

# 一种基于多特征融合的低剂量CT去噪方法

付学敬<sup>1</sup>, 桂志国<sup>2</sup>, 李志媛<sup>3\*</sup>

(1. 上海市市场监督管理局 信息应用研究中心, 上海 200032;

2. 中北大学 信息与通信工程学院, 山西 太原 030051; 3. 中北大学 软件学院, 山西 太原 030051)

**摘要:** 深度学习已在低剂量CT(Low-Dose CT, LDCT)去噪领域取得了广泛应用, 为了在深度学习训练过程中平衡LDCT图像降噪和纹理细节之间的关系, 提出了一种基于多特征提取和注意力机制的LDCT去噪模型。该模型包含3条支路, 第1条支路是浅层边缘特征提取支路, 可以对输入的LDCT图像进行充分的预训练; 第2条支路利用交叉卷积来探索LDCT图像中更多的边缘细节信息; 第3条支路利用可训练的Sobel和正常剂量CT边缘标签来进一步加强对LDCT图像边缘细节的表现。最后, 利用注意力机制实现多特征融合模块。在美国医学物理学协会(AAPM)公开数据集上的实验结果表明, 与现有方法相比, 新模型处理的AAPM数据集CT图像峰值信噪比为33.6376, 结构相似性为0.9169, 证明了该方法可以有效去除噪声和伪影, 同时有效地保留了CT图像的结构信息。

**关键词:** 低剂量CT去噪; 特征提取; 边缘提取; 注意力机制; 交叉卷积; 多特征融合

**中图分类号:** TP391

**文献标识码:** A

**doi:** 10.62756/csjs.1671-7449.2025051

**引用格式:** 付学敬, 桂志国, 李志媛. 一种基于多特征融合的低剂量CT去噪方法[J]. 测试技术学报, 2025, 39(4): 406-414.

FU Xuejing, GUI Zhiguo, LI Zhiyuan. A low-dose CT denoising method based on multi-feature fusion[J]. Journal of Test and Measurement Technology, 2025, 39(4): 406-414.

## A Low-Dose CT Denoising Method Based on Multi-Feature Fusion

FU Xuejing<sup>1</sup>, GUI Zhiguo<sup>2</sup>, LI Zhiyuan<sup>3\*</sup>

(1. Information Application Research Center, Shanghai Municipal Administration for Market Regulation, Shanghai 200032, China;

2. School of Information and Communication Engineering, North University of China, Taiyuan 030051, China;

3. School of Software, North University of China, Taiyuan 030051, China)

**Abstract:** Deep learning has achieved a wide range of successful applications in the field of low-dose computed tomography(LDCT) denoising. To balance the relationship between LDCT image denoising and texture details during deep learning training, an LDCT denoising model based on multi-feature extraction and attention mechanism is proposed. The model consists of three branches. The first branch is the shallow edge feature extraction branch, so that the input LDCT image can be fully pre-trained. The second branch uses cross-convolution to explore more edge details in LDCT images. The third branch uses trainable Sobel and normal-dose CT edge labels to further enhance the performance of LDCT image edge details. Finally, the multi-feature fusion module is realized by using the attention mechanism. The experimental results on the American Association of Physicists in Medicine (AAPM) public dataset show that compared with the existing methods,

**收稿日期:** 2024-09-23

**基金项目:** 国家自然科学基金资助项目(61801438); 国家重点研发计划资助项目(2023YFC3304900)

**作者简介:** 付学敬(1971-), 男, 高级工程师, 硕士, 主要从事机器学习、深度学习研究。E-mail: ascend\_ai@163.com。

\* **通信作者:** 李志媛(1995-), 女, 讲师, 博士, 主要从事图像处理与计算成像研究。E-mail: lizhiyuan907813@163.com。

the peak signal-to-noise ratio value of the CT image of the AAPM dataset processed by the new model is 33.637 6, and the structural similarity value is 0.916 9. This method can effectively remove noise and artifacts, while effectively retaining the structural information of the CT image.

