

DOI:10.3969/j.issn.1005-202X.2023.09.010

医学影像物理

基于3DSEU-Net不确定性循环焦点平均教师的半监督脑肿瘤分割

段逸凡, 肖洪兵, Rahman Md Mostafizur
北京工商大学人工智能学院, 北京 100048

【摘要】准确、完整地定位和分割脑肿瘤对脑胶质瘤患者的存活率以及治疗方案的确定起着决定性作用。在三维核磁共振影像(MRI)中,生成准确的注释需要大量的专业知识和时间成本,使用少量有标签数据与大量无标签数据进行半监督学习更加符合实际的临床场景与需求。为此,本文提出一种3DSEU-Net作为半监督模型中的教师与学生网络,该网络引入注意力计算,同时结合跳跃连接,以便获取三维医学影像中更加丰富鲁棒的结构与细节特征,训练过程中,教师模型通过不确定性量化,然后指导学生模型,使学生模型学习到置信度更高的结果,在仅有少量有标签数据的情况下学习到更多的知识,以提升模型的脑肿瘤分割精度。在仅有25个有标签数据的情况下,分割精度比全监督学习提升了12.9%,最高分割精度达81.41%,优于目前可同基准复现的6种半监督方法,证明了本文方法的可行性和有效性。

【关键词】三维卷积神经网络;通道注意力;半监督学习;脑肿瘤分割;循环焦点损失

【中图分类号】R318;TP183

【文献标志码】A

【文章编号】1005-202X(2023)09-1121-06

Semi-supervised learning for brain tumor segmentation through 3DSEU-Net as uncertainty-aware mean teacher and cyclical focal loss

DUAN Yifan, XIAO Hongbing, Rahman Md Mostafizur

School of Artificial Intelligence, Beijing Technology and Business University, Beijing 100048, China

Abstract: The accurate localization and segmentation of brain tumors greatly affects the survival rate of glioma patients and the determination of treatment schemes. Generating accurate annotations in three-dimensional (3D) magnetic resonance imaging (MRI) requires a lot of professional knowledge and is time-consuming. The semi-supervised learning using a small amount of labeled data and a large amount of unlabeled data is more practical in clinic. Herein a 3DSEU-Net in which squeeze and excitation block is introduced and combined with skip connections is proposed as teacher and student networks in the semi-supervised model, so that the richer and more robust structural and detailed features can be extracted from 3D medical image. During training, the teacher model guides the student model by quantifying uncertainties, which makes the student model learn the results with higher degree of confidence. The proposed model is able to learn more knowledge under the condition that only a small amount of labeled data is available, thereby improving the segmentation accuracy of brain tumors. In the case of only 25 labeled data, the proposed method improves segmentation accuracy by 12.9% over fully supervised learning, and has a highest segmentation accuracy of 81.41%, outperforming 6 semi-supervised methods currently reproducible on the same benchmark. These results verify the feasibility and effectiveness of the proposed method.

Keywords: three-dimensional convolutional neural network; squeeze and excitation; semi-supervised learning, brain tumor segmentation; cyclical focal loss

前言

【收稿日期】2023-05-06

【基金项目】北京市自然科学基金-北京市教育委员会科技计划重点联合项目(KZ202110011015)

【作者简介】段逸凡,在读研究生,研究方向:图像处理、机器学习,E-mail: 1106811434@qq.com

【通信作者】肖洪兵,博士,副教授,研究生导师,研究方向:图像处理与模式识别,E-mail: x.hb@163.com

近年来,肿瘤的发病率呈逐年上升趋势。神经胶质瘤在成人脑肿瘤患者中最为常见,约占据所有常见脑肿瘤的40%,而大约78%的恶性脑肿瘤是神经胶质瘤,神经胶质瘤细胞弥漫性浸润生长,无明确边界,无限增殖,并具有高度侵袭性,即使是专家也很难精确分割。因此,脑肿瘤分割是医学影像分析中最具挑战性的问题之一,找到有效的脑肿瘤早期检测与诊断方案对脑肿瘤的治疗至关重要,脑肿瘤分割需要生成脑肿瘤区域的精确轮廓,但由于脑部

