

多尺度残差与全局注意力结合的低剂量CT去噪

孙亚楠 陈平 潘晋孝

Low-dose CT denoising using combination of multi-scale residuals and global attention

SUN Yanan, CHEN Ping, PAN Jinxiao

引用本文:

孙亚楠, 陈平, 潘晋孝. 多尺度残差与全局注意力结合的低剂量CT去噪[J]. 应用光学, 2025, 46(2): 292–299. DOI: 10.5768/JAO202546.0202001

SUN Yanan, CHEN Ping, PAN Jinxiao. Low-dose CT denoising using combination of multi-scale residuals and global attention[J]. Journal of Applied Optics, 2025, 46(2): 292–299. DOI: 10.5768/JAO202546.0202001

在线阅读 View online: <https://doi.org/10.5768/JAO202546.0202001>

您可能感兴趣的其他文章

Articles you may be interested in

基于多尺度残差注意力网络的水下图像增强

Underwater image enhancement based on multiscale residual attention networks

应用光学. 2024, 45(1): 89–98 <https://doi.org/10.5768/JAO202445.0102003>

基于注意力残差编解码网络的动态场景图像去模糊

Image deblurring of dynamic scene based on attention residual CODEC network

应用光学. 2021, 42(4): 685–690 <https://doi.org/10.5768/JAO202142.0402008>

基于注意力机制与图卷积神经网络的单目红外图像深度估计

Depth estimation of monocular infrared images based on attention mechanism and graph convolutional neural network

应用光学. 2021, 42(1): 49–56 <https://doi.org/10.5768/JAO202142.0102001>

基于全局与局部多尺度上下文的电表数据检测

Electric meter data detection based on global and local multi-scale context

应用光学. 2024, 45(4): 804–811 <https://doi.org/10.5768/JAO202445.0403006>

基于小波变换与卷积神经网络的图像去噪算法

Image denoising algorithm based on wavelet transform and convolutional neural network

应用光学. 2020, 41(2): 288–295 <https://doi.org/10.5768/JAO202041.0202001>

一种基于双分支改良编解码器的图像去噪算法

Image denoising algorithm based on dual-branch modified codec

应用光学. 2020, 41(5): 956–964 <https://doi.org/10.5768/JAO202041.0502004>



关注微信公众号，获得更多资讯信息

文章编号: 1002-2082 (2025) 02-0292-08

引用格式: 孙亚楠, 陈平, 潘晋孝. 多尺度残差与全局注意力结合的低剂量 CT 去噪 [J]. 应用光学, 2025, 46(2): 292-299.

SUN Yanan, CHEN Ping, PAN Jinxiao. Low-dose CT denoising using combination of multi-scale residuals and global attention[J]. Journal of Applied Optics, 2025, 46(2): 292-299.



在线阅读

多尺度残差与全局注意力结合的低剂量 CT 去噪

孙亚楠^{1,2}, 陈平², 潘晋孝^{1,2}

(1. 中北大学 数学学院, 山西 太原 030051; 2. 中北大学 信息探测与处理山西省重点实验室, 山西 太原 030051)

摘 要: 针对目前低剂量 CT (low dose computed tomography, LDCT) 图像去噪方法由于缺乏对空间特征和去噪任务之间的内在联系, 导致重建图像的纹理细节丢失和过于平滑的问题, 提出了一种结合多尺度密集残差和全局注意力的图像去噪网络。通过引入多尺度密集残差块来提取图像的多尺度特征信息, 并通过全局注意力机制 (global attention mechanism, GAM) 来关注模型不同通道间的跨维信息, 同时加入跳跃连接进一步扩大全局交互特征的范围, 最后使用多尺度特征损失函数增强图像纹理细节, 避免图像过于平滑的问题。经过实验验证, 本文所提出的算法在峰值信噪比 (PSNR) 和结构相似度 (SSIM) 这两项指标上分别达到了 35.183 8 dB、0.960 5, 在去除噪声的同时很好地保留了图像细节信息, 优于其他算法。

关键词: 低剂量 CT; 图像去噪; 多尺度密集残差; 全局注意力机制

中图分类号: TN911; TP391

文献标志码: A

DOI: 10.5768/JAO202546.0202001

Low-dose CT denoising using combination of multi-scale residuals and global attention

