

DOI:10.3969/j.issn.1005-202X.2025.07.012

医学影像物理

## 基于深度学习的胰腺肿瘤靶区自动分割

陈超爽<sup>1</sup>, 曹洋森<sup>2</sup>, 朱晓斐<sup>2</sup>, 曾福斌<sup>2</sup>, 顾蕾<sup>2</sup>, 江林宫<sup>2</sup>, 张火俊<sup>2</sup>

1. 中国人民解放军92493部队医院核医学肿瘤科, 辽宁 葫芦岛 125000; 2. 中国人民解放军海军军医大学第一附属医院放射治疗科, 上海 200433

**【摘要】目的:**研究基于胰腺增强CT的卷积神经网络进行胰腺肿瘤靶区(GTV)自动分割的可行性及准确性。**方法:**回顾性选取114例胰腺癌患者的定位增强CT影像,使用AccuContour进行GTV手动勾画后导入AccuLearning按照8:1:1的比例随机抽取数据作为训练集、验证集和测试集,分别使用Flex和Segresnet两种网络结构进行自动分割模型训练,每种网络结构固定训练参数不变连续训练3次。模型的评价指标包括戴斯相似系数(DSC)、95%豪斯多夫距离(HD95)、对称位置的平均表面距离(ASSD)、体素相对误差(RVD)。**结果:**模型训练阶段, Flex组中Flex-3测试结果较差,最小DSC为0.14%,平均DSC为56.30%; Flex-1测试结果较优,最小DSC为47.90%,平均DSC为67.35%。Segresnet组中Segresnet-2测试结果较差,最小DSC为0.00%,平均DSC为42.46%; Segresnet-3测试结果较优,最小DSC为42.65%,平均DSC为63.28%。固定测试阶段, Segresnet-3组取得相对最优的DSC和RVD均值分别为63.88%和29.41%, Segresnet-2组取得相对最优的ASSD均值为4.43 mm, Segresnet-1组取得相对最优的HD95均值为12.87 mm。**结论:** Flex和Segresnet两种卷积神经网络结构都可用于胰腺肿瘤靶区的自动分割训练, Segresnet构建的分割模型的综合评估更优。

**【关键词】**胰腺癌; 肿瘤靶区; 分割; 深度学习; 卷积神经网络

**【中图分类号】**R318.14

**【文献标志码】**A

**【文章编号】**1005-202X(2025)07-0923-06

## Automatic pancreatic cancer GTV segmentation based on deep learning

CHEN Chaoshuang<sup>1</sup>, CAO Yangsen<sup>2</sup>, ZHU Xiaofei<sup>2</sup>, ZENG Fubin<sup>2</sup>, GU Lei<sup>2</sup>, JIANG Lingong<sup>2</sup>, ZHANG Huojun<sup>2</sup>

1. Department of Nuclear Medicine and Oncology, Chinese People's Liberation Army 92493 Military Hospital, Huludao 125000, China;

2. Department of Radiation Oncology, Changhai Hospital of Naval Medical University, Shanghai 200433, China

**Abstract: Objective** To investigate the feasibility and accuracy of convolutional neural networks for automatically delineating the pancreatic cancer gross target volume (GTV) in pancreatic enhanced CT. **Methods** The localizable enhanced CT images of 114 patients with pancreatic cancer were retrospectively selected, in which the GTV was manually delineated using AccuContour. The imaging data were then import to AccuLearning and randomly divided as the training set, validation set and test set at a ratio of 8:1:1. Flex and Segresnet were used to train the automatic segmentation model, with each network structure trained continuously 3 times using fixed training parameters. The model was evaluated in terms of Dice similarity coefficient (DSC), 95% Hausdorff distance (HD95), average symmetric surface distance (ASSD) and relative volume difference (RVD). **Results** In the model training phase, Flex-3 test results in Flex group were the worst, with a minimum DSC of 0.14% and an average DSC of 56.30%, while Flex-1 performed well, achieving a minimum DSC of 47.90% and an average DSC of 67.35%. Meanwhile, Segresnet-2 in Segresnet group had the worst test results, with a minimum DSC of 0.00% and an average DSC of 42.46%, while Segresnet-3 test results were better, with a minimum DSC of 42.65% and an average DSC of 63.28%. In the fixed testing phase, the best results among all were as follows: average DSC and RVD values of 63.88% and 29.41% in Segresnet-3 group, average ASSD value of 4.43 mm in Segresnet-2 group, and average HD95 value of 12.87 mm in Segresnet-1 group. **Conclusion** Both Flex and Segresnet architectures of convolutional neural network can be used for the automatic pancreatic tumor GTV segmentation training, with Segresnet performing better in comprehensive evaluation.

