

半监督医学图像分割

计算机学院（人工智能学院）



Adaptive Bidirectional Displacement for Semi-Supervised Medical Image Segmentation

Hanyang Chi, Jian Pang, Bingfeng Zhang, Weifeng Liu

<https://github.com/Star-chy/ABD>

2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) | 979-8-3503-5300-6/24/\$31.00 ©2024 IEEE | DOI: 10.1109/CVPR52733.2024.00002

Proceedings

2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition
CVPR 2024

Seattle, Washington, USA
16-22 June 2024



Los Alamitos, California
Washington • Tokyo



Adaptive Bidirectional Displacement for Semi-Supervised Medical Image Segmentation

CCF A

Publisher: IEEE

Cite This



Hanyang Chi ; Jian Pang ; Bingfeng Zhang ; Weifeng Liu All Authors

41
Cites in
Papers

439
Full
Text
Views



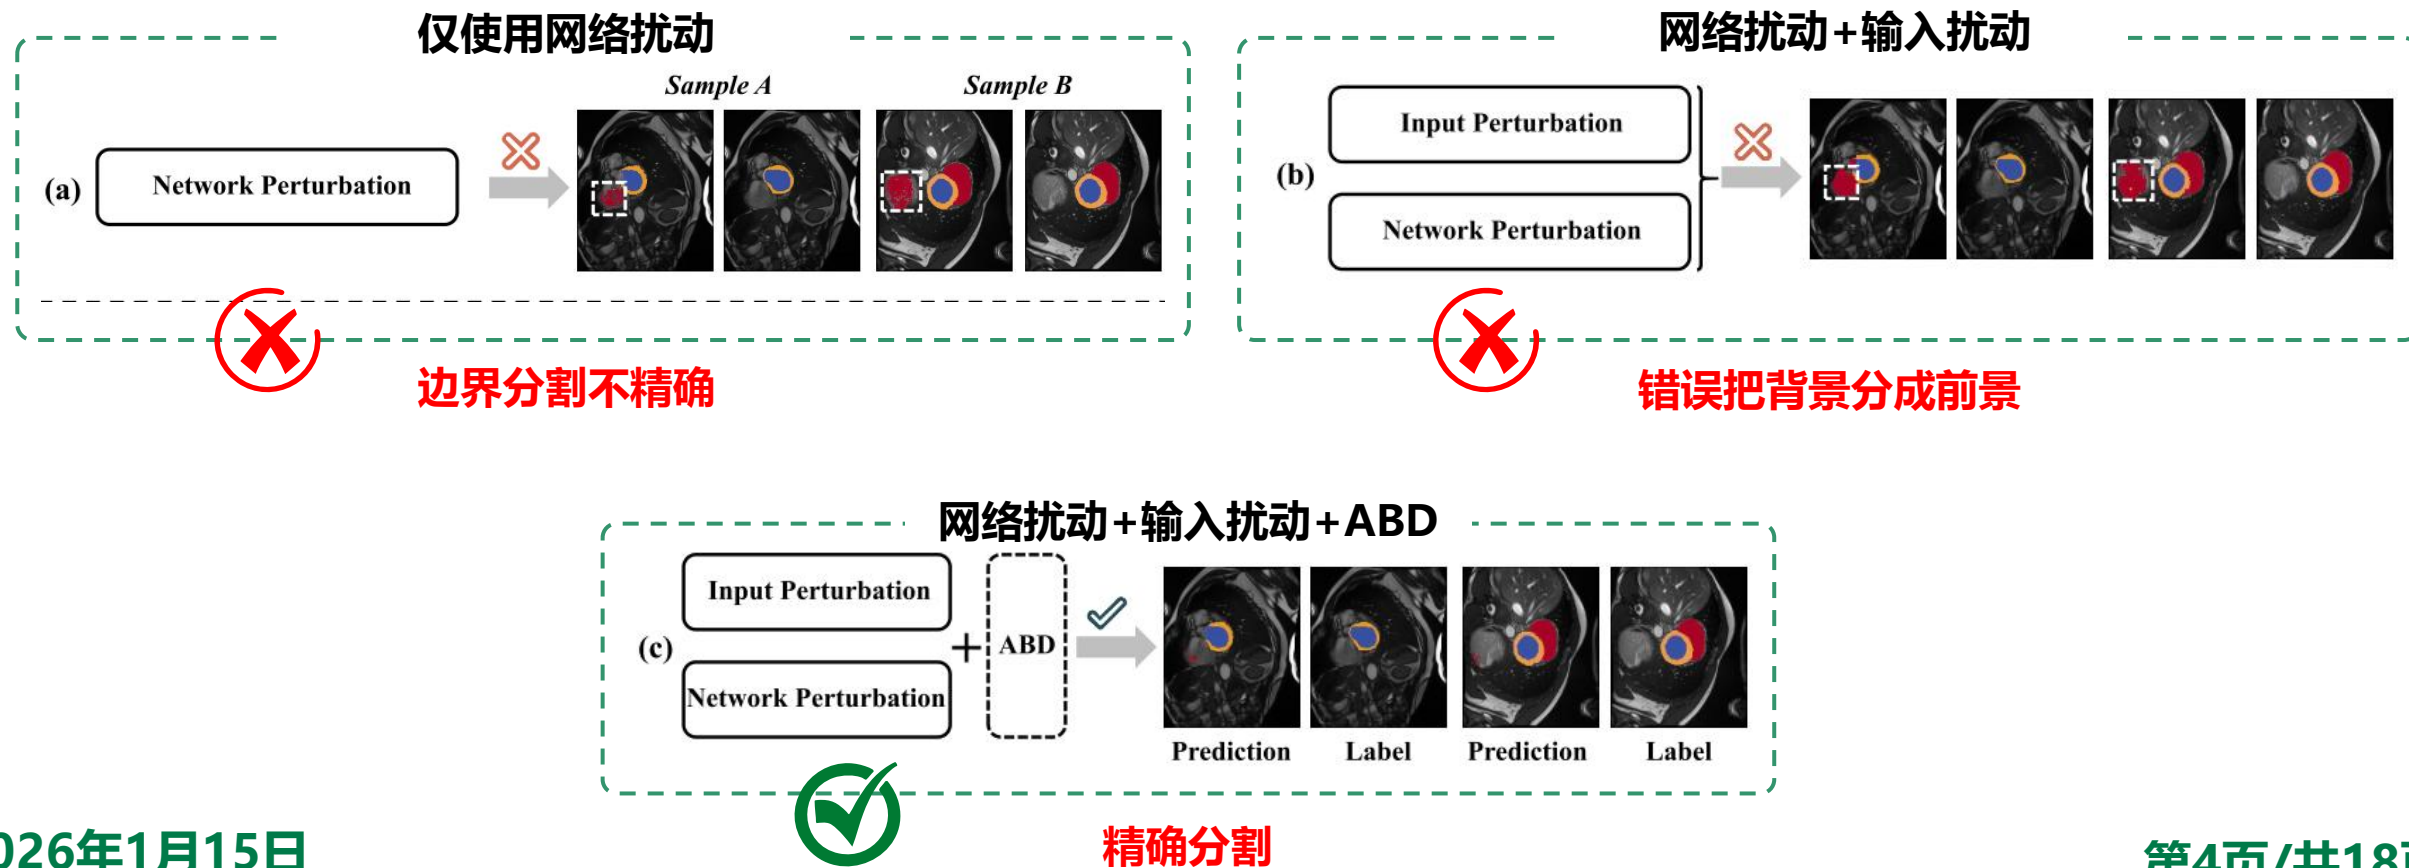
【发表会议】：CVPR

【发表时间】：2024

【分 区】：CCF A

【被引数量】：77

- 由于获取大规模精确标注的医学数据集非常困难，所以提出半督医学图像分割（SSMIS）的方法
- 当前的基于一致性学习的半监督方法仅采用单一扰动（输入/特征/网络扰动）
- 采用多种扰动的方法难以保证学习质量，导致预测不可控

