

DOI:10.3969/j.issn.1005-202X.2023.03.009

医学影像物理

## 基于DenseCUT网络由头部锥形束CT图像生成合成CT图像

吴新红<sup>1</sup>, 王江涛<sup>1</sup>, 唐巍<sup>2</sup>, 左阳<sup>1,3</sup>, 卢晓明<sup>2</sup>, 朱磊<sup>1</sup>, 杨益东<sup>1,3</sup>

1. 中国科学技术大学工程与应用物理系, 安徽 合肥 230026; 2. 合肥离子医学中心, 安徽 合肥 230088; 3. 中国科学技术大学附属第一医院放射治疗科, 安徽 合肥 230001

**【摘要】**提出一种由头部锥形束CT(CBCT)图像生成合成CT(sCT)图像的无监督深度学习网络,并与循环生成对抗(CycleGAN)网络及对比非配对转换(CUT)网络进行比较。本研究共获取56例脑部肿瘤患者的计划CT(pCT)和CBCT数据(其中49例用于训练,7例用于测试),分别使用CycleGAN网络、CUT网络以及本研究提出的密集对比非配对转换(DenseCUT)网络由CBCT图像生成sCT。DenseCUT网络有两点创新之处:将CUT网络与密集块网络结合;在损失函数中加入结构相似性。与pCT-CBCT相比,pCT-sCT(DenseCUT网络)的HU值平均绝对误差从34.38 HU降低到17.75 HU,峰值信噪比从26.19 dB提升到29.83 dB,结构相似性从0.78提升到0.87。本文方法可在不改变解剖结构的情况下从CBCT图像中生成高质量的sCT图像,同时降低图像伪影,使CBCT应用于剂量计算和自适应放疗计划成为可能。

**【关键词】**锥形束CT;合成CT;密集对比非配对转换网络

**【中图分类号】**R318;R811.1

**【文献标志码】**A

**【文章编号】**1005-202X(2023)03-0313-07

## Generation of synthetic CT image from head cone beam CT image using DenseCUT

WU Xinhong<sup>1</sup>, WANG Jiangtao<sup>1</sup>, TANG Wei<sup>2</sup>, ZUO Yang<sup>1,3</sup>, LU Hsiao-Ming<sup>2</sup>, ZHU Lei<sup>1</sup>, YANG Yidong<sup>1,3</sup>

1. Department of Engineering and Applied Physics, University of Science and Technology of China, Hefei 230026, China; 2. Hefei Ion Medical Center, Hefei 230088, China; 3. Department of Radiotherapy, the First Affiliated Hospital of University of Science and Technology of China, Hefei 230001, China

**Abstract:** An unsupervised deep learning network is presented for generating synthetic CT (sCT) images from cone beam CT (CBCT) images of the head, and it is compared with cycle-consistent generative adversarial network (CycleGAN) and contrastive unpaired translation (CUT). After collecting the planning CT (pCT) images and CBCT images of 56 brain tumor patients (49 for training and 7 for testing), the sCT images are generated from CBCT images using CycleGAN, CUT, and the proposed dense contrastive unpaired translation (DenseCUT), separately. DenseCUT has two novelties, namely combining the CUT network with the dense block network, and adding structural similarity to the loss function. Compared with pCT-CBCT, pCT-sCT (DenseCUT) reduces the average absolute error of the HU from 34.38 HU to 17.75 HU, increases the peak signal-to-noise ratio from 26.19 dB to 29.83 dB, and elevates the structural similarity from 0.78 to 0.87. The proposed method can generate high-quality sCT images from CBCT images without altering the anatomical structures, while reducing image artifacts, which makes it possible for CBCT to be applied to dose calculation and adaptive radiotherapy planning.