**Keywords:** pancreatic cancer; gross tumor volume; segmentation; deep learning; convolutional neural network

**【收稿日期】**2025-02-12

**【基金项目】**海军军医大学第一附属医院基础医学研究专项(2023PY22)

**【作者简介】**陈超爽, 主治医师, 研究方向: 恶性肿瘤的综合治疗以及放射治疗物理技术应用, E-mail: 258448423@qq.com

**【通信作者】**曹洋森, 硕士, 物理师, 副主任医师, 研究方向: 肿瘤放射物理, E-mail: caoyangsen@163.com

### 前言

2005年到2020年,我国胰腺癌男性癌症死亡率从第7位上升至第6位,女性从第9位上升至第8位<sup>[1]</sup>,整体发病率呈现快速上升趋势。2022年,预计我国新增胰腺癌患者134 374例,死亡131 203例<sup>[2]</sup>。体部立体定向放射治疗(Stereotactic Body Radiotherapy, SBRT)是胰腺癌综合治疗的重要手段之一,它通常在短时间内将高剂量的辐射能量传递到肿瘤组织,同时保护好肿瘤周边的正常组织<sup>[3-4]</sup>。与单纯化疗或联合传统常规分割外照射相比,SBRT的大分割放疗模式具有更好的疗效,已逐步成为胰腺癌治疗过程中非常重要的手段<sup>[5-8]</sup>。CT影像是胰腺癌诊断及可切除评估最常用的成像方式。由于胰腺位于腹腔深处且伴行众多血管和其他组织,采用增强CT可有效提高对胰腺肿瘤的检测和肿瘤靶区(Gross Tumor Volume, GTV)的勾画。基于增强CT的胰腺癌SBRT的GTV勾画在准确性和效率上仍存在不足。受限于胰腺结构的复杂性和周围组织的干扰,基于图谱库的自动分割往往分割精度不高。同时,针对同一CT的GTV勾画,即使不同临床医师之间也可能存在较大差异<sup>[9-11]</sup>。这些差异将影响SBRT计划设计的剂量分布,最终影响肿瘤控制和患者生存。此外,医生依据经验进行的手动GTV勾画耗费大量的人力成本,而现有的自动分割技术仍需要耗费大量的人力和时间成本进行手动修正。

Flex U-Net基于传统U-Net模型来纠正手动标注带来的噪声,完善自动分割模型性能,在直肠癌放疗中对GTV和危及器官自动分割有较好表现,戴斯相似系数(DSC)为0.80,95%豪斯多夫距离(HD95)为16.9 mm<sup>[12]</sup>。Segresnet最早应用于MRI脑部肿瘤自动分割肿瘤亚区域,采用基于编码器-解码器架构的语义分割网络,模型中添加变分自动编码器分支来重建输入图像本身,以规范共享解码器并对其各层施加额外的约束<sup>[13]</sup>。自动分割软件可以在提高影像结构分割效率的基础上,提升靶区和危及器官分割的精确度。但目前基于腹部,尤其是胰腺肿瘤的自动分割研究尚不多见。本研究旨在探讨利用Flex U-Net和Segresnet卷积神经网络对腹部增强CT影像中胰腺GTV进行自动分割的可行性和准确性。

