基于 Transformer 块的混合域网络稀疏角度 CT 成像

张庭宇,吴 凡,金 潼,孙 宇,刘 进,亢艳芹 安徽工程大学 计算机与信息学院,安徽 芜湖 241000

摘 要:目的 针对计算机断层扫描(Computed Tomography, CT)中由于不完全扫描数据导致图像噪声伪影严重的问 题,提出一种基于 Transformer 块的混合域网络稀疏角度 CT 成像算法 (Hybrid Domain network for sparse view CT imaging based on Transformer, HDTransformer)。方法 算法的主要思想是借助于新型的 Transformer 网络,构建适用于 多阶段稀疏角度 CT 投影数据及图像数据的处理流,以提高稀疏角度 CT 图像重建质量;与现有两阶段混合域处理 方法相比,本方法采用图像域-投影域-图像域三阶段混合处理流程,通过多阶段信息的联合互补提高成像质量;此 外,针对不同阶段数据噪声伪影特点设计不同的 Transformer 块,以实现差异化的处理;更进一步,算法采用可微分 的解析重建和投影运算,建立投影域与图像域数据的转换,最终实现端到端的稀疏角度 CT 优质成像流。结果 通 过 Mavo 数据实验验证. 其视觉结果表明: 处理后的不同部位 CT 图像噪声伪影均能够得到较好的抑制: 量化结果表 明:处理后的 CT 图像峰值信噪比和特征相似性均优于对比方法。结论 实验的定性和定量结果表明:所提算法在 去除图像伪影噪声方面要优于其他算法,具有更高的质量,验证了该方法的有效性。

关键词:深度学习;图像修复;Transformer模块;混合域

中图分类号:OTN911.73;TP391 文献标识码:A doi:10.16055/j. issn. 1672-058X. 2024. 0005. 005

Hybrid Domain Network for Sparse View CT Imaging Based on Transformer Blocks

ZHANG Tingyu, WU Fan, JIN Tong, SUN Yu, LIU Jin, KANG Yangin School of Computer and Information, Anhui Polytechnic University, Anhui Wuhu 241000, China

Abstract: Objective A hybrid domain network for sparse view CT imaging based on Transformer (HDTransformer) was proposed to address the serious image noise artifacts caused by incomplete scanning data in computed tomography (CT). Methods The main concept of the algorithm was to utilize a novel Transformer network to construct a processing flow suitable for multi-stage sparse view CT projection data and image data to improve the quality of sparse view CT image reconstruction. In comparison to existing two-stage hybrid domain processing methods, this approach adopted a three-stage hybrid processing flow of image domain-projection domain-image domain, enhancing imaging quality through the joint complementary information of multiple stages. Furthermore, different Transformer blocks were designed based on the characteristics of noise and artifacts in data at different stages for differentiated processing. Moreover, the algorithm adopted differentiable analytical reconstruction and projection operations to establish the conversion of data between projection domain and image domain, ultimately achieving end-to-end high-quality sparse view CT imaging flow. Results Through Mayo data experimental verification, the visual results showed that the processed CT images of different parts effectively suppressed noise artifacts. The quantization results showed that the peak signal-to-noise ratio and feature similarity of the processed CT images were better than those of the comparison method. Conclusion The qualitative and

收稿日期:2023-06-23 修回日期:2023-07-27 文章编号:1672-058X(2024)05-0038-11

作者简介:张庭宇(1999—),男,安徽合肥人,硕士研究生,从事计算机视觉图像处理研究.

通讯作者:刘进(1989—),男,博士,硕士研究生导师,从事医学图像处理、三维可视化、CT图像重建后处理及深度学习技术及应用 研究. Email:liujin@ ahpu. edu. cn.

引用格式:张庭宇,吴凡,金潼,等. 基于 Transformer 块的混合域网络稀疏角度 CT 成像[J]. 重庆工商大学学报(自然科学版),2024,

ZHANG Tingyu, WU Fan, JIN Tong, et al. Hybrid domain network for sparse view CT imaging based on Transformer blocks[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2024, 41(5): 38—48.

quantitative results of the experiment indicate that the proposed algorithm outperforms other algorithms in removing image artifacts and has higher quality, verifying the effectiveness of this method.

Keywords: deep learning; image restoration; Transformer blocks; hybrid domain

1 引 言

计算机断层(CT)扫描由于能够在不破坏物体内部的情况下对其进行可视化,已被广泛应用于临床、工业和其他领域的无损检测[1]。然而在临床诊断中,患者进行 CT 扫描时会吸收部分 X 射线,对身体的健康造成影响,甚至会诱发癌症或者其他遗传性疾病^[2]。因此,通过减少扫描角度的稀疏角度 CT 成像可以有效减少 X 射线剂量。但投影角度的减少会导致 CT 图像中存在明显的噪声和伪影,这对临床医师的诊断造成极大的影响。为了减缓稀疏角度 CT 成像中的这一问题,近年来科研人员及工程师提出了大量成像方法,取得了优异的成绩。这些方法主要被分为 3 类:投影域预处理方法^[3]、迭代重建算法^[4]和图像域后处理方法^[5]。

