

DOI:10.3969/j.issn.1005-202X.2025.01.009

医学影像物理

基于迭代配准和感知损失的肺部伪CT合成深度学习算法

杨涛^{1,2}, 黄淼¹, 刘琮³, 胡志华¹, 陶莉莉¹, 张淑平¹

1. 上海第二工业大学智能制造与控制工程学院, 上海 201209; 2. 上海第二工业大学计算机与信息工程学院, 上海 201209;
3. 上海商学院物联网工程系, 上海 201400

【摘要】目的:使用深度学习算法通过学习肺部CT域图像特征,将锥形束CT(CBCT)合成高质量伪CT(sCT)图像。**方法:**本研究提出一种基于感知损失的循环生成式对抗网络模型(CycleGAN)和迭代配准的sCT生成算法,首先,结合感知损失和循环一致性损失来训练CycleGAN模型生成高质量的sCT图像,然后,利用Elastix配准工具对所生成的sCT图像和计划CT(pCT)图像进行配准,并用来迭代CycleGAN生成器模型。**结果:**在获取到的70例肺部肿瘤患者的pCT与CBCT数据上进行实验,从定量指标上看,利用本算法生成的sCT与pCT对比的结构相似度指标比CBCT与pCT对比的提升了11.9%,由0.825上升到0.923,均方绝对误差由110.97 HU降至78.62 HU,峰值信噪比由32.21 dB上升到34.74 dB,互信息由1.187上升到1.418。可视化评估中可见该算法大幅度消除了CBCT切片的散射伪影,突显骨质结构同时也修复了软组织结构。通过与当下流行的U-CycleGAN, R-CycleGAN和CUT模型对比,说明了本算法的有效性。**结论:**本文算法生成sCT图像能够有效减小CBCT与pCT间的剂量误差与结构误差,使其应用于精准的剂量计算,辅助医生的临床放疗诊断成为可能。

【关键词】锥形束CT; CycleGAN; 感知损失; Elastix; 图像合成

【中图分类号】R318

【文献标志码】A

【文章编号】1005-202X(2025)01-0059-08

Deep learning algorithm for lung CT synthesis based on iterative registration and perceptual loss

YANG Tao^{1,2}, HUANG Miao¹, LIU Cong³, HU Zhihua¹, TAO Lili¹, ZHANG Shuping¹

1. School of Intelligent Manufacturing and Control Engineering, Shanghai Polytechnic University, Shanghai 201209, China; 2. School of Computer and Information Engineering, Shanghai Polytechnic University, Shanghai 201209, China; 3. School of Internet of Things Engineering, Shanghai Business School, Shanghai 201400, China

Abstract: Objective To synthesize high-quality synthetic CT (sCT) images from cone beam CT (CBCT) by learning lung CT domain image features with a deep learning algorithm. **Methods** A sCT generation algorithm which employs perceptual loss-based cyclic generative adversarial network model (CycleGAN) and iterative registration was presented. CycleGAN model was trained to generate high-quality sCT images by combining perceptual loss and cycle consistency loss; and Elastix was used to register the generated sCT image and the planned CT (pCT) image, and iterate CycleGAN generator model. **Results** Experiments were conducted on the obtained pCT and CBCT data of 70 patients with lung tumors. From a quantitative perspective, the SSIM between sCT generated by the proposed algorithm and pCT was improved by 11.9% as compared with that between CBCT and pCT, increasing from 0.825 to 0.923; additionally, RMSE dropped from 110.97 HU to 78.62 HU, PSNR increased from 32.21 dB to 34.74 dB, and mutual information increased from 1.187 to 1.418. The visual evaluation revealed that the proposed algorithm greatly eliminated the scattering artifacts of CBCT slices, highlighted the bone structure, and repaired the soft tissue structure. The comparisons with U-CycleGAN, R-CycleGAN and CUT models confirmed the effectiveness of the proposed algorithm. **Conclusion** Using the proposed algorithm for sCT images generation can effectively reduce the dose error and structural error between CBCT and pCT, making it possible to apply the proposed algorithm to accurate dose calculations and assist doctors in clinical diagnosis.

Keywords: cone beam computed tomography; CycleGAN; perceptual loss; Elastix; image synthesis

【收稿日期】2024-06-26

【基金项目】上海市自然科学基金(20ZR1440300)

【作者简介】杨涛, 硕士研究生, 研究方向: 医学影像处理, E-mail: 1079741347@qq.com

【通信作者】黄淼, 副教授, 研究方向: 医学影像处理、深度学习、强化学习, E-mail: huangmiao@sspu.edu.cn

前言

放射性治疗是治疗恶性肿瘤的重要手段,其中图像引导放疗技术(Image-Guided Radiation Therapy, IGRT)成为主要趋势之一^[1]。IGRT是指治疗过程中的照射野根据图像精确追踪靶区,避免剂量分布不准确以及结构误差影响放疗精确度带来严重放疗并发症^[2-3]。锥形束CT(Cone Beam CT, CBCT)成为目前放疗中较为流行的成像模态^[4],CBCT与传统CT不同的是X射线源照射呈现锥形束,并采用二维平面状探测器来代替线状探测器,旋转一周即可以获得重建所需的所有投影数据。其对X射线的利用率更高,采集速度更快,辐射剂量更低。但由于其物理成像原理的特性,不可避免会受到散射噪声与截断投影的影响,导致图像HU值不准确,无法直接用于精确剂量评估^[5],限制了其应用于IGRT中的潜力。所以改善CBCT图像质量,精准评估放疗过程中的剂量误差与摆位误差是目前IGRT的热点^[6-8]。

