

DOI:10.19651/j.cnki.emt.2520264

基于深度学习的叶片X射线图像降噪^{*}侯昕盟¹ 杨光² 曾凤英² 赵纪元¹ 鲁思朋¹

(1.北京信息科技大学自动化学院 北京 100192; 2.中国航发四川燃气涡轮研究院 成都 610500)

摘要:针对航空发动机转子叶片X射线图像中噪声多、边缘较模糊等问题,提出了一种噪声自注意力(NSA)双解码器图像降噪网络,能有效提升图像质量。本研究的网络在编码器和解码器之间引入噪声自注意力机制,增强了网络在噪声干扰下对图像特征的感知能力。网络采用双解码器结构,分别对图像进行降噪和边缘保持,并利用可学习门控融合机制整合双解码器的输出,使网络最终的结果同时抑制了噪声并保持了叶片的边缘结构。实验结果表明,所提方法对转子叶片X射线图像降噪的视觉效果均优于对比算法,峰值信噪比(PSNR)和结构相似性(SSIM)分别达到33.26 dB和0.883 7,证明了所提方法的有效性,为航空发动机叶片检测提供了可靠的X射线图像降噪方案。

关键词:深度学习;图像降噪;X射线图像;自注意力机制

中图分类号: TP391.4; TN06 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Blade X-ray image denoising based on deep learning

Hou Xinmeng¹ Yang Guang² Zeng Fengying² Zhao Jiyuan¹ Lu Sipeng¹

(1. School of Automation, Beijing University of Information Technology, Beijing 100192, China;

2. China Aviation Sichuan Gas Turbine Research Institute, Chengdu 610500, China)

Abstract: To address the issues of excessive noise and blurred edges in X-ray images of aero-engine rotor blades, this paper proposes a noise self-attention (NSA) dual-decoder image denoising network, which effectively enhances image quality. The network introduces a noise self-attention mechanism between the encoder and decoder to strengthen the perception of image features under noise interference. A dual-decoder structure is adopted to perform denoising and edge preservation separately, and a learnable gated fusion mechanism integrates the outputs of the two decoders, enabling the final result to simultaneously suppress noise and preserve blade edge structures. Experimental results demonstrate that the proposed method outperforms comparative algorithms in visual effects for denoising rotor blade X-ray images, achieving a peak signal-to-noise ratio (PSNR) of 33.26 dB and a structural similarity index (SSIM) of 0.883 7, proving the effectiveness of the proposed approach and providing a reliable X-ray image denoising solution for aero-engine blade inspection.

Keywords: deep learning; image denoising; X-ray image; self-attention mechanism

0 引言

X射线数字成像(digital radiography, DR)检测技术是一种实用的无损检测技术,被广泛应用于飞机、火箭、导弹发动机的检测等方面^[1]。飞机发动机的涡轮转子叶片在高温高压的工作环境下容易发生损坏,影响发动机的正常运行。故采用X射线数字成像检测技术对航空发动机转子叶片进行检测和分析。但由于检测设备引入的量子噪声、电子噪声以及环境噪声等的影响^[2],X射线数字成像检测设备所获得的叶片X射线图像存在噪声多、成像模糊等问

题,图像的质量较差,难以对航空发动机进行准确的检测和分析。

用于优化X射线图像质量的传统降噪方法^[3]主要分为3类:1)基于正弦图滤波技术,包括均值滤波、高斯滤波、中值滤波和双边滤波等,其计算复杂度低,易于实现,但易导致边缘模糊,细节信息丢失,难以适应不同X射线检测设备或扫描条件;2)基于迭代重建技术的降噪方法,包括全变分^[4]、非局部均值^[5]和字典学习^[6]等,该类方法伪影校正能力强,能够提高图像分辨率,但数据计算量大,受到设备性能参数限制;3)图像域后处理降噪技术,包括非局部均值

收稿日期:2025-11-22

^{*} 基金项目:国家自然科学基金面上项目(51975452)、高能X射线投影图像优化技术研究项目(GJCZ-0202-2024-0002)资助

滤波(non-local means filter, NLMF)^[7]和三维块匹配(block matching 3D, BM3D)^[8]等,这类方法通用性强,实时性好,但可能会造成图像过度平滑和边缘假象。

