

基于双注意力机制和复合损失的 LDCT 去噪方法

郭志涛, 苏逸, 袁金丽*, 赵琳琳

河北工业大学电子信息工程学院, 天津 300401

摘要 针对当前低剂量计算机断层扫描(LDCT)重建图像中存在复杂噪声与条纹伪影的问题,提出了一种基于双注意力机制和复合损失的LDCT去噪方法。该方法通过引入空间注意力机制与通道注意力机制,获取了全局特征信息,并对特征权重进行重标定,使重要的结构细节能够得以保留,从而提升网络的去噪性能;同时加入感知损失度量函数,使对人眼而言敏感的纹理信息得到保留。实验结果表明:在视觉效果上,所提方法不仅去除了LDCT图像中的噪声和伪影,同时也保留了更多的纹理特征与结构细节;峰值信噪比(PSNR)等客观指标均高于其他对比方法。

关键词 图像处理; 低剂量计算机断层扫描; 注意力机制; 感知损失

中图分类号 TP391

文献标志码 A

doi: 10.3788/LOP202259.0210008

LDCT Denoising Method Based on Dual Attention Mechanism and Compound Loss

Guo Zhitao, Su Yi, Yuan Jinli*, Zhao Linlin

School of Electronic and Information Engineering, Hebei University of Technology, Tianjin 300401, China

Abstract Aiming at the problem of complex noise and fringe artifacts in current low-dose computed tomography (LDCT) reconstructed images, a LDCT denoising method based on dual attention mechanism and compound loss is proposed. This method obtains global feature information by introducing spatial attention mechanism and channel attention mechanism, and recalibrates the feature weights, so that important structural details can be retained, thereby improving the denoising performance of the network; at the same time, the perceptual loss measurement function is added to preserve the texture information sensitive to human eyes. Experimental results show that, in terms of visual effects, the proposed algorithm not only removes noise and artifacts in LDCT images, but also retains more texture features and structural details; objective indicators such as peak signal-to-noise ratio (PSNR) are higher than that of other comparison methods.

Key words image processing; low dose computed tomography; attention mechanism; perceptual loss

1 引言

计算机断层扫描(CT)技术在为医疗诊断带来极大方便的同时,CT扫描产生的电离辐射也正在危害着人类的健康。研究表明,过量的X光照射往往会诱发许多疾病^[1]。CT技术带来的辐射危害使得CT扫

描剂量的降低变得刻不容缓。然而,辐射剂量的降低会显著增加重建图像中的噪声和伪影,造成CT成像质量的严重下降^[2],从而损害诊断信息,进而可能影响临床医生对病灶的诊断。因此,抑制低剂量计算机断层扫描(LDCT)图像中的噪声和伪影,设计更好的图像重建和图像滤波算法具有重要的意义。

收稿日期: 2020-12-23; 修回日期: 2021-01-23; 录用日期: 2021-03-11

通信作者: *jinli_yuan@hebut.edu.cn

现有 LDCT 图像去噪算法主要有投影域滤波算法^[3-5]、迭代重建算法^[6-8]和图像后处理算法^[9-11]。投影域滤波算法、迭代重建算法依赖于原始投影数据,相关研究往往由于原始数据的不公开而受阻。而图像后处理算法不依赖于原始投影数据,可以直接对重建后的 LDCT 图像进行去噪,易于集成到临床 CT 系统中,因此受到了国内外学者的广泛关注。文献[9]利用改进的非局部均值(NLM)算法对 LDCT 图像进行去噪;文献[10]在公认的先进降噪算法三维块匹配滤波算法(BM3D)的基础上提出了自适应的三维块匹配算法,并将该算法用于低剂量冠动脉 CT 血管成像质量的改善;文献[11]通过稀疏表示与字典学习(K-SVD)的算法抑制 LDCT 图像中的噪声和条形伪影。虽然上述算法一定程度上抑制了图像中的噪声,但图像域中的噪声统计特性复杂且可能伴随着伪影,因此采用传统的图像后处理算法对 LDCT 图像进行处理时,往往存在效果不佳和结构失真问题。

近年来,基于深度学习的方法^[12]由于强大的特征学习与映射能力,相较于传统方法具有更好的重建质量和更快的重建速度,因此在 CT 图像去噪领域取得了许多进展。Chen 等^[13]首次将卷积神经网络(CNN)应用于 LDCT 图像去噪,与传统方法相比,该方法在视觉效果与评价指标上都显示出一定的优势;在此基础上,Chen 等^[14]又提出了一种基于残差编解码的卷积神经网络(RED-CNN)用于 LDCT 图像去噪;高净植等^[15]结合小波变换和深度残差网络解决低剂量 CT 的降噪问题,有效地抑制了特定噪声;Wolterink 等^[16]首先将生成对抗网络(GAN)用于 LDCT 图像去噪;Li 等^[17]将 Wasserstein 距离引入 GAN,采用 Wasserstein GAN (WGAN)进行 LDCT 图像去噪。Li 等^[18]在 CycleGAN 中使用未配对的正常剂量 CT (NDCT) 图像和 LDCT 图像进行去噪,该方法在一定程度上改善了 LDCT 图像的纹理,但会使部分边缘轮廓出现损失。尽管这些算法取得了不错的去噪效果,但是没有考虑不同通道和空间特征与去噪任务之间的重要程度关系,只是将噪声图像选取出来送入网络模型,无差别地处理每一个特征图和特征子空间,缺乏对重点区域的关注,限制了网络模型的表达能力。此外,常用的基于深度学习的去噪算法大多使用单一的均方误差(MSE)作为网络训练的损失函数,这样会导致去噪后的图像出现过度平滑与重要的结构细节丢失的问

