

DOI: 10.19650/j.cnki.cjsi.J2209774

融合层次特征和注意力机制的轻量化矿井图像 超分辨率重建方法*

程德强¹, 陈 杰¹, 寇旗旗², 聂帅杰¹, 张剑英¹

(1. 中国矿业大学信息与控制工程学院 徐州 221116; 2. 中国矿业大学计算机科学与技术学院 徐州 221116)

摘 要: 针对矿井图像灰暗模糊、边缘不清晰等问题, 提出了一种融合层次特征和注意力机制的轻量化矿井图像超分辨率重建方法。首先设计一种残差坐标注意力模块, 在残差块中融入坐标注意力机制, 使网络获得更丰富的高频细节信息; 其次采用层次特征融合机制, 对不同网络层次的特征信息进行特征融合, 促进边缘细节信息的重建。最后, 再对融合后的特征进行降维以减少模型计算量和参数量。为了使模型在真实矿井场景中具有更好的泛化能力, 构建了一种煤矿井下图像数据集 CMUID 用于网络模型的训练和测试实验。实验结果表明, 本文算法的重建图像质量在客观指标和主观感受上均优于其他对比算法。当缩放因子为 4 时, 与 OISR 算法相比, 在煤矿井下数据集上 PSNR 和 SSIM 的平均值分别提升了 0.318 5 dB 和 0.012 6, 在公共数据集上 PSNR 和 SSIM 的平均值分别提升了 0.1 dB 和 0.003 5; 网络模型参数量减少了 70.7%。

关键词: 矿井图像; 超分辨率重建; 注意力机制; 层次特征; 轻量化

中图分类号: TP391 TH701 文献标识码: A 国家标准学科分类代码: 510.4050

Lightweight super-resolution reconstruction method based on hierarchical features fusion and attention mechanism for mine image

Cheng Deqiang¹, Chen Jie¹, Kou Qiqi², Nie Shuaijie¹, Zhang Jianying¹

(1. School of Information and Control Engineering, China University of Mining and Technology, Xuzhou 221116, China;
2. School of Computer Science and Technology, China University of Mining and Technology, Xuzhou 221116, China)

Abstract: The images in coal mines have problems of dim, blurry and unclear edges. To address these issues, this article proposes a lightweight mine image super-resolution reconstruction method that fuses hierarchical features and attention mechanism. Firstly, by integrating the coordinate attention mechanism into the residual block, this article designs a residual coordinate attention module, which enables the network to obtain rich high-frequency detailed information. Secondly, the hierarchical feature fusion mechanism is adopted to fuse the feature map information of different network levels. Thereby, the reconstruction of edge detail information is promoted. Finally, the dimensionality reduction is performed on the fused features to reduce the amount of model computation and parameters. In addition, to make the proposed model have better generalization performance in real-mine scenes, a coal mine underground image dataset CMUID is constructed for the training and testing experiments of the network model. Experimental results demonstrate that the reconstructed image quality of the proposed algorithm is superior to other comparison algorithms in both objective indicators and subjective feelings. Compared with the OISR algorithm on the underground coal mine image data set, when the scaling factor is set to 4, the average values of PSNR and SSIM of the proposed algorithm can be improved by 0.318 5 dB and 0.012 6. As for the public data set, the average PSNR and SSIM of the proposed algorithm are also improved by 0.1 dB and 0.003 5, respectively, as well as the number of network model parameters is reduced by 70.7%.

Keywords: mine image; super-resolution reconstruction; attention mechanism; hierarchical features; lightweight

0 引言

煤矿智能化是煤炭行业高质量发展的核心技术支撑和必由之路,高分辨率的井下图像能够为视频监控、人员行为识别、煤矸石运输等智能化分析提供关键的数据支持^[1-3]。然而,受成像系统、环境因素和成像技术的影响,煤矿井下图像呈现了灰暗模糊、边缘信息丢失等退化现象,空间分辨率较低^[4]。因此有必要对矿井图像超分辨率重建技术进行研究,利用图像超分辨率重建技术来提升矿井图像质量,使算法更易于部署到边缘计算设备中,推动煤矿智能化发展。

图像超分辨率重建技术是指利用图像处理和机器学习技术将低分辨率(low-resolution, LR)图像重建成高分辨率(high-resolution, HR)图像^[5]。目前,按算法原理,图像超分辨率重建方法可分为插值法^[6]、重建法^[7]和学习法^[8]。基于插值的算法有双三次插值、基于几何特征的插值法^[9]等,这类算法虽然计算简单但重建图像有震荡和伪影等现象;基于重建的算法有最大后验估计法^[10]、迭代反向投影法^[11]等,这类算法相较于插值法重建效果较好,但模型运算效率低且受放大因子的影响较大;基于学习的算法有邻域嵌入法^[12]、稀疏表示法^[13]等,这类算法是通过学习 HR 图像和 LR 图像样本对的映射函数或者利用图像的内部相似性来重建 HR 图像。

近年来,基于深度学习^[14-15]的超分辨率重建技术的出现,为解决传统算法中存在的各种问题提供了更多的方法。2014年,Dong等^[16]首次提出了超分辨卷积神经网络(super-resolution convolution neural network, SRCNN)算法,其网络模型是直连型结构,利用3层卷积网络来实现特征提取、特征非线性映射,从而获得比传统的超分辨率算法更好的重建效果。接着Dong等^[17]为了提高网络的训练速度提出了快速超分辨卷积神经网络(fast super-resolution convolutional neural network, FSRCNN),直接在网络输入端送入 LR 图像最后在重建层使用反卷积放大输入图像。在2016年,Shi等^[18]提出了亚像素卷积超重建网络(efficient sub-pixel convolutional neural network, ESPCN),通过亚像素卷积层来放大图像,在降低网络计算量的同时也提升了网络的训练速度。但以上方法的网络结构简单、网络层数较浅,会丢失一些高频信息,导致具有复杂纹理细节图像的重建效果不理想。因此, Kim等^[19]首次将残差网络引入单图像超分辨率重建中提出了VDSR(very deep convolutional network for single image super-resolution)算法,该网络使用了非常深的20层网络,仅学习 LR 图像和 HR 图像之间的高频残差部分,相比之前的浅层网络重建性能得到了很大的提升,但网络层数的加深会导致过度拟合和模型过于复杂的问题。于

是, Kim等^[20]又提出了DRCN(enhanced deep super-resolution network)算法,将递归神经网络引入到图像超分辨率重建算法中并取得了很好的效果。此后, Lim等^[21]提出了EDSR(enhanced deep super-resolution network),通过使用全局残差和局部残差来学习图像更多的高频细节特征,降低网络训练难度的同时提升了网络的重建效果。2018年,Zhang等^[22]将注意力机制加入到图像超分辨率重建算法中提出了RCAN(residual channel attention network),通过学习不同通道的重要性得到权重来自适应地学习更多有用的通道特征,重建出的图像包含更多的纹理信息。