SUN Yanan^{1,2}, CHEN Ping², PAN Jinxiao^{1,2}

(1. School of Mathematics, North University of China, Taiyuan 030051, China; 2. Shanxi Key Laboratory of Signal Capturing and Processing, North University of China, Taiyuan 030051, China)

Abstract: A multi-scale dense residual and global attention combined image denoising network was proposed to address the issues of texture detail loss and excessive smoothness in reconstructed images caused by the lack of intrinsic connection between spatial features and denoising tasks in current low-dose computed tomography (LDCT) image denoising methods. The multi-scale dense residual blocks were introduced to extract multi-scale feature information from images, and the global attention mechanism (GAM) was used to focus on cross dimensional information between different channels of the model, while adding skip connections to further expand the range of global interactive features, and finally the multi-scale feature loss function was used to enhance image texture details and avoid the problem of image smoothness. After experimental verification, the proposed algorithm achieves 35.183 8 dB and 0.960 5 in peak signal-to-noise ratio (PSNR) and structural similarity index method (SSIM), respectively, which effectively preserves image details while removing noise, outperforming other algorithms.

Key words: low-dose computed tomography; image denoising; multi-scale dense residuals; global attention mechanism

收稿日期: 2024-04-15; 修回日期: 2024-06-22

基金项目: 国家自然科学基金 (62122070, 61871351); 山西省自然科学基金 (20210302124190, 20210302124191)

作者简介: 孙亚楠 (2000—), 女, 硕士研究生, 主要从事 CT 图像处理研究。E-mail: syn0821@163.com

通信作者: 陈平 (1983—), 男, 博士, 教授, 主要从事信号与信息处理、CT 重建研究。E-mail: pc0912@163.com

引言

X 射线计算机断层扫描(computed tomography, CT)是医学领域普遍采用的成像方法之一,有助于疾病的早期发现和治疗方案的制定。先前的多项研究已经表明,在 CT 扫描过程中辐射暴露对患者的身体有害,可能会增加基因突变的风险,从而导致患癌症或其他疾病的风险^[1]。因此,在保证临床诊断准确度的同时,有必要最大程度地减少 CT 扫描过程中的辐射剂量^[2]。减少辐射暴露会增加重建图像中的噪声水平和伪影,这些因素会影响重建图像的质量、医生诊断的准确性^[3]。为了解决上述问题,研究人员探索了许多算法,在提高低剂量 CT(low dose CT, LDCT)图像质量的同时最大限度地减少 X 射线剂量。

目前,LDCT 图像降噪方法主要分为 3 种^[4]: 投影域处理、迭代重建和图像后处理。投影域处理方法^[5]是对原始投影数据先进行去噪处理然后使用重建算法得到去噪后的 CT 图像。常用的处理方法包括双边滤波算法^[6]、结构自适应滤波^[7]和非线性各向异性扩散滤波^[8]。迭代重建算法将先验信息作为抑制噪声及伪影和保持边缘信息的惩罚项集成到目标函数中,通过反复迭代的过程来优化统一的目标函数。例如,稀疏表示先验^[9]、总变异^[10]和字典学习先验^[11]。这些算法在一定程度上都能有效去除噪声,但它们都存在问题——投影数据获取困难和重建时间长。相较于其他两种算法,图像后处理算法针对已经重建的 CT 图像进行有效处理。传统的图像后处理算法包括使用自适应非局部均值滤波^[12]进行 LDCT 去噪,基于分块匹配和自适应 3D 滤波算法以提高 LDCT 图像的成像质量等。尽管传统的图像后处理算法在 LDCT 图像的恢复中表现良好,但它们会使图像过于平滑,并可能丢失关键的局部信息,难以在保持细节及纹理信息和抑制噪声之间达到最佳平衡。

近年来,基于深度学习的网络模型在处理低剂量 CT 图像去噪方面表现出了极大的优势。其中,基于卷积神经网络的图像去噪方法被证明具有很好的效果,如 CHEN H 等^[13]将自动编码器和反卷积网络连接到 REDCNN(residual encoder-decoder convolutional neural network),以补偿上采样引起的结构信息失真,可以有效恢复图像细节。虽然上述算法取得了一定的效果,但仍存在过拟合和模型训练不足的问题。为了解决这个问题,研究人

