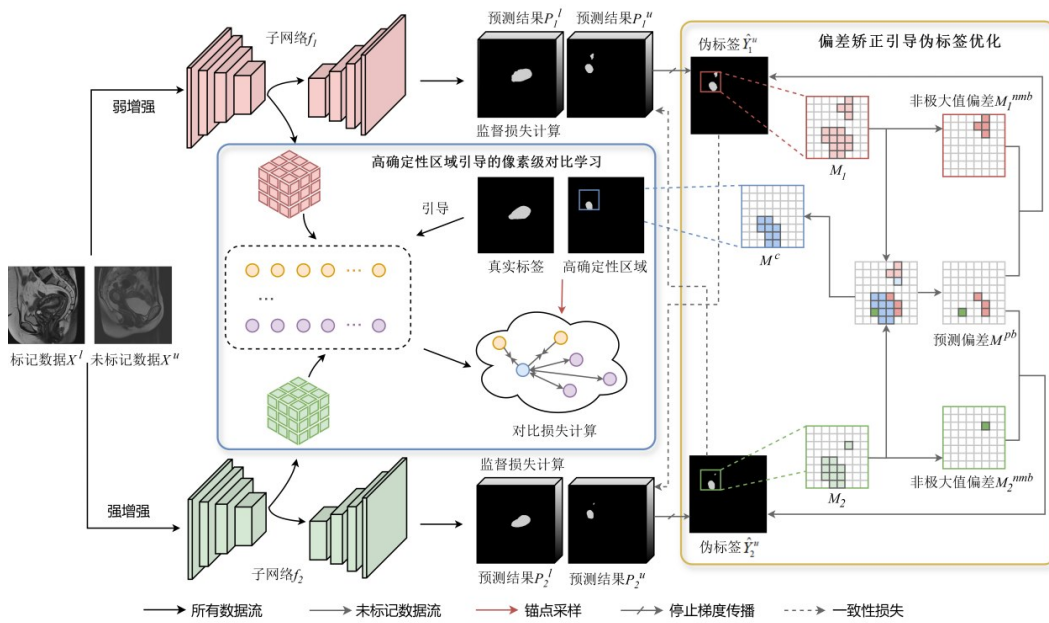


图1 偏差矫正与对比学习协同的半监督MRI图像分割方法的整体结构图

Fig. 1 Overall architecture of semi-supervised MRI segmentation via bias-correction guided contrastive consistency learning

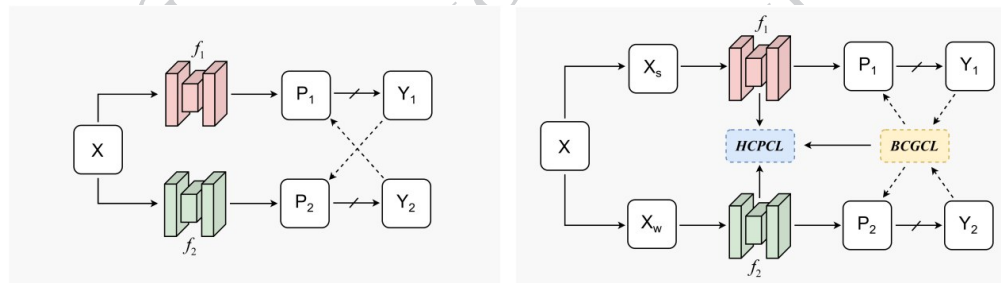
(a)CPS (b)本文方法
((a) CPS;(b) our method)

图2 CPS和本文方法的对比示意图

Fig. 2 Schematic comparison between CPS and our method

子网络 f_2 生成的伪标签 \hat{Y}_2^u 监督子网络 f_1 。基于上述交叉伪监督机制,计算一致性损失 L_{con} 来最小化不同增强视图之间的预测差异,从而促使模型在相似输入下输出一致的分割结果。一致性损失的计算如公式(2)所示:

$$L_{con} = L_{ce}(P_1, \hat{Y}_2^u) + L_{ce}(P_2, \hat{Y}_1^u) \quad (2)$$

然而,直接利用初始伪标签参与一致性训练时,伪标签中的预测偏差会被引入损失计算过程,从而影响模型的训练效果。针对这一问题,本文提出了一种基于偏差矫正引导的伪标签优化策略,用于对上述一致性损失进行改进。

1.3 基于偏差矫正引导的伪标签优化

MRI图像中普遍存在边界模糊和对比度较低的

问题,导致病灶区域与背景高度相似,使得伪标签中的预测偏差往往集中在边界及低对比度区域。在伪标签生成阶段,如果直接将这伪标签用于交叉伪监督训练,则其中的错误信息会在网络之间传播并被不断强化。例如,在子宫内膜癌MRI图像中,模型可能将子宫肌层误分割为病灶区域,从而产生高置信度但错误的伪标签,使得模型难以在后续训练中纠正该类误差。为了缓解这个问题,本文提出了基于偏差矫正引导的伪标签优化方法,首先对伪标签中的潜在偏差区域进行定位,然后在一致性训练过程中对这些区域进行重点约束,以引导模型逐步修正预测偏差,整体流程如图3所示。

进一步地,根据偏差的来源,将潜在偏差区域划分为两类:非极大值偏差区域和预测偏差区域,该划

分为后续一致性损失的加权重构提供了基础。图4展示了在子宫内膜癌MRI图像中伪标签两种类型的偏差区域。其中,图4(a)和(d)分别为子宫内膜癌原始MRI图像和对应的真实标签;图4(e)和(f)为两个子网络分别为原始图像生成的初始伪标签。

1.3.1 非极大值偏差区域

由于MRI成像过程中存在噪声,伪标签中往往会出现多个离散的连通区域。通常情况下,最大连通区域对应真实的目标结构,而较小的孤立连通区域多为噪声或错误预测。因此,本文将这些非最大

连通区域视为潜在的偏差区域,并对其进行建模。非极大值偏差区域掩码的生成过程如下:

1)连通区域提取:对两个子网络的伪标签 \hat{Y}_1^u 和 \hat{Y}_2^u 分别进行连通区域分析,排除背景类后,提取每类(如肿瘤、器官)的所有连通分量;

2)非极大值区域判定:对每个类别,保留像素数最多的连通分量作为最大连通分量(largest connected component, LCC),其余分量定义为非极大值偏差区域,如图4(e)所示的中的红色区域展示

