

基于形状引导和不确定性估计的 半监督三维医学图像分割

宋文彪^{1,2}, 许叶彤^{1,2}, 王 毅^{1,2}, 杜晓刚^{1,2}, 雷涛^{1,2†}

(1. 陕西科技大学 电子信息与人工智能学院, 陕西 西安 710021;

2. 陕西科技大学 陕西省人工智能联合实验室, 陕西 西安 710021)

摘 要:在基于深度学习方法的医学图像分割任务中,通常需要大量的标记数据。然而,获得可靠的标注是昂贵且耗时的。为此,提出了一种新的框架,采用具有形状约束和不确定性估计的双一致性正则化半监督方法,用于 3D 医学图像分割。首先,引入了一种基于学习目标区域的形状约束,通过联合学习两个网络的输出,加强几何形状约束,从而学习更可靠的信息。其次,设计了一种分割网络,以生成不同尺度的特征图,并引入了多尺度一致性损失来增强其稳定性。然而,由于这些特征图的空间分辨率不同,直接在每个像素上强制一致性可能导致不可靠的结果和信息丢失。因此,进一步提出了一种基于不确定性估计的多尺度一致性学习,以逐步学习有意义和可靠的特征区域,并增强模型的鲁棒性。实验结果表明,由于强大的无标记数据的知识挖掘能力,本文所提出的方法优于流行的半监督医学图像分割方法。

关键词:3D 医学图像分割;半监督学习;形状约束;不确定性估计

中图分类号:TP3

文献标识码:A

Semi-Supervised 3D Medical Image Segmentation Based on Shape Guidance and Uncertainty Estimation

SONG Wenbiao^{1,2}, XU Yetong^{1,2}, WANG Yi^{1,2}, DU Xiaogang^{1,2}, LEI Tao^{1,2†}

(1. School of Electronic Information and Artificial Intelligence, Shaanxi University of Science and Technology, Xi'an, Shaanxi 710021, China; 2. Shaanxi Joint Laboratory of Artificial Intelligence, Shaanxi University of Science and Technology, Xi'an, Shaanxi 710021, China)

Abstract: In medical image segmentation tasks based on deep learning methods, a large amount of labeled data is often required. However, obtaining reliable annotations is expensive and time-consuming. To solve the above problems, a new framework is proposed for 3D medical image segmentation using a biconsistent regularized semi-supervised method with shape constraints and uncertainty estimation. Firstly, a shape constraint based on the learning target region is introduced, and the geometric constraint is strengthened by jointly learning the output of the two networks, so as to learn more reliable information. Secondly, a segmentation network is designed to generate feature maps at different scales, and multi-scale consistency loss is introduced to enhance its stability. However, due to the different spatial resolutions of these feature maps, forcing consistency directly on each pixel can lead to unreliable results and loss of information. Therefore, a multi-scale consistent learning based on uncertainty estimation is further proposed to gradually learn meaningful and reliable feature regions and enhance the robustness of the model. Experimental results show that the proposed method is superior to the popular semi-supervised medical image segmentation method due to the powerful knowledge mining ability of label-free data.

Key words: 3D medical image segmentation; semi-supervised learning; shape constraints; uncertainty estimates

在医学实践中,精准自动地分割解剖结构或病变对于图像引导干预、放射治疗、计算机辅助诊断等^[1]非常关键。随着深度学习的发展,许多图像分割方法已被证明在促进医学图像定量分析方面具有有效性。然而,这些方法通常需要大量高质量标注数据才能以全监督方式进行设计。手动标注大量医学图像是昂贵和耗时的,尤其是对于三维图像,如 CT 和 MRI 扫描等。因此,开发半监督分割技术来减少对精细标记数据的依赖是必要的。

在医学图像分割领域,近年来出现了许多半监督方法^[2-5],旨在通过利用无标记数据中的信息来提高分割性能。虽然这些方法已经取得了不错的效果,但仍然面临以下两个主要挑战:

(1)在训练具有大量参数和复杂结构的 3D 卷积神经网络时,由于只使用少量标记数据和大量无标记数据^[6],因此难以充分利用从无标记数据中提取的目标区域几何约束。此外,缺乏对边界距离信息的明确建模,通常会导致目标边界较为模糊或孤立的小目标区域不完整。

(2)现有的一些半监督方法^[7]可以利用模型置信度来提高训练稳定性并实现更好的结果,但大多数方法需要通过蒙特卡罗采样^[8]来估计每个目标预测的不确定性,这意味着需要进行多次前向传递才能在每次迭代中获得不确定性,因此计算成本较高。

为了解决上述问题,提出了一种新的框架,采用具有形状约束和不确定性估计的双一致性正则化方法。该框架可以表示为两个单独网络的集成,它们具有相同的编码器和不同的解码器,并且利用分割网络的多尺度预测来捕捉不确定性。本文的主要贡献如下:

(1)建立分割模型和回归模型之间的一致性,通过联合学习两个模型的输出结果使网络能够同时考虑到形状约束和边界信息,从而准确地预测目标的形状表示,并利用未标记数据的边界信息,增强网络对目标在低维空间中形状表示能力的预测。

(2)设计分割模型生成多尺度预测,并通过比较这些预测之间的差异来估计感知不确定性。相较于蒙特卡罗采样估计不确定性的方法,本文方法只需要进行一次前向传递,降低了计算成本。利用这种估计的不确定性作为指导,模型可以自动强调可靠预测(即低不确定性)并减弱不可靠预测(即高不确定性),以实现多尺度一致性。

(3)本文的方法在公共左心房数据集上进行了广泛评估,结果表明,通过充分利用未标记数据和标记数据,该方法在性能方面优于现有半监督

方法。

1 相关工作

1.1 半监督医学图像分割

半监督学习方法的主要思路是利用未标记数据来挖掘有效的隐藏信息,从而提高性能。它基于三个核心假设^[9]:平滑性假设、低密度假设和流形假设。其中,平滑性假设表明相似的输入应该产生相似的输出;低密度假设表明同一类别的样本在特征空间中往往形成一个聚类,而不同类别的决策边界应该只穿过特征空间中的低密度区域;流形假设表明位于同一低维流形上的样本应该属于同一类别。

根据这些核心假设,现有的半监督医学图像分割方法可以分为两类。第一类方法直接利用未标记数据的伪标签来扩大训练数据集。例如, Lee 等^[10]使用完全监督算法的预测结果来生成未标记数据的伪标签。然而,简单的伪标签会在训练过程中引入大量的噪声。为了解决这个问题, Sohn 等^[11]提出了一种阈值方法,只保留具有高置信度的预测结果,从而降低伪标签率。此外, Zheng 等^[12]通过计算主输出和辅助输出之间的 KL (Kullback-Leibler) 偏差来估计模型预测的不确定性,并实现了自适应阈值处理,进一步提高伪标签的质量。

第二类方法利用了输入数据在不同扰动下的一致性。例如, Yu 等^[2]提出了一种基于不确定性感知的框架,该框架鼓励在不同扰动下的相同输入产生一致的预测,从而有效地利用未标记数据。 Li 等^[3]提出了一种形状感知的半监督分割策略,该策略利用丰富的未标记数据,并对预测结果施加几何约束。 Luo 等^[4]使用双分支网络来联合预测像素级分割图和目标的几何感知表示。 Ouali 等^[13]提出了一种具有多个辅助解码器的分割模型,并鼓励主解码器和辅助解码器所做预测的一致性。

1.2 不确定性估计

在深度神经网络模型中,准确估计不确定性是量化模型预测可靠性的重要手段。然而,通常无法获取到“真实标签”的不确定性信息,因此不确定性估计仍然是一个具有挑战性的任务。

