

基于半监督的3D肝脏CT自动分割方法研究

谢宏彪¹, 刘志勤¹, 王庆凤¹, 黄俊¹, 陈波¹, 周莹²

(1. 西南科技大学 计算机科学与技术学院, 四川 绵阳 621010;

2. 绵阳市中心医院, 四川 绵阳 621010)

摘要: 肝癌是常见癌症之一, 有着较高的死亡率, 精准分割肝癌区域是辅助诊断治疗的重要前提。然而肝脏CT图像需要专业的医师进行标注, 有标签数据较少, 获取途径单一。针对分割腹部肝脏CT图像需要大量高质量标签并且较难获取的问题, 提出了一种采用协同训练的半监督学习分割方法。首先, 将有标签数据输入3D U-Net和3D Res U-Net进行有监督训练, 保存训练得到的两个分割模型, 在两个分割模型中分别对无标签数据进行预测; 然后, 挑选预测的结果, 再加入全连接条件随机场处理挑选出的伪标签, 细化伪标签的边缘信息, 提升伪标签的精确度; 最后, 加入到训练集中, 重复上述步骤直到分割结果的Dice相似系数停止提升时结束训练。实验在LiTS2017 Challenge肝脏数据集上进行测试, 结果表明, 在有标签数据集占总数据集的30%时, 该方法的Dice值达到90.22%, 几乎与全监督3D Res U-Net分割结果持平, 说明该半监督学习方法是有效的。

关键词: 协同训练; 肝脏分割; 半监督学习; 全连接条件随机场; U-Net

中图分类号: TP391.41

文献标识码: A

文章编号: 1673-629X(2023)09-0149-06

doi: 10.3969/j.issn.1673-629X.2023.09.022

Automated Segmentation of 3D Liver CT Images Using Semi-supervision

XIE Hong-biao¹, LIU Zhi-qin¹, WANG Qing-feng¹, HUANG Jun¹, CHEN Bo¹, ZHOU Ying²

(1. School of Computer Science and Technology, Southwest University of Science and Technology,

Mianyang 621010, China;

2. Mianyang Central Hospital, Mianyang 621010, China)

Abstract: Liver cancer is one of the common cancers with a high mortality rate. Accurate segmentation of liver cancer regions is an important prerequisite for auxiliary diagnosis and treatment. However, liver CT images need to be labeled by professional physicians, and there are few labeled data and a single way to obtain them. In order to solve the problem that segmentation of abdominal liver CT images requires a large number of high-quality labels and is difficult to obtain, a semi-supervised automatic segmentation method based on cooperative training is proposed. Firstly, the labeled data is input into 3D U-Net and 3D Res U-Net for supervised training, and the two segmentation models obtained by training are saved. The unlabeled data are predicted respectively in the two segmentation models. Then the predicted results are selected, and the pseudo-labels selected by the fully connected conditional random field processing are added to refine the edge information of the pseudo-labels. It can improve the accuracy of the pseudo-label, and finally add it to the training set. Repeat the above steps until the Dice similarity coefficient of the segmentation results stops improving to end the training. The experiment was tested on the LiTS2017 Challenge. The results showed when the labeled data sets account for 30% of the total set, the Dice of the proposed method reaches 90.22%, which is almost equal to the fully supervised 3D Res U-Net segmentation result, indicating that the semi-supervised method is effective.

Key words: cooperative training; liver segmentation; semi-supervised learning; dense conditional random field; U-Net

0 引言

肝脏是人体内最大的器官, 在人体众多部位有着无可比拟的地位, 承担着存储、解毒和合成三个方面的

功能。由于人们高压工作、作息不规律等原因, 致使肝脏过度使用, 因此肝脏疾病的发病率极高, 并且具有多种类、多发性等特点, 而这些肝脏疾病均具有较高几

收稿日期: 2022-10-29

修回日期: 2023-03-01

基金项目: 四川省自然科学基金(2022NSFC0940, 2022NSFC0894); 西南科技大学博士基金(19zx7143, 20zx7137)

作者简介: 谢宏彪(1998-), 男, 硕士研究生, CCF 会员(L8065G), 研究方向为人工智能、医学图像分析; 刘志勤(1962-), 女, 教授, 硕导, 研究方向为高性能计算、数值模拟、人工智能等; 通讯作者: 王庆凤(1988-), 女, 讲师, 博士, 研究方向为人工智能、机器学习、医学图像分析。

