

儿童全骨髓全淋巴照射靶区和危及器官自动勾画

解治华^{1,2}, 路娜¹, 刘金锋³, 侯立霞³, 张富利¹

1. 解放军总医院第七医学中心放射治疗科, 北京 100700; 2. 山东省肿瘤医院放射物理技术科, 山东 济南 250000; 3. 山东第一医科大学(山东省医学科学院)放射学院, 山东 泰安 271000

【摘要】目的:基于AccuLearning自动勾画训练系统探讨儿童全骨髓全淋巴照射(TMLI)靶区和危及器官自动勾画的可行性。**方法:**选取2018年至2022年期间30例接受TMLI照射的儿童患者进行研究。患者取仰卧位,采用飞利浦大孔径CT获取CT图像,对靶区和危及器官进行手动勾画和修改,将CT图像和勾画的靶区及危及器官轮廓传至AccuLearning系统,进行自动勾画模型的训练、验证和测试。对测试集中的6例TMLI患者自动勾画结果使用Dice相似性系数(DSC)、95%豪斯多夫距离和平均表面距离进行评估。**结果:**在6例测试集数据中,除晶体难以被自动勾画以外,其它各个靶区和危及器官中仅有1例患者的胃部DSC值为0.59,其余均大于0.70;6例患者胃的平均DSC值为0.76,其余各器官平均DSC值均大于0.80。**结论:**通过该模型自动勾画的靶区和危及器官经简单修改后可满足临床计划设计要求。

【关键词】儿童;放射治疗;全骨髓全淋巴照射;自动勾画

【中图分类号】R318;R811.1

【文献标志码】A

【文章编号】1005-202X(2024)02-0163-06

Auto-segmentation of target areas and organs-at-risk for total marrow and lymphoid irradiation in children

XIE Zhihua^{1,2}, LU Na¹, LIU Jinpeng³, HOU Lixia³, ZHANG Fuli¹

1. Department of Radiotherapy, The Seventh Medical Center of the Chinese PLA General Hospital, Beijing 100700, China; 2. Department of Radiophysical Technology, Shandong Tumor Hospital, Jinan 250000, China; 3. School of Radiology, Shandong First Medical University (Shandong Academy of Medical Sciences), Tai'an 271000, China

Abstract: Objective To investigate the feasibility of AccuLearning system for the auto-segmentation of target areas and organs-at-risk (OAR) for total marrow and lymphoid irradiation (TMLI) in children. **Methods** Thirty pediatric patients who underwent TMLI since 2018 to 2022 were selected. The patients were immobilized in the supine position, and their CT images were acquired on the Philips Brilliance Big Bore CT scanner. After the target areas and OAR were manually delineated and modified, the CT images and manually delineated contours were imported into AccuLearning system for training, validation, and testing of the auto-segmentation model. The auto-segmentation results in 6 TMLI patients in the test set were evaluated in terms of Dice similarity coefficient (DSC), 95% Hausdorff distance and average surface distance. **Results** On the test set with 6 cases, except for the lens that was difficult to be delineated automatically, the DSC values was above 0.70 for all other target areas and OAR, with only one patient having a DSC value of 0.59 for the stomach. The average DSC value for the stomach in all 6 patients was 0.76, and the average DSC values for the other organs were above 0.80. **Conclusion** The target areas and OAR automatically delineated with the model can meet the requirements of clinical planning after simple modifications.

Keywords: children; radiotherapy; total marrow and lymphatic irradiation; auto-segmentation

【收稿日期】2023-10-19

【作者简介】解治华, 技师, 研究方向: 肿瘤放射治疗物理, E-mail: zhxie2000@163.com

【通信作者】张富利, 主任技师, 研究方向: 多模态影像引导精确放疗、人工智能在肿瘤放射治疗中的应用, E-mail: radiozfl@163.com

前言

放射治疗是恶性肿瘤常用的治疗手段之一,超过70%的恶性肿瘤患者需要接受放射治疗^[1],精确快速地勾画肿瘤靶区和危及器官(Organs at Risk, OARs)是实现精准放疗的前提和保障^[2]。由医生手动进行肿瘤靶区和OARs勾画仍然是当前的标准做法,但这是一

