

CDCL: 面向医学图像半监督分割的冲突驱动交叉学习策略^①



张 栋, 刘 勇

(青岛科技大学 信息科学技术学院, 青岛 266061)

通信作者: 刘 勇, E-mail: liuyong@qust.edu.cn

摘 要: 在医学图像分割中, 半监督学习技术解决了标注成本高的问题. 然而, 现有的半监督方法忽略了伪标签质量不一致和模型的约束泛化问题. 因此, 本文提出了冲突驱动的交叉学习框架 CDCL, 它无缝整合交叉监督和平均教师模型. 这一框架促进了有效的知识转移, 并采用两套不同的师生结构提升模型性能. 同时, 知识通过各自的教师模型在不同模型之间进行交换, 从而促进了相互学习和能力提升. 此外, 在 CDCL 中引入特征冲突损失 (FCL) 鼓励模型之间传递多样化且互补的知识, 从而丰富整体的学习动态. 更重要的是, CDCL 还采用了成对复制粘贴 (PCP) 策略, 以生成新的训练样本来丰富模型训练. 在 2 个公共数据集上实验结果表明, CDCL 在 ACDC 数据集标记数据比为 10% 的情况下, 平均 Dice 和 Jaccard 系数分别达到 90.23% 和 82.71%, 分别比 BCP 模型提高了 1.39% 和 2.09%. 在 PROMISE12 数据集中 20% 和 30% 标记比下 Dice 系数分别达到了 78.9% 和 80.09%.

关键词: 交叉监督; 半监督学习; 医学图像分割; 师生模型; 一致性正则化

引用格式: 张栋,刘勇.CDCL: 面向医学图像半监督分割的冲突驱动交叉学习策略.计算机系统应用,2025,34(9):162-169. <http://www.c-s-a.org.cn/1003-3254/9961.html>

CDCL: Conflict-driven Cross-learning Strategy for Semi-supervised Medical Image Segmentation

ZHANG Dong, LIU Yong

(College of Information Science and Technology, Qingdao University of Science & Technology, Qingdao 266061, China)

Abstract: In medical image segmentation, semi-supervised learning addresses the challenge of high annotation costs. However, existing methods often overlook the inconsistent quality of pseudo-labels and the limited generalization of model constraints. To address these issues, this study proposes a conflict-driven cross-learning (CDCL) framework that seamlessly integrates cross supervision with a mean teacher model. The proposed framework leverages two different teacher-student structures to facilitate effective knowledge transfer and enhance segmentation performance. Knowledge is exchanged between student models via their respective teacher models, enabling mutual learning and capability improvement. In addition, a feature conflict loss (FCL) is introduced to promote the transfer of diverse and complementary features between models, thus enriching the learning dynamics. To further augment training data, a pairwise copy-paste (PCP) strategy is adopted to generate novel training samples. Experimental results on two public datasets demonstrate the effectiveness of the proposed CDCL framework. With only 10% labeled data on the ACDC dataset, average Dice and Jaccard coefficients reach 90.23% and 82.71%, outperforming the BCP model by 1.39% and 2.09%, respectively. On the PROMISE12 dataset, Dice coefficients of 78.9% and 80.09% are achieved with 20% and 30% labeled data, respectively.

^① 收稿时间: 2025-02-17; 修改时间: 2025-03-10, 2025-03-28; 采用时间: 2025-04-07; csa 在线出版时间: 2025-07-25
CNKI 网络首发时间: 2025-07-28

Key words: cross supervision; semi-supervised learning; medical image segmentation; teacher-student model; consistency regularization

医学图像分割在计算机辅助诊断系统中扮演着至关重要的角色。近年来,深度学习已成为该领域的主流方法,推动了医学图像分割技术的显著进步^[1-3]。但是,传统的基于监督学习的深度学习在训练过程中依赖于大量的标记数据,而医学图像中像素级标注的任务既费时又费力^[4,5]。为了解决这一难题,半监督医学图像分割技术逐渐崭露头角。

半监督医学图像分割利用大量未标记数据和少量标记数据来提升模型的性能。最近的研究大部分专注于伪标签和一致性正则化方法。前者是一种利用模型对未标记数据的预测来生成伪标签,进而将这些伪标签纳入训练过程,以有效利用未标记数据提高分割性能的自我训练策略。后者通过确保模型对未标记数据的预测在不同扰动下保持稳定,来提升模型的分割准确性。这种方法基于一个假设,即如果模型在输入数据经历微小变化后仍能给出相似的预测结果,那么这些针对未标记数据的预测应当是可信的。师生模型^[6]是半监督学习方法中常见的一种架构,它通过一个预先训练的“教师”模型来指导一个“学生”模型的学习过程,以提高对未标记数据的利用效率和分割性能。UA-MT^[7]将不确定性理论纳入平均教师范式,从而引导学生模型得出与教师模型一致的预测结果。这只是简单地用阈值来决定伪标签的去留,然而,伪标签准确率的高低会呈现不同的未标记数据特征。SASSNet^[8]进一步对分割输出施加了几何形状约束。MC-Net^[9]利用多个解码器对预测进行扰动,并促进这些扰动解码器之间的预测一致性。采用多个解码器来进行一致性学习的方法存在着模型约束的问题,即在学习过程中,无法保证每个解码器都能朝着不同方向进行特征学习。