题,同时也忽视了对人类感知至关重要的纹理特征。

针对上述问题,本文提出一种基于双注意力机制和复合损失的 LDCT 去噪方法,通过引入注意力机制从通道和空间两个维度来增强特征的表达,从而提升网络去噪的性能。首先,利用通道注意力模块对输入的多通道特征进行特征重标定;然后,利用空间注意力模块对输入特征的不同位置信息进行重新加权整合,增强感兴趣的区域;最后,对增强的信息进行融合,得到增强后的特征结果。此外,所提方法采用 MSE 损失和感知损失的组合优化网络,其中感知损失部分采用 VGG 网络实现,解决了单一 MSE 损失通过逐像素比较的方式造成丢失结构细节等高频信息的问题,从而可以保留 CT 图像中更多的结构细节。

2 融合注意力机制的去噪方法

2.1 降噪模型

LDCT 滤波反投影重建后的图像叠加有较复杂的泊松噪声和图像退化噪声,所提方法在图像域通过深度学习的方法去除 LDCT 图像中的噪声以恢复出高质量的 CT 医疗图像。LDCT 去噪问题可以通过建立以下数学模型进行解决,

$$\mathbf{X} = \sigma(\mathbf{Y}), \quad (1)$$

式中: σ 表示涉及量子泊松噪声和其他因素的复杂退化过程; $\mathbf{X} \in \mathbf{R}^{m \times n}$ 为 LDCT 图像; $\mathbf{Y} \in \mathbf{R}^{m \times n}$ 为对应的 NDCT 图像。LDCT 图像的去噪过程可以看作(1)式的逆映射,即从 LDCT 图像 \mathbf{X} 恢复 NDCT 图像 \mathbf{Y} ,去噪处理的目标是寻找将 LDCT 图像 \mathbf{X} 映射到 NDCT 图像 \mathbf{Y} 的函数 f ,使得代价函数最小化。

$$\arg \min_f \|\mathbf{f}(\mathbf{X}) - \mathbf{Y}\|_2^2, \quad (2)$$

式中: f 为 σ^{-1} 的最佳近似值,在深度学习里面用可学习的卷积神经网络来表示 f 。

2.2 双注意力机制

在图像去噪中,像素点重建所依赖的上下文信息越丰富,去噪效果越好^[19]。对于 CNN,上下文信息的获取范围可以用输出图像中某个像素点对应于输入图像中的区域,即感受野来衡量^[20]。现有去噪网络主要是通过局部卷积来实现的,只能获得有限的局部信息^[21],对图像的整体结构把握不足。此外,图像的上下文信息还包括像素点之间所反映特征的紧密联系程度,基于 CNN 框架的模型在处理数据时,等价地处理每一个特征图和特征子空间,没有重点关注的区域,也就是说,这些特征在神经

网络的眼中并没有什么不同,并且网络不会在某个区域上过多关注。然而,图像上的每一个像素点在去噪任务中的重要程度是不同的,经 CNN 进行特征提取后,反映为特征图上每一个位置的权重,从噪声图像中提取的特征映射对最终去噪结果的贡献不同,其中一些对于图像去噪可能没有益处。所提方法通过引入空间注意力机制使网络更好地捕获图像上下文信息,以获取图像的全局信息;同时自适应地整合了局部特征及全局依赖关系,建立起每个点与全局之间的位置联系,并提取了隐藏在复杂背景中的关键位置信息,在去噪的同时能最大程度地保留图像的细节特征。

CNN 提取的特征为多通道特征,每个通道的特征表示该图片特征在相应卷积核上的分量,现有的基于 CNN 的图像去噪方法通常在不同的通道上对特征图进行无差别的处理,而不同通道的特征图所表达的信息是不同的^[22],因此不同通道的特征对于图像去噪的重要性不同,这在很大程度上限制了 CNN 对图像去噪的性能^[23]。所提方法通过引入通道注意力机制,建模各个特征通道的重要程度,然后针对去噪任务增强或者抑制不同的通道,自适应

调整不同通道的权重;同时,通道注意力机制能有效地获得不同通道间所表达特征的联系,从而更好地对特征进行优化,最终得到更优良的去噪结果。

综上所述,通道注意力机制可以挖掘通道图之间的相互依赖关系,而空间注意力机制可以从特征映射中的不同位置聚合信息。为了获得更好的特征表示,所提方法将两种注意力机制融合为一个双注意力模块,如图 1 所示。在该模块中,将给定的中间特征图作为输入,首先利用通道注意力模块对输入的多通道特征进行整合,以突出不同通道间的相互重要程度,并依照重要程度有选择性地关注权重值大的信息,得到重标定后的通道特征;然后利用空间注意力模块对含有通道信息的特征进行加权赋值以获取特征的全局信息,并赋予空间注意力权重从而使网络根据权重分配学习到对去噪任务有用的特征信息;最后,融合得到最终的特征表示,在输入特征和融合通道-空间信息的输出特征之间进行残差连接以实现输入特征的再利用。通过双注意力模块,网络可以充分利用特征图中不同通道和位置的信息,聚集重要信息弱化无用信息,提高网络对关键特征的注意力。




