

DOI: 10.19650/j.cnki.cjsi.J2412891

基于多尺度生成对抗网络的锥束 CT 图像 耦合伪影校正方法*

柴世杰^{1,2,3}, 黄魁东^{1,2,3}, 杨富强^{1,3}, 赵举龙^{1,3}

(1. 西北工业大学航空发动机高性能制造工业和信息化部重点实验室 西安 710072; 2. 西北工业大学宁波研究院 宁波 315000; 3. 西北工业大学航空发动机先进制造技术教育部工程研究中心 西安 710072)

摘要:针对锥束 CT(CBCT)图像存在的耦合伪影难以完全校正问题,提出 1 种基于多尺度生成对抗网络的锥束 CT 图像耦合伪影校正方法。首先,根据 CT 图像的伪影特征构建了一套包括仿真图像和实际图像的 CBCT 耦合伪影数据集,用于提高模型泛化能力。再将特征金字塔结构(FPN)和基于卷积块的注意机制(CBAM)融入网络的生成器结构中,帮助网络捕获更全面特征信息,并配合多尺度判别器(MSD)搭建生成对抗网络框架,使得生成的去伪影图像更加清晰和真实。实验分析显示,经本文方法校正图像的 PSNR 和 SSIM 在仿真数据集中提高了 21.595 dB/0.541,在实际数据集中提高了 14.072 dB/0.274。实验结果表明,本文方法可有效校正耦合伪影。

关键词: CBCT; 耦合伪影去除; 多尺度; FPN; 生成对抗网络

中图分类号: TP391.9 TH74 **文献标识码:** A **国家标准学科分类代码:** 520.60

Coupled artifacts removal in cone-beam computed tomography images based on multi-scale generative adversarial network

Chai Shijie^{1,2,3}, Huang Kuidong^{1,2,3}, Yang Fuqiang^{1,3}, Zhao Julong^{1,3}

(1. School of Mechanical Engineering, Northwestern Polytechnical University, Xi'an 710072, China; 2. Ningbo Institute of Northwestern Polytechnical University, Ningbo 315000, China; 3. Key Laboratory of High Performance Manufacturing of Aero Engines, Ministry of Industry and Information Technology, Northwestern Polytechnical University, Xi'an 710072, China)

Abstract: To address the issue of incomplete correction of coupled artifacts in cone-beam computed tomography (CBCT) images, a coupled artifact correction method for CBCT images based on a multi-scale generative adversarial network (GAN) is proposed. Firstly, a CBCT coupling artifact dataset comprising both simulated and real images was constructed based on the artifact characteristics of CT images to enhance the model's generalization capability. Additionally, the generator structure of the network was improved by integrating the feature pyramid network (FPN) and convolutional block attention module (CBAM) to capture more comprehensive feature information. We also employed a multi-scale discriminator (MSD) alongside these components to form a generative adversarial network framework, producing clearer and more realistic artifact-free images. Experimental analysis showed that the PSNR and SSIM of the corrected images increased by this method increased by 21.595 dB and 0.541 in the simulated dataset, and by 14.072 dB and 0.274 in the real dataset. The experimental results indicate that the proposed method can effectively correct coupled artifacts.

Keywords: CBCT; coupling artifact removal; multi-scale; FPN; generative adversarial network

收稿日期: 2024-05-28 Received Date: 2024-05-28

* 基金项目: 浙江省“尖兵领雁+X”研发攻关计划项目(2024C01249(SD2))、中国航空发动机集团产学研合作项目(HFZL2022CX024)、航空发动机及燃气轮机基础科学中心项目(P2022-B-IV-013-001)资助

0 引言

锥束CT(cone-beam computed tomography, CBCT)可以在不损伤被检物体的前提下,直观且清晰地展示其内部结构、材质组成以及缺陷损伤等信息^[1]。然而,CBCT在成像过程中不可避免地出现的图像退化问题,表现为图像模糊、噪声点突出、分辨率不足以及部分区域信息丢失^[2],严重时可能导致误判。因此,对与工业CT系统而言,能够准确地认识并抑制图像退化是极其重要的。

在对高密度合金材料进行扫描成像时,由于硬化效应、被测对象的微小运动、散射效应及重建算法等多种因素,CT图像不可避免地出现退化现象。其中,射线的散射效应和硬化效应对成像质量影响最为严重^[3]。散射效应是射线穿透物质时的出现的能量衰减现象,主要由光电效应和康普顿散射效应引起^[4-5]。射束硬化效应是因射线穿过被检物体时,射线的能谱向更高的能量方向偏移。不同投影角度和材料厚度导致能量偏移不同,从而在重建图像上金属结构附近产生暗条纹^[6]。