投影域预处理方法是对投影数据进行滤波、修复、 复原等处理,以去除其中的噪声恢复缺失信号,令其接 近常规扫描下的投影数据,再使用相关重建算法重建 出高质量的 CT 图像。在过去几十年里,大量的图像处 理类算法应用于投影域预处理中,如非线性平滑[6]、结 构自适应滤波[7] 和基于字典的学习[8] 等。然而投影数 据的处理异常敏感,容易出现过校正及欠校正,对重建 图像影响较大。与传统的解析重建相比,迭代重建更 加适应于稀疏角度扫描条件,具有物理模型准确,对噪 声不敏感,易于加入约束条件等优点,能获得更高质量 的CT图像。随着压缩感知(Compressed Sensing, CS) 理论[9]的发展,越来越多的先验约束项被提出,迭代重 建算法得到了极大发展。但由于这类方法因超参数 多,算法复杂度高,稳定性不足等原因,使得该类方法 在临床应用场景中难以得到充分发挥。图像域后处理 方法,是在重建后的低质量 CT 图像中进行相关处理, 以达到临床需求,如通过相关图像处理技术以消除或 减少这些伪影的干扰,提高 CT 图像的质量。对重建后 的图像进一步处理的研究,不仅拥有丰富的算法基础, 而且具有较强的实用性。例如, Cui 等[10] 借助形态分 量分析的思想,提出了一种可自动生成自适应的区别 字典学习方法,实现了无监督有区分性的稀疏表示,能 很好地抑制稀疏角度 CT 图像中的结构伪影,而且避免 了对偶字典设计时人工选取原子的不足: Karimi 等[11] 利用稀疏学习方式,建立双字典,并通过伪影字典编码 系数与干净字典编码系数之间的关系,改善了稀疏角 度 CT 图像质量; Han 等[12]提出一种低秩 HanKel 矩阵 从稀疏角度重建 CT 图像。与前两类方法相比,图像域 后处理方法存在的主要问题是难以确定图像域的退化 模型,在细小结构的保持、纹理对比度保持及噪声伪影 去除之间进行权衡。

近年来,随着深度学习(Deep Learning, DL)技术 的发展,基于数据驱动的卷积神经网络(Convolutional Neural Network, CNN)已逐步成为解决医学成像中逆 问题的主流方法。在稀疏角度 CT 成像领域中,取得了 优异的成绩,如 Jin 等[13]提出一种深度卷积网络 (FBPconvNet), 它将滤波反投影算法(Filtered Back Projection, FBP)、Unet 和残差学习相结合,以去除 CT 图像中的伪影,同时能很好地保留 CT 图像中的细节结 构; Gupta 等[14] 将投影梯度下降算法中的投影算子用 残差网络进行了代替,并设计了一种应用于稀疏角度 CT 成像的可学习松弛投影梯度下降算法,该方法获得 的重建图像不仅质量高,而且具有较好的收敛性,与传 统的迭代重建算法相比更具优势; Chen 等[15] 研究了基 于"Fields of Experts"的正则项与CNN 卷积层之间的关 系,并使用网络来实现重建算法的每次迭代更新过程, 在稀疏角度 CT 重建中取得了较好的成像效果; Chen 等[16]同时结合解析重建、统计迭代重建与 DL 算法三 者的优点,利用 Proximal Forward Backward Splitting 算 法将目标函数的求解问题转化为保真项与先验约束项 的迭代求解过程,实现了一种迭代展开式的深度重建 算法,提高了稀疏角度 CT 图像重建效果。尽管这些方 法已经显示出良好的结果,但这些方法在 CNN 设计中 忽略了图像内的长期相关性(如图像中对象的非局部 相关性),容易导致图像细小信息的丢失,产生错误的 信息。为了解决 CNN 感受野有限的问题,最近人们提 出了一种基于注意力的编码器-解码器结构 Transformer 网络[17],并在很多计算机视觉任务中取得 了巨大成功。Transformer 网络通过将注意力集中在重 要特征上,以实现基于图像内容和特征的自适应处理。 在 Transformer 网络思想基础上,目前已有一些新的 CT 图像处理及重建策略被提出,如Shi等[18]提出CTTR的 稀疏角度 CT 重建方法,该方法使用 Transformer 网络处 理投影域及图像域数据,同时增强投影域数据的注意 力,以减少解析重建后图像中的伪影;Li 等[19]提出一种 DDPTransformer 网络的稀疏角度 CT 图像重建方法.该 方法对投影域和图像域数据使用平行化的 Transformer 网络处理,可联合促进重建后 CT 图像质量的提升;Pan 等[20]借助 Swin Transformer 网络优势,提出一种多域合 成式 Swin Transformer 网络架构,实现了稀疏角度 CT 图 像的优质重建。上述方法虽然可以有效在稀疏角度 CT

图像的处理上取得较好的效果,但是稀疏角度 CT 图像中呈现的伪影水平具有较大差异,且投影域数据与图像域数据差异较大,同架构网络处理难以平衡噪声伪影与图像细节。总的来说,现有的单一图像域以及两阶段双域神经网络,在稀疏角度 CT 成像中难以取得满意的效果,CT 图像质量往往在噪声伪影抑制与图像细节保留程度上折中。

为了解决上述问题,本文借助 Transformer 网络优 势,提出一种基于 Transformer 块的混合域网络稀疏角 度 CT 成像方法(Hybrid Domain network for sparse view CT imaging based on Transformer, HDTransformer) HDTransformer 由 3 个阶段的处理组成,第一阶段是对 稀疏角度 CT 图像进行修复:第二阶段将修复过的 CT 图像投影成投影数据,并对投影数据进行修复,然后借 助解析重建算法,将修复过的投影数据重建成 CT 图 像:第三阶段是对重建后的 CT 图像进行微调,进一步 保障细小组织结构和增强组织对比度,以获得高质量 CT 图像。通过联合投影域及图像域空间信息的处理策 略,使用不同的 Transformer 处理网络,实现数据空间的 互补性处理,以提高稀疏角度 CT 投影数据的重建质 量。实验数据的定性和定量结果表明:所提算法在稀 疏角度扫描情况下,获得的图像噪声伪影少,图像质量 优于对比算法,在极度稀疏情况下,也能获得较好的成 像效果。本文方法主要贡献如下:

- (1) 采用图像域-投影域-图像域三阶段混合处理 流程,通过多阶段信息的联合处理提高成像质量。与 常规的投影域-图像域两阶段处理策略相比,本方法通 过增加图像域的初步处理及反投影,获得全角度下的 投影数据,投影数据准确度更高,提高了投影域处理阶 段的数据输入质量。
- (2) 针对不同阶段数据噪声伪影特点设计不同的 Transformer 块,以实现差异化的处理。第一阶段和第三 阶段输入的 CT 图像质量不同, Transformer 模块使用也不同。其中,第一阶段 CT 图像含有高强度的伪影和噪声,算法采用 CNN 与 Transformer 耦合的网络模型。而第三阶段 CT 图像的噪声伪影较少,主要是细节对比度的 丢失,为此算法设计用于细小组织复原和对比度增强的 轻量化 Transformer 块。在第二阶段投影域处理时,算法采用了分块处理策略及线性叠加连接架构的 Transformer 块,以防止在投影数据修复过程中出现过校正现象。
- (3)借助于可微分的解析重建算法,建立投影域与图像域数据的转换,最终实现完整的端到端稀疏角度 CT 优质成像流。算法三个阶段均在线同步训练,提高了实用性。实验表明:模型适用于不同稀疏角度和人体器官,在 CT 成像过程中表现出优异的性能,消融实验证明了算法的有效性和稳健性。

2 基本原理

2.1 算法流程

假设 P_f 为全角度扫描下的投影数据, P_s 为稀疏角度扫描下的投影数据,通过图像重建算法可以将 P_f 和 P_s 分别重建为全角度 CT 图像 I_f 和稀疏角度 CT 图像 I_s ,如式(1)所示:

$$\begin{cases}
I_f = R(P_f) \\
I_s = R(P_s)
\end{cases}$$
(1)

其中, $R(\cdot)$ 表示图像重建算法。由于扫描角度的减少和缺失,稀疏角度 CT 图像 I_s 中会存在大量的条形伪影及噪声。为了去除图像中的噪声伪影,本文设计了一种新型的成像网络流程,它由 3 个阶段组成。第一阶段是图像域模块,将稀疏角度 CT 图像 I_s 输入图像域Transformer 网络模块进行复原,以去除图像中的高强度噪声和伪影。第一阶段的图像域处理可以表示为

$$I_{s_1} = T_{I_1}(I_s) (2)$$

其中, $T_{I_1}(\cdot)$ 是第一阶段图像域 Transformer 子网络, I_{s_1} 是经过 $T_{I_1}(\cdot)$ 网络修复过的 CT 图像。第二阶段的处理:首先将经过第一阶段修复的 CT 图像 I_{s_1} 投影成全角度投影数据 P_{s_1} ,投影参数与全角度扫描参数相同;然后将投影数据进行分块并输入至投影域 Transformer 子网络进行投影数据修复;最后将修复好的投影数据借助重建算法生成二阶段 CT 图像 I_{s_2} 。第二阶段处理过程可以表示为

$$I_{s_2} = R(T_s(P_{s_1}))$$
 (3)

其中, $T_s(\cdot)$ 是投影域 Transformer 子网络。第三阶段的处理是将 I_{s_2} 输入到第三阶段图像域 Transformer 子网络中实行进一步的图像细节微调和增强,以最终获得高质量的 CT 图像。第三阶段的处理过程可以表示为

$$I_{s_3} = T_{I_2}(I_{s_2}) \tag{4}$$

其中, $T_{I_2}(\cdot)$ 是第二阶段图像域 Transformer 子网络, I_{s_3} 是经过 $T_{I_2}(\cdot)$ 修复过的高质量 CT 图像。整个成像算法流程图如图 1 所示。

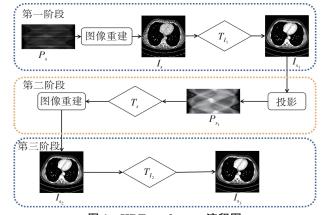


图 1 HDTransformer 流程图

Fig. 1 The flow chart of HDTransformer

2.2 基于 Transformer 块的子网络设计

HDTransformer 块 3 个阶段的子网络中,首先使用 3×3 卷积来获得浅层特征,然后,通过不同的 Transformer 模块提取不同阶段数据的主要特征并进行处理。与其他 网络模块相比,Transformer 网络模块中不存在循环结构,可大幅提高并行计算效率;同时 Transformer 中的自注意 力机制允许模型从序列中任意位置获取信息,这使得 Transformer 能够更好地处理长距离依赖关系,而不需要 通过增加卷积层数来处理这种长距离依赖,更适用于不同类型不同退化程度的数据处理。因此,HDTransformer

在 3 个阶段的数据处理过程中,选用 UNet 形式的架构,以 Transformer 模块为基本的编码解码单元,替代传统的卷积层,构建处理网络。如图 2 所示,为了简单起见,图 2 的 UNet 只显示了 2 层 Transformer 块。在 HDTransformer 中不同阶段的处理均设计了不同的 Transformer 块来提取 CT 图像和正弦图像的特征。其中第一阶段和第三阶段的 UNet 总共有 6 层 Transformer 块,考虑到处理投影数据需要谨慎,容易出现过拟合情况,第二阶段的 UNet 共有 4 层 Transformer 块。最后,再采用 3×3 卷积获取最终处理后的数据。