**Keywords:** cone beam CT; synthetic CT; dense contrastive unpaired translation network

### 前言

**【收稿日期】**2022-11-12

**【基金项目】**国家自然科学基金(81671681);国家重点研发计划(2016YFC0101400);中央高校基本科研业务费专项资金(WK2030000037, WK2030040089);安徽省科技重大专项(BJ2030480006)

**【作者简介】**吴新红,在读硕士,研究方向:医学影像CT、MR的质量提升及应用, E-mail: xinhong@mail.ustc.edu.cn

**【通信作者】**杨益东,教授,研究方向:图像引导的放射治疗系统, E-mail: ydyang@ustc.edu.cn

锥形束CT(Cone Beam CT, CBCT)由于扫描时间短、扫描范围大、射线利用率高,被广泛应用于各种临床任务,如放疗中病人的摆位。与传统CT相比,CBCT图像质量因为受到光子散射、光束硬化等伪影的影响,导致CT值不准确,这阻碍了CBCT在剂量计算和放疗计划等高级任务中的应用。许多提高CBCT图像质量的技术被提出,这些技术主要分为硬件校正和软件校正。硬件校正主要是通过减少散射来提高图像质量,如采用条纹状的X射线光束阻挡器<sup>[1]</sup>和在探测器上增加防散射栅格<sup>[2]</sup>,其优点在于操

作简单,缺点是不同的系统需要定制,并不具有通用性。软件校正主要包括蒙特卡罗建模<sup>[3]</sup>、射线追踪<sup>[4]</sup>、迭代滤波<sup>[5]</sup>等,其优点是散射去除效果好,缺点是需要的时间长和设备成本高。

近年来,深度学习已广泛应用于医学图像研究,特别是在图像重建<sup>[6]</sup>、分类<sup>[7]</sup>、边缘检测<sup>[8-9]</sup>、器官分割<sup>[10-11]</sup>和放疗剂量计算<sup>[12]</sup>等领域,同时也被广泛应用于放疗,如自动治疗计划<sup>[13]</sup>。目前有许多研究利用深度学习来提高CBCT的图像质量<sup>[14-15]</sup>,这些深度学习策略主要分为监督学习和无监督学习。监督学习的网络结构需要成对的数据集<sup>[16-17]</sup>,最常用的结构是U-net网络,如sCT-UNet<sup>[18]</sup>。然而,由于不可能同时对患者进行CBCT和CT扫描,所采集的CBCT/计划CT(planning CT, pCT)图像之间不可避免地存在解剖结构的异变。无监督学习不需要配对的数据,其分别提取2个图像域的风格信息和语义信息,生成新的图像。CycleGAN是无监督学习的代表,它基于生成对抗网络(Generative Adversarial Network, GAN)引入一个逆映射,并在损失函数中添加循环一致性损失<sup>[19-20]</sup>。然而循环一致性损失假定源域和目标域之间的关系是双射,这通常很难满足;此外, CycleGAN庞大的参数需要大量数据以及长时间的训练。

为了克服CycleGAN的缺点,本研究提出一种基于对比非配对转换(Contrastive Unpaired Translation, CUT)网络<sup>[21]</sup>改进的网络模型,即密集对比非配对转换(Dense Contrastive Unpaired Translation, DenseCUT)网络。CUT是一种单射网络,但其在图像转换时对语义信息的学习不及CycleGAN网络,且训练稳定性较差。为了提高CUT网络的性能,本研究将CUT网络生成器中的Resnetblock<sup>[22]</sup>改为Denseblock<sup>[23]</sup>,Denseblock将不同层特征在通道维上进行级联,实现特征扩充和前层特征复用,同时在损失函数中加入结构相似性损失,用来保证合成CT(synthetic CT, sCT)具有与CBCT一样的解剖结构。相较于CycleGAN网络,DenseCUT网络只需要学习单向映射,避免使用反向生成器和判别器,计算量减少近一半,简化训练过程,减少训练时间。

## 1 材料与方法

### 1.1 数据采集与处理

从合肥离子医学中心数据库中收集56例脑部肿瘤患者的pCT和CBCT数据,各有5960张,使用来自49例患者的4982张未配对图像作为训练集,以及来自7例患者的978张图像作为测试集来测试网络模型。图像像素为1.0 mm×1.0 mm×1.0 mm,图像尺寸

