

基于多尺度区域可靠性感知的半监督肺肿瘤分割

刘卫朋^{1,2}, 祁业东^{1,2}, 李健¹, 徐海星^{1,2}

1. 河北工业大学人工智能与数据科学学院, 天津 300130; 2. 河北工业大学高端装备智能感知与先进控制研究所, 天津 300130

【摘要】提出一种基于多尺度下一致性和区域可靠性感知的半监督学习方法,在使用少量标注数据的情况下结合未标记的数据来实现高性能的肺部肿瘤分割任务。首先,提出一种多尺度一致性均值教师框架,构建多尺度一致性损失并约束教师学生网络中多个尺度上的输出保持一致,使模型学习到更丰富的一致性知识。此外,提出一种区域可靠性感知方法使一致性学习之间的知识交换更加有效,使模型从无标注的数据中学习到更有效且可靠的知识。本文方法在医学图像分割十项全能比赛肺肿瘤数据集上进行充分的评估,与当前先进的半监督学习方法比较有更优越的性能,验证本文方法的有效性。

【关键词】半监督学习; 医学图像分割; 肺肿瘤; 可靠性感知; 多尺度一致性

【中图分类号】R318; TP391.41

【文献标志码】A

【文章编号】1005-202X(2024)09-1078-08

Semi-supervised lung tumor segmentation based on multi-scale consistency and regional reliability perception

LIU Weipeng^{1,2}, QI Yedong^{1,2}, LI Jian¹, XU Haixing^{1,2}

1. School of Artificial Intelligence, Hebei University of Technology, Tianjin 300130, China; 2. Laboratory of Advanced Perception and Intelligent Control of High-End Equipment, Hebei University of Technology, Tianjin 300130, China

Abstract: A semi-supervised learning method based on multi-scale consistency and regional reliability perception is proposed to combine unlabeled data with a small amount of labeled data to achieve high-performance lung tumor segmentation tasks. A multi-scale consistency mean teacher framework is used to construct a multi-scale consistency loss and constrain the outputs in the mean teacher network to be consistent across multiple scales, so that the model learns richer consistency knowledge. In addition, a regional reliability perception scheme is adopted to make the knowledge exchange between consistency learning more efficient, enabling the model to learn more valid and reliable knowledge from unlabeled data. The evaluation on the lung tumor dataset in the Medical Segmentation Decathlon shows superior performance of the proposed method over current state-of-the-art semi-supervised learning methods, validating its effectiveness.

Keywords: semi-supervised learning; medical image segmentation; lung tumor; reliability perception; multi-scale consistency

前言

由肺部肿瘤引起的肺部疾病严重威胁着人类的生命和健康,其中肺癌仍是最致命的疾病类型^[1]。因此,对于肺部肿瘤患者来说,早期的治疗和诊断至关重要。目前,深度学习等人工智能技术的发展可以在医学图像分析和诊断中为医生提供更加详细和准

确的病理信息,以便更好地辅助早期的诊断和治疗过程^[2]。同时,利用深度学习方法进行自动肺部肿瘤分割大大提升医生处理数据和阅片的效率,减轻临床医生的负担,更加高效地制定患者的治疗和康复计划。

当前,基于深度学习的医学图像分割方法往往需要像素级别的注释,通常需要专业医生进行手动标注,这个过程需要耗费大量的时间、人力和金钱等资源^[3-4]。同时由于医学领域的复杂性和专业性,手工进行标注的医学图像数据往往存在着一些误差。而半监督学习可以使用少量标注数据和大量未标注数据来训练准确的分割算法,从而减轻标注负担,并充分利用大量的未标记数据来提高分割的准确性^[5]。

【收稿日期】2024-01-20

【基金项目】国家重点研发计划(2020YFB1313703);国家自然科学基金(62027813);河北省重点研发计划(21372003D);河北省自然科学基金(F2022202054)

【作者简介】刘卫朋,博士,研究员,研究方向:医学图像处理、手术机器人控制,E-mail: liuweipeng@hebut.edu.cn

大量容易获取的原始医学数据使半监督学习在医学图像处理中的研究受到广泛关注^[6-7]。其基本思想是在仅使用少量标注样本的情况下,利用大量的无标注数据来提升深度学习的性能,有效提高分割模型的性能和泛化能力^[8]。当前主流的半监督学习方法可以分为制作伪标签的自训练策略以及基于平滑度假设的一致性学习策略^[9-11]。自训练策略首先使用带有标签的数据训练网络,生成一系列伪标签,然后将这些伪标签与原有数据集合并,重新训练模型直到收敛^[12]。然而,自训练策略对初始模型的要求较高,其成功与否往往取决于初始分类器的性能^[13]。此外,自训练算法需要多次迭代训练,对于体积较大的医学图像,训练成本更高^[14]。基于一致性学习的均值教师方法通过对标记数据和未标注数据引入不同的扰动,对扰动后的模型输出结果进行一致性约束,辅助优化网络,提高模型的鲁棒性和泛化性^[15],是更为主流的半监督学习策略。但是在一致性学习的半监督方法中,学生网络对未标注数据的输出存在着不可靠的预测区域,而这会产生错误的一致性指导,如何在教师学生网络之间进行有意义的一致性约束一直是个难点^[16]。Zhang等^[17]通过设计一个评估网络来对未标注数据的分割结果进行评判以确定输出的可靠性。Liu等^[18]将网络扰动与数据扰动相结合,减少对不可靠预测的一致性依赖。Yu等^[19]设置一种不确定性估计的方法,使模型尽可能地从更可靠的目标中学习。然而,上述关于一致性学习的半监督学习方法存在着缺乏对局部区域体素的可靠性划分的考虑^[20]。当前基于全局不确定性感知的一致性学习方法,可能会导致模型失去可靠预测区域的指导,无法充分利用可靠区域的一致性信息来提升关键区域的预测^[21]。同时,针对不可靠区域使用全局的一致性约束也无法有效发挥作用,甚至可能产生负面影响。此外,上述方法仅考虑了单一尺度下的一致性约束,这会导致模型忽视来自不同尺度上有意义的信息,通过不同尺度下的一致性学习,教师学生网络可以学习到更丰富的多尺度一致性信息^[22]。