为了解决这些问题,本文提出了一种半监督学习框架——CDCL,该框架独特地融合了交叉监督与平均教师模型的概念,显著提升了学习效率和知识的多样性。CDCL采用双教师-学生模型架构,两个教师-学生模型的解码器采用不同的训练策略,通过指数移动平均法(EMA)优化教师模型权重,以生成更精确的伪标签,与传统方法相比,实现了更高效的知识传递,并有效应对了伪标签的可靠性和特征多样性问题。此外,引

入特征冲突损失(FCL)促进了模型间的知识互补,进一步提升了学习的整体效能。同时进一步地使用了成对复制粘贴(PCP)方法,为模型提供新的训练样本,提升模型的鲁棒性。

我们提出的CDCL框架不仅能够熟练地利用无标记数据来增强分割能力,而且通过其创新的交叉监督机制,在医学图像分割领域展现出了卓越性能。本文贡献可以总结如下。

- 1) 设计了基于冲突的教师-学生网络方法(CDCL),用于半监督医学图像分割。该方法能够传递准确且多样的知识,从而提升分割过程的效果。
- 2) 设计了一种特征冲突损失(FCL),以促进两个教师-学生网络之间的多样性,从而确保在知识传递过程中实现最大程度的互补性。
- 3) 设计出成对复制粘贴方法,来解决数据分布不均问题,同时拓展数据集,提升模型鲁棒性。

1 相关工作

1.1 伪标签方法

在扩展训练数据集的过程中,采用伪标签方法往往会在训练阶段引入显著的标签噪声。针对这一问题,Wang等^[10]提出了一种解决方案,即在模型输出中嵌入一个信任模块,用以重新评估伪标签的可靠性,并通过设定阈值筛选出高置信度的样本。然而,对所有样本采用统一的阈值标准并不妥当。Lu等^[11]提出了一种自适应阈值方法,通过计算学生模型与教师模型预测之间的Kullback-Leibler散度,以评估预测结果的不确定性。同时,多项研究^[12,13]也提出了不同的样本选择策略以生成伪标签。例如,FixMatch^[12]方法采用预定义的阈值来选取模型预测置信度高的伪标签样本,以实现连贯的学习过程。但是,这种方法未能考虑不同类别在学习状态和难度上的差异性。FlexMatch^[13]则通过课程学习(curriculum learning)策略,根据训练的进展动态调整每个类别的阈值。与上述方法不同,本文面临的挑战在于将概率阈值作为筛选干净伪标签数据的可靠指标存在困难。这一难题主要源于未标记数据的特性,即无论是正确的还是错误的伪标签,都可能呈现出相似的概率

分布. 为此, 本文采取了一种不同的策略, 即利用双教师模型预测生成的伪标签, 来交叉监督和指导学生模型产生更为显著的预测.

1.2 一致性正则化方法

基于平滑性假设的方法被称为一致性正则化. 一致性正则化主要目标是当对原始数据的不同视图应用不同扰动时, 减少输出差异. 在训练过程中建立高质量的一致性目标是实现最佳性能的重要手段. Zhang 等^[14]开发了一个互学习框架, 使得两个网络在训练过程中能够协作学习. 在额外网络中的学习是一个辅助任务, 它通过两个网络之间的一致性提供异质性的监督信号. Luo 等^[15]提出了一个双任务一致性的半监督学习框架. MT^[6]同时训练学生模型和教师模型, 其中教师模型是学生模型的指数移动平均. 通过比较两个模型的预测并使用差异作为一种正则化形式, 提高了学生模型的性能. 然而, 这些方法忽略了不同子网络之间的交互, 并且没有纠正网络本身的工作偏差. 与上述方法相比, 本文采用双师生网络方法, 在数据级、特征级和网络级扰动下积极执行一致性, 这大大扩展了表征空间并增强了模型的泛化能力.

1.3 数据增强方法

现有的半监督学习策略在未标记数据上应用数据增强以实现一致性正则化. 然而, 标记数据和未标记数据之间的差异可能会降低模型的性能^[16]. CutMix^[17]是一种简单而强大的数据处理方法, 也被称为复制粘贴(CP), 它鼓励未标记数据从标记数据中学习共同特征, 因为同一领域中的像素共享更接近的语义. mixup^[16]通过图像混合来减轻标记数据和未标记数据之间的差异. MixMatch^[18]是进一步提出的技术, 以减少通过 mixup 增强的多个样本之间的方差. 但是现有的 CP 方法^[19,20]忽视了为标记和未标记数据设计一致性策略, 这阻碍了其在减少分布差距上的使用. BCP^[21]通过双向复制粘贴图像来结合标记数据与未标记数据. 受到 BCP 的启发, 本文提出了成对复制粘贴方法来解决分布不匹配问题, 同时拓展数据集.

