

## 基于自监督生成对抗网络的锥形束CT合成伪CT研究

吴书裕<sup>1</sup>, 王伟<sup>1</sup>, 阳露<sup>1</sup>, 余辉<sup>1</sup>, 周承<sup>2</sup>, 梅颖洁<sup>3</sup>

1. 广州医科大学附属肿瘤医院放疗科, 广东 广州 510095; 2. 柳州市人民医院设备科, 广西 柳州 545006; 3. 广东省人民医院放射科, 广东 广州 510080

**【摘要】目的:**旨在研究自监督生成对抗网络(SAGAN)在锥形束CT(CBCT)合成伪CT(sCT)中的应用,以解决CBCT图像质量问题,提高图像引导放疗的准确性。**方法:**收集58例头颈鳞癌患者CBCT和计划CT(pCT),采用U-Net结构和马尔科夫鉴别器构建SAGAN网络,并引入自注意力机制。使用WGAN-GP损失函数进行对抗训练,学习CBCT模态的空间映射和密度映射特性,增强CBCT图像特征表达和sCT的合成精度。分别对SAGAN和Res-Unet基线模型合成的sCT图像与原始pCT进行定性和定量分析,验证模型性能。**结果:**定性结果显示,SAGAN和Res-Unet合成的sCT均有效抑制伪影,SAGAN合成的sCT更接近pCT,误差较小。定量评价结果表明,SAGAN的平均绝对误差、结构相似性指数和峰值信噪比优于Res-Unet基线模型,特别在软组织方面表现更佳,差异有统计学意义( $P<0.05$ )。SAGAN合成的sCT在体部、骨组织、软组织的线性回归斜率分别为0.956、0.959、0.839,CT值校正能力优于对比方法。**结论:**SAGAN模型在基于CBCT的sCT合成研究具有更优的CT值校正能力和图像转换质量,为图像引导放疗提供可靠依据,提高放疗精确性。

**【关键词】**锥形束CT;合成CT;自监督机制;生成对抗网络;图像引导放疗

**【中图分类号】**R318;R811.1

**【文献标志码】**A

**【文章编号】**1005-202X(2023)11-1356-06

## Synthetic CT generation from CBCT images using self-attention generative adversarial network

WU Shuyu<sup>1</sup>, WANG Wei<sup>1</sup>, YANG Lu<sup>1</sup>, YU Hui<sup>1</sup>, ZHOU Cheng<sup>2</sup>, MEI Yingjie<sup>3</sup>

1. Department of Radiotherapy, Cancer Center of Guangzhou Medical University, Guangzhou 510095, China; 2. Department of Equipment, Liuzhou People's Hospital, Liuzhou 545006, China; 3. Department of Radiology, Guangdong Provincial People's Hospital, Guangzhou 510080, China

**Abstract: Objective** To generate synthetic CT (sCT) from cone-beam computed tomography (CBCT) images using the self-attention generative adversarial network (SAGAN) for improving CBCT image quality and enhancing the accuracy of image-guided radiotherapy. **Methods** The CBCT and planning CT (pCT) were collected from 58 cases of head and neck squamous cell carcinoma. SAGAN was constructed using U-Net architecture and a Markovian discriminator, incorporating a self-attention mechanism. WGAN-GP loss function was utilized for adversarial training to learn the spatial and density mapping characteristics of CBCT modality, which enhances feature expression in CBCT images and improves sCT generation accuracy. Qualitative and quantitative analyses were conducted to compare the sCT generated using SAGAN or Res-Unet (sCT<sub>SAGAN</sub> or sCT<sub>Res-Unet</sub>) with the original pCT for verifying model performance. **Results** The qualitative evaluation showed that both SAGAN and Res-Unet effectively suppressed artifacts, while sCT<sub>SAGAN</sub> closely resembled pCT, with smaller errors. The quantitative analysis demonstrated that SAGAN outperformed Res-Unet in mean absolute error, structural similarity index and peak signal-to-noise ratio, particularly in soft tissue areas ( $P<0.05$ ). sCT<sub>SAGAN</sub> had linear regression slopes of 0.956, 0.959 and 0.839 for body, bone tissue and soft tissues, respectively, indicating superior CT number calibration capability as compared with the other methods. **Conclusion** SAGAN demonstrated superior CT number calibration capability and image generation quality in CBCT-based synthetic CT generation, providing a reliable basis for image-guided radiotherapy and improving treatment accuracy.

