

DOI:10.3969/j.issn.1005-202X.2025.04.001

医学放射物理

基于卷积神经网络的宫颈癌调强放疗剂量预测方法

吴晓娟^{1,2}, 张艺宝³, 任鸿儒¹, 孟令军²

1. 广东工业大学自动化学院, 广东 广州 510000; 2. 山东大学齐鲁医院德州医院放射治疗科, 山东 德州 253000; 3. 北京大学肿瘤医院暨北京市肿瘤防治研究所放疗科/恶性肿瘤发病机制及转化研究教育部重点实验室, 北京 100142

【摘要】目的:建立一个卷积神经网络模型用于宫颈癌调强放疗的剂量分布,并评估它在实现自动计划方面的潜在应用。**方法:**采用100例女性盆腔调强放疗计划,80例为训练集,10例为验证集,10例为测试集,在三维深度残差网络模型基础上搭建剂量预测模型,预测三维剂量分布。通过CT影像以及RT Structure文件提取出危及器官以及计划靶体积的掩模。将不同结构按照密度赋值图进行密度赋值,赋值后的CT掩图作为训练模型的输入图像。利用获取的最优模型实现三维剂量预测分布,将预测结果与手工计划设计的剂量分布进行剂量学比较。**结果:**在10例测试集上的实验结果显示,临床剂量学参数差异较小,在临床可接受范围内。10例测试集病例平均绝对误差MAE为(0.58±0.16) Gy,平均DSC系数为0.90±0.03,HD₉₅为(10.61±7.17) mm。预测模型直肠的V₄₅和小肠的D_{2cc}与手动计划相比,略有降低,左右侧股骨头的V₂₀较手工计划有所降低;预测模型PTV的D₉₅与人工计划相比有所降低,PTV的D₉₀、HI和CI指数差异较小,两者的三维剂量分布差异较小,模型预测的剂量分布可满足临床要求。**结论:**基于卷积神经网络的剂量预测模型可以准确预测宫颈癌调强放疗的剂量分布,有望用于自动计划设计和质量评估等。

【关键词】宫颈癌;剂量预测;卷积神经网络;调强放疗

【中图分类号】R318;R815.2;TP391.4

【文献标志码】A

【文章编号】1005-202X(2025)04-0421-08

Convolutional neural network based dose prediction method for intensity-modulated radiotherapy of cervical cancer

WU Xiaojuan^{1,2}, ZHANG Yibao³, REN Hongru¹, MENG Lingjun²

1. School of Automation, Guangdong University of Technology, Guangzhou 510000, China; 2. Department of Radiation Oncology, Dezhou Hospital, Qilu Hospital of Shandong University, Dezhou 253000, China; 3. Department of Radiation Oncology, Peking University Cancer Hospital & Institute/Key Laboratory of Carcinogenesis and Translational Research (Ministry of Education), Beijing 100142, China

Abstract: Objective To develop a convolutional neural network based model for predicting the dose distribution of intensity-modulated radiotherapy (IMRT) in cervical cancer, and to evaluate its potential applications in automated treatment planning. **Methods** The pelvic IMRT plans for 100 female patients were collected, with 80 cases in the training set, 10 in the validation set, and 10 in the test set. A dose prediction model was built based on the three-dimensional (3D) residual network for forecasting 3D dose distribution. Masks for organs-at-risk and planning target areas were extracted from CT images and RT Structure files. Density values were assigned to different structures according to a density map, and the resulting CT maps were used as input images for model training. The optimal model was used to predict the 3D dose distribution, and the predicted results were compared with the dose distribution from manual treatment planning in terms of dosimetric parameters. **Results** The experimental results on the 10-case test set demonstrated that dosimetric parameter differences were insignificant and within clinically acceptable ranges. The mean absolute error, average Dice similarity coefficient, and 95% Hausdorff distance for 10 cases in test set were (0.58±0.16) Gy, 0.90±0.03, and (10.61±7.17) mm, respectively. Compared with manual planning, prediction model showed slightly decreased rectal V₄₅, small bowel D_{2cc}, and the V₂₀ of bilateral femoral heads was reduced. The predicted D₉₅ of planning target area was lower than manual planning, but the differences in D₉₀, homogeneity index, and conformity index were trivial. There were minor differences in 3D dose distributions between the two, and the dose distribution generated by prediction model met clinical requirements. **Conclusion** The convolutional

【收稿日期】2024-12-19

【基金项目】国家自然科学基金(U21A20522,12275012,12475309,12411530076);北京市自然科学基金(Z210008)

【作者简介】吴晓娟,硕士,研究方向:智能医学工程,E-mail: wjuan16@163.com

【通信作者】孟令军,副主任技师,研究方向:放射物理,E-mail: 13605349565@163.com

neural network based dose prediction model can accurately forecast the dose distribution for cervical cancer IMRT, exhibiting the potential to be used in automated treatment planning and quality evaluation.