2 方法

在半监督分割设置中, 训练集中有 N 个标记数据和 M 个未标记数据 (其中, $M \gg N$). $D^l = \{(X_i^l, Y_i^l)\}_{i=1}^N$ 和 $D^u = \{(X_i^u)\}_{i=N+1}^{M+N}$ 分别代表标记和未标记的训练集. 其中, X_i^l 和 X_i^u 表示输入图像, Y_i^l 表示 X_i^l 对应的分割标签图像.

2.1 模型架构以及训练策略

本文所提模型的整体架构图如图 1 所示, CDCL 模型创新性地融合了交叉监督与师生框架, 用来提供多样化的知识传递和精确的指导. 在该框架中, CDCL 特别设计了两个不同的均值教师 (A 和 B), 每个架构都由一对学生-教师网络组成. 师生网络 A 包含学生网络 $F^{sa}(E_a^s, D_a^s, \theta^{sa})$ 和教师网络 $F^{ta}(E_a^t, D_a^t, \theta^{ta})$; 师生网络 B 包含学生网络 $F^{sb}(E_b^s, D_b^s, \theta^{sb})$ 和教师网络 $F^{tb}(E_b^t, D_b^t, \theta^{tb})$, 其中 E 代表编码器, D 表示解码器, θ 表示对应的参数. 这两个师生模型的主要区别在于它们的解码器结构: 师生 A 采用上采样技术来恢复图像细节, 而师生 B 则使用转置卷积来进行特征的反卷积操作. 这种差异化的设计使得两个模型能够在特征重建过程中相互补充, 从而提高整体的分割性能.

我们的训练策略分为 3 个阶段进行. 首先, 利用标注数据对两个学生模型进行预训练. 接着, 使用这些预训练的参数来初始化 CDCL 模型中对应的教师网络. 随后, 利用教师网络生成未标注图像的伪标签, 并通过比较这些伪标签与学生模型的输出, 来计算损失函数. 在每次迭代过程中, 通过随机梯度下降对学生网络进行优化, 采用学生网络的指数移动平均 (EMA) 方法来优化教师模型. 教师网络参数 $\theta_{k+1}^a, \theta_{k+1}^b$ 在第 $k+1$ 次迭代更新:

$$\theta_{k+1}^a = \lambda \theta_k^a + (1 - \lambda) \theta_k^{sa} \quad (1)$$

$$\theta_{k+1}^b = \lambda \theta_k^b + (1 - \lambda) \theta_k^{sb} \quad (2)$$

其中, λ 是一个超参数.

2.2 成对复制粘贴方法以及交叉监督

为了解决数据分布不均问题, 同时拓展数据集, 本文提出了配对复制-粘贴策略 (PCP). 如图 2 所示. 我们从训练样本中取出一张标记图像 x_b 和一张未标记图像 x_a , 利用二进制分割掩码 $M \in \{0, 1\}^{H \times W}$, 0 表示图像的背景, 1 表示图像的前景. 图 2 中 x_b 的前景用红色方框表示, 背景用红色的 B 表示; x_a 的前景用黄色方框表示, 背景用黄色的 B 表示. 然后将 x_b 的前景和 x_a 的背景混合得到图像 X^{in} , 同样的方式得到混合图像 X^{out} . 然后将 X^{in} 和 X^{out} 送入两个学生网络进行训练. 在每次反向传播迭代中, 对这两个混合图像进行集体处理. 该方法确保了标记和未标记的数据都经过等效的训练, 并促进了从标记图像到未标记图像的共同语义知识的整体

转移, 相应的步骤如式 (3)、式 (4) 所示.

$$X^{in} = x_b \odot M + x_a \odot (I - M) \quad (3)$$

$$X^{out} = x_a \odot M + x_b \odot (I - M) \quad (4)$$

其中, $I \in \{1\}^{H \times W}$, \odot 表示矩阵点乘.