随着深度学习的发展,其在X射线图像降噪领域取得了显著成果。基于卷积神经网络(convolutional ceural networks, CNN)的方法利用其强大的特征提取能力,通过学习图像信息并结合不同网络结构与损失函数来优化降噪效果。Zhang等^[9]提出了Dn-CNN(denoising convolutional neural networks)模型,结合残差学习和批量归一化,有效处理噪声并提升训练效率。Chen等^[10]提出了RED-CNN(residual encoder-decoder convolutional neural network)模型,将自动编码器、反卷积网络和快捷连接集成于统一框架,引入跨层快捷连接实现残差学习,缓解了梯度消失问题。

近年来,U-Net结构^[11]已广泛应用于端到端图像处理。为提升其性能,研究者提出了多种改进策略。Fan等^[12]提出了SUNet(swin transformer U-net)模型,将Swin Transformer作为基础模块嵌入U-Net,利用其全局建模能力增强特征表达能力,在自然图像的降噪任务表现较好,但网络结构复杂,计算复杂度较高。Wang等^[13]提出了DER-UNet(dual-encoder residual Unet)模型,针对图像中高斯噪声与条纹噪声的尺度差异,设计双编码器分别提取不同感受野下的噪声特征,能有效处理高斯与条纹复合噪声,但未在解码阶段实现任务解耦,且在X射线图像中对于细节结构的保持仍有不足。Liu等^[14]提出了RA-UNet(residual convolutional block attention module Unet)模型,集成多尺度残差卷积块和注意力机制进行图像降噪,缓解了深层网络训练中的退化问题。但该方法没有显式区分图像内容与噪声特征,注意力机制计算可能被强噪声区域干扰,从而影响对细节的恢复。

上述方法虽在各自的图像降噪任务中取得进展,但在处理航空发动机叶片X射线图像这种图像质量差、噪声多、边缘较模糊的场景中,这些模型的效果仍不尽人意,具体表现在对叶片X射线图像噪声区域的感知能力不足,且解码结构单一,难以兼顾噪声抑制与边缘保持。

为此,提出了一种用于航空发动机转子叶片X射线图像降噪的噪声自注意力双解码器网络NSADDU-Net(noise self-attention dual decoder Unet),在继承U-Net多尺度编码优势的基础上,在颈部层引入噪声自注意力(noise self-attention, NSA)模块,通过噪声强度图动态调整注意力权重,增强对高噪声区域的特征提取;设计降噪解码器与边缘保持解码器,分别实现噪声抑制与结构保持,并通过可学习门控融合(learnable fusion)模块自适应整合输出;在边缘保持解码器中引入可学习Sobel算子,强化叶片轮廓等信息。与现有U-Net改进模型相比,NSADDU-Net将NSA与双解码器(dual decoder)相结合,有效提升了航空发动机转子叶片X射线图像质量。

1 方 法

1.1 降噪模型总体结构

本文针对转子叶片X射线图像降噪问题提出了NSA双解码器U-Net网络NSADDU-Net,该网络是端到端的降噪模型。网络整体结构如图1所示,主要由以下4个核心模块构成,分别为编码器模块、NSA模块、双解码器模块和可学习门融合模块。

该网络的降噪流程为带噪X射线图像经编码器逐层下采样,提取多尺度特征;所得高维特征经NSA模块增强后,并行输入至双解码器;降噪解码器重建降噪图像,边缘保持解码器通过Sobel算子^[15]增强跳连机制强化边缘结构;双解码器输出经可学习门控融合模块生成最终降噪结果。

1.2 编码器

编码器是整个模型的特征提取基础,其任务是从输入的 256×256 pixels的转子叶片X射线图像中,通过逐级下采样逐步提取高维特征,其结构如图2所示。

编码器模块包含4级下采样编码器,每级编码器采用“双卷积-最大池化”单元顺序堆叠而成。采用 3×3 卷积核进行特征提取,这种尺寸在计算效率和特征捕获能力之间取得了良好平衡。每个双卷积模块包含两层 3×3 卷积,第1层 3×3 卷积的感受野为 3×3 ,第2层 3×3 卷积在此基础上将感受野扩展至 5×5 。这种递进式的感受野扩大机制使网络能够从局部像素关系逐步构建更加全局的特征表示。每层卷积后均使用ReLU激活函数^[16]引入非线性变换,旨在通过两次非线性映射增强模型的特征判别能力。编码器通过最大池化操作实现空间下采样,每次池化将特征图尺寸减半,同时使感受野呈指数级增长。经过四级下采样操作,最终颈部层(Neck)的感受野覆盖了输入图像的较大区域,使网络能够整合充分的上下文信息来区分噪声与真实结构。