Keywords: cervical cancer; dose prediction; convolutional neural network; intensity-modulated radiotherapy

前言

宫颈癌是女性常见的恶性肿瘤之一,特别是在发展中国家,发病率和死亡率较高。根据国际癌症研究机构(WHO)对GLOBOCAN 2020数据库的研究表明,全球宫颈癌病例的58%以上发生在亚洲,39%的病例发生在中国(18%)和印度(21%),宫颈癌死亡人数的40%发生在中国(17%)和印度(23%),中国的发病率明显高于WHO阈值^[1]。由于宫颈癌早期症状不明显,很多患者在确诊时已处于中晚期,治疗难度大幅增加。宫颈癌不仅对生殖健康造成严重影响,可能导致不孕或生殖器官损伤,还会因晚期病情导致高致死率,显著降低患者生活质量。放射治疗是宫颈癌治疗的重要手段,尤其对局部晚期患者效果显著。相较于手术,放疗的副作用相对较小,治疗过程更为安全,有助于减少对周围正常组织的损伤。随着放疗技术的发展,宫颈癌放射治疗已经从二维普通放疗发展到三维适形放疗技术和调强放疗技术(Intensity Modulated Radiation Therapy, IMRT)^[2]。在IMRT中,可以通过调节射野和剂量参数等以达到想要的剂量分布和减少正常组织受量的高质量计划。IMRT计划是通过逆向处理计划而创建的,在逆向计划中,物理师创建一个目标计划列表,用于构建目标函数,通过不断优化目标函数得到可以接受的计划。放射治疗计划的制定是一个复杂而耗时的过程,它包括无数次的优化迭代,需要数小时甚至数天^[3]。IMRT计划的质量很大程度上依赖于设计者的技能水平^[4]和放射肿瘤学专家给定的治疗目标。因此,导致在临床中交付的治疗计划质量不同,可能会导致不同的临床治疗效果^[5]。

随着人工智能在放疗领域的应用,剂量预测已被深入研究,提高IMRT计划的设计效率和质量^[6]。基于知识的计划(Knowledge Based Planning, KBP)模型,使用从已治疗患者的感兴趣区域(Region of Interest, ROI)中提取的解剖结构特征来自动预测新患者的剂量-体积目标(Dose and Volume Histogram, DVH),该方法在头颈癌和直肠癌方面的应用已取得积极的临床效果^[7]。然而,现有的KBP模型有一个关键限制是预测的DVH缺乏空间信息,这可能需要额外的工作来处理不常见几何形状的情况^[8]。另一方面,影响ROI剂量分布的解剖特征的数量非常大。由于关键信息在KBP中的覆盖不足,可能无法支撑可靠模型的构建^[9]。近年来,研究者提出基于体素的预

测,以保留预测个体体素剂量值的空间信息^[10]。随着人工智能技术的发展,使用深度学习的剂量分布预测模型被进一步研究,以提高自动计划的效率和准确性^[11]。已证实使用深度学习模型可以准确预测鼻咽癌、前列腺癌、肺癌和食管癌IMRT的剂量分布^[12]。然而,由于深度学习训练网络的复杂性,预测的剂量分布很难重现,也很难在临床上应用,这导致很少有研究将预测结果直接转化为临床可交付的计划,也很少有研究预测宫颈癌基于体素的IMRT剂量分布。

本研究在残差网络的基础上引入注意力机制,搭建剂量预测模型,通过构建患者ROI分布特征与三维剂量分布之间的关系,实现预测整个照射范围内的剂量分布。本研究的目的是基于卷积神经网络(Convolutional Neural Networks, CNN)建立宫颈癌IMRT剂量分布预测模型,并评估模型在提高临床计划质量方面的可行性。

1 资料与方法

1.1 数据准备

获取2021年1月至2023年9月期间在山东大学齐鲁医院德州医院放射治疗科进行IMRT放疗的宫颈癌患者的定位CT影像数据、靶区和危及器官(Organs-at-Risk, OAR)轮廓:皮肤、膀胱、直肠、小肠、乙状结肠、脊髓、左股骨头、右股骨头与计划靶区(Planning Target Volume, PTV)的剂量分布,见图1。

选取的宫颈癌放疗病例,均由临床医生参照国际辐射单位与测量委员会(ICRU)83号报告^[13],依据CT定位影像勾画临床靶区(Clinical Target Volume, CTV)和OAR。考虑到患者摆位时的不确定性和器官运动影响,在CTV基础上均匀外扩5 mm形成PTV。病例的处方剂量均为50 Gy/25次,根据放射肿瘤治疗协作组(RTOG)的临床规范,制定针对PTV和OAR的剂量限制标准。限制条件如下:靶区体积的95%需要覆盖100%的处方剂量,而靶区内剂量超过处方剂量110%的体积不应超过1%。OAR剂量限制标准^[14]如表1所示。

患者CT扫描条件相同,在约定扫描前1 h患者膀胱排空,饮水500 mL,CT模拟机使用GE大孔径CT,扫描层厚为3 mm。患者体位:仰卧位,双手抱头,使用真空垫固定。治疗计划采用IMRT,布野方式为7野均分,起始角度0°,见图2。剂量计算均采用Pinnacle 9.10版本直接子野优化算法。靶区均不包