**Key words:** low-dose CT denoising; feature extraction; edge extraction; attention mechanism; cross convolution; multi-feature fusion

## 0 引 言

计算机断层(Computed Tomography, CT)<sup>[1]</sup>扫描作为现代医学的重要诊断手段,虽提供详尽信息,但大剂量 X 射线辐射却带来致癌等健康风险。为降低危害,低剂量 CT(Low-Dose CT, LDCT)扫描应运而生,它在减少辐射的同时,也带来了图像信噪比下降、伪影与噪声增多的问题,这对医生的诊断能力提出了更高要求。因此,平衡辐射安全与图像质量成为 LDCT 扫描应用中亟待解决的新挑战<sup>[2]</sup>。众多研究学者为了解决这些问题提出了很多优秀的后处理算法。Dabov 等<sup>[3]</sup>在 2007 年提出了 BM3D(Block Matching and 3D Filtering)算法用于对自然图像去噪;Huang 等<sup>[4]</sup>、Kang 等<sup>[5]</sup>均将 BM3D 算法用于 LDCT 图像去噪中。像素结构相似性的非局部均值<sup>[6]</sup>或其改进方法<sup>[7]</sup>的相关研究也在 CT 图像去噪中有所应用,去噪后图像的各项指标均取得了优异的结果。但传统的图像后处理方法去噪能力有限,处理后的图像结构细节不清晰。

随着深度学习技术的不断发展,为医学图像处理领域提供了新的研究思路。相较于传统去噪算法依赖于先验知识和只对特定类型的噪声有效等缺点,深度学习方法具有显著的优势。Chen 等<sup>[7]</sup>将自动编码器、反卷积网络连接至残差编码器-解码器卷积神经网络(Residual Encoder-Decoder Convolutional Neural Network, REDCNN)中来估计常规剂量 CT 值,该方法在噪声抑制、结构保存和病变检测方面得到了良好的评估效果。Fan 等<sup>[8]</sup>利用二次神经元设计了二次自编码器(Quadratic Autoencoder, Q-AE)网络用于 LDCT 去噪。Kang 等<sup>[9]</sup>提出了一种更深层次的神经网络,将传统小波变换与深度学习相结合,通过从输入的低剂量 X 射线 CT 图像的小波系数中减去估计的噪声,得到去噪后的小波系数,最后利用小波重构得到伪影噪声抑制后的图像。生成对抗网络(Generative Adversarial Network, GAN)的出现也成为 LDCT 图像处理中新的可行性方案。高文波等<sup>[10]</sup>融合不同尺度结构特征,提出了一种结合特征金字塔的 GAN 模型。Wolterink 等<sup>[11]</sup>将简单的卷积

神经网络应用于 GAN 对 LDCT 图像进行去噪,实验结果中图像总体噪声得到了有效抑制。Geng 等<sup>[12]</sup>应用内容噪声互补学习策略,并将其与对抗性生成网络相结合,提出了一种新的深度学习结构,该网络具有较强的泛化能力,在 CT、磁共振(Magnetic Resonance, MR)和正电子发射型计算机断层显像(Positron Emission Computed Tomography, PET)图像上均有较好的表现。但这些网络都没有平衡 LDCT 图像中降噪和纹理细节之间的关系。Han 等<sup>[13]</sup>提出了一种双面单解码结构的 GAN,并在主编码器上设计了非局部注意的金字塔模块,有效地提高了生成图像的质量。该变压器还为低剂量图像降噪提供了一种思路。Wang 等<sup>[14]</sup>提出了一种用于 LDCT 去噪的纯变压器 CTformer。这项工作是将视觉变压器应用于 LDCT 去噪问题的先驱,并引入了扩展和循环位移来捕获更远距离的相互作用。Liang 等<sup>[15]</sup>提出了一种基于边缘的密联卷积神经网络,利用提出的新型可训练 Sobel 卷积设计了一个边缘增强模块,并在此模块的基础上构造了一个具有密集连接的模型来融合提取的边缘信息,实现端到端图像去噪。但 these 方法对于图像特征的提取具有一定的局限性,不能很好地保持边缘细节信息。

为了进一步解决 CT 图像纹理细节不足和降噪后图像过于平滑等问题,提出了一种基于多特征融合的 LDCT 去噪方法 MFFCNN(Multi-Feature Fusion CNN)。此方法在美国医学物理学协会(AAPM)<sup>[16]</sup>公开数据集上得到了验证,不仅改善了各种客观指标,而且能够有效抑制 LDCT 图像中的噪声,同时保留图像中的纹理细节,在视觉效果上有很大优势。

## 1 本文算法

### 1.1 LDCT 降噪模型

本文所提去噪方法属于 LDCT 图像去噪中的图像后处理方法,因此本文实验只涉及图像域的 CT 图像去除。LDCT 图像去噪模型可以简化为以下情景:假设  $X$  为 LDCT 图像,  $Y$  为相对应的

