

文章编号 1004-924X(2023)17-2584-14

多维注意力机制与选择性特征融合的 图像超分辨率重建

温 剑¹, 邵剑飞^{1*}, 刘 杰², 邵建龙¹, 冯宇航¹, 叶 榕¹

(1. 昆明理工大学 信息工程与自动化学院, 云南 昆明 650500;

2. 云南警官学院 云南警用无人系统创新研究院, 云南 昆明 650223)

摘要:针对图像超分辨率重建过程中提取低分辨率特征效果较差,大量高频信息丢失导致的边缘模糊和伪影问题,提出了融合多维注意力机制与选择性特征融合作为图像特征提取模块的图像超分辨率重建方法。网络由若干个基本块和残差操作构建模型的特征提取结构,其核心是一种提取图像特征的异构组卷积块,该模块的对称组卷积块以并行的方式进行卷积提取不同通道间的内部信息特征并进行选择性特征融合,互补卷积块通过全维度动态卷积从空域、输入输出维度和核维度捕捉遗漏的上下文信息,对称组卷积块和互补卷积块连接后的特征采用特征增强残差块去除冗余造成干扰的无用信息。模型通过 5 种消融实验证明其设计的合理性,在 Set5, Set14, BSDS100 和 Urban100 测试集上与其他主流的超分辨率重建方法进行对比,峰值信噪比(PSNR)和结构相似性(SSIM)定量数据均有提升,尤其在放大因子为 3 的 Set5 数据集上比次优算法 CARN-M 均提升 0.06 dB,结果表明提出模型具有更优的性能指标和更好的视觉效果。

关键词:超分辨率重建;多维注意力机制;特征融合;残差网络

中图分类号:TP394.1 文献标识码:A doi:10.37188/OPE.20233117.2584

Multidimensional attention mechanism and selective feature fusion for image super-resolution reconstruction

WEN Jian¹, SHAO Jianfei^{1*}, LIU Jie², SHAO Jianlong¹, FENG Yuhang¹, YE Rong¹

(1. Faculty of Information Engineering and Automation,
Kunming University of Science and Technology, Kunming 650500, China;

2. Yunnan Police Unmanned System Innovation Research Institute,
Yunnan Police Officer Academy, Kunming 650223, China)

* Corresponding author, E-mail: 469365367@qq.com

Abstract: To address the problems of poor extraction of low-resolution features and blurred edges and artifacts caused by the high loss of high-frequency information in an image super-resolution reconstruction process, this paper proposes an image super-resolution reconstruction method that combines multidimensional attention and selective feature fusion (SKFF) as an image feature extraction module. The network comprises several basic blocks and residual operations to construct the feature extraction structure of the mod-

收稿日期:2022-11-22;修订日期:2022-12-28.

基金项目:国家重点研发计划资助项目(No. 2022YFC3320800);国家自然科学基金资助项目(No. 61732005, No. 61302042);云南省重大科技专项计划资助项目(No. 202002AD080001)

el, the core of which is a heterogeneous group convolution block for extracting image features. The symmetric group convolution block of this module performs convolution in a parallel manner to extract the internal information between different feature channels and performs selective feature fusion. The complementary convolution block captures the missed contextual information from the null domain, input-output dimension, and kernel dimension by full-dimensional dynamic convolution (ODconv). The features obtained after the symmetric group convolution and complementary convolution block processes are connected via a feature-enhanced residual block to remove useless information causing interference by redundancy. The rationality of the model design is demonstrated through five ablation experiments. Peak signal-to-noise ratio (PSNR) and structural similarity (SSIM) quantitative data comparison with other mainstream super-resolution reconstruction methods on the Set5, Set14, BSDS100, and Urban100 test sets are improved, especially on the Set5 dataset with an amplification factor of 3, showing a 0.06 dB improvement over the CARN-M algorithm. The experimental results demonstrate that the proposed model has better performance indexes and visual effects.

Key words: super-resolution reconstruction; multidimensional attention mechanism; feature fusion; residual network

1 引 言

单图像超分辨率(Single Image Super-resolution, SISR)的任务是将低分辨率图像(Low Resolution, LR)通过重建技术获得更自然逼真的高分辨率图像(High Resolution, HR)。通常图像的分辨率越高,代表细节纹理带来的视觉效果越好。由于硬件设备采集图像的过程中受自然环境、数字设备成本或人为干涉因素的影响,拍摄的图像不清晰,这会降低图像分类^[1]、无人机侦察^[2]、医疗辅助^[3]、遥感测绘^[4]等视觉任务的性能。图像超分辨率(Super Resolution, SR)重建算法不受平台的限制,降低了设备的硬件成本,并有效提高了图像分辨率,因此成为计算机视觉领域具有重要研究意义的底层任务之一。

多年来,为解决SR重建任务中的非适定性问题,早期的超分辨率研究包括基于插值方法和基于先验方法。插值方法主要有双线性插值^[5]和双三次插值^[6],实现从LR到HR的映射,该方法虽然操作简单,但应用范围及超分辨率效果较差,因此,基于先验的方法被提出。孙玉宝等^[7]利用稀疏先验信息获得线性组合预测HR图像,潘宗序等^[8]利用自相似先验信息引导模型实现超分辨率重建,然而这种依赖先验信息的方法需要过于耗时的代价完成任务,在一定程度上阻碍了研究者的工作。

近年来,基于深度学习的深度卷积神经网络(Convolutional Neural Network, CNN)依靠其灵活的端到端架构和卓越的学习能力,得到了广泛的应用。Dong等^[9]于2016年利用基于卷积神经网络提出了一个构建3层神经网络来学习LR到HR的映射,其图像超分辨率重建性能验证了基于深度学习方法的竞争力。随后,Dong等^[10]提出了在网络最后一层采用Bicubic上采样方式放大图像尺寸的算法,受该方法启发,相关研究人员设计出大量具有堆叠卷积层特征的网络模型,通过实验发现,深度的堆叠网络虽然可以有效提高重建性能,但在训练过程中也出现了梯度消失或梯度爆炸的问题。因此,Kim等受ResNet^[11]启发,设计了更深的卷积超分辨率网络(Super-Resolution using Very deep SR Network, VDSR)^[12],将残差网络设计到SR模型中,利用残差学习技术获取遗失的特征信息,以防止梯度爆炸或消失。Kim等又通过跳跃连接来引导模型融合全局和局部特征,提出了降低模型复杂度的递归神经网络算法^[13]。Tai等^[14]利用递归学习和门控单元构建了深度为80层的网络模型,该模型能够提取多级特征信息,提高预测图像质量。Lim等^[15]提出了基于增强的深度残差图像超分辨率网络(Enhanced Deep Residual Network for Single Image Super-Resolution, EDSR),通过去除残差块中的批归一化层来降低模型复杂度,重建后的