本文提出一种新颖的多尺度一致性和区域可靠性感知(Regional Reliability Perception, RRP)的半监督学习策略来应对上述的问题和挑战。该方法在只使用少量标注的情况下,从肺部CT扫描中准确地分割肺部肿瘤病变。本文方法使用均值教师网络的思想,构建一组相同网络结构的学生-教师模型,将受到不同扰动的数据送入网络,鼓励受到不同扰动前后的数据拥有一致的输出^[23]。同时,本文还引入多尺度一致性约束(Multi-scale Consistency Constraints,

MCC),通过构建多尺度深监督模型以产生不同尺度上的预测,并在不同尺度下进行一致性约束来获取不同尺度上的一致性信息,鼓励模型在不同尺度上的输出保持一致。此外,本文提出一种RRP方法并应用到计算多尺度一致性的过程中。通过对输入体素在不同尺度上的预测结果进行区域可靠性判别,并针对高可靠性和低可靠性的区域采用不同的一致性约束方法,提升半监督下一致性学习的有效性,以增强模型对有限标注情况下医学图像中不可靠区域的预测能力。

1 方法

1.1 算法框架

本文提出的基于多尺度RRP的半监督分割框架如图1所示,由两个结构相同的U型3D深度卷积神经网络组成,分别作为一致性学习过程中的学生和教师模型。训练数据分为有标注数据 $D_l = \{(x_i, y_i)\}_{i=1}^N$ 与无标注数据 $D_u = \{\bar{x}_i\}_{i=1}^M$,其中 $M > N$ 。 $x_i \in R^{H \times W \times D}$ 为输入的三维体积数据, $y_i \in \{0, 1\}^{H \times W \times D}$ 是对应标签的真实值。在训练阶段,将标记数据 D_l 送入学生网络中,计算多尺度上的监督损失并约束多个尺度上输出的一致性。然后,对未标记的数据添加不同的随机噪声扰动后分别送入学生和教师网络中并得到多个尺度的预测输出,在不同尺度上进行一致性学习,鼓励模型之间一致性的预测。在进行一致性学习的过程中,使用提出的RRP策略将预测输出的体素划分为可靠性区域和不可靠性区域。然后对不同可靠性的区域分别制定不同的一致性约束策略,将学生网络和教师网络对应尺度的预测输出进行更有效的一致性学习。最后将多尺度上的监督损失和由RRP作用下的一致性损失组合作为网络整体的损失函数进行迭代和优化。

1.2 多尺度下的监督损失

针对带标注数据的训练过程,本文方法使用如图2所示带有多尺度深监督的U型3D网络作为分割模型,在不同尺度的上采样块后面加入 $1 \times 1 \times 1$ 的卷积层与Softmax层,生成多个不同尺度的预测结果。同时,本文对原本的标签进行下采样,生成一组与预测结果尺度大小相同的标签 $[y_0, y_1, y_2, y_3]$,并在每个层次上设置监督信号,共同计算监督损失。在深度卷积神经网络中,不同尺度上的信息可以提供丰富的特征描述。深监督的训练策略可以让模型学到更全面表征数据对象的特征信息。在每个层次上都进行损失函数的计算,可以更有效地传递误差信号,使网络学习更多尺度特征表示,提升模型的分割性能。对于有标注数据 $x_i \in D_l$,本文的模型输出一组多尺度

