

兆伏级CT图像引导自适应放疗中生成合成CT研究

陈宇亭^{1,2}, 周飞宇^{1,2}, 张富利², 蒋华勇², 陈点点², 高彦祥², 郁艳军², 乐小云¹, 路娜²

1. 北京航空航天大学物理学院, 北京 100191; 2. 解放军总医院肿瘤学部第七医学中心放疗科, 北京 100700

【摘要】目的:开发一种基于深度学习神经网络的方法将宫颈癌MVCT图像转换为具有高信噪比和高对比度的伪kVCT图像,从而提供宫颈癌自适应放疗需要的患者三维解剖图像和定位信息,引导加速器实现精确放疗。**方法:**收集54例宫颈癌患者的MVCT和kVCT图像组成数据集,随机选择44例样本作为训练集,并将剩下的10例样本作为测试集。采用加入门控机制和多通道数据输入的循环生成对抗网络(CycleGAN)基于MVCT合成伪kVCT图像。采用平均绝对误差(MAE)、峰值信噪比(PSNR)和结构相似度指数(SSIM)等影像学成像质量评估参数,评估网络训练效果。**结果:**5通道MVCT-5通道kVCT图像与MVCT图像对比,MAE从(24.9±0.7) HU降至(17.8±0.3) HU,PSNR从(29.8±0.2) dB升至(30.7±0.2) dB,SSIM从0.841±0.007升至0.898±0.003。**结论:**该方法生成的伪kVCT在降噪和增强对比度方面具有优势,同时能够减少剂量计算中对额外MV-kVCT电子密度校准的需求。伪kVCT的剂量计算能力与MVCT相当,为伪kVCT影像应用于图像引导自适应放疗提供了可能。

【关键词】循环生成对抗网络;MVCT;合成CT;图像引导放疗;图像质量

【中图分类号】R737.33

【文献标志码】A

【文章编号】1005-202X(2024)07-0813-08

Generating synthetic CT in megavoltage CT image-guided adaptive radiotherapy

CHEN Yuting^{1,2}, ZHOU Feiyu^{1,2}, ZHANG Fuli², JIANG Huayong², CHEN Diandian², GAO Yanxiang², YU Yanjun², LE Xiaoyun¹, LU Na²

1. School of Physics, Beihang University, Beijing 100191, China; 2. Department of Radiotherapy, the 7th Medical Center, Department of Oncology, Chinese PLA General Hospital, Beijing 100700, China

Abstract: Objective To propose a deep learning neural network approach for transforming megavoltage computed tomography (MVCT) images of cervical cancer into pseudo kilovoltage computed tomography (kVCT) images with high signal-to-noise ratio and contrast-to-noise ratio, thus providing three-dimensional anatomical images and localization information required for adaptive radiotherapy of cervical cancer, and guiding the accelerator to achieve precise treatment. **Methods** The MVCT and kVCT images of 54 patients treated with cervical cancer radiotherapy were collected, with 44 cases randomly selected as the training set, and the remaining 10 cases as the test set. A cyclic generative adversarial network with gating mechanism and multi-channel data input was used to synthesize pseudo-kVCT images from MVCT images. The network training results were evaluated with imaging quality evaluation parameters, such as mean absolute error (MAE), peak signal-to-noise ratio (PSNR), and structural similarity index (SSIM). **Results** The MAE, PSNR, and SSIM of MVCT images vs pseudo-kVCT (5:5) images were (24.9±0.7) HU vs (17.8±0.3) HU, (29.8±0.2) dB vs (30.7±0.2) dB, and 0.841±0.007 vs 0.898±0.003, respectively. **Conclusion** The generated pseudo-kVCT images have advantages in noise reduction and contrast enhancement, and can reduce the need for additional MV-kVCT electron density calibration in dose calculations. The dose calculation ability of pseudo-kVCT is comparable to that of MVCT, providing a possibility for the application of pseudo-kVCT images in image-guided adaptive radiotherapy.

