

基于条件扩散模型的CT金属伪影校正

梁佩文, 郑梦洵, 唐龙, 张华

南方医科大学生物医学工程学院/广东省医学图像处理重点实验室, 广东 广州 510515

【摘要】目的:提出一种基于模板先验的条件扩散模型,以校正计算机断层扫描在扫描过程中因金属种植体导致的重建图像出现明暗相间的条纹状金属伪影。**方法:**首先利用图像分割技术将金属部分进行分割,并生成对应金属轨迹投影数据,去除金属轨迹的投影数据以及模板先验图像对应投影数据;然后构建条件扩散模型,恢复投影数据对应金属区域的缺失部分;最后对恢复投影进行滤波反投影重建获得校正图像。**结果:**本文方法与伪影解耦网络相比,峰值信噪比提高3.44 dB,结构相似性指数提高0.079;与扩散模型相比,峰值信噪比提高0.749 dB,结构相似性指数提高0.015。**结论:**本文方法优于传统金属伪影校正方法,在条形伪影及阴影型伪影校正方面具有较好表现。

【关键词】计算机断层扫描;金属伪影;条件扩散模型

【中图分类号】R318;TP391.41

【文献标志码】A

【文章编号】1005-202X(2025)04-0457-09

CT metal artifact correction using conditional diffusion model

LIANG Peiwen, ZHENG Mengxun, TANG Long, ZHANG Hua

Guangdong Provincial Key Laboratory of Medical Image Processing/School of Biomedical Engineering, Southern Medical University, Guangzhou 510515, China

Abstract: Objective To propose a conditional diffusion model based on template priors for correcting streaky metal artifacts characterized by alternating bright and dark patterns that appear in reconstructed computed tomography (CT) images due to the presence of metallic implants. **Methods** After isolating metal region using image segmentation technology to generate metal trajectory projection data, the projection data of metal trajectory and the corresponding projection data of template prior images were excluded. Subsequently, a conditional diffusion model was developed to recover the missing portions of the projection data in the metal-affected regions. Finally, the restored projection data were reconstructed using filtered back projection to obtain the corrected image. **Results** Compared with artifact disentanglement network and diffusion model, the proposed approach improved peak signal to noise ratio by 3.44 and 0.749 dB, and increased structural similarity index by 0.079 and 0.015, respectively. **Conclusion** The proposed approach outperforms traditional metal artifact correction methods and exhibits superior performance in reducing both streaky and shadow artifacts.

Keywords: computed tomography; metal artifact; conditional diffusion model

前言

计算机断层扫描(Computed Tomography, CT)技术广泛应用于检测和评估各类器官及组织的异常情况,如发现肿瘤、囊肿、结石等病变,并进一步评估这些病变的大小、形态和位置等特征。然而,随着现代医学技术的发展,越来越多的患者携带金属种植体

(如义齿、心脏支架等),这些金属植入物在CT扫描过程中会产生伪影,导致图像中CT值的偏差,从而影响病变的准确检测和组织类型的正确区分^[1]。因此,减少CT金属伪影对于提高图像质量和诊断的可靠性具有重要的临床意义。

目前,校正金属伪影的方法大致可以分为3类:基于迭代的方法^[2-5]、基于弦图插值的方法^[6-11]和插值与迭代相结合的方法^[12-13]。基于迭代的方法通常需要长时间的迭代计算,并且依赖于手工调参,难以满足实际临床应用的实时性要求;基于弦图插值的方法难以实现投影数据的完全一致性替换,容易引入与周围数据不一致的区域,导致重建后出现明显的二次伪影^[14];插值与迭代相结合的方法可以有效校正

【收稿日期】2024-12-20

【基金项目】广东省自然科学基金(2024A1515010523)

【作者简介】梁佩文,硕士研究生,研究方向:CT金属伪影校正,
E-mail: 915643910@qq.com

【通信作者】张华,副教授,研究方向:医学CT重建与分析, E-mail:
xinsier@smu.edu.cn

金属伪影,但是需要结合多种算法,计算成本比较高。

近年来,随着深度学习技术的快速发展,许多研究尝试将深度学习方法应用于CT金属伪影的校正,并取得显著进展。Gjesteby等^[15]将卷积神经网络融合到CT图像重建过程中,结合归一化减少金属伪影(Normalized Metal Artifact Reduction, NMAR)算法^[16]与投影域中的深度学习方法,在关键图像区域实现更精确的校正。Park等^[17]利用U-Net^[18]结构学习金属轨迹区域的几何形状与相应光束硬化因子之间的映射关系,从而有效消除由金属引起的不一致性。Wang等^[19]基于生成对抗网络^[20],直接从受伪影影响的图像生成无伪影的图像,解决图像到图像的转换问题。Zhang等^[21]提出一种基于卷积神经网络的先验图像估计方法,利用先验图像填充弦图中被损坏的区域,通过后处理步骤减少二次伪影的产生。Zhu等^[22]提出基于弦图的金属自动分割网络,结合残差弦图学习方法,有效减少图像域的二次伪影。Lin等^[23]提出一种端到端可训练的双域网络(DuDoNet),能同时恢复弦图数据的一致性并增强最终的CT图像质量。目前的方法依然存在一些局限性,如伪影校正不彻底,尤其是在金属周边区域,复杂的解剖结构难以完全恢复;因此,仍需探索如何更好地平衡伪影校正效果与图像的结构保真度,以满足更高的临床诊断需求。

本研究提出一种基于扩散模型的CT图像金属伪影校正方法,该方法利用扩散模型的图像恢复能力,重建被金属破坏的投影数据。具体地,对于受金

属伪影影响的CT图像,采用阈值分割技术,将金属伪影区域与其它区域分离,生成相应的金属轨迹投影数据,去除金属轨迹投影数据以及模板先验投影数据。金属轨迹投影数据被用作掩膜,训练过程中模型仅预测被掩膜遮盖的像素,而不是整个图像,这种策略有助于加快训练速度并集中模型对关键区域的学习^[24]。然而,单纯依赖扩散模型在图像转换过程中进行图像恢复可能导致生成的结果与原始图像不完全一致,每次生成的结果可能略有差异。为更好地引导金属伪影校正后的图像接近原始图像,本研究使用模板先验投影数据作为条件信息,辅助指导生成过程,以提高校正后图像的准确性和一致性。