近年来,有许多基于深度学习的方法应用于医学图像研究中并取得了不错的效果,特别在图像重建、器官分割、图像配准等领域。循环一致性对抗生成网络(CycleGAN)在其中大放异彩^[9],已经广泛用于不同医学模态转换,如MRI到CT^[10-12],CT到MRI^[13],CBCT到CT^[14-15],并且无需配对数据,能够分别提取不同医学图像域的风格信息和语义信息,生成新的图像。在CBCT到CT医学模态的转换中,有两种主流方式,图像弹性配准方式^[16-17]和图像生成方式^[18-19],配准生成的伪CT(synthetic CT, sCT)结构误差小,但图像质量明显低于合成的sCT。合成的sCT能够更显著地降低图像的散射伪影,提升图像质量,但会存在较明显的结构误差。也有学者结合两者迭代提炼解决了MR和CT错位的方法^[20],这也说明结合配准和生成的方式在CBCT与计划CT(planning CT, pCT)上有着不错的应用前景。

本文提出一种基于迭代配准的sCT合成算法,由生成模型与配准过程迭代提炼,生成高质量的sCT图像。生成模型在CycleGAN模型的基础上,在循环一

致性损失中融入感知损失^[21]。对生成的图像使用Elastix配准^[22],迭代合成高质量sCT图像。通过与流行的U-CycleGAN、R-CycleGAN和CUT模型进行定量、可视化评估对比,发现所提出的算法能对肺部CBCT图像进行结构误差校正,HU值校正,为使用CBCT实现精准肿瘤定位与图像引导放疗打下基础。

1 材料与方法

1.1 数据采集与处理

数据集来自2020~2021年的肺部肿瘤患者影像,经隐私脱敏处理的共有70例pCT和CBCT数据,其中男性患者47例,女性患者23例,年龄为43~74岁。pCT与CBCT图像体素均为1.0 mm×1.0 mm×1.0 mm, pCT图像尺寸为512×512,CBCT图像尺寸为410×410,各3753张。

第一步,使用Python的pydicom库提取出DICOM文件中的二维CBCT图像与CT图像切片,并对图像进行归一化操作。第二步,对收集数据进行清洗工作。主要清洗以下几种类型,如图1所示。CT强伪影会干扰模型训练效果,使生成图像学习到不利于改善图像质量的参数。并且成分缺失、具有多余组织信息的影像也会干扰到模型训练效果,这几种都需要进行筛选。CT切片具有多余床板信息,这是CT扫描中难以避免的结果,需要额外的处理。所以本文中使用传统图像处理方法,利用形态学操作和阈值分割方法生成掩膜,去除多余床板信息,掩膜生成过程如图2所示。第三步,将CBCT图像调准为与pCT图像统一的512×512尺寸大小,对比将pCT图像缩放至CBCT尺寸大小,减少pCT图像的信息丢失。后通过Elastix将CBCT与pCT进行刚性配准,使配对的图像在空间位置上对齐,在定量指标中得到一定改善。经过上述数据处理后,得到CBCT图像和pCT图像各2609张,将该数据集以8:2划分为训练集和测试集。最终获得2087张图像作为训练集,522张图像作为测试集。