Keywords: cyclic generative adversarial network; megavoltage computed tomography; synthetic computed tomography; image-guided radiotherapy; image quality

【收稿日期】2024-02-25

【基金项目】解放军总医院第七医学中心创新培育基金(qzx-2023-12)

【作者简介】陈宇亭, 硕士研究生, 研究方向: 医学物理, E-mail: wibx_95@163.com

【通信作者】路娜, 硕士, 主治医师, 研究方向: 肿瘤放射治疗学, E-mail: 13910033806@139.com

前言

螺旋断层放射治疗(TOMO Therapy, TOMO)可在靶区边缘形成陡峭的剂量梯度,从而有效保护危及器官。然而,这种治疗方法也会增加靶区漏照和正常组织损伤的风险,需要精确的放射治疗来克服。

为了提高放疗的准确性,可以借助加速器自身配备的兆伏级CT(MVCT)系统进行自适应放疗。然而,为了减少患者的成像剂量,MVCT扫描的光子数量较少,牺牲了图像的质量,具有较低的信噪比(Signal-to-Noise Ratio, SNR)和对比度噪声比(Contrast-to-Noise Ratio, CNR)^[1]。如何降低MVCT的噪声进行自适应放疗是临床工作中亟需解决的问题。

目前MVCT图像去噪较多使用传统方法,如全变化(TV-L1)图像去噪技术和代数重建^[2-4]。各向异性扩散滤波方法也被提出来用以提高MVCT图像的质量^[5-6]。该方法在保持对比度分辨率的同时降低了MVCT图像的噪声,但图像锐度的平滑处理降低了图像的空间分辨率。采用基于非局部均值滤波的去噪算法可进一步提高MVCT图像质量^[7-8]。不过,这些算法在投入临床应用时都会受到去噪过程中参数设置未确定的限制。利用张量帧集作为图像正则化的代数重建技术算法也是一种改进的降噪方法,但是该方法在图像分辨率方面结果不稳定^[9]。而利用深度学习方法通过图像合成方法得到合成的类似kVCT的新图像应用于自适应放疗的方法,在其他模态医学图像上已有诸多应用^[10-12],但在MVCT图像上应用还较少,尤其在宫颈癌方面的研究尚为空白。因此,本文提出利用深度学习方法将MVCT图像转换为伪kVCT图像,以提高图像的SNR和CNR,在自适应放疗中具有重要意义。

1 资料与方法

1.1 数据获取与预处理

回顾性分析解放军总医院第七医学中心54例宫颈癌患者资料。所有患者均接受了疗程为1~2个月的TOMO治疗。在算法调试和网络的训练过程中,从54例数据集中随机选取44例作为训练集,总计3496张图像,剩余10例作为测试集,考察模型的泛化能力。数据由CT扫描获得的计划kVCT图像和按分次治疗时间排列的MVCT图像构成。进行CT扫描前1h排空膀胱,分次口服泛影葡胺溶液800 mL,以充分显示小肠。MVCT图像切片层厚为4 mm,体素大小为0.763 mm,计划kVCT图像切片层厚为5 mm,体素大小为1.953 mm。

对所有患者的MVCT图像进行相关预处理操作:首先借助参考中心对MVCT和kVCT图像进行刚性配准,对图像进行重采样后获得体素大小相匹配的MVCT-kVCT数据集;然后参考MVCT的扫描区域对kVCT图像进行过滤,提高数据的匹配程度;其次将图像的体素值进行归一化,为后续进行多通道图像分割打下数据基础;最后,加入数据增强操作扩

充数据量提高模型泛化能力。

1.2 模型设计

1.2.1 带有注意力门控机制的CycleGAN 本研究采用的图像合成方法为带有注意力门控机制的循环生成对抗网络(CycleGAN)。无需输入图像和目标域图像之间有一一对应的关系,配对数据和非配对数据均可处理,适配性更广。生成对抗网络(GAN)的核心在于同时使用生成器和鉴别器网络相互竞争。CycleGAN包含两个发生器和两个鉴别器,其中一个发生器从MVCT生成一个类似kVCT的图像,即伪kVCT图像。另一个发生器从kVCT生成伪MVCT图像。两个鉴别器分别用于对伪造的图像和真实的图像进行分类区分,其中一个鉴别器专门用于识别MVCT图像,另一个鉴别器则专门用于识别kVCT图像。发生器产生的伪造图像会尽可能接近真实图像,而鉴别器会尽力区分它们。产生者和鉴别者相互竞争,直到达到最优。图1概述了CycleGAN的工作流程。

CycleGAN将MVCT图像转换为伪kVCT图像(生成器G: MVCT→kVCT),再将伪kVCT图像转换为循环MVCT图像(生成器F: kVCT→MVCT),计算循环MVCT图像与原MVCT图像的循环一致性损失,并对kVCT图像也进行相同的循环操作:

$$L_{\text{cyc}}(G, F) = \frac{1}{N} \sum_{i=1}^N \|F(G(x_i)) - x_i\|_1 + \|G(F(y_i)) - y_i\|_1 \quad (1)$$