裁剪为256×256。为了更好地训练网络,用一个二值掩膜覆盖患者身体外的体素,从而去除病人体的病床及其他病人固定装置。掩膜外的像素值设置为-1 000 HU。为了评估sCT,首先使用开源软件3D Slicer对pCT图像与CBCT图像进行配准,然后将配准后的pCT作为参考图像。

### 1.2 CUT网络

由于pCT和CBCT图像不能同时采集,导致图像中的解剖结构不能完全匹配,即便经过医学软件的配准,pCT和CBCT图像仍然存在局部不匹配问题,因此本研究采用无监督学习方法。CUT网络是一种新提出的无监督学习网络,其使用一个对比学习框架通过最大化相应输入图像和输出图像之间的互信息来保证二者之间的结构一致性。CUT网络是一种单射网络,由一个生成器和一个判别器组成,其结构如图1所示。如图2所示CUT网络的生成器由1个编码器、9个残差块和1个解码器组成,编码器部分采用卷积核大小为3×3、步长为2的卷积。每次降采样后,通道数量增加一倍,图像大小减少一半。解码器采用逆卷积,卷积核大小为3×3、步长为2,每次上采样后图像大小增加一倍,通道数减少到原来的一半。CUT的判别器采用PatchGAN<sup>[20]</sup>的结构,由5个卷积层组成,前3个下采样卷积层用于提取特征,最后2个卷积层输出判别矩阵。判别器输出判别矩阵的每个元素代表输入图中70×70的图像块为真实值的概率,在最终输出的判别矩阵与相同大小的全1矩阵之间计算最小二乘损失函数。每个卷积层由卷积、实例归一化和leakyReLU激活函数组成。




图1 CUT网络结构

Figure 1 CUT architecture

### 1.3 DenseCUT网络

本研究基于CUT网络提出一种新的神经网络,即DenseCUT网络,主要做了如下改进:(1)受DenseNet的启发,为捕捉CBCT图像中多尺度信息,将生成器网络中的残差块修改为密集块。残差块通过跳跃连接将前一层的特征图添加到后一层。如图3所示,与残差块不同,密集块中每一层将之前所有层的输入进行拼接,之后将输出的特征图传递给之