### 1 资料与方法

回顾性分析上海长海医院2019年10月至2022年9月期间使用射波刀进行立体定向放射治疗的胰腺癌患者的增强CT影像。纳入标准:(1)具有穿刺病理活检确诊的胰腺癌患者;(2)年龄18~80岁;(3)肿瘤最大径≤5 cm;(4)预计生存期>6个月;(5)

ECOG评分≤2;(6)排除有放疗史、多发病灶、远处转移的患者。最终符合入组标准共计114例患者,其基本资料见表1。收集入组患者共计118组增强CT影像(4例患者进行过2程胰腺SBRT),分配其中103例患者的107组CT用于模型训练,剩余11例患者的11组CT用于模型测试。本研究已通过海军军医大学第一附属医院伦理委员会审批(审批号:CHEC2020-099)。

表1 患者基本情况

Table 1 Baseline characteristics of patients

基本情况	训练数据集 (n=103)	测试数据集 (n=11)
年龄(岁, $\bar{x}\pm s$ )	62.2±10.1	62.4±7.7
性别[例(%)]		
男	64(62.1)	7(63.6)
女	39(37.9)	4(36.4)
T分期[例(%)]		
T <sub>1</sub>	6(5.8)	1(9.1)
T <sub>2</sub>	33(32.0)	4(36.4)
T <sub>3</sub>	29(28.2)	1(9.1)
T <sub>4</sub>	35(34.0)	5(45.4)
肿瘤位置[例(%)]		
胰腺头颈部	69(67.0)	9(81.8)
胰腺体尾部	34(33.0)	2(18.2)

定位方法:使用飞利浦16排大孔径CT(Brilliance Big Bore, 荷兰)进行CT定位扫描。所有患者在接受定位和治疗前都被要求空腹4 h以上,尽可能保证其空腹状态,减小胃肠充盈不一致带来治疗分次期间的位置差异。增强期扫描条件为:高压注射器经前臂静脉以5.5 mL/s的注射速率,向患者注射90~95 mL浓度为370 mgI/mL的碘普罗胺造影剂。注射造影剂后50 s,管电压120 kVp、管电流400 mAs、1.5 mm层厚无间隔螺旋扫描,扫描螺距为0.938,扫描范围为肿瘤上下界各自增加5 cm。

肿瘤勾画:所有胰腺GTV均由1名高年资主治医师在AccuContour上进行手动勾画,并由1名副主任医师进行确认。手动勾画均在增强CT上完成。

模型训练:107组CT影像数据导入AccuLearning中进行自动分割模型训练。系统按照8:1:1的比例随机抽取CT数据作为训练集、验证集和测试集,对应的CT数据数分别为:86、11、10。训练目标为GTV,训练参数为:(1)网络结构(Mode):Flex和Segresnet;(2)批量大小(batch\_size):16,为1次迭代中使用的样本数,batch size越大,表示当前批次的分布越接近总体的数据集分布,模型会朝着一个较为稳定的方向拟合;(3)学习率(LearningRate):0.000 3;(4)损失函数(LossFunction):Dice和CE,其中Dice损失函数(Dice Similarity Coefficient Loss

Function, Dice Loss)是基于Dice系数的一个损失函数,主要用于衡量模型分割结果与真实标注之间重叠程度的指标,直接优化分割的重叠区域,对类别不平衡问题表现鲁棒,通常用于医学图像分割任务。交叉熵损失函数(Cross-Entropy Loss Function, CE Loss)是一种衡量预测分布和真实分布之间差异的损失函数,适用于多类分类问题,并通过概率分布的匹配来优化分割任务。(5)训练轮次(MaxmumEpochs):200。考虑到验证集和测试集在训练过程中的随机性,使用相同的训练参数连续训练3次,用以测试不同网络模型训练结果的稳定性。最终生成的分割模型分别命名为Flex-1、Flex-2、Flex-3和Segresnet-1、Segresnet-2、Segresnet-3。

模型测试:将训练好的6个分割模型和固定测试集的11组增强CT影像导入AccuContour,并完成胰腺肿瘤的自动分割。以手动勾画的结构为参考,统计评估分割模型的评价指标。