然而深度学习在矿井图像超分辨率重建领域中应用较少,程德强等^[23]通过训练多组小尺度字典来替代大尺度字典提出了边缘融合的多字典超分辨率重建算法用于矿井图像的重建任务中。李保飞等^[24]提出了使用生成对抗网络(generative adversarial networks, GAN)对煤矿井下视频图像进行超分辨率复原。但对于受环境因素和硬件设备影响的低质量矿井图像而言,超分辨率重建方法还存在如下问题:1)矿井图像本身的边缘特征较弱,部分网络在重建过程中会忽视一些高频分量(边缘和纹理信息),平等对待高频信息和低频信息,导致重建后的矿井图像出现边缘模糊,细节纹理丢失等现象;2)部分方法在重建时未考虑将不同深度的特征信息进行融合,随着网络的加深会丢失部分特征信息,导致层次特征利用不充分,使得网络无法获得更好的重建性能。3)部分方法通过增加网络深度来获得较好的图像重建效果,但算法的复杂度会较高,参数量和计算量也会大幅增加,导致模型重建图像的实时性较差。4)公共数据集中缺乏与矿井图像具有相似特点的图像,目前主流算法在对灰暗模糊、边缘不清的矿井图像进行重建时达不到较好的重建效果,具有局限性。

基于此,本文提出了一种融合层次特征和注意力机制的轻量化矿井图像超分辨率重建方法。首先将坐标注意力机制融入残差块中,使网络同时学习图像中各通道关系和空间位置信息,对通道间的关系和同一通道内不同空间位置的高低频信息分配不同的权重,权值代表其重要性,再根据重要性可自适应地对图像中携带高频信息的区域分配更多的注意力,学习更丰富的高频细节信息,以解决矿井图像重建边缘不清晰的问题。其次,针对层次特征利用不充分的问题,采用层次特征融合技术,对每个经过残差坐标注意力模块提取出的特征信息进行全局融合,充分获取和利用丰富的特征信息,提高对矿井图像的重建能力。最后,通过降维以进一步降低模型的参数量和计算量,从而使得其更加的轻量化和易于在边缘计算设备上部署。为了进一步提升超分辨率算法对矿井图像重建的实用性,本文构建了一种煤矿井下图像数据集(coal mine underground image

dataset, CMUID)用于网络模型的训练和测试,为煤矿智能化视频分析提供更加有效的数据支持。

1 煤矿井下图像数据集 (CMUID) 构建

目前多数图像超分辨率重建算法都是基于公共数据集包括 ImageNet、General-100、DIV2K 等进行网络模型训练的,这些数据集包括:动物、建筑、花草、自然风景、人类等图像,然而当面对灰暗模糊的低分辨率矿井图像时,这些超分辨率算法往往达不到较好的重建效果,对矿井图像重建任务具有局限性。因此,本文构建了一种煤矿井下图像数据集 CMUID 用于网络模型的训练,使模型在真实矿井场景中具有更好的泛化能力。煤矿井下图像数据集是由 KBA12B 矿用本安型摄像机在多个煤矿井下拍摄获取的,该摄像机最高分辨率为 $2\ 560 \times 1\ 920$,500 万像素,补光距离为 30 m,具有结构紧凑、体积小、防爆和防潮

等特点,适合煤矿井下使用。通过矿用本安型摄像机在多个煤矿井下的不同场景采集视频图像,包括井下巷道、井下工作车间和煤矿运输皮带机等场景,然后对图像集进行筛选处理,剔除掉损坏图像和极其模糊图像,并且将图像统一裁剪成 $2\ 040 \times 1\ 368$ 尺寸的图像,最终生成 900 张矿井图像,数据集部分图像如图 1 所示,基本反映了实际应用过程中可能面对的各种常见场景,具备一定的代表性。同时对这些图像通过旋转 90° 、 180° 、 270° 和水平翻转进行数据增强扩充成 4 500 张训练图像用于网络的训练。使用 OpenCV 对这些 HR 图像进行 m ($m = 2, 4$) 倍下采样得到 LR 图像集。由于使用数据集中结构相似的图像组成测试集进行测试会获得非常高的重建指标,为了避免这种情况,选取其他不同地区煤矿井下的 3 种场景各 10 张图像,并将其统一裁剪成 $1\ 024 \times 680$ 尺寸的图像,组成 Roadway (巷道)、Workshop (工作车间) 和 Belt-conveyor (煤矿皮带运输机) 3 种场景的测试集用于网络性能的测试。

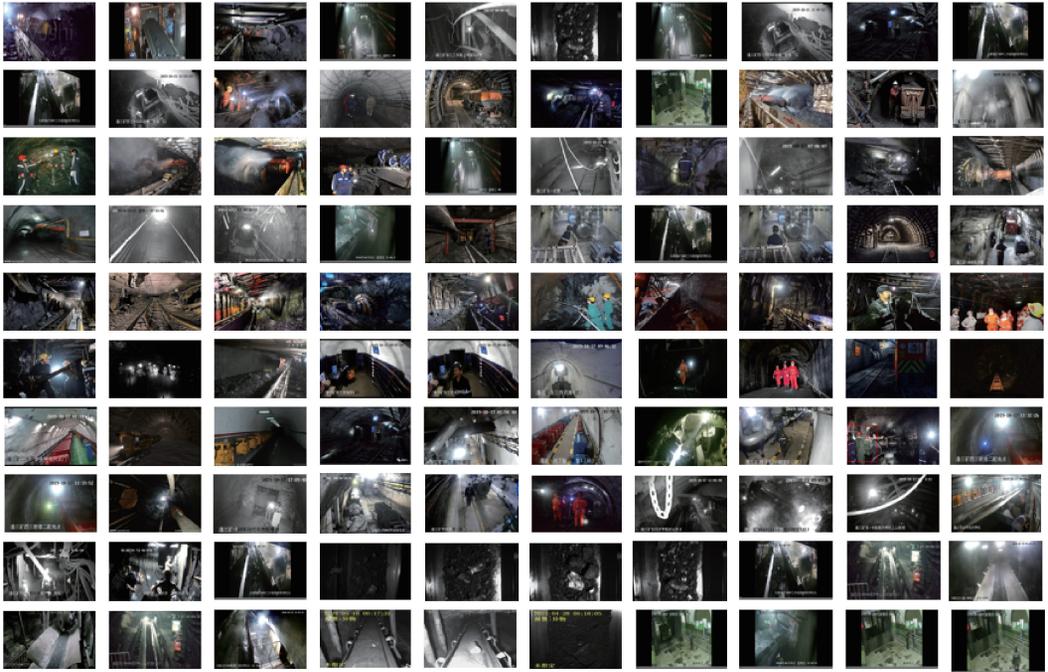


图 1 煤矿井下图像数据集部分图像

Fig. 1 Images of underground coal mine dataset

2 本文网络模型

本文提出一种融合层次特征和注意力机制的轻量化网络实现矿井图像的超分辨率重建,该网络模型由 3 个部分组成:1) 浅层特征提取模块;2) 特征映射模块;3) 图像重建模块;网络结构如图 2 所示。首先,由单个卷积层进行浅层特征提取,接着利用残差结构,设计残差坐标注意力模块,提取丰富的高频细节信息;采用层次特征融合