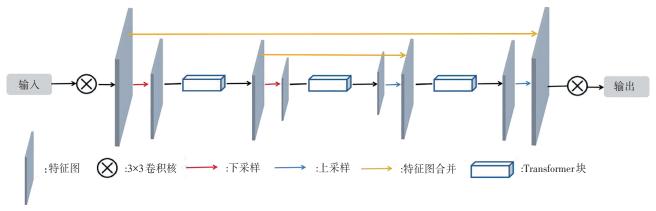


图 2 基于 Transformer 模块的 UNet 网络

Fig. 2 UNet network based on Transformer block

第一阶段图像域子网络所用的是耦合 Transformer 块结构,主要由 3 部分组成,第一部分是 3×3 的卷积层;第二部分是归一化层(Layer Normalisation),窗口式多头自注意力(Window Multi-head Self-Attention,W-MSA)模块和 GELU(Gaussian Error Linear Unit,GELU)激活函数操作;第三部分是归一化层,具有 SWIN 滑动窗口的多头自注意力(Shifted Windows Multi-head Self-Attention,SW-MSA)和 GELU 激活函数操作。第二部分之前和第三部分之后均包括 Patch Enbedding 层。第一阶段图像域网络模块如图 3(a) 所示,该耦合形式的模块融合了传统卷积网络与 Transformer 优势,能在参数较少的情况下提取有效信息实现去伪影。在训练第一阶段图像域网络时,使用均方误差(Mean Square Error,MSE)作为网络的损失函数,其中 θ_1 为网络参数,损失函数表示为

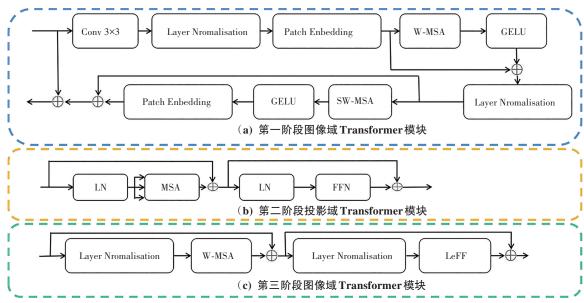
$$L_{T_1}(I_{s_1}, I_f, \theta_1) = \|I_{s_1} - I_f\|_2^2$$
 (5)

在第二阶段投影域子网络中, Transformer 块采用线性叠加连接的设计思想, 主要包含线性连接层(Linear Layer, LN)、多头自注意力模块(Multi-head Self-Attention, MSA)和前馈网络(Feed Forward Network,

FFN)等部分,且该 Transformer 块为浅层网络。浅层网络可减缓投影数据过处理现象的发生,同时可应对深层网络训练难,不易收敛等问题,还可提高投影数据的复原效果。拟采用的 Transformer 块结构如图 3(b)所示。在训练第二阶段投影域网络时,网络的损失函数如下:

 $L_{T_2}(P_{s_1},T_s(P_{s_1}),\theta_2)=\|P_{s_1}-T_s(P_{s_1})\|_2^2$ (6) 其中, θ_2 为网络参数。第三阶段图像域子网络结构同样采用轻量化的设计方案,该 Transformer 块由 3 个部分组成:Layer Normalisation 层、W-MSA 模块和局部增强的前馈网络(Locally enhanced FeedForward network,LeFF)。经过第二阶段输入到第三阶段的 CT 图像,相较于输入第一阶段的 CT 图像,伪影及噪声已大大减少,存在的主要问题是对比度不高,细节丢失。此阶段的轻量化 Transformer 块不仅可以进一步去噪去伪影,获得高质量的 CT 图像,同时还以提高组织对比度,复原丢失的图像细节,减少训练计算量和内存。结构如图 3 (c) 所示,训练第三阶段时采用的损失函数如下,其中 θ_3 为网络参数:

$$L_{T_2}(I_{s_2}, I_f, \theta_3) = \|I_{s_2} - I_f\|_2^2$$
 (7)



不同阶段子网络中 Transformer 模块结构

Fig. 3 Transformer block in subnetworks at different stages

3 结果讨论与分析

3.1 实验设计

为了验证本文所设计 HDTranformer 网络在稀疏扫 描条件下成像的有效性,实验选用 FBP、bilinear+FBP 和 CTTR 3 种方法对比,其中 FBP 和 bilinear+FBP 是非 深度学习的传统方法, CTTR 方法[18] 为一种基于 Transformer 网络的双域稀疏角度 CT 重建算法,具有优 异的稀疏角度图像处理性能,与本文方法类似。实验 硬件配置为 Intel(R) Core(TM) i5-12600k, NVIDIA GTX 4090 显卡。为加速深度学习模型的收敛,所有的 训练及测试均在显卡上完成。

为了进一步定量比较和分析本文方法与对比方法 之间的差异,需要对网络训练的结果进行量化评估。 在图像处理及复原领域,对图像质量评价常包括主观 评价和客观评价。本文实验将采用特征相似性 (Feature Similarity Index Mersure, FSIM, 其值用 F_{SIM} 表 示)和峰值信噪比(Peak Signal to Noise Ratio, PSNR,其 值用 P_{SNB} 表示)这两种客观评价指标进行比较,计算公 式如下:

$$F_{\text{SIM}} = \frac{\sum_{x,y} S_L(x,y) \cdot PC(x,y)}{\sum_{x,y} PC(x,y)}$$

$$P_{\text{SNR}}(x,y) = 10 \cdot \log_{10} \left(\frac{x_{\text{MAX}}^2}{MSE(x,y)}\right)$$
(8)

$$P_{\text{SNR}}(x,y) = 10 \cdot \log_{10} \left(\frac{x_{\text{MAX}}^2}{MSE(x,y)} \right)$$
 (9)

其中,x 表示经过 Transformer 网络结构修复输出的结果, γ 为参考图, $PC(\cdot)$ 表示图像的相位一致性特征提取, $S_{i}(\cdot)$ 表示图像相位一致性特征提取和梯度特征提取融 合的相似度, $m \times n$ 为目标图像块的大小, x_{MAX} 表示目标 图像 x 中的最大像素值, $MSE(\cdot)$ 为均方误差计算函数。

