

文章编号 1004-924X(2025)10-1657-15

多尺度深层特征蒸馏的图像超分辨率重建

李 想^{1,2}, 熊 凌^{1,2*}, 叶道辉³, 李姝凡³

(1. 武汉科技大学 人工智能与自动化学院, 湖北 武汉 430081;

2. 武汉科技大学 冶金自动化与检测技术教育部工程研究中心, 湖北 武汉 430081;

3. 中石化江钻石油机械有限公司, 湖北 武汉 430200)

摘要:针对现有的超分辨率重建算法难以充分利用图像的多尺度信息和深层特征的问题,提出了多尺度深层特征蒸馏的图像超分辨率重建方法(MSDFDN)。首先,采用 ConvNeXt 卷积替代传统卷积层,以较小的计算成本来增加网络的深度,从而提高网络的性能;其次,设计了多尺度深层特征蒸馏模块,通过构造不同尺度的 ConvNeXt 卷积层,结合残差特征蒸馏机制,绕过丰富的低频信息,提取残差块中的多尺度深层特征;最后,在模块的末端引入注意力机制,自适应地对提取的特征进行加权,使网络更加关注高频信息。在基准数据集以及自建 PDC 钻头复合片数据集上,与其他先进的轻量级超分辨率重建算法进行对比,本文方法所得图像的峰值信噪比和结构相似性定量数据均有提升,尤其在细节信息较多的 Urban100 数据集上 4 倍重建图像的峰值信噪比达到了 26.49 dB,结构相似性达到了 0.797 6。实验结果表明所提出方法具有更好的客观和主观度量结果。

关键词:图像超分辨率重建;卷积神经网络;轻量级;多尺度特征蒸馏;注意力机制

中图分类号:TP391.4 **文献标识码:**A

doi:10.37188/OPE.20253310.1657

CSTR:32169.14.OPE.20253310.1657

Image super-resolution reconstruction of multi-scale deep feature distillation

LI Xiang^{1,2}, XIONG Ling^{1,2*}, YE Daohui³, LI Shufan³

(1. School of Artificial Intelligence and Automation, Wuhan University of Science and Technology, Wuhan 430081, China;

2. Engineering Research Center for Metallurgical Automation and Measurement Technology of Ministry of Education, Wuhan University of Science and Technology, Wuhan 430081, China;

3. Sinopec Jiang Diamond Oil Machinery Co., Ltd, Wuhan 430200, China)

* Corresponding author, E-mail: xionglings@wust.edu.cn

Abstract: Aiming at the problem that existing super-resolution reconstruction algorithms were difficult to fully utilize multi-scale information and deep features of images, an image super-resolution reconstruction method based on multi-scale deep feature distillation (MSDFDN) was proposed. First, ConvNeXt convolution was used to replace traditional convolution layers, increasing network depth with lower computation-

收稿日期:2024-11-12;修订日期:2025-02-10.

基金项目:国家自然科学基金(No. 62173261);湖北省重点研发计划项目(No. 2023BAB003);武汉市重点研发计划项目(No. 2023010402010603)

al cost to improve performance. Second, a multi-scale deep feature distillation module was designed. By constructing ConvNeXt convolution layers of different scales and combining them with a residual feature distillation mechanism, multi-scale deep features in residual blocks were extracted while bypassing rich low-frequency information. Finally, an attention mechanism was introduced at the end of the module to adaptively weight extracted features, enabling the network to focus more on high-frequency information. Compared with other advanced lightweight super-resolution reconstruction algorithms on benchmark datasets and the self-built PDC bit composite dataset, the peak signal-to-noise ratio and structural similarity quantitative metrics of images obtained by this method showed improvement. Especially on the Urban100 dataset with more detailed information, the peak signal-to-noise ratio of the four-fold reconstructed image reaches 26.49 dB, and the structural similarity reaches 0.797 6. Experimental results show that the proposed method has better objective and subjective measurement results.

Key words: image super-resolution; convolutional neural network; lightweight; multi-scale feature distillation; attention mechanism

1 引言

在当今数字图像处理和计算机视觉领域,单图像超分辨率重建(Single Image Super-Resolution, SISR)技术受到了广泛关注。SISR的目标是从单张低分辨率(Low-Resolution, LR)图像中重建出对应的高分辨率(High-Resolution, HR)图像^[1]。超分辨率重建技术属于数字图像处理与模式识别、计算机视觉等多学科交叉的技术领域,广泛应用于医学成像^[2]、遥感成像^[3]、视频超分辨率^[4]等领域中,且在工业应用中具有重要价值。

近年来,随着深度学习的快速发展,基于深度卷积神经网络(Convolutional Neural Network, CNN)的超分辨率方法取得了显著进展。Dong等^[5]首次将深度学习引入超分辨率重建领域,提出了超分辨率卷积神经网络(Super-Resolution Convolutional Neural Network, SRCNN),通过逐层提取和重建图像特征,实现了高效的图像超分辨率重建,但由于其模型结构相对简单,网络较浅,无法充分捕捉复杂的高频信息。Dong等^[6]进一步提出了快速超分辨率卷积神经网络(Fast Super-Resolution Convolutional Neural Network, FSRCNN),通过更深的网络结构和更小的卷积核,实现了更高效的特征提取和图像重建,且先进行特征提取后再进行上采样,大幅降低了计算量,速度显著提高。Shi等^[7]提出了一种高效的亚像素卷积神经网络(Efficient Sub-Pixel

Convolutional Neural Network, ESPCN),它打破传统的上采样方式,通过先在低分辨率空间进行卷积操作,然后通过亚像素卷积操作将特征图映射到高分辨率空间,使得模型更高效且易于扩展,得到比FSRCNN网络模型更好的重建效果。更深的网络通常具有更强的学习能力,因此研究人员通常会构建更深更宽的网络,以获取更多信息量更大的高层特征,从而追求更好的性能。He等^[8]提出的残差网络(Residual Network, ResNet),通过引入残差连接有效解决了网络加深导致的梯度消失和退化问题,使得训练更深的网络成为可能,显著提升了深度学习模型的训练效果和精度。Kim等^[9]提出了非常深的超分辨率网络(Very Deep Super-Resolution network, VDSR),通过堆叠20层卷积层并使用残差连接直接学习高分辨率图像与低分辨率输入之间的残差,大幅加快了收敛速度并降低了训练难度,提升了图像重建的质量。Lim等^[10]提出了增强型深度超分辨率网络(Enhanced Deep Super-Resolution network, EDSR),通过简化残差块结构、加深网络层数,并去除不适用于低层任务的归一化层,使得模型在超分辨率重建任务中更加有效,能够更好地保留图像的细节和纹理。