目前已经开发出多种不确定性估计方法,尤其是在监督学习领域。例如,基于贝叶斯不确定性建模的方法使用贝叶斯神经网络来计算参数的后验分布,从而对不确定性进行估计。然而,精确计算贝叶斯推理是一项困难的任务,因此研究人员提出

了几个近似的变体^[14-16],如使用蒙特卡罗采样来估计每个目标预测的感知不确定性^[8]。此外,不确定性校正^[17,18]也被广泛采用,以提高模型的置信度。与目前仅校正基于不确定性的预测不同,本文引入了一致性正则化和不确定性估计的方法,旨在进一步减轻半监督学习中的噪声影响,并提高模型在图像外观扰动下的分割鲁棒性。

2 基于形状引导和不确定性估计的双一致性半监督三维医学图像分割

本节介绍一种新的半监督三维医学图像分割

框架,它结合了形状引导和不确定性估计的双一致性方法。具体框架如图 1 所示,它由两个独立的网络模型组成,这两个模型共享相同的编码器结构,但其解码器结构具有细微差异。这样的设计增加了模型的多样性和输出图像的不一致性。具体而言,分割模型使用原始的 3D 转置卷积进行上采样,以生成分割概率图;而回归模型则利用最近邻插值和 3D 卷积来扩展特征映射,从而产生形状感知表示。此外,具体框架中还采用了多尺度预测,在分割模型中通过三线性插值和 3D 卷积来生成这些预测。




图 1 形状引导和不确定性估计的双一致性半监督三维医学图像分割框架

2.1 形状引导的一致性学习

由于医学成像质量的限制,仅依靠少量标记数据进行精确目标分割是困难的。为了解决这个问题,对现有的编码器-解码器结构进行了改进,并添加了一个回归分支,用于生成有符号距离图以捕获目标的几何轮廓信息^[3,19]。预测的像素级分割映射到有符号距离映射的转换如下所示^[4]:

$$G_{SDF} = \begin{cases} -\inf_{y \in \partial G} \|x - y\|_2, & x \in G_{in} \\ 0, & x \in \partial G \\ +\inf_{y \in \partial G} \|x - y\|_2, & x \in G_{ex} \end{cases} \quad (1)$$

其中 x, y 表示预测的像素级映射中的两个不同体素, $\|x - y\|_2$ 表示 x 和 y 之间的欧几里得距

离。 ∂G 表示目标的轮廓,而 G_{in} 和 G_{ex} 分别表示目标的内部区域和外部区域。

为了将有符号距离映射转换为像素级分割映射,采用了平滑逼近方法,该方法在^[4]中进行了定义:

$$G_{mask} = \frac{1}{1 + e^{-k \cdot z}} = \sigma(k \cdot z), z \in G_{SDF} \quad (2)$$

其中 z 是体素 x 处的有符号距离图的值, σ 是输入 z 乘因子 k 的 sigmoid 函数, k 选择尽可能大的值以进行逆变换的近似。

对于三维医学图像的半监督分割,训练集 D 包含 M 个标记样本和 N 个未标记样本,其中 $N \gg M$,将标记的数据集表示为 $D_L = \{X_i, Y_i\}_{i=1}^M$,

未标记的数据集表示为 $D_U = \{X_i\}_{N_{i=1}}$, 其中 X_i 表示为输入图像, Y_i 表示为标签。

对于标记的数据集 D_L , 每个网络主要通过监督损失来学习分割目标的可靠表示。使用 Dice 损失和交叉熵损失的组合作为监督损失函数, 具体如下所示:

$$L_{\text{seg}}^{\text{sup}} = \sum_{x_i, y_i \in D_L} \frac{L_{\text{dice}}[f_{\text{seg}}(x_i), y_i] + L_{\text{bce}}[f_{\text{seg}}(x_i), y_i]}{2} \quad (3)$$

$$L_{\text{sdm}}^{\text{sup}} = \sum_{x_i, y_i \in D_L} \frac{L_{\text{dice}}\{\sigma[k f_{\text{sdm}}(x_i)], y_i\} + L_{\text{bce}}\{\sigma[k f_{\text{sdm}}(x_i)], y_i\}}{2} \quad (4)$$