1 方法

整体工作流程见图1。首先,在初始阶段,对未校正的含有金属伪影的CT图像进行阈值分割,并将这些区域提取出来以生成金属图像。随后,对提取的金属图像进行投影,生成相应的弦图,并通过二值化处理得到用于输入扩散模型的二值掩膜。接下来,对CT图像中的骨骼、软组织等结构进行分类,从而获得模板先验图像。在扩散模型的前向阶段,模型利用未受金属伪影影响的CT图像正投影生成的弦图,仅对掩膜覆盖部分进行加噪;在扩散模型的反向过程,模板先验图像与被噪声破坏的弦图拼接后,一同输入扩散模型的U-Net中。先验图像作为条件输入能更精确地引导模型恢复被金属伪影破坏的CT弦图。最后,对校正后的弦图进行滤波反投影重建,以获得优化后的CT图像。

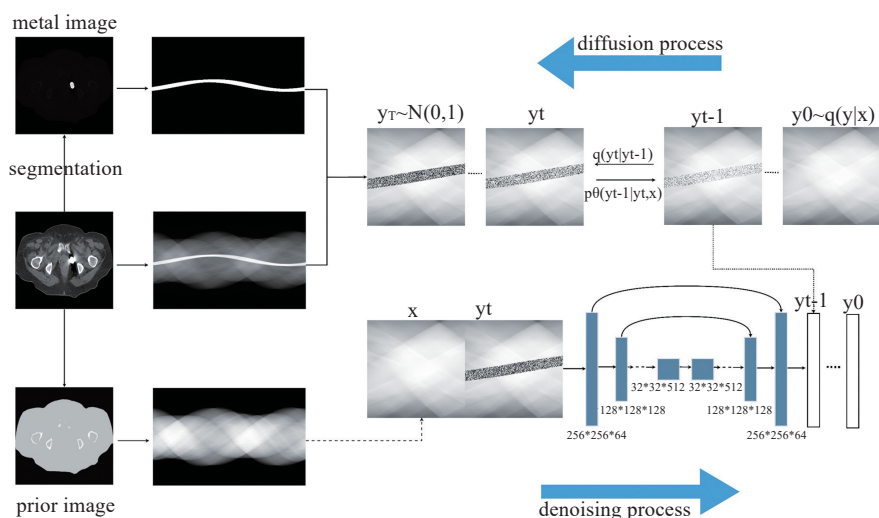


图1 金属伪影校正算法流程图

Figure 1 Flowchart of the proposed metal artifact correction algorithm

1.1 扩散模型

扩散模型是一种深度生成模型,与生成对抗网

络^[20]等其他生成模型相比,扩散模型在图像恢复中的应用显示了其强大的能力和广泛的适用性。扩散模

型的前向过程旨在为神经网络学习如何在逆向过程中有效去噪提供训练数据。给定真实图像 y_0 ,前向扩散过程是在 T 次迭代中将高斯噪声添加到 y_0 的马尔可夫过程,得到一系列 $y_1, y_2, \dots, y_t, \dots, y_T$ 噪声图像,直到得到完全被噪声破坏的图像:

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

$$q(y_{1:T}|y_0) = \prod_{t=1}^T q(y_t|y_{t-1}) \quad (2)$$

其中, α_t 是超参数,介于0~1, α_t 与 $1-\alpha_t$ 分别表示保留信号和添加噪声的比例。通常情况下, t 越大, $\sqrt{\alpha_t}$ 越接近0,所以如果扩散步数 $t=T$ 的时候, y_T 就会变成完全的随机噪声,根据式(1)、(2)可以推理得到以下公式:

$$q(y_t|y_0) = N(y_t; \sqrt{\gamma_t} y_0, (1 - \gamma_t)I) \quad (3)$$

$$q(y_{t-1}|y_0, y_t) = N(y_{t-1}; \mu, \sigma^2 I) \quad (4)$$

其中,

$$\gamma_t = \prod_{i=1}^t \alpha_i \quad (5)$$

从推理得到的公式可以发现因为每个过程的状态只与前一个过程有关,所以给定原始图像 y_0 ,即可计算出加入 t 次噪声后的 y_t 。

去噪过程的目标是将被噪声破坏的图像 y_T 逐步去噪还原为初始图像 y_0 。与前向过程不同,根据 t 时刻被噪声破坏的图像 y_t 来计算得到 $t-1$ 的图像是比较困难的,需要训练神经网络 $p_\theta(y_{t-1}|y_t)$,并将反向去噪过程定义为一个马尔可夫链,这样做的原因是,马尔可夫链是一种概率模型,由一系列状态组成,每个状态通过神经网络参数化为一个高斯分布,而高斯分布依赖于两个关键参数:均值和方差。在扩散模型中,通常将方差设定为固定值,并根据预先定义的超参数进行计算,以简化建模过程。

$$p_\theta(y_{0:T}) = p_\theta(y_T) \prod_{i=1}^T p_\theta(y_{t-1}|y_t) \quad (6)$$

$$p_\theta(y_{t-1}|y_t) = N(y_{t-1}; \mu_\theta(y_t, \gamma_t), \sigma^2 I) \quad (7)$$

其中,

$$\mu_\theta(x, y_t, \gamma_t) = \frac{1}{\sqrt{\alpha_t}} \left(y_t - \frac{1 - \alpha_t}{\sqrt{1 - \gamma_t}} f_\theta(y_t, \gamma_t) \right) \quad (8)$$

训练神经网络预测 $f_\theta(y_t, \gamma_t)$ 就可以计算 $q(y_{t-1}|y_t)$ 的均值与方差,根据 t 时刻的 y_t 得到 $t-1$ 时刻的 y_{t-1} 。

