

DOI:10.19651/j.cnki.emt.2417100

曲线匹配矫正扩散网络的 LDCT 图像去噪

夏君陶 颜明轩 杨心齐 张晓俊 陶智

(苏州大学光电科学与工程学院 苏州 215000)

摘要: 低剂量 CT 检查的使用极大减少了 CT 检查的辐射剂量,但却导致了 CT 图像中噪声增加和伪影增多等一系列问题,从而降低了图像质量和准确性,影响医生在诊断过程中的判断。而近年来生成式模型在解决这一问题上表现出了其优秀的性能,然而生成模型在生成过程中仍存在着容易生成混淆和结构性不足的问题,为了解决这一问题,构建了一个条件扩散去噪网络模型,并在此基础上引入了可训练的曲线矫正模块来对不同噪声等级进行矫正处理,并入了联合损失函数。实验结果表明,所提出算法相较于对比算法取得了较优去噪结果,在数据集测试中得到了 35.70 的 PSNR 和 0.912 8 的 SSIM,在所选取方法中获得最优效果,同时在不同剂量的低剂量 CT 图像中取得了较好的泛化性,可以保持较优秀的降噪水平。

关键词: 扩散模型;曲线矫正;低剂量 CT;图像去噪

中图分类号: TN95 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Curve matching diffusion model for LDCT images denoising

Xia Juntao Yan Mingxuan Yang Xinqi Zhang Xiaojun Tao Zhi

(School of Optoelectronic Science and Engineering, Soochow University, Suzhou 215000, China)

Abstract: The use of low-dose CT scans has significantly reduced radiation exposure during examinations. However, this reduction has led to increased noise and artifacts in CT images, compromising image quality and diagnostic accuracy, which can affect physicians' judgment during the diagnostic process. Recent advancements in generative models have demonstrated excellent performance in addressing these issues. Nonetheless, these models still face challenges, such as generating confusion and structural deficiencies during the generation process. To tackle these problems, a conditional diffusion denoising network model has been developed. This model incorporates a trainable curve matching module to correct different noise levels and includes a joint loss function. Experimental results indicate that the proposed algorithm achieves superior denoising outcomes compared to comparative algorithms, with test results of PSNR 35.70 and SSIM 0.912 8 on the dataset, representing the optimal performance among the selected methods. Additionally, it demonstrates good generalization across low-dose CT images with varying radiation doses, maintaining excellent denoising levels.

Keywords: diffusion model; curve correction; low dose CT; image denoising

0 引言

计算机扫描(computed tomography, CT),最初被称为计算机轴向断层摄影,是一种医学成像方法,通过断层成像原理和数字几何处理技术,将围绕单一旋转轴拍摄的大量二维 X 射线图像重建为三维物体内部图像^[1]。CT 技术的广泛应用极大地推动了医学影像学的发展,然而传统 CT 扫描往往需要较高剂量的辐射以获取高质量图像^[2]。这种高剂量辐射不仅会增加患者罹患癌症的风险,并且对儿童、孕妇等敏感群体的影响更加显著^[3]。因此,在保证图像质

量的同时,尽量降低辐射剂量成为临床应用中的重要难题。然而,辐射剂量的减少常伴随着图像质量的下降,具体表现为噪声的增加和细节的丢失,这严重影响医生的解读与诊断精度。

为了解决上述问题,国内外学者开发了多种低剂量 CT (low-dose CT, LDCT)图像降噪技术。这些方法主要包括正弦图滤波^[4]、迭代重建^[5-7]和图像降噪^[8]。其中,图像降噪技术因其不依赖 CT 图像重建过程而受到广泛关注,可以灵活适配于不同 CT 系统。以 Ma 等^[9]提出的基于块匹配 3D 的算法为例,该方法通过利用 BM3D 去噪后生成的

残留纹理数据显著提高软组织的视觉清晰度。此外, Liu 等^[10]和黄金等^[11]提出的三维高斯平滑滤波器虽然有效去除了图像中的噪声和伪影,但在边缘保护方面存在不足,易导致细节模糊。

