

基于优化循环生成对抗网络的医学图像合成方法

曹国刚¹, 刘顺堃¹, 毛红东¹, 张 术¹, 陈 颖¹, 戴翠霞²

(1. 上海应用技术大学计算机科学与信息工程学院, 上海 201418; 2. 上海应用技术大学理学院, 上海 201418)

摘要: 放射治疗计划系统需要CT图像准确计算剂量分布, 但有时临床只能获得MR图像。图像合成能有效利用现有图像合成新模态图像, 从而增强图像信息。针对MR图像生成CT图像问题, 综合循环一致生成对抗网络不成对数据可训练合成新模态图像的特点, 以及密集连接网络的特征复用和优化信息传播的优点, 提出融合密集连接的循环生成对抗网络模型, 改善输入信息的消失和梯度信息稀释, 合成更可信的CT图像。在18个病人的数据集上训练和验证模型, 优化后的循环生成对抗网络与原方法相比, 平均绝对误差降低了3.91%, 结构相似性提高了1.1%, 峰值信噪比提高了4.4%; 与深度卷积神经网络模型和基于图谱方法比较, 相对误差分别降低了0.065%和0.55%。本文利用深度学习模型优点, 能根据MR图像合成更接近真实的CT图像, 更好地满足放射治疗计划系统剂量计算的需求。

关键词: 图像合成; 循环生成对抗网络; 密集连接网络; 不成对数据

中图分类号: TP391 **文献标志码:** A

Medical Image Synthesis Based on Optimized Cycle-Generative Adversarial Networks

CAO Guogang¹, LIU Shunkun¹, MAO Hongdong¹, ZHANG Shu¹, CHEN Ying¹, DAI Cuixia²

(1. School of Computer Science and Information Engineering, Shanghai Institute of Technology, Shanghai 201418, China; 2. School of Sciences, Shanghai Institute of Technology, Shanghai 201418, China)

Abstract: The radiation treatment plan system needs to calculate the dose distribution accurately based on CT images, but sometimes clinical MR images can only be obtained. Image synthesis effectively creates new modality images from another modality, which enhances image information. This paper presents a new method of synthesizing high precision and definition of CT images from MR images. To synthesize clearly pseudo CT images, an improved cycle-consistent generative adversarial network (CycleGAN) with densely connected convolutional network (DenseNet) is proposed. Avoiding the disappearance of input information and the vanishing of gradient information, the improved network can synthesize more credible CT images. Compared with the original method, the proposed method is reduced by 5.9% on mean absolute error, increased by 1.1% on structural similarity and increased by 4.4% on peak signal to ratio, which is trained and tested on the dataset of 18 patients. And compared with the deep convolutional neural network and the atlas-based method, the improved CycleGAN is reduced by 0.065% and 0.55% on relative error, respectively. The proposed method can synthesize more vivid CT images owing to the

基金项目: 国家自然科学基金(61976140, 61675134, 81827807, 62175156); 上海市科委科技创新行动计划(19441905800); 温州医科大学重点实验室开放项目(K181002); 上海应用技术大学协同创新项目(XTCX2019-14)。

收稿日期: 2021-04-29; **修订日期:** 2021-07-06

advantages of deep learning model, which better meets the requirements of dose calculation in radiation treatment planning system.

Key words: image synthesis; cycle-consistent generation adversarial network (CycleGAN); densely connected convolutional network (DenseNet); unpaired data

引 言

放射治疗方案需要患者拍摄病灶部位的计算机断层扫描(Computed tomography, CT)图像,用来进行放射剂量规划,也需要拍摄相应的磁共振(Magnetic resonance, MR)图像,以便更好地对肿瘤组织与健康器官分割。肿瘤病人需要分别拍摄MR和CT图像,会造成较高的社会经济负担,效率低^[1]。而且,病人在拍摄CT图像时,病人暴露在放射性的电离辐射中,对其造成二次伤害。在很多情况下,研究人员有时只能获得MR图像,因此,许多研究人员希望从MR图像中合成相应的CT图像^[2]。