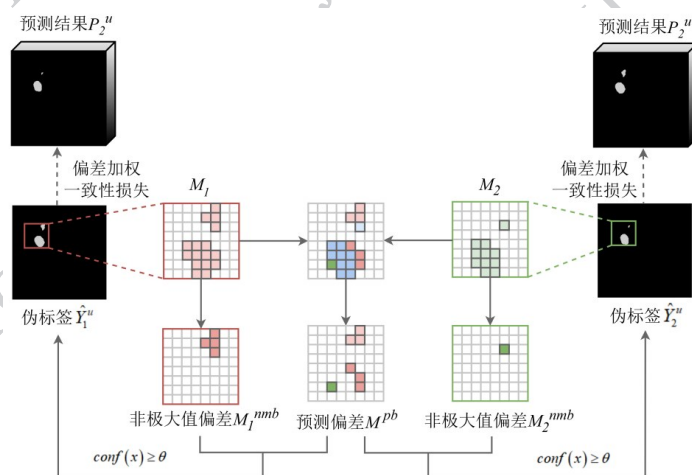
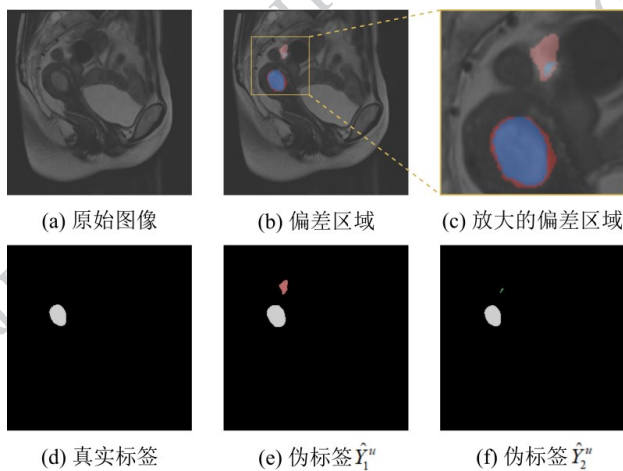


图3 基于偏差矫正引导伪标签优化方法流程

Fig. 3 Workflow of the bias-correction guided pseudo label optimization method



((a) image; (b) bias regions; (c) enlarged bias regions; (d) groundtruth; (e) pseudo label \hat{Y}_1^u ; (f) pseudo label \hat{Y}_2^u)

图4 子宫内膜癌MRI图像中的非极大值偏差与预测偏差区域示意图

Fig. 4 Illustration of non-maximum bias and prediction-biased regions in MRI images of endometrial cancer

了伪标签 \hat{Y}_1^u 中的非极大值偏差区域;图4(f)中的绿色区域表示伪标签 \hat{Y}_2^u 中的非极大值偏差区域。

3)非极大值偏差区域掩码 M_i^{nm} 生成如公式(3)所示:

$$M_i^{nm} = \bigcup_{c \in C} (CC_c^i \setminus LCC_c^i) \quad (i = 1, 2) \quad (3)$$

式中, $i = 1, 2$ 分别表示子网络 f_1 和 f_2 , CC_c^i 表示子网络 f_i 输出的类别 c 的所有连通分量, LCC_c^i 为最大连通分量。

1.3.2 预测偏差区域

预测偏差来源来自于两个子网络在同一像素上的预测不一致性,当两个子网络对同一位置给出不同预测结果时,通常表明该区域属于边界模糊或语义不确定区域,此类区域若处理不当,容易在交叉监督过程中引入错误传播,如图4所示的(b)、(c)中的深红色区域展示了伪标签中的预测偏差区域。为此,本文通过对两个子网络生成的伪标签进行逐像素比较,利用异或(exclusive OR, XOR)操作检测预

测不一致区域,从而得到预测偏差区域的掩码 M^{pb} , 如公式(4)所示:

$$M^{pb} = \hat{Y}_1^a \oplus \hat{Y}_2^a \quad (4)$$

在获得非极大值偏差区域和预测偏差区域后,若直接对所有偏差区域赋予较大权重,可能会对真实的模糊结构产生过度约束。特别是对于低置信度的偏差区域,其往往对应真实存在的解剖结构过渡区域,此时模型仍需保留对该类区域的探索能力。因此,本文提出了一种基于置信度的偏差权重分配策略,仅对高置信度的偏差区域赋予更大的权重,以突出可信但可能错误的预测区域,同时抑制低置信度噪声的干扰。

首先设置一个随训练迭代动态变化的置信度阈值 θ ,用于判断偏差区域的预测可靠性,其定义如公式(5)所示:

$$\theta = \log(2) \cdot (\alpha + \beta \cdot \sigma(T, \max_T)) \quad (5)$$

式中, T 表示当前的迭代次数, \max_T 表示总迭代次数, α 和 β 是超参数, σ 是 sigmoid 函数。

然后,通过以上置信阈值可以筛选出高置信度的非极大值偏差区域 $M_{i,c}^{nmb}$ 和高置信度的预测偏差区域 M_c^{pb} , 计算公式如式(6)所示:

$$M_{i,c}^{nmb}, M_c^{pb} = \{x \in M_i^{nmb}, M^{pb} | \text{conf}(x) \geq \theta\} \quad (6)$$

($i = 1, 2$)

式中, $\text{conf}(\cdot)$ 表示置信度分数。

在伪标签优化过程中,不同偏差区域对伪标签的影响存在差异,本文为不同偏差区域在一致性损失计算中设置了不同的权重关注。因此,本文在一致性损失计算中对不同偏差区域赋予不同的权重。此外,为了充分利用偏差区域中可能包含的有效语义信息,对于置信度较低的偏差区域,其预测结果不予直接丢弃,而对于无偏差区域,由于其预测已相对稳定,也无需赋予额外权重。

因此,对于除了高确定性区域的其他区域,保持原有的一致性损失计算方式,经过权重分配优化后的一致性损失 L'_{con} 的计算如公式(7)所示:

$$L'_{con} = \underbrace{\sum_{i=1}^2 \sum_{x \in M_{i,c}^{nmb}} \omega_2 \cdot L_{con}(x)}_{\text{高置信度非极大值偏差}} + \underbrace{\sum_{x \in M_c^{pb}} \omega_1 \cdot L_{con}(x)}_{\text{高置信度预测偏差}} + \sum_{x \in \{M_{i,c}^{nmb}, M_c^{pb}\}} L_{con}(x) \quad (7)$$

式中, ω_1 和 ω_2 分别表示高置信度的预测偏差和非极

大值偏差区域的权重超参数。

随着训练的进行,通过偏差矫正机制实现了对伪标签的迭代优化,伪标签的质量逐步提高,从而提高了分割模型的性能,其具体流程如算法1所示。

1.4 基于高确定性区域引导的像素级对比学习

医学图像分割中,像素间的语义关联(如肿瘤边界的连续性、器官内部纹理一致性)是提升分割精度的关键。然而,传统半监督方法通常将像素视为相互独立的个体,忽略了像素之间的空间关系和语义相关性。此外,现有像素级对比学习方法直接使用伪标签构建样本对,但伪标签中的噪声会对特征空间产生干扰,从而影响模型对语义关系的建模能力。

针对上述问题,本文提出了基于高确定性引导的像素级对比学习方法,其整体学习流程如图5所示。首先,在初始伪标签的高确定性区域中进行采样,作为对比学习的锚点特征,然后在特征空间中进行像素级对比学习,并构建了一个内存队列来存储最新的样本,避免了噪声采样对鲁棒特征表示学习的负面影响,加强了模型的全局特征表示能力。

1.4.1 基于高确定性区域的锚点采样策略

基于偏差区域划分,本文进一步筛选高置信度的低偏差区域作为高确定性区域 M^c , 以子宫内膜癌MRI图像为例,如图4所示的(e)中的深蓝色区域为低偏差区域 M^{lb} , M^c 的计算如公式(8)所示:

$$M^c = \{x \in M^{lb} | \max(p_1(x), p_2(x)) \geq \theta\} \quad (8)$$

式中, θ 为置信阈值,设置与1.3节中保持一致,确保锚点特征来自高确定性区域。

1.4.2 特征空间压缩与语义对齐

由于高分辨率伪标签图像在处理过程中计算开销较大,且单个像素级特征往往缺乏充分的语义信息,受UGPCL(Wang等,2022)的启发,本文在低维特征空间中进行对比学习优化。首先通过特征提取网络获取图像的深层表征,然后使用 1×1 卷积将这些特征投影到 D 维潜在空间,以获得具有丰富语义信息的紧凑特征表示。为实现特征空间与标签空间的几何对齐,采用双线性插值将标签降采样至于特征图相同的尺度,并通过 argmax 操作建立特征向量与语义类别的映射关系,为确保训练样本的质量,仅保留伪标签中的高确定性区域的特征向量作为锚点特征。