项耗时繁重的任务,一般至少需要花费有经验的医生 30 min 甚至更长的时间。即使有勾画指南,不同的医生也会有不同的勾画习惯,即使是同一名医生在不同时间也会形成不同的勾画结果,已有文献报道不同医生之间的勾画差异^[3]。与手动勾画相比,自动勾画自提出以来已经显示出较大优势,包括减轻医生的工作负担,缩短患者的等候时间,有助于改善肿瘤的治疗增益比^[4]。目前广泛使用的自动勾画技术是基于深度学习(Deep Learning, DL)算法训练出来的自动勾画模型,其流程见图 1。目前市场上已经有多款商用的基于 DL 的自动勾画软件,如 Yorktal-CS 软件、智能放疗云平台(RACI. OIS)、Manteia、联影、柏视、Mirada^[5-9]。白血病是儿童癌症中的高发疾病,利用基于螺旋断层放疗系统(TOMO)的全骨髓全淋巴照射(Total Marrow and Lymphoid Irradiation, TMLI)技术进行骨髓移植前的预处理工作已广泛应用于临床中^[10-11]。国内目前已有研究对 TOMO 应用于全骨髓照射的可行性进行探索^[12-13]。对于 TMLI 自动勾画方面的最新研究是文献[14-15]进行的 TMI 自动勾画方法。

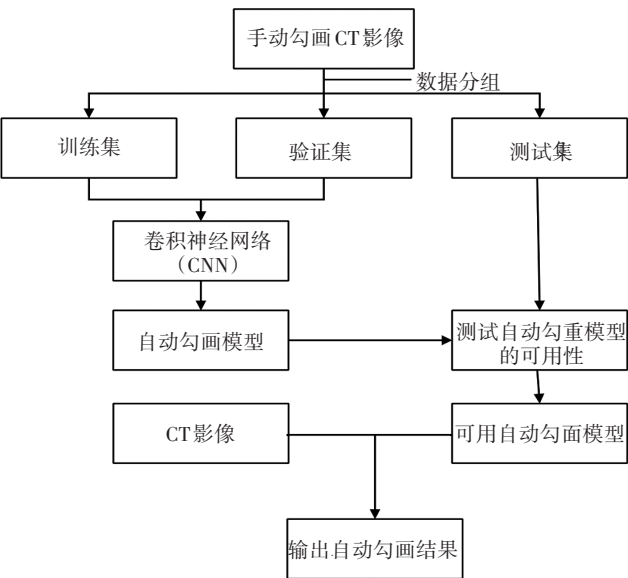


图1 自动勾画方法的流程示意图
Figure 1 Auto-segmentation flowchart

本研究主要针对未成年患者 TMLI 的靶区和 OARs,利用基于卷积神经网络(Convolutional Neural Network, CNN)的深度学习机,训练适用于儿童 TMLI 的自动勾画算法模型,并对训练结果进行测试和评估,对其应用于临床的可行性进行研究。

1 资料与方法

1.1 数据集获取和预处理

选取解放军总医院第七医学中心放疗科 2018 年至 2022 年期间接受 TMLI 治疗且年龄为 18 岁及以下的患者 30 例。其中,男 22 例,女 8 例;中位年龄 9 岁;4 例患者仅照射部分淋巴和骨髓,但仍然可以用来训练 OARs 的自动勾画模型。已有研究表明可使用 AccuLearning 进行小样本模型的训练,30 例患者数据已经能够满足本研究的训练要求^[16]。

定位扫描使用飞利浦 Brilliance Big Bore CT 模拟定位机(Philips Healthcare, Best, the Netherlands)。患者定位时均采用头先进仰卧位,胸部以上用头颈肩一体热塑面罩固定,腹部盆腔用热塑膜固定,腿部使用真空垫进行固定。由于儿童身高的影响,部分患者进行扫描时可以直接从头部扫描至脚底,但有部分身高较高的患者仅扫描到膝盖部位,然后反转为脚先进仰卧位进行扫描。在 FFS 扫描的影像中只包含腿部骨髓靶区,为了研究方便,本研究所定义的靶区只包括膝部以上的区域。获取的 CT 图像分辨率为 512×512,扫描层厚 5 mm,层间距 5 mm,扫描电压 120 kV。将采集的 CT 图像导入 Pinnacle³ 治疗计划系统(Philips Radiation Oncology Systems, Madison, WI)进行手动勾画。