近年来,深度学习技术在低剂量 CT 图像降噪领域的应用取得了突破性进展。与传统算法相比,深度学习方法通常基于监督学习框架,通过建立低剂量与正常剂量 CT 图像间的映射关系实现去噪效果。例如,早期研究使用了卷积神经网络,而后 Chen 等^[12]提出了一种基于编码器-解码器结构的 RED-CNN 网络,通过最小化去噪图像与标准剂量图像之间的像素误差进行优化。进一步地, RED-CNN 被整合到参数依赖框架中,用以增强对不同剂量水平和形状图像的适应能力^[13]。尽管这些方法在去噪效果上表现突出,但在保持图像细节和纹理方面仍存在挑战。为改善这一问题, Liang 等^[14]设计了基于边缘增强的密集连接网络 EDCNN,通过可训练的 Sobel 卷积核强化边缘信息,同时利用密集连接网络捕获更多特征。Jiang 等^[15]则提出了频率分离网络(FSNet),结合混合卷积和自适应聚合技术分别恢复低频与高频成分,改善去噪与细节保留。然而, FSNet 有时会导致图像过度平滑^[16]。

为了进一步提高降噪图像的视觉质量,生成对抗网络 GAN 被逐渐应用于低剂量 CT 图像去噪任务中。例如, Kim 等^[17]提出了一种基于 GAN 的框架,通过生成网络和判别网络的对抗式训练逐步提升去噪效果。Yang 等^[18]将 Wasserstein 距离和感知损失函数融入 GAN 框架,有效改善了细节保留能力。然而, GAN 模型仍然面临生成图像可能失真或结构性不足的问题。

综上所述,目前生成式低剂量 CT 图像降噪方法尽管取得了显著进展,但现有方法在生成图像的细节还原和全局结构保持能力方面仍存在局限性。为此,本研究提出了一种基于条件扩散模型的曲线匹配矫正去噪网络,通过引入真实图像的特征结构性对生成阶段进行监督,从而有效提升去噪图像的细节还原能力和全局一致性,为低剂量 CT 图像质量的提升提供了一种新的解决方案。

1 方法与实验

1.1 条件扩散模型

原始扩散模型其工作原理是逐步向训练数据添加高斯噪声,并随后学习逆转这一噪声过程以恢复原始数据。广泛采用的基于扩散的去噪扩散概率模型主要包括两个核心组成部分。前向过程涉及到逐步地将高斯噪声引入到原始图像中,可以表示为:

$$q(y_t | y_{t-1}) = N(y_t; \sqrt{\beta_t}; y_{t-1}(1 - \beta_t)I) \quad (1)$$

其中, $q(y_t | y_{t-1})$ 表示条件概率, β_t 表示时间步长 t 的噪声调动参数, I 为单位矩阵, 保证噪声添加在每一个方向上。通过边缘化中间步骤, 模型能够更有效地处理噪声的添加和移除过程, 从而提高图像恢复的质量。具体来说, 这

个过程可以表示为:

$$q(y_t | y_0) = N(\sqrt{\alpha_t}y_0, (1 - \bar{\alpha}_t)I) \quad (2)$$

其中, $\alpha_t = 1 - \beta_t$, $\bar{\alpha}_t = \prod_{i=0}^t \alpha_i$, 同时参数被设计确保

所产生的最终噪声服从正态分布 $\sim N(0, 1)$ 。

在扩散模型的逆向过程中, 通常会运用神经网络来进行数据去噪。逆向过程的主要目标是通过条件概率来重建原始数据。如下:

$$p_\theta(y_{t-1} | y_t) = N(\hat{y}_0, \frac{1 - \bar{\alpha}_{t-1}}{1 - \bar{\alpha}_t} \beta_t) \quad (3)$$

其中, $\hat{y}_0 = \frac{1}{\sqrt{\alpha_t}}(y_t - \frac{\beta_t}{\sqrt{1 - \bar{\alpha}_t}}\epsilon_\theta(y_t, t))$, 参数 ϵ_θ 通过

使用 U-Net 网络进行学习, 并通过这一过程来估计噪声图像中的噪声分布, 最终通过逐步采样最终获得无噪声的图像, 通过优化得到快速采样方法:

$$y_{t-1} = \sqrt{\alpha_{t-1}} \left(\frac{y_t - \sqrt{1 - \bar{\alpha}_t} \cdot \epsilon_\theta(y_t, t)}{\sqrt{\alpha_t}} \right) + \sqrt{1 - \bar{\alpha}_{t-1}} \cdot \epsilon_0(y_t, t) \quad (4)$$

