

稀疏 Transformer 联合细节还原网络的 CT 金属伪影去除算法

任亚利^{1,2}, 刘 祎^{1,2}, 桂志国^{1,2}, 张鹏程^{1,2}

(1. 中北大学 信息与通信工程学院, 太原 030051;

2. 生物医学成像与影像大数据山西重点实验室, 太原 030051)

摘要: 在 CT 成像中, 若病人体内存在金属植入物时, CT 重建图像中会出现严重的金属伪影, 降低图像质量并影响医生诊断结果; 对现有金属伪影去除算法进行了研究, 分析了简单的神经网络模型去除金属伪影时存在伪影残留及组织细节模糊的问题, 提出了稀疏 Transformer 联合细节还原网络; 该网络由伪影去除网络和细节还原网络两个独立的子网络构成, 伪影去除网络将标准 Transformer 中的自注意力替换为稀疏注意力机制, 并且引入混合尺度前馈网络提取多尺度信息, 以产生更好的图像去噪特征; 细节还原网络同时提取全局和局部信息, 在不损失图像分辨率的前提下清晰地恢复原始图像细节, 然后通过加法运算将其整合到上述去除伪影的图像中; 在 Deeplesion 数据集上验证了模型的有效性, 实验结果表明, 该方法在金属伪影去除效果上优于目前已有方法, 在 PSNR、SSIM 指标上表现更优, 能有效去除金属伪影, 恢复出大部分精细的结构细节。

关键词: CT 图像; 金属伪影; 稀疏 Transformer; 注意力机制; 细节还原

CT Metal Artifact Reduction for Restoration Network Sparse Transformer Joint with Details

REN Yali^{1,2}, LIU Yi^{1,2}, GUI Zhiguo^{1,2}, ZHANG Pengcheng^{1,2}

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

2. State Key Laboratory of Dynamic Testing Technology, North University of China, Taiyuan 030051, China)

Abstract: In CT imaging, if there is a metal implant in the patient's body, it will appear serious metal artifact in CT reconstruction images, reducing the image quality and affecting the doctor's diagnosis. This paper studies existing metal artifact reduction methods, analyzes artifact residue and fuzzy organizational details with a simple neural network model removing metal artifacts. A joint sparse Transformer and detail restoration network is proposed, which consists of two independent sub networks: artifact removal network and detail restoration network. The artifact removal network replaces the self-attention mechanism in standard Transformer with the sparse attention mechanism, the mixed-scale feed-forward network is introduced to extract multi-scale information, achieving better image denoising features. Additionally, the detail restoration network extracts both global and local information to clearly recovers the original image details without losing image resolution, and then integrate the detail feature map into the above artifact reduction image through addition operation. The effectiveness of the model is verified on the Deeplesion dataset. Experimental results show that the proposed method outperforms the existing network models in metal artifact reduction, showing superior performance in peak signal to noise ratio (PSNR) and structural similarity index measure (SSIM) metrics, which can effectively remove metal artifacts and recover most of fine structural details.

Keywords: CT images; metal artifact; sparse Transformer; attention mechanism; detail restoration

收稿日期:2024-10-21; 修回日期:2024-12-12。

基金项目:山西省基础研究计划项目(202303021211148);山西省专利转化专项计划项目(202302006)。

作者简介:任亚利(1999-),女,硕士。

通讯作者:桂志国(1972-),男,博士,教授。

引用格式:任亚利,刘 祎,桂志国,等.稀疏 Transformer 联合细节还原网络的 CT 金属伪影去除算法[J].计算机测量与控制, 2025,33(3):197-203,212.

0 引言

计算机断层扫描 (CT, Computed Tomography) 利用 X 射线和计算机技术, 通过旋转的 X 射线发射器和探测器, 从多个角度扫描人体。计算机将这些扫描数据重建成断层图像 (横截面图像), 提供比单一方向的 X 射线更详细的内部结构信息^[1]。因此 CT 能够提供更高分辨率的图像, 可以清晰地显示不同组织的密度差异, 提高病变的检出率和诊断的准确率。然而在成像过程中, 患者体内金属植入物 (如存在金属填充物的牙齿、带有假肢的关节等) 对 X 射线光谱不同能量层的衰减系数的剧烈变化会使投影数据出现异常^[2], 导致重建的 CT 图像中出现明显的放射状或条纹状暗金属伪影^[3]。金属伪影会降低 CT 图像的视觉质量, 影响后续诊断结果的准确性^[4]。因此金属伪影去除任务越来越受到学术界的关注, 金属伪影去除算法的研究对恢复原始图像内容信息、提高临床诊断的准确性具有重要意义。

针对这个不适定逆问题, 国内外学者在金属伪影去除 (MAR, metal artifact reduction) 算法的研究方面^[5-8]广泛探索并取得了一定的成果。目前金属伪影去除算法主要分为传统方法和基于深度学习的校正方法两大类。传统方法中, 物理效应校正旨在^[9]对形成金属伪影的物理效应进行建模以对其直接纠正, 包括光束硬化等, 然而在高原子序数金属存在的情况下很难达到令人满意的性能^[10], 需同其他方法结合; 投影域插值^[11-12]将正弦图中受金属影响的区域视为缺失并采用不同的插值策略如线性插值、二维插值、多项式插值以及归一化标准技术等进行填补, 该方法简单快速且易实现, 但由于正弦图中填补后的值与未受影响的值不一致, 边缘可能存在不连续性, 导致重建图像出现二次伪影; 迭代重建法^[13-14]利用手工制作的正则器从未受影响的正弦图或加权/校正的正弦图中逐步恢复 CT 图像, 但手工制作的正则器通常很难适应复杂多样的伪影, 而且迭代算法步骤复杂耗时, 其临床实用性受到限制。由于各种金属材料、尺寸、位置等的高度复杂性, 使用单一的 MAR 算法很难在所有情况下获得令人满意的效果, 因此一些研究人员将两种或 3 种研究方法混合, 融合各种 MAR 方法的优点进行金属伪影去除。

