面向半监督血管分割的深度学习方法

谢怡宁[1]， 阙楠双[2]， 龙 俊[1]， 张宇航[2]， 陈 宇[2]， 郝 明[3]， 谢永华[2]
（1. 东北林业大学 机电工程学院，哈尔滨 150040；2. 东北林业大学 计算机与控制工程学院，哈尔滨 150040；
3. 哈尔滨医科大学附属第一医院 内分泌科，哈尔滨 150001）

摘 要：视网膜眼底血管分割技术对诊断及预防糖尿病与视网膜疾病具有重要意义。然而，血管的像素级标注非常耗时且成本昂贵，在有限标记数据的情况下，血管分割仍然是一项具有挑战性的任务。为了解决以上问题，提出了双重不确定性引导的动态竞争协同训练师生框架（dual uncertainty-guided dynamic-competitive collaborative mean teacher framework，DU-DCMT）用于半监督血管分割。该框架利用双重不确定性区域处理模块（dual uncertainty region-processing module，DURM）扩大数据分布，同时提高伪标签的置信度，引导网络注意并纠正自身潜在的易错区域。此外，通过动态竞争教师模型，选择高质量伪标签生成器，在网络间联合训练，保留网络差异，以便获得更好的分割性能。实验结果表明：该方法在标注比例为0.2的情况下，DRIVE数据集上的灵敏度和准确率分别为0.817 3、0.967 3，STARE数据集上分别为0.768 2、0.978 3。因此，DU-DCMT可有效缓解数据标签稀缺问题，且分割性能均优于当前方法。

关键词：血管分割；半监督学习；双重不确定性引导；动态竞争协同训练；均值教师模型
DOI：10.15938/j.jhust.2026.04.006
中图分类号：TP315.69 **文献标志码**：A **文章编号**：1007-2683(2026)04-0056-13

Deep Learning Method for Semi-supervised Vessel Segmentation

XIE Yining[1]， QUE Nanshuang[2]， LONG Jun[1]， ZHANG Yuhang[2]，
CHEN Yu[2]， HAO Ming[3]， XIE Yonghua[2]
（1. College of Mechanical and Electrical Engineering，Northeast Forestry University，Harbin 150040，China；
2. College of Computer and Control Engineering，Northeast Forestry University，Harbin 150040，China；
3. Department of Endocrinology，The First Affiliated Hospital of Harbin Medical University，Harbin 150001，China）

Abstract：Retinal fundus vessel segmentation technology is of great significance for the diagnosis and prevention of diabetes and retinal diseases. However，pixel-level annotation of blood vessels is very time-consuming and costly. In the case of limited labeled data，blood vessel segmentation remains a challenging task. To address the above problems，this paper proposes a Dual Uncertainty-guided Dynamic-competitive Collaborative Mean Teacher framework （DU-DCMT） for semi-supervised vessel segmentation. The framework utilizes a Dual Uncertainty Region-processing Module （DURM） to expand data distribution，enhance the confidence of pseudo-labels，and guide network attention to correct potential error-prone regions. Additionally，a dynamic competitive teacher model is designed to select high-quality pseudo-label generators，jointly train networks，and preserve network diversity for better segmentation performance. Experimental results show that when the labeling ratio is 0.2，the sensitivity and accuracy of this method on the DRIVE dataset are 0.817 3 and 0.967 3 respectively，and on the STARE dataset are 0.768 2 and 0.978 3 respectively. Therefore，DU-DCMT effectively alleviates the problem of data label scarcity，and its segmentation performance outperforms current state-of-the-art methods.

Keywords：vessel segmentation；semi-supervised learning；dual uncertainty-guided；dynamic-competitive collaborative learning；mean teacher model

收稿日期：2024-11-04
基金项目：黑龙江省重点研发计划（2024ZXDXC30，2022ZX06C09）；哈尔滨市科技局制造业创新人才项目（CXRC20221110393）；黑龙江省科技厅省重点研发计划应用研究项目（SC2022ZX06C0025）；黑龙江省科技厅省重点研发计划指导项目（GZ20220088）.
作者简介：阙楠双（2001—），女，硕士研究生；
龙 俊（1996—），男，博士研究生.
通信作者：谢怡宁（1979—），女，博士，教授，博士研究生导师，E-mail：yiningxie@nefu.edu.cn.

0　引　言

医学图像分割对于医学图像分析至关重要,旨在为图像的每个像素分配 1 个来自一组类别的标签[1]。基于深度学习的分割模型在大量标记数据的支持下取得了巨大进展[2-3]。在各种医学图像模态中,视网膜血管图像包含丰富的病理变化相关信息。因此,血管分析对糖尿病及眼部疾病的早期诊断至关重要[4],同时在不同临床领域中也起着基础作用[5]。

全卷积网络(fully convolutional network,FCN)是将深度学习应用于该任务并取得巨大成功的开端[6],该网络可以接受任意大小的输入。然而,FCN 参数量、计算量较大,降低了模型计算效率。为了解决这一问题,文[7]提出了新的分割网络 SegNet。在特征上采样过程中,SegNet 复制最大池化层的索引,减少模型参数,提高训练效率。文[8]提出了用于高精度医学图像分割的 U-Net 网络,该网络由 1 个具有跳跃连接的对称编码器 - 解码器组成,性能优越,是医学图像分割领域的里程碑。近年来,受 U-Net 网络的启发,有许多基于 U-Net 的改进方案被相继提出:JIN 等[9]提出了端到端的可变形 DUNet(deformable U-Net,DUNet),根据血管的尺度和形状自适应调整感受野,并结合低级特征和高级特征实现精准定位,从而捕获各种形状和尺度的视网膜血管。为了进一步自适应地结合眼底图像的局部特征与全局依赖性,MOU 等[10]在编码器和解码器之间引入了由空间注意和通道注意组成的双重自注意力机制。

但由于像素级别的标注通常耗时且费力,导致标记数据获取困难。在这种情况下,半监督学习(semi-supervised learning,SSL)已成为主导的数据高效策略,利用有限数量的标记数据和任意数量的未标记数据的信息,缓解标签稀缺问题[11-13]。伪标签方法是半监督学习中的经典实践,其关键在于如何生成可靠的伪标签。LEE[14]首先提出伪标签这一方法的应用,通过固定阈值区分未标记样本的置信度,并进行伪标记。LI 等[15]采用了新的伪标签生成方法,通过集成多个模型得到不确定性估计的近似值,作为未标记图像的基准值。为了提高伪标签的质量,YAO 等[16]提出了新的置信度感知的交叉伪监督算法。该算法通过测量伪标签的方差来正则化网络,以选择更可信的伪标签。QIU 等[17]提出了用于半监督医学图像的双重不确定性引导多模型伪标签学习框架(dual uncertainty-guided multi-model,DUMM),该框架利用基于像素级不确定性的多模型伪标签生成模块,旨在获得高质量伪标签。

另一种主流的半监督方法是一致性正则化,代表性方法之一是均值教师模型(mean teacher,MT)[18],由 1 个利用梯度传播更新参数的学生网络和 1 个通过指数移动平均(exponential moving average,EMA)更新参数的教师网络组成。MT 通过对扰动样本进行一致性预测来执行标签传播。之后,受 MT 启发,WANG 等[19]将多任务学习引入 MT 框架,并利用三重不确定性引导学生模型从教师模型中学到更可靠的预测。CHEN 等[20]提出了具有密集焦距损失的不确定性教师模型,可充分利用未标记数据并解决类别不平衡的问题。WANG 等[21]提出了正则化驱动的均值教师模型,通过虚拟对抗训练来提高分割性能,并增强平均教师模型的鲁棒性。

