

## 基于级联3D U-Net的CT和MR视交叉自动分割方法

沈镇炯<sup>1</sup>, 彭昭<sup>1</sup>, 孟祥银<sup>1</sup>, 汪志<sup>1,2</sup>, 徐榭<sup>1,3</sup>, 裴曦<sup>1,4</sup>

1. 中国科学技术大学核医学物理研究所, 安徽 合肥 230025; 2. 安徽医科大学第一附属医院肿瘤放疗科, 安徽 合肥 230022; 3. 中国科学技术大学附属第一医院放疗科, 安徽 合肥 230001; 4. 安徽慧软科技有限公司, 安徽 合肥 230088

**【摘要】目的:**基于级联3D U-Net,利用配对患者头颈部数据[CT和磁共振图像(MRI)],取得比仅CT数据更高分割精度的视交叉自动分割结果。**方法:**该级联3D U-Net由一个原始3D U-Net和改进的3D D-S U-Net(3D Deeply-Supervised U-Net)组成,实验使用了60例患者头颈部CT图像及MRI图像(T<sub>1</sub>和T<sub>2</sub>模态),其中随机选取15例患者数据作为测试集,并使用相似性系数(DSC)评估视交叉的自动分割精度。**结果:**对于测试集中的所有病例,采用多模态数据(CT和MRI)的视交叉的DSC为0.645±0.085,采用单模态数据(CT)的视交叉的DSC为0.552±0.096。**结论:**基于级联3D U-Net的多模态自动分割模型能够较为准确地实现视交叉的自动分割,且优于仅利用单模态数据的方法,可以辅助医生提高放疗计划制定的工作效率。

**【关键词】**3D U-Net;视交叉;自动分割;多模态

**【中图分类号】**R318;R811.1

**【文献标志码】**A

**【文章编号】**1005-202X(2021)08-0950-05

### Automatic optic chiasm segmentation using CT and MRI based on cascaded 3D U-Net

SHEN Zhenjiong<sup>1</sup>, PENG Zhao<sup>1</sup>, MENG Xiangyin<sup>1</sup>, WANG Zhi<sup>1,2</sup>, XU Xie<sup>1,3</sup>, PEI Xi<sup>1,4</sup>

1. Institute of Nuclear Medical Physics, University of Science and Technology of China, Hefei 230025, China; 2. Department of Radiation Oncology, the First Affiliated Hospital of Anhui Medical University, Hefei 230022, China; 3. Department of Radiation Oncology, the First Affiliated Hospital of University of Science and Technology of China, Hefei 230001, China; 4. Anhui Wisdom Technology Co., Ltd, Hefei 230088, China

**Abstract: Objective** To realize the automatic segmentation of the optic chiasm using multimodal images (CT and MRI) that contain head-and-neck data and based on cascaded 3D U-Net for obtaining a higher segmentation accuracy than using only CT data. **Methods** The proposed cascaded 3D U-Net consists of an original 3D U-Net and an improved 3D D-S U-Net (3D Deeply-Supervised U-Net). The head-and-neck CT images and MRI images (T<sub>1</sub> and T<sub>2</sub> modalities) of 60 patients were used in the experiment, and the data of 15 patient were randomly selected as the test set. Dice similarity coefficient was used to evaluate the accuracy of automatic optic chiasm segmentation. **Results** For all cases in the test set, the Dice similarity coefficient of the optic chiasm segmentation using multimodal data (CT and MRI) or monomodal data (CT) was 0.645±0.085 and 0.552±0.096, respectively. **Conclusion** The multimodal automatic segmentation model based on cascaded 3D U-Net can accurately realize the automatic segmentation of the optic chiasm, superior to the method using only monomodal data, and it can assist doctors in improving the efficiency of radiotherapy planning.