机制,充分利用网络不同层次特征信息,提高重建图像的质量。最后,由亚像素卷积方法实现图像的上采样,再经卷积层生成最后的重建图像。

2.1 浅层特征提取模块

在浅层特征提取阶段,使用单个 3×3 卷积层来提取 LR 图像的浅层特征,提取出来的浅层特征图通道数为 64,计算公式为:

$$F = \sigma(f_{3 \times 3}(I_{LR})) \quad (1)$$

式中: I_{LR} 表示低分辨率图像; $f_{3 \times 3}$ 表示用来提取浅层特

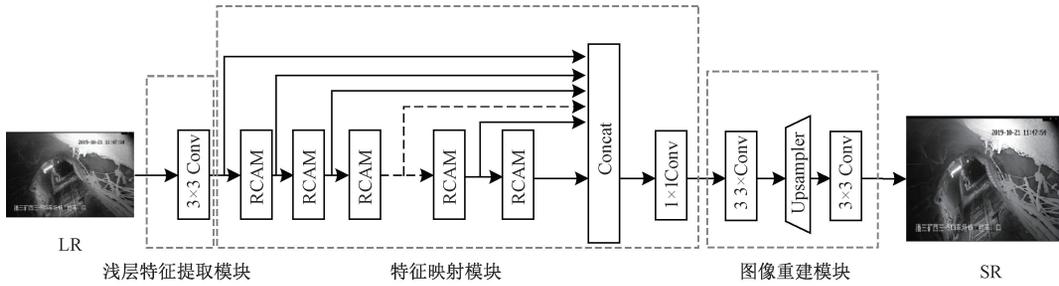


图2 融合层次特征和注意力机制网络结构

Fig. 2 Fusion of hierarchical features and attention mechanism network structure

征的 3×3 卷积层; $\sigma(\cdot)$ 表示 ReLU 激活函数; F 表示提取出来的浅层特征, 作为后面特征映射模块的输入。

2.2 特征映射模块

考虑到矿井图像本身的边缘特征较弱, 并且部分特征信息容易在特征映射阶段随着网络的加深而丢失, 从而导致重建后的矿井图像出现纹理模糊和边缘锯齿效应的问题。因此, 在特征映射模块中, 首先设计了一种残差坐标注意力模块 (residual coordinate attention module, RCAM), 将坐标注意力融入残差块中使网络充分捕捉和利用高频特征信息; 接着对不同层次特征进行全局融合, 充分利用不同网络深度丰富的特征信息, 加强各网络层之间的信息交互, 提高网络的表达能力。

在本文的网络结构设计中, 基于残差坐标注意力机制的层次特征融合模块是网络实现特征映射的重点。该模块包含 16 个残差坐标注意力模块 (RCAM), 为了充分利用各网络层提取到的特征信息, 对每个经 RCAM 的输出进行融合操作, 同时在融合层后加了一个瓶颈层, 即 1×1 卷积层, 通道数为 64。经过每个 RCAM 的输出可以表示为:

$$\begin{aligned} F_1 &= R_{RCAM}(F) \\ F_2 &= R_{RCAM}(F_1) \\ F_3 &= R_{RCAM}(F_2) \\ &\vdots \\ F_n &= R_{RCAM}(F_{n-1}) \end{aligned} \quad (2)$$

式中: $R_{RCAM}(\cdot)$ 表示使用残差坐标注意力模块提取特征; F 表示浅层特征信息; $F_1, F_2, F_3, \dots, F_{n-1}, F_n$ 表示经过各个 RCAM 提取出的特征。

接着对每个 RCAM 提取出的特征进行融合并且利用瓶颈层进行降维并去除冗余信息, 减少参数量, 具体计算如下式:

$$F_M = \sigma(f_{1 \times 1}[F, F_1, F_2, F_3, \dots, F_{n-1}, F_n]) \quad (3)$$

式中: $f_{1 \times 1}$ 表示 1×1 卷积层; $\sigma(\cdot)$ 表示 ReLU 激活函数; $[F, F_1, F_2, F_3, \dots, F_{n-1}, F_n]$ 表示对特征进行拼接融合 (concatenation) 操作; F_M 表示经层次特征融合后输出特征。

1) 残差坐标注意力模块

矿井图像往往有着丰富的低频信息, 但边缘和纹理区域的高频信息较弱, 低频信息相较于高频信息更易于重建, 因此应使网络更加关注高频细节信息。受 EDSR 中去除 BN 层的残差块 (residual block) 启示, 如图 3 所示, 本文将坐标注意力机制^[25]融入残差块中构建了一种特征表达能力更强的残差坐标注意力模块 RCAM, 如图 4 所示。相比于普通的残差块, RCAM 可以增加对高频信息区域的注意力, 学习更多的高频细节信息, 同时可以更加高效地利用计算资源。首先输入的特征 F_{n-1} 依次经过卷积层、ReLU 激活、卷积层和坐标注意力机制, 最后与输入特征 F_{n-1} 跳跃连接相加实现残差学习, 具体计算如下:

$$F_n = H_{CA}(f_{3 \times 3}(\sigma(f_{3 \times 3}(F_{n-1})))) + F_{n-1} \quad (4)$$

式中: F_n 表示第 n 个残差坐标注意力模块的输出特征; $H_{CA}(\cdot)$ 表示使用坐标注意力提取特征; $f_{3 \times 3}$ 表示 3×3 卷积层; F_{n-1} 表示第 $n-1$ 个残差坐标注意力模块的输出特征; $\sigma(\cdot)$ 表示 ReLU 激活函数。

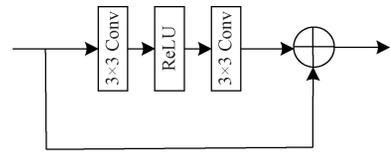


图3 残差块

Fig. 3 Residual block

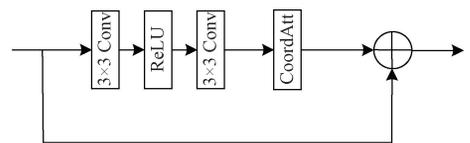


图4 残差坐标注意力模块 RCAM

Fig. 4 Residual coordinate attention module RCAM

2) 坐标注意力机制

由于 SE (squeeze-and-excitation)^[26] 通道注意力只考虑内部通道信息而忽略了空间位置信息的重要性, 卷积

注意力模块 (convolutional block attention module, CBAM)^[27] 则是在通道上进行全局池化从而引入空间位置信息,但这样只考虑了局部范围的信息,因此本文选择使用坐标注意力机制,如图 5 所示,通过把空间位置信息嵌入到通道注意力中,使经该模块能生成对通道和位置信息均敏感的特征图,增加网络对高频特征信息的注意力,提高矿井图像边缘细节的重建效果。坐标注意力机制首先使用尺寸 $(H, 1)$ 和 $(1, W)$ 的池化核对输入的特征图 $X^{C \times H \times W}$ 沿着水平方向和垂直方向进行编码,得到一对大小为 $C \times H \times 1$ 和 $C \times 1 \times W$ 的方向感知特征图。因此,高度为 h 的第 c 通道的输出为:

$$z_c^h(h) = \frac{1}{W} \sum_{0 \leq i \leq W} f_c(h, i) \quad (5)$$

同理,宽度为 w 的第 $z_c^w(h) = \frac{1}{H} \sum_{0 \leq j \leq H} f_c(j, w)$ 通道的输出为:

$$z_c^w(w) = \frac{1}{H} \sum_{0 \leq j \leq H} f_c(j, w) \quad (6)$$

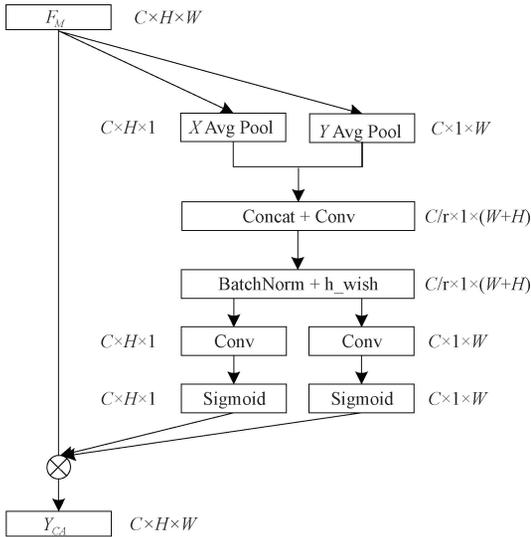


图 5 坐标注意力机制

Fig. 5 Coordinate attention mechanism

接着对生成的具有位置感知的特征图进行融合操作并且用 1×1 卷积层实现降维:

$$X' = \delta(f_{1 \times 1}([z^h, z^w])), X' \in R^{C/r \times (H+W)} \quad (7)$$

