

控制与决策

Control and Decision

多级信息补偿的U型网络图像超分辨率重建算法

宋昭漾, 赵小强, 惠永永, 蒋红梅

引用本文:

宋昭漾, 赵小强, 惠永永, 蒋红梅. 多级信息补偿的U型网络图像超分辨率重建算法[J]. 控制与决策, 2023, 38(9): 2479–2486.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.2250>

您可能感兴趣的其他文章

Articles you may be interested in

基于自注意力生成对抗网络的图像超分辨率重建

Image super-resolution reconstruction based on self-attention GAN

控制与决策. 2021, 36(6): 1324–1332 <https://doi.org/10.13195/j.kzyjc.2019.1290>

基于条件对抗生成孪生网络的目标跟踪

Conditional generative adversarial siamese networks for object tracking

控制与决策. 2021, 36(5): 1110–1118 <https://doi.org/10.13195/j.kzyjc.2019.1215>

基于多层次特征的机械臂单阶段抓取位姿检测

Single-stage grasp pose detection of manipulator based on multi-level features

控制与决策. 2021, 36(8): 1815–1824 <https://doi.org/10.13195/j.kzyjc.2019.1840>

基于双分支特征融合的场景文本检测方法

A scene text detection based on dual-path feature fusion

控制与决策. 2021, 36(9): 2179–2186 <https://doi.org/10.13195/j.kzyjc.2020.0002>

复杂背景下全景视频运动小目标检测算法

Panoramic video motion small target detection algorithm in complex background

控制与决策. 2021, 36(1): 249–256 <https://doi.org/10.13195/j.kzyjc.2019.0686>

多级信息补偿的U型网络图像超分辨率重建算法

宋昭漾^{1,2,3}, 赵小强^{1,2,3†}, 惠永永^{1,2,3}, 蒋红梅^{1,2,3}

1. 兰州理工大学 电气工程与信息工程学院, 兰州 730050;
2. 甘肃省工业过程先进控制重点实验室, 兰州 730050;
3. 兰州理工大学 国家级电气与控制工程实验教学中心, 兰州 730050)

摘要: 针对基于深度神经网络的图像超分辨率重建算法在特征提取过程中容易丢失特征信息, 导致重建图像缺少纹理和边缘细节等问题, 提出一种多级信息补偿的U型网络图像超分辨率重建算法. 首先设计一个用于图像超分辨率重建的U型网络, 该网络通过下通道分支对输入特征进行多层次特征提取和通道压缩, 通过底层模块对压缩后的特征进行融合并提取不同通道的相关特征, 通过上通道分支对压缩后的相关特征进行多层次特征提取和通道恢复; 然后设计多级信息补偿模型, 对U型网络的通道压缩过程中丢失的信息和通道恢复过程中难以恢复的信息进行补偿; 最后在不同放大倍数下的Set5、Set14、BSD100和Urban100测试集上对所提算法和主流算法进行对比测试分析, 实验结果表明所提算法相比主流算法实现了在峰值信噪比(PSNR)/结构相似度(SSIM)指标和视觉效果上的巨大提升.

关键词: 超分辨率重建; 深度神经网络; 多级信息补偿; U型网络

中图分类号: TP391 文献标志码: A

DOI: 10.13195/j.kzyjc.2021.2250

引用格式: 宋昭漾, 赵小强, 惠永永, 等. 多级信息补偿的U型网络图像超分辨率重建算法[J]. 控制与决策, 2023, 38(9): 2479-2486.

Image super-resolution reconstruction algorithm of U-shaped network based on multi-level information compensation

SONG Zhao-yang^{1,2,3}, ZHAO Xiao-qiang^{1,2,3†}, HUI Yong-yong^{1,2,3}, JIANG Hong-mei^{1,2,3}

1. College of Electrical Engineering and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China;
2. Key Laboratory of Gansu Advanced Control for Industrial Processes, Lanzhou 730050, China;
3. National Experimental Teaching Center of Electrical and Control Engineering, Lanzhou University of Technology, Lanzhou 730050, China)

Abstract: Aiming at the problem that the image super-resolution reconstruction algorithm based on the deep neural network is easy to lose feature information during feature extraction, which leads to the lacks of texture and edge details in the reconstructed image, this paper proposes a U-shaped network image super-resolution reconstruction algorithm with multi-level information compensation. Firstly, a U-shaped network for image super-resolution reconstruction is designed, which performs multi-level feature extraction and channel compression on the input features through the lower channel branch, and fuses the compressed features through the bottom module and extracts the related features of different channels, and performs multi-level feature extraction and channel recovery on the compressed related features through the upper channel branch. Then, a multi-level information compensation model is designed, which compensates for the lost information in the channel compression process and the information that is difficult to recover in the channel recovery process of the U-shaped network. Finally, compared with the mainstream algorithms, the proposed algorithm is tested and analyzed by the test sets of Set5, Set14, BSD100 and Urban100 at different magnifications. The experimental results show that the proposed algorithm greatly improves the peak signal-to-noise ratio (PSNR)/structural similarity (SSIM) index and visual effect.