1.3 噪声自注意力机制

尽管卷积神经网络在图像降噪中表现出色,但其依赖的卷积操作存在固有局限:卷积核的局部加权平均特性使其倾向于优先学习低频特征,在处理高频噪声较多的X射线图像时,容易导致边缘等关键结构信息丢失^[17]。这一问题在转子叶片检测中尤为突出,因为叶片边缘等高频细节对缺陷识别至关重要。为突破这一限制,自注意力机制通过强化关键特征,为卷积神经网络的改进提供了新思路^[18]。然而,传统自注意力机制在噪声环境中可能过度关注清晰区域,而忽视噪声干扰下的重要特征。故本文提出了一种NSA方法。该方法通过为转子叶片X射线图像的噪声区域分配更高注意力分数,使模型能够聚焦于这些区域中的关键特征。NSA模块结构如图3所示。

NSA模块的输入为U-Net网络颈部的输出,是一个 $C \times H \times W$ 特征图,即 $\mathbf{X} \in \mathbf{R}^{C \times H \times W}$ 。




图 1 NSADDU-Net 总体结构

Fig. 1 The overall framework of NSADDU-Net




图 2 编码器模块

Fig. 2 Encoder module

其中, C 表示通道数, H 和 W 分别表示特征图的垂直像素尺寸和水平像素尺寸。

首先,对特征图进行处理得到噪声强度图 (noise intensity map, NIM)。当图像局部存在噪声时,其像素值与常规图像相比会急剧变化。本文的噪声图生成过程基

于局部统计量估计。如式(1)、(2)所示,先对特征数据进行 3×3 平均池化,得到局部均值图 μ , 随后计算每个位置与邻域均值的平方差,再对平方差图再做一次同样的平均池化,得到局部方差,最后再开方得到与模块输入同分辨率的噪声强度图 σ 。该图在通道间独立计算,因此每一通




图 3 噪声自注意力模块

Fig. 3 NSA module

道都拥有一张反映“局部起伏强度”的噪声强度图。

$$\mu = \text{AvgPool}_{3 \times 3}(\mathbf{X}) \quad (1)$$

$$\sigma = \sqrt{\text{AvgPool}_{3 \times 3}((\mathbf{X} - \mu)^2)} \quad (2)$$

式中: $\text{AvgPool}_{3 \times 3}()$ 表示 3×3 平均池化, μ 表示局部均值图, σ 表示噪声强度图。

然后使用 1×1 卷积分别对输入的特征图和噪声强度图处理,使用特征图生成 $\mathbf{Q}$ 、 $\mathbf{K}$ 、 $\mathbf{V}$ 集,同时使用噪声强度图生成 $\mathbf{Q}_n$ 集。接着分别计算特征图的标准自注意力得分和噪声强度图的噪声自注意力得分。为了增强模型捕获不同类型依赖关系的能力,将特征维度分组为多个头,设注意力头数为 h ,则维度 $d = C/h$ 。这使得每个头都能学习不同的注意力模式,不同的头部也能够关注不同的空间结构和噪声特征。在计算每个头的注意力后,将来自不同头的信息聚合成统一的特征表示,确保不同的注意力模式有助于最终的特征图。将两份得分按可学习权重 γ 进行加权融合,并在融合结果上执行归一化操作,得到噪声自注意力权重矩阵,如式(3)~(5)所示。

$$\mathbf{A}_x = \frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d}} \quad (3)$$

$$\mathbf{A}_n = \frac{\mathbf{Q}_n\mathbf{K}^T}{\sqrt{d}} \quad (4)$$

$$\mathbf{A} = \text{softmax}(\mathbf{A}_x + \gamma\mathbf{A}_n) \quad (5)$$

式中: $\mathbf{A}_x$ 表示特征图的标准自注意力得分, $\mathbf{A}_n$ 表示噪声强度图的噪声自注意力得分, $\mathbf{A}$ 表示噪声自注意力权重矩阵, T 表示矩阵转置。 γ 是可学习的权重,它决定需要将多少比例的噪声注意力分数添加到标准注意力分数中以获得理想的降噪性能。