**Keywords:** 3D U-Net; optic chiasm; automatic segmentation; multimodal

## 前言

**【收稿日期】**2021-03-19

**【基金项目】**安徽省自然科学基金(1908085MA27);安徽省重点研究与开发计划(1804a09020039);中国科学技术大学“Med-X医学物理和生物工程双一流交叉学科”建设经费

**【作者简介】**沈镇炯,硕士,主要从事医学图像分割、深度学习等研究,  
E-mail: szj0117@mail.ustc.edu.cn

**【通信作者】**裴曦,博士,副教授,主要从事医学物理、人工智能和医学影像等研究, E-mail: xpei@ustc.edu.cn

放疗要求确保肿瘤靶区接受足够的处方剂量照射的同时,避免靶区周边危及器官正常组织受到过多的损伤<sup>[1-2]</sup>。因此,精准可靠的危及器官分割是制定放疗计划的一个必备条件。传统的手工分割非常耗时,而且准确性受医生个体经验所限<sup>[3-4]</sup>。因此,近年来基于多图谱和深度学习的自动分割方法逐渐受到了更多的关注,其中基于深度学习的方法在图像分割领域取得了更好的成果<sup>[5-7]</sup>。在医学图像分割领域,绝大多数的深度学习分割算法都基于卷积神经

网络(CNN)<sup>[8]</sup>和U-Net<sup>[9]</sup>。Zhou等<sup>[10]</sup>为解决3D图像内存制约计算性能的问题,提出先以一个点提取感兴趣区域(ROI)进行分割后,再进行更精确的ROI提取,反复迭代至收敛。Han等<sup>[11]</sup>则使用粗分割结果提取肝脏的ROI。Isensee等<sup>[12]</sup>提出级联U-Net用于心脏、肝脏等器官的分割。Sun等<sup>[13]</sup>将级联模型应用于眼睛及周边器官的分割,提出先定位后分割的方法可以提高小体积危及器官的分割性能。但是,他们都没有将级联模型应用于视交叉的分割。在垂体腺瘤和视神经胶质瘤的放射治疗中,视交叉的定位对于评估视交叉受压情况和预后的视觉恢复非常重要<sup>[14-15]</sup>。Bekes等<sup>[16]</sup>提出的依据CT图像的半自动分割算法在眼球和晶体上表现很好,但是分割视交叉的效果不佳,准确度只有眼球的65%。MICCAI 2015头颈自动分割挑战赛中视交叉分割的最优DSC结果仅为0.57<sup>[17]</sup>。对于视交叉这类软组织危及器官,磁共振图像(MRI)比CT具备更好的图像对比度,因此针对病人个体同时采集CT和MRI,有可能进一步提高分割的精准度<sup>[18]</sup>。因此,采用多模态图像逐渐广泛应用于医学图像分割领域<sup>[18-20]</sup>。Noble等<sup>[18]</sup>基于多图谱和模型的方法分割CT和配准的MRI中的视交叉,但是需要手动调整参数。基于此,本文拟通过改进的级联3D U-Net网络研究利用多模态数据提高自动

分割视交叉的精度。

## 1 资料与方法

### 1.1 实验数据及预处理

实验使用的数据来自2019年8月至2020年8月于安徽医科大学第一附属医院已接受放疗的60例头颈癌患者,同一患者的CT及MRI采集的时间间隔均不超过3个月,其中MRI包含T<sub>1</sub>、T<sub>2</sub>两种成像模态。患者均采用热塑面膜固定,CT图像的分辨率从(2.500×0.488×0.488) mm<sup>3</sup>至(5.000×0.976×0.976) mm<sup>3</sup>不等,MRI的分辨率从(4.000×0.687×0.687) mm<sup>3</sup>至(7.000×0.532×0.532) mm<sup>3</sup>不等。主管医生在Eclipse计划系统(Varian, USA)中仅依据CT图像手工分割患者视交叉,并交由上级资深医生审核修改。此外,该主管医生使用MIM Maestro软件(Ver 6.8.7)将MRI形变配准到CT图像上,然后结合配准后的MRI在CT上重新手工分割视交叉,如图1所示,并交由上级资深医生审核修改。将CT图像及配准后的MRI重新采样到统一分辨率(1.250×0.800×0.800) mm<sup>3</sup>,预裁剪为256×256×80大小的3D图像。这些预处理可减少计算量,减少由于成像扫描参数不同引起的差异,加速级联3D U-Net网络的收敛。