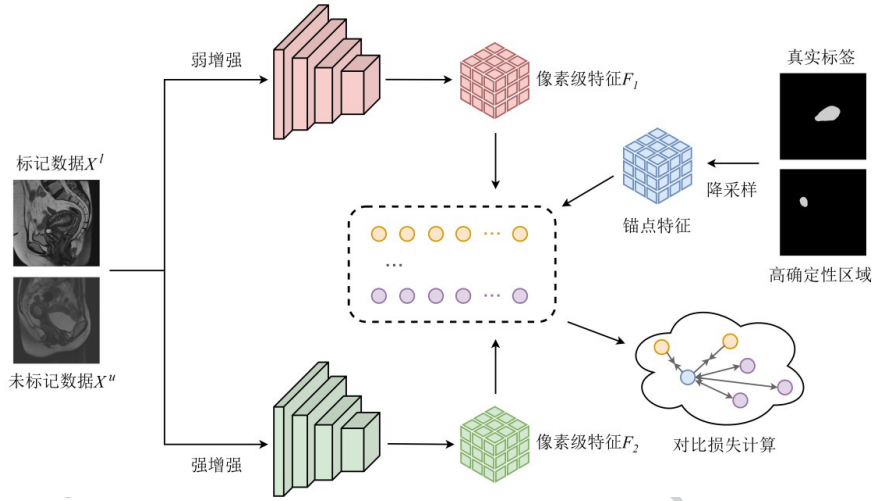


图5 基于高确定性引导的像素级对比学习方法

Fig. 5 High-confidence guided pixel-level contrastive learning method

算法1 基于偏差矫正引导伪标签优化的算法流程

输入: 一个批次的MRI图像 $\{X^l, Y^l\}, \{X^u\}$, 迭代次数 T
输出: 分割子网络 f_1 和 f_2 的参数 θ_1 和 θ_2
for $t \leftarrow 1$ **to** T **do**
for $x^l \in X^l$ **do**

 输入分割子网络 f_1 得到预测输出: $P_1^l \leftarrow f_1(X^l)$;

 输入分割子网络 f_2 得到预测输出: $P_2^l \leftarrow f_2(X^l)$;

 对标记数据计算有监督的损失: $L_{sup} \leftarrow L_{seg}(P_1^l, Y^l) +$
 $L_{seg}(P_2^l, Y^l)$;

end for
for all $x \in X^u$ **do**

 输入分割子网络 f_1 得到预测输出: $P_1^u \leftarrow f_1(X^u)$;

 输入分割子网络 f_2 得到预测输出: $P_2^u \leftarrow f_2(X^u)$;

 生成初始伪标签: $(\hat{Y}_1^u, \hat{Y}_2^u) \leftarrow \arg \max(P_1^u, P_2^u)$;

 计算交叉一致性损失: $L_{con} \leftarrow L_{ce}(P_1^u, \hat{Y}_1^u) +$
 $L_{ce}(P_2^u, \hat{Y}_2^u)$;

生成非极大值偏差区域掩码:

 $M_i^{amb} \leftarrow \bigcup_{c \in C} (CC_c^i \setminus LCC_c^i) \quad (i = 1, 2)$;

 生成非极大值偏差区域掩码: $M^{pb} \leftarrow \hat{Y}_1^u \oplus \hat{Y}_2^u$;

筛选高置信度的区域:

 $M_c^{pb}, M_{ic}^{amb} \leftarrow \{x \in M^{pb}, M_i^{amb} \mid \text{conf}(x) \geq \theta\} \quad (i = 1, 2)$;

 计算最终一致性损失: $L'_{con} \leftarrow \sum_{i=1}^2 \sum_{x \in M_{ic}^{amb}} \omega_2 \cdot L_{con}(x) +$
 $\sum_{x \in M_c^{pb}} \omega_1 \cdot L_{con}(x) + \sum_{x \notin \{M_{ic}^{amb}, M_c^{pb}\}} L_{con}(x)$;

end for

 最小化监督损失 L_{sup} 和 L'_{con} 以优化参数 θ_1 和 θ_2 ;

end for

1.4.3 动态内存队列与正负样本集构建

本文维护了一个全局先进先出的内存队列 $Q_c \in \mathbb{R}^{k \times d}$, 用于存储每一类别 $c \in [1, C]$ 的特征样

本, 该队列按类别进行划分, 并由各类别独立维护。随着训练的进行, 在每次迭代中, 将当前 batch 中的特征按照类别存入对应队列, 并更新其存储内容; 同时, 在更新过程中淘汰最早加入的特征, 以保证队列中始终保留最新的样本。

每次迭代时, 从高确定性区域随机采样 M 个锚点对应的特征向量 v_i , 在确定锚点特征后, 进一步构建正负样本集, 其具体形式如公式(9)所示:

$$P_i = \{v_i^+ \mid v_i^+ \in Q_c, v_i^+ \neq v_i\}, N_i = \bigcup_{c \neq v_i^+} Q_c \quad (9)$$

式中, P_i 和 N_i 分别表示锚点特征 v_i 的正样本和负样本集合, v_i^+ 表示从与锚点特征 v_i 具有相同类别标签的特征队列 Q_c 中采样得到的特征向量, 用于表示正样本。相应地, 负样本集合由除该类别之外的其他类别特征队列 Q_c 中的所有特征向量构成。

1.4.4 像素级对比损失计算

通过 InfoNCE 损失函数来计算每个锚点的对比损失, 然后平均所有锚点的损失作为整体对比损失, 具体计算如公式(10)所示:

$$L_c^i = -\frac{1}{|P_i|} \sum_{v_i^+ \in P_i} \log \frac{e^{\cos(v_i, v_i^+)/\tau}}{e^{\cos(v_i, v_i^+)/\tau} + \sum_{v^- \in N_i} e^{\cos(v_i, v^-)/\tau}} \quad (10)$$

$$L_{pct} = \frac{1}{M} \sum_{i=1}^M L_c^i$$

式中, $\cos(\cdot)$ 表示余弦相似度的计算, τ 是温度超参数。

1.5 总体损失函数

本文提出的基于偏差矫正与对比学习的半监督
© 中国图象图形学报版权所有

分割方法的总体损失函数包括了对标记数据的有监督损失,对未标记数据的一致性损失以及对所有数据计算的像素级对比损失,因此总体的目标函数计算如公式(11)所示:

$$L = L_{sup} + L'_{con} \cdot \exp\left(-5\left(1 - \frac{t}{200}\right)^2\right) + \mu \cdot L_{pcl} \quad (11)$$

