

网络出版时间: 2023-01-20 16:06:30 网络出版地址: <https://kns.cnki.net/kcms/detail/34.1065.R.20230119.1742.019.html>

◇ 临床医学研究 ◇

食管癌术后调强放疗剂量预测及自动计划研究

王文成¹, 周解平², 张朋², 吴爱林², 吴爱东^{1,2}

摘要 目的 探讨食管癌术后调强放疗自动计划的临床剂量学优势及所构建的 3D U-Res-Net 深度学习模型的剂量预测精度。方法 选取 110 例中上段食管癌术后调强放疗计划病例, 其中 90 例采用九折交叉验证方式进行深度学习预测模型训练, 利用获取的最优模型和自动计划的 Auto-Plan 引擎分别对余下 20 例进行三维剂量分布预测和自动计划设计, 所得结果与手动调强放疗计划进行剂量学比较。结果 3D U-Res-Net 预测模型等剂量面平均 dice 系数大于 0.92, 平均霍夫距离 (HD_{95}) 为 0.58 ~ 0.62 cm; 预测模型的双肺 V_{20} 、 V_{30} 、 D_{mean} 比手动计划结果略有降低 ($P < 0.05$); Auto-Plan 的计划靶区 D_2 、 D_{50} 、 D_{mean} 、HI 指数及双肺 V_{30} 都明显优于人工计划 ($P < 0.05$); 三者的三维剂量分布差异性较小, 靶区及危及器官 DVH 曲线吻合度较好。结论 Auto-Plan 和 3D U-Res-Net 模型能分别较好地完成食管癌术后 IMRT 计划的自动设计以及三维剂量分布的精准预测。

关键词 食管癌; 自动计划; 深度学习; 剂量学; 调强适形放射治疗

中图分类号 R 735.1; R 811.1

文献标志码 A 文章编号 1000-1492(2023)02-0280-06

doi: 10.19405/j.cnki.issn1000-1492.2023.02.019

食管癌具有预后性较差、高发病率、高死亡率等特点, 严重威胁我国居民健康和生命安全^[1], 而调强适形放射治疗 (intensity modulate radiotherapy, IMRT) 在提高靶区适形度和剂量均匀性的同时, 更能有效降低靶区周边正常组织的照射剂量, 目前已成为食管癌治疗的主要技术手段之一。但在调强放疗计划设计过程中, 放疗物理师需凭借个人经验反复调整目标函数并不断优化以期获得最优计划, 其设计过程费时、费力, 且人为主观不确定性较大, 极

大地降低了计划设计效率和放疗效果^[2-3]。近年来有学者基于深度学习方法对前列腺癌、乳腺癌和直肠癌等肿瘤调强放疗计划的自动设计方法开展研究并取得一定成果^[4-6], 而该研究正是利用构建的 3D U-Res-Net^[5] 深度学习预测模型和飞利浦 pinnacle³ 16.2 计划系统中的 Auto-Plan 自动计划模块^[7] 对食管癌术后病例分别进行三维剂量分布预测及调强自动计划设计, 并分别与人工计划结果进行剂量学比较, 以探讨 Auto-Plan 自动计划对食管癌术后 IMRT 临床剂量学优势及 3D U-Res-Net 模型的预测精度。

1 材料与方法

1.1 食管癌患者 IMRT 计划选取 取中上段食管癌术后 IMRT 计划共 110 例, 患者年龄 42 ~ 82 岁, 中位年龄 65.5 岁, 胸部 CT 增强等影像资料提示均无阳性淋巴结。患者采用仰卧位和体部热塑面膜固定, 放疗大孔径 CT (GE Discovery RT 590) 扫描获取患者 CT 影像数据, 扫描层厚为 2.5 mm。IMRT 计划靶区处方剂量为 95% 计划靶区体积 (planning target volume, PTV) 50 Gy/25 次; 危及器官 (organs at risks, OARs) 剂量限量为: 心脏 $V_{30} < 40\%$, $V_{40} < 30\%$, $D_{mean} < 26$ Gy; 双肺 $V_{30} < 20\%$, $V_{20} < 20\%$, $V_5 < 55\%$, $D_{mean} < 13$ Gy; 脊髓 $D_{max} < 45$ Gy。IMRT 计划均使用飞利浦计划系统 (pinnacle³ 16.2) 进行 6 MV X 线五野共面设计, 所有计划剂量参数均满足上述要求, 并都经过主任物理师审核确认。