近年来, 在深度学习在医学图像重建和分析方面取得重大成功的推动下, 出现了很多基于深度学习去除金属伪影的方法^[15-17]并取得了不错的效果。卷积神经网络 (CNN, convolutional neural network) 具有强大的图像特征提取能力^[18], 文献 [19] 首次将基于 CNN 的深度学习方法应用到金属伪影去除中, 该研究将 CNN 与传统的归一化金属伪影校正算法 (NMAR, normalized MAR) 相结合, 利用 CNN 网络将金属伪影影响的图像

映射到无伪影图像, 以便在 NMAR 之上实现额外的校正, 从而进一步提高图像质量。结果表明深度学习是实现 CT 图像金属伪影去除的新工具。基于深度学习的校正方法根据学习方式可以分为三类: 监督、无监督和半监督。监督方法大多采用合成的金属伪影来模拟图像对。文献 [20] 提出了基于 CNN 的开放式 MAR 框架 (CNNMAR, convolutional neural network based MAR), 将 CNN 视为一种信息融合工具, 在训练过程中捕获来自不同校正方法的信息并融合这些方法的优点, 最终生成一张伪影减少的高质量图像。文献 [21] 提出了双域 MAR 网络 (DuDoNet, dual domain network), 该网络首次通过在双域中学习两个 CNN 来同时恢复正弦图和 CT 图像, 结果表明相较于仅在正弦图域或图像域某个单一域中去除金属伪影, 采用双域联合的方式能够取得更好的效果。此后, 许多学者开始致力于无监督方法的研究, 解决了 MAR 监督方法中需要配对数据的问题。文献 [22] 从无监督角度出发提出了具有专门编码器和解码器的伪影解耦网络 (ADN, artifact disentanglement network), 这些编码器和解码器分别处理非配对输入的伪影和内容分量的编码和解码。该研究将伪影去除问题重新表述为伪影解耦问题, 通过在潜在空间中解开这两个分量实现伪影与组织细节的解耦, 并且通过重建没有伪影分量的 CT 图像实现伪影去除。文献 [23] 提出了注意力引导的 β -CycleGAN 网络, 利用 CycleGAN 作为无监督金属伪影去除的可解释网络主干, 通过引入一个超参数 β 来控制特征解纠缠的水平, 同时纳入注意力机制, 通过关注伪影存在的位置及出现的方式来提高网络的表示能力。半监督方法混合了监督和无监督两种方法的优点。文献 [24] 提出了半监督 MAR 网络 (SemiMAR, semi-supervised learning for CT MAR), 它侧重于学习图像中干净的部分, 通过从包含金属伪影的原图中减去干净的部分得到伪影, 从而减轻使用多个编码器和解码器来解耦伪影的需求, 同时, 该方法利用单个生成器执行所有复杂的转换, 从而减小模型规模并防止干净部分和伪影之间的重叠。基于深度学习的金属伪影去除算法已被广泛研究, 但现有模型所使用的神经网络仍存在不足, 如 CNN 只能对局部特征进行提取, 难以捕捉长期依赖关系, 其对全局语义信息的捕捉能力相对较弱; 生成对抗网络 (GAN, generative adversarial networks) 易出现训练不稳定、模型不可控的情况等。

Transformer 模型因其并行计算能力强、可以捕捉序列中不同位置的依赖关系、可扩展性好等优势已经席卷了许多计算机视觉任务。Transformer 模型已经被应用于金属伪影去除并取得了不错的效果, 但也存在一些固有的问题, 即对于局部上下文的捕捉能力较弱, 它缺

乏保留局部特征细节的能力。针对现有基于 Transformer 的 CT 金属伪影去除方法中重建图像局部细节清晰度较低的问题, 本文采用稀疏 Transformer 联合细节还原网络的方法进行金属伪影去除。整体模型包含两个独立的子网络, 伪影去除网络对标准 Transformer 模型进行调整以充分利用局部特征, 改进后的模型可以帮助网络更好地关注图像中最有用的特征信息, 从而改善去伪影效果; 同时引入一个单独的细节还原网络, 将输出的细节特征图融合到上述去除伪影后的图像中, 得到最终高质量的输出图像。

1 Transformer 模型及扩张卷积

1.1 Transformer 模型

Transformer^[25] 是自然语言处理领域中一种主要用于处理序列数据的神经网络模型, 旨在解决传统神经网络模型难以并行计算及难以捕捉长距离依赖关系的问题。Transformer 模型基于编码器-解码器框架, 其核心是自注意力机制 (self-attention), 其计算公式如公式 (1) 所示:

$$Attention(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\lambda}\right)V \quad (1)$$