其中, $f_{\text{seg}}(\cdot)$ 表示分割网络模型, $f_{\text{sdm}}(\cdot)$ 表示回归网络模型; L_{dice} 表示 Dice 损失函数, L_{bce} 表示二进制的交叉熵损失函数。在整个训练数据集 $D_L \cup D_U$ 上, 采用形状引导的一致性损失, 以鼓励对同一输入图像进行一致的预测, 从而有效利用未标记数据。通过联合学习分割概率图和几何形状感知表示, 框架可以加强形状约束, 并从未标记的数据中协同学习更多的判别特征。为了提高模型的性能并提升对医学图像中目标的准确分割能力, 本文增强了生成的分割概率图与从有符号距离图转换而来的逐像素分割图之间的形状引导一致性:

$$L_{\text{sdc}}^{\text{unsup}} = \sum_{x_i \in D_L \cup D_U} \|f_{\text{seg}}(x_i) - \sigma[k f_{\text{sdm}}(x_i)]\|^2 \quad (5)$$

$$L_{\text{bdl}}^{\text{unsup}} = \sum_{x_i \in D_L \cup D_U} \text{BDL}\{\partial f_{\text{seg}}(x_i), \partial \sigma[k f_{\text{sdm}}(x_i)]\} \quad (6)$$

通过 $\text{BDL}(\cdot)$ 边界距离函数^[20]来计算边界距离损失, 用于度量相邻边界之间的变化。由于使用轮廓空间上的距离度量, 而不是区域信息, 因此此损失在一定程度上可以减轻分割概率图中模糊边缘的问题。

为了更好地衡量和优化目标区域的形状和边界, 还引入了来自两个不同模型的预测之间的余弦相似度:

$$L_{\text{cr}}^{\text{unsup}} = 1 - \sum_{x_i \in D_L \cup D_U} \cos\{f_{\text{seg}}(x_i), \sigma[k f_{\text{sdm}}(x_i)]\} \quad (7)$$

其中, $\cos(\cdot)$ 表示余弦距离函数。

2.2 不确定性估计的多尺度一致性学习

为了充分利用模型在不同尺度上的预测差异, 在分割网络模型上生成了多尺度的预测。在这项工作中, 选择了 V-Net^[21] 作为主干网络, 并在分割网络的解码器的每个上采样块之后添加预测块, 以产生多尺度的预测, 这些预测块通过 $1 \times 1 \times 1$ 卷积和 softmax 层来实现。为了增加模型的鲁棒性和泛化能力, 在不同尺度的预测块之前引入了 dropout 层和特征级噪声附加层, 以引入扰动和增加多样性。

对于输入图像 X_i , 分割网络模型生成一组多尺度的预测值 $p'_1, p'_2, \dots, p'_{s-1}, p'_s$, 其中 p'_s 是尺度为 s 的预测, 较小的 s 对应于解码器中较高的分辨率, 然后将这些多尺度预测重新缩放到输入图像的大小 $p_1, p_2, \dots, p_{s-1}, p_s$, 对于标记数据, 使用 Dice 损失和交叉熵损失的组合作为多尺度上的监督损失:

$$L_{\text{ms}}^{\text{sup}} = \frac{1}{S} \sum_{s=1}^S \frac{L_{\text{dice}}[p_s(x_i), y_i] + L_{\text{bce}}[p_s(x_i), y_i]}{2} \quad (8)$$