图1 待清洗数据
Figure 1 Data to be cleaned




图2 图像掩膜生成流程
Figure 2 Image mask generation process

1.2 迭代配准合成sCT的算法

输入经过配准后的图像有利于提高模型图像质量^[23], 合成的高质量图像有利于提高Elastix的配准

精度^[24], 故本文提出一种基于迭代配准的sCT合成算法来进一步提升合成图像的质量, 迭代的流程如图3所示。

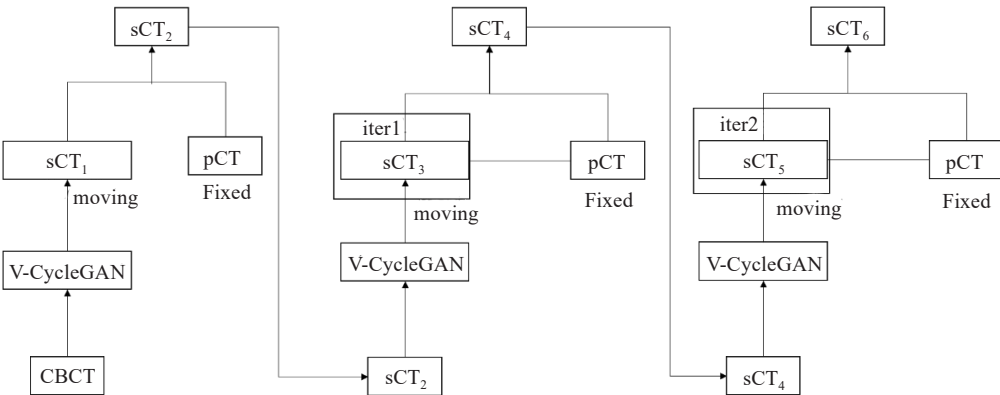


图3 网络迭代配准合成sCT过程
Figure 3 Network iterative registration and sCT generation

本算法将融合感知损失的 CycleGAN 模型与 Elastix 配准进行迭代。首先输入原始 CBCT 图像到生成模型合成 sCT_1 , 将生成的 sCT_1 与 pCT 进行弹性配准, sCT 作为移动图像, pCT 作为固定图像, 配准后生成 sCT_2 。 sCT_2 继续输入到生成模型中, 以此往复生成 sCT_{-iter1} 、 sCT_{-iter2} 等。

1.2.1 融合感知损失的 CycleGAN 网络 将本文的生成模型简称为 V_CycleGAN, 即在循环一致性损失中加入感知损失。前向循环与后向循环的网络结构一致, 生成器为 ResNet_9Blocks 网络, 鉴别器为 PatchGAN 网络, 整体结构如图4所示。

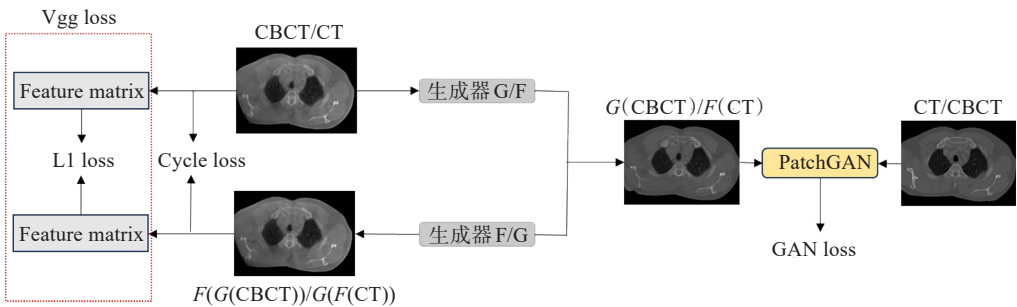


图4 V-CycleGAN整体网络结构
Figure 4 Overall architecture of V-CycleGAN

生成器结构如图 5 所示,输入图像尺寸为 512×512 的灰度图,先通过 ReflectionPad2d 填充图像,保持图像边缘信息完整性,再经过尺寸为 7×7 的卷积层。通过归一化层和 ReLU 激活函数后,开始下采样,使用带步长

的卷积层来代替池化层,经过两层下采样提取高维信息。再通过 9 个残差网络,减少数据的损耗,同时也增加了网络深度,解决了梯度消失的问题,避免丢失重要的信息。最后通过上采样层合成图像。

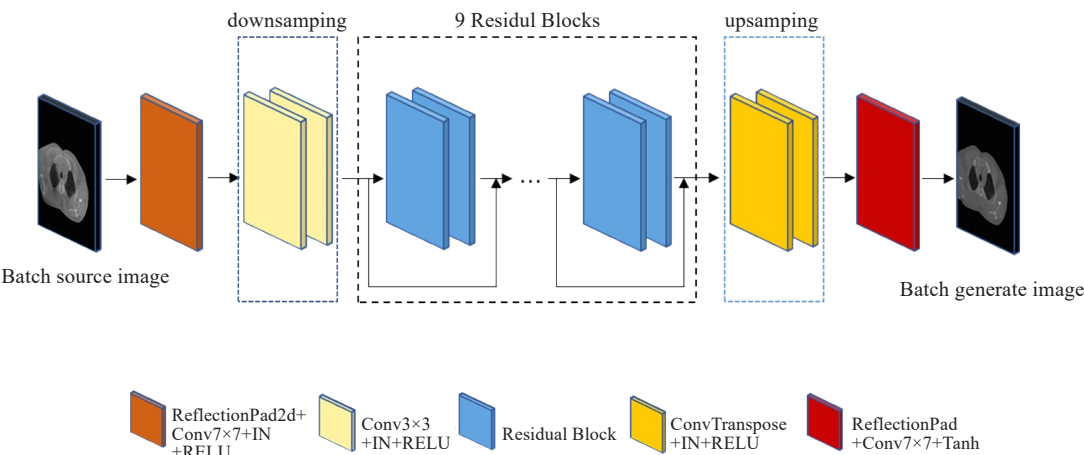


图 5 生成器网络结构
Figure 5 Network architecture of generator

本文使用尺寸为 70×70 的 PatchGAN 作为鉴别器,结构如图 6 所示,使用全卷积网络,与普通 GAN 的鉴别器将输入映射成一个实数不同,PatchGAN 输出一个矩阵。并且 PatchGAN 只对 Patch 规模的图像进行鉴别,本文中将原图像裁剪成 N 个 70×70 的 Patch,经过几层卷积层和 LeakyReLU 激活函数,分别判别这些 Patch 为真样本的概率,最终将结果概率平均化作为鉴别器的最终输出。并且 PatchGAN 的感受域更小,在训练时模型更注重图像的细节,更有利于图像质量提升。激活函数选择 LeakyReLU,并增加了多层滤波器,使鉴别器能够学习到更复杂的图像特征。