正常剂量CT(Normal-Dose CT, NDCT)图像,则LDCT图像与NDCT图像之间的关系为

$$X = T(Y), \tag{1}$$

式中:  $T$ 为以非线性的方式将NDCT图像  $Y$ 退化为阈值对应的LDCT图像  $X$ 的过程。去噪过程可以转化为求函数  $f$ ,

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

式中:  $f$ 为通过深度学习所能得到的对  $T^{-1}$ 的最佳近似函数,可以通过  $f$ 函数将LDCT图像映射为对应的NDCT图像。

### 1.2 可训练Sobel卷积块边缘特征提取

边缘检测算子的基本思想是通过计算图像局部区域的微分来表示图像亮度的变化以检测图像的边缘。边缘检测本质上是一种滤波算法,区别在于滤波器的选择。Sobel<sup>[17]</sup>提取图像边缘算子是以一阶导数算子为基础进行计算的,其包含2个

$3 \times 3$ 的检测模板,一个模板用来提取图像水平方向上的边缘,且这个模板对水平方向的边缘作用大,另一个是提取图像垂直方向上的边缘,它对垂直方向的边缘作用大。检测模板如图1所示。




图1 Sobel边缘检测模板

Fig. 1 Sobel edge detection template

与传统定值Sobel算子不同,可训练的Sobel算子中定义了一个可训练的Sobel因子  $\alpha$ ,该因子的值可在训练优化过程中自适应调整,以更加精确地提取LDCT图像的边缘细节特征。可训练的Sobel检测模板如图2所示。




图2 可训练的Sobel检测模板

Fig. 2 Trainable Sobel detection template

### 1.3 交叉卷积边缘特征提取

交叉卷积通过并行利用垂直和水平梯度信息来强调边缘信息。与具有相同感受野的传统滤波器相比,并行设计的计算复杂度更小,参数更少。同时,并行开发也可以比顺序设计保留更多的信息。图3展示了顺序卷积和交叉卷积在信息保存方面的差异。

输入特征包含各个方向的梯度信息,箭头表示每个像素的梯度方向。在通过两个不对称滤波器进行垂直和水平探索后,利用了来自不同方向的梯度。最后,顺序卷积的输出特征只关注特征的主要梯度方向,而交叉卷积可以保留更多的梯度方向。




图3 顺序卷积与交叉卷积之间信息保存差异的示例

Fig. 3 An example of the difference in information preservation between sequential and cross-convolution

### 1.4 注意力机制

注意力机制通过加权分布的方式,有效地突出了关键信息的重要性,从而实现了重要特征的精准捕捉和高效整合。以往基于CNN的特征提取方法对图像信道特征的处理都是平等的,缺乏对实际情况的灵活性。为了使网络更多关注有价值的信息,利用特征通道之间的相关性形成通道关注模块。LDCT图像中含有丰富的低频分量和有价值的高频分量,低频部分相对平坦,高频部分通常是一个充满边缘、纹理等细节的区域,而卷积层只使用局部信息而不能使用全局上下文信息,因此,对每个通道特征产生不同的关注至关重要。

### 1.5 MFFCNN 网络架构

本文提出了一种基于多特征提取的LDCT降噪网络MFFCNN,网络框架如图4所示。

所提模型包含3条支路:第1条支路是浅层边缘特征提取支路,可以对输入的LDCT图像进行充分的预训练;第2条支路利用交叉卷积来探索

LDCT图像中更多的边缘细节信息;第3条支路利用可训练的Sobel和NDCT边缘标签进一步加强LDCT图像边缘细节的表现。最后,利用注意力机制实现了多特征融合模块。其中,交叉卷积边缘模块、可训练Sobel边缘特征提取模块、注意力融合模块的架构如图5所示。

