



基于多路径自适应信息增强的矿井图像超分辨率重建方法

齐爱玲 付远远 张广明

引用本文:

齐爱玲, 付远远, 张广明. 基于多路径自适应信息增强的矿井图像超分辨率重建方法[J]. 煤炭科学技术, 2025, 53(11): 172–184.

QI Ailing, FU Yuanyuan, ZHANG Guangming. Super-resolution reconstruction method of mine image based on multi-path adaptive information enhancement[J]. Coal Science and Technology, 2025, 53(11): 172–184.

在线阅读 View online: <https://doi.org/10.12438/cst.2025-0996>

您可能感兴趣的其他文章

Articles you may be interested in

矿井图像的多维特征与残差注意力网络超分辨率重建方法

Coalmine image super-resolution reconstruction via fusing multi-dimensional feature and residual attention network
煤炭科学技术. 2024, 52(11): 117–128 <https://doi.org/10.12438/cst.2024-1055>

基于改进型生成对抗网络的矿井图像超分辨重建方法研究

Super-resolution reconstruction of mine image based on generative adversarial network
煤炭科学技术. 2025, 53(S1): 338–345 <https://doi.org/10.12438/cst.2024-0298>

基于注意力机制和空洞卷积的CycleGAN煤矿井下低照度图像增强算法

Low illumination image enhancement algorithm of CycleGAN coal mine based on attention mechanism and Dilated convolution
煤炭科学技术. 2024, 52(S2): 375–383 <https://doi.org/10.12438/cst.2023-1597>

基于Transformer和自适应特征融合的矿井低照度图像亮度提升和细节增强方法

An illuminance improvement and details enhancement method on coal mine low-light images based on Transformer and adaptive feature fusion
煤炭科学技术. 2024, 52(1): 297–310 <https://doi.org/10.13199/j.cnki.cst.2023-0112>

基于自适应光照估计的Retinex-Net矿井图像增强算法

Retinex-Net mine image enhancement algorithm based on adaptive illumination estimation
煤炭科学技术. 2025, 53(7): 234–248 <https://doi.org/10.12438/cst.2024-0561>

基于多尺度快速双边滤波和小波变换的矿井图像增强算法

Mine image enhancement algorithm based on multi-scale fast bilateral filtering and wavelet transform
煤炭科学技术. 2025, 53(10): 237–250 <https://doi.org/10.12438/cst.2024-1874>



关注微信公众号, 获得更多资讯信息



移动扫码阅读

齐爱玲,付远远,张广明. 基于多路径自适应信息增强的矿井图像超分辨率重建方法[J]. 煤炭科学技术, 2025, 53(11): 172-184.

QI Ailing, FU Yuanyuan, ZHANG Guangming. Super-resolution reconstruction method of mine image based on multi-path adaptive information enhancement[J]. Coal Science and Technology, 2025, 53(11): 172-184.

基于多路径自适应信息增强的矿井图像超分辨率重建方法

齐爱玲¹, 付远远¹, 张广明²

(1. 西安科技大学 人工智能与计算机学院, 陕西 西安 710054; 2. 利物浦约翰摩尔斯大学 通用工程研究所, 英国利物浦 L3 3AF)

摘要: 煤矿井下环境复杂, 光照条件差, 高湿度与悬浮粉尘易形成水雾和辉光, 导致高频信息缺失与边缘细节模糊, 同时叠加噪声干扰。为提升矿井图像质量, 解决矿井场景下超分辨率重建中噪声抑制与细节恢复的协同难题, 提出一种基于多路径自适应信息增强的矿井图像超分辨率重建方法。方法上, 首先设计残差多路径特征聚集块(Residual Multi-path Feature Aggregation Block, RMFAB), 通过残差学习和多路径自适应卷积网络(Multi-path Adaptive Convolution Network, MACN)充分利用不同路径的特征, 增强全局与局部高频信息建模能力; 其次, 引入多注意力融合模块, 在通道和空间维度聚焦图像中的高频信息, 提升特征表达能力; 最后, 构建大核感知块(Large Kernel Perception Block, LKPA), 利用多尺度卷积扩展感受野并实现层次特征融合, 从而优化图像纹理与结构细节。实验在公开矿井数据集 CMUID 上开展, 结果显示该算法在峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)和结构相似性(Structural Similarity, SSIM)指标上优于其他主流先进算法。尤其在缩放因子为 4 时, 该算法在 PSNR 指标上较 Bicubic、CRAFT-SR、PAN、ESRGCN、DiVANet 及 SMAFNet 分别提升 2.88、2.04、1.94、1.52、0.53、0.36 dB; SSIM 指标分别提升 4.32%、3.37%、3.20%、2.74%、3.19%、1.08%。实验结果表明, 该方法实现了对矿井图像多层次特征的精细化提取与融合, 在抑制噪声干扰的同时有效恢复了复杂纹理特征, 提升了矿井图像的超分辨率重建质量, 为煤矿井下智能感知提供了技术支持。

关键词: 矿井图像; 超分辨率重建; 多路径自适应卷积; 大核感知块; 并联多注意力机制

中图分类号: TP391.41 文献标志码: A 文章编号: 0253-2336(2025)11-0172-13

Super-resolution reconstruction method of mine image based on multi-path adaptive information enhancement

QI Ailing¹, FU Yuanyuan¹, ZHANG Guangming²

(1. School of Artificial Intelligence and Computer Science, Xi'an University of Science and Technology, Xi'an 710054, China;

2. General Engineering Research Institute, Liverpool John Moores University, Liverpool L3 3AF, UK)

Abstract: The complex underground coal mine environment suffers from poor illumination, high humidity, and suspended dust-conditions that easily form water mist and glare. These factors lead to the loss of high-frequency information and blurring of edge details in captured images, while also superimposing noise interference. To improve mine image quality and address the challenge of synergistically suppressing noise and restoring details in mine scene super-resolution reconstruction, a mine image super-resolution reconstruction method based on multi-path adaptive information enhancement is proposed. Methodologically, a Residual Multi-path Feature Aggregation Block (RMFAB) is designed first, leveraging residual learning and a Multi-path Adaptive Convolution Network (MACN) to fully utilize features from different paths, significantly enhancing the modeling capability for both global and local high-frequency information. Second, a Multi-attention Fusion Module is introduced to focus on high-frequency information across channel and spatial dimensions, im-

收稿日期: 2025-07-05 策划编辑: 常琛 责任编辑: 王晓珍 DOI: 10.12438/cst.2025-0996

基金项目: 国家自然科学基金资助项目(61674121)

作者简介: 齐爱玲(1972—), 女, 陕西西安人, 副教授, 博士。E-mail: qalemail@126.com

通讯作者: 付远远(2000—), 女, 新疆乌鲁木齐人, 硕士研究生。E-mail: 1392148021@qq.com

proving feature representation. Finally, a Large Kernel Perception Block (LKPA) is constructed, employing multi-scale convolution to expand the receptive field and fuse hierarchical features, optimizing texture and structural details. Experimental results on the public CMUID mine dataset demonstrate that the proposed method outperforms existing state-of-the-art algorithms in both Peak Signal-to-Noise Ratio (PSNR) and Structural Similarity (SSIM). Particularly at a scaling factor of 4, the algorithm achieves PSNR improvements of 2.88, 2.04, 1.94, 1.52, 0.53, 0.36 dB over Bicubic, CRAFT-SR, PAN, ESRGCNN, DiVANet, and SMAFNet, respectively. Corresponding SSIM improvements are 4.32%, 3.37%, 3.20%, 2.74%, 3.19%, 1.08%. The method achieves refined extraction and fusion of multi-level features in mine images, effectively suppressing noise interference while restoring complex texture features. This enhances the super-resolution reconstruction quality of mine images, thus contributing to intelligent perception in coal mine environments.