其中 p_s 是尺度为 s 的预测, 为了更好地利用未标记数据, 还采用不确定性估计方法来促使多尺度预测保持一致性。尽管不同尺度的预测最终会被重采样到与输入图像相同的分辨率, 但重采样结果仍然具有不同的频率特征。即在低分辨率下的预测会捕获低频分量, 在高分辨率下的预测会捕获高频分量。受到现有研究的启发^[2,7,14,22], 本文提出了一种新的不确定性估计方法来解决上述问题。通过在分割网络的一次前向传递中获取不同尺度的预测, 可以有效地计算它们之间的差异, 从而得到不确定性的估计。相较于现有方法, 本文的方法在计算成本和运行时间上更加高效。具体而言, 使用多尺度平均预测和各个尺度预测之间的 KL 散度来计算不确定性:

$$p_c = \frac{1}{S} \sum_{s=1}^S p_s \quad (9)$$

$$D_s = \sum_{i=0}^c p_{i_s} \cdot \log\left(\frac{p_{i_s}}{p_{i_c}}\right) \quad (10)$$

其中 p_c 是 s 个尺度的平均预测输出, c 是指类别(通道)数。对于 D_s 中的给定体素, 较大的值表示该体素在尺度 s 下的预测与其他尺度相差较大, 即具有高不确定性。最终, 可以得到一组不确定性 $D_0, D_1, \dots, D_{s-1}, D_s$, 其中 D_s 对应于 p_s 的不确

定性。

根据估计的不确定性 $D_0, D_1, \dots, D_{s-1}, D_s$, 引入了多尺度一致性, 以强调可靠部分并忽略不可靠的无监督训练预测。具体而言, 对于未标记的数据, 引入了自适应体素加权^[14]来计算 MSE 损失, 其中置信度值较高的体素具有较高的权重, 而置信度值低的体素具有较低的权重。这样的校正减少了标签噪声的影响并提高了分割的鲁棒性。修正后的多尺度一致性损失公式如下所示:

$$L_{\text{urp}}^{\text{unsup}} = \frac{1}{S} \sum_{s=1}^S (p_s - p_c) 2 \cdot e - D_s \quad (11)$$

总之, 框架由两个单独的网络模型组成, 它们在训练过程中合作, 并从未标记的数据中探索更可靠的信息, 但在推理阶段只需要分割网络模型。最终的损失定义如下:

$$L_{\text{seg}}^{\text{total}} = L_{\text{ms}}^{\text{sup}} + L_{\text{seg}}^{\text{sup}} + \lambda \cdot L_{\text{urp}}^{\text{unsup}} + L_{\text{bdl}}^{\text{unsup}} + \alpha \cdot L_{\text{cr}}^{\text{unsup}} \quad (12)$$

$$L_{\text{seg}}^{\text{total}} = L_{\text{ms}}^{\text{sup}} + L_{\text{sdm}}^{\text{sup}} + \lambda \cdot L_{\text{sdc}}^{\text{unsup}} + L_{\text{bdl}}^{\text{unsup}} + \alpha \cdot L_{\text{cr}}^{\text{unsup}} \quad (13)$$

其中 α 等于 0.3 时训练最有效, λ 表示上升的加权系数。根据文献[4], 使用高斯上升函数:

$$\lambda_{(t)} = e - 5 \left(1 - \frac{t}{t_{\text{max}}} \right)^2 \quad (14)$$

为了控制监督损失和一致性损失之间的平衡, 其中 t 表示迭代的当前轮数, t_{max} 表示最大训练轮数。

经过实验验证, 在总共 6000 次迭代中的前 3500 次迭代后, 观察到将边界距离损失引入训练中可以改善分割效果。在初始阶段的训练中, 不确定性区域通常分布在硬区域, 甚至可能位于前景的中心部分。然而, 随着训练的进行, 模型逐渐对之前的区域表现出更高的置信度, 导致不确定性区域逐渐移动到边界区域。这一观察结果表明边界距离损失的引入有助于模型更好地捕捉到图像中的边界信息, 并进一步提高分割结果的准确性。