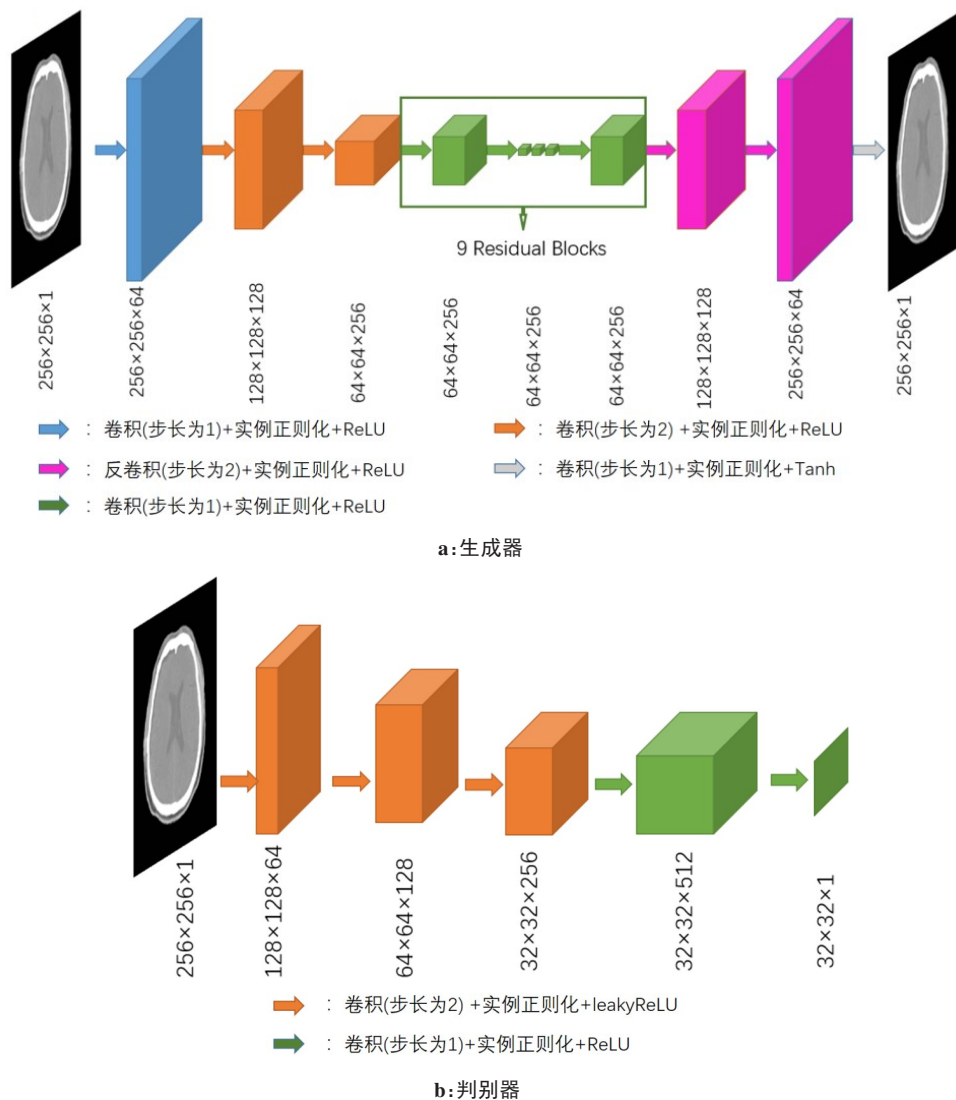


图2 生成器及判别器的网络结构  
Figure 2 Generator and discriminator architectures

后的所有层,学习低频和高频信息,并将其结合起来。与残差块相比,Denseblock优势在于不同层特征在通道维上进行级联,实现特征扩充和前层特征复用,密集块需要的参数数量不到残差块的一半,计算量约为残差块的一半。(2)由于pCT图像不能反映患

者治疗当天的解剖结构,而CBCT通常在当天放疗前摆位时采集,所以CBCT更能体现患者治疗当天的解剖结构,故在生成sCT时要保留CBCT中病人的解剖结构信息。为实现这一点,本研究在生成器的损失函数中加入输入和输出间的结构相似性损失 $L_{DSSIM}$ 。




图3 密集块的结构  
Figure 3 Dense block architecture



深度学习方法需要设计损失函数来优化网络。DenseCUT网络的主要损失函数为CUT网络的 $L_{\text{NCE}}$ 损失函数,该损失函数用来计算输入图像和目标域图像编码后的多尺度信息之间的偏差。CUT网络的核心思想是输入与输出图像不仅在整体上具有相同的语义信息,两者对应图像块间的语义信息也是一致的。网络将与输出图像块位置对应的图像块称为正样本块,其他位置的图像块称为负样本块,将输出图像块、正样本块和负样本块分别依次输入编码器、多层感知机后得到对应特征向量 $\mathbf{z}$ 。然后分别计算正样本块和负样本块向量与输出样本块的余弦相似,根据余弦相似构建语义的损失函数,为使对应的图像块间的余弦相似性最大化,引入softmax函数,其有着拉开差异再归一化的作用。单个图像块的损失函数表达式如下:

$$l(\mathbf{z}, \mathbf{z}^+, \mathbf{z}^-) = -\log \frac{\exp\left(\frac{\mathbf{z} \cdot \mathbf{z}^+}{\tau}\right)}{\exp\left(\frac{\mathbf{z} \cdot \mathbf{z}^+}{\tau}\right) + \sum_{n=1}^N \exp\left(\frac{\mathbf{z} \cdot \mathbf{z}^-}{\tau}\right)} \quad (1)$$