图 1 双注意力模块。(1)通道注意力模块;(2)空间注意力模块

Fig. 1 Dual attention module. (1) Channel attention module; (2) spatial attention module

2.2.1 通道注意力机制

通道注意力机制如图 2 所示,模块的输入为大小为 $H \times W$ 的 C 个特征通道。为了获得通道的权重向量,在开始时对输入进行全局平均池化(global avg pooling)操作;其次,采用两个 1×1 卷积层压缩通道;然后恢复通道以融合通道之间的信息;最后,通过 Sigmoid 函数将 $1 \times 1 \times C$ 向量转化为权重向量。这个过程可以描述为

$$W_{ca} = f \left\{ W_u \left\{ \delta \left\{ W_d [G(z)] \right\} \right\} \right\}, \quad (3)$$

式中: z 是通道注意力模块的输入; G 表示全局平均池化操作; W_d 和 W_u 表示用于通道降维和升维的 $1 \times$

1 卷积层; δ 和 f 分别表示校正的线性单元(ReLU)和 Sigmoid 激活函数。

2.2.2 空间注意力机制

空间注意力机制如图 3 所示,模块的输入为通道数为 C 的 $H \times W$ 大小的特征图 z 。首先对低层特征在通道方向上进行全局平均池化来降维,得到大小为 $H \times W$ 的特征映射,并且通过卷积学习到一定的权重,其次通过形变操作将单通道特征图变为 $H \times W$ 行的一维特征,通过 Softmax 得到每个特征位置相对于整张特征图的全局信息,然后再将包含全局信息的一维特征变为大小为 $H \times W$ 的特征映射 M 。

$$M = \text{Softmax} [G(z)]. \quad (4)$$




图 2 通道注意力模块

Fig. 2 Channel attention module




图 3 空间注意力模块

Fig. 3 Spatial attention module

最后再将 M 经过卷积层和 Sigmoid 激活函数生成空间注意力权重 W_{sa} ,

$$W_{sa} = \text{Sigmoid}[\text{Conv}(M)], \quad (5)$$

式中: Conv 表示卷积操作。最终加权后的特征输出为

$$z' = W_{sa} \otimes z \quad (6)$$

式中: \otimes 表示元素相乘。

2.3 损失函数

基于深度学习的图像去噪任务中, MSE 作为传统的目标函数, 常常被用于许多低剂量 CT 去噪算法中以取得更高的信噪比, 然而这种逐像素比较的方法容易丢失细节信息, 造成结果模糊^[24]。使用特征比较方式的感知损失更符合真实视觉感知^[25], 可复原出更清晰的图像, 视觉效果远好于 MSE 损失, 但感知损失有时会因像素空间覆盖不均匀产生细微的视觉伪影。因此所提方法采用 MSE 损失及感知损失的加权和作为网络的目标函数, 在保留细节信息的同时, 弥补感知损失可能因像素空间不均匀覆盖带来的影响。

$$L = L_{MSE} + \lambda L_{Per}, \quad (7)$$

式中: L_{MSE} 为逐像素的均方误差损失; L_{Per} 为语义特征比较的感知损失; λ 为权重系数, 根据以往经验设置为 0.1。

MSE 损失计算生成图像与干净图像的均方根误差, 使两者进行逐个像素点的比较和匹配。MSE 损失的表达式为

$$L_{MSE}(y, \hat{y}) = \left[\frac{1}{HW} \left\| y - \hat{y} \right\|_F^2 \right], \quad (8)$$

式中: $\|\cdot\|_F$ 代表 Frobenius 范数; \hat{y} 为预测的输出图像; y 为干净的标签图像; 大小均为 $H \times W \times C$ 。

感知损失通过比较图像特征差异的方法重建更多细节得到清晰的结果^[26]。所提方法选用预先训练的 VGG16 网络作为损失网络。由于预先训练的 VGG 网络以彩色图像为输入, 而 CT 图像是灰度图像, 因此在输入 VGG 网络之前, 对 CT 图像进行通道复制, 形成 RGB 通道。VGG16 网络包含 13 个卷积层, 3 个完全连接的层, 所提方法用第 13 个卷积层的输出作为 VGG 网络提取的特征, 用于感知损失的计算。

$$L_{Per}(y, \hat{y}) = \frac{1}{H_j W_j C_j} \left\| \phi_j(\hat{y}) - \phi_j(y) \right\|_2^2, \quad (9)$$

式中: j 为网络的第 j 层; ϕ_j 为 VGG 网络中第 j 层卷积层得到的特征图; $H_j \times W_j \times C_j$ 为第 j 层特征图的大小。

2.4 网络结构设计

所提网络模型由 3 部分组成,分别是预处理模块、CNN 去噪网络和感知损失网络,如图 4 所示。网络的预处理模块为一个多尺度特征提取器,结合不同尺寸的卷积核,既可以融合不同尺度的特征,

又可以捕捉图像细节特征,增加网络深度和宽度的同时减少了参数。该模块采用了 3 个分支进行特征提取,分别为 3×3 卷积分支、 5×5 卷积及 7×7 卷积分支,最后对各分支进行拼接,如图 5 所示。