率诱发肝癌,也叫做肝脏恶性肿瘤^[1]。肝癌在全球癌症中有着极高死亡率,每年约有 84 万多新病例和 78 万多死亡病例^[2]。人类的生命健康正被肝癌等疾病摧残着。

在临床治疗中,自动肝脏肿瘤分割^[3-5]在 CT (computed tomography) 图像中有着重要的研究价值,不但可以减少医务人员在分析病情中所耗费的时间,有些还能模仿临床手术操作,提高治疗成功率。但自动肝脏肿瘤分割的准确性在较大程度上依赖标签数据的质量和数量^[6-7],获取这些肝脏区域标注既需要医学专家进行细致的手动勾画,专家个人的主观因素也会影响标注精度,会影响后续治疗时间,降低效率^[8]。并且 CT 图像是三维图像,一些分割方法^[9-10]只利用了二维图像,由于 2D 网络结构本身的不足,导致 CT 图像的三维信息没有得到很好的利用,对 2D 网络结构的各种改动也仅限于提高单张切片分割的准确率,让肝脏肿瘤的整体分割性能的提升受到限制。

对于以上问题,该文提出了一种基于半监督协同训练的 3D CT 肝脏自动分割方法。主要有以下几个方面的贡献:

(1)为了更好地利用医学分割图像中少量的肝脏数据,提出了半监督协同训练方法。

(2)提出使用 3D U-Net 和 3D Res U-Net 方法可以更好地利用 CT 图像的三维信息。

(3)用全连接条件随机场 (Dense Conditional Random Field, Dense CRF) 把预测得到的伪标签通过边缘细化,提升伪标签的精确度。

1 相关研究

深度学习^[11]的发展推进了图像分割性能的大幅提升,通过对标注数据进行学习,能够自动提取大量的特征值,从而提升肝脏分割的准确性。因为肝脏 CT 图像边界不清晰,准确分割出肝脏又需要较多高分辨率信息;同时,人体器官的位置相对固定,分割有一定的规律,语义简单清晰,所以对目标器官的识别还需要低分辨率信息。Ronneberger 等人^[12]在 2015 年首次提出将 U-Net 应用到医学图像分割中。U-Net 在编码器和解码器之间加入跳跃连接,可以将低分辨率信息和高分辨率信息很好地结合起来,能够更好地分割肝脏和肝肿瘤。跳跃连接虽然结合了低分辨率信息和高分辨率信息,但没有筛选一些无用的低分辨率信息,使得低分辨率信息过多而导致图像边界模糊。为了解决这个问题,Seo 等人^[13]改进了网络框架,提出了 mU-Net,他们引入了一个剩余路径,加到 U-Net 的跳跃连接部分,其中包含激活操作和反卷积操作,有效地加强了全局特征的提取能力和高分辨率的边缘特征。Fan

等人^[14]提出了一种多尺度嵌套 U-Net,优化了跳跃连接区域,解决了跳跃连接传递过多低分辨率信息的问题。由于医学 CT 图像为 3D 图像,使用 2D 网络无法有效利用 CT 图像的三维信息。Milletari 等人^[15]在 2016 年提出 3D 网络 V-Net,该方法解决了 2D 网络无法利用 CT 图像的三维信息的问题。紧接着,Jeong 等人^[16]提出一种深度三维注意力 U-Net (3D attention U-Net) 有效学习了各个形状的肝脏。Jin 等人^[17]提出用于肝肿瘤分割的 RA-UNet,在网络中加入注意力剩余机制,可以较好地获取并利用上下文信息。

以上肝脏自动分割的研究方法都需要大量的肝脏标注数据进行全监督学习训练,但获取这些肝脏区域标注需要医学专家进行细致的手动勾画,费时费力。因此有研究者提出了一种半监督学习,以减少对人工标注的依赖。在 2013 年 Lee 等人^[18]提出“伪标签”一词,通过网络自训练利用少量标签数据训练大量无标注样本,分割结果较好。Yang 等人^[19]提出了一个基于图嵌入的半监督学习网络框架,可以共同预测伪标签和图形中的邻域上下文信息。但上述方法生成的伪标签部分效果欠佳,容易使网络错误学习。在这个问题上,Zhou 等人^[20]提出从矢状面、冠状面和轴向平面等多个平面挖掘共识信息,采用多平面融合生成更可靠的伪标签,减少了伪标签中出现的误差,有助于训练更好的分割网络。Liu 等人^[21]提出使用全连接条件随机场处理伪标签,提升伪标签精度,其改进了网络的并行空间和激励模块,能更好地保留图像边缘信息。

