

DOI:10.3969/j.issn.1005-202X.2023.03.006

医学放射物理

两种自动勾画方法对T₃分期鼻咽癌靶区勾画结果对比分析

郭翌^{1,2,3}, 蓝林臻^{1,2}, 刘清泉⁴, 柳炫宇^{1,2}, 陈君^{1,2}, 陈舒影^{1,2}, 郭飞宝^{1,2,3}

1. 福建医科大学附属第一医院肿瘤中心放疗科, 福建 福州 350005; 2. 福建医科大学附属第一医院滨海院区国家区域医疗中心, 福建 福州 350212; 3. 放射生物福建省高等学校重点实验室, 福建 福州 350005; 4. 上海大图医疗科技有限公司, 上海 200062

【摘要】目的:比较和分析基于常规图谱集(Atlas)自动勾画方法和深度学习自动勾画方法对T₃分期鼻咽癌靶区的勾画结果。**方法:**回顾性选取本院T₃分期鼻咽癌患者138例,由一名高年资医生在CT上勾画GTV和CTV,勾画结果经另外两名高年资医生审核。建立3D-Unet模型,随机选取110例病例作为训练集,28例病例作为测试集。比较3D-Unet模型与Atlas模型的优劣性。**结果:**与医生勾画结果相比,3D-Unet模型的GTV和CTV平均勾画结果如下所示,平均表面距离:3.01和1.84 mm,95%豪斯多夫距离:16.05和7.70 mm,Dice相似性系数:0.71和0.83,Jaccard相似性系数:0.56和0.71,精确率:0.70和0.85,召回率:0.76和0.81,各项参数均显著优于Atlas模型($P<0.05$)。**结论:**与Atlas自动勾画技术相比,基于3D-Unet模型的自动勾画方法对鼻咽癌靶区的勾画准确率明显提升。

【关键词】鼻咽癌;调强放射治疗;深度学习;靶区勾画

【中图分类号】R318;R811.1

【文献标志码】A

【文章编号】1005-202X(2023)03-0291-06

Comparison of target segmentation results of two auto-segmentation methods for T₃ nasopharyngeal carcinoma

GUO Yi^{1,2,3}, LAN Linzhen^{1,2}, CHEN Qingquan⁴, LIU Xuanyu^{1,2}, CHEN Jun^{1,2}, CHEN Shuying^{1,2}, GUO Feibao^{1,2,3}

1. Department of Radiation Therapy, Cancer Center, the First Affiliated Hospital of Fujian Medical University, Fuzhou 350005, China; 2. National Regional Medical Center, Binhai Branch of the First Affiliated Hospital of Fujian Medical University, Fuzhou 350212, China; 3. Key Laboratory of Radiation Biology of Fujian Higher Education Institutions, Fuzhou 350005, China; 4. Datu Medical Technology Co., Ltd., Shanghai 200062, China

Abstract: Objective To compare and analyze the accuracy of tumor segmentation using Atlas-based auto-segmentation method and deep learning method for T₃ nasopharyngeal carcinoma (NPC). **Methods** A total of 138 cases of T₃ NPC were selected retrospectively. GTV and CTV were outlined in CT by one senior doctor, and the delineation results were reviewed by two other senior doctors. A 3D-Unet model was established, with 110 cases as the training set and 28 cases as the test set. The performances of 3D-Unet model and Atlas models were compared. **Results** The ASD, 95%HD, DSC, JSC, precision, and recall rate of GTV and CTV segmentations using 3D-Unet model were 3.01 and 1.84 mm, 16.05 and 7.70 mm, 0.71 and 0.83, 0.56 and 0.71, 0.70 and 0.85, 0.76 and 0.81, respectively. The comparison of the above mentioned parameters revealed that 3D-Unet model was superior to Atlas models ($P<0.05$). **Conclusion** Compared with Atlas models, the 3D-Unet based auto-segmentation method significantly improves the accuracy of target segmentation in NPC.