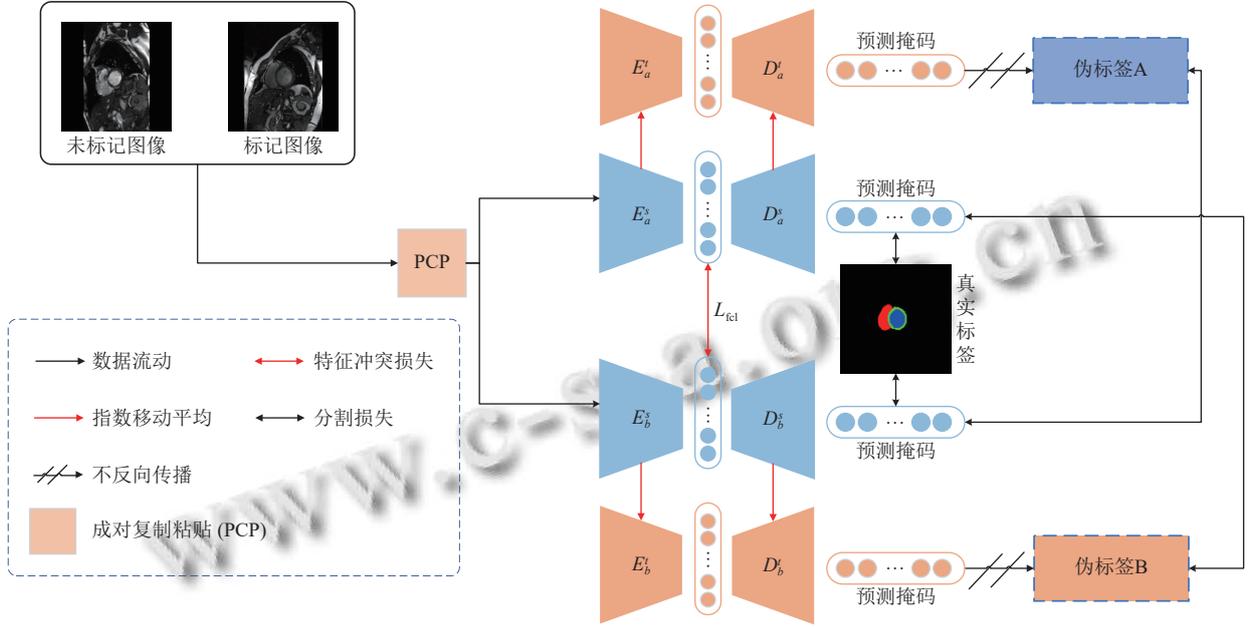


图1 整体架构

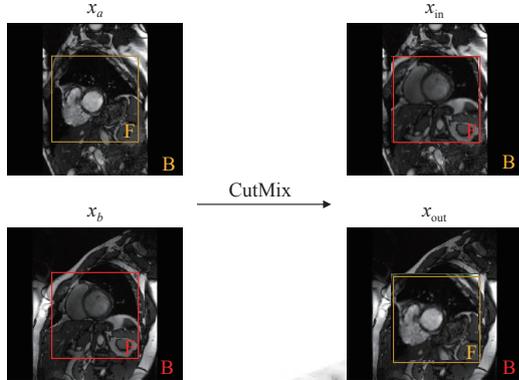


图2 成对复制粘贴方法

为了训练学生网络, 我们使用相同的成对复制粘贴方法生成监督信号. 将未标记图像 x_a 输入到两个教师网络中, 生成的概率图如下:

$$\tilde{P}_n^u = F^n(x_a; \theta^n), n \in \{a, b\} \quad (5)$$

伪标签 \tilde{Y}^u 是通过二分任务中的 \tilde{P}^u (省略了 n) 用常见的 0.5 阈值, 或者在多类分割任务中对 \tilde{P}^u 执行 argmax 操作来确定的. 然后采用与式 (3)、式 (4) 相同的方法来获得监督信号:

$$Y_n^{in} = Y_b^l \odot M + \tilde{Y}_n^u \odot (I - M), n \in \{a, b\} \quad (6)$$

$$Y_n^{out} = Y_b^l \odot (I - M) + \tilde{Y}_n^u \odot M, n \in \{a, b\} \quad (7)$$

由于标记数据部分对于生成的伪标签更加可靠, 我们设置了一个影响因子 α 来调节未标记数据在整个损失中的比例. 通过两个师生模型的教师网络生成的伪标签来相互监督对方学生网络的预测结果来实现交叉监督. 对于师生模型 A 的学生网络预测 X^{in} 和 X^{out} 分割图结果如式 (8)、式 (9) 所示:

$$Q_a^{in} = F^{sa}(X^{in}, \theta^{sa}) \quad (8)$$

$$Q_a^{out} = F^{sa}(X^{out}, \theta^{sa}) \quad (9)$$

师生 A 对于 X^{in} 和 X^{out} 的损失计算为:

$$L_a^{in} = L_{seg}(Q_a^{in}, Y_b^{in}) \odot M + \alpha L_{seg}(Q_a^{in}, Y_b^{in}) \odot (I - M) \quad (10)$$

$$L_a^{out} = L_{seg}(Q_a^{out}, Y_b^{out}) \odot (I - M) + \alpha L_{seg}(Q_a^{out}, Y_b^{out}) \odot M \quad (11)$$