目前,子网络之间的交叉监督将一致性正则化与伪标签相结合,在半监督分割中显示出了良好的性能[22-23]。这些方法存在如下限制:①子网络往往会早期收敛到共识状态,导致协同训练模型退化为自我训练。②由于输入扰动,网络易产生低置信度的伪标签。③基于一致性的伪标签生成方法使得网络更容易陷入认知偏见,难以纠正预测错误的区域。并且由于血管大小、形状和强度随局部区域的变化而变化,迫使分割模型学习血管复杂的结构[24]。因此,半监督血管分割任务对模型的训练过程及伪标签的质量都提出了更高的要求。

针对上述问题,本文提出了双重不确定性引导的动态竞争协同均值教师框架(DU-DCMT),旨在同时提高协同训练网络之间的不一致性和伪标签的质量,更好地实现眼底血管图像分割。

DU-DCMT 主要由两部分组成:基于动态竞争的协同均值教师(dynamic-competitive collaborative mean teacher,DCMT)和双重不确定性区域处理模块(DURM)。DCMT 引入第 3 个网络到协同训练架构中,通过动态评估分割性能,实时选择教师网络,实现更可靠的标签传播和更有效的半监督学习。

DURM 首先专注于 3 个网络不一致的预测区域并进行评审训练,接着执行不确定性引导的区域混合(uncertainty-guided region mix,URM)生成新样本,扩大数据分布,进一步进行网络协同训练。

本文主要贡献包括:

1)设计了双重不确定性引导的动态竞争协同均值教师框架,用于缓解半监督血管分割中数据标注稀缺的问题。

2)提出了 DCMT 结构,该结构提高了协同训练子网络之间的不一致性,并结合集成学习思想,实现更可靠的伪标签传播,从而得到更精细的血管分割结果。

3)提出 DURM 模块,用于引导网络注意并纠正自身潜在的易错区域,扩大训练数据分布,鼓励分割网络生成高置信度的伪标签,提高网络对血管真阳性预测的灵敏度。

1 具体实验

1.1 整体框架

本文提出的框架如图 1 所示,DU-DCMT 引入了 3 个结构相同的网络,分别表示为 $f(.;\theta_A)$,$f(.;\theta_B)$,$f(.;\theta_C)$。在半监督学习场景中,训练集 D_S 包含标记样本 $D_l=\{(x_{l,i},y_i)\mid i=1,\cdots,n\}$ 和未标记样本 $D_u=\{(x_{ul,j})\mid j=n+1,\cdots,m\}$。其中 $x_{l,i}$,$x_{ul,j}$ 分别为第 i 张标记图像和第 j 张未标记图像,y_i 为标记图像的标签图像,D_S 分别作为 3 个网络的输入。该框架由 3 个子网络组成,动态竞争教师选择模块首先选择 1 个网络作为教师 $f(.;\theta)$,其余 2 个作为学生 $f(.;\theta_1)$ 和 $f(.;\theta_2)$。监督损失 L_s 包括标记数据的 L_{dice} 和 L_{att},而无监督损失 L_u 包括未标记数据的 L_{cps} 和 L_{ds}。在 URM 构建每个新样本 $x_{l,i'}$ 和 $x_{ul,j'}$ 后,网络将重新训练。

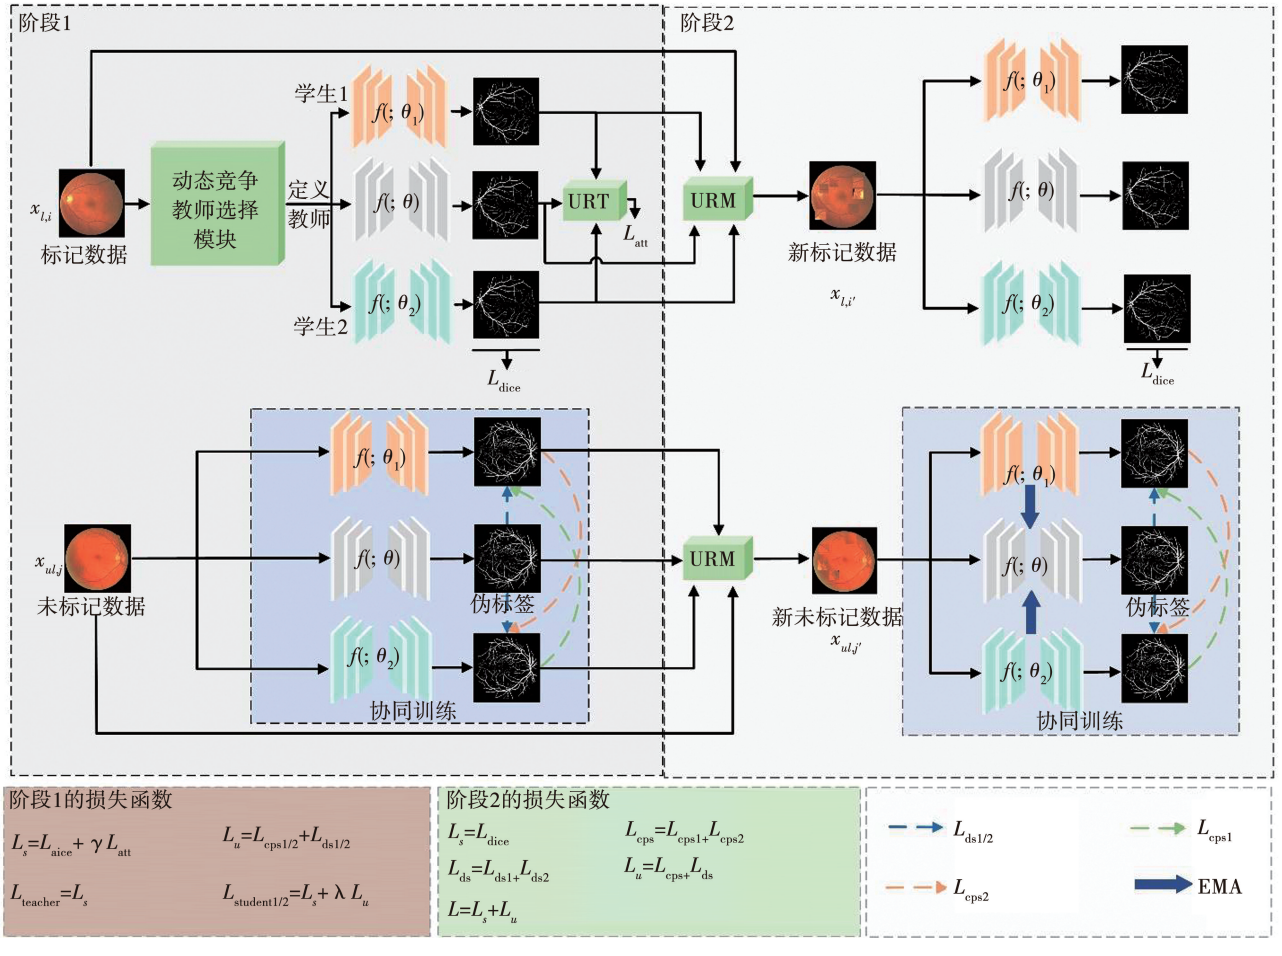

图 1 DU-DCMT 总体框架

Fig. 1 Overview framework of DU-DCMT

DU-DCMT 实现过程分为 2 个阶段。

1)第 1 阶段

利用标记数据 D_l 和未标记数据 D_u 训练 DCMT。首先,在有标签训练过程中利用 Dice 损失评估模型性能,为网络在后续的无监督训练及第 2 阶段训练确定教师、学生 1 和 2 的角色提供基础条件。其次,对于 D_u,模型进行协同均值教师训练。第 1 阶段网络参数独立更新,网络损失函数包括有监督损失和无监督损失。有监督损失 L_s 包括 Dice 损失 L_{s1}及注意力损失 L_{att},注意力损失用于潜在的错误预测纠正。无监督损失由教师对学生的直接监督损失和 2 个学生之间的交叉伪监督损失组成。

