

DOI: 10.11830/ISSN.1000-5013.202012009



改进的二阶龙格-库塔超分辨率算法

陈剑涛, 黄德天, 陈健, 朱显丞

(华侨大学 工学院, 福建 泉州 362021)

摘要: 提出一种改进的二阶龙格-库塔超分辨率算法. 首先, 提出一种浅层共享编码器, 以实现低分辨率图像的浅层特征提取. 其次, 提出一种深层特征学习单元, 并与基于龙格-库塔方法的残差模块相融合, 进而构建出一种基于深层特征的残差模块, 以提升深层特征提取能力. 实验结果表明: 与主流超分辨率算法相比, 文中算法在主观视觉效果和客观评价指标方面都具有更好的效果.

关键词: 超分辨率; 卷积神经网络; 共享编码器; 深度特征

中图分类号: TP 391

文献标志码: A

文章编号: 1000-5013(2022)01-0127-08

Improved Second-Order Runge-Kutta Super-Resolution Algorithm

CHEN Jiantao, HUANG Detian, CHEN Jian, ZHU Xiancheng

(College of Engineering, Huaqiao university, Quanzhou 362021, China)

Abstract: An improved second-order Runge-Kutta super-resolution algorithm is proposed. Firstly, a shallow shared encoder is proposed to extract the shallow feature of low-resolution images. Secondly, a deep feature learning unit is proposed and further integrated with the residual module based on the Runge-Kutta method to construct a deep-feature-based residual module to improve the ability of deep feature extraction. Experimental results show that compared with the mainstream super-resolution algorithm, the algorithm proposed in this paper has better effect in subjective visual effect and objective evaluation index.

Keywords: super-resolution; convolutional neural network; shared encoder; deep feature

图像超分辨率技术由于能够利用软件算法从一幅或多幅现有的低分辨率(LR)图像中重建清晰的高分辨率(HR)图像,成为计算机视觉领域的重要课题之一. 在实际成像过程中,由于设备、环境、传输、噪声等影响,相对于原始的 HR 图像,采样到的图像丢失了某些高频特征,成为 LR 图像,难以满足工程应用的需求. 超分辨率技术突破了固有分辨率的限制,可通过现有的 LR 图像恢复对应的 HR 图像,是获取 HR 图像经济而有效的方法,在遥感、医学、智能交通、人脸识别等领域具有重要的应用价值^[1-4].

传统的超分辨率方法主要可以分成基于插值和基于重建的方法. 在插值方法中,常用的有双三次插值(Bicubic)^[5]和最近邻插值^[6],此类算法计算开销小、实时性高,但在图像高频区域会产生振铃和锯齿现象. 基于重建的方法通过引入图像的先验知识,可以有效地维持锐利的边缘特征并抑制振铃效应,例如贝叶斯先验法^[7]、非局部自相似先验法^[8]、梯度轮廓先验法^[9],但是在复杂场景下,此类方法无法很好

收稿日期: 2020-12-02

通信作者: 黄德天(1985-),男,副教授,博士,主要从事计算机视觉、深度学习和嵌入式系统的研究. E-mail: huangdetian@hqu.edu.cn.

基金项目: 国家自然科学基金青年科学基金资助项目(61901183);福建省自然科学基金面上资助项目(2019-J01083);华侨大学研究生科研创新能力培育计划资助项目(18014084001)

地恢复丢失的高频信息。当前,基于学习的方法在超分辨率任务中被广泛使用,通过训练大量成对的 LR 和 HR 图像块,学习它们之间的映射关系,例如非线性回归法^[10]、稀疏字典学习^[11]、卷积神经网络(CNN)。