式中: $\delta(\cdot)$ 表示 h_swish 激活函数; $[z^h, z^w]$ 表示融合操作; $f_{1 \times 1}$ 表示 1×1 卷积层; $X' \in R^{C/r \times (H+W)}$ 表示水平方向和垂直方向对空间信息进行编码的中间特征映射, r 表示下采样的步长。

接着沿着空间维度将 F' 切分为两个单独的张量 X'^h 和 X'^w ,再分别经过 1×1 卷积层将特征图 X'^h 和 X'^w 转换成和输入 X 同样的通道数,得到如下结果:

$$g^h = \sigma(f_{1 \times 1}(X'^h)), g^h \in R^{C/r \times H} \quad (8)$$

$$g^w = \sigma(f_{1 \times 1}(X'^w)), g^w \in R^{C/r \times W} \quad (9)$$

式中: $\sigma(\cdot)$ 表示 $sigmoid$ 激活函数;接着对 g^h 和 g^w 进行拓展作为注意力权重,最后坐标注意力模块的输出表示为:

$$Y_{CA} = X_c(i, j) \times g^h \times g^w \quad (10)$$

2.3 图像重建模块

本文的网络模型输入的是原始低分辨率图像,经过特征提取模块和特征映射模块后,利用亚像素卷积方法对图像进行上采样,具体实现方法是:首先使用亚像素卷积对经前面网络输出的特征图做上采样至所需要的目标倍数,接着再经 3×3 卷积层得到重建图像 I_{SR} ,具体计算如下:

$$I_{Up} = H_{Up}(F_M) \quad (11)$$

$$I_{SR} = f_{3 \times 3}(I_{Up}) \quad (12)$$

式中: H_{Up} 表示亚像素卷积操作; $f_{3 \times 3}$ 表示 3×3 卷积层; I_{SR} 表示重建后的超分辨率图像。

2.4 损失函数

本文网络在训练过程中,使用 L1 范数损失函数来优化网络参数,对于给定的矿井图像训练集 $\{I_{LR}^i, I_{HR}^i\}_{i=1}^N$,其包含 N 对高低分辨率矿井图像对,损失函数的具体计算为:

$$L_1(\theta) = \frac{1}{N} \sum_{i=1}^N \|I_{HR}^i - I_{SR}^i\|_1 \quad (13)$$

式中: θ 表示网络参数包括各层权重 w_i 和偏置 b_i 参数的集合,即 $\theta = (w_1, w_2, \dots, w_i, b_1, b_2, \dots, b_i)$; I_{HR}^i 表示原始高分辨率图像; I_{SR}^i 表示经本文算法重建后超分辨率图像。

3 实验结果与分析

3.1 网络实验环境和实验数据集

本实验训练测试的实验硬件环境为: Intel (R) Core (TM) i9-10980XE CPU@ 3.00 GHz, 18 核 36 线程;系统内存为 64 GB;显卡为 NVIDIA RTX 3090, 24 GB 显存容量。软件环境为: Ubuntu20.04 操作系统; Pytorch1.8 深度学习框架; cuda11.4 加速学习;编程语言为 Python3.7。

本文使用自建的煤矿井下图像数据集 CMUID 进行训练,在巷道 (Roadway)、工作车间 (Workshop) 和煤矿皮带输送机 (Belt-conveyor) 3 种场景的测试集上进行测试对比。训练阶段使用 $\beta_1 = 0.9, \beta_2 = 0.999, \epsilon = 10^{-8}$ 的 ADAM 算法优化器,总共训练 800 个周期 (epoch),初始学习率为 1×10^{-4} ,每迭代 200 个周期后,学习率衰减 $1/2$,最终衰减为 1.25×10^{-5} 。

3.2 客观评价指标

本文采用峰值信噪比 (peak signal-to-noise ratio, PSNR)^[28] 和结构相似性 (structural similarity, SSIM)^[29] 来衡量重建图像的质量。峰值信噪比是一个重要的评价

指标,单位为 dB,其数值越高,代表重建图像的质量越好,计算公式如下:

$$PSNR = 10 \lg \left(\frac{MAX^2}{MSE} \right) \quad (14)$$

式中:MAX 表示图像点颜色的最大数值;MSE 表示真实图像与含噪图像之差的能量均值。

为了更好地体现算法的重建性能,本文还采用结构相似性来评价重建图像的质量,其是一种全参考的图像质量评价指标,它分别从亮度、对比度和结构 3 方面度量两幅图像之间的相似性,更符合人类视觉系统,其数值越接近 1 代表图像重建的质量越好,计算公式如下:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (15)$$

式中: x, y 分别表示真实的矿井图像和重建后的矿井图像; μ_x, μ_y 分别代表两幅矿井图的灰度平均值; σ_{xy} 表示 x 和 y 的协方差; σ_x 和 σ_y 分别代表 x 和 y 的方差; c_1 和 c_2 分别为常数。

表 1 各超分算法对 3 种测试集在缩放因子为 2,4 倍时的 PSNR (dB) 和 SSIM 对比

Table 1 Comparison of PSNR (dB) and SSIM of each algorithm for the three test sets with the scaling 2, 4 times factor

放大倍数	模型	巷道 (Roadway)	工作车间 (Workshop)	煤矿运输皮带机 (Belt-conveyor)	平均值
		PSNR/SSIM	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM
x2	Bicubic ^[30]	28.660 0/0.925 8	25.651 5/0.924 1	29.206 8/0.927 0	27.839 4/0.925 6
	FSRCNN ^[17]	30.989 7/0.963 4	27.885 8/0.958 3	31.156 2/0.950 4	30.010 6/0.957 4
	EDSR ^[21]	31.492 5/0.972 5	28.420 6/0.963 3	31.987 9/0.972 9	30.633 7/0.969 6
	CARN ^[31]	31.495 5/0.972 1	28.428 5/0.963 4	31.991 3/0.972 8	30.638 4/0.969 4
	MSRN ^[32]	31.498 6/0.972 5	28.431 2/0.963 5	31.996 7/0.973 1	30.642 2/0.969 7
	OISR-RK2 ^[33]	31.528 0/0.972 8	28.512 0/0.963 7	32.122 4/0.973 8	30.720 8/0.970 1
	Ours	31.724 1/0.976 2	28.986 8/0.973 9	32.421 4/0.978 1	31.044 1/0.976 1
x4	Bicubic	24.452 4/0.783 0	22.192 2/0.782 6	25.324 4/0.813 6	23.989 7/0.793 1
	FSRCNN	25.989 4/0.837 7	23.423 5/0.813 4	26.142 3/0.849 5	25.185 1/0.833 5
	EDSR	26.806 7/0.867 8	24.637 5/0.835 6	26.842 3/0.873 9	26.095 5/0.859 1
	CARN	26.809 6/0.868 0	24.645 1/0.835 9	26.848 8/0.874 2	26.101 2/0.859 4
	MSRN	26.812 3/0.868 3	24.649 6/0.836 1	26.854 3/0.874 6	26.105 4/0.859 7
	OISR-RK2	26.938 1/0.870 2	24.723 8/0.838 5	26.975 3/0.881 2	26.212 4/0.863 3
	Ours	27.259 7/0.875 8	25.096 3/0.863 2	27.236 6/0.888 8	26.530 9/0.875 9