员在网络结构改进方面做了大量的研究。例如, PENG Y 等^[14]提出对称跳跃连接和扩展卷积相结合的扩展残差网络,提高了网络的去噪性能。LI M^[15]等提出自注意力三维卷积网络,改善 CNN 感受野,通过自监督学习来进行图像去噪。为了更好地保留边缘信息, LIANG T 等^[16]提出了一种基于边缘的密集耦合卷积神经网络(EDCNN),该网络通过构建密集连接模型将边缘信息融合在一起,用注意力模块提取更准确的噪声信息,实现了端到端的 LDCT 图像去噪。虽然上述方法对于图像恢复是有效的,但无法捕捉到不同尺度下噪声图像的层次特征。GUI X 等^[17]提出 AAFFA(artifact-assisted feature fusion attention)网络去除 LDCT 噪声,结合伪影辅助特征融合与多层次注意力,有效去噪并保留细节。此外, WANG D 等^[18]提出了一种基于 Transformer 的低剂量 CT 去噪模型,可以有效去除边界伪影,但是它的网络运算复杂,且部分图像细节会丢失。

尽管现有的网络架构对 LDCT 图像的去噪性能有了显著的提升,但在进行网络训练时没有考虑到空间特征和去噪任务之间的关系,对图像上下文信息的使用不足导致图像细节丢失,且缺乏对噪声及伪影的关注,限制了降噪效果。因此,本文提出一种多尺度密集残差和全局注意力机制结合的模型,进行低剂量 CT 图像去噪,采用改进的多尺度密集残差块(multi scale dense residual blocks, MRDB)实现多尺度特征的有效提取,全局注意力机制在低剂量图像去噪中的应用能够充分利用图像的全局信息,实现自适应的权重调整,从而提高去噪效果并保留图像的细节和特征。

1 降噪模型

基于深度学习的 LDCT 图像去噪算法依赖于噪声和伪影的统计模型,相比于传统算法而言,可以有效解决图像中噪声模型的不确定性问题。假设 $X \in \mathbb{R}^{M \times N}$ 是一张大小为 $M \times N$ 的 LDCT 图像, $Y \in \mathbb{R}^{M \times N}$ 为对应的 NDCT 图像。LDCT 的去噪模型表示为

$$X = g(Y) \quad (1)$$

式中: $g(\cdot)$ 表示 LDCT 图像到 NDCT 图像的映射,即经过一个复杂的退化过程。通过最小化目标函数减少噪声,使

$$F(X) = \arg \min_{f(X)} \|f(X) - Y\|_2^2 \quad (2)$$

式中 $F(X)$ 可以被视为 g^{-1} 的最优近似。

2 整体网络结构

本文设计了一个 LDCT 去噪模型 MRD-GAMNet (multi scale dense residual-global attention mechanism network), 其总体网络框架如图 1 所示, 该模型由多尺度密集残差块(MRDB)、全局注意力模块(GAM)和去噪模块(DB)构成。为了加速模型收敛, 该模型直接学习 LDCT 图像中噪声的分布, 以实现更好的去噪效果。在主特征提取网络中, 我们创新性

地融合了多尺度密集残差块和全局注意力模块, 分为提取图像特征的编码端和专注于特征有效融合的解码端。构建编码器和解码器时, 使用 MRDB 作为核心模块, 全面捕获图像在不同尺度下的特征信息。此外, 利用密集连接的方式, 可以有效解决训练过程中的梯度消失问题, 进而提升模型训练的性能。为了提高对跨维信息的关注, 减少信息损失, 在编码端的每一层加入全局注意力模块, 提高对噪声和伪影的关注。最后, 将原始 LDCT 图像与上一步输出相减以获得高质量去噪图像。