图1 弹性配准后的CT与MRI(T<sub>1</sub>、T<sub>2</sub>)图像及视交叉手工分割结果

Fig.1 CT and MRI (T<sub>1</sub>, T<sub>2</sub>) images after elastic registration and manual segmentation of the optic chiasm

### 1.2 自动勾画模型

本文提出一种级联3D U-Net模型,具体如图2所示。该级联3D U-Net由两部分组成,第一部分为基础的3D U-Net网络模型,包括一个捕获上下文信息的收缩路径和一个支持精确本地化的对称扩展路径,每一个路径均包含5个卷积块,每个卷积块包含两个3×3卷积层和一个Leaky ReLU激活函数,下采样过程使用一个步长为2的3×3卷积层和一个Leaky ReLU激活函数来代替原始的最大池化层,来提升网络性能<sup>[21]</sup>。第二部分为改进的3D D-S U-Net,在基

础的3D U-Net模型上添加深度监督机制。Lee等<sup>[22]</sup>提出的深度监督网络(DSN),在基础的CNN的隐藏层中引入了分类器(SVM或Softmax)来提高分类网络的性能。Zeng等<sup>[23]</sup>将深度监督机制应用于3D U-Net,提出深度监督3D U-net-like网络,并用于3D磁共振图像中股骨头的分割,提高网络训练效率。Zeng等<sup>[23]</sup>将深度监督3D U-net-like网络在扩展路径中引入了低、中、高3个不同级别的深度监督,每一层深度监督中均包含一个解卷积块和分支分类器。本网络在此基础上改进了3D D-S U-Net,在低级别

(24×24×4)深度监督中,经过卷积和上采样操作,得到与中级别(48×48×8)隐藏层相同分辨率的图像并与其叠加,再一次经过卷积和上采样操作,得到与高

级别(96×96×16)隐藏层相同分辨率的图像并与其叠加,通过分类器(Softmax)输出分割结果。




图2 级联3D U-Net模型结构

Fig.2 Cascaded 3D U-Net model structure

Conv:一个卷积层;Down Sampling:包含一个卷积层和Leaky ReLU激活函数;Up Sampling:包含一个卷积层、一个上采样块和Leaky ReLU激活函数;Add:特征信息叠加;Testing:测试过程;ROI Crop:依据定位信息进行新ROI裁剪;Concatenate:特征信息融合

### 1.3 训练方法

模型以256×256×80大小的预处理3D图像作为原始输入,实现视交叉ROI的提取,并重新自动裁剪为96×96×16大小的3D图像,作为第二部分网络的输入,最终输出结果至大小为512×512×Sz的原始临床图像中,其中Sz为原始临床图像的层数。

模型训练过程中,将CT图像像素值约束为-160~240 HU, T<sub>1</sub>图像像素值约束为200~800, T<sub>2</sub>图像像素值约束为200~1 700。模型采用Pytorch框架,以DSC Loss作为损失函数,训练迭代次数采用早停法(Early Stopping),当损失函数连续30个迭代期不减少时停止训练。模型采用Adam优化器,学习率为0.000 2, Batch的大小为1。在单个NVIDIA GTX 1070TI(8 GB)上,训练消耗显存约为7 GB,训练耗时约20 h。