其中, $\|\cdot\|_1$ 为向量的L1范数, x_i 为输入的MVCT训练图像, y_i 为输入的kVCT训练图像。该过程对模型的一对一映射进行了双重约束,旨在生成更精确的输出图像。

1.2.2 多通道数据输入 在本研究中,提出了一种按HU值等分的多通道数据输入训练方法,以增强空气、软组织、骨骼等不同组织的训练效果。具体实现时,笔者对计划kVCT和MVCT图像(去除治疗床和背景)进行HU值直方图统计,取统计直方图面积的3等分点,分别生成3个HU值窗口图像,得到按HU值等分的3通道图像数据(图2、图3)。为了减少等分点受个体差异的影响,应尽可能统计所有训练数据的HU值,找到平均的HU值3等分点。在每个通道的图像中,超过该窗口灰度值范围的像素点,均以该窗口HU值的最大值和最小值进行赋值处理。通过类似的方式,可以生成N等分的N通道数据。在训练结束后,进行逆操作,将不同通道的图片相加,即可得到最终输出的单通道伪kVCT图像。

1.2.3 网络训练架构及参数 本文采用的深度学习框架为Tensorflow,编程语言为Python。训练所用的硬

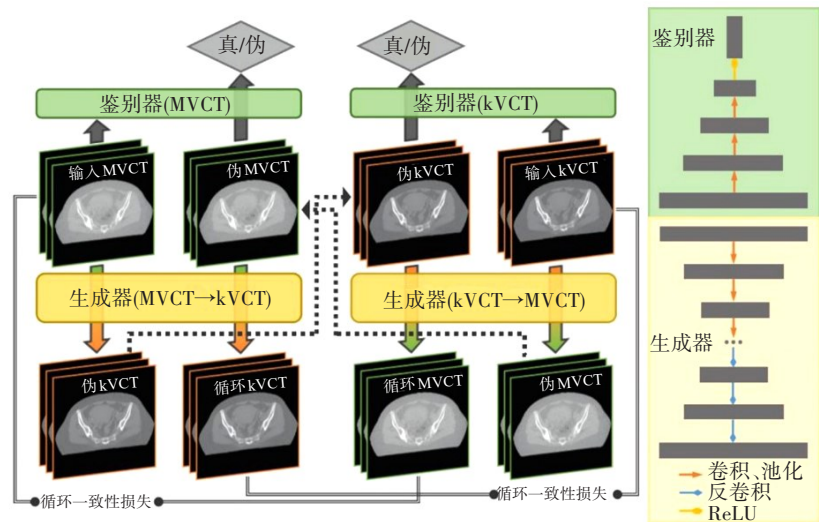


图1 CycleGAN工作流程示意图
Figure 1 Work flowchart of CycleGAN




图2 计划kVCT图像按HU值3等分形成3通道数据

Figure 2 The planned kVCT image is equally divided into 3 parts according to HU value to form 3-channel data

a: 计划kVCT图像HU值直方图; b~d: 计划kVCT图像HU值3等分HU值直方图; e: 计划kVCT图像; f~h: 将计划kVCT图像HU值3等分后的3张kVCT图像

件参数如下所示。CPU: Intel(R) Xeon(R) Gold6139M CPU@2.30 GHz, 内存为 96 G; GPU: NVIDIA GeForce RTX3090Founders Edition, 显存为 24 G。软件参数如下所示。GeForce 驱动版本: 515.65.01; conda 版本: 4.9.2; cuda 版本: 11.7; python 版本: 3.6.8; Tensorflow 版本: 2.4.0。

1.3 图像质量评价指标

成像质量评估采用常见的图像评估指标, 包括平均绝对误差 (Mean Absolute Error, MAE)、峰值信噪比 (Peak Signal to Noise Ratio, PSNR) 和结构相似度指数 (Structural Similarity, SSIM) 等。其具体定义