Dong 等^[12]首次利用 CNN 模型提出超分辨率卷积神经网络(SRCNN)算法,通过三层卷积层分别实现了特征提取、非线性映射和图像重建 3 个阶段。Kim 等^[13]根据残差网络的思想,通过级联卷积核小的卷积层,提出深度卷积超分辨率算法(VDSR),使其在更大的图像块区域学习更多的上下文信息。为了减轻插值过程带来的计算成本,Dong 等^[14]在网络结构的最后一层使用反卷积层,将模型学习的特征放大到 HR 图像空间上。Wai 等^[15]同样采用深层卷积的思想,并结合拉普拉斯金字塔结构,在没有增加额外计算负担的前提下,逐步重建 HR 图像。Lim 等^[16]提出增强型深层网络(EDSR),指出通过批标准化(BN)层^[17]的特征容易降低模型的收敛速度,将其移除,从而扩大模型尺寸以提升重建图像的质量。Haris 等^[18]提出迭代的错误反馈机制,设计上下投影单元,计算投影误差以获得更好的重建结果。为了解决单纯堆叠残差模块的局限性,Zhang 等^[19]提出残差嵌套残差(RIR)结构,构建非常深的可训练网络结构;随后,又设计局部和非局部注意力模块^[20],以提取可捕获像素之间长期依赖关系的特征,同时更注意具有图像重要特征的部分,进一步增强网络的表示能力。He 等^[21]利用微分动力学思想,提出一种基于常微分方程启发的超分辨率模型(OISR),从而增加超分辨率网络设计的可解释性。

然而,当前的超分辨率网络大多忽视了模型的运算开销,为了在超分辨率任务中取得良好的效果,在学习特征阶段堆叠数量庞大的模块,导致网络层数太深而不利于模型的训练。基于深度学习的超分辨率网络模型虽然能在不同复杂程度场景下恢复一定的纹理细节特征,但是对网络内部结构的轻微调整会表现出极敏感的特点。为了解决上述问题,本文提出一种改进的二阶龙格-库塔超分辨率算法。

1 超分辨率重建算法

1.1 龙格-库塔方法残差模块

传统的深度学习网络多数依赖于已有的设计经验,此类模型往往存在一些通病,如网络层数深、模型训练困难及训练技巧复杂等。而如今许多学者试图将数学与神经网络联系起来,以突破深度学习的不可解释性^[22-23]。基于常微分方程启发的二阶龙格-库塔超分辨率网络(OISR-RK2)满足轻量化和无需复杂的训练技巧的优势,建立起神经网络和常微分方程之间的联系。

欧拉(Euler)方法是一种常用的常微分方程数值解法,根据前向欧拉法的基本表现形式

$$y_{n+1}=y_n+h f(x_n,y_n),$$

(1)

通过当前状态和当前状态的导数,可以求解出下一时刻的状态表示。其中, h 为间隔区间, $f(\cdot)$ 为 x_n 处的导数,即可以表示为两个状态之间的增量关系。同样,在残差模块里也有类似的特点,可以表示为

$$y_{n+1}=y_n+G(y_n).$$

(2)

因此,将前向欧拉法映射成残差模块的形式,得到二阶龙格-库塔(RK2)方法对应的公式,即

$$y_{n+1}=y_n+\frac{h}{2}(f(x_n,y_n)+f(x_{n+1},y_{n+1})).$$

(3)

再通过前向欧拉公式进行估计,可以将式(3)简化为

$$y_{n+1}=y_n+\frac{1}{2}(G_1+G_2).$$

(4)

对照式(1)和式(4)可知, G_1 和 G_2 分别表示 x_n 和 x_{n+1} 两种状态的增量关系。RK2 残差模块,如图 1 所示。

1.2 网络结构

为了提高超分辨率图像的分辨率和清晰度,提出一种基于深度特征的超分辨率网络模型,其整体框架,如图 2 所示。该模型主要分为特征提取和图像重建两个阶段,前者又进一步分为浅层特征提取和深层特征提取 2 个子阶段。浅层特征提取阶段以 LR 图像作为输入,利用浅层共享编码结构学习 LR 图像空间的浅层特征;深层特征提取阶段通过级联若干个学习深度特征的 RK2 模块,并在末端经过一个卷积(Conv)层和一个长跳跃连接,构成深度特征提取子阶段;图像重建部分则是由 Conv 层和像素重组层




图 1 RK2 残差模块

Fig. 1 RK2 residual module

(Upscale)组合,共同完成 HR 图像的重建.