Key words: mining images; super-resolution reconstruction; multi-path adaptive convolution; large kernel perception block; parallel multi-attention mechanism

0 引 言

煤矿智能化建设是整个煤炭行业高质量发展的必由之路^[1]。随着煤矿智能化进程的不断加快, 矿井安全保障、精准开采与自动化作业成为核心目标, 这对矿井监测系统中图像信息的质量提出更高要求。由于矿井作业环境普遍存在光照不足、湿度大、粉尘质量浓度高等复杂因素, 且现有视频监控系统获取的图像常存在细节缺失、色彩偏移及模糊降质等问题, 显著制约了矿井智能监测与风险预警系统的精度和可靠性^[2]。为此, 将图像超分辨率重建技术应用于矿井监测系统, 为设备状态识别、安全隐患排查工作提供关键支撑。

图像超分辨率重建技术作为数字图像处理的关键分支, 基于传统算法与深度学习模型, 实现低分辨率图像至高分辨率图像的重构^[3]。传统图像超分辨率重建方法主要划分为3类: 插值法^[4]通过数学插值运算填补像素来提升分辨率, 如双三次插值法、几何特征插值^[5]等, 虽计算简便但易引发震荡与伪影等现象; 重建法^[6]如最大后验估计法^[7]、迭代反向投影法^[8]等, 依赖图像先验构建约束模型, 能够提升重建质量, 但计算成本较高; 学习法^[9-10]聚焦于学习高分辨率图像和低分辨率图像之间的映射关系, 自动提取高频细节, 其具备良好的鲁棒性与适应性。常用的方法有邻域嵌入法^[11]和稀疏表示法^[12]等。

近年来, 深度学习方法在图像超分辨率重建中表现出显著优势^[13]。其中, DONG C等^[14]提出的SRCNN(Super-Resolution Convolutional Neural Network), 运用卷积神经网络, 以简洁3层自动学习低分辨率(LR)-高分辨率(HR)^[15]图像映射关系, 显著提升重建图像质量。接着, DONG C等^[16]提出的FSRCNN(Fast SRCNN)通过引入反卷积层显著提高了模型的计算效率, 并增强了网络对不同放大倍率的适应性。尽管上述方法取得一定成效, 但由于网

络结构较浅, 其在高频细节的恢复方面仍存在不足。为此, LIM B等^[17]提出的EDSR(Enhanced Deep Residual Networks for Single Image Super-Resolution)通过深化网络架构并优化残差模块设计, 在提升模型对高频细节捕捉能力的同时增强了训练稳定性, 有效弥补了浅层网络在复杂纹理恢复上的局限。在SRGAN的基础上, WANG X等^[18]提出了ESRGAN(Enhanced SRGAN), 基于生成器与判别器的对抗训练, 通过去除批归一化层、引入残差密集模块及全局残差连接策略, 进一步增强了特征表达与图像重建性能。

基于深度学习的图像超分辨率重建技术虽取得显著突破, 但其在矿井图像处理领域的研究仍较有限。受井下环境复杂、成像设备性能有限及数据传输条件不稳定影响, 采集的矿井图像常具有分辨率低、纹理与边缘信息模糊等特点。程德强等^[19]提出基于边缘融合的多字典超分辨率算法, 通过图像块梯度分类与字典训练改善边缘重建效果, 虽在一定程度上抑制伪影, 但在强噪声环境下泛化能力不足。汪海涛等^[20]采用在线多字典学习以适应图像变化, 提升了部分场景下的重建精度, 但易受噪声干扰影响字典更新的稳定性。程健等^[21]则融合多维特征与残差注意力网络, 增强了模型对边缘与结构特征的表达能力, 在结构信息还原方面取得较好效果, 但在高噪声背景下仍存在性能退化的问题。

针对矿井图像因噪声干扰导致的高频信息丢失与细节模糊的问题^[22], 提出一种基于多路径自适应卷积的矿井图像超分辨率重建方法。该方法通过构建双分支的多路径自适应卷积(MACN), 协同提取图像的全局与局部特征, 有效提升高频信息的建模能力。同时, 引入并联的多注意力融合模块, 在通道与空间维度聚焦关键信息, 增强特征表达与融合效果。各模块间通过残差连接实现信息的高效传递, 抑制冗余噪声, 有效缓解因噪声干扰导致的高频信

息缺失与边缘细节模糊问题。此外,设计大核感知块(LKPA)以增强模型对复杂场景下多尺度细节感知能力,提高在强噪声背景下的特征提取精度。最后,通过亚像素卷积层实现矿井图像不同倍数的超分辨率重建。实验结果表明,该方法在主客观评价指标上均优于现有主流算法,具有良好的鲁棒性与重建性能。

1 多路径矿井图像超分重建模型

1.1 整体网络

针对煤矿井下采集图像常伴有严重噪声干扰,进而引发高频细节信息缺失、边缘轮廓模糊,制约智能监测精度这一核心问题,提出一种基于多路径自适应信息增强的矿井图像超分辨率重建模型,如图 1 所示。

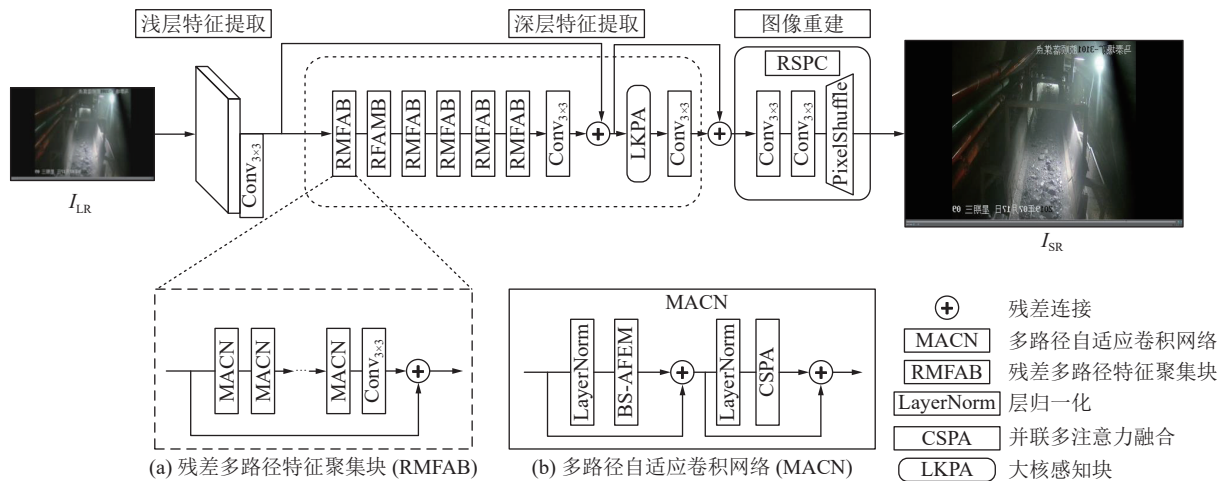


图 1 总体网络结构

Fig.1 Overall network structure

首先,采用单个 3×3 卷积层对输入的低分辨率矿井图像 I_{LR} 进行浅层特征提取,通过初步特征编码捕获基础纹理信息。深层特征融合主干由 6 个串联的残差多路径特征聚集块 RMFAB 构成,该设计旨在通过多路径机制差异化提取并融合受水雾、辉光影响的全局低频结构和受粉尘噪声破坏的局部高频细节,以解决矿井图像退化问题的核心矛盾。残差连接保障信息传递与训练稳定。图像重建上采样模块采用高效的亚像素卷积^[23](Sub-pixel Convolution)技术,在兼顾井下边缘计算资源限制的同时,重建出高分辨率图像 I_{SR} 。整体架构通过 RMFAB 的特征差异化处理、集成注意力机制的噪声鲁棒聚焦以及 LKPA 的大尺度结构稳固与边缘细节锐化,系统性地提升模型在井下恶劣成像条件下的性能。

1.2 残差多路径特征聚集块

为解决矿井图像水雾、辉光导致大范围结构模糊和粉尘噪声破坏局部细节而产生的双重退化问题,本文设计了一种残差多路径特征聚集块 RMFAB 作为深层特征提取主干的核心单元。每个 RMFAB 由 6 个多路径自适应卷积网络 MACN 和 1 个 3×3 卷积层串联构成。RMFAB 的核心思想在于通过差异化的特征提取路径与噪声鲁棒的注意力机制,协同增