如下:

$$\text{MAE} = \frac{1}{n_i n_j n_k} \sum_{x,y,z} |\text{CT}(x,y,z) - \text{sCT}(x,y,z)| \quad (2)$$
$$\text{PSNR} = 10 \times \log_{10} \frac{\text{MAX}^2}{\sum_{x,y,z} |\text{CT}(x,y,z) - \text{sCT}(x,y,z)|^2 / n_i n_j n_k} \quad (3)$$

$$\text{SSIM}(\text{CT}, \text{sCT}) = \frac{(2\mu_{\text{CT}}\mu_{\text{sCT}} + c_1)(2\sigma_{\text{CT}}\sigma_{\text{sCT}} + c_2)}{(\mu_{\text{CT}}^2 + \mu_{\text{sCT}}^2 + c_1)(\sigma_{\text{CT}}^2 + \sigma_{\text{sCT}}^2 + c_2)} \quad (4)$$

其中, $\text{CT}(x,y,z)$ 和 $\text{sCT}(x,y,z)$ 分别为计划kVCT和伪kVCT中的像素 (x,y,z) 的值。 $n_i n_j n_k$ 是像素的总数量。




图3 MVCT 图像按HU值3等分形成3通道数据

Figure 3 MVCT image is equally divided into 3 parts according to HU value to form 3-channel data

a:原MVCT图像HU值直方图;b~d:原MVCT图像HU值3等分HU值直方图;e:原MVCT图像;f~h:将原MVCT图像HU值3等分后的3张MVCT图像

MAX是计划CT和伪kVCT的CT值的最大强度。 μ_{CT} 和 μ_{sCT} 为计划kVCT和伪kVCT图像所有像素值的平均值。 σ_{CT} 和 σ_{sCT} 为计划kVCT和伪kVCT图像所有像素值的标准差。MAE是计划kVCT和伪kVCT基于体素的HU值之间绝对误差的平均值。而PSNR是以dB为单位的图像质量评价指标,数值增加表示失真减小。SSIM是一种衡量两幅图像相似度的指标,其取值范围为-1~1,数值越大代表图像越相似。

此外,为了更详细地评估图像质量,研究还将选取若干个感兴趣区域(Region of Interest, ROI)进行图像评估指标计算,并对剂量计算能力进行评估。将基于kVCT图像的计划靶区(Planning Target Volume, PTV)、临床靶区(Clinical Target Volume, CTV)以及危及器官的勾画数据移植到伪kVCT图像上,并根据解剖学结构的实际变化进行相应的调整。最终,利用TPS计算得到基于伪kVCT图像的剂量分布,并绘制相关的剂量体积直方图(Dose Volume Histogram, DVH)进行分析。

2 结果

2.1 数据增强方法与注意力门控对网络的效果评估

在本研究中,笔者对原始CycleGAN、数据增强CycleGAN、注意力门控CycleGAN以及数据增强+注意力门控CycleGAN的训练进行评估。表1提供了数据增强方法与注意力门控机制在训练过程中的效果对比。通过与MVCT图像进行比较,对伪kVCT的成像质量参数及其与MVCT图像参数的差值进行了综合评估。此外,表中还总结了训练集和测试集中

所有图像的训练结果,以评估这些技术在图像质量提升方面的表现和效率。结果显示原始CycleGAN训练效果最差,应用了数据增强+注意力门控的CycleGAN训练效果最好。训练集伪kVCT图像的MAE、PSNR和SSIM由 (42.7 ± 1.4) HU、 (25.6 ± 0.2) dB和 0.763 ± 0.008 提高到 (37.2 ± 1.2) HU、 (25.4 ± 0.2) dB和 0.806 ± 0.005 。测试集伪kVCT图像的MAE、PSNR和SSIM由 (42.6 ± 4.8) HU、 (25.3 ± 0.5) dB和 0.771 ± 0.022 提高到 (36.8 ± 3.6) HU、 (25.3 ± 0.5) dB和 0.813 ± 0.015 。表2展示了数据增强方法和注意力门控机制对PTV、CTV、危及器官等勾画区域的影响,通过与MVCT图像进行比较,对伪kVCT的成像质量参数及其与MVCT图像参数的差值进行了综合评估。结果发现无论是数据增强方法,还是门控机制,对SSIM指数的提升幅度都较小,在MAE和PSNR指数上则表现优异。同时采用数据增强+注意力门控机制的CycleGAN改善效果最为明显,膀胱和股骨头的伪kVCT图像MAE较MVCT下降了30%以上。