2 方法

该文充分利用少量带有肝脏分割标记的 CT 图像来预测大量无标记的肝脏 CT 图像,提出一种基于协同训练^[22]的肝脏 CT 图像自动分割方法,包括全监督训练、伪标签挑选和伪标签优化三个阶段。(1)将有标签数据输入 3D U-Net 和 3D Res U-Net 进行全监督训练,然后把得到的两个分割模型分别对无标签图像进行预测,得到多个伪标签;(2)利用两种分割网络之间的差异性,将得到的伪标签用 Dice 值进行挑选,挑选出 Dice 值较高的伪标签进行下一步处理;(3)把挑选后的伪标签用全连接条件随机场进行细化处理,提高伪标签的准确性。处理后的伪标签加入到训练集继续训练,直到第二步 Dice 值不再增大后停止训练。所提方法可以减少分割模型对肝脏区域手动勾画标注数据的依赖,同时还可以提升 CT 肝脏器官的分割结果精度。半监督分割网络框架如图 1 所示。具体方法如下所述。

2.1 基于 3D U-Net 和 3D Res U-Net 的全监督训练

实验先把有标签数据分别输入到 3D U-Net 和

3D Res U-Net 进行全监督训练,训练网络中损失函数均采用 DiceLoss ,如公式(1):




图1 网络协同训练示意图

$$\text{DiceLoss} = 1 - \frac{2|X \cap Y|}{|X| + |Y|} \quad (1)$$

2.2 挑选伪标签

将无标签数据分别输入基于3D U-Net 和3D Res U-Net 训练出的两个分割模型中进行预测,预测结果作为伪标签集。在半监督学习方法中,难点是如何选择可靠的伪标签加入到训练集中以扩大训练集,该选用常用的评估指标 Dice (Dice similarity coefficient) 值的大小来判断,如公式(2)所示。Dice 值超过0.85的伪标签在下一步进行标签优化。

$$\text{Dice} = \frac{2|P_1 \cap P_2|}{|P_1| + |P_2|} \quad (2)$$

式中, P_1 和 P_2 分别代表3D U-Net 与3D Res U-Net 网络对同一CT图像的分割结果。

2.3 基于全连接条件随机场的伪标签优化

在网络训练中,若有通过3D U-Net 与3D Res U-Net 协同网络预测产生精度不高的伪标签,未作处理便加入训练集中进行训练,会导致迭代训练过程中网络学习出错,致使错误累积。Dense CRF 可以优化伪标签中粗糙和边缘不确定的标记,修补零星的区域,使其趋近于金标签。Dense CRF 的能量函数^[23]如下:

$$E_{(Z)} = \sum_i \tau_e(k_i) + \sum_{i,j} \tau_f(k_i, k_j) \quad (3)$$

式中, $\tau_e(k_i)$ 为一元势能,用于衡量像素点的类别概率, $\tau_e(k_i) = -\log P(f_i)$, f_i 为经过分割网络后像素 i 得到的预测结果, $P(f_i)$ 为 f 的概率; $\tau_f(k_i, k_j)$ 为像素 i 和像素 j 上的预测结果 k_i, k_j 之间的二元势能,解释各个像素点之间的关系,表达式如下:

$$\tau_f(k_i, k_j) = \mu(k_i, k_j) \cdot \left[\omega_1 \exp\left(-\frac{m_i - m_j^2}{2\sigma_\alpha^2}\right) - \frac{n_i - n_j^2}{2\sigma_\beta^2} \right] + \omega_2 \exp\left(-\frac{m_i - m_j^2}{2\sigma_\gamma^2}\right) \quad (4)$$

式中, ω_1, ω_2 为线性组合权重; μ 为标签兼容性函数, $\mu(k_i, k_j)$ 为标签兼容项^[24],它约束了像素间传导的条件,当 $k_i \neq k_j$ 时, $\mu(k_i, k_j) = 1$, 否则为0;像素之间的邻近程度和相似度由系数 σ_α 和 σ_β 控制; $\sigma_\gamma = 1$, 其将较小的独立区域去除; m_i, m_j 分别为像素 i 和像素 j 的位置关系, n_i, n_j 分别为像素 i 和像素 j 的强度值。二元势能函数会多于注意到具有相似位置 m 、相似强度 n