1.2 深度学习模型数据训练与处理 从 110 例 IMRT 计划中随机选取 20 例为测试集, 同时也作为深度学习预测模型、Auto-Plan 计划与人工计划剂量学横向对比试验对象, 剩余 90 例计划数据按照 8 : 1 比例分为训练集和验证集输入构建的 3D U-Res-Net 深度学习模型中, 采用九折交叉验证方式进行训练, 最终获得 9 个预测模型, 选取最优模型对测试集行三维剂量分布预测。模型训练的 IMRT 计划数据处理如下: 采用自编 Python 程序提取计划的 CT 影像、OARs 结构、三维剂量分布和适形射束等信息, 并将这些数据信息都裁剪为大小 $128 \times 128 \times$

2022-12-19 接收

基金项目: 国家自然科学基金 (编号: 11805198); 安徽省学术和技术带头人及后备人选科研活动经费资助项目 (编号: 2020H230)

作者单位: ¹ 安徽医科大学生物医学工程学院, 合肥 230032

² 中国科学技术大学附属第一医院放疗科, 合肥 230001

作者简介: 王文成, 男, 硕士研究生;

吴爱东, 男, 教授, 硕士生导师, 责任作者, E-mail: flkaidongwu@163.com

128、分辨率为 2.5 mm × 2.5 mm × 2.5 mm 的三维矩阵; 最终上述 7 类信息的三维矩阵以 128 × 128 × 128 × 7 的形式作为输入, IMRT 剂量的三维矩阵以 128 × 128 × 128 × 1 的形式输出。

1.3 IMRT 计划设计

1.3.1 人工计划设计 测试集的人工 IMRT 计划采用五野共面照射, 直接子野优化 (direct machine parameter optimization, DMPO) [7] 设计, 物理师根据目标计划的靶区形状和位置信息凭个人经验确定射野方向和优化目标函数, 该计划设计过程不限制设计时间, 但为模拟日常放疗物理师繁杂的工作状态, 该物理师须凭个人经验确定当前计划设计是否已满足临床剂量限值和治疗需求后, 不再进行多余优化操作并经主任物理师审核确认。

1.3.2 自动计划设计 物理师基于自动计划引擎 (auto-planning engine, APE) [8] 的优化方法运行 Auto-Plan 自动 IMRT 计划模块。为避免其他不确定因素的影响, 自动计划的等中心点、靶区处方剂量、机器优化参数、射野射束信息和 OARs 限量均与人工计划相同, 且该模块会根据靶区与 OARs 的重叠程度自主设定 OARs 优先级及优化目标函数, 在满足 PTV 剂量的同时尽可能的降低 OARs 的受射剂量, 最后根据计算结果中剂量冷、热点区域, 将其添加为新的目标函数, 反复优化和调整, 直至得到满足处方要求的调强计划。

