

基于肿瘤形状特征与点云方法的PET-CT多模态图像神经母细胞瘤分割

周维钦¹, 王朝立¹, 孙占全¹, 陈素芸², 李超², 傅宏亮², 刘晓虹³

(1. 上海理工大学光电信息与计算机工程学院, 上海 200093; 2. 上海交通大学医学院附属新华医院核医学科, 上海 200092; 3. 上海市第八人民医院放射科, 上海 200235)

摘要: 通过智能学习方法对PET-CT图像进行肿瘤自动分割, 是辅助医生制定诊疗计划的重要研究领域。PET-CT图像兼具PET和CT两种模态优点, 传统方法大多只简单的将两种模态的图像进行配准和融合后提取特征, 忽略了神经母细胞瘤具有肿瘤边界轮廓不规则的特点。为此, 提出一种两阶段的自动分割框架结构模型。首先, 利用3D卷积神经网络定位肿瘤位置; 然后在分割出的肿瘤区域附近生成多模态点云数据, 并提取肿瘤的形状轮廓特征; 最后, 将两个网络提取的特征进行融合用来预测最终分割结果。在自有数据集和公共数据集上, 将所提模型与其他多模态方法进行比较实验, 实验结果验证了所提模型的优越性与有效性。以期为研究神经母细胞瘤分割的研究人员提供参考与借鉴。

关键词: 深度学习; 点云; 多模态; 医学图像分割; PET-CT

DOI: 10.11907/hjtk.231336

中图分类号: TP183

文献标识码: A

开放科学(资源服务)标识码(OSID):

文章编号: 1672-7800(2024)003-0128-06



Segmentation of Neuroblastoma with PET-CT Multimodal Images Based on Tumor Shape Characteristics and Point Clouds Method

ZHOU Weiqin¹, WANG Chaoli¹, SUN Zhanquan¹, CHEN Suyun², LI Chao², FU Hongliang², LIU Xiaohong³

(1. College of Optoelectronic Information and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China; 2. Department of Nuclear Medicine, Xinhua Hospital Affiliated to Shanghai Jiaotong University School of Medicine, Shanghai 200092, China; 3. Department of Radiology, Shanghai Eighth People's Hospital, Shanghai 200235, China)

Abstract: The automatic tumor segmentation of PET-CT images through intelligent learning methods is an important research field to assist doctors in formulating diagnosis and treatment plans. PET-CT images have the advantages of both PET and CT modalities. Traditional methods mostly simply register and fuse the images of the two modalities to extract features, ignoring the irregular tumor boundary contour of neuroblastoma. To this end, a two-stage automatic segmentation framework structure model is proposed. Firstly, use 3D convolutional neural networks to locate the tumor location; Then generate multimodal point cloud data near the segmented tumor area and extract the shape contour features of the tumor; Finally, the features extracted by the two networks are fused to predict the final segmentation result. The proposed model was compared with other multimodal methods on both proprietary and public datasets, and the experimental results verified the superiority and effectiveness of the proposed model, which can provide reference and inspiration for researchers studying the segmentation of neuroblastoma.

收稿日期: 2023-03-31

基金项目: 国家自然科学基金项目(6217323); 国防科工局基础研究项目(JCKY2019413D001)

作者简介: 周维钦(1994-), 男, 上海理工大学光电信息与计算机工程学院硕士研究生, 研究方向为深度学习、医学图像处理等; 王朝立(1965-), 男, 博士, 上海理工大学光电信息与计算机工程学院教授、博士生导师, 研究方向为非线性控制、机器人控制、图像分割等; 孙占全(1977-), 男, 博士, CCF会员, 上海理工大学光电信息与计算机工程学院副教授, 研究方向为人工智能、医学图像分割等; 陈素芸(1982-), 女, 博士, 上海交通大学医学院附属新华医院核医学科副主任医师, 研究方向为PET/CT读片及甲状腺功能亢进症等; 李超(1990-), 女, 博士, 上海交通大学医学院附属新华医院核医学科主治医师, 研究方向为肿瘤核医学、PET/CT显像等; 傅宏亮(1969-), 男, 博士, 上海交通大学医学院附属新华医院核医学科副主任医师, 研究方向为甲亢及甲状腺癌的核素治疗、放射性核素显像读片等; 刘晓虹(1967-), 女, 上海市第八人民医院放射科副主任医师, 研究方向为PET/CT骨质疏松诊治等。本文通讯作者: 王朝立。