2)第 2 阶段

对数据集 D_S 及 DCMT 输出的预测结果图执行 URM,生成新的样本,接着重新对模型进行训练。此时,教师模型参数不再独立更新,为学生模型均值的自集合。具体来说,教师模型参数 θ 通过学生模型参数 θ_1、θ_2 平均值的指数移动平均(EMA)更新:$\theta_t = \alpha\theta_{t-1} + (1-\alpha)[\beta\theta_{1t} + (1-\beta)\theta_{2t}]$,其中 t 为当前训练迭代次数,α 为 EMA 衰减率,用于控制参数更新速率,β 为加权系数。网络损失中有监督损失为 Dice 损失,无监督损失定义不变。

1.2　基于动态竞争的协同均值教师框架

DCMT 的实现细节如算法 1 所示。本文设计了基于动态竞争的协同均值教师框架。受到用于应对早期收敛到共识状态并陷入自我训练的协同教师[23]的启发,本文在框架中引入第 3 个网络。该框架通过动态竞争教师选择模块选择高质量伪标签生成器。此外,在网络间引入协同训练,加强网络互相学习,提升训练效果。

算法 1　DCMT 算法

输入:标记数据:$D_l = \{(x_{l,i}, y_i) \mid i = 1, \cdots, n\}$,未标记数据:$D_u = \{(x_{ul,j}) \mid j = n+1, \cdots, m\}$; 网络参数:$\theta_A$、$\theta_B$、$\theta_C$;超参数:总训练轮数 Num epochs;循环变量:当前轮次 loop。

输出:$f(.;\theta_A)$,$f(.;\theta_B)$,$f(.;\theta_C)$.

for loop = 1 to Num epochs do
　监督训练过程:定义教师网络
　$\hat{y}_{iA} \leftarrow f(x_{l,i};\theta_A)$,$\hat{y}_{iB} \leftarrow f(x_{l,i};\theta_B)$,$\hat{y}_{iC} \leftarrow f(x_{l,i};\theta_C)$
　　if $L_{s1}(\hat{y}_{iA}, y_i)$ is minimum
　　$f(.;\theta_A)$ = teacher
　　else if $L_{s1}(\hat{y}_{iB}, y_i)$ is minimum
　　$f(.;\theta_B)$ = teacher
　　else
　　$f(.;\theta_C)$ = teacher
　无监督训练过程:协同训练
　　$L_t \leftarrow L_s(f(x_{l,i};\theta), y_i)$
　　$L_{1/2} \leftarrow L_s(f(x_{l,i};\theta_{1/2}), y_i) +$
　　$\lambda(\text{loop}) L_u(f(x_{ul,j};\theta), f(x_{ul,j};\theta_1), f(x_{ul,j};\theta_2))$
　利用优化器更新 $f(.;\theta)$,$f(.;\theta_1)$,$f(.;\theta_2)$
end for
return $f(.;\theta_A)$,$f(.;\theta_B)$,$f(.;\theta_C)$

DCMT 中的 3 个网络分别为 $f(.;\theta_A)$,$f(.;\theta_B)$,$f(.;\theta_C)$,网络结构相同,但为了鼓励网络分歧,初始化了不同的权重。

在监督学习过程中,以 D_l 作为 3 个网络的输入,得到预测结果:

$$\hat{y}_{iA/B/C} = f(x_{l,i};\theta_{A/B/C}) \tag{1}$$

本文以 Dice 损失为标准,实时衡量网络对 D_l 的分割性能,并选择性能最好的网络作为教师网络,具体流程如图 2 所示。

为方便后文理解,我们将确定后的教师网络表示为 $f(.;\theta)$,将其余 2 个学生网络分别表示为 $f(.;\theta_1)$,$f(.;\theta_2)$。

对于 D_u,网络训练方式为协同均值教师训练。协同均值教师训练损失由 2 个学生网络之间的交叉伪监督 L_{cps}和教师对学生网络的直接监督 L_{ds}组成。

1)交叉伪监督

L_{cps}旨在促进 2 个学生相互学习,加强两者之间的一致性。L_{cps}定义如下:

$$L_{\text{cps}} = L_{\text{cps1}} + L_{\text{cps2}} \tag{2}$$

L_{cps1}为学生网络 1 受学生网络 2 伪监督计算得到的损失,L_{cps2}同理。L_{cps1}和 L_{cps2}的损失定义如下:

$$L_{\text{cps1/2}} = \frac{1}{m-n}\sum_{j=1}^{m-n}\{\alpha_{\text{Dice}}(\hat{y}_{j1/2}, \hat{y}_{j2/1})\} \tag{3}$$

式中:$\hat{y}_{j1}$和 $\hat{y}_{j2}$分别为 $f(.;\theta_1)$和 $f(.;\theta_2)$预测 $x_{ul,j}$的伪分割结果;α_{Dice}为损失函数。

2)直接监督

为了避免 2 个学生在错误的方向上进行共同训练,本文还引入了教师网络对学生网络的直接监督优化。

直接监督的损失为 $L_{\text{ds}} = L_{\text{ds1}} + L_{\text{ds2}}$,$L_{\text{ds1/2}}$分别为教师网络对相应学生网络的直接监督,具体计算方

式如下：

$$L_{\mathrm{ds1/2}}=\frac{1}{m-n}\sum_{j=1}^{m-n}\{\alpha_{\mathrm{Dice}}(\hat{y}_{j1/2},\hat{y}_{j0})\} \tag{4}$$

式中：$\hat{y}_{j0}$为由教师网络训练得到的分割图。3 个子网络$f(.;\theta_A)$、$f(.;\theta_B)$和$f(.;\theta_C)$分别对标记图像$x_{l,i'}$进行分割，其中 Dice 损失最小的网络被定义为教师网络，其余网络则作为学生网络。

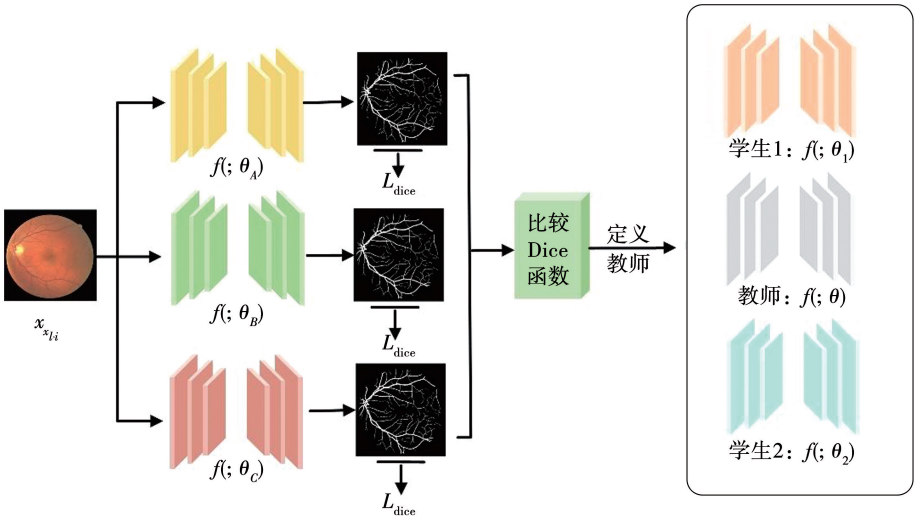

图 2 动态竞争教师选择模块示意图

Fig. 2 Dynamic competitive teacher selection module diagram

1.3 双重不确定性区域处理模块

双重不确定性区域处理模块主要由两部分构成：①不确定性区域评审训练（uncertainty-region review training，URT）：在有监督训练过程中，专注 3 个网络不一致的预测区域，对该不确定性区域进行评审训练；②不确定性引导的区域混合（URM）：为了在有监督训练过程中扩大训练数据分布，在无监督训练中提高伪标签的置信度，URM 将输入图像中最不确定（低置信度）的区域替换为最确定（高置信度）的区域来构建新样本图像，其中不确定性映射通过整合教师模型和学生模型的输出来获得。