1.4 计划评估

1.4.1 深度学习预测模型精度评估 采用戴斯相似系数 (dice similarity coefficient, DSC) 和豪斯多夫距离 (Hausdorff distance, HD₉₅) [5, 9] 评估预测值与测试集之间的三维等剂量面相似性程度, 以评估深度学习预测模型的精准度, 具体公式如下:

$$DSC = \frac{2 \times (Sp \cap Sc)}{(Sp \cup Sc)} \quad (1)$$

$$H(A, B) = \max\{h(A, B), h(B, A)\} \quad (2)$$

$$h(A, B) = \max_{a \in A} \left(\min_{b \in B} \|a - b\| \right)$$

$$h(B, A) = \max_{b \in B} \left(\min_{a \in A} \|b - a\| \right)$$

其中, Sp 和 Sc 分别表示预测和测试集计划三维等剂量面, $Sp \cap Sc$ 表示两种计划等剂量面重叠部分的体素个数, $Sp \cup Sc$ 表示总体素个数, DSC 值介于 0 ~ 1, 本研究计算剂量范围为 1 ~ 50 Gy, 间隔为 1 Gy, 且 DSC 值越大, 表明两个样本的重合度越高。HD(A, B) 是单向距离 $h(A, B)$ 和 $h(B, A)$ 中较大的

一个, 它表示两个点集之间的最大失配距离, $h(A, B)$ 表示 A 集合的任一点到 B 集合任意点最小距离集中的最大值, HD 越小, 表示样本 A 与样本 B 重合度越高, 即三维等剂量面符合度越好。本研究取 HD 最大值的第 95 百分位数, 即 HD₉₅, 剂量计算范围为 20 ~ 50 Gy, 每隔 5 Gy 取一等剂量面计算相应的 HD₉₅。

1.4.2 剂量学参数评估 所有 IMRT 计划的 PTV 和 OARs 均满足剂量限值要求。采用自编 Python 程序提取上述三组计划的剂量学数据, 并比较 PTV 剂量学参数: D_2 、 D_{50} 、 D_{98} (D_i 表示 $i\%$ 体积的 PTV 受照剂量)、平均剂量 D_{mean} 以及靶区的均匀性指数 (homogeneity index, HI) 和适形度指数 (conformity index, CI); 危及器官剂量学参数: 心脏 V_{30} 、 V_{40} (V_i 表示接受 i Gy 剂量的器官体积百分比) 和平均剂量 D_{mean} ; 双肺 V_{30} 、 V_{20} 、 V_5 和 D_{mean} ; 脊髓最大剂量 D_{max} 。其中 HI 指数和 CI 指数 [10] 具体计算公式如下:

$$HI = (D_2 - D_{98}) / D_{50} \quad (3)$$

$$CI = (V_{pref} / V_p) \times (V_{pref} / V_{ref}) \quad (4)$$

式中 V_{pref} 表示 PTV 和参考等剂量线覆盖区域的重叠部分, V_p 表示 PTV 体积, V_{ref} 表示参考等剂量线覆盖区域的全部体积。CI 指数取值范围为 0 ~ 1, 数值越大表示 PTV 适形度越好; 而 HI 指数越小, 表示 PTV 剂量均匀性越好。

1.5 统计学处理 采用 SPSS 23.0 统计软件进行分析, 数据以 $\bar{x} \pm s$ 形式表示, 利用配对 t 检验的方式评价两组数据间差异, $P < 0.05$ 为差异有统计学意义。

2 结果

2.1 深度学习预测模型精确度评估 图 1 为最优预测模型对测试集剂量预测的 dice 系数。结果显示: 除个别病例在 50 Gy 处 dice 系数低于 0.9 外, 其余均在 0.9 以上, 且平均 dice 系数大于 0.92, 在 40 Gy 以下时平均 dice 系数可达到 0.95 以上, 等剂量面的平均 HD₉₅ 为 0.58 ~ 0.62 cm, 见图 2。

2.2 剂量学参数比较 三组计划的 PTV 和 OARs 剂量学参数比较见表 1。Auto-Plan 计划的靶区 CI, 心脏 V_{30} 、 V_{40} 、 D_{mean} , 双肺 V_5 、 V_{20} 、 D_{mean} , 脊髓 D_{mean} 与人工计划相应参数相比差别不大 ($P > 0.05$), 但 Auto-Plan 计划其他剂量参数明显优于人工计划且靶区均匀性更好。深度学习预测模型中双肺 V_{20} 、 V_{30} 、 D_{mean} 剂量学参数明显低于人工计划相应结果 ($P < 0.05$) 且 V_5 也偏低, 但在靶区均匀性和脊髓 D_{max} 保