实验中采用的数据集为 Mayo Clinic 授权的"2016年

NIH-AAPM-Mayo LDCT 图像处理比赛"的数据集。该 数据集中包括与 10 名匿名患者匹配的 CT 图像与投 影。选取9名患者的 CT 数据作为训练集,1 名患者的 CT 数据作为测试集。在第一阶段,将 10 名患者的 CT 投影数据进行稀疏角度采样并重建,将重建后的稀疏 角度 CT 图像作为训练集和测试集的输入,全角度下的 CT 图像作为标签输入到网络结构中。在第二阶段,将 第一阶段修复的 CT 投影数据作为输入,将全角度 CT 图像的投影数据作为标签。在第三阶段,将经过第二 阶段修复的投影数据进行重建,将重建后的 CT 图像作 为输入,将对应的全角度 CT 图像作为标签。重建均采 样 FBP 算法。重建 CT 图像大小为 512×512,全角度投 影数据大小为 720×768,720 个投影角度。网络训练 中,为减少单次数据量的使用,BatchSize 大小为3,网络 通道数为96,训练epoch设置为50次,学习率的初始值 为 2×10⁻⁴,学习率递减到最小值为 1×10⁻⁶。

3.2 实验结果

图 4、图 5 和图 6 分别显示了 90 个角度、120 个角 度和180个角度下的重建结果,其中第一行、第二行和 第三行表示使用不同算法对所选胸部、腹部和胯部切 片的成像结果,显示窗为[-150 HU,250 HU]。图 4 (a)—图 6(a) 为全角度下的 FBP 重建图像,作为不同 方法成像结果的对比。对比图 4(b)—图 6(b)中的成 像结果,可以看到:由于投影数据的缺失,传统解析重 建算法获得的图像含有大量伪影,图像细节被伪影淹 没,严重影响诊断。同时也发现,随着扫描角度的减 少,重建图像中伪影越来越多。经过双线性插值后,缺 失的投影数据被粗略地补全,重建图像有了明显的改 善,部分细节清晰,但依旧含有大量的条状伪影和部分 噪声。通过对比第四列 CTTR 方法成像结果和第五列

HDTransformer 方法成像结果,可以发现图像质量有了大幅度的提升。进一步通过局部放大图可以看出: CTTR 算法结果会丢失一部分图像信息,细节对比度有所下降,出现一定的过平滑现象,而本文 HDTransformer 方法获得的图像细节更多,对比度更高(如图 4(e)—图 6(e)红色箭头所示),更接近参考图,整体图像质量要优

于其他 3 种对比方法。其中 CTTR 算法和本文算法均采用 Transformer 网络结构, CTTR 算法的参数和时间复杂度为 166M Parms 和 187G FLOPs, 而本文提出的算法参数和时间复杂度为 99M Parms 和 30G FLOPs, 具有更少的参数和计算量, 并且在测试时间和训练时间上均少于 CTTR 算法(表1)。

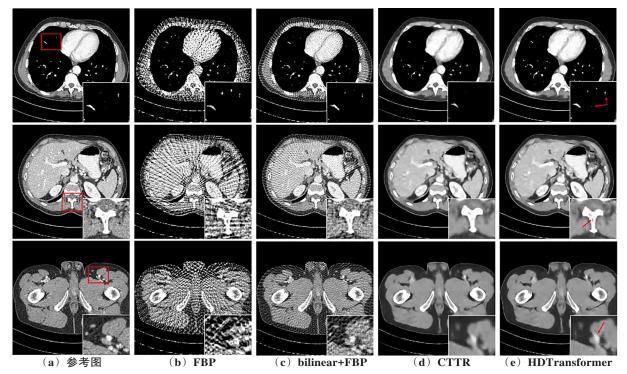


图 4 90 个扫描角度下不同方法的 CT 成像效果图

Fig. 4 CT imaging results for different methods at 90 scanning angles

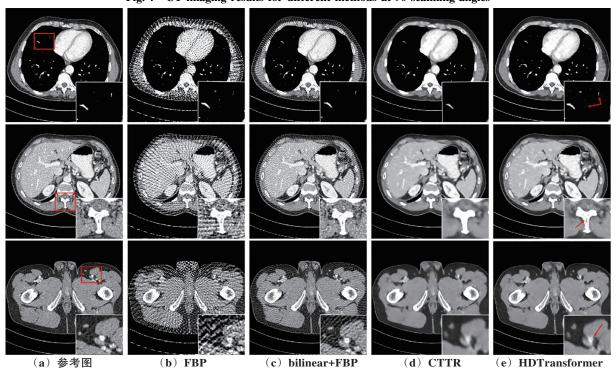


图 5 120 个扫描角度下不同方法的 CT 成像效果图

Fig. 5 CT imaging results for different methods at 120 scanning angles

投稿地址(http://journal.ctbu.edu.cn/zr/ch/index.aspx)

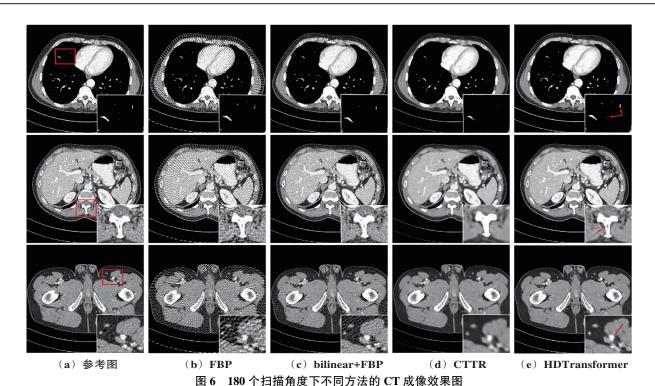


Fig. 6 CT imaging results for different methods at 180 scanning angles

表 1 CTTR 算法和 HDTransformer 算法复杂情况对比
Table 1 Comparison of complexity between CTTR
and HDTransformer