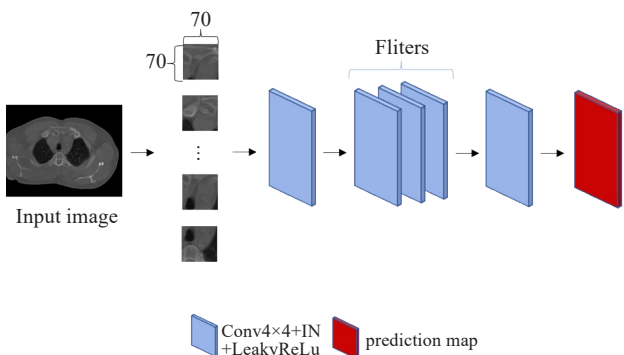


图 6 鉴别器网络结构
Figure 6 Network architecture of discriminator

V-CycleGAN所使用的损失函数及定义如下所示。

(1)GAN 损失。GAN 损失的核心在于最小最大博弈,用于衡量生成器和鉴别器的对抗关系,损失函数如下所示:

$$\min_G \max_D V(D, G) = E_{x \sim p_{\text{data}}(x)} [\log D(x)] + E_{z \sim p_z(z)} [\log (1 - D(G(z)))] \quad (1)$$

(2)循环一致性损失。GAN 训练只能学习到映射关系,从源域的概率分布映射到目标域的概率发布,在没有任何约束的情况下会有无穷多种映射关系,后面使用 \rightarrow 符号指代映射关系。要使得 CBCT \rightarrow CT,CT \rightarrow CBCT 有着配对的意义,需要在图像域转换的过程中,满足循环一致的特性,即 CBCT \rightarrow G(CT) \rightarrow F(G(CBCT))=CT,G 为 CBCT \rightarrow CT 的生成器,F 为 sCT \rightarrow CBCT 的生成器。反之亦然,即能够通过两次变换,转换为与源域类似的概率分布。因此引入了循环一致性损失,定义如下:

$$L_{\text{cycle}}(G, F) = E_{\text{ct} \sim p_{\text{data}}(\text{ct})} [\|G(F(\text{CT})) - \text{CT}\|_1] + E_{\text{cbct} \sim p_{\text{data}}(\text{cbct})} [\|F(G(\text{CBCT})) - \text{CBCT}\|_1] \quad (2)$$

(3)L1 损失。在大多数情况下,L1 损失能够捕捉低频信息、保证图像低层特征的准确性。定义如下:

$$L_{\text{L1}}(G) = E_{x \sim p_{\text{data}}(x), y \sim p_{\text{data}}(y)} [\|G(x) - y\|_1] \quad (3)$$

(4)感知损失。研究表明,在计算机视觉训练任

务中结合感知损失,可以达到更好的效果。像素级别的损失,在像素仅偏离几个像素点也会造成巨大的差异。对于CT图像而言,图像特征十分重要,MSE损失会使生成图像过于平滑,丢失纹理细节^[25]。感知损失需要计算图像的高级语义特征差异。本文使用在ImageNet数据集预训练的VGG19网络^[26],能够捕获图像中的高层特征,再通过高层特征计算L1损失,由此获得图像间的感知损失。可以更有效地约束循环生成图像与原图像的高级语义特征一致性,同时也保有图像底层特征的损失。感知损失在本模型中定义如下:

$$L_{\text{perc}}(G, F) = E_{\text{cbct}, \text{ct} \sim p_{\text{data}}(\text{cbct}, \text{ct})} \left[\left\| V(F(G(\text{CBCT}))) - V(\text{CBCT}) \right\|_1 + \left\| V(G(F(\text{CT}))) - V(\text{CT}) \right\|_1 \right] \quad (4)$$

(5)总损失函数。V-CycleGan的总损失函数定义如下:

$$L(G, F, D_{\text{cbct}}, D_{\text{ct}}) = L_{\text{Gan}}(G, D_{\text{ct}}, X, Y) +$$

$$L_{\text{Gan}}(F, D_{\text{cbct}}, X, Y) + \lambda_1 L_{\text{cycle}}(G, F) + \lambda_2 L_{\text{vgg19}}(G, F) \quad (5)$$

1.2.2 Elastix 医学图像配准 Elastix是流行的开源图像配准工具,能够将一幅移动图像的空间坐标系变换成固定图像的空间坐标系,以便它们之间的特征对齐,在医学图像配准方面具有较高的配准精度。本文使用Python中的PyElastix库来进行图像间弹性配准。配准具体参数如下,变换模型选用BSpline-Transform,度量函数选用改进的Mattes互信息,使用自适应随机梯度下降的优化器,计算互信息直方图的bin数量为2,图像采样器选用随即坐标采样器,计算度量函数的空间采样点数量为2048,每次迭代时重新选择采样点,优化过程中的最大迭代次数为300,最终输出的变换网格的体素间隔为15。

