

DOI:10.16136/j.joel.2022.02.0351

基于改进生成对抗网络的低剂量 CT 去噪算法

欧阳婉卿, 张 剑*, 彭 辉, 罗禹杰, 黄代琴, 杨羽翼

(湖南科技大学 信息与电气工程学院, 湖南 湘潭 411201)

摘要:针对低剂量计算机断层扫描(computerized tomography, CT)在图像采集过程中引入较多噪声,造成图像质量严重下降的问题,提出一种基于残差注意力机制与复合感知损失的低剂量 CT 去噪算法。在该算法中,利用生成对抗网络完成对低剂量 CT 图像的去噪,在网络框架中引入多尺度特征提取及残差注意力模块,以融合图像中不同尺度的信息,提高网络对噪声特征的区分能力,避免在去噪过程中丢失图像细节信息。同时采用复合感知损失函数,以加快网络收敛速度,促使去噪图像在感知上与原图像更接近。实验结果表明:与现有的算法相比,所提算法能够有效抑制低剂量 CT 图像中的噪声,并恢复更多的纹理细节;对比低剂量 CT 图像,所提算法处理后的 CT 图像峰值信噪比(peak signal-to-noise ratio, PSNR)值提高了 31.72%,结构相似性(structural similarity, SSIM)值提高了 13.15%,可以满足更高的医学影像诊断要求。

关键词:低剂量计算机断层扫描(computerized tomography, CT);生成对抗网络;多尺度特征提取;注意力机制;复合感知损失

中图分类号:TP391 文献标识码:A 文章编号:1005-0086(2022)02-171-10

Low-dose CT denoising algorithm based on improved generative adversarial network

OUYANG Wanqing, ZHANG Jian*, PENG Hui, LUO Yujie, HUANG Daiqin, YANG Yuyi

(College of Information and Electrical Engineering, Hunan University of Science and Technology, Xiangtan, Hunan 411201, China)

Abstract: In order to solve the problem that low-dose computerized tomography (CT) introduces a lot of noise in the process of image acquisition, which leads to the serious degradation of image quality, a low-dose CT denoising algorithm based on residual attention mechanism and composite perceptual loss is proposed in this paper. In this algorithm, the Generative Adversarial Networks is used to complete the denoising of low-dose CT images. The multi-scale feature extraction and residual attention module are introduced into the network framework to fuse the information of different scales in the image, improve the ability of the network to distinguish noise features, and avoid the loss of image details in the process of denoising. At the same time, the composite perceptual loss function is used to accelerate the convergence speed of the network and promote the denoising image to approach the original image perceptually. Experimental results show that the proposed algorithm can effectively suppress noise and recover more texture details in low-dose CT images compared with existing algorithms. Compared with the low-dose CT images, the peak signal-to-noise ratio (PSNR) value and structural similarity (SSIM) value of the CT images processed by the proposed algorithm are increased by 31.72% and 13.15%, which can meet the higher requirements of medical imaging diagnosis.

Key words: low-dose computerized tomography (CT); generative adversarial network; multi-scale feature extraction; attentional mechanism; composite perceptual loss

* E-mail: jzhang@hnust.edu.cn

收稿日期: 2021-05-25 修订日期: 2021-06-24

基金项目: 国家自然科学基金(11972157)和湖南省教育厅重点项目(15A066)资助项目

1 引言

随着医学影像技术的不断发展,计算机断层扫描(computerized tomography, CT)已经成为目前临床诊断使用最广泛的成像方式之一。为减少影像采集中电离辐射对人体造成的严重危害,低剂量计算机断层扫描(low-dose computerized tomography, LDCT)应运而生^[1]。然而,降低辐射剂量引入了更多的噪声与伪影,干扰医生对病情的诊断。因此,如何抑制 LDCT 图像中的噪声,并最大程度上保留原图像细节,具有重要的研究意义^[2]。