最后,使用噪声自注意力权重矩阵 $\mathbf{A}$ 对 $\mathbf{V}$ 进行矩阵相

乘得到加权特征,并恢复通道维度,最终通过残差形式输出增强特征,如式(6)、(7)所示。

$$\mathbf{Z} = \mathbf{A}\mathbf{V} \quad (6)$$

$$\mathbf{X}_{\text{NSA_out}} = \mathbf{X} + \mathbf{Z} \quad (7)$$

式中: $\mathbf{Z}$ 表示加权特征, $\mathbf{X}_{\text{NSA_out}}$ 表示 NSA 模块输出的增强特征。

1.4 双解码器

解码器的任务是将通过 NSA 模块增强的特征信息重建为高质量的降噪图像。针对转子叶片 X 射线图像中的噪声去除与结构保持需求,本文设计了双解码器架构,即降噪解码器和边缘保持解码器,实现了噪声抑制与边缘保持的并行处理。

降噪解码器结构如图 4 所示。降噪解码器首先接收 NSA 模块的增强特征,通过步长为 2 的转置卷积逐级上采样,每级后接两层 3×3 卷积和 ReLU 激活函数。第 1 层解码器将分辨率升至 32×32 同时将通道减至 512;后续 3 层继续使用转置卷积串联,逐步将分辨率提升至 64×64 、 128×128 和 256×256 ,同时将通道分别减少至 256、128 和 64。同级编码器特征经跳跃连接拼接,补偿低频信息,最终输出基础降噪图像。

边缘保持解码器结构如图 5 所示。边缘保持解码器保持与降噪解码器路径对称的空间-通道尺寸,但将每级的跳连中引入可学习的 Sobel 增强跳连。这种设计使网络能够增强叶片边缘结构,同时保持与降噪解码器的架构一致性。

设第 L 级解码器上采样输出为 $\mathbf{F}_L$,同级编码器跳连特征为 $\mathbf{S}_L$ 。采用固定 3×3 Sobel 核提取梯度幅值 $\mathbf{G}_L$,如式(8)、(9)所示。通过逐层可训练标量 α_L 残差式叠加到跳连特征,得到 Sobel 增强跳连特征 $\bar{\mathbf{S}}_L$,使叶片边缘细节




图 4 降噪解码器模块

Fig. 4 Denoise decoder module




图 5 边缘解码器模块

Fig. 5 Edge decoder module

等高频特征得到增强,如式(10)所示。该操作仅在边缘保持解码器启用,确保降噪解码器不受梯度扰动。

$$\left\{ \begin{array}{l} \mathbf{V}_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \\ \mathbf{V}_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \end{array} \right. \quad (8)$$

$$\mathbf{G}_L = |\mathbf{V}_x + \mathbf{F}_L| + |\mathbf{V}_y + \mathbf{F}_L| \quad (9)$$

$$\bar{\mathbf{S}}_L = \mathbf{S}_L + \alpha_L \mathbf{G}_L \quad (10)$$

式中: $\mathbf{V}_x$ 表示水平方向的 Sobel 算子; $\mathbf{V}_y$ 表示水平方向的 Sobel 算子; α_L 表示可训练的标量。

1.5 可学习融合输出

为协同利用降噪解码器与边缘保持解码器的输出优势,本文设计了一个可学习融合模块。该模块的核心在于能够自适应地学习权重分布,从而实现降噪效果与边缘保持的最佳平衡。模块结构如图 6 所示,具体实现如下。

可学习融合模块将前述双解码器的输出作模块的输入。设降噪解码器输出为 $\mathbf{F}_{\text{denoise}}$, 边缘保持解码器的输出为 $\mathbf{F}_{\text{edge}}$, 将两路输出在通道维度拼接成 128 通道张量 $\mathbf{F}_{\text{concat}}$ 。接着通过两层 3×3 卷积和 ReLU 函数压缩回 64 通道,使用 sigmoid 函数,生成单通道门控值 G , 确保门控值在 $0 \sim 1$, 实现空间自适应权重分配。随后进行像素级加权融合。为保留降噪解码器的灰度基准,融合结果再通




图 6 可学习融合模块

Fig. 6 Learnable fusion module

过 1×1 卷积并与 F_{edge} 做残差相加, 输出模型的最终降噪图像 X_{out} , 如式(11)、(12)所示。

$$F_{\text{fused}} = GF_{\text{edge}} + (1 - G)F_{\text{denoise}} \quad (11)$$

$$X_{\text{out}} = F_{\text{denoise}} + \text{Conv}_{1 \times 1}(F_{\text{fused}}) \quad (12)$$