其中, $\mathbf{z}, \mathbf{z}^+, \mathbf{z}^-$ 分别代表输出样本、正样本以及 $N$ 个负样本的特征向量,余弦相似通过参数 $\tau = 0.07$ 进行缩放,遍历输出图像中所有图像块便得到 $L_{\text{NCE}}$ 损失,如下所示:

$$L_{\text{NCE}}(\mathbf{G}, \mathbf{H}, \mathbf{X}) = E_{\mathbf{x} \sim \mathbf{X}} \sum_{l=1}^L \sum_{s=1}^{S_l} l(\hat{\mathbf{z}}_l^s, \mathbf{z}_l^s, \mathbf{z}_l^{S_l^s}) \quad (2)$$

其中, $L$ 为感兴趣特征的层数, $S_l$ 是每一层特征图的空间位置个数。

$L_{\text{NCE}}$ 取代了CycleGAN网络中的循环一致性损失,用来保证图像内容的一致性,更多细节详见文献[22]。同时,DenseCUT网络使用GAN网络的生成对抗损失来保证生成的图像与目标域的图像风格一致,其损失函数如式(3)所示:

$$L_{\text{GAN}} = E_{\text{CBCT} \sim P_{\text{data}}(\text{CBCT})} [(D(\mathbf{G}(\text{CBCT})) - 1)^2] \quad (3)$$

为了更好地保留sCT图像中CBCT图像的解剖结构,本研究在生成器中加入 $L_{\text{DSSIM}}$ 损失函数:

$$\text{SSIM}(\text{sCT}, \text{CBCT}) = \frac{(2\mu_{\text{CBCT}}\mu_{\text{sCT}} + C_1)(2\sigma_{\text{CBCT-sCT}} + C_2)}{(\mu_{\text{CBCT}}^2 + \mu_{\text{sCT}}^2 + C_1)(\sigma_{\text{CBCT}}^2 + \sigma_{\text{sCT}}^2 + C_2)} \quad (4)$$

$$L_{\text{DSSIM}}(\text{sCT}, \text{CBCT}) = 1 - \text{SSIM}(\text{sCT}, \text{CBCT}) \quad (5)$$

其中, $C_1 = (0.01L)^2$ ,  $C_2 = (0.03L)^2$ ,  $L$ 为CT图像像素值的动态范围, $\mu$ 和 $\sigma^2$ 分别表示其均值跟方差, $\sigma_{\text{CBCT-sCT}}$ 是CBCT和sCT的协方差。

DenseCUT生成器的最终损失函数为:

$$\text{Loss}_G = L_{\text{GAN}} + L_{\text{NCE}} + L_{\text{DSSIM}} \quad (6)$$

DenseCUT判别器损失函数为:

$$\text{Loss}_D = E_{\text{pCT} \sim P_{\text{data}}(\text{PCT})} [(D(\text{pCT}) - 1)^2] + E_{\text{CBCT} \sim P_{\text{data}}(\text{CBCT})} [D(\mathbf{G}(\text{CBCT}))^2] \quad (7)$$

#### 1.4 定量评价

本研究选取平均绝对误差(MAE)、均方根误差(RMSE)、峰值信噪比(PSNR)和结构相似度(SSIM)评价sCT的HU值、噪声水平和结构相似度,如式(8)、(9)、(10)、(4)所示。

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |I_{\text{sCT},i} - I_{\text{pCT},i}| \quad (8)$$

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

$$\text{PSNR} = 10 \log_{10} \left( \frac{Q^2}{\|I_{\text{pCT}} - I_{\text{sCT}}\|_2^2 / N} \right) \quad (10)$$

其中, $I_{\text{pCT}}, I_{\text{sCT}}$ 分别表示pCT、sCT的HU值, $N$ 表示图像感兴趣区域的体素数, $Q$ 为pCT、sCT图像中最大值。

## 2 结果

CycleGAN、CUT和DenseCUT网络都训练了200个epochs,使用7例患者的978张脑部图像作为测试集来测试网络模型。为了进行对比,CycleGAN、CUT和DenseCUT网络均采用相同的训练参数和策略。对于神经网络中所有算法和模型都使用Adam优化器在PyTorch中实现,并在NVIDIA GeForce RTX 3090 GPU(12 G)上进行训练。Adam优化器的动量超参数 $\beta_1$ 和 $\beta_2$ 分别设置为0.5和0.9,网络总共训练200个epochs,前100个学习epochs的学习率固定为0.0002,后面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。