本研究所定义的 OARs 包括:脑、脑干、心脏、肾脏、肝脏、肺、口腔、腮腺、胃、膀胱、晶状体、眼球。临床靶区(Clinical Target Volume, CTV)具体分为 3 个部分(图 2):CTV1(股骨头、肱骨头和除四肢骨外的骨髓)、CTV2(膝部以上除 CTV1 外的其他骨髓)、CTV3(淋巴引流区)。合并 3 个部分 CTV 并进行适当外放生成计划靶区(Planning Target Volume, PTV)用于后续治疗计划设计。勾画完毕后在临床患者原有信息的基础上按照统一勾画标准进行手动修改,再由多位经验丰富的临床医生进行审核确认,并以此作为基准值(Ground Truth, GT)。

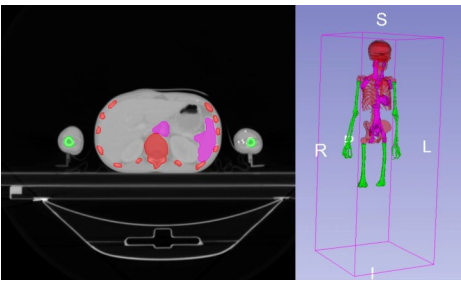


图2 CTV(红色为 CTV1、绿色为 CTV2、紫红色为 CTV3)
Figure 2 Clinical target volume (CTV1 in red, CTV2 in green, CTV3 in purple)

1.2 环境设置

自动勾画模型的训练和验证使用 Manteia 公司

(Manteia Technologies Co., Ltd, Xiamen, China)研发的基于DL的影像自动勾画训练平台 AccuLearning。该平台基于 Windows10 操作系统,处理器为 Intel(R) Core(TM) i7-10700 CPU @ 2.90 GHz。AccuLearning 能够进行小样本自动勾画算法模型的训练,高精度小样本训练即可输出高精度模型,在训练过程中可以通过数据驱动更新模型参数,实现特征的自动提

取,与传统的图像处理算法相比可获得更好的效果^[17]。近年来,以 U-Net 及其变体为代表的 CNN 已广泛应用于医学图像自动勾画中,并取得良好的效果^[18-23]。AccuLearning 基于的网络结构便是 2D U-net,是典型的 Encoder-Decoder 结构(图 3),中间为短接通道(Skip-connect),进行特征融合。