1.6 损失函数

为兼顾图像降噪效果和叶片边缘保持, 本文在模型训练阶段采用一种复合损失函数, 如式(13)所示。

$$L_{\text{loss}} = L_{\text{RMSE}} + \lambda \cdot L_{\text{Grad}} \quad (13)$$

式中: L_{RMSE} 是像素级 L2 范数, 即均方根误差, L_{Grad} 是边缘差分 L1 正则项, 权重 λ 设为 0.01。

L_{RMSE} 定义为均方根误差, 如式(14)所示。

$$L_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \hat{x}_i)^2} \quad (14)$$

式中: x_i 为图像像素, $\hat{x}_i$ 为模型输出图像像素。RMSE 对较大误差平方惩罚更重。

L_{Grad} 源于梯度差分损失 (gradient difference loss, GDL)^[19], 本文将其嵌入损失函数。

$$L_{\text{Grad}} = \| |\nabla \mathbf{x}| - |\nabla \hat{\mathbf{x}}| \|_1 \quad (15)$$

式中: $\nabla \mathbf{x}$ 表示图像 x 的空间梯度向量场; $\nabla \hat{\mathbf{x}}$ 表示模型输出图像 $\hat{x}$ 的空间梯度向量场。

梯度计算采用 2 方向一阶前向差分:

$$|\nabla \mathbf{x}| = |x_{i,j} - x_{i+1,j}| + |x_{i,j} - x_{i,j+1}| \quad (16)$$

通过复合损失函数的约束, 模型能够抑制 X 射线图像中的噪声, 同时保留叶片边缘等细节, 为叶片检测提供良好图像基础。

2 实验设计

2.1 实验数据集的构建

深度学习降噪算法的训练需要通过大量数据进行有

监督的学习。本文中使用的发动机转子叶片 X 射线图片由中国航发四川涡轮研究院^[20]的高能 X 射线设备提供。由于该设备采集到的图片数据存在较多重复, 需要对采集到的数据进行数据增强^[21], 降低模型过拟合风险。

首先, 对研究所提供的数据集中随机选取分辨率为 256×256 pixels 的 200 张图像作为原始数据集, 如图 7 所示。然后对 200 张图像进行多角度反转、镜像、平移和缩放, 每张图片随机选取 1~4 种增强操作, 如图 8 所示, 获得一个包含 2 000 张图像的增强数据集。最后, 数据集按照 70% 训练、15% 验证、15% 测试进行划分, 验证集用于评估模型训练过程中的训练质量, 测试集用于测试模型输出降噪图像的质量。




图 7 原始数据集

Fig. 7 Original dataset




图 8 数据集增强

Fig. 8 Dataset enhancement

2.2 实验环境和参数设置

本文的实验环境如表 1 所示,实验参数设置如表 2 所示。

表 1 实验环境

Table 1 Experimental environment

实验设备	类型/版本号
CPU	Intel Core i9-13900K
GPU	NVIDIA GeForce RTX 3090×2
开发环境	Windows11
Python	3.9
Pytorch	2.7
Cuda	12.6
Torchvision	0.22.0

表 2 实验参数设置

Table 2 Experimental parameter settings

参数类型	参数
图像尺寸	256×256 pixels
优化器	Adam
批量大小	8
起始学习率	0.000 1
迭代次数	50
学习率调整方式	分阶段减半策略

2.3 评价指标

在 X 射线图像降噪领域,通常使用峰值信噪比 (peak signal-to-noise ratio, PSNR) 和结构相似性 (structural similarity index for measuring image quality, SSIM)^[22] 来量化模型的降噪效果。

PSNR 通过比较对应像素点间的均方误差 (mean squared error, MSE) 来度量降噪图像与原始图像之间的失真情况,其值越大表示降噪后图片质量越好,计算公式为:

$$P_{\text{PSNR}} = 10 \cdot \lg(\frac{E_{\text{max}}^2}{E_{\text{MSE}}}) = 20 \cdot \lg(\frac{E_{\text{max}}}{\sqrt{E_{\text{MSE}}}}) \quad (17)$$

式中: E_{max} 表示整张图像中的最大的像素值, E_{MSE} 表示均方误差。

SSIM 从亮度、对比度和结构 3 方面度量两幅图像的相似性,更符合人眼视觉特性。其值越接近于 1 则表示这两幅图像越相似,计算公式为:

$$S_{\text{SSIM}}(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (18)$$

式中: x 表示原始图像, y 表示模型降噪后的图像。 μ_x 和 μ_y 表示图像灰度值的均值, σ_x 和 σ_y 表示图像灰度值的标准差, σ_{xy} 表示 x 和 y 的协方差, C_1 和 C_2 表示防止公式除零的小常数。