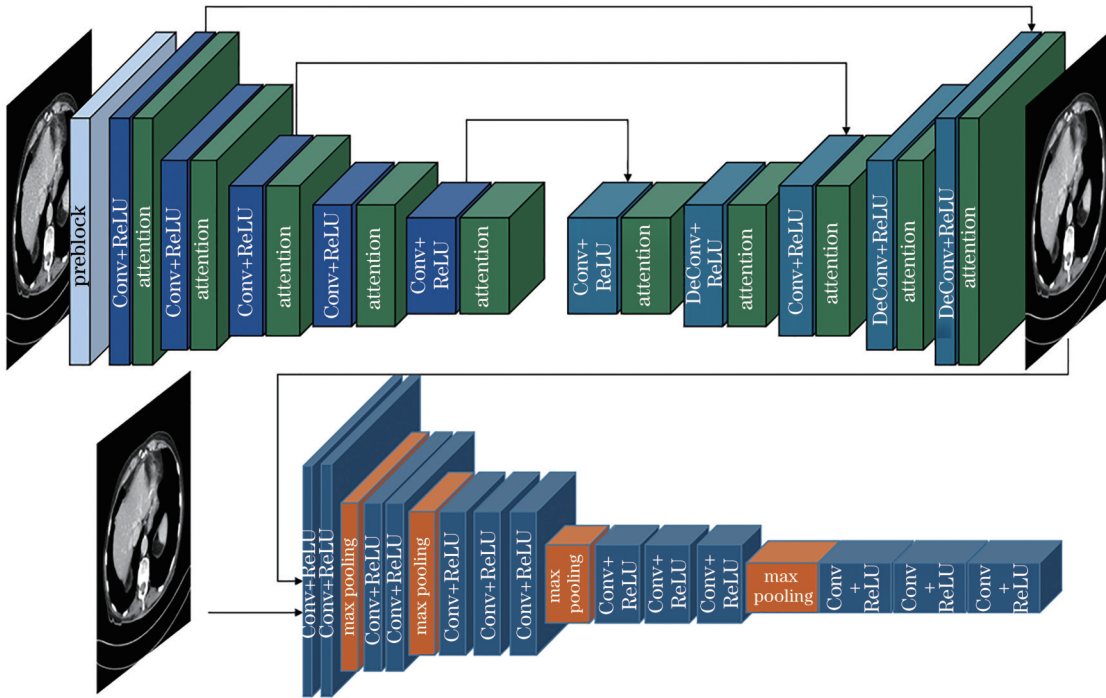


图 4 网络结构模型

Fig. 4 Network structure model




图 5 预处理模块

Fig. 5 Preprocessing module

CNN 去噪网络是以 RED 网络为原型进行改进的,由 10 层组成,包括 5 个结合注意力机制的卷积层和 5 个结合注意力机制的与卷积层对称排列的反卷积层,并在卷积层和与之对应的反卷积层之间加入跳跃连接使后方的卷积层能够利用前方

各层的特征图作为输入,增强网络中特征图的重用,并加速网络的收敛,同时使学习端到端映射更容易。所有卷积层和反卷积层都使用 3×3 大小的卷积核进行特征提取,其中第 1 层卷积和最后 1 层反卷积输出的通道数为 1,其余层的通道数为 96。使用整流线性单元 (ReLU) 作为非线性激活函数。

3 实验设计与结果

3.1 实验数据

所提方法使用由 Mayo Clinics 授权的“2016 NIH-AAPM-Mayo Clinic 低剂量 CT 大挑战”的临床数据集,用于网络的训练和测试。该数据集由投影数据和切片厚度分别为 1 mm 和 3 mm 的重建图像组成;实验使用 3 mm 厚的重建图像,其中包含来自 10 位匿名患者的 2378 张正常剂量 CT 图像及对应的低剂量(四分之一剂量)CT 图像,每张图像的大小为 $512 \text{ pixel} \times 512 \text{ pixel}$ ^[27]。

实验中,选取来自 8 名患者的 1824 对图像作为训练集,另外 2 名患者的 554 对图像作为测试集。在每次训练中,从每张切片中随机提取大小为 64×64 的图像块用于训练。测试时,将训练后的模型直接应用于测试病人扫描的全图像切片。在选择图像块时,排除大部分空气区域图像块。所提网络为全卷积网络,能够训练图像块和测试全尺寸图像 (512×512),从而有助于减少计算量,提高训练速度,并增加训练样本数,避免过拟合。

3.2 网络训练参数设置

实验在 64 位 Windows 10 系统下进行,采用 Pytorch 深度学习框架进行网络训练,并使用 CUDA-Toolkit10.1 对其加速;硬件配置为 Intel Core i7-9700K CPU@3.2 GHz,内存为 16 GB,显卡为 NVIDIA GeForce RTX 2080Ti。训练过程中使用 Adam 优化算法对权值进行迭代优化,参数 betas 设置为默认值(0.9),初始学习率设为 1×10^{-5} ,随迭代