Keywords: super-resolution reconstruction; deep neural network; multi-level information compensation; U-shaped network

收稿日期: 2021-12-27; 录用日期: 2022-04-27.

基金项目: 国家自然科学基金项目(61763029); 国防基础科研项目(JCKY2018427C002); 国家重点研发计划项目(2020YFB1713600); 甘肃省重点研发计划项目(21YF5GA072); 甘肃省自然科学基金项目(21JR7RA206, 20JR5RA459); 甘肃省教育厅优秀研究生创新之星项目(2021CXZX-501).

责任编辑: 张国山.

†通讯作者. E-mail: xqzhao@lut.edu.cn.

0 引言

图像超分辨率重建 (super-resolution, SR) 技术是计算机视觉很重要的一个研究分支,其应用于生活中的诸多领域,比如城市管理^[1]和遥感成像^[2]等,该技术主要是从低分辨率图像 (low-resolution, LR) 中重建出高分辨率图像 (high-resolution, HR). 近年来,诸多领域对图像的分辨率要求越来越高,而通过改变硬件设备提升图像的分辨率存在一定的限制,因此图像超分辨率重建技术成为了研究热点. 众多研究人员提出了一些超分辨率重建算法^[3],如双三次插值^[4]、邻域嵌入^[5]和稀疏表示^[6]等,虽然这些算法能够取得一些效果,但会造成图像振铃、模糊和虚化等问题,图像质量难以满足要求.

最近,一些研究人员提出了基于深度学习^[7]的图像超分辨率重建算法^[8-11],例如,受卷积神经网络在计算机视觉其他任务中成功应用的启发,Dong等^[12]基于卷积神经网络率先提出了一个只使用了3个卷积层来重建高分辨率图像的算法SRCNN,该算法取得了比传统超分辨率重建算法更好的结果,开启了利用神经网络处理超分辨率重建问题的新时代. Dong等^[13]进一步提出了一种快速的卷积神经网络超分辨率重建算法FSRCNN,与SRCNN相比,FSRCNN增加了网络的深度,同时因为反卷积可以实现LR空间到HR空间的转换,所以FSRCNN引入了反卷积层来重建图像特征. 从LR空间重建图像特征的另外一种方法是Shi等^[14]提出的亚像素卷积重建方法,亚像素卷积可以直接依靠卷积运算代替反卷积运算来实现特征重建,大大提高了计算速度. 为了克服增加网络深度从而导致的梯度消失或梯度爆炸问题,Kim等^[15]在网络的第一层和最后一层之间添加了全局残差连接,使得信息可以在浅层特征和深层特征之间进行传递. 同年,Kim等^[16]使用递归神经网络重建高分辨率图像,提出了一种深度递归卷积网络超分辨率重建算法,该算法通过循环校正策略使重建图像不断接近目标图像. 由于残差网络和生成对抗网络在图像处理的其他领域内获得了良好的效果,一些学者对残差网络和生成对抗网络进行了改进,并应用到图像超分辨率重建领域. 比如Lim等^[17]提出的基于增强的深度残差网络的图像超分辨率重建算法和Ledig等^[18]提出的基于生成对抗网络的图像超分辨率重建算法,都获得了较好的性能指标和视觉效果. 在图像的重建过程中,重建误差会随着网络深度的加深而增大,为了解决此问题,Haris等^[19]提出了基于深度反向投影网络的图像超分辨率重建算法,该算法通过迭代上采样和迭代下采样操作来计算重建误差以获得更好的

重建性能. 注意力机制与人类视觉相似,能够将网络计算量聚焦于重点区域,一些学者将注意力机制应用到超分辨率重建领域并不断改进. 比如Zhang等^[20]提出了基于残差通道注意力网络超分辨率重建算法,改进了“squeeze-and-excitation”模块^[21],并提出了通道注意力块实现超分辨率重建性能的提升;Dai等^[22]提出了二阶注意力机制的图像超分辨率重建算法,该算法设计了二阶通道注意力机制来自适应地调整特征,提高其重建性能;Zhang等^[23]提出了基于注意力的网络图像超分辨率重建算法,该算法动态调整注意力层的作用,更主动地进行像素级注意力调整,减少重建性能的退化. 虽然这些算法获得了较好的重建效果,但是在提取低分辨率图像特征过程中容易丢失图像的一些细节信息,比如纹理和边缘信息等.

