

## 卷积神经网络放疗计划剂量预测:两种解码器对比

陈辛元, 易俊林, 戴建荣

国家癌症中心/国家肿瘤临床医学研究中心/中国医学科学院北京协和医学院肿瘤医院, 北京 100021

**【摘要】目的:**拟建立卷积神经网络放疗计划三维剂量分布预测模型,比较两种解码器对网络性能的影响。**方法:**实验数据包括80例早期鼻咽癌的放疗计划,并随机分为训练集(70例)和测试集(10例)。基于VGG16卷积神经网络,分别采用插值和反卷积两种解码器,建立两种网络结构:插值解码VGG16网络(IVGG16)和反卷积解码VGG16网络(DVGG16),用于端到端的放疗计划剂量预测。评价模型准确性指标主要包括外轮廓、靶区及危及器官(OAR)的平均绝对误差(MAE),并分别记录两个网络的训练时间和预测时间。**结果:**使用两种解码器均可以较准确地预测患者三维剂量分布。IVGG16和DVGG16的外轮廓MAE分别为 $(5.48\pm 0.46)\%$ 和 $(5.42\pm 0.34)\%$ ,差别无统计学意义;靶区的预测值均较准确,MAE均低于2.63%,两种解码器没有统计学意义;两个网络均可以较准确预测OAR的剂量分布。脊髓PRV和甲状腺的MAE,DVGG16较IVGG16分别下降11.8%和15.6%( $P=0.029, 0.034$ ),其余OAR的MAE差别无统计学意义。IVGG16和DVGG16模型训练时间分别为14.8 h和24.6 h,每例平均预测时间分别为 $(6.6\pm 1.0)$  s和 $(28.7\pm 3.9)$  s。**结论:**采用插值和反卷积两种解码器预测得到的放疗剂量在整体上具有相当的效果。反卷积解码器对部分OAR剂量分布预测准确性略优,但模型训练和预测的效率有待提高。

**【关键词】**卷积神经网络;解码器;放射治疗;剂量预测

**【中图分类号】**R318;R815

**【文献标志码】**A

**【文章编号】**1005-202X(2020)02-0153-06

## Radiotherapy planning dose prediction using convolutional neural network: a comparison of two kinds of decoders

CHEN Xinyuan, YI Junlin, DAI Jianrong

National Cancer Center/National Clinical Research Center for Cancer/Cancer Hospital, Chinese Academy of Medical Sciences and Peking Union Medical College, Beijing 100021, China

**Abstract: Objective** To establish a three-dimensional radiotherapy planning dose distribution prediction model using convolutional neural network, and to compare the effects of two kinds of decoders on network performance. **Methods** The radiotherapy plans of 80 cases of early nasopharyngeal carcinoma were included in the study, and then were randomly divided into a training set (70 cases) and a test set (10 cases). Based on VGG16 convolutional neural network, interpolation VGG16 network (IVGG16) and deconvolution VGG16 network (DVGG16) were established by two kinds of decodes, namely interpolation and deconvolution. The established networks were used for end-to-end radiotherapy planning dose prediction. The main indicators for the evaluation of model accuracy included the mean absolute errors (MAE) of the outline, tumor target areas and organs-at-risk (OAR). Moreover, the training time and prediction time of two kinds of networks were also recorded. **Results** The three-dimensional dose distribution could be predicted accurately using both two kinds of decoders. The MAE of the outline obtained by IVGG16 and DVGG16 were  $(5.48\pm 0.46)\%$  and  $(5.42\pm 0.34)\%$ , respectively, without statistical significance. The doses of the target areas were accurately predicted by two kinds of decodes, with a MAE lower than 2.63%, and there was no statistical difference between two kinds of decodes. The dose distributions of OAR were accurately predicted by two kinds of networks. However, compared with those obtained by IVGG16, the MAE of spinal cord PRV and thyroid obtained by DVGG16 was decreased by 11.8% and 15.6%, respectively ( $P=0.029, 0.034$ ), and there was no statistical differences in the MAE of the remaining OAR. The training time of IVGG16 and DVGG16 models were 14.8 h and 24.6 h, respectively, and the average prediction time for each case were

