

基于改进 ADNet 网络模型的低剂量 CT 图像 降噪方法^{*}

黄 银¹ 陈 波¹ 钱俊磊¹ 曾 凯¹ 陈伟彬² 冯雪聪¹

(1. 华北理工大学电气工程学院 唐山 063210; 2. 华北理工大学附属医院 唐山 063000)

摘 要:与正常剂量计算机断层扫描成像(CT)相比,低剂量 CT 成像可以有效减少 X 射线对身体的辐射,但因此产生的噪声会显著降低 CT 成像质量。传统的神经网络由于提取通道单一,影响了图像的特征提取,不利于低剂量 CT 图像的降噪。分析了基于双注意力机制和记忆与高频特征融合的神经网络图像降噪方法。实验结果表明,与目前常用的 3 种典型网络相比,该模型避免 CT 图像过度平滑,可有效保留图像细节纹理。与 ADNet 网络模型相比在结构相似性上提升了 0.005 5,峰值信噪比上提升了 0.270 7。

关键词:低计算断层扫描成像;记忆与高频特征融合;双注意力机制

中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Low-dose CT image noise reduction method based on improved ADNet network model

Huang Yin¹ Chen Bo¹ Qian Junlei¹ Zeng Kai¹ Chen Weibin² Feng Xuecong¹

(1. North China University of Science and Technology School of Electrical Engineering, Tangshan 063210, China;

2. North China University of Science and Technology Affiliated Hospital, Tangshan 063000, China)

Abstract: Compared with normal dose computed tomography (CT) imaging, low-dose CT imaging can effectively reduce the radiation of X-rays to the body, but the resulting noise will significantly reduce the quality of CT imaging and thus affect the doctor's diagnosis. Because of the single extraction channel, the traditional neural network affects the image feature extraction, which is not conducive to the noise reduction of low-dose CT images. This paper analyzes an image denoising method based on dual attention mechanism and fusion of memory and high frequency features. The experimental results show that, compared with the three typical networks commonly used at present, the model can avoid excessive smoothing of CT images, and can effectively preserve the image texture details. Compared with the ADNet network model, the structure similarity is improved by 0.005 5, and the peak signal-to-noise ratio is improved by 0.270 7.

Keywords: low dose computed tomography; memory is fused with high-frequency features; double attentional mechanisms

0 引 言

图像降噪在计算机断层成像(computed tomography, CT)和计算机辅助诊断领域有着重要的应用价值^[1-2],高质量的医学图像可以有效的辅助医生进行病情诊断^[3]。

根据国际健康委员会的调查结果,低剂量(80 mSv,正常剂量 120 mSv)的 CT 成像(low dose computed tomography, LDCT)可有效减少 X 射线对的人体辐射伤害^[4]。临床上,希望在保证诊断准确度下将放射量减小^[5]。然而低剂量 CT 成像容易出现边界模糊、高斯噪声和条状伪迹噪声

收稿日期:2022-12-02

^{*} 基金项目:河北省省属高等学校基本科研业务费研究项目(JYG2020004, JYG2021002)、华北理工大学教育教学改革研究与实践项目资助

等噪声,从而影响医生的诊断,因此针对低剂量计算机断层成像降噪显得尤为重要。

近年来,基于卷积神经网络(convolutional neural network,CNN)的CT图像降噪方法得到国内外的广泛关注,如3维块匹配滤波(block-matching and 3D filtering, BM3D)^[6]、亚像素卷积模型(efficient sub-pixel CNN,ES-PCNN)^[7]、超分辨率卷积模型(super-resolution CNN, SRCNN)^[8]、注意力指导卷积模型^[9](attention-guided CNN,ADNet)。研究表明,卷积神经网络对图像噪声均有不同程度的改善,其中ADNet在深挖图像细节方面效果明显。由于人体组织比较复杂,在进行图像降噪时很容易把局部组织视为噪声进行处理以及把病灶误认为噪声进行处理,导致过度平滑丢失图像纹理细节^[10]。

为此,提出记忆与高频特征增强模型^[11]和双注意力机制对ADNet网络进行改进(MDADNet)。记忆与高频特征增强模型用于加强低频信息,双注意力机制更好的引导网络提取噪声。改进后的算法在LDCT图像中能较好的保留图像的纹理细节。