工业CT伪影校正的传统方法主要包括基于物理模型和基于图像处理的策略,分别从成像物理过程和图像后处理2个角度尝试减轻伪影。随着深度学习技术的兴起和发展,其展现出了卓越学习能力和高效的特征提取能力,为CBCT图像退化校正提供了新的解决途径,其有望颠覆传统方法,成为一种精准高效的CBCT成像耦合伪影校正的新方法。

正弦图校正指在正弦图域运用插值手段,针对金属路径中的不一致数据实施修正,以实现校正目的。具体而言,归一化MAR(normalized metal artifact reduction, NMAR)采取了一种基本的插值策略,旨在估算正弦图损坏数据^[7]。后续,Veldkamp等^[8]设计了一种自适应性插值算法,该算法依托马尔科夫随机场来定位投影数据中的退化部分,通过融合线性插值及拉普拉斯平滑运算,规范正弦图的校准过程。Kratz等^[9]采用非等距快速傅里叶变换(non-equidistant fast fourier transform, NFFT)进行高维插值,这一方法能够结合金属物体的先验信息,增强校正的精确性。Bal等^[10]使用一个径向自适应滤波器来处理有轻微伪影影响的图像。因各类金属物体几何形状、材质、内部结构等并不相同,单一的MAR方法很难彻底去除伪影。图像后处理算法与正弦图域校正相结合的方法相较于其单一方法具有更好的校正效果^[11]。在后续研究中人们将多种MAR方法有效结合,Mouton等^[12]提出了一种将投影校正与后处理相结合的MAR方法,以减少插值引入的伪影。但是此类方法面对复杂的伪影情况,可能导致部分区域校正过度,且部分参数需要调整,现实中考虑到检测效率,实际工程应用中还处于探究阶段。

深度学习方法通过使用卷积神经网络(convolutional neural network, CNN)或生成对抗网络(generate adversarial networks, GAN),建立在输入(伪影影响图像)和输出(无伪影图像)之间的非线性映射上,克服了传统方法的局限性。Xiang等^[13]利用CNN网络,从实际测量的单能扫描投影和CT衰减投影中估计散射信息。然而,这种方法可能受限于训练数据的多样性和质量,导致模型泛化能力有限。Jiang等^[14]提出了1种新的基于深度残差卷积神经网络(deep residual convolutional neural network, DRCNN)的CBCT散射校正方案,旨在通过增强网络的深度和残差学习机制,提高模型的稳定性和准确性。Hansen等^[15]通过借鉴U-net的网络架构设计出了Scatter Net,其可以对重建前投影进行散射校正。尽管基于U-net的方法在散射校正方面表现出色,但其在上采样下采样的过程中会造成图像细节的丢失,且对训练数据中的噪声和异常值较为敏感。Yusuke等^[16]使用残差卷积神经网络作为特征权值反馈,成功实现了从有耦合伪影图像到无耦合伪影图像的端到端映射。马燕等^[17]提出1种基于残差编解码网络的方法。Zhang等^[18]设计了1种基于简单卷积神经网络的耦合伪影校正算法;但简单的卷积不能充分提取图像特征,无法彻底消除伪影。Gomi等^[19]在投影域使用混合条件的生成对抗网络,并结合迁移学习提高了学习网络的泛化性能,但其训练过程复杂且计算成本高,需要进一步优化以适应资源受限的环境。

针对耦合伪影的分布特点和图像特性,本文提出了一种多尺度的全监督的生成对抗网络。通过生成对抗网络结构,有效约束真值信息,抑制了伪影干扰^[20]。利用特征金字塔(feature pyramid network, FPN)^[21]结构的多层语义提取能力,从CT图像中提取多尺度特征和图像信息,实现高质量伪影校正,并提高修复信息的一致性。采用多尺度判别器,确保生成网络模型的真实性和稳定性,并结合适当的损失函数,使生成图像在客观指标和视觉感知上更接近真实图像。为最大化地利用多尺度生成对抗网络的潜力,构建了高质量的仿真和真实数据集^[22],进一步提升了模型在生成图像真实性方面的表现。

1 多尺度生成对抗网络

鉴于CT图像退化的原因复杂多变,各种因素之间存在相互耦合,直接应用传统的图像恢复算法难以达到理想的校正效果。因此,本文致力于根据图像特征和退化的具体特点设计网络,通过充分利用图像的多尺度信息和特征融合技术,生成质量更高、视觉效果更佳的校正图像。