Key Words: deep learning; point clouds; multimodal; medical image segmentation; PET-CT

0 引言

肿瘤是目前全球致死率最高的病因之一。正电子发射计算机断层显像(PET-CT)在肿瘤的影像诊断方面具有独特的优势,尤其是广泛使用的正电子显像剂氟代脱氧核糖(18F-FDG)能显像诊断出绝大部分的肿瘤,包括神经母细胞瘤(颅外实体恶性肿瘤,主要发生在婴幼儿)。神经母细胞瘤常呈浸润性生长而侵入邻近结构,例如侵入椎管内生长,出现哑铃型结构,因此其边界轮廓通常不规则。在国际上,神经母细胞瘤的一线影像学方法为123I-MIBG,但在中国广泛使用的是PET-CT。精确的肿瘤分割是临床医生更好地制订诊疗计划与预后预测的必要条件^[1-2],但手动肿瘤分割包含大量重复性劳动往往费时费力,消耗了临床医生大量时间。为此,借助计算机技术研究自动肿瘤分割方法既能减轻临床医生枯燥的重复性劳动,又能避免因医生疲劳而导致的误诊。

然而,在PET-CT图像上进行自动肿瘤分割是一项非常具有挑战性的任务,因为两种单模态的图像提供的信息都不充分,需要互补才能完成最终的分割任务。其中,CT图像能显像出精确的器官解剖结构,但无法提供代谢信息,例如软组织肿瘤由于密度与周围组织相似,在CT图上不易分辨;PET图像能根据代谢信息提供肿瘤的可能位置,但需要查看CT图像上的解剖信息来排除生理性高摄取区域,例如心脏、肝脏、大脑皮层等区域。

此外,PET图像的分辨率较低,无法分割出肿瘤的精确轮廓^[3],临床医生通常使用LIFEX软件自动融合两种模态图像来查看病人的PET-CT图像。具体为,首先提升PET图像的亮度、对比度来寻找肿瘤的大致位置;然后观察CT图像提供的解剖信息排除生理性高摄取区域。

1 相关研究

目前,U-Net及其拓展版本在医学图像分割领域得到了广泛应用和探讨,对大部分医学图像分割任务而言通常是首选方法^[4]。3D U-Net是第一个将原本应用于2D医学图像的U-Net拓展到3D医学图像的研究,并且取得了不错的结果^[5]。然而,由于处理3D图像所需的计算显存较大,因此该方法难以应用更多临床数据。V-Net同样是一个经典的3D医学图像分割方法,首先将Dice Loss作为优化目标来训练网络,但该网络无法很好地识别肿瘤信息^[6]。

TransUNet结合卷积的局部性和自注意力的长期语义建模,首先使用卷积模块提取医学图像的局部特征,然后通过自注意力模块计算高级语义特征来提升医学图像分割性能,但对医学图像分割的效果仍然不够^[7]。Swin UN-

et^[8]将文献[9]的研究成果应用于医学图像领域,在多个任务上取得了不错的效果。虽然这些常用的医学图像分割方法都取得了不错的效果,但他们的结构设计并不针对PET-CT多模态图像,缺乏对两种模态特征融合的研究。

当前,对于PET-CT多模态图像上神经母细胞瘤分割任务的研究仍然不够,以往研究主要集中在CT图像上的神经母细胞瘤分割与分析^[10-12]。Li等^[13]提出DS-U-Net,引入形态学的约束损失获得更精细的分割结果,然而这些研究仅针对CT图像,并未探究PET-CT多模态图像上的神经母细胞瘤分割任务。在针对PET-CT多模态图像的研究中,Iantsen等^[14]将Squeeze-and-Excitation Normalization模块加入3D U-Net,在PET-CT的头颈癌分割任务中取得了当时的最好成绩,并获得了HECKTOR2020比赛的冠军。Xue等^[3]在PET-CT图像的肝损伤分割任务中,尝试在Encoder模块中加入多模态融合模块,并在Decoder模块中加入不同阶段特征的融合模块,取得了良好的结果。然而,上述研究并未对神经母细胞瘤的分割任务进行探究。