1 MDADNet 基本原理

本文所提出的网络模型是在ADNet网络模型上进行改进,ADNet网络模型由4个模块组成,分别为稀疏机制模块(sparse block,SB)、特征增强模块(feature enhancement block ,FEB)、注意力机制模块(attention block, AB)、重建模块(reconstruction block, RB)所组成。ADNet在处理自然图像上有着较好的降噪效果,为了ADNet在低剂量CT成像中发挥更好的降噪效果,本文将对ADNet网络进行改进。

1.1 MDADNet 网络结构

在ADNet的基础上把特征增强模块FEB改进为记忆模块(memory block,MB)与高频特征增强模型(high-light feature enhancement block,HFEB),注意力机制改进为双注意力模型(double attention block,DAB),得到了MDADNet网络结构,如图1所示。MDADNet输入噪声图像,输出为噪声,将噪声图像与噪声作差即可得到清晰图像。

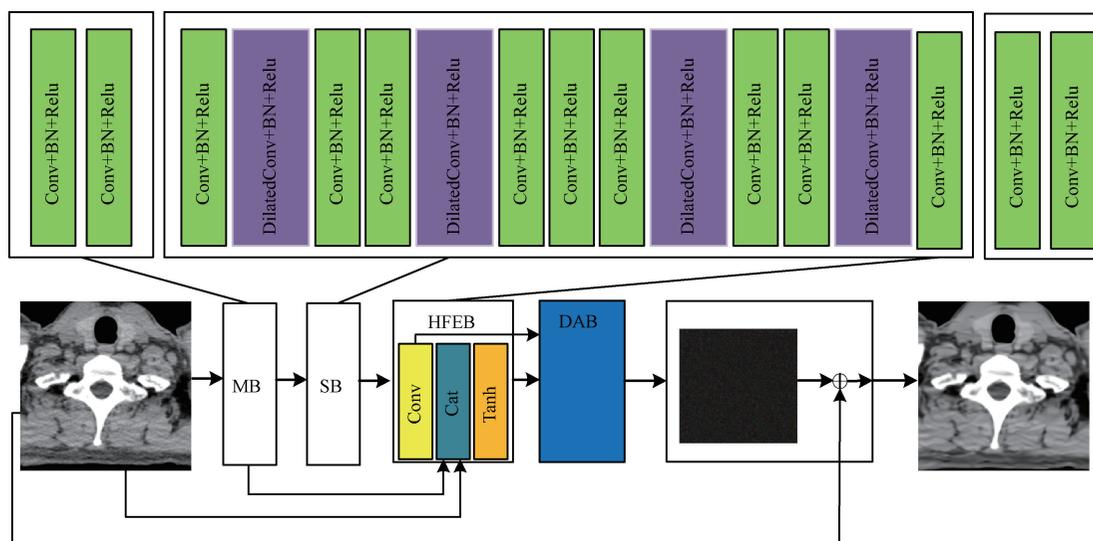


图1 MDADNet网络结构

图1中1~2层是MB模型,3~15层是SB,SB模型包括了两种类型的卷积,普通卷积和扩张因子为2的空洞卷积^[12](dilated convolutional,DC)。SB模型的普通卷积核设置为3×3,空洞卷积核为5×5。空洞卷积设置在网络的第4层、第7层、第11层、第14层,普通卷积设置在网络的第3、5、6层、8~10层、12、13层。16层至18层为高频特征增强层,高频特征增强层的卷积核为3×3。19~22层为双注意力机制层。

MB模型操作流程为:

$$O_{MB} = f_{MB}(I_N) = (CBR(CBR(I_N))) \quad (1)$$

式中: I_N 表示输入的噪声图像; $f_{MB}()$ 表示记忆模型操作; O_{MB} 表示输出的局部特征; CBR 表示 Conv+BN+ReLU 操作。

SB模型运行流程为:

$$O_{SB} = f_{SB}(O_{MB}) = CBR(DBR(2CBR(DBR(3CBR(DBR(2CBR(DBR(CBR(O_{MB})))))))))) \quad (2)$$

式中: O_{SB} 表示SB输出; DBR 表示了如下的 DilatedConv+BN+ReLU 操作。2CBR 表示网络进行了2次 Conv+BN+ReLU 操作。