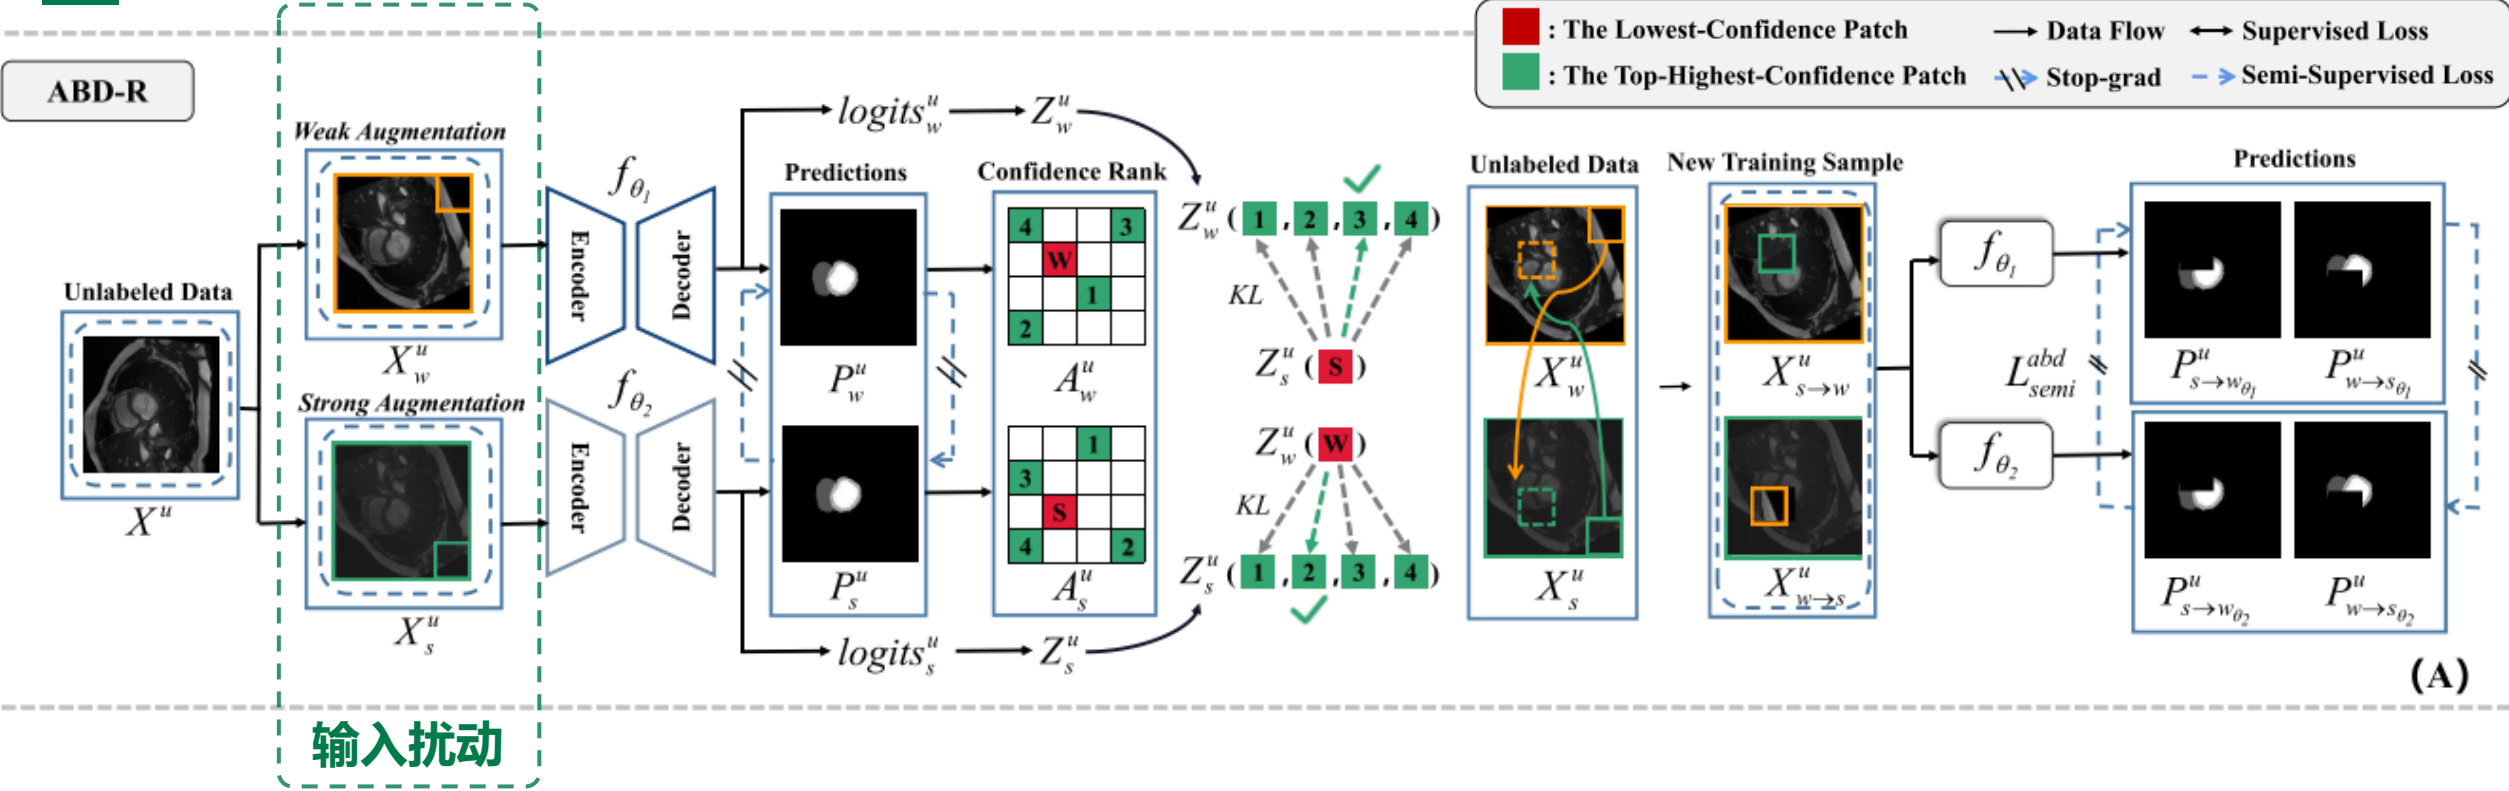


ABD-R: 针对**混合扰动**导致的一致性学习不稳定问题, 设计了基于可靠预测置信度的**双向Patch位移机制**, 通过替换模型不适应区域为可信区域, 提升一致性学习质量

ABD-I: 提出结合**逆置信度**的自适应双向位移策略。通过将**高置信区域**替换为**低置信区域**, 强制模型学习潜在不可控区域, 弥补ABD-R模块对原始区域学习的不足