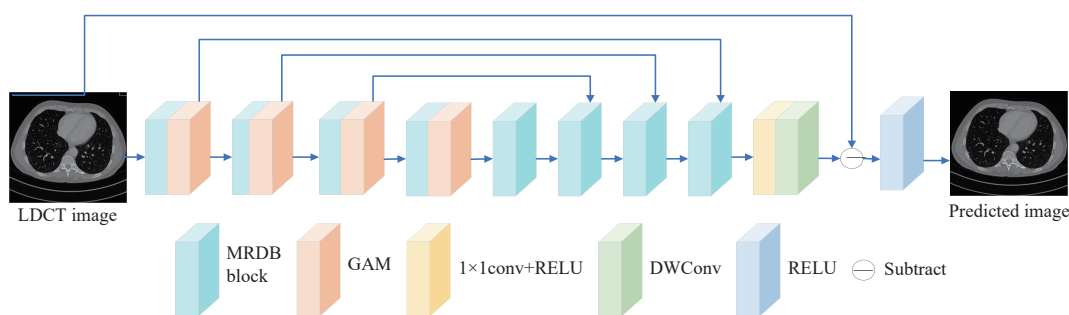


图 1 总体网络框架

Fig. 1 Framework of overall network

2.1 多尺度密集残差块

MRDB 在密集残差块(RDB)中加入了空洞空间卷积池化金字塔(atrous spatial pyramid pooling, ASPP)模块, 如图 2 所示。本文由 4 组卷积层与 ReLU 激活函数构成密集残差块(residual dense block), 其中卷积核的大小为 3×3 , 每组都由 32 个卷积核组成, 可以从网络中有效地提取特征并降低网络训练的复杂度。ASPP 模块是基于扩张卷积原理构建的, 该模型旨在通过不增加网络参数

的方式, 有效扩展模型的感受野, 从而有助于模型获取更广泛的图像信息。文中 ASPP 模块包括 1×1 Conv、用于调整特征图的通道数以及扩张率为 6 和 12 的 3×3 卷积, 用于捕获不同尺度的图像特征, 同时增加一个全局池化层来提取全局信息。将得到的不同尺度的特征进行合并, 并通过 1×1 Conv 进行特征融合。随后, 这些融合后的特征与 RDB 的特征进行融合, 进一步提升了特征的表达能力。

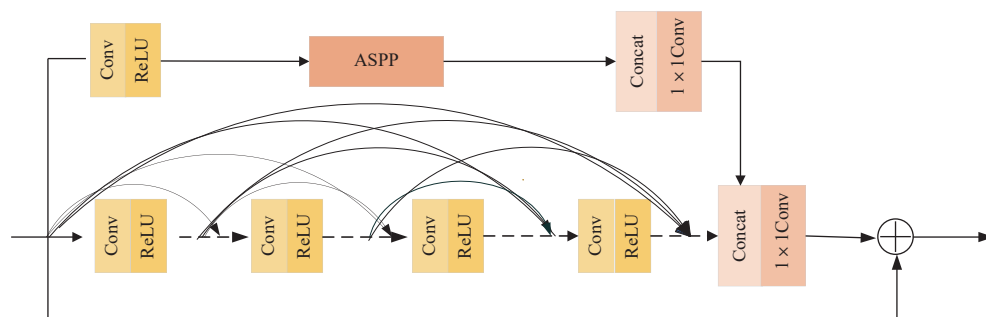


图 2 多尺度密集残差模块

Fig. 2 Multi-scale dense residual blocks

2.2 全局注意力机制

在图像的降噪过程中, 像素重构的效果取决于

其获取的上下文信息的丰富程度, 信息越丰富, 去噪效果越好。WOO S 等^[19]提出了通道和空间注意

力相结合的卷积块注意模块(convolutional block attention module, CBAM), 可以更好地捕捉到图像中的局部细节和结构信息, 然而这种方法忽略了通道和空间之间的相互作用, 从而失去了跨维信息。为了充分提取图像的上下文信息, 以加大全局跨维度交互和重要特征的充分学习, 本文引入了 GAM 模块(如图 3 所示), GAM 通过集成改进的 CAM 和 SAM, 加强网络对 LDCT 图像噪声及伪影的关注, 抑制不相关信息, 以实现更好的去噪效果。给定输入特征映射 $F \in \mathbb{R}^{C \times H \times W}$, 其计算过程为