高频特征增强层为:

$$O_{HFEB} = f_{HFEB}(I_N, O_{SB}) = T(Cat(Conv(2CBR(O_{SB}))), I_N) \quad (3)$$

式中: O_{HFEB} 表示高频特征输出; $f_{HFEB}()$ 表示高频特征操作; T 表示 Tanh 激活函数; Cat 表示连接作用; $Conv$ 表示普通卷积; 2CBR 表示网络进行了2次 Conv+BN+ReLU 操作。

空间注意力机制(position attention module,PAM)和通道注意力机制(channel attention module,CAM)操作为:

$$O_{PAM} = f_{PAM}(O_{HFEB}) = Reshape((Softmax(Reshape \& Transpose(Conu(O_{HFEB})) \otimes Reshape(Conu(O_{HFEB}))) \otimes Reshape(Conu(O_{HFEB}))) \oplus O_{HFEB} \quad (4)$$

$$O_{CAM} = f_{CAM}(O_{HFEB}) = Reshape(Softmax(Reshape \& Transpose(O_{HFEB})) \otimes Reshape(O_{HFEB})) \oplus O_{HFEB}$$

$$I_{DAB} = \alpha O_{PAM} + \beta O_{CAM} \quad (5)$$

式中: O_{PAM} 表示空间注意力输出; O_{CAM} 表示通道注意力机制输出; I_{DAB} 表示预测的噪声, Reshape&Transpose表示重组及转置; Reshape表示重组; \otimes 表示卷积操作; \oplus 表示矩阵融合; Softmax表示激活函数; α 和 β 表示常数。

$$O_C = f_{MDADNet}(I_N) = I_N - I_{DAB} \quad (6)$$

式中: O_C 表示所求的清晰的图片; $f_{MDADNet}()$ 表示整个网络操作函数; I_N 是输入的带有噪声的图像; I_{DAB} 表示预测的噪声。

均方误差(MSE)损失函数模型为:

$$l(\theta) = \frac{1}{2N} \sum_{i=1}^N \| f_{MDADNet}(I_N^i) - (I_N^i - I_C^i) \|^2 \quad (7)$$

式中: θ 表示训练模型的参数; I_N^i 表示第*i*个训练模型的噪声图像; I_C^i 表示第*i*个训练模型的清晰图像。

1.2 DAB

为了解决 LDCT 图像中微型噪声的特征提取问题,在 ADNet 单注意力引导模型中引入空间注意力和通道注意力机制,通过改变两种注意力机制的权重,有效避免了特征提取过度引起的图像过度平滑、纹理细节保留不完整问题。双注意力机制如图 2 所示。

1)PAM,输入一张 $C \times H \times W$ (高 \times 宽 \times 通道数)的特征图经过空间注意力机制运算得出 3 张新生成的特征图 A 、 B 、 D 之后将 A 、 B 矩阵重组为 A' ($C, H \times W$)、 B' ($C, H \times W$)矩阵,接着将 A 的转置与 B 进行矩阵乘法进行 Softmax 激活函数得到一个空间矩阵 S ($H \times W, H \times W$),接着将 D 特征图同样进行重组为 D' 与 S 转置进行矩阵乘法与 α 进行乘积,通过重组转换为原来特征图大小,最后该特征图与输入的特征图进行相加作为输出。

2)LAM,输入一张 $C \times H \times W$ 的特征图进行重组为 ($C, H \times W$)、($H \times W, C$)之后进行相乘与 Softmax 激活得到一张通道注意力特征图 S , S 与重组的 ($C, H \times W$)进行相乘再乘以 β 系数之后重组为原来特征图大小,最后与输入的特征图进行相加得到一张新的特征图。