方法可无缝嵌入现有一致性学习框架 (**Cross Teaching、BCP**), 在多个数据集上实现SOTA的性能

ABD-R



对于未标记的图像，对一幅图像进行弱增强和强增强，得到两幅图像，分别输入到两个网络进行交叉监督；然后，基于 A_w^u 、 Z_w^u 、 A_s^u 和 Z_s^u ，对图像中的Patch块进行双向位移，形成新的样本 $X_{s \rightarrow w}^u$ 和 $X_{w \rightarrow s}^u$ 。这些新样本被进一步送入网络进行交叉监督

ABD-R

数据定义： $D^l = \{(X_i^l, Y_i^l)\}, i = 1, 2, \dots, N,$ $D^u = \{X_i^u\}, i = N + 1, \dots, N + M,$ $N \ll M$

弱增强： $X_w^u \in R^{3 \times H \times W},$ 强增强： $X_s^u \in R^{3 \times H \times W}$

两个子网络的**原始输出**:

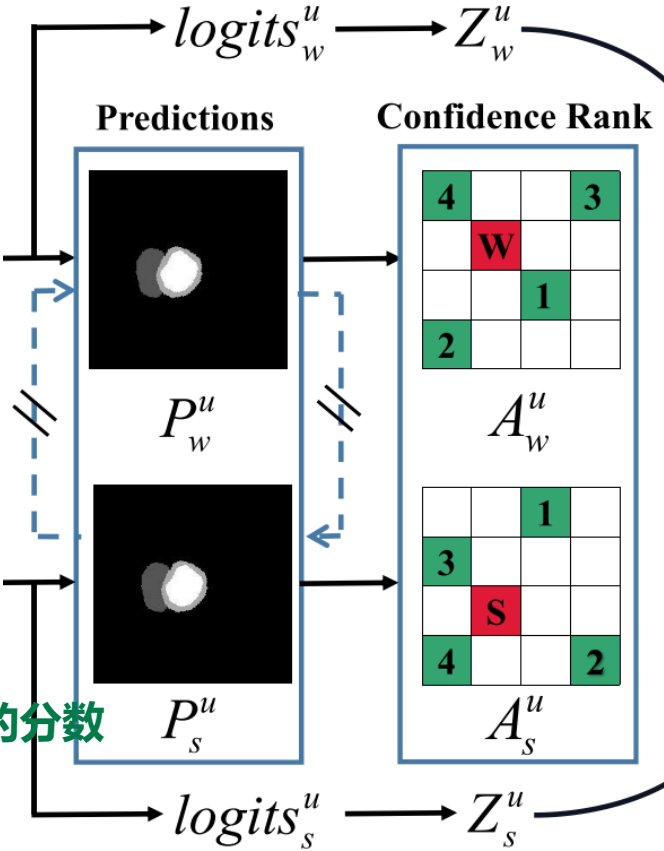
$logits_w^u = f_{\theta_1}(X_w^u), \quad logits_s^u = f_{\theta_2}(X_s^u)$

预测概率输出:

$P_w^u = \text{softmax}(logits_w^u), \quad P_s^u = \text{softmax}(logits_s^u)$

把 X_w^u 分成K个Patch ($K = k \times k$) , 计算 X_w^u 的Patch块得分:

第j个Patch中第m个像素的c类别的分数
表示类别c的第j个Patch的平均分 $Z_{w,c}^{u,j} = \frac{\sum_{m=1}^{k \times k} logits_{w,c}^{u,j}(m)}{|k \times k|}$
Patch的大小



ABD-R

第j个Patch的置信度得分:

Patch中第m个像素出现c类的概率

$$A_w^{u,j} = \frac{\sum_{m=1}^{k \times k} \max_{c \in \mathcal{C}} \left(P_{w,c}^{u,j}(m) \right)}{|k \times k|}$$

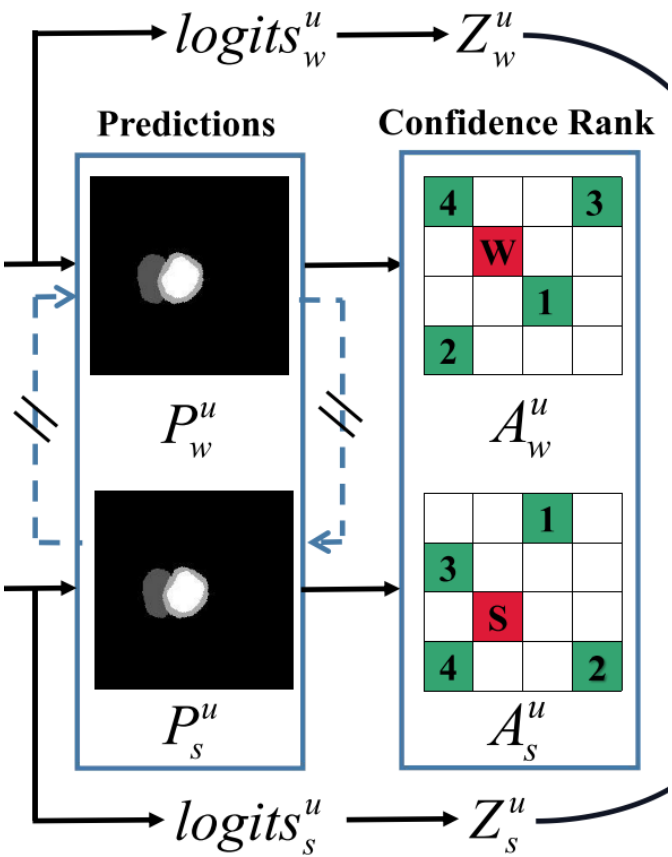
第j个Patch的平均置信度得分

计算 X_w^u 最低置信度的Patch的索引:

$$\text{ind}_{w-\min}^u = \text{argmin}(A_w^{u,j})$$

计算 X_w^u 前n个最高置信度的Patch的索引:

$$\text{Ind}_{w-\text{top}}^u = \{\text{ind}_{w-\max^1}^u, \text{ind}_{w-\max^2}^u, \dots, \text{ind}_{w-\max^n}^u\}$$



ABD-R

计算最后选择的Patch索引:

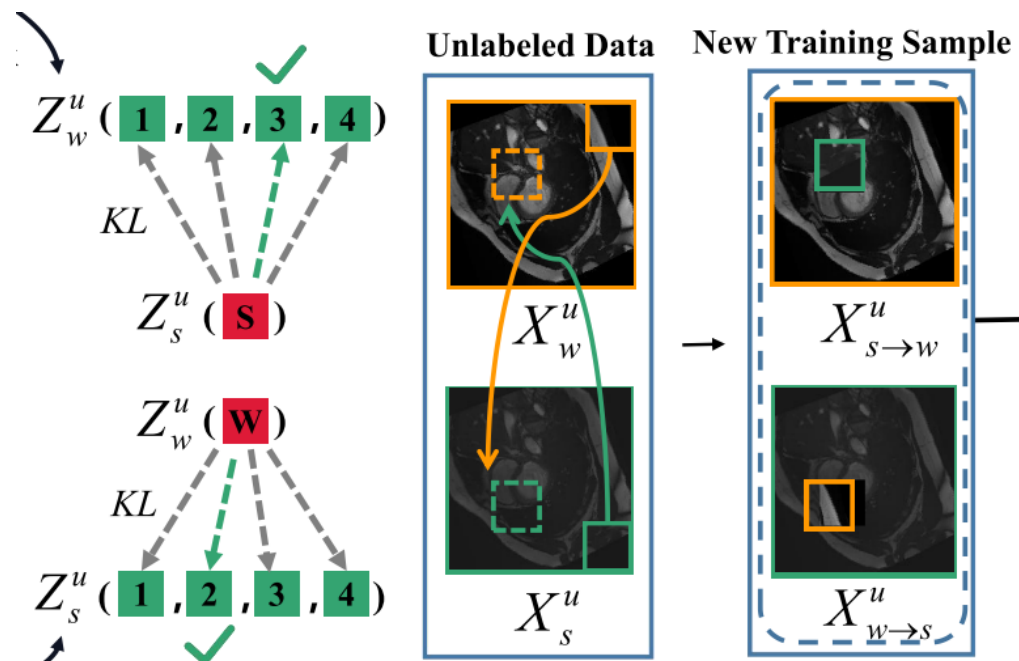
$$\text{ind}_{w \rightarrow \max^s} = \operatorname{argmin} \left(kl_{div} \left(Z_w^{u, \text{ind}_{w \rightarrow \max^s}^u}, Z_s^{u, \text{ind}_{s \rightarrow \min}^u} \right) \right)$$

$$\text{ind}_{s \rightarrow \max^s} = \operatorname{argmin} \left(kl_{div} \left(Z_s^{u, \text{ind}_{s \rightarrow \max^s}^u}, Z_w^{u, \text{ind}_{w \rightarrow \min}^u} \right) \right)$$