图 2 网络的整体框架
Fig. 2 Overall framework of network

1.3 浅层共享编码器

提出的浅层共享编码器 (SSC) 用于提取待重建的 LR 图像的浅层特征, 主要由 Conv 层和残差 (Res) 模块组成, 如图 3 所示. 图 3 中: H_i 和 G_i 分别为 Res 单元和 Conv 层的输出特征, 最后一层 H_i 为通过两层 Res 模块的输出特征. 受到残差网络 (ResNet) 的启发, Res 结构由两个卷积层构成, 中间采用参数化修正线性单元 (PReLU) 激活函数, 在残差的输出位置也使用一个 PReLU 激活函数. 在 SSC 模块中, 使用 PReLU 激活函数代替 ReLU 激活函数, 主要是考虑到 PReLU 在负数部分有一个可学习的系数, 可以消除 ReLU 中由零梯度导致的“死特征”. 因此, 提出的 SSC 模块可以充分利用所有参数, 以提高网络的特征表示能力. 考虑到原始 ResNet 网络中 Res 模块的 BN 层容易降低模型的收敛速度和整体性能, 与 EDSR 提出的残差模块一致, 移除 BN 层, 使 SSC 结构能够从 LR 图像学习并保留更多有用的高频信息, 增加特征的变化范围.

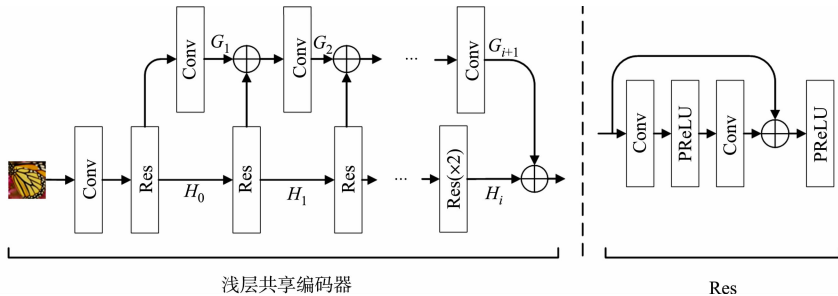


图 3 浅层共享编码器
Fig. 3 Shallow shared encoder

在 SSC 模块中, 每一级的 Res 模块通过对上一级的输出信息提取的特征进行分离, 再经过一个 Conv 层的特征学习, 并与下一级 Res 模块得到的特征相融合, 表达式为

$$H_i = \delta(F_{3 \times 3}(\delta \cdot F_{3 \times 3}(x_i)) + x_i), \quad G_{i+1} = F_{3 \times 3}(H_i + G_i). \quad (5)$$

式(5)中: x_i 为 Res 单元的输入特征; $F_{3 \times 3}$ 为卷积核为 3×3 的卷积操作; δ 为 PReLU 激活函数.

1.4 深层特征提取模块

He 等^[21]在常微分方程的基础上提出了 RK2 残差模块, 其中的特征学习单元, 如图 4 所示. 虽然 RK2 残差模块具有参数量小、训练速度快等优点, 但其对深度特征的学习不够充分, 从而限制了 OISR-RK2 模型的重建图像的质量.

许多超分辨率模型使用的特征学习单元对内部结构的轻微调整会产生巨大的影响, 在 RK2 残差模块中的 Module 同样也会产生此类问题. 为了尽可能多地学习更丰富的细节和纹理, 并将参数量保持在一个合理的范围, 在原始的特征学习单元上, 使用更深层的 Module 结构, 并在每一个卷积层后引入参数规范化 (WN) 层^[24]. 得到的深度特征学习单元, 如图 5 所示.