最终将空间注意力机制和通道注意力机制的输出结果进行融合。经过双注意力机制的引导可以获取更多噪声信息,有效的提高降噪效率及准确性,且保留更多的图像细节信息。

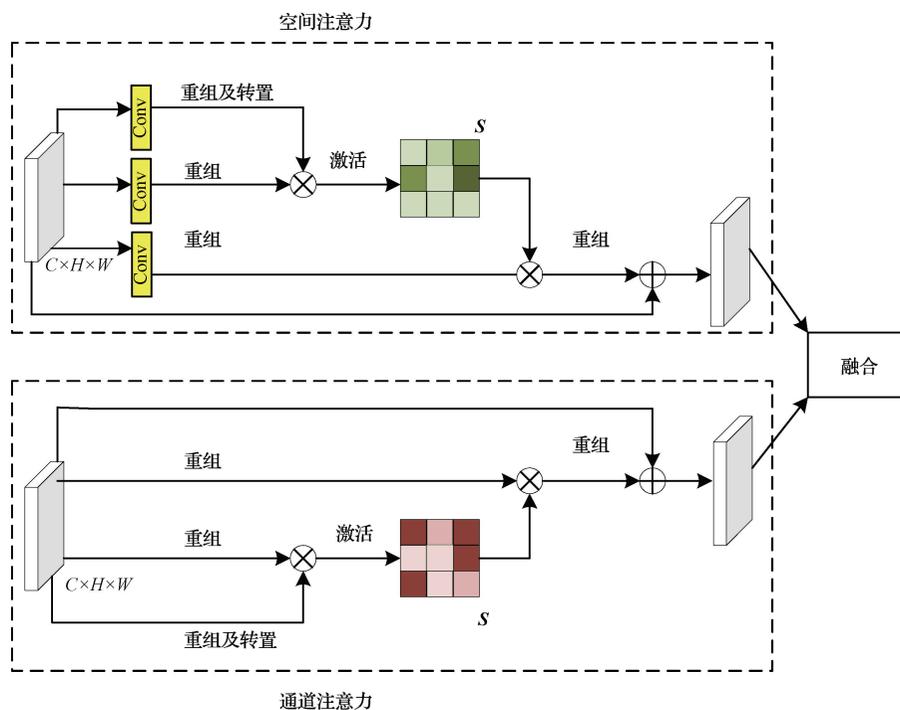


图 2 双注意力机制

1.3 记忆与高频特征融合模型

随着卷积神经网络的不断加深,浅层网络提取的特征

对深层网络提取的特征影响会逐渐的减弱^[13],此现象也可称为记忆减弱现象。为此本文提出将浅层网络中的高

频信息与深层网络中的高频信息进行融合来解决记忆减弱问题^[14]。首先把从浅层网络中获取的低频特征和稀疏机制的高频特征进行融合,转化后的高频特征实现了局部特征和全局特征的增强,使得网络在学习噪声中更好的把握了全局观,同时降低了梯度消失的风险,使网络有更好的健壮性。

记忆与高频特征融合过程如图3所示,包括MB模型、SB模型、HFEB模型。

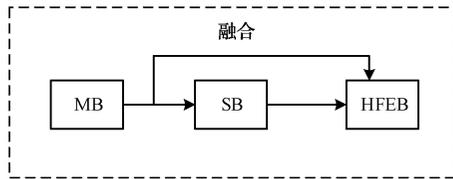


图3 记忆机制与高频特征增强

2 实验与结果分析

2.1 实验条件

实验配置如表1所示。从本地三甲医院获得1000张DICM格式的肺部NDCT及LDCT图像。为了保证实验数据集不受患者的年龄、性别、检测时间和CT设备因素的影响,在与医院合作时收集18~65岁且男女比例1:1,采集同CT设备不同时间段不同病人的CT图像。训练过程中设置batchsize的大小为4,学习率前30epoch设为0.001,30~60设为0.0001,60之后设置为0.00001,选用Adam优化器^[15]。

表1 实验环境

硬件配置	参数
CPU	5218R
RAM	32 G
GPU	RTX3060
GPU Memory	12 G
Framework	Pytorch1.1

实验采用峰值信噪比(PSNR)结构相似性(SSIM)做为衡量降噪效果优劣的评价指标,SSIM用来评价真实图像与降噪后图像之间的相似度,PSNR用来衡量真实图像与降噪后图像的峰值信噪比。PSNR计算公式为:

$$MSE = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n (I_{i,j} - I'_{i,j})^2 \quad (8)$$

$$PSNR = 10 \lg \left(\frac{255^2}{MSE} \right)$$

式中: $I_{i,j}$ 表示实际的图片; $I'_{i,j}$ 表示去噪后的图片。PSNR值越大,说明去噪的效果越好。SSIM计算公式为:

$$SSIM(x, y) = \frac{2u_x u_y + C_1}{u_x^2 + u_y^2 + C_1} \times \frac{2\sigma_x \sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \times \frac{\sigma_{xy} + C_3}{\sigma_x \sigma_y + C_3} \quad (9)$$

式中: u 表示真实图像和去噪后图像的像素均值; σ 表示真实图像和去噪后图像的方差; C_1, C_2, C_3 常数为了防止出现分母为0从而引起计算错误。SSIM取值范围是0~1,越接近1表明相似度越高。