### 1.4 评价标准

本研究以医生手工分割的视交叉轮廓为“金标准”,使用形状相似性系数(Dice Similarity Coefficient, DSC)评价网络自动分割的视交叉轮廓的准确性,该值为0~1,数值越大表示自动分割与手工分割越相似,表明预测精度越高,DSC计算公式如下所示,其中A为医生手工分割的视交叉区域,B为自动分割的视交叉区域,公式如下所示:

$$DSC(A, B) = 2 \times \frac{|A \cap B|}{|A| + |B|}, 0 \leq DSC \leq 1 \quad (1)$$

## 2 结果

### 2.1 自动分割精度

级联3D U-Net的一阶段分割结果得到视交叉的三维中心,据此获得像素为96×96×16大小的外扩轮廓,如图3a~图3c所示。依据外扩轮廓,对原始图像进行定位裁剪,减少背景类的信息<sup>[24]</sup>。将自动定位裁剪后的图像输入二阶段的分割网络后,得到自动分割的最终结果,如图3d~图3f所示。以随机选取的15例患者作为测试集,一阶段分割的五折交叉验证DSC系数及标准差为0.564±0.159,最终分割的五折交叉验证结果为0.645±0.085,经过定位裁剪后,DSC系数得到了约0.08的提升,说明一定程度上减少背景类的占比可以提升网络模型的自动分割精度。本实验还尝试将定位裁剪像素大小调整为64×64×16,发现结果并没有提升,这可能是由于ROI太小,虽然背景类占比更少,但同时也减少了有用的图像特征信息。

图4中展示了测试集中某一例病例的视交叉分割情况,图4a和图4b分别是正反两个视角下的分割对比情况,其中手工分割结果用蓝色表示,自动分割



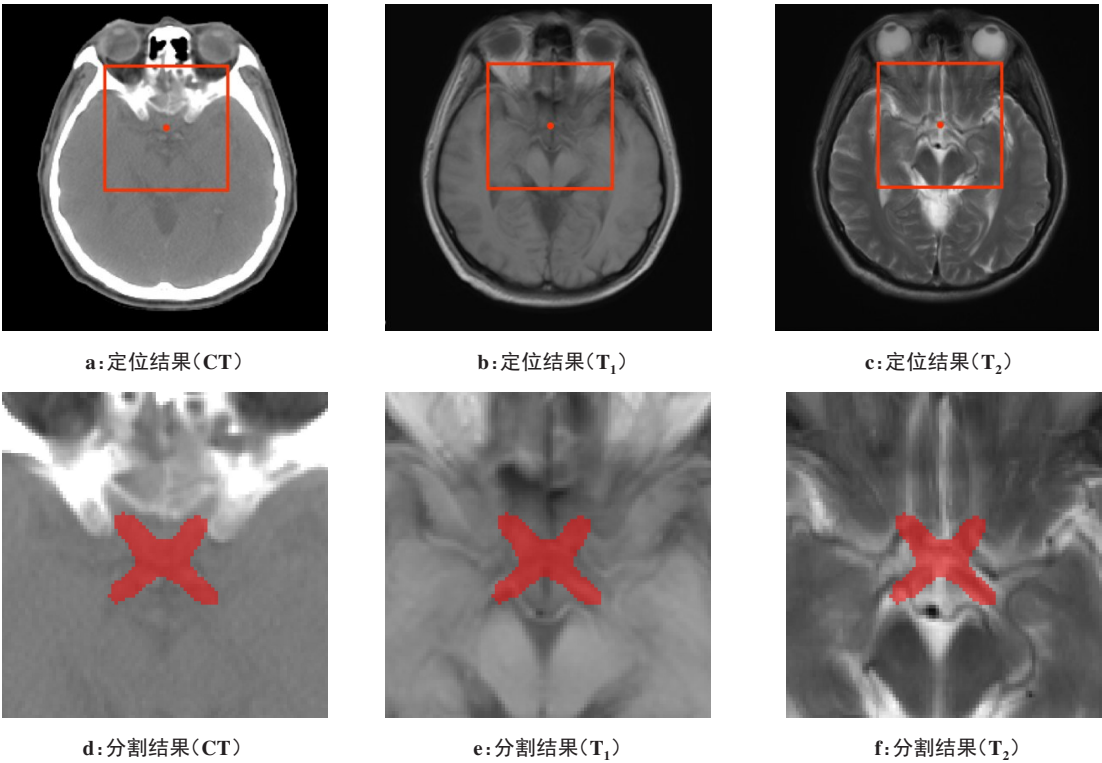


图3 级联 3D U-Net 的定位和分割结果  
Fig.3 Positioning and segmentation of cascaded 3D U-Net