其中, L_{seg} 是交叉熵损失和 Dice 损失的线性组合, 其表示为:

$$L_{seg} = (L_{ce} + L_{dice})/2 \quad (12)$$

师生 A 的总体损失为:

$$L_A = L_a^{in} + L_a^{out} \quad (13)$$

对于师生 B 的学生网络预测 X^{in} 和 X^{out} 分割图结果如式 (14)、式 (15) 所示:

$$Q_b^{\text{in}} = F^{sb}(X^{\text{in}}, \theta^{sb}) \quad (14)$$

$$Q_b^{\text{out}} = F^{sb}(X^{\text{out}}, \theta^{sb}) \quad (15)$$

师生 B 对于 X^{in} 和 X^{out} 的损失计算为:

$$L_b^{\text{in}} = L_{\text{seg}}(Q_b^{\text{in}}, Y_a^{\text{in}}) \odot M + \alpha L_{\text{seg}}(Q_b^{\text{in}}, Y_a^{\text{in}}) \odot (I - M) \quad (16)$$

$$L_b^{\text{out}} = L_{\text{seg}}(Q_b^{\text{out}}, Y_a^{\text{out}}) \odot (I - M) + \alpha L_{\text{seg}}(Q_b^{\text{out}}, Y_a^{\text{out}}) \odot M \quad (17)$$

师生 B 的总体损失为:

$$L_B = L_b^{\text{in}} + L_b^{\text{out}} \quad (18)$$

2.3 特征冲突损失

交叉监督的主要思想是利用不同模型的多样性来引入扰动, 以实现一致性学习. 然而, 随着训练的开始, 出现了一个值得考虑的问题. 不同模型学习的方法会逐渐重叠, 这会制约模型的性能. 为了应对这一挑战, 我们提出了特征冲突损失 (FCL), 核心思想是让两个模型朝着相对的方向进行学习, 来保持整个训练过程和增强模型间的多样性. 师生模型 A 中的学生编码器提取的特征可以表示为 $f_a = E_a^s(x)$, 其中 x 表示输入图像. 师生模型 B 中的学生编码器提取的特征可以表示为 $f_b = E_b^s(x)$. 师生模型 A 和师生模型 B 的学生网络的特征冲突损失表示为:

$$L_{\text{fcl}}(x) = 1 + \text{cosine_similarity}(f_a, f_b) = 1 + \frac{f_a \cdot f_b}{\|f_a\| \times \|f_b\|} \quad (19)$$

其中, $x \in (X^{\text{in}}, X^{\text{out}})$, cosine_similarity 为余弦相似度, f_a 和 f_b 分别是师生模型 A 和 B 中学生编码器提取的特征. 为了确保特征冲突损失的值大于 0, 我们对特征冲突损失增加 1. 在模型训练期间, 加入特征冲突损失, 会使得两个学生模型的编码器提取的特征有“对抗性”, 从而进入解码器的特征会具有差异性. 因此, 总的特征冲突损失表示为:

$$L_{\text{fcl}} = L_{\text{fcl}}(X^{\text{in}}) + L_{\text{fcl}}(X^{\text{out}}) \quad (20)$$

因此, 模型总的损失表示为:

$$L_{\text{all}} = L_A + L_B + \beta L_{\text{fcl}} \quad (21)$$

其中, β 是超参数.

3 实验及结果分析

3.1 数据集

本文使用了两个公共数据集: ACDC 和 PROMISE12.

ACDC 数据集包含 200 张短轴心脏 MR 电影图像, 这些图像来自 100 名患者, 包括 4 个分割类别: 背景、右心室、左心室和心肌. 遵循 BCP 方法的数据划分, 训练分配了 70 名患者的扫描; 验证分配了 10 名; 测试分配了 20 名. PROMISE12 数据集包含 50 张横向 T2 加权 MRI 扫描. 与先前工作^[21]一致, 本文所有实验中采用了一种标准化的数据分割策略, 分配了 35 张扫描用于训练, 5 张用于验证, 10 张用于测试. 使用 4 个指标来衡量 CDCL 的性能: Dice 系数、Jaccard 指数、95% Hausdorff 距离 (95HD) 和平均表面距离 (ASD).

3.2 实验设置

在实验过程中, α 和 β 的值设置为 0.5 和 1/3. 本文方法均是基于 Torch 实现的, 所有的实验均在 24 GB NVIDIA GeForce RTX 3090 卡上进行. 在 ACDC 和 PROMISE12 数据集上沿用 SS-Net^[22] 方法, 我们使用 2D 的 U-Net 作为实验的骨干网络. 在训练期间, 输入的补丁大小为 256×256 (二维切片), 为了保证整张图像的分割区域被划分为前景, 我们将掩码 M 的中心区域大小设置为 170×170 . 批处理大小、预训练迭代次数和自训练迭代次数分别设置为 24、10000 和 30000.

3.3 对比实验

表 1 展示了 UA-MT^[7]、SASSNet^[8]、DTC^[15]、MC-Net^[9]、SS-Net^[22]、BCP^[23]、DiffRect^[24] 和 CDCL 这 8 种模型在 ACDC 数据集的定量分析, 其中标注训练数据的比例分别为 5% 和 10%. 从表 1 可以看出, 本文方法是性能最佳的, 当使用 5% 的标记样本时, 本文方法相较于大多数半监督方法, 平均 Dice 和 Jaccard 系数有明显的增加. 然而与 BCP 相比, Dice 系数有稍微下降, 这是由于标记数据太少, 模型中针对未标记数据的扰动过于强, 从而导致了模型学习能力受限. 当标注样本的比例增加到 10% 时, 相比较于 DiffRect, CDCL 的平均 Dice 和 Jaccard 系数分别提高了 0.96% 和 1.58%. 这些结果清楚地表明, 本文方法在少量标记数据情况下, 其能力强于其他模型, 从而证明了 CDCL 在利用未标记数据提高性能方面的有效性.