HR 图像展现出良好的视觉效果和性能指标。Zhang 等^[16]受 EDSR 的启发,在模型基础上引入注意力机制完善残差网络,模型增强了不同通道的相互依赖型,采用自适应性过滤冗余的低频特征,进一步提高了重建后的 SR 质量。

然而,以上模型在重建过程中需要计算大量参数,导致算法依赖具有较高算力和内存的硬件设备,过深的网络结构也会导致训练过拟合等问题。为解决此类问题,使超分辨率重建任务能够在实际应用领域得到发展,一些参数较少、计算复杂度低的算法模型被提出。宋昭漾等的倒 N 型网络^[17],MSRN^[18]和 CARN^[19]以略微降低图像 SR 质量为代价,大规模减少参数量。另一方面,对于追求主观视觉效果更好、细节纹理丰富的计算机视觉任务,一些学者选择增大模型复杂性,从而实现提升性能指标和丰富重建图像纹理的目的,例如 Ledig 等^[20]提出的基于生成式对抗网络的超分辨率模型(Photo-realistic Single Image Super-Resolution using a Generative Adversarial Network, SRGAN)。Wang 等^[21]在 SRGAN 模型的基础上引入密集残差块作为生成器的特征提取块,改用相对判别器提升模型性能,重建后的图像 SR 视觉效果卓越,但细节信息失真的特性,使此类方法不能有效应用到医学图像的 SR 重建领域。

目前,主流 SR 重建方法均采用尺寸为 3×3 或 5×5 的卷积来降低参数量,但较小的感受野不能完全学习各区域的特征信息。近年来,注意力机制的有效性得到验证,并成功应用至计算机视觉领域,能够很好地捕捉图像全局信息,重建后的图像具有更加丰富的纹理特征,但同时也产

生了大量冗余信息。本文提出了一种融合多维注意力机制与选择性特征融合的图像超分辨率重建方法,并构建了一种由对称组卷积块、互补卷积块和特征增强残差块组成的特征提取模块。两个并行对称的对称组卷积块用于提取不同通道间的内部信息,并使用选择性内核特征融合内部信息。互补卷积块采用多维注意力机制以并行策略动态学习核空间的四个维度,捕捉全部通道的特征,以获得更加细腻的纹理特征信息,特征增强残差块在增强特征的同时去除产生的冗余信息。最后,提出了一种丰富图像纹理,降低计算参数量的网络模型,该模型在 SISR 任务中表现出优越的视觉效果和性能指标。

2 网络模型

受文献[22]启发,本文提出的网络模型的主体组件包括两个带有 Relu 的全维动态卷积层(Omni-Dimensional Dynamic Convolution, ODconv)、6 个具有特征提取作用的异构组块(Heterogeneous Group Block, HGB)和一个用于提取高频特征的亚像素卷积选择块,分别完成网络的浅层特征提取、深层特征提取和超分辨率重建工作,如图 1 所示。具体流程为:

(1)浅层特征提取:网络第一层采用全维动态卷积从空域、输入通道、输出通道以多维注意力机制提取输入图像 I_{LR} 的浅层特征信息,并使用 Relu 作为激活函数,提取过程如下:

$$F_1 = R(ODconv(I_{LR})), \quad (1)$$

式中: I_{LR} 表示输入的初始低分辨率图像, $ODconv(\cdot)$ 表示全维动态卷积操作, $R(\cdot)$ 表示进行




图 1 融合多维注意力机制与选择性特征融合的网络结构示意图

Fig. 1 Schematic diagram of network structure integrating multi-dimensional attention mechanism and selective feature fusion

Relu 操作, F_1 表示经过浅层特征提取后的特征信息。

(2) 深层特征提取: 该部分使用 5 个 HGB 模块逐渐提取特征, 并用第一层 HGB 与第五层 HCB 使用 SKFF 采集特征信息, 最后将浅层特征与第 6 个 HGB 模块进行残差连接。深层特征提取公式如下:

$$F_2 = GE_1(HGB_6(SKFF(HGB_5^{1-5}(F_1)))) \quad (2)$$

式中: HGB_i^{n-m} 中的 i 表示第 i 个 HGB 模块, $n-m$ 表示经过 n 至 m 层 HGB 特征提取操作, $SKFF(\bullet)$ 表示选择性内核特征融合, $GE_j(\bullet)$ 表示第 j 次残差连接。

(3) 图像重建: 在深层特征提取之后, 使用 ODconv+Relu 对深层特征的冗余信息进行去除工作, 然后使用亚像素卷积选择块进行尺度选择, 选择块采用并行的上采样机制, 将获得的高

频特征信息递交至 1×1 卷积层, 以获得预测的 HR 图像。重建过程如下:

$$P_{HR} = Conv(PUM(R(ODconv(F_2)))) \quad (3)$$

式中: $PUM(\bullet)$ 表示执行 3 种不同的尺寸 (X_2, X_3, X_4) 来训练模型。

2.1 选择性内核特征融合模块

选择性内核特征融合^[23]作为一种动态选择卷积核的机制被提出后, 在计算机视觉领域得到了广泛的关注, 它在超分辨率重建任务中, 通过适应性调整感受野机制在平行流间进行信息传递, 提取丰富的低频特征信息, 并进行特征选择和聚合。本文模型改进了一种二分支特征提取策略的选择性内核特征融合模块(SKFF), 整合不同内核特征增强抗干扰能力, 提高超分辨率重建泛化能力, 使模型适应不同测试集的数据, 如图 2 所示。