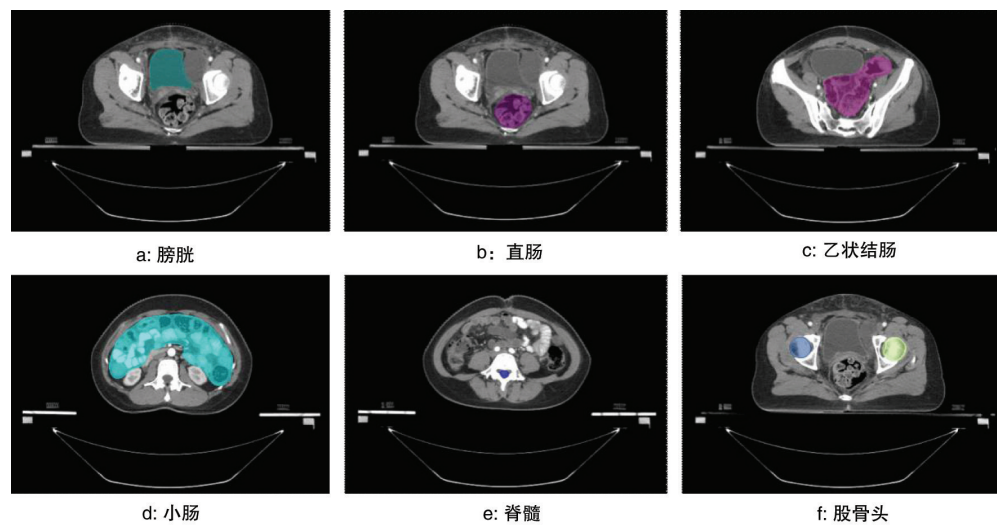


图1 OAR轮廓图
Figure 1 Organs-at-risk contours

含腹主动脉和腹股沟淋巴引流区,卵巢均不做限量要求。将数据分为训练集(80 例)、验证集(10 例)和测试集(10 例)。

表1 OAR 剂量限制标准	
Table 1 Dose limit standards for organs-at-risk	
OAR	剂量限值
膀胱	$V_{45}<50\%$; $D_{2cc}<52\text{ Gy}$
左股骨头	$V_{50}<5\%$; $V_{20}<50\%$
右股骨头	$V_{50}<5\%$; $V_{20}<50\%$
直肠	$V_{45}<50\%$; $D_{2cc}<52\text{ Gy}$
小肠	$V_{45}<50\%$; $D_{2cc}<52\text{ Gy}$
脊髓	$D_{max}<45\text{ Gy}$

1.2 方法

三维深度残差注意力网络(图3和图4)通过构建患者ROI分布特征与三维剂量分布之间的关系,在残差网络的基础上增加注意力机制模块,在处理患者ROI分布特征信息的开始阶段会集中专注于重点区域PTV。每个注意力模块有主干支路和门控支路两个支路。注意力机制模块可以更好地学习残差结构提取的特征,并强化局部有效的特征,提高网络对目标区域的定位分割能力,同时也提高模型对图像的特征提取能力。




图2 IMRT 7野均分剂量分布
Figure 2 Dose distribution of 7-field IMRT

1.2.1 数据预处理 为了确保导入数据中的OAR、PTV、Dose剂量分布和CT的体素是一致的,于是进行重采样操作。首先读取数据图像的大小、体素数据、患者CT定位原点 and 方向信息。接着将原数据图像进行体素间隔为[4, 4, 4]和图像大小为[128, 128, 128]的重采样操作,最终生成大小为[128, 128, 128]和体素间距为[4, 4, 4]的图像。为了减少图像噪声对模型的影响,对ROI进行赋值密度填充,按照实际人体不同结构类型密度的不同,自定义

密度赋值图,具体ROI密度见图5。将不同结构器官按照密度赋值图进行密度赋值,赋值后的靶区和结构图像即为CT掩图,与剂量分布图像一起构成深度学习的输入训练数据集,见图6。
1.2.2 模型训练 本文的所有网络均使用Python 3.9编程语言,深度学习框架选用Tensorflow2.10,优化器使用Adam,损失函数使用交叉熵损失函数,迭代次数为300,学习率预设值均为0.001,若20次迭代Loss不更新,则将学习率修正为原来的0.1倍,超过30次