MR合成CT图像的深度学习方法是风格迁移方法的延伸,叶继华等^[3]提出结合残差密集生成对抗网络对高清动漫进行人脸生成,该模型提升了动漫人脸识别率的效果。然而在深度学习中,随着网络加深,梯度信息消失的问题越发明显,许多研究人员提出解决方案,如Huang等^[4]提出密集连接网络,保证网络中层与层之间有最大程度的信息传递。

MR合成CT图像的主流方法是深度学习,其他种类方法没有深度学习方法易于使用且性能好。Xiao^[5]2017年提出运用深度卷积神经网络(Deep convolutional neural network, DCNN)方法在脑部图像上进行基于MR图像合成CT图像。该模型在有限的的数据上通过迁移学习原理和从预训练的模型中初始化模型权重实现从MR图像到CT图像的端到端映射。然而,该方法在MR和CT图像在体素方向上的轻微对齐可能会导致合成模糊图像。为了解决这个问题,Nie等^[6]提出在生成式对抗网络(Generative adversarial networks, GAN)上将体素损失与图像损失相结合,该网络中生成器卷积神经网络和判别器网络相竞争;判别器旨在将合成的伪CT图像与真实CT图像区分开,并且其判别器根据合成CT图像的整体质量提供反馈给生成器。

虽然Dong等提出的生成对抗网络方法可以通过合并图像损失解决图像未对准的问题,但该方法仍存在体素损失成分的问题,并且需要成对的MR和CT图像数据训练集。然而在现实生活中,研究人员很难获取到成对的训练集。Yi和Zhang等提出利用不成对的自然图像训练图像生成图像的卷积神经网络方法,即对偶模式学习生成对抗网络(Dual learning GAN, DualGAN)^[7]和循环生成对抗网络(Cycle-consistent GAN, CycleGAN)^[8]。这些卷积神经网络模型将图像从一个域转换到另外一个域。与上述提到的方法不同,训练过程中的损失函数仅依赖于由判别器网络确定的合成图像的整体质量。为了让合成图像更加真实且与输入图像没有相似性,该文提出周期一致性的概念,即训练一个额外的卷积神经网络将合成图像转换回原始域,并将重构图像与原始图像之间的差异作为正则项函数加入到训练中。

Wolterink等^[9]利用CycleGAN模型从大脑MR图像合成CT图像,并且提出不需要同一个患者的空间对齐的MR和CT图像进行训练。2D-CycleGAN生成的结果在用于训练的切片上看起来不错,但用于构建3D容积时,生成的图像会观察到空间不一致。Zhang等^[8]尝试研究用于图像翻译的3D-CycleGAN,但是其训练需要大量数据,这些数据很难获取。

当具有不成对数据时,本文利用优化后的循环生成对抗网络方法从MR图像合成CT图像,可以减少大量的成对数据采集的工作量,解决训练样本不足的问题。该方法利用循环生成对抗网络可以通过使用不成对数据训练完成图像翻译,避免了训练数据集的配准精度不高的问题。

在传统循环生成对抗网络和密集连接网络的启发下,本文提出优化后的循环生成对抗网络方法,

将生成器转换层中的残差块换成密集连接块,其中密集连接块的优点在于随着网络层数的加深,可以缓解输入和梯度信息消失和稀释的问题。此外,目标损失函数使用最小二乘生成对抗网络(Least square GAN, LSGAN)平方差损失代替传统的GAN损失,获取图像离决策边界的距离,且不容易达到饱和状态使其网络训练更稳定。

1 融合密集连接的循环生成对抗网络模型

1.1 循环生成对抗网络模型

假设有一个包含大脑MR图像 $x \in \mathbf{R}_{\text{MR}}^{h \times w \times d}$ 和CT图像 $y \in \mathbf{R}_{\text{CT}}^{h \times w \times d}$ 的数据集,目标是学习一个可以表示为 $f: x \rightarrow y$ 的交叉模态映射,其中 f 表示大脑MR和CT图像之间的复杂非线性映射。然而,不同受试者的脑解剖之间存在着不同的几何结构,对跨模态网络的基因擦除能力提出了巨大的挑战。为了应对这一挑战,研究人员提出不同的网络模型来进行MR跨模态合成CT。