图 3 直观地对比了应用于 ACDC 数据集的不同半监督方法, 其中前两行是 5% 标记数据的实验结果, 后两行是 10% 标记数据的实验结果. 图中明显地展示了本文方法在预测每个切片方面始终优于其他方法, 这也证明了本文方法能够有效地划分目标边界. 对于左心室 (LV, 蓝色) 和心肌 (MYO, 绿色) 来说, 右心室 (RV,

红色) 的形状更加不规则和复杂. 可以看出, 其他半监督方法对这些样本的分割结果存在误划分边界和部分区域缺失, 但本文方法却能有效地纠正这些错误, 生成解剖上更一致的结果.

表1 ACDC 实验结果对比 (%)

Model	5%				10%			
	Dice (%)	Jaccard (%)	95HD (mm)	ASD (mm)	Dice (%)	Jaccard (%)	95HD (mm)	ASD (mm)
UA-MT	46.03	35.40	16.33	5.89	80.96	69.69	8.78	2.51
SASSNet	57.77	46.14	20.05	6.06	84.14	74.09	5.03	1.40
DTC	56.90	45.67	23.36	7.39	82.71	72.14	11.31	2.99
MC-Net	67.13	55.77	14.08	4.79	86.35	76.97	8.36	2.43
SS-Net	66.32	55.83	5.46	1.56	86.80	77.56	4.92	1.34
BCP	87.59	78.67	1.90	0.67	88.84	80.62	3.98	1.17
DiffRect	82.46	71.76	7.18	1.94	89.27	81.13	3.85	1.00
CDCL	86.47	77.10	2.50	0.72	90.23	82.71	2.24	0.58

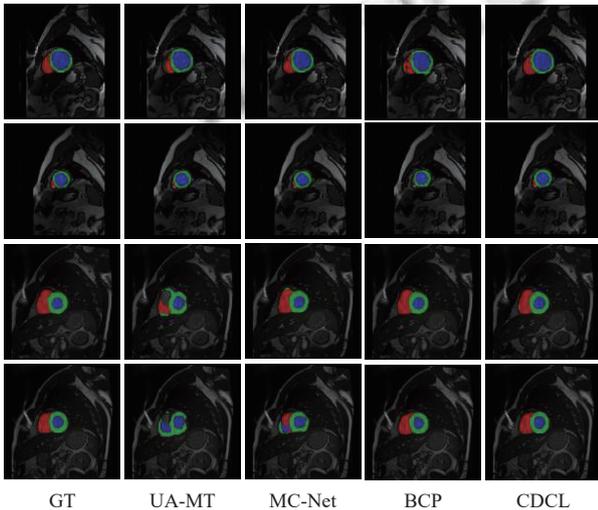


图3 ACDC 数据集上的对比实验结果图

表2 列出了在 PROMISE12 数据集上选择 20% 和 30% 的训练样本作为标注数据集时的定量比较. 我们的方法在使用 20% 和 30% 的标记样本时, 相较于 SLC-Net, Dice 系数分别提高了 6% 和 1.29%. 这表明我们的方法有效地利用了未标记数据来提高模型性能. 同时, 与其他半监督方法相比, 本文方法在各种条件下都表现出卓越的性能, 在所有指标上都取得了最高的性能.

图4 展示了 20% (前两行) 和 30% (后两行) 的标记数据比下本文方法和其他模型的分割结果. 显然, 与其他半监督方法相比, 我们的分割结果展示了更高的准确性, 特别是在边缘轮廓上. 本文方法结合了特征冲突损失, 它能够展现模型多方面的学习能力, 显著提高

了整体分割性能. 此外, 所提出的 PCP 策略和交叉监督损失函数通过提高模型的泛化能力进一步增强了结果. 这意味着本文方法不仅准确地捕捉并表示了目标结构, 而且通过提高泛化能力可以有效地处理各种场景.