1.2 基于模板先验的投影图像恢复条件扩散模型

针对金属伪影校正过程中缺失投影数据的恢复问题,本研究提出一种基于模板先验的投影图像恢复条件扩散模型,单纯依赖扩散模型进行图像生成时,由于其依赖于神经网络对噪声的预测来逐步重

建前一时刻投影,这种去噪生成的数据具有随机性和不可控性,难以实现预期的结果。因此,本研究通过引入条件输入 x 来引导图像生成过程:

$$p_\theta(y_{0:T}) = p_\theta(y_T) \prod_{i=1}^T p_\theta(y_{t-1}|y_t, x) \quad (9)$$

$$p_\theta(y_{t-1}|y_t, x) = N(y_{t-1}; \mu_\theta(x, y_t, \gamma_t), \sigma^2 I) \quad (10)$$

其中,

$$\mu_\theta(x, y_t, \gamma_t) = \frac{1}{\sqrt{\alpha_t}} \left(y_t - \frac{1 - \alpha_t}{\sqrt{1 - \gamma_t}} f_\theta(x, y_t, \gamma_t) \right) \quad (11)$$

1.2.1 金属伪影掩膜扩展 在众多针对金属伪影弦图进行校正的方法中,金属边界区域数据的不连续数据时常会引入二次伪影的问题,为降低二次伪影的产生,在对金属区域进行弦图修补时,采用逐行扩展金属伪影掩膜的策略。具体而言,通过比较原始弦图与金属伪影弦图中的数值,从相邻的非伪影区域出发,逐步扩展掩膜的范围,直至 $g(x, \phi)$ 的值低于每行非金属信号平均值的1%,此方法旨在实现修补过程的平滑^[25]。 $g(x, \phi)$ 的值定义为:

$$g(x, \phi) = |p_\rho^{kv}(x, \phi) - p_\rho^{sv}(x, \phi)| \quad (12)$$

1.2.2 模板先验图像 本研究中,条件 x 的选择是被金属伪影破坏后的CT图像经过线性插值(Linear Interpolation, LI)后的分类模板,LI通过对不同类别之间的边界进行平滑处理,然后对骨骼和软组织等进行分类得到图像作为先验图像,在图像处理中提供平滑过渡和增强的鲁棒性,可以使最终的图像质量得到显著提升。

$$g(x, y) = \begin{cases} \text{骨骼}, & \text{if } f(x, y) \geq T_1 \\ \text{软组织}, & \text{if } T_2 < f(x, y) < T_1 \\ \text{空气或其他}, & \text{if } f(x, y) \leq T_2 \end{cases} \quad (13)$$

其中, $g(x, y)$ 是分类后的输出标签(如骨骼、软组织等), $f(x, y)$ 为原始图像在位置 (x, y) 的灰度值(HU值), T_1 和 T_2 是针对骨骼和软组织的预设阈值。

1.2.3 噪声预测网络 图2展示了基于模板先验的投影图像恢复条件扩散模型的内置网络架构。U-Net作为噪声预测网络,将受噪声干扰的弦图像与模板先验图像拼接后作为输入,由上采样、下采样、残差模块和注意力模块组成,每个部分包含多个卷积块。图2中的虚线部分表示跳跃连接,将来自编码器(下采样阶段)的特征图与解码器(上采样阶段)的特征图相连接,以保留更多原始分辨率信息,从而提高恢复质量。

图3a展示了U-Net的残差模块,每个残差模块包含两个卷积层。第一个卷积层用于调整通道数,第二个卷积层用于学习特征图内容。在调用模块

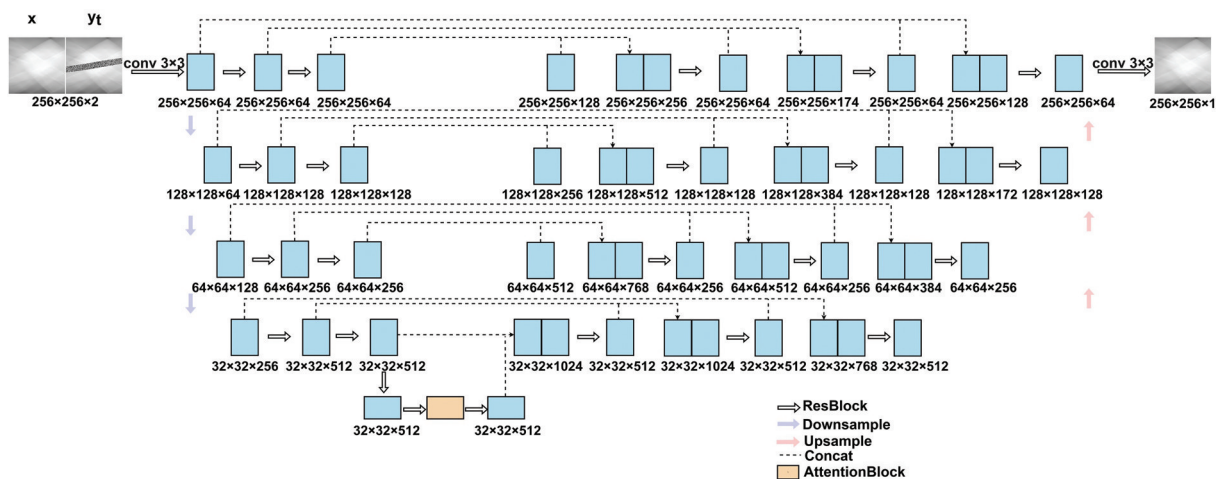


图2 扩散模型内置 U-Net 架构

Figure 2 U-Net architecture embedded in the diffusion model

时,输出将与输入相加,形成残差连接,有助于增强深度学习模型的训练稳定性并增加网络深度。图 3b 展示了 U-Net 的注意力模块,该模块首先对输入进行归一化处理,然后通过一维卷积层生成查询 (Query)、键(Key)和值(Value)向量,接着利用查询和

键之间的点积计算注意力权重,计算出的注意力权重用于对输入特征进行加权求和,最终通过一个投影层输出。注意力模块能增强模型的表达能力和数据处理能力,提高对输入数据的复杂特征的捕捉能力。