当前最流行的生成模型是生成对抗网络,该网络由Goodfellow等^[10]提出,其有两个子网络:生成器和判别器。在生成任务中,生成器学会捕捉真实的数据分布,并将其潜在向量映射到合成图像中;判别器估计来自真实图像而不是合成图像的输入样本分类概率。在对抗性训练机制中同时训练生成器和判别器,生成器训练生成无法与真实图像区分的合成图像,而判别器则旨在区分两者间的不同。当训练模型收敛时,生成器能够产生接近真实的假图像,而判别器很难识别出真实图像还是合成的伪图像。

医学图像数据匮乏,有时候很难得到成对的MR和CT图像,因此研究人员提出利用CycleGAN来克服这一困难。CycleGAN是对生成对抗网络进行改变的一种网络体,在没有成对训练数据的情况下,将源域MR图像转换到目标域CT图像。如图1中循环生成对抗网络的目标是学习一个映射 G ,将源域MR图像转换到目标域CT图像,再使用另一个生成器 F ,将图像从目标域CT图像转换回源域MR图像,引入一个循环一致性损失实现 $F(G(\text{MR})) \approx \text{MR}$ 。最小化输入图像与 $F(G(\text{MR}))$ 的损失,就需要 G 生成的图像不会与最初输入的图像有太大的差异,否则通过 F 生成器转换回去获得的图像就与最初输入图像有较大的不同。在CycleGAN中有两个生成器与两个判别器,其核心思想就是循环一致性,即原始输入MR通过生成器 G 获得CT图像后,可以获得与图像MR同源域的从合成CT图像生成的MR图像,最终保证原始MR图像与伪MR图像一致,相当于让图像循环了一周回到起点并且保持一致。循环生成对抗网络可以解决生成器生成图像与输入图像无关的问题,为了让生成图像与输出图像产生关联,除了使用编码器,还使用另外一个生成器将上一个生成器生成的图像转换回去。CycleGAN生成器利用残差块,残差网络可以更好地保存图像的语义信息。

CycleGAN中的生成器是卷积神经网络和残差网络相结合,残差网络将输入数据交由特征层获得特征数据后传递给输出层,并且将部分输入数据直接传递给输出层,其目的在于保留输入数据部分特征,加强输入数据与输出数据之间的关系。生成器还添加了编码-解码模块,用来提高信息传递的质量,从而激活比较集中的特征图^[11]。

CycleGAN中的判别器采用5层卷积层,4个卷积和实例归一化处理以及LeakyRelu作为激活函数,最后输出层采用sigmoid函数,判断该输出是否为真实的CT图像。

CycleGAN的目标损失函数使用LSGAN平方差损失代替传统的GAN损失(交叉熵)。LSGAN是为了解决传统GAN中生成图像不理想以及训练过程中不稳定的过程,而交叉熵损失无法让生成器继续生成那些被判别器鉴别为真实图像的图像。故而使用最小二乘的方式可以获取图像离决策边界的距离,同时让较远的数据获得与距离成正比的惩罚项,这样判别器的梯度要接近于0,就必须让生成器图像接近真实图像所在的位置,并且该损失函数不容易到达饱和状态,有利于网络训练。