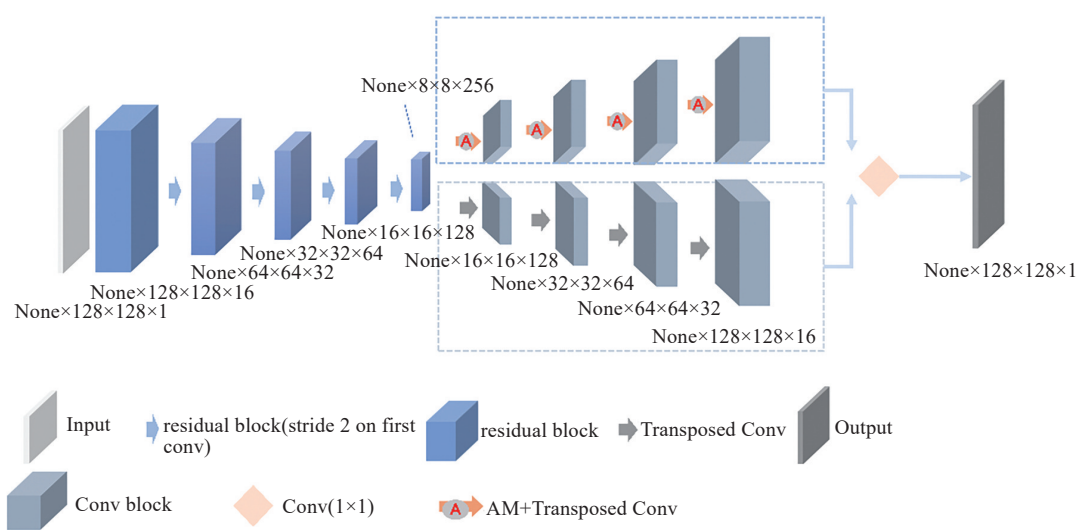


图 3 模型框架
Figure 3 Model framework

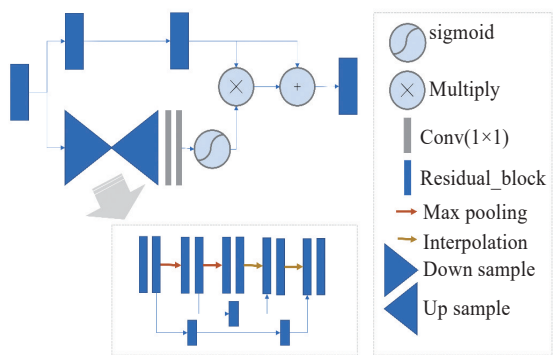


图 4 注意力残差模块
Figure 4 Attention residual module




图 5 ROI 密度赋值
Figure 5 Density values assigned to regions of interest




图 6 CT 掩图
Figure 6 CT masks

不更新自动终止训练,在 NVIDIA RTX A6000(48 GB) GPU 计算机服务器上训练并完成测试。

1.3 计划评估

1.3.1 模型精度评估 本研究采用 Dice 相似系数 (Dice Similarity Coefficient, DSC) 和 95% 豪斯多夫距离 (95% Hausdorff Distance, HD₉₅) 来评估模型对测试集的精准度^[15]。DSC 表示两个结构之间的空间重叠程度,公式如下:

$$DSC = \frac{2|Pr \cap GT|}{|Pr| + |GT|}$$

(1)

其中,Pr 为预测结果,GT 为真实标签。DSC 值为 0~1, 值越接近 1,表示两个集合相似性越高;值越接近 0,表示两个集合相似性较低,共同元素较少。

HD 表示两边界之间的距离,HD 值越小,表示预测结果与真实结果的重合度越高,三维等剂量面的符合度越好。HD₉₅ 是一种稳健的指标,取边界距离从小到大排序的前 95% 值,以排除离群点的影响,从而得到更稳定的豪斯多夫距离,称为 95% 豪斯多夫距离,公式如下:

$$h(\text{Pr}, \text{GT}) = \max(\min(\|c - g\|), h(\text{GT}, \text{Pr}))$$
$$\max(\min(\|g - c\|), c \in \text{Pr}, g \in \text{GT}) \quad (2)$$

$$\text{HD}_{95}(\text{Pr}, \text{GT}) = 95\% \max(h(\text{Pr}, \text{GT}), h(\text{GT}, \text{Pr})) \quad (3)$$

1.3.2 模型效果评估 使用平均平方误差 (Mean Squared Error, MSE)、平均绝对误差 (Mean absolute Error, MAE)、平均平方根误差 (Root Mean Squared Error, RMSE) 指标来评估模型效果。MAE 表示数据集中实际值与预测值之间绝对差的平均值, 反映残差的平均水平, 计算公式如下:

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (4)$$

其中, N 是样本数量, y 是真实值, \hat{y} 是 y 的预测值。MAE 能准确反映预测误差的大小, 用于评价真实值与拟合值的偏离程度。MAE 越接近 0, 说明模型拟合效果越好, 预测准确率越高。MSE 表示数据集中原始值和预测值之间差值平方的平均值, 它衡量的是残差的方差, 计算公式如下:

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (5)$$

其中, N 是样本数量, y 是真实值, \hat{y} 是 y 的预测值。MSE 是衡量模型预测误差的常用指标, 值越接近 0, 表明模型拟合越好。RMSE 是 MSE 的平方根, 常用于回归模型评估, RMSE 值越接近 0, 说明模型拟合越好, 比 MSE 更常用, RMSE 值计算公式如下:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (6)$$

