

文章编号: 2096-1618(2021)03-0286-07

# 基于生成对抗网络的 CT 图像生成

王 蕾<sup>1</sup>, 李媛茜<sup>2</sup>

(1. 成都信息工程大学计算机学院, 四川 成都 610225; 2. 成都盛达仁科技有限公司, 四川 成都 610225)

**摘要:**准确地预测生成 CT 图像,在仅磁共振图像引导(MRI-onlyRT)的放疗计划中有着极其重要的作用,使用 MRI 预测生成 CT 图像可以避免患者单独进行 CT 扫描,从而避免额外的辐射剂量。在医学图像跨模态合成中,生成对抗网络(generative adversarial networks, GAN)正成为一种有影响力的方法。研究利用 GAN,结合 U-Net 网络建立鼻咽癌磁共振图像(MRI)与 CT 图像的映射模型,实现在仅磁共振图像引导的放疗过程中 CT 图像的预测生成。实验结果表明,建立的网络模型可以生成接近真实数据的 CT 图像,与改进的 U-Net 卷积网络生成模型相比,降低了生成图像的模糊度,减小了 MAE,提高了 PSNR,生成的图片能够更好地展示细节信息。

**关 键 词:**生成对抗网络;图像生成;CT;MRI-onlyRT

**中图分类号:**TP391

**文献标志码:**A

**doi:**10.16836/j.cnki.jcuit.2021.03.008

## 0 引言

放射治疗是治疗肿瘤性疾病的一种主要方法,过程采用 X 射线杀伤肿瘤组织。从全身放射治疗到适形放射治疗,再发展到图像引导放疗。图像引导放疗治疗(IGRT)通过医学图像,正确识别和勾画出肿瘤组织,并对危机器官作好标记,在制定治疗计划时,确保射线对肿瘤组织高剂量照射,同时保护周围正常组织或者危机器官所受到的剂量降到最低。IGRT 的放疗工作流程,多以 CT 图像作为基准影像,对肿瘤及病灶区进行靶区勾画,且勾画出危机器官进行保护,该工作流程 CT 图像扫描速度快,CT 图像的像素值可以直接反映不同组织的电子密度(衰减特性),而电子密度信息又是放疗计划中进行剂量计算的关键信息,缺点是 CT 图像成像过程中,病人会遭受额外的电离辐射剂量,且图像软组织对比度差,随着精准医疗的发展,用 CT 图像作放疗定位,是相当不准确的。

随着磁共振成像在放疗领域的作用越来越重要,磁共振成像(MRI)作为唯一医学图像模态的放射治疗(MRI-onlyRT),已得到了医学图像领域中研究学者的广泛关注,磁共振图像逐步开始替代 CT 图像,成为图像引导放疗的基准影像。MRI 被视为软组织对比度的金标准,有着优越的软组织对比度,与 CT 图像相比, MRI 软组织分辨率更高,对于肿瘤边界显示更清晰,对于精准定位肿瘤靶区、定位危机器官避免危及临近正常组织器官以及提高局部控制率等至关重要;与 CT

图像相比,更能区分肿瘤活性组织和水肿组织,为多次放疗及放疗后疗效评估提供更安全更准确的信息。在 MRI-onlyRT 中,一个主要的问题是,由于 MRI 与电子密度信息无关,不能直接用于后期的剂量计算和基于 X 光的患者摆位验证,所以还需要 CT 图像提供电子密度信息,将 MRI 与 CT 图像配准融合, MRI 用于靶区和危机器官轮廓勾画,再通过配准将数据转移到 CT 图像,以获取电子密度信息用于放疗剂量计算,这个过程会带来系统配准误差,尤其是非刚体结构中或者是结果就是系统偏靶和增加对健康组织的剂量,影响治疗的精准性。

为解决以上问题,研究人员提出了使用 MRI 生成含有电子密度信息的 CT 图像的方法,患者不需要再单独做 CT 扫描,这种方法可以避免引入配准误差,也没有电离辐射。虽然 MRI 和 CT 图像的成像原理不同,但是对于同一患者相同位置,解剖结构是一致的,可以利用一致的解剖信息,实现 MRI 到 CT 图像的生成。