2.2 MDADNet与ADNet模型的实验结果对比

为了验证双注意力机制和记忆与高频特征在保留图像细节方面的有效性,采取如下实验过程(图4),实验条件等同。

ADNet模型去噪结果如图4(b)所示。ADNet上其他模型不变,将FEB模型更换为记忆与高频特征增强模块(记作ADNet-c)其降噪效果如图4(c)所示。ADNet其他模型不变,注意力机制更换为双注意力机制(ADNet-d)其降噪效果如图4(d)所示。最后采用MDADNet的结果如图4(e)所示。

从图4的降噪结果可以看出,红色标记框内(图4(b)和(c))肺部纵膈窗上在降噪效果、肺部组织纹理保存、肺部细微组织机构上逐渐清晰。其中可以看出红色区域出现了平滑是临床医生不愿意看到的。图4(d)相比图4(b)、(c)未出现过度平滑问题且在保留图像细节和去噪方面有提升。图4(e)在图4(d)的基础上在保留细节纹理方面更进一步。采用PSNR和SSIM进行定量评价,数据评价如表2所示。

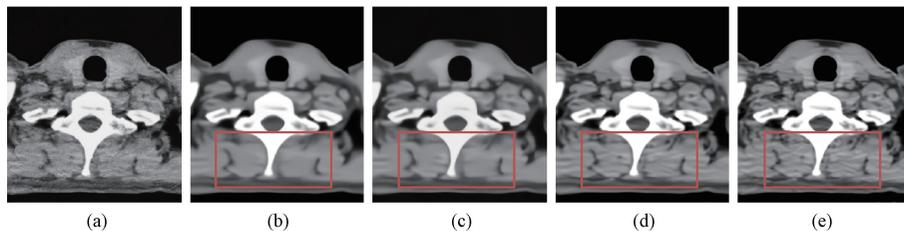


图4 结果实验对比

由表2可知,只更换记忆与高频特征增强模型的ADNet-c网络与ADNet模型相比在PSNR和SSIM均有

小幅度提升。只更换双注意力机制的ADNet-d网络,SSIM评价指标提升了0.0055,PSNR评价指标提升了

0.270 7。最后将本文所提出的 MDADNet 网络与 ADNet 网络相比 SSIM 提升了 0.009 3, PSNR 提升了 0.378 5。比较可见, MDADNet 网络有着更好的降噪效果。

表 2 复杂组织纹理的数据评价

方法	PSNR	SSIM
ADNet-b	27.185 1	0.855 7
ADNet-c	27.378 2	0.856 3
ADNet-d	27.455 8	0.861 2
MDADNet	27.563 6	0.869 5

2.3 不同模型降噪效果对比

为了进一步验证 MDADNet 网络的有效性,将不同扫

描层上的低剂量 CT 图像处理效果与引言部分提到的具有代表性的 BM3D、ESPCN、SRCNN 进行对比。降噪效果如图 5 所示。为了更直观的表达降噪效果,将图 5 中肺窗细节较多的区域(肺窗中红色标记框内的区域)进行放大如图 6 所示,通过对比图 5 和 6 的降噪效果可以看出, BM3D 网络处理的图像仍有噪点, SRCNN 处理的效果在图像细节纹理上有丢失现象, ESPCN 虽然保留了图像细节纹理但图像的细节纹理不够清晰。而文中提出的 MD-CNN 降噪效果在软组织窗、肺窗和较复杂的软组织窗都有着较好的效果,表现在视觉体验好、结构清晰、更加细腻和最接近 NDCT。综上所述 MDCNN 网络在肺窗、软组织窗、较复杂的软组织窗对低剂量 CT 图像降噪效果有较好的结果。