信息蒸馏技术在超分辨率重建中的应用日益广泛,该技术旨在降低计算负担。信息蒸馏沿通道维度将中间特征分为两部分,一部分来保留信息,另一部分用于后续卷积层的进一步处理,这种设计能够大幅减少运算量,提高模型的计算

效率。Zheng 等^[11]提出新型信息蒸馏网络(Information Distillation Network, IDN),引入了信息蒸馏模块,通过分离和精炼关键信息,提高了网络的效率和重建质量,同时减少了参数量和计算开销,在降低计算成本的同时维持了模型的性能。Hui 等^[12]提出信息多蒸馏网络(Information Multi-Distillation Network, IMDN),创新性地设计了多级信息蒸馏模块。该模块通过分层精炼不同层次的特征,在保持网络轻量化的同时,其重建质量可媲美甚至超越复杂模型。Liu 等^[13]对 IMDN 架构进行改进,并提出一种名为残差特征蒸馏网络(Residual Feature Distillation Network, RFDN)的轻量级模型,结合了残差学习和特征蒸馏,通过残差特征蒸馏模块有效提取和聚合多层次的关键信息,提升了图像重建的质量,在性能和模型复杂度方面实现了更好的权衡。Li 等^[14]提出了蓝图可分离残差网络(Blueprint Separable Residual Network, BSRN),在 RFDN 的基础上使用蓝图可分离卷积(Blueprint Separable Convolution, BSConv)取代了冗余的卷积操作,从而大幅降低了计算量和参数量,并且通过引入更有效的注意力模块来增强模型能力,取得了更好的性能。

目前大多数超分辨率重建算法主要存在两方面问题:一是为了提高重建性能,盲目增加网络深度导致计算成本过高,无法应用于边缘设备;二是难以充分利用图像的多尺度信息和深层特征。基于以上问题,本文提出了一种多尺度深层特征蒸馏的图像超分辨率重建网络(MSDFDN)。受 ConvNeXt Block^[15]的启发,本文通过改变 ConvNeXt 卷积中逐深度卷积核尺寸,构建不同尺度的 ConvNeXt 卷积层代替标准卷积层,同时保留逆瓶颈层架构,以较小的计算成本来增加网络的深度,从而提高网络的性能。设计多尺度深层特征蒸馏模块(MSDFDB)作为网络的主要特征提取模块。MSDFDB 叠加不同尺度的 ConvNeXt 卷积层,结合残差特征蒸馏机制可以绕过丰富的低频信息,提取残差块有助于恢复更多视觉细节的多尺度深层特征。在 MSDFDB 模块的最后加入空间注意力机制和通道注意力机制,自适应地对提取到的特征进行加权,使网络关注图像中的重要特征区域,以产生更具代表

性的特征。

2 算法设计

2.1 网络总体结构

本文所提出的 MSDFDN 由四个主要模块组成,分别为浅层特征提取模块、深层特征提取模块、特征融合模块和重建模块。浅层特征提取模块使用一个标准 3×3 卷积层将 RGB 通道转换到特征空间,并从输入的低分辨率图像中提取浅层特征;深层特征提取模块由 6 个 MSDFDB 模块级联组成,用于提取深层特征。每个 MSDFDB 模块中,使用多尺度的 ConvNeXt 卷积层结合残差特征蒸馏机制提取残差块中的多尺度深层特征,并使用 1×1 卷积层融合多尺度特征,最后经过空间注意力模块和通道注意力模块,更多地关注携带高频信息的区域;为了解决深度网络训练过程中的信息丢失问题,在特征融合模块中,使用 1×1 卷积层对 MSDFDN 的输出层进行聚合和降维,并使用一个 ConvNeXt-3 卷积层进行特征融合。上采样模块由 3×3 标准卷积层和亚像素卷积层组成,将上采样输出与经过双三次插值处理的 LR 图像输出相加得到最终重建结果。网络架构如图 1 所示。下面详细介绍 MSDFDN 的各个部分。

假定输入的 LR 图像为 I_{LR} , I_{LR} 首先通过一个 3×3 标准卷积层,提取浅层特征:

$$F_0 = \text{Conv}_{3 \times 3}(I_{LR}), \quad (1)$$

其中: $\text{Conv}_{3 \times 3}(\cdot)$ 为 3×3 标准卷积层, F_0 为其输出特征,通道数为 48。 F_0 再输入到 MSDFDB,进行深层特征提取。 F_0 共经过 6 个 MSDFDB,每个 MSDFDB 的输出可表示为:

$$F_n = H_n(F_{n-1}), n = 1, 2, \dots, 6, \quad (2)$$

其中: $H_n(\cdot)$ 为第 n 个 MSDFDB 函数, F_n 为其输出特征,每个 MSDFDB 模块的输出特征图大小和通道数与输入保持一致。对每个模块的输出特征在通道维度拼接:

$$F_{\text{fused}} = H_{\text{fusion}}(\text{Concat}(F_1, F_2, \dots, F_6)), \quad (3)$$

其中: $H_{\text{fusion}}(\cdot)$ 为特征融合模块,由 1×1 卷积层, GELU 激活函数和 ConvNeXt-3 卷积层构成, F_{fused} 表示聚合特征; $\text{Concat}(\cdot)$ 表示将特征在通道维度进行拼接操作。

$$I_{SR} = H_{\text{up}}(F_{\text{fused}} + F_0) + H_{\text{bic}}(I_{LR}), \quad (4)$$




图1 多尺度深层特征蒸馏网络结构

Fig. 1 Multi-scale deep feature distillation network structure

其中: $H_{up}(\cdot)$ 为上采样 Upsampler 函数; $H_{bic}(\cdot)$ 为传统的双三次插值函数, 叠加到残差的输出 $H_{up}(\cdot)$, 得到最终输出的目标 SR 图像 I_{SR} 。

为了使网络保留更多的图像细节, 使用平均绝对误差 (MAE) 对模型进行优化, 用公式可表述为:

$$L(\theta) = \frac{1}{N} \sum_{i=1}^N \|H_{MSDFDN}(I_{LR}^i) - I_{HR}^i\|_1, \quad (5)$$

其中: θ 为网络模型的参数集; N 为样本数量; $H_{MSDFDN}(\cdot)$ 表示 MSDFDN 函数, I_{LR}^i 和 I_{HR}^i 分别表示第 i 个样本对应的低分辨率图像和真实高分辨率图像; $\|\cdot\|_1$ 为 $L1$ 范数。

2.2 多尺度深层特征蒸馏块

为了提取图像固有的多尺度特性并抑制冗余特征, 本文设计了一种多尺度深层特征蒸馏块作为主要特征提取模块, 其结构如图 2 所示。该模块主要由三部分组成: 多尺度深层特征提取、特征蒸馏和注意力机制。