**【收稿日期】**2019-10-20

**【基金项目】**国家自然科学基金(11875320);北京市科学技术委员会医药协同科技创新研究(Z181100001918002);中国癌症基金会北京希望马拉松专项基金(LC2018A14)

**【作者简介】**陈辛元,博士,助理研究员,研究方向:图像引导放疗、人工智能,E-mail: cinya126chen@163.com

**【通信作者】**戴建荣,E-mail: dai\_jianrong@cicams.ac.cn

( $6.6\pm 1.0$ ) s and ( $28.7\pm 3.9$ ) s, respectively. **Conclusion** The radiotherapy dose prediction using interpolation or deconvolutional decoders has a satisfactory effect. The deconvolutional decoder has a slightly higher prediction accuracy for some OAR dose distribution, but the efficiency of model training and prediction need to be further improved.

**Keywords:** convolutional neural network; decoder; radiotherapy; dose prediction

## 前言

深度学习方法是一种多層級的特征学习方法,通过非线性的模型转换提取更抽象的高层次表达,以强化区分输入数据的能力,同时去除不相关因素<sup>[1]</sup>。近年来,计算机硬件的性能不断提升,能够更好地支持深度学习所需要的算力,促进其发展。其中,深度卷积神经网络(Convolutional Neural Network, CNN)是具有代表性的表达学习方法之一,在模式识别和计算机视觉等领域取得了较大突破<sup>[1-2]</sup>。诸如VGGNet等CNN是通过卷积等运算,从海量数据中自动提取数据多层次的特征,这些特征通常对预测更有效,从而解决传统机器学习需要人工提取特征的难题<sup>[3-4]</sup>。2014年,VGGNet在ImageNet图像集的识别分类任务中,错误率降低到6.8%,并且仅采用了16~19层的卷积网络,相对简单而高效。

近几年,有学者将深度学习网络应用于医学领域,在皮肤癌和糖尿病视网膜病变自动检测等领域已取得重大突破<sup>[5-6]</sup>。也有学者将CNN应用于放射治疗领域<sup>[7-8]</sup>,并取得较传统方法更好的效果,如靶区及危及器官(Organs-at-Risk, OAR)自动分割<sup>[9-11]</sup>和放疗的毒副作用预测<sup>[12]</sup>等;在计划设计领域,笔者提出可以将CNN应用于三维(Three-Dimensional, 3D)剂量预测,可取得较准确的效果<sup>[13]</sup>;亦有学者对前列腺癌和鼻咽癌进行研究,分别采用3D网络和二维网络,将器官和靶区分别作为多通道进行输入,输出剂量分布<sup>[14-15]</sup>。

笔者及其他学者的研究均证明,深度学习方法可能是解决放疗计划3D剂量预测的潜在工具,但仍需进一步实验验证更多算法,探索性能较优的网络结构。CNN包括编码器和解码器两部分,编码器的池化层会逐渐缩减输入图像的空间维度,而解码器通过插值或反卷积恢复图像细节和相应的空间维度。本研究拟开发两不同编码器的CNN结构,用于实现放疗计划患者3D剂量分布预测,并比较两种网络的预测效果,探索较理想的CNN解码器结构。

## 1 材料和方法

### 1.1 患者数据和治疗计划

本研究纳入2011~2016年期间接受同步加量放疗的80例早期鼻咽癌患者,随机分成训练集70例和测试集10例,分别进行模型训练和模型验证。所有患者均采用仰卧位,头颈肩热塑膜面罩固定。使用Somatom Definition AS 40 (Siemens Healthcare, Forchheim, Germany)或Brilliance CT Big Bore (Philips Healthcare, Best, the Netherlands)系统,获得患者模拟定位CT图像(扫描层厚3 mm; 512×512矩阵)。

所有放疗计划均通过头颈组及物理组专家团队的审核,保证放疗计划数据的质量。常规采用两程治疗方案,本研究预测的3D剂量为一程治疗方案,并且按33分次进行计算。同步加量靶区PTVboost包括鼻咽原发灶和阳性淋巴结,按处方剂量69.96 Gy进行计划设计,单次剂量为2.12 Gy。计划靶区(Planning Target Volume, PTV)按处方剂量60.06 Gy进行计划设计,单次剂量为1.82 Gy<sup>[16]</sup>。共勾画21个OAR,并用于计划设计和计划评估,包括脑干的危及器官计划体积(Planning Organs-at-Risk Volume, PRV)、脑干、喉、左右晶体、左右下颌骨、视交叉、左右视神经、左右腮腺、垂体、脊髓PRV、脊髓、左右颞颌关节(Temporomandibular Joint, TMJ)、左右颞叶、甲状腺和气管。放疗计划均由有经验的物理师进行设计,使用Pinnacle 8.0-9.10治疗计划系统(Philips Radiation Oncology Systems, Fitchburg, WI, USA)进行逆向优化和计算。