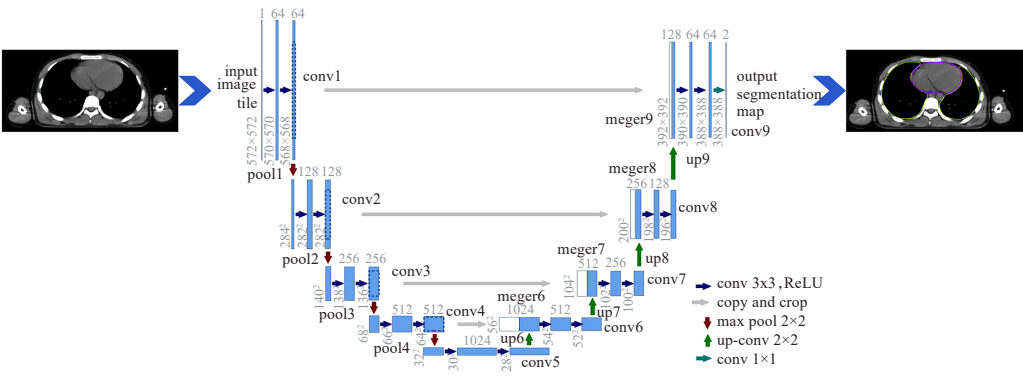


图3 2D U-Net网络结构
Figure 3 2D U-Net structure

1.3 模型训练

将手动勾画完成的患者数据传输到 AccuLearning 平台,在 AccuLearning 中,一组 CT 图像以及对应的轮廓文件(RT Structure)构成一个数据集。为了数据处理方便,保证模型训练的准确性,将感兴趣区域(Region of Interest, ROI)分为 5 组数据集进行训练:脑、脑干、口腔、肺(双侧)、心脏、肝脏、胃、膀胱,8 个 OARs 放到同一训练数据集;左眼球、右眼球、左晶状体、右晶状体、左腮腺、右腮腺、左肾、右肾,8 个 OARs 放到同一训练数据集;CTV1、CTV2、CTV3 各为一个训练集。随机将 30 例患者数据按照 20:4:6 划分为训练集、验证集、测试集。训练集用于实际的模型训练;验证集用于对模型的参数进行调整,以及在训练过程中对训练效果进行检测;测试集用于对模型效果进行评价。结合经验与实际情况对训练参数进行设置,批量大小设置为 16,学习率使用经验数值 0.000 3,训练轮次为 50 次。模型训练结束后对测试集的 6 例患者进行自动勾画,获得相应的 RT structure 文件。

1.4 评价指标

医生手动勾画的靶区和 OARs 作为 GT 值,采用 Dice 相似性系数(Dice Similarity Coefficient, DSC)、95% 豪斯多夫距离(95% Hausdorff Distance, HD95)和平均表面距离(Average Surface Distance, ASD)3 项

指标定量评估模型自动勾画的效果。

目前,AccuLearning 自动勾画平台仅提供 DSC 一个评价指标,用于评价自动勾画与手动勾画之间的重合性。文献[24-25]指出 DSC 值大于 0.70 时表明结构重复性较好,自动勾画的效果可以接受。虽然 DSC 值简洁明了,但不足以描述所有情况,因此补充了对距离敏感的 HD95 和 ASD 两个指标。HD95 和 ASD 使用本研究机构自主开发的 Python 脚本进行计算,计算 HD95 和 ASD 时,像素之间的距离按照 1 mm 计算。HD 用来评价自动勾画与手动勾画之间三维空间上的表面距离。为了避免离群噪声点对评价结果产生影响,通常选取每个点集之间距离从小到大的前 95%(HD95)的数据参与计算。HD95 的值越小,表明自动勾画与手动勾画之间的交集越大,自动勾画越准确。HD95 距离具有很强的容错能力和抗干扰能力,是对位置差异十分敏感的参数,如果图像重合度好,HD95 值会很小,如果图像存在部分偏差,即使较小的偏差也会导致 HD95 值骤增至几十甚至上百,通常越大的区域 HD95 值也会相应越高^[26]。因此 HD95 值的好坏并没有明确的标准值,只要 HD95 值不是异常大都可以认为重合度较好。ASD 表示两个点集之间的平均距离,用两个点集之间的相互距离之和除以两个点集之间的总面积,用来衡量自动勾画图像与手动勾画图像之间总体轮廓的偏移程度,

ASD越接近于0,说明自动勾画图像与手动勾画图像之间的形状总体偏移越小。

2 结果

表1列出除晶状体以外OARs自动勾画效果的评价指标。测试集6例患者OARs自动勾画结果中,有1例患者胃的DSC值为0.59,其余器官的DSC值均大于0.70。表1中可以看出除胃以外其余各OARs的DSC值均大于0.80。通过检查测试集中各患者CT图像推断出,由于胃形状的个体差异较大导致胃部自动勾画结果相对较差,但仍在可接受范围之内。通过表1可发现体积较大的OARs的HD95数值相对较大,如膀胱(11.02±6.50) mm、肝脏(14.64±6.08) mm、肺(11.64±6.62) mm,但两指标的数值均在可接受范围之内,并未出现异常值。像眼球这种体积小的OAR的HD95和ASD的数值相对较小。

表1 OARs自动勾画效果的评价指标($\bar{x}\pm s$)
Table 1 Evaluation indexes for OAR auto-segmentation
(Mean±SD)

OARs	DSC	HD95/mm	ASD/mm
膀胱	0.82±0.06	11.02±6.50	5.54±5.06
脑	0.98±0.00	5.83±1.14	1.42±0.18
脑干	0.82±0.03	3.36±0.52	1.34±0.24
心脏	0.86±0.07	9.15±3.47	2.93±1.18
肝脏	0.92±0.02	14.64±6.08	3.51±0.84
肺	0.96±0.01	11.64±6.62	2.05±0.68
口腔	0.84±0.03	4.88±0.89	1.64±0.18
胃	0.76±0.10	14.68±5.70	4.45±1.83
左眼	0.91±0.03	2.84±0.73	0.82±0.21
右眼	0.91±0.02	2.02±0.42	0.66±0.10
左肾	0.94±0.01	3.02±0.66	0.92±0.14
右肾	0.94±0.02	2.63±0.76	0.90±0.24
左腮腺	0.86±0.02	4.55±1.36	1.17±0.28
右腮腺	0.84±0.03	4.69±1.63	1.39±0.45