结构复杂,因而很难保证分割精度。

近年来,深度学习方法在解决各种计算机视觉问题,如图像分类、目标检测和语义分割等方面表现出了良好的性能。但是深度神经网络的训练质量受训练集中有标签样本数目影响,而在3D MRI中生成准确的注释需要大量的专业知识和时间成本,因此基于少量有标签样本和大量无标签样本的半监督学习更适用于真实场景中的应用^[1]。许多半监督学习方法已经用于医学影像分析中,包括给无标签数据加入预测标签的伪标签方法^[2-4],基于分歧的深度协同训练方法^[5],网络相互对抗的深度对抗学习方法^[6],由教师和学生组成的平均教师方法^[7-8],多个任务并行学习的多任务学习方法^[9],能找出错误标签的置信学习方法^[10],以及通过学习相似数据的对比学习方法^[11]等,这些方法都结合了有标签数据和无标签数据,训练出强大鲁棒的卷积神经网络(Convolutional Neural Network, CNN)模型,其中平均教师模型在医学图像分割中展现了强大的学习能力。

由于CNN模型在医学任务中取得了非常有前景的结果,因此目前的医学影像分割大部分基于U-Net及其变体^[12]。基于CNN的模型具有非常出色的表达能力,加入跳跃连接的U-Net网络能够捕捉到大量的医学影像细节信息,但是却缺乏对全局和长期语义信息交互建模的能力,基于注意力机制的Transformer能对全局依赖关系建模,但是却依赖大量数据驱动,因此,出现了大量CNN与Transformer相结合的变体,如Swin-UNet^[13]、TransUNet^[14]、CoTr^[15]、UNETR^[16]、nnFormer^[17]等,这些变体表明在CNN中引入注意力机制可以有效提升模型的分割精度。

本文在以上思想的启发下,提出以3DSEU-Net作为教师与学生网络模型,在下采样过程中引入通道注意力计算(Squeeze and Excitation, SE)模块^[18],既通过跳跃连接捕捉医学影像细节信息,同时利用注意力模块对全局依赖关系建模。此外,使用不确定性循环焦点半监督框架,利用大量无标签数据与少量有标签数据学习脑肿瘤知识,并通过循环焦点损失(Cyclical Focal Loss, CFL)消除脑肿瘤样本数据不平衡所带来的不利影响^[19]。

1 方法

本文提出的半监督学习框架基于3DSEU-Net网络结构,由学生模型和教师模型组成,教师模型权重使用学生模型的指数移动平均值(Exponential Moving Average, EMA),学生模型通过最小化教师模型的循环焦点分割损失和一致性损失来学习教师模型,同时教师模型利用蒙特卡罗抽样方法估计每个目标预测的不确定性。在计算一致性损失时,以估

计的不确定性为指导,过滤掉不可靠的预测,使学生模型获得更可靠的监督,反过来指导教师模型产生更高质量的分割结果。提出的3DSEU-Net不确定性循环焦点半监督框架结构如图1所示。




图1 3DSEU-Net不确定性循环焦点半监督框架
Figure 1 Semi-supervised framework based on 3DSEU-Net as uncertainty-aware mean teacher and cyclical focal loss

1.1 3DSEU-Net

本文提出的网络结构3DSEU-Net如图2所示,编码器和解码器结构与U-Net类似,由4层3DSE最大池化下采样模块、4层3D反卷积块与4条连接上下采样的跳跃连接组成。

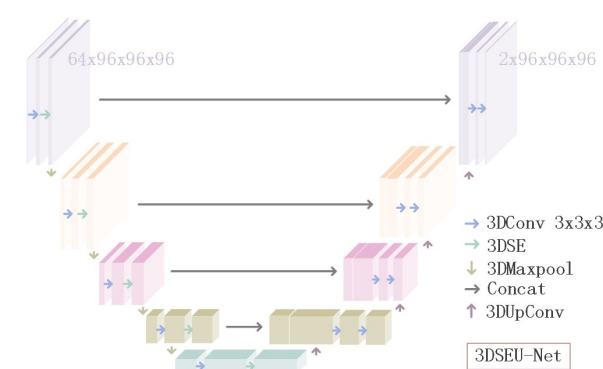


图2 3DSEU-Net
Figure 2 3DSEU-Net

网络使用3D卷积模块,并在下采样过程中引入通道注意力计算,3DSE最大池化下采样模块如图3所示,首先采用3D自适应全局池化(平均池化)层将特征图压缩,两个3D全连接层对特征向量进行映射变换,生成通道维度注意力权值矩阵,将得到的权值矩阵与通道进行逐通道相乘,最后通过3D最大池化层下采样输出特征图。