1.3.3 剂量学参数评估 PTV 剂量学参数: D_{90} 、 D_{95} (D_i 表示 $i\%$ 体积的 PTV 受照剂量) 以及靶区的均匀性指数 (Homogeneity Index, HI) 和 适形度指数 (Conformity Index, CI) 进行比较^[16]。OAR 剂量学参数: 膀胱、直肠、小肠的 V_{45} (V_i 表示接受 i Gy 剂量的器官体积百分比) 和 D_{2cc} ; 脊髓最大剂量 D_{\max} ; 左右侧股骨头的 V_{50} 和 V_{20} 。

HI 用于反映剂量分布的均匀性, 理想情况下, 靶区每个位置的剂量相等。HI 的计算公式比较多, RTOG 推荐的一种计算方法为:

$$\text{HI} = D_5/D_{95} \quad (7)$$

其中, D_5 和 D_{95} 分别表示 5% 和 95% PTV 体积所接受的最小剂量。若靶区剂量均匀, D_5 与 D_{95} 相等, HI 值为 1。HI 值越接近 1, 表示剂量分布越均匀, 越大则表示分布越不均匀。CI 的计算公式为:

$$\text{CI} = \left(V_{t, \text{ref}}/V_t \right) \times \left(V_{t, \text{ref}}/V_{\text{ref}} \right) \quad (8)$$

其中, V_t 为靶区体积, $V_{t, \text{ref}}$ 为处方剂量线面包绕的靶区体积, V_{ref} 为处方剂量线面所包绕的所有区域的体积。CI 值为 0~1, 取值越大, 适形度越好。

2 结果

2.1 预测模型精确度评估

由表 2 和图 7 可知, 测试集 10 例病例中的 HD_{95} 值为 8.08~13.07 mm, 平均值为 10.61 mm。由表 3 和图 8 可知, 数据显示大多数样本的 DSC 值接近 0.90, 且波动范围相对较小, DSC 的平均值为 0.90, 表明模型在整体上具有良好的预测性能。由表 4 可知, 模型在不同病例中的预测误差相对一致, 在整体上具有良好的预测性能。

表 2 模型预测值和真实值 HD_{95} ($\bar{x} \pm s$, mm)

Table 2 HD_{95} between predicted and actual values

(Mean \pm SD, mm)

病例	HD_{95}
病例 1	8.84 \pm 5.10
病例 2	9.35 \pm 7.48
病例 3	11.49 \pm 9.32
病例 4	13.07 \pm 7.25
病例 5	11.12 \pm 8.48
病例 6	12.93 \pm 8.62
病例 7	8.08 \pm 8.21
病例 8	10.53 \pm 7.65
病例 9	9.65 \pm 7.57
病例 10	10.01 \pm 5.95
10 例平均值	10.61 \pm 7.17




图 7 模型预测值和真实值等剂量面 HD_{95}

Figure 7 Model predicted values and actual values of isodose surface HD_{95}

2.2 剂量学参数比较

表 5 显示了剂量学参数对比结果, PTV 与各 OAR 的人工计划与模型预测结果呈现差异化特征。具体而言, PTV 的 D_{90} 指标预测误差较小, 表现可靠。PTV 的 D_{95} 参数在人工计划中为 (50.25 \pm 0.20) Gy, 模型预测值为 (48.90 \pm 1.04) Gy, 比较差异有统计学意义 ($P < 0.05$), 提示模型预测的靶区剂量覆盖水平较人

表 3 模型真实值与预测值的 DSC 值($\bar{x}\pm s$)

Table 3 Dice similarity coefficient between actual and predicted values (*Mean* \pm *SD*)

病例	DSC 值
病例 1	0.90 \pm 0.03
病例 2	0.91 \pm 0.03
病例 3	0.90 \pm 0.03
病例 4	0.90 \pm 0.03
病例 5	0.91 \pm 0.00
病例 6	0.87 \pm 0.04
病例 7	0.92 \pm 0.03
病例 8	0.91 \pm 0.03
病例 9	0.92 \pm 0.03
病例 10	0.91 \pm 0.02
10 例平均值	0.90 \pm 0.03




图 8 模型真实值与预测值等剂量面的 DSC

Figure 8 Dice similarity coefficient of the isodose surface between actual and predicted values

表 4 模型评估指标

Table 4 Model evaluation indicators

病例	MAE/Gy	MSE/Gy ²	RMSE/Gy
病例 1	0.45	2.10	1.45
病例 2	0.37	2.17	1.47
病例 3	0.49	2.93	1.71
病例 4	0.64	3.70	1.92
病例 5	0.82	4.84	2.20
病例 6	0.78	6.23	2.50
病例 7	0.34	1.83	1.35
病例 8	0.55	2.81	1.68
病例 9	0.76	3.69	1.92
病例 10	0.60	2.95	1.72
10 例平均值	0.58 \pm 0.16	3.32 \pm 1.29	1.79 \pm 0.34