图4为测试集中一个病例,分别为pCT图像、CBCT图像、DenseCUT生成的sCT图像以及相应差分图。sCT图像与CBCT图像相比,图像质量有了很大的提升,其CT值更接近pCT。值得注意的是,sCT与pCT在某些区域的CT值存在显著差异,主要是由于CBCT和pCT的解剖结构变化导致的,即使经过严格的配准也无法完全消除这部分的差异。图5为图4虚线处pCT、CBCT以及sCT的CT值分布,sCT的CT值分布曲线在形状和数值上最接近pCT。图6展示了测试集中3例患者的不同层切片,宽窗窗位: [-200, 200] HU,对比了CycleGAN、CUT以及DenseCUT网络的输出结果,放大图显示了图像中软组织的细节,CUT网络生成的sCT在软组织区域有颗粒感,CycleGAN网络生成的sCT有部分细节的丢失,DenseCUT网络生成的sCT更加接近pCT。本文方法的伪影去除和病变组织学习效果均优于另外两种方法。

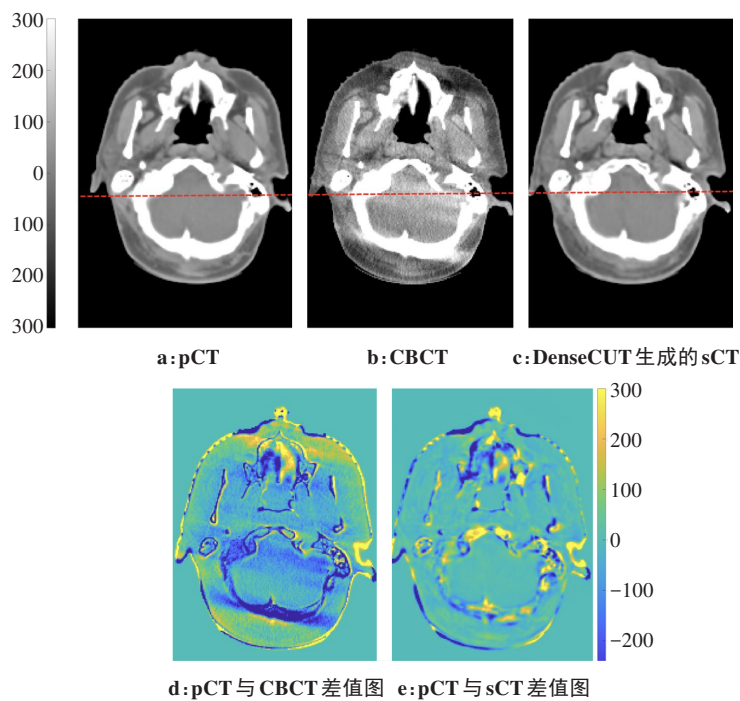


图4 某一个病例的pCT、CBCT、sCT、pCT与CBCT差值图以及pCT与sCT差值图  
Figure 4 pCT, CBCT, sCT, pCT-CBCT difference, and pCT-sCT difference of a case




图5 图4中虚线处pCT、CBCT、sCT的HU值分布  
Figure 5 HU values of pCT, CBCT, and sCT at the dashed line in Figure 4

为了定量评价本研究提出的 DenseCUT 网络,将 DenseCUT 网络生成的 sCT 图像分别与 CBCT 图像以及 CycleGAN 和 CUT 网络生成的 sCT 图像进行定量分析。7 例患者的整张图像间 MAE、RMSE、PSNR、SSIM 的具体数值如表 1 所示, DenseCUT 网络生成的 sCT 图像质量有了明显的提高,在整个测试集中,相比于 CBCT, sCT 与 pCT 之间 HU 值的 MAE 从 34.38 HU 降到了 17.75 HU, RMSE 由 97.08 HU 降低到 65.97 HU, PSNR 从 26.19 dB 上升到 29.83 dB。