注:加粗字体为各列最优结果。

2) 主观视觉分析

为了进一步验证本文提出的融合层次特征和注意力网络对矿井图像边缘细节信息重建性能的提升,分别选取 3 种场景测试集中的巷道图像、工作车间图像和煤矿运输皮带机图像进行可视化对比分析。表 2 为各算法对 3 张矿井图像进行重建后图像的 PSNR 和 SSIM 指标对

3.3 实验结果分析

1) 客观指标分析

将本文算法与其他超分辨率重建算法进行对比实验,分别有传统方法 Bicubic^[30] 和深度学习方法 FSRCNN^[17]、EDSR^[21]、CARN^[31]、MSRN^[32]、OISR-RK2^[33],使用这些算法分别在巷道(Roadway)、工作车间(Workshop)和煤矿皮带运输机(Belt-conveyor)3 种场景的测试集上进行重建图像 2 倍和 4 倍的性能对比实验,表 1 为本文算法与其他算法在 3 种场景测试集上重建后图像的 PSNR 和 SSIM 性能评价指标对比。从表 1 的结果可以看出,本文的算法模型对煤矿井下不同场景测试集上的重建性能都超越了其他几种算法,在 4 倍缩放因子下,相比于 FSRCNN、EDSR、CARN、MSRN、OISR-RK2 算法在 PSNR 平均值上分别提升了 1.345 8、0.435 4、0.429 7、0.425 5 和 0.318 5 dB,在 SSIM 平均值上分别提高了 0.042 4、0.016 8、0.016 5、0.016 2 和 0.012 6。

比;图 6~8 显示了 3 种场景测试集图像进行缩放因子为 4 的超分辨率重建效果对比图。图 6 显示了各算法对于 Roadway 测试集中井下巷道图像的可视化结果,本文算法重建的“里”字相比于其他算法的重建结果线条较为清晰和易辨识。图 7 显示了各算法对于 Belt-conveyor 测试集中矿下煤矿运输皮带机图像的可视化结果,可以

看出其他算法会出现细节模糊和边缘信息平滑等情况,而本文算法能预测更多的边缘细节,更好地恢复了头部安全帽区域的纹理细节。图 8 显示了各算法对于 Workshop 测试集中矿下工作车间图像的可视化结果,不难看出,本文算法重建结果中的“总”字相比于其他算法的重建结果更加清晰并且更接近原始图像。图 9 为本文算法和 EDSR 算法的深层特征可视化图,以热力图形式呈现对比。从图 9 中可以看出本文算法的深层特征图在

边缘纹理等高频信息处更加突出,对高频细节信息有更多的关注度。这些比较结果表明,本文算法在客观指标和主观视觉对比上均优于其他超分重建算法,之所以能够预测更多的边缘高频细节,主要得益于残差坐标注意力模块和层次特征融合机制,残差坐标注意力模块能够获得丰富的高频细节信息,层次特征融合机制能够充分利用不同网络层次的特征信息。因此,本文算法能够更好地重建矿井图像的结构特征和纹理细节。

表 2 各超分算法对 3 张具体场景图在缩放因子为 2,4 倍时的 PSNR (dB) 和 SSIM 对比

Table 2 The comparison of PSNR (dB) and SSIM of each algorithm in the scaling factor of 2, 4 times for three specific scene images

方法	图 6	图 7	图 8
	x4	x4	x4
	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM
Bicubic ^[30]	24.596 7/0.816 3	23.528 6/0.814 4	22.125 1/0.736 5
FSRCNN ^[17]	25.992 5/0.839 9	24.894 1/0.831 9	23.485 7/0.767 4
EDSR ^[21]	27.158 8/0.859 7	25.648 6/0.846 9	24.201 9/0.803 7
CARN ^[31]	27.162 3/0.859 9	25.649 7/0.847 3	24.203 6/0.803 9
MSRN ^[32]	27.165 2/0.860 3	25.651 5/0.847 7	24.205 5/0.804 1
OISR ^[33]	27.251 4/0.895 2	25.795 7/0.851 2	24.348 2/0.813 7
Ours	27.863 5/0.891 3	27.603 1/0.912 2	25.837 0/0.878 5

注:加粗字体为各列最优结果。

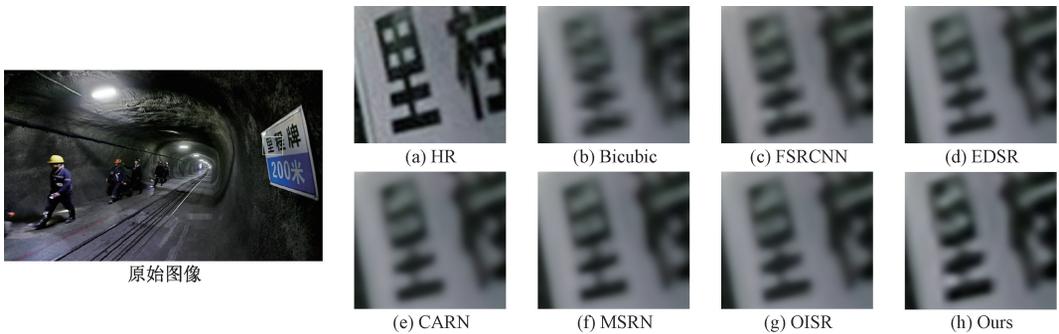


图 6 巷道 (Roadway) 测试集下本算法与其他算法的 x4 重建效果对比

Fig. 6 The comparison of x4 reconstruction effect between this algorithm and other algorithms under Roadway test set

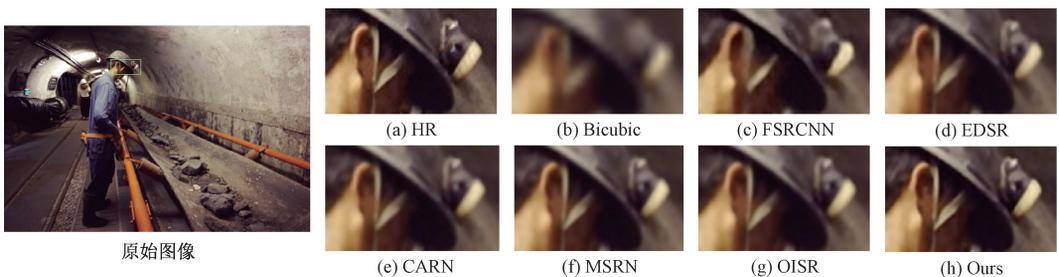


图 7 煤矿皮带运输机 (Belt-conveyor) 测试集下本算法与其他算法的 x4 重建效果对比

Fig. 7 The comparison of x4 reconstruction effect between this algorithm and other algorithms under Belt-conveyor test set