式中, t 为训练轮次,用于调节一致性损失项的贡献权重, μ 为用于调节像素级对比损失项贡献的权重参数,在本文实验中固定设为 0.1。

2 实验设计与分析

2.1 数据集

为了对本文提出的基于偏差矫正与对比学习的半监督MRI分割方法进行有效性的验证,本文在三个MRI数据集上进行了实验,包括一个私有的子宫内膜癌MRI数据集和两个公开的MRI数据集。本文选择了与子宫内膜癌数据集具有类似特征的ACDC (Bernard 等, 2018)数据集和PROMISE12 (Litjens 等, 2014)数据集来评估所提出的方法在处理不同MRI图像时的有效性。

子宫内膜癌MRI数据集为私有数据集,所有研究对象的盆腔MRI图像来源于医院提供的DICOM格式核磁共振数据,在专业医师的指导下挑选具有高诊断价值的矢状位切片后将数据转化为一系列二维的PNG格式图像。最后,经筛选得到矢状位的MRI图像共755张,所有图像分辨率为512×512。所有图像由专业的医生对子宫内膜肿瘤进行分割标记和复核,以确保数据集的可靠性。完成数据集的标记工作之后,实验对数据集进行以下划分:512张用作训练集,95张用作验证集,148张用作测试集。

ACDC数据集来自于2017年MICCAI举行的一个MRI心脏图像分割和诊断挑战赛,旨在推动自动化心脏疾病诊断的发展。该数据集是一个四分类的心脏分割数据集,包括右心室、左心室、心肌和背景四个类。它一共包含了100个患者的心脏MRI样本扫描数据,按顺序选取70、10和20个患者的扫描切片分别用作训练集、验证集和测试集。

PROMISE12数据集来源于MICCAI于2012年发起的前列腺分割挑战赛数据集,包含了50个患者的扫描图像,按顺序选取35、5和10个患者的扫描切

片分别用作训练集、验证集和测试集。

2.2 评价指标

本文使用了分割任务中广泛使用的四个评价指标来评估所提出的方法性能,Dice系数和Jaccard指数主要用于衡量区域重叠程度,而平均边界距离(average surface distance, ASD)和95%豪斯多夫距离(95% hausdorff distance, 95HD)则用于评估边界的精确度和误差,综合使用这些指标可以更全面地评估医学图像分割模型的性能。

Dice系数量化了预测分割区域与真实标签的空间重叠程度,用于衡量分割任务的精确程度。

Jaccard指数反映了预测分割区域与真实标签之间的相似度,Jaccard指数的取值范围是 $[0, 1]$,数值越高,说明分割精度越高。

ASD用于衡量分割边界的精确度,计算预测分割区域与真实分割区域的表面点之间的平均距离,ASD取值越小,表示预测分割边界越接近真实边界,分割精度越高。

豪斯多夫距离是一种用于度量边界误差的指标,用于衡量两个边界点集之间的最大误差,而95HD是去除极端值后的95%分位数的最大距离,以减少异常值的影响。95HD数值越小,说明分割边界与真实边界越接近,模型精度越高。

2.3 实验设置

本文在具有固定随机种子的NVIDIA 1080Ti GPU上进行了所有实验。为了公平比较,实验中使用的的所有方法都选择U-Net作为图像分割的基准架构,并使用ResNet-50替换U-Net的编码器部分,使用ImageNet上预训练的权重初始化其参数。所有输入图像分辨率为256×256。本文采用Adam作为优化器,其权重衰减为0.0005,并使用PyTorch库实现了这些方法。对于子宫内膜癌MRI数据集和ACDC数据集,初始学习率设置为0.01,对于PROMISE12数据集,初始学习率设置为0.05。由于数据集大小的差异,ACDC数据集的批大小设置为16,每批有8张标记图像和8张未标记图像;对于子宫内膜癌MRI数据集和PROMISE12数据集,批大小设置为8,每批有4张标记图像和4张未标记图像。所有方法都经过10000次迭代训练。此外,通过实验确定了超参数的取值为 $\alpha = 0.6, \beta = 0.2, \omega_1 = 4, \omega_2 = 5, \tau = 0.07$ 。

2.4 对比实验结果与分析

本文在三个 MRI 数据集的不同标注比例(即 10% 和 20%)设置下将本文方法与现有的半监督方法以及最先进的方法进行了比较,包括 mean teacher (MT) (Rasmus 等, 2015), uncertainty-aware mean teacher (UAMT) (Yu 等, 2019), cross-consistency training (CCT) (Ouali 等, 2020), cross pseudo supervision (CPS) (Chen 等, 2021), uncertainty rectified pyramid consistency (URPC) (Luo 等, 2022), smoothness and class-separation network (SS-Net) (Wu 等, 2022), decoupled consistency network (DC-Net) (Chen 等, 2023), bidirectional copy-paste (BCP) (Bai 等, 2023), shape-aware and local context constraints network (SLC-Net) (Liu 等, 2024) 以及 probabilistic prototype-based classifier (PPC) (Yuan 等, 2025)。

子宫内膜癌 MRI 数据集上的实验结果如表 1 所示。实验结果表明,在 10% 与 20% 标注比例下,本

文方法在 Dice 系数、Jaccard 指数、95HD 及 ASD 四项指标上均取得最优表现。具体而言,在 10% 标注比例下,本文方法的 Dice 系数较 CPS 提升了 6.04%, 该性能还优于 20% 标注比例下的全监督 U-Net 模型,表明大量未标记数据的有效利用能够显著弥补标注数据不足所带来的性能损失,验证了 BC-Net 对标记数据的高效利用率。得益于偏差校正的思想,模型能够更加关注非极大值偏差区域及边界模糊区域,使得 95HD 与 ASD 指标均显著降低,验证了方法在边界刻画方面的有效性。

图 6 展示了在 10% 标注比例的子宫内膜癌 MRI 数据集上,本文方法与其他半监督分割方法的可视化结果,红色框所标示区域对应典型的非极大值偏差区域。从结果可以观察到,SS-Net、BCP 等方法在该类区域普遍存在边界偏移及误分割现象,而本文方法的预测边界与真实标注保持更高一致性。




图 6 子宫内膜癌 MRI 数据集 10% 标注比例下的可视化结果

Fig. 6 Visualization results on the endometrial cancer MRI dataset with 10% labeling data

ACDC 数据集上,本文同样在不同标注比例的半监督设置下与现有半监督方法进行了全面的比较,实验结果如表 2 所示。整体来看,本文方法表现出较强的竞争力。在 10% 标注比例下, Dice 系数达到 89.47%, 全局分割性能略优于 DC-Net; 尽管相比次优方法, ASD 和 95HD 略有约 0.02 mm 的增加,但整体仍保持较高的边界精度,表明该方法在全局区

域一致性与局部边界刻画之间实现了较好的平衡。在 20% 标注比例下, Dice 系数进一步提升至 90.09%, 验证了所提方法在不同标注规模下的稳定性与有效性。结合如图 7 所示的训练过程偏差数量变化图,在 10% 标注比例下,本文方法的优势更加显著。图 7(a)展示了非极大值偏差像素数量的变化情况,相较于 CPS 方法,本文方法的偏差像素数量

表1 子宫内膜癌MRI数据集与现有的半监督医学图像分割方法的对比实验

Table 1 Comparative experiments between the endometrial cancer MRI dataset and existing semi-supervised medical image segmentation methods