结果用粉色表示,二者交叉重合的部分用红色表示。通过观察图 4 中手工分割和自动分割的情况,我们发现自动分割结果能够较为准确地包含完整的视交叉区域,对于视交叉核心区域分割非常准确,只有在视交叉延伸至视神经及视束的边界区域稍有误差。

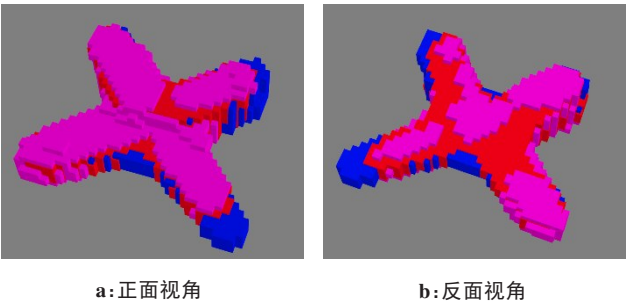


图 4 自动分割与手工分割结果对比  
Fig.4 Comparison between automatic segmentation and manual segmentation

由于目前尚无文献同时利用 CT 和配准的 MRI 数据用于视交叉的自动分割研究,我们对比了本研究中的级联 3D U-Net 方法与其他采用 CT 数据分割方法的 DSC 值。Ren 等<sup>[25]</sup>采用交错式的 3D-CNN,其视交叉的平均 DSC 结果为  $0.580\pm0.170$ ,田娟秀等<sup>[26]</sup>采用基于 3D 深度残差 FCN 的 SV-Net,其视交叉的平均 DSC 结果为  $0.583\pm0.286$ ,这两个方法均采用了 MICCAI 2015 头颈自动分割挑战赛的数据<sup>[17]</sup>,共包

含 48 例 CT,其中 15 例患者作为测试。本研究提出的级联 3D U-Net 自动分割模型,其视交叉的平均 DSC 结果为  $0.645\pm0.085$ ,通过对比发现,本研究提出的模型在视交叉自动分割领域取得了更好的结果。

同时,本研究进行不同模态数据的实验对比,其中采用多模态数据(包含 CT、MRI 的  $T_1$  和  $T_2$  模态)的自动分割结果为  $0.645\pm0.085$ ,采用单模态数据(仅 CT 图像)的结果为  $0.552\pm0.096$ 。通过对比发现,在视交叉的自动分割中,采用多模态数据相比单模态 CT 数据能得到更好的分割结果。

本实验采用多种数据增强方法来扩充数据,将图像进行添加高斯噪声、随机翻转、弹性形变(Elastic deformation)<sup>[27]</sup>,最终分割 DSC 结果得到 0.03 的提升。

2.2 自动分割效率

测试集中 15 例患者的视交叉自动分割耗时约 42 s,平均每例患者的视交叉自动分割仅需 2.8 s,可以大幅提升临床手工分割的效率。

3 讨论及总结

本研究不需要借助其他器官的分割算法用于辅助定位,直接针对视交叉进行二级分割,所需手工分割标签更少,临床应用更加简单。相比 CT 图像,MRI 具备更高的空间分辨率和软组织对比度,临床上 MRI 已经被用于检查视交叉及相关病变情况,利用