图1 20例测试集病例预测与原计划等剂量面 dice 系数(红实线为平均值)




图2 20例测试集病例预测与原计划等剂量面 HD₉₅

护方面人工计划优势明显。该研究对于以上计划设计,深度学习预测模型训练需要一周左右,但预测模型对食管癌术后 IMRT 计划剂量预测所花费时间仅需数秒,而 Auto-Plan 对测试集计划设计平均耗时约

15 min。

2.3 三维剂量分布及 DVH 图比较 从测试集中随机选取 1 例病例,采用 Python 中的 matplotlib 库分别显示其三组计划的三维剂量分布及其差异、PTV 和 OARs 的 DVH 曲线(图 3 和图 4)。就选取的病例而言,三者的三维剂量分布差异性较小且 PTV 及 OARs 的 DVH 曲线具有较好的吻合度。

3 讨论

本研究采用构建的 3D U-Res-Net 深度学习预测模型与 Auto-Plan 自动计划分别对食管癌术后 IMRT 计划进行相应处理,并将所得结果分别与人工计划进行剂量学差异研究。结果表明,所构建的深度学习预测模型对食管癌术后 IMRT 计划三维剂量预测具有较好的精确度,而 Auto-Plan 模块应用于食管癌 IMRT 计划设计时,不仅耗时较短,人为不确定因素干扰较少,更能够让 OARs 的受射剂量在满足临床要求的同时实现更好的靶区剂量均匀性。但本研究中测试集人工计划设计旨在模拟日常放疗物理师繁忙的工作状态,计划设计时仅考虑计划能否达到临床实际治疗要求即可,没有对患者调强计划进行反复深度优化,故而不能反映 Auto Plan 的优化深度。

与基于 APE 优化方法的 Auto-Plan 相比,研究所构建的 3D U-Res-Net 深度学习模型采用卷积神经网络 U-Net 网络^[11]和残差网络(Residual-Net)^[12]相结合方式,以医院大量 IMRT 放疗计划病例数据作为依托,经由深度学习训练得到预测模型。预测结果显示,人工设计计划在肺组织剂量上可能仍有一定

表1 20例测试集三组计划剂量学比较($\bar{x} \pm s$)

结构组	剂量参数	人工计划	Auto-Plan 计划	深度学习预测	T_1 值	T_2 值	P_1 值	P_2 值
PTV	D_2 (Gy)	53.81 ± 0.60	53.09 ± 0.40	54.04 ± 0.74	5.784	-1.056	<0.001	0.148
	D_{50} (Gy)	52.04 ± 0.35	51.72 ± 0.30	52.01 ± 0.48	4.067	0.295	0.001	0.772
	D_{98} (Gy)	48.88 ± 0.63	49.22 ± 0.26	48.53 ± 0.69	-2.698	2.259	0.014	0.036
	D_{mean} (Gy)	51.87 ± 0.31	51.55 ± 0.24	51.83 ± 0.52	4.933	0.369	<0.001	0.716
	HI	0.09 ± 0.02	0.07 ± 0.08	0.10 ± 0.16	4.897	-2.612	<0.001	0.017
	CI	0.82 ± 0.03	0.81 ± 0.03	0.82 ± 0.03	0.895	0.074	0.382	0.942
心脏	V_{30} (%)	9.76 ± 11.22	9.49 ± 2.16	9.79 ± 10.90	0.484	-0.204	0.634	0.840
	V_{40} (%)	4.50 ± 5.90	5.45 ± 5.81	5.34 ± 6.50	-1.896	-1.949	0.073	0.066
	D_{mean} (Gy)	6.83 ± 5.80	6.82 ± 5.44	6.91 ± 5.81	0.026	-1.454	0.979	0.162
	V_5 (%)	46.70 ± 3.12	46.62 ± 3.98	46.43 ± 2.95	0.148	0.930	0.884	0.364
双肺	V_{20} (%)	17.62 ± 1.53	17.28 ± 1.70	17.35 ± 1.63	1.577	2.822	0.131	0.011
	V_{30} (%)	9.84 ± 1.70	9.25 ± 1.77	9.68 ± 1.61	3.28	2.168	0.004	0.043
	D_{mean} (Gy)	9.74 ± 0.76	9.60 ± 0.84	9.64 ± 0.72	1.704	3.235	0.105	0.004
	D_{max} (Gy)	42.08 ± 0.93	42.26 ± 1.41	43.13 ± 1.40	-0.623	-4.173	0.541	0.001