1.2 半监督学习

半监督学习通过对大量无标签样本中的脑肿瘤




图3 3DSE模块
Figure 3 3DSE block

先验知识进行学习,同时学习少量有标签样本的监督信息。训练集 X 由 N 个有标签数据 $X_l = \{x_i, y_i\}_{i=1}^N$ 与 $M+N$ 个无标签数据 $X_u = \{x_i\}_{i=1}^{M+N}$ 组成,在训练集 X 中加入随机噪声,分别输入网络结构(3DSEU-Net)相同的教师与学生模型,为了克服时间集成的局限性,相对于直接使用最终权重,平均模型权重能产生更精确的模型。因此,教师模型使用学生模型的EMA权重进行在线学习,能获得更好的中间表示。框架总期望函数如式(1)所示:

$$F = \min_{\theta} \sum_{i=1}^N L_{\text{CFL}}(F(x_i; \theta), y_i) + \lambda \sum_{i=1}^{N+M} L_{\text{CON}}(F_T(x_i; \theta', \xi'), F_S(x_i; \theta, \xi)) \quad (1)$$

其中,第一项为循环焦点监督损失 L_{CFL} ,用于有标签数据部分的监督学习,第二项为一致性损失 L_{CON} ,用于衡量教师模型与学生模型输出间的一致性。 $F(x_i; \theta)$ 表示网络在权值为 θ 时监督学习的输出, y_i 为有标签数据中的标签数据(真实分割结果), λ 为监督与无监督梯度加权平衡系数, $F_T(x_i; \theta', \xi')$ 表示教师网络在权值与扰动为 θ' 和 ξ' 时的输出, $F_S(x_i; \theta, \xi)$ 表示学生网络在权值与扰动为 θ 和 ξ 时的输出。教师模型 θ' 为学生模型权值 θ 的EMA, θ'_t 为第 t 步的更新方式,如式(2)所示:

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

其中, α 为平滑系数。

使用蒙特卡罗 Dropout 来估计样本的不确定性^[20],其基本原理是:事件的概率可以用大量试验中发生的频率来估计,当样本容量足够大,可以认为该事件的发生频率即为其概率。以体素水平估计整个体积 U 的不确定度 u ,如式(3)所示:

$$u = -\sum_c \mu_c \log \mu_c \quad (3)$$

每个输入在 Dropout 和高斯噪声的情况下对教师模型进行 T 随机正向传递。其中 μ_c 为预测熵,如式(4)所示:

$$\mu_c = \frac{1}{T} \sum_t P_t^c \quad (4)$$

其中, P_t^c 为第 t 次预测中第 c 类的概率。

1.3 损失函数

在大部分网络监督学习中都使用交叉熵损失(Cross Entropy Loss, CE)进行训练, Lin 等^[21]对 CE 进行修改,提出了焦点损失(Focal Loss, FL),增加了神经网络训练在错误和难分类的数据样本中的关注度,当存在每类训练样本数量、前景背景不平衡或多标签分类中正负标签不平衡时,FL 优于 CE。在 FL 中加入循环因子构成 CFL,在前期依据自信训练样本进行网络权值更新,难分样本的训练在中期进行,以提高泛化能力,训练后期是自信样本的微调阶段,以学习到更复杂的样本特征模式信息。 L_{CFL} 为循环焦点监督损失,如式(5)所示:

$$L_{\text{CFL}} = \zeta L_{\text{hc}} + (1 - \zeta) L_{\text{lc}} \quad (5)$$

其中, ζ 为随训练时间变化的权值,计算如式(6)所示:

$$\zeta = \begin{cases} 1 - f_c \frac{e_i}{e_n}, & f_c \times e_i \leq e_n \\ \frac{f_c \frac{e_i}{e_n} - 1}{f_c - 1}, & \text{其他} \end{cases} \quad (6)$$