2.2 多通道数据输入方法效果评估

表3展示了54例宫颈癌患者影像数据在5通道MVCT-5通道kVCT(5:5)和1通道MVCT-1通道kVCT(1:1)的训练结果。SSIM指数基本不变。对于MAE和PSNR指数,5通道MVCT-5通道kVCT的训练效果有一定提升。表4展示了54例宫颈癌患者影像数据的5通道MVCT-5通道kVCT训练结果与原始MVCT的数据对比结果。训练集图像的MAE从 (24.9 ± 0.7) HU降至 (17.8 ± 0.3) HU,PSNR从 (29.8 ± 0.2) dB升至 (30.7 ± 0.2) dB,SSIM从 0.841 ± 0.007 升至 0.898 ± 0.003 。

表 1 数据增强方法与注意力门控机制的训练结果对比

Table 1 Comparison of training results of data augmentation method and attention gating mechanism

数据集	参数	MVCT	伪kVCT(原始)	伪kVCT(数据增强)	伪kVCT(AG)	伪kVCT(AG+数据增强)
训练集 (n=44)	MAE/HU	40.8±1.3	42.7±1.4	39.2±1.2	40.2±1.3	37.2±1.2
	相对差值/%	-	4.73	-3.87	-1.46	-8.72
	PSNR/dB	25.5±0.2	25.6±0.2	25.3±0.2	25.6±0.2	25.4±0.2
	相对差值/%	-	0.31	-0.90	0.27	-0.30
	SSIM	0.769±0.008	0.763±0.008	0.796±0.006	0.780±0.007	0.806±0.005
	相对差值/%	-	-0.74	3.54	1.45	4.89
测试集 (n=10)	MAE/HU	40.7±4.4	42.6±4.8	38.8±3.7	40.5±4.2	36.8±3.6
	相对差值/%	-	4.48	-4.79	-0.63	-9.75
	PSNR/dB	25.3±0.5	25.3±0.5	25.1±0.5	25.3±0.5	25.3±0.5
	相对差值/%	-	0.09	-0.77	-0.15	-0.20
	SSIM	0.774±0.022	0.771±0.022	0.801±0.017	0.784±0.018	0.813±0.015
	相对差值/%	-	-0.30	3.46	1.32	5.10

伪kVCT(原始)表示使用原始CycleGAN训练的图像;伪kVCT(数据增强)表示使用数据增强CycleGAN训练的图像;伪kVCT(AG)表示使用注意力门控CycleGAN训练的图像;伪kVCT(AG+数据增强)表示使用数据增强+注意力门控CycleGAN训练的图像

表 2 数据增强方法和注意力门控机制对PTV、CTV、危及器官勾画区域影响

Table 2 Effects of data augmentation + attention gating mechanism on PTV, CTV, and OAR segmentations

区域	参数	MVCT	伪kVCT(原始)	伪kVCT(数据增强)	伪kVCT(AG)	伪kVCT(AG+数据增强)
PTV	MAE/HU	4.21±0.29	4.29±0.28	4.02±0.24	3.96±0.26	3.33±0.19
	相对差值/%	-	1.86	-4.61	-6.11	-21.01
	PSNR/dB	39.9±0.4	39.6±0.4	39.9±0.4	40.4±0.4	41.2±0.5
	相对差值/%	-	-0.65	0.14	1.28	3.24
	SSIM	0.968±0.004	0.969±0.003	0.972±0.003	0.972±0.003	0.977±0.002
	相对差值/%	-	0.06	0.46	0.37	0.95
CTV	MAE/HU	2.43±0.23	2.56±0.23	2.37±0.18	2.31±0.21	1.85±0.13
	相对差值/%	-	9.07	-2.46	-5.23	-24.15
	PSNR/dB	43.4±0.4	42.7±0.4	43.2±0.3	43.9±0.4	45.2±0.5
	相对差值/%	-	-0.02	-0.50	1.14	4.04
	SSIM	0.980±0.003	0.980±0.003	0.983±0.002	0.982±0.003	0.986±0.002
	相对差值/%	-	0.01	0.25	0.22	0.64
膀胱	MAE/HU	1.83±0.30	1.99±0.34	1.49±0.30	1.63±0.29	1.24±0.31
	相对差值/%	-	9.07	-18.35	-10.48	-31.96
	PSNR/dB	46.2±0.9	45.6±1.0	48.3±1.3	47.2±1.1	50.4±1.6
	相对差值/%	-	-1.17	4.64	2.28	9.12
	SSIM	0.985±0.002	0.983±0.002	0.989±0.002	0.986±0.002	0.991±0.002
	相对差值/%	-	-0.25	0.38	0.09	0.60
股骨头	MAE/HU	3.41±0.27	2.57±0.27	2.33±0.24	2.40±0.26	2.19±0.24
	相对差值/%	-	-24.73	-31.74	-29.77	-35.95
	PSNR/dB	39.1±0.6	41.5±0.8	42.1±0.7	41.8±0.8	42.6±0.8
	相对差值/%	-	6.25	7.62	7.00	9.02
	SSIM	0.988±0.001	0.991±0.001	0.993±0.001	0.992±0.001	0.993±0.001
	相对差值/%	-	0.33	0.50	0.40	0.54