WN 层在神经网络中是一种针对权重向量重新参数化的方式, 分离了权重向量的方向和长度. 虽然 WN 和 BN 都属于参数重写, 但是相比于 BN 层, WN 层加快了模型训练的收敛速度, 减少了批次大小在梯度计算过程中引入的噪声, 更加适用于超分辨率任务. 假设特征输出的表达式为

$$y = w \times x + b. \quad (6)$$

式(6)中: w 为 k 维特征向量; x 为网络输入特征; b 为标量偏差项.




图 4 特征学习单元

Fig. 4 Feature learning unit

则参数规范化可将 w 分解为

$$w=g\boldsymbol{v}/\|\boldsymbol{v}\|. \tag{7}$$

式(7)中: \boldsymbol{v} 为参数向量; g 为参数标量; $\|\boldsymbol{v}\|$ 表示 \boldsymbol{v} 的欧式范数.

长度和方向的分离加快了模型的收敛速度. 对于超分辨率任务来说,WN 层并不会受到批次大小的影响,也不需要额外的空间保存 BN 层的均值和方差,因为它只是一种重新参数化技术.

2 实验结果与分析

2.1 实验环境及实验设置

实验环境为 Ubuntu 18.04 系统搭配 PyTorch 1.3 平台,GPU 为 NVIDIA TITAN Xp 12 GB. 为了与当前最先进的方法比较,与 OISR 方法一致,选择已公开的 DIV2K 数据集集中的 800 张高分辨率 RGB 图像作为训练图像;并且选择 Set5,Set14,B100 和 Urban100 作为测试图像集. 在训练集中,使用大小为 48 px×48 px 的低分辨率图像块,以及与之相对应的高分辨率图像,并采用随机翻转和 90°,180°,270° 旋转来增加训练集数据,同时,在模型的输入端减去 DIV2K 数据集的平均 RGB 值作为图像预处理.

训练模型采用自适应矩估计(ADAM)优化器训练网络模型,一阶指数衰减率为 0.9,二阶指数衰减率为 0.999, $\epsilon=10^{-8}$,学习率设置为 0.000 1,采用损失函数 $Loss=\sum_{j=0}^s|y_j-f(x_j)|$,迭代次数设置为 800 次. 在浅层共享编码器结构中,设置编码器数量 i 为 2,卷积层卷积核大小为 3×3,特征图数量为 64;深度特征学习阶段设置残差块数量为 8,深度特征学习单元 n 分别取 2,3,4 进行比较,卷积层的卷积核大小为 3×3,特征图数量为 64.

2.2 评价标准

对于不同模型的超分辨率评价标准,采用峰值信噪比(R_{PSN})和结构相似性(M_{SSI})两种评价方式,其表达式分别为

$$R_{PSN}=10\cdot\lg\frac{(2^a-1)^2}{E_{MS}}, \tag{8}$$

$$M_{SSI}=\frac{(2\mu_X\mu_Y+C_1)(2\sigma_{XY}+C_2)}{(\mu_X^2+\mu_Y^2+C_1)(\sigma_X^2+\sigma_Y^2+C_2)}. \tag{9}$$

式(8),(9)中: a 为图像位数; E_{MS} 为均方误差; μ_X,μ_Y 和 σ_X,σ_Y 分别对应原始图像、预测图像的均值和方差. R_{PSN} 越大,表示失真越小,对应的超分辨率方法的效果越好;而 M_{SSI} 越接近 1,则表示重建图像与原始图像越相似,对应的超分辨率方法的性能越好.

2.3 模型分析

首先,在 RK2-s 算法的基础上引入浅层共享编码器结构进行分析比较,在原始的模型基础上使用共享编码器结构,采用 Set5 数据集进行测试(×2);设置 i 的取值分别为 2,4,深度特征学习单元 n 为 3,保证在其他训练参数一致的前提下,在 Set5 数据集进行对比测试(×2),结果如表 1 所示.

由表 1 可知:在引入浅层共享编码器的情况下, R_{PSN} 为 38.02 dB,比无共享编码器提高了 0.04 dB;在浅层特征的提取部分,浅层共享编码器增加 2 个标准残差模块和 2 个卷积层, R_{PSN} 提升了 0.02 dB. 因此,加深共享编码器的结构可以学习更多层次的特征,具体可以根据实际的应用选择不同的 i 值. 但在后续对比实验中,为了降低模型的复杂度并提高模型的效率, i 的取值均为 2.