评估指标(Evaluation Metrics):主要分割模型的评价指标包括DSC、HD95、体素相对误差(Relative Volume Difference, RVD)、对称位置的平均表面距离(Average Symmetric Surface Distance, ASSD),综合评估模型的分割情况。

## 2 结果

### 2.1 模型训练阶段随机测试集的评估情况

模型训练阶段随机分配10组CT数据作为模型训练阶段的测试,训练集在训练过程中随机测试的DSC值见表2。由于胰腺肿瘤位置的复杂性且每次训练的测试数据均为随机抽取,尽管固定训练参数不变,两种网络连续3次训练的分割模型测试结果仍然存在较大的差异。Flex组中Flex-3测试结果较差,最小DSC为0.14%,平均DSC为56.30%;Flex-1测试结果较优,最小DSC为47.90%,平均DSC为67.35%;Segresnet组中Segresnet-2测试结果较差,最小DSC为0.00%,平均DSC为42.46%;Segresnet-3测试结果较优,最小DSC为42.65%,平均DSC为63.28%。

表2 模型训练阶段随机测试数据的分割评估(%)

Table 2 Segmentation evaluation on random test data in model training phase (%)

模型名称	DSC均值	DSC最小值	DSC最大值	DSC中位值
Flex-1	67.35	47.90	79.69	69.82
Flex-2	63.37	19.74	81.94	68.98
Flex-3	56.30	0.14	77.45	62.27
Segresnet-1	62.20	26.72	72.34	66.33
Segresnet-2	42.46	0.00	74.35	56.97
Segresnet-3	63.28	42.65	78.92	61.57

### 2.2 模型测试阶段固定测试集的评估情况

模型测试阶段收集11组数据作为固定测试集进行实际临床外部测试,测试评估结果见表3。相较于训练阶段随机抽取的测试集,固定测试数据显示各组之间DSC、HD95、RVD和ASSD的差异不大。Segresnet-3组取得相对最优的DSC和RVD均值分别为63.88%和29.41%,Segresnet-2组取得相对最优的ASSD均值为4.43mm,Segresnet-1组取得相对最优的HD95均值为12.87mm。测试结果可见,Flex因为架构相对简单,具有一定的灵活性,能够动态调整特征提取的范围和细粒度程度,但在捕获胰腺肿瘤这种相对复杂的图像特征和表达高阶空间信息时可能存在不足;Segresnet具有残差网络的强大特征学习能力,其深层网络结构在捕获全局信息时具有优势,残差连接能够更有效地缓解深层网络中的梯度消失问题,从而促进特征的传播和学习。此外,Segresnet通过多层卷积对图像细节进行更深层次的特征提取,在对噪声和低对比度区域的处理上显示出更好的稳定性,这可能是其在胰腺肿瘤图像的分割任务中优于Flex的原因。

表3 模型测试阶段固定测试数据的分割评估

Table 3 Segmentation evaluation on fixed test data in model testing phase

模型名称	DSC/%	HD95/mm	RVD/%	ASSD/mm
Flex-1	61.84±12.46	18.52±15.01	35.65±22.50	5.07±1.80
Flex-2	61.68±9.07	16.89±6.86	37.13±13.15	5.08±1.21
Flex-3	62.91±13.79	15.52±8.47	38.30±20.24	4.93±1.95
Segresnet-1	60.80±11.73	12.87±4.87	42.11±19.58	4.71±1.62
Segresnet-2	62.12±12.25	13.39±7.27	38.24±17.02	4.43±1.97
Segresnet-3	63.88±11.55	14.63±5.59	29.41±19.10	4.67±1.69

图1展示使用Segresnet-3分割模型进行临床测试的3个案例,分别代表分割结果良好(DSC≥0.7)、一般(0.5≤DSC<0.7)、较差(DSC<0.5)。如图1所示,案例1肿瘤体积相对较大,总体自动分割和手动勾画的一致性较好;案例2自动分割的结果更为贴近肿瘤的实际边缘,未考虑可能的临床侵犯所需的照射范围,和手动勾画存在一定的经验差异;案例3肿瘤体积相对较小,肿瘤边界较为模糊,自动分割模型的分割区域较小,且将肿瘤外两处正常肠道误分割为GTV,导致DSC值较低。