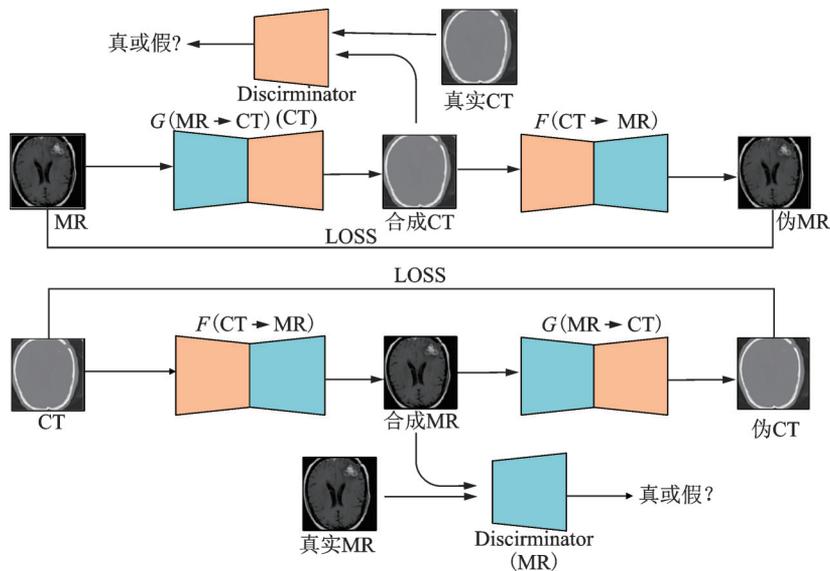


图1 优化的循环生成对抗网络模型图

Fig.1 Diagram of improved CycleGAN model

当输入信息和梯度信息进入深层网络时,两者的信息将消失和被稀释。为了解决这个问题,可以执行从浅层网络到深层网络的快捷连接,这部分最有效的模型之一就是密集连接卷积网络。在许多计算机视觉任务的准确性和效率等方面,使用密集连接网络比残差网络等其他方法的优势都得到了很好的证明。

1.2 融合密集连接网络的生成器

优化CycleGAN的生成器首先提出将密集连接网络嵌入生成器中,先卷积解码MR图像信息,再通过密集连接块改善输入和梯度信息消失和稀释情况,最后解码生成CT图像。

在密集连接的启发下,本文提出在循环生成对抗网络的生成器的转换层采用密集连接块。设 x_l 表示第 l 层输出,密集连接可表示为

$$X_l = H_l[(x_{l-1}, x_{l-2}, \dots, x_{i_0})] \quad l = 1, 2, \dots, n \quad (1)$$

式中: H_l 表示卷积运算, $[(x_{l-1}, x_{l-2}, \dots, x_{i_0})]$ 表示级联连接。

优化循环生成对抗网络的生成器为端到端的卷积神经网络,共有24个卷积层。如图2所示,输入MRI图像首先经过卷积核大小为 7×7 的卷积层,再使用重复的卷积核大小为 3×3 的卷积层来提取图像特征,每个卷积操作后均包含1个实例归一化层和1个ReLU激活函数,编码部分使用最大池化来减少特征尺寸,经过1个池化层,图像大小缩小1倍,特征通道数增加1倍,编码后的特征图进入到密集连接块中,密集连接块中包含3个卷积层,每一层都与之前的层相连接,每一层接收前面所有层的状态,然后将新的状态传递给下一层,改变状态,但也传递需要保留的特征信息,解码部分使用上采样操作来增大特征尺寸,经过两个上采样。编码后使用密集连接块,进一步利用密集连接的特征的传递以及更有效地重用特征,同时也可以防止网络深度增加时输入和梯度信息的消失。

基于密集连接块的生成器,先进行编码,再进行密集连接块网络提取特征,最后进行解码。编码部分是下采样卷积神经网络,该部分从输入的MR图像中提取复杂的特征层次信息。密集连接块来代替原本的残差块,在解码和编码中间部分使用层与层之间密集连接。密集连接可以提高网络的信息流和参数效率,方便地训练合成模型。解码部分进行上采样反卷积操作,逐步重建对应真实MR图像的CT