## 1 相关工作

基于 MRI 生成 CT 图像的方法主要有容积密度分配法、基于体素、基于图集和基于深度学习这些方法<sup>[1]</sup>。

容积密度分配法为整个目标体积假设一个均匀的密度,然后为每个组织分配 CT 值或 HU 值<sup>[2-5]</sup>,但是这种方法可能会导致在包含足够大的致密骨厚度的区域产生剂量差异。基于体素的生成方法,使用不同的序列,如 DIXON,超短回波序列(ultra-short echo, UTE)来分割不同的组织,建立信号强度与每个体素的

CT 值的相关性,成像体的所有体素被分类为不同的类别,HU 值被分配到每个类别<sup>[6-8]</sup>。基于图集通常使用单一的、标准的 MRI 序列来生成 CT,将图谱 MR 图像应用于相应的图谱 CT 图像,以生成多个变形的图谱图像,它需要大量的 MRI 和 CT 图像对数据,CT 生成过程可以完全自动化和参考图像以进行位置验证,以及自动勾勒危机器官轮廓,基于 Atlas 的 CT 方法优于容积密度分配方法的均匀性和准确性,但不适用于所有解剖结构和组织,如果没有该组织或解剖学的图谱数据作为参考图,则很难生成 CT 图像<sup>[9-11]</sup>。

基于深度学习的图像生成方法是目前的主流方法,在过去几年中,深度学习在放射治疗中的应用有了极大的发展。基于学习的方法,基于两个图像之间的相关信息,输入大量的 MRI 与 CT 图像,来找到两个图像域之间的映射关系<sup>[12-13]</sup>。由于生成对抗网络(generative adversarial networks, GANs)在图像转换任务中的出色表现,研究者们也开始将 GANs 运用到医学图像领域,基于上下文感知的生成对抗网络方法实现 CT 图像生成<sup>[14]</sup>,以及将循环生成对抗网络同时用于图像生成和分割任务的实现<sup>[15-18]</sup>都充分证明了生成对抗网络用于 CT 图像生成任务的可行性。

基于生成对抗网络结构,结合 U-net 网络建立鼻咽癌磁共振图像与 CT 图像的映射模型,实现 CT 图像的预测生成。与改进的 U-Net 卷积神经网络生成模型生成结果相比,降低了生成图像的模糊度,减小了 MAE(mean absolute error)提高了 PSNR(peak signal noise ratio),生成的图片能够更好地展示细节信息。

## 2 方法

### 2.1 生成对抗网络

生成对抗网络(GAN)提出一种新的框架,通过一个对抗过程训练生成模型,是一种能够生成与创建数据的深度学习网络框架<sup>[19]</sup>。GAN 由生成器(generator, G)和判别器(discriminator, D)两个重要模块组成,生成器负责生成样本,判别器负责鉴别样本属于训练数据还是生成样本。训练过程中,两个网络模型被同时训练,生成器 G 以一个随机噪声作为输入,生成数据  $G(z)=x'$ ,生成器 G 目标是尽量生成真实的样本来欺骗判别器 D,使判别器对其生成的样本预测概率值最大化,判别器在训练过程中,与生成器对抗,目标是尽量把生成器 G 生成的样本与真实的训练数据样本区分开,最小化做出错误判断的概率,判别器 D 的输出值通常是  $[0, 1]$  的一个概率预测值,衡量输入到判

别器中数据的真假程度。两个模块在互相博弈中达到一个纳什平衡,生成对抗网络即训练完成,生成器 G 重建出训练数据分布,判别器 D 在此状态下区分不出生成样本与真实样本,对于生成数据和真实数据的预测输出值均为 0.5,这样在具体的生成任务中,就可以生成贴近真实数据的目标样本。

生成对抗网络的训练过程见图 1,生成对抗网络要做的就是通过对抗训练让生成器去拟合真实训练数据的分布,图像生成任务就是拟合真实训练数据集图像的像素概率分布。生成对抗网络通过同时更新判别器模型 D 的概率分布(图 1 蓝色虚线)来训练,让判别器模型 D 鉴别数据是来源于真实数据集的分布(图 1 黑色点线)还是生成的样本分布(图 1 绿色实线)。横线表示的是随机采样的样本空间,横线表示的是生成器模型映射以后学习到的概率分布的范围和密度,向上的箭头表示了映射是如何将非均匀分布加在转换的样本上的。在图 1(a)中,判别器 D 刚开始训练,分类能力还很弱,波动较为明显,但还是能初步区分出真实训练样本和生成样本,这时候判别器 D 是一个部分准确的分类器;图 1(b)中,判别器 D 训练得更好一些,可以更明显地区分出生成样本,明显没有波动;图 1(c)中,更新了生成器模型 G 之后,判别器模型 D 的梯度引导向更有可能被分类为真实数据的区域训练,绿色的线开始更偏向黑色点线;图 1(d)中,随着训练的持续,由于两个网络模型都得到了提升,如果生成器 G 和判别器 D 有足够的力量,它们将达到一个平衡,无法再进一步更新。