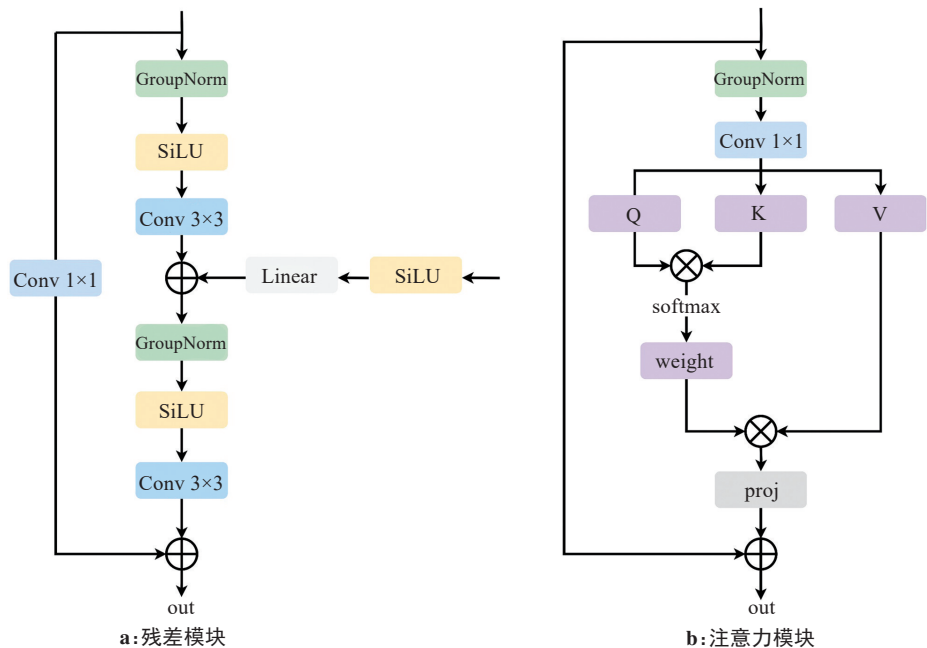


图3 U-Net的关键模块

Figure 3 Key modules of U-Net

网络采用L2损失函数,定义如下:

$$\text{Loss} = E_{(x,y)} E_{\epsilon \sim N(0,1)} E_{\gamma} \left\| f_{\theta} \left(x, \sqrt{\gamma} y + \sqrt{1-\gamma} \epsilon, \gamma \right) - \epsilon \right\|_2^2 \quad (14)$$

其中, ϵ 是在每个时间步 t 上独立采样得到的噪声,而 f_{θ} 是U-Net模型在时间步 t 下的输出,利用损失函数最小化模型预测的噪声和实际噪声之间的差距来估计 $t-1$ 时刻的噪声,对 t 时刻的图像减去预测得到的噪声,从而恢复出 $t-1$ 时刻的图像。

1.3 模型参数选择

在模型训练中训练阶段噪声是线性变化的,并涉及多个超参数,其中,初始线性噪声水平设定为 $1e-6$,结束值为0.01,学习率设为0.000 1。网络在具有11 GB内存的NVIDIA 1080Ti GPU上训练,批次大小为3,测试阶段的超参数的值分别是 $1e-4$ 和0.02,残差块的数量设置为2,衰减值设定为0.2。

2 实验

2.1 实验数据

(1) 仿真数据: 本研究使用未被金属伪影破坏的CT图像进行金属伪影仿真来构建训练数据, 为更好地模拟临床场景中可能出现的潜在金属伪影, 本研究根据Meyer等^[16]提出的NMAR生成的100个手动分割的金属模板, 这些模板涵盖临床中常见的金属植入物, 如牙科填充物、脊柱螺钉等。通过对这些金属模板进行位置调整、旋转和缩放等操作, 使得植入物的大小和位置更符合临床实践中常见的解剖位置和形态。本研究选择25张CT图像和100个金属掩膜模拟2 500张金属伪影图像。在模拟金属伪影时, 考虑金属物体会对CT扫描的图像产生的多种影响, 包括多能量X射线效应、部分容积效应、光束硬化和泊松噪声, 所有数据在输入网络前都已被标准化到0~1。

(2) 真实数据: 本研究采用头颈部区域带有金属伪影的口腔轴向CT切片图像进行真实数据实验测试。

2.2 评价方法

为评估金属伪影仿真数据集的质量, 采用峰值信噪比(Peak Signal to Noise Ratio, PSNR)和结构相似性指数(Structural Similarity Index, SSIM)作为主要的评估指标。

PSNR是信号最大功率与信号噪声功率之比, 主要用于定量评估图像重建质量, 通过比较原始图像和重建图像之间的均方误差来衡量图像的保真度, 其定义为:

$$\text{PSNR} = 10 \cdot \log_{10} \frac{\text{MAX}_I^2}{\text{MSE}} \quad (15)$$

其中, MAX_I 表示图像中可能的最大像素值, 而MSE为干净图像I和噪声图像K的均方误差。PSNR值越高, 表明重建图像与原始图像的相似度越高, 即噪声干扰越小。

SSIM是一种衡量两幅图像相似度的指标, 用于评估图像质量或图像的保真度, 主要考虑了人类视觉系统对图像质量的感知, 尤其是亮度、对比度和结构等方面的变化, 因此被认为相较传统的像素差值(如均方误差)更符合人类对图像质量的主观感受, 其定义为:

$$\text{SSIM}(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (16)$$

其中, μ_x 和 μ_y 分别是x和y的平均值, σ_x^2 和 σ_y^2 分别为图像的方差, σ_{xy} 为图像之间的协方差。

2.3 实验结果

本研究将提出的方法与几种流行的金属伪影校

正方法进行对比分析, 主要有LI^[26]方法和NMAR^[16]方法以及伪影解耦网络(Artifact Disentanglement Network, ADN)^[27], 除上述的对比实验方法, 还采用一种不依赖模板先验图像作为条件, 通过扩散模型进行金属伪影校正的对比方法。