表2 PROMISE12 实验结果对比 (%)

Model	20%				30%			
	Dice (%)	Jaccard (%)	95HD (mm)	ASD (mm)	Dice (%)	Jaccard (%)	95HD (mm)	ASD (mm)
UA-MT	68.29	53.65	24.07	7.14	76.68	63.39	11.56	3.72
MC-Net	69.39	57.34	28.25	6.72	76.84	63.44	27.98	7.93
SASSNet	61.98	49.20	39.75	8.0	68.29	53.65	24.07	7.14
DTC	68.29	53.65	24.07	7.14	74.79	61.58	9.98	2.21
SLC-Net	72.90	—	—	3.15	78.8	—	—	2.28
CDCL	78.90	66.20	13.34	4.57	80.09	67.29	24.87	5.14

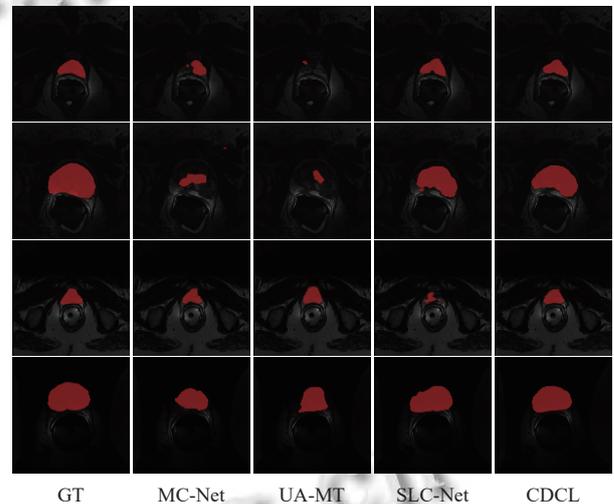


图4 PROMISE12 数据集上的对比实验结果图

3.4 消融实验

本节对所提双师生模型交叉监督 (DMT+CS)、成对复制粘贴 (PCP) 和特征冲突损失 (FCL) 进行消融实验, 来验证其有效性. 值得注意的是, 我们统一使用 10% 标记比的 ACDC 数据集. 解决了数据分布不均的问题, 进一步提升了模型的鲁棒性. 表3 列出了 CDCL 模型中每个模块使用与不使用的实验结果对比图. 其中第 1 行是 MT 模型的实验结果, 展现基线效果. 可以明显看出, 使用了双师生模型和交叉监督策略, 平均 Dice 和 Jaccard 系数分别提高了 1.35% 和 1.75%. 此外, 使用成对复制粘贴策略, 平均 Dice 和 Jaccard 系数分别提高了 7.59% 和 10.64%, 表现出成对复制策略有效地解决了数据分布不平衡的问题, 进一步提升了模型的鲁棒性. 采用了特征冲突损失, 让模型的平均 Dice 系数达到了 90.23%, 这说明模型学习到了更多的特征,

因此达到了优秀的分割结果. 更重要的是, 每个模块能够协同作用于 CDCL 模型中, 都体现了积极作用.

表3 CDCL 各模块消融实验对照

DMT+CS	PCP	FCL	Dice (%)	Jaccard (%)	95HD (mm)	ASD (mm)
×	×	×	80.4	68.93	9.06	2.73
√	×	×	81.75	70.68	6.12	2.30
√	√	×	89.34	81.32	2.11	0.63
√	√	√	90.23	82.71	2.24	0.58

4 结论与展望

本文提出了一种半监督学习框架——CDCL, 该框架独特地融合了交叉监督与平均教师模型的概念, 显著提升了学习效率和知识的多样性. 此外, 引入特征冲突损失促进了模型间的知识互补, 进一步提升了学习的整体效能. 同时, 还进一步使用了成对复制粘贴 (PCP) 方法, 为模型提供新的训练样本, 提升模型的鲁棒性. 在 ACDC 和 PROMISE12 数据集上的对比实验结果表明, CDCL 模型相较于 UA-MT、DTC、MC-Net、BCP、DiffRect 和 SLC-Net 模型更接近 GT 的分割结果. 消融实验结果再次证明了双师生模型、交叉监督、特征冲突损失和成对复制粘贴的有效性. 虽然, 本研究提出的 CDCL 有着优秀的医学图像分割表现, 但在标记数据集过少时, 模型的能力并未完全体现. 因此, 在后续研究中, 将着重研究在极少标记数据下, 模型能力的进一步提升.