而在实验中目标不仅仅是生成一张与低剂量 CT 图像相对应的标准剂量 CT 图像, 而是利用现有的配对图像数据集来学习噪声条件分布。实验所采用的扩散模型融入了额外的条件信息。在前向过程中, 没有做出特别的改变; 它仍然遵循原始扩散模型的前向过程, 即逐渐向标准剂量 CT 图像添加高斯噪声直到其完全变为符合 $\sim N(0, 1)$ 的高斯噪声。然而, 在反向过程中, 配对的低剂量图像被用作额外的输入。同时为了对低剂量 CT 图像进行针对性的降噪, 提出了再加入 SNR(signal to noise ratio)空间注意力图, 其有助于模型再去噪过程中更有效处理低信噪比区域, 从而提高图像质量, 表达式为:

$$SNR(x) = \frac{Fil(x)}{|x - Fil(x) + \delta|} \quad (5)$$

其中, δ 是一个可调参数, 用来防止分母等于零从而保持生成图像是稳定的, 为了实现高斯滤波, 引入了低通滤波器 $Fil(x)$ 。根据原始扩散模型的误差最小化任务:

$$E_{y_0, y_t, \epsilon} [\| \epsilon - \epsilon_\theta(\sqrt{\alpha_t}y_0 + \sqrt{1 - \bar{\alpha}_t}\epsilon, t) \|^2] \quad (6)$$

实验中训练过程首先随机采样配对的低剂量 CT 图像和对应的正常剂量 CT 图像, 然后将输入的低剂量 CT 图像与 SNR 图和噪声图在各位置上充分连接, 作为扩散模型的输入, 最后将原始误差最小化任务推导至:

$$E_{y_0, y_t, \epsilon} [\| \epsilon - \epsilon_\theta(\sqrt{\alpha_t}y_0 + \sqrt{1 - \bar{\alpha}_t}\epsilon, y_t, SNR(x), t) \|^2] \quad (7)$$

式中: y_t 为低剂量 CT 图像, $SNR(x)$ 为空间注意力信噪比图。

1.2 曲线匹配矫正模块

为了解决生成模型中可能存在的混乱生成的问题, 提出了一种基于曲线增强的曲线校正网络模块。该模块在训练过程中确保去噪后的正常剂量图像的结构合理性。

图 1 显示了不同 CMC 曲线, 为了实现自动将图像映射

到增强图像的曲线,所设计的曲线必须确保增强图像的像素值落在 $[0, 1]$ 的归一化范围内。此外,为了防止增强后局部关系被扭曲,曲线应保持单调递增趋势。这有助于在增强之前保留相邻像素值之间的对比差异。此外,为避免反向传播过程中出现梯度消失的情况,曲线的形式应尽可能简单。所提出增强曲线为:

$$CMC(y_H(x); \gamma) = y_H(x) + \gamma y_H(x)(1 - y_H(x)) \quad (8)$$

此外,为了实现多层级的最优图像增强,曲线被迭代地调节至更高阶,从而带来更加细致和精准的图像增强效果:

$$CM_n(x) = CM_{n-1}(x) + \gamma_n CM_{n-1}(x)(1 - CM_{n-1}(x)) \quad (9)$$

如图 2 所示整体网络结构图,为了学习输入图像到最合适的高阶曲线的映射,本研究采用了由 8 个前向卷积层组成的对称结构。此外为了保持相邻像素间的原始结构关系,去除了批量归一化层和下采样,通过 \tanh 激活函数输出。