2.3.1 仿真数据结果 图4~6显示了不同方法在仿真金属伪影CT上的应用效果。利用红色标签作为掩膜标记金属位置, 虚线红框则标示了一个重点观察的区域。为便于比较, 所有图像的显示范围统一设置为[800 HU, 1500 HU]。

当金属植入物为单个时(图4), 生成的伪影多为局部伪影, 主要表现在金属物体附近有暗带区域以及交替出现的明暗条形伪影。LI方法和NMAR方法可以填补暗带区域, 校正大部分金属伪影, 然而, 由于金属植入物与相邻骨骼组织的特性相近, 这两种方法受到干扰, 从而产生二次条形伪影。在图4的例2中, 当金属在骨骼附近位置时, LI方法和NMAR方法都不能恢复骨骼结构, 导致图像的SSIM和PSNR较低, 影响图像质量, 进而影响对图像内容的准确判断。ADN方法在应对图4中的金属植入物时表现出一定的局限性, 尽管该方法能部分缓解伪影的影响, 但在金属区域的伪影去除和结构恢复方面表现不足, 校正后的图像边缘仍残留些许伪影, 甚至在某些情况下生成新的伪结构。

当金属植入物为两个较小的金属时(图5), 由于两个金属互相影响, 金属周围的条形伪影和黑影现象变得更明显, 大幅降低CT图像的质量。这些伪影干扰了金属周围骨骼或软组织结构的判断。LI方法和NMAR方法通过有效补全丢失数据, 减少大部分条形伪影, 但也因为填补数据的不一致性产生新的伪影; 尽管ADN方法校正效果较好, 但是从放大的局部图可以看出仍有部分伪影没有完全消除。

图6显示了不同方法对两个较大金属植入物进行校正的结果, 两个较大的金属导致显著的暗带区域, 增加恢复图像的难度。LI方法由于直接替换受伪影影响的像素值, 导致新的伪影的产生; NMAR方法通过更精确的非线性处理, 效果优于LI方法, 但仍存在伪影问题, 而且无法恢复金属植入物周围结构; ADN方法在恢复金属周围结构上表现出明显优势, 尤其是对于复杂伪影, 但由于金属较大, 暗带区域的恢复仍存在不足, 校正后残留的暗带痕迹依然可见。相比之下, 扩散模型算法有效校正了大部分金属伪影, 虽然一般的扩散模型算法对单个或者多个金属植入物破坏的CT图像有较好的校正结果, 但也存在明显的二次伪影, 且无法很好地恢复金属伪影附近的骨骼结构。本文方法利用条件图像约束恢复过

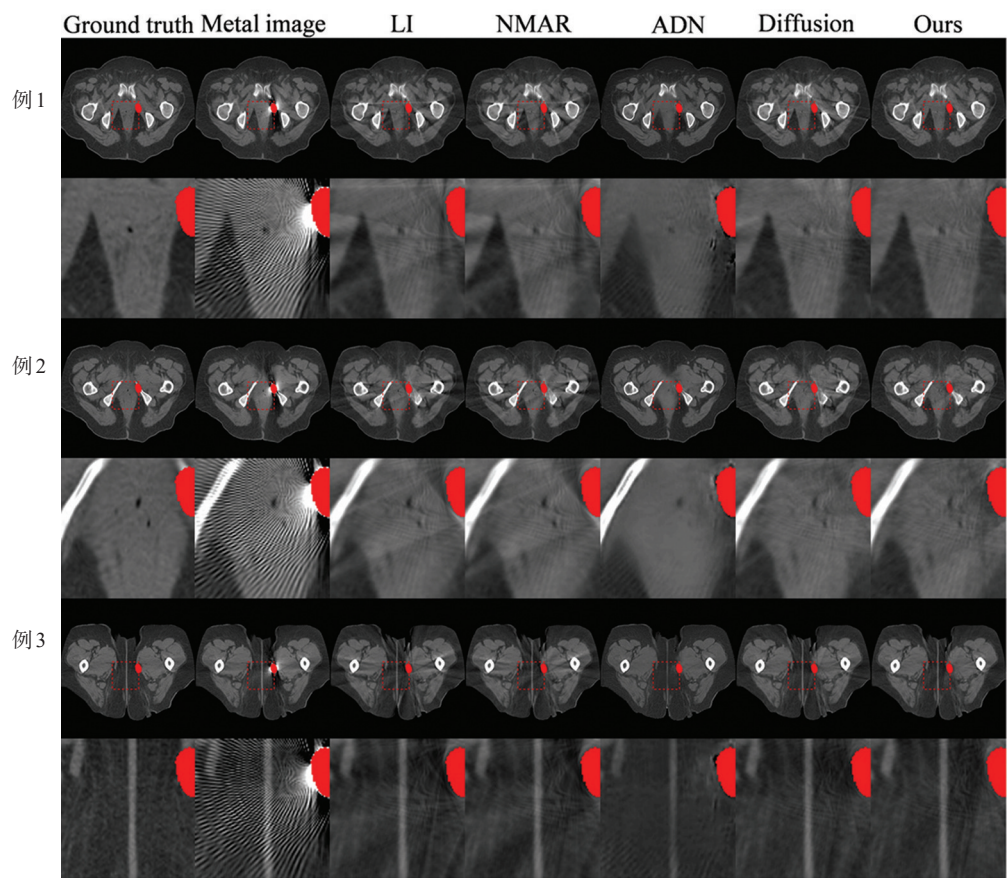


图4 校正金属伪影方法结果对比(单个金属)
Figure 4 Comparison of metal artifact reduction results for a single metal