方法	数据		评价指标			
	标注比例	未标注比例	Dice ↑	Jaccard ↑	95HD ↓	ASD ↓
U-Net	10%	0	54.05	44.29	18.32	7.28
U-Net	20%		66.55	57.63	14.79	5.13
MT(NeurIPS2017)			68.03	55.58	18.23	6.00
UAMT(MICCAI2019)			68.02	56.19	28.75	9.03
CCT(CVPR2020)			65.28	55.47	16.03	5.19
CPS(CVPR2021)			70.53	59.34	17.04	5.93
URPC(MICCAI2022)			64.63	54.74	15.90	5.02
SS-Net(MICCAI2022)	10%	90%	60.68	50.18	29.42	11.83
DC-Net(MICCAI2023)			61.38	51.60	16.12	6.44
BCP(CVPR2023)			<u>75.03</u>	<u>64.76</u>	17.59	6.75
SLC-Net(TMI2024)			72.28	63.41	<u>16.05</u>	<u>6.08</u>
PPC(TMI2025)			63.09	53.72	24.68	8.23
BC-Net			76.57	66.38	11.66	3.70
MT(NeurIPS2017)			72.18	61.22	21.03	6.72
UAMT(MICCAI2019)			73.18	62.01	14.23	4.54
CCT(CVPR2020)			71.13	61.92	25.02	10.78
CPS(CVPR2021)			72.49	61.65	13.68	4.70
URPC(MICCAI2022)			71.93	62.51	17.36	5.51
SS-Net(MICCAI2022)	20%	80%	68.61	<u>59.96</u>	17.48	6.20
DC-Net(MICCAI2023)			67.18	59.10	11.69	<u>3.70</u>
BCP(CVPR2023)			<u>78.38</u>	69.40	12.60	4.37
SLC-Net(TMI2024)			77.93	66.74	<u>11.37</u>	3.77
PPC(TMI2025)			70.43	60.76	16.48	4.91
BC-Net			79.57	<u>68.78</u>	8.08	3.29

注:加粗字体表示各列最优结果,带下划线字体代表各列次优结果,↑表示指标值越大越好,↓表示指标值越小越好

显著更低且波动幅度更小。这表明在处理图像中的非极大值区域时,本文方法能够更有效地抑制非极大值偏差像素,从而减少由局部特征误判引起的分割偏差。图7(b)展示了预测偏差像素数量的变化趋势,可以观察到本文方法的下降趋势更加明显,说明其在训练过程中能够更快速地降低由模糊边界引起的预测偏差,从而获得更高的收敛精度。

PROMISE12数据集上,本文在10%与20%两种标注比例的半监督设置下进行了全面比较,实验结

果如表3所示。从结果可以看出,在10%标注比例下的纯监督训练中,Dice系数仅为44.48%,表明在极低标注条件下,监督学习性能受到显著限制。相比之下,本文方法将Dice系数提升了28.3%,并较次优方法进一步提高了3.89%,体现出在极端数据稀缺场景下的良好鲁棒性。在20%标注比例下,本文方法在Dice系数、Jaccard指数和95HD指标上均取得了明显提升,但ASD仍略低于当前最优方法,说明在保证整体分割精度与边界定位能力的同时,模

型在边缘细节刻画方面仍有进一步优化空间。

图8展示了在10%标注比例下 PROMISE12数据集的可视化分割结果。结合结果可以观察到,与真实标签相比,图中绿色框标示了MT方法存在目标区域缺失的问题,而本文方法能够较为完整地恢复目标结构;红色框标示了BCP方法在MRI图像中的误分割区域,而本文方法通过偏差矫正机制有效抑制了此类干扰,表现出对复杂图像特征的较强鲁

棒性。

2.5 消融实验结果与分析

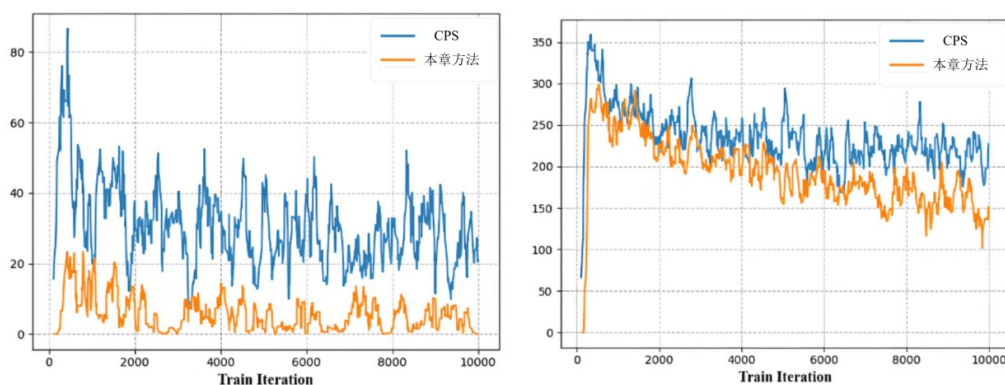
为验证所提出方法的有效性,本文设计并开展了一系列消融实验,对半监督分割框架中的各个关键组件进行系统性分析与验证,从而深入理解方法的工作机制和关键因素,进一步辅助优化模型。本在标注比例为10%的ACDC数据集上进行了以下的消融实验。

表2 ACDC数据集与现有的半监督医学图像分割方法的对比实验

Table 2 Comparative experiments between the ACDC dataset and existing semi-supervised medical image segmentation methods

方法	数据		评价指标			
	标注比例	未标注比例	Dice ↑	Jaccard ↑	95HD ↓	ASD ↓
U-Net	10%	0	82.84	72.03	7.47	2.19
U-Net	20%		83.96	74.01	9.76	3.06
MT(NeuriPS2017)			83.55	72.97	9.14	2.30
UAMT(MICCAI2019)			84.32	74.29	7.57	2.64
CCT(CVPR2020)			83.96	73.85	6.30	1.92
CPS(CVPR2021)			85.13	75.33	6.85	1.96
URPC(MICCAI2022)			84.84	74.79	5.49	1.53
SS-Net(MICCAI2022)	10%	90%	86.78	77.67	6.07	1.40
DC-Net(MICCAI2023)			<u>89.42</u>	<u>81.37</u>	1.28	0.38
BCP(CVPR2023)			88.84	80.62	3.98	1.17
SLC-Net(TMI2024)			84.31	74.36	4.41	1.29
PPC(TMI2025)			82.63	71.75	12.75	3.37
BC-Net			89.47	81.39	<u>1.30</u>	<u>0.40</u>
MT(NeuriPS2017)			86.51	77.43	6.52	1.92
UAMT(MICCAI2019)			84.67	75.13	9.81	2.47
CCT(CVPR2020)			85.87	76.83	7.44	2.03
CPS(CVPR2021)			87.72	79.18	5.64	1.65
URPC(MICCAI2021)			86.33	77.27	5.63	1.53
SS-Net(MICCAI2022)	20%	80%	87.31	78.65	7.36	1.95
DC-Net(MICCAI2023)			89.74	<u>82.09</u>	<u>2.19</u>	<u>0.72</u>
BCP(CVPR2023)			<u>89.77</u>	81.97	6.75	1.51
SLC-Net(TMI2024)			87.73	79.21	5.98	1.50
PPC(TMI2025)			86.23	76.67	6.41	1.95
BC-Net			90.09	82.40	1.67	0.48