**Keywords:** cone-beam CT; synthetic CT; self-attention mechanism; generative adversarial network; image-guided radiotherapy

**【收稿日期】**2023-06-12

**【基金项目】**广东省自然科学基金(2020A1515110577)

**【作者简介】**吴书裕,博士,研究方向:医学图像处理与肿瘤放射物理,E-mail: wsyeasy@outlook.com

**【通信作者】**梅颖洁,博士,研究方向:医学成像技术与图像处理,E-mail: yingjie.mei@gmail.com

## 前言

锥形束CT(CBCT)是目前图像引导放疗技术(IGRT)最为普遍的成像模式<sup>[1-2]</sup>。在放射治疗实施过程中,通过获取日常的CBCT图像与模拟定位CT图像进行定性评估,观测对应的解剖结构变化和摆位误差<sup>[3-6]</sup>。然而,CBCT成像过程中会受到严重的散射噪声和截断投影等影响,使其图像质量欠佳和伪影严重,无法直接用于再程放疗的计划设计或剂量评估<sup>[7-8]</sup>。如何提高CBCT图像质量,以评估放疗实施过程的摆位误差和剂量误差,进而实现个性化适应性剂量调整,是目前图像引导放射治疗的研究热点<sup>[9]</sup>。

基于CBCT的伪CT(synthetic CT, sCT)转换是提升现有IGRT设备最重要的技术手段,其经典的处理方法包括:基于密度校准系数的CT值映射,各像素按照校准系数进行统一的变化,该方法较简单,但忽略了不同区域伪影噪声对像素值的干扰,转换精度较差<sup>[10-11]</sup>;基于类别密度映射的方法,按不同组织类别的先验密度值进行CT值的数值映射,该方法忽略不同组织的密度差异,且对器官分割精度要求较高<sup>[12-13]</sup>;基于不同模态的图像配准,利用分次治疗CBCT和定位CT两种图像模态进行配准,将CT值映射至CBCT空间中,该方法严重依赖于配准精度特别是非刚性配准精度<sup>[14-15]</sup>。近年来研究学者将深度学习的图像生成技术应用于医学领域,通过构建和训练对应的映射模型,可直接学习CBCT模态分布特性,合成所得sCT图像的成像质量有一定的改善<sup>[16-17]</sup>。然而,上述基于深度学习的sCT合成模型仍存在如下不足:相关模型对训练数据的依赖性较高,仍需要大量数据来进行训练和泛化<sup>[16, 18-19]</sup>。其次,对于头颈部CBCT具有复杂结构变化的区域,传统模型可能难以捕捉非局部特征来实现高质量的图像转换。

基于此,本研究提出基于自监督生成对抗网络(Self-Attention Generative Adversarial Network, SAGAN)实现基于CBCT的sCT合成。该方法利用少量的CBCT/CT训练数据进行训练,在转成模型探究CBCT的物理成像特性过程中,构建相关的自适应机制模块,以提高sCT的转换精度和鲁棒性。模型将通过头颈部CBCT进行定性和定量评估,以评价该方法在临床放疗的应用前景。

## 1 资料与方法

### 1.1 数据采集与处理

本研究回顾性收集广州医科大学附属肿瘤医院的头颈鳞癌患者58例,所有患者均在模拟定位期间进行标准化的计划CT图像(planning CT, pCT)扫描,在首次IGRT放疗中收集对应的CBCT影像。上述对应图像采集时均采用仰卧位并以头颈肩面罩固定。pCT采用飞利浦大孔径定位CT扫描,扫描参数为120 kV/

280 mAs,图像扫描范围为颅顶到锁骨下缘,重建体素尺寸为:0.97 mm×0.97 mm×3.00 mm。CBCT采用医科达 Synergy 的XVI扫描,扫描参数设定为140 kV/280 mAs,以计划原点作为图像扫描中心,重建体素尺寸为:0.97 mm×0.97 mm×3.00 mm。

对所述的pCT和CBCT图像进行相关的预处理操作:首先,将pCT作为参考图像,通过MIM 6.2.6系统进行图像配准,以修正刚性的摆位误差;然后利用阈值分割、形态学处理等图像算法转换CT和CBCT图像的体部轮廓,并将轮廓外的像素置为0,去除无关背景信息;其次,通过计算CBCT成像FOV(Field of View)的最大边界框,删除锥角层面的图像,并将图像尺寸调整至256×256;最后,去除头颈部常存在定位铅点、假牙等异常体素值,并对CBCT和pCT的体素值映射至0~1。