图2 选择性内核特征融合模块示意图

Fig. 2 Schematic diagram of selective kernel feature fusion module

该机制分为融合和选择两部分。融合是根据输入的分组数为二的两个并行信息源进行聚合, 聚合后的特征为: $L = f_r + f_m$, 然后将得到的特征在 $L \in \mathbb{R}^{H \times W \times C}$ 的空间维度上采用全局平均池化操作来计算通道数据, 通道统计数据为: $s \in \mathbb{R}^{1 \times 1 \times C}$, 接下来使用 ODconv 对 s 进行缩减并生成紧凑的特征 $Z \in \mathbb{R}^{1 \times 1 \times \frac{8}{C}}$, 最后再通过两个并

行的 ODconv 扩充通道至 C , 得到两个特征描述符: V_1, V_2 。选择是两个特征描述符经过 softmax 函数分离不同类别的特征后, 选择更具有代表性的特征 S_1, S_2 , 并分别与 f_r, f_m 进行元素层面的乘积, 得到特征校准的特征图后进行聚合。

2.2 异构型残差模块

在基于深度学习的超分辨率重建任务中, 大多网络都采用具有有效缓解网络深度退化功能

的标准残差模块提取图像的特征信息,或使用密集残差块通过网络层提取特征,但两者都会增加网络结构的复杂性,并产生模型过拟合的问题。为了解决这些问题,本文提出一种异构型残差模块提取特征,模块以对称组卷积块提取通道中的内部特征,以互补卷积块提取不同通道间的特

征。两者连接增强不同通道间内部与外部的关系。为防止过多的冗余信息影响特征提取的准确率,使用特征增强残差块作为细化块,进一步融合整体和局部的低频结构特征。对称组卷积块、互补卷积块和特征增强残差块的具体结构如图3所示。




图3 异构型残差模块内部原理示意图

Fig. 3 Schematic diagram of internal principle junction of heterogeneous residual module

2.2.1 对称组卷积块

对称组卷积块由两个并行的三层卷积子网络分别学习所有通道的上半部分特征和下半部分特征,并通过选择性内核特征融合获得的特征,以增强所有通道内部的关联性。具体来说,子网络的第一层和第二层都是 $\text{Conv}3 \times 3 + \text{ReLU}$,第三层是 $\text{Conv}3 \times 3$ 。每层的输入通道和输出通道都是32个,三层网络后使用SKFF作为特征连接的方式。并行特征的提取公式如下:

$$I_i^U = \begin{cases} \frac{U}{2} O_1 \\ \frac{U}{2} O_{i-1} \end{cases}, \quad (4)$$

$$I_i^L = \begin{cases} \frac{L}{2} O_1 \\ \frac{L}{2} O_{i-1} \end{cases}, \quad (5)$$

$$O_i^{\text{HCB}} = \text{SKFF}(\text{C}(\text{R}(\text{C}(\text{R}(\text{C}(I_i^U))))), \text{C}(\text{R}(\text{C}(\text{R}(\text{C}(I_i^L))))), \quad (6)$$

其中:将输入分成两部分 I_i^U 和 I_i^L ,分别表示图像所有通道特征的上半部分和下半部分; $\frac{L}{2}$ 和 $\frac{U}{2}$ 分别表示输入分裂后上半部分和下半部分的通道数; O_1 表示网络经过第一层ODconv操作后的输

出,当 $i \geq 2$ 时, O_{i-1} 表示第 $i-1$ 个异构型残差模块的输出。式(6)是第 i 对称组卷积块的提取流程。

2.2.2 互补卷积块

ODconv的概念由Li^[24]于2022年提出,它是对CondConv的进一步延伸。4种注意力运算方式为:从空域维度的位置进行乘法运算、从输入维度进行通道乘法运算、从输出维度进行滤波器乘法运算、以内核乘法沿着卷积核空间进行核维度运算。这4个维度以动态特性进行卷积,利用一种多维注意力机制以并行策略对4个维度进行互补性学习,并将注意力逐步应用到相应的卷积核,以此增强卷积操作的特征提取能力。一个内核的ODconv能达到多核动态卷积的效果,因此ODconv减少了额外的参数量,这有利于提升模型的训练准确率、降低训练成本。计算公式如下:

$$y = (a_{w1} \otimes a_{f1} \otimes a_{c1} \otimes a_{s1} \otimes W_1 + \dots + a_{wn} \otimes a_{fn} \otimes a_{cn} \otimes a_{sn} \otimes W_n) * x, \quad (7)$$

式中: a_{wi} 表示卷积核 wi 的注意力标量, a_{si} 表示卷积核 a_{wi} 的核空间维度, a_{ci} 和 a_{fi} 分别表示输入通道维度和输出通道维度, $\otimes$ 表示内核空间不同维度的乘法运算。

网络模型将初始图像进行 ODconv 处理后的特征分成两部分,一部分交给对称组卷积块,另一部分交给互补卷积块,互补卷积块由三个串联的全维动态卷积和 Relu 操作组成。互补卷积块利用全维动态卷积对每一层得到抽象特征再提取,得到更加抽象的特征,使互补卷积块具有捕捉输入特征复杂关系的能力,最后将三层 ODconv 提取的特征与对称组卷积块相结合,有利于补充对称组卷积块遗失的特征。

2.2.3 特征增强残差块

传统的残差块包括两层 3×3 Conv 和一层 Relu 操作,并将第一层卷积和第三层卷积聚合,这种基础残差块提取图像特征的过程会存在信息丢失的问题。为利用残差块更好增强异构卷积块提取的特征,本文构建一种特征增强残差块,它可以有效捕捉长距离特征之间的依赖关系,并降低图形中的冗余信息。如图 1 所示,第一层卷积采用 3×3 的卷积核,输入通道数和输出通道数分别为 64 和 32,并进行 Relu 操作,与输入通道和输出通道均为 32 的第二层 3×3 卷积核执行 concatenate 操作。随后采用通道数为 64,卷积核分别为 $1 \times 1, 3 \times 3$ 的卷积核进行特征提取和整合。特征增强残差块获得的初始信息与第四个卷积层做聚合操作。

$$F_{c1} = \text{Relu}(\text{Conv}_{3 \times 3}(F_{i-1})), \quad (8)$$

$$O_i^F = \text{Conv}_{3 \times 3}(\text{Relu}(\text{Conv}_{1 \times 1}(\text{concat}(\text{Conv}_{3 \times 3}(F_{c1}), \text{half}(F_{c1})))) + F_{i-1}, \quad (9)$$