1）URT

由于血管分割隶属于二元分类问题，如果 3 个分类器对同一像素有不同的预测，那么其中必有分类器预测错误。因此，我们将预测不一致区域视为预测易错区域，让网络审查该区域，并加强对其的注意力。

将 3 个分类器的预测结果经二值化处理，并取其交集的补集，得到潜在误测区域掩码 R_{diff}，其形式如下：

$$R_{\mathrm{diff}}=\sim[\mathrm{BINA}(\hat{y}_{iA})\cap\mathrm{BINA}(\hat{y}_{iB})\cap\mathrm{BINA}(\hat{y}_{iC})] \tag{5}$$

式中：BINA（）为二值化操作；~为按位取反操作。

潜在的错误预测区域 $\hat{y}_{\mathrm{diff}}$可由下式得到：

$$\hat{y}_{\mathrm{diff},A/B/C}=\mathrm{CROP}(R_{\mathrm{diff}},\hat{y}_{iA/B/C}) \tag{6}$$

式中：通过 CROP（）可获得掩码 R_{diff}对应的预测分割结果。

本文通过注意力损失增强网络对不确定区域的关注。注意力损失如下：

$$L_{\mathrm{att},A/B/C}=\alpha_{\mathrm{MSE}}(\hat{y}_{\mathrm{diff}A/B/C},y_{\mathrm{diff}}) \tag{7}$$

式中：MSE（）为均方误差损失函数（mean square error，MSE），y_{diff}为与该区域对应的标签图像。

2）URM

随机丢弃部分区域可以扩展训练分布，提高网络泛化能力。然而，由于输入图像的随机扰动会将噪声引入新样本中，导致伪标签质量降低，进而影响网络训练性能。为克服上述限制，本文提出了 URM，如图 3 所示。

为确保不确定性评估的可靠性，URM 首先通过集成教师网络和学生网络的输出来获得不确定性映射 U_m，具体过程如下：

$$U_m=\mathrm{Uncertain}(f(x;\theta_m),f(x;\theta))=-\sum_c P_c\log(P_c) \tag{8}$$

$$P_c=\frac{1}{2}(\mathrm{Softmax}(f(x;\theta_m))+\mathrm{Softmax}(f(x;\theta))) \tag{9}$$

式中:$m=1,2$ 为学生网络的索引;c 为类别索引值;Uncertain 为获得不确定性映射操作;P_c 为第 c 类别下教师和学生的平均预测概率。

根据不确定性映射,将 x 中前 k 个最不确定区域(V_1 和 V_2 中的红色网格)替换为前 k 个最确定区域(V_1 和 V_2 中的绿色网格),构造新的样本 $x'=\mathrm{URM}(x,U_1,U_2;k,1/r)$,其中每个区域的大小为$1/r$。为适应图像尺寸,本文将 k 设为 2,r 设为 16。

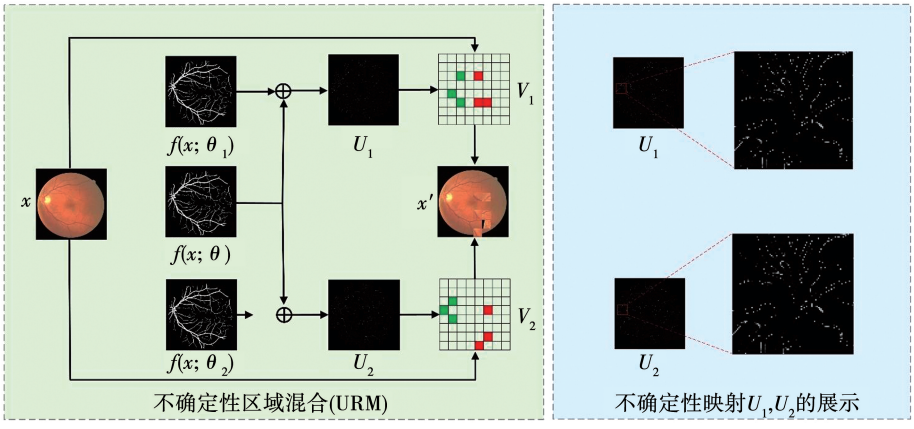

图 3　不确定性引导的区域混合(URM)示意图

Fig. 3　Uncertainty-guided region mix (URM) schematic

1.4　总体损失函数

1)第 1 阶段

3 个网络参数独立更新。网络相对应的总优化损失函数由监督损失 L_s 和无监督损失 L_u 构成,教师损失函数 L_t 和 2 个学生网络损失函数 $L_{1/2}$ 如下所示:

$$L_t=L_s \tag{10}$$

$$L_{1/2}=L_s+\lambda L_u \tag{11}$$

式中:λ 为正则化参数,用于平衡监督学习和无监督学习的损失。本文采用高斯 ramp-up 函数逐渐增加 λ,即 $\lambda(t)=\lambda_m\exp[-5(1-\frac{t}{t_m})^2]$,其中 $\lambda_m=1$,为缩放加权函数的最大值,t 为当前迭代次数,t_m 为训练的最大迭代次数。

监督损失 L_s 由医学图像分割中常用的 Dice 损失和注意力损失组成,如下式所示:

$$L_{s1}=\alpha_{\mathrm{Dice}}(\hat{y}_i,y_i) \tag{12}$$

$$L_s=\frac{1}{n}\sum_{i=1}^{n}\{L_{s1}+\gamma L_{\mathrm{att}}(\hat{y}_{\mathrm{diff},i},y_{\mathrm{diff},i})\} \tag{13}$$

式中:超参数 γ 用于注意力损失和 Dice 损失之间的均衡,本文将 γ 设为 0.5。

无监督损失 L_u 充当正则化项,用于探索网络学习 D_l 和 D_u 的潜在能力。L_u 由学生网络受另一个学生网络的伪监督 $L_{\mathrm{cps1/2}}$ 和教师网络分别对学生网络的直接监督 $L_{\mathrm{ds1/2}}$ 组成,具体如下:

$$L_u=L_{\mathrm{cps1/2}}+L_{\mathrm{ds1/2}} \tag{14}$$

2)第 2 阶段

教师网络是学生网络均值的自集合,总损失函数如下:

$$L=L_s+\lambda L_u \tag{15}$$

式中:监督损失 L_s 为 Dice 损失,不再包括注意力损失。λ 定义不变。此时无监督损失 L_u 由 2 个学生网络之间的交叉伪监督 L_{cps} 和教师网络引导学生网络的直接监督 L_{ds} 组成,具体如下:

$$L_u=L_{\mathrm{cps}}+L_{\mathrm{ds}} \tag{16}$$

2　实验和结果分析

2.1　数据集

本方法在 2 个公共数据集上进行了评估,分别为 DRIVE[25]、STARE[26]。这些数据集提供了由专家手动标记的血管分割图片作为标签。数据集的详细信息如下。