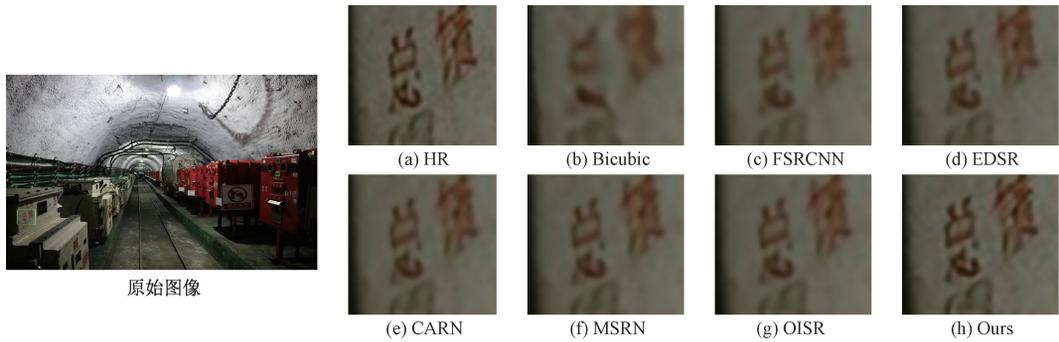


图8 工作车间(Workshop)测试集下本算法与其他算法的x4重建效果对比

Fig. 8 The comparison of x4 reconstruction effect between this algorithm and other algorithms in the Workshop test set

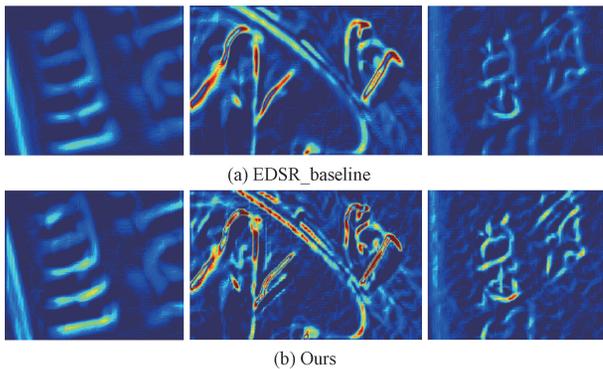


图9 深层重建特征热力图

Fig. 9 The heatmap of deep reconstruction feature

3) 在公共数据集上的对比实验

此外,本文算法还在公共数据集 DIV2K^[34]上与其他超分辨率算法进行了对比实验。DIV2K数据集已被广泛应用于图像超分辨率领域,该数据集包括800张训练图像,100张验证图像,100张测试图像。本文算法使用该数据集中的800张训练图像和前10张验证图像来训练网络,并且使用基准数据集 Set5^[35]、Set14^[36]、B100^[37]和Urban100^[38]来测试网络模型性能,实验结果具体数据如表3所示。

据表3结果可知,在公共数据集上本文算法的重建结果均优于其他超分辨率算法。在基准测试集Urban100上进行缩放因子为4的重建结果中,本文算法相比于Bicubic、FSRCNN、EDSR、CARN、MSRN和OISR算法在PSNR上分别提升了3.38、1.9、0.87、0.45、0.48和0.15 dB,在SSIM上分别提升了0.145 4、0.075 9、0.032 1、0.019 4、0.013 5和0.007 8。实验结果表明,本文提出的融合层次特征和注意力机制网络相较于其他算法在图像重建性能上有了一定提升。

4) 算法复杂度分析

为证明本文算法具备的轻量化,与FSRCNN、EDSR、CARN、MSRN和OISR-RK2等图像超分辨率重建算法进

行参数量、浮点运算量(Flops)和性能的对比。表4为各算法的复杂度对比,其中性能指标使用的是各算法在煤矿测试集上的PSNR平均值;图10为各算法模型参数量和性能的对应该关系,横坐标表示模型参数大小,纵坐标表示这些算法模型在煤矿测试集上的峰值信噪比(PSNR)平均值,三角形点代表本文算法模型。从表4和图10中可以看出本文算法模型虽然参数量和运算量略高于FSRCNN、EDSR和CARN,但是在重建性能上远高于它们,并且本文算法模型在参数量和运算量低于MSRN和OISR-RK2的同时重建性能也高于这些算法。相比于当前主流的超分辨率重建算法,本文算法模型在性能、参数量和运算量上有较好的权衡,在提升网络重建性能的同时具备较少的参数量和运算量,使网络更加轻量化,更容易部署于边缘计算设备中。

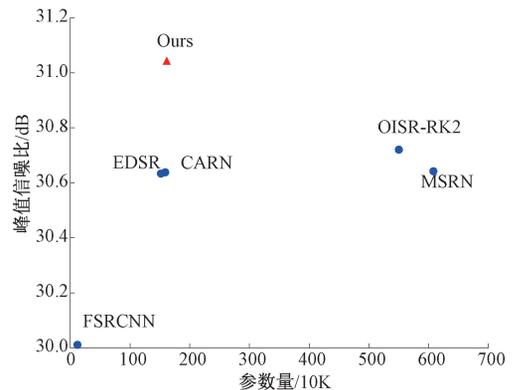


图10 各算法参数量和和煤矿数据集上PSNR值对应比较

Fig. 10 The comparison between parameters of each algorithm and the PSNR value on the coal mine datasets

3.4 消融实验

为了证明坐标注意力模块(coordinate attention)和层次特征融合机制HFF(hierarchical feature fusion)对网络模型重建性能的影响,下面对这两个改进点进行消融实验。

表 3 各超分算法对基准数据集在缩放因子为 2,3,4 倍时的 PSNR(dB) 和 SSIM 对比

Table 3 The PSNR (dB) and SSIM of the benchmark datasets comparison with the 2, 3, and 4 times scaling factor

放大倍数	模型	Set5	Set14	B100	Urban100
		PSNR/SSIM	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM
x2	Bicubic ^[30]	33.66/0.929 9	30.24/0.868 8	29.56/0.843 1	26.88/0.840 3
	FSRCNN ^[17]	37.06/0.955 4	32.76/0.907 8	31.53/0.891 2	29.88/0.902 4
	EDSR_baseline ^[21]	37.68/0.958 0	33.28/0.914 0	31.29/0.897 0	31.29/0.925 0
	CARN ^[31]	37.76/0.959 0	33.52/0.916 6	32.09/0.897 8	31.92/0.925 6
	MSRN ^[32]	38.08/0.960 5	33.74/0.917 0	32.23/0.901 3	32.22/0.932 6
	OISR-RK2 ^[33]	38.12/0.960 9	33.80/0.919 3	32.26/0.900 6	32.48/0.931 7
	Ours	38.28/0.961 5	33.96/0.919 4	32.36/0.902 6	32.84/0.936 1
x3	Bicubic	30.39/0.868 2	27.55/0.774 2	27.21/0.738 5	24.46/0.734 9
	FSRCNN	33.20/0.914 9	29.54/0.827 7	28.55/0.794 5	26.48/0.817 5
	EDSR_baseline	34.13/0.924 0	30.14/0.838 0	28.98/0.801 0	27.69/0.841 0
	CARN	34.29/0.925 5	30.29/0.840 7	29.06/0.803 4	28.06/0.849 3
	MSRN	34.38/0.926 2	30.34/0.839 5	29.08/0.804 1	28.08/0.855 4
	OISR-RK2	34.55/0.928 2	30.46/0.844 3	29.18/0.8075	28.50/0.859 7
	Ours	34.73/0.929 9	30.58/0.846 7	29.25/0.809 5	28.71/0.865 5
x4	Bicubic	28.42/0.810 4	26.00/0.702 7	25.96/0.667 5	23.14/0.657 7
	FSRCNN	30.73/0.960 1	27.71/0.748 8	26.98/0.702 9	24.62/0.727 2
	EDSR_baseline	31.91/0.889 0	28.44/0.777 0	27.45/0.731 0	25.65/0.771 0
	CARN	32.13/0.893 7	28.60/0.780 6	27.58/0.734 9	26.07/0.783 7
	MSRN	32.07/0.890 3	28.60/0.775 1	27.52/0.727 3	26.04/0.789 6
	OISR-RK2	32.32/0.896 5	28.72/0.784 3	27.66/0.739 0	26.37/0.795 3
	Ours	32.45/0.897 8	28.79/0.786 4	27.71/0.741 9	26.52/0.803 1