其中, e_i 为当前训练 epoch 数, e_n 为总训练 epoch 数, f_c 为循环因子,为循环提供可变性。

L_{hc} 为高置信度训练样本损失,如式(7)所示:

$$L_{\text{hc}} = -(1 + p_i)^{\gamma_c} \log(p_i) \quad (7)$$

L_{lc} 为低置信度训练样本损失,如式(8)所示:

$$L_{\text{lc}} = -(1 - p_i)^{\gamma_c} \log(p_i) \quad (8)$$

其中, p_i 为样本置信度概率, γ_c 为 FL 权重,当设置为 0 时焦点损失等同于 CE。

L_{CON} 为不确定一致性损失,如式(9)所示:

$$L_{\text{CON}} = \frac{\sum_v \Pi(u_v < H) \|f'_v - f_v\|^2}{\sum_v \Pi(u_v < H)} \quad (9)$$

其中, f'_v 和 f_v 分别为教师模型和学生模型在第 v 个体素上的预测, u_v 为第 v 个体素处估计的不确定度, H 为置信度阈值。

2 实验结果与分析

2.1 数据集与预处理

所有的实验和比较都基于 BraTS 2019 公共数据集^[22-24],包含 335 个胶质瘤病例,其中有 259 位高级别胶质瘤患者,76 位低级别胶质瘤患者。数据标签共 4 类,即肿瘤增强区、水肿区、坏死区以及健康组织。

分割结果通过完整肿瘤(Whole Tumor, WT)指标评估。WT包括肿瘤增强区、水肿区以及坏死区。每位患者数据包含5种模态的图像,分别是flair、 T_1 、 T_1 CE

和 T_2 共4种MRI模态,以及专家手动分割用于比较的金标准(seg),如图4所示。

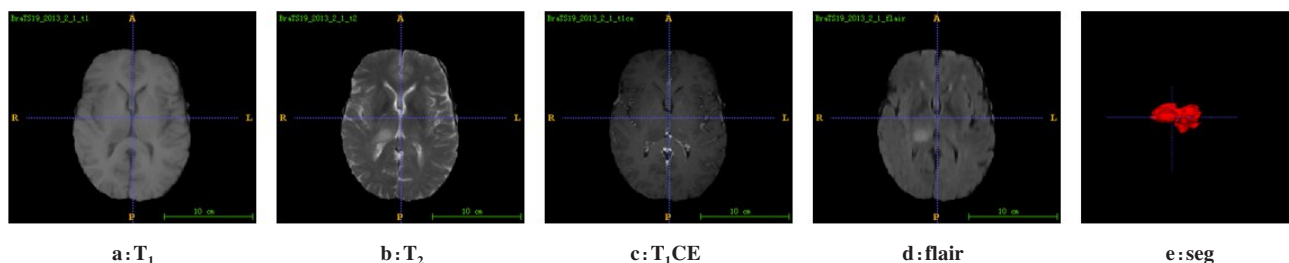


图4 5种模态的图像

Figure 4 Five-modal images

实验将数据集随机分为训练集(250个训练样本)、测试集(60个训练样本)和验证集(25个样本),所有样本都以脑部区域为中心进行随机裁剪,使用标准数据增强来扩大训练集的规模,避免过拟合,包括随机旋转、随机翻转,并归一化为零均值和单位方差。

实验环境搭载在一台操作系统为Centos7.6, 32核心2.5 GHz主频的x86处理器和4块7285DCU服务器上,编程语言为Python3.6,深度学习框架为Pytorch1.8.0-rocm4.0.1。

2.2 评价标准

实验使用医学图像分割中的经典模型评价指标Dice相似系数(Dice Similarity Coefficient, DSC)、相对体积差(Relative Volume Difference, RVD)、豪斯多夫距离(Hausdorff_95%, HD95)以及平均表面距离(Average Symmetric surface Distance, ASD)进行分割结果评价。

DSC表示两个物体相交的面积占总面积的比值,越接近1代表分割越精确,计算公式如式(10)所示:

$$DSC = \frac{2 \times (\text{pre} \cap \text{gt})}{\text{pre} + \text{gt}} \quad (10)$$