### 1.2 模型设计

本研究提出的SAGAN包括两个部分:基于自注意力机制的生成器和判别器。生成器采用经典的U-Net<sup>[20]</sup>作为基础框架(图1),其中Encoder编码器部分负责CBCT图像域的不同尺度不同深度的特征提取,由5层特征提取网络组成,每一网络采用2个卷积block和最大池化层级级联组成。所述卷积block采用多通道卷积层、BatchNorm层和ReLU激活层串联而成确保网络的梯度收敛性和非线性度。Decoder译码器部分则负责将CBCT图像不同尺度和深度的特征图进行整合、编码,最终合成对应的sCT图像,该部分由4层特征编码网络组成,每一特征提取网络采用上采样层、自注意力层、拼接层和2个卷积block级联组成。上采样层的采样率为2倍,实现图像维度的恢复。自注意模块将Decoder下层的特征图和Encoder同一层特征图的非局部特征的加权融合,并利用拼接层进行拼接处理,继而通过2个卷积block实现特征编码,最终合成对应层面的sCT图像。

传统的端到端生成网络常用的基于像素级别的损失函数会造成合成图像高频信息丢失、边缘模糊、细节丢失等问题。本研究引入马尔科夫鉴别器(patchGAN)作为SAGAN的判别器,用于判别输入图像为CT的真伪程度<sup>[21]</sup>。该鉴别器则利用全卷积网络将待检测图像分成尺寸为7×7的图像块,对逐一图像块的真伪程度进行判别,从而映射成二值矩阵。该二值矩阵有助于增强模型对CT图像的高频信息和局部感知能力。这种可学习的鉴别器可作为生成器的损失函数项,使SAGAN能够有效利用局部信息,使转换的sCT图像在高频信息和边缘细节更逼真。

损失函数方面,本研究通过构建平均绝对误差(MAE)和结构相似性指数(SSIM)作为生成器损失函数。具体公式见式(1)。

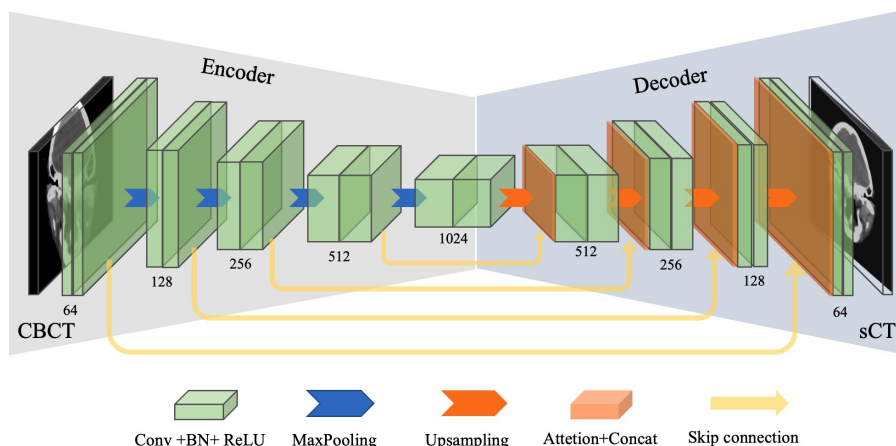


图1 基于自注意力的SAGAN生成器网络框架

Figure 1 Framework of the generator of self-attention generative adversarial network (SAGAN)

$$L_{\text{gen}} = \lambda \cdot \text{MAE}(\text{sCT}, \text{pCT}) + (1 - \lambda) \cdot (1 - \text{SSIM}(\text{sCT}, \text{pCT})) \quad (1)$$

其中,  $\lambda$  表示 MAE 和 SSIM 损失函数的调整权重因子, 在本研究中  $\lambda$  设定为 0.5。MAE 衡量了合成图像和真实图像之间的像素级别差异, SSIM 用于评估合成图像和真实图像之间的结构相似性:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |x_i - y_i| \quad (2)$$

$$\text{SSIM} = \frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1} \cdot \frac{2\sigma_{xy} + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \quad (3)$$

其中,  $n$  表示样本数量,  $x_i$  表示 pCT 影像,  $y_i$  表示 sCT。  $\mu_x$  和  $\mu_y$  表示图像  $x$  和  $y$  的均值,  $\sigma_x$  和  $\sigma_y$  表示图像  $x$  和  $y$  的方差,  $\sigma_{xy}$  表示图像  $x$  和  $y$  的协方差。  $C_1$  和  $C_2$  是常数项, 在本研究中分别设定为  $1e-4$  和  $9e-4$ 。

鉴别器则使用 WGAN-GP (Wasserstein GAN with Gradient Penalty) 损失函数, 进行反向传播优化<sup>[22]</sup>, 其公式为:

$$L_{\text{dis}} = -E[D(\text{pCT})] + E[D(\text{sCT})] + \lambda_{\text{GP}} \cdot E\left[\left(\left\|\nabla_{\hat{x}} D(\hat{x})\right\|_2 - 1\right)^2\right] \quad (4)$$