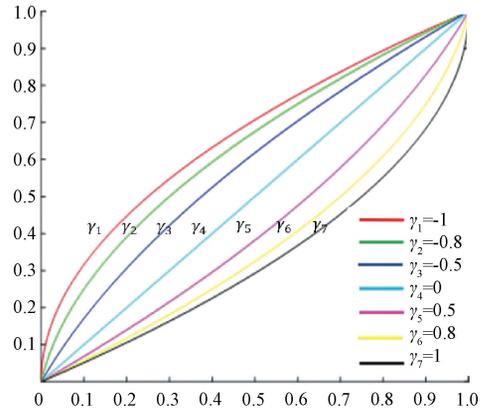


图 1 不同 γ 值对应的 CMC 曲线

Fig. 1 The CMC curves corresponding to different γ values

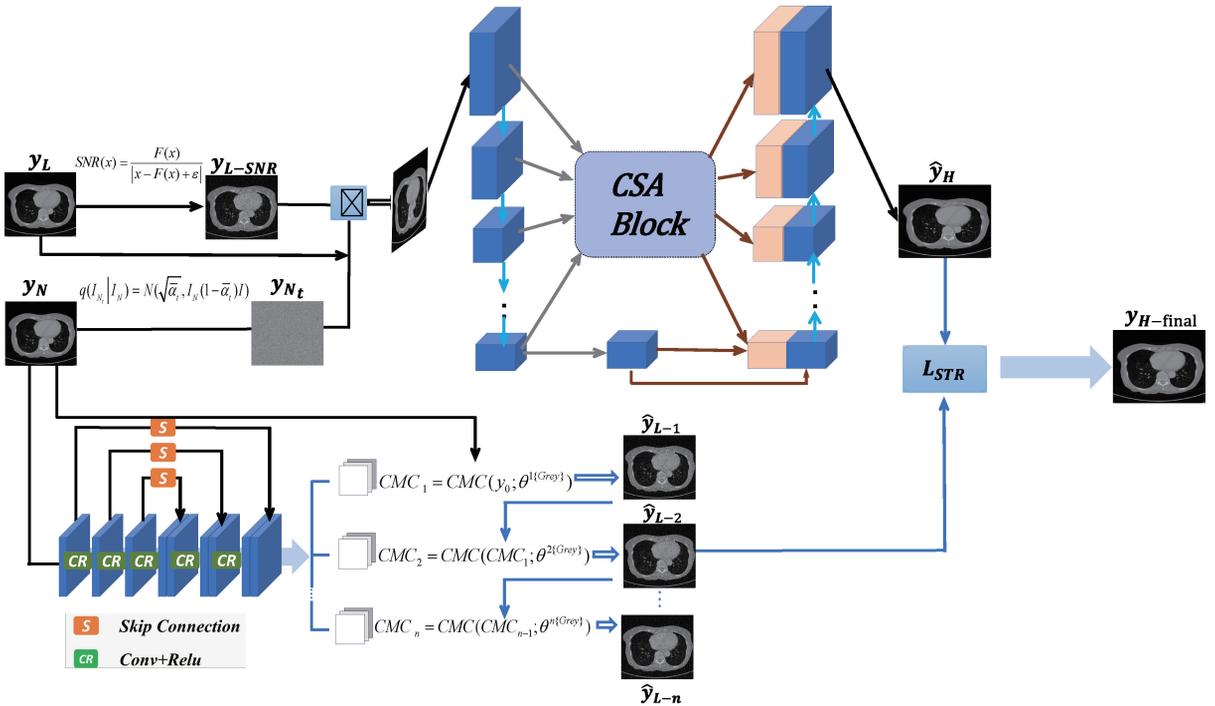


图 2 整体网络结构模型

Fig. 2 Overall network structure model

1.3 交叉注意力模块

扩散模型所使用的 U-Net 添加 CSA 块来增强对称结构间的跳跃连接;具体结构如图 3 所示。

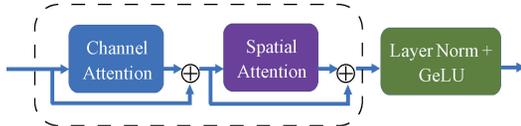


图 3 CSA 模块

Fig. 3 CSA block

CSA 模块中包含了通道注意力块和空间注意力块,利用多尺度编码器特征跨通道提取全局关系,同时可以获取

跨空间的空间依赖性。这种方法相对于普通的跳跃连接更能缩小语义间差距。

1.4 损失函数

实验中采用的为双阶段的网络结构,其中包含了一个条件扩散模型和曲线匹配矫正模块,除了两个阶段各自的损失函数以外,引入了一个结构证实性损失函数来进行优化。

首先在提出的条件扩散模型中,使用了两种损失函数,前文所提到改进的扩散模型损失函数:

$$L_{simple} = E_{y_0, t, \epsilon} [\| \epsilon - \epsilon_\theta(\sqrt{\alpha_t} y_0 + \sqrt{1 - \alpha_t} \epsilon, y_L, SNR(x), t) \|^2] \quad (10)$$

为了使图片质量更加接近于人类的视觉感知,并且增强生成式图像的真实感和细节感知差异,引入了感知损失,通过预训练的特征网络提取的高阶特征的差异进行训练:

$$L_{lpips} = \sum_l \frac{1}{H_l W_l} \|\phi_{VGG}^l(\hat{y}_0) - \phi_{VGG}^l(y_H)\|_2 \quad (11)$$

而在曲线矫正模块中,使用了空间连续性损失函数来保证增强图像空间一致性,防止增强过程中产生某一部分过度增强的问题,可以使增强图像过渡更加平滑自然。

$$L_{spa} = \frac{1}{K} \sum_{i=1}^K \sum_{j \in \Omega(i)} (|Y_i - Y_j| + |I_i - I_j|)^2 \quad (12)$$

其中, K 代表了选取的局部区域的数量,而 $\Omega(i)$ 表示以该区域为中心的 4 个相邻区域。通过 Y 和 I 表示了输入和输出图像的平均强度值即像素平均值。

最后可以得到实验中的最终损失函数为:

$$L_{total} = L_{simple} + L_{STR} + W_{spa} L_{spa} + W_{lpips} L_{lpips} \quad (13)$$