Keywords: nasopharyngeal carcinoma; intensity modulated radiation therapy; deep learning; target segmentation

前言

【收稿日期】2022-12-05

【基金项目】福建省高校产学研合作项目(2019Y4005);福建省自然科学基金青创项目(2021J05146);福建省卫生健康科技计划中青年骨干项目(2022GGA025)

【作者简介】郭翌,工程师,主要研究方向:医学物理, E-mail: gyi@mail.ustc.edu.cn

【通信作者】郭飞宝,高级工程师,主要研究方向:放射物理, E-mail: 23434552@qq.com

鼻咽癌是东亚以及东南亚国家高发的头颈部恶性肿瘤之一,具有明显的地域性分布特征^[1]。由于鼻咽癌对电离辐射敏感,中国临床肿瘤学会推荐鼻咽癌的治疗方式为调强放射治疗(Intensity Modulated Radiation Therapy, IMRT)^[2-3],IMRT具有靶区剂量高度适形和边缘剂量陡峭的特点,为了达到精准治疗的目的需要准确勾画肿瘤靶区。临床上常采用手动勾画方式勾画肿瘤,然而其勾画准确度取决于医生或物理师的临床经验,不同年资医生勾画相同靶区存在较大差异^[4-5]。

除此之外,手动勾画肿瘤费时费力。过往研究表明临床医生精准勾画头颈部肿瘤平均需要消耗2.7 h^[6]。因此寻找精准快速的自动勾画方法对于提高靶区勾画准确性与一致性具有重要意义。

常见的肿瘤自动勾画方法主要包括基于阈值、基于区域、基于像素分类和基于模板的技术。基于阈值的方法将像素值按照指定的范围进行归类^[7],基于区域的方法则假设一个区域由具有相似属性的相邻像素组成^[8]。在基于像素分类的技术中,肿瘤勾画取决于像素属性的特征空间,包括灰度值、局部纹理等^[9]。采用先验知识的Atlas方法属于基于模板的技术,该方法通过预先建立图谱集,将待勾画图像与图谱集数据进行图像配准后寻找最相似图像并复制其轮廓信息。尽管传统的肿瘤自动勾画技术已在大部分治疗计划系统(Treatment Planning System, TPS)上实现,然而其勾画准确度以及稳定性仍有待提高。

基于人工智能的靶区自动勾画方法是近年来的研究重点,国内外许多研究报道了该方法的可行性。Wadhwa等^[10]总结了深度学习技术在大脑磁共振影像(Magnetic Resonance Imaging, MRI)中的肿瘤勾画应用,研究发现采用条件随机场和全卷积神经网络相结合的方法在脑部MRI肿瘤勾画中具有优势。Qiao等^[11]提出一种注意力引导联合相位学习网络,在乳腺癌MRI上取得了良好的肿瘤勾画结果。Ilesanmi等^[12]同样报道了乳腺癌肿瘤的勾画研究进展,证明了人工智能技术相比于传统勾画方式有巨大应用潜力。

相比于脑胶质瘤与乳腺癌,鼻咽癌更为复杂且形状不规则,其靶区自动勾画难度较大^[13]。本文采用3D-Unet神经网络对T₃分期鼻咽癌靶区进行自动勾画研究,勾画结果与不同规模图谱集Atlas模型的勾画结果进行比较分析。

1 资料与方法

1.1 研究数据

本研究选取2010年4月~2021年3月在福建医科大学附属第一医院行IMRT治疗的鼻咽癌患者作为研究对象。根据美国肿瘤联合会第8版癌症分期手册,基于病理报告对所有病例进行相应的TNM分期^[14]。由于不同肿瘤T分期代表了肿瘤对鼻咽部的侵犯程度,因此多种T分期病例联合训练容易对神经网络模型造成干扰。为了提高神经网络的鲁棒性,本研究仅采用T₃分期病例作为训练与测试数据。病例入组标准:(1)T₃分期肿瘤病例;(2)无其他恶性肿瘤病史。排除标准:(1)其他分期肿瘤病例;(2)定位CT图像具有严重伪影。入组数据共138例,其中男106例,女32例,中位年龄50