在无序点云数据的研究领域,Qi等^[15]提出的PointNet是第一个使用深度学习处理无序点云数据的算法,开创了深度学习处理点云的先河。近年来,也有一些研究者使用点云方法来提升医疗图像分割的效果。例如,Balsiger等^[16]基于规则的体素图像分割,进一步使用点云方法提取形状信息以实现更精确的分割,并在坐骨神经的分割中取得了更好效果。Vesal等^[17]引入点云生成方法提取心脏的形状特征以提升模型分割性能。然而,这些方法均未涉及PET-CT多模态图像的研究。

为此,本文提出一种利用点云方法提取肿瘤多模态轮廓形状特征的方法,旨在将肿瘤的多模态形状特征引入之前的分割方法中来提升在PET-CT扫描图像中分割肿瘤的精度。然而,传统肿瘤分割方法大多只简单将PET-CT双模态图像在通道上拼接,再使用卷积神经网络进行自动分割,缺乏对肿瘤形状特征的有效利用。然而,PET图像是一种功能性成像技术,高摄取区域包含生理性高摄取区域和病理性高摄取区域,在临床医生进行手动勾画时,通常会将PET图像与CT图像配准融合,观察高亮区域(高摄取区域)和CT图像提供的解剖信息来排除生理性高摄取区域,因此PET图像会指示肿瘤区域的大致位置。受此启发,本文提出一种新的肿瘤分割方法,通过模仿人类医生手动分割时观察图像的过程,从PET-CT图像中采样生成肿瘤的多模态点云,利用点云进行肿瘤形状特征提取。在评估时将PointNet++的预测输出与卷积神经网络的输出进行融合,以获得最终的预测结果^[18]。

综上,本文首先在PET-CT多模态图像上详细研究了神经母细胞瘤的自动分割方法。然后,提出了一种新的用于PET-CT多模态图像处理的分割算法框架,该框架首先使用3D卷积神经网络大致确定肿瘤的位置,然后在粗分

割的肿瘤位置附近利用PET的值采样生成点云,并使用点云处理网络提取肿瘤的形状特征,最终将两阶段的预测结果进行融合获得最终的分割结果。此外,本文还设计了用于有序点云的特征提取单元(Ordered Point Clouds Processing Unit, OPU)加速模型特征提取速度,从而提升模型训练速度。

2 数据集准备

2.1 自有数据集

上海交通大学附属新华医院核医学科室提供了近10年共计120余例FDG PET-CT扫描样本,本文选取其中的85例病人数据作为自有数据集进行研究。其中,随机选择75例扫描样本作为训练集,剩余10例扫描样本作为验证集。具体的,扫描样本CT分辨率为 512×512 ,物理间距为 $0.98 \text{ mm} \times 0.98 \text{ mm} \times 3.00 \text{ mm}$;PET扫描的分辨率有两种规格:分辨率为 200×200 ,物理间距是 $4.07 \text{ mm} \times 4.07 \text{ mm} \times 3.00 \text{ mm}$;分辨率为 256×256 ,物理间距为 $3.18 \text{ mm} \times 3.18 \text{ mm} \times 3.00 \text{ mm}$ 。

数据集的神经母细胞瘤示例如图1所示,每个病人的PET-CT的序列中大约有10~58帧存在肿瘤,且肿瘤大小、形状各异,数据集由新华医院核医学科室的两名资深临床专家使用临床软件LifeX进行标注,平均每套病例影像标注费时3h。




Fig. 1 PET-CT images of neuroblastoma

图1 神经母细胞瘤的PET-CT图像

2.2 公共数据集

本文使用HECKTOR2021比赛^[19]提供的数据集(<https://www.aicrowd.com/challenges/miccai-2021-hecktor>)进行模型的泛化性研究,该比赛提供了325例病人的头部

PET-CT扫描样本,其中224例用于训练,101例用于测试。由于举办方未公开测试集的标签,本文只使用了224例训练集的数据。其中,224例训练集的数据来自CHGJ, CHMR, CHUS, CHUP和CHUM共5个不同中心,由于不同中心的机器不同,生成的图像略有差异,因此根据比赛要求将数据集处理为提供感兴趣区域的 $144 \times 144 \times 144$ 大小的图像。

3 本文方法

3.1 算法框架

图2为本文算法的框架,采用传统的卷积神经网络(Convolutional Neural Networks, CNN)作为第一阶段网络,以处理PET-CT规则数据。由于CNN具有参数量少、显卡内存需求小的特点,适用于处理3D医学图像。具体而言,本文先将CT图像和PET图像按通道维度拼接在一起,然后输入到类3D U-Net网络以获得肿瘤的粗分割结果;然后利用输入的原多模态图像及粗分割结果计算肿瘤轮廓;最后在粗分割的肿瘤区域附近采样生成多模态点云数据。