其中, W_{spa} 和 W_{lpips} 是权重系数,通过这两个系数来平衡空间损失和感知损失对于全局的优先程度,并保持多损失函数联合训练的稳定性

1.5 数据集

实验使用数据集主要有两部分,首先为了验证实验所提出网络的有效性,采用 Mayo Clinics 授权的 Mayo2016 数据集并用于网络训练及测试,其中包含了 2 378 位患者的低剂量 CT 图像以及配对的正常剂量 CT 图像,大小为 512×512 。其次为了验证本方法在不同剂量等级下的泛化性,本文使用了 Piglet 数据集,该数据集总计包含 850 张 CT 图像,通过不同管电流模拟正常剂量 50%、25%、10% 的低剂量 CT 图像。

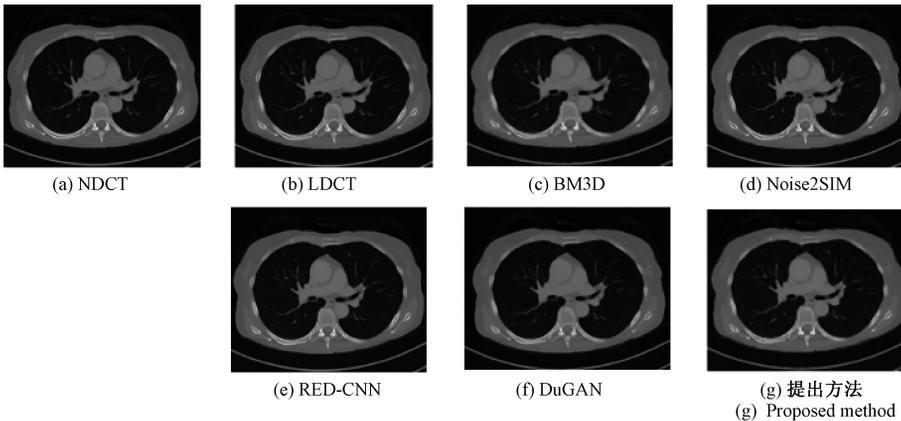


图 5 不同方法整体对比图

Fig. 5 Overall comparison of different method

图 5 为不同方法应用于所采用样本的整体对比图,首先从整体看,所使用对比方法相对于 LDCT 图像都有一定的去噪效果,而图 5(g)中本研究所提方法不管是在细节信息还是噪声和伪影方面都取得了较优秀的结果,且在主观

1.6 实验设置

实验中采取 9 位患者训练,一位患者测试的数据集构成进行实验,并通过客观性与主观性两方面进行评判。主观性评价选取一例切片样本进行评价,客观性评价通过评价指标在测试集中的平均值进行评价。Piglet 中选取 25% 和 10% 的低剂量 CT 图像进行测试。

实验设备如下:使用 PyTorch 框架,硬件配置为: Intel Core i9-11900K CPU@3.50 GHz, 内存 128 GB, 显卡为 NVIDIA GeForce RTX 3090。

2 结果

2.1 定性对比试验

为了验证实验中提出的方法准确性,本文选取了如图 4 的一例 CT 图像切片进行主观效果展示。



图 4 选取的测试图像

Fig. 4 Selected image for testing

如图 5 所示实验选取了 4 种对比算法: BM3D 算法、Noise2Sim 算法、RED-CNN 算法和 DuGAN 算法。同时根据审稿意见引入了更先进的两种对比方法 CT-former 和 CycleGAN 来更全面评估所提出模型的优劣。

观感上更接近于图 5(a)中的正常剂量 CT 图像。但直接全局观察整张去噪图像并不能直观体现出所使用方法的性能,所以在图 6 中选取了去噪结果的 3 个 ROI 区域来进行更细致的分析:

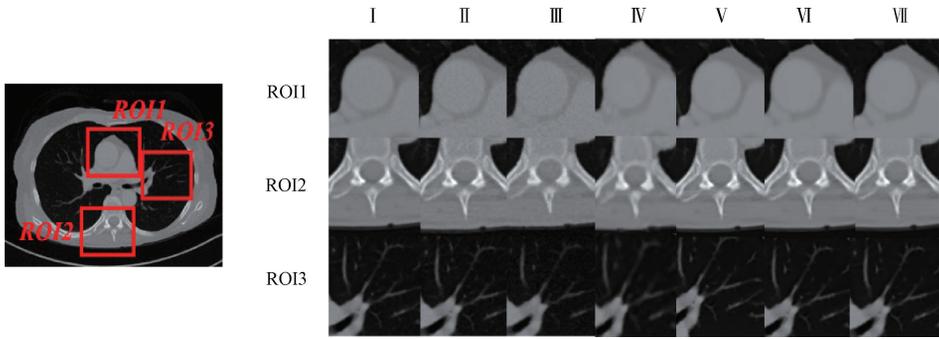


图 6 ROI 区域对比图

Fig. 6 ROI area comparison chart

基于 ROI1 区域中,针对 LDCT 图像中存在着大量散点噪声的情况下,所使用方法图 6Ⅶ与图 6Ⅳ和图 6Ⅴ相比显然更清晰,去除散点噪声能力更强,而 ROI2 区域中本文所使用的方法图 6Ⅶ明显优于其他对比方法,所降噪后生成的边缘过度更平滑清晰,而图 6Ⅴ和图 6Ⅵ都有轻微的出现过度平滑而导致分界面不清晰的问题。而在所标注出 ROI3 区域内,各种方法都体现出了不错的去噪能力,最终生成的效果相似,很难用肉眼做出区分。综上所述,结合 3 个 ROI 区域的综合分析,本研究所提出的方法优于所使用的 4 种对比方法,获得了肉眼更清晰,并且保留的更多的细节信息。

2.2 定量指标对比

本研究的定量对比指标主要采用了结构相似 SSIM、峰值信噪比 PSNR 和特征相似指数 FSIM 来进行去噪效果的客观评估。

在测试中获得的平均客观指标对比表 1 中,本研究算法在 3 种评价指标结构相似性 SSIM、峰值信噪比 PSNR 和特征相似指数 FSIM 中均取得了最优效果,表明了在该测试集中本文提出的算法不管是在结构相似度还是去噪之后的图像细节上都更接近于原始的正常剂量 CT 图像。结合上一节的主观评价指标,可以得到本文算法不管是在人眼主观评价效果和还是客观评价指标上都获得了优秀的效果,证明了实验的可靠性和有效性。

表 1 客观指标评估

Table 1 Objective evaluation

| 算法 | SSIM ↑ | PSNR/dB ↑ | FSIM ↑ |
|-----------|----------------|--------------|----------------|
| LDCT | 0.857 6 | 32.09 | 0.944 3 |
| BM3D | 0.902 5 | 34.20 | 0.962 4 |
| Noise2Sim | 0.908 9 | 34.68 | 0.954 5 |
| RED-CNN | 0.910 3 | 35.19 | 0.960 8 |
| DuGAN | 0.912 4 | 35.70 | 0.962 5 |
| CT-former | 0.911 0 | 35.48 | 0.962 6 |
| CycleGAN | 0.908 4 | 35.52 | 0.962 8 |
| 本文算法 | 0.912 8 | 35.70 | 0.962 9 |

表 2 为使用 Piglet 数据集中通过不同管电流模拟的 25%和 10%剂量的不同剂量 CT 图像客观评价,可以看出所提的方法除了在 25%中测试中的特征相似指数 FSIM 略低于 DuGAN 方法之外,在两种剂量的结构相似性 SSIM、峰值信噪比 PSNR 这两种评价指标和 10%剂量的 FSIM 均取得了最佳效果。

表 2 不同剂量 CT 图像客观评价

Table 2 Objective evaluation of different dose CT images

| 算法(剂量) | SSIM ↑ | PSNR/dB ↑ | FSIM ↑ |
|----------------|--------------|--------------|----------------|
| LDCT(25%) | 0.904 | 32.16 | 0.961 5 |
| BM3D(25%) | 0.923 | 34.19 | 0.962 3 |
| Noise2Sim(25%) | 0.932 | 34.39 | 0.963 6 |
| RED-CNN(25%) | 0.927 | 34.56 | 0.964 5 |
| DuGAN(25%) | 0.935 | 34.93 | 0.965 5 |
| CT-former | 0.934 | 34.88 | 0.964 9 |
| CycleGAN | 0.932 | 34.95 | 0.964 9 |
| 本文算法(25%) | 0.936 | 34.96 | 0.965 0 |
| BM3D(10%) | 0.885 | 33.87 | 0.961 9 |
| Noise2Sim(10%) | 0.908 | 34.06 | 0.957 6 |
| RED-CNN(10%) | 0.913 | 34.27 | 0.962 5 |
| DuGAN(10%) | 0.922 | 34.54 | 0.963 1 |
| CT-former | 0.923 | 34.50 | 0.963 3 |
| CycleGAN | 0.925 | 34.48 | 0.963 0 |
| 本文算法(10%) | 0.928 | 34.56 | 0.963 4 |