### 1.2 数据的预处理方法

自主开发结构图像预处理算法,生成结构图像(Structure Images, StrutImgs),以解决放疗计划DICOM文件无法直接用于深度学习网络训练的缺点<sup>[13]</sup>。对结构DICOM文件进行预处理,定义分配不同的灰度值作为每个结构的轮廓标签,外轮廓标号为1,各OAR依次标号为2~22,PTV为23,OAR与PTV重叠处标号为PTV+OAR,为保证标号的唯一性,PTVboost需大于PTV+OAR最大值45,因此本研究PTVboost设置为46。同时,为保证图像PTV以外的层面剂量预测的准确性,对PTV野外的头脚方向图像层位置进行标记。最终生成可用于模型训练的StrutImgs。

### 1.3 基于深度学习的放疗计划剂量预测 workflow

笔者提出了一个端到端的基于深度学习的放疗

计划剂量预测 workflow, 在先前研究中使用 101 层 ResNet 进行模型的验证, 取得了较好的效果<sup>[13]</sup>。但是 ResNet 结构相对复杂, 且层数较多, 对服务器性能要求较高, 训练和预测时间都较长。为了提高效率,

本研究基于相对简单高效的 16 层 VGG16 网络, 分别开发两个全卷积 CNN 架构, 用于实现端到端的自动放疗计划剂量预测, 并探索较理想的网络结构(图 1)。




图1 基于两种 CNN 解码器(IVGG16 和 DVGG16)的端到端 3D 剂量预测 workflow  
Fig.1 End-to-end framework of 3D dose prediction using two kinds of convolutional neural network decoders (IVGG16 and DVGG16)

CNN 采用编码器-解码器构架, 本研究基于 VGG16 的编码部分, 分别采用插值和反卷积两种解码器, 建立两种网络结构, 用于端到端的放疗计划剂量预测, 并对比两种解码器的性能(表 1)。编码器的卷积层由多个 3×3 卷积滤波器和一系列的池化层组成, 以进行特征提取。最大池化层用于提取图像的主要特征, 并减小特征图的尺寸, 因此在解码器部分需要恢复到原始空间大小。建立两种 CNN 解码器结构, 一是采用全卷积双线性插值算法进行上采样, 称为插值解码 VGG16 网络 (Interpolation VGG16, IVGG16); 二是解码器采用改进的反卷积网络层, 逐步恢复剂量分布的细节和相应的空间维度, 进行参数计算, 称为反卷积解码 VGG16 网络 (Deconvolutional VGG16, DVGG16)。

基于 Caffe 机器学习框架进行编程, 可实现模型的训练、评估、错误分析和可视化<sup>[17]</sup>。利用随机梯度下降法对函数的损失进行优化。批处理数值为 2, 采用“poly”学习策略, 初始学习速率设置为 0.001, power 设置为 0.9, 动量设置为 0.9, 最大迭代次数设为 5 万次。使用 Intel® Core i7 processor (3.4 GHz) 服务器和 Titan X GPU 卡进行模型训练和测试运算。在实验中, 采用一系列数据增强技术, 包括随机裁剪、翻转等操作, 以扩增数据量。

1.4 定量评估模型的准确性

对预测剂量分布的准确性进行定量评估, 基于体素计算外轮廓范围内的平均误差 (Mean Error, ME)、平

均绝对误差 (Mean Absolute Error, MAE) 和均方根误差 (Root-Mean-Square Error, RMSE) 以及各 OAR 及靶区的 MAE。ME、MAE 和 RMSE 的计算如式(1)~(3)所示。

$$ME = \frac{1}{m} \sum_{i=1}^m (D_p(i) - D_g(i)) / \text{Prescription Dose} \times 100\%$$
 (1)

$$MAE = \frac{1}{m} \sum_{i=1}^m |D_p(i) - D_g(i)| / \text{Prescription Dose} \times 100\%$$
 (2)

$$RMSE = \sqrt{\frac{\sum_{i=1}^m D_p(i)^2 - D_g(i)^2}{m}} / \text{Prescription Dose} \times 100\%$$
 (3)