目前用于提高 LDCT 的图像质量的方法可以分为 3 类:投影域滤波法、迭代重建法、图像后处理法^[3]。图像后处理法无需依赖于原始投影数据,且易集成于 CT 成像及解析系统中,因此得以广泛应用。诸如非局部均值算法(non-local means, NLM)^[4]、自适应全变分滤波器^[5]、基于字典学习的伪影抑制算法(artifact suppressed dictionary learning, ASDL)等^[6]被研究用于 LDCT 图像的去噪任务,然而这类传统去噪算法很难精确地区分图像中的噪声与高频细节,造成去噪图像的细节过度模糊。

随着人工智能的飞速崛起,基于深度学习的图像处理算法也为 LDCT 去噪提供了巨大的发展潜能^[7]。CHEN 等^[8]将卷积神经网络应用于 LDCT 图像去噪,从 LDCT 图像到正常剂量计算机断层扫描(normal-dose computerized tomography, NDCT)图像的学习特征映射。CHEN 等^[9]提出残差编码器-解码器卷积神经网络(residual encoder-decoder convolutional neural network,

RED-CNN),将自编码器、反卷积网络和捷径连接等技术应用于 LDCT 图像去噪工作,取得了显著的效果。YANG 等^[10]提出了一种带有感知损失函数的生成对抗网络框架——WGAN-VGG (Wasserstein generative adversarial networks-visual geometry group),该算法在有效抑制 LDCT 图像中噪声的同时,还使重要信息得以保留。WANG 等^[11]提出将引入了无监督学习的方式的 CycleGAN 应用于低剂量 CT 图像去噪任务中,通过从未配对的 NDCT 和 LDCT 图像中学习器官结构的数据分布,从而达到去噪的目的。

虽然现有的算法能够在一定程度上改善 LDCT 的图像质量,但是仍普遍存在没有充分利用浅层特征、网络计算成本较高、纹理细节处理模糊等缺陷。因此,本文发挥生成对抗网络强大的学习能力和泛化能力,在网络框架中引入多尺度特征提取、残差注意力等模块并结合复合感知损失函数,提出一种应用于 LDCT 图像的去噪算法。

2 本文算法

基于残差注意力机制与复合感知损失的去噪网络(residual attention-Wasserstein generative adversarial networks with perceptual loss, RAP-WGAN)整体框架如图 1 所示,主要由生成器网络、判别器网络、复合感知损失函数等 3 个部分组成。

2.1 去噪模型

传统去噪算法一般是针对特定的噪声类型而设计,LDCT 图像的特性在很大程度上影响了这些方法的去噪性能,然而,基于深度学习的去噪算法可以完美解决 LDCT 图像中噪声模型的不确定




图 1 RAP-WGAN 的整体框架

Fig. 1 Overall framework of RAP-WGAN

的问题,因此将低剂量 CT 降噪问题建模如下:

$$X = \sigma(Y) + \varepsilon, \quad (1)$$

式中, X 为 LDCT 图像, Y 为对应的 NDCT 图像, σ 为包含量子噪声、电子噪声等参数在内的复杂退化

过程(一般为非线性的), ϵ 为无法精确建模随机噪声。

因此,LDCT 图像去噪问题转换为寻找目标函数如式(2)表示为:

$$D(X) = \arg \min \|f(X) - Y\|_2^2, \quad (2)$$

式中, $D(X)$ 为目标函数, $f(X) \approx \sigma^{-1}(X)$ 且可以通过深度学习的方法进行最佳逼近。

2.2 注意力机制

在经典去噪算法中,普通的卷积运算平等地对待各通道的特征映射进行特征提取,导致网络缺乏对高、低特征信息的合理利用^[12,13]。注意力机制则是通过不同特征通道与特征空间的相互依赖性,对图像中的被污染的像素进行定位,充分提取噪声周围的上下文信息。因此,在 RAP-WGAN 中引入注意力模块,提高网络对噪声特征的关注,注意力模块概述如图 2 所示。