通过 3 个权重矩阵将输入序列中所有词向量转变为计算 Attention 值所需要的 Q 、 K 、 V 向量矩阵, 自注意力允许模型在编码和解码过程中使用点积法为每个单词计算其与序列中所有单词的相关性, 并基于这些相关性加权聚合信息, 所得到的相关性得分为矩阵形式, 其作用是对得分矩阵进行归一化以保持训练时梯度稳定, softmax 函数将得分矩阵转换成值在 $[0, 1]$ 之间的概率分布矩阵再与 V 相乘。这种密集计算模式使得较小的相似权重也会被放大并参与到特征交互和聚合过程中, 导致某些噪声信号也被考虑进去, 因此可以考虑使用更有选择性的注意力机制以关注金属伪影存在的位置, 从而减少冗余和伪影影响。

1.2 扩张卷积

在医学图像处理领域, 对图像细节的保真度以及生成图像的可信度要求很高。现有的 MAR 方法大多只致力于去除伪影, 而忽略了细节的恢复, 原始图像信息在伪影去除过程中丢失。

文献 [26] 在细节还原过程中考虑通过扩张卷积获取更多的全局特征, 扩张卷积又称为空洞卷积, 通过在标准的卷积核中注入空洞来增加模型的感受野, 它不损失图像的分辨率和覆盖范围, 同时也不增加参数量或计算复杂度, 但在扩张率大于 1 的情况下, 由于扩张卷积特性会导致输出特征图上的相邻单元是由输入特征图上非连续区域计算得到的, 即所谓的“网格伪影”, 这种现象在需要保持局部空间连续性较高的任务中会对模型性能产生影响。因此可以考虑在扩张卷积之前插入可分

离共享卷积以对扩张卷积进行平滑处理, 大大减少“网格伪影”所带来的影响。

2 金属伪影去除算法设计

本文提出了一种有效的稀疏 Transformer 金属伪影去除网络 (STNMAR, sparse transformer network MAR), 该网络框架的关键组成部分是稀疏 Transformer 块 (STM, sparse transformer module), 在伪影分布揭示侵蚀位置和程度的基础上, 将 STM 考虑为保留最相关的相关性得分用于特征聚合的 top-k 稀疏选择算子 (TSSO, top-k sparse select operator) 和探索多尺度特征以更好地去除金属伪影的混合尺度前馈网络 (MSFN, mixed-scale feed-forward network)。

同时, 本文提出了包含全局和局部双分支的细节还原网络 (IDRN, independent detail restoration network), 该网络不依赖于伪影去除网络主干, 以一幅包含金属伪影的图像作为输入, 输出细节特征图, 然后将其与经 STNMAR 去除金属伪影的图像融合, 最终输出高质量的图像。具体来说, 全局分支考虑通过平滑扩张卷积模块 (SDCM, smoothed dilated convolution module) 消除扩张卷积带来的影响以实现全局特征提取, 局部分支仅通过一个卷积层关注局部细节, 并合并到全局分支中。

如图 1 所示, 整个金属伪影去除模型主体由 STNMAR 和 IDRN 构成, 将两个子网络的输出相加得到最终的金属伪影去除图像。

2.1 伪影去除网络

STNMAR 是基于编码器-解码器结构的, 给定一张包含金属伪影的图像, 首先通过 3×3 卷积实现重叠图像块嵌入以确保图像所有部分都被充分考虑并以更利于后续计算的形式表达。网络以 STM 作为基本单元以提取丰富的金属伪影分布特征。为了挖掘多尺度表示, 每一层编码器-解码器有它自己特定的空间分辨率和通道维度。在每个 STM 中, 与标准 Transformer 模型中的自注意不同, 本文通过 TSSO 来实现特征稀疏性, 通过一个可学习的 top-k 选择算子自适应地保留最重要的得分以更好地进行特征聚合。同时, 由于标准 Transformer 模型中的前馈网络没有对对潜在清晰图像恢复重要的多尺度信息建模, 本文在 STM 中引入 MSFN 来更好地捕捉和利用多尺度信息。

给定第 $(l-1)$ 个块 X_{l-1} 的输入特征, 利用提出的 STM 作为特征提取单元, STM 的编码过程可以定义为:

$$X_{(l-1)}^* = X_{(l-1)} + \text{TSSO}[\text{LN}[X_{(l-1)}]] \quad (2)$$

$$X_l = X_{(l-1)}^* + \text{MSFN}\{\text{LN}[X_{(l-1)}^*]\} \quad (3)$$

如图 2 所示, 对于 TSSO, 首先采用 1×1 卷积编码上下文信息, 紧接着采用 3×3 深度卷积操作提取更深

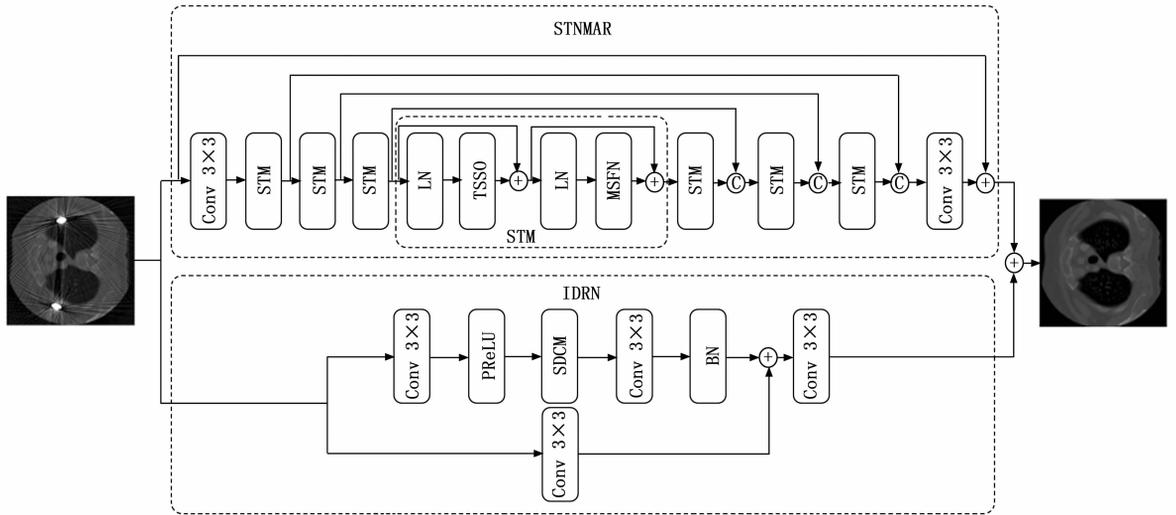


图 1 金属伪影去除算法模型

层次的特征并降低计算复杂度。接下来我们计算所有重构的 Q 和 K 之间像素对的相似性，生成一个相似性得分矩阵，即注意力矩阵 M ，并在 M 中忽略或削弱那些较低权重的键 K 的影响， M 通过计算得到。与标准 Transformer 模型中运用 dropout 随机丢弃的方式不同，本文在注意力矩阵 M 上实施了一种通过 top-k 筛选的自适应选择策略，具体而言，对于每个 Q ，该方法仅保留了其在 M 中对应的前 k 个最大贡献的 K 元素， k 是一个可调节的参数，用于动态控制稀疏性。保留下来的 top-k 注意力得分，我们通过 softmax 函数进行归一化处理，对于未被选入 top-k 得分的其他元素，我们使用

scatter 函数在给定索引处将其概率替换为 0，这种动态选择使注意力从密集到稀疏：

$$\text{SparseAttention}(Q, K, V) = \text{softmax}\left[T_k\left(\frac{QK^T}{\lambda}\right)\right]V \quad (4)$$

式 (4) 中表示可学习的 top-k 选择算子：

$$[T_k(\cdot)]_{ij} = \begin{cases} S_{ij}, S_{ij} \geq t_i \\ 0, \text{otherwise} \end{cases} \quad (5)$$

式 (5) 中 t_i 是 $\frac{QK^T}{\lambda}$ 的第 j 行中第 k 个大的值。

如图 3 所示，本文通过在传输过程中插入两个多尺度深度卷积路径来设计 MSFN。给定一个输入 X_{l-1} ，先对输入数据执行层归一化操作 (LN, layer normalization)，用于调整输入数据的分布，使其更适合后续的网络处理。接下来应用 1×1 卷积扩展通道维度，然后将其送入两个平行分支， 3×3 和 5×5 深度卷积用来增强多尺度局部信息提取。ReLU 激活函数是一种常见的非线性激活函数，通过该函数引入非线性特性，使得网络能够拟合更复杂的函数关系。最后将来自这两条路径的不同尺度的特征融合并通过一个卷积层输出结果。因此 MSFN 的整个特征融合过程表示为：

$$X_{l-1}^1 = \sigma\{f_{\text{DepthwiseConv}3 \times 3} f_{\text{Conv}1 \times 1} [\text{LN}(X_{l-1})]\} \quad (6)$$

$$X_{l-1}^2 = \sigma\{f_{\text{DepthwiseConv}5 \times 5} f_{\text{Conv}1 \times 1} [\text{LN}(X_{l-1})]\} \quad (7)$$

$$X_{l-1}^{12} = \sigma[f_{\text{DepthwiseConv}3 \times 3}(X_{l-1}^1, X_{l-1}^2)]JY \quad (8)$$

$$X_{l-1}^{21} = \sigma[f_{\text{DepthwiseConv}5 \times 5}(X_{l-1}^2, X_{l-1}^1)]JY \quad (9)$$

$$X_l = f_{\text{Conv}1 \times 1} + f_{\text{Conv}1 \times 1}(X_{l-1}^{12}, X_{l-1}^{21}) \quad (10)$$