注:加粗字体为各列最优结果。

表 4 算法复杂度对比

Table 4 Algorithm complexity comparison

算法	参数量/M	浮点运算量/G	PSNR/dB
			煤矿测试集
FSRCNN ^[17]	0.012	5	30.010 6
EDSR ^[21]	1.52	100.51	30.633 7
CARN ^[31]	1.59	118.8	30.638 4
MSRN ^[32]	6.08	328.66	30.642 2
OISR-RK2 ^[33]	5.50	412.2	30.720 8
Ours	1.61	103.34	31.044 1

模型 a 表示未加入注意力模块和未进行层次特征融合;模型 b 表示加入 SE 通道注意力模块,未进行层次特征融合;模型 c 表示加入坐标注意力模块(CoordA),未进行层次特征融合;模型 d 表示加入坐标

注意力模块,并且进行层次特征融合;表 5 为不同模块组合形式在 3 种矿下场景测试集上缩放因子为 2 的重建评价指标对比,可以看出,加坐标注意力模块相比于通道注意力模块在 3 个测试集上的 PSNR 和 SSIM 分别提升了 0.016 2 dB 和 0.001 5,说明融入坐标注意力模块比融入 SE 通道注意力模块对矿井图像重建效果的提升更大;接着,进行层次特征融合相比于未进行特征融合在 3 个测试集上的 PSNR 和 SSIM 分别提升了 0.087 6 dB 和 0.001 6,说明采用层次特征融合技术可以增强网络的表达能力,提升矿井图像重建质量。图 11 显示了各模块组合形式在矿井综采图像上的可视化结果,本文算法模型相比于其他模型可以较好的恢复出顶部钢筋网的纹理结构,而其他模型重建出的图像则存在平滑模糊的现象。

另外,可以看出将层次特征融合机制和坐标注意力模块二者进行组合,虽然引入了极少的参数量和计算量,但是能显著提高网络对矿井图像的重建效果。

表5 不同组合模块在3个测试集上的PSNR(dB)和SSIM对比

Table 5 PSNR (dB) and SSIM comparison of different combined modules in three data set

方式		模型		参数 量/M	浮点运算 量/G	Roadway	Workshop	Belt-conveyor	平均值
SE	CoordA	HFF	/			x2	x2	x2	x2
						PSNR/SSIM	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM
×	×	×	a	1.52	100.51	31.492 5/0.972 5	28.420 6/0.963 3	31.987 9/0.972 9	30.633 7/0.969 6
√	×	×	b	1.53	99.79	31.612 1/0.972 9	28.824 3/0.969 4	32.383 7/0.976 6	30.940 0/0.973 0
×	√	×	c	1.54	99.85	31.641 2/0.974 5	28.831 5/0.971 1	32.396 8/0.977 8	30.956 5/0.974 5
×	√	√	d	1.61	103.34	31.724 1/0.976 2	28.986 8/0.973 9	32.421 4/0.978 1	31.044 1/0.976 1

注:加粗字体为各列最优结果。

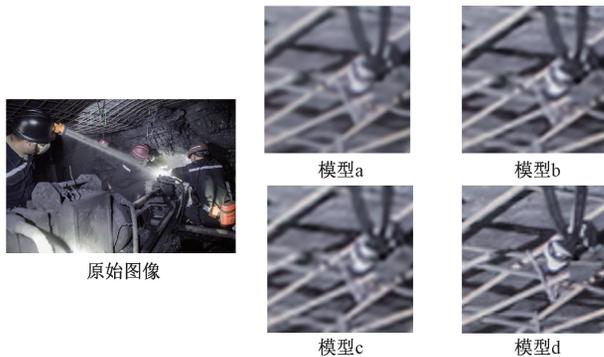


图11 消融实验重建效果对比

Fig. 11 The comparison of ablation experiment reconstruction results

4 结论

针对矿井图像灰暗模糊、重建后边缘细节丢失等问题,本文提出一种融合层次特征和注意力机制的轻量化矿井图像超分辨率重建方法。该方法通过将坐标注意力机制融入残差块中构建残差坐标注意力模块,对高频特征分配更多的注意力,增强网络对高频细节信息的恢复能力,解决了矿井图像重建后的边缘模糊问题;其次,通过层次特征融合机制将不同层次的丰富特征信息进行融合,能够提高特征利用率,增强网络的表达能力;此外在多个煤矿井下获取了矿井图像数据,同时进行筛选、切分和数据增强等操作构建煤矿井下图像数据集 CUMID 供网络模型的训练和测试,解决了公共数据集中缺乏与矿井图像具有相似特点图像的局限性问题,使网络模型在真实的矿井场景中具有更好的泛化性能。实验结果表明,本文算法在煤矿井下图像数据集和公共数据集上均能取得较好的表现,能够增强边缘细节信息的重建能力,获得更好的矿井图像重建效果,同时本文算法模型也具备较少的参数量和运算量,更加轻量化,可适用于边缘计算设备中,满足工程应用上的需求。

参考文献

- [1] 谢和平,王金华,王国法,等. 煤炭革命新理念与煤炭科技发展构想[J]. 煤炭学报, 2018, 43(5): 1187-1197.
XIE H P, WANG J H, WANG G F, et al. New concept of coal revolution and development conception of coal science and technology [J]. Journal of China Coal Society, 2018, 43(5): 1187-1197.
- [2] 杨春雨,顾振,张鑫,等. 基于深度学习的带式输送机煤流量双目视觉测量[J]. 仪器仪表学报, 2021, 41(8): 164-174.
YANG CH Y, GU ZH, ZHANG X, et al. Binocular vision measurement of coal flow of belt conveyors based on deep learning [J]. Chinese Journal of Scientific Instrument, 2021, 41(8): 164-174.
- [3] 王国法. 加快煤矿智能化建设 推进煤炭行业高质量发展[J]. 中国煤炭, 2021, 47(1): 2-10.
WANG G F. Accelerate the intelligent construction of coal mines and promote the high-quality development of coal industry [J]. China Coal, 2021, 47(1): 2-10.
- [4] 韩冉,曾广森,王荣杰. 基于残差块网络的图像去雨算法[J]. 仪器仪表学报, 2021, 41(8): 175-182.
HAN R, ZENG G M, WANG R J. Image rain removal algorithm based on residual block network [J]. Chinese Journal of Scientific Instrument, 2021, 41(8): 175-182.
- [5] 孙菁阳,陈凤东,韩越越,等. 图像超分辨率重建算法综述[J]. 计算机工程与应用, 2021, 57(17): 1-9.
SUN J Y, CHEN F D, HAN Y Y, et al. Overview of image super-resolution reconstruction algorithms [J]. Computer Engineering and Application, 2021, 57(17): 1-9.
- [6] LIU X, ZHAO D, ZHOU J, et al. Image interpolation via graph-based Bayesian label propagation [J]. IEEE Transactions on Image Processing, 2014, 23(3): 1084.
- [7] RASTI P, DEMIREL H, ANBARJAFARI G. Image