次数增加逐渐降至 1×10^{-6} ;网络的批处理大小设置为 128,网络训练周期设置为 100。

3.3 不同算法的去噪结果对比

为了评估所提算法的性能,选取测试集中的两张有代表性的腹部 CT 图像进行测试,如图 6 所示;同时将测试结果同目前常用且效果较好的去噪算法进行比较,包括 BM3D 算法、K-SVD 算法、RED-CNN 算法、WGAN-VGG 算法及 CycleGAN 算法。BM3D 为三维块匹配算法,K-SVD 是一种基于稀疏字典学习的方法,RED-CNN 为一个对称结构的残差自动编解码卷积神经网络。WGAN-VGG 在 WGAN 网络的基础上加入新的感知损失度量函数,使人眼而言敏感的纹理信息得到保留。CycleGAN 为循环一致生成对抗网络,可以有效地学习从低剂量域到正常剂量域的图像转换且不需要配对数据集。这些对比算法的参数是根据原始论文的建议设置的。




图 6 腹部 CT 图像。(a)测试图 1;(b)测试图 2

Fig. 6 CT images of abdomen. (a) Test fig. 1; (b) test fig. 2

实验结果采用主观效果和客观指标两个方面进行评价。主观效果主要从视觉的角度出发说明去噪图像的结构形态问题,客观指标严格利用图像质量评价的方法从而得到不同算法优劣的客观依据。

3.3.1 主观效果

为了直观地说明所提算法的去噪性能,对选定的腹部低剂量 CT 图像进行了定性分析,所有 CT 图像的展示窗宽为 $[-160 \text{ HU}, 240 \text{ HU}]$,Hounsfield 单位(HU)是 CT 中普遍使用的无量纲单位。图 7 为测试图 1 对应的 LDCT 图像与各种算法处理结果的对比,图中图 7(a)为 LDCT 图像,图中包含明显的条状伪影和噪声污染,图 7(b)~(g)分别为

BM3D 算法、K-SVD 算法、RED-CNN 算法、WGAN-VGG 算法、CycleGAN 算法与所提算法的处理结果图,图 7(h)为 NDCT 图像。图中的方框是选取的局部感兴趣区域(ROI)。图 8 为图 7(a)方框内感兴趣区域(ROI)的局部放大图,箭头指向与椭圆内分别是 LDCT 与 BM3D、K-SVD、RED-CNN、WGAN-VGG、CycleGAN、所提算法处理结果及 NDCT 的不同细节部分。图 9 为测试图 1 对应的 LDCT 与各种算法处理结果存在的噪声。

从视觉效果来看,上述算法都展示出了一定的去噪能力。从图 8(b)、(c)可以看出,BM3D 算法、K-SVD 算法仅去除了部分噪声,去噪效果不明显。从图 8(d)可以看出,相比于图 8(b)、(c),RED-CNN




图 7 测试图 1 的 LDCT 和不同算法的去噪效果。(a) LDCT; (b) BM3D; (c) K-SVD; (d) RED-CNN; (e) WGAN-VGG; (f) CycleGAN; (g) 所提算法; (h) NDCT

Fig. 7 LDCT and denoising effect of different algorithms of test Fig. 1. (a) LDCT; (b) BM3D; (c) K-SVD; (d) RED-CNN; (e) WGAN-VGG; (f) CycleGAN; (g) proposed algorithm; (h) NDCT




图 8 图 7 中 ROI 的局部放大图。(a) LDCT; (b) BM3D; (c) K-SVD; (d) RED-CNN; (e) WGAN-VGG; (f) CycleGAN; (g) 所提算法; (h) NDCT

Fig. 8 Partial enlarged view of ROI in Figs. 7. (a) LDCT; (b) BM3D; (c) K-SVD; (d) RED-CNN; (e) WGAN-VGG; (f) CycleGAN; (g) proposed algorithm; (h) NDCT

算法的去噪效果良好,但 RED-CNN 采用 MSE 作为损失函数,容易丢失细节信息造成结果模糊。图 8(e)、(f)在细节方面表现出更好的视觉质量,但是与 LDCT 图像进行对比,可看出这两幅图扭曲了原始图像的结构信息。图 8(g)为所提算法对 LDCT

的处理结果,相比之下整体上表现出更清晰的视觉效果且噪声分布与 NDCT 中的噪声分布最为接近,去噪效果优于其他对比算法,而且保留了更多的图像细节信息,去噪后的图像与 NDCT 相似度更高。图 9 为去噪算法结果减去正常剂量 CT 图像得到的