岁。所有患者均在西门子大孔径CT模拟定位机上行CT扫描,扫描图像传输至TPS由一名高年资医生在CT图像上勾画大体肿瘤靶区(Gross Tumor Volume, GTV)和肿瘤临床靶区(Clinical Target Volume, CTV)。靶区勾画结果由另外两名高年资医生进行盲审,两名医生均对勾画结果无异议。

1.2 数据预处理

不同病例之间的CT图像具有不同的图像分辨率以及层厚,容易影响神经网络模型的收敛以及结果准确性,因此需要对训练数据进行预处理。本研究将所有入组病例随机分为110例训练数据和28例测试数据。所有图像数据首先进行重采样,重采样后体素间距为1.0 mm×1.0 mm×3.0 mm。由于图像重采样后不同病例之间图像大小不一致,需要固定神经网络模型的输入图像尺寸。受限于计算机显存大小,本研究采用图像块(Patch)方式代替重采样后的原始图像作为神经网络模型输入。每个Patch固定大小为64 mm×128 mm×224 mm,从重采样后的CT图像中截取。为了消除因类别不均产生的影响,本研究采用了动态截取Patch的策略:根据病例CT图像中感兴趣区域(Region of Interest)体素的数量计算每个病例截取的Patch个数,并随机生成每个Patch的截取位置。对于110例训练图像总共截取250个Patch。最后对数据进行归一化,将所有图像像素值映射到(0,1)范围内。

1.3 神经网络结构

本研究采用3D-Unet神经网络模型进行鼻咽癌靶区勾画,如图1所示。模型的输入为CT,输出为GTV和CTV的勾画图像。模型由5个下采样层(编码器)和5个上采样层(解码器)组成,每个采样层有两个计算块,每个计算块包含卷积、归一化(Instance Normalization)和激活函数(Leaky ReLU)。编码器与解码器之间使用跳跃连接,将编码器浅层特征与解码器的深层语义相结合。神经网络模型的总训练次数为1 000,优化器采用Nesterov Momentum($\mu=0.99$),初始化学学习率为0.1,批尺寸(Batchsize)为1。

1.4 损失函数

神经网络模型的损失函数包括戴斯值(Dice)和交叉熵(Cross Entropy, CE)。以医生勾画的GTV和CTV轮廓作为训练目标,计算网络模型输出轮廓与目标轮廓的Dice值与CE值,如式(1)、式(2)所示, A 表示神经网络输出的勾画结果, B 表示医生勾画的轮廓。

$$L_{\text{Dice}} = \frac{2 \times |A \cap B|}{|A| + |B|} \quad (1)$$

$$L_{\text{CE}} = - \sum_{a \in A, b \in B} (a \times \log b) \quad (2)$$




图1 3D-Unet神经网络结构
Figure 1 3D-Unet structure

1.5 评价指标

本研究建立了 3D-Unet 模型和两个 Atlas 图谱集:基于 60 例先验病例的 Atlas 图谱集 (Atlas60) 和基于 110 例先验病例的 Atlas 图谱集 (Atlas110)。其中 Atlas60 与 Atlas110 基于治疗计划系统 RayStation 建立,先验数据均从 110 例训练数据集中随机选取。3D-Unet 模型、Atlas60 和 Atlas110 的靶区勾画结果均与高年资医生勾画的 GTV 和 CTV 轮廓进行对比,采用以下几个指标进行分析。(1)平均表面距离 (Average Surface Distance, ASD) 和 95% 豪斯多夫距离 (95% Hausdorff Distance, 95%HD)。这两个指标分别表明了一个轮廓点集合到另一个轮廓点集合最近点距离的平均值和最大值,ASD 和 95%HD 越小表明模型勾画结果越好。(2)Dice 相似性系数 (Dice Similarity Coefficient, DSC) 和 Jaccard 相似性系数 (Jaccard Similarity Coefficient, JSC)。DSC 和 JSC 均用于评价两个轮廓之间的重合程度,DSC 和 JSC 越大代表两个轮廓重合程度越高。(3)精确率 (Precision) 和召回率 (Recall)。其中精确率指模型勾画正确的肿瘤区域占全部勾画区域的比值,召回率指模型勾画正确的肿瘤区域占实际肿瘤区域的比值^[15],上述两个指标越大说明模型的勾画结果越好。