1.3 训练过程

使用V-CycleGAN与R-CycleGAN进行消融实验得到感知损失对模型效果的提升,再将V-CycleGAN与U-CycleGAN、CUT模型进行对比实验,V-CycleGAN、R-CycleGAN、U-CycleGAN、CUT网络统一训练了200个epochs。为了更好地进行消融实验及对比实验,V-CycleGAN、R-CycleGAN、U-CycleGAN网络均采用相同的训练参数和策略。网络模型基于PyTorch实现,在优化器方面均采用Adam优化器,并在NVIDIA GeForce RTX 4090 GPU(24G)上进行训练。Adam优化器的初始学习率lr设定分别为 $1e-4$ 和 $1e-5$,动量超参数 β_1 和 β_2 分别设置为0.5和0.99,网络总共训练200个epochs,前100个epochs的学习率固定为0.0002,后100个epochs的学习率线性衰减为0。所有权值随机正常初始化,平均值为0,标准偏差为0.02,batchsize设置为8。

2 结果

实验结果通过可视化评估与定量评估的方式呈现,可视化评估的方式包括sCT与pCT间的差分图分析和放大ROI区域对比,差分图运算公式如式(6)所示,Gray代表灰度值。

$$\text{Gray}_{\text{diff}} = \left| \text{Gray}_{\text{pCT}} - \text{Gray}_{\text{sCT/CBCT}} \right| \quad (6)$$

定量评估使用箱线图分析不同模型生成的sCT图像在各定量指标上的差异。

2.1 定量指标

对生成图像进行定量的评价,本文研究选取结构相似度(SSIM)、峰值信噪比(PSNR)、均方绝对误差(RMSE)、互信息(MI)来评价模型的效果。各指标定义如下所示:

$$\text{SSIM}(x, y) = \frac{(2\mu_x \mu_y + c_1)(\mu_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (7)$$

$$\text{PSNR} = 10 \log_{10} \left(\frac{Q^2}{\|I_{\text{pCT}} - I_{\text{sCT}}\|^2 / N} \right) \quad (8)$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N |I_{\text{sCT},i} - I_{\text{pCT},i}|^2} \quad (9)$$

$$\text{MI} = \sum_{\text{sCT}, \text{pCT}} p(\text{sCT}, \text{pCT}) \log \frac{p(\text{sCT}, \text{pCT})}{p(\text{sCT})p(\text{pCT})} \quad (10)$$

2.2 对比实验

2.2.1 生成模型间的对比实验 图7展示了两位患者的肺部图像切片原图像及不同模型生成的sCT图像,ROI区域显示了图像中软组织、骨组织等细节。图7上方切片中CBCT图像具有严重的散射伪影,HU值受干扰,CUT模型图像并未能消除伪影并受到了干扰,导致部分组织扭曲。U-CycleGAN和R-CycleGAN在一定程度上削弱了伪影,但仍保留散射伪影的痕迹,V-CycleGAN几乎消除了散射伪影的影响,并且结构误差更小。图7下方切片中CUT与U-CycleGAN模型在骨组织伪影去除方面表现更好,软组织修复方面较差,V-CycleGAN与R-CycleGAN模型在软组织修复方面表现较好。迭代配准合成的第三代模型,简称为V-CycleGAN(iter3),在骨组织及软组织均表现最优,并且与pCT的结构最为接近。

如图8所示,第一行为pCT、CBCT和各模型生成sCT图像。第二行为各图像与pCT的差分图,差分图通过计算sCT与pCT图像灰度值间的绝对误差得到,越接近黑色,表示合成图像的HU值更准确。CBCT




图 7 不同模型生成的sCT图像及 ROI 区域细节对比
Figure 7 Comparison of sCT images generated by different models and ROI details

差分图像显示残留较多,CUT左侧HU值较CBCT更准确,U-CycleGAN整体HU值准确度均劣于CBCT,R-CycleGAN与V-CycleGAN差分图像内部残留更少,但仍存在边缘的误差,V-CycleGAN(iter3)HU值更加接近pCT,几乎无轮廓边缘误差。根据一系列的定量指标对模型效果进行定量评估,使用箱线图可视化量化结果,如图9所示。各模型均在各指标中得到一定提升,通过与其他模型对比实验得出,

V-CycleGAN在各指标都明显优于其他模型。基于迭代配准的sCT合成算法V-CycleGAN(iter3)与V-CycleGAN对比,可以发现,经过配准合成后的图像在各指标上有显著提升,如表1所示,SSIM指标从0.894提升到0.923,PNSR从33.71 dB提升到34.74 dB, RMSE由86.99 HU降到了78.62 HU,MI从1.286提升到1.418。




图 8 不同模型生成的sCT图像与pCT的差分图对比
Figure 8 Comparison of difference maps between sCT images generated by different models and pCT