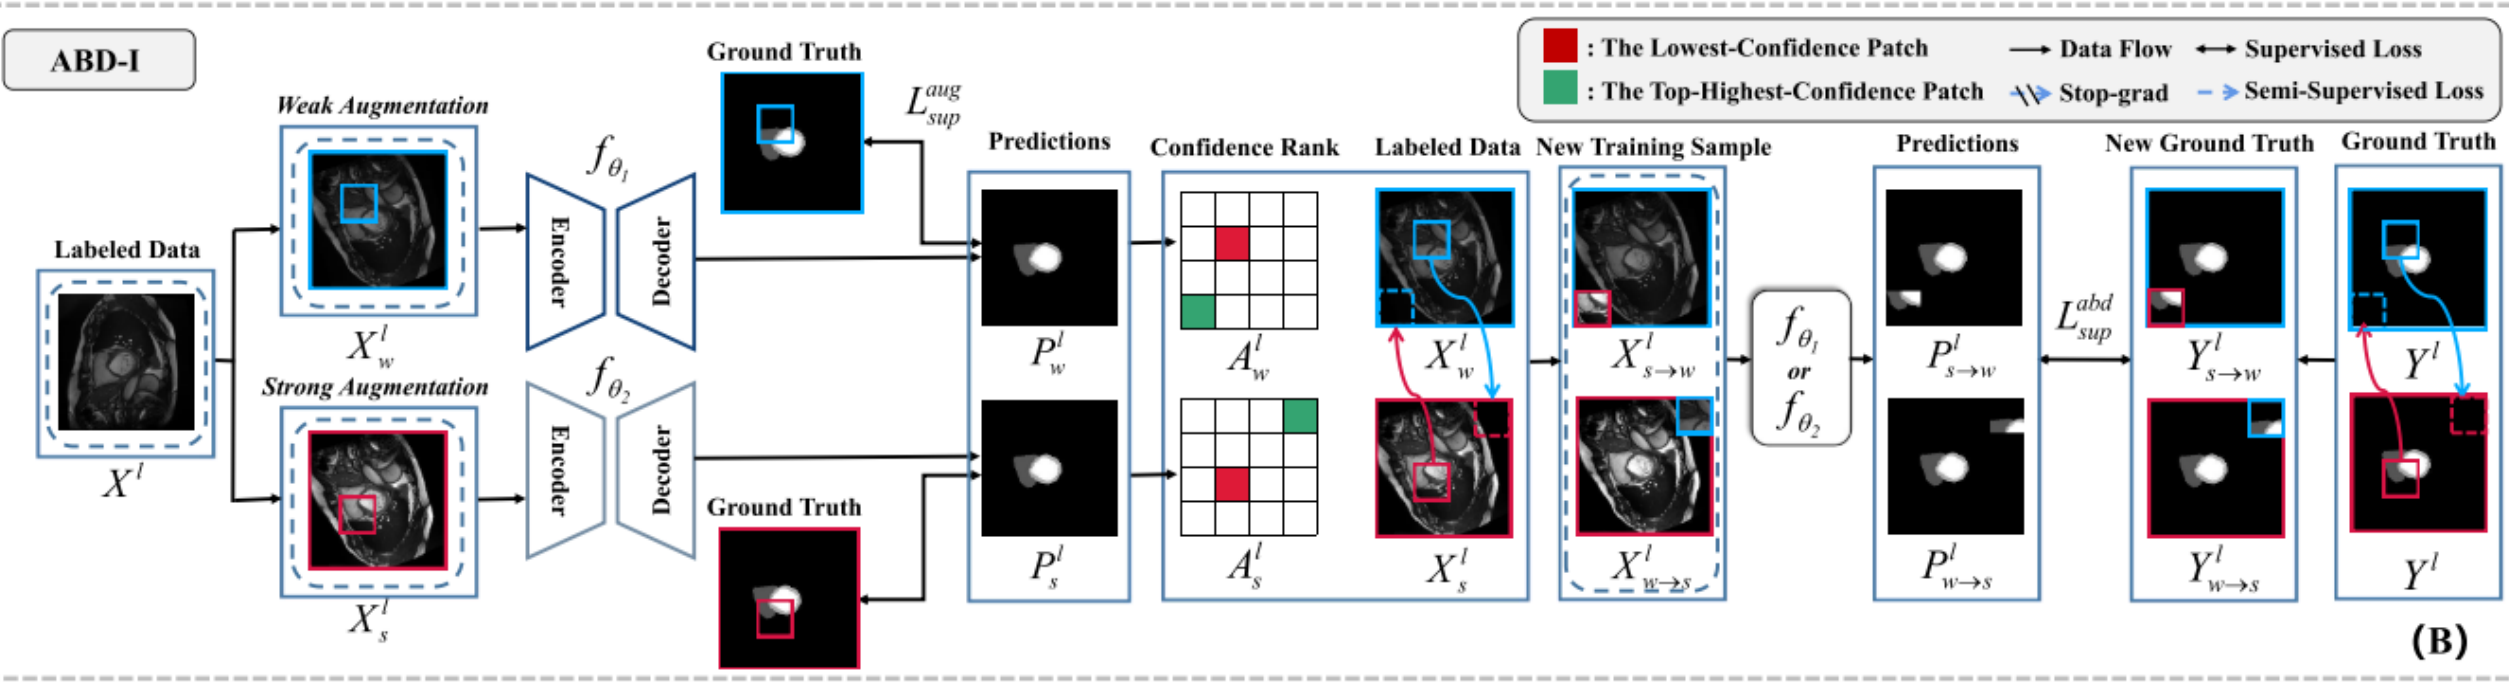
计算从增强图像中选择的Patch索引:

$$X_{s \rightarrow w}^{u,j} = \begin{cases} X_s^{u, \text{ind}_{s \rightarrow \max^s}^u}, & \text{if } j = \text{ind}_{w \rightarrow \min}^u \\ X_w^{u,j}, & \text{else} \end{cases}$$

$$X_{w \rightarrow s}^{u,j} = \begin{cases} X_w^{u, \text{ind}_{w \rightarrow \max^s}^u}, & \text{if } j = \text{ind}_{s \rightarrow \min}^u \\ X_s^{u,j}, & \text{else} \end{cases}$$