注:加粗字体表示各列最优结果,带下划线字体代表各列次优结果,↑表示指标值越大越好,↓表示指标值越小越好



(a)非极大值偏差像素数量 (b)预测偏差像素数量
((a) number of non-maximum bias pixels; (b) number of prediction bias pixels)

Fig. 7 Variation in the number of two types of biases during training on the ACDC dataset with 10% labeled data




图8 在PROMISE12数据集上本文方法与其他半监督分割方法的可视化结果比较

Fig. 8 Comparison of visualization results between the proposed method and other semi-supervised segmentation methods on the PROMISE12 dataset

2.5.1 各模块贡献的消融实验

本文方法各组成部分对结果的消融贡献如表4所示。当仅使用基本一致性损失的情况下, Dice系数和Jaccard指数分别为85.13%和75.33%, 表明模型在基础条件下的精度和边界质量仍存在较大的提升空间; 在基础模型上加入数据增强后, Dice系数和Jaccard指数分别提升到了87.45%和78.43%, 且边界误差显著降低, 说明数据增强使模型在更复杂的输入情况下获得了更高的分割精度; 在加入BCGPL模块后, Dice系数和Jaccard指数得到了进一步提升, 表明该模块能够有效校正伪标签中的偏差, 从而显著缓解偏差累积对模型训练的不利影响; 将BCGPL替换为HCPCL模块后, 四项评价指标均得到

提升, 说明基于高确定性区域开展像素级对比学习, 有助于增强模型的特征表征能力; 当同时加入BCGPL模块和HCPCL模块后, 模型的性能达到了最佳, 这表明两个模块在提升伪标签质量和增强像素级对比学习方面具有互补性, 能够协同提高分割尤其在边界细节刻画方面效果更加显著。

2.5.2 超参数的消融实验

在BCPCL中, 将 ω_1 和 ω_2 用于控制非极大值偏差区域和预测偏差区域的影响程度, 保持其他参数不变, ω_1 越大表示对非极大值偏差区域的敏感度越高, ω_2 越大表示对预测偏差区域的敏感度越高, 因此, 平衡 ω_1 和 ω_2 的权重对于提升模型性能至关重要。如图9所示的实验结果表明 $\omega_1 = 4, \omega_2 = 5$

是最优选择,能够在保证高分割精度的同时,有效降低边界误差并提升一致性。

为评估像素级对比损失权重参数 μ 对模型性能的影响,本文还对其进行了消融实验分析,实验结果如表5所示。从表中可以看出,当 $\mu = 0.1$ 时本文提

出的方法取得了最优的分割性能。这表明适当的对比损失权重能够在增强特征判别能力的同时,避免过强约束对主任务学习的干扰,从而实现分割精度与训练稳定性的有效平衡。

表3 PROMISE12数据集与现有的半监督医学图像分割方法的对比实验

Table 3 Comparative experiments between the PROMISE12 dataset and existing semi-supervised medical image segmentation methods

方法	数据		评价指标			
	标注比例	未标注比例	Dice \uparrow	Jaccard \uparrow	95HD \downarrow	ASD \downarrow
U-Net	10%	0	44.48	35.88	17.06	7.25
U-Net	20%		53.79	45.45	17.83	6.19
MT(NeurIPS2017)			55.79	45.70	23.65	10.92
UAMT(MICCAI2019)			45.07	36.92	18.84	8.77
CCT(CVPR2020)			56.30	46.91	41.34	19.72
CPS(CVPR2021)			56.52	47.68	26.03	12.85
SS-Net(MICCAI2022)	10%	90%	61.65	51.77	14.86	4.99
DC-Net(MICCAI2023)			68.89	54.88	<u>12.93</u>	3.75
BCP(CVPR2023)			67.58	<u>57.23</u>	14.84	6.70
SLC-Net(TMI2024)			61.49	46.67	27.34	12.38
PPC(TMI2025)			68.71	53.21	82.07	22.01
BC-Net			72.78	60.37	10.65	<u>3.95</u>
MT(NeurIPS2017)			63.13	53.59	26.62	11.34
UAMT(MICCAI2019)			73.24	62.97	19.35	7.24
CCT(CVPR2020)			65.96	56.56	15.19	6.15
CPS(CVPR2021)			73.77	63.16	18.01	6.39
SS-Net(MICCAI2022)	20%	80%	69.53	59.74	10.83	<u>2.65</u>
DC-Net(MICCAI2023)			<u>78.68</u>	65.44	<u>10.65</u>	2.53
BCP(CVPR2023)			76.96	<u>66.05</u>	10.77	3.43
SLC-Net(TMI2024)			74.55	63.81	18.86	8.72
PPC(TMI2025)			71.09	56.16	38.17	9.32
BC-Net			79.57	68.78	8.08	3.29

注:加粗字体表示各列最优结果,带下划线字体代表各列次优结果, \uparrow 表示指标值越大越好, \downarrow 表示指标值越小越好

2.5.3 不同的偏差区域的关注

为进一步分析不同偏差区域对分割性能的影响,本文在实验中进行了深入分析,具体结果如表6所示。当仅关注非极大偏差区域或仅关注预测偏差区域时,相较于完全忽略这些区域,分割精度均有所提升。说明针对特定类型偏差的抑制能够有效改善

模型的学习效果。当两种偏差区域同时考虑时,模型性能达到最优,Dice系数和Jaccard指数进一步提升至89.47%和81.39%,同时95HD和ASD显著降低至1.30mm和0.40mm,表明模型在边界定位方面更加精确。这一现象表明,在偏差校正过程中,仅关注单一类型偏差具有一定局限性,而联合建模非极

表4 评估各模块贡献的消融实验

Table 4 Ablation experiments evaluating the contribution of each module

con	aug	BCGPL	HCPGL	Dice ↑	Jaccard ↑	95HD ↓	ASD ↓
√				85.13	75.33	6.85	1.96
√	√			87.45	78.43	4.34	1.28
√	√	√		87.80	78.93	3.45	1.08
√	√		√	88.97	80.58	2.46	0.78
√	√	√	√	89.47	81.39	1.30	0.40

注:加粗字体表示各列最优结果,↑表示指标值越大越好,↓表示指标值越小越好,√表示使用该模块

表5 像素级对比损失权重参数的消融实验

Table 5 Ablation experiments on the pixel-level contrastive loss weight parameter

μ	Dice ↑	Jaccard ↑	95HD ↓	ASD ↓
0.05	88.23	79.56	4.47	1.25
0.1	89.47	81.39	1.30	0.40
0.15	88.54	80.04	3.97	1.22
0.2	88.25	79.65	4.30	1.41

注:加粗字体表示各列最优结果,↑表示指标值越大越好,↓表示指标值越小越好

大值偏差与预测偏差对于提升模型整体性能至关重要。因此,本文方法通过综合考虑不同类型的偏差区域,有效挖掘其潜在信息,从而充分提升模型的分割精度与稳定性。

表6 关注不同偏差区域的消融实验

Table 6 Ablation experiments focusing on different bias regions

非极大值偏差	预测偏差	Dice ↑	Jaccard ↑	95HD ↓	ASD ↓
		88.97	80.58	2.46	0.78
√		89.15	80.89	2.64	0.90
	√	89.06	80.77	2.13	0.55
√	√	89.47	81.39	1.30	0.40