为了验证 DenseCUT 网络生成的 sCT 的临床应用效果,将 pCT 与 sCT 配准,并将 pCT 上的危及器官和 PTV 轮廓映射到 sCT 上,按照 pCT 的治疗方案分别由 pCT 与 sCT 生成剂量体积直方图(DVH)。图 7 为测试集中一名患者真实 pCT 和 DenseCUT 生成的

sCT 对应的 DVH。其中方块代表 pCT 对应的 DVH,三角代表由 DenseCUT 生成的 sCT 对应的 DVH。两者的 DVH 曲线吻合的很好, sCT 在剂量验证方面取得很好的结果,这说明 DenseCUT 生成的 sCT 可有效地应用于放疗计划。

### 3 结 论

本研究提出一种基于 CUT 和 Denseblock 的无监督深度学习网络,使用非配对的 CBCT 和 pCT 图像来训练网络参数。测试结果表明,该方法生成 sCT 图像噪声低,伪影少,图像质量高,很好地校正了 CBCT 中的 HU 值。与 CycleGAN、CUT 网络相比,该网络生成 sCT 图像质量更高。此外,与 pCT 图像相比, sCT 图像很好地保留了 CBCT 中病人的解剖结构,这对于 CBCT 的应用具有重要意义,特别是当患者的身体和解剖结构在不同放疗分次间发生变化时,使用 sCT 制定放疗计划可提高放疗精度。基于 sCT 和基于 pCT 的放疗计划的 DVH 比较和患者危及器官与 PTV 等区域的放射剂量差异比较证明了 sCT 用于放疗计划的安全性和可靠性。在多次放疗过程中,随着患者肿瘤及其解剖结构的变化,患者可能需要重新获得 pCT 设计放疗计划,这导致患者接受的辐射剂量增加。本研究的主要目的在于优化患者每次放疗前采集的 CBCT 图像质量,为其将来用于制定自适应放疗计划做准备。




图6 不同方法生成的sCT的轴状面

Figure 6 Axial planes of sCT generated by different methods

表1 CycleGAN、CUT、DenseCUT生成的sCT与CBCT、pCT定量比较

Table 1 Quantitative comparison between pCT or CBCT and sCT generated by CycleGAN, CUT and DenseCUT

方法	MAE/HU	RMSE/HU	PSNR/dB	SSIM
pCT-CBCT	34.38±7.39	97.08±7.16	26.19±1.56	0.78±0.13
pCT-sCT(CycleGAN网络)	18.02±2.62	70.31±8.83	29.63±1.03	0.85±0.08
pCT-sCT(CUT网络)	19.76±3.37	70.56±8.43	29.08±1.07	0.85±0.08
pCT-sCT(DenseCUT网络)	17.75±3.14	65.97±7.33	29.83±1.17	0.87±0.03




图7 一例病例的DVH图比较

Figure 7 DVH comparison of a patient

本研究主要探讨了由CBCT合成sCT的任务,对生成网络的训练都是基于二维数据。未来可将网络结构的输入数据格式拓展到三维,这样可以利用更多层的信息,同时获得三维空间中的连续特征<sup>[24]</sup>。

本研究获取的数据都来自一个中心,甚至仅来自同一型号的CT和CBCT设备以及同样的扫描参数,这极大地限制了网络的适用性。下一步研究将收集多中心和多设备的CT数据,增加数据集的多样性。