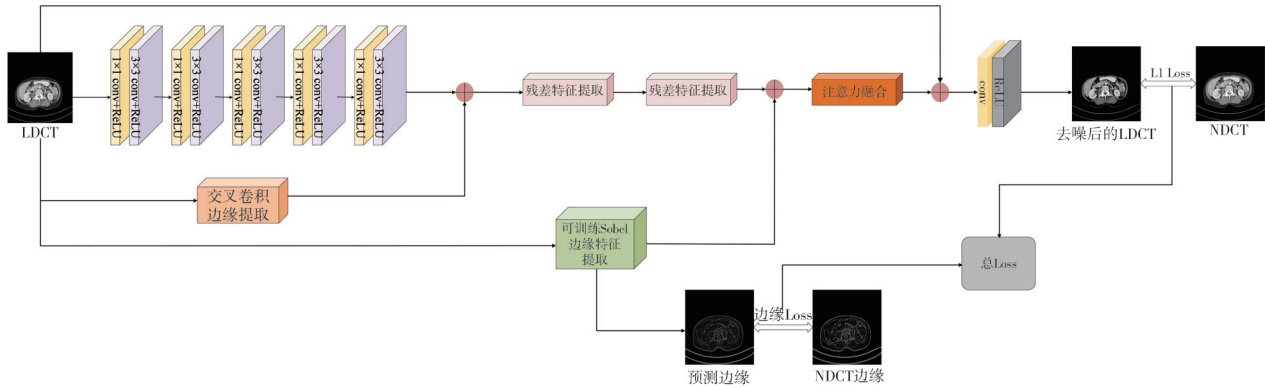


图4 MFFCNN网络框架

Fig. 4 MFFCNN network framework

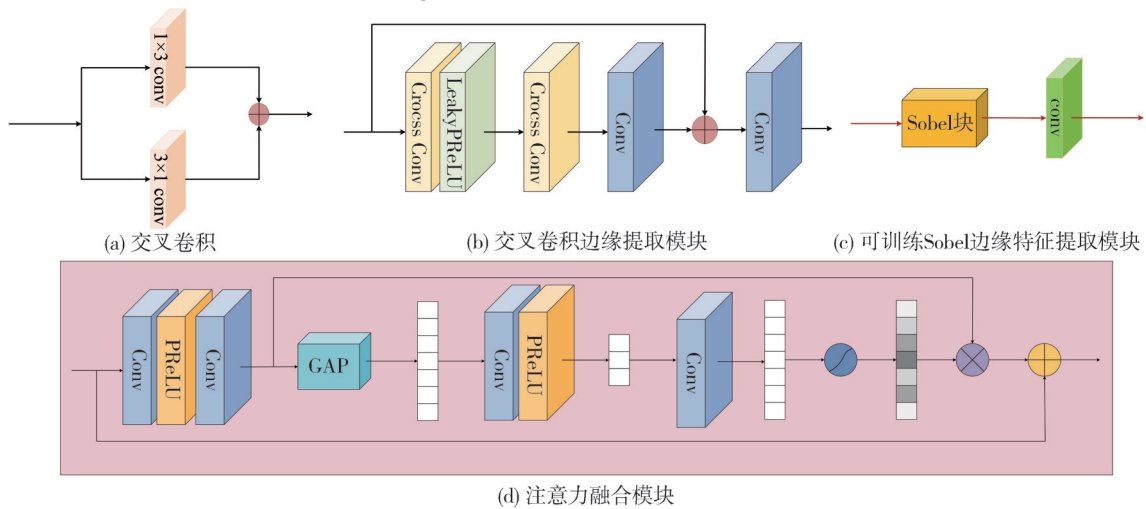


图5 MFFCNN网络框架分图

Fig. 5 MFFCNN network framework sub-graph

### 1.6 NDCT 边缘标签实现

由于传统边缘检测器(如Sobel和Canny)提取二值化图像边缘会导致大量信息丢失和虚构边缘, Fang等<sup>[18]</sup>提出通过去除二值化策略保留额外的边缘信息,以及一种新的边缘检测曲率公式,不使用二值化策略。本文利用式(3)提取NDCT图像的边缘作为边缘特征提取的目标图,利用边缘特征提取网络提取深度边缘细节信息,提高了LDCT图像的去噪效果。

$$\begin{cases}
 Y_{\text{edge}} = \text{div}(u_x, u_y), \\
 u_x = (\nabla_x Y / (1 + |\nabla Y|^2)^{1/2}), \\
 u_y = (\nabla_y Y / (1 + |\nabla Y|^2)^{1/2}),
 \end{cases} \quad (3)$$