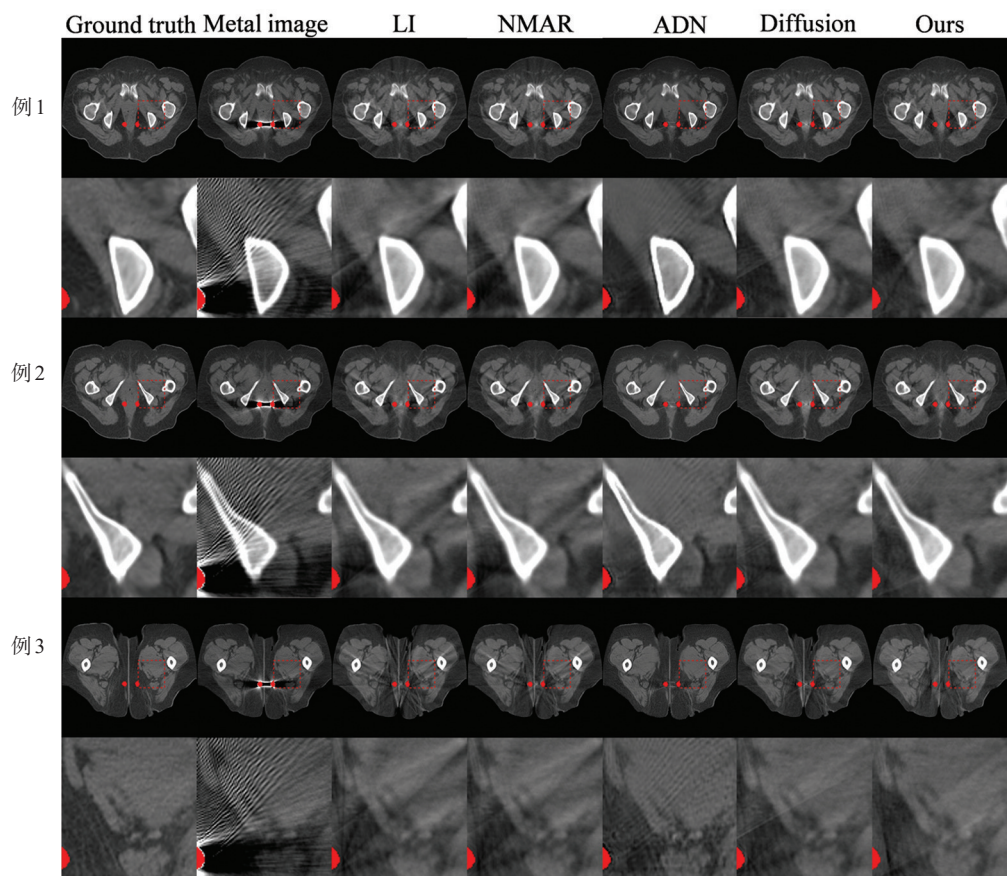


图5 校正金属伪影方法结果对比(两个较小金属)
Figure 5 Comparison of metal artifact reduction results for two small metals

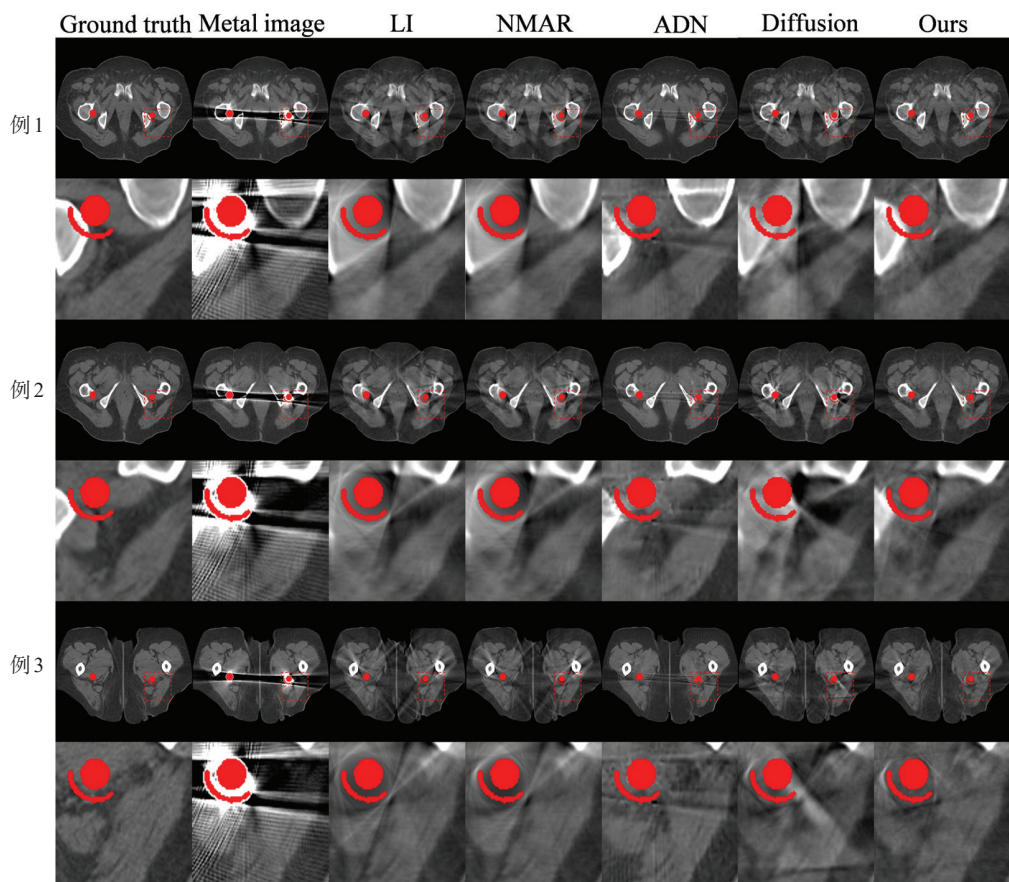


图6 校正金属伪影方法结果对比(两个较大金属)
Figure 6 Comparison of metal artifact reduction results for two large metals

程,相比一般扩散模型算法进一步提高恢复效果。从图4~6中可以明显观察到,本文方法可以更自然地恢复金属植入物周围的组织结构,提高图像质量,与原始图像更接近。

表1列出不同方法的评价指标,根据金属植入物的尺寸,测试数据被分成4组,尺寸大小分别是1 113、542、371、29,并计算每组的平均值。与金属伪影仿真图像相比,传统的校正金属伪影算法在SSIM和PSNR方面均有一定程度的提升。然而,LI方法和NMAR方法的评价指标虽然有所改善,但校正后仍