式中: F_{c1} 是异构卷积块获得的特征图经过第一个卷积层和 Relu 操作处理后的特征图, O_i^F 表示特征增强过程, $\text{concat}(\cdot)$ 表示连接合并, $\text{half}(\cdot)$ 表示取特征图的一半通道数。

2.3 损失函数

本文将均方误差公式 (Mean Square Error, MSE) [22] 作为损失函数来训练网络模型,模型对输入的 LR 图像 P_{LR} 进行预测,得到 HR 图像 P_{HR} 。随后使用 MSE 计算 HR 图像与 HR 图像之间的差异,并进行参数优化,公式如下:

$$\text{Loss} = \frac{1}{2N} \sum_{j=1}^N \|p_{LR}^j - p_{HR}^j\|^2, \quad (10)$$

式中: Loss 表示损失函数, p_{LR}^j 和 p_{HR}^j 分别表示训练的第 j 个 LR 图像和 HR 图像, N 表示训练图像的数量。

3 实验及结果分析

3.1 实验设置

本文使用公开数据集 DIV2K 彩色图像数据集 [25] 作为融合多维注意力机制与选择性特征融合的图像超分辨率重建算法的训练集,该数据集由放大因子为 2~4 的 800 张高清 HR 图像、100 张 HR 验证样本和 100 张 HR 测试样本组成。为增强模型的稳定性,本文使用文献 [22] 实验设置的方法扩大数据集,并将每张 LR 图像裁剪尺寸为 81×81 。测试集使用研究领域的标准数据集: Set5 [26], Set14 [27], BSD100 [28] 和 Urban100 [29]。这里使用峰值信噪比 (Peak Singal-to-Noise Ratio, PSNR) [30] 和结构相似度 (Structural Similarity, SSIM) [31] 作为评价指标。公式如下:

$$\text{PSNR} = 10 \cdot \lg \frac{\text{MAX}_1^2}{P_{\text{MSE}}} = 20 \cdot \lg \left(\frac{\text{MAX}_1}{\sqrt{P_{\text{MSE}}}} \right), \quad (11)$$

$$\text{SSIM} = \frac{1}{N_R} \sum_{i \in R} \frac{(2\mu_{ik}\mu_{ik'} + a_1)(2\sigma_{ik}\sigma_{ik'} + a_2)}{(\mu_{ik}^2\mu_{ik'}^2 + a_1)(\sigma_{ik}^2\sigma_{ik'}^2 + a_2)}, \quad (12)$$

式中: MAX_1 代表图像像素点的最大值; P_{MSE} 代表尺寸为 $M \times N$ 的 HR 图像和重建后图像的均方误差; $\mu_{ik}\mu_{ik'}$ 和 $\sigma_{ik}\sigma_{ik'}$ 分别表示 HR 图像与重建后的图像以第 i 个像素为中心点的窗口的平均值与标准差; N_R 表示图像数量; a_1 与 a_2 表示常量。

本文在图像 RGB 上训练模型,在 YCbCr 彩色空间中的 Y 通道测试模型的超分辨率重建效果。初始参数如下:初始学习率为 10^{-4} ,每迭代 40 000 次学习率降为原来的一半,总迭代为 152 400 次,图像批处理大小为 32。实验在 Linux 系统下实施,硬件环境为 CPU 处理器 24 核 AMD EPYC 7642 48-Core Processor,内存 80 G, GPU 为 NVIDIA GeForce RTX 3090, 24GB 显存;开发平台为 Python 3.8 和 Pytorch 1.11.0, Cuda 11.3。

3.2 消融实验

为了验证本文设计的异构型的有效性,对互补卷积模块、选择性内核特征融合模块和特征增强残差模块进行 5 种组合,并对其网络进行了消融实验及数据分析对比,对于没有选择性内核的特征融合模块使用普通连接操作。测试集使用放大因子为 2~4 的 Urban100 数据集,其中 Plan A~Plan E 5 种方法放大 2 倍的数据分析结果如表 1 所示。表中,所有方法均使用对称组卷

积模块, Plan A 方法仅包括互补卷积模块, 对称组卷积块以并行卷积的方式分别对所有通道的上半部分和下半部分进行特征提取, 不使用 SKFF 模块进行特征融合, 只使用普通的特征连接方式, 评价指标显示效果较差, PSNR 只有 30.43, 证明互补卷积模块虽能提取特征, 预测的图像接近真实图像, 但细节纹理处理欠缺。Plan B 方法仅包括选择性内核特征融合模块, 对称组卷积块的融合方式和网络第五个异构型残差模块后的融合方式均采用选择性内核特征融合模块, Plan B 与 Plan A 相比, 评价指标明显提高。Plan B 和 Plan C 的结果证明了选择性内核特征融合模块和特征增强残差模块的有效性。Plan D 使用互补卷积模块, 并按照 Plan B 的方式进行特征融合, 实验结果较 Plan C 的 PSNR 提升了 0.64, SSIM 提升了 0.029。Plan E 同时使用互补卷积模块、选

择性内核特征融合模块和特征增强残差块, 评价指标 PSNR 和 SSIM 分别达到 32.12 和 0.928 8, 结果表明三个模块的结合能够更好地提取特征信息, 提高模型的超分辨率重建效果。

如图 4 所示, 本文将 Plan A~Plan E 使用放大 2~4 倍的 U100 数据集进行主观视觉效果对比, 结果通过可视化展示, 在训练批次为 152 400 的结果中发现, Plan A 与 Plan D 对比表明, 信息的叠加也导致一些错误特征的产生, SKFF 有效地融合特征使纹理的细节信息更加清晰。Plan B 与 Plan D 对比表明, 互补卷积模块使特征提取的过程更加注重与周围特征的联系, 条纹更加合理, 同时降低了模糊感。Plan D 和 Plan E 对比表明, 特征增强残差块有效地降低了信息冗余造成的特征失真程度, 恢复图像的高频信息特征更加接近 HR 图像。