注:加粗字体表示各列最优结果,↑表示指标值越大越好,↓表示指标值越小越好,√表示使用该模块

2.5.4 锚点采样策略

本文提出的基于高置信度的锚点采样策略在实验中表现优越。为验证其有效性,本文将其与两种

常见的采样方法进行对比。第一种是高置信度采样,该方法通过计算每个像素的置信概率,并过滤掉低置信度区域,以确保模型主要学习高置信度样本;第二种是低不确定性采样,该方法利用熵来估计不确定性,并过滤掉高不确定性的区域,以降低模型受噪声影响的风险。然而,这两种方法在一定程度上忽略了数据中潜在的偏差信息,可能导致模型对复杂或难分割区域的学习不足。表7展示了不同锚点采样策略的消融实验结果。相比之下,本文方法从高置信度区域中进行采样,既保证了样本的高可靠性,又有效缓解了潜在偏差对学习过程的影响,使得网络能够学习更加精准的全局语义信息。

实验结果表明,不同的锚点采样策略对模型的分割性能具有显著影响。其中,高置信度区域采样的Dice和Jaccard分数相对较低,同时95HD和ASD相对较高,说明该方法虽然保证了样本的高置信度,但可能忽略部分困难区域,从而影响边界预测的精度。低不确定性区域采样提升了Dice系数和Jaccard指数,同时降低了95HD和ASD,表明该方法能够减少噪声干扰,提高边界预测的准确性。而本文提出的基于高确定性区域的锚点采样策略表现最佳,说明该方法不仅能够提升整体分割精度,还能显著优化边界刻画能力。上述结果进一步验证了从高确定性区域进行锚点采样,能够在保证样本可靠性的同时有效缓解偏差影响,从而提升模型的全局语义建模能力以及分割结果的鲁棒性与准确性。

表7 像素级对比学习中对不同锚点采样策略的消融实验

Table 7 Ablation experiments on different anchor sampling strategies in pixel-level contrastive learning

锚点采样策略	Dice ↑	Jaccard ↑	95HD ↓	ASD ↓
高置信度区域	88.86	80.45	3.22	0.92
低不确定性区域	89.12	80.83	2.06	0.72
高确定性区域	89.47	81.39	1.30	0.40

注:加粗字体表示各列最优结果,↑表示指标值越大越好,↓表示指标值越小越好

2.6 限制与讨论

尽管本文提出的方法在分割性能上取得了较好的效果,但在一些具有挑战性的场景下仍然存在一定的局限性,如图9所示。在ACDC数据集中,部分区域在灰度分布和纹理特征上与右心室腔体高度相

似,导致模型难以有效区分二者,从而产生过分割现象。同时,在部分图像中,右心室区域尺寸较小,且与周围组织在灰度和纹理上缺乏明显差异,在这种情况下,模型难以将其准确识别为独立的解剖结构,进而导致类别级的漏检问题。上述现象表明,所提出的方法仍存在进一步优化与提升的空间。未来工作中,将会引入更强的结构先验约束或形状建模机制,以提升模型在复杂解剖结构下的分割一致性与稳定性。此外,本文还会探索跨模态信息融合或更大规模多中心数据训练,进一步增强模型的泛化能力与对不同成像条件的适应性。




图9 ACDC数据集上的挑战性案例可视化结果。红色表示右心室,绿色表示心肌,蓝色表示左心室

Fig. 9 Visualization results of challenging cases on the ACDC dataset. The red region indicates the right ventricle, the green region indicates the myocardium, and the blue region indicates the left ventricle

3 结论

针对MRI图像对比度低所导致的伪标签偏差累积问题,本文提出了一种偏差矫正引导的伪标签优化策略。该方法在两个子网络进行交叉伪监督训练的过程中,并不直接采用它们的预测结果作为伪标签,而是通过差异化的权重分配机制,优先关注高置信度筛选出的潜在偏差区域,从而优化伪标签质量并减少错误的累积传播。此外,为解决传统一致性学习在像素级别缺乏足够语义关联的问题,本文提出了一种基于高确定性区域引导的像素级对比学习

方法。该方法利用伪标签中高确定性区域的稳定性,构建可靠的像素级对比样本,并引入高确定性区域的锚点采样策略,以降低噪声干扰的影响。随后,通过动态内存队列存储大量负样本,并结合像素级对比学习损失计算,协同增强网络的全局表征能力。最终,该方法充分挖掘病灶的上下文信息,以推断周围组织结构,实现更精确的目标区域分割。在子宫内膜癌MRI数据集以及两个公开MRI数据集上的实验结果表明,本研究方法在减少标记需求的同时,能够有效提升病灶分割的精度。

参考文献(References)

- Basak H and Yin Z. 2023. Pseudo-label guided contrastive learning for semi-supervised medical image segmentation// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, Canada: IEEE: 19786-19797 [DOI: 10.1109/CVPR52729.2023.01895]
- Bai Y, Chen D, Li Q, Shen W and Wang Y. 2023. Bidirectional copy-paste for semi-supervised medical image segmentation// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, Canada: IEEE: 11514-11524 [DOI: 10.1109/CVPR52729.2023.01108]
- Bernard O, Lalande A, Zotti C, Cervenansky F, Yang X, Heng P A, et al. 2018. Deep learning techniques for automatic MRI cardiac multi-structures segmentation and diagnosis: is the problem solved? IEEE Transactions on Medical Imaging, 37(11): 2514-2525 [DOI: 10.1109/TMI.2018.2837502]
- Chen F, Fei J, Chen Y and Huang C. 2023. Decoupled consistency for semi-supervised medical image segmentation// International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer Nature Switzerland: 551-561 [DOI: 10.1007/978-3-031-43907-0_53]
- Chen X, Yuan Y, Zeng G and Wang J. 2021. Semi-supervised semantic segmentation with cross pseudo supervision// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE: 2613-2622 [DOI: 10.1109/CVPR46437.2021.00264]
- Ding W, Wang H, Huang J, Ju H, Geng Y, Lin CT, et al. 2023. FTransCNN: fusing transformer and a CNN based on fuzzy logic for uncertain medical image segmentation. Information Fusion, 99: 101880 [DOI: 10.1016/j.inffus.2023.101880]
- Jiang T and Li X N. 2024. Segmentation of abdominal CT and cardiac MR images with multi scale visual attention. Journal of Image and Graphics, 29(1): 268-279 (蒋婷, 李晓宁. 2024. 采用多尺度视觉注意力分割腹部CT和心脏MR图像. 中国图象图形学报, 29(1): 268-279)[DOI:10.11834/jig.221032]
- Jiao R, Zhang Y, Ding L, Xue B, Zhang J, Cai R, et al. 2023. Learn-