强模型对全局结构信息的建模能力和对局部高频细节的恢复能力。MACN 模块如图 1b 所示,是实现上述目标的关键,其由蓝图可分离自适应卷积模块 (Blueprint Separable Adaptive Convolution Module, BS-ACM) 和并联多注意力融合模块 (Concatenated Spatial and Channel Attention, CSPA) 组成。

1.2.1 蓝图可分离自适应卷积模块

蓝图可分离自适应卷积模块 (BS-ACM) 的核心设计思想是借助差异化特征提取以提升抗干扰能力。BS-ACM 模块结构如图 2 所示,采用双分支并行结构,专门针对矿井图像退化的二元性进行设计:一个分支聚焦于受水雾、辉光影响而模糊的低频全局结构,另一分支致力于因受粉尘噪声而丢失的高频局部细节。

首先,给定输入特征图 $F_m \in \mathbb{R}^{H \times W \times C}$ ($H \times W$ 表示空间大小, C 为通道数),通过 1×1 卷积层进行通道扩展,接着,采用通道分裂操作将特征图 F_m 分成 2 个部分,分别进行非局部特征和局部特征的提取,使其作为两分支的输入特征:

$$\{X, Y\} = S(\text{Conv}_{1 \times 1}(\|F_m\|_2)) \quad (1)$$

其中, $S(\cdot)$ 表示通道分裂操作; $\text{Conv}_{1 \times 1}$ 表示执行 1×1 卷积操作; $\|F_m\|_2$ 为输入特征图的 L_2 归一化。将

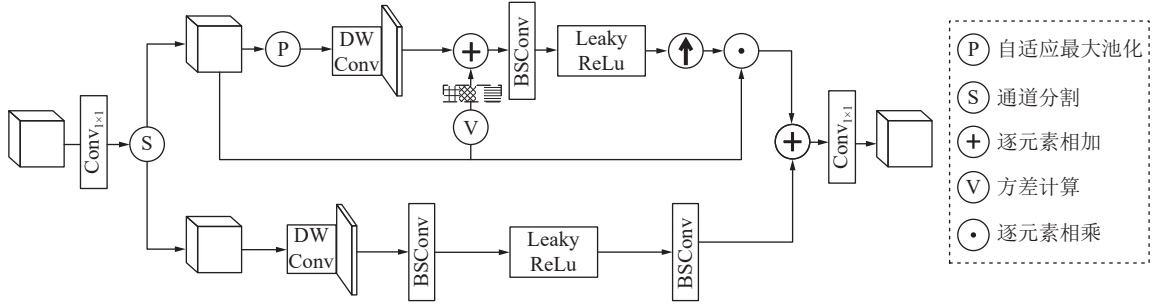


图 2 蓝图可分离自适应卷积模块

Fig.2 Blueprint separable adaptive convolution module

特征 X 和特征 Y 分别作为非局部特征分支和局部细节分支的输入。

非局部特征分支旨在提取并增强表征图像整体轮廓和低频信息的特征,以抵抗水雾、辉光造成的大范围模糊。为获取低频信息以更好地构建图像的全局视觉特征,非局部特征提取分支通过自适应最大池化操作进行下采样以获取低频分量,并采用 3×3 的深度卷积操作生成非局部特征。计算公式如下

$$X_s = \text{DWConv}_{3 \times 3}(\text{D}(X)) \quad (2)$$

式中: $\text{D}(\cdot)$ 为自适应最大池化; $\text{DWConv}_{3 \times 3}(\cdot)$ [24] 为 3×3 的深度卷积层。

为显著增强网络对结构信息的表达能力,引入基于特征图空间方差的调整机制。并通过 1×1 的蓝图可分离卷积将其与全局特征 X_s 融合,得到调制后特征 $X_m \in \mathbb{R}^{H \times W \times C}$ 。计算公式如式(3)(4)所示。

$$\sigma_L^2 = \frac{1}{N} \sum_{i=0}^{N-1} (x_i - \mu)^2 \quad (3)$$

$$X_m = \text{BSConv}_{1 \times 1}(X_s + \sigma_L^2) \quad (4)$$

其中, σ_L^2 反映了特征图在空间维度上的统计差异,方差越大,表明结构信息越丰富; N 为像素总数; x_i 为第 i 个像素的值; μ 为 X_s 所有像素的均值; $\text{BSConv}_{1 \times 1}$ 为 1×1 的蓝图可分离卷积。该调制操作自适应地强化空间结构显著区域的响应,抑制噪声主导区域的响应,从而有效提升模型对受水雾、辉光影响的巷道、设备等大尺度轮廓的感知和重建能力。

将调制后的特征 X_m 通过 Leaky ReLU [25] 进行非线性变换,再将其上采样至原始空间尺寸 $H \times W$,并与原始输入特征 X 通过逐元素相乘融合,最终输出的 X_G 蕴含增强的抗水雾与辉光模糊的全局结构信息,计算过程如下。

$$X_G = X \odot U(\varphi(X_m)) \quad (5)$$

式中: $\varphi(\cdot)$ 为 Leaky ReLU 激活函数; $U(\cdot)$ 为最近邻上采样操作; \odot 为逐元素乘法。

局部分支直接提取可能被粉尘噪声掩盖的高频纹理和边缘细节。首先,将输入特征 Y 通过 3×3 的深度卷积操作提取局部特征 Y_l 。接着,为提升特征对噪声的鲁棒性和表达能力,使用 2 个串联的 1×1 蓝图可分离卷积(blueprint separable convolution, BSConv) [26] 和 Leaky ReLU 激活函数生成增强的局部特征 Y_d ,如(6)和(7)所示。

$$Y_l = \text{BSConv}_{1 \times 1}(\text{DWConv}_{3 \times 3}(Y)) \quad (6)$$

$$Y_d = \text{BSConv}_{1 \times 1}(\varphi(Y_l)) \quad (7)$$

输出的 Y_d 携带了对粉尘噪声具有更强鲁棒性的高频细节信息。最后,将两分支的输出结果逐元素相加,融合后的特征同时包含稳固的全局结构和强化的局部细节。再将融合后的特征图通过 1×1 卷积进一步整合信息并调整通道数,如下。

$$F_{\text{out}}^{\text{BS-ACM}} = \text{Conv}_{1 \times 1}(X_G + Y_d) \quad (8)$$

1.2.2 并联多注意力融合模型

CSPA 核心为噪声环境下关键信息的鲁棒聚焦。BS-ACM 输出的 $F_{\text{out}}^{\text{BS-ACM}}$ 虽已融合了全局与局部信息,但在复杂的井下噪声干扰下,关键的高频细节和边缘信息仍可能被淹没。为了在强噪声背景下更精准、更鲁棒地聚焦这些关键信息,设计了并联多注意力融合模块(CSPA)结构,如图 3 所示。其核心在于采用并联结构,避免传统串联注意力机制在噪声环境下因信息顺序传递导致噪声放大或关键线索损失。

CSPA 模块将特征 $F = F_{\text{out}}^{\text{BS-ACM}}$ 并行输入通道注意力子分支和空间注意力子分支。其中,通道注意力采用平均池化 [27] 和最大池化操作,将输入特征分别压缩为 2 个不同的通道特征向量,然后将二者输入共享的多层感知器,生成通道权重系数 M_c 。