	训练时间/min			测试时	参数	计算
	Epoch = 1	Epoch = 10	Epoch = 50	间/min	/M	量/G
CTTR	51	624	3 262	9	166	187
HDTransformer	24	279	1 408	5	99	30

为进一步分析不同方法在冠状面和矢状面中的成像效果,实验选取90个投影角度下冠状面和矢状面重建图进行比较,成像结果如图7所示,显示窗为

[-150 HU,250 HU]。从图 7 中可以看出:冠状面和 矢状面中噪声伪影相对较少,扫描角度减少对这两个 切面影响没有横断面大。对比方法 bilinear+FBP,虽 然在一定程度上去除了图像伪影,但是整体复原度不高,部分细节丢失,同时在胯部位置中存在伪影残留。 CTTR 方法在噪声伪影上去除得非常干净,但图像组织纹理保持度不高,部分细节丢失,而本文 HDTransformer 方法显著降低了各部位噪声和伪影,同时也更好地保留了图像组织区域的边缘特征,处理后的图像具有较好的视觉效果。

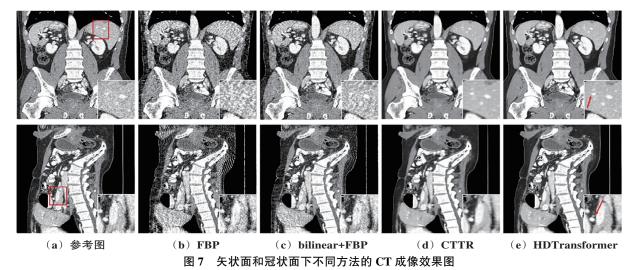


Fig. 7 CT imaging results for different methods in sagittal plane and coronal plane

图 8 分别展示了 90 个角度、120 个角度和 180 个角度扫描下成像结果与对应参考图之间的差异,差异图由不同

方法重建的图像与全角度扫描下参考 CT 图像相减得到, 差异图反映处理后的图像与原始 CT 图像之间的接近程 度,图8显示窗口为[0 HU,200 HU]。通过差异图,可以发现:前三种方法处理后的 CT 图像残留伪影较多,与参考图像之间差异较大,而本文 HDTransformer 方法的差异图强

度较低,整体较均匀,这表明本文方法获得的图像更加接近于参考图,显著优于其他处理方法。综上,从视觉效果来看,本文方法的处理效果要优于对比方法。

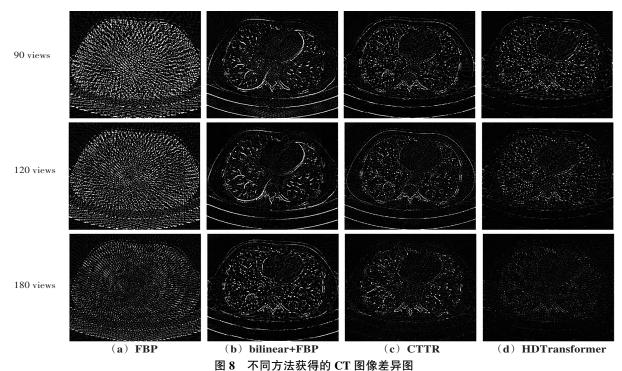
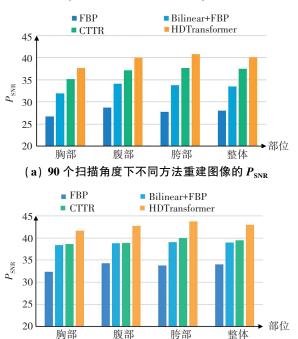
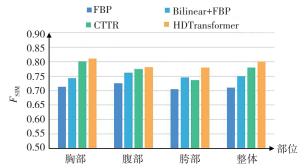


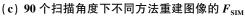
Fig. 8 Difference diagrams of CT images obtained by different methods

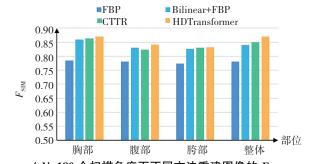
为更加直观及定量地比较不同算法的处理效果,本文采用 P_{SNR} 和 F_{SIM} 两个指标来评估实验结果。图 9 为 90 个角度和 180 个角度扫描下不同方法重建图像的 P_{SNR} 和 F_{SIM} 直方图。通过对比直方图可以看出,本文 HDTransformer 方法在 P_{SNR} 和 F_{SIM} 两个指标下,均优于其他 3 种方法,具有明显的量化优势。



(b) 180 个扫描角度下不同方法重建图像的 P_{SNR}







(d) 180 个扫描角度下不同方法重建图像的 F_{SIM} 图 9 不同扫描角度下不同方法重建图像的 P_{SNR} 值和 F_{SIM} 值 Fig. 9 P_{SNR} and F_{SIM} values of reconstructed images using different scanning angles and methods

3.3 模型分析

本文 HDTransformer 成像方法由 3 个阶段组成,分别是第一阶段图像域、第二阶段投影域和第三阶段图

像域,不同阶段对稀疏角度 CT 图像均有一定程度的提升。为了证明本文混合域网络对图像提升最大,此部分分别对不同阶段成像效果进行比较,包括第一阶段图像域(记为 T_1)、第二阶段的投影域(记为 T_1)、第一阶段图像域与第二阶段投影域(记为 T_1)、第二阶段投影域与第三阶段图像域(记为 T_1)以及本文的同时采用三个阶段处理(记为 T_1 , T_2)。实验结果选取胸部器官和腹部器官图像进行比较,如图 10、图 11 所示,其

中图 10 为 90 个稀疏角度扫描后的 CT 图像,图 11 为 180 个稀疏角度扫描后的 CT 图像,显示窗口均为 [-150 HU,250 HU]。通过图 10、图 11 的胸部局部放大图可以发现:本文的三阶段处理策略 $T_1S_2T_3$ 具有最好的成像效果,其余 4 种组合都存在不同程度的细节丢失情况。通过对比图 10 和图 11 中腹部局部放大图可以看出:在处理伪影和噪声方面,本文所采用的三阶段混合域网络处理效果最好,更加接近参考 CT 图像。