DRIVE:包含 40 张彩色眼底图像,分辨率为 565×584 像素。图像由 Canon CR5 非显微镜相机拍摄得到,视场为 45°,位深度为 8 位。

STARE:包括 20 张彩色眼底图像,其中一半包含各种病理迹象。图像由 Canon TopCon TRV-50 眼底相机拍摄得到,分辨率为 700×605 像素,视场为

35°,位深度为8位。

2.2 实施细节

本文利用 PyTorch 实现了该方法,并在单个 NVIDIA Quadro RTX 4090 GPU 上进行了实验。实验中固定学习率为 10^{-4},设置 $\alpha=0.99$,$\beta=0.99$,采用 AdamW 算法来优化模型参数。在预处理中,将 DRIVE 和 STARE 数据集中的彩色视网膜图像转换为灰度图像并进行均匀标准化。训练阶段,将随机裁剪的 256×256 补丁作为模型输入进行训练。测试阶段,输入完整尺寸的图像进行评估。

2.3 评价指标

我们通过比较经阈值划分的二进制分割图与相应的标签图像来计算准确率(α_{Acc})、灵敏度(S_{en})、特异性(S_{pe}),并将其作为定量结果来衡量分割性能。定义如下:

$$S_{\mathrm{en}}=\frac{\mathrm{TP}}{\mathrm{TP}+\mathrm{FN}} \tag{17}$$

$$S_{\mathrm{pe}}=\frac{\mathrm{TN}}{\mathrm{TN}+\mathrm{FP}} \tag{18}$$

$$\alpha_{\mathrm{Acc}}=\frac{\mathrm{TP}+\mathrm{TN}}{\mathrm{TP}+\mathrm{FN}+\mathrm{TN}+\mathrm{FP}} \tag{19}$$

式中:真正例(true positives,TP)和真负例(true negatives,TN)分别为正确分割的血管像素和非血管像素的数量;假正例(false positives,FP)和假负例(false negatives,FN)分别为错误分割的血管像素和非血管像素的数量。

2.4 对比实验

我们以0.2带标签的比例在 DRIVE、STARE 数据集上评估了模型的性能,并与最先进的全监督[27-29]和半监督[30-32]方法进行了比较。

表1为本文方法及对比方法在 DRIVE 与 STARE 数据集的血管分割性能对比。本方法在 DRIVE 数据集和 STARE 数据集上的准确率、灵敏度和特异性如表所示。

表1 不同方法的血管分割性能对比

Tab.1 Comparison of vessel segmentation performance with different methods

方法	DRIVE 数据集			STARE 数据集		
	α_{Acc}	S_{en}	S_{pe}	α_{Acc}	S_{en}	S_{pe}
RCAR-UNet[27]	0.953 7	0.748 7	0.983 6	0.959 4	0.697 9	0.990 5
MSIFA[28]	0.952 3	0.702 5	0.977 3	0.945 5	0.727 3	0.962 2
DSeU-net[29]	0.957 8	0.800 5	0.983 4	0.957 3	0.689 5	0.986 8
HDN-UASSL[30]	0.957 0	0.791 6	0.981 1	—	—	—
Duo-SegNet[31]	0.937 7	0.625 3	0.965 7	0.949 2	0.606 1	0.967 4
Min-max similarity[32]	0.914 2	0.728 2	0.931 0	0.932 6	0.667 6	0.947 4
本文方法(DU-DCMT)	0.967 3	0.817 3	0.981 1	0.978 3	0.768 2	0.988 5

在全监督方法中,与基于粗糙通道注意力机制的视网膜血管分割方法 RCAR-UNet[27]相比,虽然 RCAR-UNet 的特异性高于 DU-DCMT,但 DU-DCMT 在 DRIVE 数据集上的准确率、灵敏度分别提升了1.36%、6.86%,在 STARE 数据集上准确率、灵敏度分别提升了1.89%、7.03%。这表明 DU-DCMT 识别血管像素的能力有了非常大的提升。MSIFA[28]是1种多尺度空间强度域融合自适应滤波模型,与 MSIFA 相比,DU-DCMT 在 DRIVE 数据集和 STARE 数据集上都取得了更高的灵敏度和准确率。特别在灵敏度方面,在2个数据集上,DU-DCMT 较其分别提高了11.48%和4.09%。DSeU-net[29]是基于可变形卷积和挤压激励残差模块的深度学习网络,旨在提升网络在眼底图像中的特征提取能力。该网络在 DRIVE 数据集上的准确率和灵敏度低于 DU-DCMT,特异性高于 DU-DCMT,两者性能较为接近。但其在 STARE 数据集上的所有指标,特别是灵敏度显著低于 DU-DCMT,表明了 DU-DCMT 在血管感知能力和泛化能力上的优势。

在半监督方法中,基于不确定性感知的 HDN-UASSL[30]方法虽然特异性与 DU-DCMT 较为接近,但 DU-DCMT 在 DRIVE 数据集上的准确率和灵敏度较其分别提升了 1.03% 和 2.57%,由此可见,HDN-UASSL 对血管的感知能力有待提升,血管分割性能不及 DU-DCMT。与基于对抗训练的 Duo-SegNet[31]方法相比,DU-DCMT 在 DRIVE 数据集和 STARE 数据集上准确率、灵敏度和特异性均有所提高。这是由于 Duo-SegNet 引入了多视角学习和对抗性训练的概念,增加了方法复杂性,易出现收敛不充分的情况。与基于对比学习 Min-max similarity[32]的方法相比,DU-DCMT 在 DRIVE 数据集和 STARE 数据集上的准确率、灵敏度和特异性表现更佳。这是由于 Min-max similarity 引入了对比学习,分割性能易受到数据分布不均的影响。由此可得,本方法优于目前先进的半监督方法,较全监督方法也极具竞争优势,进一步证明了其在血管细分任务中的卓越性能。

2.5　定性分析

继续对语义分割结果进行视觉评估。首先,针对 DRIVE、STARE 数据集,本文展示了整个图像的预测结果图、差异显示图及局部放大细节图,如图 4~5 所示。其中差异显示图用于突出预测结果图和地面真值之间的差异,绿色为假阳性像素,代表错误分割为血管的像素,蓝色为假阴性像素,代表误判为非血管的像素。由图可见,本方法在半监督场景下得到了非常接近地面真值的预测结果,保留了视网膜的形状和血管方向等初步信息。面对复杂的血管分布,本方法较为准确地分割出各种分叉、交叉血管结构,同时表现出了出色的血管提取能力,较为完整地捕获了厚血管像素。但本方法在血管分割上仍存在一些细微差异,如高亮显示的矩形区域图所示,存在薄血管被遗漏的问题。此外,血管边缘易出现一些错误的分割像素,即将非血管像素错误地分类为血管。