图 1 生成对抗网络的训练过程

### 2.2 生成器网络

在深度学习领域,相比于自然图像,医学图像具有更高的获取难度,如果使用结构复杂参数量大的模型,容易过拟合,U-Net 网络是一个轻量级的网络,且 U-Net 特有的跳跃连接可以融合不同层级的特征,因此引入改进的 U-Net 深度卷积神经网络,作为网络模型的生成器模块。

生成器网络模型是建立的 U 型生成对抗网络的重要部分,原始的生成对抗网络采用编码器-解码器作为生成器,本文采用改进的 U-Net 卷积神经网络作为生成器网络。U 型卷积神经网络(U-Net)<sup>[21]</sup>是在 2015

年被提出,用于解决医学图像分割任务,U-Net 结构见图 2。




图 2 U-Net 网络结构

这是一个经典的全卷积网络结构,网络中没有全连接层,每一个蓝色的框就是一个多通道的特征图,框顶部是通道个数,框左下角边缘是图像尺寸,白色的框是要拼接到解码器中的图像特征层。U-net 包括两个部分,类似编码器-解码器:第一部分用于特征提取,该部分遵循卷积网络的经典结构,包括重复使用卷积层、线性整流单元(ReLU)和最大池化层;第二部分用于上采样,包括多个卷积层和上采样层,特别的是该部分在每个卷积层之前,将输入和解码器部分对应的编码器部分中镜像层之间进行拼接,则该卷积层的输入通道数增加了 1 倍,这样做的好处是能够直接充分利用编码器部分的特征信息,当高层次和低层次的特征融合时,最后的分割效果会非常好。网络的命名就来源于其对称 U 型结构的网络特征。

使用改进的 U-Net<sup>[22]</sup> 在 2017 年被提出,结构见图 3。

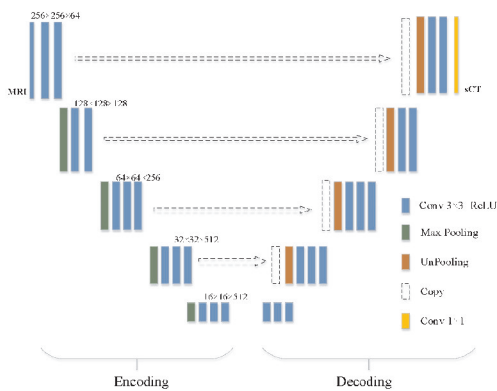


图 3 改进的 U-Net 网络结构

该生成器网络与 U-Net 类似,由左侧编码器和右侧解码器两部分组成,编码部分的行为类似传统卷积神经网络,学习从 MRI 中提取越来越复杂的特征层次结构,解码部分对提取到的特征进行变换,逐步从低分辨率到高分辨率重构 sCT 图像,网络最终的输出是与输入图像相同大小的二维 CT 图像切片。引入直接连接在编码部

分与解码部分之间,网络编码部分的高分辨率特性可以作了解码部分卷积层额外的输入,这样的设计可以使解码部分产生更贴近真实数据的 CT 图像。

2.3 判别器网络

判别器网络输出一个预测值,区分真实 CT 数据和生成 sCT 数据,预测值为[0,1],真实 CT 即为获取的病人 CT 数据,生成 sCT 为生成器网络输出的结果。判别器网络的体系结构见图 4,判别器网络由 5 层卷积层组成,卷积层后使用激活函数,前 4 个激活函数为 LeakyReLU,可以防止梯度稀疏,最后一个激活函数为 sigmoid。