$$F' = M_s \times (M_c \times F) \quad (3)$$

式中: M_c 和 M_s 是通道注意力图和空间注意力图; \times 表示按元素进行乘法运算, 得到新的特征映射 F' 。

如图 4 所示, 首先, 对于输入的特征图, 通道注意力模块(CAM)不改变特征图的空间维度, 使用 3D 排列来跨 3 个维度保留信息。随后, 特征图被

输入到多层感知器(MLP), 该 MLP 采用压缩比为 r 的两层结构, 旨在学习通道和空间相关性。然后将这 3 个维度再次在三维空间中对齐, 以确保信息的完整性和一致性。最后, 运用 sigmoid 激活函数, 将输出值映射到 0~1 的区间内, 以实现归一化, 从而得到具有增强通道重要性的特征表示。其计算公式为

$$M_c(F_1) = \sigma \{M_{rp} \{M_{MLP} \{M_p(F_1)\}\}\} \quad (4)$$

式中: F_1 为输入映射; M_p 和 M_{rp} 为排列操作和重排列操作; M_{MLP} 为多层感知器算法; σ 为 sigmoid 函数。




图 3 全局注意力机制

Fig. 3 Global attention mechanism




图 4 通道注意力模块

Fig. 4 Channel attention module

如图 5 所示, 在空间注意力模块(SAM)中, 为了更好地保留特征映射的细节信息, 本文去除了 SAM 中最大池化操作。同时, 为了保持与通道注意力模块的一致性, 采用了与其相同的压缩比 r 。此外, 引入 7×7 卷积核以扩大感受野, 并捕捉更丰富的空间上下文信息。最后, 为了规范特征图的取值

范围并提升模型的稳定性, 使用 sigmoid 激活函数。通过 SAM 获取不同空间位置的特征信息, 模型能更有效地捕获图像中的噪声特征。其计算公式为

$$M_s(F_2) = \sigma \{M_{conv} \{M_{conv}(F_2)\}\} \quad (5)$$

式中: F_2 为 CAM 的输入; M_{conv} 为 7×7 卷积运算; σ 为 sigmoid 函数。




图 5 空间注意力模块

Fig. 5 Spatial attention module

2.3 去噪模块

在去噪任务中, 网络结构的选择和函数的组合对于提高去噪效果至关重要。本文的去噪块包括

1×1 Conv 与 ReLu 激活函数组合、深度可分离卷积(DWConv)、Subtract 和 ReLu 激活函数, 以实现高效且准确的去噪。 1×1 Conv+ReLu 可以更有效地集

成前一层边缘信息,使输出特征图更加稳定,有效避免信息重复或丢失,同时有助于减少计算次数。设置 DWConv 的滤波器数量为 1,对应于单个通道的输出,进一步优化网络的结构,减少卷积计算所需的参数数量。同时, DWConv 块能够学习到原始图像与噪声之间的差异,通过 Subtract 操作,将原始 LDCT 图像与 DWConv 块的输出相减,将这种差异从原始图像中去除,以获得最终的去噪图像。最后,采用 ReLU 激活函数,旨在进一步增强模型的泛化性能。去噪模块如图 6 所示。




图 6 去噪模块

Fig. 6 Denoising module

2.4 损失函数

为了克服均方误差损失方法造成的图像过于平滑且丢失细节导致模糊的问题,本文将多尺度特征损失作为目标函数,如式(6)所示:

$$L_{MSE}(F(x), F(x')) = \frac{1}{L} \sum_{i=1}^L \|F_i(x) - F_i(x')\|^2 \quad (6)$$

式中: x 为重建图像; x' 为对应的标准剂量图像; $F_i(x)$ 为重建图像经过第 i 层卷积层后提取的特征; $F_i(x')$ 为对应的标准剂量图像经过第 i 层卷积层后提取的特征; L 为卷积层的数量。

3 实验设计及结果分析

3.1 数据集

为了证明本文提出模型对 LDCT 图像的去噪能力,在本文的研究实验中使用了癌症档案馆(the cancer imaging archive, TCIA)所提供的 2016 年 NIH-AAPM-Mayo Clinic 低剂量 CT 挑战赛的数据集^[20]。该数据集包含了 10 名匿名患者 NDCT 图像和相应的 LDCT(四分之一剂量)图像,共 2378 对。所有图像的切片厚度均为 3 mm,原始分辨率为 512×512 像素。在实验中,我们选择了 8 名患者的 1 900 对 CT 图像进行训练,以及另外 2 名患者的 478 对 CT 图像进行测试。