表3 多通道输入方法的训练结果 PTV、CTV 及危及器官等勾画区域对比

Table 3 Comparison of training results of the multi-channel input method for PTV, CTV and OAR segmentations

区域	参数	MVCT	伪kVCT(1:1)	伪kVCT(5:5)
PTV	MAE/HU	4.21±0.29	3.47±0.17	3.33±0.19
	相对差值/%	-	-17.64	-21.01
	PSNR/dB	39.9±0.4	40.9±0.4	41.2±0.5
	相对差值/%	-	2.63	3.24
	SSIM	0.968±0.004	0.976±0.002	0.977±0.002
	相对差值/%	-	0.88	0.95
CTV	MAE/HU	2.43±0.23	1.93±0.11	1.85±0.13
	相对差值/%	-	-20.53	-24.15
	PSNR/dB	43.4±0.4	43.4±0.4	45.2±0.5
	相对差值/%	-	3.06	4.04
	SSIM	0.980±0.003	0.986±0.002	0.986±0.002
	相对差值/%	-	0.62	0.64
膀胱	MAE/HU	1.83±0.30	1.30±0.33	1.24±0.31
	相对差值/%	-	-28.72	-31.96
	PSNR/dB	46.2±0.9	49.9±1.4	50.4±1.6
	相对差值/%	-	8.08	9.12
	SSIM	0.985±0.002	0.989±0.002	0.991±0.002
	相对差值/%	-	0.42	0.60
股骨头	MAE/HU	3.41±0.27	2.25±0.25	2.19±0.24
	相对差值/%	-	-34.13	-35.95
	PSNR/dB	39.1±0.6	42.2±0.8	42.6±0.8
	相对差值/%	-	8.08	9.02
	SSIM	0.988±0.001	0.993±0.001	0.993±0.001
	相对差值/%	-	0.52	0.54

1:1代表1通道MVCT-1通道kVCT;5:5代表5通道MVCT-5通道kVCT

表4 MVCT与多通道输入方法的训练结果对比

Table 4 Comparison of training results between MVCT and multi-channel input method

参数	训练集		测试集	
	MVCT	伪kVCT (5:5)	MVCT	伪kVCT (5:5)
MAE/HU	24.9±0.7	17.8±0.3	29.4±4.3	22.3±4.7
相对差值/%	-	-28.35	-	-24.24
PSNR/dB	29.8±0.2	30.7±0.2	28.7±0.5	29.7±0.5
相对差值/%	-	2.85	-	3.24
SSIM	0.841±0.007	0.898±0.003	0.834±0.016	0.896±0.009
相对差值/%	-	6.78	-	7.42

2.3 剂量计算能力评估

分别对计划kVCT、MVCT和伪kVCT进行剂量

计算,获得等剂量分布图(图4)和DVH曲线(图5)。综合分析可以发现,伪kVCT的剂量计算结果与MVCT接近。

3 讨论

本文设计了一种基于深度学习神经网络的图像合成方法,完成MVCT到伪kVCT的图像合成,改善了其SNR和CNR较低的缺点,MVCT的图像质量得到了显著提高。本研究采用了数据增强和注意力门控相结合的方法,取得了很好的结果。数据增强方法对伪kVCT的整体效果改善较为显著。数据增强可以扩充训练数据总量,可以提高模型泛化能力,减少网络过拟合情况的发生^[13-14]。本文主要采用了旋转和裁剪操作来进行数据增强,整体图像数量扩充为原来的3倍,极大地增加了数据数量,解决了网络数据量少的问题。门控机制在伪kVCT的PTV、

