C3S3: 用于半监督医学图像分割的互补竞争与对比选择

Jiaying He †,1 , Yitong Lin †,1 , Jiahe Chen 1 , Honghui Xu *,1 , Jianwei Zheng *,1 Zhejiang University of Technology, Hangzhou, China Email: { xhh, zjw } @zjut.edu.cn

Abstract—针对医学领域中样本标注不足的潜在挑战,半监督 医学图像分割 (SSMIS) 提供了一个有前景的解决方案。尽管在主要目标区域的划分上取得了令人印象深刻的成果,但现有的大多数方法在精确捕捉边界细节上仍存在困难。这种不足经常导致显著的诊断不准确性。为了应对这一问题,我们引入了 C3S3,一种新型的半监督分割模型,协同整合补充竞赛和对比选择。该设计显著增强了边界划分能力并提高了整体精确度。具体而言,我们开发了一个结果驱动对比学习模块,专门用于优化边界定位。此外,我们还纳入了一个动态补充竞赛模块,该模块利用两个高性能子网络生成伪标签,从而进一步改善分割质量。所提出的C3S3 在两个公共可访问的数据集上经过严格验证,涵盖了 MRI和 CT 扫描的应用实践。结果显示,我们的方法相比于之前的最先进的竞争对手取得了更出色的性能。特别是在 95HD 和 ASD 指标上,我们的方法实现了至少 6 % 的显著改善,突出表现了这一重大进步。代码可以在 https://github.com/Y-TARL/C3S3 获取。

Index Terms—Semi-Supervised Learning, Medical Image Segmentation, Consistency Learning, Contrastive Learning

I. 引言

医学图像分割 (MIS) 在医疗保健中至关重要,有助于临床医生监测疾病进展和规划治疗。深度学习的进步,尤其是监督方法,极大地提升了 MIS,使其成为该领域的领先方法,并显著改善了各种实践中的表现 [1]。传统的监督深度学习方法需要大量标注数据进行训练,而医学图像的像素级标注既耗时又具有挑战性。为了解决这一问题,已经开发出半监督医学图像分割技术,旨在减少对广泛人工标注的需求,同时保持高性能。

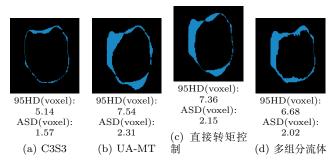


Fig. 1: C3S3 与其他方法之间的视觉比较,其中蓝色区域代表定位不准确的片段。

SSMIS 主要通过利用未标记的数据来提高分割性能而脱颖而出。在此框架内,伪标签监督和一致性正则化两种

 † Equal contributions. * Corresponding author.

This work was supported in part by the National Natural Science Foundation of China under Grant 62276232 and 62406285, the China Postdoctoral Science Foundation under Grant 2024M752863, and the Key Program of Natural Science Foundation of Zhejiang Province under Grant LZ24F030012.

关键策略得到了广泛研究。前者使用伪标签来监督未标记的图像,而后者则是基于像平均教师(MT)或协同训练这样流行的框架,强调不同模型或分支之间预测的一致性。这些方法通常训练两个网络以确保一致的预测,即使在同样的样本面对随机变化时也是如此。尽管这些方法在准确定位目标区域方面取得了成功,但精细边界的优化仍然是一个重大挑战。