图 2 注意力模块概述

Fig. 2 The overview of attention module

注意力模块主要由通道注意力及空间注意力两部分组成,其计算过程描述如下:

$$z' = M_C(z) \otimes z, \quad (3)$$

$$z'' = M_S(z') \otimes z', \quad (4)$$




图 3 通道注意力模块示意图

Fig. 3 Diagram of channel attention module




图 4 空间注意力模块示意图

Fig. 4 Diagram of spatial attention module

式中, z 为输入的特征映射,大小为 $h \times w \times c$, $M_C(z)$ 为一维通道注意力映射,大小为 $1 \times 1 \times c$, $M_S(z')$ 为二维空间注意力映射,大小为 $h \times w \times 1$, h, w, c 分别为高度、宽度和长度。

2.2.1 通道注意力

通过充分利用各通道间特征信息的相互关系,智能地给予各通道不同的注意量,生成一种通道注意力掩码^[14],通道注意力模块示意图如图 3 所示。

首先对输入映射分别采用最大池化和平均池化来聚合特征图的空间信息,再由两个 1×1 的卷积层对通道信息进行压缩 r 倍后恢复,其中 r 是缩减率,最后通过元素求和与 Sigmoid 函数来合并特征,得到通道注意力掩码。该过程可描述为:

$$M_C(z) = \sigma[F_{MLP}(Pool_{Avg}^C(z)) + F_{MLP}(Pool_{Max}^C(z))], \quad (5)$$

$$F_{MLP}(p) = W_u^C \times \delta[W_d^C(p)], \quad (6)$$

式中, z 为 CA 模块的输入映射, $Pool_{Avg}^C$ 、 $Pool_{Max}^C$ 分别为全局平均池化与最大池化运算, p 为经池化运算后得的特征向量, W_u^C 、 W_d^C 分别为两个为 1×1 大小卷积核的权值, σ 、 δ 分别为 Sigmoid 函数和 ReLU 函数。

2.2.2 空间注意力

利用各空间位置的特征之间存在一定相互关系,在原始的空间注意力模块上进行改进,引入空洞卷积获得更大的感受野,同时有助于捕获不同空间位置上噪声多尺度上下文信息,从而更有效地捕捉图像中的噪声特征。空间注意力模块示意图如图 4 所示。

首先利用 1×1 卷积对跨通道维数的特征映射进行整合和压缩,再由两个核为 3×3 的空洞卷积对特征向量的空间信息进行充分提取,最后通过 1×1 卷积与 Sigmoid 函数得到空间注意力掩码。该过程可描述为:

$$M_s(z') = \sigma[W_2^S(f_{\text{dilated}}^{3 \times 3}(W_1^S(z')))], \quad (7)$$

式中, z' 为 SA 模块的输入, $f_{\text{dilated}}^{3 \times 3}$ 代表两层大小为 3×3 的空洞卷积层, W_1^S 和 W_2^S 分别为卷积核大小为 1×1 用于压缩和整合通道尺度时的权值, σ 为 Sigmoid 激活函数。

2.3 网络结构

2.3.1 生成器网络结构

生成器网络内部结构如图 5 所示,主要由浅层特征提取、中高层特征提取、重构模块等 3 个部分组成。

LDCT 图像输入到多尺度特征提取模块中,采用 3 个大小为 5×5 、 3×3 和 1×1 ,核数分别为 10、44

和 10 的卷积层以获得 LDCT 图像不同感受野大小的低维特征,然后通过 Concat 函数连接特征映射的通道,融合图像中不同尺度的信息,增加特征提取的多样性。随后,输入的由 8 个堆叠的残差注意力模块组成中高层特征提取部分,每个残差注意力模块由两个残差单元、注意力模块及短接结构组成,其残差注意力模块结构如图 6 所示。

该残差注意力模块中,残差单元采取经典的“Conv+BN+ReLU”组合,卷积层采用 64 个大小为 3×3 的卷积核,激活函数采用带有参数的 PReLU 函数保证网络的非线性。注意力模块包括前文中提及的通道注意力及空间注意力两部分,注意力模块的引入可以使中高层特征提取获得一定的增益,提高了网络对噪声特征的敏感度,以恢复去噪 CT 图像更精细的纹理细节。最后引入短接结构对每两个残差单元进行连接,避免在深层特征传输过程中信息丢失的问题出现,增强网络的泛化性能。