工计划有所降低。HI 和 CI 的比较差异有统计学意义 ($P<0.05$)。其中 CI 的模型预测值(0.93 ± 0.03)低于人工计划值(0.97 ± 0.01),提示模型在适形性上略差。HI 的模型预测值(0.07 ± 0.03)与人工计划(0.07 ± 0.01)差异较小,表明模型在稳定性上较差,波动性较大。

在 OAR 保护方面,模型预测呈现出差异化表现:膀胱参数中, V_{45} 预测值(35.62 ± 10.99)%与人工计划(35.08 ± 9.18)%差异没有统计学意义 ($P>0.05$),而 D_{2cc} 参数则显示模型预测值(51.00 ± 0.00) Gy 显著低于人工计划(51.46 ± 0.27) Gy ($P<0.001$),提示模型在控制膀胱热点剂量方面具有优势。在大部分 OAR (如直肠、小肠、脊髓、股骨头)的剂量预测中,模型与人工计划无显著差异,符合临床要求。

表 5 剂量学参数人工计划和深度学习模型预测值比较结果($\bar{x}\pm s$)

Table 5 Comparisons of dosimetric parameters between manual planning and prediction model (*Mean* \pm *SD*)

结构组	参数	人工计划	深度学习模型	P 值
PTV	D_{95}/Gy	50.25 \pm 0.20	48.90 \pm 1.04	0.024
	D_{90}/Gy	50.65 \pm 0.16	49.90 \pm 0.57	0.112
	HI	0.07 \pm 0.01	0.07 \pm 0.03	0.004
	CI	0.97 \pm 0.01	0.93 \pm 0.03	0.020
膀胱	$V_{45}/\%$	35.08 \pm 9.18	35.62 \pm 10.99	0.261
	D_{2cc}/Gy	51.46 \pm 0.27	51.00 \pm 0.00	<0.001
直肠	$V_{45}/\%$	35.93 \pm 8.05	32.86 \pm 13.03	0.452
	D_{2cc}/Gy	50.29 \pm 0.81	49.10 \pm 1.04	0.310
小肠	$V_{45}/\%$	6.43 \pm 1.95	9.35 \pm 3.35	0.220
	D_{2cc}/Gy	51.51 \pm 0.28	50.80 \pm 0.40	0.469
	D_{200cc}/Gy	20.28 \pm 6.54	18.20 \pm 8.08	0.583
脊髓	D_{max}/Gy	37.78 \pm 21.12	38.40 \pm 19.94	0.906
左侧股骨头	$V_{50}/\%$	15.40 \pm 22.43	17.27 \pm 27.03	0.613
	$V_{20}/\%$	58.99 \pm 27.73	53.47 \pm 28.35	0.993
右侧股骨头	$V_{50}/\%$	6.44 \pm 18.43	7.02 \pm 21.02	0.895
	$V_{20}/\%$	78.53 \pm 14.21	73.71 \pm 17.01	0.368

2.3 三维剂量分布及 DVH 曲线比较

为验证模型预测效果,本研究从测试集中随机

选取 1 例病例进行三维剂量分布及剂量体积直方图 (Dose Volume Histogram, DVH) 的对比分析。如图 9

所示,模型预测的剂量分布在PTV内呈现出良好的适形性和均匀性,且剂量梯度在PTV边缘区域呈现与临床计划相似的陡峭下降特征。临床真实值与模型预测值误差接近于0,说明模型预测的三维剂量分布与临床剂量差异较小。

图10的DVH对比显示,模型预测的PTV剂量覆盖曲线与临床计划在D₄₅-D₅₀区间(45~50 Gy)吻合良好(曲线重叠度>90%),但在高剂量区出现显著偏差。对于OAR如直肠、小肠的DVH曲线与临床计划在整体趋势上保持高度一致。

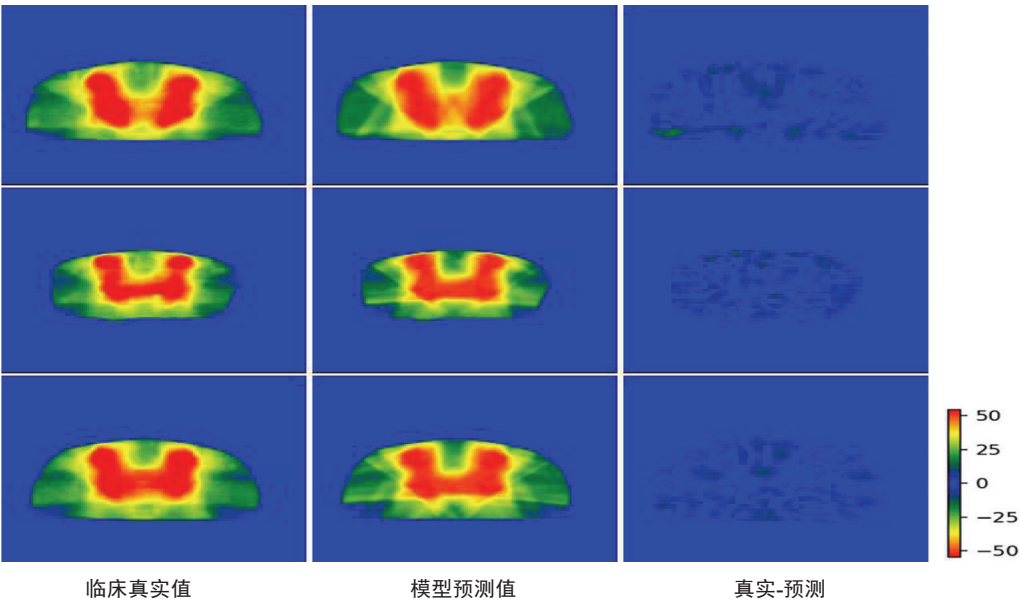


图9 临床真实值与模型预测剂量分布图比较
Figure 9 Comparison of actual and predicted dose distribution maps