MSDFDB 通过堆叠不同尺度的 ConvNeXt 卷积块来提取图像中的多尺度特征, ConvNeXt 卷积块是一种逆瓶颈层架构, 将标准卷积分解为逐深度卷积和逐点 1×1 卷积, 在逐深度卷积后先使用逐点 1×1 卷积将通道数放大 4 倍, 创造高维隐空间以增强非线性表达能力。再使用一个逐点 1×1 卷积恢复到原来的通道数。该逆瓶颈结构在降低计算复杂度的同时, 增强特征表达能力, 使网络具备更强的非线性建模能力。其中, 逐深度卷积仅在单个通道内部执行卷积操作, 极大地减少了计算量, 而逐点 1×1 卷积则负责跨通道的信息交互, 以恢复和增强特征表示。Con-




图2 多尺度深层特征蒸馏架构

Fig. 2 Multi-scale deep feature distillation architecture

vNeXt-3, ConvNeXt-5, ConvNeXt-7 分别对应逐深度卷积核的大小为 3, 5, 7 的 ConvNeXt 卷积块, 其中 ConvNeXt-3 的结构如图 3 所示。MSDFDB 在浅层使用 3×3 卷积核, 利用其较小的感受野和高计算效率, 专注于提取图像的局部细




图3 ConvNeXt-3卷积层

Fig. 3 ConvNeXt-3 convolutional layer

节和低频信息,从而增强纹理和边缘特征的表达能力;中层过渡到 5×5 卷积核,通过扩展感受野,逐渐融入更广泛的上下文信息;深层则采用 7×7 卷积核,进一步扩大感受野,以更有效地建模全局结构信息,捕获长距离依赖关系。最终,末端使用ConvNeXt-3模块优化多尺度特征的提取与融合。

多尺度深层特征蒸馏块只在每个ConvNeXt卷积块的 $4 \times \text{dim}$ 层使用GELU激活函数。所有输出可表示为:

$$F_{d1}, F_{c1} = \text{Conv}_{1 \times 1}(\text{ConvNeXt}_{3 \times 3}(F_{n-1})), \quad (\text{ConvNeXt}_{3 \times 3}(F_{n-1}) + F_{n-1}), \quad (6)$$

$$F_{d2}, F_{c2} = \text{Conv}_{1 \times 1}(\text{ConvNeXt}_{5 \times 5}(F_{c1})), \quad (\text{ConvNeXt}_{5 \times 5}(F_{c1}) + F_{c1}), \quad (7)$$

$$F_{d3}, F_{c3} = \text{Conv}_{1 \times 1}(\text{ConvNeXt}_{7 \times 7}(F_{c2})), \quad (\text{ConvNeXt}_{7 \times 7}(F_{c2}) + F_{c2}), \quad (8)$$

$$F_{d4} = \text{ConvNeXt}_{3 \times 3}(F_{c3}), \quad (9)$$

其中: $\text{Conv}_{1 \times 1}(\cdot)$ 为 1×1 标准卷积层, $\text{ConvNeXt}_{3 \times 3}(\cdot)$, $\text{ConvNeXt}_{5 \times 5}(\cdot)$, $\text{ConvNeXt}_{7 \times 7}(\cdot)$ 分别表示卷积核大小为 3, 5, 7 的 ConvNeXt 卷积块, 蒸馏特征的通道数为输入通道数的 $1/2$; 在特征浓缩阶段, 将蒸馏特征 $F_{d1}, F_{d2}, F_{d3}, F_{d4}$ 在通道维度拼接, 然后通过 1×1 卷积浓缩为:

$$F_{\text{condensed}} = \text{Conv}_{1 \times 1}(\text{Concat}(F_{d1}, F_{d2}, F_{d3}, F_{d4})), \quad (10)$$

其中: $\text{Concat}(\cdot)$ 表示将特征在通道维度拼接操作, $F_{\text{condensed}}$ 表示浓缩特征, 其通道数和 MSDFDB

模块的输入通道数保持一致。为了对提取到的特征进一步增强, 在 MSDFDB 中引入空间注意力机制 ESA 和通道注意力机制 CCA, 用公式表示为:

$$F_{\text{enhanced}} = H_{\text{CCA}}(H_{\text{ESA}}(F_{\text{condensed}})), \quad (11)$$

其中: F_{enhanced} 表示增强特征, H_{ESA} 和 H_{CCA} 分别表示 ESA 和 CCA 注意力机制模块。最后, 使用局部残差连接将通道注意力机制输出特征图与模块输入相加构成一个多尺度深层特征蒸馏模块的输出特征:

$$F_n = F_{n-1} + F_{\text{enhanced}}. \quad (12)$$

2.3 注意力机制

Liu 等^[16]提出的增强空间注意力(Enhanced Spatial Attention, ESA)模块在轻量级图像超分辨率重建中表现优异。ESA 模块利用了空间注意力机制, 关注对目标任务贡献更大的区域, 从而提升特征提取效果。ESA 模块的结构图如图 4 所示, 首先使用 1×1 卷积对输入特征进行降维, 随后, 通过跨步卷积和最大池化操作减少空间尺寸, 以扩大感受野, 接着使用卷积组学习特征权重, 并将其上采样还原至原始尺寸, 最后使




图4 ESA模块结构

Fig. 4 Architecture of ESA block

用 1×1 卷积恢复通道维度。经过 Sigmoid 激活后,与原始输入点乘,得到最终输出特征。

Hui 等^[12]提出了一种对比度感知通道注意力模块 (Contrast-aware Channel Attention, CCA),不同于传统的利用每个通道特征的均值计算通道注意力,CCA 使用包括均值和标准差之和在内的对比度信息计算通道注意力权重,其结构如图 5 所示。本文模型在 ESA 模块之后级联通道注意力模块 CCA,通过跨通道的信息交互和自适应权重分配,提升模型对关键特征的关注能力。




图 5 CCA 模块结构

Fig. 5 Architecture of CCA block

3 实验结果与分析

3.1 实验数据与设置

训练数据集采用 DIV2K^[17]数据集的 800 张训练图像,测试集采用 5 个广泛使用的基准数据集: Set5^[18], Set14^[19], BSD100^[20], Urban100^[21], Manga109^[22]。自建数据集是工厂现场采集的 PDC 钻头复合片图像,其中 320 张作为训练集,40 张作为验证集,30 张作为测试集,通过双三次下采样生成低分辨率图像与高分辨率图像的配准训练对。评价指标采用峰值信噪比 (Peak Signal-to-Noise Ratio, PSNR) 和结构相似度指数 (Structural Similarity Index, SSIM),在 YCbCr 空间的 Y 通道上计算两个指标结果,并裁剪对应尺度的图像边缘像素值。PSNR 和 SSIM 的值越高,表示模型重建性能越好。