2.2 细节还原网络

IDRN 将包含金属伪影的图像分别送入全局和局部两个分支，将两个分支输出的互补特征信息合并，生成最终的详细特征图。

全局分支首先通过 3×3 卷积调整通道数，然后利

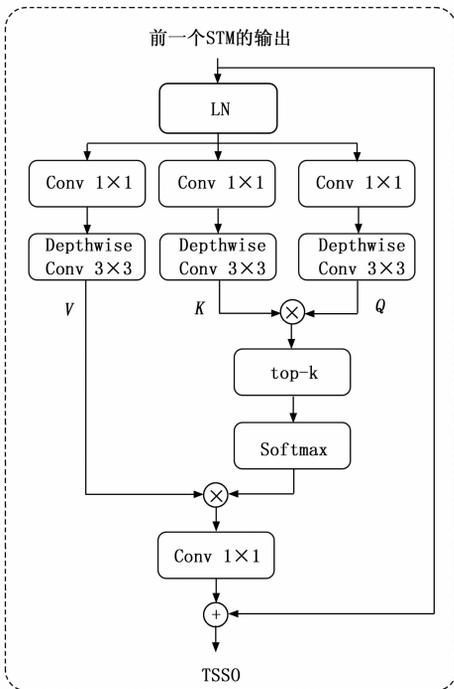


图 2 TSSO 结构

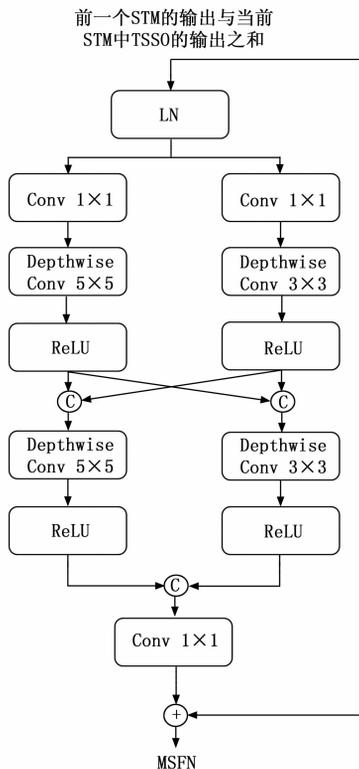


图 3 MSFN 结构

用 SDCM 实现无图像分辨率损失的全局特征提取。如图 4 所示, 该模块由 3 个并行的不同扩张率的平滑扩张卷积层组成, 此处扩张率分别设置为 1、3、5, 平滑扩张卷积层考虑在扩张卷积前使用可分离共享卷积, 为输入特征图中的每个单元更好地整合邻域信息, 弥补扩张卷积因较大扩张率造成的局部连续性损失, 从而减轻网格伪影的影响, 而后将这些层获得的中间特征图通过 concatenate 操作连接起来, 并通过 1×1 卷积实现通道数的减少。

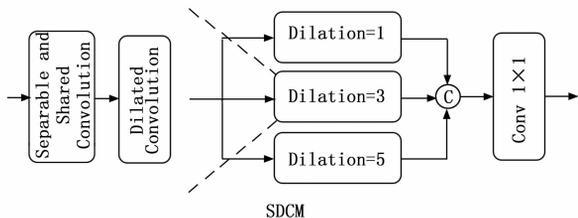


图 4 SDCM 结构

由于随着网络的加深会有信息损失, 并且考虑到深度卷积通常有较大的感受野, 不能关注局部细节, 所以本文构建了仅使用一个 3×3 卷积的局部分支。通过加法操作将局部特征信息合并到全局分支中, 使局部细节得到更好的补充, 随后通过 3×3 卷积层进行进一步的通道调整和信息融合, 得到最终的输出特征图。

2.3 损失函数

图像最终重建结果为:

$$I_{\text{final}} = \text{STNMAR}(I_{\text{origin}}) + \text{IDRN}(I_{\text{origin}}) \quad (11)$$

$L1$ 损失函数直接衡量生成图像与目标图像之间的像素级差异, 使它们的误差在学习过程中最小化, 并且使模型更易收敛。 $L1$ 范数损失函数定义为生成图像与目标图像之间差值的绝对值:

$$L = \sum_{i=1}^n \| I_{\text{final}} - I_{\text{gt}} \|_1 \quad (12)$$

式中, n 为训练样本的数量, I_{gt} 为目标图像。 $L1$ 范数损失函数可以约束生成图像和目标图像之间的相关性, 通过最小化该损失函数进行训练, 使得生成图像更接近于目标图像。 $L1$ 损失函数对于离群点造成的惩罚是固定的, 对异常离群点有更好的鲁棒性, 且收敛速度快。所以首选 $L1$ 损失以避免误差被放大或忽略, 使伪影去除模型有更强的鲁棒性。

3 实验与结果分析

3.1 实验设置

本文按照与文献 [19] 相同的方法合成金属伪影数据集进行模型的训练和测试。首先从 DeepLesion 大型公开数据集中收集临床 CT 图像, 然后收集 90 张不同的金属掩膜以代表真实情况下的典型金属物体, 通过模拟射束硬化和泊松噪声并采用滤波反投影^[27] (FBP, filtered back projection) 算法重建生成像素大小为 256×256 的金属伪影图像, 共计 4 500 张。为保证训练所得模型的有效性, 将合成金属伪影数据集分成两部分, 其中 80% 用于训练, 20% 用于测试。

本文算法依托 Pytorch 深度学习框架实现。训练迭代 (iteration) 次数设置为 300 K, 批处理参数 (batch size) 设置为 8, 采用的目标函数优化器 Adam 优化模型的训练过程, 初始学习率 (learning rate) 设置为 1×10^{-4} , 92 K 次迭代后使用余弦退火方案降到 1×10^{-6} 。 $L1$ 损失函数的权重设置为 $\lambda_{L1} = 1$ 。

为了验证算法的有效性与可行性, 选取现有的五种主流算法与本文算法进行对比, 这些对比算法包括 CNNMAR 算法^[19]、ADN 算法^[22]、InDuDoNet 算法^[28]、DICDNet 算法^[29]、ACDNet 算法^[30]。图 5 为随机从测试集中选取的 3 张含伪影原图以进行测试对比。

3.2 定性分析

不同 MAR 算法对随机选取的 3 张含伪影原图进行测试结果如图 6~11 所示。可以看出, 经过不同算法校正后金属伪影均得到有效抑制。具体来说, CNNMAR 算法有效消除了明暗相间的条形伪影, 且很大程度上恢复了金属附近的组织结构, 但由于校正过程不理想, 所