3.2 实验环境与参数设置

本实验是在 64 位 Windows10 系统上进行的,

该系统具有用于网络训练的 Pytorch 框架,所有实验均使用 NVIDIA GeForce MX330GPU 完成。在优化过程中我们使用自适应动量估计(Adam)对模型进行优化,并将参数设置如下:参数 β_1 为 0.9, β_2 为 0.999。学习率最初设置为 0.001,网络训练周期设置为 200。

3.3 评价指标

为了全面评估图像质量,本文采用了多种评价指标,峰值信噪比(PSNR)、结构相似度(SSIM)以及散斑指数(speckle index, SI)。其中,PSNR 用于量化处理后图像与标准图像间的差异,该值越大表明处理后的图像与标准图像越接近,代表图像质量越好。其表达式为

$$Q_{PSNR} = 10 \lg \left(\frac{I_{MAX}^2}{I_{MSE}} \right) \quad (7)$$

式中: I_{MAX} 表示图像像素值的最大可能取值, I_{MSE} 表示均方误差。

SSIM 是从三个方面来度量图像的视觉质量:亮度、对比度和图像结构值,范围为 [0, 1]。SSIM 值越高,表示结构越相似。其表达式为

$$Q_{SSIM}(X, Y) = \frac{(2\mu_X\mu_Y + c_1)(2\sigma_{XY} + c_2)}{(\mu_X^2 + \mu_Y^2 + c_1)(\sigma_X^2 + \sigma_Y^2 + c_2)} \quad (8)$$

式中: μ_X 、 μ_Y 分别表示 X 和 Y 的平均值; σ_X 、 σ_Y 分别是 X 和 Y 的标准差; c_1 、 c_2 是维持计算稳定的常量。

SI 是衡量图像中散斑噪声水平的一个量化指标,散斑指数越小,表示图像受散斑噪声调制的程度越低,即图像质量越好。其表达式为

$$Q_{SI} = \frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N \frac{\sigma(i, j)}{u(i, j)} \quad (9)$$

式中: $M \times N$ 表示图像的大小; $\sigma(i, j)$ 表示图像中位置 (i, j) 的测量窗口内像素灰度值的标准差; $u(i, j)$ 表示在图像中位置 (i, j) 的测量窗口内像素灰度值的平均值。

3.4 实验结果分析

为了评估所提方法的性能,本文选取传统算法 BM3D、编码器-解码器卷积网络 RED-CNN、第一个基于纯 Transformer 架构的网络 CTformer 这 3 种典型的方法进行了比较。从测试集中挑选两个具有代表性的切片,不同去噪方法对 LDCT 图像的去噪效果如图 7 所示,每幅图的下方为感兴趣区域(ROI)的放大图。

观察图 7 可以发现,LDCT 图像分布了大量的条纹伪影和散射噪声,相比之下,NDCT 图像中可




图 7 不同算法去噪效果对比

Fig. 7 Comparison of denoising effects of different algorithms

以清楚地看到正常的人体组织结构。通过对整体去噪结果的综合分析,可以看到 4 种算法在去除 LDCT 图像中的伪影和噪声方面均有所成效,但各自的效果存在显著差异。具体而言,在 BM3D 算法的去噪图像中,不难发现仍有大量伪影残留,其去噪效果相对较差,去噪性能仍有待提升;RED-CNN 的去噪图像有效地抑制了噪声,但是该算法使用 MSE 作为损失函数,使得去噪后的图像存在过度平滑和纹理细节缺失的问题,视觉效果显得很模糊;CTformer 可以显著抑制伪影和噪声,很好地保留了细节信息,但也存在过渡平滑的问题。所提出的 MRD-GAMNet 去除了大范围的噪声水平,条纹伪影也是对比方法中最浅的,细节恢复的更多。总体而言,该方法结果图中的纹理和细节更接近 NDCT 图像,比另外 3 种典型的方法具有更明显的优势和更好的泛化性。

为了客观评价所提出方法在 LDCT 图像降噪的有效性,表 1 展示了 4 种方法对数据集中 478 对测试图像的去噪效果的平均 PSNR、SSIM 和 SI 值。从表中可以看出,由于 BM3D 处理后的图像 PSNR 和 SSIM 的指标值最低,且散斑指数最高,说明这种算法相比于深度学习的去噪方法,效果并不理想。RED-CNN 是基于 MSE 的去噪方法,尽管获得了更好的 PSNR 和 SSIM 结果,但图 7 的视觉结果证实,在处理 LDCT 图像时,基于 MSE 的方法产生