膀胱是否充盈对于自动勾画结果并无明显影响,因此在定位时并未对膀胱充盈程度做任何要求。CT图像中部分充盈的膀胱可以分辨出边界,但由于儿童子宫或前列腺的发育并不成熟,并不能十分清晰地分辨出未充盈的膀胱与子宫或前列腺的边界。膀胱的DSC为0.82±0.06,临床上可以接受;HD95为(11.02±6.50) mm,无论是对于充盈的膀胱(体积大,边界清晰),还是未充盈的膀胱(体积小,边界不清晰),这个数值都是偏高的,这会导致自动勾画的效果欠佳。

表2列出各个CTV自动勾画的评价指标,均在临床可接受范围内。CTV2勾画的结构相对简单,DSC可以达到0.90±0.04,HD95为(5.99±3.63) mm,说明其自动勾画的重合性较好。对于CTV3来说其HD95为(12.75±2.91) mm,说明自动勾画的淋巴引流区在整体上会有一些位置上的偏差。虽然CTV1在评价参数中的表现较好,但在检查自动勾画结果时发现CTV1中的颅骨部分自动勾画结果并不理想,仍需人工干预修改。在CT图像中,垂体上方头骨呈环形,但大部分自动勾画仅能勾画出骨环的外轮廓,并不能勾画出骨环的内轮廓(图4),这可能会导致DSC值偏低。后期经过多次测试,仍出现这种情况,推测可能是由于算法层面的局限性导致。

表2 CTV自动勾画评价指标($\bar{x}\pm s$)
Table 2 Evaluation indexes for CTV
auto-segmentation (Mean±SD)

CTV	DSC	HD95/mm	ASD/mm
CTV1	0.79±0.05	5.99±1.83	1.02±0.23
CTV2	0.90±0.04	5.99±3.63	2.33±2.30
CTV3	0.81±0.03	12.75±2.91	4.00±1.81

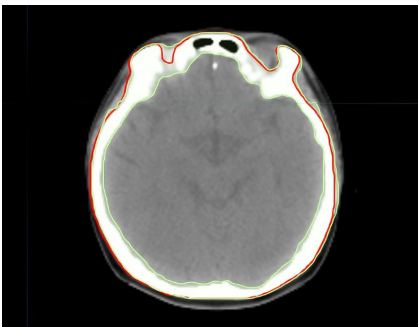


图4 头部CTV1勾画结果对比(绿色:手动勾画,红色:自动勾画)
Figure 4 Comparison of CTV1 segmentation results in the head
(manual segmentation in green, auto-segmentation in red)

针对晶状体的勾画,在测试集的6例患者当中,仅勾画出3例右晶状体(病例A、B、C)和1例左晶状体(病例D),部分勾画效果见图5,评价指标见表3。通过对原始数据勾画的晶状体进行再次检查,排除数据出错的可能,额外对晶状体进行单独的模型训练实验,但结果仍然会出现晶状体无法勾画的情况,分析认为可能是由于晶状体的体积相对微小,且由于CT扫描时使用的是成人的扫描条件,导致部分儿童的CT图像并不能清晰地显示晶状体的影像,因此出现无法勾画出晶状体的情况。