会产生二次伪影,影响图像质量。这些方法在处理小型金属植入物时表现较好,但随着金属植入物的增大,特别是其靠近骨骼的情况下,效果明显下降。ADN方法在校正伪影方面优于传统方法,但在一些情况下仍无法完全消除伪影,甚至可能引入新的伪影。相较于上述方法,本文方法与ADN方法相比PSNR提高3.44 dB,SSIM提高0.079,与扩散模型相比PSNR提高了0.749 dB,SSIM提高了0.015,图像质量评估指标的显著提升验证了本文方法的优越性。

表1 不同方法在仿真数据集上的PSNR/SSIM
Table 1 PSNR/SSIM of different methods on simulation dataset

方法	尺寸大小				平均值
	1 113	542	371	29	
金属伪影图像	11.123 dB/0.394	11.123 dB/0.396	11.040 dB/0.408	10.970 dB/0.380	11.064 dB/0.395
LI方法	24.646 dB/0.707	24.226 dB/0.714	25.185 dB/0.743	25.282 dB/0.746	24.835 dB/0.728
NMAR方法	25.476 dB/0.727	25.601 dB/0.744	25.826 dB/0.794	25.799 dB/0.760	25.676 dB/0.756
ADN方法	31.830 dB/0.824	33.480 dB/0.876	31.208 dB/0.946	33.766 dB/0.891	32.571 dB/0.884
扩散模型	32.751 dB/0.895	35.516 dB/0.967	35.829 dB/0.973	36.950 dB/0.959	35.262 dB/0.948
本文方法	34.797 dB/0.938	36.264 dB/0.980	35.941 dB/0.974	37.042 dB/0.961	36.011 dB/0.963

2.3.2 真实数据实验 图7展示了不同金属伪影校正方法在口腔CT切片上的应用效果。该数据中,牙齿填充物的存在引发明显的金属伪影,特别是在金属区域周围,而远离金属的区域结构则表现良好。LI方法和NMAR方法对该数据的金属伪影校正方面表现良好,但由于它们是在投影域上进行处理,数据的不连续性引入二次伪影。相较之下,ADN方法可能因为训练过程中所使用的数据与真实数据差异较

大,导致在该数据中的校正效果较差;扩散模型虽然在金属伪影的校正上有一定效果,但其结果同样引入新的伪影,影响图像的整体质量。本文方法显著改进校正结果,尤其是在填充物周围区域结构的恢复上,表现尤为突出。通过视觉效果的对比,本文方法在所有评估的算法中均展现良好的表现,充分证明其在临床应用中的潜在价值。

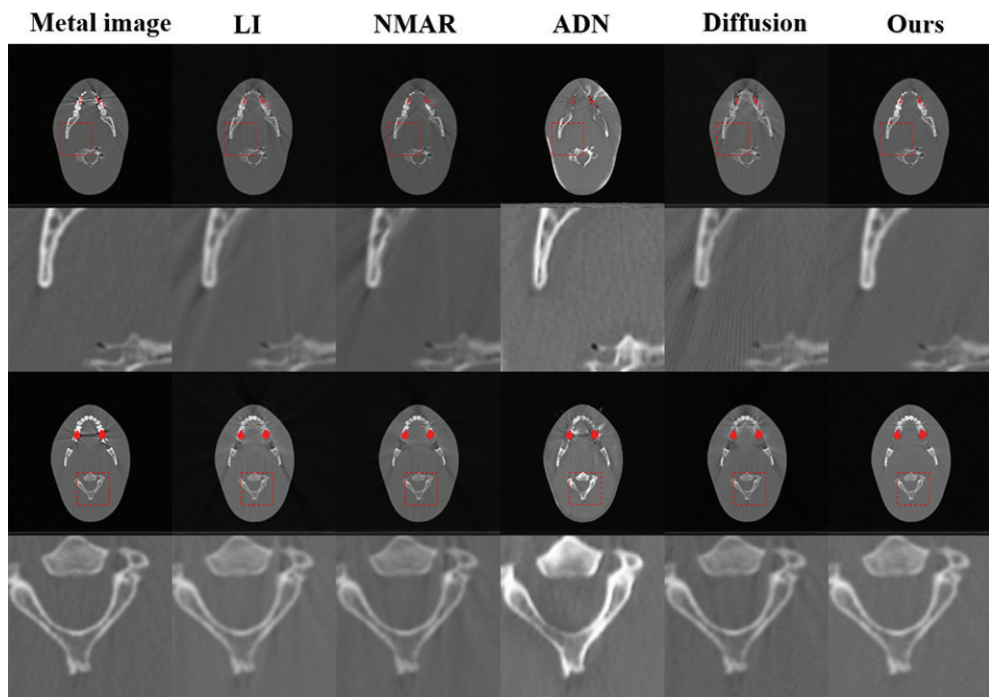


图7 校正真实数据金属伪影方法结果对比
Figure 7 Comparison of metal artifact reduction results for real data

3 讨论

为提高CT扫描图像的质量,提出多种金属伪影校正方法。弦图修补法作为最常用的金属伪影校正技术之一,通过将受到金属破坏的投影数据缺失问题转换为图像修复问题,在投影域中对受影响的数据区域进行插值,生成新的数据,从而校正伪影并恢复图像信息。然而,由于生成的新弦图域数据的非连续性,修补过程中可能引入二次伪影,影响校正效果。因此,尽管弦图修补法在校正部分伪影上有效,但其固有的局限性依然存在。

针对金属伪影校正问题,本研究提出一种基于模板先验的条件扩散模型,利用扩散模型逐步将简单分布(如高斯噪声)转换为目标图像分布,以捕捉图像的复杂结构,从而在去噪过程中有效地恢复图像的真实细节。通过使用金属伪影掩膜和分类模板对扩散模型进行条件约束,克服传统扩散模型对神

经网络噪声预测的过度依赖,实现更精确的伪影校正。在实验结果中,校正后的图像质量显著提升,伪影得到有效处理,同时保留正常的组织结构。本文方法为CT图像中金属伪影的校正提供一种更为有效和稳定的解决方案,在保持图像细节的同时能校正伪影,为未来的相关研究和应用提供新的思路和方法。

【参考文献】

[1] Gjestebj L, De Man B, Jin YN, et al. Metal artifact reduction in CT: where are we after four decades?[J]. IEEE Access, 2016, 4: 5826-5849.