3 实验与分析

3.1 数据集和实验设置

在心房分割挑战数据集^[23]上评估了所提框架, 该数据集包括 100 张 3D MR 扫描图像和相应的真实标签。在已有工作的基础上, 进行了两种典型的半监督设置实验(分别使用 10% 标记数据和

20% 标记数据进行训练)。在本研究中, 使用 NVIDIA GeForce RTX 3090、Ubuntu 18 和 PyTorch 1.7 进行训练。训练总迭代次数设置为 6000 次, 使用 SGD 进行优化, 初始学习率为 0.01, 每 2500 次迭代衰减 0.1。批量大小设置为 4, 其中包括 2 个标记图像和 2 个未标记图像, 并且将图像随机裁剪成大小为 $112 \times 112 \times 80$ 的子块作为网络的输入。为了避免数据过度拟合, 还采用了标准的数据增强技术, 包括随机翻转和沿轴向平面旋转 90° 、 180° 和 270° 。此外, 使用四个指标来定量评估, 包括 Dice 系数、Jaccard 系数、平均表面距离 (ASD) 和 95% Hausdorff 距离 (95HD)。

3.2 实验与分析

为了评估提出的框架的优越性, 进行了全面比较, 将其与最近提出的八种半监督方法进行对比, 包括 DAP^[24]、UA-MT^[2]、SASSNet^[3]、LGER-MT^[25]、DUWM^[26]、PDC Net^[27]、DTC^[4] 和 UR-PC^[20]。为了公平比较, 在所有方法中采用相同的骨干网络和数据集预处理方法。表 1 展示了这些方法在 LA 数据集上的定量性能比较结果。在完全监督设置下, 使用基于 V-Net^[21] 实现的性能作为任务的上下限。通过有效利用未标记数据进行训练, 本文的方法在性能上取得了显著的提升, 在使用 10% 标记数据时 Dice 指标提高了 8.13%, 在使用 20% 标记数据时 Dice 指标从 86.03% 提高到 90.11%。此外, 与上限性能 (91.14% 的 Dice 指标) 相比, 本文的方法取得了与之相当的结果, 并在其他指标上超过了主流的半监督方法。

在本文中, 重点介绍了两个贡献: 形状引导的一致性学习和不确定性估计的多尺度一致性学习。在心房分割挑战数据集上进行了消融实验, 如表 2 所示, 使用半监督方法 MT 作为基线, V-Net 作为网络的主干。首先, 引入了形状引导的一致性学习 (SDC), 实验结果表明第二行的 Dice 指标提高了 1.01%, 得益于它可以加强形状约束并从未标记的数据中协同学习更多的判别特征。其次, 在形状引导的一致性学习上加入了边界距离损失 (BDL) 和余弦相似度 (CR) 使得 Dice 指标提升了 1.08%, 因为这样使得模型在训练过程中可以更加关注边界信息的学习, 减轻分割概率图中模糊边缘的问题。最后, 第 4 行实验结果证明了不确定性估计的多尺度一致性学习 (MS、URP) 可以帮助网络从多尺度预测中学习有用的特征, 减轻半监督学习中的噪声