图 5 生成器网络内部结构

Fig. 5 The internal structure of the generator network




图 6 残差注意力模块结构图

Fig. 6 Structure of residual-attention module

在重构模块中由两个大小为 3×3 卷积核将图像各层次特征进行筛选和融合。由于输入与输出的图像底层的结构特征都是相似的,为了恢复潜在的细节及结构特征,引入长跳跃连接结构,将图像浅层

特征无损失地传输到深层网络与高层特征进行融合。最后通过大小为 9×9 步长为 4 的大尺度卷积层对获取到的特征映射进行重构,得到单通道的去噪图像。

2.3.2 判别器网络结构

判别器网络内部结构如图 7 所示,判别器网络由 6 个卷积层、Leaky-ReLU 激活层及两个全连接层构成,此外在卷积层末端引入空间注意力,以提高判别器网络的鉴别性能。6 个卷积层的卷积核尺寸均设置为 3×3 ,每层卷积分别输出 64、64、128、128、256、256 个特征图,单数层的卷积步长设置为 1 用于特征提取,双数层的卷积步长设置为 2 用于下采样,防止在池化操作中容易丢失图像中重要的细节信息,判别器网络最后分别是两个 1024 输出与单输出

全连接层。




图7 判别器网络内部结构

Fig. 7 The internal structure of the discriminator network

2.4 损失函数构建

一般地,生成对抗网络(generative adversarial network, GAN)主要通过最小化真实数据与生成数据之间的距离来构建损失函数,优化后的 WGAN-gp 采用 Wasserstein 距离对生成分布与真实分布进行距离度量,同时引入梯度惩罚项对目标函数进行约束,有效地解决 GAN 训练不稳定、性能病态等问题。其对抗损失函数的计算式为:

$$L_{\text{adv}}(D, G) = -E_{y \sim P_y}[D(y)] + E_{\tilde{x} \sim P_{\tilde{x}}}[D(\tilde{x})] + \lambda E_{\tilde{x} \sim P_{\tilde{x}}}[\|\nabla_{\tilde{x}} D(\tilde{x})\|_p - 1]^2, \quad (8)$$

式中, x 为输入样本 LDCT 图像, y 为真实样本 FDCT 图像, P_x 为输入数据分布, P_y 为真实数据分布, $\tilde{x} = G(x)$ 为生成样本, $P_{\tilde{x}}$ 为生成数据的概率分布, λ 为加权参数, $\tilde{x}$ 为对生成样本与输入样本进行均匀采样, $P_{\tilde{x}}$ 表示采样数据的概率分布, G 为生成器映射函数, D 为判别器映射函数。

为提高网络的去噪能力,在 WGAN-gp 的基础上结合内容损失进行优化,构成一种复合感知损失函数:采用性能更优且对异常点、离群点更不敏感的 $\text{smooth } L_1$ 距离作为像素级的内容损失函数,用于计算生成图像与真实 FDCT 图像之间的误差, $\text{smooth } L_1$ 损失的定义计算式为:

$$\text{smooth } L_1(G) = \begin{cases} \frac{1}{2}(\tilde{x} - y)^2, & |\tilde{x} - y| < 1 \\ |\tilde{x} - y| - \frac{1}{2}, & \text{otherwise.} \end{cases} \quad (9)$$

然而,仅使用逐像素损失的方法无法捕捉到去噪图像和 FDCT 图像之间的感知差异,因此,引入 VGG-19 网络作为损失网络,对图像进行高维特征提取,再计算其欧式距离来衡量两者之间的高水平感知即感知内容损失^[15,16],其函数计算式为:

$$L_{\text{VGG19}}(G) = E_{(y \sim P_y, \tilde{z} \sim P_{\tilde{z}})} \left[\frac{1}{C_j H_j W_j} \|\phi_j(\tilde{x}) - \phi_j(y)\|_2^2 \right], \quad (10)$$