图 5 深度特征学习单元

Fig. 5 Deep feature learning unit

其次,在深度特征学习单元 n 分别为 2,3,4 情况下,保持模型中其他参数一致,在 Set5 数据集上进行对比测试($\times 4$),如表 2 所示.表 2 中: t 为模型训练所需要的时间.由表 2 可知:随着深度特征学习单元数的增加,模型能够有效地对图像的深度特征进行提取,但模型的训练时间也在增加.因此,为了使提出的模型更适合于实际应用,将深度特征学习单元 n 值设置为 3.

表 1 浅层共享编码器对模型的影响

Tab. 1 Influence of shallow shared encoder on model


参数	浅层共享编码器		i	
	无	有	2	4
R_{PSN}/dB	37.98	38.02	38.11	38.13

表 2 深度特征学习单元对模型的影响


Tab. 2 Influence of deep feature learning unit on model

参数	$n=2$	$n=3$	$n=4$
R_{PSN}/dB	32.22	32.29	32.32
t/d	2	3	4

最后,对比有、无使用 WN 层的模型训练损失,结果如图 6 所示.图 6 中: N 为迭代次数.由图 6 可知:在使用 WN 层的情况下,损失函数 Loss 值降低得更快,模型收敛更加迅速,重建图像和真实图像之间的误差更小,且网络在训练过程中表现出更佳稳定性.因此,在相同的条件下,WN 层能够更好地预测重建图像,有利于超分辨率网络模型的训练.



(a) 使用 WN 层的模型



(b) 未使用 WN 层的模型

图 6 有、无使用 WN 层的模型训练损失对比

Fig. 6 Comparison of model training loss with and without WN layer

2.4 与其他算法的比较

为了验证提出模型的有效性,与 Bicubic, SRCNN^[12], VDSR^[13], EDSR-s^[16], OISR-RK2-s^[21] 和 OISR-LF-s^[21] 算法进行比较.在 Set5 数据集上测试 SRCNN, VDSR, EDSR-s, OISR-RK2-s, OISR-LF-s 算法和文中算法的重建时间,结果分别为 0.21, 0.24, 0.52, 0.28, 0.30, 0.33 s.在 Set5, Set14, B100, Urban100 四个数据集中,文中算法与其他算法的超分辨率评价对比,如表 3 所示.

表 3 文中算法与其他算法的超分辨率评价对比

Tab. 3 Comparison of super-resolution evaluation between proposed algorithm and other algorithms

算法	图像放大 倍数	Set5		Set14		B100		Urban100	
		R_{PSN}/dB	M_{SSI}	R_{PSN}/dB	M_{SSI}	R_{PSN}/dB	M_{SSI}	R_{PSN}/dB	M_{SSI}
Bicubic	$\times 2$	33.66	0.929	30.24	0.868	29.56	0.843	26.88	0.840
SRCNN		36.66	0.954	32.42	0.906	31.36	0.887	29.50	0.894
VDSR		37.53	0.958	33.03	0.912	31.90	0.896	30.76	0.914
EDSR-s		37.91	0.959	33.47	0.916	32.15	0.898	31.97	0.924
OISR-RK2-s		37.98	0.960	33.58	0.917	32.18	0.899	32.09	0.928
OISR-LF-s		38.02	0.960	33.62	0.917	32.20	0.900	32.21	0.929
文中算法		38.11	0.962	33.67	0.919	32.23	0.899	32.41	0.931
Bicubic	$\times 3$	30.39	0.868	27.55	0.774	27.21	0.738	24.46	0.734
SRCNN		32.75	0.909	29.28	0.820	28.41	0.786	26.24	0.798
VDSR		33.66	0.921	29.77	0.831	28.82	0.797	27.14	0.827
EDSR-s		34.29	0.924	30.25	0.843	29.05	0.804	27.98	0.849
OISR-RK2-s		34.43	0.927	30.33	0.842	29.10	0.805	28.20	0.853
OISR-LF-s		34.39	0.927	30.35	0.842	29.11	0.805	28.24	0.854
文中算法		34.51	0.928	30.39	0.843	29.15	0.806	28.41	0.858