1.1 网络结构搭建

本文所提出的网络整体结构如图1所示。整个网络由3个主要部分构成:特征提取部分、特征融合及回归部

分和特征判别部分。特征提取部分的骨干网络为 DenseNet-121^[23],配合 FPN 结构进行特征融合回归,最终通过多尺度判别器对过程及结构特征进行判别。首先,将退化图像输入至特征提取网络 DenseNet-121 中,通过其逐步提取 5 种不同尺寸的特征图。后续将生成的特征图输入到 FPN 结构中,利用侧向连接增强深层语义和

底层细节。再将处理过的特征图进行上采样,以保留高语义信息的同时将低分辨率特征图恢复到原始输入图像的尺寸。随后进行特征融合,以获取不同尺度的丰富语义。最终通过对 3 个不同尺度的判别,对生成图像进行更加全面、细致的评估,逐步迭代以使模型生成接近理想的 CT 图像。




图 1 网络结构简图
Fig. 1 Network structure diagram

1.2 生成器模型

生成器模型采用 DenseNet-121 作为骨干网络,其是一种卷积神经网络架构,通过引入密集连接和特征重用的机制,在相对较少的参数量下实现了较好的性能,并缓解了梯度消失问题。
每一层都与前一层相连接,多个密集残差连接的卷积相互堆栈,提取图像特征,并在密集连接模块之间通过池化等操作来调整特征图尺寸,以增强特征传递并减少参数数量以改进网络性能,有助于模型捕捉细微的图像细节,具体骨干网络配置如表 1 所示。

表 1 骨干网络阶段结构与输出尺寸			
Table 1 Backbone network stage structure and output size			
名称	阶段	输出尺寸	骨干结构
DenseNet-121	特征提取层 1	256×256×64	Denseblock1
	特征提取层 2	128×128×256	Denseblock2
	特征提取层 3	64×64×512	Denseblock3
	特征提取层 4	32×32×1 024	Denseblock4
	特征提取层 5	16×16×2 048	归一层

FPN 结构主要功能在于通过 1 个自顶向下的架构与横向连接,使得网络能够在不同的解析度上获得丰富的语义信息。在生成器中,来自 DenseNet 不同层级的特征图可以通过 FPN 融合,使生成的图像不仅保持局部的详细信息,最终还得到一系列不同语义的高分辨率特征矩

阵。详细结构如图 2 所示,首先 Data 经过网络提取不同尺度的特征图 (Conv1, Conv2, Conv3, Conv4, Conv5),随后将通过 Lateral 层 (1×1 的卷积层) 进行处理。Lateral 层主要作用是减少卷积核的个数,帮助模型捕捉到丰富的局部和全局的伪影特征,同时也减少了特征图的通道数,但并不改变特征图的尺寸大小。利用像素间的加法进行结合,重复迭代该过程,生成中间层的特征图 (Map1, Map2, Map3, Map4, Map5),实现特征融合。特征金字塔网络结构在图像去伪影任务中起到了多尺度特提取、特征融合和注意力加强等作用,有效提高图像去伪影的质量。




图 2 生成器 FPN 结构
Fig. 2 FPN structure of generator

将混合注意力机制 (convolutional block attention module, CBAM)^[24] 融入到特征映射转换结构中,可以帮助网络在特征融合部分自适应地调整权重,以更好地捕捉不同尺度的特征,如图 3 所示。有助于网络更好地理解退化目标的形状和边缘信息,并增强其对重要特征的感知能力。其中参数 N 指的是语义分割的类别数,参数 S 指放大至原图的倍数。




图 3 特征映射转换结构简图

Fig. 3 Structural diagram of feature mapping transformation

1.3 多尺度判别器

多尺度判别器旨在对图像的不同尺度和级别进行判别,以提高对图像真实性的评估和辨别能力。这种设计对于处理伪影任务尤为重要,因为伪影可能会表现在不同尺度或层次上。此外,多尺度判别器通过在不同的分辨率层次上分析图像,能够识别出那些在单一尺度上可能不明显的细微伪影。与传统的单一尺度判别器相比,本文的多尺度判别器分别在 3 个尺度上对生成图像进行判别,在较小尺度中,大范围的结构性伪影可能更容易被检测,而在较大尺度中,细节层面的小伪影(如纹理不连续或边缘失真)则更易被识别。通过整合来自 3 个不同尺度的评估结果,多尺度判别器提高了对伪影的识别能力,增强了模型对于图像内容的理解,从而能够更精确地指导生成器进行图像的生成和修正。结合多尺度判别器的反馈信息,可以提供更加全面和丰富的图像真实性信息,这些信息有助于优化去伪影模型,更有效地修复或移除图像中的伪影。