所提 MSDFDN 由 6 个 MSDFDB 组成,通道数为 48,MSDFDN+ 由 7 个 MSDFDB 组成,通道数为 64。采用随机旋转 90° , 180° , 270° 和水平翻转的数据增强方法。小批量数据大小设置为 32,每个 LR 输入的尺寸设置为 $48 \text{ pixels} \times 48 \text{ pixels}$ 。采用自适应矩估计优化器 (Adam) 对模型进行训练, $\beta_1=0.9$, $\beta_2=0.999$ 。初始学习率设置为 5×10^{-4} ,每 2×10^5 减半。采用 L_1 损失对模型进行优化,总迭代次数为 1.2×10^6 。实验环境基于 Windows10 操作系统, CPU 型号为 Intel Core i9-11900K,运行内存为 64 GB, GPU 型号为 NVIDIA GeForce RTX 3080 Ti。

3.2 重建算法对比

3.2.1 客观定量分析

为了客观地评价重建算法的性能,将所提算法在公开数据集上的训练结果与 VDSR^[9], DRCN^[23], IDN^[11], CARN^[24], IMDN^[12], RFDN^[13], SMSR^[25], ShuffleMixer^[26], VLESR^[27], SAFMN^[28] 及 LBRN^[29] 等轻量级图像超分算法进行了比较。不同算法 2 倍、3 倍和 4 倍的超分结果如表 1~表 3 所示,最优结果用加粗字体表示,次优结果加下划线表示,“-”表示无数值。MSDFDN 方法在各数据集上均表现出良好的重建性能,从表 1~表 3 中数据可知,MSDFDN 在大多数数据集上都优于其他方法。针对三种上采样尺度的重建结果,在纹理密集的 Urban100 数据集和 Manga109 数据集上均取得了最高的 PSNR 和 SSIM 值。MSDFDN+ 在 5 个基准数据集上均取得了最优的 2 倍、3 倍和 4 倍超分结果。实验结果表明,本文算法在图像超分辨率方面具有明显的优势,重建性能也有所提高。

将 MSDFDN 与传统的 Bicubic 插值算法以及 RFDN^[13], ShuffleMixer^[26], SAFMN^[28] 等算法在自建 PDC 钻头复合片数据集上的重建性能进行比较。不同算法的 2 倍、3 倍和 4 倍的超分结果如表 4 所示,每行最优结果用加粗字体表示。由表 4 中数据可以看出,MSDFDN 在 PDC30 测试集上取得了最高的 PSNR 和 SSIM 值。实验结果证明了 MSDFDN 在 PDC 钻头复合片图像超分辨率方面的优势。

表 1 不同算法在 5 个基准数据集上 2 倍重建性能

Tab. 1 Performance of different algorithms on five benchmark datasets at $\times 2$ magnification

Method	Scale	PSNR/SSIM				
		Set5	Set14	BSD100	Urban100	Manga109
Bicubic	$\times 2$	33.69/0.928 4	30.34/0.867 5	29.57/0.843 8	26.88/0.843 8	30.80/0.933 9
VDSR ^[9]	$\times 2$	37.53/0.958 7	33.03/0.912 4	31.90/0.896 0	30.76/0.914 0	37.22/0.972 9
DRCN ^[23]	$\times 2$	37.63/0.958 8	33.04/0.911 8	31.85/0.894 2	30.75/0.913 3	37.63/0.972 3
IDN ^[11]	$\times 2$	37.83/0.960 0	33.30/0.914 8	32.08/0.898 5	31.27/0.919 6	38.01/0.974 9
CARN ^[24]	$\times 2$	37.76/0.959 0	33.52/0.916 6	32.09/0.897 8	31.92/0.925 6	— / —
IMDN ^[12]	$\times 2$	38.00/0.960 5	33.63/0.917 7	32.19/0.899 6	32.17/0.928 3	38.88/0.977 4
RFDN ^[13]	$\times 2$	38.05/0.960 6	<u>33.68/0.918 4</u>	32.16/0.899 4	32.12/0.927 8	38.88/0.977 3
SMSR ^[25]	$\times 2$	38.00/0.960 1	33.64/0.917 9	32.17/0.899 0	32.19/0.928 4	38.76/0.977 1
ShuffleMixer ^[26]	$\times 2$	38.01/0.960 6	33.63/0.918 0	32.17/0.899 5	31.89/0.925 7	38.83/0.977 4
VLES ^[27]	$\times 2$	38.01/0.960 5	33.58/0.917 7	32.16/0.899 3	32.14/0.928 0	38.75/0.977 0
SAFMN ^[28]	$\times 2$	38.00/0.960 5	33.54/0.917 7	32.16/0.899 5	31.84/0.925 6	38.71/0.977 1
LBRN ^[29]	$\times 2$	38.08/0.960 8	33.57/0.917 3	32.23/0.900 5	32.35/0.930 3	<u>38.93/0.977 7</u>
MSDFDN	$\times 2$	<u>38.13/0.960 9</u>	<u>33.68/0.918 5</u>	<u>32.26/0.900 8</u>	<u>32.44/0.930 9</u>	<u>38.94/0.977 7</u>
MSDFDN+	$\times 2$	38.17/0.961 1	33.82/0.920 2	32.28/0.901 0	32.58/0.932 3	39.09/0.977 8

表 2 不同算法在 5 个基准数据集上 3 倍重建性能

Tab. 2 Performance of different algorithms on five benchmark datasets at $\times 3$ magnification