- resolution enhancement by using interpolation followed by iterative back projection[C]. 2013 21st Signal Processing and Communications Applications Conference (SIU), IEEE, 2013: 1-4.
- [8] TIMOFTE R, DE SMET V, VAN GOOL L. Anchored neighborhood regression for fast example-based super-resolution [C]. Proceedings of the IEEE International Conference on Computer Vision, 2013: 1920-1927.
- [9] 施志勇. 基于方向判定的超分辨率图像重建算法研究[D]. 重庆:重庆大学,2017.
- SHI ZH Y. Research on super-resolution image reconstruction algorithm based on direction determination [D]. Chongqing: Chongqing University, 2017.
- [10] LIU C, SUN D Q. On Bayesian adaptive video super resolution [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 36(2): 346-360.
- [11] IRANI M, PELEG S. Improving resolution by image registration [J]. CVGIP: Graphical Models and Image Processing, 1991, 53(3): 231-239.
- [12] RAHIMAN V A, GEORGE S N. Single image super resolution using neighbor embedding and statistical prediction model [J]. Computers & Electrical Engineering, 2017, 62: 281-292.
- [13] 练秋生,石保顺,陈书贞. 字典学习模型、算法及其应用研究进展 [J]. 自动化学报, 2015, 41(2): 240-260.
- LIAN Q SH, SHI B SH, CHEN SH ZH. Research progress of dictionary learning model, algorithm and its application [J]. Journal of Automation, 2015, 41(2): 240-260.
- [14] 蓝金辉,王迪,申小盼. 卷积神经网络在视觉图像检测的研究进展 [J]. 仪器仪表学报, 2020, 41(4): 167-182.
- LAN J H, WANG D, SHEN X P. Convolution the research progress of neural network in the visual image detection [J]. Chinese Journal of Scientific Instrument, 2020, 41(4): 167-182.
- [15] 李萍,刘以安,徐安林. 基于多尺度耦合的密集残差网络红外图像增强 [J]. 电子测量与仪器学报, 2021, 35(7): 148-155.
- LI P, LIU Y AN, XU AN L. Infrared image enhancement using dense residual network with multi-scale coupling [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(7): 148-155.
- [16] DONG C H, LOY C C, HE K M, et al. Learning a deep convolutional network for image super-resolution [C]. Proceedings of the 2014 European Conference on Computer Vision (ECCV). Cham, Germany: Springer International Publishing, 2014: 184-199.
- [17] DONG C, LOY C C, TANG X. Accelerating the super-resolution convolutional neural network [C]. Proceedings of European Conference on Computer Vision, 2016: 391-407.
- [18] SHI W, CABALLERO J, HUSZAR F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016.
- [19] KIM J, LEE J K, LEE K M. Accurate image super resolution using very deep convolutional networks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1646-1654.
- [20] KIM J, LEE J K, LEE K M. Deeply-recursive convolutional network for image super-resolution [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1637-1645.
- [21] LIM B, SON S, KIM H, et al. Enhanced deep residual networks for single image super-resolution [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 136-144.
- [22] ZHANG Y, LI K, LI K, et al. Image super-resolution using very deep residual channel attention networks [C]. Proceedings of the European Conference on Computer Vision, 2018: 286-301.
- [23] 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 D Q, CHEN L L, CAI Y CH, et al. Multi-dictionary super-resolution image reconstruction algorithm based on edge fusion [J]. Journal of China Coal Society, 2018, 43(7): 2084-2090.
- [24] 李保飞,邵珺杰,李泽西. 基于生成对抗网络的煤矿井下视频图像超分辨率复原方法研究 [J]. 内蒙古煤炭经济, 2021(2): 84-85.
- LI B F, SHAO Y J, LI Z X. Research on super-resolution restoration method of underground video image in coal mine based on generated countermeasure network [J]. Inner Mongolia Coal Economy, 2021(2): 84-85.
- [25] HOU Q B, ZHOU D Q, FENG J S. Coordinate attention for efficient mobile network design [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13713-13722.
- [26] JIE H, LI S, GANG S, et al. Squeeze-and-excitation networks [C]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 7132-7141.

- [27] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [J]. European Conference on Computer Vision, 2018:3-19.
- [28] HORÉ A, ZIOU D. Image quality metrics: PSNR vs SSIM [J]. Proceedings-International Conference on Pattern Recognition, 2010:2366-2369.
- [29] WANG Z, BOVIK A C, SHEIKH H R, et al. Image quality assessment: From error visibility to structural similarity[J]. IEEE Transactions on Image Processing, 2004, 13(4): 600-612.
- [30] KEYS R. Cubic convolution interpolation for digital image processing[J]. IEEE Transactions on Acoustics, Speech, and Signal Processing, 1981, 29 (6): 1153-1160.
- [31] AHN N, KANG B, SOHN K A. Fast, accurate, and lightweight super-resolution with cascading residual network[C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018: 252-268.
- [32] LI J, FANG F, MEI K, et al. Multi-scale residual network for image super-resolution [C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018: 517-532.
- [33] HE X Y, MO Z T, WANG P S, et al. ODE-inspired network design for single image super-resolution [C]. Proceedings of the 2019 IEEE CVF Conference on Computer Vision and Pattern Recognition (CVPR), Piscataway, NJ, USA: IEEE, 2019: 1732-1741.
- [34] TIMOFTE R, AGUSTSSON E, VAN GOOL L, et al. Ntire 2017 challenge on single image super-resolution: Methods and results [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2017: 114-125.
- [35] SZEGEDY C, IOFFE S, VANHOUCKE V, et al. Inception-v4, inception-resnet and the impact of residual connections on learning [C]. Thirty-First AAAI Conference on Artificial Intelligence, 2017.
- [36] BEVILACQUA M, ROUMY A, GUILLEMOT C, et al. Low-complexity single image super-resolution based on nonnegative neighbor embedding [C]. British Machine Vision Conference. BMVA Press, 2012.
- [37] ZEYDE R, ELAD M, PROTTER M. On single image scale-up using sparse-representations [C]. International Conference on Curves and Surfaces, Springer, Berlin, Heidelberg, 2010: 711-730.
- [38] MARTIN D, FOWLKES C, TAL D, et al. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics [C]. Proceedings Eighth IEEE International Conference on Computer Vision, 2001, 2: 416-423.

作者简介



程德强, 2007 年于中国矿业大学获得博士学位, 现为中国矿业大学教授、博士生导师, 主要研究方向为机器视觉与模式识别、图像智能检测与信息处理。

E-mail: chengdq@cumt.edu.cn

Cheng Deqiang received his Ph. D. degree from China University of Mining and Technology in 2007. He is currently a professor and a Ph. D. advisor at China University of Mining and Technology. His main research interests include machine vision and pattern recognition, image intelligent detection and information processing.



寇旗旗 (通信作者), 2019 年于中国矿业大学获得博士学位, 现为中国矿业大学讲师, 主要研究方向为图像处理与模式识别。

E-mail: kouqiqi@cumt.edu.cn。

Kou Qiqi (Corresponding author) received his Ph. D. degree from China University of Mining and Technology in 2019. He is currently a lecturer at China University of Mining and Technology. His main research interests include image processing and pattern recognition.