- ing with limited annotations: a survey on deep semi-supervised learning for medical image segmentation. *Computers in Biology and Medicine*, 169: 107840 [DOI: 10.1016/j.combiomed.2023.107840]
- Lei T, Zhang D, Du X, Wang X, Wan Y and Nandi AK. 2022. Semi-supervised medical image segmentation using adversarial consistency learning and dynamic convolution network. *IEEE Transactions on Medical Imaging*, 42(5): 1265-1277 [DOI: 10.1109/TMI.2022.3225687]
- Li G, Xie J, Zhang L, Cheng G, Zhang K and Bai M. 2025. Dynamic graph consistency and self-contrast learning for semi-supervised medical image segmentation. *Neural Networks*, 184: 107063 [DOI: 10.1016/j.neunet.2024.107063]
- Litjens G, Toth R, Van De Ven W, Hoeks C, Kerkstra S, Van Ginneken B, et al. 2014. Evaluation of prostate segmentation algorithms for MRI: the PROMISE12 challenge. *Medical Image Analysis*, 18(2): 359-373 [DOI: 10.1016/j.media.2013.12.002]
- Liu J, Desrosiers C, Yu D and Zhou Y. 2024. Semi-supervised medical image segmentation using cross-style consistency with shape-aware and local context constraints. *IEEE Transactions on Medical Imaging*, 43(4): 1449-1461 [DOI: 10.1109/TMI.2023.3338269]
- Luo X, Wang G, Liao W, Chen J, Song T, Chen Y, et al. 2022. Semi-supervised medical image segmentation via uncertainty rectified pyramid consistency. *Medical Image Analysis*, 80: 102517 [DOI: 10.1016/j.media.2022.102517]
- Ouali Y, Hudelot C and Tami M. 2020. Semi-supervised semantic segmentation with cross-consistency training// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle, WA, USA: IEEE: 12674-12684 [DOI: 10.1109/CVPR42600.2020.01269]
- Pan W, Xu Z, Yan J, Wu Z, Tong RK, Li X, et al. 2025. Semi-supervised semantic segmentation meets masked modeling: fine-grained locality learning matters in consistency regularization. *Pattern Recognition*, 172: 112586 [DOI: 10.1016/j.patcog.2025.112586]
- Qureshi I, Yan J, Abbas Q, Shaheed K, Riaz AB, Wahid A, et al. 2023. Medical image segmentation using deep semantic-based methods: a review of techniques, applications and emerging trends. *Information Fusion*, 90: 316-352 [DOI: 10.1016/j.inffus.2022.09.031]
- Rasmus A, Berglund M, Honkala M, Valpola H and Raiko T. 2015. Semi-supervised learning with ladder networks. *Advances in Neural Information Processing Systems*, 28 [DOI: 10.1186/1477-5956-9-S1-S5]
- Shen Z, Cao P, Yang H, Liu X, Yang J and Zaïane OR. 2023. Co-training with high-confidence pseudo labels for semi-supervised medical image segmentation// *Proceedings of the Thirty-Second International Joint Conference on Artificial Intelligence*. Macau, China: International Joint Conferences on Artificial Intelligence Organization: 4199-4207 [DOI: 10.24963/ijcai.2023/467]
- Sohn K, Berthelot D, Carlini N, Zhang Z, Zhang H, Raffel CA, et al. 2020. Fixmatch: simplifying semi-supervised learning with consistency and confidence// *Advances in Neural Information Processing Systems*. Curran Associates, Inc.: 596-608 [DOI: 10.48550/arXiv.2001.07685]
- Tarvainen A and Valpola H. 2017. Mean teachers are better role models: weight-averaged consistency targets improve semi-supervised deep learning results. *Advances in Neural Information Processing Systems*, 30 [DOI: 10.48550/arXiv.1703.01780]
- Wang T, Lu J, Lai Z, Wen J and Kong H. 2022. Uncertainty-guided pixel contrastive learning for semi-supervised medical image segmentation// *Proceedings of the Thirty-First International Joint Conference on Artificial Intelligence*. Vienna, Austria: International Joint Conferences on Artificial Intelligence Organization: 1444-1450 [DOI: 10.24963/ijcai.2022/201]
- Wang W, Zhou T, Yu F, Dai J, Konukoglu E and Van Gool L. 2021. Exploring cross-image pixel contrast for semantic segmentation// *Proceedings of the IEEE/CVF International Conference on Computer Vision*. IEEE: 7303-7313 [DOI: 10.1109/ICCV48922.2021.00721]
- Wu H, Xie W, Lin J and Guo X. 2023. ACL-Net: semi-supervised polyp segmentation via affinity contrastive learning// *Proceedings of the AAAI Conference on Artificial Intelligence*. Washington, DC, USA: 2812-2820 [DOI: 10.1609/aaai.v37i3.25382]
- Wu Y, Wu Z, Wu Q, Ge Z and Cai J. 2022. Exploring smoothness and class-separation for semi-supervised medical image segmentation// *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Cham: Springer Nature Switzerland: 34-43 [DOI: 10.1007/978-3-031-16443-9_4]
- Xiong W, Chen Z, Liu Q, Wu W, Zhang J and Shen H. 2024. Pacaswaa: patch-based contrastive semi-supervised learning with wavelet guidance and adaptive augmentation for tumour segmentation// *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing*. Seoul, South Korea: IEEE: 12941-12945 [DOI: 10.1109/ICASSP48485.2024.10446202]
- Xu Z, Wang Y, Lu D, Luo X, Yan J, Zheng Y, et al. 2023. Ambiguity-selective consistency regularization for mean-teacher semi-supervised medical image segmentation. *Medical Image Analysis*, 88: 102880 [DOI: 10.1016/j.media.2023.102880]
- Yang L, Zhuo W, Qi L, Shi Y and Gao Y. 2022. ST++: make self-training work better for semi-supervised semantic segmentation// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. New Orleans, LA, USA: IEEE: 4268-4277 [DOI: 10.1109/CVPR52688.2022.00423]
- Yu L, Wang S, Li X, Fu CW and Heng PA. 2019. Uncertainty-aware self-ensembling model for semi-supervised 3D left atrium segmentation// *Medical Image Computing and Computer-Assisted Intervention*. Cham: Springer: 605-613 [DOI: 10.1007/978-3-030-32245-5_52]

8_67]

Yuan Y, Wang X, Yang X and Heng PA. 2025. Effective semi-supervised medical image segmentation with probabilistic representations and prototype learning. *IEEE Transactions on Medical Imaging*, 44(3): 1181-1193 [DOI: 10.1109/TMI.2024.3484166]

Zhang D P, Li Z, Xie Y G, Wang D Y, Tang S L, Bu Y Z and Wang M T. 2025. Boundary cue deep fusion polyp image segmentation network. *Journal of Image and Graphics*, 30(5): 1479-1496 (章东平, 李铮, 谢亚光, 王都洋, 汤斯亮, 卜玉真, 王梦婷. 2025. 边界线索深度融合息肉图像分割网络. *中国图象图形学报*, 30(5): 1479-1496)[DOI:10.11834/jig.240383]

Zhong Y, Yuan B, Wu H, Yuan Z, Peng J and Wang YX. 2021. Pixel contrastive-consistent semi-supervised semantic segmentation// *Proceedings of the IEEE/CVF International Conference on Computer Vision*. IEEE: 7273-7282 [DOI: 10.1109/ICCV48922.2021.

00718]

作者简介

陈再良,男,副教授,主要研究方向为医学图像处理、计算机视觉和机器学习。E-mail: xxxyczl@163.com

沈海澜,通信作者,女,副教授,主要研究方向为机器学习、医学图像分析和医学数据处理。E-mail: hn shl@126.com

刘佰成,男,硕士研究生,主要研究方向为医学图像处理和机器学习。E-mail: lbc_csu_hn@163.com

伍文佳,女,硕士研究生,主要研究方向为计算机视觉和医学图像处理。E-mail: wenjiawu955@163.com

刘慧,女,主任医师,主要研究方向为腹部及盆腔影像学。E-mail: 403799@csu.edu.cn