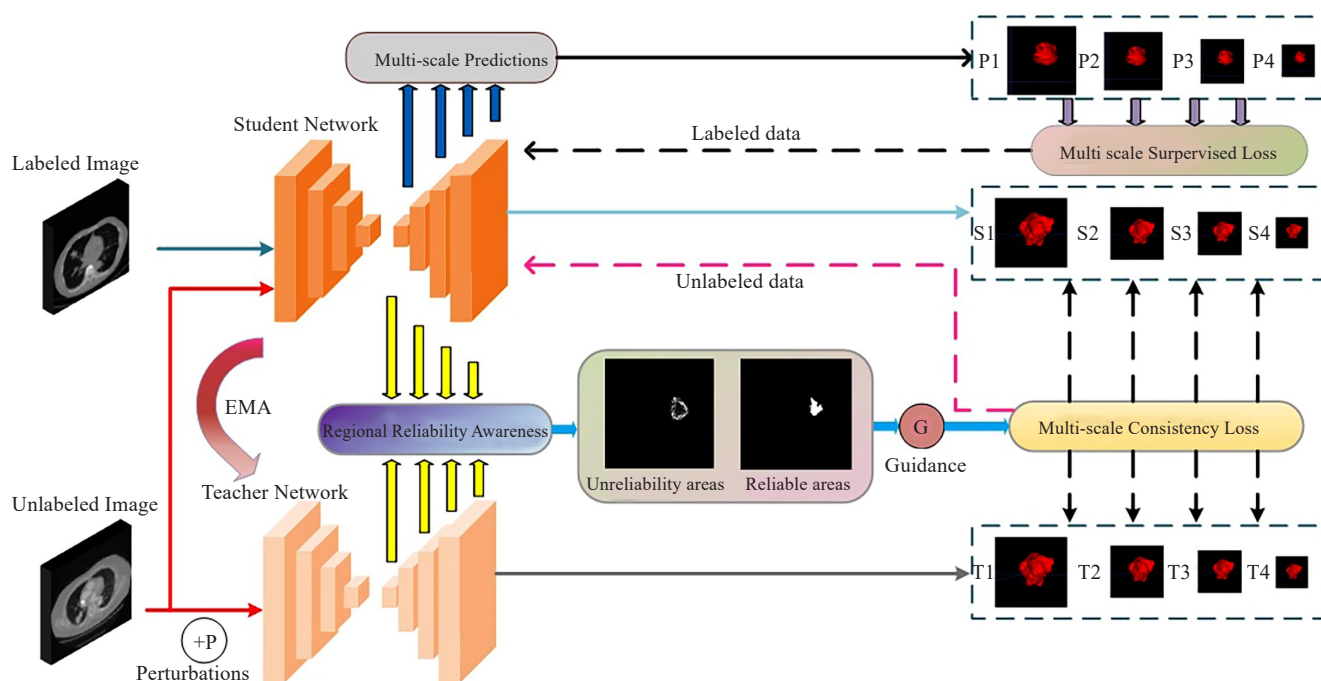


图1 整体半监督分割框架示意图

Figure 1 Schematic diagram of the proposed overall semi-supervised segmentation framework

预测 $[p_0, p_1, p_2, p_3]$ 。其中 p_3 对应模型最下层输出,拥有最小的分辨率。然后,本文将这组多尺度预测与经过相对应尺度的标签相匹配,来计算标记数据的监督损失。本文使用DSC Loss与Focal Loss的组合损失作为模型的损失函数,具体公式如下:

$$L_{sup} = \frac{1}{4} \sum_{s=0}^3 \frac{L_{dice}(p_s, y_s) + L_{focal}(p_s, y_s)}{2} \quad (1)$$

其中, s 表示网络预测的尺度, p_s, y_s 表示 s 尺度下的预测和标签, p_s, y_s 具有相同的尺度大小。 L_{dice} 和 L_{focal} 表示骰子损失和焦点交叉熵损失,本文将这两种损失函数组合使用,可以更好地优化像素级分类任务,有效提高模型的性能和小目标识别能力^[24]。

1.3 RRP下的多尺度一致性损失

1.3.1 均值教师框架 本文的半监督分割框架基于均值教师框架设计,由两个结构完全相同的分割模型分别作为教师和学生网络。根据平滑假设^[25],给予神经网络相似的输入,会得到相近的输出。在训练过程中,标记数据作为学生网络的输入进行有监督学习。未标记的数据同时送入学生和教师网络中,并添加上不同的随机噪声来提升网络的鲁棒性和抗干扰能力。本文使用均方差来设计一致性损失约束学生和教师模型在无标注的数据上产生一致性预测,将监督学习的损失和一致性损失进行组合来更新学生模型的参数,细化未标记数据的预测结果,从而提升整体的分割性能。

教师模型的参数更新使用指数平均移动(EMA)

方法从学生模型中集成不同时期的训练参数来更新教师模型的权重。研究已经表明这样可以集合不同训练时期中的信息,提升分割的精度。由于进行时序上的融合^[26],教师模型的预测更加稳定并可以作为标签指导学生模型的更新方向,具体为:

$$\theta'_t = \alpha \theta'_{t-1} + (1 - \alpha) \theta_t \quad (2)$$

其中, θ_t 是学生模型的参数, θ'_t 表示教师网络中的参数,此处 α 是控制更新率的EMA衰减,根据经验设置 $\alpha=0.99$ ^[27]。因为在模型初始训练阶段,模型参数来自随机初始化,学生模型的参数并不准确,所以构成的教师模型参数也是不准确的。教师网络的参数应该以学生模型学习到的参数为准,所以 α 的值应该从零开始,随着网络的训练,学生模型达到一定的准确率之后,就可以采用时序融合的思想, α 会随着迭代次数的进行而更新最终达到0.99,如式(3)所示:

$$\alpha = \min \left(1 - \frac{1}{\text{iteration} + 1}, 0.99 \right) \quad (3)$$

1.3.2 RRP方法 在医学图像分割任务中,预测不可靠区域往往位于目标器官和病变区域,来自这些区域的一致性学习并不能提供足够的约束效应。当前主流的全局不确定性估计不能完全发挥一致性学习在半监督任务中的优势。为了使教师和学生模型之间的一致性信息交换更加有效,如图3所示,本研究设计一种针对一致性学习过程中的RRP方法,分别对4个尺度上的预测输出进行区域稳定性划分,将预测输出划分为稳定可靠的区域和不可靠的区域。满