1.6 硬件平台

本研究采用的设备平台参数如下:操作系统为 Ubuntu 16.04.6 LTS,图形处理单元 (Graphics Processing Unit, GPU) 为 NVIDIA GeForce RTX 2080TI 和 NVIDIA TITAN RTX 双显卡。

1.7 统计学分析

基于 SPSS 19 统计学软件分析 3D-Unet、Atlas60 和 Atlas110 的靶区勾画结果。采用非参数 Friedman

检验方法进行分析,并根据检验结果进行两两比较, $P<0.05$ 表示差异有统计学意义。

2 结果

2.1 不同自动勾画模型勾画结果

不同自动勾画模型勾画 GTV 和 CTV 结果对比见图 2、图 3。

2.2 不同自动勾画模型勾画结果参数对比评估

GTV 勾画结果如表 1 所示,3 种 GTV 勾画结果的 ASD、95%HD、DSC、JSC、精确率与召回率差异均有统计学意义 ($P<0.05$),其中 3D-Unet 模型的勾画结果优于 Atlas60 和 Atlas110。表 2 显示了 3 种模型的 CTV 勾画结果,3D-Unet 模型同样显著优于 Atlas 模型。

3 讨论

肿瘤靶区的准确勾画是精准放疗的前提。传统的手动勾画方式受限于医生的临床实践经验,不同资历医生甚至同一名医生在不同时间段内的靶区勾画结果存在不可忽视的差异。寻找快速且稳定的自动勾画方法能够在减轻医生工作负担的同时摆脱勾画结果对临床经验的依赖。目前大多数 TPS 均提供了基于先验知识的 Atlas 自动勾画功能。该方法需要使用者预先准备模板图谱集,当对新病例图像进行勾画时,模型从图谱集中寻找与新病例最相似的图像数据,并将其已有的勾画结果配准复制到新病例图像中。尽管 Atlas 模型能够在一定程度上提供自动勾画结果,然而其准确性与图谱集的规模相关^[16-17]。基于深度学习技术的肿瘤自动勾画方法已被证明在乳腺癌中具有应用可行性。本研究针对靶区形状更




图 2 不同模型勾画 GTV 结果对比

Figure 2 Comparison of GTV segmentation results among different models

图中红色部分为医生勾画结果,第一行图像为横断面图像,第二行图像为矢状面图像,第三行图像为冠状面图像




图 3 不同模型勾画 CTV 结果对比

Figure 3 Comparison of CTV segmentation results among different models

图中红色部分为医生勾画结果,第一行图像为横断面图像,第二行图像为矢状面图像,第三行图像为冠状面图像

表 1 3D-Unet、Atlas60 和 Atlas110 对鼻咽癌患者 GTV 的勾画结果($\bar{x}\pm s$)
Table 1 GTV segmentation results obtained by 3D-Unet, Atlas60 and Atlas110 ($Mean\pm SD$)

组别	ASD/mm	95%HD/mm	DSC	JSC	精确率	召回率
3D-Unet	3.01±1.02	16.05±2.40	0.71±0.08	0.56±0.10	0.70±0.15	0.76±0.10
Atlas60	4.86±1.99*	12.70±4.27*	0.59±0.12*	0.43±0.12*	0.56±0.18*	0.67±0.13
Atlas110	4.01±1.88 [#]	12.11±3.90 [#]	0.61±0.11 [#]	0.45±0.11 [#]	0.64±0.19 [#]	0.65±0.15 [#]
F 值	33.96	36.93	40.93	40.93	26.80	8.25
P 值	0.00	0.00	0.00	0.00	0.00	0.02