1.4 混合损失函数

本文所提出网络的生成器损失函数由像素空间损失、感知损失和判别器损失 3 部分组成,其计算过程为:

$$L_G = 0.5 \times L_{p1} + 0.5 \times L_{p2} + 0.006 \times L_X + 0.01 \times L_{adv} \quad (1)$$

其中, L_p 为像素空间损失,这部分损失衡量了重建图像与目标图像在像素级别的差异,权重系数设置较高,因为精确匹配像素值对于视觉质量至关重要。 L_X 为感知距离损失^[25],根据平衡像素和视觉相似性设置其权重系数。 L_{adv} 为全局和局部判别器损失,权重系数的设定依赖于生成图像的真实性与多样性之间的权衡。权重的具体

数值通过交叉实验验证和基于特定任务的性能指标进行优化。为避免使用 L_p 产生过度平滑的像素空间输出,选用 L_{p1} 为 MSE, L_{p2} 为 SSIM,将该两项作为损失函数的一部分可以提高生成图像与真实图像之间的感知一致性。这意味着生成图像在视觉上更接近于真实图像,更符合人眼的感知。帮助模型在去除耦合伪影时更全面地优化图像质量。 L_X 作为“内容”损失的一种形式,与 L_2 距离相比,可以计算 VGG19^[26] Conv 3x3 特征映射上的欧几里得损失; L_{adv} 为全局和局部判别器损失,包含了多个尺度判别器的损失,充分利用图像的多尺度信息,从而提高对图像细节的恢复能力。

2 实验及结果分析

2.1 实验环境与参数设置

实验环境为 GPU: NVIDIA GeForce RTX 3090 显卡; CPU: AMD Ryzen 75800X 8-Core Processor。网络代码基于 Pytorch 框架,使用 Python 语言编写。训练优化器选择为 Adam 优化器,初始学习率设置为 0.000 1,从第 50 轮开始采用 linear 衰减策略,其调整因子设置为 0.13,学习率的最小值设置为 0.000 000 1;迭代次数为 3 000 次,批处理尺寸为 16,在模型训练中,每个 Epoch 都会使用验证集评估模型性能,并保存最佳模型和最终模型。

2.2 CBCT 耦合伪影数据集构建

1) 仿真数据集获取

目前,CBCT 图像普遍存在退化问题,因此实际实验中很难获得没有耦合伪影的高质量图像,故本文选择通过构建仿真数据来补充。首先构建仿真模型,并利用单能仿真算法得到模型的投影。然后,通过重建算法对该投影进行处理,得到单能情况下无伪影的切片图像,即为仿真理想图像。同时,结合散射场拟合的思想,通过单光栅探测散射数据获取散射场,以获得散射解析模型。对射线衰减规律进行分析,探析了射线穿越长度与透射投影的关系。对不同零件模型在单能投影上添加由散射伪影,硬化伪影和噪声组成的耦合伪影模型曲线,得到仿真耦合伪影图像。后续通过对实际耦合伪影图像的比对和侦测调整参数得到更逼近实际图像的仿真耦合伪影图像,该图像与仿真理想图像配对可以得到仿真数据集。本文构建了 16 个不同的模型,部分参数如表 2 所示。最终获得了 2 955 对图像。部分仿真数据集数据如图 4 所示。

2) 真实数据集获取

在实际的重建图像,几乎得不到理想图像。本此实验依托于 CT 扫描平台,对不同模型实际进行扫描,如图 5 所示展示了部分实际数据集模型。部分参数如表 3 所示,将进行滤波、散射等校正后的投影图像进行重建

表 2 仿真 CT 系统参数

Table 2 Simulation CT system parameters	
仿真参数	数值
源到探测器距离/mm	500
源到旋转中心距离/mm	50
投影幅数	360
重建算法	FDK
重建体数据大小	512×512×400
体素尺寸/mm	0.139 3×0.139 3




图 4 部分仿真数据集
Fig.4 Partial simulation dataset




图 5 部分实际数据集模型
Fig.5 Partial actual dataset models

表 3 实际 CT 系统参数

Table 3 Actual CT system parameters	
实际参数	数值
射线管电流/ mA	1.5
射线管电压/ kV	450
源到探测器距离/mm	1 220
源到旋转中心距离/mm	870
投影幅数	360
重建算法	FDK
重建体数据大小	1 024×1 024×800
体素尺寸/mm	0.139 3×0.139 3