3 实验结果与分析

3.1 消融实验

为了验证本文提出的 NSA 模块、双解码器和可学习

融合模块的有效性,本文设计了消融实验来对比验证。通过控制变量法,在发动机转子叶片 X 射线图像数据集上开展了详细的消融实验,对比分析了不同模块组合对模型性能的影响。消融实验结果如表 3 所示。

表 3 消融实验结果

Table 3 Ablation experimental results

NSA	Dual Decoder	Learnable fusion	PSNR/dB	SSIM
			29.95	0.843 7
	✓		30.63	0.845 3
	✓	✓	31.72	0.851 6
✓			32.37	0.857 4
✓	✓		32.78	0.879 2
✓	✓	✓	33.26	0.883 7

注:粗体值表示每种情况下的最高分数

从表 3 中可看出,基准 U-Net 模型取得了 PSNR 29.95 dB、SSIM 0.843 7,其降噪能力有限,图像边缘结构保持不足。引入双解码器后,PSNR 与 SSIM 均提升,表明该结构能有效兼顾噪声抑制与边缘保持。引入双解码器的同时进一步添加可学习融合模块,性能继续改善,证明自适应融合策略能优化双路输出。单独使用 NSA 模块即可大幅提升指标,说明噪声感知机制能增强对噪声区域的特征提取。结合 NSA 与双解码器产生协同效应,PSNR 与 SSIM 进一步提升。

完整的模型达到了最优性能,PSNR 为 33.26 dB, SSIM 为 0.883 7。与基准模型相比,PSNR 提升了 3.31 dB, SSIM 提升了 0.04。消融实验表明每个模块都是不可或缺的,它们的共同作用最终使模型在抑制噪声和保持叶片边缘结构方面达到了最佳效果。

3.2 与其他算法对比

为进一步验证评估本文所提出的降噪模型的有效性,本文选择了 5 种不同的降噪方法进行对比实验:传统降噪算法 BM3D、基于编-解码的 RED-CNN 降噪网络、基础的 Unet 模型、具有双编码器结构的 DER-UNet 降噪模型、集成残差卷积和注意力机制的 RA-UNet 降噪模型和本文提出的方法进行了比较和分析。

1) 实验结果的视觉分析

选取数据集中几个典型图片作为样本,展示对比算法和本文提出的算法在测试集上的降噪结果,降噪结果对比如图 9、10 所示,重点关注的结构部位已使用方框标出。

从图 9 和 10 可以看出,传统降噪方法 BM3D 在抑制噪声方面效果有限,降噪后图像仍残留明显噪声,且叶片边缘模糊,细节丢失严重。RED-CNN 和基础 UNet 方法相比传统降噪方法 BM3D 在噪声抑制上有所改善,但容易导致图像过度平滑,在图 10 的机匣薄壁结构处尤为明显。




图 9 多级叶片结构 X 射线图像降噪效果对比

Fig. 9 Comparison of denoising effects for multi-stage blades structure X-ray images




图 10 单级叶片和机匣 X 射线图像降噪效果对比

Fig. 10 Comparison of denoising effects for single-stage blade and casing X-ray images

DER-UNet 通过双编码器处理复合噪声,在均匀噪声区域表现尚可,但对于叶片 X 射线图像中强度变化的噪声和复杂边缘,其保护能力有限,边缘存在残留噪声与模糊。RA-UNet 引入的注意力机制提升了模型的降噪性能,整体画面更干净,但在图 9 中叶片重叠处高噪声区域的边缘保持仍不理想,局部有细节损失。

通过视觉效果对比,可以看出本文所提方法在视觉上

取得了最佳效果。一方面,它能有效抑制图像中各区域的噪声,画面整体更干净;另一方面,叶尖及机匣结构等关键边缘清晰,细节保留完整。这证明了噪声自注意力机制能有效聚焦于噪声干扰区域进行特征增强,而双解码器与可学习融合设计则成功实现了降噪与边缘保持这两个子任务的协同优化,为后续的叶片检测和状态评估提供了高质量的图像基础。