噪声图像,从此图可看出算法去噪后噪声的整体分布与噪声含量,针对于不同算法的整体去噪效果来

说,图 9(g)所含噪声最少,保留的细节信息最多,图 9(d)、(e)、(f)次之,图 9(b)、(c)包含噪声较多。

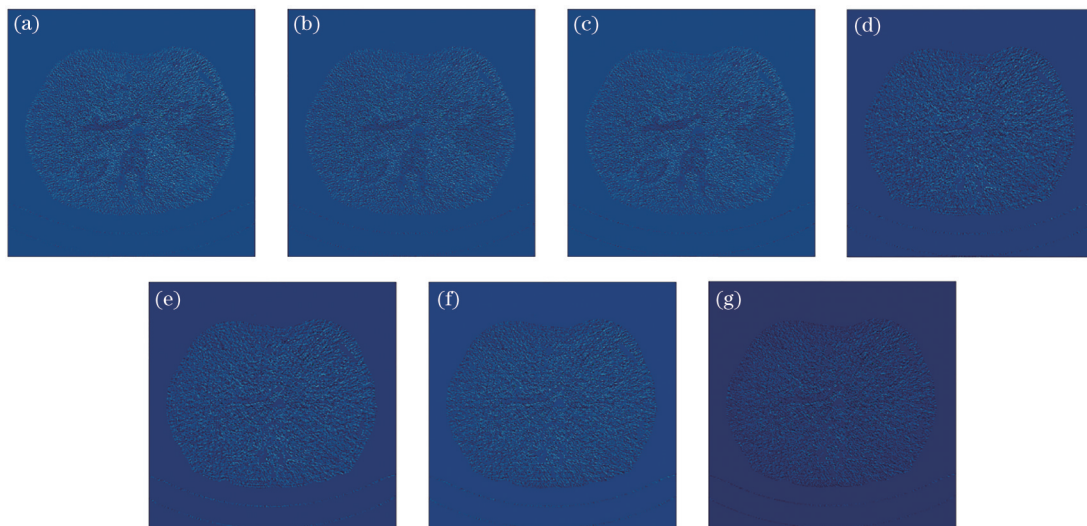


图 9 图 7 中 LDCT 和不同算法去噪后的噪声。(a) LDCT; (b) BM3D; (c) K-SVD; (d) RED-CNN; (e) WGAN-VGG; (f) CycleGAN; (g) 所提算法

Fig. 9 Noise after denoising by LDCT and different algorithms in Figs. 7. (a) LDCT; (b) BM3D; (c) K-SVD; (d) RED-CNN; (e) WGAN-VGG; (f) CycleGAN; (g) proposed algorithm

图 10~12 分别为腹部另一部位的 CT 图像对应的 LDCT、NDCT 与各种算法处理结果对比, LDCT、NDCT 与各种算法处理结果的 ROI 区域, LDCT 与各种算法处理结果存在的噪声。所得结

论与图 7~图 9 相同,与其他去噪算法相比,所提算法取得了最好的视觉效果,能够保留与常规剂量图像相近的细节信息,并除去了大部分噪声。因此,从视觉效果来看,所提算法效果最优。




图 10 测试图 2 的 LDCT 和不同算法的去噪效果。(a) LDCT; (b) BM3D; (c) K-SVD; (d) RED-CNN; (e) WGAN-VGG; (f) CycleGAN; (g) 所提算法; (h) NDCT

Fig. 10 LDCT and denoising effect of different algorithms of test Fig. 2. (a) LDCT; (b) BM3D; (c) K-SVD; (d) RED-CNN; (e) WGAN-VGG; (f) CycleGAN; (g) proposed algorithm; (h) NDCT

3.3.2 客观效果

为了评估所提算法的有效性,采用峰值信噪比

(PSNR)和结构相似性(SSIM)作为低剂量 CT 图像去噪效果的评价指标来进行图像质量评估。




图 11 图 10 中 ROI 的局部放大图。(a) LDCT; (b) BM3D; (c) K-SVD; (d) RED-CNN; (e) WGAN-VGG; (f) CycleGAN; (g) 所提算法; (h) NDCT

Fig. 11 Partial enlarged view of ROI in Figs. 10. (a) LDCT; (b) BM3D; (c) K-SVD; (d) RED-CNN; (e) WGAN-VGG; (f) CycleGAN; (g) proposed algorithm; (h) NDCT




图 12 图 10 中 LDCT 和不同算法去噪后存在的噪声。(a) LDCT; (b) BM3D; (c) K-SVD; (d) RED-CNN; (e) WGAN-VGG; (f) CycleGAN; (g) 所提算法

Fig. 12 Noise after denoising by LDCT and different algorithms in Figs. 10. (a) LDCT; (b) BM3D; (c) K-SVD; (d) RED-CNN; (e) WGAN-VGG; (f) CycleGAN; (g) proposed algorithm

$$R_{\text{PSNR}} = 20 \lg \frac{I_{\text{max}}}{E_{\text{RMSE}}}, \quad (10)$$

$$M_{\text{SSIM}} = \frac{(2\mu_z\mu_x + c_1)(2\delta_{z,x} + c_2)}{(\mu_z^2 + \mu_x^2 + c_1)(\delta_z^2 + \delta_x^2 + c_2)}, \quad (11)$$

式中: I_{max} 是最大像素值, E_{RMSE} 为均方根误差; x 和 y 分别表示 LDCT 图像和去噪后图像; μ_x 、 μ_y 分别表示图像 x 和 y 的均值; δ_x 、 δ_y 分别表示图像 x 和 y 标准

差; $\delta_{z,x}$ 表示 z 和 x 之间的协方差; c_1 和 c_2 分别是定义为 $(0.01 \times I_{\text{max}})^2$ 和 $(0.03 \times I_{\text{max}})^2$ 的两个默认 SSIM 参数。

图 13(a) 和图 13(b) 分别为不同算法对两张测试图的 ROI 处理结果的 PSNR 和 SSIM。从图 13(a) 中可以看出, 所提算法处理结果的 PSNR 略高于其他算法, 表明所提算法的预测结果图像噪声较小, 性