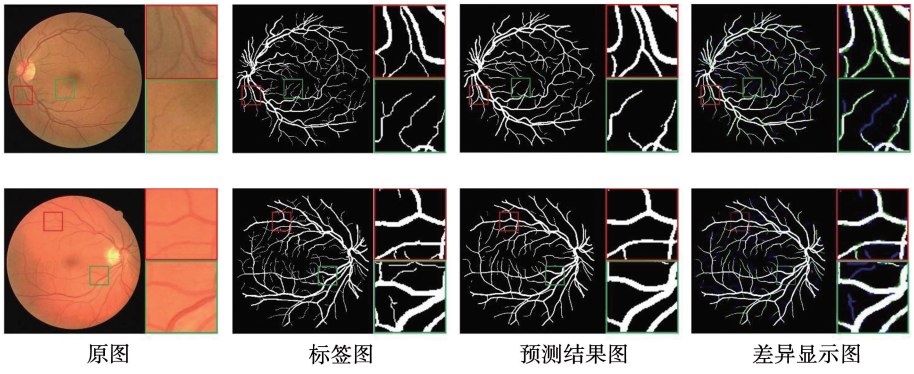

图 4　DRIVE 数据集上的血管分割结果可视化

Fig. 4　Visualization of vessel segmentation on the DRIVE dataset

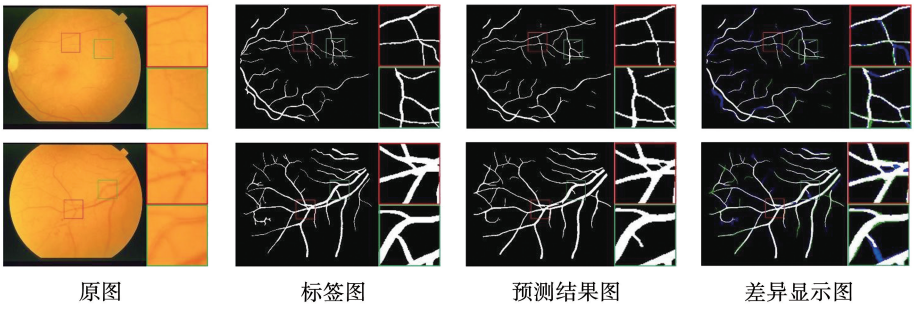

图 5　STARE 数据集上的血管分割结果可视化

Fig. 5　Visualization of vessel segmentation on the STARE dataset

本文还提供了一些局部图像块以进一步分析本方法的血管分割性能,如表 2 所示。本方法能够很好地适应较灰暗但血管对比度明显的眼底图像(局部 1),在血管交叉复杂的区域也能较为完整地分割

血管,但在对比度不足之处出现了细微血管丢失的情况。局部 2、局部 3 图像同样明亮度不足,但血管清晰度适中,本方法展现出了优良的分割性能,准确地分割出血管脉络,基本捕获了较为细小的血管。局部 4 ~ 6 眼底图像明亮度良好但对比度不足,在局部 4、局部 6 中,本方法依然能够很好地感知并分割出交叉血管,但由于对比度太差,极个别毛细血管被丢失。对于局部 5 中的大直径血管,本方法克服了图片质量的干扰,完整准确地实现了血管分割。上述图片总体表明了本方法分割血管的有效性。

表 2 视网膜眼底图像细节的可视化结果

Tab. 2 Visualization results of details in retinal fundus images

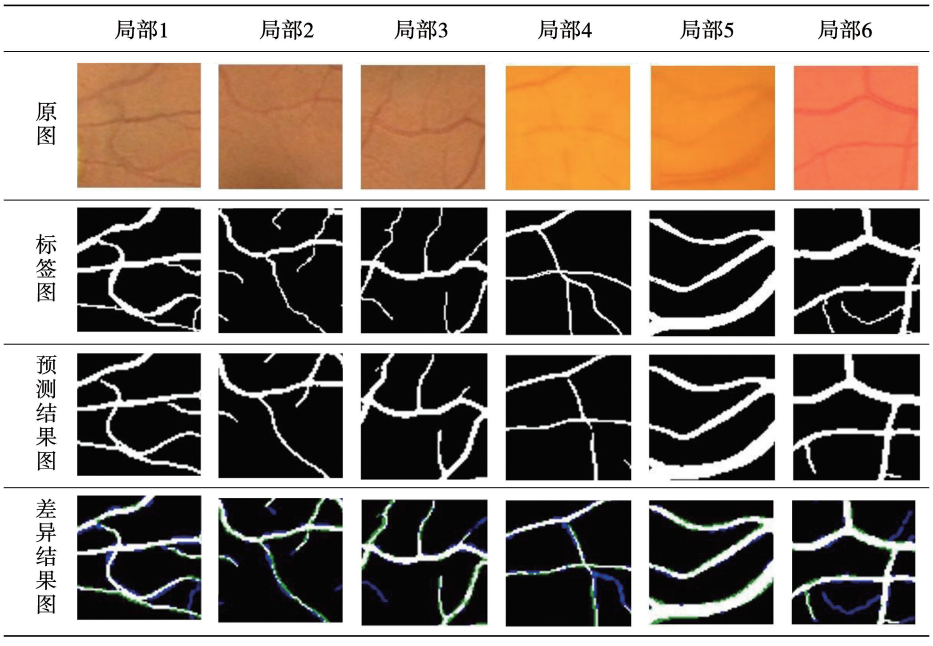

2.6 消融实验

2.6.1 方法消融

在 DRIVE 视网膜图像数据集上对本文方法进行消融研究,旨在评估方法中动态竞争协同均值教师(DCMT)和双重不确定性区域处理模块(DURM)的实际贡献。我们使用学生 - 教师 - 学生架构的 FR-UNet 模型作为本文的基线模型。表 3 为血管分割性能的结果对比,血管分割性能可视化对比如图 6 所示。

表 3 血管分割的消融实验结果

Tab. 3 The ablation experiment results of vessel segmentation

方法设计			血管分割		
基线模型	DURM	DCMT	α_{Acc}	S_{pe}	S_{en}
✓			0.967 9	0.982 8	0.805 5
✓	✓		0.968 0	0.982 9	0.806 3
✓		✓	0.967 5	0.982 0	0.810 8
✓	✓	✓	0.967 3	0.981 1	0.817 3

注:“✓”表示使用该模块。

由表 3 可见,基线模型在 DRIVE 数据集上的灵敏度、准确率及特异性分别为0.805 5、0.967 9 和 0.982 8。随后,引入双重不确定性区域处理模块,基线模型 + DURM 取得了0.806 3的灵敏度,相较基线模型的灵敏度提升了0.000 8,这表明 DURM 模块引导网络关注潜在预测错误区域,同时促使网络产生高置信度伪标签。并且,基线模型 + DURM 维持了准确率和特异性的稳定,表明模型在提升血管像素识别能力的同时,保持了区分背景像素的能力。此外,本文在基线模型基础上引入 DCMT,以验证其有效性。基线模型 + DCMT 模型取得了0.810 8的灵敏度,较基线模型提高了0.005 3,表明了 DCMT 动态选择老师学生角色,可提高伪标签质量。然而,由于 DCMT 增加了训练的不一致性,背景像素的区分能力有所波动,准确率和特异性略微下降。最后,本文将 DURM 和 DCMT 均引入基线模型中,基线模型 + DURM + DCMT 模型的灵敏度较基线模型、基线模型 + DURM 以及基线模型 + DCMT 分别提升了 0.011 8、0.011 与0.006 5。表明最终的模型以极小