式中:  $Y_{\text{edge}}$  为NDCT边缘图像;  $u_x$  为  $x$  方向的梯度;  $u_y$  为  $y$  方向的梯度。

### 1.7 Loss 函数

本文所提网络是从LDCT图像到NDCT图像的端对端的映射和LDCT图像的边缘特征图像到NDCT图像的端到端的映射。所以,本文有两个损失函数,均用L1范数损失进行模型训练。给定  $N$  对图像  $\{\text{LDCT}, \text{NDCT}\}$  的训练集,定义的损失函数为

$$L_{\text{fusion}} = \frac{1}{N} \|Y - \text{Fusion\_Net}(X)\|_1 \quad (4)$$

给定  $N$  对边缘图像  $\{Sobel(LDCT), Edge(NDCT)\}$  的训练集, 定义的损失函数为

$$L_{\text{edge}} = \frac{1}{N} \|Edge(Y) - Sobel(X)\|_1 \quad (5)$$

总损失函数为

$$L = L_{\text{fusion}} + L_{\text{edge}} \quad (6)$$

## 2 实验与结果分析

本文研究使用来自 2016 年 LDCT 挑战赛的 AAPM 数据集, 其中包含 10 名匿名患者的配对 CT 图像。每个 LDCT 图像都有对应的 NDCT 图像, 每个图像为  $512 \times 512$ 。本文随机选取 812 张 CT 图像作为训练集, 35 张未经训练的图像作为测试集。

### 2.1 训练过程

本实验基于 Pytorch 框架, 使用配置为 NVIDIA GeForce RTX 2080 SUPER GPU 的计算机对网络进行训练和测试。将  $512 \times 512$  的 CT 图像随机自适应裁剪成大小为  $64 \times 64$ , 滑动间隔为 40 的 patch 进行训练, 对于目标批 NDCT 图像, 也采用了相同的裁剪策略。在本实验中, 评估了几种参数组合, 并最终确定了以下参数设置。在优化过程中, 采用基于动量的 Adam 算法对所有网络进行优化。Adam 的超参数设置为学习率

0.001, 两个指数衰减因子  $\beta_1=0.5, \beta_2=0.999$ , 并进行 100 次训练以使模型收敛。虽然训练是在小块图像上进行的, 但所提网络可以处理任意大小的图像。所有的测试图像都被简单地输入到网络中, 而不进行剪裁处理。对比实验的参数是根据前文的建议设置的<sup>[7,11,15,19,20]</sup>。

### 2.2 对比实验

#### 2.2.1 Mayo 数据集

为了进一步验证本文方法的有效性, 将本文提出的网络与 REDCNN、基于边缘的 EDCNN、基于小波和 CNN 的 WavResNet<sup>[19]</sup>、基于 GAN 网络的 WGAN\_VGG 和 pix2pix<sup>[20]</sup> 在视觉效果和量化指标方面进行了比较。其中, 定量分析中的客观评价指标包括基于结构差异的结构相似性 (Structural Similarity, SSIM)<sup>[21]</sup>、基于像素灰度差的峰值信噪比 (Peak Signal-to-Noise Ratio, PSNR)、基于梯度值变化的梯度幅度相似偏差 (Gradient Magnitude Similarity Deviation, GMSD)<sup>[22]</sup>、基于特征差异的特征相似指数度量 (Feature Similarity, FSIM)<sup>[23]</sup> 和基于视觉感知的方差信息保真度 (Visual Quality Fidelity Spatial, VIFs)<sup>[24]</sup>。除 GMSD 外, 其余指标值越高, 说明去噪后 CT 图像质量越好。

采用不同方法对两个代表性切片进行处理后的结果如图 6 和图 7 所示。




图 6 不同算法去噪结果对比 (第一组)

Fig. 6 Comparison of denoising results of different algorithms (Group 1)

所有轴向视图的 CT 图像显示在  $[-160, 240]$  HU 窗口中。与图 6 和图 7 的 NDCT 相比, 可以观察到

LDCT 图像中存在大量的斑驳噪声和条纹伪影, 因此, 研究 LDCT 图像去噪方法具有重要意义。从整

体降噪效果来看,6种比较方法都对噪声和伪影有一定的抑制作用。为了更清晰地展示降噪效果,在图6和图7中扩大了一些感兴趣区域(Region of Interest, ROI),可以在NDCT图像中观察到人体的组织结构。然而,LDCT图像存在明显的条纹伪影和散斑噪声。WavResNet消除了一些噪声,但引入了额外的伪影。WGAN\_VGG和pix2pix可以很好地消除噪声,但是这两种方法都有模糊的视觉效果。相比之下,REDCNN没有图像失真和模糊问题,但