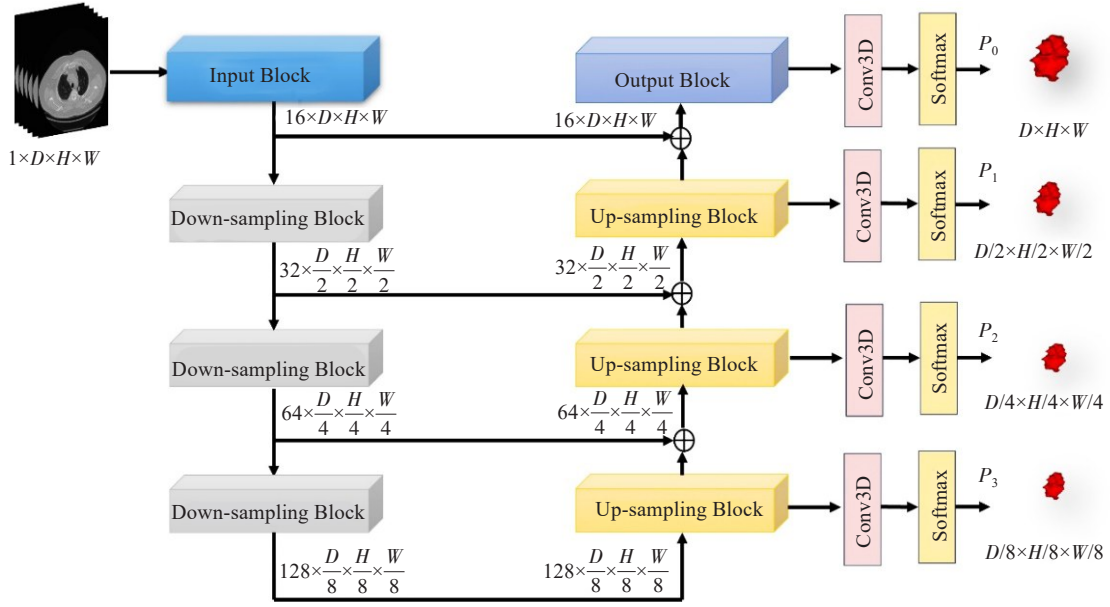


图2 所提出分割网络结构图

Figure 2 Structure of the proposed segmentation network

足在加入不同的随机噪声扰动条件下,模型的输出仍然具有一致性预测的体素区域定义为可靠性体素区域。这些被定义为可靠的体素需要满足 $f(v; \zeta) \geq \theta$ 且 $f'(v; \zeta') \geq \theta$, 其中 θ 为设置的可靠性阈值, $f(\cdot)$ 和 $f'(\cdot)$ 代表相同结构的学生和教师模型, v 表示输入体积数据中的体素, ζ 代表对输入数据进行的不同噪声扰动。

在RRP模块进行区域可靠性划分后,进一步为这两类区域设置不同的一致性约束方案,并添加到目标损失函数中。对于那些拥有可靠预测的体素区域,仅使用常规的一致性约束操作。在模型难以准确区分的不可靠体素区域中,则使用具有不确定性约束的一致性学习来进行优化。本研究通过计算预测熵来为这些不可靠体素区域制定不确定性约束,对它们的一致性学习进行加权处理,如下式所示:

$$u_s = - \sum_{v \in R_s^{\text{ur}}} f(v) \log(f(v)) \quad (4)$$

其中, R_s^{ur} 表示在 s 尺度下的不可靠体素组成的区域。在RRP的指导下,教师学生网络对来自可靠区域的一致性约束信息充分利用,对来自相对不可靠区域的体素利用预测熵加权约束这部分的一致性学习。在多尺度RRP下无标注数据的一致性损失公式如下:

$$L_{\text{con}-s}^r = \frac{1}{N_s^r} \sum_{v \in R_s^r} (f(v; \zeta) - f'(v; \zeta'))^2 \quad (5)$$

$$L_{\text{con}-s}^{\text{ur}} = \frac{1}{N_s^{\text{ur}}} \sum_{v \in R_s^{\text{ur}}} e^{-u_s} (f(v; \zeta) - f'(v; \zeta'))^2 \quad (6)$$

其中, N_s^r 和 N_s^{ur} 分别表示在 s 尺度下可靠区域和不可

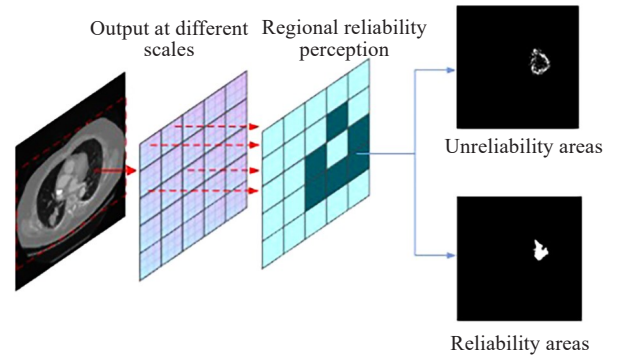


图3 RRP方法示意图

Figure 3 Schematic diagram of the proposed regional reliability perception

靠区域中体素的个数。本文的一致性损失计算方法是在模型预测的不同尺度上分别计算学生和教师模型之间的一致性损失。通过定义 s 尺度下不可靠区域的一致性学习权重为 e^{-u_s} , 较大的熵对应更大的不确定性, 较高的不确定性也就意味着较小的一致性学习权重。在学生和教师网络受到不同扰动的情況下, 对不同尺度上的一致性损失求平均。学生模型的总体一致性损失如下所示:

$$L_{\text{unsup}} = \frac{1}{4} \sum_{s=0}^3 L_{\text{con}-s}^{\text{ur}} + L_{\text{con}-s}^r \quad (7)$$