多模态点云格式的每个点为 $P_i = \{x_i, y_i, z_i, a_i, b_i\}$, x_i, y_i, z_i 分别为每个点的物理坐标, a_i, b_i 分别为该点的CT强度值和PET强度值。因此,每个点的属性不仅包含空间坐标位置,还包含PET和CT的值,通过学习这些多模态点的形状特征能更好地融合PET-CT多模态信息。本文将第一阶段获得的肿瘤的点云数据输入点云处理网络,提取出肿瘤的形状特征,并将预测结果还原为规则数据与CNN的预测结果融合,得到最终的肿瘤分割结果。




Fig. 2 Network framework

图2 网络框架

3.2 有序点云处理单元

通过传统方法处理点云时,在分组层使用了球查询的方法(Ball query),即利用该点周围一定范围内的点来提取该点的特征,适用于无序的点云数据,但在点较多的情况下,计算最近邻所需时间过长。本文方法中从3D图像中转换得到的点云在空间坐标上是规则的,因此提出了有序点云处理单元(Ordered Point Clouds Processing Unit, OPU),直接计算点的坐标来快速索引邻近的点。如图3所示,首先分两路进行索引,即小范围索引18个点,大范围特征索引32个点;然后分别输入3个由 1×1 卷积层与批归

一化层组成的特征提取层,在点的数量维度上分别得到 $N \times 16$ 和 $N \times 32$ 的特征;最后将两者拼接在一起得到 $N \times 48$ 的点特征,用于输入后续点云处理网络。通过该模块能有效加速点云数据在训练时的处理速度。

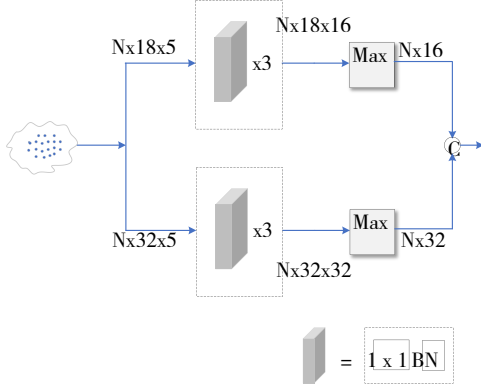


Fig. 3 OPU module

图3 OPU模块

3.3 计算流程

如图2所示,每次训练时将一例经过预处理的体素数据 $x_0 \in R^{C \times L \times H \times W}$ 输入CNN(图2中3D卷积模型)。本文中 $L = H = W = 144, C = 2$,由于预处理时要将CT图像与PET图像在通道上进行拼接,因此通道数为2,且因为卷积网络结构限制,输入图像分辨率无法改变。

在CNN编码器的第一层,特征图经过两次3D卷积后特征维度大小不变,通道数变为64,再经过一次最大池化层后特征维度变为原来的一半,即特征图为 $x_1 \in R^{64 \times \frac{L}{2} \times \frac{H}{2} \times \frac{W}{2}}$ 。随后在编码器的每层中通道数变为原来的2倍,分辨率下降为原来的一半,经过3层下采样后特征图为 $x_4 \in R^{512 \times \frac{L}{16} \times \frac{H}{16} \times \frac{W}{16}}$,可将其拉平成长度为729的序列,即 $x_5 \in R^{512 \times 729}$ 。接下来,将该序列输入自注意力融合模块,经过12层自注意力模块进行处理,序列的长度与宽度不会变化,可重新排列为 $x_6 \in R^{512 \times \frac{L}{16} \times \frac{H}{16} \times \frac{W}{16}}$ 的特征图,再输入CNN的解码器模块。在扩散路径阶段,每一层通道数变为原来的一半,分辨率变为原来的2倍,经过4层后特征图大小为 $x_{10} \in R^{64 \times L \times H \times W}$ 。最后,经过一层卷积与sigmoid函数概率化后,得到通道数为1的粗分割预测图 $x_{11} \in R^{1 \times L \times H \times W}$ (图2中预测图1)。