其中,  $D(\text{pCT})$  和  $D(\text{sCT})$  分别表示判别器对真实 CT 图像和 sCT 图像的判别结果;  $\lambda_{\text{GP}}$  是梯度惩罚的系数;  $\nabla_{\hat{x}} D(\hat{x})$  表示对输入图像  $\hat{x}$  的梯度。 WGAN-GP 的损失函数主要通过最大化 pCT 的判别结果和最小化 sCT 的判别结果来实现生成器的对抗训练。梯度惩罚项则用于稳定训练过程, 防止梯度消失或爆炸的问题, 从而提高生成器和判别器的训练稳定性。

### 1.3 自注意力机制

在本研究中采用 Non-local block 作为自注意力模块<sup>[23]</sup>, 其公式如下所示:

$$\text{NonLocal}(x) = \text{softmax}\left(\frac{(\theta(x) \cdot \phi(x))^T}{\sqrt{d_k}}\right) \cdot g(x) \quad (5)$$

其中,  $x$  表示输入特征图,  $\theta(x)$ 、 $\phi(x)$  和  $g(x)$  分别表示通过卷积操作得到的特征映射;  $d_k$  表示特征映射的维度。函数中的 softmax 操作对  $(\theta(x) \cdot \phi(x))^T$  进行了归一化, 以获得注意力权重。最后, 注意力权重与  $g(x)$  进行加权相乘, 得到 Non-local block 的输出。通过  $\theta(x)$ 、 $\phi(x)$  来获得特征图的全局空间信息, 来增强 sCT 合成模型的非局部特征处理的性能, 有助于提高网络对 CBCT 的散射伪影识别和降噪能力。

上述生成器 Decoder 的每一层, 既保留同一层面 Encoder 的精细特征图, 又引入上述 Non-local 自注意力模块来增强生成器的非局部特征表达和处理能力, 从而更好地捕捉图像特征中的长依赖关系。

### 1.4 网络训练参数

本研究将 CBCT 和对应的 pCT 输入 SAGAN 网络的生成器中进行训练, 同时将生成器合成的 sCT 和 pCT 图像输入到判别器中进行对抗训练。针对优化器方面的设置如下: 生成器 G 和判别器 D 均采用 Adam 优化器, 其初始学习率 lr 设定分别为  $1e-4$  和  $1e-5$ , beta1 和 beta2 为 0.5 和 0.999。在训练过程中使用了多步长 MultiStepLR 来动态调整模型的学习率以减少过拟合, 调整的里程碑分别为 40、80 和 120, 对应 Gamma 值为 0.5。模型训练的 batch size 设定为 8, 训练 epoch 则为 150。上述模型代码均基于 PyTorch 框架实现, 采用 Quadro P6000 (24 GB 显存) 的 GPU 进行训练。

### 1.5 性能评估和分析

在本研究收集的 58 例患者数据中随机选取 42 例患者作为训练集用于 SAGAN 的训练建模, 余下的 16 例患者 CBCT 作为测试集生成 sCT 图像进行模型评估。本研究训练了 Res-Unet 合成模型作为基线模型对比评价<sup>[24-25]</sup>。为了对合成的 sCT 图像的质量进行评估, 本研究将分别进行定性和定量分析。



**1.5.1 定性性能评估** 通过比较合成的sCT图像和原始的pCT图像,本研究选择3种定性分析手段来评估不同图像间差异:(1)视觉比较:直接比较合成的sCT图像与原始pCT图像的外观和结构特征,观察图像中各个组织区域的对比度、边缘、细节等;(2)剖视图(Profile)显示了图像中沿着直线的像素强度分布,可直观比较不同图像对应组织在同一方向的变化趋势和差异;(3)差分剖视图(Profile Diff)对不同图像和真实图像进行差值运算,再生成剖视图,剖视曲线距离0刻度横线越近则表示转换误差越小,越远则表示误差越大。

**1.5.2 定量性能评估** 按不同组织计算对应的定量指标进行评价。根据pCT的CT值(Hounsfield Unit, HU)范围,本研究分别对各sCT与pCT在体部( $HU \geq -100$ )、骨性结构( $HU \geq 150$ )和软组织( $150 > HU \geq -100$ )3类组织进行划分,并采用以下的定量评价指标来量化评估模型的性能:(1)MAE,MAE值越小表示sCT图像与pCT的灰度值越接近;(2)SSIM,SSIM值越接近1,表明生成的sCT在结构上与pCT更相似,意味着模型能保留图像的结构信息;(3)峰值信噪比(PSNR),PSNR值越高,意味着生成图像的噪声水平越低,与原始图像更接近,其公式如式(6)所示:

$$PSNR = 10 \cdot \log_{10} \left( \frac{MAX^2}{MSE} \right)$$

(6)