2) 实验结果的定量分析

表 4 为本文提出的模型与对比算法在测试集上的定量对比结果。

表 4 实验结果的评价指标对比

方法	PSNR/dB	SSIM
BM3D	26.31	0.822 3
RED-CNN	30.71	0.853 7
UNet	29.95	0.843 7
DER-UNet	31.15	0.859 1
RA-UNet	32.84	0.879 2
本文	33.26	0.883 7

注:粗体值表示每种情况下的最高分数

表 4 中,传统降噪算法 BM3D 表现相对较差。这一结果与深度学习方法存在明显差距,表明传统降噪方法在处理复杂的 X 射线图像噪声时存在局限性,难以处理复杂图像中的噪声。RED-CNN 和 UNet 方法相比传统降噪算法 BM3D,指标分数有明显提升,体现了深度学习方法在图像降噪中的基础能力。采用双编码器结构的 DER-UNet 和引入注意力机制的 RA-UNet 进一步提升了模型的降噪性能,其中 RA-UNet 的 PSNR 达到 32.84 dB,SSIM 达到 0.879 2,显示了注意力机制的有效性。

相比之下,本文提出的 NSADDU-net 方法在指标上均取得了最优结果,PSNR 为 33.26 dB,SSIM 为 0.883 7。相较于性能次优的 RA-UNet,PSNR 提升了 0.42 dB,SSIM 提升了 0.004 5。这一优势证明了本文所提的噪声自注意力机制、双解码器分工重建与可学习融合策略共同作用,能够在降低图像噪声的同时,更好地保持图像的结构信息。

4 结 论

本研究针对转子叶片 X 射线图像降噪问题,提出了一种噪声自注意力双解码器 U-Net 网络。该网络在 U-Net 架构的基础上,在网络的颈部引入了 NSA 模块,以增强对噪声区域的特征关注;同时采用双解码器结构,分别进行降噪和边缘保持,并通过可学习融合模块整合双解码器输出,从而在降噪的同时保留叶片边缘等关键细节。将提出的算法在转子叶片 X 射线图像数据集上进行实验,结果表明,本文所提出的模型在转子叶片 X 射线图像降噪任务中,在视觉效果上优于其他方法,同时在 PSNR 和 SSIM 两个关键指标上均取得了最优结果,分别达到 33.26 dB 和 0.883 7,能够有效地抑制 X 射线图像中的噪声并保持叶片边缘。后续工作拟进一步优化模型在工业检测复杂噪声环境下的鲁棒性和泛化能力。