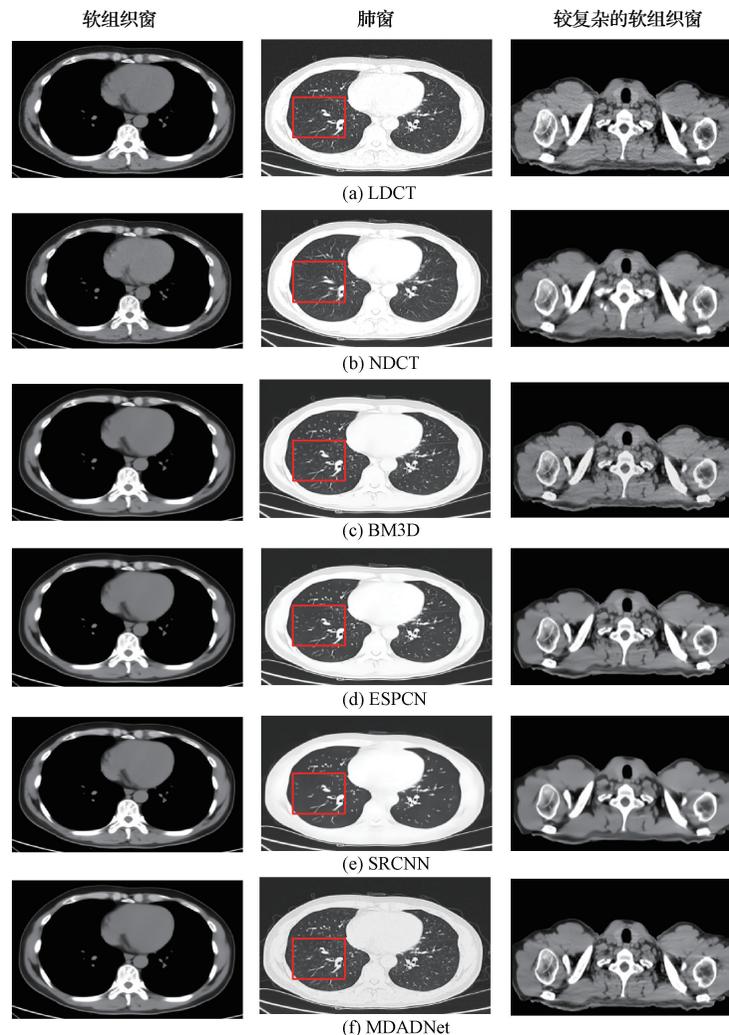


图 5 肺部图像降噪效果对比

引入 SSIM 和 PSNR 图像评标对图像进行客观评价,评价结果如表 3 所示。由表 3 可以看出,本文所提出的 MDADNet 模型处理,无论在组织较少的软组织

窗、还是组织纹理较多的肺窗上, PSNR 和 SSIM 评价价值均高于目前较常使用的 BM3D、SRCNN、ESPCNN 模型。

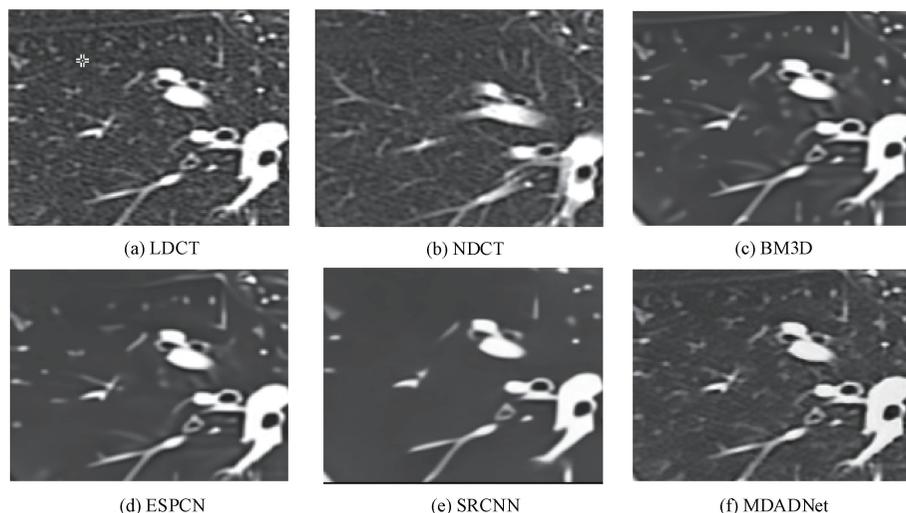


图6 肺窗局部放大图

表3 肺部图像客观评价

方法	软组织窗		肺窗		较复杂软组织窗	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
BM3D	28.365 4	0.865 2	28.751 3	0.845 2	27.236 5	0.873 6
SRCNN	28.458 2	0.868 8	28.915 4	0.856 2	27.335 6	0.866 4
ESPCNN	28.651 0	0.874 1	29.012 5	0.846 4	27.452 6	0.878 5
MDADNet	28.836 4	0.881 2	29.425 3	0.861 2	27.832 6	0.880 5