式中, ϕ_j 为从预训练的 VGG-19 网络中提取的第 j 层特征, C_j, H_j, W_j 分别为提取的特征空间的通道数、高度及宽度。

结合式(8)、(9)、(10)得到本文网络的复合损失函数计算式为:

$$L = \min_G \max_D L_{\text{adv}}(D, G) + \lambda_1 \text{smooth } L_1(G) - \lambda_2 L_{\text{VGG19}}(G), \quad (11)$$

式中, λ_1, λ_2 为平衡对抗损失与 $\text{smooth } L_1$ 损失和 L_{VGG19} 感知损失之间的加权参数。

3 实验分析及结果

3.1 实验数据集及评价指标

本文实验使用的数据是来自 Mayo 诊所授权的“2016 年 NIH-AAPM-Mayo 诊所低剂量 CT 大挑战”的真实临床数据集^[17],该数据集中 CT 图像均为 512×512 的灰度图像。抽取其中 14 名患者的腹部 NDCT 和 LDCT 投影数据,共 4 018 张图像作为训练集,从另外的数据集中抽取一名患者的腹部 LDCT 投影数据,共 23 张图像作为验证集。

为保证实验的公平性,采用结合主观评价与客观评价的方式来测评算法对 LDCT 图像的去噪能力。采用主观平均意见值(mean opinion score, MOS)作为图像质量的主观评价标准,由 16 名评分者参考目标图像,同时对去噪图像从 1(质量差)到 5(质量好)进行比较评分。采用均方根误差(root mean square error, RMSE)、峰值信噪比(peak signal-to-noise ratio, PSNR)、结构相似性(structural similarity, SSIM)作为图像质量的客观评价标准, RMSE 值越小说明生成图像与降噪图像之间的差距越小, PSNR 值越高说明图像中含有的噪声越少, SSIM 值越接近 1 说明两组图像之间的结构性差异越小。

3.2 网络训练参数及设置

网络训练过程中,采用 Adam 算法进行优化,其

超参数设置如下:学习率 $\alpha=10^{-5}$ 、指数衰减率 $\beta_1=0.5$ 、 $\beta_2=0.999$ 。输入到网络中训练的图像 Patch 尺寸为 64, 梯度惩罚因子 $\lambda=10$, 批量尺寸大小设置为 16, 迭代步数 epoch=30 000, LeakyReLU 的斜率 $\alpha=0.2$, 并采用随机高斯分布对生成器参数进行初始化。根据不同权重条件下训练得到网络模型的性能表现, 确定复合感知损失函数中 L_1 损失加权参数 $\lambda_1=200$, 感知损失加权参数 $\lambda_2=0.1$ 。

3.3 对比实验

选择目前主流的低剂量 CT 图像去噪算法包括 CNN-MSE^[8]、RED-CNN^[9]、WGAN-VGG^[10] 与 RAP-WGAN 进行对比实验。为公平比较, 从验证集

中随机选取两张 LDCT 切片: 切片一中含有一个较大的病灶结构, 图像中噪声与高频细节深度融合, 难以分辨; 切片二中的病灶结构相对较小, 且边缘模糊, 噪声与伪影对纹理细节污染严重。

各算法对切片一的去噪效果对比图如图 8 所示, 为了更好地显示各网络去噪效果, 选取一个局部感兴趣的区域 (region of interest, ROI) 以便于观察各方法对 LDCT 图像中病灶结构及高频细节的处理效果。图 9 展示了放大图 8 中矩形框 (ROI) 部分。各算法在切片二的去噪效果对比图如图 10 所示, 图 11 展示了放大图 10 中矩形框 (ROI) 部分。

如图 8—图 11 所示, 针对 LDCT 图像各算法都





图 8 各算法对切片一的去噪效果对比图: (a) 全剂量 CT; (b) 低剂量 CT; (c) CNN-MSE; (d) RED-CNN; (e) WGAN-VGG; (f) RAP-WGAN