其次,空间维度上初始特征 F 通过通道压缩卷积减少维度,将多通道特征压缩为单通道空间响应图,突出空间显著性。并使用大核卷积捕获局部空间上

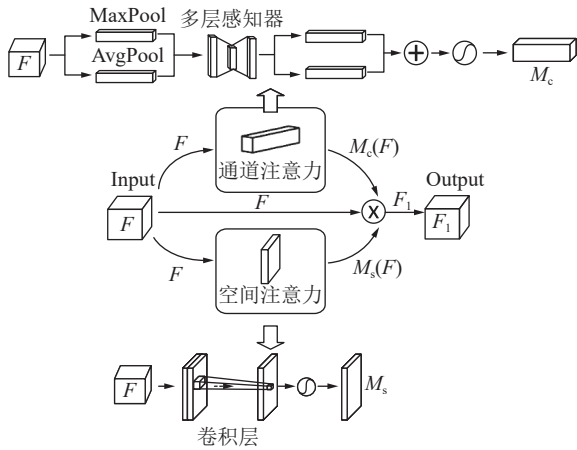


图 3 多注意力融合模块
Fig.3 CSPA module

下文关系,来强化连续边缘结构。再通过 Sigmoid 函数生成空间权重系数 M_s 。具体计算过程如式(9)(10)所示。

$$M_c = \sigma(\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{MaxPool}(F))) \quad (9)$$

$$M_s = \sigma(\text{Conv}_{7 \times 7}(\text{Conv}_{1 \times 1}(F))) \in [0, 1]^{H \times W} \quad (10)$$

其中, σ 为 Sigmoid 非线性激活函数; MLP 为多

层感知器; AvgPool 表示平均池化操作; MaxPool 表示最大池化操作。 $M_s(x, y) \approx 1$ 表示位置 (x, y) 是关键边缘区域(如设备边缘), $M_s(x, y) \approx 0$ 表示位置 (x, y) 是背景或平坦区域。最后,将通道注意力和空间注意力生成的权重系数直接与原始输入特征图 F 加权得到输出 F_1 。

这种并联融合方式确保通道注意力和空间注意力基于相同的原始特征独立学习权重,最大程度地保留了各自维度的关键信息,显著增强了模块在强噪声背景下精准定位并强化高频细节和边缘信息的鲁棒性。

1.3 大核感知块

针对矿井图像中大范围结构连续性受损(如巷道轮廓模糊,带式输送机全线形变)与局部细节缺失(如设备表面纹理丢失、关键部件边缘弱化)的耦合退化问题,笔者提出大核感知块 LKPA,其结构如图 4a 所示。该模块通过多尺度大核卷积扩展感受野捕获全局结构连续性,并通过并行通道注意力(PCA)机制强化方向性边缘特征,显著提升对矿井复杂场景的建模能力。

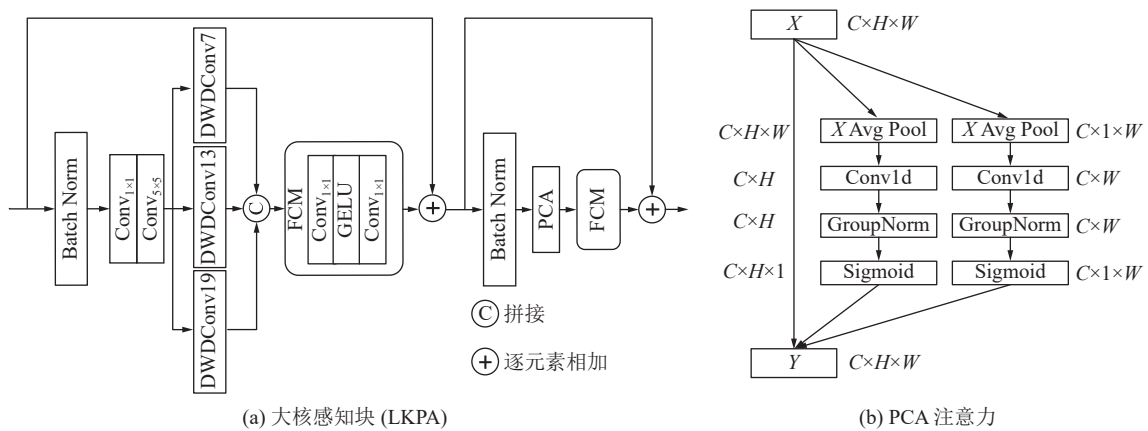


图 4 大核感知块(LKPA)和 PCA 注意力
Fig.4 Large Kernel Perception Attention (LKPA) and PCA attention

LKPA 模块的关键在于采用大核卷积进行特征提取。处理过程为输入特征经过批归一化(BN)后,通过 1×1 卷积调整通道维度,再经 5×5 卷积提取基础空间特征 F_0 。核心采用三路深度可分离空洞卷积(Depthwise Dilated Convolution, DWDConv)^[28]进行特征提取,计算公式如下。

$$F_a = \text{DWDConv}_{a \times a}^{\text{dilate}=3}(F_0) \quad (11)$$

其中, F_a 表示输出的特征图,大小为 $a \times a$,本文中选取 $a = 7, 13, 19$,其中 19×19 大核主要针对宏观矿井结构重建,如恢复带式输送机全线线性结构,水

雾弥漫的纵深巷道的轮廓。 13×13 中核针对中观设备形态的修复,可矫正辉光干扰引发的液压支架群排布空间畸变与模糊。 7×7 小核针对微观表面特征增强,如增强设备表面锈蚀等亚微米特征。其次,多尺度特征经通道拼接与压缩可有效抑制多尺度融合引入的噪声干扰。计算公式如下。

$$F_{\text{fused}} = \text{Conv}_{1 \times 1}(\text{GELU}(\text{Concat}(F_{19}, F_{13}, F_7))) \quad (12)$$

接着,为强化煤矿设备特有的方向性边缘特征(传送带-水平方向,液压支架-垂直方向),通过并行的通道注意力机制(PCA)对多尺度特征进行加权优化,

确保保留煤矿设备最具有代表性的方向性边缘特征。PCA 注意力流程如图 4b 所示,将 3 组不同感受野的特征图分别沿水平方向和垂直方向进行平均池化操作,以获得高度为 h 第 c 个通道的输出 Z^h 和宽度为 w 第 c 个通道的输出 Z^w 。该过程如式(13)(14)所示。

$$Z^h(c) = \frac{1}{W} \sum_{j=1}^W F_{in}(c, i, j) \quad (13)$$

$$Z^w(c) = \frac{1}{H} \sum_{i=1}^H F_{in}(c, i, j) \quad (14)$$

随后,将得到的水平结构响应 $Z^h(c)$ 和垂直结构响应 $Z^w(c)$ 通过 7×7 的卷积操作强化图像在 X 轴和 Y 轴的位置特征。随后采用组归一化对增强后的特征进行归一化处理,得到横轴和纵轴方向上的位置坐标表征,分别为 f^h 和 f^w 。最后使用激活函数对其进行非线性激活,得到水平和垂直方向的位置注意力 d^h 和 d^w , 计算公式如下。

$$d^h = \sigma(f^h), d^w = \sigma(f^w) \quad (15)$$

最终,将计算得到的位置注意权重与输入特征图相乘,得到最终特征图 F_f 。

PCA 注意力机制分别从 2 个方向捕获跨通道特征信息,有效聚焦矿井设备图像的方向性边缘特征。

1.4 图像重建模块

为进一步提高模型重建效果,本文在上采样部分引入亚像素卷积,该方法通过重组和重排多通道特征图像素信息来提升图像分辨率。与传统的插值或转置卷积不同,其通过周期性像素重排,在不显著增加计算量的前提下提高图像的空间分辨率。

亚像素卷积先将特征图扩展为更高维度的多通道图像,再通过像素重排操作(Pixel Shuffle),将这些信息重新组合成高分辨率图像。这一操作不仅能有效提升图像的细节,还能在增加分辨率的同时保持计算资源的高效利用。首先,对图像的浅层特征、深层特征及多尺度特征进行聚合。通过 2 个卷积操作对融合后的特征增加通道维度,并将这些额外通道作为像素数据,此时得到的新特征图大小为 $H \times W \times s^2C$, (s 为放大倍数),再经过亚像素卷积将特征图像素排列组合,实现图像放大,得到高分辨率图像,此时的高分辨率图像大小为 $sH \times sW \times C$ 。该过程如下。

$$F = \text{Pixelshuffle}(\text{Conv}_{3 \times 3}(I)) \quad (16)$$

式中: PixelShuffle 为像素排序; Conv 为卷积操作; I 为输入的特征图。

2 实验与分析

2.1 实验环境与数据集

本实验基于 Pytorch 深度学习框架构造网络模型。所采用处理器为 Inter(R)Xeon(R)W-2150B CPU @3.00 GHz, 实验环境为 Python3.8, CUDA12.2。模型训练和测试在 Nvidia GeForce RTX3090Ti 24GB 显卡上进行。训练采用 ADAM 优化器,提高训练的效率和稳定性。超参数设置为 $\beta_1 = 0.9$ 、 $\beta_2 = 0.999$ 。由于学习率过低会导致收敛速度慢,模型无法进行彻底的学习;学习率过高则会导致参数更新幅度过大而跳过最优解。因此本文通过固定其他参数值将不同学习率下的 PSNR 和 SSIM 值进行对比,对比结果见表 1。最终确定初始学习率为 $\varepsilon = 0.0002$ 。共训练 1 000 个 epoch,批训练数据量 batch-size 设置为 32。