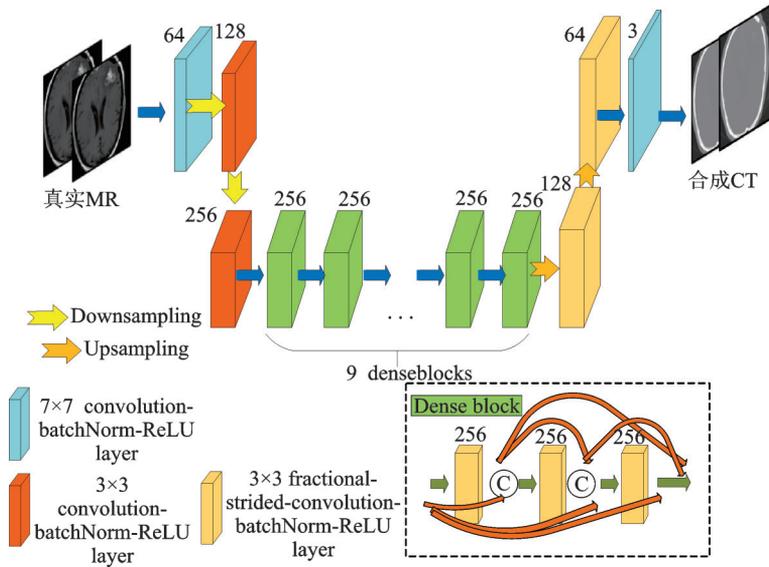


图2 优化循环生成对抗网络的生成器网络图

Fig.2 Generator network diagram of improved CycleGAN

图像的预测。该生成器的最后输出是合成CT图像的二维切片图像,其大小与输入MR图像尺寸相同。

每个密集连接块包括3个卷积层,每个卷积层的卷积核大小为 $3 \times 3 \times 3$ 以及激活函数为修正线性单元,每个卷积层的卷积核数量如图2所示。每个卷积层中间有一个过渡层即图2中圆形C部分,其减少一半的输出特征信息,即过渡层由 $1 \times 1 \times 1$ 的卷积层组成,然后每一层的输入都有之前的层的输出,从而每一层都可以接收到来自损失函数和原始输入信息的梯度信息,使其有一个隐含的深度监督方法。

2 实验部分

2.1 实验数据

实验数据集取自18个病人的图像数据^[5],对每个患者的MR/CT图像进行刚性配准,利用N3偏压场相关算法^[12]对强度不均匀的MR图像进行了校正。为了更好地评价合成CT的精度,从每幅MR图像中自动导出二进制头掩模,将头区域与图像的非解剖、背面区域分开,这是通过在每个MR图像上应用Otsu^[13]提出的自动阈值方法来实现的。为了避免头帧对模型训练产生的不利影响,将先前计算的头掩模区域之外的所有体素HU值设置为1000,然后将每个CT图像中的头帧删除。

2.2 评价指标及训练参数

本文用3种评价指标来评价实验的优劣,分别是平均绝对误差(Mean absolute error, MAE)、峰值信噪比(Peak signal to ratio, PSNR)和结构相似性(Structural similarity, SSIM),其表达式分别为

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |R_{\text{CT}}(i) - S_{\text{CT}}(i)| \quad (2)$$

$$\text{PSNR} = 10 \lg \left(\frac{\text{MAX}^2}{\text{MSE}} \right) \quad (3)$$

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

式(2)中 i 为图像索引, $S_{CT}(i)$ 表示由第 i 张 MRI 图像预测所得到的合成 CT, $R_{CT}(i)$ 表示第 i 张 MRI 图像对应的真实 CT 图像。平均绝对误差即合成的预测 CT 图像与真实 CT 图像的绝对值差之和, 再取平均所得。均方误差即合成的预测 CT 图像与真实 CT 图像的平方和差之和, 再取平均所得。峰值信噪 PSNR(dB) 即表示 CT 图像信号重建的质量好坏, 其中式(3)中的 MAX 指真实 CT 图像与合成 CT 图像的最大可能值。SSIM 是评价真实 CT 图像与合成伪 CT 图像整体相似程度的评价指标, 如式(4)所示, 范围在 0~1, 值越大说明两张图像越相似。式中 $\mu_{R_{CT}}$ 和 $\mu_{S_{CT}}$ 分别表示真实 CT 图像的均值、合成伪 CT 图像的均值; $\sigma_{R_{CT}}$ 和 $\sigma_{S_{CT}}$ 为真实 CT 图像和合成伪 CT 图像的协方差; $c_1 = (k_1 L)^2$, $c_2 = (k_2 L)^2$ 是维持稳定的常数, L 是像素值的动态范围, 本文中的 $L=7$, k_1 默认值为 0.01, k_2 默认值为 0.03。

网络模型使用常用的 Adam 算法来优化网络参数, 学习率设置为 0.000 2, 将批大小设置为 1, 使用端到端的学习方式, 输入 MR 图像大小为 256×256 , 输出 CT 图像大小也为 256×256 。整个模型使用 Python 语言, 由 TensorFlow 框架搭建, 在一台 Linux 系统 (Ubuntu16.04) 的工作站上运行。工作站的配置为: 8Intel(R) Xeon(R) CPUs, 64GB DDR4 RAM, 1GPU cards (TITAN X(Pascal), 12GB)。