其中,MAX为像素的最大值,MSE为生成图像和原始图像之间的均方误差,其公式为:

$$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2$$

(7)

除了上述常规的定量指标对模型性能评价外,为了更细致地评估合成的sCT图像与原始pCT图像之间的差异,本研究提出一种新的定量评价方法,即基于线

性回归斜率的图像量化评估:分别对体部、骨组织和软组织所在区域的各像素,分别与pCT对应组织同一位置的像素进行线性回归,分析其线性回归斜率。本研究分析不同组织CT值对应的线性回归斜率,即合成图像与原始图像之间CT值的线性关系。线性回归斜率约接近1,则表示模型对不同组织的转换效果较好,CT值校正能力越高。

2 结果与分析

将测试集输入至本研究模型和对比的基线模型,输出所得的合成sCT与pCT进行定性评估,结果如图2所示。通过对比pCT、CBCT和sCT结果可知,CBCT整体噪声水平较高,高密度组织附近软组织区域的散射伪影和噪声较为明显。经过Res-UNET和SAGAN合成的sCT均可抑制CBCT上述的伪影,且器官的边缘相对清晰。观测pCT与CBCT、Res-UNET和SAGAN合成的sCT的Profile及其Profile Diff分布可得:上述两种方法合成sCT(蓝色和绿色虚线所示)基本与pCT灰度分布(青色粗线)相重合,能较好地修正CBCT的伪影和密度差异,其中SAGAN所得数据对应Profile Diff曲线相对较小,距离0刻度横线的更为接近,反映SAGAN合成的sCT与pCT的误差较小,预测的CT值分布更为准确。

此外,本研究还分别计算Res-UNET、SAGAN所得sCT的量化评估指标,通过图3和对应统计差异值可知:(1)对于骨组织和体部计算的MAE、SSIM和PSNR指标,SAGAN所得指标均优于Res-UNET方法,但差异无统计学意义( $P > 0.05$ ),该结果一定程度上表明SAGAN合成的sCT图像与真实pCT更为相似且质量更高,但该改进未显著体现;(2)对于软组织方面,SAGAN与Res-UNET方法相比,表现出更明显的优势,有更优的MAE

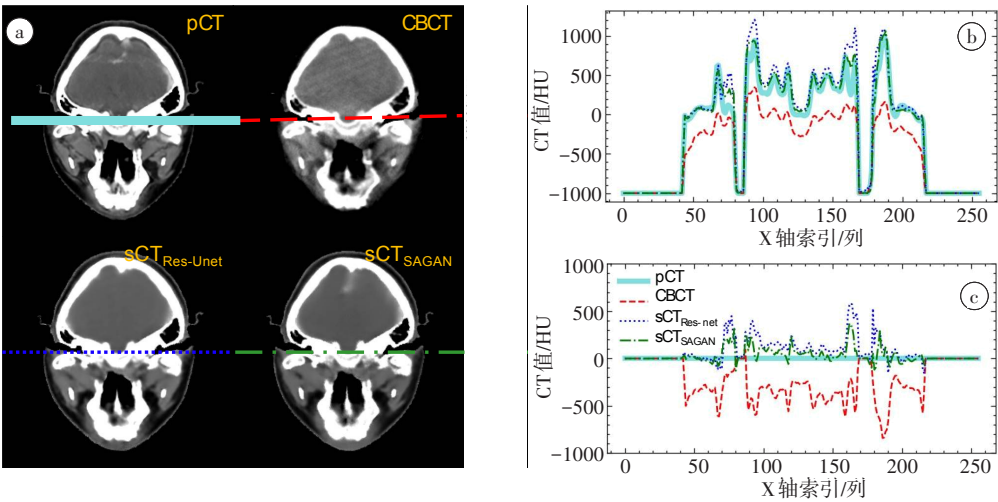


图2 pCT、CBCT、sCT<sub>Res-UNET</sub>和sCT<sub>SAGAN</sub>的CT图像、对应剖视图和差分剖视图

**Figure 2** Cross-sectional images of pCT, CBCT, sCT<sub>Res-UNET</sub> and sCT<sub>SAGAN</sub> at a certain level, and the corresponding Profile and Profile Diff  
a: pCT、CBCT、sCT<sub>Res-UNET</sub>和sCT<sub>SAGAN</sub>在某一层面的横断位图像;b:图a对应图像横线位置所示的剖视图Profile;c:图a对应图像横线位置所示的差分剖视图Profile Diff