Method	Scale	PSNR/SSIM				
		Set5	Set14	BSD100	Urban100	Manga109
Bicubic	$\times 3$	30.39/0.868 2	27.55/0.774 2	27.21/0.738 5	24.46/0.734 9	26.95/0.855 6
VDSR ^[9]	$\times 3$	33.66/0.921 3	29.77/0.831 4	28.82/0.797 6	27.14/0.827 9	32.01/0.934 0
DRCN ^[23]	$\times 3$	33.82/0.922 6	29.76/0.831 1	28.80/0.796 3	27.15/0.827 6	32.24/0.934 3
IDN ^[11]	$\times 3$	34.11/0.925 3	29.99/0.835 4	28.95/0.801 3	27.42/0.835 9	32.71/0.938 1
CARN ^[24]	$\times 3$	34.29/0.925 5	30.29/0.840 7	29.06/0.803 4	28.06/0.849 3	— / —
IMDN ^[12]	$\times 3$	34.36/0.927 0	30.32/0.841 7	29.09/0.804 6	28.17/0.851 9	33.61/0.944 5
RFDN ^[13]	$\times 3$	34.41/0.927 3	30.34/0.842 0	29.09/0.804 2	28.21/0.852 5	33.67/0.944 9
SMSR ^[25]	$\times 3$	34.40/0.927 0	30.33/0.841 2	29.10/0.805 0	28.25/0.853 6	33.68/0.944 5
ShuffleMixer ^[26]	$\times 3$	34.40/0.927 2	30.37/0.842 3	29.12/0.805 1	28.08/0.849 8	33.69/0.944 8
VLES ^[27]	$\times 3$	34.40/0.927 2	30.34/0.841 5	29.08/0.804 3	28.16/0.851 9	33.61/0.944 5
SAFMN ^[28]	$\times 3$	34.34/0.926 7	30.33/0.841 8	29.08/0.804 8	27.95/0.847 4	33.52/0.943 7
LBRN ^[29]	$\times 3$	34.43/0.927 6	30.39/0.842 9	29.13/0.805 9	28.29/0.854 5	33.72/0.945 5
MSDFDN	$\times 3$	<u>34.54/0.928 2</u>	<u>30.45/0.844 8</u>	<u>29.18/0.806 9</u>	<u>28.47/0.858 6</u>	<u>33.96/0.946 8</u>
MSDFDN+	$\times 3$	34.61/0.928 9	30.52/0.845 9	29.23/0.808 3	28.64/0.861 7	34.12/0.947 9

表 3 不同算法在 5 个基准数据集上 4 倍重建性能

Tab. 3 Performance of different algorithms on five benchmark datasets at $\times 4$ magnification

Method	Scale	PSNR/SSIM				
		Set5	Set14	BSD100	Urban100	Manga109
Bicubic	$\times 4$	28.42/0.810 4	26.00/0.702 7	25.96/0.667 5	23.14/0.657 7	24.89/0.786 6
VDSR ^[9]	$\times 4$	31.35/0.883 8	28.01/0.767 4	27.29/0.725 1	25.18/0.752 4	28.83/0.887 0
DRCN ^{†[23]}	$\times 4$	31.53/0.885 4	28.02/0.767 0	27.23/0.723 3	25.14/0.751 0	28.93/0.885 4
IDN ^[11]	$\times 4$	31.82/0.890 3	28.25/0.773 0	27.41/0.729 7	25.41/0.763 2	29.41/0.894 2
CARN ^[24]	$\times 4$	32.13/0.893 7	28.60/0.780 6	27.58/0.734 9	26.07/0.783 7	— / —
IMDN ^{†[12]}	$\times 4$	32.21/0.894 8	28.58/0.781 1	27.56/0.735 3	26.04/0.783 8	30.45/0.907 5
RFDN ^[13]	$\times 4$	32.24/0.895 2	28.61/0.781 9	27.57/0.736 0	26.11/0.785 8	30.58/0.908 9
SMSR ^[25]	$\times 4$	32.12/0.893 2	28.55/0.780 8	27.55/0.735 1	26.11/0.786 8	30.54/0.908 5
ShuffleMixer ^{†[26]}	$\times 4$	32.21/0.895 3	28.66/0.782 7	27.61/0.736 6	26.08/0.783 5	30.65/0.909 3
VLESR ^[27]	$\times 4$	32.17/0.894 5	28.55/0.780 2	27.55/0.734 5	26.03/0.783 0	30.48/0.907 3
SAFMN ^[28]	$\times 4$	32.18/0.894 8	28.60/0.781 3	27.58/0.735 9	25.97/0.780 9	30.43/0.906 3
LBRN ^{†[29]}	$\times 4$	<u>32.33/0.896 4</u>	28.62/0.782 6	27.60/0.737 7	26.17/0.788 2	30.60/0.910 2
MSDFDN	$\times 4$	<u>32.28/0.896 5</u>	<u>28.67/0.783 9</u>	<u>27.63/0.738 2</u>	<u>26.27/0.791 7</u>	<u>30.73/0.911 4</u>
MSDFDN+	$\times 4$	32.46/0.898 2	28.78/0.785 9	27.68/0.740 1	26.49/0.797 6	30.96/0.914 4

表 4 不同算法在 PDC 钻头复合片数据集上性能

Tab. 4 Performance of different algorithms on PDC bit composite dataset

Dataset	Scale	PSNR/SSIM				
		Bicubic	RFDN ^{†[13]}	ShuffleMixer ^{†[26]}	SAFMN ^[28]	MSDFDN
PDC30	$\times 2$	35.40/0.954 8	41.87/0.978 6	42.02/0.978 5	41.81/0.977 4	42.13/0.978 9
	$\times 3$	32.49/0.917 2	37.17/0.946 3	37.24/0.946 5	37.18/0.946 1	37.26/0.946 7
	$\times 4$	30.49/0.879 5	34.37/0.915 1	34.32/0.915 1	34.32/0.914 7	34.38/0.915 2

3. 2. 2 主观视觉效果

在定量评估之外,还将 MSDFDN 与传统的 Bicubic 插值算法及 CARN^[24],IMDN^[12],RFDN^[13],

ShuffleMixer^[26] 和 SAFMN^[28] 等基于深度学习的高效超分辨率方法进行了定性比较。图 6、图 7、图 8 分别展示了不同算法对 Urban100 数据集中



图 6 Urban100 数据集中的“img_061”在放大 4 倍下的重建效果对比

Fig. 6 Reconstruction effect comparison of “img_061” from Urban100 datasets at $\times 4$ magnification




图 7 Urban100 数据集中的“img_067”在放大 4 倍下的重建效果对比


Fig. 7 Reconstruction effect comparison of “img_067” from Urban100 datasets at $\times 4$ magnification

图 8 Urban100 数据集中的“img_073”在放大 4 倍下的重建效果对比

Fig. 8 Reconstruction effect comparison of “img_073” from Urban100 datasets at $\times 4$ magnification

img_061.png, img_067.png 和 img_073.png 图像的 4 倍超分辨率重建结果。结果显示, Bicubic 插值算法生成的图像较为模糊, 细节难以展现。其他基于深度学习的方法虽能较好恢复整体轮廓, 但在纹理与细节重建上存在失真和伪影。相比之下, MSDFDN 网络在纹理还原方面具有更优表现, 能够更精准地重建复杂细节, 凸显了其在高质量图像超分辨率重建中的优势。图 9 展示了 PDC30 中 028.png 通过双三次下采样 4 倍生成的低分辨率图像以及不同方法的 4 倍超分辨率重建的结果, 其中 MSDFDN 表现出更好的重建效果。