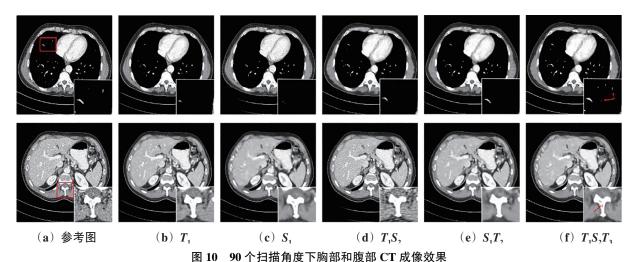


Fig. 10 Chest and abdomen CT imaging results at 90 scanning angles

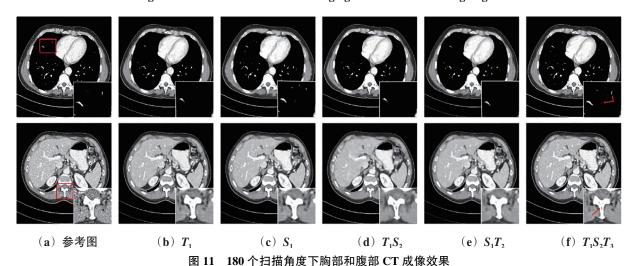
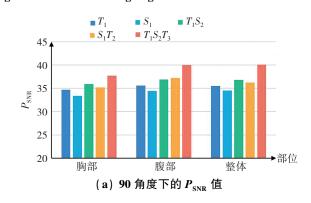


Fig. 11 Chest and abdomen CT imaging results at 180 scanning angles

为更加直观及定量地比较不同阶段方法的成像效果,此部分将进一步采用 $P_{\rm SNR}$ 和 $F_{\rm SIM}$ 这两种客观评价指标进行比较。不同阶段重建后的 CT 图像的 $P_{\rm SNR}$ 值和 $F_{\rm SIM}$ 平均值如图 12 所示。通过 $P_{\rm SNR}$ 和 $F_{\rm SIM}$ 的直方图可以看出:单一的投影域处理网络其重建图像 $P_{\rm SNR}$ 和 $F_{\rm SIM}$ 值最低,两阶段的处理方法 $(T_1S_2 \ n \ S_1T_2)$ 要优于一阶段的单域处理方法 $(T_1 \ n \ S_1)$,而本文提出的三阶段混合域方法重建 CT 图像的 $P_{\rm SNR}$ 和 $F_{\rm SIM}$ 最高,表明其重建图像更加接近于全角度下的参考图像。



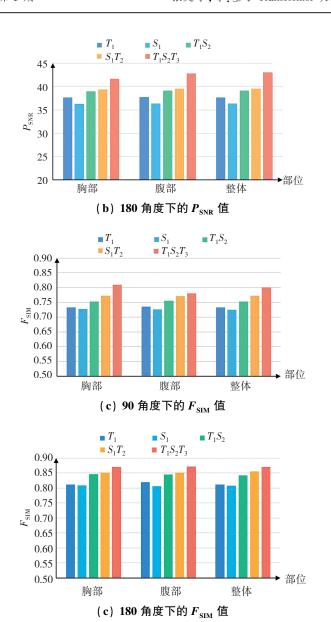
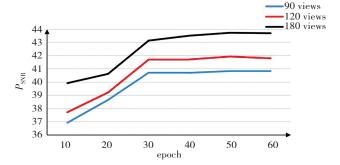


图 12 不同角度下的 $P_{\rm SNR}$ 值和 $F_{\rm SIM}$ 值 Fig. 12 $P_{\rm SNR}$ and $F_{\rm SIM}$ values at different angles

此部分实验进一步分析了网络的收敛性。实验采用不同训练 epoch 下重建 CT 图像的 $P_{\rm SNR}$ 均值和 $F_{\rm SIM}$ 均值变化曲线,来对比分析网络的收敛性。测试数据为 300 张 CT 图像,不同扫描角度下,网络训练后 $P_{\rm SNR}$ 和 $F_{\rm SIM}$ 曲线如图 13 所示。从图 13 (a) 中可以看出:随着训练周期的增加,不同数据的 $P_{\rm SNR}$ 值均逐步增高并在 30 个 epoch 后趋于平缓,并逐步收敛。从图 13 (b) 中可以看到:不同扫描数据训练后 $F_{\rm SIM}$ 值变化差异较大。180 个扫描角度数据在 30 个 epoch 的训练下 $F_{\rm SIM}$ 值反而有所下降,在 50 个 epoch 训练后均能达到最大值,随后有了略微地下降,表明网络开始出现过拟合现象。为此,综合视觉效果、 $P_{\rm SNR}$ 及 $F_{\rm SIM}$,实验选取训练周期为 50 个 epoch。



(a) 不同 epoch 下 90 角度,120 角度和 180 角度的 P_{SNR} 值

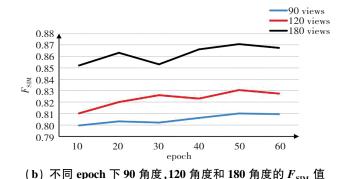


Fig. 13 $P_{\rm SNR}$ and $F_{\rm SIM}$ values at 90, 120, and 180 angles under different epochs