Fig. 8 Comparison of denoising effects of each algorithm in slice 1: (a) Full-dose CT (FDCT); (b) LDCT; (c) CNN-MSE; (d) RED-CNN; (e) WGAN-VGG; (f) RAP-WGAN






图 9 放大图 8 中矩形框(ROI)部分:(a) 全剂量 CT; (b) 低剂量 CT; (c) CNN-MSE;
(d) RED-CNN; (e) WGAN-VGG; (f) RAP-WGAN

Fig. 9 Enlarge the rectangular box (ROI) in Fig. 8: (a) FDCT; (b) LDCT; (c) CNN-MSE;
(d) RED-CNN; (e) WGAN-VGG; (f) RAP-WGAN





图 10 各算法在切片二的去噪效果对比图:(a) 全剂量 CT; (b) 低剂量 CT; (c) CNN-MSE;
(d) RED-CNN; (e) WGAN-VGG; (f) RAP-WGAN

Fig. 10 Comparison of denoising effects of each algorithm in slice 2: (a) FDCT; (b) LDCT;
(c) CNN-MSE; (d) RED-CNN; (e) WGAN-VGG; (f) RAP-WGAN






图 11 放大图 10 中矩形框(ROI)部分:(a) 全剂量 CT; (b) 低剂量 CT; (c) CNN-MSE; (d) RED-CNN; (e) WGAN-VGG; (f) RAP-WGAN

Fig. 11 Enlarge the rectangular box (ROI) in Fig. 10: (a) FDCT; (b) LDCT; (c) CNN-MSE; (d) RED-CNN; (e) WGAN-VGG; (f) RAP-WGAN

具备一定的去噪能力,但 CNN-MSE 的去噪效果不够理想,图中还保留了部分噪声与伪影,且对结构边缘显示不够清晰。RED-CNN 可以消除了图像中大量的噪声和伪像,但过度平滑的程度随之加深,在保留图像完整性方面还存在不足。与前两种算法相比,基于生成对抗网络的 WGAN-VGG 算法可以获得更好的去噪性能,处理的图像与原图像在感知效果上更接近,但图中残留的噪声对病灶边缘显示造成干扰,仍存在对高频细节重建不到位的问题,RAP-WGAN 处理的图像在有效去除噪声的同时恢复了更多的纹理细节,可以更清晰地展示病灶的边缘及结构特征,进一步提高了 LDCT 的图像质量。

为进一步展现实验结果,各算法在切片一和二上去噪效果的评价指标如表 1 和表 2 所示,且每组指标结果的最优值用黑色粗体标出。

表 1 各算法在切片一上去噪效果的评价指标
Tab. 1 Evaluation indexes of noise effect of each algorithm in slice 1

Group	Method	PSNR	SSIM	RMSE	MOS
1	CNN-MSE	32.437	0.889	9.555	2.625
2	RED-CNN	33.913	0.910	8.061	2.125
3	WGAN-VGG	31.775	0.879	10.311	3.813
4	RAP-WGAN	33.864	0.913	8.107	4.125
—	LDCT	27.046	0.824	17.772	1.625

实验结果表明:对比 LDCT 图像,RAP-WGAN 获得的去噪图像 PSNR 值平均提升 29.58%、SSIM 值平均提升 9.99%。与其他算法相比,各项指标均表现得更出色,且获得更高的 MOS 值,说明本文算法处理的图像含有的噪声更少,与 NDCT 图像的结

构性差异更小。

表 2 各算法在切片二上去噪效果的评价指标
Tab. 2 Evaluation indexes of noise effect of each algorithm in slice 2

Group	Method	PSNR	SSIM	RMSE	MOS
1	CNN-MSE	33.849	0.941	8.120	3.250
2	RED-CNN	35.608	0.949	6.631	2.438
3	WGAN-VGG	33.274	0.935	8.677	3.813
4	RAP-WGAN	35.793	0.952	6.492	4.500
—	LDCT	26.721	0.872	18.451	1.563