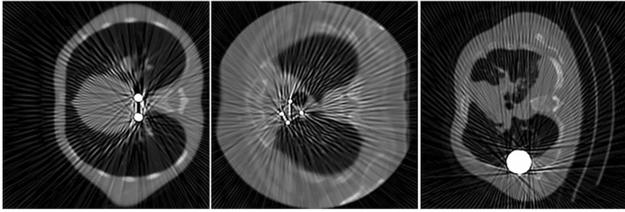


图 5 待处理的含伪影原图

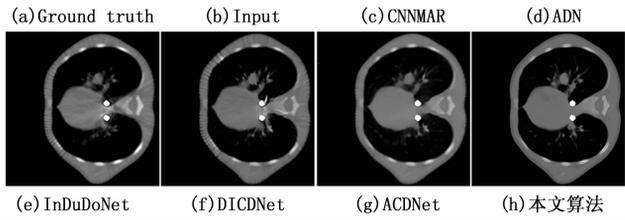
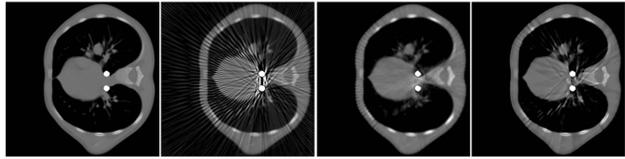


图 6 Case1 实验结果对比图

以结果中仍然包含残留伪影。无监督的 ADN 算法恢复出的图像组织细节干净，图像清晰度相比 CNNMAR 算法明显提高，但伪影消除效果不理想，且边缘轮廓恢复不完整，一些组织在一定程度上丢失。InDuDoNet 算法

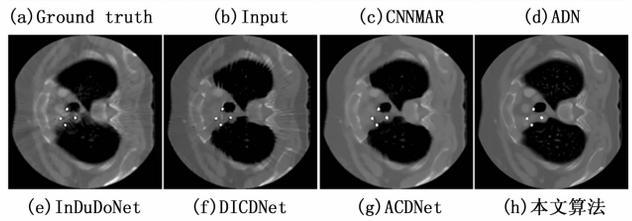
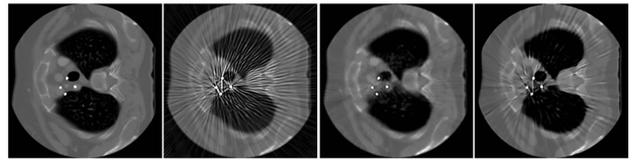


图 7 Case2 实验结果对比图

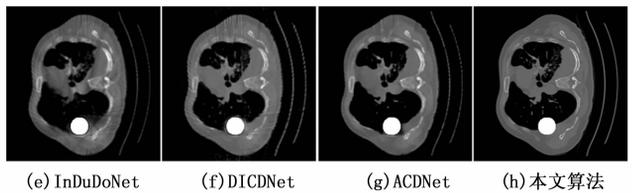
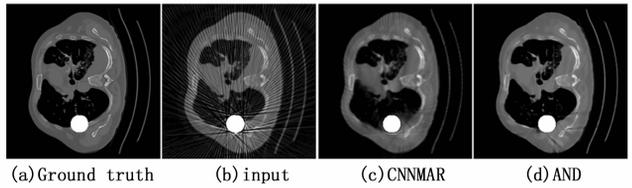