2.2.2 迭代配准合成算法不同 iter 间的对比实验 由上面分析可得融合了感知损失的V-CycleGAN模型合成sCT的图像优于其他模型合成的sCT图像,并且基于此的迭代配准的 iter-3sCT又进一步的提高了质量。现对该迭代方法生成的不同sCT进行定量评估。首先将V-CycleGAN模型合成的sCT与Elastix迭代配准合成4次,并将不同 iter 的sCT图像进行定

量分析的对比,如表1所示。Iter1的提升效果相对显著,提升幅度较大,Iter2,Iter3相对上一个 iter 也有提升效果,提升幅度较小。Iter4相对于Iter3,SSIM、MI几乎持平,RMSE值增加表现甚至不如 iter2。说明该方法并不能一直稳定地提升合成sCT质量,达到一定 iter 时质量可能会有所下降。

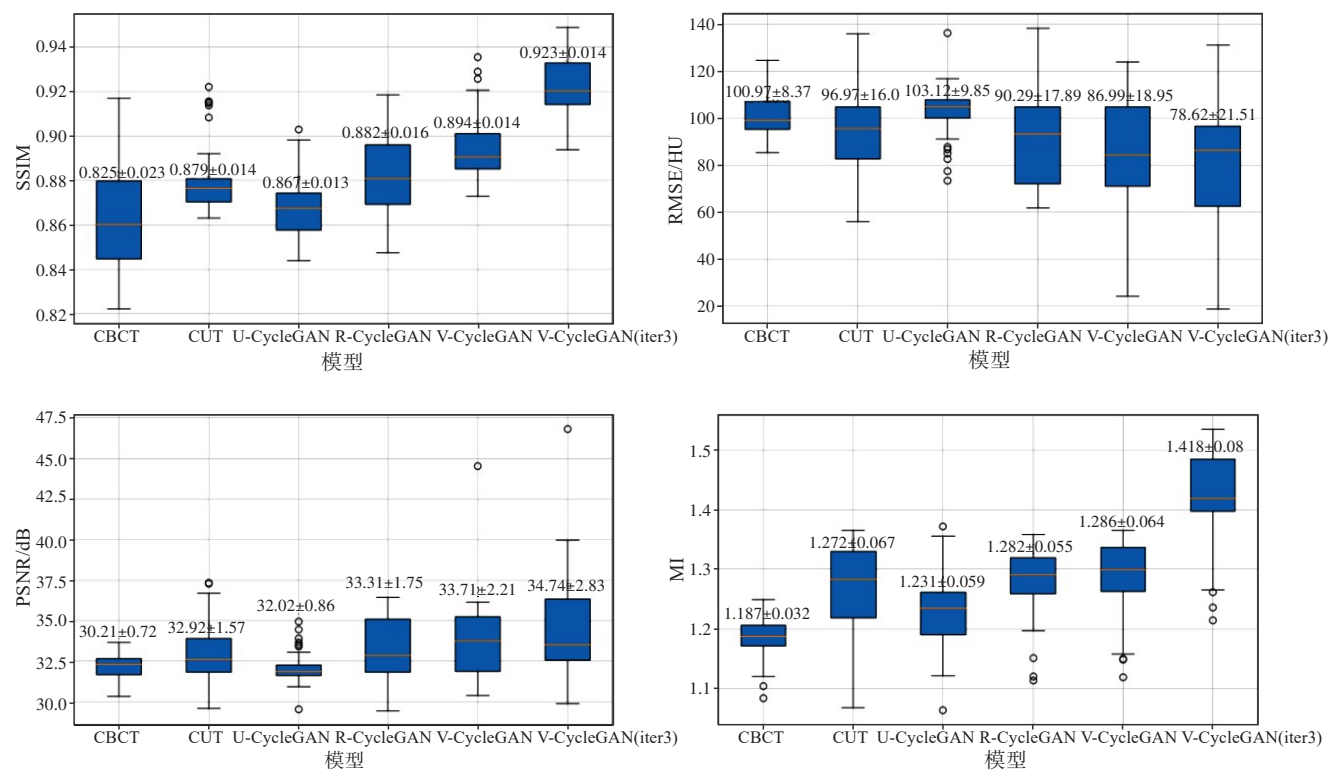


图9 各模型定量指标对比

Figure 9 Comparison of quantitative indicators

表1 迭代配准合成方法中不同iter间的定量评估

Table 1 Quantitative evaluation among different iter in iterative registration synthesis methods

方法	SSIM	PSNR/dB	RMSE/HU	MI
V-CycleGAN	0.894±0.014	33.71±2.21	86.99±18.95	1.286±0.064
Iter1	0.902±0.015	34.12±2.35	82.37±19.25	1.342±0.077
Iter2	0.915±0.014	34.33±2.79	80.65±21.25	1.376±0.074
Iter3	0.923±0.014	34.74±2.83	78.62±21.51	1.418±0.080
Iter4	0.922±0.016	34.40±2.95	80.73±22.17	1.420±0.083