T_1 、 P_1 和 T_2 、 P_2 分别为人工计划与 Auto-Plan 计划、深度学习预测计划配对 t 检验结果




图3 随机选取1例测试集病例三组计划的三维剂量分布进行比较

A、B、C 分别为人工计划、深度学习预测和 Auto-Plan 计划; D、E 分别为人工计划与深度学习预测、Auto-Plan 计划的三维剂量分布差异图




图4 随机选取1例测试集病例三组计划的 PTV 及危及器官 DVH 曲线比较

A: 靶区 PTV; B: 心脏; C: 全肺; D: 脊髓

的剂量节省空间,但在 PTV 均匀性和脊髓 D_{\max} 保护方面预测模型略有不足。脊髓 D_{\max} 相对剂量比人工计划偏高约 2.5%,但仍满足临床处方剂量要求,脊

髓 D_{\max} 出现偏高原因可能是由于计划中脊髓结构区域较小,剂量特征提取困难所致,而 PTV 均匀性较差可能是中上段食管癌靶区自身长度较长,模型本

身对剂量特征学习不完善所致,后期研究将予以针对性完善。

近年来,国内外研究者对自动计划研究成果颇多^[13-15],但当前商用自动计划系统均是基于系统自身嵌入的软件模块或由第三方案实现,对于其他研究人员自主设计的自动计划设计程序具有一定的排他性,故可移植性较差^[16]。本研究中建立的3D U-Res-Net模型预测的三维剂量分布目前虽只能作为放疗物理师计划设计参考,但对于自动计划系统的研发具有一定的临床指导意义。相对于Auto-Plan在PTV与OARs之间寻求最优解平衡的方法以及人工计划设计中在OARs限值满足处方剂量要求的情况下寻求靶区最优解方法,深度学习方法依据医院既往大量IMRT计划数据进行反复的剂量特征学习,对肿瘤PTV及OARs存在不同解剖结构位置关系的计划实施最优预测,具有预测耗时短,无任何人为因素干扰等特点,已广泛用于自动计划系统研发,但如何在当前的剂量预测结果基础上进行深度优化,得到更优计划预测结果是下一步研究需要关注的问题。