确实遭受过度平滑和纹理细节的损失。EDCNN在保留图像细节方面优于其他方法,但仍然可以看到细微的条纹伪影。从感知性能的角度来看,本文提出的MFFCNN在保持边缘信息的同时,去除了大量的噪声水平,而且ROI的边缘是清晰的,阴影和条纹伪影是所有对比度方法中最轻的。众所周知,CT图像的纹理信息对放射科医生的诊断有很大的影响。该方法能有效抑制伪影,恢复纹理和细节,更接近于NDCT。




图7 不同算法去噪结果对比(第二组)

Fig. 7 Comparison of denoising results of different algorithms (Group 2)

为了进一步评价所提网络的有效性,计算了不同方法处理的所有结果的量化指标。表1为不同方法得到的去噪图像在整个试验数据上的平均PSNR、SSIM、GMSD、FSIM和VIF<sub>s</sub>值。

表1 各去噪算法在测试集上的去噪表现

Tab. 1 Performance of various denoising algorithms on the test dataset

方法	PSNR	SSIM	GMSD	FSIM	VIF <sub>s</sub>
LDCT	30.280 5	0.858 5	0.087 6	0.945 2	0.464 3
WavResNet	33.098 4	0.908 4	0.060 6	0.961 9	0.519 7
REDCNN	33.202 1	0.910 9	0.061 0	0.961 4	0.512 8
EDCNN	33.221 7	0.908 1	0.060 5	0.961 4	0.520 4
WGAN-VGG	32.283 1	0.900 6	0.067 5	0.960 9	0.497 0
pix2pix	31.757 1	0.902 0	0.067 6	0.950 2	0.475 0
MFFCNN	33.637 6	0.916 9	0.059 3	0.962 8	0.528 2

可以看出,本文方法对所有客观指标都有很好的量化性能,PSNR和SSIM提高显著。总体而言,RED\_CNN的SSIM次之,EDCNN的PSNR、GMSD和VIF<sub>s</sub>次之。WGAN\_VGG的指数不是很突出。EDCNN、REDCNN和WavResNet处理后的图像

GMSD无显著差异。Pix2pix在SSIM、PSNR、FSIM等指标上表现不佳。由于医生在实际临床应用中倾向于关注局部ROI,故将不同方法得到的结果中ROI的表现进行量化,如图8所示。比较每种方法在相同ROI下的PSNR,MFFCNN的量化性能普遍领先,pix2pix和WGAN\_VGG的数值最差。但其他方法之间没有太大区别,有时几乎等于MFFCNN。MFFCNN的SSIM得分最高。因此,在评价图像质量时,应在多种定量指标中考虑不同方法的性能。综上所述,无论从定量指标还是视觉效果分析,所提方法都取得了优异的降噪性能。

2.2.2 Piglet数据集

Piglet数据集是一个公开的真实数据集,其专门用于评估LDCT图像的降噪效能以及算法的稳健性。该数据集采用GE的Discovery CT750 HD扫描仪对仔猪进行了扫描。在本次实验中,随机挑选了400对Piglet图像,并额外设置了40对图像作为测试集。




图 8 各去噪算法在两处 ROI 区域上的 PSNR 和 SSIM

Fig. 8 PSNR and SSIM of each denoising algorithm in two ROI regions

图 9 为在不同辐射剂量水平(即 150, 75 和 30 mAs)下,采用多种处理技术所得的代表性 Piglet 切片影像。所有 CT 图像均于[40, 400]HU 窗宽范围内展示。分析结果显示,基于 CNN 的方法展现出了相对稳定的降噪能力。具体而言, WavResNet 方法虽实施了一定程度的平滑处理,却引入了过度的平滑效应及额外的伪影现象。REDCNN、WGAN\_VGG 及 pix2pix 等方法在降

噪的同时牺牲了图像细节,导致细节模糊。相比之下, EDCNN 方法在维持边缘与细节方面表现较好,但在噪声抑制方面则略显不足。当管电流设定为 150 mAs 与 75 mAs 时, MFECNN 网络所生成的图像与对应的 NDCT 图像接近,此现象表明 MFECNN 方法不仅能够有效抑制噪声,还能最大限度地保留图像中的关键细节信息,展现出其在图像处理上的优越性能。




图 9 不同辐射水平下各噪型去噪结果对比

Fig. 9 Comparison of denoising results of different noise types under different radiation

### 2.3 消融实验

本节在 Mayo 数据集上进行消融实验,以分析 MFECNN 中所有贡献的影响。为了研究不同子模块对网络性能的影响,进行了一组消融实验,消融实验的训练数据集和测试数据集与对比实验相同。