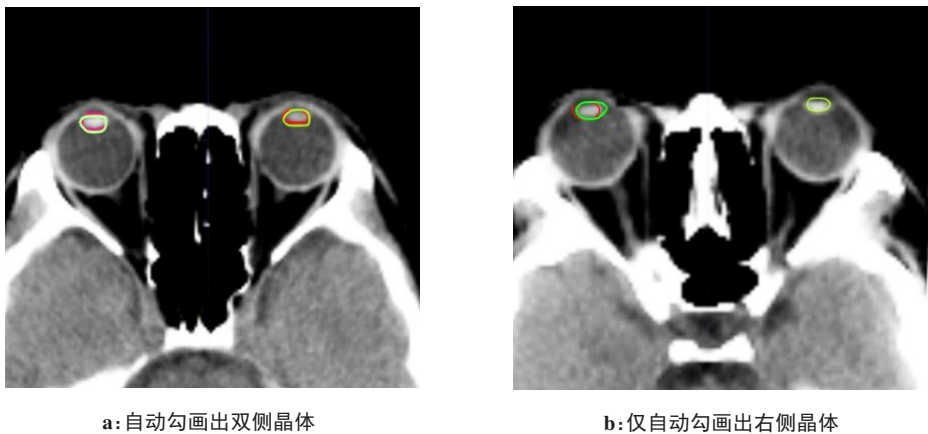


图5 晶状体勾画结果对比(绿色:手动勾画,红色:自动勾画)

Figure 5 Comparison of lens segmentation results (manual segmentation in green, auto-segmentation in red)

表3 晶状体自动勾画轮廓评价指标

Table 3 Evaluation indexes for auto-segmentation of lens

数据编号	DSC	HD95/mm	ASD/mm
病例A	0.76	0.98	0.48
病例B	0.58	2.11	0.80
病例C	0.73	0.88	0.31
病例D	0.82	1.07	0.41

手动勾画完成1例儿童TMLI患者的轮廓通常需要5~8 h。利用本研究训练的自动勾画模型从导入数据开始到完成自动勾画,再到对勾画结果进行检查修改至满足临床计划设计要求,这个过程可以缩短至约1.5 h,从而可以提高工作效率,减少患者治疗前的等待时间。

3 讨论

本研究针对儿童TMLI的轮廓勾画,基于24例儿童患者影像数据进行训练,并用6例儿童患者数据进行测试获得自动勾画模型。对测试集患者的勾画结果进行分析评价,证明利用基于CNN进行儿童TMLI自动勾画的可行性,可以有效解决目前儿童患者的特殊性导致的常规自动勾画软件无法普遍适用的问题,有利于放疗中心提高工作效率,为开展儿童TMLI提供技术支持。Watkins等^[15]使用100例临床TMLI患者数据,基于U-Net框架的Medical Mind AI-software进行自动勾画模型的训练,将训练的模型应用于21例临床患者的自动勾画中,结果显示21个OARs中有18个OARs的DSC>0.8,这与本研究得到的结果基本一致,其中口腔和胃部的DSC大于0.9,优于本研

究的结果。此项研究中靶区的定义规则与本研究略有不同,但得到的自动勾画结果却十分相似。对于晶状体的自动勾画,Watkins等^[15]研究中同样出现针对微小器官(晶状体、视交叉等)自动勾画效果不理想的情况,这与本研究中所遇到的问题相似。其他文献^[27-28]研究也表明,晶体在自动勾画中的效果普遍不理想,但由于手动勾画晶体十分便捷,并不会增加医生的工作量,因此无需过分关注其自动勾画的效果。对于颅骨部分的靶区,在其它研究报道中均是单独作为一个靶区进行定义的,得到的DSC值分别为 0.814 ± 0.99 和 0.893 ± 0.005 ,与对应研究中的其它骨靶区的结果相比均属于自动勾画结果较差的一个结构^[15,20]。结合本研究中所出现的颅骨靶区自动勾画效果不佳的情况,可能是由于算法本身的局限性导致,所使用的神经网络可能无法识别“环”这一概念,当然这需要进一步的针对性研究去支持这一推测。用于自动勾画的CNN不止局限于U-Net网络,也可尝试使用其它网络去改善自动勾画效果,如Chen等^[29]引用WB-Net的人工智能算法,在一定程度上提高自动勾画的效果。Shi等^[14]提出DE-Net双编码混合结构的算法,将算法同样应用于TMLI患者的自动勾画中并与其它几种常见的算法进行对比,表明其获得较好的勾画效果,同时也指出混合结构的神经网络在医学图像分析中具有巨大的潜力。

本研究仅使用30例儿童患者数据,在样本量上存在一定欠缺。此外,仅实现12个主要OARs的自动勾画,并未验证其它OARs(如:肠带、视交叉、直肠、食管等)自动勾画的可行性。未来可以尝试扩充样本数量,增加来自不同医院、不同型号CT设备采集的患者影像数据,并优化算法,以使训练出的自动勾画模型更加适用于儿童TMLI患者,从而更好地辅助临床放疗工作。