ABD-I



对于**标记的图像**，它们也经过弱增强和强增强的处理，并且它们的预测由标签监督，数据和GT都经过双向位移，得到新的数据 $X_{s \rightarrow w}^l$, $X_{w \rightarrow s}^l$ 和Ground Truth $Y_{s \rightarrow w}^l$, $Y_{w \rightarrow s}^l$




Loss Functions

整体损失函数由两部分组成，标记数据的**监督损失** L_{sup} 和未标记数据的**无监督损失** L_{semi} ：

$$L = \mathcal{L}_{sup} + \lambda \mathcal{L}_{semi} = (\mathcal{L}_{sup}^{aug} + \mathcal{L}_{sup}^{abd}) + \lambda (\mathcal{L}_{semi}^{aug} + \mathcal{L}_{semi}^{abd})$$

数据集和评估指标




ACDC 心脏分割数据集¹

评估
指标

Dice 相似性系数(DSC), Jaccard,
95HD和ASD

¹https://drive.google.com/drive/folders/1_cOBDNIMYjNGCJFzbmWXXGPj2vvKESE



PROMISE12前列腺分割数据集²

评估
指标

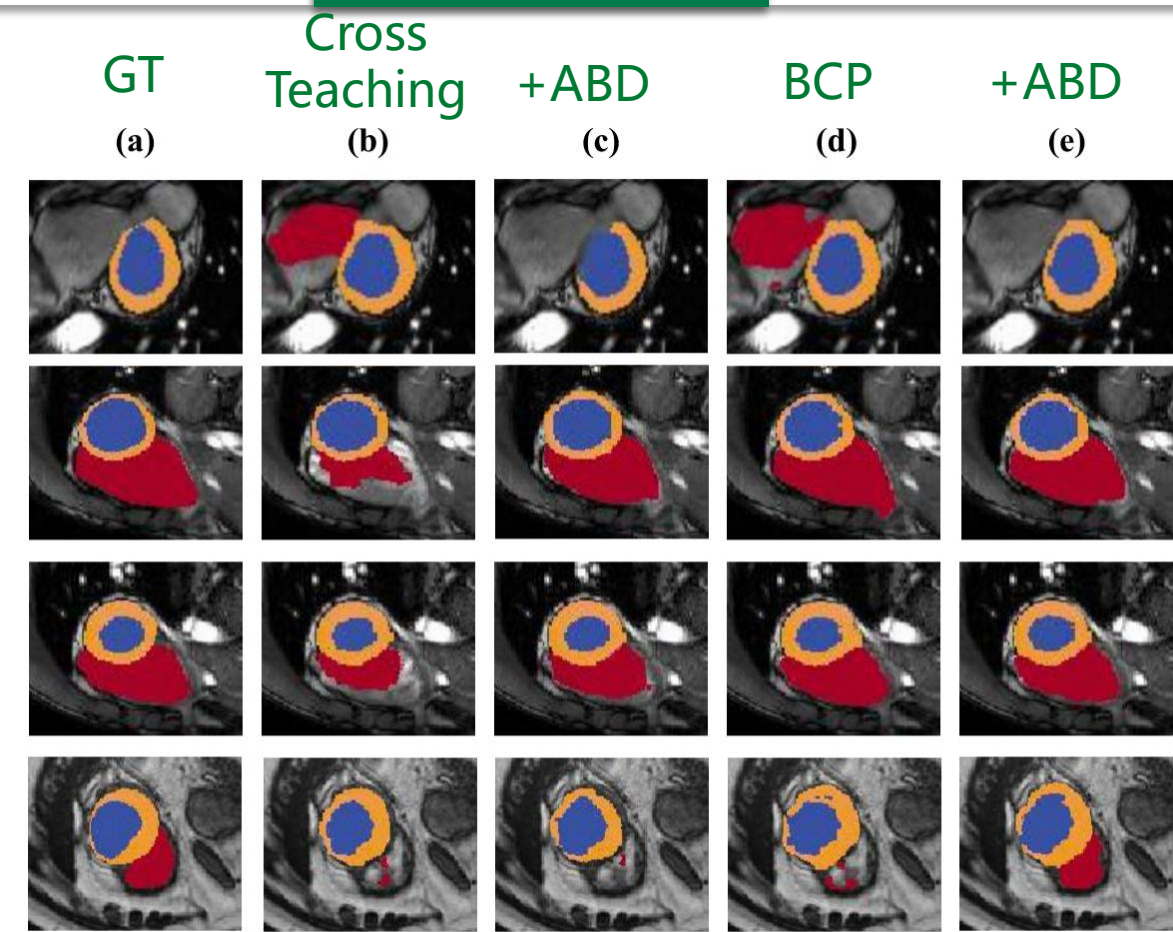
Dice 相似性系数(DSC)和ASD

²<https://zenodo.org/records/8026660>

对比实验结果分析

Method	Scans used		Metrics			
	Labeled	Unlabeled	DSC↑	Jaccard↑	95HD↓	ASD↓
U-Net (MICCAI'2015) [27]	3(5%)	0	47.83	37.01	31.16	12.62
	7(10%)	0	79.41	68.11	9.35	2.70
	70(All)	0	91.44	84.59	4.30	0.99
DTC (AAAI'2021) [21]	3(5%)	67(95%)	56.90	45.67	23.36	7.39
URPC (MICCAI'2021) [22]			55.87	44.64	13.60	3.74
MC-Net (MICCAI'2021) [36]			62.85	52.29	7.62	2.33
SS-Net (MICCAI'2022) [37]			65.83	55.38	6.67	2.28
SCP-Net (MICCAI'2023) [44]			87.27	-	-	2.65
Cross Teaching (Reported) (MIDL'2022) [23]			65.60	-	16.2	-
BCP (CVPR'2023) [2]			87.59	78.67	1.90	0.67
Ours-ABD (Cross Teaching)			86.35	76.73	4.12	1.22
Ours-ABD (BCP)			88.96	80.70	1.57	0.52
DTC (AAAI'2021) [21]	7(10%)	63(90%)	84.29	73.92	12.81	4.01
URPC (MICCAI'2021) [22]			83.10	72.41	4.84	1.53
MC-Net (MICCAI'2021) [36]			86.44	77.04	5.50	1.84
SS-Net (MICCAI'2022) [37]			86.78	77.67	6.07	1.40
SCP-Net (MICCAI'2023) [44]			89.69	-	-	0.73
PLGCL (CVPR'2023) [3]			89.1	-	4.98	1.80