得到的切片图像近似看作理想图像,将未做任何校正的投影图像重建得到的切片图像作为原始图像,2 种配对构成实际数据集。

在对不同材料的数据处理过程中可以发现,针对投影图像提取的灰度数据,形状和材质差异过大的零件其耦合伪影的拟合参数也存在微小差异,在切片图像如图 6 所

示。具体表现为:铝合金材质零件总体质量比不锈钢材质和高温合金材质的零件好;大面积实体零件相对于薄壁类零件中间区域耦合伪影更严重。其中铝合金材质工件的切片图像耦合伪影程度很小,即铝合金材质工件的耦合伪影切片几乎和校正后切片相同,所以在铝合金工件的实际图像上也人为添加了如仿真数据集中的耦合伪影,最终构成了实际数据集包含 14 个模型,3 650 对图像。




图 6 部分配对的实际校正图像和实际耦合伪影图像
Fig.6 Partial paired actual corrected image and coupled artifact image

对于深度学习来说,较大的数据集容量通常可以提供更多的样本和更多的变化,有助于网络更好地学习耦合伪影的特征和模式。

对于去耦合伪影网络,数据集应该包含各种伪影的类型和程度,以反映真实世界中的不同情况。如果数据集的分布不平衡或不够代表性,网络可能无法充分学习和处理特定类型的耦合伪影。因此,合理选择和设计数据集的分布且使其大小与网络容量相匹配对于去耦合伪影网络的性能至关重要,为保证模型在训练过程中接触到更多不同种类的数据,提高模型的适应能力;有效减少模型对特定数据集的过度依赖导致过拟合,从上述数据库中提取 1 000 对图像生成数据集,将仿真图像与实际图像按占比 7:3 输入,部分弥补两者的不足,利用彼此的优势进行互补,输入尺寸大小为 256×256。其中 80% 作为训练集,20% 用于验证集。为了增加模型的鲁棒性和泛化能力,采用了随机裁剪和缩放、水平翻转、灰度抖动等 7 种数据增强方式,数据增强概率设置为 0.5。

2.3 评价指标

本文选取峰值信噪比 (peak signal-to-noise ratio, PSNR) 和结构相似性 (structural similarity, SSIM) 2 个指标对重建结果进行评价。

1) 峰值信噪比

峰值信噪比通过均方差 (mean-square error, MSE) 来

定义,对两张大小为 $m \times n$ 的图像 I 和 K ,其均方差定义为:

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [I(i,j) - K(i,j)]^2 \quad (2)$$

峰值信噪比定义为:

$$PSNR = 10 \times \lg \left(\frac{MAX_f^2}{MS_E} \right) \quad (3)$$

$PSNR$ 的单位为分贝 (dB), $PSNR$ 的值越大,代表重建质量越好。

由于峰值信噪比没有考虑到图像结构的信息,有时 $PSNR$ 值很高,但实际效果并不好,因此还需要通过结构相似性结合评价图像质量。

2) 结构相似性

$SSIM$ 其不仅考虑到图像的像素值,还把图像的结构也考虑进来。 $SSIM$ 定义如下:

$$SSIM(X, Y) = L(X, Y) \times C(X, Y) \times S(X, Y) \quad (4)$$

其中, $\mu_X \cdot \mu_Y$ 分别表示图像 X 和图像 Y 的像素值均值; σ_X 和 σ_Y 表示图像 X 和图像 Y 的像素值的标准差, c_i 是 1 个常数,保证式中分母不为 0。 $SSIM$ 值介于 0~1 之

间,较高的值表明重建图像与原始图像的相似度更高,通常意味着图像重建的质量更优。

2.4 实验结果及分析

为证实提出方法在图像伪影校正方面的有效性,本文选取 ResNet101 和 U-NetSEResNeXt50^[27] 及 Restormer^[28] 这 3 种网络进行对比。由于仿真数据集有易于控制的退化因素,并便于进行大量实验以得出可靠结论,能够更准确地评估算法性能,故先在仿真数据集上进行实验对比。后续为了更全面地评估本文所提出算法的实际性能,选用了真实数据集进行实验。考虑到铝合金材料模型的耦合伪影较轻,难以有效评估方法的优越性,因此选择了不锈钢作为实验材料。不锈钢在实际扫描中常表现出严重的耦合伪影,所以通过该材质模型能够更准确地评估算法的性能。4 种方法的迭代次数均设置为相同,其他参数根据网络定义进行了适当调整。为了更好地观察图像的灰度信息、评估图像的细节和恢复效果,对以下模型进行了线性灰度图分析,如图 7 所示,分析位置为上述模型对比图像中横线所在位置。