2.3 实验结果与分析

实验将 18 个病人的 367 组 MR/CT 图像分为训练集和测试集进行训练与测试, 测试训练好的不同网络模型在相同测试数据集上的表现。首先对原方法采用的残差网络与改进后采用密集连接网络的生成器进行实验对比和分析, 接着分析在使用不同密集连接层下的实验效果, 最后实验结果表明, 使用 9 个 3 层密集连接块作为转换层的生成器网络合成的伪 CT 图像更接近于真实的 CT 图像。

首先对其定性分析, 结果如图 3 所示。从图 3 可以看出, 基于 MR 图像的 CT 图像合成结果对于大脑的绝大部分区域, 融合密集连接网络的 CycleGAN 相比于原始 CycleGAN 能够预测出更接近于真实图像的伪 CT 图像; 以及在不同层的密集连接网络比较中, 9 个 3 层的密集连接块的生成器比其他个数的其他层的密集连接块合成的伪 CT 图像更接近于真实的 CT 图像且其成像得更加清晰。如图 3 所示, 优化后的 CycleGAN 预测出的侧室前角 (红色框) 的细节更好, 而原方法和其他方法合成的 CT 图像边界较为模糊且其细节也不够具体。本文方法的合成结果恢复了真实 CT 图像的骨结构细节的模糊估计, 表明神经网络在训练样本相对有限的情况下进行训练可得到较为真实的伪 CT 图像。融合密集连接网络的 CycleGAN 合成的伪 CT 图像比原有方法的更清晰, 优化后的网络可以更好地保存图像的特征信息, 更适合医学图像分析任务。本文提出的方法显著超越了主流的 CycleGAN, 使得伪 CT 图像更加靠近真实 CT 图像, 且优化 CycleGAN 产生的伪 CT 图像的形状和细节部分更清晰。

对所有训练的模型做定量分析, 在相应的测试集上进行 MAE、PSNR 和 SSIM 这 3 个评价指标的测度, 结果如表 1 所示。其中平均绝对误差 (MAE) 值越小, 则表明合成 CT 图像越接近于真实 CT 图像; 结构相似性 (SSIM) 值越大, 表示图像失真越小; 峰值信噪比 (PSNR) 值越大, 表示图像失真越小。

由表 1 可知, 融合密集连接网络的循环生成对抗网络与原始循环生成对抗网络相比, 在 MAE 这一指标上, 从 86.8 HU 降低到 83.4 HU, 降低了 3.4; 在 SSIM 这一指标上, 从 0.966 提升到 0.977, 提升了 0.011, 值越大表示合成图像与真实图像的差距越小, 即合成图像质量越好; 在 PSNR 指标上, 从 32.164 dB 提升到 33.595 dB, 增加了 1.431。在测试时间上, 随着本文方法网络的加深, 对比原始方法测试时间也随之增加。

此外, 从表 1 数据可以看到, 若密集连接块数量不变, 层数为 3 层的情况更好。例如 3 个密集连接块时, 密集连接块为 3 层的生成器的 MAE 为 85.3 HU, 分别比 2 层和 4 层的连接块降低 3.3 和 3.7。造成这一结果的原因是在密集连接块在为 3 层时能更好地处理特征信息。从测试时间上来看, 层数越多, 则测