表 1 不同学习率的结果对比

Table 1 Comparison of results of different learning rates

学习率 ε	0.000 05	0.000 1	0.000 2	0.000 5
PSNR/dB	31.93	32.16	32.59	30.85
SSIM	0.890 6	0.887 8	0.898 6	0.881 4

实验所用数据集为 CUMID,该数据集包含 600 张井下图像,涵盖工作车间、巷道和煤矿带式输送机 3 个场景。为扩充矿井图像样本,利用图像增强操作,通过左右翻转和随机旋转 90° 、 180° 及 270° ,将数据集扩展至 2 400 张图像。此外,为构建匹配的低分辨率数据集,本文采用双三次插值算法对原始高分辨率图像进行处理,放大倍数为 $n(n=2,3,4)$ 。本文采用 8 : 2 的比例分配策略将数据集划分为训练集和测试集。

2.2 损失函数

针对矿井图像超分辨率任务,考虑到井下环境中存在的粉尘、水雾等干扰易导致像素值跳变(如设备表面反光区域的过曝像素、低照度区域的噪声点),以像素级损失为基础约束,通过计算重建图像与高分辨率真值图像的绝对误差累积,引导网络聚焦于全局结构与局部细节的一致性恢复,其数学表达式为

$$L = \sum_{p,k} |I_{rec}(p,k) - I_{gt}(p,k)| \quad (17)$$

式中: I_{rec} 为模型输出的重建图像; I_{gt} 为对应的高分辨率矿井图像真值; (p,k) 为图像像素坐标。

该损失函数通过绝对差值的线性累加,对矿井图像中水雾、反光引发的极端像素具有强稳健性,可规避局部噪声对全局优化方向的干扰。

2.3 评价指标

为客观评估重建图像质量,本文采用峰值信噪比^[29](PSNR)和结构相似性^[30](SSIM)对矿井图像重建结果进行性能评价,确保评价结果的可靠性与稳定性,符合人眼视觉认知规律。

PSNR 值越高,表明重建图像的质量越好,算法的性能越优,其计算公式如下。

$$\text{PSNR} = 10 \lg \left(\frac{\text{MAX}^2}{\text{MSE}} \right) \quad (18)$$

其中,MAX为图像像素的最大数值,对于8位图像而言,MAX通常取255;MSE为重建图像与原始图像的均方误差。PSNR的优势在于计算简单且易于理解,但仅考虑了像素级别的误差,未能充分反映人眼对图像质量的感知差异。

为弥补 PSNR 的不足,本文引入结构相似性(SSIM)来评价重建图像的质量。SSIM 基于人眼视觉特性,从亮度、对比度和结构3个维度综合评估图像质量,其值范围为0到1,越接近1表示重建图像与原始图像的相似性越高,质量越好,其计算公式如下。

$$\text{SSIM}(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (19)$$

其中, x 和 y 分别对应高分辨率原始图像和重建结果; σ_x^2 和 σ_y^2 分别为两幅图像的方差, σ_{xy} 为二者间的协方差; μ_x 和 μ_y 为输入图像的灰度均值; C_1 和 C_2 为常数项,避免分母为零。

2.4 实验分析

2.4.1 消融实验

为验证本文所提各模块的有效性,笔者在矿井数据集上共设计5组消融实验:基准Base组、Base+RMFAN的模型1、Base+RMFAB+LKPA的模型2、Base+RMFAB+RSPC的模型3以及Base+RMFAB+LKPA+RSPC的模型4,均采用相同配置参数,通过比较各组模型的峰值信噪比和结构相似性,验证各模块的有效性。实验结果见表2。

表2 不同模块组合实验结果

Table 2 Experimental results of different module combinations

模型	RMFAB	LKPA	RSPC	PSNR/dB	SSIM
Base				30.72	0.872 7
1	√			31.35	0.884 3
2	√	√		31.82	0.891 0
3	√		√	32.21	0.894 6
4	√	√	√	32.59	0.898 6

从模型1可以看出,添加RMFAB模块后,实验结果相较于Base组有所提升。RMFAB通过蓝图可分离自适应卷积,结合局部特征提取分支、全局特征提取分支,再融入多注意力融合模块,有效提取并融合全局-局部特征,显著提升了重建效果。针对基准模型,本文分别引入LKPA和RSPC模块来构建模型2和模型3。定量实验表明,2个模块均显著增强了网络的超分辨率重建性能。与Base组相比,模型2和模型3在PSNR指标分别提高0.47 dB和0.86 dB,SSIM值分别提升0.67%和1.03%。这表明,多尺度特征提取对矿井图像的超分辨率重建具有良好的效果。LKPA通过并行的多尺度大核卷积和PCA注意力相结合,充分提取特征图信息并有效融合。多尺度大核卷积有助于获取不同尺度的特征信息,显著改善了矿井场景图像的超分辨率重建质量。PCA注意力机制通过空间-通道协同建模,有效解决传统大核卷积在精细特征捕获方面的局限性。其将几何位置整合至通道注意力,实现特征增强,从而显著提升了重建图像的保真度。RSPC模块通过2个3×3卷积来增加特征图的通道维度,随后通过亚像素卷积进行像素重排序,从而聚合特征信息,使重建图像更接近真实值。

在模型4中,加入3种模块后的模型表现最优,相较于基准模型,本文所提方法在PSNR和SSIM指标上分别提升了1.87 dB和2.59%。结果验证了本文所提方法的有效性,也表明本文模型达到了最优的重建性能。

2.4.2 CSPA 模块性能验证

为评估多注意力融合模块有效性,本文在4倍超分任务下设计了4组实验:无注意力、仅通道注意力机制、仅空间注意力机制以及并联通道-空间注意力机制模型。性能对比结果见表3。

表3 CSPA 模块性能对比验证

Table 3 Comparison and verification of CSPA module per-formance

对照项	通道注意力	空间注意力	PSNR/dB	SSIM
1			30.55	0.877 0
2	√		30.84	0.882 5
3		√	30.98	0.880 4
4	√	√	32.59	0.898 6

实验分析表明,仅使用通道或空间注意力模块对模型性能的改善程度有限。这是因为单独采用通道或空间注意力仅能针对特定维度的特征进行增强,

虽然能在一定程度上提升模型的特征表征能力,但无法从多维度捕获特征,导致模型的重建效果不佳。因此,考虑到多维度特征提取的需求,本研究将通道和空间注意力并联融合后加入网络进行实验。实验数据表明,采用并联注意力机制的网络在超分辨率任务中展现出显著优势,与无注意力机制的模型相比,其 PSNR 和 SSIM 指标分别提升了 2.04 dB、2.16%。这表明,该机制通过协同利用空间与通道双维度的特征表示,相比单一注意力能够更全面地捕捉图像有效信息,显著增强了特征表征能力,从而获得更优的重建质量,证明了 CSPA 模块的有效性。