但具有不同标记的 k 像素。能量 $E_{(Z)}$ 越小,预测的类别标签 m 就越准确。

在实验中,预测的伪标签用 Dense CRF 进行优化,可以提高伪标签的准确度,使其更趋近金标签。

2.4 具体训练方案

实验将数据分为两部分,设 X 为CT图像, Y 为其对应的标签图像。第一部分设置有标签数据集 $F_L = \{X_L, Y_L\}$, 第二部分是无标签数据集 $F_U = [X_U]$ 。通过训练3D U-Net 与3D Res U-Net 分割模型,预测无标签数据得到伪标签 Y_U , 加入 F_U 中得到 $F'_U = [X_U, Y_U]$ 。整个实验流程见算法1。

Algorithm1: 半监督训练算法

I. Network training

Input: 输入有标签数据集 $F_L = \{X_L, Y_L\}$

Output: Model M_U, M_R // M_U 为3D U-Net 网络模型, M_R 为3D Res U-Net 网络模型

1: Training 3D U-Net, 3D Res U-Net

2: Save model M_U, M_R

II. Semi-supervised training

Input: 输入无标签数据集 $F_U = \{X_U\}$

Output: Model M'_U, M'_R

1: Load model M_U, M_R

2: for $i = 1, 2, \dots, N$ do // i 表示样本集编号

3: Make inference $M_U(X_U) \rightarrow Y_U^1,$

$M_R(X_U) \rightarrow Y_U^2$

4: Compare $\in Y_U$

5: Optimize Y_U with Dense CRF

6: end for

7: until converged

8: return Model M'_U, M'_R

3 实验结果与分析

3.1 数据及预处理

实验数据来自公开数据集 2017 MICC AI LiTS 肝脏肿瘤分割挑战赛 (<https://competitions.codalab.org/competitions/17094>), 其中包括0~130号共131例的腹部CT图像及其金标签。将数据中的肝脏和肝肿瘤的标签融合为一个, 肝脏CT图像大小为 $512 \times 512 \times L$ (其中 L 为CT数据中的切片数量)。将肝脏CT图像的灰度值标准化到 $[-100, 100]$ 。

3.2 参数设置

网络学习率设置为 $1e-4$; 设置 $\text{epoch} = 200$; 设置 $\text{batch size} = 1$ 或 2。实验使用的服务器配置如下: Intel E5-2620 v2@2.10 GHz CPU 和 NVIDIA RTX 3090 显卡, 主要的软件环境 Python3.7、CUDA11.1、Keras2.2.5 等。

3.3 评估指标

Dice 系数和 Iou (Intersection over union) 是医学分割任务中常见的评估指标, 它们都是用来衡量网络分割结果与金标准 mask 之间的相似性, 表达式如下:

$$\text{Dice} = \frac{2|P \cap G|}{|P| + |G|} \quad (5)$$

$$\text{Iou} = \frac{|P \cap G|}{|P \cup G|} \quad (6)$$

式中, P 为预测所得到的结果区域, G 为金标签, 即医师所标注的真实区域。

特异性 (specificity) 和灵敏度 (sensitivity) 两个指标经常用来描述分类器的性能, 前者指识别出的负例占有所有负例的比例, 后者指识别出的所有正例占有所有正例的比例, 表达式如下:

$$\text{Spec} = \frac{\text{TN}}{\text{TN} + \text{FP}} \quad (7)$$

$$\text{Sens} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (8)$$

式中, TP 是真阳性, 分类器预测结果为正样本, 实际也为正样本, 即正样本被正确识别的数量; TN 是真阴性, 分类器预测结果为负样本, 实际为负样本, 即负样

本被正确识别的数量; FP 是假阳性, 分类器预测结果为正样本, 实际为负样本, 即误报的负样本数量; FN 是假阴性, 分类器预测结果为负样本, 实际为正样本, 即漏报的正样本数量。

3.4 分割结果

实验在 2017 MICCAI LiTS 肝脏肿瘤数据集随机选取 100 例 CT 图像作为训练集, 剩余 31 例作为测试集。在这 100 例数据中将其分为 30、50、70 例有标签数据, 剩下数据依次分为 70、50、30 的无标签数据。将这几种实验设置下获得的模型分别对测试集进行分割预测, 将其结果与 3D U-Net、3D KiU-Net^[25]、3D SegNet^[26] 和 3D ResU-Net 使用 100 例灰度图像及其真值标注的全监督分割结果进行对比。