为了解决上述问题,本文提出一种多级信息补偿的U型网络图像超分辨率重建算法. 具体地,首先设计一种用于图像超分辨率重建的U型网络,它由下通道分支、底层模块和上通道分支构成,下通道分支对低分辨率图像特征进行不同层级特征提取和通道压缩,底层模块对压缩后的特征进行融合并提取不同通道之间的相关特征,上通道分支对获得的相关特征进行不同层次特征提取和通道恢复来获得低分辨率图像的多级特征信息;其次设计多级信息补偿模型,该方法对下通道分支通道压缩过程中丢失的细节信息和上通道分支通道恢复过程中难以恢复的特征信息进行补偿来获得低分辨率图像更丰富的特征信息. 对比实验验证了本文算法在客观性能评价和主观视觉评估都能够获得更好的结果.

1 本文算法

1.1 U型网络

随着深度学习^[24]的快速发展,学者们提出了经典的深度神经网络,如残差网络^[25]、循环神经网络^[26]和生成对抗网络^[27]等. 一些学者将这些神经网络应用到图像超分辨率领域,提出了一系列的基于深度神经网络的图像超分辨率重建算法. 这些算法通过深度神经网络的各种学习策略学习LR图像到HR图像之间的映射函数,生成对应的网络模型. 然而这些深度神经网络的层数很深,训练得到的SR算法网络模型参数量较大,导致很难应用在特定的现实场景中.

本文提出一种用于图像超分辨率重建的U型网络,如图1所示. 该网络主要由下通道分支、底层模块和上通道分支模块组成. 下通道分支和上通道分支是由多层级的特征提取模块组和下(上)通道模块组成,其中特征提取模块组由多个残差注意力块构成. 该网络的具体运算过程如图1所示.

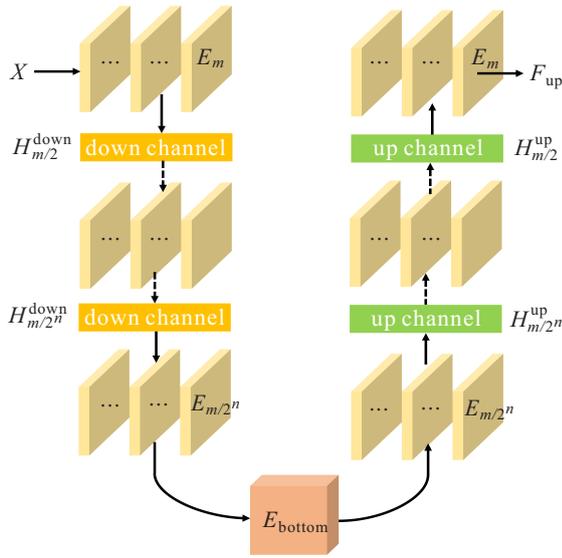


图1 U型网络结构示意图

1) 下通道分支. 该网络首先将输入特征送入到下通道分支进行不同通道上的特征提取. 在下通道分支中, 有 n 个层级, 分别进行 n 个不同通道情况下的

特征提取, 有 $n - 1$ 个下通道模块, 分别进行相邻层级之间的通道压缩. 输入特征首先被输入到通道数为 m 维的特征提取模块中提取特征, 然后通过下通道模块进行压缩, 将通道数变为 $m/2$, 并在通道数为 $m/2$ 维的特征提取模块中提取特征, 直到下分支的最后一层级进行通道数为 $m/2^n$ 维的特征提取. 其运算过程如下所示:

$$F_{\text{down}} = E_{m/2^n}(H_{m/2^{n-1}}^{\text{down}}(\dots H_{m/2}^{\text{down}}(E_m(X))\dots)). \quad (1)$$

其中: X 表示输入特征, F_{down} 表示输入特征经过下通道分支 n 个层级运算得到的特征, $E_{m/2^n}$ 和 E_m 表示不同层级的特征提取运算, $H_{m/2^n}^{\text{down}}$ 和 $H_{m/2^{n-1}}^{\text{down}}$ 表示不同的下通道模块. 下通道模块是由反卷积层组成, 其输入通道值为上一层级的输出通道值, 输出通道值为下一层级的输入通道值. 不同层级的特征提取模块结构如图2所示, 其由多个残差注意力块通过局部残差连接组成.