[2] Layer YC, Mesropyan N, Kupczyk PA, et al. Combining iterative metal artifact reduction and virtual monoenergetic images severely reduces hip prosthesis-associated artifacts in photon-counting detector CT[J]. Sci Rep, 2023, 13(1): 8955.

[3] Aissa J, Thomas C, Sawicki LM, et al. Iterative metal artefact reduction in CT: can dedicated algorithms improve image quality after spinal instrumentation?[J]. Clin Radiol, 2017, 72(5): 428.e7-428.e12.

- [4] Schmidt AM, Grunz JP, Petritsch B, et al. Combination of iterative metal artifact reduction and virtual monoenergetic reconstruction using split-filter dual-energy CT in patients with dental artifact on head and neck CT[J]. *AJR Am J Roentgenol*, 2022, 218(4): 716-727.
- [5] Mohammadinejad P, Baffour FI, Adkins MC, et al. Benefits of iterative metal artifact reduction and dual-energy CT towards mitigating artifact in the setting of total shoulder prostheses[J]. *Skeletal Radiol*, 2021, 50(1): 51-58.
- [6] Queiroz PM, Groppo FC, Oliveira ML, et al. Evaluation of the efficacy of a metal artifact reduction algorithm in different cone beam computed tomography scanning parameters[J]. *Oral Surg Oral Med Oral Pathol Oral Radiol*, 2017, 123(6): 729-734.
- [7] Tang H, Lin YB, Sun GY, et al. A metal artifact reduction scheme in CT by a Poisson fusion sinogram based postprocessing method [J]. *J Xray Sci Technol*, 2021, 29(2): 245-257.
- [8] Hegazy MA, Cho MH, Cho MH, et al. Metal artifact reduction in dental CBCT images using direct sinogram correction combined with metal path-length weighting[J]. *Sensors (Basel)*, 2023, 23(3): 1288.
- [9] Bannas P, Li YS, Motosugi U, et al. Prior image constrained compressed sensing metal artifact reduction (PICCS-MAR): 2D and 3D image quality improvement with hip prostheses at CT colonography[J]. *Eur Radiol*, 2016, 26(7): 2039-2046.
- [10] Kim J, Nam H, Lee R. Development of a new metal artifact reduction algorithm by using an edge preserving method for CBCT imaging[J]. *J Korean Phys Soc*, 2015, 67(1): 180-188.
- [11] Benammar A, Allag A, Araar IE, et al. Metal artifact reduction in CT images through sinogram data inpainting[J]. *Eurasia Proc Sci Technol Eng Math*, 2023, 26: 770-779.
- [12] Zeng GL. Neural network guided sinogram-domain iterative algorithm for artifact reduction[J]. *Med Phys*, 2023, 50(9): 5410-5420.
- [13] An ZC, Zhu XM, Fu XL, et al. An iterative sinogram metal artifact reduction based on UNet[C]//2023 IEEE International Conference on Big Data (BigData). Piscataway, NJ, USA: IEEE, 2023: 2518-2522.
- [14] Deng SW, Li YJ, Wang DH. Streak metal artifact reduction based on sinogram fusion and tissue-class model in CT images[J]. *Wirel Commun Mob Comput*, 2022, 2022(1): 8021862.
- [15] Gjestebj L, Yang QS, Xi Y, et al. Deep learning methods to guide CT image reconstruction and reduce metal artifacts[C]//Medical Imaging 2017: Physics of Medical Imaging. Bellingham, WA, USA: SPIE, 2017: 101322W.
- [16] Meyer E, Raupach R, Lell M, et al. Normalized metal artifact reduction (NMAR) in computed tomography[J]. *Med Phys*, 2010, 37(10): 5482-5493.
- [17] Park HS, Chung YE, Lee SM, et al. Sinogram-consistency learning in CT for metal artifact reduction[EB/OL]. (2017-08-02)[2024-05-19]. <https://arxiv.org/abs/1708.00607v1>.
- [18] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation[C]//Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015. Cham: Springer International Publishing, 2015: 234-241.
- [19] Wang JN, Zhao YY, Noble JH, et al. Conditional generative adversarial networks for metal artifact reduction in CT images of the ear[C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2018. Cham: Springer International Publishing, 2018, 11070: 3-11.
- [20] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[J]. *Commun ACM*, 2020, 63(11): 139-144.
- [21] Zhang YB, Yu HY. Convolutional neural network based metal artifact reduction in X-ray computed tomography[J]. *IEEE Trans Med Imaging*, 2018, 37(6): 1370-1381.
- [22] Zhu YL, Zhao HQ, Wang TS, et al. Sinogram domain metal artifact correction of CT via deep learning[J]. *Comput Biol Med*, 2023, 155: 106710.
- [23] Lin WA, Liao HF, Peng C, et al. DuDoNet: dual domain network for CT metal artifact reduction[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2019: 10504-10513.
- [24] Saharia C, Chan W, Chang HW, et al. Palette: image-to-image diffusion models[C]//ACM SIGGRAPH 2022 Conference Proceedings. New York, NY, USA: ACM, 2022: 15.
- [25] Jeon H, Park D, Youn H, et al. Generation of hybrid sinograms for the recovery of kV-CT images with metal artifacts for helical tomotherapy[J]. *Med Phys*, 2015, 42(8): 4654-4667.
- [26] Kalender WA, Hebel R, Ebersberger J. Reduction of CT artifacts caused by metallic implants[J]. *Radiology*, 1987, 164(2): 576-577.
- [27] Liao HF, Lin WA, Zhou SK, et al. ADN: artifact disentanglement network for unsupervised metal artifact reduction[J]. *IEEE Trans Med Imaging*, 2020, 39(3): 634-643.

(编辑:谭斯允)