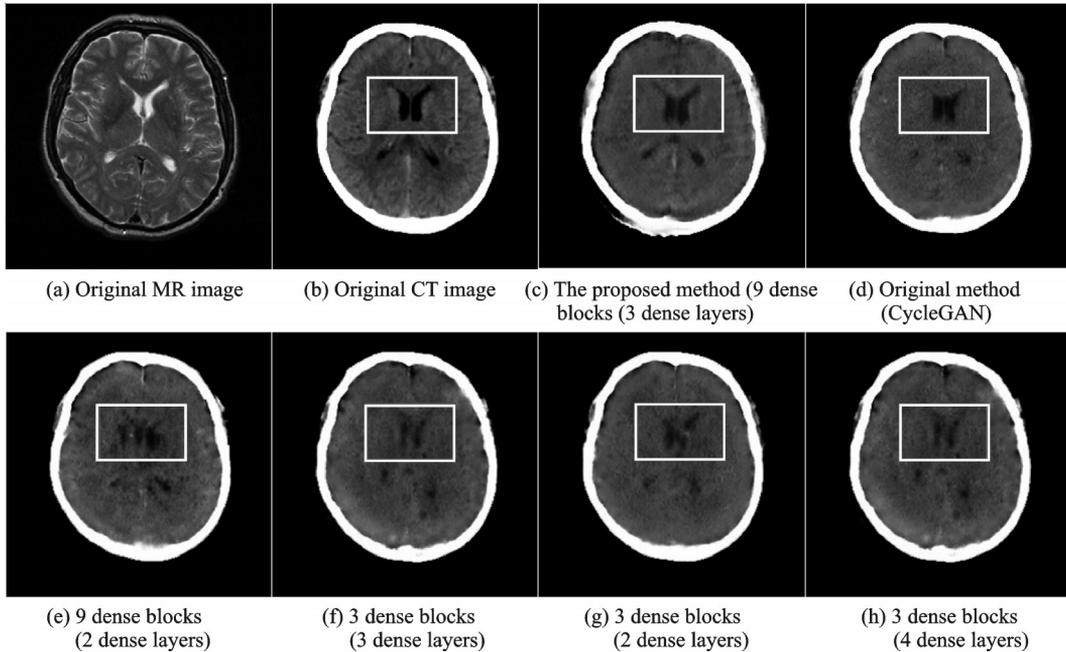


图3 不同网络模型生成的伪CT图像

Fig.3 Pseudo CT images generated by different network models

表1 不同生成器网络模型的3种评价指标和测试时间比较

Table 1 Comparison of three indices and testing time for different generator network models

生成器的不同网络模型	MAE/HU	SSIM	PSNR/dB	测试1张图像 所用时间/s
3个密集连接块(2层)	88.6	0.969	32.486	1.636
3个密集连接块(3层)	85.3	0.969	31.910	1.864
3个密集连接块(4层)	89.0	0.967	32.122	2.364
9个密集连接块(2层)	84.6	0.973	32.600	3.091
9个残差块(原方法)	86.8	0.966	32.164	2.909
本文方法(9个密集连接块(3层))	83.4	0.977	33.595	4.727
9个密集连接块(4层)	87.1	0.970	32.140	6.227
12个密集连接块(3层)	86.2	0.971	32.713	5.773

试图像所需要的时间越多。若密集连接块的层数不变,块数为9个的情况更好。例如当密集连接块的层数为3层时,9个密集连接块的生成器的MAE为83.4 HU,分别比3个和12个密集连接块降低了1.9和2.8,即本文优化后的方法使得密集连接重用特征和参数使用率较高,且测试时间相对于12个密集连接块较短并且效果更好。

将优化后的CycleGAN与DCNN和基于图谱的方法进行比较,DCNN可以从传统的单序列的MRI图像中实时产生较高质量的伪CT。由表2可知,优化后的CycleGAN在MAE指标上都所有优化,对比DCNN从84.8 HU降低到了83.4 HU,对比基于图谱的方法从94.5 HU降低到了83.4 HU;在相对误差这个指标上,相对误差是MAE值除以2 000(CT值的范围是从-1 000 HU~+1 000 HU),可以看出本

文方法对比于 DCNN 方法降低了 0.065%，对比基于图谱的方法降低了 0.55%。

从上述数据比较得出，在原有方法中，残差学习虽然可以提高不同层的梯度流，使网络更容易收敛，但 MR 图像不明显的特征信息不能被生成器中的残差网络识别出来。由于密集连接网络的特征重用参数中更有效，保证了最大的信息流，所以优化后的 CycleGAN 在所有度量中实现了最佳性能。

3 结束语

本文将循环生成对抗网络与密集连接网络融合在一起，克服网络在深度训练时的输入和梯度信息消失和稀释，对比原有方法，新网络加强特征的传递，减轻了梯度消失的现象，使得合成的伪 CT 图像更清晰。本文利用深度学习模型优点，有效解决了合成图像边界模糊问题，能根据 MR 图像合成较为真实的伪 CT 图像，更好地满足放射治疗计划系统剂量计算的需求。在未来的工作中，将考虑增强提取边界特征信息的作用，进一步克服 CT 图像骨和软组织交界处的模糊问题。