通过结合两种流行技术,即半监督学习和对比学习,我 们提出了一种新模型来应对这一挑战。首先,我们的方法 结合了一个结果驱动的对比学习模块(ODCL), 精心设计 以增强界限信息的描绘。注意,对比学习致力于训练一个 模型, 使其对相似(正)和不相似(负)数据对具有高度的 可辨能力,从而对图像内容有更细致的理解。在此基础上, 特别是在与半监督学习结合时,可以从最终模型中获得更 高的精度和更精细的细节。其次,我们详细制定了一个动 态互补竞争模块(DCC)來超越传统。传统上,在 Mean Teacher 模型中, 教师网络的性能在很大程度上依赖于学 生网络,因为前者本质上是后者历史状态的加权组合。相 比之下, 我们的 DCC 模块最小化了学生和教师网络之间 的依赖性,同时利用伪标签促进互补竞争,推动一种协作 动态, 使双方的改进互惠互利。图 1 显示了我们的 C3S3 与其他方法的对比示例。可以看出,我们的提议捕捉到了 更加清晰的界限,相较于竞争对手具有显著优势。数值结 果也验证了视觉结果。从技术上讲,我们工作的主要贡献 有三个方面。

- 为追求更好的边界划分,我们提出了一个名为 ODCL 的新模块,该模块包含两个关键组成部分,即空间位 置二值掩码和双空间交并比损失。
- 我们提出了一种 DCC 模块,采用加权竞争机制进行 精确伪标记,同时也使得整个模型的两个子网络能够 相互学习。
- 通过 VNet 和 ResVNet 作为双子网,以及所提出的两个模块无缝组装,最终的分割网络 C3S3 被塑造出来。在两个公共基准数据集上的结果,即 MRI 中左心房分割和 CT 扫描中的胰腺分割,验证了 C3S3 设定了新的最先进分数。

II. 相关工作

A. 半监督医学图像分割

近年来,半监督医学图像分割取得了一系列创新进展。例如,CauSSL [2] 使用一种新颖的因果图为主流半监督分割方法提供理论基础。值得注意的是,两种与我们研究紧密相关的方法是使用伪标签的自训练 [3], [4] 和一致性正则化 [5], [6] ,它们在提高分割性能方面显示出了显著的潜力。

伪标签法涉及使用训练好的模型为无标签数据生成标签,这些标签随后用于通过迭代更新来完善模型,从而提高其学习能力。然而,随着无标签数据的大量存在,由于不准确的伪标签导致的错误传播风险构成了一个显著的挑战。因此,提高伪标签的可靠性和准确性成为一项关键优先事项。C3T [4] 引入了一种可信度感知的伪标签过滤机制,专为像素级分割任务设计,验证和过滤伪标签,以增强网络间引导的可靠性并减轻错误传播。此外,CAML [7] 引入了传递先验知识和执行分布一致性的模块,增强伪标签方法的可靠性。

一致性正则化是半监督学习中的关键技术,通过对扰动样本进行一致性预测来减少误差传播。它已通过结合辅助任务来利用几何信息扩展到多任务学习。在医学图像分割(MIS)中,广泛采用了 Mean Teacher (MT) 框架,其中学生网络通过梯度更新,而教师网络通过 EMA 更新。TraCoCo [8] 通过改变空间上下文来增强一致性学习,提高对前景对象的关注和分割性能。CORN [9] 利用二阶统计和动态特征池来提高精度和保持一致性。此外,ICR-Net [10] 集成标注数据以增强正则化,并改善从未标注数据中提取信息,补充传统一致性方法。

B. 对比学习

对比学习在计算机视觉领域取得了显著成功 [11], [12] ,其重点是在区分相似(正样本)和不相似(负样本)特征对的过程中学习辨别特征。它最初在图像级任务中取得成功,随后被改编用于图像分割等密集预测任务,这种方法在半监督应用中越来越受到关注。UGCL [12] 通过利用不确定性感知对比学习提高了医学图像分析中的分割精度,以应对边界模糊和高熵区域等挑战。

最近,将对比学习与一致性正则化相结合应用于半监督分割领域取得了显著进展,该方法利用伪标签进行对比学习,同时优化对比损失和一致性损失 [11]。这种双重方法促进了特征表示的学习和伪标签的优化,从而提高了分割的效率和准确性。