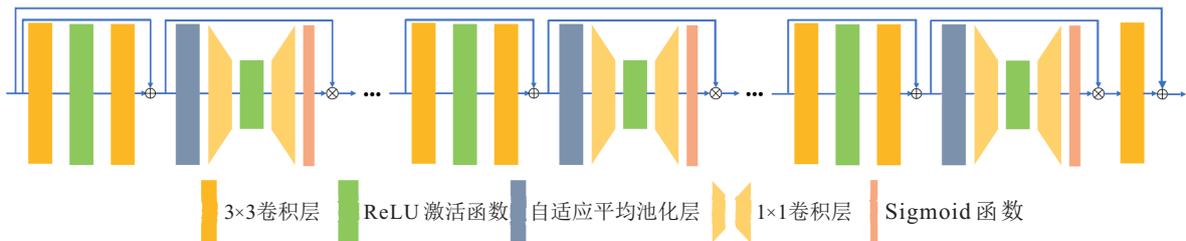


图2 不同层级的特征提取模块结构

2) 底层模块. 下通道分支通过不同层级提取到不同通道的特征, 而这些特征之间缺乏通道间的信息关联. 因此, 本文构造了底层模块对这些不同通道间的特征进行处理, 具体地, 底层模块对下通道分支获得的不同通道的特征进行融合处理, 并提取不同通道间的相互关联特征, 其运算过程如下所示:

$$F_{\text{bottom}} = E_{\text{bottom}}(F_{\text{down}}). \quad (2)$$

其中: E_{bottom} 表示底层模块的运算, F_{bottom} 表示下通道分支提取的不同通道特征 (F_{down}) 通过底层模块的运算 (E_{bottom}) 得到的特征.

3) 上通道分支. 底层模块在小通道的情况下通过融合处理和提取获得的特征具有较少的信息, 如果直接用这些特征重建 SR 图像会使得图像的细节信息重建的不充分. 因此, 本文构造了上通道分支对这些特征进行不同层次的通道恢复, 并在不同的通道恢复过程中提取特征. 上通道分支的结构和下通道分支的结构相似, 也有 n 个层级和 $n - 1$ 个上通道模块, 分别进行 n 个不同通道情况下的特征提取和相邻层级通道之间的特征恢复. 相比下通道分支通过 $n - 1$

个下通道模块将 m 维通道的特征压缩到 $m/2^n$ 维通道的特征, 上通道分支通过 $n - 1$ 个上通道模块, 将 $m/2^n$ 维通道的特征恢复到 m 维通道的特征, 其运算过程如下所示:

$$F_{\text{up}} = E_m(H_{m/2}^{\text{up}}(\dots H_{m/2^{n-1}}^{\text{up}}(E_{m/2^n}(F_{\text{bottom}}))\dots)). \quad (3)$$

其中: F_{up} 表示底层特征 (F_{bottom}) 经过上通道分支 n 个层级运算得到的特征, $H_{m/2}^{\text{up}}$ 和 $H_{m/2^{n-1}}^{\text{up}}$ 表示不同的上通道模块. 上通道模块是由卷积层组成, 其输入通道值为下一层级的输出通道值, 输出通道值为上一层级的输入通道值.

1.2 多级信息补偿

图像特征在U型网络不同层级的通道压缩过程中, 由于一些较小的特征信息被压缩, 很难在下一层级的特征提取过程中获得重要的特征信息, 这意味着通道压缩会丢失一些特征信息. 同样地, 图像特征在U型网络不同层级的通道恢复过程中, 由于压缩后的较小特征丢失了一些信息, 很难恢复出丰富的特征信息. 为了解决这些问题, 本文提出多级信息补偿模型,

其结构如图3所示.