其中,pre为模型输出的分割结果,gt为样本数据的真实标签。

RVD表示两者体积之间的差异,数学定义如式(11)所示:

$$RVD = \frac{|\text{pre}| - |\text{gt}|}{|\text{gt}|} \quad (11)$$

HD95用来计算两个集合之间的距离,值越小,代表两个集合的相似度越高,将距离从大到小排列后,取排名前5%的距离。计算公式如式(12)所示:

$$HD = \max(h(\text{pre}, \text{gt}), h(\text{gt}, \text{pre})) \quad (12)$$

其中,

$$h(\text{pre}, \text{gt}) = \max_{p \in \text{pre}} \left\{ \min_{g \in \text{gt}} \|p - g\| \right\} \quad (13)$$

$$h(\text{gt}, \text{pre}) = \max_{g \in \text{gt}} \left\{ \min_{p \in \text{pre}} \|g - p\| \right\} \quad (14)$$

ASD用于计算默认设置下从模型输出的分割结果到样本数据的真实标签的平均表面距离,代表分割结果与真实值之间的表面变化,如式(15)所示:

$$ASD = \frac{1}{|\text{pre}| + |\text{gt}|} \left(\sum_{p \in \text{pre}} \min_{g \in \text{gt}} \|p - g\| + \sum_{g \in \text{gt}} \min_{p \in \text{pre}} \|g - p\| \right) \quad (15)$$

2.3 实验结果

2.3.1 消融研究 在实验中,分别控制各模块进行独立研究,从网络结构到半监督框架分别进行测试,研究测试中共有25个有标签数据样本与225个无标签数据样本,测试结果如表1所示。

从表1的实验结果可以看出,当使用全监督学习时,分割精度(DSC)仅为68.51%,加入半监督学习后精度有了明显提升,说明半监督框架可以有效地从大量无标签数据中学习到广泛的脑肿瘤信息。表中数据显示,在3DU-Net网络中加入通道注意力3DSE模块后,能够有效捕捉到通道维度的关联,填补了U-Net网络对全局和长期信息的关注,有效提升了分割精度。同时可以看出,在损失函数中引入循环焦点计算后,分割精度均有所提升,说明在不同训练时期,对不同置信度样本特征进行加权,能够有效帮助模型对样本特征进行更好的学习。

2.3.2 与基线网络对比结果 为了证实本文所提方法的有效性,首先测试了全监督(Fully Supervised, FS)学习网络3DU-Net的性能,并对比了目前比较经典的6种半监督学习网络模型:平均教师(Mean Teacher, MT)模型^[7]、不确定性平均教师(Uncertainty Aware

表1 消融研究测试结果
Table 1 Ablation study results

框架	网络	DSC/%	RVD/%	HD95/mm	ASD/mm
全监督学习方法	3DU-Net	68.51	0.410 8	37.998	2.590
	3DSEU-Net	69.15	0.340 3	36.985	2.421
半监督学习方法					
平均教师	3DU-Net	77.65	0.387 6	27.713	2.249
	3DSEU-Net	78.04	0.340 7	27.101	2.368
循环焦点平均教师	3DU-Net	79.67	0.366 2	24.967	2.464
	3DSEU-Net	80.72	0.359 0	23.421	2.422
不确定性平均教师	3DU-Net	79.99	0.385 1	23.769	2.440
	3DSEU-Net	81.13	0.306 4	24.473	2.257
不确定循环焦点平均教师	3DU-Net	80.92	0.307 6	20.422	2.229
	3DSEU-Net	81.41	0.305 4	20.160	2.228

Mean Teacher, UAMT)模型^[8]、深度对抗网络(Deep Adversarial Network, DAN)^[6]、交叉伪监督(Cross Pseudo Supervision, CPS)^[3]、插值一致性训练(Interpolation Consistency Training, ICT)^[25]、最小熵(Entropy Minimization, EM)^[10]。本文方法与6种半监督学习网络模型分割结果对比如图5所示。