图 5 不同数量的 RMFAB 对重建结果的影响

Fig.5 Impact of different numbers of RMFAB on reconstruction results

2.4.4 BS-ACM 模块有效性验证

为验证 BS-ACM 模块的有效性,本节设计了仅含非局部分支、仅含局部分支以及双分支蓝图可分离自适应卷积模块 3 组实验。对比结果见表 4,可视化结果如图 6 所示。观察图 6 中的红框和蓝框区域,在图 6a 仅使用非局部分支时,蓝框内局部细节纹理因长距离依赖捕捉而被忽略;红框全局关联受局部忽视影响,导致重建图像的局部质量不足。图 6b 仅使用局部分支时,蓝框局部特征提取较完整,但红框内因无全局关联,产生失真伪影。使用本文提出的

2.4.3 不同数量 RMFAB 的影响

为评估 RMFAB 数量对网络性能的影响,本小节在缩放因子为 4 的条件下开展实验,结果如图 5 所示。由图可知,当 RMFAB 数量从 4 个增至 6 个时,整体重建性能稳步提升。然而,当 RMFAB 的数量增至 7 个时,重建性能反而下降。这表明,增加 RMFAB 数量虽能提升网络特征提取能力,但超过阈值后,网络优化难度与计算复杂度均会上升,最终导致性能退化。因此,本文选用 6 个 RMFAB 模块,既能在矿井图像中有效提取多尺度特征,又能在性能与计算成本间实现良好平衡。

双分支结构蓝图可分离自适应卷积图 6c 时,蓝框和红框内容通过全局和局部特征协同优化,实现了特征表示的互补增强,在保持全局结构一致性的同时

表 4 BS-ACM 模块不同分支的有效性验证

Table 4 Validation of different branches of BS-ACM module

对照项	非局部分支	局部分支	PSNR/dB	SSIM
1	√		32.11	0.891 7
2		√	32.10	0.891 2
3	√	√	32.59	0.898 6



图 6 蓝图可分离自适应卷积模块不同分支的可视化效果

Fig.6 Visualization effect of single branch blueprint separable adaptive convolution module

精准重建局部细节,且在 PSNR 和 SSIM 指标上均优于单分支,弥补了单分支的不足。

2.5 实验结果与分析

2.5.1 客观结果分析

为评估所提方法的有效性,将其与 Bicubic、CRAFT-SR^[31]、PAN^[32]、ESRGCN^[33]、DiVANet^[34]和 SMFANet^[35]等 6 种主流算法,在不同放大倍数(2、3、4 倍)下的重建结果进行客观评价,结果见表 3。

由表 5 可知,本文方法在 3 种放大倍数下的超分性能均优于其他 6 种先进方法。当放大倍数为 2 时,所提方法较 DiVANet 的 PSNR 和 SSIM 分别平均提高 0.95 dB 和 5.09%,较 SMFANet 则分别平均提高 0.94 dB 和 3.22%。这一结果表明,所提方法在 2 倍超分重建中能有效保持结构细节,主要得益于模型中 RMFAB 的多路径卷积对粉尘环境下高频

细节的多路径特征提取能力,显著提升了边缘特征保留率。

当放大倍数为 3 时,所提方法较 DiVANet 的 PSNR 和 SSIM 分别平均提高 0.67 dB 和 2.64%,较 SMFANet 则分别平均提高 0.62 dB 和 0.95%。在 3 倍超分任务中,显示出 LKPA 模块的大感受野在处理更严重退化时的价值:当放大倍数增大时,中距模糊更显著,而 SMFANet 的小感受野会导致中距离特征纹理丢失。当放大倍数为 4 时,所提方法仍保持显著优势,较 DiVANet 的 PSNR 和 SSIM 分别平均提高 0.53 dB 和 3.19%,较 SMFANet 则分别平均提高 0.36 dB 和 1.08%。

上述结果表明,在相同实验环境下,本文所提算法在矿井图像超分辨率重建的客观评价指标上均优于其他算法。

表 5 放大倍数为 2, 3, 4 倍时各超分辨率重建算法的客观指标对比

Table 5 Comparison of objective metrics for different super-resolution reconstruction algorithms at scaling factor of 2, 3, 4 times

模型	放大2倍		放大3倍		放大4倍	
	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM
Bicubic	35.19	0.916 7	31.37	0.886 8	29.71	0.855 4
CRAFT-SR	36.23	0.942 4	32.67	0.898 6	30.55	0.864 9
PAN	36.40	0.937 0	32.85	0.900 4	30.65	0.866 6
ESRGCN	36.94	0.946 4	33.06	0.901 6	31.07	0.871 2
DiVANet	36.81	0.906 6	34.49	0.901 7	32.06	0.866 7
SMFANet	36.82	0.925 3	34.54	0.918 6	32.23	0.887 8
Ours	37.76	0.957 5	35.16	0.928 1	32.59	0.898 6

2.5.2 主观视觉分析

为直观展现基于多路径自适应卷积的矿井图像超分辨率重建方法的重建效果,本研究将该算法与 Bicubic、CRAFT-SR、PAN、ESRGCN、DiVANet 及 SMFANet 进行可视化对比。各超分算法从测试集中选取 2 种不同场景的矿井图像,在放大倍数为 2、3、4 倍下的可视化结果进行对比,对比结果如图 7~12 所示。图 7、8 显示放大 2 倍时,各超分算法对带式输送机机头和带式输送机机头落煤点场景的重建结果。可明显看出,其他模型重建的蓝色部件的边角结构衔接处及红色输送带防护栏存在模糊、伪影等问题,表面纹理细节有偏差,边缘细节不够清晰。而本文模型能较好地恢复边角结构细节信息和输送带防护栏的细节形状。图 9、10 显示了放大 3 倍时,各超分算法对绞车上口和泵房前门场景的重建效果。本文算法能更好恢复绞车上口部分机械结构、泵房

前门的设备及周边环境的轮廓与纹理,对光照区域处理得更自然,有效减少了模糊感和噪声,呈现出更优质的视觉重建效果。图 11、12 显示了放大 4 倍时,各超分算法对带式输送机漏斗和带式输送机场景的重建效果。其他模型重建的侧边钢筋栏杆存在平滑模糊的现象,且在重建光线过曝且较远的文字牌时,存在标识牌边缘模糊、文字笔画模糊难辨的问题。而本文算法能较好恢复文字及标识牌,受光照环境影响较小,对高频细节信息的关注度更高,重建结果与真实图像高度接近。对比结果证实,本文算法在性能指标和视觉质量上均优于其他超分重建算法。

为更直观展示各类算法在图像重建任务中的性能差异,本文通过像素差值生成误差可视化图与误差直方图,对各模型输出图像与原始高分辨率图像的差异进行量化分析。如图 13 所示,误差颜色图通过颜色映射表征像素差值大小:其中红色代表最大




图 7 带式输送机头在缩放因子为 2 倍时的重建效果对比

Fig.7 Comparison of reconstruction effects in the belt conveyor head under 2× scaling




图 8 带式输送机机头落煤点在缩放因子为 2 倍时的重建效果对比

Fig.8 Comparison of reconstruction effects at coal discharge point of the belt conveyor head under 2× scaling




图 9 绞车上口在缩放因子为 3 倍时的重建效果对比

Fig.9 Comparison of reconstruction effects at the winch inlet under 3× scaling




图 10 泵房前门在缩放因子为 3 倍时的重建效果对比

Fig.10 Comparison of reconstruction effects at the pump house entrance under 3× scaling




图 11 带式输送机漏斗在缩放因子为 4 倍时的重建效果对比
 Fig.11 Comparison of reconstruction effects at the belt conveyor funnel under 4× scaling



图 12 带式输送机指示牌在缩放因子为 4 倍时的重建效果对比
 Fig.12 Comparison of reconstruction effects for belt conveyor signage under 4× scaling

差值(设定上限为 50),颜色向蓝色渐变表示差值递减,以此反映超分辨率重建效果的优劣。误差直方图中,横轴为像素误差值(沿用相同的颜色映射方式),纵轴为对应误差值的像素数量(即误差频率)。实验图像选取带式输送机漏斗图像作为测试对象,为确保对比的全面性与代表性,选取 DiVANet、