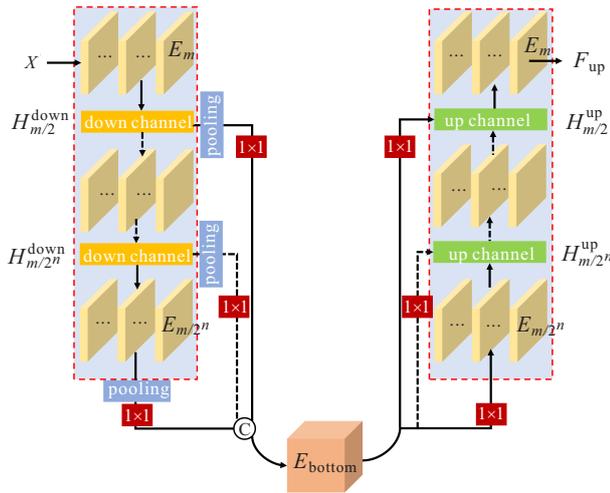


图3 多级信息补偿结构

对下通道分支的不同层级压缩过程中丢失的特征信息进行补偿的操作为:在下通道分支的不同层级的通道压缩过程中,首先将压缩之前的特征先进行池化,然后将池化后的特征通过 1×1 卷积层进行运算,最后将这些特征进行级联操作并输入到底层模块,则式(2)更新为

$$F_{\text{bottom}} = E_{\text{bottom}}(\text{concat}[C_1(H_{\text{pool}}(E_m(X))), \dots, C_1(H_{\text{pool}}(F_{\text{down}}))]). \quad (4)$$

其中: H_{pool} 表示池化运算, C_1 表示 1×1 卷积层运算,

$\text{concat}[\cdot]$ 表示级联运算.底层模块结构如图4所示,底层模块的输入通道为 $nm/2^n$,输出通道为 $m/2^n$.

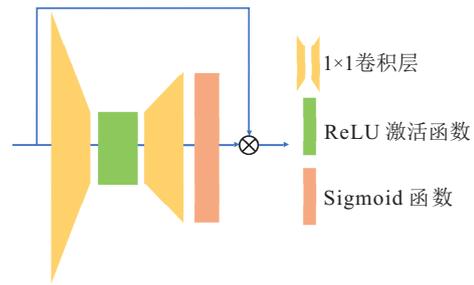


图4 底层模块结构

对上通道分支的不同层级恢复过程中进行补偿的操作为:在上通道分支的不同层级的通道恢复过程中,首先将底层模块运算后的特征通过 1×1 卷积层进行运算,然后将运算得到的特征与不同层级的通道恢复前的特征级联,最后将级联的特征进行通道恢复操作,则式(3)更新为

$$F_{\text{up}} = E_m(\text{concat}[H_{m/2}^{\text{up}}(\dots H_{m/2^{n-1}}^{\text{up}}(E_{m/2^n}(F_{\text{bottom}})) \dots), C_1(F_{\text{bottom}})]). \quad (5)$$

1.3 模型框架

多级信息补偿的U型网络图像超分辨率重建算法操作主要分为浅层特征提取、深层特征提取、上采样和图像重建,其模型框架如图5所示.