图10 测试集预测剂量与临床剂量的PTV及OAR的DVH曲线图(预测剂量为虚线,临床剂量为实线)
Figure 10 Dose-volume histogram of planning target area and organ-at-risk for comparing predicted doses on the test set with clinical doses

3 讨论

本研究利用深度学习中的CNN搭建剂量预测模型,将宫颈癌CT影像以及标注的靶区和OAR的掩模输入模型,将放疗剂量作为输出,最终通过测试集测试模型的准确性。实验结果表明该模型能够较准确地实现宫颈癌的三维剂量预测,预测模型用于宫颈癌调强放疗剂量预测时,可明显缩短设计时间,并大大减少人为干扰因素,排除因计划设计经验导致的

靶区欠量及OAR不合理的照射因素,有助于减少肿瘤的复发风险及正常组织的放疗不良反应发生概率。目前,有研究者提出基于规则或知识库的剂量预测方法,KBP利用已有放疗方案的剂量分布数据,通过相似度匹配或基于规则的插值来预测新的剂量分布^[17]。本研究提出的CNN模型能够直接从大量患者数据中学习剂量分布模式,具备更强的灵活性,适用于不同患者的个体化剂量需求^[18]。相比之下,基于规则的知识库方法往往依赖于预设的规则或基于历史病例的相似度,难以适应特殊情况。CNN的训练过程不需要手动设定规则或调整参数,而是通过数据驱动自动学习分布特征,减少人工干预和偏差的可能性。相比于全卷积神经网络方法,CNN在高剂量区域的预测效果更为稳定,CNN能够较为准确地捕捉靶区内的高剂量分布,这使得其在靶区剂量预测的性能上优于一些基于全卷积神经网络模型。与生成对抗网络(GAN)相比,CNN的结构较为简单,训练过程相对稳定,而GAN则由于生成器和判别器的对抗过程,训练过程容易不稳定。

本研究提出的剂量预测模型在靶区剂量学参数与OAR保护方面呈现出差异化表现,模型预测PTV的D₉₀指标预测误差较小,表明模型对靶区基础剂量分布的预测具有较高可靠性,能够满足临床对核

心剂量覆盖的需求。在膀胱保护方面,模型预测的 D_{2cc} 参数显著优于人工计划($P<0.001$),说明模型在控制高危热点剂量方面具有独特优势,说明算法对剂量梯度优化的特殊处理能力较好。直肠、小肠、脊髓及股骨头等关键OAR的剂量参数与人工计划无统计学意义($P>0.05$),表明模型在大多数OAR保护方面已达到临床可接受标准。然而,模型在靶区高剂量方面覆盖不足:PTV的 D_{95} 预测值较人工计划显著降低,提示模型在确保靶区高剂量覆盖方面存在缺陷,这与物理师在计划设计时为了优先保护OAR,对OAR指标给予高权重导致靶区与OAR交界处出现欠量。适形性指标待优化:CI值模型预测结果(0.93 ± 0.03)显著低于人工计划(0.97 ± 0.01),差异有统计学意义($P=0.02$),反映模型在空间剂量分布的适形性控制上仍存在改进空间,特别是靶区边缘剂量跌落梯度的优化需要加强。虽然HI均值与人工计划相近(0.07 ± 0.03 vs 0.07 ± 0.01),但差异有统计学意义($P<0.05$),说明模型预测结果的剂量均匀性存在个体化波动,可能与训练样本的异质性或模型泛化能力不足有关。

模型在保持剂量覆盖的同时,将重点改进以下方面:通过引入自适应权重调整机制,优化 D_{95} 参数;扩大训练数据集的临床多样性以提高模型稳定性。值得注意的是,模型在特定参数(如膀胱 D_{2cc})上展现的优化能力提示可作为人工计划的有效补充工具,可以将模型预测结果作为计划优化的初始解,结合物理师经验提前预判计划质量,有望在保证计划质量的同时提升工作效率。本研究结果表明,当前模型已具备基础临床应用潜力,但在高剂量覆盖精度和稳定性方面仍需进一步优化。后续研究将增加数据集,并探索将剂量预测模型用于自动计划。