## 3 讨论

基于胰腺肿瘤的自动分割一直是肿瘤自动分割领域的难题,目前基于CT结构自动分割的解决方案

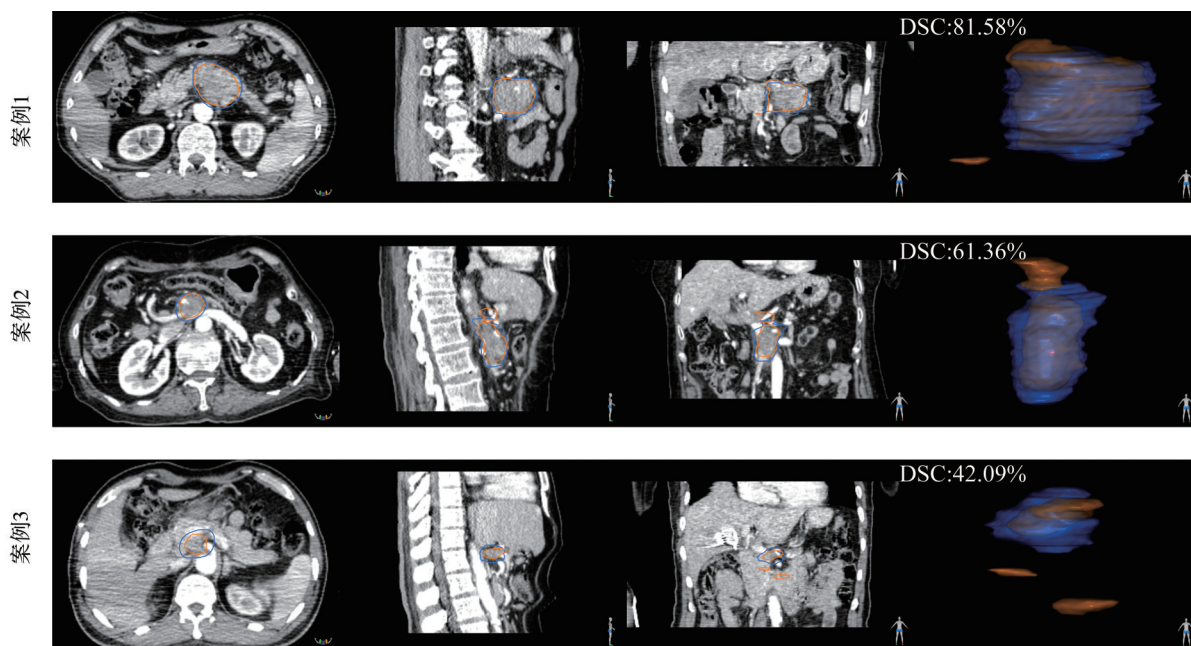


图1 Segresnet-3模型测试不同案例的分割结果对比

Figure 1 Comparison of segmentation results for different cases tested by Segresnet-3 model

案例1:良好(DSC>0.7);案例2:一般(0.5<DSC<0.7);案例3:较差(DSC<0.5)(图中蓝色为手动分割GTV标注区域,橙色为自动分割GTV预测区域)