“w/o 非二进制边缘检测子网络”(用二进制边缘检测算子代替非二进制边缘检测)模型记为①,“w/o 注意机制模块”(从提出的 MFECNN 中去除注意模块)模型记为②,完整的 MFECNN 模型记

为③。表 2 为消融实验各模型在处理 35 对测试集时的平均指标值,各模型在测试集另一组代表性 CT 图像上的去噪效果如图 10 所示,显示窗位为  $[-160, 240]$  HU。

由表 2 可知,提出的 MFECNN 在每个指标上都获得了最好的分数。相较于模型①,模型②在 PSNR、SSIM 上有较大提升,但边缘相对于模糊。比较模型②和模型③,注意力模块的加入让模型③在所有定量指标上都有了提升。观察图 9 可知, LDCT 图像的噪声/伪影对病灶边缘的判断有一定

的干扰,模型①的噪声抑制效果有限且在ROI区域处理得较为模糊,肉眼观不佳。模型②在噪声抑制上有了很大提升,但处理结果的整体图像对比度不高。模型③在加入注意力模块和非二进制边缘检

测标签后,去噪结果的纹理细节得到了提升,视觉效果在3个模型中最佳。综上所述,边缘提取模块和注意力模块在MFFCNN中都有正向效果,提升了模型的噪声抑制和细节保留能力。




图 10 消融实验下各噪型去噪结果对比

Fig. 10 Comparison of denoising results of different noise types under ablation experiment

表 2 消融实验时各模型在测试集下的去噪表现

Tab. 2 Performance of denoising by each model on the test dataset under ablation experiments

模型	非二进制边缘	注意力融合模块	PSNR	SSIM
①		✓	33.377 3	0.913 5
②	✓		33.444 0	0.915 0
③	✓	✓	33.637 6	0.916 9

### 3 结 论

本文提出了一种针对LDCT图像去噪的新网络,该网络通过多特征提取策略,旨在解决深度学习去噪中常见的纹理细节丢失和图像过平滑难题。设计了一个端到端的处理框架,巧妙融合了边缘检测、图像去噪与图像融合功能,并引入了注意力机制以增强效能。本文核心创新在于交叉卷积边缘模块,它利用并行处理垂直和水平梯度的方法,有效提升了LDCT图像边缘信息的提取能力,从而显著增强了去噪效果。此外,还设计了注意力融合模块,通过整合通道注意力和空间注意力,构建了一个双注意力图像融合结构,促进了特征间的深度融合,进一步提高了降噪性能。实验结果表明,该方法具有较好的噪声抑制能力和边缘细节保护能力。对比试验和消融实验表明,该网络各个模块的改进具有积极意义。尽管所提网络模型在噪声抑制与细节保留方面展现了出色的性能,但仍有潜力通过采用更先进的细节

增强技术来进一步提升边缘细节信息的提取能力。此外,本研究采用的方法完全基于神经网络架构,而深度神经网络固有的一个局限性在于其可解释性相对较弱。因此,未来的研究方向将着重于在现有网络架构的基础上融合传统去噪方法,旨在构建一个既高效又更具可解释性的综合去噪框架。

### 参考文献:

[ 1 ] 王耀鹏,贾丽娜,刘卓. 一种基于边缘提取和渐进非局部均值的快速LDCT图像去噪算法[J]. 测试技术学报, 2023, 37(3): 243-248.  
WANG Yaopeng, JIA Lina, LIU Zhuo. A fast low-dose CT images denoising algorithm based on edge extraction and progressive non-local means[J]. Journal of Test and Measurement Technology, 2023, 37 (3): 243-248. (in Chinese)

[ 2 ] 刘卓,贾丽娜,王耀鹏. 基于低秩矩阵近似的LDCT图像两步去噪方法[J]. 测试技术学报, 2023, 37 (5): 449-454.  
LIU Zhuo, JIA Lina, WANG Yaopeng. Two-step denoising method for low-dose CT images based on low-rank matrix approximation [J]. Journal of Test and Measurement Technology, 2023, 37 (5): 449-454. (in Chinese)

[ 3 ] DABOV K, FOI A, KATKOVNIK V, et al. Image denoising by sparse 3-D transform-domain collabora-