2.3 消融实验

2.3.1 V-CycleGAN 和 R-CycleGAN 的消融实验 V-CycleGAN 和 R-CycleGAN 同样使用 ResNet 作为生成器,但 V-CycleGAN 在循环一致性损失的基础上增加了感知损失。如表2所示,在定量评估中,V-CycleGAN 生成的 sCT 与 pCT 间的 SSIM 相比 R-CycleGAN 与 pCT 间的 SSIM 从 0.882 提升到 0.894,PNR 从 33.31 dB 提升到 33.71 dB, RMSE 由 90.29 HU 降到了 86.99 HU, MI 从 1.282 提升到 1.286。与 pCT 的差分图与放大细节对比中,可以得出 V-CycleGAN 的 HU 值更准确,更大程度上削弱了原图像中的散射伪影。通过该消融实验得出感知损失提升了生成模型的性能。

2.3.2 迭代配准合成算法与 V-CycleGAN 间的消融实验 迭代配准合成算法在 V-CycleGAN 的基础上加入

了 Elastix 配准的模块,如图 3 结构,迭代生成不同 iter 的 sCT 图像。将 V-CycleGAN 生成的 sCT 与不同 iter 的 sCT 进行对比,在表 1 中,迭代配准合成算法的各指标均优于 V-CycleGAN,可以得出迭代配准合成算法进一步提升了 sCT 图像的质量,在兼顾结构误差的情况下同时能保证精准的 HU 值。

3 结 论

本研究提出了一种基于迭代配准合成 sCT 的算法,使用融合感知损失的 CycleGAN 模型与 Elastix 的迭代提炼实现高质量 sCT 的生成。通过对实验数据的可视化与定量评估,分析对比了合成 sCT 的不同模型间的性能差异。定性评估显示本文模型合成 sCT 图像在消除散射伪影,以及图像软组织修复方面有着一定优势,结

表2 生成模型间定量评估
Table 2 Quantitative evaluation of different models

模型	SSIM	PSNR/dB	RMSE/HU	MI
CBCT	0.825±0.023	32.21±0.72	100.97±8.37	1.187±0.032
CUT	0.879±0.014	32.92±1.57	96.97±16.00	1.272±0.067
U-CycleGAN	0.867±0.013	32.02±0.86	103.12±9.85	1.231±0.059
R-CycleGAN	0.882±0.016	33.31±1.75	90.29±17.89	1.282±0.055
V-CycleGAN	0.894±0.014	33.71±2.21	86.99±18.95	1.286±0.064

构误差更小。定量评估显示模型在很大程度上校正了CBCT的HU值,减小了剂量误差。本文针对CBCT图像引导放疗取得一定的进展,但仍存在一些局限性。首先,研究方法仅基于肺部的CBCT图像进行训练及评估,不同部位的CT图像的噪声分布与散射特性不同,可能需要对模型进行针对性的改进以及临床验证。其次,样本数量有限导致模型的泛化能力与稳定性存在不足。并且,本研究只用到二维图像切片的信息,并未利用到图像切片间的层间信息。

综上所述,本研究提出的算法实现CBCT合成sCT图像,有效提高sCT的图像质量,并抑制了CBCT图像产生的散射伪影,在剂量和结构上更加准确。在未来的研究中可将数据拓展成三维格式,利用三维特征信息增强算法的性能。并可将传统的Elastix替换为基于深度学习的配准模型,可以大幅减少图像配准及合成的时间,并且可以基于不同部位进行模型实验。

【参考文献】

[1] Zelefsky MJ, Kollmeier M, Cox B, et al. Improved clinical outcomes with high-dose image guided radiotherapy compared with non-IGRT for the treatment of clinically localized prostate cancer[J]. *Int J Radiat Oncol Biol Phys*, 2012, 84(1): 125-129.

[2] Soussain C, Ricard D, Fike JR, et al. CNS complications of radiotherapy and chemotherapy[J]. *Lancet*, 2009, 374(9701): 1639-1651.

[3] 丘敏敏, 钟嘉健, 李敏, 等. 鼻咽癌调强放疗摆位不同配准方式对实际剂量学的影响[J]. *中国医疗设备*, 2020, 35(11): 94-97.

Qiu MM, Zhong JJ, Li M, et al. Different registration methods for volumetric modulated arc therapy in the nasopharyngeal carcinoma: effect on dose distribution[J]. *China Medical Devices*, 2020, 35(11): 94-97.

[4] Scarfe WC, Farman AG. What is cone-beam CT and how does it work? [J]. *Dent Clin North Am*, 2008, 52(4): 707-730.

[5] Yang Y, Schreiber E, Li TF, et al. Evaluation of on-board kV cone beam CT (CBCT)-based dose calculation[J]. *Phys Med Biol*, 2007, 52(3): 685-705.

[6] Hu YM, Xu S, Li BY, et al. Improving the accuracy of bone mineral density using a multisource CBCT[J]. *Sci Rep*, 2024, 14(1): 3887.

[7] Wang H, Liu X, Kong LK, et al. Improving CBCT image quality to the CT level using RegGAN in esophageal cancer adaptive radiotherapy [J]. *Strahlenther Onkol*, 2023, 199(5): 485-497.