的准确率、特异性下降的代价,显著改善了对血管真阳性的预测性能。

由图 6 可见,血管分割结果与血管整体分布高度吻合,表明模型成功学习到眼底图像血管的特征表示,对眼底血管具有卓越的感知能力。

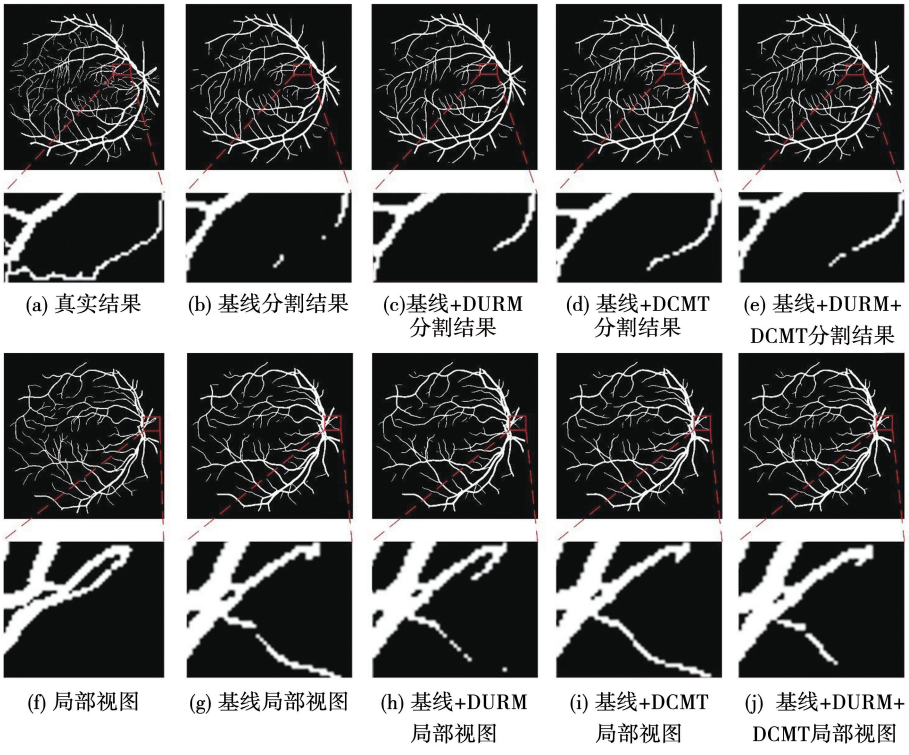

图 6　消融实验图像比较

Fig. 6　Comparisons of the ablation experiment images

观察局部细节图,具体分析各个设计。图 6(b)基线模型出现细微血管分割丢失的问题。然而,图 6(c)、(d)中血管分割丢失现象均得到一定缓解,且图 6(d)改善效果略强于图 6(c)。图 6(c)表明:通过关注潜在预测错误区域,并生成新样本促使网络生成高置信度伪标签,DURM 能够提高网络对血管像素的感知能力。同样地,图 6(d)表明了 DCMT 的有效性。通过动态竞争提高伪标签质量,同时在师生结构中引入协同学习,能够有效提高模型训练效果,提升模型血管分割能力。结合双重不确定性区域模块和动态竞争协同均值教师的模型分割图如图 6(e)所示,最终模型有效结合了 DURM 和 DCMT 的优点,提升了血管分割性能,获得了最接近标签图像的预测。

图 6(g)表明基线模型出现血管丢失且错误分割血管的问题。但令人惊喜的是,图 6(h)中错误分割现象得到明显改善,进一步追踪到了丢失的血管,血管丢失问题得到了一定的缓解。这表明 DURM 能提高模型对血管真阳性预测的灵敏度,同时维持对背景像素的区分能力。然而图 6(i)较基线模型仅略微改善了血管分割结果,对错误分割的血管无明显调整作用。最后图 6(j)中和了 2 个模块的作用,修正了部分错误分割血管的像素,进一步改善了对血管真阳性的预测。上述图片表明了本方法的有效性,并且最终模型结合了各个设计的优点,综合性能达到了最高。

2.6.2　损失函数消融

网络预测不一致的区域非常小且分散,因此损失函数的选择直接影响网络审查差异区域的效果。本文对常见的 CE(cross entropy)、Dice 及 MSE 损失函数在 DRIVE 数据集上进行了实验。表 3 展示了分别采用 CE、Dice 和 MSE 作为注意力损失函数时的模型分割性能。与 CE、Dice 相比,MSE 实现了更好的分割结果,故采用 MSE 作为注意力损失。

表 3 不同损失函数下的模型性能

Tab. 3 Module performance with different loss functions

损失函数	性能指标		
	α_{Acc}	S_{en}	S_{pe}
MSE	0.967 3	0.817 3	0.981 1
CE	0.966 1	0.772 5	0.983 9
Dice	0.966 3	0.760 4	0.985 1

2.6.3 参数敏感度分析

DU-DCMT 有 3 个超参数,即区域混合的前 k 个区域,区域与图像大小之比 $1/r$ 及用来平衡注意力损失 L_{att} 和 Dice 损失的 γ。本文研究了这些因素对 DU-DCMT 在 DRIVE 数据集上表现的影响。首先,我们研究了不同的 k 和 $1/r$ 值对模型灵敏度的影响,结果如表 4 所示。

表 4 DRIVE 数据集 k 和 $1/r$ 的消融实验结果

Tab. 4 Ablation experiment results of k and $1/r$ values on DRIVE

$1/r$	k				
	1	2	3	4	5
1/4	0.791 5	0.794 9	0.793 5	0.793 3	0.794 5
1/8	0.803 6	0.806 5	0.802 8	0.803 9	0.806 4
1/16	0.814 0	0.817 3	0.815 5	0.816 4	0.814 4

由表可见,减小区域大小可以较为有效地提高模型性能,在固定区域大小不变时,模型性能随 k 值的变化略有波动,对性能的影响较小,这表明模型对 k 值不敏感,可以选择适合的 k 值来消除异常值并获得高置信度的伪标签。

其次,研究了 γ 取值对模型性能的影响,结果如表 5 所示。在 γ 从 0.3 到 0.7 变化时,模型在准确率、灵敏度和特异性方面的表现如下:灵敏度随着 γ 从 0.3 增加到 0.5 显著提升,在 $\gamma=0.5$ 时达到最高值0.817 3,但随着 γ 进一步增加到 0.7 开始下降。其他指标虽然略有差异,但总体上变化不大,这说明模型在灵敏度方面对 γ 的变化尤其敏感,这使得 $\gamma=0.5$ 成为优选值。

分析 3 个超参数可知,本文模型对区域大小和 γ 值较为敏感,而对 k 值则相对不敏感。根据这些经验结果,在本文实验中可以选择 $k=2$,$1/r=1/16$ 和 $\gamma=0.5$ 作为默认参数设定,以期望获得最佳性能。

表 5 DRIVE 数据集上不同 γ 消融实验结果

Tab. 5 Ablation experiment results of different values of γ on DRIVE

γ	性能指标		
	α_{Acc}	S_{en}	S_{pe}
0.3	0.966 6	0.778 0	0.983 9
0.4	0.965 9	0.786 1	0.982 5
0.5	0.967 3	0.817 3	0.981 1
0.6	0.966 3	0.802 0	0.981 4
0.7	0.966 8	0.791 5	0.982 9

3 结 语

本文解决了眼底血管语义分割模型训练时缺乏标注数据的问题,提出了双重不确定性引导的动态竞争协同均值教师框架,通过动态竞争协同均值教师提高网络之间的不一致性与伪标签的质量;采用双重不确定性区域处理模块关注易错区域,扩大数据分布并提高伪标签的置信度。本文消融实验证明了动态竞争协同均值教师结构与双重不确定性区域处理模块的有效性,与基线模型相比,本方法提出的血管分割方法灵敏度及准确率等指标更优。此外,本文方法在 DRIVE、STARE 数据集分别取得了0.967 3和0.978 3的准确率,0.817 3和0.768 2的灵敏度和0.981 1和0.988 5的特异性,均优于其他经典半监督方法,甚至优于部分全监督方法。但本文方法在部分复杂场景下仍可能出现细微血管遗漏或边缘误判问题,在未来的工作中,将尝试探索准确度更高的半监督血管分割,并扩展半监督的视盘分割、动静脉分类等相关研究。

参 考 文 献:

[1] CHEN X, WILLIAMS B M, VALLABHANENI S R, et al. Learning Active Contour Models for Medical Image Segmentation [C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019: 11624.