所提的基于多尺度一致性和RRP的半监督学习方法, 不仅可以让模型学习到不同尺度上的一致性知识, 而且可以引导模型来自更可靠区域中学习, 提升模型整体的预测准确性并使来自教师学生网络中的一致性学习更加可靠。

1.4 网络整体损失函数构成

本文提出的基于多尺度一致性RRP的半监督分割框架通过最小化下面的损失函数来优化学生模型:

$$L_{\text{total}} = \lambda L_{\text{unsup}} + L_{\text{sup}} \quad (8)$$

损失函数包含带标注数据的多尺度监督损失和教师学生模型的多尺度一致性损失。式子中的 L_{sup} 和 L_{unsup} 已经由式(1)和式(7)定义。 λ 是平衡一致性损失和监督损失之间的权重,由于模型初步训练阶段,学生和教师模型的预测精度有限,来自一致性学习的影响较小, λ 的设置需要减少一致性学习在整个损失函数中的影响。随着训练的进行,模型的精度也会逐渐提升,一致性学习产生的影响也逐渐变大,来自一致性学习中的知识和信息也更加可靠和稳定,因此其权重 λ 需要随着训练进度逐步上升,以更好地优化损失函数来训练模型。本文根据经验将 λ 设置为 $e^{\left(-5\left(1-\frac{t}{t_{\max}}\right)^2\right)}$,其中, t 表示当前的训练迭代次数, t_{\max} 表示最大的训练迭代次数^[28]。

2 实验与结果分析

2.1 数据集和预处理

本研究使用来自医学图像分割十项全能比赛(MSD)的肺肿瘤数据集^[29]。该数据集的分割区域是肺部肿瘤,从肺癌患者的术前肺部CT扫描图像中获得。肺部肿瘤区域由专业肺科医生在CT横截面上注释。该数据集包括95张3D体积生物医学图像,其中63张带有专业医生标注的有标签数据,32张是无标注的CT图像。为了更好地提高分割效果,本文对数据集进行一系列预处理。

为了更好地增强对肺肿瘤特征的识别能力,将图像的Hounsfield单元(HU)调整为 $[-1\ 000, +400]$,并对每个数据进行重采样到 $[1.0, 1.0, 1.0]$,之后根据图像全局的平均值和方差将输入归一化到 $[0, 1]$ 内。此外,本研究对图像进行随机旋转、平移、翻转和仿射变换作为数据增强,以提高网络的通用性。最后,对训练集的数据在包含肺肿瘤目标的情况下随机裁剪到 $144 \times 144 \times 144$ 大小,可以有效地提升计算效率,减少算力消耗。

2.2 评价指标

本研究采用5个在3D医学图像分割任务中常用的评价指标来评估本文的方法性能,包括Dice系数(DSC)、JI系数(JI)、豪斯多夫距离(HD)、平均表面距离(ASD)以及相对体积差异(RVD)。首先DSC和JI用于评估预测分割结果和标签真实值之间的相似度,其取值范围为 $[0, 1]$,其值越接近1表示分割效果

越好,如下式所示:

$$\text{DSC} = \frac{2 \times |P \cap G|}{|P| + |G|} \quad (9)$$

$$\text{JI} = \frac{|P \cap G|}{|P \cup G|} \quad (10)$$

其中, P 代表模型预测的分割结果, G 代表标签真实值, $|P|$ 和 $|G|$ 分别代表 P 和 G 的体素数量。RVD用于衡量分割结果和参考标准之间分割体积大小的相对差异。其计算公式为:

$$\text{RVD} = \frac{|V_P - V_G|}{V_G} \times 100\% \quad (11)$$

其中, V_P 和 V_G 分别表示预测分割结果和对应真实标签的体积大小。此外,为了更准确地衡量分割效果,使用95HD和ASD来度量分割结果和真实标签之间体积表面的距离。这两个指标均能衡量分割器官表面形状和大小的差异,用于衡量体积边界的分割精度。

$$\text{ASD} = \frac{\sum_{s_P \in S(P)} d(s_P, S(G)) + \sum_{s_G \in S(G)} d(s_G, S(P))}{S(P) + S(G)} \quad (12)$$

$$\text{HD} = \max\left(\max_{s_P \in S(P)} d(s_P, S(G)), \max_{s_G \in S(G)} d(s_G, S(P))\right) \quad (13)$$

其中, $S(P)$ 和 $S(G)$ 分别表示预测结果和真实标签中所有的表面体素, $d(s_P, S(G))$ 表示 $S(P)$ 中的任意体素 s_P 到 $S(G)$ 中体素的最短距离, $d(s_G, S(P))$ 也是同理。95HD表示将参考标准表面到预测分割结果表面距离从小到大排序后,第95%处的值,这样可以确保指标不会被不合理的离群点影响。