Atlas60 与 3D-Unet 相比, * $P<0.05$; Atlas110 与 3D-Unet 相比, [#] $P<0.05$

表2 3D-Unet、Atlas60和Atlas110对鼻咽癌患者CTV的勾画结果
Table 2 CTV segmentation results obtained by 3D-Unet, Atlas60 and Atlas110

组别	ASD/mm	95%HD/mm	DSC	JSC	精确率	召回率
3D-Unet	1.84±0.56	7.70±4.39	0.83±0.04	0.71±0.05	0.85±0.04	0.81±0.10
Atlas60	2.92±0.70*	10.64±3.21*	0.73±0.04*	0.57±0.05*	0.77±0.07*	0.70±0.09*
Atlas110	3.08±1.03 [#]	13.33±6.31 [#]	0.70±0.08 [#]	0.54±0.09 [#]	0.74±0.10 [#]	0.68±0.11 [#]
F值	36.93	21.26	44.82	44.82	41.73	33.85
P值	0.00	0.00	0.00	0.00	0.00	0.02

Atlas60与3D-Unet相比,*P<0.05;Atlas110与3D-Unet相比,[#]P<0.05

为复杂的鼻咽癌建立了3D-Unet模型以及两个Atlas图谱集:Atlas60和Atlas110,对比评估了3个模型对鼻咽癌的自动勾画能力。

表1展示了鼻咽癌GTV的勾画结果,评价指标包括了ASD、95%HD、DSC、JSC、精确率和召回率。可以看出在6种指标上3D-Unet的勾画结果均显著优于Atlas模型。3种模型的两两对比结果显示3D-Unet的勾画结果与两种Atlas图谱集勾画结果的差异均具有统计学意义。在鼻咽癌CTV的勾画方面,表2给出了相同的结论,3D-Unet模型的勾画能力领先于Atlas模型。尽管两种Atlas图谱集也能在一定程度上对GTV和CTV进行勾画,然而受限于图谱集的大小以及图像配准误差,其勾画准确性难以达到临床应用程度。图2和图3显示,Atlas模型的靶区勾画结果与医生勾画结果相比在轮廓边缘处难以对齐。在大部分层面上Atlas模型低估了GTV和CTV区域,而在少部分层面上则过分高估了靶区区域。相比之下3D-Unet模型则更好地预测了靶区轮廓,其勾画结果与医生勾画结果的重合性更好。由此可见,3D-Unet网络模型相比于Atlas模型能够提取鼻咽癌影像中人眼难以捕捉的细节信息,通过对图像特征的学习达到精准靶区勾画的目的。

以往的研究工作也表明了深度神经网络的鼻咽癌靶区勾画能力^[18-24],Wang等^[25]使用了T₁WI核磁影像进行卷积神经网络(Convolutional Neural Networks, CNN)训练,其肿瘤勾画轮廓的DSC和JSC为0.6~0.8。Guo等^[26]同样使用MRI进行鼻咽癌靶区边界勾画,提出一种具有长距离跳跃连接和多尺度特征金字塔形的CNN,采用DSC和ASD两种评价指标,测试数据平均结果分别为73.7%和1.214 mm。Bai等^[27]则基于鼻咽癌CT影像建立了神经网络勾画模型,在测试数据集上对GTV的勾画结果平均DSC为61.81%。与上述研究相比,本研究采用了更多的评价指标,多角度定量分析了神经网络模型的性能,同时在测试数据集上的平均勾画结果相比于其他研究准确性更高。

除了对比神经网络模型与Atlas模型的优劣性之外,本研究还探索了图谱集规模对于Atlas模型勾画准确性的影响。Atlas60和Atlas110分别随机使用了60例和110例T₃分期鼻咽癌数据。这两种模型对于GTV和CTV的自动勾画能力基本没有差异。这提示Atlas模型的准确性并非随图谱集规模的增大而线性增长,图谱集规模越大则存在冗余重复的数据越多,同时自动勾画能力还受到图像配准误差等限制。钱月晶^[28]考虑到图谱集的干扰性和冗余性的不足,提出一种基于两步图谱选择策略的脑MRI器官勾画方法,相比于传统方式具有更高的鲁棒性和准确性。