根据 [13] 的 MCF, 著名的 VNet (A) 及其变体 ResVNet (B) 被使用为我们的双重骨干,两个骨干均拥有一个 U 型特征提取器和一个尾部准备好的分类器。此外,如图 2 所示,我们方案的核心成分集中于两个主要模块,即 DCC和 ODCL,其详细解释分别在小节??和 II-C 中提供。

在半监督学习中,假设训练数据集包含 N 个有标签的数据和 M 个无标签的数据,其中 $M\gg N$ 。为了方便起见,我们将少量的有标签数据记为 $\mathcal{D}_L=\{(x_i^L,y_i^L)\}_{i=1}^N$,对应的无标签数据记为 $\mathcal{D}_U=\{x_i^U\}_{i=1}^M$,其中 $x_i\in\mathbb{R}^{H\times W\times D}$ 表示训练图像, $y_i\in\mathbb{B}^{H\times W\times D}$ 是标签(如果有)。然而,由于有标签样本 x_i^L 的数量有限,半监督学习的目标是借助额外的无标签数据 x_i^U 来实现理想的结果。最初通过两种随机的数据增强 [13] ,整个输入 X 然后分别输入到两个骨干网络中,生成有标签数据 \hat{Y}^L 和无标签数据 \hat{Y}^U 的特征。

$$\hat{Y}_A = A(\mathbf{X}), \hat{Y}_B = B(\mathbf{X}) \tag{1}$$

参考之前的工作 [11] ,对于标记数据,使用交叉熵损失 L_{ce} 和骰子损失 L_{dice} 进行监督训练:

$$L_{seg} = L_{ce}(\hat{Y}^L, y) + L_{dice}(\hat{Y}^L, y)$$
 (2)

对于未标记的数据,我们计算伪监督损失 L_{cp} 和结果驱动的对比损失 L_{iuc} :

$$L_{unsup} = L_{cp}(\hat{Y}_A^U, \hat{Y}_B^U, \hat{Y}^L) + \lambda L_{iuc}(p_A, p_B, p^-)$$
(3)

,其中 λ 是平衡两个子损失的权重,其详细设置取决于具体的任务。 p_A 、 p_B 和 p^- 的实践将在小节 II-C 中详细阐述。

同时,我们使用一致性正则化以进一步减少两个预测之间的差异,从而导致一致性损失 L_{cos} 。集成所有子损失后,整体损失表示为 $L_{total} = L_{seg} + L_{cos} + L_{unsup}$ 。我们提出了一种动态互补竞争机制,使两条主干网络能够同时相互学习和竞争。DCC 的动态特性使其能够实时适应变化的数据模式,相较于静态版本,具有显著的改进。同时,由于两条主干网络共享平等的地位,紧密依赖性的解耦应得以实现,进一步允许在各自的学习上更多地专注于独立的方向。

在实际操作中,我们开始对输入进行两种随机增强,然后分别将其输入到主干 A 和主干 B 中。结果可以生成关注的输出 $\{\hat{Y}_A^1,\hat{Y}_A^2\}$ 和 $\{\hat{Y}_B^1,\hat{Y}_B^2\}$ 。在使用真实值获得监督损失 L_{seg} 后,使用加权竞争函数来确定哪个主干在当前状态下表现得更具竞争性。

$$L_{competition} = \alpha L_{ce}(\hat{Y}^L, y) + (1 - \alpha) L_{dice}(\hat{Y}^L, y)$$
 (4)

, 其中参数 α 是决定性权重。

然后,我们利用当前表现较好的骨干网络生成伪标签,用于监督另一骨干网络的预测并计算伪监督损失:

$$L_{cp} = MSE(\hat{Y}^{U1}, Y_p^{U1}) + MSE(\hat{Y}^{U2}, Y_p^{U2})$$
 (5)