2.3 实验配置

本文提出的框架在Pytorch上实现,在NVIDIA A6000 48 GB GPU上进行训练。设置batch size=4的批大小,包括两个无标注数据和两个有标注数据。本文使用Kaiming初始化来初始化模型的权重,使用Adam优化器用于优化网络,其学习率为0.01,权重衰减为 1×10^{-4} 。其次,训练中没有使用任何的预训练权重,整个训练过程进行了6 000次iteration。在推理阶段,将输入体积随机裁剪为 $144 \times 144 \times 144$ 送入推理网络中,最终的可视化预测分割结果由滑动窗口的策略得到,3个方向的步长都为32。

2.4 对比实验

本文提出的半监督分割框架与其他先进的3D医学图像半监督分割方法在MSD的肺肿瘤数据集上进行充分的对比实验,包括Mean teacher(MT)^[15]、Deep Adversarial Networks (DAN)^[17]、Uncertainty-aware self-ensembling (UA-MT)^[19]、Uncertainty Rectified Pyramid Consistency (URPC)^[22]和Dual Multi-scale

Mean Teacher (DMMT)^[28], 并使用相同的 3D U 型网络作为分割主干。在训练过程中, 分别使用数据集 中的 10 例和 30 例有标注数据作为半监督分割框架 中的有标签样本, 其余的数据作为训练过程中无标 签样本分别进行训练实验。在测试过程中, 使用与 训练样本不同的 13 例带标注数据作为测试集, 用 5 个评价指标充分评估本文方法的性能。此外, 本文 在相同的网络结构下与监督学习进行对比实验。同 样的, 在监督学习下也使用 10 例和 30 例标注数据 进行训练, 在 13 例测试集中进行测试, 并与 63 例 有标注数据全监督下实验进行对比, 以证明本文方 法可以对无标注的数据进行充分利用, 从无标注数 据中获取有意义的信息来提升分割的性能。

对比实验的结果如表 1 所示, 可以看出本文方法 在 10 例和 30 例有标注样本的情况下, DSC 都优 于其他半监督学习方法。由表 1 可以看出, 在 10 例和 30 例有标注样本的半监督实验条件下, 本文 方法的 DSC 分别达到 0.721 和 0.776, 相较于次优 的 URPC 半监督分割方法分别提升 1.4% 和 2.7%, 证明本文方法在相较于其他半监督学习方法上有着 明显的改进。此外, 与监督学习下的对比实验中, 在 相同数量标注数据的情况下, 所提半监督方法在结 果上有着巨大优势。即使在使用 63 例有标注样本 的全监督学习实验设置下, 本文的半监督方法在 主要指标 DSC 和 JI 也与全监督学习下实验的结 果相近, 说明本文方法可以有效利用无标注的数 据来提升分割结果。此外, 医学体积图像分割的不 确定区域大多集中在目标区域的边缘, 而本文的 RRP 方法会对不可靠的区域进行加权一致性学习, 获取更可靠 的一致性知识来优化半监督学习过程。本文的 ASD 和 95HD 指标在 10 例和 30 例有标注样本的设置下 明显优于其他先进的半监督学习方法, 证明本文方 法在分割体积图像的边界时, 有着更好的性能。

图 4 和图 5 分别展示在采用 30 例有标签样本 的半监督条件下, 不同半监督学习方法分割结果的 2D 和 3D 可视化结果。图 4 红色代表真实值, 白色代 表不同方法分割结果, 第一行表示不同方法分割预 测图, 第二行表示各个方法预测结果与真实值的重 合度对比。可以看出, 本文方法的分割结果(白色) 和真实值(红色)最为相似, 说明本文方法可以捕 捉到更多的细节, 而且假阳性区域较少。图 5 是 3D 可 视化结果, 红色代表分割结果, 绿色代表标签真实 值, 在两个例子上比较不同方法的分割结果和真实 标签的轮廓对比, 可以看出本文方法的分割结果与 边界轮廓更加契合, 具有更优越的边缘分割能力。 这些比较表明, 所提的半监督学习方法相较于其他 半监督方法可以更准确地分割 CT 图像中的肺部肿 瘤。

表 1 在肺肿瘤数据集上与其他先进半监督分割方法的性能比较
Table 1 Performance comparison with other state-of-the-art semi-supervised segmentation methods on the lung tumor dataset

方法	有标注 样本	无标注 样本	DSC	JI	ASD/ mm	95HD/ mm	RVD
监督训练	10	0	0.603	0.498	6.257	19.47	0.359
	30	0	0.659	0.543	5.892	17.24	0.238
	63	0	0.772	0.639	2.239	8.97	0.219
MT	10	73	0.643	0.538	5.075	23.48	0.709
DAN	10	73	0.658	0.557	5.931	22.71	0.715
UA-MT	10	73	0.677	0.563	5.707	14.14	0.628
URPC	10	73	0.707	0.594	5.237	17.58	0.482
DMMT	10	73	0.685	0.579	6.578	18.69	0.398
本文方法	10	73	0.721	0.611	4.720	17.39	0.329
MT	30	53	0.678	0.552	4.851	18.21	0.517
DAN	30	53	0.691	0.586	5.657	19.52	0.674
UA-MT	30	53	0.724	0.601	5.248	13.19	0.510
URPC	30	53	0.749	0.631	4.757	14.61	0.382
DMMT	30	53	0.739	0.592	5.432	14.05	0.448
本文方法	30	53	0.776	0.647	4.551	12.23	0.227