## 【参考文献】

- [1] Liang X, Chen L, Dan N, 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.
- [2] Siewerdsen JH, Moseley DJ, Bakhtiar B, et al. The influence of antiscatter grids on soft-tissue detectability in cone-beam computed tomography with flat-panel detectors[J]. *Med Phys*, 2004, 31(12): 3506-3520.
- [3] Zbijewski W, Beekman FJ. Efficient Monte Carlo based scatter artifact reduction in cone-beam micro-CT[J]. *IEEE Trans Med Imaging*, 2006, 25(7): 817-827.
- [4] Jia X, Yan H, Cervino L, et al. A GPU tool for efficient, accurate, and realistic simulation of cone beam CT projections[J]. *Med Phys*, 2012, 39(12): 7368-7378.
- [5] Wang J, Li T, Xing L. Iterative image reconstruction for CBCT using edge-preserving prior[J]. *Med Phys*, 2009, 36(1): 252-260.
- [6] Reader AJ, Corda G, Mehranian A, et al. Deep learning for PET image reconstruction[J]. *IEEE Trans Radiat Plasma Med Sci*, 2021, 5(1): 1-25.
- [7] Kalidindi A, Kompalli PL, Bandi S, et al. CT image classification of human brain using deep learning[J]. *iJOE*, 2021, 17(1): 51-62.
- [8] Gholizadeh-Ansari M, Alirezaie J, Babyn P. Deep learning for low-dose CT denoising using perceptual loss and edge detection layer[J]. *J Digit Imaging*, 2020, 33(2): 504-515.
- [9] Li X, Jiao H, Wang Y. Edge detection algorithm of cancer image based on deep learning[J]. *Bioengineered*, 2020, 11(1): 693-707.
- [10] Buerger C, von Berg J, Franz A, et al. Combining deep learning and model-based segmentation for labeled spine CT segmentation[C]// *Image Processing in Medical Imaging Conference*. Houston: TX, 2020.
- [11] Tureckova A, Turecek T, Kominkova Oplatkova Z, et al. Improving CT image tumor segmentation through deep supervision and attentional gates[J]. *Front Robot AI*, 2020, 7: 106.
- [12] Xue X, Ding Y, Shi J, et al. Cone beam CT (CBCT) based synthetic CT generation using deep learning methods for dose calculation of nasopharyngeal carcinoma radiotherapy[J]. *Technol Cancer Res T*, 2021, 20: 1-10.
- [13] 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): 671-675.
- Fan JW, Chen Z, Wang JZ, et al. Study of automatic treatment planning of intensity-modulated radiotherapy based on deep learning technique for breast cancer patients[J]. *Chinese Journal of Radiation Oncology*, 2020, 29(8): 671-675.
- [14] Wu WJ, Qu JD, Cai J, et al. Multiresolution residual deep neural network for improving pelvic CBCT image quality[J]. *Med Phys*, 2022, 49(3): 1522-1534.
- [15] Lee D, Kim K, Kim W, et al. Four-dimensional CBCT reconstruction based on a residual convolutional neural network for improving image quality[J]. *J Korean Phys Soc*, 2019, 75(1): 73-79.
- [16] Jiang Y, Yang C, Yang P, et al. Scatter correction of cone-beam CT using a deep residual convolution neural network (DRCNN) [J]. *Phys Med Biol*, 2019, 64(14): 145003.
- [17] Kida S, Nakamoto T, Nakano M, et al. Cone beam computed tomography image quality improvement using a deep convolutional neural network[J]. *Cureus*, 2018, 10(4): e2548.
- [18] Chen L, Liang X, Shen C, et al. Synthetic CT generation from CBCT images via deep learning[J]. *Med Phys*, 2020, 47(3): 1115-1125.
- [19] Usui K, Ogawa K, Goto M, et al. A cycle generative adversarial network for improving the quality of four-dimensional cone-beam computed tomography images[J]. *Radia Oncol*, 2022, 17(1): 69.
- [20] Goodfellow IJ, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets [C]//the 28th Conference on Neural Information Processing Systems (NIPS). 2014: 2672-2680.
- [21] Taesung P, Efros AA, Zhang R, et al. Contrastive learning for unpaired image-to-image translation[C]//Computer Vision-ECCV 2020. 16th European Conference. Proceedings. Lecture Notes in Computer Science (LNCS 12354). 2020: 319-345.
- [22] He KM, Zhang XY, Ren SQ, et al. Deep residual learning for image recognition[C]. 2016CPRV, 2016: 770-778.
- [23] Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks[C]. 2017CVPR, 2017: 4700-4708.
- [24] Pei YR, Ai XS, Zha HB, et al. 3D exemplar-based random walks for tooth segmentation from cone-beam computed tomography images[J]. *Med Phys*, 2016, 43(9): 5040-5050.

(编辑:谭斯允)