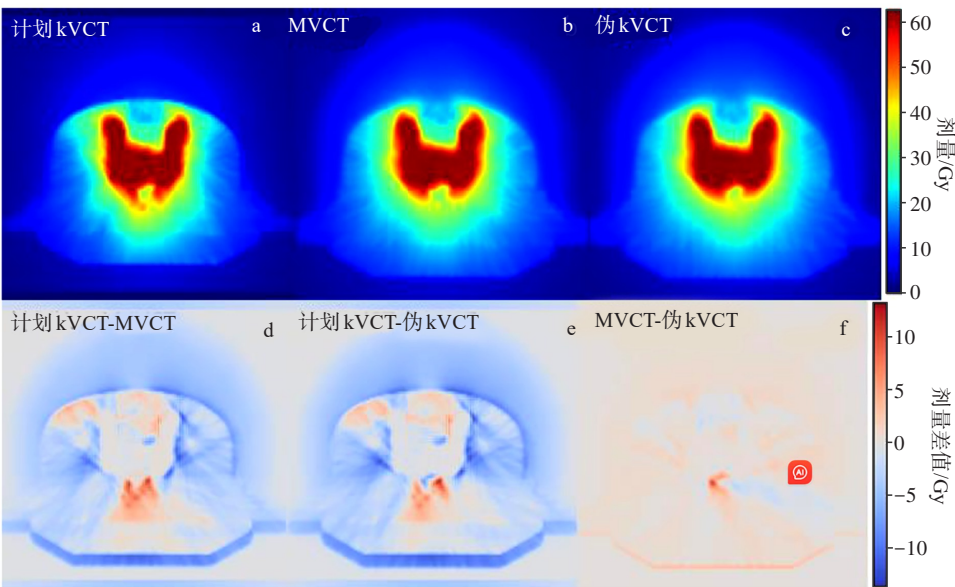


图4 等剂量分布图

Figure 4 Calculated isodose distribution maps

a: 计划kVCT; b: MVCT; c: 伪kVCT; d: 计划kVCT与MVCT的差值; e: 计划kVCT与伪kVCT的差值; f: MVCT与伪kVCT的差值




图5 DVH曲线图

Figure 5 Calculated dose-volume histogram

CTV 和危及器官等需要特别关注的区域上也有良好的提升效果。注意力门控模型的特点是能自动学会并区分不同形状和尺寸的目标,突出图像的显著特征。推测是应用于CycleGAN生成器结构中的门控机制改善了网络对膀胱、直肠等危及器官的识别效果,从而加强 CycleGAN 网络的训练效果。而结合两者之后,网络训练可以发挥更好的作用。

尽管这些方法均有所成效,但原始CycleGAN网络训练的效果不佳,导致目前的图像质量提升效果仍然较少,因此提出了多通道数据输入方法对网络训练效果进行改善。

从图6可以观察到,MVCT图像的CT值-电子密度曲线和kVCT图像不同,以光电效应为主的千伏级射线对高原子序数物质更敏感,在高电子密度物质

上的HU值要高于MVCT。这和图7、图8所反映的kVCT有效信息区间HU值上限(1500)高于MVCT有效信息区间HU值上限(750)相吻合。观察图7和图8发现,CT图像的灰度值分布并不均匀,主要集中在窗位为60 HU,窗宽为300 HU的范围内,这与人体主要由软组织构成有关。然而,这种集中的灰度分布使得软组织之间的对比度不够明显。因此推测通过多通道数据输入的方法,可以更好地区分不同组织之间的差异,从而提高神经网络的训练效果。




图6 CT值-电子密度曲线

Figure 6 CT value-electron density curve

在自适应放疗中,确保MVCT图像的组织密度(HU值)与计划kVCT图像相匹配,是计算患者剂量的关键步骤。本研究采用CycleGAN网络进行图像合成,生成伪kVCT图像,其HU值分布类似于计划kVCT。这种




图7 计划kVCT的HU值直方图统计

Figure 7 Histogram statistics of HU value of planned kVCT




图8 MVCT的HU值直方图统计

Figure 8 Histogram statistics of HU value of MVCT

方法有效降低了MVCT图像的噪声,并提升了图像的对比度。笔者分别对计划kVCT、MVCT和伪kVCT进行剂量计算,并计算其DVH曲线后发现,伪kVCT的剂量计算结果与MVCT接近,但伪kVCT图像的剂量计算过程直接使用了kVCT-电子密度校准曲线,而MVCT则需要使用MVCT电子密度曲线(图6),引入了额外的校准过程。因此,与将MVCT应用于自适应螺旋断层治疗的直接方法相比,伪kVCT保留了MVCT的轮廓变化信息,提高了图像质量,并且不需要额外的MV-kVCT校准过程。MVCT和伪kVCT的总体剂量差异不大,可在图像引导自适应放疗中应用于腹部和盆腔区域的癌症治疗。