MRI的信息进行自动分割视交叉逐渐成为有效趋势,Sun等<sup>[15]</sup>在研究中进行基于MRI的视交叉分割实验,取得较好的结果,但是他们借助了垂体瘤患者的垂体位置信息进行辅助,而且最终分割未应用于CT。在基于深度学习的视交叉自动分割的相关工作中,本研究首次结合CT和MRI进行自动分割,发现相比仅采用CT图像进行自动分割,采用多模态数据的策略更好,得到更高的分割精度。

在本研究中发现,常规头颈放疗中使用的MRI层厚通常为6~7 mm,视交叉的可见层数少,边界难以界定,是目前结合MRI进行视交叉自动分割的一个难点,未来结合深度学习技术,针对层厚较大的MRI进行重采样,重建成层厚较小,信息更丰富的图像,是一种可考虑的数据增强方式。

综上所述,本研究提出一种新的基于级联3D U-Net的多模态视交叉自动分割方法,首次结合CT和MRI应用于视交叉的自动分割,比通常仅采用CT图像进行自动分割的方法,在平均DSC评估上高出约0.093,取得更好的精度,该方法可以作为临床中医生手工分割视交叉的辅助手段。未来将本方法拓展至其他视神经、晶体及海马等脑部小体积危及器官的通用性研究中,并集成至中国科学技术大学核医学物理研究所团队研发的一款危及器官自动勾画软件——DeepViewer系统中<sup>[28]</sup>,从而提高放疗计划制定的工作效率。