值 $[(28.15\pm2.79)\text{HU} \text{ vs } (35.12\pm3.44)\text{HU}, P=0.003]$ 和 PSNR 值 $[(33.98\pm0.74)\text{ dB} \text{ vs } (32.90\pm0.73)\text{ dB}, P=0.012]$ , 这意味着 SAGAN 在合成软组织的 sCT 图像方面取得了显著改进, 图像质量和相似性均有明显提高。

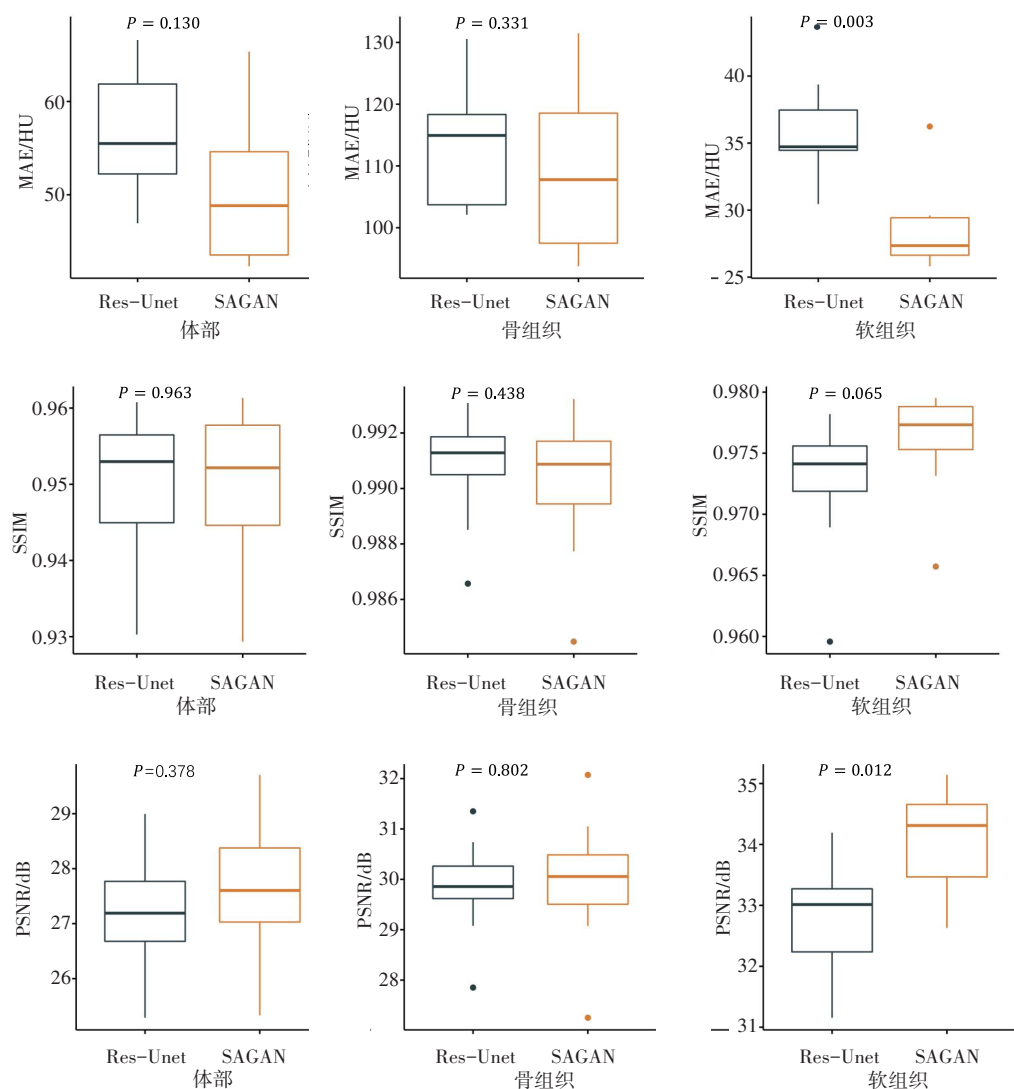


图 3 Res-Net、SAGAN 合成的 sCT 与 pCT 分别在体部、骨组织和软组织计算所得的 MAE、SSIM、PSNR 结果  
Figure 3 MAE, SSIM and PSNR of sCT<sub>Res-Net</sub>, sCT<sub>SAGAN</sub> and pCT in the body, bone and soft tissue