目前改善的CycleGAN网络对MVCT图像质量有较大提升,生成的伪kVCT在噪声减少,对比度提高的同时,还可以减少剂量计算中对额外MV-kVCT电子密度校准的需求。但想要实现MVCT在自适应放疗中的更深入应用,还需要开展更多的研究工作。例如引入时间维度,借助训练成熟的CycleGAN网络开展关注患者身体组织结构周期性变化的4D MVCT

研究,或对MVCT的剂量计算能力进行详细准确的评估,以帮助剂量引导放疗等过程的顺利开展。除了从数据端进行补足外,还可以进一步学习医学图像合成相关的深度学习方法,了解模型改善的方向。

4 结论

本研究提出了一种基于CycleGAN的多通道数据输入方法,完成MVCT到伪kVCT的图像合成。该方法能够有效保留MVCT图像的原始解剖信息,同时降低图像噪声,提高对比度。基于伪kVCT的剂量计算与MVCT精度相似,并避免了对MVCT图像的校准。在临床实践中,笔者可以获取患者在放疗期间的MVCT图像,并生成伪kVCT图像进行剂量重建。该方法的应用有望提高放疗治疗的准确性,并为未来ART技术的实施提供更加可靠的支持。

【参考文献】

- [1] Rios I, Vázquez I, Cuervo E, et al. Problems and solutions in IGRT for cervical cancer[J]. Rep Pract Oncol Radiother, 2018, 23(6): 517-527.
- [2] LaRoque SJ, Sidky EY, Pan XC. Accurate image reconstruction from few-view and limited-angle data in diffraction tomography[J]. J Opt Soc Am A Opt Image Sci Vis, 2008, 25(7): 1772-1782.
- [3] Chen GH, Tang J, Leng S. Prior image constrained compressed sensing (PICCS): a method to accurately reconstruct dynamic CT images from highly undersampled projection data sets[J]. Med Phys, 2008, 35(2): 660-663.
- [4] Tian Z, Jia X, Yuan KH, et al. Low-dose CT reconstruction via edge-preserving total variation regularization[J]. Phys Med Biol, 2011, 56(18): 5949-5967.
- [5] Lu WG, Olivera GH, Chen Q, et al. Deformable registration of the planning image (kVCT) and the daily images (MVCT) for adaptive radiation therapy[J]. Phys Med Biol, 2006, 51(17): 4357-4374.
- [6] Martin S, Rodrigues G, Chen Q, et al. Evaluation of tomotherapy MVCT image enhancement program for tumor volume delineation[J]. J Appl Clin Med Phys, 2011, 12(3): 3505.
- [7] Sheng K, Gou SP, Wu JL, et al. Denoised and texture enhanced MVCT to improve soft tissue conspicuity [J]. Med Phys, 2014, 41(10): 101916.
- [8] Liu YR, Yue CX, Zhu J, et al. A megavoltage CT image enhancement method for image-guided and adaptive helical TomoTherapy[J]. Front Oncol, 2019, 9: 362.
- [9] Gao H, Qi XS, Gao Y, et al. Megavoltage CT imaging quality improvement on TomoTherapy via tensor framelet[J]. Med Phys, 2013, 40(8): 081919.
- [10] Yang QS, Yan PK, Zhang YB, et al. Low-dose CT image denoising using a generative adversarial network with Wasserstein distance and perceptual loss[J]. IEEE Trans Med Imaging, 2018, 37(6): 1348-1357.
- [11] Wang TH, Lei Y, Tian Z, et al. Deep learning-based image quality improvement for low-dose computed tomography simulation in radiation therapy[J]. J Med Imaging (Bellingham), 2019, 6(4): 043504.
- [12] Song TA, Chowdhury SR, Yang F, et al. PET image super-resolution using generative adversarial networks[J]. Neural Netw, 2020, 125: 83-91.
- [13] Simard PY, Steinkraus D, Platt JC. Best practices for convolutional neural networks applied to visual document analysis[C]//Proceedings of the Seventh International Conference on Document Analysis and Recognition. Piscataway, NJ, USA: IEEE, 2003: 958-963.
- [14] Shorten C, Khoshgoftaar TM. A survey on image data augmentation for deep learning[J]. J Big Data, 2019, 6(1): 60.

(编辑:薛泽玲)