其中,  $m$  是体素的数量,  $D_p(i)$  是第  $i$  个像素点的剂量预测值,  $D_g(i)$  是第  $i$  个像素点的剂量真实值。

使用 SPSS 19.0 软件, 分析 IVGG16 和 DVGG16 预测结果的准确性, 使用配对  $t$  检验进行统计学分析。  $P < 0.05$  为差异有统计学意义。

1.5 模型训练和预测时间比较

分别记录 IVGG16 和 DVGG16 网络的模型训练时间以及每个病人的预测时间。

2 结果

2.1 模型整体剂量分布预测比较

10 例测试集, IVGG16 和 DVGG16 的外轮廓 MAE 分别为 (5.48±0.46)% 和 (5.42±0.34)%, RMSE 分别为 (8.85±0.71)% 和 (8.70±0.53)%, 差别均无统计学意义 ( $P=0.51, 0.15$ ), 表明这两个网络均可以较准确

表1 IVGG16和DVGG16的网络结构  
Tab.1 Net architectures of IVGG16 and DVGG16

编码器		解码器			
IVGG16和DVGG16		IVGG16		DVGG16	
conv1	$\begin{bmatrix} 3 \times 3, 1, 1, 64 \\ 3 \times 3, 1, 1, 64 \end{bmatrix}$	fc6	$[3 \times 3, 1, 1, 1024]$	Dconv5	$\begin{bmatrix} 3 \times 3, 2, 1, 512 \\ 3 \times 3, 1, 1, 512 \\ 3 \times 3, 1, 1, 512 \end{bmatrix}$
pool1	$[3 \times 3, 2, 1, 64]$	fc7	$[1 \times 1, 1, 0, 1024]$	Dpool4	$[3 \times 3, 1, 1, 512]$
conv2	$\begin{bmatrix} 3 \times 3, 1, 1, 128 \\ 3 \times 3, 1, 1, 128 \end{bmatrix}$	fc8	$[1 \times 1, 1, 0, 256]$	Dconv4	$\begin{bmatrix} 3 \times 3, 2, 1, 512 \\ 3 \times 3, 1, 1, 512 \\ 3 \times 3, 1, 1, 512 \end{bmatrix}$
pool2	$[3 \times 3, 2, 1, 128]$	Interpolation	Factor = 8	Dpool3	$[3 \times 3, 1, 1, 512]$
conv3	$\begin{bmatrix} 3 \times 3, 1, 1, 256 \\ 3 \times 3, 1, 1, 256 \\ 3 \times 3, 1, 1, 256 \end{bmatrix}$			Dconv3	$\begin{bmatrix} 3 \times 3, 2, 1, 512 \\ 3 \times 3, 1, 1, 512 \\ 3 \times 3, 1, 1, 512 \end{bmatrix}$
pool3	$[3 \times 3, 2, 1, 256]$			fc6	$[1 \times 1, 1, 0, 1024]$
conv4	$\begin{bmatrix} 3 \times 3, 1, 1, 512 \\ 3 \times 3, 1, 1, 512 \\ 3 \times 3, 1, 1, 512 \end{bmatrix}$			fc7	$[1 \times 1, 1, 0, 256]$
pool4	$[3 \times 3, 1, 1, 512]$				
conv5	$\begin{bmatrix} 3 \times 3, 1, 1, 512 \\ 3 \times 3, 1, 1, 512 \\ 3 \times 3, 1, 1, 512 \end{bmatrix}$				
pool5	$[3 \times 3, 1, 1, 512]$				

地完成放疗计划剂量预测。IVGG16和DVGG16的外轮廓ME分别为 $(-1.30 \pm 0.98)\%$ 和 $(-1.70 \pm 0.93)\%$ ，差异有统计学意义( $P=0.007$ )，但是平均值差别仅