同时,为了最小化 \hat{Y}_A^1 和 \hat{Y}_A^2 (分别为 \hat{Y}_B^1 和 \hat{Y}_B^2)之间的分歧,利用两个预测结果之间的余弦距离来获得一致性损失:

$$L_{cos}(\hat{Y}_A^1, \hat{Y}_A^2) = 1 - \frac{\hat{Y}_A^1 \cdot \hat{Y}_A^2}{\|\hat{Y}_A^1\|_2 \cdot \|\hat{Y}_A^2\|_2}$$
 (6)

将显式损失项集成到模型中在训练过程中提供了额外的 正则化,这对于提高整个训练过程的稳定性和一致性至关 重要。此外,在选择性能更好的骨干网络时,由于竞争中 的两个损失项已经在模型训练期间计算,因此无需引入额 外的计算,这进一步保证了降低计算开销。

C. ODCL 模块

为了确保两个主干网络的特征空间一致,融合了对比学习,它在两个阶段中进行:空间位置二值掩码和双空间交并损失。对比学习使模型能够更深入地理解复杂的数据结构,提供更详细的数据分析。

空间位置二值掩码:图 3 提供了掩码采样方案的概述。未标记的数据首先输入到两个主干网络中,随后将提取器的输出投影到低维特征图。接着,我们将两个特征图二值化,并计算结果的交集和并集以得出掩码。交集和并集的掩码分别标记为 \mathcal{M}_{\cap} 和 \mathcal{M}_{\cup} 。在特征图通过这两个掩码时,获得的结果分别表示为 p_A^1 和 p_A^2 (分别为 p_B^1 和 p_B^2),负样本定义为 p^- 。注意,这些符号已在方程 3 中出现。

我们将交集部分视为高概率正确的前景预测,而将并集中排除的体素视为正确的背景预测。当我们从前景区域设

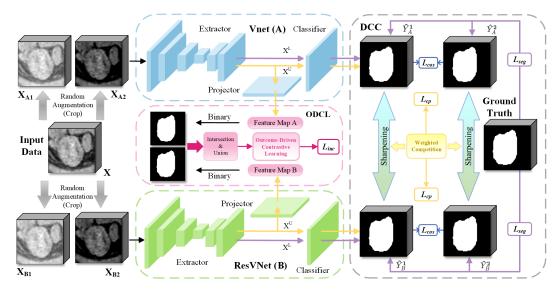


Fig. 2: 我们提案的概述。在接收到输入数据后,C3S3 进行两次随机数据增强,随后通过两个独立的骨干网络,即 VNet 和 ResVNet。 黄色 线路代表未标记的样本,而 紫色 线路表示已标记的样本。未标记的数据在处理通过投影仪后被直接输入到 ODCL,其中会产生损失 L_{iuc} 。VNet 和 ResVNet 均产生两个预测结果,其中计算了一致性损失 L_{cos} ,接着通过加权竞争模块生成伪标签损失 L_{cp} 。此外,标记数据则贡献了监督损失 L_{seg} 。

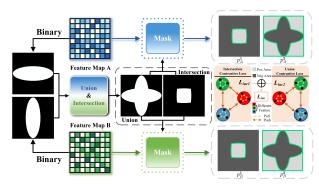


Fig. 3: ODCL 的说明。ODCL 从特征图中识别出通过交集和并集运算处理过的正负样本区域,然后计算损失 L_{iuc} 。

置正样本时,负样本将从可能的背景区域中选择,反之亦 然,这确保了明显的对比效果。

在实践中,我们设计了一种选择正负样本对的策略。即给定一个锚点,选择相同空间位置对应的体素作为正样本。利用交集合,我们进一步将相交区域指定为正样本区域,其余的为负样本,据此可以计算对比损失 L_{iuc1} 。类似地,使用并集合,我们将排除在并集结果之外的体素视为正样本区域,剩下的作为负样本,用来计算对比损失 L_{iuc2} 。