图 7 仿真对比实验结果

Fig. 7 Simulation comparison experiment results

为比较模型复杂度与计算效率,对 4 种网络的模型总参数数量和每秒浮点计算进行了统计。如表 4 所示,本文方法在模型总参数数量上显著低于 U-NetSEResNeXt50 和 Restormer,仅略高于 Resnet101,表明其结构较为轻量。本文方法在每秒浮点计算方面也表现出较低的计算需求,远低于其他 2 种模型,说明本文方法有着较高的性能和推理效率。

表 4 网络模型总参数数量与每秒浮点计算				
Table 4 Total number of parameters in the network model and floating-point operations per second				
网络模型	Resnet101	U-NetSEResNeXt50	Restormer	本文方法
模型总参数数量	11 378 179	51 285 971	26 126 644	12 126 957
每秒浮点计算(G)	7.26	57.82	87.7	43.75

1) 仿真实验

仿真数据集评价指标对比如表 5 所示。综合分析表 5 和图 7 可知,对于仿真模型而言,尽管效果有所不同,Resnet101、U-NetSEResNeXt50、Restormer 以及本文提出的方法都能较为有效地校正退化。在伪影最严重的模型中,Restormer 和本文提出的方法能够较为彻底地消除耦合伪影,而 Resnet101 和 U-NetSEResNeXt50 仍然存在残余伪影,从图 8~10 中可以观察到,4 种深度学习方法均提高的图像整体亮度与对比度,有效的去除了图像的硬化效应,其中 Resnet101 的校正性能较 U-NetSEResNeXt50 差,而 Restormer 在部分区域出现了灰度抖动的情况,其灰度曲线与标签的灰度曲线仍不够贴近。在仿真复杂件模型和仿真叶片模型的对比图上可以观察到,Resnet101 和 U-NetSEResNeXt50 出现了模糊并丢失了孔边缘区域的一些细节,且 U-NetSEResNeXt50 出现了类似于模型崩溃的现象,而相较于 Restormer 方法,本文

表 5 仿真数据集评价指标对比				
Table 5 Comparison of evaluation indicators for simulation datasets				
网络模型	PSNR		SSIM	
	值/dB	提升/%	值	提升/%
伪影图像	15.088	/	0.399	/
U-NetSEResNeXt50	29.145	93.167	0.818	105.013
Resnet101	27.507	82.310	0.705	76.692
Restormer	36.327	140.768	0.953	138.847
本文方法	36.683	143.127	0.941	135.839




图 8 仿真齿轮模型线性灰度

Fig. 8 Linear grayscale image of simulated gear model




图 9 仿真复杂件模型线性灰度

Fig. 9 Linear grayscale image of simulated complex component model




图 10 仿真叶片模型线性灰度

Fig. 10 Linear grayscale image of simulated blade model

提出的方法校正后的图像更为清晰,实现了更高水平的伪影减少、准确性和更完整的细节表达。综上所述,与其他

方法相比,本文方法不仅有效去除了耦合伪影,还有效地恢复了图像的细节结构信息,从而提高了恢复的准确性。

2) 实际实验

从图 11 中可以清晰地观察到,本文提出的网络模型在去除实际模型中的耦合伪影任务上表现出了与仿真模型相当的效果。恢复的图像质量接近理想图像,并且在保留工件边界信息方面显示出了显著的优势。由表 6 分析可知,相较于其他方法,采用本文提出的方法恢复的图像更为清晰、灰度更为均匀,对比度也有显著提升。与仿

真实验数据不同的是,本文方法在实际图像的数值校准方面表现出了出色的性能。从图 12~14 中来看,实际的耦合伪影图像具有复杂的成分、边缘对比度差以及严重的伪影。虽然一般方法改善了对比度,但也引入了大量噪声和新的伪影。相比于 Resnet、U-NetSEResNeXt50 和 Restormer 方法,本文所述的方法整体修正效果更好,同时噪声也得到了有效消除,也未出现过度平滑的问题,本文方法具有更为清晰的边缘轮廓定义、增强的图像对比度以及更为均匀的灰度。




图 11 实际对比实验结果

Fig. 11 Actual comparative experimental results




图 12 实际齿轮模型线性灰度

Fig. 12 Linear grayscale image of real gear model




图 13 实际多面体模型线性灰度

Fig. 13 Linear grayscale image of real polyhedral model




图 14 实际叶片模型线性灰度

Fig. 14 Linear grayscale image of real blade model

表 6 实际数据集评价指标对比

Table 6 Comparison of evaluation indicators for actual datasets

网络模型	PSNR		SSIM	
	值/dB	提升/%	值	提升/%
伪影图像	16.517	/	0.630	/
U-NetSEResNeXt50	28.412	72.017	0.722	14.603
Resnet101	26.537	60.665	0.698	10.794
Restormer	28.004	69.547	0.869	37.937
本文方法	30.589	85.197	0.904	43.493