主要有两种:一是基于图谱库的自动分割;二是基于深度学习的自动分割。本文对这两种自动分割方案进行回顾讨论。基于图谱库的自动分割研究较为成熟且商业化,但其应用范围更多局限于头颈部等相对较为刚性的人体结构部位(如脑干、下颌骨等)或者与周围灰度差异较大的组织(如肺、脊髓等)。对于腹部受蠕动及充盈影响形变较大的器官(如十二指肠、空回肠、结肠)以及与临近器官灰度相似的胰腺,基于图谱库的自动分割效果不理想,这些器官上深度学习优于图谱库分割。Gibson等<sup>[14]</sup>研究比较密集扩张卷积网络、多数投票、联合标签融合3种方法在肝脏、胰腺、胃和食管的自动分割,结果显示基于多数投票无法完成胰腺分割,肝脏、胃、食管的DSC指数分别为0.85、0.49、0.25;基于联合标签融合的胰腺、肝脏、胃、食管的DSC指数分别为0.37、0.93、0.72、0.54;基于密集扩张网络的胰腺、肝脏、胃、食管的DSC指数分别为0.66、0.92、0.83、0.73,除肝脏外显著优于另外两种算法。针对胰腺开展的众多研究中平均DSC值为0.45~0.74<sup>[15-18]</sup>,不同研究间差异较大。基于深度学习的自动分割应用范围更为广泛,除上述图谱库适用的器官结构外,还可应用于解剖结构相对固定的器官(如胃、膀胱等)以及部分临床靶区(如乳腺癌胸壁区域、盆腔淋巴引流区域)。胰腺肿瘤基于深度学习的分割研究主要集中于近几年,依据分割图像的来源不同主要分为基于MRI和CT两

种自动分割。

在基于MRI影像的深度学习自动分割研究中,Liang等<sup>[19]</sup>研究一种基于多参数MRI的胰腺肿瘤深度神经网络自动分割模型,使用一种基于方窗的卷积神经网络对27例患者的37套MRI数据进行训练及测试,最终测试集平均DICE值为0.73。Chen等<sup>[20]</sup>提出一种基于ResUNet的螺旋变换分割方法,收集73例患者的多序列MRI,包括65例ADC、69例DWI、68例T<sub>1</sub>W和70例T<sub>2</sub>W。研究主要在T<sub>2</sub>W数据集上评估该胰腺癌分割模型,并在ADC、DWI和T<sub>1</sub>W数据集进一步验证该模型,同时使用MSD的281例公共数据库标注图像进行验证测试。训练比较使用2D、2.5D、3D网络的分割模型平均DSC为0.49、0.55、0.61,使用Spiral-ResUNet模型的平均DSC为0.66。Choi等<sup>[21]</sup>基于21例MR自适应放疗胰腺癌患者共126套MR影像,计划MR和第1~4分次治疗图像集作为训练集(n=105),而测试集(n=21)包括第5分次的图像,分割模型使用5折交叉验证在训练集上进行训练,对比评估Segresnet、Segresnet 2D和SwinUNETR这3种深度学习模型架构在GTV和危及器官自动分割表现,研究显示SwinUNETR模型表现最佳,总体训练DSC为0.88±0.06,测试DSC为0.78,其中对于GTV的DSC为0.79,显示出自动分割与临床靶区较好的一致性。

在基于CT影像的深度学习自动分割研究中,

Wang等<sup>[22]</sup>收集400组CT影像测试了基于不同流行CNN主干网的IAG网络(VGG和2D U-net)和其他4种公开的分割方法进行比较,IAG-Net在使用VGG-Net的胰腺肿瘤分割平均DSC为0.54,在使用U-Net的胰腺肿瘤分割平均DSC为0.60。Shen等<sup>[23]</sup>针对增强CT扩张胰管自动分割问题提出一种解剖学的注意力策略。通过胰腺定位和胰管分割两步操作,利用粗胰腺掩膜操作引导全卷积网络关注胰腺解剖结构并忽略不必要特征。同时,采用多尺度聚合方案V-Net/U-Net和管状结构IN/BN增强作为全卷积网络的额外输入通道。在30例对比增强腹部CT的实验表明,具有V-Net和IN基线的NMCPMNet网络表现出了最佳性能,其中DSC最高为0.64,HD95最低为0.56 mm,优于其他仅使用单期CT扫描的胰管分割方法。该策略不仅有助于关注胰腺区域,而且通过增强管状结构使FCNs能够捕获类似血管的结构,可能适用于其他目标解剖结构中的管状结构分割任务。此外,最近邱丹丹等<sup>[24]</sup>提出基于多尺度视觉信息和非局部目标挖掘的非显著小肿瘤分割框架,通过分层地聚合多尺度特征,得到清晰、完整的肿瘤表征,在281例病人的胰腺肿瘤数据集中实证表明DSC为0.58,ACC为0.998 3。