【参考文献】

- [1] Barton MB, Frommer M, Shafiq J. Role of radiotherapy in cancer control in low-income and middle-income countries[J]. *Lancet Oncol*, 2006, 7(7): 584-595.
- [2] Lee JG, Jun S, Cho YW, et al. Deep learning in medical imaging: general overview[J]. *Korean J Radiol*, 2017, 18(4): 570-584.
- [3] Liu Z, Liu X, Xiao B, et al. Segmentation of organs-at-risk in cervical cancer CT images with a convolutional neural network[J]. *Phys Med*, 2020, 69: 184-191.
- [4] Rigaud B, Anderson BM, Yu ZH, et al. Automatic segmentation using deep learning to enable online dose optimization during adaptive radiation therapy of cervical cancer[J]. *Int J Radiat Oncol Biol Phys*, 2021, 109(4): 1096-1110.
- [5] 曹世鹏, 王大奖, 王骁踊, 等. AccuContour 和 United Imaging 软件自动勾画胸部危及器官[J]. *中国医学影像技术*, 2021, 37(11): 1715-1719.
Cao SP, Wang DJ, Wang XY, et al. AccuContour and United Imaging software auto-segmentation the chest and organs at risk[J]. *Chinese Journal of Medical Imaging Technology*, 2021, 37(11): 1715-1719.
- [6] You J, Wang Q, Wang R, et al. Deep learning-aided automatic contouring of clinical target volumes for radiotherapy in breast cancer after modified radical mastectomy[J]. *Front Phys*, 2022, 9: 1-10.
- [7] Loop P, Tkatchenko N, Kirova Y. Evaluation of a delineation software for cardiac atlas-based autosegmentation: an example of the use of artificial intelligence in modern radiotherapy[J]. *Cancer Radiother*, 2020, 24(8): 826-833.
- [8] 罗邦雨, 伍亚军, 周一兵, 等. 一款基于深度学习的放疗轮廓勾画软件的研发[J]. *中国医疗设备*, 2020, 35(7): 40-44.
Luo BY, Wu YJ, Zhou YB, et al. Development of a radiotherapy auto-segmentation software based on deep learning[J]. *Journal of China Medical Devices*, 2020, 35(7): 40-44.
- [9] 时飞跃, 王敏, 秦伟, 等. 智能放疗云平台自动勾画食管癌患者心脏结构的应用[J]. *中国医学物理学杂志*, 2019, 36(12): 1377-1382.
Shi FY, Wang M, Qin W, et al. Application of RAIC.OIS in automatic segmentation of the heart in patients with esophageal cancer[J]. *Chinese Journal of Medical Physics*, 2019, 36(12): 1377-1382.
- [10] Liveringhouse C, Robinson TJ, Garcia G, et al. Dosimetric comparison of volumetric modulated arc therapy with tomotherapy based total body irradiation for patients undergoing conditioning prior to hematopoietic stem cell transplantation for acute lymphocytic leukemia[J]. *Int J Radiat Oncol Biol Phys*, 2021, 111(3S): 303.
- [11] Köksal M, Baumert J, Jazmati D, et al. Whole body irradiation with intensity-modulated helical tomotherapy prior to haematopoietic stem cell transplantation: analysis of organs at risk by dose and its effect on blood kinetics[J]. *J Cancer Res Clin Oncol*, 2023, 149(10): 7007-7015.
- [12] 朱峰, 吴伟章, 常冬妹, 等. 螺旋断层 IMRT 全骨髓照射流程可行性探讨[J]. *中华放射肿瘤学杂志*, 2018, 27(1): 94-100.
Zhu F, Wu WZ, Chang DS, et al. Feasibility of helical tomotherapy intensity-modulated radiation therapy applied in total marrow irradiation[J]. *Chinese Journal of Radiation Oncology*, 2018, 27(1): 94-100.
- [13] 孔凡洋, 简亚雷, 刘乐乐, 等. 基于螺旋断层治疗的儿童全骨髓全淋巴照射临床研究[J]. *中华放射肿瘤学杂志*, 2018, 27(10): 911-915.
Kong FY, Lin YL, Liu LL, et al. Clinical study of total marrow and lymphatic irradiation in children using helical tomotherapy[J]. *Chinese Journal of Radiation Oncology*, 2018, 27(10): 911-915.