本研究建立了一个基于T₃分期鼻咽癌CT图像的深度学习神经网络模型,结果表明人工智能技术在鼻咽癌靶区自动勾画应用中的可行性以及优越性。采用深度学习能够代替人工手动勾画方式,得到快速且稳定的靶区勾画结果,在减轻医生负担的同时消除临床经验带来的误差影响。除此之外为了提高Atlas自动勾画模型的准确性,仅仅增加图谱集的规模并不能得到性能的大幅提升,可能还需要改善图像配准算法等问题。

【参考文献】

[1] Sung H, Ferlay J, Siegel RL, et al. Global cancer statistics 2020: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries[J]. CA Cancer J Clin, 2021, 71(3): 209-249.
[2] 中国临床肿瘤学会指南工作委员会. 鼻咽癌诊疗指南2021[M]. 北京: 人民卫生出版社, 2021: 31-45.
Chinese Society of Clinical Oncology. Guidelines of Chinese society of clinical oncology nasopharyngeal carcinoma 2021[M]. Beijing: People's Medical Publishing House, 2021: 31-45.
[3] 吴俚蓉, 顾佳佳, 宗升, 等. 鼻咽癌诊疗总览分析[J]. 肿瘤学杂志, 2021, 27(11): 889-899.
Wu LR, Gu JJ, Zong D, et al. Overview and analysis on diagnosis and treatment of nasopharyngeal carcinoma[J]. Journal of Chinese Oncology, 2021, 27(11): 889-899.
[4] Li Y, Han GH, Liu XJ. DCNet: densely connected deep convolutional encoder-decoder network for nasopharyngeal carcinoma segmentation[J]. Sensors (Basel), 2021, 21(23): 7877.
[5] Bi WL, Hosny A, Schabath MB, et al. Artificial intelligence in cancer imaging: clinical challenges and applications[J]. CA Cancer J Clin, 2019, 69(2): 127-157.
[6] Das IJ, Moskvina V, Johnstone PA. Analysis of treatment planning time