SMFANet 和 ESRGCNN 等近年先进算法与本文算法进行对比。图 13a~图 13d 分别展示各算法的重建结果、误差图和误差直方图。从可视化结果可见,DiVANet 在漏斗整体区域(尤其是金属杆边缘轮廓处)存在显著高误差区域,表现为密集红色像素分布,表明其在边缘细节恢复上存在明显不足。相比

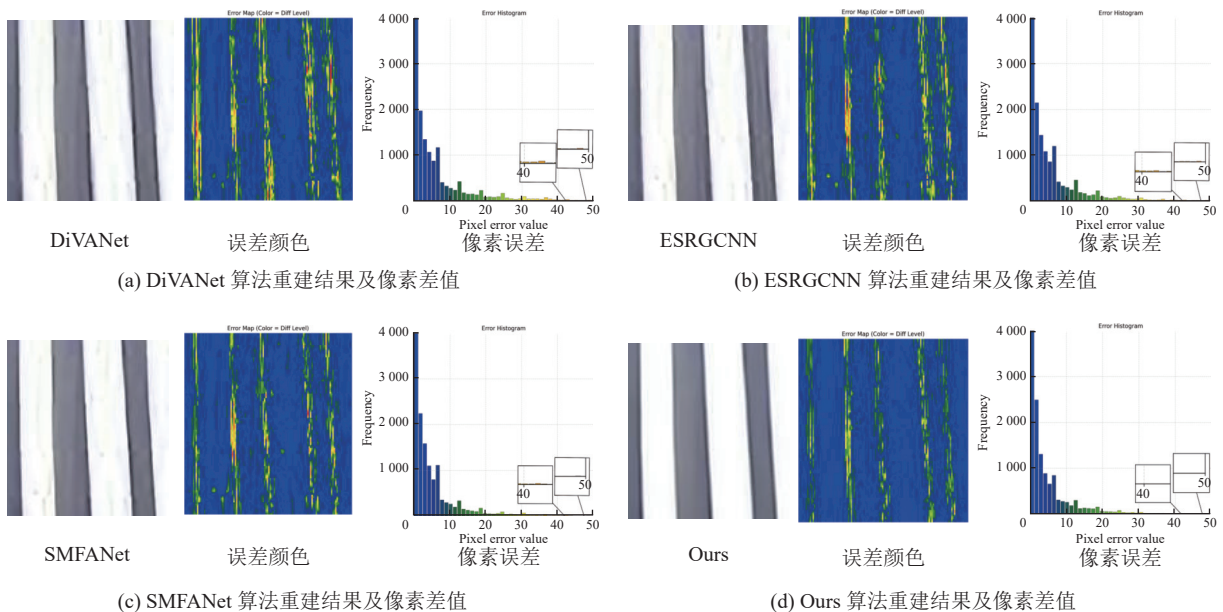


图 13 不同算法重建结果的像素差值颜色图对比
 Fig.13 Comparison of pixel difference color maps of reconstruction results from different algorithms

之下, ESRGCNN 与 SMFANet 整体误差水平较低, 误差图以绿色区域为主, 仅局部出现少量红色像素, 说明其细节还原能力优于 DiVANet。而本文算法的误差颜色图中几乎无红色区域, 尤其在边缘细节和高亮区域的重建上表现出较高稳定性与准确性。进一步分析误差直方图可知, 本文算法在像素误差区间为 [40,50] 的频率为 0, 凸显其在最大误差控制上的显著优势。

2.6 实验结果与分析

本节在 480 张矿井图像上评估模型推理效率, 对比结果见表 6。由实验结果可知, 本文模型推理速度优于 CRAFT-SR 和 SMFANet。这是由于本文模型采用双分支并行结构的蓝图可分离自适应卷积模块, 高效提取全局与局部特征, 减少冗余计算。并且还采用并联多注意力融合模块, 以并联的方式独立学习通道和空间注意力权重, 相比串行结构减少了信息传递消耗, 加快了模型推理速度。大核感知块虽然使用大核卷积, 但通过多尺度卷积扩展感受野并融合层次特征, 在复杂场景下高效捕捉关键信息, 降低整体计算量。尽管 ESRGCNN 和 DiVANet 模型的推理速度更快, 但其重建质量显著下降。本文模型在保持高重建质量的同时, 推理速度优于同类复杂方法。

表 6 不同算法的推理时间对比

Table 6 Comparison of reasoning time of different algorithms

模型	ESRGCNN	DiVANet	PAN	SMFANet	CRAFT-SR	Ours
运行时间/s	0.03	0.07	0.1	1.61	1.65	1.57

3 结 论

1) 提出了一种基于多路径自适应信息增强的矿井图像超分辨率重建方法。该方法通过设计串联的残差多路径特征聚集块 (RMFAB) 与大核感知块 (LKPA), 实现对矿井图像多层次特征的精细化提取与融合。RMFAB 模块采用残差学习和多路径自适应卷积机制, 显著增强了模型全局与局部特征的协同提取能力; LKPA 模块则利用大感受野和长距离依赖建模能力, 在抑制噪声干扰的同时能有效恢复复杂纹理特征。

2) 在煤矿井下图像测试集上进行全面的对比实验。实验结果表明, 无论在客观指标还是主观视觉上, 都显示本文方法的优越性。所提方法的 PSNR 指标与次优的 SMFANet 算法相比, 在 2、3、4 倍放大倍数下分别提升 0.94、0.62、0.36 dB, SSIM 指标则

分别提升 3.22%、0.95% 和 1.08%。

3) 由于当前基于双三次下采样的退化模型未能充分模拟井下实际成像条件(如运动模糊和复杂噪声), 未来研究将聚焦于建立更接近矿井图像实际情况的退化模型, 并研发更具环境适应性的重建算法, 以更好地服务于矿井安全生产需求。

参考文献(References):

- [1] 寇旗旗, 汪鹏, 崔文, 等. 矿井复杂环境下低质图像超分辨率重建关键技术及研究展望 [J/OL]. 煤炭学报, 2025: 1–26[2025–05–13]. <https://link.cnki.net/doi/10.13225/j.cnki.jccs.2025.0099>.
KOU Qiqi, WANG Peng, CUI Wen, et al. Key technologies and research prospects of super-resolution reconstruction of low-quality images in complex mine environment[J/OL]. Journal of China Coal Society, 2025: 1–26[2025–05–13]. <https://link.cnki.net/doi/10.13225/j.cnki.jccs.2025.0099>.
- [2] 程德强, 钱建生, 郭星歌, 等. 煤矿安全生产视频 AI 识别关键技术研究综述[J]. 煤炭科学技术, 2023, 51(2): 349–365.
CHENG Deqiang, QIAN Jiansheng, GUO Xingge, et al. Review on key technologies of AI recognition for videos in coal mine[J]. Coal Science and Technology, 2023, 51(2): 349–365.
- [3] 钟梦圆, 姜麟. 超分辨率图像重建算法综述[J]. 计算机科学与探索, 2022, 16(5): 972–990.
ZHONG Mengyuan, JIANG Lin. Review of super-resolution image reconstruction algorithms[J]. Journal of Frontiers of Computer Science and Technology, 2022, 16(5): 972–990.
- [4] 唐述, 曾婉凌, 杨书丽, 等. 基于 Transformer 的块内块间双聚合的单图像超分辨率重建网络[J]. 计算机学报, 2024, 47(12): 2783–2802.
TANG Shu, ZENG Wanling, YANG Shuli, et al. Intra-block and inter-block dual aggregation transformer for single image super-resolution[J]. Chinese Journal of Computers, 2024, 47(12): 2783–2802.
- [5] CAO J F, DING Q H, LUO H B. Geometric relationship-guided transformer network for omnidirectional image super-resolution [J]. *Signal, Image and Video Processing*, 2025, 19(5): 386.
- [6] YANG J C, WRIGHT J, HUANG T S, et al. Image super-resolution via sparse representation[J]. *IEEE Transactions on Image Processing*, 2010, 19(11): 2861–2873.
- [7] TANG Y, LI J, YUE L W, et al. A CNN-transformer embedded unfolding network for hyperspectral image super-resolution[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5525016.
- [8] 郑秋富, 金燕, 姜智伟, 等. 基于反投影回归网络的医学图像超分辨率重建[J]. 计算机辅助设计与图形学学报, 2024, 36(12): 1968–1977.
ZHENG Qiufu, JIN Yan, JIANG Zhiwei, et al. Medical image super-resolution reconstruction based on back projection regression network[J]. Journal of Computer-Aided Design & Computer Graphics, 2024, 36(12): 1968–1977.
- [9] 寇旗旗, 刘规, 江鹤, 等. 基于多域信息增强的轻量级图像超分辨率网络[J]. 通信学报, 2025, 46(4): 144–159.
KOU Qiqi, LIU Gui, JIANG He, et al. Lightweight image super-resolution network based on Muti-domain information enhancement[J]. Journal on Communications, 2025, 46(4): 144–159.
- [10] LEPCHA D C, GOYAL B, DOGRA A, et al. Image super-resolu-