[2] 毕蓉蓉, 王进科. CT 图像下结合 RCNN 与 U-Net 的肺实质自动分割方法[J]. 哈尔滨理工大学学报, 2021, 26(3): 74.
BI Rongrong, WANG Jinke. Automatic Lung Segmentation Using RCNN Combing U-Net in CT[J].

Journal of Harbin University of Science and Technology, 2021, 26(3): 74.

[3] 刘明珠, 付聪, 宋诗杰, 等. 用于颈部超声图像的 SED-UNet 分割方法研究[J]. 哈尔滨理工大学学报, 2024, 29(2): 7.
LIU Mingzhu, FU Cong, SONG Shijie, et al. Research on SED-UNet Segmentation Method for Neck Ultrasound Image[J]. Journal of Harbin University of Science and Technology, 2024, 29(2): 7.

[4] YAN Z, YANG X, CHENG K T. Joint Segment-level and Pixel-wise Losses for Deep Learning Based Retinal Vessel Segmentation [J]. IEEE Transactions on Biomedical Engineering, 2018, 65(9): 1912.

[5] MOCCIA S, DE M E, EL H S, et al. Blood Vessel Segmentation Algorithms-Review of Methods, Datasets and Evaluation Metrics [J]. Computer Methods and Programs in Biomedicine, 2018, 158: 71.

[6] LONG J, SHELHAMER E, DARRELL T. Fully Convolutional Networks for Semantic Segmentation[C]// 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015: 3431.

[7] BADRINARAYANAN V, KENDALL A, CIPOLLA R. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(12): 2481.

[8] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional Networks for Biomedical Image Segmentation[C]//International Conference on Medical Image Computing and Computer-assisted Intervention, 2015: 234.

[9] JIN Q, MENG Z, PHAM T D, et al. DUNet: A Deformable Network for Retinal Vessel Segmentation[J]. Knowledge-Based Systems, 2019, 178: 149.

[10] MOU L, ZHAO Y, CHEN L, et al. CS-Net: Channel and Spatial Attention Network for Curvilinear Structure Segmentation[C]//International Conference on Medical Image Computing and Computer-Assisted Intervention, 2019: 721.

[11] LUO X, CHEN J, SONG T, et al. Semi-supervised Medical Image Segmentation through Dual-task Consistency[C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(10): 8801.

[12] XIA Y, YANG D, YU Z, et al. Uncertainty-aware Multi-view Co-training for Semi-supervised Medical Image Segmentation and Domain Adaptation[J]. Medical Image Analysis, 2020, 65: 101766.

[13] WANG G, ZHAI S, LASIO G, et al. Semi-supervised Segmentation of Radiation-induced Pulmonary Fibrosis from Lung CT Scans with Multi-scale Guided Dense Attention[J]. IEEE Transactions on Medical Imaging, 2022, 41(3): 531.

[14] LEE D H. Pseudo-label: The Simple and Efficient Semi-supervised Learning Method for Deep Neural Networks [C]//Workshop on Challenges in Representation Learning, 2013, 3(2): 896.

[15] LI Y, CHEN J, XIE X, et al. Self-loop Uncertainty: A Novel Pseudo-label for Semi-supervised Medical Image Segmentation[C]//International Conference on Medical Image Computing and Computer-assisted Intervention, 2020: 614.

[16] YAO H, HU X, LI X. Enhancing Pseudo Label Quality for Semi-supervised Domain-generalized Medical Image Segmentation[C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2022, 36(3): 3099.

[17] QIU Z, GAN W, YANG Z, et al. Dual Uncertainty-guided Multi-model Pseudo-label Learning for Semi-supervised Medical Image Segmentation [J]. Mathematical Biosciences and Engineering, 2024, 21(2): 2212.

[18] TARVAINEN A, VALPOLA H. Mean Teachers are Better Role Models: Weight-averaged Consistency Targets Improve Semi-supervised Deep Learning Results [J]. Advances in Neural Information Processing Systems, 2017, 30:1.

[19] WANG K, ZHAN B, ZU C, et al. Tripled-uncertainty Guided Mean Teacher Model for Semi-supervised Medical Image Segmentation [C]//International Conference on Medical Image Computing and Computer-Assisted Intervention, 2021: 450.

[20] CHEN J, FU C, XIE H, et al. Uncertainty Teacher with Dense Focal Loss for Semi-supervised Medical Image Segmentation[J]. Computers in Biology and Medicine, 2022, 149: 106034.

[21] WANG Q, LI X, CHEN M, et al. A Regularization-driven Mean Teacher Model Based on Semi-supervised Learning for Medical Image Segmentation[J]. Physics in Medicine & Biology, 2022, 67(17): 175010.

[22] KE Z, QIU D, LI K, et al. Guided Collaborative Training for Pixel-wise Semi-supervised Learning[C]// European Conference on Computer Vision, 2020: 429.

[23] CHEN X, YUAN Y, ZENG G, et al. Semi-supervised Semantic Segmentation with Cross Pseudo Supervision [C]//2021 IEEE/CVF Conference on Computer Vision

and Pattern Recognition (CVPR), 2021: 2613.

[24] FRAZ M M, BARMAN S A, REMAGNINO P, et al. An Approach to Localize the Retinal Blood Vessels Using Bit Planes and Centerline Detection[J]. Computer Methods and Programs in Biomedicine, 2012, 108(2): 600.

[25] STAAL J, ABRAMOFF M D, NIEMEIJER M, et al. Ridge-based Vessel Segmentation in Color Images of the Retina[J]. IEEE Transactions on Medical Imaging, 2004, 23(4): 501.

[26] HOOVER A D, KOUZNETSOVA V, GOLDBAUM M. Locating Blood Vessels in Retinal Images by Piecewise Threshold Probing of a Matched Filter Response[J]. IEEE Transactions on Medical Imaging, 2000, 19(3): 203.

[27] DING W, SUN Y, HUANG J, et al. RCAR-UNet: Retinal Vessel Segmentation Network Algorithm via Novel Rough Attention Mechanism[J]. Information Sciences, 2024, 657: 120007.

[28] HUANG M, FENG C, LI W, et al. Vessel Enhancement Using Multi-scale Space-intensity Domain Fusion Adaptive Filtering[J]. Biomedical Signal Processing and Control, 2021, 69: 102799.

[29] ZHU X, LI W, ZHANG W, et al. A Deformable Network with Attention Mechanism for Retinal Vessel Segmentation [J]. Journal of Beijing Institute of Technology, 2024, 33(3): 186.

[30] LI C, MA W, SUN L, et al. Hierarchical Deep Network with Uncertainty-aware Semi-supervised Learning for Vessel Segmentation [J]. Neural Computing and Applications, 2022, 34(4): 3151.

[31] PEIRIS H, CHEN Z, EGAN G, et al. Duo-SegNet: Adversarial Dual-views for Semi-supervised Medical Image Segmentation [C]//International Conference on Medical Image Computing and Computer-Assisted Intervention, 2021: 428.

[32] LOU A, TAWFIK K, YAO X, et al. Min-max Similarity: A Contrastive Semi-supervised Deep Learning Network for Surgical Tools Segmentation [J]. IEEE Transactions on Medical Imaging, 2023, 42(10): 2832.

(编辑:温泽宇)