本文基于粗分割预测图与原输入采样生成点云(图2中点云) $x_{12} \in R^{n \times 5}$,设置 $n=30\ 000$,将其送入点云处理网络PointNet++(图2中点云分割网络)。在PointNet++的收缩路径中,第一层使用最远点采样方法采样出4 096个点,然后在基本点的一定空间距离内采样获得点群,点群经过全连接层和批归一化层计算得到点的特征表示,最终获得特征图 $x_{13} \in R^{m \times W}$,其中 $m = 4\ 096, W = 32$ 。每经过一层下采样层,特征图点数为原来的四分之一,特征数为原来的两倍,经过4层后特征图为 $x_{17} \in R^{\frac{m}{256} \times W \times 16}$ 。

随后,将该特征图输入扩张通路(同U-Net的设计),最终获得的特征图为 $x_{21} \in R^{m \times 128}$ 。再之,经过全连接层与sigmoid层概率化得到最终点的预测图,将点的预测概率图按空间位置映射到原图,获得概率图2(图2中预测图2)。最后,将两个预测图按权重融合作为最终预测结果(图2中最终预测图)。

3.4 损失函数

为了解决3D图像分割任务中存在的严重类别不平衡,本文使用Focal Loss^[20]和Dice loss^[6]的复合损失函数对网络进行训练,以提升模型精确度。并在PointNet++的训练中使用交叉熵损失函数(CrossEntropy loss)。具体计算公式公式如式(1)一式(3)所示。

$$L_{Dice}(y, \hat{y}) = 1 - \frac{2 \sum_i y_i \hat{y}_i + 1}{\sum_i y_i + \sum_i \hat{y}_i + 1} \quad (1)$$

$$L_{Focal}(y, \hat{y}) = -\frac{1}{N} \sum_i y_i (1 - \hat{y}_i)^\gamma \ln(\hat{y}_i) \quad (2)$$

$$L_{CE}(y, \hat{y}) = -\frac{1}{N} y_i \log \hat{y}_i + (1 - y_i) \log(1 - \hat{y}_i) \quad (3)$$

因此,总损失定义为:

$$L_{final} = L_{Dice} + L_{Focal} + L_{CE} \quad (4)$$

式中: $y_i \in \{0, 1\}$ 为标签中的体素点; $\hat{y}_i \in [0, 1]$ 为算法预测出来的体素点上的概率值; N 为输入数据中体素点的总数;实验中Focal loss的超参数 γ 依据原文设置为2。

4 实验结果与分析

本文肿瘤分割实验基于上述两个数据集,为了保证实验公正性,采用的超参数均一致。对于粗分割阶段使用的SE-Based U-Net,按照原文设置进行训练;对于PointNet++,根据之前描述的方法,在PET-CT规则数据上采样出2个关于肿瘤轮廓的多模态点云用于训练;对于点云数据的数据增强,对输入的点云应用常用的数据增强方法进行随机抖动和随机3D旋转,类似于图像中的变形与随机旋转。本文卷积网络训练的损失函数使用Dice loss和Focal loss组成的复合函数,PointNet++网络训练的损失函数使用交叉熵损失,网络每训练300个次使用AdamW优化器进行训练,学习率设置为0.000 1。整个训练过程在一台Ubuntu服务器上完成,该服务器配备两张NVIDIA RTX3090 GPU(显存24 GB),仅使用了上述两个网络的源码,未使用其他部分的代码。

同时,实验所使用的的评估函数包括Dice系数(Dice Similarity Coefficient, DSC)、精准度(Precision)、召回率(Recall)、交并比(Intersection over Union, IoU)及豪斯多夫距离(Hausdorff Distance, HD)。具体计算公式如式(5)一式(9)所示:

$$DSC = \frac{2 \times TP}{FP + 2 \times TP + FN} \quad (5)$$

$$Precision = \frac{TP}{TP + FP} \quad (6)$$

$$Recall = \frac{TP}{TP + FN} \quad (7)$$

$$IoU = \frac{TP}{FP + TP + FN} \quad (8)$$

$$HD(X, Y) = \max \{ \sup_{x \in X} \inf_{y \in Y} d(x, y), \sup_{y \in Y} \inf_{x \in X} d(x, y) \} \quad (9)$$

式中: TP 为分类正确的正样本数量; FP 为分类错误的正样本数量; TN 为分类正确的负样本数量; FN 为分类错误的负样本数量; X, Y 为度量空间 M 的两个真子集; d 代表距离。