4 结 论

由于扫描角度的缺失,导致重建后的 CT 图像中存 在大量条形伪影和斑点噪声,单一图像域的复原难以 达到满意的效果。为此,论文采用联合投影域及图像 域处理策略,建立基于 Transformer 网络的混合域成像 流,以提高稀疏角度 CT 图像重建质量。成像流中,第 一阶段图像域采用耦合 Transformer 网络,以融合传统 CNN 和 Transformer 的优势, 能极大程度地提取有效信 息实现伪影噪声的去除。第二阶段投影域采用线性叠 加连接的网络设计思想,以尽可能地减缓投影数据过 处理现象的发生,同时为避免处理不均匀问题,实施中 采用数据分块策略进行网络训练。第三阶段的图像域 设计的轻量化 Transformer 网络在减少计算量和内存空 间的同时,实现了对 CT 图像进一步的细节微调。实验 结果表明:本文所提混合域 Transformer 网络模型可适 用于不同稀疏程度的 CT 数据,与其他 CT 图像算法相 比,图像质量均有明显的提升,并优于对比算法结果, 在 P_{SNR} 和 F_{SIM} 的量化指标上同样也取得了最好的结 果。总的来说,本文所提模型在抑制噪声伪影的同时, 可有效保留 CT 图像的结构和纹理信息,并获得令人满 意的定性指标。后续研究可进一步优化处理流程,提 高成像效率。

参考文献(References):

- BAKATOR M, RADOSAV D. Deep learning and medical diagnosis: A review of literature[J]. Multimodal Technologies and Interaction, 2018, 2(3): 47—58.
- [2] WANG S, YU H, XI Y, et al. Spectral-image decomposition with energy-fusion sensing for spectral CT reconstruction [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1—11.
- [3] 马晨欣,胡君杰,闫镔.CT扇形束滤波反投影图像重建 算法优化[J].激光与光电子学进展,2012,49(9): 86—91.
 - MA Chen-xin, HU Jun-jie, YAN Bin. Optimization of fanbeam CT filtered backprojection reconstruction algorithm[J]. Laser & Optoelectronics Progress, 2012, 49(9): 86—91.
- [4] 亢艳芹, 刘进, 王勇, 等. 联合卷积稀疏编码与梯度 L0 范数的低剂量 CT 三维重建[J]. 光学学报, 2021, 41(9): 104—115.
 - KANG Yan-qin, LIU Jin, WANG Yong, et al. Low-dose CT 3D reconstruction using convolutional sparse coding and gradient L0-norm [J]. Acta Optica Sinica, 2021, 41 (9): 104—115.
- [5] 章云港, 易本顺, 吴晨玥, 等. 基于卷积神经网络的低剂量 CT 图像去噪方法[J]. 光学学报, 2018, 38(4): 115—121. ZHANG Yun-gang, YI Ben-shun, WU Chen-yue, et al. Lowdose CT image denoising method based on convolutional neural network[J]. Acta Optica Sinica, 2018, 38(4): 115—121.
- [6] WANG Y, SHAO Y, ZHANG Q, et al. Noise removal of low-dose CT images using modified smooth patch ordering [J]. IEEE Access, 2017(5): 26092—26103.
- [7] KADAM C, BORSE S B. An improved image denoising using spatial adaptive mask filter for medical images [C]// Proceedings of the International Conference on Computing, Communication, Control and Automation. Piscataway: IEEE Press, 2017: 1—5.
- [8] HU Z, WANG Y, ZHANG X, et al. Super-resolution of PET image based on dictionary learning and random forests [J]. Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment, 2019, 927: 320—329.
- [9] BAO P, XIA W, YANG K, et al. Convolutional sparse coding

- for compressed sensing CT reconstruction[J]. IEEE Transactions on Medical Imaging, 2019, 38(11): 2607—2619.
- [10] CUI X Y, GUI Z G, ZHANG Q, et al. Learning-based artifact removal via image decomposition for low-dose CT image processing[J]. IEEE Transactions on Nuclear Science, 2016, 63(3): 1860—1873.
- [11] KARIMI D, WARD R. Reducing streak artifacts in computed tomography via sparse representation in coupled dictionaries[J]. Medical Physics, 2016, 43(3): 1473—1486.
- [12] HAN Y, JIN K, KIM K, et al. Sparse-view X-ray spectral CT reconstruction using annihilating filter-based low rank Hankel matrix approach, IEEE International Symposium on Biomedical Imaging, 2016, 99(3): 573—576.
- [13] JIN K H, MCCANN M T, FROUSTEY E, et al. Deep convolutional neural network for inverse problems in imaging [J]. IEEE Transactions on Image Processing, 2017, 26(9): 4509—4522.
- [14] GUPTA H, JIN K H, NGUYEN H Q, et al. CNN-based projected gradient descent for consistent CT image reconstruction [J]. IEEE Transactions on Medical Imaging, 2018, 37(6): 1440—1453.
- [15] CHEN H, ZHANG Y, CHEN Y, et al. LEARN: Learned experts' assessment-based reconstruction network for sparsedata CT[J]. IEEE Transactions on Medical Imaging, 2018, 37(6): 1333—1347.
- [16] CHEN G, HONG X, DING Q, et al. AirNet: Fused analytical and iterative reconstruction with deep neural network regularization for sparse-data CT[J]. Medical Physics, 2020, 47(7): 2916—2930.
- [17] ASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [J]. Advances in Neural Information Processing Systems, 2017, 30(1):86—97.
- [18] SHI C, XIAO Y, CHEN Z. Dual-domain sparse-view CT reconstruction with Transformers[J]. Physica Medica, 2022, 101: 1—7.
- [19] LI R, LI Q, WANG H, et al. DDP Transformer: Dual-domain with parallel transformer network for sparse view CT image reconstruction[J]. IEEE Transactions on Computational Imaging, 2022(8): 1101—1116.
- [20] PAN J, ZHANG H, WU W, et al. Multi-domain integrative swin transformer network for sparse-view tomographic reconstruction[J]. Patterns, 2022, 3(6): 498—508.

责任编辑:李翠薇