图 4 判别器网络

2.4 U 型生成对抗网络

本文搭建的 U-GAN 网络生成模型中,结合改进的 U-Net 网络,作为生成对抗网络的生成器模型,利用 U-Net 特有的跳跃连接融合不同层级的特征,以此弥补网络自编码阶段中高级语义信息获取中的信息缺失,MRI 与 CT 图像虽然成像原理不同,外观上也有极大的区别,但是对于同一患者的同一位置,解剖信息是一致的,基于此实现 MRI 到 CT 图像的生成。生成模型包括生成器和判别器两个部分,对于给定的 MRI-CT 图像对,将 MRI 作为生成器网络的输入,CT 图像作为网络学习的目标。生成器网络结构与 U-Net 网络结构类似,由左侧编码器和右侧解码器两部分组成,编码部分的行为类似传统卷积神经网络,学习从 MRI 中提取越来越复杂的特征层次结构,解码部分对提取到的特征进行变换,逐步从低分辨率到高分辨率重构 sCT 图像,网络最终的输出是与输入图像相同大小的二维 CT 图像切片,即 sCT(synthesis CT)。判别阶段将 sCT 和 CT 图像输入判别器网络,判断输入图片的真假。

U-GAN 网络的对抗损失函数可描述为

$$\mathcal{L}_{GAN}(G,D)=\mathbb{E}_{ct}[\lg D(ct)] + \mathbb{E}_{mri}[\lg(1-D(G(mri)))] \tag{1}$$

生成器 G 目标是最小化这个目标损失函数,让判别器 D 无法分别出生成的 CT 图像,作为对抗,判别器 D 目标是最大化这个目标损失函数,尽可能分辨出图片是生成的 CT 图像。以前方法发现,将 GAN 的目标损失函数与传统损失混合是有好处的,判别器的工作保持不变,生成器 G 生成的内容不仅可以欺骗判别器,还能在更接近



真实图像,引入  $L1$  距离可以减少模糊程度:

$$\mathcal{L}_{L1}(G) = \mathbb{E}_{\text{mri}, \text{ct}} [\| \text{ct} - G(\text{mri}) \|_1] \quad (2)$$

目标损失函数可以表示为

$$G^* = \operatorname{argmin}_G \max_D \mathcal{L}_{\text{GAN}}(G, D) + \lambda \mathcal{L}_{L1}(G) \quad (3)$$

U-GAN 网络的实现流程见图 5, CT 图像生成流程可分为输入、训练网络、以及输出 3 个部分。输入阶段,将处理获得的 2D MRI 切片图像,作为生成器模型的输入,送入到网络模型当中。网络训练阶段,整个模型训练一个轮次,首先固定判别器模型  $D$ ,对于生成器模型  $G$  来讲,输入 2D MRI 切片图像,生成器模型  $G$  生成一个 sCT 图像,接着将生成的 sCT 图像输入判别器模型  $D$ ,判别器模型  $D$  输出一个反应图像真假的概率值,以此提供给生成器模型学习的梯度。该步骤重复 3 次,此时固定生成器模型  $G$ ,将生成器模型生成的 sCT 图像和真实的 2D CT 图像传入鉴别器模型  $G$ ,输出概率值标量,更新一次鉴别器模型,这样就完成了模型一个轮次的训练。输出阶段,从测试集中取 2D MRI 图像,传入生成器模型  $G$  中,输出对应的 2D sCT 图像,然后对 sCT 图像进行质量分析,来衡量网络模型的图像生成质量。




图5 U-GAN 网络研究流程

## 2.5 MRI 生成 CT 评价标准

通过医学图像的生成,可以实现不同模态医学图像之间的转换,如基于 MRI 生成 CT 图像,生成的图片质量好不好,通常有主观评价和客观评价两种。

### 2.5.1 主观评价

一些特殊情况下,无法知道生成后的图像是否反映真实解剖信息,也无法用定量评价指标来做定量分析,只能借助有经验的放射科专家凭借临床累积的知识与经验来分析评价。

### 2.5.2 客观评价

有已知真实的图像数据,则可以用生成的图像数据来和这些真实的图像数据之间做比较,定量地来衡量生成图像与真实图像之间的差异性,差异越小,就可以说明生成的图像质量越好,越接近真实图像。一些常用的定量评价指标有平均绝对误差 (mean absolute error, MAE)、峰值信噪比 (peak signal to noise ratio,