了过度平滑结果,导致结构信息丢失。CTformer 通过无卷积 token2Token 扩展视觉变压器进行去噪,各个指标值都取得了显著的改善。与这 3 种算法相比,本文算法不仅采用多尺度特征损失函数来改善图像过于平滑的问题,还通过全局注意力机制和多尺度密集残差模块进一步提取全局信息能力和图像的多尺度特征,PSNR 和 SSIM 两项指标最高,散斑指数最低,均达到了最佳效果。较 LDCT 图像相比,PSNR 提高了 19.5%,SSIM 提高了 10.9%。对比 4 种方法的散斑指数,可以看出本文算法对散斑噪声的抑制效果最好。从视觉感知和定量性能来看,本文算法在 LDCT 去噪任务中获得了最优的效果。

表 1 不同算法对 LDCT 图像降噪对比结果

Table 1 Comparison of denoising results of LDCT images using different algorithms

| Method | PSNR | SSIM | SI |
|----------|---------|--------|--------|
| LDCT | 29.4354 | 0.8660 | 0.3695 |
| BM3D | 31.8327 | 0.8992 | 0.3044 |
| RED-CNN | 32.6219 | 0.9169 | 0.2914 |
| CTformer | 34.3157 | 0.9511 | 0.2848 |
| Ours | 35.1838 | 0.9605 | 0.2845 |

考虑到不同算法在极端噪声条件下的鲁棒性,我们采用了泊松噪声模型,在 LDCT 图像上加入了强度为 1×10^2 的泊松噪声。图 8 显示了 4 种算法

在极端噪声水平下的去噪结果。从图中可以看出,加入泊松噪声的 LDCT 图像噪声和伪影更加严重,图像质量明显下降,难以分辨图像中的组织结构和详细信息。通过观察 4 种方法的效果差异,BM3D 方法去噪后图像存留了大量的噪声伪影,

RED-CNN 和 CTformer 方法的去噪效果都存在边缘模糊和细节损失的情况(如图中的蓝色箭头所示)。相比之下,本文方法在细节信息和纹理结构方面更具有优势。与其他 3 种算法相比,所提方法在这种极端噪声条件下具有很强的鲁棒性。




图 8 极端噪声条件下不同算法去噪效果对比

Fig. 8 Comparison of denoising effects of different algorithms under extreme noise conditions

表 2 显示了 4 种算法降噪效果的 PSNR、SSIM 和 IS 的平均指标,从表 2 中不同算法对应的极端噪声去噪图像指标可以看出,BM3D、RED-CNN 和 CTformer 算法的各项指标均有所改善,但不同算法的结果差异不明显。同时结果表明,对于本文所提出的 MRD-GAMNet,其各项指标都具有最佳值,其网络性能更好。因此,MRD-GAMNet 在较好地保留特征信息的前提下,可以更好地实现去噪,使去噪结果在很大程度上接近 NDCT。通过分析同一算法对 LDCT 图像和极端噪声条件中 LDCT 图像的去噪结果,发现在不同场景下,本文算法与 3 种比较算法的量化值均有提高。然而,本文方法对不同噪声条件的 LDCT 图像的去噪性能更稳定,其各项指标均值都达到了较好的效果。

表 2 极端噪声条件下不同算法降噪评价指标

Table 2 Evaluation indexes of noise reduction by different algorithms under extreme noise conditions

| Method | PSNR | SSIM | SI |
|----------|---------|--------|--------|
| LDCT | 18.0209 | 0.6932 | 0.5629 |
| BM3D | 18.5560 | 0.7313 | 0.4161 |
| RED-CNN | 18.9179 | 0.7643 | 0.3848 |
| CTformer | 19.7843 | 0.7358 | 0.3472 |
| Ours | 20.1060 | 0.7791 | 0.3102 |

4 结论

本文提出的 MRD-GAMNet 网络充分运用了 MRDB 的多尺度特征提取优势与 GAM 模块的全局信息提取能力,该网络可以自适应图像数据的复杂性,显著提升去噪的准确性和鲁棒性,使图像中的细微细节得以完整保留。在训练过程中运用了