对于 25%剂量的数据集,本研究的方法达到了 0.936 的结构相似性指数 SSIM、34.96 的峰值信噪比 PSNR、0.965 0 的特征相似性指数 FSIM 这些结果与现有的方法相当。虽然 DuGAN 在 FSIM 方面有轻微的优势,但在 PSNR 和 MSE 指标上,实验提出方法表现更优,这表明本研究在整体去噪性能上占据领先地位。

在 10%剂量的数据集中,本研究的方法获得了 0.928 的 SSIM、34.56 的 PSNR、0.963 4 的 FSIM 在所使用的全部分评估指标中,本研究的方法超越所有本研究对比方法,

表现了更低的残余噪声水平和更高的图像保真度。展现了在保留结构细节与降低噪声之间良好的平衡性能。

这些客观指标的评估结果表明,实验方法在处理低剂量 CT 图像时,不仅能有效减少图像噪声,同时还能很好地保持图像的结构细节和特征,从而保证了图像的高质量输出。本研究的技术在保持图像真实性和细节清晰度方面表现出了显著优势,特别是在低剂量扫描条件下同时表 2 所显示的数据也证明了所提出方法在不同剂量 CT 图像中的鲁棒性。

2.3 消融实验

本研究通过消融实验来分析网络结构中不同功能部分对结果产生的影响,消融实验所使用训练集和测试集与客观评价实验中的相同。

实验中主要选取了几个部分作为消融实验选取点如表 3 所示,首先验证的是联合损失函数的作用,消融实验通过只使用扩散模型的 L_{simple} 损失函数即原始扩散模型进行训练,第 2 个消融实验为本研究设计的条件概率扩散模型但移除了曲线矫正模块,第 3 个消融实验是将 CSA 去除而只使用 U-Net 网络跳跃连接的整体网络架构。

表 3 消融实验
Table 3 Ablation study

| 消融实验 | SSIM ↑ | PSNR/dB ↑ | FSIM ↑ |
|---|----------------|--------------|----------------|
| Origin diffusion | 0.727 1 | 24.32 | 0.823 8 |
| Conditional diffusion | 0.886 4 | 30.84 | 0.884 2 |
| Conditional diffusion+ CMC Conditional | 0.911 2 | 33.65 | 0.954 5 |
| 本文方法 | 0.912 8 | 35.70 | 0.962 9 |

所采用的评价指标和对比实验所采用的评价指标相同,同样为结构相似性 SSIM、峰值信噪比 PSNR 和特征相似指数 FSIM。

表 3 中得到在根据低剂量 CT 图像噪声特点添加了条件扩散模型后使得模型相较于原始扩散模型提升幅度较大,而在添加了 CMC 曲线匹配矫正模块后所得图像显示了更强的细节质量和结构相似性,在使用 CSA 块通过优化 U-Net 跳跃连接后整体结果也有一定程度的上升。证明了实验中网络结构改进后的有效性。

3 结 论

针对现有低剂量 CT 图像处理存在着细节不足,过度过于平滑,生成式模型生成过程混淆等问题,本研究提出了一种基于扩散网络结构的 CMC-Diffusion 网络,专门用于低剂量 CT(LDCT)图像的降噪。通过融合了一个曲线匹配校正模块,通过在扩散模型结合高阶曲线增强方法进行 LDCT 图像增强。此外,为了满足 LDCT 图像特有的降噪需求,网络还把与 LDCT 图像噪声相关的条件参数整合

进条件扩散模型中,并设计了相应的损失函数。实验结果证明,所提出的网络结构在 LDCT 图像降噪方面实现了显著提升。它不仅表现出稳健的性能,而且在不同的 LDCT 数据集和剂量水平上具有良好的泛化能力。尽管利用公开可用的数据集已经取得了较好的结果,但是还未在临床 CT 检测图像中应用,未来还需继续加强。