双空间交集-并集损失: 在进行正样本和负样本的选择之后, 我们制定了一种对比损失, 以使正样本对更接近而负样本对更远离。具体来说, 对于前景体素特征 $\varphi_1 \in p_A$, 对比损失计算如下:

$$L_{iuc1}(\varphi_1, \varphi_2) = -\log \left(\frac{\mathcal{M}_{\cap} e^{\cos(\varphi_1, \varphi_2)/\tau}}{\mathcal{M}_{\cap} e^{\cos(\varphi_1, \varphi_2)/\tau} + (1 - \mathcal{M}_{\cap}) \sum_{n=1}^{N} e^{\cos(\varphi_1, \varphi_n)/\tau}} \right)$$
(7)

其中 φ_2 表示从 p_B 中提取的正体素,而 φ_n 指的是负体素。N 表示采样的负体素总数, τ 代表温度超参数。

同样地,对于背景体素,对比损失可以被表示为如下形式:

$$L_{iuc2}(\varphi_1, \varphi_2) = -\log \left(\frac{(1 - \mathcal{M}_{\cup})e^{\cos(\varphi_1, \varphi_2)/\tau}}{(1 - \mathcal{M}_{\cup})e^{\cos(\varphi_1, \varphi_2)/\tau} + \mathcal{M}_{\cup} \sum_{n=1}^{N} e^{\cos(\varphi_1, \varphi_n)/\tau}}\right)$$
(8)

因此,两个特征图之间的整体对比损失可以表示为:, 其中

$$L_{iuc}(p_A, p_B, p^-) = \frac{1}{N_p} \sum_{\varphi_1 \in p_A} L_{iuc1}(\varphi_1, \varphi_2) + \frac{1}{N_p} \sum_{\varphi_1 \in p_A} L_{iuc2}(\varphi_1, \varphi_2)$$
(9)

表示 p_A 中的体素数量。

通过两个骨干网络的四个特征图,我们通过计算来自不同分支的特征图对之间的对比损失来最大化它们的信息效用,最终定义了双空间交并损失:

$$L_{all}(p_A, p_B, p^-) = L_{iuc}(p_A^1, p_B^1, p^-) + L_{iuc}(p_A^1, p_B^2, p^-) + L_{iuc}(p_A^2, p_B^1, p^-) + L_{iuc}(p_A^2, p_B^2, p^-)$$

$$(10)$$

III. 实验

我们在两个数据集上评估我们的方法: 左心房(LA)数据集 [14],包含 100 个 MR 体积($112 \times 112 \times 80$ 作物用于训练和滑动窗口用于推理)和胰腺-CT 数据集 [15],包含 82 个 CT 扫描($96 \times 96 \times 96$ 作物和 K 折交叉验证用于评估)。

与最近的先进方法 [13], [16] 相一致,我们采用了四个广泛使用的指标: Dice 相似系数 (Dice)、Jaccard 相似系数 (Jaccard)、95 % Hausdorff 距离 (95HD) 和平均表面距离 (ASD)。Dice 和 Jaccard 用于评估预测分割与真实值之间 的区域重叠,而 95HD 和 ASD 用于评估边界对齐。具体来说,95HD 测量的是表面对表面的 95 百分位距离,而

ASD 则计算平均表面距离。为了进行比较,我们参考了几种先进的方法,包括 UA-MT [17] 、SASSNet [18] 、DTC [19] 、SS-Net [20] 、MCF [13] 、CAML [7] 、CauSSL [2] 和 TraCoCo [8] 。

A. LA 的结果

表?? 展示了在 LA 数据集上的评估结果,包括在全监督(100%标注)和半监督(20%标注)设置下与独立的VNet 和 ResVNet 的比较。C3S3取得了5.14的95HD,优于全监督的 ResVNet (5.61),并且接近 VNet (4.97)。对于 ASD, C3S3 达到了1.57,最接近全监督的表现。在半监督方法中,C3S3显示出比竞争对手显著的改进。值得注意的是,C3S3实现了最高的 Dice 系数(91.24%),超过了半监督的 ResVNet (91.05%),并且几乎接近全监督的 VNet (91.47%)。同样,其 Jaccard 指数(84.01%)与 VNet (84.36%)相当。这些结果突显了 C3S3 在精确边界定位和分割精度方面的优势。图4通过可视化的方式确认了这些发现,展示了 C3S3 在边界描绘方面的细节捕获能力优于其他方法。