本研究前期使用AccuLearning内置的Flex、UNet、VNet、Highrenet和Segresnet进行探索性预实验,UNet、VNet、Highrenet均未能取得较好的分割结果。针对性使用Flex和Segresnet,优化训练参数并构建胰腺GTV的分割模型,DSC平均可达0.621和0.623,优于常规基于CT的胰腺肿瘤自动分割模型。但本模型依然存在一定局限性:首先,因胰腺癌行SBRT的患者数量较少,本研究仅入组了118组胰腺增强CT影像,相对于其他靶区分割的研究样本量偏少,需要在后续研究中回顾性和前瞻性收集纳入更多样本数据以提高模型的分割精度;其次,训练得到的分割模型对体积较大的胰腺肿瘤可以取得较好的分割效果,体积较小以及位于胰尾部的肿瘤的分割效果则相对较差。造成这一结果的原因主要有以下3点:(1)小体积肿瘤通常和周围正常组织密度接近,且因为体积小,分割偏差占据全肿瘤体积分的权重比例更高,DSC偏差更易显著;(2)小体积以及位于胰尾部的胰腺肿瘤患者通常优先考虑手术,SBRT入组的样本量相对较少,模型训练集的情况存在偏差;(3)本研究基于胰腺SBRT的GTV开展,勾画区域除影像学肉眼可见的肿瘤区外,通常会结合临床经验外放部分高危易侵犯的区域,这在小体积胰腺肿瘤的情况下更为显著。

综上所述,基于AccuLearning的卷积神经网络

Flex和Segresnet都可以一定程度上完成基于增强CT的胰腺GTV的自动分割,节约人工勾画靶区的时间成本。在后续研究中一方面需要通过增加小体积以及位于胰尾部的胰腺肿瘤患者的样本量,包括区分是否手术进行分组训练,进一步提升分割模型的综合分割能力;另一方面本研究基于单中心数据集开展,需要通过纳入公共数据集及其他中心胰腺肿瘤分割数据集拓展训练,进一步提升胰腺GTV分割模型的普适性。

## 【参考文献】

- [1] Qi JL, Li ML, Wang LJ, et al. National and subnational trends in cancer burden in China, 2005-20: an analysis of national mortality surveillance data[J]. *Lancet Public Health*, 2023, 8(12): e943-e955.
- [2] Xia CF, Dong XS, Li H, et al. Cancer statistics in China and United States, 2022: profiles, trends, and determinants[J]. *Chin Med J (Engl)*, 2022, 135(5): 584-590.
- [3] Jung J, Yoon SM, Park JH, et al. Stereotactic body radiation therapy for locally advanced pancreatic cancer[J]. *PLoS One*, 2019, 14(4): e0214970.
- [4] Vornhülz M, Anton S, Eross B, et al. Role of stereotactic body radiation in the enhancement of the quality of life in locally advanced pancreatic adenocarcinoma: a systematic review[J]. *Radiat Oncol*, 2022, 17(1): 108.
- [5] Qing SW, Ju XP, Cao YS, et al. Dose escalation of stereotactic body radiotherapy (SBRT) for locally advanced unresectable pancreatic cancer patients with CyberKnife: protocol of a phase I study[J]. *Radiat Oncol*, 2017, 12(1): 6.
- [6] Zhu XF, Li FQ, Ju XP, et al. Prognostic role of stereotactic body radiation therapy for elderly patients with advanced and medically inoperable pancreatic cancer[J]. *Cancer Med*, 2017, 6(10): 2263-2270.
- [7] Zhu XF, Cao YS, Liu WY, et al. Stereotactic body radiotherapy plus pembrolizumab and trametinib versus stereotactic body radiotherapy plus gemcitabine for locally recurrent pancreatic cancer after surgical resection: an open-label, randomised, controlled, phase 2 trial[J]. *Lancet Oncol*, 2021, 22(8): 1093-1102.
- [8] Cui JJ, Jiao F, Li Q, et al. Chinese society of clinical oncology (CSCO): clinical guidelines for the diagnosis and treatment of pancreatic cancer[J]. *J Natl Cancer Cent*, 2022, 2(4): 205-215.
- [9] Cao K, Xia YD, Yao JW, et al. Large-scale pancreatic cancer detection via non-contrast CT and deep learning[J]. *Nat Med*, 2023, 29(12): 3033-3043.
- [10] Park HJ, Shin K, You MW, et al. Deep learning-based detection of solid and cystic pancreatic neoplasms at contrast-enhanced CT[J]. *Radiology*, 2023, 306(1): 140-149.
- [11] Shouman MA, Fuchs F, Walter F, et al. Stereotactic body radiotherapy for pancreatic cancer—a systematic review of prospective data[J]. *Clin Transl Radiat Oncol*, 2024, 45: 100738.
- [12] Sha X, Wang H, Sha H, et al. Clinical target volume and organs at risk segmentation for rectal cancer radiotherapy using the Flex U-Net network[J]. *Front Oncol*, 2023, 13: 1172424.
- [13] Myronenko A. 3D MRI brain tumor segmentation using autoencoder regularization[C]//Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries. Cham: Springer International Publishing, 2019: 311-320.
- [14] Gibson E, Giganti F, Hu YP, et al. Towards image-guided pancreas and biliary endoscopy: automatic multi-organ segmentation on abdominal CT with dense dilated networks[C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2017. Cham: Springer International Publishing, 2017: 728-736.
- [15] Xu ZB, Burke RP, Lee CP, et al. Efficient abdominal segmentation on clinically acquired CT with SIMPLE context learning[J]. *Proc SPIE Int Soc Opt Eng*, 2015, 9413: 94130L.
- [16] Cerrolaza JJ, Reyes M, Summers RM, et al. Automatic multi-