表 1 不同方法在 Urban100 数据集放大 2 倍的比较结果

Tab. 1 Comparison results of different methods on Urban100 data set magnified by 2 times

方法/评价指标	对称组卷积模块	互补卷积模块	选择性内核 特征融合模块	特征增强 残差模块	PSNR/dB	SSIM
Plan A	✓	✓	×	×	30.43	0.921 6
Plan B	✓	×	✓	×	31.26	0.915 7
Plan C	✓	×	×	✓	31.15	0.911 7
Plan D	✓	✓	✓	×	31.79	0.924 5
Plan E	✓	✓	✓	✓	32.12	0.928 8




图 4 Urban100 数据集放大 2 倍的 PSNR 消融对比

Fig. 4 Comparison of PSNR ablation on Urban100 dataset magnified 2 times

3.3 与其他主流方法对比

为了从不同角度客观地评估本文算法的超分辨率重建效果, 从定量和定性两个方面进行分析, 定量分析以 PSNR 和 SSIM 作为评价指标, 对

比算法采用 Bicubic 插值^[32], A++^[33], RFL^[34], 基于无监督退化表示学习的盲超分辨率网络 (DASR)^[35], 去噪卷积网络 (a denoising CNN, DnCNN)^[36], 基于模型驱动的深度神经盲超分辨

网络 (A Model-Driven Deep Neural Network for Blind Super-Resolution, KXNet)^[37], 具有三十层残差的编码器解码器网络 (RED30)^[38], 记忆网络 (MemNet)^[39], 级联残差移动网络 (Cascading Residual Network Mobile, CARNM)^[19], 端到端的深浅网络 (End-To-End Deep and Shallow Network, EEDS+)^[15], 深度递归融合网络 (Deep Recurrent Fusion Network, DRFN)^[40], 多尺度深度编码器解码器网络 (Multi-scale Deep Encoder-Decoder with Phase Congruency, MSDEPC)^[41], CF-SRCNN^[42], 轻量级增强残差卷积网络 (Lightweight Enhanced SR CNN, LESRCNN)^[22], 多尺度的 LESRCNN (LESRCNN-S)^[22], 非对称 SR 网络 (Asymmetric CNN, ASCNN)^[43], 以及用于盲 SR 的 ACNet (ACNet-B)^[43]。为更好展示 SR 的定量对比分析结果, 本文使用 Set5, Set14, B100 和 Urban100 测试集放大 2~4 倍作为补充测试集, 对评价指标最高的最优算法进行加粗注

释, 次优算法用下划线注释。由表 2~表 5 可知, 本文提出的融合多维注意力机制与选择性特征融合的图像超分辨率重建算法在 4 个放大 2~4 倍的基准数据集上均有较好的定量数据, 在 Set5 数据集上, 本文算法在放大 2~3 倍的 PSNR 测试效果上比次优算法分别提升 0.004, 0.005, 在放大 4 倍的测试效果上与次优算法数据持平, SSIM 指标在放大 3~4 倍的 Set5 和 BSDS100 测试集上达到最优。在 Set14 数据集上, 本文算法的 PSNR 和 SSIM 均达到最优。在 Urban100 和 BSDS100 数据集上, 本文算法的 PSNR 指标在放大 2~3 倍的情况下均达到最优, SSIM 指标在放大 2 倍的 Urban100 数据集上达到次优。

为验证本文算法的主观视觉效果, 选取 Urban100 基准数据集中的 img015 和 img030 和 img039 三张图片分别放大 2~4 倍进行对比测试。对比算法选用定量数据最好的 6 种方法, 通过观察发现, 重建 2~4 倍的大多数方法存在边缘

表 2 不同方法在 4 个基准数据集放大 2 倍的比较结果

Tab. 2 Comparison results of different methods on 4 Baseline datasets enlarged by 2 times

算 法	Set5		Set14		BSDS100		Urban100	
	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM
Bicubic ^[32]	33.66	0.929 9	30.24	0.868 8	29.56	0.841	26.88	0.840 3
A+ ^[33]	36.54	0.954 4	32.28	0.905 6	31.21	0.886 3	29.20	0.893 8
RFL ^[34]	36.54	0.953 7	32.26	0.904 0	31.16	0.884 0	29.11	0.890 4
DASR ^[35]	37.22	0.951 5	32.93	0.902 9	31.76	0.890 1	30.63	0.907 9
KXNet ^[37]	37.59	0.955 2	33.36	0.909 1	32.03	0.894 1	31.48	0.919 2
RED30 ^[38]	37.66	<u>0.959 9</u>	32.94	0.914 4	31.99	0.897 4	30.91	0.915 9
DnCNN ^[36]	37.58	0.959 0	33.03	0.912 8	31.90	0.896 1	30.74	0.913 9
MemNet ^[39]	37.78	0.959 7	33.28	0.914 2	32.08	0.897 8	31.31	0.919 5
CARN ^[19]	37.76	0.959 0	<u>33.52</u>	<u>0.916 6</u>	31.92	0.897 8	31.51	0.931 2
CARN-M ^[19]	37.53	0.958 3	33.26	0.914 1	32.09	0.896 0	30.83	0.923 3
EEDS+ ^[15]	37.78	0.960 9	33.21	0.915 1	31.95	0.896 3	31.92	0.928 9
MSDEPC ^[41]	37.39	0.957 6	32.94	0.911 1	31.64	0.896 1	31.83	0.928 3
CFSRCNN ^[42]	<u>37.79</u>	0.959 1	33.51	0.916 5	<u>32.11</u>	0.898 8	<u>32.07</u>	0.819 0
LESRCNN ^[22]	37.65	0.958 6	33.32	0.914 8	31.95	0.896 4	31.45	0.920 6
LESRCNN-S ^[22]	37.57	0.958 2	33.30	0.914 5	31.95	0.896 5	31.45	0.920 7
ACNet ^[43]	37.72	0.958 8	33.41	0.916 0	32.06	0.897 8	31.79	0.924 5
ACNet-B ^[43]	37.60	0.958 4	33.32	0.915 1	31.97	0.897 0	31.57	0.922 2
Ours	37.83	0.959 4	33.53	0.917 2	32.14	<u>0.898 7</u>	32.12	<u>0.930 6</u>