- among systems and planners for intensity-modulated radiation therapy [J]. J Am Coll Radiol, 2009, 6(7): 514-517.
- [7] Sujan M, Alam N, Noman SA, et al. A segmentation based automated system for brain tumor detection[J]. Int J Comput Appl, 2016, 153(10): 41-49.
- [8] Ba JI, Asghar MN, Naeen MA. Learning-based improved seeded region growing algorithm for brain tumor identification [J]. Proceedings of the Pakistan Academy of Sciences, 2017, 54(2): 127-133.
- [9] Vijay J, Subhashini J. An efficient brain tumor detection methodology using K-means clustering algorithm[C]//International Conference on Communications & Signal Processing. IEEE, 2013: 653-657.
- [10] Wadhwa A, Bhardwaj A, Verma VS. A review on brain tumor segmentation of MRI images[J]. Magn Reson Imaging, 2019, 61: 247-259.
- [11] Qiao MY, Suo ST, Cheng F, et al. Three-dimensional breast tumor segmentation on DCE-MRI with a multilabel attention-guided joint-phase-learning network[J]. Comput Med Imaging Graph, 2021, 90: 101909.
- [12] Ilesanmi AE, Chaumrattanakul U, Makhanov SS. Methods for the segmentation and classification of breast ultrasound images: a review [J]. J Ultrasound, 2021, 24(4): 367-382.
- [13] Qi YX, Li JY, Chen H, et al. Computer-aided diagnosis and regional segmentation of nasopharyngeal carcinoma based on multi-modality medical images[J]. Int J Comput Assist Radiol Surg, 2021, 16(6): 871-882.
- [14] Amin MB, Greene FL, Edge SB, et al. The eighth edition AJCC cancer staging manual: continuing to build a bridge from a population-based to a more "personalized" approach to cancer staging[J]. CA Cancer J Clin, 2017, 67(2): 93-99.
- [15] 谷静, 马瑞齐, 朱恒安. 基于卷积神经网络的X图像骨骼评估方法[J]. 中国医学物理学杂志, 2022, 39(3): 305-310.
- Gu J, Ma RQ, Zhu HA. Convolutional neural network-based method for bone age assessment in X-ray image[J]. Chinese Journal of Medical Physics, 2022, 39(3): 305-310.
- [16] 朱大龙, 易云山. 人工智能在医学影像中的MRI海马区勾画算法研究综述[J]. 网络安全技术与应用, 2020, 12: 47-49.
- Zhu DL, Yi YS. Summary of MRI hippocampal segmentation algorithm of artificial intelligence in medical images[J]. Network Security Technology & Application, 2020, 12: 47-49.
- [17] Huang HM, Zheng H, Lin LF, et al. Medical image segmentation with deep atlas prior[J]. IEEE Trans Med Imaging, 2021, 40(12): 3519-3530.
- [18] Wang DL, Gong Z, Zhang YF, et al. Convolutional neural network intelligent segmentation algorithm-based magnetic resonance imaging in diagnosis of nasopharyngeal carcinoma foci[J]. Contrast Media Mol Imaging, 2021. Doi: 10.1155/2021/2033806.
- [19] Daoud B, Morooka K, Kurazume R, et al. 3D segmentation of nasopharyngeal carcinoma from CT images using cascade deep learning[J]. Comput Med Imaging Graph, 2019, 77: 101644.
- [20] Ma ZQ, Zhou S, Wu X, et al. Nasopharyngeal carcinoma segmentation based on enhanced convolutional neural networks using multi-modal metric learning[J]. Phys Med Biol, 2019, 64(2): 025005.
- [21] Ye YF, Cai ZY, Huang B, et al. Fully-automated segmentation of nasopharyngeal carcinoma on dual-sequence MRI using convolutional neural networks[J]. Front Oncol, 2020, 10: 166.
- [22] Ma ZQ, Wu X, Song Q, et al. Automated nasopharyngeal carcinoma segmentation in magnetic resonance images by combination of convolutional neural networks and graph cut[J]. Exp Ther Med, 2018, 16(3): 2511-2521.
- [23] Ke LR, Deng YS, Xia WX, et al. Development of a self-constrained 3D DenseNet model in automatic detection and segmentation of nasopharyngeal carcinoma using magnetic resonance images[J]. Oral Oncol, 2020, 110: 104862.
- [24] 刘裕良, 李永宝, 开孟科, 等. 基于不同感受野的鼻咽癌靶区和危及器官自动勾画网络研究[J]. 中华放射肿瘤学杂志, 2021, 30(5): 468-474.
- Liu YL, Li YB, Qi MK, et al. Different receptive fields-based automatic segmentation network for gross target volume and organs at risk of patients with nasopharyngeal carcinoma [J]. Chinese Journal of Radiation Oncology, 2021, 30(5): 468-474.
- [25] Wang Y, Zu C, Hu GL, et al. Automatic tumor segmentation with deep convolutional neural networks for radiotherapy applications [J]. Neural Process Lett, 2018, 48(3): 1323-1334.
- [26] Guo F, Shi CH, Li XJ, et al. Image segmentation of nasopharyngeal carcinoma using 3D CNN with long-range skip connection and multi-scale feature pyramid[J]. Soft Computing, 2020, 24(16): 12671-12680.
- [27] Bai XY, Hu Y, Gong GZ, et al. A deep learning approach to segmentation of nasopharyngeal carcinoma using computed tomography[J]. Biomed Signal Proces, 2021, 64: 102246.
- [28] 钱月晶. 基于两步图谱选择的脑MR图像勾画[J]. 计算机系统应用, 2022, 31(3): 203-211.
- Qian YJ. Brain MR image segmentation based on two-stage atlas selection[J]. Computer Systems & Applications, 2022, 31(3): 203-211.

(编辑:薛泽玲)