## 【参考文献】

- [1] DAWSON L A, SHARPE M B. Im a ge-gui de dradiotherapy: rationale, benefits, and limitations[J]. *Lancet Oncol*, 2006, 7(10): 848-858.
- [2] TUBIANA M. Can we reduce the incidence of second primary malignancies occurring after radiotherapy? A critical review [J]. *Radiother Oncol*, 2009, 91(1): 4-15.
- [3] LI X A, TAI A, ARTHUR D W, et al. Variability of target and normal structure delineation for breast cancer radiotherapy: an RTOG multiinstitutional and multiobserver study[J]. *Int J Radiat Oncol Biol Phys*, 2009, 73(3): 944-951.
- [4] HARDCASTLE N, TOME W A, CANNON D M, et al. A multiinstitution evaluation of deformable image registration algorithms for automatic organ delineation in adaptive head and neck radiotherapy[J]. *Radiat Oncol*, 2012, 7(1): 90.
- [5] IGLESIAS J E, SABUNCU M R. Multi-atlas segmentation of biomedical images: a survey [J]. *Med Image Anal*, 2015, 24(1): 205-219.
- [6] SHARP G, FRITSCHER K D, PEKAR V, et al. Vision 20/20: perspectives on automated image segmentation for radiotherapy[J]. *Med Phys*, 2014, 41(5): 050902.
- [7] LITJENS G, KOOI T, BEJNORDI B E, et al. A survey on deep learning in medical image analysis[J]. *Med Image Anal*, 2017, 42(9): 60-88.
- [8] SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation [J]. *IEEE Trans Pattern Anal Mach Intell*, 2017, 39(4): 640-651.
- [9] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[C]//In *Medical Image Computing and Computer-Assisted Intervention*. 2015: 234-241.
- [10] ZHOU Y, XIE L, SHEN W, et al. A fixed-point model for pancreas segmentation in abdominal CT scans [C]//In *the Medical Image Computing and Computer Assisted Intervention*. 2017: 693-701.
- [11] HAN X. Automatic liver lesion segmentation using a deep convolutional neural network method [J]. *arXiv Preprint*, arXiv: 1704.07239, 2017.
- [12] ISENSEE F, PETERSEN J, KLEIN A, et al. nnU-Net self-adapting framework for U-Net-based medical image segmentation [J]. *arXiv Preprint*, arXiv: 1809.10486v1, 2018.
- [13] SUN Y, SHI H, ZHANG S, et al. Accurate and rapid CT image segmentation of the eyes and surrounding organs for precise radiotherapy [J]. *Med Phys*, 2019, 46(5): 2214-2222.
- [14] YANG X, CERROLAZA J, DUAN C, et al. Weighted partitioned active shape model for optic pathway segmentation in MRI [C]//In *Clinical Image-Based Procedures*. 2014: 109-117.
- [15] SUN M, ZHANG Z, MA C, et al. Random walk based optic chiasm localization using multi-parametric MRI for patients with pituitary adenoma [C]//In *SPIE Medical Imaging*. 2018.
- [16] BEKES G, MATE E, NYUL L G, et al. Geometrical model-based segmentation of the organs of sight on CT images [J]. *Med Phys*, 2008, 35(2): 735-743.
- [17] RAUDASCHL P F, ZAFFINO P, SHARP G C, et al. Evaluation of segmentation methods on head and neck CT: auto-segmentation challenge 2015 [J]. *Med Phys*, 2017, 44 (5): 2020-2036.
- [18] NOBLE J H, DAWANT B M. An atlas-navigated optimal medial axis and deformable model algorithm (NOMAD) for the segmentation of the optic nerves and chiasm in MR and CT images [J]. *Med Image Anal*, 2011, 15(6): 877-884.
- [19] MOČNIK D, IBRAGIMOV B, XING L, et al. Segmentation of parotid glands from registered CT and MR images [J]. *Phys Med*, 2018, 52(8): 33-41.
- [20] ZHOU T, RUAN S, CANU S. A review: deep learning for medical image segmentation using multi-modality fusion [J]. *arXiv preprint arXiv: 2004.10664*, 2019.
- [21] SPRINGENBERG J T, DOSOVITSKIY A, BROX T, et al. Striving for simplicity: the all convolutional net [J]. *arXiv preprint arXiv: 1412.6806*, 2014.
- [22] LEE C, XIE S, GALLAGHER P, et al. Deeply-supervised nets [J]. *arXiv preprint arXiv: 1409.5185*, 2014.
- [23] ZENG G, YANG X, LI J, et al. 3D U-net with multi-level deep supervision: fully automatic segmentation of proximal femur in 3D MR images [C]// In *Multimedia Modeling*. *Multimedia Modeling*. 2017: 274-282.
- [24] SUN Y, SHI H, ZHANG S, et al. Accurate and rapid CT image segmentation of the eyes and surrounding organs for precise radiotherapy [J]. *Med Phys*, 2019, 46(5): 2214-2222.
- [25] REN X, XIANG L, NIE D, et al. Interleaved 3D-CNNs for joint segmentation of small-volume structures in head and neck CT images [J]. *Med Phys*, 2018, 45(5): 2063-2075.
- [26] 田娟秀, 刘国才, 谷珊珊, 等. 基于3D深度残差全卷积网络的头颈CT放疗危及器官自动勾画 [J]. *中国生物医学工程学报*, 2019, 38 (3): 257-265.
- [27] TIAN J X, LIU G C, GU S S, et al. Segmentation of organs at risk on head and neck CT for radiotherapy based on 3D deep residual fully convolutional neural network [J]. *Chinese Journal of Biomedical Engineering*, 2019, 38(3): 257-265.
- [28] SIMARD P Y, STEINKRAUS D, PLATT J. Best practices for convolutional neural networks applied to visual document analysis [C]//In *Seventh International Conference on Document Analysis and Recognition*. 2003: 958-963.
- [29] 时飞跃, 王敏, 秦伟, 等. DeepViewer软件自动勾画乳腺癌保乳术后患者心脏结构的应用 [J]. *中国医疗设备*, 2020, 35(4): 48-51.
- [30] SHI F Y, WANG M, QIN W, et al. Application of DeepViewer in automatic delineation of heart structure for patients with breast cancer after breast-conserving surgery [J]. *China Medical Devices*, 2020, 35(4): 48-51.

(编辑:陈丽霞)