影响,提高模型在图像外观扰动下的分割鲁棒性,从而获得更大的性能增益。

表 1 与其他先进的方法比较性能指标

Method	Scans used		Metrics				
	Labeled	Unlabeled	Dice(%) ↑	Jaccard(%) ↑	ASD(voxel) ↓	95HD(voxel) ↓	
V-Net	8	0	79.99	68.12	5.48	21.11	
V-Net	16	0	86.03	76.06	3.51	14.26	
V-Net	80	0	91.14	83.82	1.52	5.75	
DAP	8	72	81.89	71.23	3.80	15.81	
UA-MT	8	72	84.25	73.48	3.36	13.48	
SASSNet	8	72	87.32	77.72	2.55	9.62	
LG-ER-MT	8	72	85.54	75.12	3.77	13.29	
DUWM	8	72	85.91	75.75	3.31	12.67	
PDC-Net	8	72	86.55	76.57	3.92	13.61	
DTC	8	72	87.51	78.17	2.36	8.23	
URPC	8	72	85.01	75.02	3.96	15.37	
Ours	8	72	88.12	78.98	1.95	7.76	
DAP	16	64	87.89	78.72	2.74	9.29	
UA-MT	16	64	88.88	80.21	2.26	7.32	
SASSNet	16	64	89.54	81.24	2.20	8.24	
LG-ER-MT	16	64	89.62	81.31	2.06	7.16	
DUWM	16	64	89.65	81.35	2.03	7.04	
PDC-Net	16	64	89.76	81.57	2.95	10.31	
DTC	16	64	89.42	80.98	2.10	7.32	
URPC	16	64	88.74	80.10	3.66	12.73	
Ours	16	64	90.11	82.15	1.58	6.81	

表 2 消融实验

Method	Scans used		Metrics				
	Labeled	Unlabeled	Dice(%) ↑	Jaccard(%) ↑	ASD(voxel) ↓	95HD(voxel) ↓	
SSL+VNet	16	64	87.23	77.73	2.89	11.37	
SSL+VNet+SDC	16	64	88.24	79.13	1.91	7.86	
SSL+VNet+BDL+CR	16	64	89.32	81.32	1.85	7.10	
SSL+VNet+MS+URP	16	64	90.11	82.15	1.58	6.81	

4 结 论

专注于半监督分割方法,提出了一种双一致性半监督学习框架,用于 3D 医学图像分割任务。具体框架包括形状引导和不确定性估计,旨在集成两个独立的分割网络,使这两个网络相互合作,以获得更可靠的信息。同时,引入形状约束来指导边界信息的学习。为了更好地利用未标记数据,还鼓励在多个尺度上生成一致的预测,并设计了一个不确定性估计方法,以提高从未标记图像中学习的稳定

性,进一步提升模型性能。不确定性估计可以通过单次前向传递有效地获得。在 LA 数据集上应用了提出的框架进行分割实验,并取得了令人满意的结果,证明了该框架的有效性和通用性。未来,将对该框架在其他细分任务上进行评估。

参考文献

[1] 张艺. 少量标注数据下半监督医学图像分割算法研究[D]. 济南:山东大学,2022.
[2] YU L, WANG S, LI X, et al. Uncertainty-aware self-ensembling model for semi-supervised 3D left atrium segmentation