图 8 Case3 实验结果对比图

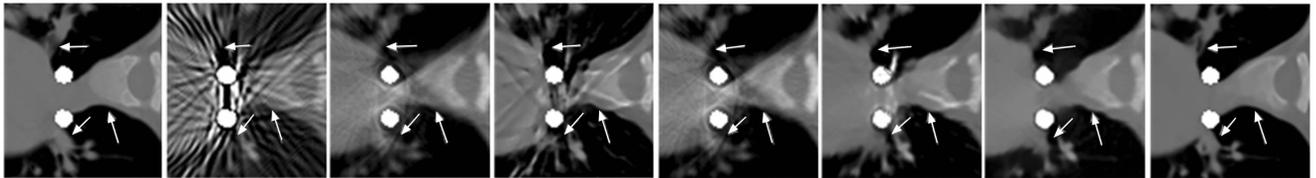


图 9 图 6 (a) ~ (h) 对应的 ROI 局部放大图

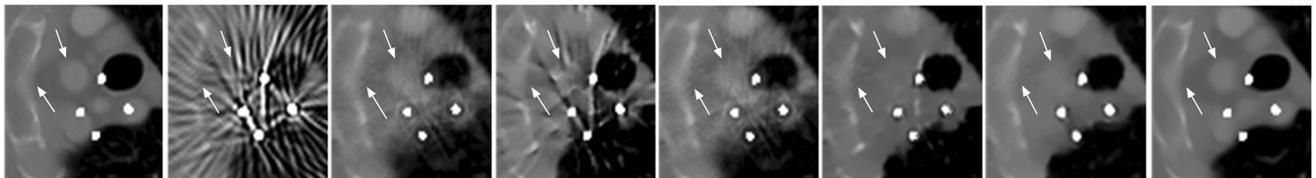


图 10 图 7 (a) ~ (h) 对应的 ROI 局部放大图

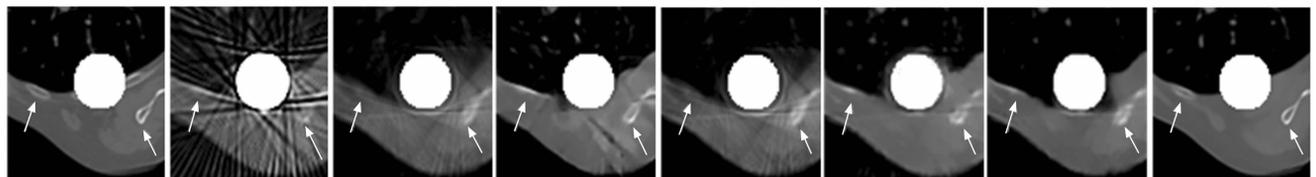


图 11 图 8 (a) ~ (h) 对应的 ROI 局部放大图

利用双域优势, 去除严重金属伪影的同时也恢复了大部分组织细节, 与 ADN 算法相比效果更好但仍不理想。DICDNet 算法伪影去除不彻底, 且信息丢失较多, 得到的重建图像中一些组织结构的边缘和细节被模糊掉。ACDNet 算法基于 DICDNet 算法进行改进, 伪影去除效果较 DICDNet 算法有了提升, 基本没有残留, 且组织结构保留完整, 但仍存在少数细节丢失、边缘模糊的情况。而经过本文算法校正后的结果图像中几乎没有残留伪影或者二次伪影, 组织结构边缘也十分清晰, 两方面视觉对比均优于其他方法, 结果更接近真实的参考图像。

3.3 定量分析

在定性分析不同 MAR 算法校正伪影效果的基础上, 为了更全面地观察对比算法与文本算法之间的差异, 采用结构相似性指数 (SSIM, structural similarity index measure) 和峰值信噪比 (PSNR, peak signal to noise ratio) 对不同算法的校正结果进行定量评估。

SSIM 是衡量两幅图像结构相似度的指标, SSIM 值的范围为 0~1, 越大代表图像越相似。如果两张图片完全一样时, SSIM 值为 1。给定两张图像 x 和 y , SSIM 计算式如下:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (13)$$

式中, μ_x 和 σ_x^2 分别为 x 的均值和方差, μ_y 和 σ_y^2 分别为 y 的均值和方差, σ_{xy} 为 x 和 y 的协方差, C_1 和 C_2 为两个常数。

PSNR 是衡量图像是否失真的指标, PSNR 值越大, 表示图像的质量越好。给定两张图像 x 和 y , 通过均方误差 (MSE) 来定义 PSNR:

$$MSE = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W [x(i, j) - y(i, j)]^2 \quad (14)$$

$$PSNR = 10 \log_{10} \left(\frac{MAX^2(x)}{MSE} \right) \quad (15)$$

式中, i, j 为图像像素点, H, W 分别为图像的高和宽, $MAX(x)$ 是表示图像 x 中像素值的最大数值。

相应的定量评价指标如表 1~3 所示, 最好的指标值用粗体。与定性分析一致, 本文算法较前几种算法质量评价指标显著提升, 表明本文所提出的算法能够在去除伪影的同时很好地保留原始图像的组织结构。

表 1 Case 1 评价指标

	SSIM	PSNR
CNNMAR	0.921 1	30.9182
ADN	0.869 8	27.0958
InDuDoNet	0.925 2	31.966 2
DICDNet	0.924 8	30.224 5
ACDNet	0.940 6	32.766 6
本文算法	0.984 9	40.052 2

表 2 Case 2 评价指标

	SSIM	PSNR
CNNMAR	0.869 2	30.776 1
ADN	0.789 1	24.417 7
InDuDoNet	0.882 4	31.494 4
DICDNet	0.856 5	29.139 3
ACDNet	0.875 9	30.114 4
本文算法	0.974 3	42.693 8

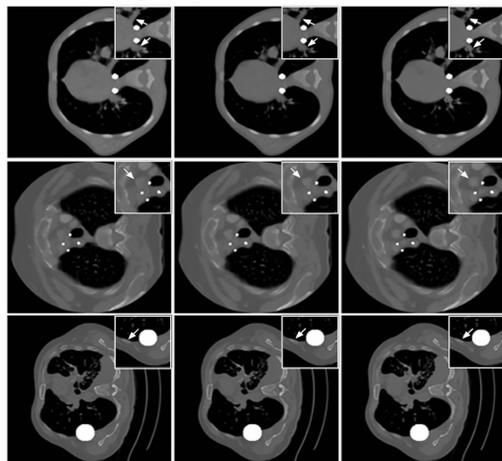
表 3 Case 3 评价指标

	SSIM	PSNR
CNNMAR	0.859 6	28.982 9
ADN	0.867 9	27.083 7
InDuDoNet	0.869 6	29.542 2
DICDNet	0.893 6	29.856 5
ACDNet	0.903 5	30.347 9
本文算法	0.973 1	37.297 4

3.4 消融实验

本文提出的稀疏 Transformer 联合细节还原网络的 CT 金属伪影去除算法, 利用 IDRN 为图像恢复提供了更多的细节特征。为了研究 IDRN 对模型功能是否有影响, 以及局部分支是否能给 IDRN 提供有用信息, 本文进行了两组消融实验。第一组为不含 IDRN 的金属伪影去除算法, 第二组为 IDRN 不含局部分支的金属伪影去除算法。

两组实验视觉效果和量化性能分别如图 12 和表 4 所示。由图 12 可以看出, 模型不含 IDRN 网络的时候, 虽然保留了大部分细节, 但靠近金属的部分会有组织模糊、边缘被平滑掉的情况。添加 IDRN 但是不含局部分支时, 图像细节恢复有了明显的改进, 但仍然不是很理想。而在添加我们包含局部分支的 IDRN 的情况下, 图像的边缘和细节都是最优的结果。从表 4 也可以看出添加 IDRN 时结果是最优的。