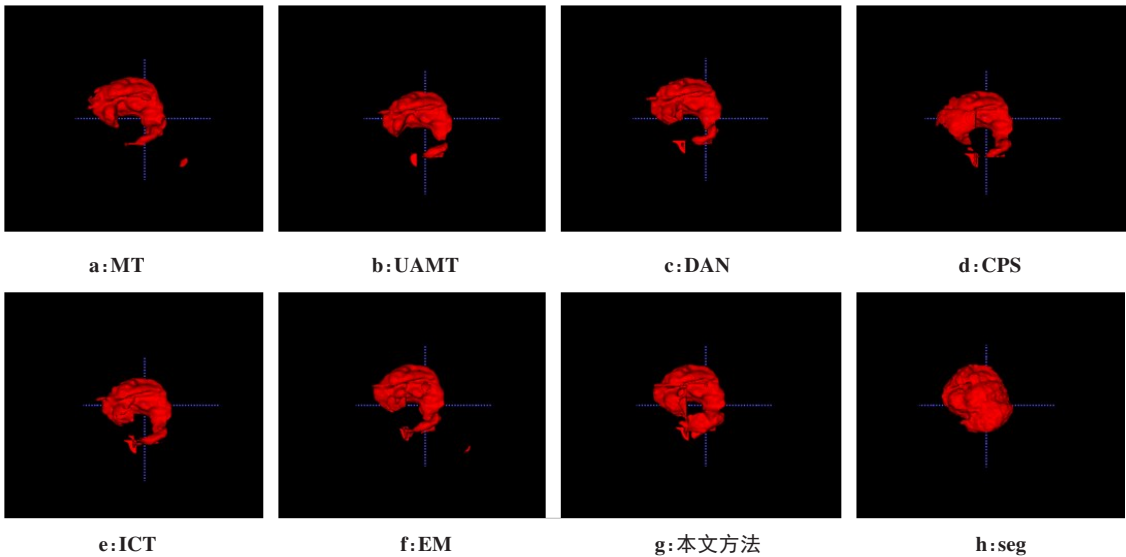


图5 分割结果对比图
Figure 5 Segmentation result comparison

为了比较的公平性,实验中均采用相同的数据集进行测试,取每种方法的最优结果,测试结果如表2所示。从表2的实验结果可以看出,本文提出的方法相较于6种半监督方法有明显提升,最高分割精度达81.41%,较FS模型提升12.9%,平均HD95也降低了17.838 mm。表2结果表明循环焦点损失配合不确定性计算,能够更有效地捕捉到脑肿瘤数据中的肿瘤特征信息,并消除脑肿瘤数据不平衡对网络产生的不利影响,同时在网络中加入通道注意力模块,能

够弥补3D医学影像数据缺失的通道间的关联信息,以及长期语义信息,使网络拥有四维数据特征信息,以实现更精确的三维脑肿瘤分割。

3 结 论

本文尝试在监督与无监督学习中将循环因子与不确定性相结合,提出一种不确定循环焦点平均教师半监督框架,通过在不同训练时期对不同置信度样本特征进行加权,使模型能更有效地学习到数据

表2 本文方法与7种经典模型的实验结果对比

Table 2 Experimental results of the proposed method and other 7 algorithms

网络模型	DSC/%	RVD/%	HD95/mm	ASD/mm
FS	68.51	0.410 8	37.998	2.590
MT	77.65	0.387 6	27.713	2.249
UAMT	79.99	0.385 1	23.769	2.440
DAN	80.33	0.386 5	24.554	2.429
CPS	80.90	0.342 2	25.054	2.400
ICT	80.83	0.343 7	22.093	2.272
EM	80.76	0.409 3	20.445	2.393
本文方法	81.41	0.305 4	20.160	2.228

集中有限的标签指导信息,以及无标签数据中广泛的脑肿瘤先验知识。并尝试在3DCNN中加入注意力机制,对缺失的通道维度关联信息建模,提出教师与学生网络使用相同的3DSEU-Net网络结构,在U型网络下采样过程中引入3DSE模块,计算通道注意力后,对特征进行加权,使网络更加关注肿瘤部分,同时拥有4个维度脑肿瘤分割特征信息。在仅有25个有标签数据和225个无标签数据的情况下,获得了81.41%的分割精度,同时HD95仅有20.16 mm。对比实验结果表明,本文提出的方法学习性能优于目前流行的半监督方法。未来工作将尝试结合3DCNN与Transformer,探索半监督学习框架下脑肿瘤分割的可行性和有效性。

【参考文献】

[1] 吕昊远,俞璐,周星宇,等. 半监督深度学习图像分类方法研究综述[J]. 计算机科学与探索, 2021, 15(6): 1038-1048.
Lü HY, Yu L, Zhou XY, et al. Review of semi-supervised deep learning image classification methods[J]. Journal of Frontiers of Computer Science & Technology, 2021, 15(6): 1038-1048.

[2] Bai W, Oktay O, Sinclair M, et al. Semi-supervised learning for network-based cardiac MR image segmentation[C]//International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2017: 253-260.