- tion: A comprehensive review, recent trends, challenges and applications[J]. *Information Fusion*, 2023, 91: 230–260.
- [11] 寇旗旗,程志威,程德强,等.基于蓝图分离卷积的轻量化矿井图像超分辨率重建方法[J].*煤炭学报*,2024,49(9):4038–4050.
KOU Qiqi, CHENG Zhiwei, CHENG Deqiang, et al. Lightweight super resolution method based on blueprint separable convolution for mine image[J]. *Journal of China Coal Society*, 2024, 49(9): 4038–4050.
- [12] KIM D, LEE M, MUSETH K. NeuralVDB: High-resolution sparse volume representation using hierarchical neural networks[J]. *ACM Transactions on Graphics*, 2024, 43(2): 1–21.
- [13] 张帆,张嘉荣,程海星.基于深度学习的矿井智能目标检测技术研究综述[J].*煤炭科学技术*,2025,53(S1):284–296.
ZHANG Fan, ZHANG Jiarong, CHENG Haixing. Research review on intelligent object detection technology for coal mines based on deep learning[J]. *Coal Science and Technology*, 2025, 53(S1): 284–296.
- [14] DONG C, LOY C C, HE K M, et al. Image super-resolution using deep convolutional networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 38(2): 295–307.
- [15] AL-MEKHLAFI H, LIU S. Single image super-resolution: a comprehensive review and recent insight[J]. *Frontiers of Computer Science*, 2024, 18(1): 181702.
- [16] DONG C, LOY C C, TANG X O. Accelerating the super-resolution convolutional neural network[C]//LEIBE B, MATAS J, SEBE N, et al, eds. *Computer Vision – ECCV 2016*. Cham: Springer, 2016: 391–407.
- [17] LIM B, SON S, KIM H, et al. Enhanced deep residual networks for single image super-resolution[C]//IEEE Conference on Computer Vision and Pattern Recognition Workshops. 2017: 136–144.
- [18] WANG X, YU K, WU S X, et al. ESRGAN: Enhanced super-resolution generative adversarial networks[C]//Computer Vision – ECCV 2018 Workshops. New York: ACM, 2018: 63–79.
- [19] 程德强,陈亮亮,蔡迎春,等.边缘融合的多字典超分辨率图像重建算法[J].*煤炭学报*,2018,43(7):2084–2090.
CHENG Deqiang, CHEN Liangliang, CAI Yingchun, et al. Image super-resolution reconstruction based on multi-dictionary and edge fusion[J]. *Journal of China Coal Society*, 2018, 43(7): 2084–2090.
- [20] 汪海涛,于文洁,张光磊.基于在线多字典学习的矿井图像超分辨率重建方法[J].*工矿自动化*,2020,46(9):74–78.
WANG Haitao, YU Wenjie, ZHANG Guanglei. Super-resolution reconstruction method of mine image based on online multi-dictionary learning[J]. *Industry and Mine Automation*, 2020, 46(9): 74–78.
- [21] 程健,米立飞,李昊,等.矿井图像的多维特征与残差注意力网络超分辨率重建方法[J].*煤炭科学技术*,2024,52(11):117–128.
CHENG Jian, MI Lifei, LI Hao, et al. Coalmine image super-resolution reconstruction via fusing multi-dimensional feature and residual attention network[J]. *Coal Science and Technology*, 2024, 52(11): 117–128.
- [22] 张帆,刘莹,宋惠,等.基于改进型生成对抗网络的矿井图像超分辨率重建方法研究[J].*煤炭科学技术*,2025,53(S1):338–345.
ZHANG Fan, LIU Ying, SONG Hui, et al. Super-resolution reconstruction of mine image based on generative adversarial network[J]. *Coal Science and Technology*, 2025, 53(S1): 338–345.
- [23] 唐晓天,杨雪,李峰,等.自注意力映射超时空遥感图像超分辨率重建[J].*遥感学报*,2024,28(6):1551–1559.
TANG Xiaotian, YANG Xue, LI Feng, et al. Super-resolution reconstruction of hypertemporal remote sensing images based on self-attention[J]. *National Remote Sensing Bulletin*, 2024, 28(6): 1551–1559.
- [24] GENDY G, HOU J C, SABOR N, et al. Lightweight image super-resolution network based on dynamic graph message passing and convolution mixer[J]. *Expert Systems with Applications*, 2025, 263: 125683.
- [25] CAO W F, LEI X Y, SHI J, et al. HASN: Hybrid attention separable network for efficient image super-resolution; HASN: Hybrid attention separable[J]. *The Visual Computer: International Journal of Computer Graphics*, 2024, 41(5): 3423–3435.
- [26] 毕修平,陈实,张乐飞.轻量级图像超分辨率的蓝图可分离卷积Transformer网络[J].*中国图象图形学报*,2024,29(4):875–889.
BI Xiuping, CHEN Shi, ZHANG Lefei. Blueprint separable convolution Transformer network for lightweight image super-resolution[J]. *Journal of Image and Graphics*, 2024, 29(4): 875–889.
- [27] WANG L P, LEI Z Y. Deep learning based speckle image super-resolution for digital image correlation measurement[J]. *Optics & Laser Technology*, 2025, 181: 111746.
- [28] CHEN J, YE S L, CHEN G, et al. Lightweight image deblurring via recurrent gated attention and efficient decoupling[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2025, 35(2): 1814–1824.
- [29] 曹坪,林树冉,张淳杰,等.梯度引导的JPEG压缩图像超分辨率重建[J].*自动化学报*,2025,51(6):1261–1276.
CAO Ping, LIN Shuran, ZHANG Chunjie, et al. Gradient-guided super-resolution reconstruction for JPEG-compressed images[J]. *Acta Automatica Sinica*, 2025, 51(6): 1261–1276.
- [30] 黄峰,刘鸿伟,沈英,等.基于多尺度空间自适应注意力网络的轻量级图像超分辨率方法[J].*模式识别与人工智能*,2025,38(1):36–50.
HUANG Feng, LIU Hongwei, SHEN Ying, et al. Lightweight image super-resolution reconstruction method based on multi-scale spatial adaptive attention network[J]. *Pattern Recognition and Artificial Intelligence*, 2025, 38(1): 36–50.
- [31] LI A, ZHANG L, LIU Y, et al. Feature modulation transformer: Cross-refinement of global representation via high-frequency prior for image super-resolution[C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway, NJ: IEEE, 2023: 12480–12490.
- [32] WONG L, ZHAO D, WAN S, et al. Perceptual image super-resolution with progressive adversarial network[J]. *arXiv preprint arXiv: 2003.03756*, 2020.
- [33] TIAN C W, YUAN Y X, ZHANG S C, et al. Image super-resolution with an enhanced group convolutional neural network[J]. *Neural Networks*, 2022, 153: 373–385.
- [34] BEHJATI P, RODRIGUEZ P, FERNÁNDEZ C, et al. Single image super-resolution based on directional variance attention network[J]. *Pattern Recognition*, 2023, 133: 108997.
- [35] ZHENG M J, SUN L, DONG J X, et al. SMFANet: A lightweight self-modulation feature aggregation network for efficient image super-resolution[C]//Computer Vision – ECCV 2024. New York: ACM, 2024: 359–375.