(a) 无 IDRN (b) IDRN 无局部分支 (c) 本文算法

图 12 案例 1~3 消融实验结果对比图

表 4 消融实验评价指标

	SSIM	PSNR
无 IDR N	0. 962 6	37. 037 5
IDRN 无局部分支	0. 966 1	37. 638 7
有 IDR N	0. 977 1	40. 014 5

4 结束语

本文提出了一种稀疏 Transformer 联合细节还原网络的 CT 金属伪影去除算法, 整个模型包含两个独立的子网络: 伪影去除网络和细节还原网络。伪影去除网络基于编解码器结构, 以稀疏 Transformer 块作为基本单元以提取丰富的伪影分布特征, 细节还原网络以包含金属伪影的图像作为输入, 输出细节特征图。将两个子网络的输出结果融合得到最终高质量的图像。通过建立 CT 合成伪影数据集来训练和评估本文算法, 并与对比方法进行对比。实验结果表明, 提出的算法能够有效去除严重金属伪影, 且图像清晰度较高, 组织细节恢复良好。但本文算法网络结构较大, 训练所需时间较长, 未来需在网络结构的优化上进一步研究, 以达到效果的同时缩短训练时间。

参考文献:

- [1] 余晓镔, 龚 剑. CT 原理与技术 [M]. 北京: 科学出版社, 2014.
- [2] 谷建伟, 张 丽, 陈志强, 等. 工业 CT 图像的伪影成因和校正方法综述 [J]. CT 理论与应用研究, 2005, 14 (3): 24-28.
- [3] DE MAN B, NUYTS J, DUPONT P, et al. Metal streak artifacts in X-ray computed tomography: a simulation study [J]. IEEE Transactions on Nuclear Science, 1999, 46 (3): 691-696.
- [4] GHANI M U, KARL W C. Fast enhanced CT metal artifact reduction using data domain deep learning [J]. IEEE Transactions on Computational Imaging, 2020, 6: 181-193.
- [5] 肖 文, 曾 理. CT 图像的金属伪影校正方法综述 [J]. 中国体视学与图像分析, 2019, 24 (1): 29-37.
- [6] YU L, ZHANG Z, LI X, et al. Deep sinogram completion with image prior for metal artifact reduction in CT images [J]. IEEE Transactions on Medical Imaging, 2021, 40 (1): 228-238.
- [7] GJESTEBY L, YANG Q S, XI Y, et al. Deep learning methods for CT image-domain metal artifact reduction [C] // Developments in X-Ray Tomography XI: Conference on Developments in X-ray Tomography XI, 2017: 103910W.1-103910W.6.
- [8] LYU Y Y, FU J J, PENG C, et al. U-DuDoNet: Unpaired dual-domain network for CT metal artifact reduction [C] // Medical Image Computing and Computer Assisted Intervention-MICCAI 2021: 24th International Confer-

ence, 2021: 296-306.

- [9] VERBURG J M, SECO J. CT metal artifact reduction method correcting for beam hardening and missing projections [J]. Physics in Medicine & Biology, 2012, 57 (9): 2803-2818.
- [10] 嵇龙寅, 李 光, 杨 姣. 基于生成对抗网络与注意力机制的 CT 图像金属伪影去除算法 [J]. 信息化研究, 2022, 48 (5): 10-15, 38.
- [11] KALENDER WA, HEBE IR, EBERSBERGER J. Reduction of CT artifacts caused by metallic implants [J]. Radiology, 1987, 164 (2): 576-577.
- [12] MEYER E, RAUPACH R, LELL M, et al. Normalized metal artifact reduction (NMAR) in computed tomography [J]. Medical Physics, 2010, 37 (10): 5482-5493.
- [13] WANG G, SNYDER D L, O'SULLIVAN J A, et al. Iterative deblurring for CT metal artifact reduction [J]. IEEE Transactions on Medical Imaging, 1996, 15 (5): 657-664.
- [14] SLAMBROUCK K V, NUYTS J. Metal artifact reduction in computed tomography using local models in an image block-iterative scheme [J]. Medical Physics, 2012, 39 (11): 7080-7093.
- [15] WANG JN, ZHAO Y Y, NOBLE J H, 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: 21st International Conference, 2018: 3-11.
- [16] LEE D, PARK C, LIM Y, et al. A metal artifact reduction method using a fully convolutional network in the sinogram and image domains for dental computed tomography [J]. Journal of Digital Imaging, 2020, 33 (2): 538-546.
- [17] KHALEGHI G, HOSNTALAB M, SADEGHI M, et al. Metal artifact reduction in computed tomography images based on developed generative adversarial neural network [J]. Informatics in Medicine Unlocked, 2021, 24: 100573.
- [18] 李 康, 谢 宁, 李 旭, 等. 基于卷积神经网络和几何优化的统计染色体核型分析方法 [J]. 南京大学学报 (自然科学), 2020, 56 (1): 116-124.
- [19] GJESTEBY L, YANG Q S, XI Y, et al. Deep learning methods for CT image-domain metal artifact reduction [C] // Developments in X-Ray Tomography XI: Conference on Developments in X-ray Tomography XI, 2017: 103910W.1-103910W.6.
- [20] ZHANG Y B, YU H Y. Convolutional neural network based metal artifact reduction in X-ray computed tomography [J]. IEEE Transactions on Medical Imaging, 2018, 37 (6): 1370-1381.

(下转第 212 页)