参考文献

- Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation. Proceedings of the 18th International Conference on Medical Image Computing and Computer-assisted Intervention. Munich: Springer, 2015. 234–241.
- Li CX, Fahmy A, Li SX, *et al.* An enhanced robot massage system in smart homes using force sensing and a dynamic movement primitive. *Frontiers in Neurorobotics*, 2020, 14: 30. [doi: [10.3389/fnbot.2020.00030](https://doi.org/10.3389/fnbot.2020.00030)]
- Li CX, Fahmy A, Sienz J. Development of a neural network-based control system for the DLR-HIT II robot hand using leap motion. *IEEE Access*, 2019, 7: 136914–136923. [doi: [10.1109/ACCESS.2019.2942648](https://doi.org/10.1109/ACCESS.2019.2942648)]
- Li CX, Zhu S, Sun ZB, *et al.* BAS optimized ELM for KUKA iiwa robot learning. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 2021, 68(6): 1987–1991.
- Milletari F, Navab N, Ahmadi SA. V-Net: Fully convolutional neural networks for volumetric medical image segmentation. Proceedings of the 4th International Conference on 3D Vision. Stanford: IEEE, 2016. 565–571.
- Tarvainen A, Valpola H. Mean teachers are better role models: Weight-averaged consistency targets improve semi-supervised deep learning results. Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc., 2017. 1195–1204.
- Yu LQ, Wang SJ, Li XM, *et al.* Uncertainty-aware self-ensembling model for semi-supervised 3D left atrium segmentation. Proceedings of the 22nd International Conference on Medical Image Computing and Computer-assisted Intervention. Shenzhen: Springer, 2019. 605–613.
- Li SL, Zhang CY, He XM. Shape-aware semi-supervised 3D semantic segmentation for medical images. Proceedings of the 23rd International Conference on Medical Image Computing and Computer-assisted Intervention. Lima: Springer, 2020. 552–561.
- Wu YC, Xu MF, Ge ZY, *et al.* Semi-supervised left atrium segmentation with mutual consistency training. Proceedings of the 24th International Conference on Medical Image Computing and Computer-assisted Intervention. Strasbourg: Springer, 2021. 297–306.
- Wang XY, Yuan YW, Guo DY, *et al.* SSA-Net: Spatial self-attention network for COVID-19 pneumonia infection segmentation with semi-supervised few-shot learning. *Medical Image Analysis*, 2022, 79: 102459. [doi: [10.1016/j.media.2022.102459](https://doi.org/10.1016/j.media.2022.102459)]
- Lu LY, Yin MX, Fu LY, *et al.* Uncertainty-aware pseudo-label and consistency for semi-supervised medical image segmentation. *Biomedical Signal Processing and Control*, 2023, 79: 104203. [doi: [10.1016/j.bspc.2022.104203](https://doi.org/10.1016/j.bspc.2022.104203)]
- Sohn K, Berthelot D, Li XL, *et al.* FixMatch: Simplifying semi-supervised learning with consistency and confidence. Proceedings of the 34th International Conference on Neural Information Processing Systems. Vancouver: Curran Associates Inc., 2020. 51.
- Zhang BW, Wang YD, Hou WX, *et al.* FlexMatch: Boosting semi-supervised learning with curriculum pseudo labeling. Proceedings of the 35th International Conference on Neural Information Processing Systems. Curran Associates Inc., 2021. 1407.
- Zhang YC, Zhang JC. Dual-task mutual learning for semi-supervised medical image segmentation. Proceedings of the

- 4th Chinese Conference on Pattern Recognition and Computer Vision. Beijing: Springer, 2021. 548–559.
- 15 Luo XD, Hu MH, Song T, *et al.* Semi-supervised medical image segmentation via cross teaching between CNN and Transformer. Proceedings of the 5th International Conference on Medical Imaging with Deep Learning. Zurich: PMLR, 2022. 820–833.
- 16 Zhang HY, Cisse M, Dauphin YN, *et al.* mixup: Beyond empirical risk minimization. arXiv:1710.09412, 2018.
- 17 Yun S, Han D, Oh S J, *et al.* CutMix: Regularization strategy to train strong classifiers with localizable features. Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019. 6023–6032.
- 18 Berthelot D, Carlini N, Goodfellow I, *et al.* MixMatch: A holistic approach to semi-supervised learning. Proceedings of the 33rd International Conference on Neural Information Processing Systems. Vancouver: Curran Associates Inc., 2019. 454.
- 19 Hou SH, Wang ZL. Weighted channel dropout for regularization of deep convolutional neural network. Proceedings of the 33rd AAAI Conference on Artificial Intelligence. Honolulu: AAAI, 2019. 8425–8432.
- 20 Zhao Z, Liu Y, Zhao M, *et al.* Rethinking data perturbation and model stabilization for semi-supervised medical image segmentation. arXiv:2308.11903, 2023.
- 21 Liu JH, Desrosiers C, Yu DX, *et al.* Semi-supervised medical image segmentation using cross-style consistency with shape-aware and local context constraints. IEEE Transactions on Medical Imaging, 2024, 43(4): 1449–1461. [doi: [10.1109/TMI.2023.3338269](https://doi.org/10.1109/TMI.2023.3338269)]
- 22 Wu YC, Wu ZH, Wu QY, *et al.* Exploring smoothness and class-separation for semi-supervised medical image segmentation. Proceedings of the 25th International Conference on Medical Image Computing and Computer-assisted Intervention. Singapore: Springer, 2022. 34–43.
- 23 Bai YH, Chen DW, Li QL, *et al.* Bidirectional copy-paste for semi-supervised medical image segmentation. Proceedings of the 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver: IEEE, 2023. 11514–11524.
- 24 Liu XY, Li WY, Yuan YX. DiffRect: Latent diffusion label rectification for semi-supervised medical image segmentation. Proceedings of the 27th International Conference on Medical Image Computing and Computer-assisted Intervention. Marrakesh: Springer, 2024. 56–66.

(校对责编: 王欣欣)