表 3 不同方法在 4 个基准数据集放大 3 倍的比较结果

Tab. 3 Comparison results of different methods on 4 Baseline datasets enlarged by 3 times

算 法	Set5		Set14		BSDS100		Urban100	
	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM
Bicubic ^[32]	30.39	0.868 2	27.55	0.774 2	27.21	0.738 5	24.46	0.734 9
A+ ^[33]	32.58	0.908 8	29.13	0.818 8	28.29	0.783 5	26.03	0.797 3
RFL ^[34]	32.43	0.905 7	29.05	0.816 4	28.22	0.780 6	25.86	0.790 0
DASR ^[35]	33.78	0.920 0	29.94	0.826 6	28.85	0.793 2	27.28	0.830 7
KXNet ^[37]	34.22	0.923 8	30.27	0.834 0	<u>29.06</u>	0.801 0	28.00	0.845 7
RED30 ^[38]	33.82	0.929 9	29.61	0.834 1	28.93	0.799 4	27.31	0.830 3
DnCNN ^[36]	33.75	0.929 0	29.81	0.832 1	28.85	0.798 1	27.15	0.827 6
MemNet ^[39]	34.09	0.924 8	30.00	0.835 0	28.96	0.800 1	27.56	0.837 6
CARN ^[19]	33.99	0.923 6	30.08	0.836 7	28.91	0.800 0	26.86	0.826 3
CARN-M ^[19]	<u>34.29</u>	0.925 5	<u>30.29</u>	0.840 7	<u>29.06</u>	0.803 4	27.38	0.840 4
EEDS+ ^[15]	33.81	0.925 2	29.85	0.833 9	28.88	0.805 4	27.43	0.835 9
MSDEPC ^[41]	33.37	0.918 4	29.62	0.827 9	29.58	0.791 8	27.23	0.819 0
CFSRCNN ^[42]	33.24	<u>0.925 6</u>	30.27	<u>0.841 0</u>	29.03	0.803 5	<u>28.04</u>	<u>0.849 6</u>
LESRCNN ^[22]	34.93	0.923 1	30.12	0.838 0	28.91	0.800 5	27.70	0.841 5
LESRCNN-S ^[22]	33.05	0.923 8	30.16	0.838 4	28.94	0.801 2	27.76	0.842 4
ACNet ^[43]	34.14	0.924 7	30.19	0.839 8	28.98	0.802 3	27.97	0.848 2
ACNet-B ^[43]	34.07	0.924 3	30.15	0.838 6	28.97	0.801 6	27.88	0.844 7
Ours	34.35	0.926 8	30.36	0.841 7	29.11	<u>0.804 7</u>	28.19	0.853 1

表 4 不同方法在 4 个基准数据集放大 4 倍的比较结果

Tab. 4 Comparison results of different methods on 4 Baseline datasets enlarged by 4 times

算 法	Set5		Set14		BSDS100		Urban100	
	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM
Bicubic ^[32]	28.42	0.810 4	26.00	0.702 7	25.96	0.667 5	23.14	0.657 7
A+ ^[33]	30.28	0.860 3	27.32	0.749 1	26.82	0.708 7	24.32	0.718 3
RFL ^[34]	30.14	0.854 8	27.24	0.745 1	26.82	0.705 4	24.19	0.709 6
DASR ^[35]	31.68	0.885 4	28.26	0.766 8	27.40	0.728 6	25.49	0.762 1
KXNet ^[37]	31.94	0.891 2	<u>28.61</u>	0.778 2	<u>27.59</u>	0.733 0	26.18	<u>0.787 3</u>
RED30 ^[38]	31.51	0.886 9	27.86	0.771 8	27.40	0.729 0	25.35	0.758 7
DnCNN ^[36]	31.40	0.884 5	28.04	0.767 2	27.29	0.725 3	25.20	0.752 1
MemNet ^[39]	31.74	0.889 3	28.26	0.772 3	27.40	0.728 1	25.50	0.763 0
CARN ^[19]	31.92	0.890 3	28.42	0.776 2	27.44	0.730 4	25.63	0.768 8
CARN-M ^[19]	32.13	<u>0.893 7</u>	28.60	<u>0.780 6</u>	27.58	<u>0.734 9</u>	<u>26.07</u>	0.783 7
EEDS+ ^[15]	31.53	0.886 9	28.13	0.769 8	27.35	0.726 3	25.45	0.762 9
MSDEPC ^[41]	31.05	0.879 7	27.79	0.758 1	27.10	0.719 3	25.23	0.758 6
CFSRCNN ^[42]	32.06	0.892 9	28.57	0.780 0	27.53	0.733 3	26.03	0.782 4
LESRCNN ^[22]	31.88	0.890 3	28.44	0.777 2	27.45	0.731 3	25.77	0.773 2
LESRCNN-S ^[22]	31.88	0.890 7	28.43	0.777 6	27.47	0.732 1	25.78	0.773 9
ACNet ^[43]	31.83	0.890 3	28.46	0.778 8	27.48	0.732 6	25.93	0.779 8
ACNet-B ^[43]	31.82	0.890 1	28.41	0.777 3	27.46	0.731 6	25.86	0.776 0
Ours	<u>32.11</u>	0.894 3	28.63	0.781 2	27.65	0.735 2	<u>26.07</u>	0.790 1

表 5 不同模型在 Set5(×4) 上的推理时间

Tab. 5 Inference time of different models on Set5(×4) dataset

算 法	推理时间/s
CARN	0.032 0
CFSRCNN	0.029 8
MemNet	14.690 0
ACNet	0.031 5
DASR	0.072 1
KXNet	0.642 9
Ours	0.051 6