- [14] Shi J, Wang Z, Kan H, et al. Automatic segmentation of target structures for total marrow and lymphoid irradiation in bone marrow transplantation[J]. *Annu Int Conf IEEE Eng Med Biol Soc*, 2022, 2022: 5025-5029.
- [15] Watkins WT, Qing K, Han C, et al. Auto-segmentation for total marrow irradiation[J]. *Front Oncol*, 2022, 12: 970425.
- [16] 陈飞, 胡静, 戴春华, 等. 小样本训练模型在宫颈癌放疗中自动勾画可行性研究[J]. *中国医疗设备*, 2021, 36(11): 27-31.
Chen F, Hu J, Dai CH, et al. Feasibility study on automatic segmentation of small sample training model in cervical cancer radiotherapy[J]. *China Medical Devices*, 2021, 36(11): 27-31.
- [17] Zhang W, Chen Z, Liang Z, et al. AccuLearning: a user-friendly deep learning auto-segmentation platform for radiotherapy[J]. *Int J Radiat Oncol Biol Phys*, 2021, 111(3S): 122.
- [18] Isensee F, Jaeger PF, Kohl SA, et al. nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation[J]. *Nat Methods*, 2021, 18(2): 203-211.
- [19] Zunair H, Hamza AB. Sharp U-Net: depthwise convolutional network for biomedical image segmentation[J]. *Comput Biol Med*, 2021, 136: 104699.
- [20] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation[J]. *CoRR*, 2015: abs/1505.04597.
- [21] Zhou Z, Siddiquee MM, Tajbakhsh N, et al. UNet++: a nested U-net architecture for medical image segmentation[J]. *Deep Learn Med Image Anal Multimodal Learn Clin Decis Support*, 2018, 11045: 3-11.
- [22] 黄晓鸣, 何富运, 唐晓虎, 等. U-Net 及其变体在医学图像分割中的应用研究综述[J]. *中国生物医学工程学报*, 2022, 41(5): 567-576.
Huang XM, He FY, Tang XH, et al. Review on applications of U-Net and its variants in medical image segmentation[J]. *Chinese Journal of Biomedical Engineering*, 2022, 41(5): 567-576.
- [23] 殷晓航, 王永才, 李德英. 基于 U-Net 结构改进的医学影像分割技术综述[J]. *软件学报*, 2021, 32(2): 519-550.
Yin XH, Wang YC, Li DY. Suvery of medical image segmentation technology based on U-Net structure improvement[J]. *Journal of Software*, 2021, 32(2): 519-550.
- [24] Artachevarria X, Munoz-Barrutia A, Ortiz-De-Solorzano C. Combination strategies in multi-atlas image segmentation: application to brain MR data[J]. *IEEE Trans Med Imaging*, 2009, 28(8): 1266-1277.
- [25] Zijdenbos AP, Dawant BM, Margolin RA, et al. Morphometric analysis of white matter lesions in MR images: method and validation[J]. *IEEE Trans Med Imaging*, 1994, 13(4): 716-724.
- [26] 何奕松, 蒋家良, 余行, 等. 影像分割中 Dice 系数和 Hausdorff 距离的比较[J]. *中国医学物理学杂志*, 2019, 36(11): 1307-1311.
He YS, Jiang JL, Xu X, et al. Comparison of Dice similarity coefficient and Hausdorff distance in image segmentation[J]. *Chinese Journal of Medical Physics*, 2019, 36(11): 1307-1311.
- [27] Ibragimov B, Xing L. Segmentation of organs-at-risks in head and neck CT images using convolutional neural networks[J]. *Med Phys*, 2017, 44(2): 547-557.
- [28] Zhu W, Huang Y, Zeng L, et al. AnatomyNet: deep learning for fast and fully automated whole-volume segmentation of head and neck anatomy[J]. *Med Phys*, 2019, 46(2): 576-589.
- [29] Chen X, Sun S, Bai N, et al. A deep learning-based auto-segmentation system for organs-at-risk on whole-body computed tomography images for radiation therapy[J]. *Radiother Oncol*, 2021, 160: 175-184.

(编辑:陈丽霞)