PSNR) 和结构相似度 (structural similarity index, SSIM)<sup>[1]</sup> 表达式以下依次列出:

$$\text{MAE} = \frac{\sum_{i=1}^n |I_{\text{CT}(i)} - I_{\text{sCT}}|}{n} \quad (4)$$

$$\text{PSNR} = 10 \cdot \lg \left( \frac{\text{MAX}^2}{\text{MSE}} \right) \quad (5)$$

$$\text{SSIM} = \frac{(2\mu_x\mu_y + c_1)(2\sigma_x\sigma_y + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (6)$$

其中,  $y$  表示生成的图像,  $x$  表示真实的参考图像,  $y_i$  与  $x_i$  分别是生成的图像和真实参考图像的像素值,  $n$  为像素个数。MAX 为真实图像与生成的图像的最大可能值。PSNR 即表示峰值信号的能量与噪声的平均能量之比,单位为 dB,数值越大表示失真越小。SSIM 用于评价图像整体上的相似程度,范围  $[0, 1]$ , 其值越大说明两张图片越相似,  $\mu_x$  与  $\mu_y$  分别表示真实图像与生成图像的均值,  $\sigma_x$  与  $\sigma_y$  分别表示真实图像与生成图像的标准差,  $c_1$  与  $c_2$  则是用来维持稳定的常数。

## 3 实验分析

### 3.1 数据集

采用华西医院的 80 例病人 (男/女: 42/38) 的鼻咽癌三维数据的 MRI-CT 图像对,且已配准。CT 图像通过西门子 SOMATOM Definition AS+ 系统获取,体素尺寸范围为  $0.88 \text{ mm} \times 0.88 \text{ mm} \times 3.0 \text{ mm}$  到  $0.97 \text{ mm} \times 0.97 \text{ mm} \times 3.0 \text{ mm}$ 。MRI 由 Philips Achieva 3T 扫描仪获得。采用 T1 加权图像, T1 加权图像具有  $0.61 \text{ mm} \times 0.61 \text{ mm}$  的高切片分辨率  $0.8 \text{ mm}$  的切片间隔。所有成像数据均采用 DICOM 格式编码,并经华西医院放射科批准使用。

### 3.2 实验结果

实验在深度学习 Pytorch 框架 python 语言完成,实验系统环境是 Ubuntu 18.04 操作系统、NVIDIA Tesla T4 GPU 服务器。

所用数据共 80 例病人的医学图像数据对,将 72 组病人的数据用作训练数据,8 例病人的数据用作测试数据,从配准好的三维数据中读取二维切片,最终获得训练数据 4450 组 MRI-CT 图像对,测试数据 500 组 MRI-CT 图像对,分别在 U-Net 和本文网络进行实验。网络模型使用 Adam 优化器,训练模型 60000 轮次 (epoch),生成器  $G$  与判别器  $D$  交替训练,  $G$  利用  $D$  反馈的损失函数信息实现权值更新,初始学习率设置为

0.001,根据经验设为 10。模型在单个 NVIDIA Tesla T4 GPU 服务器上训练,本文网络模型在数据集上完整训练一次需花费168 h,使用训练好的模型做一次 MRI 到 CT 图像的生成大约平均需要7.2 s,实验环境设置见表1,超参设置见表2。本文采用平均绝对误差

表1 实验环境设置

| 实验环境   | 配置信息         |
|--------|--------------|
| 操作系统   | Ubuntu 18.04 |
| GPU    | Tesla T4     |
| 显存     | 8 GB         |
| 编程语言   | Python 3.6   |
| 深度学习框架 | Pytorch      |

表3 U-Net 与 U-GAN 实验结果对比

|            | MAE         |             | PSNR/dB      |              |
|------------|-------------|-------------|--------------|--------------|
|            | U-Net       | U-GAN       | U-Net        | U-GAN        |
| Slice1     | 0.073       | 0.044       | 54.367       | 58.286       |
| Slice2     | 0.085       | 0.058       | 53.563       | 58.277       |
| Slice3     | 0.070       | 0.041       | 59.767       | 62.511       |
| Slice4     | 0.071       | 0.046       | 54.476       | 58.541       |
| Average±SD | 0.075±0.007 | 0.047±0.007 | 55.543±2.845 | 59.404±2.075 |