为 $-0.40\%$ ，对于临床应用影响较小。图2显示IVGG16和DVGG16均可以通过输入StructImgs较好地预测放疗计划3D剂量分布。

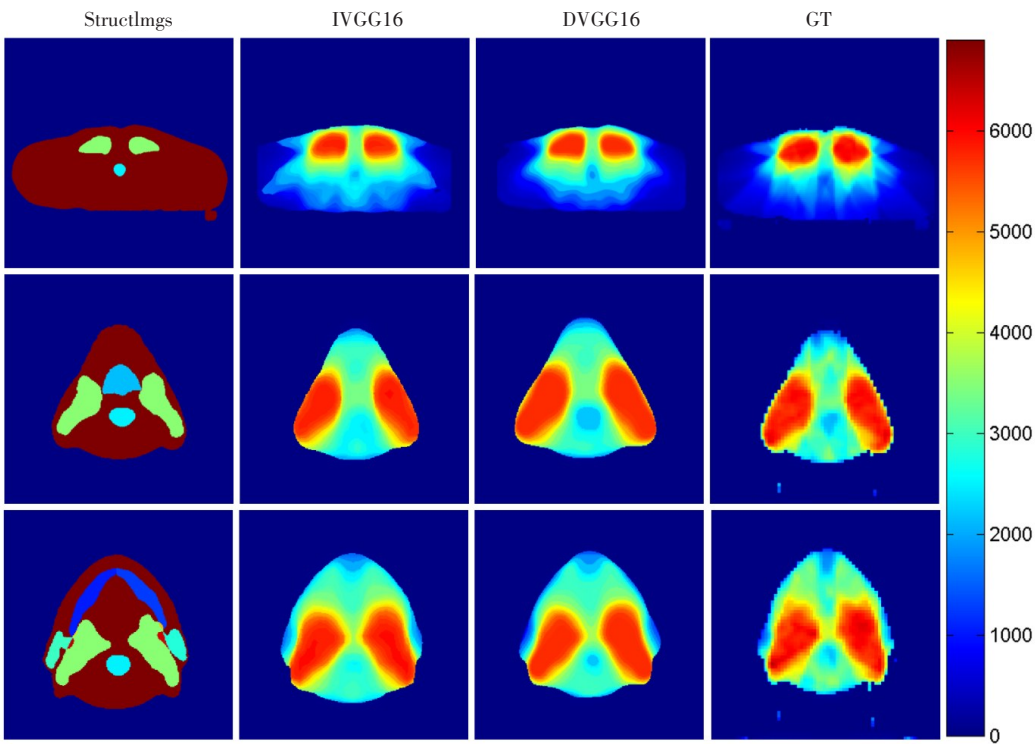


图2 使用IVGG16和DVGG16预测的3D剂量分布及相应的StructImgs和真实值  
Fig.2 Dose prediction of IVGG16 and DVGG16 and the corresponding StructImgs and ground truth



2.2 模型对各靶区与OAR预测比较

由表2可知,IVGG16和DVGG16对于靶区PTV和PTVboost剂量分布的预测均较准确,MAE均低于2.63%,且没有统计学意义。对于OAR的预测精度,两个网络均可以较准确预测OAR的剂量分布。对于脊髓PRV和甲状腺,DVGG16较IVGG16的MAE相对分别下降11.8%和15.6%,有统计学差异( $P=0.029, 0.034$ ),其余OAR的MAE均无统计学意义。IVGG16较DVGG16对脊髓的细节预测精度下降,与脊髓PRV的MAE统计学分析结果相一致。

表2 靶区和OAR的MAE值比较  
Tab.2 Comparison of mean absolute error for each target area and organ-at-risk