- resolution shape modeling of multi-organ structures[J]. Med Image Anal, 2015, 25(1): 11-21.
- [17] Shimizu A, Ohno R, Ikegami T, et al. Segmentation of multiple organs in non-contrast 3D abdominal CT images[J]. Int J Comput Assist Radiol Surg, 2007, 2(3): 135-142.
- [18] Okada T, Linguraru MG, Hori M, et al. Abdominal multi-organ segmentation from CT images using conditional shape-location and unsupervised intensity priors[J]. Med Image Anal, 2015, 26(1): 1-18.
- [19] Liang Y, Schott D, Zhang Y, et al. Auto-segmentation of pancreatic tumor in multi-parametric MRI using deep convolutional neural networks[J]. Radiother Oncol, 2020, 145: 193-200.
- [20] Chen XH, Chen ZH, Li J, et al. Model-driven deep learning method for pancreatic cancer segmentation based on spiral-transformation [J]. IEEE Trans Med Imaging, 2022, 41(1): 75-87.
- [21] Choi W, Nourzadeh H, Chen Y, et al. Novel deep learning segmentation models for accurate GTV and OAR segmentation in MR-guided adaptive radiotherapy for pancreatic cancer patients[J]. Int J Radiat Oncol Biol Phys, 2023, 117(2S): e462.
- [22] Wang Y, Tang P, Zhou YY, et al. Learning inductive attention guidance for partially supervised pancreatic ductal adenocarcinoma prediction[J]. IEEE Trans Med Imaging, 2021, 40(10): 2723-2735.
- [23] Shen C, Roth HR, Hayashi Y, et al. Anatomical attention can help to segment the dilated pancreatic duct in abdominal CT[J]. Int J Comput Assist Radiol Surg, 2024, 19(4): 655-664.
- [24] 邱丹丹, 任书敏, 张倩, 等. 基于多尺度视觉信息和非局部目标挖掘的肿瘤分割[J]. 计算机应用研究, 2024, 41(12): 3873-3880.
- Qiu DD, Ren SM, Zhang Q, et al. Tumor segmentation based on multi-scale visual information and non-local target mining[J]. Application Research of Computers, 2024, 41(12): 3873-3880.

(编辑:陈丽霞)