图6 切片1 U-Net 网络与 U-GAN 网络的生成结果

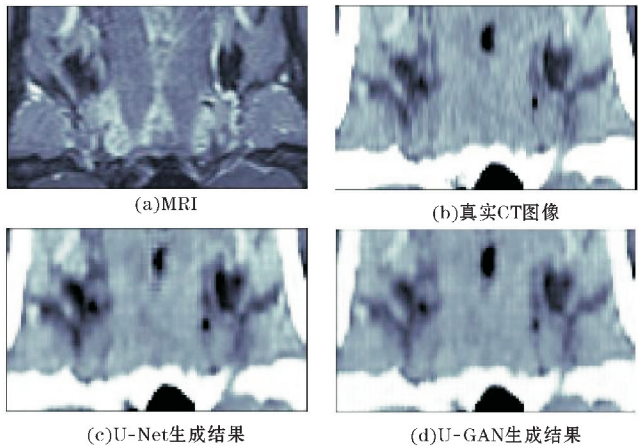


图7 切片2 U-Net 网络与 U-GAN 网络的生成结果

(MAE)和峰值信噪比(PSNR)两个评价指标来评价生成结果,生成结果见表3,结果展示见图6、图7。

表2 超参设置

| 参数               | 参数值     |
|------------------|---------|
| Learningrate     | 1e-3    |
| Batch size       | 8       |
| Training epochs  | 60000   |
| Optimizer        | Adam    |
| Beta1            | 5e-1    |
| Input image size | 128×128 |
| Output imagesize | 128×128 |

从表3可知,本文提出的 U-GAN 网络模型 MAE 从0.075降低到0.047,平均降低了0.028,PSNR 从55.543 dB提高到59.404 dB,平均提高了3.861 dB。图6、图7展示了部分测试结果,使用改进的 U-Net 深度卷积神经网络和本文所建立的生成对抗网络生成的 CT 图像的定性比较,使用 U-Net 网络模型生成的鼻咽癌 CT 图像较本文所建立的生成对抗网络生成的 CT 图像显得模糊一些,本文建立的生成对抗网络从 MRI 生成的 CT 图像效果更接近真实 CT 图像。

4 结束语

将改进的 U-Net 网络与生成对抗网络模型相结合,提高了网络的图像生成性能,证明了医学图像生成模型可以进一步提高,实验结果也确实证明网络可以和成模糊度更低的 CT 图像,但模型仍有很大的改进空间,比如在本模型中使用的是三维数据的二维切片训练的网络,完全没有使用图像的三维结构信息,将在以后的工作中改进。

参考文献:

[1] Edmumd JM,Nyholm T. A review of substitute CT generation for MRI-only radiation therapy[J]. Ra-