- tive filtering[J]. *IEEE Transactions on Image Processing*, 2007, 16(8): 2080-2095.
- [4] HUANG J, MA J, LIU N, et al. Projection data restoration guided non-local means for low-dose computed tomography reconstruction [C]//2011 IEEE International Symposium on Biomedical Imaging: From Nano to Macro, 2011: 1167-1170.
- [5] KANG D, SLOMKA P, NAKAZATO R, et al. Image denoising of low-radiation dose coronary CT angiography by an adaptive block-matching 3D algorithm [C]//Medical Imaging: Image Processing, 2013: 86692.
- [6] BUADES A, COLL B, MOREL J M. A non-local algorithm for image denoising [C]//2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05), 2005: 60-65.
- [7] CHEN Y, YANG Z, HU Y, et al. Thoracic low-dose CT image processing using an artifact suppressed large-scale nonlocal means [J]. *Physics in Medicine and Biology*, 2012, 57(9): 2667-2688.
- [8] FAN F, SHAN H, KALRAM K, et al. Quadratic autoencoder (Q-AE) for low-dose CT denoising[J]. *IEEE Transactions on Medical Imaging*, 2019, 39(6): 2035-2050.
- [9] KANG E, MIN J, YE J C. A deep convolutional neural network using directional wavelets for low-dose X-ray CT reconstruction[J]. *Medical Physics*, 2017, 44(10): 360-375.
- [10] 高文波, 孔慧华, 连祥媛. 基于多尺度生成对抗网络的LDCT去噪算法[J]. *国外电子测量技术*, 2021, 40(8): 1-6.  
GAO Wenbo, KONG Huihua, LIAN Xiangyuan. Low-dose CT denoising algorithm based on multi-scale generative adversarial network[J]. *Foreign Electronic Measurement Technology*, 2021, 40(8): 1-6. (in Chinese)
- [11] 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.
- [12] GENG M, MENG X, YU J, et al. Content-noise complementary learning for medical image denoising [J]. *IEEE Transactions on Medical Imaging*, 2022, 41(2): 407-419.
- [13] HAN Z, SHANGGUAN H, ZHANG X, et al. A dual-encoder-single-decoder based low-dose CT denoising network [J]. *IEEE Journal of Biomedical and Health Informatics*, 2022, 26(7): 3251-3260.
- [14] WANG D, FAN F, WU Z, et al. CTformer: convolution-free Token2Token dilated vision transformer for low-dose CT denoising[J/OL]. *Electrical Engineering and System Science*, 2022. arXiv: 2202.13517. <https://arxiv.org/abs/2202.13517v1>.
- [15] LIANG T, JIN Y, LI Y, et al. EDCNN: edge enhancement-based densely connected network with compound loss for low-dose CT denoising [C]//2020 15th IEEE International Conference on Signal Processing (ICSP), 2020: 193-198.
- [16] AAPM. Low dose CT grand challenge [EB/OL]. [2024-08-25]. <http://www.aapm.org/GrandChallenge/LowDoseCT/>.
- [17] KAZAKOVA N, MARGALA M, DURDLE N G. Sobel edge detection processor for a real-time volume rendering system [C]//2004 IEEE International Symposium on Circuits and Systems, 2004: 913.
- [18] FANG F, LI J, YUAN Y, et al. Multilevel edge features guided network for image denoising [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, 32(9): 3956-3970.
- [19] KANG E, MIN J, YE J C. Wavelet domain residual network (WavResNet) for low-dose X-ray CT reconstruction [J/OL]. *Computer Science*, 2017. arXiv: 1703.01383. <https://arxiv.org/abs/1703.01383>.
- [20] ISOLA P, ZHU J Y, ZHOU T, et al. Image-to-image translation with conditional adversarial networks [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 5967-5976.
- [21] WANG Z, BOVIK A C, SHEIKH H R, et al. Image quality assessment: from error visibility to structural similarity [J]. *IEEE Transactions on Image Processing*, 2004, 13(4): 600-612.
- [22] XUE W, ZHANG L, MOU X, et al. Gradient magnitude similarity deviation: a highly efficient perceptual image quality index [J]. *IEEE Transactions on Image Processing*, 2013, 23(2): 684-695.
- [23] ZHANG L, ZHANG L, MOU X, et al. FSIM: a feature similarity index for image quality assessment [J]. *IEEE Transactions on Image Processing*, 2011, 20(8): 2378-2386.
- [24] SHEIKH H R, BOVIK A C. Image information and visual quality [J]. *IEEE Transactions on Image Processing*, 2006, 15(2): 430-444.