参考文献

- [1] Sung H, Ferlay J, Siegel R L, 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): 209-49.
- [2] 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]. Medical Physics, 2019, 46(1): 56-64.
- [3] Liu Z, Fan J, Li M, et al. A deep learning method for prediction of three-dimensional dose distribution of helical tomotherapy [J]. Med Phys, 2019, 46(5): 1972-83.
- [4] Nguyen D, Long T, Jia X, et al. A feasibility study for predicting optimal radiation therapy dose distributions of prostate cancer patients from patient anatomy using deep learning [J]. Sci Rep, 2019, 9(1): 1076.
- [5] Zhou J, Peng Z, Song Y, 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 Med Phys, 2020, 21(5): 26-37.
- [6] 范嘉伟, 陈帆, 王佳舟, 等. 基于深度学习方法的乳腺癌调强放疗自动计划研究[J]. 中华放射肿瘤学杂志, 2020, 29(8): 671-5.
- [7] 程博, 方诗杰, 任强, 等. DeepPlan系统中快速直接子野优化在临床中的应用研究[J]. 中华放射医学与防护杂志, 2020, 40(12): 938-44.
- [8] Hazell I, Bzdusek K, Kumar P, et al. Automatic planning of head and neck treatment plans [J]. J Appl Clin Med Phys, 2016, 17(1): 272-82.
- [9] 秦楠楠, 薛旭东, 石军, 等. 基于空洞卷积U-Net模型的胰腺自动分割方法研究[J]. 安徽医科大学学报, 2021, 56(9): 1469-74.
- [10] 程志奎, 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): 285-90.
- [11] Ibtehaz N, Rahman M S. MultiResUNet: Rethinking the U-Net architecture for multimodal biomedical image segmentation [J]. Neural Netw, 2020, 121: 74-87.
- [12] 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): 370-81.
- [13] Kajikawa T, Kadoya N, Ito K, et al. A convolutional neural network approach for IMRT dose distribution prediction in prostate cancer patients [J]. J Radiat Res, 2019, 60(5): 685-93.
- [14] 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): 65020.
- [15] 王雪桃, 肖江洪, 赵建玲, 等. 基于RayStation计划系统的宫颈癌容积旋转调强自动计划设计[J]. 中华放射医学与防护杂志, 2018, 38(10): 751-5.
- [16] 刘映, 宋莹, 张惠玲. 胃癌术后调强放疗自动与人工计划的剂量学比较[J]. 中华肿瘤防治杂志, 2021, 28(3): 223-9.

The study of dose prediction and automated plan for IMRT of postoperative esophageal cancer

Wang Wencheng¹, Zhou Jieping², Zhang Peng², Wu Ailin², Wu Aidong^{1,2}

(¹School of Biomedical Engineering, Anhui Medical University, Hefei 230032; ²Dept of Radiation Oncology, The First Affiliated Hospital of University of Science and Technology of China, Hefei 230001)

Abstract Objective To explore the clinical dosimetry advantages of automated plan of IMRT for postoperative esophageal cancer and the dose prediction accuracy of the constructed 3D U-Res-Net model. **Methods** A total of 110 postoperative esophageal cancer (middle and upper) cases treated by IMRT were considered in the study, of which 90 cases were randomly selected for training of deep learning prediction model. The deep learning prediction model and Auto-Plan module (Philips pinnacle³ 16.2) were used to predict the three-dimension dose distribution and redesigned the remaining 20 cases respectively, and the results obtained were compared with manual plan.

网络出版时间: 2023-01-20 16:07:21 网络出版地址: <https://kns.cnki.net/kcms/detail/34.1065.R.20230119.1742.020.html>

基于卷积神经网络的白光内镜下早期胃癌检测

晋 晶^{1,2}, 张倩倩^{1,2}, Bill Dong³, 马 涛³, 王 曦^{1,2}, 梅雪灿^{1,2}, 宋绍方⁴, 彭 杰⁴, 吴艾久⁴, 董兰芳³, 孔德润^{1,2}

摘要 目的 开发一种基于区域卷积神经网络(Mask R-CNN)的内镜下自动检测早期胃癌(EGC)系统。方法 首先从安徽医科大学第一附属医院获得3 579张和892张EGC白光图像(WLI),分别进行训练和测试。随后前瞻获取10个WLI实时视频以测试动态性能。另外再随机选取400张WLI图像,用于Mask R-CNN系统和内镜医师对照。诊断能力以准确率、敏感度、特异度、阳性预测值(PPV)和阴性预测值(NPV)进行评估。结果 在WLI图像诊断中,Mask R-CNN系统准确率、敏感度和特异度分别为90.25%、91.06%和89.01%,与病理诊断差异无统计学意义。在WLI视频中,诊断EGC的准确率为90.27%,实时测速可达35帧/s。在对照实验中,Mask R-CNN系统的敏感度明显高于高年资组医师(93.00% vs 80.20%, $\chi^2 = 7.059$, $P < 0.001$),特异度高于低年资组医师(82.67% vs 71.87%, $\chi^2 = 9.955$, $P < 0.001$),总体准确率高于中年资组医师(85.25% vs 78.00%, $\chi^2 = 7.009$, $P < 0.001$)。结论 在WLI下,Mask R-CNN系统检测EGC的性能良好,在实际临床应用中有较大潜力。