对 CBCT 和不同模型合成的 sCT, 分别与 pCT 的灰度值按组织进行线性回归, 分析不同组织 CT 值对应的线性度 (图 4), 结果显示: 体部的 CBCT、Res-Net 和 SAGAN 的线性回归斜率分别为 0.503、0.887、0.956; 骨组织分别为 2.396、0.882、0.959; 软组织分别为 0.243、0.740、0.839。结果表明, 本文提出的 SAGAN 方法在合成 CT 图像的 CT 值线性度方面表现更优, 具备更好的 CT 值校正性能。相较于 CBCT 和 Res-Net, SAGAN 合成的 sCT 图像更接近 pCT 图像的灰度值分布, 呈现更高的线性度, 这表明 SAGAN 合成的 sCT 图像在不同组织的 CT 值估计上更加准确。

3 讨论

解决 CBCT 图像质量问题, 并定量评估摆位误差和

剂量误差, 是当前图像引导放疗的研究热点之一。基于此, 本研究提出一种基于自监督机制的 SAGAN 网络来实现基于 CBCT 的 sCT 合成。该研究采用基于 U-Net 架构和 patchGAN 作为生成器和鉴别器, 进行特征提取和 sCT 图像转换与辨别。在生成器中引入 Non-local block 自注意力模块来增强网络的非局部特征表达和处理能力, 从而更好地捕捉 CBCT 图像中的长程依赖关系, 提高生成器对 CBCT 的散射伪影识别和降噪能力。本研究通过定性和定量评估对比了不同模型的 sCT 图像转换的性能。定性评估显示, 采用 SAGAN 和 Res-Net, 均能一定程度抑制伪影和噪声, 而 SAGAN 转换的 sCT 图像在视觉上更接近于原始 pCT 图像, 误差更小, 重建的 CT 值分布更准确。定量评估显示, SAGAN 的 MAE、SSIM 和 PSNR 均优于 Res-Net, 在软组织方面的合成




图4 pCT的CT值与CBCT、Res-Unet-sCT、SAGAN-sCT的CT值在不同组织的线性回归结果

Figure 4 Linear regression results between CT number of pCT and that of CBCT, sCT<sub>Res-Unet</sub> or sCT<sub>SAGAN</sub> in different tissues

性能明显优于其他方法,表现更出色。此外,SAGAN转换的sCT图像在不同组织区域的线性回归斜率更接近于1,具备更优的CT值校正性能。综合来看,SAGAN方法在修正CBCT伪影、提高图像质量、CT值校正精度等方面更具优势。本文针对CBCT在临床应用取得了一定的研究进展,但仍存在一些局限性。首先,由于本研究采集样本数量的限制,可能会影响该模型的泛化能力和稳定性。其次,本研究方法仅基于头颈部CT进行训练和评价,对如腹部等其他部位CBCT而言,其图像噪声特性和伪影分布存在差异,可能需要对模型进行针对性的改进和临床验证。

综上所述,本研究提出的SAGAN方法实现CBCT的sCT合成图像相关研究,有效改善CBCT图像质量,抑制了伪影和噪声,合成的sCT图像更准确、真实。在未来的研究中,将进一步完善和改进模型,并探索将SAGAN方法在MRI<sup>[26]</sup>、兆伏CT<sup>[27]</sup>等其他模态的应用,为放射治疗计划和实施提供更全面、准确的图像引导和剂量评估,从而提高肿瘤患者的治疗效果和生存率。

## 【参考文献】

- [1] De Vos W, Casselman J, Swennen G. Cone-beam computerized tomography (CBCT) imaging of the oral and maxillofacial region: a systematic review of the literature[J]. *Int J Clin Oral Maxillofac Surg*, 2009, 38(6): 609-625.
- [2] Scarfe WC, Farman AG. What is cone-beam CT and how does it work? [J]. *Dent Clin North Am*, 2008, 52(4): 707-730.
- [3] Grills IS, Hugo G, Kestin LL, et al. Image-guided radiotherapy via daily online cone-beam CT substantially reduces margin requirements for stereotactic lung radiotherapy[J]. *Int J Radiat Oncol Biol Phys*, 2008, 70(4): 1045-1056.
- [4] Srinivasan K, Mohammadi M, Shepherd J. Applications of linac-mounted kilovoltage cone-beam computed tomography in modern radiation therapy: a review[J]. *Pol J Radiol*, 2014, 79: 181.
- [5] Posiewnik M, Piotrowski T. A review of cone-beam CT applications for adaptive radiotherapy of prostate cancer[J]. *Phys Med*, 2019, 59: 13-21.
- [6] Hvid CA, Elström UV, Jensen K, et al. Cone-beam computed tomography (CBCT) for adaptive image guided head and neck radiation therapy[J]. *Acta Oncol*, 2018, 57(4): 552-556.
- [7] Schulze R, Heil U, Gross D, et al. Artefacts in CBCT: a review[J]. *Dentomaxillofac Radiol*, 2011, 40(5): 265-273.
- [8] Tang X, Krupinski EA, Xie H, et al. On the data acquisition, image reconstruction, cone beam artifacts, and their suppression in axial