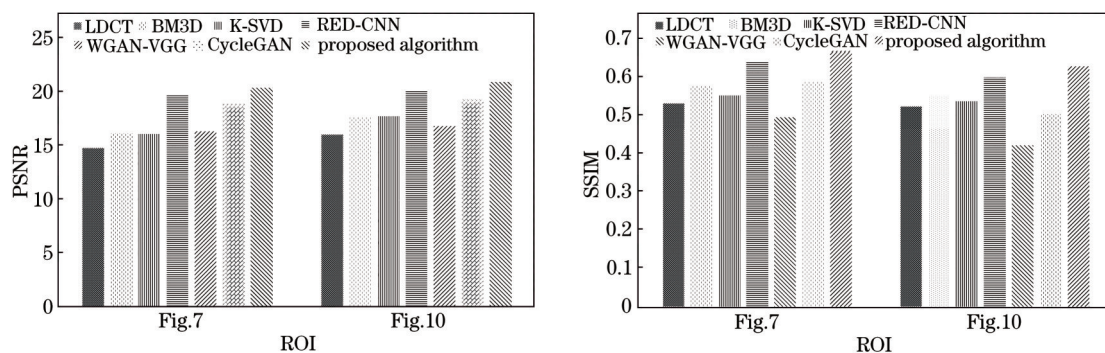


图 13 图 7 与图 10 的 ROI 区域性性能指标。(a) PSNR 指标;(b) SSIM 指标

Fig. 13 Performance indicators of ROI area in Fig.7 and Fig.10. (a) PSNR indicator; (b) SSIM indicator

能优于其他算法。从图 13(b)中可以看出,所提算法处理结果的 SSIM 值最大,表明所提算法的预测结果与原图偏差较小,结果与原图更相似。

表 1 为图 7 和图 10 的客观评价指标,其中粗体表示最优的结果。从表 1 中可以看出,所提算法在 PSNR、SSIM 方面的性能均为最优。表 2 为不同算法在测试集中的平均客观指标,所提算法在整个测试数据集中同样获得了最好的定量结果。从表 2 中可以看出,所提算法在测试图中的客观评价指标优于 BM3D 算法、K-SVD 算法、RED-CNN 算法、WGAN-VGG 算法与 CycleGAN 算法,其中 RED-CNN 算法性能位居第二,相比于 RED-CNN 算法的客观指标结果,所提算法的 PSNR 值提升了

表 1 图 7 和图 10 的客观评价指标

Table 1 Objective evaluation indicators in Fig.7 and Fig.10

Algorithm	Fig. 7		Fig. 10	
	PSNR	SSIM	PSNR	SSIM
LDCT	16.9986	0.6888	15.6697	0.5829
BM3D	18.3782	0.7056	16.9822	0.6006
K-SVD	18.4449	0.6968	17.0610	0.5917
RED-CNN	22.3074	0.7267	20.7173	0.6167
WGAN-VGG	20.7928	0.7115	19.2119	0.6014
CycleGAN	21.6082	0.7186	20.0165	0.6097
Proposed algorithm	22.9577	0.7587	20.8507	0.6529

表 2 测试集中不同算法的平均客观指标

Table 2 Average objective indicators of different algorithms in test set

Algorithm	PSNR	SSIM
LDCT	21.5756	0.7928
BM3D	23.9134	0.8122
K-SVD	24.0704	0.8040
RED-CNN	26.4464	0.8195
WGAN-VGG	24.9213	0.8121
CycleGAN	25.7264	0.8163
Proposed algorithm	27.2176	0.8538

0.7712, SSIM 值提升了 0.0343, 对去噪性能有明显改善。

4 结 论

针对当前 LDCT 图像存在复杂噪声与条纹伪影等问题,提出了一种基于双注意力机制和复合损失的 LDCT 图像去噪方法。所提方法在网络中加入双注意力机制,对通道信息进行特征重标定,整合了网络对不同通道特征的表达;同时,充分利用网络空间中的上下文联系,有效获取空间特征的全局信息,实现了网络对关键特征位置的全面把握,提升了网络对特征的利用率。此外,为解决传统 MSE 损失丢失结构细节等高频信息的问题,所提方法采用 MSE 损失和感知损失的融合损失函数用于优化网络。最后,通过与各种经典去噪算法进行主观与客观的对比,表明了所提算法在 LDCT 图像去噪领域的优越性。

参 考 文 献

- [1] Berrington de González A, Mahesh M, Kim K P, et al. Projected cancer risks from computed tomographic scans performed in the United States in 2007[J]. Archives of Internal Medicine, 2009, 169(22): 2071-2077.
- [2] Zhu S Q, Wang J, Cai Y F. Low-dose CT denoising algorithm based on improved cycle GAN[J]. Acta Optica Sinica, 2020, 40(22): 2210002. 朱斯琪, 王珏, 蔡玉芳. 基于改进型循环一致性生成对抗网络的低剂量 CT 去噪算法[J]. 光学学报, 2020, 40(22): 2210002.
- [3] Manduca A, Yu L F, Trzasko J D, et al. Projection space denoising with bilateral filtering and CT noise modeling for dose reduction in CT[J]. Medical Physics, 2009, 36(11): 4911-4919.