[3] Chen X, Yuan Y, Zeng G, et al. Semi-supervised semantic segmentation with cross pseudo supervision[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021: 2613-2622.

[4] Wang G, Zhai SW, Lasio G, et al. Semi-supervised segmentation of radiation-induced pulmonary fibrosis from lung CT scans with multi-scale guided dense attention[J]. IEEE Trans Med Imaging, 2022, 41(3): 531-542.

[5] Zhou Y, Wang Y, Tang P, et al. Semi-supervised 3D abdominal multi-organ segmentation via deep multi-planar co-training[C]//2019 IEEE Winter Conference on Applications of Computer Vision (WACV).

IEEE, 2019: 121-140.

[6] Zhang Y, Yang L, Chen J, et al. Deep adversarial networks for biomedical image segmentation utilizing unannotated images[C]//International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2017: 408-416.

[7] Tarvainen A, Valpola H. Mean teachers are better role models: weight-averaged consistency targets improve semi-supervised deep learning results[J]. arXiv preprint arXiv: 1703.01780, 2017.

[8] Yu L, Wang S, Li X, et al. Uncertainty-aware self-ensembling model for semi-supervised 3D left atrium segmentation[C]//International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2019: 605-613.

[9] Luo XD, Chen JN, Song T, et al. Semi-supervised medical image segmentation through dual-task consistency[C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2020.

[10] Vu TH, Jain H, Bucher M, et al. ADVENT: adversarial entropy minimization for domain adaptation in semantic segmentation[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019: 2517-2526.

[11] Peng J, Wang P, Desrosiers C, et al. Self-paced contrastive learning for semi-supervised medical image segmentation with meta-labels[J]. Adv Neural Inf Process Syst, 2021, 34: 16686-16699.

[12] 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. Cham: Springer, 2015: 234-241.

[13] Cao H, Wang Y, Chen J, et al. Swin-UNet: UNet-like pure transformer for medical image segmentation[J]. arXiv preprint arXiv: 2105.05537, 2021.

[14] Chen J, Lu Y, Yu Q, et al. TransUNet: transformers make strong encoders for medical image segmentation[J]. arXiv preprint arXiv: 2102.04306, 2021.

[15] Xie Y, Zhang J, Shen C, et al. CoTr: efficiently bridging CNN and transformer for 3D medical image segmentation[J]. arXiv preprint arXiv: 2103.03024, 2021.

[16] Hatamizadeh A, Tang Y, Nath V, et al. UNetr: transformers for 3D medical image segmentation[C]//Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision. 2022: 574-584.

[17] Zhou HY, Guo J, Zhang Y, et al. nnFormer: interleaved transformer for volumetric segmentation[J]. arXiv preprint arXiv: 2109.03201, 2021.

[18] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[J]. IEEE Trans Pattern Anal Mach Intell, 2020, 42(8): 2011-2023.

[19] Smith LN. Cyclical focal loss[J]. arXiv preprint arXiv: 2202.08978, 2022.

[20] Kendall A, Gal Y. What uncertainties do we need in bayesian deep learning for computer vision?[J]. arXiv preprint arXiv: 1703.04977, 2017.

[21] Lin TY, Goyal P, Girshick R, et al. Focal loss for dense object detection[C]//Proceedings of the IEEE International Conference on Computer Vision. 2017: 2980-2988.

[22] Menze BH, Jakab A, Bauer S, et al. The multimodal brain tumor image segmentation benchmark (BRATS)[J]. IEEE Trans Med Imaging, 2014, 34(10): 1993-2024.

[23] Bakas S, Akbari H, Sotiras A, et al. Advancing the cancer genome atlas glioma MRI collections with expert segmentation labels and radiomic features[J]. Sci Data, 2017, 4(1): 1-13.

[24] Bakas S, Reyes M, Jakab A, et al. Identifying the best machine learning algorithms for brain tumor segmentation, progression assessment, and overall survival prediction in the BRATS challenge[J]. arXiv preprint arXiv: 1811.02629, 2018.

[25] Verma V, Kawaguchi K, Lamb A, et al. Interpolation consistency training for semi-supervised learning[J]. arXiv preprint arXiv: 1903.03825, 2019.

(编辑:薛泽玲)