- MDCT and CBCT-a review[J]. *Med Phys*, 2018, 45(9): e761-e782.
- [9] Landry G, Hua C. Current state and future applications of radiological image guidance for particle therapy[J]. *Med Phys*, 2018, 45(11): e1086-e1095.
- [10] Park YK, Sharp GC, Phillips J, et al. Proton dose calculation on scatter-corrected CBCT image: feasibility study for adaptive proton therapy [J]. *Med Phys*, 2015, 42(8): 4449-4459.
- [11] Hatton J, McCurdy B, Greer PB. Cone beam computerized tomography: the effect of calibration of the Hounsfield unit number to electron density on dose calculation accuracy for adaptive radiation therapy[J]. *Phys Med Biol*, 2009, 54(15): N329.
- [12] Petit SF, van Elmpt WJ, Nijsten SM, et al. Calibration of megavoltage cone-beam CT for radiotherapy dose calculations: correction of cupping artifacts and conversion of CT numbers to electron density[J]. *Med Phys*, 2008, 35(3): 849-865.
- [13] Onozato Y, Kadoya N, Fujita Y, et al. Evaluation of on-board kV cone beam computed tomography - based dose calculation with deformable image registration using Hounsfield unit modifications[J]. *Int J Radiat Oncol Biol Phys*, 2014, 89(2): 416-423.
- [14] Kim J, Kumar S, Liu C, et al. A novel approach for establishing benchmark CBCT/CT deformable image registrations in prostate cancer radiotherapy[J]. *Phys Med Biol*, 2013, 58(22): 8077.
- [15] Roy S, Sarkar B, Pradhan A. Comparative analysis of setup margin calculation in cone beam CT, by van Herk formula, using two different image registration methods[J]. *J Radiother Pract*, 2023, 22: e92.
- [16] Rusanov B, Hassan GM, Reynolds M, et al. Deep learning methods for enhancing cone-beam CT image quality toward adaptive radiation therapy: a systematic review[J]. *Med Phys*, 2022, 49(9): 6019-6054.
- [17] Joseph J, Biji I, Babu N, et al. Fan beam CT image synthesis from cone beam CT image using nested residual UNet based conditional generative adversarial network[J]. *Phys Eng Sci Med*, 2023, 46(2): 703-717.
- [18] Meyer P, Noblet V, Mazzara C, et al. Survey on deep learning for radiotherapy[J]. *Comput Biol Med*, 2018, 98: 126-146.
- [19] Sibolt P, Andersson LM, Calmels L, et al. Clinical implementation of artificial intelligence-driven cone-beam computed tomography-guided online adaptive radiotherapy in the pelvic region[J]. *Phys Imaging Radiat Oncol*, 2021, 17: 1-7.
- [20] Ronneberger O, Fischer P, Brox T. Medical image computing and computer-assisted intervention-MICCAI 2015[C]. 2015: 234-241.
- [21] Isola P, Zhu JY, Zhou T, et al. Proceedings of the IEEE conference on computer vision and pattern recognition[C]. 2017: 1125-1134.
- [22] Gulrajani I, Ahmed F, Arjovsky M, et al. Improved Training of Wasserstein GANs. In Proceedings of the 31st International Conference on Neural Information Processing Systems (NeurIPS 2017) [C]. 2017: 5767-5777.
- [23] Wang X, Girshick R, Gupta A, et al. Proceedings of the IEEE conference on computer vision and pattern recognition[C]. 2018: 7794-7803.
- [24] He K, Zhang X, Ren S, et al. Proceedings of the IEEE conference on computer vision and pattern recognition[C]. 2016: 770-778.
- [25] Xiao X, Lian S, Luo Z, et al. 2018 9th international conference on information technology in medicine and education (ITME)[C]. IEEE, 2018: 327-331.
- [26] Johnstone E, Wyatt JJ, Henry AM, et al. Systematic review of synthetic computed tomography generation methodologies for use in magnetic resonance imaging-only radiation therapy[J]. *Int J Radiat Oncol Biol Phys*, 2018, 100(1): 199-217.
- [27] Scholey JE, Rajagopal A, Vasquez EG, et al. Generation of synthetic megavoltage CT for MRI-only radiotherapy treatment planning using a 3D deep convolutional neural network[J]. *Med Phys*, 2022, 49(10): 6622-6634.

(编辑:陈丽霞)