参考文献

- [1] 孔欣,张兴超,郭珊珊,等. X 射线诱导声学计算机断层成像技术及其生物医学应用进展[J]. 激光生物学报, 2021,30(6):481-488.
KONG X, ZHANG X CH, GUO SH SH, et al. X-ray-induced acoustic computed tomography and its biomedical applications[J]. Acta Laser Biology Sinica, 2021,30(6):481-488.
- [2] 张心如,周先春,汪志飞,等. 基于改进各向异性扩散的图像去噪算法[J]. 电子测量技术, 2022, 45(17): 113-119.
ZHANG X R, ZHOU X CH, WANG ZH F, et al. Image denoising algorithm based on improved anisotropic diffusion [J]. Electronic Measurement Technology, 2022, 45(17): 113-119.
- [3] 谢巧雪,马宗庆,祝连庆,等. 基于结构相似约束生成对抗网络的视网膜 OCT 图像去噪算法[J]. 电子测量与仪器学报, 2023, 37(3):11-20.
XIE Q X, MA Z Q, ZHU L Q, et al. Retinal OCT image denoising algorithm based on structural similarity-constrained generative adversarial network[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(3): 11-20.
- [4] 火元莲,脱丽华,齐永锋,等. 量化核最小逆双曲正弦自适应滤波算法[J]. 物理学报, 2022, 71(22):361-368.
HUO Y L, TUO L H, QI Y F, et al. Quantized kernel minimum inverse hyperbolic sine adaptive filtering algorithm [J]. Acta Physica Sinica, 2022, 71(22): 361-368.
- [5] MILETO A, GUIMARAES L S, MCCOLLOUGH C H, et al. State of the art in abdominal CT: The limits of iterative reconstruction algorithms[J]. Radiology, 2019, 293(3): 491-503.
- [6] 徐勇,张志伟,朱宏禹,等. 基于改进 DTCWT 和引导滤波的低剂量 CT 图像降噪[J]. 国外电子测量技术, 2023(3):189-194.
XU Y, ZHANG ZH W, ZHU H Y, et al. Low-dose CT image denoising based on improved DTCWT and guided filtering [J]. Foreign Electronic Measurement Technology, 2023(3): 189-194.
- [7] 陈妍,徐海黎,邢强,等. 结合小波变换和双边滤波的 SICM 图像降噪算法[J]. 电子测量技术, 2022, 45(4):

- 114-119.
CHEN Y, XU H L, XING Q, et al. SICM image denoising algorithm combining wavelet transform and bilateral filtering [J]. Electronic Measurement Technology, 2022, 45(4): 114-119.
- [8] 周先春, 伍子锴, 石兰芳. 小波包与偏微分方程相结合的图像去噪方法[J]. 电子测量与仪器学报, 2018, 32(7): 61-67.
ZHOU X CH, WU Z K, SHI L F. Image denoising method combining wavelet packet and partial differential equations [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32 (7): 61-67.
- [9] MA J, HUANG J, FENG Q, et al. Low-dose computed tomography image restoration using previous normal-dose scan [J]. Medical Physics, 2011, 38(10): 5713-5731.
- [10] LIU B, ZHANG H, HUA S, et al. An automatic segmentation system of acetabulum in sequential CT images for the personalized artificial femoral head design [J]. Computer Methods and Programs in Biomedicine, 2016, 127: 318-335.
- [11] 黄金, 周先春, 吴婷, 等. 混合维纳滤波与改进型 TV 的图像去噪模型[J]. 电子测量与仪器学报, 2017, 31(10): 1659-1666.
HUANG J, ZHOU X CH, WU T, et al. Image denoising model based on hybrid Wiener filtering and improved TV[J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(10): 1659-1666.
- [12] 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.
- [13] XIA W, LU Z, HUANG Y, et al. CT reconstruction with PDF: Parameter-dependent framework for data from multiple geometries and dose levels [J]. IEEE Transactions on Medical Imaging, 2021, 40 (11): 3065-3076.
- [14] 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), IEEE, 2020, 1: 193-198.
- [15] JIANG X, WANG L, HE Z, et al. Learning a frequency separation network with hybrid convolution and adaptive aggregation for low-dose CT denoising [C]. 2021 IEEE International Conference on Bioinformatics and Biomedicine (BIBM), IEEE, 2021: 919-925.
- [16] LI H, SHI X, ZHU X, et al. FSNET: Dual interpretable graph convolutional network for Alzheimer's disease analysis [J]. IEEE Transactions on Emerging Topics in Computational Intelligence, 2022, 7(1): 15-25.
- [17] KIM B, HAN M, SHIM H, et al. A performance comparison of convolutional neural network based image denoising methods: The effect of loss functions on low-dose CT images [J]. Medical Physics, 2019, 46(9): 3906-3923.
- [18] 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.

作者简介

夏君陶, 硕士研究生, 主要研究方向为图像信号处理。

E-mail: 20225239007@stu.suda.edu.cn

颜明轩, 硕士研究生, 主要研究方向为信号处理和病理嗓音研究。

E-mail: 20234239036@stu.suda.edu.cn

杨心齐, 硕士研究生, 主要研究方向为图像信号处理。

E-mail: 20234239037@stu.suda.edu.cn

张晓俊, 博士, 主要研究方向为数字信号处理。

E-mail: zhangxj@suda.edu.cn

陶智(通信作者), 教授, 博士, 主要研究方向为数字信号处理。

E-mail: taoz@suda.edu.cn