4 结论

本研究提出一种基于CNN的模型,用于宫颈癌IMRI剂量分布的预测。实验结果表明,该模型能够在高剂量区域实现较高的预测精度,并在靶区剂量覆盖和部分风险器官的剂量控制方面表现出良好的效果,验证了CNN在宫颈癌IMRT剂量预测中的有效性和可行性,为剂量分布预测提供一种高效的数据驱动方法。然而,考虑到模型在低剂量区域的预测偏差和对复杂解剖结构的适应性问题,未来可以通过引入多尺度特征提取、结合GAN等方法,进一步提升模型的预测精度和鲁棒性。

综上所述,本研究为基于深度学习的放疗剂量预测提供新的思路,有望为实现精准、个性化的放疗计划提供有力支持。

【参考文献】

- [1] Singh D, Vignat J, Lorenzoni V, et al. Global estimates of incidence and mortality of cervical cancer in 2020: a baseline analysis of the WHO global cervical cancer elimination initiative[J]. *Lancet Glob Health*, 2023, 11(2): e197-e206.
- [2] Vordermark D. Radiotherapy of cervical cancer[J]. *Oncol Res Treat*, 2016, 39(9): 516-520.
- [3] 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.
- [4] Nelms BE, Robinson G, Markham J, et al. Variation in external beam treatment plan quality: an inter-institutional study of planners and planning systems[J]. *Pract Radiat Oncol*, 2012, 2(4): 296-305.
- [5] Zhong HY, Men K, Wang JZ, et al. The impact of clinical trial quality assurance on outcome in head and neck radiotherapy treatment[J]. *Front Oncol*, 2019, 9: 792.
- [6] Wang CH, Zhu XF, Hong JC, et al. Artificial intelligence in radiotherapy treatment planning: present and future[J]. *Technol Cancer Res Treat*, 2019, 18: 1533033819873922.
- [7] Appenzoller LM, Michalski JM, Thorstad WL, et al. Predicting dose-volume histograms for organs-at-risk in IMRT planning[J]. *Med Phys*, 2012, 39(12): 7446-7461.
- [8] Shiraishi S, Moore KL. Knowledge-based prediction of three-dimensional dose distributions for external beam radiotherapy[J]. *Med Phys*, 2016, 43(1): 378.
- [9] Wang YB, Heijmen BJ, Petit SF. Prospective clinical validation of independent DVH prediction for plan QA in automatic treatment planning for prostate cancer patients[J]. *Radiother Oncol*, 2017, 125(3): 500-506.
- [10] McIntosh C, Welch M, McNiven A, et al. Fully automated treatment planning for head and neck radiotherapy using a voxel-based dose prediction and dose mimicking method[J]. *Phys Med Biol*, 2017, 62(15): 5926-5944.
- [11] Nguyen D, Jia X, Sher D, et al. 3D radiotherapy dose prediction on head and neck cancer patients with a hierarchically densely connected U-net deep learning architecture[J]. *Phys Med Biol*, 2019, 64(6): 065020.
- [12] Barragán-Montero AM, Thomas M, Defraene G, et al. Deep learning dose prediction for IMRT of esophageal cancer: the effect of data quality and quantity on model performance[J]. *Phys Med*, 2021, 83: 52-63.
- [13] Das IJ, Andersen A, Chen ZJ, et al. State of dose prescription and compliance to international standard (ICRU-83) in intensity modulated radiation therapy among academic institutions[J]. *Pract Radiat Oncol*, 2017, 7(2): e145-e155.
- [14] 庞皓文, 孙小杨, 杨波, 等. IMRT中OAR和靶区相交体积与其吸收剂量间关系研究[J]. *中华放射肿瘤学杂志*, 2017, 26(2): 187-191.
- [15] Pang HW, Sun XY, Yang B, et al. Relationship between the overlap volume of organ at risk and target and the dose to organ at risk in intensity-modulated radiotherapy[J]. *Chinese Journal of Radiation Oncology*, 2017, 26(2): 187-191.
- [16] Zhou JP, Peng Z, Song YC, et al. A method of using deep learning to predict three-dimensional dose distributions for intensity-modulated radiotherapy of rectal cancer[J]. *J Appl Clin Phys*, 2020, 21(5): 26-37.
- [17] 程志杰, 李定杰, 吴慧, 等. MdaccAutoPlan软件在鼻咽癌调强放疗计划设计的应用分析[J]. *中华放射医学与防护杂志*, 2018, 38(4): 285-290.
- [18] Cheng ZY, Li DJ, Wu H, et al. Clinical application of MdaccAutoPlan in the planning of nasopharyngeal carcinoma with intensity modulated radiotherapy[J]. *Chinese Journal of Radiological Medicine and Protection*, 2018, 38(4): 285-290.
- [19] Shiraishi S, Tan J, Olsen LA, et al. Knowledge-based prediction of plan quality metrics in intracranial stereotactic radiosurgery[J]. *Med Phys*, 2015, 42(2): 908.
- [20] Shan WY, Li XY, Yao HQ, et al. Convolutional neural network-based virtual screening[J]. *Curr Med Chem*, 2021, 28(10): 2033-2047.

(编辑:陈丽霞)