B. 胰腺 CT 上的结果

表 I 展示了在胰腺 CT 数据集上的评估结果,这比 LA MRI 更具挑战性,因为胰腺 CT 体积具有复杂的背景。在完全监督 (100 % 标注数据) 和半监督 (20 % 标注数据) 设置下,C3S3 的性能与 VNet 和 ResVNet 进行了基准测试。采用四折交叉验证策略,使用 12 个标注样本和 50 个未标注样本,确保评估的稳健性。C3S3 取得了出色的结果,特别是在对边界敏感的指标中,95HD 降低到 6.96,ASD降低到 1.74,显著优于使用 20 % 标注数据训练的 VNet和 ResVNet。与其他半监督模型相比,C3S3 在 95HD 和ASD 方面也取得了最佳结果,突显出其优越的边界划分能力。在 Dice和 Jaccard 指标方面,C3S3 在所有半监督方法中取得了最高 Dice分数 (80.93 %)和第二高的 Jaccard指数 (68.06 %)。图 4 形象地展示了这些结果,展示了C3S3 较其他方法更精准的边界定位和改进的分割准确性。

IV. 消融研究

超参数 α 的影响: 在 DCC 模块中,利用加权竞争评估两个骨干网络的实际性能,选择最具竞争力的一个进行伪标记。左心房数据集的分析显示,不同的超参数 α 的值对模型性能的影响相对较轻,当将 α 设置为 0.8 时可获得最佳结果,如表 II 所示。

ODCL 的作用: ODCL 模块旨在提升目标边界划定的精确度。通过对比含有和不含 ODCL 的模型进行实验比较,显示出显著差异,如表 III 所示。具体来说,95HD 从6.97 下降到 5.64, ASD 从 2.03 下降到 1.81, Dice 系数从87.12 % 提升到 89.92 %, Jaccard 指数从 80.14 % 增加到81.88 %。这些结果证实了 ODCL 在多种指标上有效地提高了目标定位的准确性。

DCC 的作用:综合消融分析突出 DCC 模块在 C3S3 框架中的影响。DCC 通过双主干之间的竞争机制动态生成伪标签,以表现较好的主干监督另一主干,从而优化预测。这种方法提高了边界划分的准确性,并增强了边界敏感性和重叠指标。如表 III 所示,例如,95HD 从 6.97 降至6.27,ASD 从 2.03 降至 1.86,而 Dice 和 Jaccard 得分分别提升至90.18 %和 82.26 %。这些结果证明了 DCC 在减少伪标签误差和增强框架鲁棒性方面的关键作用。此外,

DCC 与其他损失组成的集成进一步提升了整个框架的稳定性和鲁棒性。

V. 结论

在本研究中,我们提出了一种用于 3D 医学图像分割的新半监督方法,专门设计用于提供精细的边界并支持丰富的细节。为此,精心开发了一个以结果为导向的对比学习模块,其中进一步包含一个空间位置二元掩蔽方案和一个双空间交并比损失,这两者显著改善了边界塑造。此外,我们实现了一个动态互补竞争模块,通过加权竞争机制选择更具竞争力的主干来生成伪标签。还采用一致性正则化来减少不同预测之间的差异。我们在两个公共基准数据集上的验证证明了 C3S3 在 SSMIS 中的有效性。具体而言,在绝大多数指标上都达到了新的最先进的分数。此外,我们发现提出的 ODCL 和 DCC 模块可以作为即插即用的角色,并适用于各个领域。