- [4] Balda M, Hornegger J, Heismann B. Ray contribution masks for structure adaptive sinogram filtering[J]. *IEEE Transactions on Medical Imaging*, 2012, 31(6): 1228-1239.
- [5] Wu W W, Quan C, Liu F L. Filtered back-projection image redonstruction algorithm for opposite parallellinear CT scanning[J]. *Acta Optica Sinica*, 2016, 36(9): 0911009.
伍伟文, 全超, 刘丰林. 相对平行直线扫描 CT 滤波反投影图像重建[J]. *光学学报*, 2016, 36(9): 0911009.
- [6] Liu J, Kang Y Q, Gu Y B, et al. Low dose computed tomography image reconstruction based on sparse tensor constraint[J]. *Acta Optica Sinica*, 2019, 39(8): 0811004.
刘进, 亢艳芹, 顾云波, 等. 稀疏张量约束的低剂量 CT 图像重建[J]. *光学学报*, 2019, 39(8): 0811004.
- [7] Katsura M, Matsuda I, Akahane M, et al. Model-based iterative reconstruction technique for radiation dose reduction in chest CT: comparison with the adaptive statistical iterative reconstruction technique [J]. *European Radiology*, 2012, 22(8): 1613-1623.
- [8] Dong J W. The progress on research and principles of computed tomography iterative reconstruction[J]. *China Medical Equipment*, 2016, 13(10): 128-133.
董继伟. CT 迭代重建技术原理及其研究进展[J]. *中国医学装备*, 2016, 13(10): 128-133.
- [9] Li Z B, Yu L F, Trzasko J D, et al. Adaptive nonlocal means filtering based on local noise level for CT denoising[J]. *Medical Physics*, 2014, 41(1): 011908.
- [10] Kang D, Slomka P, Nakazato R, et al. Image denoising of low-radiation dose coronary CT angiography by an adaptive block-matching 3D algorithm[J]. *Proceedings of SPIE*, 2013, 8669: 86692G.
- [11] Chen Y, Yin X D, Shi L Y, et al. Improving abdomen tumor low-dose CT images using a fast dictionary learning based processing[J]. *Physics in Medicine and Biology*, 2013, 58(16): 5803-5820.
- [12] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. *Nature*, 2015, 521(7553): 436-444.
- [13] Chen H, Zhang Y, Zhang W H, et al. Low-dose CT denoising with convolutional neural network[C]// 2017 IEEE 14th International Symposium on Biomedical Imaging (ISBI 2017), April 18-21, 2017, Melbourne, VIC, Australia. New York: IEEE Press, 2017: 143-146.
- [14] 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.
- [15] Gao J Z, Liu Y, Bai X, et al. Stationary wavelet domain deep residual convolutional neural network for low-dose computed tomography image estimation [J]. *Journal of Computer Applications*, 2018, 38(12): 3584-3590.
高净植, 刘祎, 白旭, 等. 平稳小波域深度残差 CNN 用于低剂量 CT 图像估计[J]. *计算机应用*, 2018, 38(12): 3584-3590.
- [16] Wolterink J M, Leiner T, Viergever M A, et al. Generative adversarial networks for noise reduction in low-dose CT[J]. *IEEE Transactions on Medical Imaging*, 2017, 36(12): 2536-2545.
- [17] Li Z H, Zhou S W, Huang J Z, et al. Investigation of low-dose CT image denoising using unpaired deep learning methods[J]. *IEEE Transactions on Radiation and Plasma Medical Sciences*, 2021, 5(2): 224-234.
- [18] Li Z H, Huang J Z, Yu L F, et al. Low-dose CT image denoising using cycle-consistent adversarial networks[C]//2019 IEEE Nuclear Science Symposium and Medical Imaging Conference (NSS/MIC), October 26-November 2, 2019, Manchester, UK. New York: IEEE Press, 2019: 1-3.
- [19] Wang F, Jiang M Q, Qian C, et al. Residual attention network for image classification[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 6450-6458.
- [20] Guo P C, Su X D, Zhang H R, et al. A multi-scaled receptive field learning approach for medical image segmentation[C]//2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), May 4-8, 2020, Barcelona, Spain. New York: IEEE Press, 2020: 1414-1418.
- [21] Wang X L, Girshick R, Gupta A, et al. Non-local neural networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 7794-7803.
- [22] Chen L, Zhang H W, Xiao J, et al. SCA-CNN: spatial and channel-wise attention in convolutional networks for image captioning[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 6298-6306.
- [23] Lee H, Cho S. Locally adaptive channel attention-based network for denoising images[J]. *IEEE Access*,

- 2020, 8: 34686-34695.
- [24] Ledig C, Theis L, Huszár F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 105-114.
- [25] Yang J, Li W J, Wang R G, et al. Generative adversarial network for image super-resolution combining perceptual loss[J]. Journal of Image and Graphics, 2019, 24(8): 1270-1282.
- 杨娟, 李文静, 汪荣贵, 等. 融合感知损失的生成式对抗超分辨率算法[J]. 中国图象图形学报, 2019, 24(8): 1270-1282.
- [26] Yuan P Y, Zhang Y P. Image super-resolution reconstruction method using dual discriminator based on generative adversarial networks[J]. Laser & Optoelectronics Progress, 2019, 56(23): 231010.
- 袁飘逸, 张亚萍. 双判别器生成对抗网络图像的超分辨率重建方法[J]. 激光与光电子学进展, 2019, 56(23): 231010.
- [27] Chen H, Zhang Y, Zhang W H, et al. Low-dose CT denoising with convolutional neural network[C]//2017 IEEE 14th International Symposium on Biomedical Imaging (ISBI 2017), April 18-21, 2017, Melbourne, VIC, Australia. New York: IEEE Press, 2017: 143-146.