3.3 消融实验

3.3.1 MSDFDB 模块数量消融实验

为了在模型性能和模型大小之间取得平衡,

进行了相关的实验研究。定义 n 为网络中模块的数量, 通过设置不同的 n 值, 即不同的模型大小, 观察模型取得的重建性能, 设置消融实验学习率为 5×10^{-4} , 迭代次数为 1×10^6 , 模型通道数为 48, 其他实验条件与上述相同, 表 5 展示了不同模型在 5 个基准数据集上的 2 倍重建图像的平均 PSNR 和 SSIM 值, 每列最优结果用加粗字体表示, 次优结果加下划线表示。从表 5 可以看出, 模型参数量随着模块数量的增加而增加, 当模块数量从 5 个增加到 7 个时, 重建性能在大多数数据集上都有明显的提升, 表明适当增加模块数量有助于增强模型的特征表达能力和重建质量。然而当模块数量从 7 个增加到 8 个时, 性能反而下降, 网络过深可能会引入冗余参数, 干扰高频细节的重建。为了实现模型性能与模型大小的平衡, 最终




图 9 PDC30 数据集中的“028”在放大 4 倍下的重建效果对比
Fig. 9 Reconstruction effect comparison of “028” from PDC30 datasets at $\times 4$ magnification

表 5 MSDFDB 模块数量对所提算法性能的影响

Tab. 5 Influence of the number of MSDFDB modules on the performance of the proposed algorithm

模块数量	Params/K	PSNR/SSIM				
		Set5	Set14	BSD100	Urban100	Manga109
$n=5$	481	38.10/0.960 8	33.67/0.918 8	32.24/0.900 5	32.31/0.930 2	38.86/0.977 3
$n=6$	572	<u>38.13/0.961 0</u>	33.67/0.918 5	32.26/0.900 8	32.44/0.930 9	38.91/0.977 6
$n=7$	664	38.17/0.961 1	33.79/0.920 2	<u>32.26/0.900 7</u>	<u>32.52/0.931 8</u>	39.01/0.977 6
$n=8$	755	<u>38.13/0.961 0</u>	<u>33.76/0.919 1</u>	32.25/0.900 6	<u>32.50/0.931 9</u>	<u>38.97/0.977 2</u>

确定 MSDFDN 与 MSDFDN+ 的模块数分别为 6 和 7,以确保较优的重建效果和计算效率。

3.3.2 注意力机制消融实验

为了验证注意力机制的有效性,对网络中 ESA 和 CCA 两个模块设计了消融实验,Model1 移除 MSDFDN 中的注意力机制模块,Model2 在 Model1 的基础上添加 CCA 模块,Model3 在 Model1 的基础上添加 ESA 模块,Model4 在 Model3 的基础上添加 CCA 模块,设置消融实验学习率为 5×10^{-4} ,迭代次数为 1×10^6 ,MSDFDB 的模块数量为 6,模型通道数为 48,其他实验条件与上述相同,表 6 展示了不同模型在 5 个基准数据集上的 2 倍重建图像的平均 PSNR 和 SSIM 值。其中符号“ $\checkmark$ ”代表包括该模块,“ $\times$ ”表示不包括该模块,各列最优结果用加粗字体表示。结果表明,Model2 在 Model1 的基础

上添加 CCA 模块,在 Set5, Urban100, Manga109 数据集上的重建性能得到了提升,CCA 模块能够有效捕捉特征之间的通道关系,增强关键特征并抑制冗余信息。Model3 在 Model1 的基础上加入 ESA 模块,在 Set5, BSD100, Urban100, Manga109 数据集上的重建性能得到了提升,ESA 模块能够有效关注图像中的细节信息,增强高频特征的表达能力,特别是在包含丰富纹理细节的 Urban100 数据集上表现突出。Model4 在 Model3 的基础上加入 CCA 模块,在 Set5, BSD100, Urban100, Manga109 数据集上的重建性能得到了进一步的提升。ESA 模块主要关注局部空间信息的细节增强,而 CCA 模块则优化全局通道间的信息流,使得特征提取更加高效。两者结合可以充分利用空间与通道注意力的优势,实现更高质量的重建效果。实验结果进一

表 6 注意力机制模块消融实验结果

Tab. 6 Experimental results of attention mechanism module ablation

Method	ESA	CCA	PSNR/SSIM				
			Set5	Set14	BSD100	Urban100	Manga109
Model1	×	×	38.07/0.960 7	33.71/0.918 5	32.22/0.900 4	32.23/0.929 3	38.59/0.977 0
Model2	×	✓	38.10/0.960 8	33.70/0.918 4	32.22/0.900 3	32.36/0.930 3	38.90/0.977 4
Model3	✓	×	38.11/0.960 9	33.69/0.918 5	32.25/0.900 7	32.41/0.930 8	38.87/0.977 3
Model4	✓	✓	38.13/0.961 0	33.67/0.918 5	32.26/0.900 8	32.44/0.930 9	38.91/0.977 6

步验证了 ESA 模块和 CCA 模块在 MSDFDN 中的有效性。

3.3.3 MSDFDB 多尺度结构消融实验

为了验证 MSDFDB 多尺度结构的有效性,对 MSDFDB 模块中不同尺度的 ConvNeXt 残差块的顺序设计了消融实验。MSDFDB-333 表示全部使用 ConvNeXt-3 残差块,不具备多尺度特性。MSDFDB-753 表示正向堆叠顺序为 ConvNeXt-7 残差块、ConvNeXt-5 残差块、ConvNeXt-3 残差块,其中较深层的区块采用较小卷积核残差块,以提取特征图。MSDFDB-357 表示正向堆叠顺序为 ConvNeXt-3 残差块、ConvNeXt-5 残差块、ConvNeXt-7 残差块,将具有较大卷积核的残差块用在较深的区块中学习。设置消融实验学习率为 5×10^{-4} ,迭代次数为 $1 \times$

10^6 , MSDFDB 的模块数量为 6,模型通道数为 48,其他实验条件与上述相同。表 7 展示了不同模型在 5 个基准数据集上的 2 倍重建图像的平均 PSNR 和 SSIM 值,各列最优结果用加粗字体表示。结果表明,使用 MSDFDB-357 的模型在 Set5, BSD100, Urban100, Manga109 数据集上取得了更好的性能。这表明,在较深层使用较大卷积核的策略有助于提取更广域的上下文信息,增强全局结构理解,同时结合浅层的小卷积核捕捉局部细节。相比之下,MSDFDB-753 虽然也具有多尺度特性,但在较深层使用小卷积核限制了对全局特征的建模能力。图 10 为不同尺度的 ConvNeXt 残差块堆叠顺序的模型对 BSD100 数据集中图像 21077 的 2 倍超分辨率重建效果对比,直观地验证了 MSDFDB-357 在细节还原和