Cross Teaching (Reported) (MIDL'2022) [23]			86.40	-	8.60	-
Cross Teaching (Reproduced)			86.45	77.02	6.30	1.86
BCP (CVPR'2023) [2]			88.84	80.62	3.98	1.17
Ours-ABD (Cross Teaching)			88.52	79.97	5.06	1.43
Ours-ABD (BCP)			89.81	81.95	1.46	0.49

在ACDC 数据集上的定量实验



在ACDC 数据集上的定性实验


结果分析

在Cross Teaching和BCP中，ABD的表现最好

对比实验结果分析

结果分析

在所有的对比方法中，ABD的表现最好



Method	Scans used		Metrics	
	Labeled	Unlabeled	DSC↑	ASD↓
U-Net [27]	7(20%)	0	60.88	13.87
	35(100%)	0	84.76	1.58
CCT [25]	7(20%)	28(80%)	71.43	16.61
URPC [22]			63.23	4.33
SS-Net [37]			62.31	4.36
SLC-Net [20]			68.31	4.69
SCP-Net [44]			77.06	3.52
Ours-ABD			82.06	1.33
Ours-ABD	3(10%)	32(90%)	81.81	1.46

在PROMISE12 数据集上的定量实验

消融实验结果分析

Base	IP	ABD-R	ABD-I	DSC↑	Jaccard↑	95HD↓	ASD↓
✓				86.45	77.02	6.30	1.86
✓	✓			86.25	76.69	5.44	1.72
✓	✓	✓		87.42	78.37	5.23	1.68
✓	✓		✓	87.20	78.07	6.06	1.96
✓	✓	✓	✓	88.52	79.97	5.06	1.43

ABD-R和ABD-I模块的有效性，IP: 输入添加扰动

Strategy	DSC↑	Jaccard↑	95HD↓	ASD↓
Random	86.55	77.07	6.13	1.74
Same	87.22	78.04	5.61	1.50
Same+Reliable	87.38	78.06	4.56	1.69
Reliable	87.42	78.37	5.23	1.68

位移策略的消融实验

结果分析

在添加输入扰动和使用ABD策略时，整体性能最佳；
同时利用可靠区域的位移策略时效果最好

消融实验结果分析

K	DSC↑	Jaccard↑	95HD ↓	ASD ↓
4	87.39	78.35	5.06	1.69
16	88.52	79.97	5.06	1.43
64	87.54	78.57	5.52	1.88

Patch块的划分数量K的消融实验

剪切	抖动	模糊	DSC↑	Jaccard↑	95HD↓	ASD↓
Cutout	Colorjitter	Blur				
✓			88.23	79.53	5.90	1.40
	✓		88.03	79.34	7.15	1.76
		✓	87.76	78.76	7.28	1.61
✓	✓		88.52	79.97	5.06	1.43
✓	✓	✓	87.83	79.02	6.14	1.87

输入数据增强的消融实验

结果分析

当K=16时，ABD的效果达到最佳；当使用剪切和抖动的数据增强时，整体效果最好



提出ADB-R

针对无标记图像，基于**可靠预测置信度**执行双向Patch位移，生成新样本以减少不可控区域，并保留输入扰动的影响，有效捕获输入扰动的语义信息。



提出ADB-I

针对有标记图像，采用**逆置信度**进行双向位移操作，生成包含更多不可靠信息的样本，强制模型学习潜在的不可控区域。

谢谢大家！

计算机学院（人工智能学院）