关键词 人工智能; 区域卷积神经网络; 白光内镜; 早期胃癌中图分类号 R 573.9

文献标志码 A 文章编号 1000-1492(2023)02-0285-07
doi: 10.19405/j.cnki.issn1000-1492.2023.02.020

胃癌是世界上最常见的恶性肿瘤之一^[1],早期胃癌(early gastric cancer, EGC)的5年生存率可以达到95%,而进展期胃癌(advanced gastric cancer, AGC)的5年生存率只有30%^[2]。因此,胃癌的早期发现、诊断及早期根除是降低胃癌死亡率的重要措施。人工智能(artificial intelligence, AI)基于机器的计算和学习能力,能高效地解决问题,在医学图像识别领域得到广泛应用和发展。在内镜领域,既往文献^[3]报道了AI在识别食管癌等方面的应用。目前内镜图像检测多采用基于深度学习的目标检测算法,有训练样本量大、训练时间长、计算体量大、表达精度低等局限性^[4]。该研究开发了一种基于掩膜区域卷积神经网络(mask region-based convolutional neural network, Mask R-CNN)的AI系统作为内镜下辅助诊断EGC的新技术,并测试其性能,与内镜医师对照,评估该系统的临床适用性。

1 材料与方法

1.1 仪器和软件 CV-290型内镜主机、GIF Q260J型胃镜、GIF H260Z型胃镜(Olympus Corporation), LabelMe软件(版本1.1, IBM Corporation)、SPSS(版本26.0, IBM Corporation)、Pair软件(版本2.0, 深圳度影医疗科技有限公司)。

1.2 患者选择 选取2017年10月—2022年3月在安徽医科大学第一附属医院接受放大内镜和窄带

2022-12-22 接收

基金项目: 安徽省重点研究与开发计划项目(编号: 2022e07020048)

作者单位: ¹ 安徽医科大学第一附属医院消化内科, 合肥 230022

² 安徽省消化病重点实验室, 合肥 230022

³ 中国科学技术大学计算机科学与技术学院, 合肥 230027

⁴ 合肥中纳医学仪器有限公司, 合肥 230088

作者简介: 晋 晶, 女, 硕士研究生;

孔德润, 男, 教授, 主任医师, 博士生导师, 责任作者, E-mail: kongderun@ahmu.edu.cn

Results The average DSC value between the deep learning prediction plan and the manual plan was greater than 0.92 in isodose surface, and the average Hausdorff distance HD_{95} of the isodose surface was 0.58-0.62 cm; The V_{20} , V_{30} , D_{mean} of total lung were slightly lower than those of manual plan ($P < 0.05$) for the prediction model, meanwhile, the D_2 , D_{50} , D_{mean} , HI of the target area and V_{30} of total lungs were better than those of manual plan ($P < 0.05$) for Auto-Plan; Three-dimensional dose distribution of the three groups and the corresponding DVH curve showed that the three-dimensional dose distribution of the three groups had a little differences, and the DVH curves of the target area and organs at risk had a good agreement. **Conclusion** Auto-Plan can realize the design of automated plan for postoperative esophageal cancer, while the deep learning prediction model can realize the accurate prediction of the 3D dose distribution.

Key words esophageal cancer; automated plan; deep learning; dosimetry; intensity modulate radiotherapy