References

- Ziyun Yang and Sina Farsiu, "Directional connectivity-based segmentation of medical images," in CVPR, 2023, pp. 11525– 11535.
- [2] Juzheng Miao, Cheng Chen, Furui Liu, et al., "Caussl: Causality-inspired semi-supervised learning for medical image segmentation," in ICCV, Oct. 2023, pp. 21369–21380.
- [3] Hritam Basak and Zhaozheng Yin, "Pseudo-label guided contrastive learning for semi-supervised medical image segmentation," in CVPR, 2023, pp. 19786–19797.
- [4] Yucheng Shu, Jiaxin Xie, Lihong Qiao, et al., "C3t: Contrastive consistency cross-network learning for semi-supervised semantic segmentation," in ICME, 2024, pp. 1–6.
- [5] Xiaomeng Li, Lequan Yu, Hao Chen, et al., "Transformationconsistent self-ensembling model for semi-supervised medical image segmentation," IEEE Transactions on Neural Networks and Learning Systems, pp. 523–534, 2020.
- [6] Lequan Yu, Shujun Wang, Xiaomeng Li, et al., "Uncertainty-aware self-ensembling model for semi-supervised 3d left atrium segmentation," in MICCAI, 2019, pp. 605–613.
- [7] Shengbo Gao, Ziji Zhang, Jiechao Ma, et al., "Correlation-aware mutual learning for semi-supervised medical image segmentation," in MICCAI, 2023, pp. 98–108.
- [8] Yuyuan Liu, Yu Tian, Chong Wang, et al., "Translation Consistent Semi-supervised Segmentation for 3D Medical Images," IEEE Transactions on Medical Imaging, pp. 1–1, 2024.
- [9] Xinze Li, Runlin Huang, Zhenghao Wu, et al., "Leveraging coral-correlation consistency network for semi-supervised left atrium mri segmentation," ArXiv, 2024.
- [10] Xianpeng Cao, Weixing Xie, Xianxing Cao, et al., "Icr-net: Semi-supervised medical image segmentation guided by intrasample cross reconstruction," in ICME, 2024, pp. 1–6.
- [11] Xiangyu Zhao, Zengxin Qi, Sheng Wang, et al., "Rcps: Rectified contrastive pseudo supervision for semi-supervised medical image segmentation," IEEE Journal of Biomedical and Health Informatics, pp. 251–261, 2023.
- [12] Hengyang Liu, Pengcheng Ren, Yang Yuan, et al., "Uncertainty global contrastive learning framework for semi-supervised medical image segmentation," IEEE Journal of Biomedical and Health Informatics, pp. 1–10, 2024.
- [13] Yongchao Wang, Bin Xiao, Xiuli Bi, et al., "Mcf: Mutual correction framework for semi-supervised medical image segmentation," in CVPR, 2023, pp. 15651–15660.
- [14] Zhaohan Xiong, Qing Xia, Zhiqiang Hu, et al., "A global benchmark of algorithms for segmenting late gadolinium-enhanced cardiac magnetic resonance imaging," Medical Image Analysis, p. 101832, 2020.
- [15] Holger R. Roth, Le Lu, Amal A. Farag, et al., "Deeporgan: Multi-level deep convolutional networks for automated pancreas segmentation," in MICCAI, 2015, p. 556–564.