表 7 不同算法在 5 个基准数据集上性能

Tab. 7 Performance of different algorithms on five benchmark datasets

Method	PSNR/SSIM				
	Set5	Set14	BSD100	Urban100	Manga109
MSDFDB-333	38.07/0.960 8	33.65/ 0.918 6	32.23/0.900 6	32.32/0.930 0	38.90/ 0.977 6
MSDFDB-753	38.09/0.960 9	33.68/0.918 6	32.24/0.900 5	32.38/0.930 5	38.87/0.977 5
MSDFDB-357	38.13/0.961 0	33.67/0.918 5	32.26/0.900 8	32.44/0.930 9	38.91/0.977 6



图 10 不同尺度的 ConvNeXt 残差块堆叠顺序重建效果对比

Fig. 10 Comparison of different scales of ConvNeXt residual block stacking sequence reconstruction results

纹理保持方面的优势。实验结果验证了所提出

3.4 网络参数量比较

图 11 展示了 MSDFDN 和其他轻量级算法的模型参数量与重建性能之间的对比,其中 PSNR 指标基于 Set5 数据集上的 2 倍超分重建结果。MSDFDN 以较少的参数量实现了更优的性能。与 SMSR、CARN 和 DRCN 等参数量较大的方法相比,MSDFDN 分别以 58%,36% 和 32% 的参数量实现了更好的重建效果,在性能和模型大小之间实现了更好的平衡。MSDFDN+ 在 MSDFDN 的基础上通过增加特征通道数量和模块数量,重建性能得到了进一步的提升,尽管参数量有所增加,但其计算复杂度仍然控制在可接受范围内,使其适用于边缘计算设备或资源受限环境下的高质量图像恢复任务。相比于其他轻量级模型,MSDFDN+ 具有更高的重建质量,适用于医学影像增强、遥感图像超分辨率重建等对重建性能要求较高的应用场景。




图 11 不同算法的参数量和重建性能对比
Fig. 11 Comparison of parameters and reconstruction performance of different algorithms

3.5 超分辨率重建的工业应用

PDC 钻头广泛应用于石油、天然气钻探,矿山勘探及地质工程等领域。PDC 钻头复合片的失效是增加钻井成本的主要因素,对复合片失效程度进行分级是修复钻头的前提。为了确定复合片的失效等级,首先使用 HRNet 网络^[30]对复合片进行语义分割,再使用随机采样一致性算法(RANSAC)对分割后的复合片进行椭圆拟合,根据椭圆拟合结果判定失效程度。

为了验证超分辨率重建对 PDC 钻头复合片

的 MSDFDB 多尺度结构的有效性和优越性。

椭圆拟合结果准确性的影响,从 PDC30 中选取 10 张复合片图像作为测试集,对超分辨率重建前后椭圆拟合结果进行比较,采用拟合误差作为评价指标,包括:平均绝对误差(Mean Absolute Error, MAE)、均方误差(Mean Squared Error, MSE)和最大误差(Maximum Error)。

如表 8 所示,Group1 为低分辨率图像椭圆拟合实验结果,Group2 为使用 MSDFDN 进行 4 倍超分辨率重建后的椭圆拟合实验结果,拟合误差为所有图片进行拟合后得到的平均值。实验结果表明,与超分辨率重建前的结果相比,使用 MSDFDN 进行 4 倍超分辨率重建后椭圆拟合结果的平均绝对误差、均方误差、最大误差都有所下降。

图 12 展示了 PDC30 中 013. png 超分辨率重建前后的语义分割图和椭圆拟合结果。实验结

表 8 超分辨率重建前后椭圆拟合误差对比

Tab. 8 Comparison of ellipse fitting errors before and after super-resolution reconstruction

Group	1	2
MAE/px	0.071	0.043
MSE/px	0.013	0.005
Max Error/px	0.152	0.110




图 12 超分辨率重建前后 PDC30 数据集中“013. png”的语义分割图以及椭圆拟合结果

Fig. 12 Semantic segmentation map and ellipse fitting results of “013. png” from PDC30 datasets before and after super-resolution reconstruction

果表明,超分辨率重建能够增加使用随机采样一致性算法对语义分割后的PDC钻头复合片椭圆拟合的准确性,特别是在低分辨率图像或边缘不清晰的情况下。通过提升图像分辨率,能够捕捉更丰富的细节与更精确的边缘轮廓,从而为椭圆拟合算法提供更高质量的特征点集,最终实现更加准确的椭圆拟合结果。

4 结 论

本文提出了一种多尺度深层特征蒸馏的图像超分辨率重建网络,该网络引入了ConvNeXt卷积层替代传统卷积层,以较小的计算成本来增加网络的深度,从而提高网络的性能;设计了多尺度深层特征蒸馏模块,通过构造不同尺度的ConvNeXt卷积层,结合残差特征蒸馏机制,抑制低频干扰,提取多尺度深层特征,并在模块末端引入有效注意力机制模块来增强模型的代表性。本文算法具有紧凑的结构,且注重高频信息的学

习,有助于恢复更多视觉细节,从而实现轻量级单图像超分辨率重建。在基准数据集以及自建PDC钻头复合片数据集上的实验结果表明,所提算法在客观评价指标和主观视觉效果上均取得更好的图像重建结果,尤其在细节信息较多的Urban100数据集上4倍重建图像的峰值信噪为26.49 dB,结构相似性为0.797 6。在超分辨率重建的工业应用方面,通过实验证明了使用MSDFDN超分辨率重建能够降低使用RANSAC对语义分割后的PDC钻头复合片椭圆拟合的拟合误差。

作者贡献声明:

李想:超分辨率重建方法的提出,论文构思和撰写;

熊凌:实验的设计及数据分析,论文审核;

叶道辉:超分辨率重建的工业应用方法设计;

李姝凡:超分辨率重建的工业应用实验结果分析。

参考文献:

- [1] TSAI R Y, HUANG T S. Multiframe image restoration and registration[J]. *Computer Vision and Image Processing*, 1984, 1: 317-339.
- [2] 刘雪岩, 许聿达, 雷建昕, 等. 基于视差放大与超分辨率的三维光场腹腔镜标定[J]. *光学精密工程*, 2022, 30(5): 510-517.
LIU X Y, XU Y D, LEI J X, et al. Three-dimensional light field endoscope calibration based on light field disparity amplifier and super-resolution network[J]. *Opt. Precision Eng.*, 2022, 30(5): 510-517. (in Chinese)
- [3] 易见兵, 陈俊宽, 曹锋, 等. 轻量级重参数化的遥感图像超分辨率重建网络设计[J]. *光学精密工程*, 2024, 32(2): 268-285.
YI J B, CHEN J K, CAO F, et al. Design of lightweight re-parameterized remote sensing image super-resolution network [J]. *Opt. Precision Eng.*, 2024, 32(2): 268-285. (in Chinese)
- [4] 夏振平, 陈豪, 张宇宁, 等. 基于混合时空卷积的轻量级视频超分辨率重建[J]. *光学精密工程*, 2024, 32(16): 2564-2576.
XIA Z P, CHEN H, ZHANG Y N, et al. Lightweight video super-resolution based on hybrid spatio-temporal convolution [J]. *Opt. Precision Eng.*, 2024, 32(16): 2564-2576. (in Chinese)
- [5] 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.
- [6] DONG C, LOY C C, TANG X O. Accelerating The Super-Resolution Convolutional Neural Network[M]. LEIBE B, MATAS J, SEBE N, et al. Computer vision-ECCV 2016. Lecture notes in computer science. Cham: Springer, 2016, 9906: 391-407.
- [7] SHI W Z, CABALLERO J, HUSZÁR F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network[C]. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. June 27-30, 2016, Las Vegas, NV, USA. IEEE, 2016: 1874-1883.
- [8] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. June 27-30, 2016, Las Vegas, NV, USA. IEEE, 2016: 770-778.

- [9] KIM J, LEE J K, LEE K M. Accurate image super-resolution using very deep convolutional networks[C]. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. June 27-30, 2016, Las Vegas, NV, USA. IEEE, 2016: 1646-1654.
- [10] LIM B, SON S, KIM H, *et al.* Enhanced deep residual networks for single image super-resolution [C]. 2017 *IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. July 21-26, 2017, Honolulu, HI, USA. IEEE, 2017: 1132-1140.
- [11] HUI Z, WANG X M, GAO X B. Fast and accurate single image super-resolution Via information distillation network[C]. 2018 *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. June 18-23, 2018, Salt Lake City, UT, USA. IEEE, 2018: 723-731.
- [12] HUI Z, GAO X B, YANG Y C, *et al.* Lightweight image super-resolution with information multi-distillation network [C]. *Proceedings of the 27th ACM International Conference on Multimedia*. Nice France. ACM, 2019: 2024-2032.
- [13] LIU J, TANG J, WU G S. *Residual Feature Distillation Network for Lightweight Image Super-Resolution* [M]. Computer Vision-ECCV 2020 Workshops. Cham: Springer International Publishing, 2020: 41-55.
- [14] LI Z Y, LIU Y Q, CHEN X Y, *et al.* Blueprint separable residual network for efficient image super-resolution [C]. 2022 *IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. June 19-20, 2022, New Orleans, LA, USA. IEEE, 2022: 832-842.
- [15] LIU Z, MAO H Z, WU C Y, *et al.* A ConvNet for the 2020s[C]. 2022 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 18-24, 2022, New Orleans, LA, USA. IEEE, 2022: 11966-11976.
- [16] LIU J, ZHANG W J, TANG Y T, *et al.* Residual feature aggregation network for image super-resolution[C]. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 13-19, 2020, Seattle, WA, USA. IEEE, 2020: 2356-2365.
- [17] AGUSTSSON E, TIMOFTE R. NTIRE 2017 challenge on single image super-resolution; dataset and study[C]. 2017 *IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. July 21-26, 2017, Honolulu, HI, USA. IEEE, 2017: 1122-1131.
- [18] BEVILACQUA M, ROUMY A, GUILLEMOT C, *et al.* Low-complexity single-image super-resolution based on nonnegative neighbor embedding [C]. *Proceedings of the British Machine Vision Conference 2012*. Surrey. British Machine Vision Association, 2012: 135. 1-135. 10.
- [19] ZEYDE R, ELAD M, PROTTER M. *on Single Image Scale-Up Using Sparse-Representations*[M]. Boissonnat J D, Chenin P, Cohen A, *et al.* Curves and surfaces. Lecture notes in computer science. Heidelberg: Springer, 2012, 6920: 711-730.
- [20] ARBELÁEZ P, MAIRE M, FOWLKES C, *et al.* Contour detection and hierarchical image segmentation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2011, 33(5): 898-916.
- [21] HUANG J B, SINGH A, AHUJA N. Single image super-resolution from transformed self-exemplars[C]. 2015 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. June 7-12, 2015, Boston, MA, USA. IEEE, 2015: 5197-5206.
- [22] MATSUI Y, ITO K, ARAMAKI Y, *et al.* Sketch-based manga retrieval using manga109 dataset [J]. *Multimedia Tools and Applications*, 2017, 76(20): 21811-21838.
- [23] KIM J, LEE J K, LEE K M. Deeply-recursive convolutional network for image super-resolution [C]. 2016 *IEEE Conference on Computer Vision and Pattern Recognition*, 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 1637-1645.
- [24] AHN N, KANG B, SOHN K A. *Fast, Accurate, And Lightweight Super-Resolution with Cascading Residual Network*[M]. Ferrari V, Hebert M, Sminchisescu C, *et al.* Computer vision-ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11214: 256-272.
- [25] WANG L G, DONG X Y, WANG Y Q, *et al.* Exploring sparsity in image super-resolution for efficient inference[C]. 2021 *IEEE/CVF Conference on Computer Vision and Pattern Recognition*

- (CVPR), 20-25, 2021, Nash-ville, TN, USA. New York: IEEE Press, 2021:4915-4924.
- [26] SUN L, PAN J S, TANG J H. ShuffleMixer: an efficient convnet for image super-resolution [J]. *Advances in Neural Information Processing Systems*, 2022, 35: 17314-17326.
- [27] GAO D D, ZHOU D W. A very lightweight and efficient image super-resolution network [J]. *Expert Systems with Applications*, 2023, 213: 118898.
- [28] SUN L, DONG J X, TANG J H, *et al.* Spatially-adaptive feature modulation for efficient image super-resolution[C]. 2023 *IEEE/CVF International Conference on Computer Vision (ICCV)*. October 1-6, 2023, Paris, France. IEEE, 2023: 13144-13153.
- [29] HAO F W, WU J S, LIANG W L, *et al.* L-light-weight blueprint residual network for single image super-resolution[J]. *Expert Systems with Applications*, 2024, 250: 123954.
- [30] SUN K, XIAO B, LIU D, *et al.* Deep high-resolution representation learning for human pose estimation[C]. 2019 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 15-20, 2019, Long Beach, CA, USA. IEEE, 2019: 5686-5696.

作者简介:



李 想(2000—),男,河南南阳人,2023年于河南科技大学获得学士学位,现为武汉科技大学硕士研究生,主要研究方向为图像处理、机器视觉。E-mail: lixiang8568@163.com

通讯作者:



熊 凌(1971—),女,湖北武汉人,2010年于华中科技大学获得博士学位,现为武汉科技大学人工智能与自动化学院教授,主要研究方向为图像处理、模式识别。E-mail: xiongling@wust.edu.cn