通过在不同尺度上不可靠区域的感知和一致性学 习的加权, 本文方法可以捕捉到更多的细节和一 致性信息来优化半监督学习过程。

2.5 消融实验

本节将讨论本文方法中 MCC 和 RRP 模块对最 后性能的影响。同样的, 消融实验中也分别设置 了 10 例有标注样本和 30 例有标注样本的不同监 督情况, 在肺肿瘤数据集上进行广泛的实验, 如表 2 所示。本文选择 URPC 网络设置作为消融实验 中的基线网络, DSC 和 JI 作为主要的参考指标来 评估本文半监督框架中这些模块的作用和优势。

由表 2 可以看出, 基线网络与 MCC 和 RRP 模 块结合后, 在不同的监督设置下都有性能的提升。 同时, 在半监督学习下加入 MCC 和 RRP 有着最好 的分割性能, 证明本文方法的有效性。如表 3 所 示, 本文进一步探索了由 θ 确定的区域可靠性阈 值的选择。在 30 例有标注样本的实验设置下, 当 阈值 θ 设置为 0.20 时, 模型在 DSC 指标上达到最 高的性能。此外, 本文进一步对 RRP 模块的有效 性进行特征图可视化验证。如图 6 所示, 加入 RRP 的模型预测结果中不确定的区域更少, 模型 预测的边界区域也更加紧凑和可信, 相对于普通 的全局一致性, 预测结果也更加接近真实标签。 这表明在一致性学习中加入 RRP 模块能够产生置 信度更高的预测, 更准确的分割目标边界等不可 靠区域从而提升最后的分割结果。




图 4 不同方法分割结果的可视化
Figure 4 Visualization of segmentation results of different methods




图 5 不同方法分割结果的 3D 可视化
Figure 5 3D visualization of segmentation results of different methods

表 2 肺肿瘤数据集上不同消融实验结果

Table 2 Results of different ablation studies on the lung tumor dataset

方法	MCC	RRP	10 例有标注样本		30 例有标注样本	
			DSC	JI	DSC	JI
Baseline	×	×	0.707	0.594	0.749	0.631
Baseline+MCC	√	×	0.714	0.604	0.765	0.640
Baseline+RRP	×	√	0.711	0.602	0.759	0.638
本文方法	√	√	0.721	0.611	0.776	0.647

表 3 不同可靠性阈值的实验结果

Table 3 Experimental results for different reliability thresholds

θ	DSC	JI
0.05	0.759	0.634
0.10	0.761	0.637
0.15	0.768	0.639
0.20	0.776	0.647
0.30	0.774	0.643

3 讨论

本文提出一种用于肺部肿瘤分割的半监督学习算法,可以在仅有少量标注数据的情况下,对无标注数据进行充分的利用,提升分割的结果和准确性。本文方法首先利用多尺度上的一致性约束来充分交换一致性学习的知识,避免了单一尺度上一致性学习的局限性。此外,提出 RRP 这样一种新颖的不确

定性估计策略,在区域级别优化预测结果,提升一致性学习的有效性,优化医学图像中不确定边界的分割效果。本文的半监督学习方法在 MSD 的肺部肿瘤数据集上实现了最好的 DSC 分数,优于其他先进的半监督学习方法,具有更好的分割性能。未来将继续探讨在其他医学图像分割中的应用,并探索在少量人工标注的情况下,进一步提升分割的精度,将算法应用到实际临床任务中去。