3 结 论

针对目前 CBCT 耦合伪影去除中数据集不充分、训练困难等和恢复效果不佳等问题,提出了一种基于多尺度的 CBCT 图像退化校正网络模型。该模型将 FPN 结构融入到生成器中,有助于网络更好地分析并提取图像多层特征,同时混入注意力机制,帮助网络关注特定信息。此网络结构有效提升了去除伪影和退化恢复的能力。

经仿真和实际实验验证,本文提出的方法不仅在主观视觉效果和客观评价指标上均优于现有的几种耦合伪影去除算法,表现出较强的伪影去除能力,且能有效消除工件的耦合伪影和噪声,同时保证几何尺寸和轮廓边缘的准确性,更好地恢复图像的细节信息。然而,由于网络模型较为庞大,导致网络训练速度稍慢,需要进一步缩短训练时间。因此,在后续的研究中,需要在保证恢复效果的同时优化网络结构,提高模型的收敛速度。同时,还将尝试建立一个完善的工业零件 CT 图像数据库,以更客观地评价不同的校正方法。

参考文献

[1] 谭川东,何泳江,罗雪清,等. 基于邻层数据匹配的工业 CT 图像生成 G 代码方法[J]. 仪器仪表学报, 2021,42(4):265-274.
TAN CH D, HE Y J, LUO X Q, et al. A G code generation method of industrial CT image based on data matching between layers [J]. Chinese Journal of Scientific Instrument, 2021,42(4):265-274.
[2] 杨富强,杨瑶,李志翔,等. X 射线工业 CT 成像过程复杂伪影抑制方法综述[J]. 自动化学报,2023,49(4): 687-704.
YANG F Q, YANG Y, LI ZH X, et al. Review of complex artifact reduction methods for industrial

- computerized tomography imaging[J]. *Acta Automatica Sinica*, 2023, 49(4):687-704.
- [3] LI K, DONA D G C, LUBNER M G, et al. Imaging task-based optimal kV and mA selection for CT radiation dose reduction: From filtered back projection (FBP) to statistical model based iterative reconstruction (MBIR) [C]. *Medical Imaging 2015*, 2015: 94121M.
- [4] ZHAO W, VERNEKOHL D, ZHU J, et al. A model-based scatter artifacts correction for cone beam CT[J]. *Medical Physics*, 2016, 43(4):1736-1753.
- [5] 张文君, 黄钢, 丁海宁, 等. 基于深度学习的医用锥形束 CT 图像散射伪影校正的研究进展[J]. *CT 理论与应用研究*, 2023, 32(2):285-296.
- ZHANG W J, HUANG G, DING H N, et al. Research progress of scattering artifact correction in medical cone-beam computed tomography imaging based on deep learning[J]. *CT Theory and Applications*, 2023, 32(2): 285-296.
- [6] 吴志宏, 丛鹏, 刘锡明. 基于重投影的 CT 图像硬化伪影校正[J]. *原子能科学技术*, 2015, 49(5):935-938.
- WU ZH H, CONG P, LIU X M. Beam hardening artifact correction in CT based on re-projection [J]. *Atomic Energy Science and Technology*, 2015, 49(5):935-938.
- [7] MEYER E, RAUPACH R, LELL M, et al. Normalized metal artifact reduction (NMAR) in computed tomography[J]. *Medical physics*, 2010, 37(10):5482-5493.
- [8] VELDKAMP W J H, JOEMAI R M S, VANDER MOLEN A J, et al. Development and validation of segmentation and interpolation techniques in sinograms for metal artifact suppression in CT[J]. *Medical Physics*, 2010, 37(2):620-628.
- [9] KRATZ B, WEYERS I, BUZUG T M. A fully 3D approach for metal artifact reduction in computed tomography[J]. *Medical Physics*, 2012, 39(11):7042-7054.
- [10] BAL M, CELIK H, SUBRAMANYAN K, et al. A radial adaptive filter for metal artifact reduction[C]. *Medical Imaging*, 2005, 5747:2075-2082.
- [11] ZHANG Y B, MOU X Q. Metal artifact reduction based on beam hardening correction and statistical iterative reconstruction for X-ray computed tomography [C]. *Medical Imaging 2013*, 2013, 866820.
- [12] MOUTON A, MEGHERBI N, VAN SLAMBROUCK K, et al. An experimental survey of metal artefact reduction in computed tomography[J]. *Journal of X-ray Science and Technology*, 2013, 21(2):193-226.
- [13] XIANG H W, LIM H K, FESSLER J A, et al. A deep neural network for fast and accurate scatter estimation in quantitative SPECT/CT under challenging scatter conditions[J]. *European Journal of Nuclear Medicine and Molecular Imaging*, 2020, 47(13):2956-2967.
- [14] JIANG Y K, YANG CH L, YANG P F, et al. Scatter correction of cone-beam CT using a deep residual convolution neural network (DRCNN) [J]. *Physics in Medicine & Biology*, 2019, 64(14):145003.
- [15] HANSEN D C, GUILLAUME L, FLORIAN K, et al. ScatterNet: A convolutional neural network for cone-beam CT intensity correction [J]. *Medical Physics*, 2018, 45(11):4916-4926.
- [16] YUSUKE N, XU Q, HIROKI S, et al. Projection-domain scatter correction for cone beam computed tomography using a residual convolutional neural network[J]. *Medical Physics*, 2019, 46(7):3142-3155.
- [17] 马燕, 余海军, 钟发生, 等. 基于残差编解码网络的 CT 图像耦合伪影校正[J]. *仪器仪表学报*, 2020, 41(8): 160-169.
- MA Y, YU H J, ZHONG F SH, et al. CT metal artifact reduction based on the residual encoder-decoder network [J]. *Chinese Journal of Scientific Instrument*, 2020, 41(8):160-169.
- [18] 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.
- [19] GOMI T, SAKAI R, HARA H, et al. Usefulness of a metal artifact reduction algorithm in digital tomosynthesis using a combination of hybrid generative adversarial networks[J]. *Diagnostics*, 2021, 11(9):11091629.
- [20] MIRZA M, OSINDERO S. Conditional generative adversarial nets [J]. *ArXiv preprint arXiv:1411.1784*, 2014.
- [21] DOLLÁR P, APPEL R, BELONGIE S, et al. Fast feature pyramids for object detection [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2014, 36(8):1532-1545.
- [22] SU J W, XU B Y, YIN H J. A survey of deep learning approaches to image restoration [J]. *Neurocomputing*,