表 1 展示了四种网络的全监督分割结果与文中方法在不同有标签占比下的比较结果。文中方法在有标签占 30% 时便可达到 3D ResU-Net 全监督分割的效果。在表 2 中可以看出, 随着有标签数据的减少, 四种分割网络的半监督分割结果明显比全监督的时候有所降低。

当有标签数据的占比达到 70% 时, 文中方法比全监督 3D ResU-Net 的 Dice 值高出 1.32%, 比全监督 3D U-Net 的 Dice 值高出 3.67%。为能更直观地展示文中方法的分割结果, 在 $\text{MP} = 70\%$ 的时候选取部分结果的分割图像, 如图 2 所示。在图 3 展示了分割结果的三维可视化。

表 1 不同标签数量占比下的分割性能比较

方法	M	N	MP/%	Dice	Iou	Sens	Spec
全监督 3D U-Net	100	0	100	0.886 1	0.823 6	0.872 3	0.993 5
全监督 3D KiU-Net	100	0	100	0.883 8	0.822 1	0.883 6	0.997 0
全监督 3D SegNet	100	0	100	0.843 8	0.741 3	0.855 6	0.997 5
全监督 3D ResU-Net	100	0	100	0.909 6	0.858 8	0.981 9	0.997 9
文中方法	30	70	30	0.902 2	0.853 1	0.982 3	0.995 2

(注: M 为有标签的图像数量, N 为无标签的图像数量, MP 为有标签占比)

表 2 不同标签数量占比下的半监督分割性能比较

方法	M	N	MP/%	Dice	Iou	Sens	Spec
半监督	30	70	30	0.853 7	0.804 5	0.862 8	0.993 3
3D	50	50	50	0.877 1	0.815 4	0.923 4	0.997 4
U-Net	70	30	70	0.890 5	0.838 7	0.915 2	0.991 5
半监督	30	70	30	0.841 6	0.792 5	0.835 7	0.992 1
3D KiU-Net	50	50	50	0.887 0	0.826 7	0.938 7	0.995 4
	70	30	70	0.894 2	0.842 5	0.926 4	0.992 7
半监督	30	70	30	0.839 4	0.779 2	0.832 4	0.994 5
3D	50	50	50	0.857 9	0.795 8	0.882 1	0.992 8
SegNet	70	30	70	0.862 8	0.817 6	0.831 5	0.994 9

续表 2

方法	M	N	MP/%	Dice	Iou	Sens	Spec
半监督 3D ResU-Net	30	70	30	0.883 5	0.823 6	0.872 2	0.992 4
	50	50	50	0.888 0	0.819 4	0.938 5	0.996 4
	70	30	70	0.905 3	0.852 1	0.983 5	0.995 3
文中方法	30	70	30	0.902 2	0.853 1	0.982 3	0.995 2
	50	50	50	0.918 7	0.864 2	0.986 2	0.997 1
	70	30	70	0.922 8	0.873 4	0.987 3	0.996 6




图 2 分割对比网络效果图




图 3 3D 可视化分割图

4 结束语

提出的基于半监督的 3D 肝脏 CT 图像自动分割方法,有效利用了 CT 图像的三维信息,解决了医学图像需要大量有标签数据并且获取困难的问题,为医生诊断治疗节约时间。实验结果表明,该方法的肝脏分割精度相比 3D U-Net 等网络都有明显的提升。

在未来工作中,要进一步提高半监督学习中加入伪标签的模型的分割性能,达到用少量标签就可实现大量预测且达到高精度的效果。该研究还会将提出的半监督分割方法应用到其他医学图像数据集中,以提高该方法的普适性。

参考文献:

[1] 陈明杰. 基于深度学习的肝脏肿瘤 CT 图像分割方法研究 [D]. 哈尔滨:哈尔滨工程大学,2019.

[2] BRAY F, FERLAY J, SOERJOMATARAM I, et al. Global cancer statistics 2018: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries[J]. CA: A Cancer Journal for Clinicians, 2018, 68: 394-424.

[3] 徐宝泉, 凌彤辉. 基于级联 Vnet-S 网络的 CT 影像单一器官自动分割算法 [J]. 计算机应用, 2019, 39 (8): 2420-2425.