[8] Urban R, Haluzová S, Strunga M, et al. AI-assisted CBCT data management in modern dental practice: benefits, limitations and innovations[J]. *Electronics*, 2023, 12(7): 1710.

[9] Zhu JY, Park T, Isola P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks [C]//2017 IEEE International Conference on Computer Vision (ICCV). Piscataway, NJ, USA: IEEE, 2017: 2242-2251.

[10] Lei Y, Harms J, Wang TH, et al. MRI-only based synthetic CT generation using dense cycle consistent generative adversarial

networks[J]. *Med Phys*, 2019, 46(8): 3565-3581.

[11] Sun HF, Xi QY, Fan RB, et al. Synthesis of pseudo-CT images from pelvic MRI images based on an MD-CycleGAN model for radiotherapy[J]. *Phys Med Biol*, 2022, 67(3): 035006.

[12] Dong X, Lei Y, Tian SB, et al. Synthetic MRI-aided multi-organ segmentation on male pelvic CT using cycle consistent deep attention network[J]. *Radiother Oncol*, 2019, 141: 192-199.

[13] Kalantar R, Messiou C, Winfield JM, et al. CT-based pelvic T₁-weighted MR image synthesis using UNet, UNet++ and cycle-consistent generative adversarial network (cycle-GAN) [J]. *Front Oncol*, 2021, 11: 665807.

[14] Liang X, Chen LY, Nguyen D, et al. Generating synthesized computed tomography (CT) from cone-beam computed tomography (CBCT) using CycleGAN for adaptive radiation therapy[J]. *Phys Med Biol*, 2019, 64(12): 125002.

[15] 吴书裕, 王伟, 阳露, 等. 基于自监督生成对抗网络的锥形束CT合成伪CT研究[J]. *中国医学物理学杂志*, 2023, 40(11): 1356-1361.

Wu SY, Wang W, Yang L, et al. Synthetic CT generation from CBCT images using self-attention generative adversarial network [J]. *Chinese Journal of Medical Physics*, 2023, 40(11): 1356-1361.

[16] 兰其斌, 黄立勤. 基于注意力机制无监督心脏超声序列图像配准[J]. *福州大学学报(自然科学版)*, 2023, 51(1): 41-48.

Lan QB, Huang LQ. Unsupervised image registration of cardiac ultrasound sequences based on channel attention[J]. *Journal of Fuzhou University (Natural Science Edition)*, 2023, 51(1): 41-48.

[17] 智强. 基于无监督非刚性的三维脑部图像配准算法研究[D]. 哈尔滨: 哈尔滨理工大学, 2023.

Zhi Q. Research on non-rigid 3D brain image registration algorithm based on unsupervised[D]. Harbin: Harbin University of Science and Technology, 2023.

[18] 吴新红, 王江涛, 唐巍, 等. 基于DenseCUT网络由头部锥形束CT图像生成合成CT图像[J]. *中国医学物理学杂志*, 2023, 40(3): 313-319.

Wu XH, Wang JT, Tang W, et al. Generation of synthetic CT image from head cone beam CT image using DenseCUT[J]. *Chinese Journal of Medical Physics*, 2023, 40(3): 313-319.

[19] 张泽茹, 李兆同, 刘良友, 等. 融合感知损失的深度学习在常规MR图像转换的研究[J]. *中国医学物理学杂志*, 2021, 38(2): 178-185.

Zhang ZR, Li ZT, Liu LY, et al. Application of deep learning with perceptual loss in conventional MR image translation[J]. *Chinese Journal of Medical Physics*, 2021, 38(2): 178-185.

[20] Zhou LY, Ni XY, Kong Y, et al. Mitigating misalignment in MRI-to-CT synthesis for improved synthetic CT generation: an iterative refinement and knowledge distillation approach[J]. *Phys Med Biol*, 2023, 68(24): 245020.

[21] Rad MS, Bozorgtabar B, Marti UV, et al. SROBB: targeted perceptual loss for single image super-resolution [C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway, NJ, USA: IEEE, 2019: 2710-2719.

[22] Klein S, Staring M, Murphy K, et al. Elastix: a toolbox for intensity-based medical image registration[J]. *IEEE Trans Med Imaging*, 2010, 29(1): 196-205.

[23] Azam MA, Khan KB, Ahmad M, et al. Multimodal medical image registration and fusion for quality enhancement[J]. *Comput Mater Contin*, 2021, 68(1): 821-840.

[24] Cao X, Yang J, Gao Y, et al. Region-adaptive deformable registration of CT/MRI pelvic images via learning-based image synthesis[J]. *IEEE Trans Image Process*, 2018, 27(7): 3500-3512.

[25] Li M, Hsu W, Xie XD, et al. SACNN: self-attention convolutional neural network for low-dose CT denoising with self-supervised perceptual loss network[J]. *IEEE Trans Med Imaging*, 2020, 39(7): 2289-2301.

[26] Rajinikanth V, Joseph Raj AN, Thanaraj KP, et al. A customized VGG19 network with concatenation of deep and handcrafted features for brain tumor detection[J]. *Appl Sci*, 2020, 10(10): 3429.

(编辑: 薛泽玲)