续表
Continue table

算法	图像放大 倍数	Set5		Set14		B100		Urban100	
		R_{PSN}/dB	M_{SSI}	R_{PSN}/dB	M_{SSI}	R_{PSN}/dB	M_{SSI}	R_{PSN}/dB	M_{SSI}
Bicubic	×4	28.42	0.810	26.00	0.702	25.96	0.667	23.14	0.657
SRCNN		30.48	0.862	27.49	0.750	26.90	0.710	24.52	0.722
VDSR		31.35	0.883	28.01	0.767	27.29	0.725	25.18	0.752
EDSR-s		32.05	0.888	28.51	0.772	27.52	0.732	25.87	0.780
OISR-RK2-s		32.21	0.895	28.63	0.782	27.58	0.736	26.14	0.787
OISR-LF-s		32.14	0.894	28.63	0.781	27.60	0.736	26.17	0.788
文中算法		32.29	0.895	28.65	0.781	27.61	0.736	26.20	0.790

由表 3 可知:在不同的测试数据集中,图像放大 2~4 倍下,文中算法的 R_{PSN} 和 M_{SSI} 总体均高于其他算法,取得了最优的超分辨率效果,而 LF-s 算法取得了次优的效果;在 Set5 数据集且图像放大 2 倍的情况下,相比于 OISR-RK2-s 和 OISR-LF-s 算法,文中算法的 R_{PSN} 分别提高了 0.13,0.09 dB;在 Urban100 数据集且图像放大 3 倍的情况下,文中算法的 R_{PSN} 比 OISR-LF-s 算法提升了 0.17 dB.

不同超分辨率算法的参数量(M)及在 Set5 数据集(×4)的 R_{PSN} 对比,如图 7 所示.由图 7 可知:虽然文中算法的网络模型参数量有一定的增加,但仍在一个较为合理的范围内,并且对于所有的测试数据集,在图像放大 3 倍的情况下,文中算法取得了最优的效果.

图 8~10 分别展示了不同超分辨率算法的主观视觉效果.为了便于观察比较,测试图像的细节区域经过局部放大.

由图 8~10 可知:Bicubic 算法重建的图像效果模糊,甚至观测不到图像的纹理;SRCNN 和 VDSR 算法虽然能呈现一定的结构特征,但容易学习到不属于原本图像的高频信息,导致重建的图像包含较多




图 7 不同超分辨率算法的 M 及 R_{PSN} 对比

Fig. 7 Comparison of M and R_{PSN} in different super resolution algorithms




图 8 数据集 Urban100 中图像“Img_098”的重建结果展示图

Fig. 8 Display images of reconstruction result of image “Img_098” in data set Urban100




图 9 数据集 Set14 中图像“Barbara”的重建结果展示图

Fig. 9 Display images of reconstruction result of image “Barbara” in data set Set14

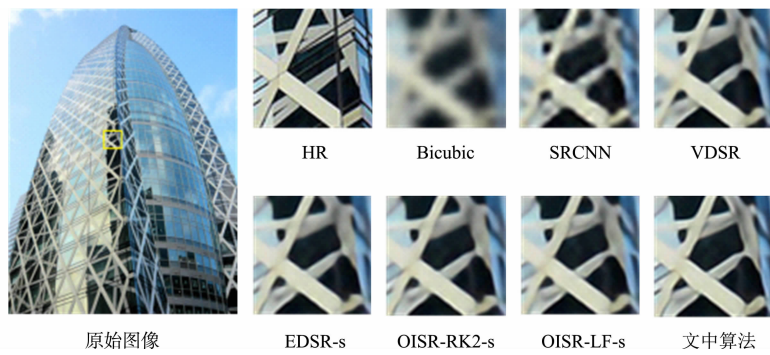


图 10 数据集 Urban100 中图像“Img_039”的重建结果展示图

Fig. 10 Display images of reconstruction result of image “Img_039” in data set Urban100