危及器官以及靶区	IVGG16/%	DVGG16/%	P值
脑干	5.21±2.17	4.89±1.31	0.373
脑干PRV	5.45±1.28	4.98±0.92	0.056
喉	4.96±1.35	4.85±1.35	0.632
左晶体	2.61±1.99	1.76±0.87	0.096
右晶体	2.38±2.36	1.31±0.53	0.157
左下颌骨	4.33±0.78	4.09±0.54	0.143
右下颌骨	4.90±0.90	4.96±0.62	0.652
视交叉	7.60±3.31	8.21±4.47	0.440
左视神经	7.61±4.68	8.11±3.37	0.316
右视神经	6.64±2.82	7.77±2.87	0.077
左腮腺	6.99±1.56	6.82±1.67	0.715
右腮腺	7.28±1.14	7.13±1.43	0.787
脊髓	5.34±2.61	5.07±1.53	0.544
脊髓PRV	5.51±1.52	4.93±1.16	0.029
左颞颌关节	6.30±2.13	7.12±2.65	0.135
右颞颌关节	5.30±2.19	6.05±2.15	0.208
左颞叶	4.61±0.69	4.94±1.09	0.236
右颞叶	4.65±1.53	4.55±1.11	0.724
甲状腺	5.86±1.51	5.07±1.79	0.034
PTVboost	1.72±0.30	1.71±0.28	0.896
PTV	2.63±0.43	2.58±0.42	0.149

2.3 模型训练和预测效率比较

IVGG16网络模型训练时间为14.8 h,而DVGG16网络模型训练时间为24.6 h。测试集每例平均预测时间,IVGG16网络和DVGG16网络分别为(6.6±1.0) s和(28.7±3.9) s。

3 讨论

本研究尝试采用不同的深度学习解码器结构,并使用合理的输入和输出,实现精准的患者放疗计划3D剂量分布预测。该模型将StuctImgs作为输入,剂量分布作为输出。医生完成一例新计划的靶区和OAR勾画后,输入训练好的模型,两个网络均可在10 s内,预测出该病例每层的剂量分布,并可计算每个感兴趣区域的DVH等剂量参数,从而可以更好地应用于计划质量控制和自动计划设计等。

VGG网络结构相对简单且更容易训练。本研究分别建立了IVGG16和DVGG16两个全卷积深度学习网络,测试解码器复原的准确性。DVGG16网络可进行反卷积、反池化和反激活运算<sup>[18-19]</sup>。结果显示,两个网络均可较好地实现放疗计划3D剂量预测,两个网络外轮廓MAE差别约为0.06,无统计学意义;DVGG16和IVGG16在脊髓PRV和甲状腺MAE比较上有统计学意义,在细节方面,DVGG16优于IVGG16。

使用传统机器学习方法进行DVH或3D剂量分布预测需手动进行特征提取<sup>[20-25]</sup>。本研究生成了具有自定义灰度值的StuctImgs,考虑了外轮廓、OAR和靶区的整体信息以及射野内和射野外头脚方向的位置信息,这些信息与剂量分布有较明显的直接关系。基于深度学习的3D剂量预测模型,直接将StuctImgs用于模型训练,其中包含一系列卷积层和池化层,而不是提取复杂的特征。在模型训练效率和预测效率方面,IVGG16较DVGG16有较明显优势,这与网络解码器的结构相关。模型训练时间,IVGG16较DVGG16减少9.8 h,模型预测时间IVGG16较DVGG16每例病人平均减少(22.1±2.9)s。今后可通过进一步提高GPU性能,提高反卷积运算速度。随着深度学习的发展,笔者提出的放疗计划剂量预测 workflow 可以采用更加准确和高效的网络;该 workflow 亦可应用于其它部位放疗计划的3D剂量预测。

综上所述,采用插值和反卷积两种解码器预测得到的放疗计划3D剂量分布在整体上具有相当的效果,可应用于基于深度学习的放疗计划质量控制和自动计划设计。反卷积解码器在细节预测方面略优于插值解码器,但模型训练和预测的效率有待提高。

【参考文献】

[1] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521: 436-444.  
[2] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet

- classification with deep convolutional neural networks [C]. International Conference on Neural Information Processing Systems, 2012: 1097-1105.
- [3] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. Comput Sci, 2014. arXiv: 1409.1556v6.
- [4] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2015: 3431-3440.
- [5] ESTEVA A, KUPREL B, NOVOA R A, et al. Dermatologist-level classification of skin cancer with deep neural networks[J]. Nature, 2017, 542(7639): 115.
- [6] GULSHAN V, PENG L, CORAM M, et al. Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs [J]. JAMA, 2016, 316(22): 2402-2410.
- [7] PARK S, LEE S J, WEISS E, et al. Intra- and inter-fractional variation prediction of lung tumors using fuzzy deep learning[J]. IEEE J Transl Eng Health Med, 2016. DOI: 10.1109/JTEHM.2016.2516005.
- [8] MEN K, DAI J R, LI Y X. Automatic segmentation of the clinical target volume and organs at risk in the planning CT for rectal cancer using deep dilated convolutional neural networks[J]. Med Phys, 2017, 44(12): 6377-6389.
- [9] LIU Y, STOJADINOVIC S, HRYCUSHKO B, et al. A deep convolutional neural network-based automatic delineation strategy for multiple brain metastases stereotactic radiosurgery[J]. PLoS One, 12(10): e0185844.
- [10] MEN K, CHEN X Y, ZHANG Y, et al. Deep deconvolutional neural network for target segmentation of nasopharyngeal cancer in planning computed tomography images[J]. Front Oncol, 2017, 7: 315.
- [11] MEN K, ZHANG T, CHEN X Y, et al. Fully automatic and robust segmentation of the clinical target volume for radiotherapy of breast cancer using big data and deep learning[J]. Phys Med, 2018, 50: 13-19.
- [12] ZHEN X, CHEN J W, ZHONG Z C, et al. Deep convolutional neural network with transfer learning for rectum toxicity prediction in cervical cancer radiotherapy: a feasibility study[J]. Phys Med Biol, 2017, 62(21): 8246-8263.
- [13] CHEN X, MEN K, LI Y, et al. A feasibility study on an automated method to generate patient-specific dose distributions for radiotherapy using deep learning[J]. Med Phys, 2019, 46(1): 56-64.
- [14] KEARNEY V, CHAN J W, HAAF S, et al. DoseNet: a volumetric dose prediction algorithm using 3D fully-convolutional neural networks[J]. Phys Med Biol, 2018, 63(23): 235022.
- [15] FAN J, WANG J, CHEN Z, et al. Automatic treatment planning based on three-dimensional dose distribution predicted from deep learning technique[J]. Med Phys, 2019, 46(1): 370-381.
- [16] YI J, HUANG X, GAO L, et al. Intensity-modulated radiotherapy with simultaneous integrated boost for locoregionally advanced nasopharyngeal carcinoma[J]. Radiat Oncol, 2014, 9: 56.
- [17] JIA Y Q, SHELHAMER E, DONAHUE J, et al. Caffe: convolutional architecture for fast feature embedding [C]. Proceedings of the 22nd ACM International Conference on Multimedia, 2014: 675-678.
- [18] ZEILER M D, KRISHNAN D, TAYLOR G W, et al. Deconvolutional networks[J]. IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2010. DOI: 10.1109/CVPR.2010.5539957.
- [19] ZEILER M D, TAYLOR G W, FERGUS R. Adaptive deconvolutional networks for mid and high level feature learning [C]. 2011 IEEE International Conference on Computer Vision (ICCV), 2011: 2018-2025.
- [20] ZHU X, GE Y, LI T, et al. A planning quality evaluation tool for prostate adaptive IMRT based on machine learning[J]. Med Phys, 2011, 38(2): 719-726.
- [21] YUAN L, GE Y, LEE W R, et al. Quantitative analysis of the factors which affect the interpatient organ-at-risk dose sparing variation in IMRT plans[J]. Med Phys, 2012, 39(11): 6868-6878.
- [22] SHIRAIISHI S, MOORE K L. Knowledge-based prediction of three-dimensional dose distributions for external beam radiotherapy[J]. Med Phys, 2016, 43(1): 378.
- [23] CAMPBELL W G, MIFTEN M, OLSEN L, et al. Neural network dose models for knowledge-based planning in pancreatic SBRT[J]. Med Phys, 2017, 44(12): 6148-6158.
- [24] NWANKWO O, SIHONO D S, SCHNEIDER F, et al. A global quality assurance system for personalized radiation therapy treatment planning for the prostate (or other sites)[J]. Phys Med Biol, 2014, 59(18): 5575-5591.
- [25] NWANKWO O, MEKDASH H, SIHONO D S, et al. Knowledge-based radiation therapy (KBRT) treatment planning *versus* planning by experts: validation of a KBRT algorithm for prostate cancer treatment planning[J]. Radiat Oncol, 2015, 10(1): 111.

(编辑:谭斯允)