- diat Oncol,2017,26,(1):28.
- [2] Kim J, Garbarino K, Schultz L, et al. Dosimetric evaluation of synthetic CT relative to bulk density assignment-based magnetic resonance-only approaches for prostate radiotherapy [J]. Radiation Oncology, 2015, 10(1):1-9.
  - [3] ShuHui Hsu, Irene Zawisza, Kyle O'Grady, et al. Towards abdominal MRI-based treatment planning using population-based Hounsfield units for bulk density assignment[J]. Physics in Medicine & Biology, 2018; 63(15):1.
  - [4] Chin AL, Lin A, Anamalayil S, et al. Feasibility and limitations of bulk density assignment in MRI for head and neck IMRT treatment planning[J]. J Appl Clin Med Phys, 2014; 15(5):4851.
  - [5] QIN Songbing, ZHOU Juying, GONG Wei, et al. Study of the feasibility and precision in dose calculation with the method of bulk density assignment [J]. Chinese Journal of Radiation Oncology, 2013, 22(3):247-249.
  - [6] Chen Lili, Nguyen B, Jones E, et al. Magnetic resonance-based treatment planning for prostate intensity-modulated radiotherapy: creation of digitally reconstructed radiographs[J]. Int J Radiation Oncol Biol Phys, 2007, 68(3):903-911.
  - [7] D H Ye, D Zikic, B Glocker, et al. Modality propagation: coherent synthesis of subject-specific scans with data-driven regularization [C]. International Conference on Medical Image Computing and Computer-Assisted Intervention, 2013; 606-613.
  - [8] Roy S, Caress A, Prince JL. Magnetic Resonance Image Example-Based Contrast Synthesis [J]. IEEE Transactions on Medical Imaging. 2013; 32(12):2348-2363.
  - [9] F Guerreiro, N Burgos, A Dunlop, et al. Evaluation of a multi-atlas CT synthesis approach for MRI-only radiotherapy treatment planning[J]. Physica Medica, 2017, 35:7-17.
  - [10] Schreibmann E, Nye J A, Schuster DM, et al. MR-based attenuation correction for hybrid PET-MR brain imaging systems using deformable image registration[J]. Med Phys, 2010, 37(5):2101-2109.
  - [11] Andreasen D, Van Leemput K, Hansen RH, et al. Patch-based generation of pseudo CT from conventional MRI sequences for MRI-only radiotherapy of the brain [J]. Med Physics, 2015, 42(4):1596-1605.
  - [12] K N D Brou Boni, L Vanquin, A Wagner, et al. Deep MR to CT synthesis using paired data in the pelvic area[J]. Physica Medica, 2019, 68:29.
  - [13] Jin C B, Kim H, Liu M, et al. Deep CT to MR Synthesis Using Paired and Unpaired Data [J]. Sensors (14248220), 2019, 19(10):2361.
  - [14] Nie D, Trullo R, Lian J, et al. Medical image synthesis with context-aware generative adversarial networks [C]. The International Conference on Medical Image Computing and Computer-Assisted Intervention, 417-425.
  - [15] Zhang Z, Yang L, Zheng Y. Translating and segmenting multimodal medical volumes with cycle- and shape-consistency generative adversarial network [C]. The IEEE Conference on Computer Vision and Pattern Recognition, 2018:9242-9251.
  - [16] Edmund J M, Nyholm T. A review of substitute CT generation for MRI-only radiation therapy [J]. Radiation Oncology, 2017, 12(1):28.
  - [17] Wang Y, Yu B, Wang L, et al. 3D conditional generative adversarial networks for high-quality PET image estimation at low dose [J]. Neuroimage, 2018, 174:550-562.
  - [18] Yang G, Yu S, Dong H, et al. DAGAN: deep de-aliasing generative adversarial networks for fast compressed sensing MRI reconstruction [J]. IEEE Trans Med Imag, 2018, 37(6):1310-1321.
  - [19] I Goodfellow, J Pouget-Abadie, M Mirza, et al. Generative adversarial nets [C]. The International Conference on Neural Information Processing Systems, Montréal. Montréal: NIPS, 2014: 2672 - 2680.
  - [20] Mardani M, Gong E, Cheng J Y, et al. Deep generative adversarial networks for compressed sensing automates MRI [J]. IEEE Trans Med Imaging, 2019, 38(1):167-179.
  - [21] O Ronneberger, P Fischer, T. Brox. U-Net: convolutional networks for biomedical image segmentation [C]. MICCAI, 2015:234-2.
  - [22] Han Xiao. MR-based synthetic CT generation u-

sing a deep convolutional neural network method  
[J]. Medical Physics,2017,44(4):1408–1419.

[23] Nie D,Cao X,Gao Y,et al. Estimating CT image  
from MRI data using 3D fully convolutional net-

works[M]. Deep Learning and Data Labeling for  
Medical Applications. Springer, Cham, 2016: 170  
–178.

CT Image Generation based on Generative Adversarial Network

WANG Lei<sup>1</sup>, LI Yuanqian<sup>2</sup>

(1. Chengdu University of Information Technology, Chengdu 610225, China;2. Chengdu Shengdaren Technology Co. , Ltd,Chengdu 610225, China)

**Abstract:** Accurate prediction of CT image generation plays an important role in MRI-only radiotherapy planning. Using MRI prediction to generate CT images can prevent patients from having separate CT scans, thus avoiding additional radiation doses. Generative Adversarial Networks (GAN) is becoming an influential method in cross-modal synthesis of medical images. In this paper, the mapping model of MRI and CT images of nasopharyngeal carcinoma was established by GAN combined with U-Net network, to realize the prediction generation of CT images in the radiotherapy guided by MRI images only. The experimental results show that the model established in this paper can generate CT images close to real data. Compared with the improved U-Net convolutional network generation model, the fuzzy degree of the image is reduced, MAE is reduced and PSNR is improved, and the generated images can better display the detailed information.

**Keywords:** generative adversarial networks; image generation; CT; MRI-only RT