- [C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2019: 22nd International Conference, Shenzhen, China, October 13–17, 2019, Proceedings, Part II 22. Springer International Publishing, 2019: 605–613.
- [3] LI S, ZHANG C, HE X. Shape-aware semi-supervised 3D semantic segmentation for medical images[C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2020: 23rd International Conference, Lima, Peru, October 4–8, 2020, Proceedings. Springer International Publishing, 2020: 552–561.
- [4] 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): 8801–8809.
- [5] 方超伟, 李雪, 李钟毓, 等. 基于双模型交互学习的半监督医学图像分割[J]. 自动化学报, 2023, 49(4): 805–819.
- [6] 苏逸欣, 肖志勇. 面向 3 维心脏 MRI 分割的半监督双任务交叉一致性约束网络[J]. 中国图象图形学报, 2023, 28(4): 1198–1211.
- [7] CAO X, CHEN H, LI Y, et al. Uncertainty aware temporal-ensembling model for semi-supervised abus mass segmentation[J]. IEEE Transactions on Medical Imaging, 2020, 40(1): 431–443.
- [8] GAL Y, GHAHRAMANI Z. Dropout as a Bayesian approximation: representing model uncertainty in deep learning [C]//International Conference on Machine Learning. PMLR, 2016: 1050–1059.
- [9] 李永国, 徐彩银, 汤璇, 等. 半监督学习方法研究综述[J]. 世界科技研究与发展, 2023, 45(1): 26–40.
- [10] LEE D H. Pseudo-label: The simple and efficient semi-supervised learning method for deep neural networks [C]//Workshop on Challenges in Representation Learning. ICML, 2013, 3(2): 896.
- [11] SOHN K, BERTHELOT D, CARLINI N, et al. Fixmatch: simplifying semi-supervised learning with consistency and confidence[J]. Advances in Neural Information Processing Systems, 2020, 33: 596–608.
- [12] ZHENG Z, YANG Y. Rectifying pseudo label learning via uncertainty estimation for domain adaptive semantic segmentation[J]. International Journal of Computer Vision, 2021, 129(4): 1106–1120.
- [13] OUALI Y, HUDELOT C, TAMI M. Semi-supervised semantic segmentation with cross-consistency training [C]//Proceedings of the CVF Conference on Computer Vision and Pattern Recognition. 2020: 12674–12684.
- [14] 李双双. 贝叶斯框架下的深度学习不确定性研究及应用[D]. 南京: 南京理工大学, 2021.
- [15] 杨佳霖. 深度学习中的不确定性研究及其在目标检测中的应用[D]. 武汉: 武汉大学, 2020.
- [16] LOUIZOS C, WELLING M. Structured and efficient variational deep learning with matrix Gaussian posteriors[C]//International Conference on Machine Learning. PMLR, 2016: 1708–1716.
- [17] 徐琪森. 基于置信度学习的医疗图像分割算法研究[D]. 上海: 华东师范大学, 2021.
- [18] LUO X, LIAO W, CHEN J, 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: 24th International Conference, Strasbourg, France, September 27–October 1, 2021, Proceedings, Part II 24. Springer International Publishing, 2021: 318–329.
- [19] XUE Y, TANG H, QIAO Z, et al. Shape-aware organ segmentation by predicting signed distance maps[C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2020, 34(7): 12565–12572.
- [20] KERVADEC H, BOUCHTIBA J, DESROSIERS C, et al. Boundary loss for highly unbalanced segmentation[C]//International Conference on Medical Imaging with Deep Learning. PMLR, 2019: 285–296.
- [21] MILLETARI F, NAVAB N, AHMADI S A. V-net: fully convolutional neural networks for volumetric medical image segmentation[C]//2016 Fourth International Conference on 3D Vision (3DV). IEEE, 2016: 565–571.
- [22] WANG G, LI W, AERTSEN M, et al. Aleatoric uncertainty estimation with test-time augmentation for medical image segmentation with convolutional neural networks[J]. Neurocomputing, 2019, 338: 34–45.
- [23] XIONG Z, XIA Q, HU Z, et al. A global benchmark of algorithms for segmenting the left atrium from late gadolinium-enhanced cardiac magnetic resonance imaging [J]. Medical Image Analysis, 2021, 67: 101832.
- [24] ZHENG H, LIN L, HU H, et al. Semi-supervised segmentation of liver using adversarial learning with deep atlas prior [C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2019: 22nd International Conference, Shenzhen, China, October 13–17, 2019, Proceedings, Part VI 22. Springer International Publishing, 2019: 148–156.
- [25] HANG W, FENG W, LIANG S, et al. Local and global structure-aware entropy regularized mean teacher model for 3d left atrium segmentation[C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2020: 23rd International Conference, Lima, Peru, October 4–8, 2020, Proceedings, Part I 23. Springer International Publishing, 2020: 562–571.
- [26] WANG Y, ZHANG Y, TIAN J, et al. Double-uncertainty weighted method for semi-supervised learning[C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2020: 23rd International Conference, Lima, Peru, October 4–8, 2020, Proceedings, Part I 23. Springer International Publishing, 2020: 542–551.
- [27] HAO X, GAO S, SHENG L, et al. Parameter decoupling strategy for semi-supervised 3D left atrium segmentation [C]//Fourteenth International Conference on Machine Vision (ICMV 2021). SPIE, 2022, 12084: 118–124.