的伪边缘信息;EDSR-s,OISR-RK2-s,OISR-LF-s 算法得到的重建图像的视觉效果明显优于 SRCNN 和 VDSR 算法,主要表现在边缘纹理方面更加清晰,但是局部恢复图像块中(图 9),这 3 种算法都学习到了错误的高频特征,导致重建图像的纹理严重变形.在原始 OISR 提出的 OISR-RK2-s 算法中,建立了超分辨率网络和微分方程之间的联系,但是在超分辨率网络的设计过程中,仍未充分学习图像的高频信息.而文中算法与其不同,一方面,不仅重视浅层特征的学习,并根据提取的初始特征,通过配合 WN 层,使模型训练更加稳定;另一方面,还注重深层特征的学习,在图像重建的过程中,充分利用浅层特征与深层特征恢复图像的高频信息,从而生成更加精准的边缘纹理;相比于其他算法,文中算法得到的重建图像在整体效果上最接近原始的 HR 图像.

3 结束语

针对 OISR-RK2 超分辨率方法存在深度特征学习少、图像重建质量一般的问题,充分利用 LR 图像包含的丰富的低频信息和高频信息,提出浅层共享编码器对图像作初始特征提取;在深度特征学习阶段提出更深层的结构,结合参数规范化,学习更加有用的高频特征,在保证一定模型训练时长下,更好地构造高低分辨率图像之间的映射关系.无论从客观评价指标,还是主观视觉上,文中算法均优于当前的轻量级模型算法.

参考文献:

- [1] LEI Sen,SHI Zhenwei,ZOU Zhengxia. Coupled adversarial training for remote sensing image super-resolution[J]. IEEE Transactions on Geoscience and Remote Sensing,2020,58(5):3633-3643. DOI:10. 1109/TGRS. 2019. 2959020.
- [2] LYU Qing,SHAN Hongming,WANG Ge. MRI super-resolution with ensemble learning and complementary priors [J]. IEEE Transactions on Computational Imaging,2020,6:615-624. DOI:10. 1109/TCI. 2020. 2964201.
- [3] ZHU Jianqing,ZENG Huanqiang,HUANG Jingchang, *et al.* Vehicle re-identification using quadruple directional deep learning features[J]. IEEE Transactions on Intelligent Transportation Systems,2020,21(1):410-420. DOI:10. 1109/TITS. 2019. 2901312.
- [4] CHEN Jin,CHEN Jun,WANG Zheng, *et al.* Identity-aware face super-resolution for low-resolution face recognition [J]. IEEE Signal Processing Letters,2020,27:645-649. DOI:10. 1109/LSP. 2020. 2986942.
- [5] KEYS R. Cubic convolution interpolation for digital image processing[J]. IEEE Transactions on Acoustics, Speech, and Signal Processing,1981,29(6):1153-1160. DOI:10. 1109/TASSP. 1981. 1163711.
- [6] FATTAL R. Image upsampling *via* imposed edge statistics[J]. ACM Transactions on Graphics,2007,26(3):95. DOI:10. 1145/1276377. 1276496.
- [7] AKHTAR N,SHAFAIT F,MIAN A. Bayesian sparse representation for hyperspectral image super resolution[C]// IEEE Conference on Computer Vision and Pattern Recognition. Boston: IEEE Press,2015:3631-3640. DOI:10. 1109/CVPR. 2015. 7298986.
- [8] ZHANG Kaibing,GAO Xinbo,TAO Dacheng, *et al.* Image super-resolution *via* non-local steering kernel regression regularization[C]// IEEE International Conference on Image Processing. Melbourne: IEEE Press,2013:943-946.

DOI:10.1109/ICIP.2013.6738195.