[4] ÇIÇEK Ö, ABDULKADIR A, LIENKAMP S, et al. 3D U-Net: learning dense volumetric segmentation from sparse an-

- notation [C]//International conference on medical image computing and computer – assisted intervention. Athens; Springer, 2016; 424–432.
- [5] XU W, LIU H, WANG X, et al. Liver segmentation in CT based on ResUNet with 3D probabilistic and geometric post process [C]//2019 IEEE 4th international conference on signal and image processing (ICSIP). Wuxi; IEEE, 2019; 685–689.
- [6] ANTONELLI M, REINKE A, BAKAS S, et al. The medical segmentation decathlon [J]. arXiv; 2106.05735, 2021.
- [7] CAMPELLO V M, GKONTRA P, IZQUIERDO C, et al. Multi-centre, multi-vendor and multi-disease cardiac segmentation; the M&Ms challenge [J]. IEEE Transactions on Medical Imaging, 2021, 40(12): 3543–3554.
- [8] NIE D, GAO Y, WANG L, et al. ASDNet: attention based semi-supervised deep networks for medical image segmentation [J]//Medical image computing and computer assisted intervention–MICCAI 2018. Granada; Springer, 2018; 370–378.
- [9] 李 阳, 赵于前, 廖 苗, 等. 基于水平集和形状描述符的腹部 CT 序列肝脏自动分割 [J]. 自动化学报, 2021, 47(2): 327–337.
- [10] 刘云鹏, 刘光品, 王仁芳, 等. 深度学习结合影像组学的肝脏肿瘤 CT 分割 [J]. 中国图象图形学报, 2020, 25(10): 2128–2141.
- [11] LITJENS G, KOOI T, BEJNORDI B E, et al. A survey on deep learning in medical image analysis [J]. Medical Image Analysis, 2017, 42: 60–88.
- [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. [s. l.]; Springer, 2015: 234–241.
- [13] SEO H, HUANG C, BASSENNE M, et al. Modified U-Net (mU-Net) with incorporation of object-dependent high level features for improved liver and liver-tumor segmentation in CT images [J]. IEEE Transactions on Medical Imaging, 2019, 39(5): 1316–1325.
- [14] FAN T, WANG G, WANG X, et al. MSN-Net: a multi-scale context nested U-Net for liver segmentation [J]. Signal, Image and Video Processing, 2021, 15(6): 1089–1097.
- [15] 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). Stanford; IEEE, 2016; 565–571.
- [16] JEONG J G, KIM Y J, KIM K G, et al. Deep 3D attention U-Net based whole liver segmentation for anatomical volume analysis in abdominal CT images [C]//Proc. SPIE 11792, international forum on medical imaging in Asia 2021. Taipei, China; [s. n.], 2021; 13–18.
- [17] JIN Q, MENG Z, SUN C, et al. RA-UNet: a hybrid deep attention-aware network to extract liver and tumor in CT scans [J]. Frontiers in Bioengineering and Biotechnology, 2020, 8(3): 1471–1486.
- [18] LEE D H. Pseudo-label: the simple and efficient semi-supervised learning method for deep neural networks [C]//International conference on machine learning. Atlanta; ICML, 2013; 896.
- [19] YANG Z, COHEN W, SALAKHUDINOV R. Revisiting semi-supervised learning with graph embeddings [C]//International conference on machine learning. New York; ICML, 2016; 40–48.
- [20] 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). Waikoloa; IEEE, 2019; 121–140.
- [21] 刘清清, 周志勇, 范国华, 等. 基于 3D scSE-UNet 的肝脏 CT 图像半监督学习分割方法 [J]. 浙江大学学报: 工学版, 2021, 55(11): 2033–2044.
- [22] HONG Y, ZHU W. Spatial co-training for semi-supervised image classification [J]. Pattern Recognition Letters, 2015, 63: 59–65.
- [23] 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. Quebec; Springer, 2017; 253–260.
- [24] KRAHENBUHL P, KOLTUN V. Efficient inference in fully connected CRFs with Gaussian edge potentials [J]. Advances in Neural Information Processing Systems, 2011, 24: 109–117.
- [25] VALANARASU J M J, SINDAGI V A, HACIHALILOGLU I, et al. Kiu-net: overcomplete convolutional architectures for biomedical image and volumetric segmentation [J]. IEEE Transactions on Medical Imaging, 2021, 41(4): 965–976.
- [26] 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): 2481–2495.