参考文献

[1] 王春满,尚勇,孙家正,等. 数字图像相关在叶片振动频

率测量中的应用[J]. 燃气涡轮试验与研究, 2025, 38(3):24-34.
WANG CH M, SH Y, SUN J ZH, et al. Application of DIC in blade vibration frequency measurement[J]. Gas Turbine Experiment and Research, 2025,38(3): 24-34.
[2] 程宏波,詹义河,付蒙蒙,等. GIS 设备 X 射线检测图像混合噪声的自适应去噪方法[J]. 核电子学与探测技术,2026,46(1):62-71.
CHENG H B, ZHAN Y H, FU M M, et al. An adaptive denoising method for mixed noise in X-ray detectionimages of GIS equipment [J]. Nuclear Electronics & Detection Technology, 2026, 46 (1): 62-71.
[3] 夏君陶,颜明轩,杨心齐,等. 曲线匹配矫正扩散网络的 LDCT 图像去噪[J]. 电子测量技术,2025,48(3): 138-144.
XIA J T, YAN M X, YANG X Q, et al. Curve matching diffusion model for LDCT images denoising[J]. Electronic Measurement Technology, 2025, 48 (3): 138-144.
[4] 鲁思琪,周先春,汪志飞. 改进型自适应全变分图像降噪模型[J]. 电子测量与仪器学报,2022,36(6):236-243.
LU S Q, ZHOU X CH, WANG ZH F. Improved adaptive total variational image denoising model[J]. Journal of Electronic Measurement and Instrumentation, 2022,36(6):236-243.
[5] XU M L, LYU P, LI M Y, et al. Medical image denoising by parallel non-local means[J]. Neurocomputing, 2016, 195: 117-122.
[6] YAN R B, LIU Y, LIU Y H, et al. Image denoising for low-dose CT via convolutional dictionary learning and neural network [J]. IEEE Transactions on Computational Imaging, 2023, 9: 83-93.
[7] LEPCHA D C, DOGRA A, GOYAL B, et al. A constructive non-local means algorithm for low-dose computed tomography denoising with morphological residual processing[J]. PLoS One, 2023, 18(9): e0291911.
[8] HE X K, WANG C, ZHENG R Y, et al. GPR image denoising with NSST-UNET and an improved BM3D[J]. Digital Signal Processing, 2022, 123: 103402.
[9] ZHANG K, ZUO W M, CHEN Y J, et al. Beyond a gaussian denoiser: Residual learning of deep cnn for image denoising [J]. IEEE Transactions on Image Processing, 2017, 26(7): 3142-3155.
[10] 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.
- [11] YU J C, ZHOU Y, SUN M C, et al. Dual-path adversarial denoising network based on UNet [J]. Sensors, 2025, 25(15): 4751.
- [12] FAN C M, LIU T J, LIU K H. SUNet: Swin transformer UNet for image denoising [C]//2022 IEEE International Symposium on Circuits and Systems (ISCAS), 2022: 2333-2337.
- [13] WANG M H, YUAN P, QIU S, et al. Dual-encoder unet-based narrowband uncooled infrared imaging denoising network[J]. Sensors, 2025, 25(5): 1476.
- [14] LIU W P, LI Y Y, HUANG D. RA-UNet: An improved network model for image denoising[J]. The Visual Computer, 2024, 40: 4319-4335.
- [15] 王云艳,周志刚,罗冷坤. 基于 Sobel 算子滤波的图像增强算法[J]. 计算机应用与软件, 2019, 36(12): 184-188.
- WANG Y Y, ZHOU ZH G, LUO L K. Image enhancement algorithm based on sobel operator filtering[J]. Computer Applications and Software, 2019, 36(12): 184-188.
- [16] 陈丹,令陈佩,刘瑞瑜. 新型 DRNet 结合 EIoU 的遮挡目标分割模型[J]. 电子测量与仪器学报, 2025, 39(8): 209-217.
- CHEN D, LING CH P, LIU R Y. Novel DRNet occlusion target segmentation model combined with EIoU[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(8): 209-217.
- [17] WANG B, DENG F, JIANG P F, et al. Witunet: A U-shaped architecture integrating cnn and transformer for improved feature alignment and local information fusion[J]. Scientific Reports, 2024, 14(1): 25525.
- [18] 薛钟毫,姜金刚,孙健鹏,等. 基于多尺度卷积和选择性核双注意力机制的半监督全景 X 射线图像龋齿分割[J]. 仪器仪表学报, 2025, 46(6): 241-250.
- XUE ZH H, JIANG J G, SUN J P, et al. Semi-supervised caries segmentation of panoramic X-ray images based on multi-scale convolution and selective kernel dual-attention[J]. Chinese Journal of Scientific Instrument, 2025, 46(6): 241-250.
- [19] ALGUACIL A, BAUERHEIM M, JACOB M C, et al. Predicting the propagation of acoustic waves using deep convolutional neural networks[J]. Journal of Sound and Vibration, 2021, 512: 116285.
- [20] 林枫,唐梓潇,毛承洸,等. 基于灰度梯度函数标定的涡轮转子叶片内窥成像离焦图像修正方法[J]. 燃气涡轮试验与研究, 2025, 38(3): 35-40.
- LIN F, TANG Z X, MAO CH L, et al. Dynamic correction of endoscopic imaging of high-speed turbine rotor blades based on calibration of the grayscale gradient function[J]. Gas Turbine Experiment and Research, 2025, 38(3): 35-40.
- [21] HAN R, WANG Y Z, GUO W H, et al. DDEG: Addressing data scarcity in additive manufacturing defect detection through joint generation of CT images and defect annotations [J]. Advanced Engineering Informatics, 2025, 68: 103619.
- [22] 张剑飞,李浩. 基于多尺度残差融合的水下图像增强网络[J]. 电子测量技术, 2025, 48(17): 169-177.
- ZHANG J F, LI H. Underwater image enhancement network based on multi-scale residual fusion [J]. Electronic Measurement Technology, 2025, 48(17): 169-177.

作者简介

侯昕盟,硕士研究生,主要研究方向为无损检测与深度学习。

E-mail: 2024020414@bistu.edu.cn

赵纪元(通信作者),博士,教授,博士生导师,主要研究方向为设备状态监测与故障诊断、增材制造、无损检测。

E-mail: jiyuan.zhao@bistu.edu.cn