综上所述,对比目前主流的去噪算法,RAP-WGAN 可以更好地抑制 LDCT 图像中混合的噪声及伪影,保留图像中绝大部分的纹理细节,可以更清晰地显示各部分结构特征,在视觉上与原图的结构相似性较高,得到的去噪图像更加自然,证明了本文基于残差注意力机制与复合感知损失的低剂量 CT 去噪算法的优势性。

3.4 消融实验

本文算法主要是从改进网络结构及优化损失函数两个方面对 WGAN 的去噪性能进行提升,因此在本节中,分别对未经网络结构改良的模型(A 实验组)及未经损失函数优化的模型(B 实验组)与 RAP-WGAN 进行对比实验,来验证残差注意力结构及感知损失函数的有效性,各组实验的参数指标均与 3.2 节中保持一致,腹部 CT 切片消融实验结果如图 12 所示。

实验结果表明:A 实验组通过残差注意力模块使得图像的内容相对应,避免出现过度光滑的情况,但从图中仍能观察到轮廓细节不够清晰;B 实验组处

理的图像保留了原图像中大部分的结构细节,使其视觉上更类似于 NDCT 图像,但由于网络结构的限制,对图像深层特征提取不够充分,图中少数白色条纹伪影未消除干净;RAP-WGAN 对 LDCT 图像的去噪效果更优,在保留原图像结构完整性的同时重建了更多的高频细节,使图像质量得以提升。

为更直观地反映实验结果,计算得到消融实验的量化评价指标如表 3 所示。表中实验结果显示:对比 LDCT 图像,本文所提改进方法处理后的图像,其 *PSNR* 值提高 31.72%,*SSIM* 值提高 13.15%,*RMSE* 值降低 62.92%,且其各项评价指标均为所有对比组中的最优。




图 12 腹部 CT 切片消融实验结果:(a) 全剂量 CT; (b) 低剂量 CT;
(c) A 实验组; (d) B 实验组; (e) RAP-WGAN
Fig. 12 Results of ablation experiment in abdominal CT slice:(a) FDCT; (b) LDCT;
(c) Group A; (d) Group B; (e) RAP-WGAN

表 3 消融实验的量化评价指标

Group	<i>PSNR</i>	<i>SSIM</i>	<i>RMSE</i>	<i>MOS</i>
A	33.348	0.936	8.603	3.563
B	33.750	0.941	8.214	4.313
RAP-WGAN	35.782	0.955	6.501	4.688
LDCT	27.165	0.884	17.531	1.875

实验结果表明,与其他实验组相比,本文算法 RAP-WGAN 生成的去噪图像无论在视觉效果上还是在各项量化评价指标方面都表现得更加优秀,因此,本文从网络结构及损失函数两个方面对 WGAN 进行改进的方法是有效的。

4 结 论

本文提出了一种基于改进生成对抗网络的低剂量 CT 去噪算法,该算法分别从网络结构及损失函数两个方面对原始网络进行优化:一方面,在 WGAN 网络架构中引入多尺度特征提取与残差注意力模块,提升网络对噪声特征的分辨能力,增强对 LDCT 图像全局信息的捕捉学习能力;另一方面,采用复合感知损失函数加快网络收敛的速度,同时,促使去噪图像在感知更接近于 NDCT 图像。通过与当前流行的 LDCT 去噪算法对比,本文算法可以有效去除 LDCT 图像中的伪影及噪声,生成的去噪图像恢复了更多的纹理细节,无论在视觉效果还是图像评价指标方面都表现更优,验证了本文改进方法的优势性。

参考文献:

- [1] NAIDICH D P, MARSHALL C H, GRIBBIN C, et al. Low-dose CT of the lungs; preliminary observations[J]. Radiology, 1990, 175(3): 729-731.
- [2] XIAO Y. Research on low-dose CT denoising method[D]. Chengdu: University of Electronic Science and Technology of China, 2020: 1-2.
肖烨. 低剂量 CT 去噪方法研究[D]. 成都: 电子科技大学, 2020: 1-2.
- [3] WANG S. Research on low-dose CT denoising method [D]. Beijing: Beijing Jiaotong University, 2019: 5.
王爽. 低剂量 CT 去噪方法研究[D]. 北京: 北京交通大学, 2019: 5.
- [4] BIAN Z, MA J, HUANG J, et al. SR-NLM: a sinogram restoration induced non-local means image filtering for low-dose computed tomography [J]. Computerized Medical Imaging and Graphics, 2013, 37(4): 293-303.
- [5] ZAMYATIN A, KATSEVICH G, KRYLOV R, et al. Adaptive multi-scale total variation minimization filter for low dose CT imaging[C]//Medical Imaging 2014: Image Processing, March 21, 2014, San Diego, California, United States. Washington: SPIE, 2014: 903426.
- [6] CHEN Y, SHI L, FENG Q, et al. Artifact suppressed dictionary learning for low-dose CT image processing[J]. IEEE Transactions on Medical Imaging, 2014, 33(12): 2271-2292.
- [7] LI K. Research on strengthening artificial intelligence deep learning in clinical application of medical imaging [J]. Chinese Journal of Medical Imaging, 2019, 35(12): 1769-1770.
李坤成. 加强人工智能深度学习在医学影像学临床应用领域的研究[J]. 中国医学影像技术, 2019, 35(12): 1769-1770.
- [8] CHEN H, ZHANG Y, ZHANG W, et al. Low-dose CT via convolutional neural network[J]. Biomedical Optics Express, 2017, 8(2): 679-694.
- [9] CHEN H, ZHANG Y, KALRA M K, et al. Low-dose CT with a residual encoder-decoder convolutional neural network [J]. IEEE Transactions on Medical Imaging, 2017, 36(12): 2524-2535.
- [10] YANG Q, YAN P, ZHANG Y, et al. Low-dose CT image denoising using a generative adversarial network with Wasserstein distance and perceptual loss[J]. IEEE Transactions on Medical Imaging, 2018, 37(6): 1348-1357.
- [11] WANG T, LEI Y, TIAN Z, et al. Deep learning-based image quality improvement for low-dose computed tomography simulation in radiation therapy[J]. Journal of Medical Imaging, 2019, 6(4): 043504.
- [12] HUANG Z, CHEN Z, ZHANG Q, et al. CaGAN: a cycle-consistent generative adversarial network with attention for low-dose CT imaging[J]. IEEE Transactions on Computational Imaging, 2020, (99): 1-1.
- [13] CAI J, MENG Z, HO C M. Residual channel attention generative adversarial network for image super-resolution and noise reduction[EB/OL]. (2020-04-28) [2021-05-25]. <https://arxiv.org/abs/2004.13674v1>.
- [14] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [C]//European Conference on Computer Vision (ECCV), September 8-14, 2018, Munich, Germany. Switzerland: Springer, 2018: 3-19.
- [15] JOHNSON J, ALAHI A, FEI-FEI L. Perceptual losses for real-time style transfer and super-resolution[C]//European Conference on Computer Vision (ECCV), October 8-16, 2016, Amsterdam, Netherlands. Switzerland: Springer, 2016: 694-711.
- [16] ATAIE S, ALIREZAIE J, BABYN P. Cascaded convolutional neural networks with perceptual loss for low dose CT denoising[EB/OL]. (2020-07-26) [2021-05-25]. <https://arxiv.org/abs/2006.14738v1>.
- [17] CLARK K, VENDT B, SMITH K, et al. The cancer imaging archive (TCIA): maintaining and operating a public information repository[J]. Journal of Digital Imaging, 2013, 26(6): 1045-1057.

作者简介:

张 剑 (1974—), 男, 博士, 硕士生导师, 主要从事图像信号处理与智能控制、故障诊断方面的研究。