图6 特征图结果可视化

Figure 6 Visualization of feature map results

【参考文献】

- [1] 邓靓娜,周俊林. CT功能成像在肺癌中的研究进展[J]. 中国医学物理学杂志, 2023, 40(10): 1198-1203.
Deng LN, Zhou JL. A review on CT functional imaging in lung cancer [J]. Chinese Journal of Medical Physics, 2023, 40(10): 1198-1203.
- [2] 王雪,李占山,吕颖达. 基于多尺度感知和语义适配的医学图像分割算法[J]. 吉林大学学报(工学版), 2022, 52(3): 640-647.
Wang X, Li ZS, Lü YD. Medical image segmentation based on multi-scale context-aware and semantic adaptor [J]. Journal of Jilin University (Engineering and Technology Edition), 2022, 52(3): 640-647.
- [3] Wong CW, Chaudhry A. Radiogenomics of lung cancer[J]. J Thorac Dis, 2020, 12(9): 5104-5109.
- [4] Jiao RS, Zhang YC, Ding L, et al. Learning with limited annotations: a survey on deep semi-supervised learning for medical image segmentation[J]. Comput Biol Med, 2024, 169: 107840.
- [5] Luo XD, Wang GT, Liao WJ, et al. Semi-supervised medical image segmentation via uncertainty rectified pyramid consistency[J]. Med Image Anal, 2022, 80: 102517.
- [6] Wang YX, Zhang Y, Tian J, et al. Double-uncertainty weighted method for semi-supervised learning[C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2020. Cham: Springer International Publishing, 2020: 542-551.
- [7] Bai WJ, Oktay O, Sinclair M, et al. Semi-supervised learning for network-based cardiac MR image segmentation[C]//Medical Image Computing and Computer-Assisted Intervention-MICCAI 2017. Cham: Springer International Publishing, 2017: 253-260.
- [8] Luo XD, Hu MH, Song T, et al. Semi-supervised medical image segmentation via cross teaching between CNN and transformer[C]//Proceedings of The 5th International Conference on Medical Imaging with Deep Learning. Chia Laguna Resort, Sardinia, Italy: PMLR, 2022: 820-833.
- [9] Zhu Y, Zhang ZY, Wu CR, et al. Improving semantic segmentation via efficient self-training[J]. IEEE Trans Pattern Anal Mach Intell, 2024, 46(3): 1589-1602.
- [10] Chen XK, Yuan YH, Zeng G, et al. Semi-supervised semantic segmentation with cross pseudo supervision[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2021: 2613-2622.
- [11] Verma V, Kawaguchi K, Lamb A, et al. Interpolation consistency training for semi-supervised learning[J]. Neural Netw, 2022, 145: 90-106.
- [12] Xu MC, Zhou YK, Jin C, et al. Bayesian pseudo labels: expectation maximization for robust and efficient semi-supervised segmentation [C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2022. Cham: Springer Nature Switzerland, 2022: 580-590.
- [13] Wang YC, Wang HC, Shen YJ, et al. Semi-supervised semantic segmentation using unreliable pseudo-labels[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2022: 4238-4247.
- [14] Li YX, Chen JW, Xie XP, et al. Self-Loop uncertainty: a novel Pseudo-Label for semi-supervised medical image segmentation[C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2020. Cham: Springer International Publishing, 2020: 614-623.
- [15] Tarvainen A, Valpola H. Mean teachers are better role models: weight-averaged consistency targets improve semi-supervised deep learning results[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc., 2017: 1195-1204.
- [16] Ke ZH, Wang DY, Yan Q, et al. Dual student: breaking the limits of the teacher in semi-supervised learning[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway, NJ, USA: IEEE, 2019: 6727-6735.
- [17] Zhang YZ, Yang L, Chen JX, et al. Deep adversarial networks for biomedical image segmentation utilizing unannotated images[C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2017. Cham: Springer International Publishing, 2017: 408-416.
- [18] Liu SD, Liu CP, Ji Y, et al. Regional consistency for semi-supervised segmentation of 3D medical images[J]. IEEE Signal Process Lett, 2023, 30: 1307-1311.
- [19] Yu LQ, Wang SJ, Li XM, et al. Uncertainty-aware self-ensembling model for semi-supervised 3D left atrium segmentation[C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2019. Cham: Springer International Publishing, 2019: 605-613.
- [20] Shi YH, Zhang J, Ling T, et al. Inconsistency-aware uncertainty estimation for semi-supervised medical image segmentation[J]. IEEE Trans Med Imaging, 2022, 41(3): 608-620.
- [21] Cao C, Lin TW, He DL, et al. Adversarial dual-student with differentiable spatial warping for semi-supervised semantic segmentation[J]. IEEE Trans Circuits Syst Video Technol, 2023, 33(2): 793-803.
- [22] Luo XD, Liao WJ, Chen JN, et al. Efficient semi-supervised gross target volume of nasopharyngeal carcinoma segmentation via uncertainty rectified pyramid consistency [C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2021. Cham: Springer International Publishing, 2021: 318-329.
- [23] 赵林林,王潜,王军,等. 基于深度学习的肢体骨肉瘤CT医学图像分割[J]. 中国医学物理学杂志, 2023, 40(10): 1204-1211.
Zhao LL, Wang Q, Wang J, et al. Deep learning based approach for extremity osteosarcoma segmentation in CT image [J]. Chinese Journal of Medical Physics, 2023, 40(10): 1204-1211.
- [24] Zhu WT, Huang YF, Zeng L, et al. AnatomyNet: deep learning for fast and fully automated whole-volume segmentation of head and neck anatomy[J]. Med Phys, 2019, 46(2): 576-589.
- [25] Luo YC, Zhu J, Li MX, et al. Smooth neighbors on teacher graphs for semi-supervised learning [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2018: 8896-8905.
- [26] Wang KP, Zhan B, Zu C, et al. Semi-supervised medical image segmentation via a tripled-uncertainty guided mean teacher model with contrastive learning[J]. Med Image Anal, 2022, 79: 102447.
- [27] Zhu J, Bolsterlee B, Chow BV, et al. Hybrid dual mean-teacher network with double-uncertainty guidance for semi-supervised segmentation of magnetic resonance images[J]. Comput Med Imaging Graph, 2024, 115: 102383.
- [28] Wang LS, Wang JC, Zhu L, et al. Dual multiscale mean teacher network for semi-supervised infection segmentation in chest CT volume for COVID-19[J]. IEEE Trans Cybern, 2023, 53(10): 6363-6375.
- [29] Simpson AL, Antonelli M, Bakas S, et al. A large annotated medical image dataset for the development and evaluation of segmentation algorithms[EB/OL]. (2019-02-25). <https://arxiv.org/abs/1902.09063>.

(编辑:薛泽玲)