模糊和伪影,本文方法可以有效缓解边缘模糊和伪影的问题,恢复更多的图像细节,产生的细腻纹理更接近真实超分辨率图像。在图 5 中,其他算法在重建高楼窗户的细节纹理时,两侧栏杆的模糊感较重,而本文算法重建的图像可以较清晰地观察到栏杆的形状。在图 6 中,其他算法重构的六组窗户边缘纹理呈圆矩形,反光细节产生了泛白的虚假信息,本文算法重构的窗户清晰,窗户与墙面对比凹凸清晰。在图 7 中,其他算法重构的大厦交错的结构细节模糊不清,而本文算法重构的图像中有“V”型结构轮廓。




图 5 Urban100 数据集中 Img015 放大 2 倍的对比图

Fig. 5 Comparison of Img015 magnified 2 times in Urban100 dataset




图 6 Urban100 数据集中 Img030 放大 3 倍的对比图

Fig. 6 Comparison of Img030 magnified 3 times in Urban100 dataset




图7 Urban100数据集中Img039放大4倍的对比图

Fig. 7 Comparison of Img039 magnified 4 times in Urban100 dataset

将本文方法与其他主流方法从定量和定性两个方面进行对比。图8和表5分别表示在Set5放大4倍的重建任务中,模型与其他模型在评价指标、参数量及推理时间的对比结果,本文算法的SR重建性能与模型复杂度数据取得了良好的平衡,在提升性能的同时并未带来大量的参数量,相对于DASR和KXNet算法,本文算法的推理时间更短,仅有0.0516 s。

4 结 论

本文介绍了一种融合多维注意力机制与选择性特征融合的图像超分辨率重建方法,该方法将全维动态卷积融入到互补卷积块,以并行策略动态学习核空间的四个维度,捕捉全部通道的特征,选择性内核特征融合应用到对称组卷积块,融合不同通道间的内部信息。对称组卷积块和互补卷积块的组合通过特征增强残差块去除冗余信息后提取的深层特征具有更加细腻的纹理边缘信息。数据分析及数据可视化结果显示,本文提出的模型在超分辨率重建任务




图8 不同模型在Set5(×4)上的PSNR以及参数量

Fig. 8 PSNR and parameters on Set5(×4)dataset of different models

的基准数据集上有着较好的性能,尤其在放大因子为3的Set5数据集上峰值信噪比提升0.06 dB,在放大因子为4的BSDS100数据集上峰值信噪比提升0.07 dB。在后续工作中,将应用模型对医学图像和遥感图像进行重建,以满足高级视觉任务的实际应用需求。

参考文献:

[1] 蔡体健,彭潇雨,石亚鹏,等. 通道注意力与残差级联的图像超分辨率重建[J]. 光学精密工程, 2021, 29(1): 142-151.

CAI T J, PENG X Y, SHI Y P, *et al.* Channel attention and residual concatenation network for image super-resolution [J]. *Opt. Precision Eng.*, 2021, 29(1): 142-151.

- 29(1): 142-151. (in Chinese)
- [2] ZOU W W, YUEN P C. Very low resolution face recognition problem[J]. *IEEE Transactions on Image Processing*, 2012, 21(1): 327-340.
- [3] SHI W, CABALLERO J, LEDIG C, *et al.* Cardiac image super-resolution with global correspondence using multi-atlas patchmatch[C]. *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Berlin: Springer, 2013, 8151: 9-16.
- [4] 朱福珍, 刘越, 黄鑫, 等. 改进的稀疏表示遥感图像超分辨率重建[J]. *光学精密工程*, 2019, 27(3): 718-725.
- ZHU F ZH, LIU Y, HUANG X, *et al.* Remote sensing image super-resolution based on improved sparse representation [J]. *Opt. Precision Eng.*, 2019, 27(3): 718-725. (in Chinese)
- [5] CHIANG M C, BOULT T E. Efficient image warping and super-resolution [C]. *Proceedings Third IEEE Workshop on Applications of Computer Vision*. WACV'96. December 2-4, 1996, Sarasota, FL, USA. IEEE, 2002: 56-61.
- [6] HA V K, REN J C, XU X Y, *et al.* Deep learning based single image super-resolution: a survey[J]. *International Journal of Automation and Computing*, 2019, 16(4): 413-426.
- [7] 孙玉宝, 费选, 韦志辉, 等. 基于前向后向算子分裂的稀疏性正则化图像超分辨率算法[J]. *自动化学报*, 2010, 36(9): 1232-1238.
- SUN Y B, FEI X, WEI ZH H, *et al.* Sparsity regularized image super-resolution model via forward-backward operator splitting method[J]. *Acta Automatica Sinica*, 2010, 36(9): 1232-1238. (in Chinese)
- [8] 潘宗序, 禹晶, 胡少兴, 等. 基于多尺度结构自相似性的单幅图像超分辨率算法[J]. *自动化学报*, 2014, 40(4): 594-603.
- PAN Z X, YU J, HU SH X, *et al.* Single image super resolution based on multi-scale structural self-similarity [J]. *Acta Automatica Sinica*, 2014, 40(4): 594-603. (in Chinese)
- [9] 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.
- [10] DONG C, LOY C C, TANG X O. *Accelerating the Super-resolution Convolutional Neural Network*[M]. Computer Vision-ECCV 2016. Cham: Springer International Publishing, 2016: 391-407.
- [11] 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.
- [12] 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.
- [13] 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 (CVPR)*. June 27-30, 2016, Las Vegas, NV, USA. IEEE, 2016: 1637-1645.
- [14] TAI Y, YANG J, LIU X M, *et al.* MemNet: a persistent memory network for image restoration [C]. 2017 *IEEE International Conference on Computer Vision (ICCV)*. October 22-29, 2017, Venice, Italy. IEEE, 2017: 4549-4557.
- [15] 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.
- [16] ZHANG Y L, LI K P, LI K, *et al.* *Image Super-resolution using Very Deep Residual Channel Attention Networks* [M]. Computer Vision-ECCV 2018. Cham: Springer International Publishing, 2018: 294-310.
- [17] 程德强, 赵佳敏, 寇旗旗, 等. 多尺度密集特征融合的图像超分辨率重建[J]. *光学精密工程*, 2022, 30(20): 2489-2500.
- CHENG D Q, ZHAO J M, KOU Q Q, *et al.* Multi-scale dense feature fusion network for image super-resolution [J]. *Opt. Precision Eng.*, 2022, 30(20): 2489-2500. (in Chinese)
- [18] LI J C, FANG F M, MEI K F, *et al.* *Multi-scale Residual Network for Image Super-resolution* [M]. Computer Vision-ECCV 2018. Cham: Springer International Publishing, 2018: 527-542.
- [19] AHN N, KANG B, SOHN K A. *Fast, Accurate, and Lightweight Super-resolution with Cascading Residual Network* [M]. Computer Vision-