2022, 487:46-65.

- [23] HUANG G, LIU ZH, VANDER MAATEN L, et al. Densely connected convolutional networks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017:2261-2269.
- [24] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018:3-19.
- [25] LEDIG C, THEIS L, HUSZÁR F, et al. Photo-realistic single image super-resolution using a generative adversarial network [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017:105-114.
- [26] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. ArXiv preprint arXiv:1409.1556, 2014.
- [27] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018:7132-7141.
- [28] ZAMIR S W, ARORA A, KHAN S, et al. Restormer: Efficient transformer for high-resolution image restoration[C]. 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022:5728-5739.

作者简介



柴世杰, 2018 年于西北工业大学获得学士学位, 现为西北工业大学硕士研究生。主要研究方向为深度学习, 图像质量优化。

E-mail: chaishijie@mail.nwpu.edu.cn

Chai Shijie received his B. Sc. degree from

Northwestern Polytechnical University in 2018. He is currently a master student at Northwestern Polytechnical University. His main research interest is deep learning and image quality optimization.



黄魁东 (通信作者), 2009 年于西北工业大学获得博士学位, 现为西北工业大学副教授, 主要研究方向为锥束 CT 理论和应用、计算机图形图像处理。

E-mail: kdhuang@nwpu.edu.cn

Huang Kuidong (Corresponding author)

received his Ph.D. degree from Northwestern Polytechnical University in 2009. Now he is an associate professor in Northwestern Polytechnical University. His main research interests include cone-beam CT theory and application, computer graphics and image processing



杨富强, 现为西北工业大学航空发动机高性能制造工业实验室副研究员。主要研究方向为先进无损检测, CT 智能装备和图像处理算法。

E-mail: fqyang@nwpu.edu.cn

Yang Fuqiang is an associate researcher at the Key Laboratory of High Performance Manufacturing for Aero Engine, Northwestern Polytechnical University. His research interest is advanced CT nondestructive testing, CT intelligent equipment and image processing.



赵举龙, 现为西北工业大学硕士研究生。主要研究方向为深度学习, 超分辨率成像。

E-mail: jlzhao@mail.nwpu.edu.cn

Zhao Julong is currently a master student at Northwestern Polytechnical University. His main research interest is deep learning and super-resolution image reconstruction.