4.1 实验比较

本文实验旨在比较常用的 3D 多模态图像分割方法, 由于 3D 算法需要大量的显卡内存, 因此可比较的模型不多。综合选择了 3D U-Net、V-Net 和 SE-Based U-Net 方法, 并使用相同的评价指标进行评估, 实验结果如表 1 所示。

Table 1 Comparative experiments among the proposed method and various 3D methods

表 1 本文方法与多种 3D 方法的比较结果

Approachs	DSC/%	Precision/%	Recall/%	IoU/%	HD/mm
3D U-Net	81.27	90.42	74.12	81.79	11.72
V-Net	81.83	89.37	77.52	81.77	14.62
Baseline	83.41	90.93	77.66	82.73	9.67
Ours	86.51	93.05	80.61	84.36	7.40

由此可知, 本文所提出方法在 DSC 上为 86.51%, 在 Precision 上为 93.05%, 在 Recall 上为 80.61%, 在 IoU 上为 84.36%, 在 HD 上为 7.40 mm, 相较于其他方法表现更优。综上, 本文所提出方法在 PET-CT 多模态神经母细胞瘤分割任务中具有更强的竞争力, 证明结合肿瘤的形状特征具有意义。

4.2 多模态融合效果实验

本文实验比较了所提多模态融合方法与单模态图像

输入之间的分割性能, 实验结果如表 2 所示。由此可见, 只使用 CT 图像的效果最差, DSC 为 78.16%; 只使用 PET 图像的效果略有提升, DSC 为 81.54%; 双模态图像融合后的效果最优, DSC 为 86.51%。实验证明, 在 PET-CT 图像处理中, PET 图像对肿瘤分割的意义大于 CT 图像, 且多模态特征融合十分必要, 该方法值得进一步深入研究。

Table 2 Experimental results of different modal inputs

表 2 不同模态输入的实验结果

Approachs	DSC/%	Precision/%	Recall/%	IoU/%	HD/mm
PET	81.54	87.17	78.06	78.81	12.9
CT	78.16	82.91	77.21	79.99	28.88
PET-CT	86.51	93.05	80.61	84.36	7.40

4.3 公共数据集上的比较实验

为了验证本文模型的鲁棒性, 在 HECKTOR2021 头颈癌的 PET-CT 图像数据集上进行验证, 将 CHUS 部分数据作为验证集来评估结果, 实验结果如表 3 所示。

Table 3 Experimental results of different methods on the Hecktor 2021 public dataset

表 3 不同方法在 Hecktor2021 公共数据集上的实验结果 %

Approachs	DSC	Precision	Recall
SE-Based U-Net	75.1	81.6	75.1
nnU-Net	77.6	77.7	82.5
UNTER	73.7	78.3	75.6
Ours	75.2	82.8	72.8

由此可见, 所提模型相较于基线方法 DSC 提升了 0.1%, 但相较于 nnU-Net 的 DSC 降低了 2.4%; 在 Precision 上相较于基线方法提升了 0.12%^[21]。实验表明, 本文方法在分割结果上相较于基线方法具有一定程度的提升, 证明了该方法在 PET-CT 图像处理中具有一定的鲁棒性。

图 4 展示了本文方法和 Baseline 在该数据集上的可视化结果, 从左至右依次为 CT 图、PET 图、标签图、其他方法的结果、本文方法结果。由此可见, 本文方法所提取的图片更接近肿瘤轮廓线, 证明了该方法在分割时融合形状特征的有效性。




Fig. 4 Visualization result

图 4 可视化结果

5 结语

神经母细胞瘤是婴幼儿中常见的恶性肿瘤之一, PET-CT扫描在该疾病的诊断中具有重要的应用价值,因此在自动分割PET-CT图像时,高效地融合双模态图像特征十分必要。

为此,本文提出了一种利用点云网络提取肿瘤多模态形状特征并融合的方法。实验证明,该方法能提升PET-CT多模态图像的肿瘤分割性能,使分割的肿瘤形状更精确,助于节省医生手动分割的时间,提升临床工作效率。

由于淋巴瘤的分布广泛,直接使用全套规则数据进行分割需要巨大的内存。为此,本文将计划研究PET-CT扫描在全身淋巴瘤的瘤负荷计算中的应用,探索更高效的分割方法以更准确地测量淋巴瘤的瘤负荷,有望让该方法在临床医疗中得到广泛推广与应用。

参考文献:

- [1] FU X, BI L, KUMAR A, et al. Multimodal spatial attention module for targeting multimodal PET-CT lung tumor segmentation [J]. *IEEE Journal of Biomedical and Health Informatics*, 2021, 25(9): 3507-3516.
- [2] KUMAR A, FULHAM M, FENG D, et al. Co-learning feature fusion maps from PET-CT images of lung cancer [J]. *IEEE Transactions on Medical Imaging*, 2019, 39(1): 204-217.
- [3] XUE Z, LI P, ZHANG L, et al. Multi-modal co-learning for liver lesion segmentation on PET-CT images [J]. *IEEE Transactions on Medical Imaging*, 2021, 40(12): 3531-3542.
- [4] 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: 234-241.
- [5] ÇIÇEK Ö, ABDULKADIR A, LIENKAMP S S, et al. 3D U-Net: learning dense volumetric segmentation from sparse annotation [C]// *International Conference on Medical Image Computing and Computer-Assisted Intervention*, 2016: 424-432.
- [6] MILLETARI F, NAVAB N, AHMADI S A. V-Net: fully convolutional neural networks for volumetric medical image segmentation [DB/OL]. <https://arxiv.org/abs/1606.04797>.
- [7] CHEN J, LU Y, YU Q, et al. Transunet: transformers make strong encoders for medical image segmentation [DB/OL]. <https://arxiv.org/abs/2102.04306>.
- [8] CAO H, WANG Y, CHEN J, et al. Swin-Unet: Unet-like pure transformer for medical image segmentation [DB/OL]. <https://arxiv.org/abs/2105.05537>.
- [9] LIU Z, LIN Y, CAO Y, et al. Swin transformer: hierarchical vision transformer using shifted windows [DB/OL]. <https://arxiv.org/abs/2105.05537>.
- [10] VU R H, RANGAYYAN R M, DEGLINT H J, et al. Segmentation and analysis of neuroblastoma [J]. *Journal of the Franklin Institute*, 2007, 344(3-4): 257-284.
- [11] RANGAYYAN R M, BANK S, BOAG G S. Landmarking and segmentation of computed tomographic images of pediatric patients with neuroblastoma [J]. *International Journal of Computer Assisted Radiology and Surgery*, 2009, 4(3): 245-262.
- [12] DEGLINT H J, RANGAYYAN R M, AYRES F J, et al. Three-dimensional segmentation of the tumor in computed tomographic images of neuroblastoma [J]. *Journal of Digital Imaging*, 2007, 20(1): 72-87.
- [13] LI S, ZHANG X, WANG X, et al. Children's neuroblastoma segmentation using morphological features [C]// *International Workshop on Machine Learning in Medical Imaging*, 2019: 81-88.
- [14] IANTSEN A, VISVIKIS D, HATT M. Squeeze-and-excitation normalization for automated delineation of head and neck primary tumors in combined PET and CT images [C]// *3D Head and Neck Tumor Segmentation in PET/CT Challenge*, 2020: 37-43.
- [15] QI C R, SU H, MO K, et al. Pointnet: deep learning on point sets for 3D classification and segmentation [C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017: 652-660.
- [16] BALSIGER F, SOOM Y, SCHEIDEGGER O, et al. Learning shape representation on sparse point clouds for volumetric image segmentation [C]// *International Conference on Medical Image Computing and Computer-Assisted Intervention*, 2019: 273-281.
- [17] VESAL S, GU M, KOSTI R, et al. Adapt everywhere: unsupervised adaptation of point-clouds and entropy minimization for multi-modal cardiac image segmentation [J]. *IEEE Transactions on Medical Imaging*, 2021, 40(7): 1838-1851.
- [18] QI C R, YI L, SU H, et al. PointNet++: deep hierarchical feature learning on point sets in a metric space [C]// *Proceedings of the 31st International Conference on Neural Information Processing Systems*, 2017: 5100-5109.
- [19] ANDREARCZYK V, OREILLER V, BOUGHADAD S, et al. Overview of the HECKTOR challenge at MICCAI 2021: automatic head and neck tumor segmentation and outcome prediction in PET/CT images [DB/OL]. <https://arxiv.org/abs/2201.04138>.
- [20] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [DB/OL]. <https://arxiv.org/abs/1708.02002>.
- [21] SOBIROV I, NAZAROV O, ALASMAWI H, et al. Automatic segmentation of head and neck tumor: how powerful transformers are? [DB/OL]. <https://arxiv.org/abs/2201.06251>.

(责任编辑:刘嘉文)