- ECCV 2018. Cham: Springer International Publishing, 2018: 256-272.
- [20] LEDIG C, THEIS L, HUSZÁR F, *et al.* Photo-realistic single image super-resolution using a generative adversarial network[C]. 2017 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. July 21-26, 2017, Honolulu, HI, USA. IEEE, 2017: 105-114.
- [21] WANG X T, YU K, WU S X, *et al.* *ESRGAN: Enhanced Super-resolution Generative Adversarial Networks* [M]. Lecture Notes in Computer Science. Cham: Springer International Publishing, 2019: 63-79.
- [22] TIAN C W, ZHUGE R B, WU Z H, *et al.* Lightweight image super-resolution with enhanced CNN [J]. *Knowledge-Based Systems*, 2020, 205: 106235.
- [23] LI X, WANG W H, HU X L, *et al.* Selective kernel networks[C]. 2019 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 15-20, 2019, Long Beach, CA, USA. IEEE, 2020: 510-519.
- [24] LI C, ZHOU A, YAO A. Omni-dimensional dynamic convolution [EB/OL]. 2022: *arXiv*: 2209.07947. <https://arxiv.org/abs/2209.07947>.
- [25] TIMOFTE R, AGUSTSSON E, VAN G 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*. July 21-26, 2017, Honolulu, HI, USA. IEEE, 2017: 1110-1121.
- [26] 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.
- [27] ZEYDE R, ELAD M, PROTTER M. *On Single Image Scale-up using Sparse-Representations* [M]. Curves and Surfaces. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012: 711-730.
- [28] 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*. ICCV. July 7-14, 2001, Vancouver, BC, Canada. IEEE, 2002: 416-423.
- [29] 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.
- [30] ZHANG K, ZUO W M, ZHANG L. Learning a single convolutional super-resolution network for multiple degradations[C]. 2018 *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. June 18-23, 2018, Salt Lake City, UT, USA. IEEE, 2018: 3262-3271.
- [31] 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: a Publication of the IEEE Signal Processing Society*, 2004, 13(4): 600-612.
- [32] SUN J, XU Z B, SHUM H Y. Image super-resolution using gradient profile prior[C]. 2008 *IEEE Conference on Computer Vision and Pattern Recognition*. June 23-28, 2008, Anchorage, AK. IEEE, 2008: 1-8.
- [33] TIMOFTE R, DE S V, VAN G L. *A+: Adjusted Anchored Neighborhood Regression for Fast Super-resolution* [M]. Computer Vision-ACCV 2014. Cham: Springer International Publishing, 2015: 111-126.
- [34] SCHULTER S, LEISTNER C, BISCHOF H. Fast and accurate image upscaling with super-resolution forests[C]. 2015 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. June 7-12, 2015, Boston, MA, USA. IEEE, 2015: 3791-3799.
- [35] WANG L G, WANG Y Q, DONG X Y, *et al.* Unsupervised degradation representation learning for blind super-resolution[EB/OL]. 2021: *arXiv*: 2104.00416. <https://arxiv.org/abs/2104.00416>.
- [36] ZHANG K, ZUO W M, CHEN Y J, *et al.* Beyond a Gaussian denoiser: residual learning of deep CNN for image denoising[C]. *IEEE Transactions on Image Processing*. February 1, 2017, IEEE, 2017: 3142-3155.
- [37] FU J, WANG H, XIE Q, *et al.* KXNet: a model-driven deep neural network for blind super-resolution [EB/OL]. 2022: *arXiv*: 2209.10305. <https://arxiv.org/abs/2209.10305>.

- [38] MAO X J, SHEN C H, YANG Y B. Image restoration using very deep convolutional encoder-decoder networks with symmetric skip connections[C]. *Proceedings of the 30th International Conference on Neural Information Processing Systems. December 5-10, 2016, Barcelona, Spain*. New York: ACM, 2016: 2810-2818.
- [39] WANG Y F, WANG L J, WANG H Y, *et al.* End-to-end image super-resolution via deep and shallow convolutional networks[C]. *IEEE Access. March 13, 2019, IEEE, 2019: 31959-31970.*
- [40] YANG X, MEI H Y, ZHANG J Q, *et al.* DRFN: deep recurrent fusion network for single-image super-resolution with large factors [C]. *IEEE Transactions on Multimedia. August 6, 2018, IEEE, 2018: 328-337.*
- [41] LIU H, FU Z L, HAN J G, *et al.* Single image super-resolution using multi-scale deep encoder-decoder with phase congruency edge map guidance [J]. *Information Sciences*, 2019, 473: 44-58.
- [42] TIAN C W, XU Y, ZUO W M, *et al.* Coarse-to-fine CNN for image super-resolution [J]. *IEEE Transactions on Multimedia*, 2021, 23: 1489-1502.
- [43] TIAN C W, XU Y, ZUO W M, *et al.* Asymmetric CNN for image superresolution [C]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems. May 3, 2021, IEEE, 2021: 3718-3730.*

作者简介:



温 剑(1998—),男,河北承德人,硕士研究生,中国计算机学会学生会员,主要从事图像超分辨率重建、图像去噪的研究。E-mail: 20212204261@stu.kust.edu.cn

通讯作者:



邵剑飞(1970—),男,云南昆明人,硕士,副教授,硕士生导师,主要从事研究图像处理、通信与信息系统的研究。E-mail: 469365367@qq.com