- [9] WANG Lingfeng, XIANG Shiming MENG Gaofeng, *et al.* Edge-directed single-image super-resolution *via* adaptive gradient magnitude self-interpolation[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2013, 23(8):1289-1299. DOI:10.1109/TCSVT.2013.2240915.
- [10] TIMOFTE R, DESMET V, VANGOOL L. A+: Adjusted anchored neighborhood regression for fast super-resolution[C]// Asian Conference on Computer Vision. Singapore: Springer, 2014: 111-126. DOI: 10.1007/978-3-319-16817-3_8.
- [11] YANG Jianchao, WRIGHT J, HUANG T S, *et al.* Image super-resolution *via* sparse representation[J]. IEEE Transactions on Image Processing, 2010, 19(11):2861-2873. DOI:10.1109/TIP.2010.2050625.
- [12] DONG Chao, LOY C C, HE Kaiming, *et al.* Image super-resolution using deep convolutional networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(2):295-307. DOI:10.1109/TPAMI.2015.2439281.
- [13] KIM J, LEE J K, LEE K M. Accurate image super-resolution using very deep convolutional networks[C]// IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE Press, 2016: 1646-1654. DOI:10.1109/CVPR.2016.182.
- [14] DONG Chao, LOY C C, TANG Xiaoou. Accelerating the super-resolution convolutional neural network[C]// European Conference on Computer Vision. Amsterdam: Springer, 2016: 391-407. DOI:10.1007/978-3-319-46475-6_25.
- [15] WAI Weisheng, HUANG Jiabin, AHUJA N, *et al.* Deep laplacian pyramid networks for fast and accurate super-resolution[C]// IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE Press, 2017: 5835-5843. DOI:10.1109/CVPR.2017.618.
- [16] LIM B, SON S, KIM H, *et al.* Enhanced deep residual networks for single image super-resolution[C]// IEEE Conference on Computer Vision and Pattern Recognition Workshops. Honolulu: IEEE Press, 2017: 1132-1140. DOI:10.1109/CVPRW.2017.151.
- [17] LEDIG C, THEIS L, HUSZÁR F, *et al.* Photo-realistic single image super-resolution using a generative adversarial network[C]// IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE Press, 2017: 105-114. DOI:10.1109/CVPR.2017.19.
- [18] HARIS M, SHAKHNAROVICH G, UKITA N. Deep back-projection networks for super-resolution[C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE Press, 2018: 1664-1673. DOI: 10.1109/CVPR.2018.00179.
- [19] ZHANG Yulun, LI Kunpeng, LI Kai, *et al.* Image super-resolution using very deep residual channel attention networks[C]// Proceedings of the European Conference on Computer Vision. Munich: Springer, 2018: 294-310. DOI: 10.1007/978-3-030-01234-2_18.
- [20] ZHANG Yulun, LI Kunpeng, LI Kai, *et al.* Residual non-local attention networks for image restoration[C]// International Conference on Learning Representations. New Orleans: [s. n.], 2019: 1-18.
- [21] HE Xiangyu, MO Zitao, WANG Peisong, *et al.* ODE-inspired network design for single image super-resolution [C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE Press, 2019: 1732-1741. DOI:10.1109/CVPR.2019.00183.
- [22] YE Xinchun, SUN Baoli, WANG Zhihui, *et al.* PMBANet: Progressive multi-branch aggregation network for scene depth super-resolution[J]. IEEE Transactions on Image Processing, 2020, 29: 7427-7442. DOI:10.1109/TIP.2020.3002664.
- [23] YE Xinchun, SUN Baoli, WANG Zhihui, *et al.* Depth super-resolution *via* deep controllable slicing network[C]// Proceedings of the 28th ACM International Conference on Multimedia. Seattle: ACM, 2020: 1809-1818. DOI: 10.1145/3394171.3413874.
- [24] SALIMANS T, KINGMA D P. Weight normalization: A simple reparameterization to accelerate training of deep neural networks[C]// Advances in Neural Information Processing Systems. Barcelona: Curran Associates Inc, 2016: 901-909.

(责任编辑: 黄晓楠 英文审校: 吴逢铁)