参考文献：

- [1] 菅影超,付东山,王伟.基于MRI的合成CT生成方法综述[J].中国生物医学工程学报, 2020, 39(4): 485-492.
JIAN Yingchao, FU Dongshan, WANG Wei. A review of MRI-based synthetic CT image generation[J]. Chinese Journal of Biomedical Engineering, 2020, 39(4): 485-492.
- [2] 施俊,汪琳琳,王珊珊,等.深度学习在医学影像中的应用综述[J].中国图象图形报, 2020, 25(10): 1953-1981.
SHI Jun, WANG Linlin, WANG Shanshan, et al. Applications of deep learning in medical imaging: A survey[J]. Journal of Image and Graphics, 2020, 25(10): 1953-1981.
- [3] 叶继华,刘凯,祝锦泰,等.RD-GAN:一种结合残差密集网络的高清动漫人脸生成方法[J].数据采集与处理, 2021, 36(1): 22-34.
YE Jihua, LIU Kai, ZHU Jintai, et al. RD-GAN: A high definition animation face generation method combined with residual dense network[J]. Journal of Data Acquisition and Processing, 2021, 36(1): 22-34.
- [4] HUANG G, LIU Z, LAURENS V, et al. Densely connected convolutional networks[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. [S.l.]: IEEE, 2016.
- [5] XIAO H.MR-based synthetic CT generation using a deep convolutional neural network method[J]. Medical Physics, 2017, 44(4): 1408-1419.
- [6] NIE D, TRULLO R, PETITJEAN C, et al. Medical image synthesis with context-aware generative adversarial networks [C]//Proceedings of Conference on Computer Vision and Pattern Recognition. [S.l.]: Springer, 2017.
- [7] YI Z, ZHANG H, TAN P, et al. DualGAN: Unsupervised dual learning for image-to-image translation[C]//2017 IEEE International Conference on Computer Vision (ICCV). [S.l.]: IEEE, 2017.
- [8] ZHANG Z, LIN Y, ZHENG Y. Translating and segmenting multimodal medical volumes with cycle- and shape-consistency generative adversarial network[C]//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). [S.l.]: IEEE, 2018.
- [9] WOLTERINK J M, DINKLA A M, SAVENIJE M H F, et al. Deep MR to CT synthesis using unpaired data[C]// Proceedings of Conference on Computer Vision and Pattern Recognition. [S.l.]: Springer, 2017.
- [10] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. Advances in Neural Information Processing Systems, 2014, 3: 2672-2680.
- [11] 谢烟平,谭晓阳.基于信息修正的深度残差学习[J].数据采集与处理, 2020, 35(3): 441-448.

表2 不同方法的MAE评价指标比较

Table 2 Comparison of MAE indices for different methods

方法	MAE/HU	相对误差/%
DCNN	84.8	4.240
基于图谱的方法	94.5	4.725
本文方法(优化 CycleGAN)	83.4	4.175

XIE Yanping, TAN Xiaoyang. Deep residual learning with information refinement[J]. Journal of Data Acquisition and Processing, 2020, 35(3): 441-448.

[12] SLED J, ZIJDENBOS A, EVANS A. A nonparametric method for automatic correction of intensity nonuniformity in MRI data[J]. IEEE Transactions on Medical Imaging, 1998, 17(1): 87-97.

[13] OTSU N. A threshold selection method from gray-level histograms[J]. IEEE Transactions on Systems Man & Cybernetics, 2007, 9(1): 62-66.

作者简介:



曹国刚(1977-),通信作者,男,博士,高级工程师,研究方向:人工智能、医学图像处理、计算机辅助医学图像诊断与治疗等,E-mail:guogangcao@163.com。



刘顺堃(1996-),女,硕士研究生,研究方向:医学图像生成。



毛红东(1996-),男,硕士研究生,研究方向:医学图像分割。



张术(1995-),男,硕士研究生,研究方向:医学图像分割。



陈颖(1974-),女,博士,教授,研究方向:图像处理、生物特征识别。



戴翠霞(1973-),女,教授,研究方向:生物医学光子成像技术及应用。

(编辑:王静)