多尺度特征损失函数,避免了图像过于平滑导致模糊的现象。实验结果表明,相比于其他算法,本文方法在图像视觉质量和客观指标上都具有更好的性能,在实现 LDCT 图像降噪上达到最佳效果。

参考文献:

- [1] PINSKY P F, LYNCH D A, GIERADA D S. Incidental findings on low-dose CT lung cancer screenings and deaths from respiratory diseases[J]. Chest, 2022, 161(4): 1092-1100.
- [2] WU W, CHEN P, WANG S, et al. Image-domain material decomposition for spectral CT using a generalized dictionary learning[J]. IEEE Transactions on Radiation and Plasma Medical Sciences, 2021, 5(4): 537-547.
- [3] 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): 70-78.
ZHU Siqi, WANG Jue, CAI Yufang. Low-dose CT denoising algorithm based on improved cycle GAN[J]. Acta Optica Sinica, 2020, 40(22): 70-78.
- [4] CHEN Y, DAI X, DUAN H, et al. A quality improvement method for lung LDCT images[J]. Journal of X-ray Science and Technology, 2020, 28(2): 255-270.
- [5] LIU J, MA J, ZHANG Y, et al. Discriminative feature representation to improve projection data inconsistency for low dose CT imaging[J]. IEEE Transactions on Medical Imaging, 2017, 36(12): 2499-2509.
- [6] MANDUCA A, YU L, 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.

- [7] BALDA M, HORNEGGER J, HEISMANN B. Ray contribution masks for structure adaptive sinogram filtering[J]. IEEE Transactions on Medical Imaging, 2011, 31(6): 1228-1239.
- [8] LIU Y, CHEN Y, CHEN P, et al. Artifact suppressed non-linear diffusion filtering for low-dose CT image processing[J]. IEEE Access, 2019, 7: 9856-9869.
- [9] TIAN Z, JIA X, YUAN K, et al. Low-dose CT reconstruction via edge-preserving total variation regularization[J]. *Physics in Medicine and Biology*, 2011, 56: 5949-5967.
- [10] LIU Y, MA J, FAN Y, et al. Adaptive-weighted total variation minimization for sparse data toward low-dose X-ray computed tomography image reconstruction[J]. *Physics in Medicine and Biology*, 2012, 57(23): 23-56.
- [11] XU Q, YU H, MOU X, et al. Low-dose X-ray CT reconstruction via dictionary learning[J]. IEEE Transactions on Medical Imaging, 2012, 31: 1682-1697.
- [12] KIM B G, KANG S H, PARK C R, et al. Noise level and similarity analysis for computed tomographic thoracic image with fast non-local means denoising algorithm[J]. *Applied Sciences*, 2020, 10(21): 7455.
- [13] 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.
- [14] PENG Y, ZHANG L, LIU S, et al. Dilated residual networks with symmetric skip connection for image denoising[J]. *Neurocomputing*, 2019, 345: 67-76.
- [15] LI M, HSU W, XIE X D, et al. SACNN: self-attention convolutional neural network for low-dose CT denoising with self-supervised perceptual loss network[J]. IEEE Transactions on Medical Imaging, 2020, 39(7): 2289-2301.
- [16] LIANG T, JIN Y, Y LI, et al. EDCNN: edge enhancement-based densely connected network with compound loss for low-dose CT denoising[C]//IEEE International Conference on Signal Processing (ICSP). New York: IEEE, 2020: 193-198.
- [17] GUI X, GUO Y, ZHANG X, et al. Artifact-assisted multi-level and multi-scale feature fusion attention network for low-dose CT denoising[J]. *Journal of X-Ray Science and Technology*, 2022, 30(5): 875-889.
- [18] WANG D, FAN F, WU Z, et al. CTformer: convolution-free token2token dilated vision transformer for low-dose CT denoising[J]. *Computer Science*, 2022, 10: 623.
- [19] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]//Proceedings of the Proceedings of the European Conference on Computer Vision (ECCV). New York: IEEE, 2018: 3-19.
- [20] MCCOLLOUGH C. TU-FG-207A-04: overview of the low dose CT grand challenge[J]. *Medical Physics*, 2016, 43: 3759-3760.