TABLE I: 在胰腺 CT 数据集上的比较。最佳和次佳表现者分别用加粗和下划线表示。

Method	Volumes used		Metrics				
Method	Labeled	Unlabeled	$95HD \text{ (voxel)} \downarrow$	ASD (voxel) \downarrow	$Dice (\%) \uparrow$	$Jaccard (\%) \uparrow$	
VNet	62(100%)	0	7.21	1.69	80.72	68.90	
ResVNet	62(100%)	0	7.38	1.63	79.84	67.35	
VNet	12(20%)	0	17.69	4.64	64.04	48.17	
ResVNet	12(20%)	0	18.95	5.63	66.45	51.12	
UA-MT (MICCAI 2019)	12(20%)	50	17.06	5.23	74.02	60.10	
SASSNet (MICCAI 2020)	12(20%)	50	13.89	3.56	73.58	59.73	
DTC (AAAI 2021)	12(20%)	50	13.18	3.75	73.31	59.26	
SS-Net (MICCAI 2022)	12(20%)	50	12.64	3.59	74.27	60.56	
MCF (CVPR 2023)	12(20%)	50	11.59	3.27	75.00	61.27	
CauSSL (ICCV 2023)	12(20%)	50	8.11	2.34	79.97	67.32	
TraCoCo(TMI 2024)	12(20%)	50	7.34	1.84	80.90	69.26	
C3S3 (ours)	12(20%)	50	6.96	1.74	80.93	68.06	

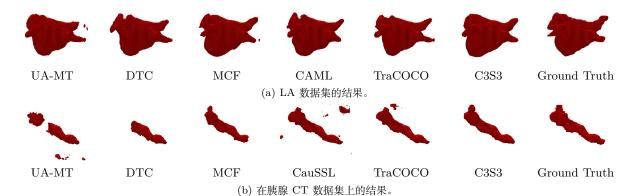


Fig. 4: 定性分割结果。(a) LA 数据集上的结果。(b) Pancreas-CT 数据集上的结果。

TABLE II: 不同 α 值在加权竞争机制对 LA 数据集的影响。

Parameter	Metrics					
α	$95HD \text{ (voxel)} \downarrow$	ASD (voxel) \downarrow	$Dice (\%) \uparrow$	$Jaccard (\%) \uparrow$		
1.0	5.94	1.97	88.89	80.58		
0.9	5.62	1.90	89.70	81.57		
0.8	5.14	1.57	91.24	84.01		
0.7	5.40	1.66	90.34	82.56		
0.6	5.87	1.84	89.17	80.91		
0.5	5.83	1.88	89.59	81.44		
0.4	5.76	2.00	89.26	80.97		
0.3	7.14	2.16	89.15	80.78		
0.2	5.83	2.02	88.51	80.20		
0.1	5.75	1.95	89.91	81.85		
0.0	6.47	2.01	88.70	80.27		

TABLE III: ODCL 和 DCC 模块的消融实验结果。

Method	L_{iuc}	L_{cp}	Metrics			
Method			$95HD \text{ (voxel)} \downarrow$	ASD (voxel) \downarrow	$Dice (\%) \uparrow$	$Jaccard$ (%) \uparrow
(1)	_	_	6.97	2.03	87.12	80.14
(2)	√	_	5.64	1.81	89.92	81.88
(3)	-	✓	6.27	1.86	90.18	82.26
(4)	✓	✓	5.14	1.57	91.24	84.01

- [16] Yunhao Bai, Duowen Chen, Qingli Li, et al., "Bidirectional copy-paste for semi-supervised medical image segmentation," in CVPR, 2023, pp. 11514–11524.
- [17] Lequan Yu, Shujun Wang, Xiaomeng Li, et al., "Uncertainty-aware self-ensembling model for semi-supervised 3d left atrium segmentation," in MICCAI, 2019, pp. 605–613.
- [18] Shuailin Li, Chuyu Zhang, and Xuming He, "Shape-aware semisupervised 3d semantic segmentation for medical images," in MICCAI, 2020, pp. 552–561.
- [19] Xiangde Luo, Jieneng Chen, Tao Song, et al., "Semi-supervised medical image segmentation through dual-task consistency," in AAAI, 2021, pp. 8801–8809.
- [20] Yicheng Wu, Zhonghua Wu, Qianyi Wu, et al., "Exploring smoothness and class-separation for semi-supervised medical image segmentation," in MICCAI, 2022, pp. 34–43.