3 结 论

针对实际获取的 LDCT 图像降噪,采用 MDCNN 网络进行降噪处理,与具有代表性 BM3D、ESPCNN、SRCNN 网络的降噪结果进行对比,结果表明 MDCNN 网络在图像细节纹理保留方面有着较好的表现。与 ADNet 网络降噪效果对比,结果显示本文所提出的双注意力机制和记忆及高频增强在低剂量 CT 图像中表现更好。双注意力机制弥补了 ADNet 在单注意力机制上的细节丢失问题,记忆与高频特征增强弥补了 ADNet 网络在深层训练时忽略浅层特征问题。MDADNet 方法较好的保留了图像细节纹理以及对低剂量 CT 图像噪声较好的去除。通过对实际采集的图像进行处理,表明本文所提出的方法是有效的。

改进 ADNet 网络增加了双注意力机制和高频特征融合,在肺部 CT 数据上有着较好的降噪效果,但在头部等其他部位效果一般。接下来将对网络进行改进,使网络对其他组织结构同样有着较好的降噪效果。保证降噪质量同时使网络向轻量化方向发展减少对硬件的要求进而降低成本。

参 考 文 献

[1] 陈聪霞,李旭,刘甫庚,等. 肺通气/灌注单光子发射计算机断层和低剂量 CT 融合显像在老年人肺栓塞中

的诊断价值[J]. 中华老年医学杂志, 2022, 41(7): 827-833.

- [2] 李斌,李科宇,汤渝玲,等. 基于深度学习的肺癌计算机辅助诊断[J]. 当代医学, 2021, 27(9): 89-93.
- [3] 高文波,孔慧华,连祥媛. 基于多尺度生成对抗网络的低剂量 CT 去噪算法[J]. 国外电子测量技术, 2021, 40(8): 1-6.
- [4] BOON I S, AU Y, BOON C S. Assessing the role of artificial intelligence (AI) in clinical oncology: Utility of machine learning in radiotherapy target volume delineation [J]. Medicines, 2018, 5(4): 131.
- [5] 蒲晓蓉,黄佳欣,刘军池,等. 面向临床需求的 CT 图像降噪综述[J]. 数据与计算发展前沿, 2021, 3(6): 35-49.
- [6] ABUBAKAR A, ZHAO X J, LI S T, et al. A block-matching and 3-D filtering algorithm for Gaussian noise in DoFP polarization images[J]. IEEE Sensors Journal, 2018, 18(18): 7429-7435.
- [7] SHI W, CABALLERO J, HUSZAR F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1874-1883.
- [8] DONG C, TANG X O, HE K M, et al. Image su-

- per-resolution using deep convolutional networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 38(2): 295-307.
- [9] TIAN C W, XU Y, LI Z Y, et al. Attention-guided CNN for image denoising [J]. Neural Networks, 2020, 124: 117-129.
- [10] 刘岳哲. 基于组合扩散的低剂量 CT 图像降噪方法[J]. 国外电子测量技术, 2022, 41(7): 50-55.
- [11] 牟海维, 段朝辉, 韩建, 等. 基于多视小波变换融合的医学 CT 图像增强方法[J]. 电子测量技术, 2021, 44(9): 122-127.
- [12] ZHANG Z D, WANG X R, JUNG C. DCSR: Dilated convolutions for single image super-resolution [J]. IEEE Transactions on Image Processing, 2018, 28(4): 1625-1635.
- [13] YE J, HAN Y, CHA E. Deep convolutional framelets: A general deep learning framework for inverse problems [J]. SIAM Journal on Imaging Sciences, 2018, 11(2): 991-1048.
- [14] ZHANG Y L, TIAN Y P, KONG Y, et al. Residual dense network for image super-resolution [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 2472-2481.
- [15] KINGMA D P, BA J. Adam: A method for stochastic optimization [C]. CoRR, 2014: 1412-6980.

作者简介

黄银, 硕士研究生, 主要研究方向为医学图像处理。

E-mail: hhy811609783@163.com

陈波, 教授, 主要研究方向为光电检测技术及仪器、图像处理。

E-mail: chenbo182001@163.com

钱俊磊, 副教授, 主要研究方向为图像处理、工业网络安全、工业过程控制。

E-mail: catherineqjl@163.com