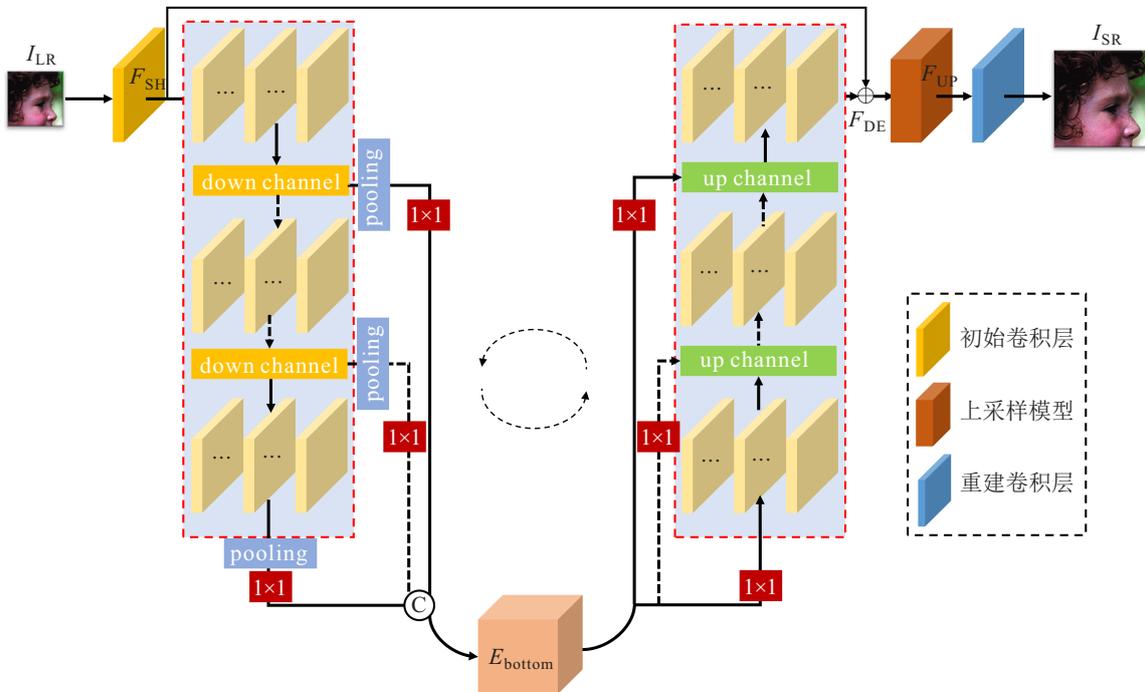


图5 基于U型网络的图像超分辨率重建模型框架示意图

假设 I_{LR} 为输入的低分辨率图像, I_{SR} 为输出的重建图像,该网络模型首先通过初始卷积层从低分辨率图像中提取浅层特征,即

$$F_{\text{SH}} = H_{\text{INI}}(I_{\text{LR}}). \quad (6)$$

其中: H_{INI} 表示初始卷积层的运算, F_{SH} 表示提取到的浅层特征.然后浅层特征通过U型网络多次循环

提取到图像的深层特征,即

$$F_{DE} = H_U(F_{SH}). \quad (7)$$

其中: F_{DE} 表示提取到的深层特征, H_U 表示U型网络多次循环的运算. 其次深层特征和浅层特征通过上采样模型进行上采样,即

$$F_{UP} = H_{UP}(F_{DE} + F_{SH}). \quad (8)$$

其中: F_{UP} 表示上采样得到的特征, H_{UP} 表示上采样模块的运算. 最后上采样的特征通过重建卷积层重建超分辨率图像,即

$$I_{SR} = H_{REC}(F_{UP}), \quad (9)$$

其中 H_{REC} 表示重建卷积层的运算.

2 实验

2.1 实验准备

本文实验所用的CPU为Inter i9-9900k处理器,内存为64 G, GPU为RTX 2080Ti,显存为11 G,使用的操作系统为Ubuntu18.04,深度学习框架及其版本为Pytorch = 0.4.0,编程语言及其版本为python = 3.7.

本文使用DIV2K数据集^[28]作训练集,该数据集包含800张2K分辨率的高清图像. 本文对这些高分辨率图像进行旋转(90°、180°、270°、360°)和比例缩放(0.6、0.7、0.8、0.9)来进行数据增强,使用Bicubic算法处理这800张高分辨率图像获得对应的低分辨率

图像,将高分辨率图像和对应的低分辨率图像分别裁剪成尺寸为 $48s \times 48s$ 和 48×48 的图像块,其中 s 表示放大因子. 本文使用Set5^[29]、Set14^[30]、BSD100^[31]和Urban100^[32]数据集作为实验所用的测试集,这些测试集的图片主要分为风景、人物、美食、动物和城市建筑等风格. 为了客观评价本文所提算法的性能,使用峰值信噪比(peak signal to noise ratio, PSNR)和结构相似度(structural similarity index, SSIM)^[33]作为本次实验的评价指标.

U型网络中下通道分支和上通道分支分别由3个层级组成,每一层级由4个多级残差注意力块组成. 在从浅层特征中提取深度特征的过程中,本文对U型网络设置了5次循环,使用 L_1 函数作为损失函数,并使用Adam优化算法^[34]来最小化损失函数进行参数优化. 在训练时,本文设置批次大小为16,初始学习率为0.0001,每隔200个epoch,学习率降为原来的一半,总共训练1000个epoch.

2.2 实验结果分析

为了评估本文算法的性能,选取主流的SR算法Bicubic、SRCNN^[12]、FSRCNN^[13]、VDSR^[15]、LapSRN^[35]、SRMDNF^[36]、CARN^[37]和CBPN^[38],与本文算法对不同放大倍数情况下的4个基准测试集进行对比测试,结果见表1(CBPN在3倍下没有数据).

表1 9种算法对不同放大倍数情况下的4个基准测试集测试得到的评估结果

scale	method	Set 5	Set 14	BSD100	Urban100
		PSNR/SSIM	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM
×2	Bicubic	33.68/0.9304	30.24/0.8691	29.56/0.8435	26.88/0.8405
	SRCNN	36.66/0.9542	32.42/0.9063	31.36/0.8879	29.50/0.8946
	FSRCNN	37.00/0.9558	32.63/0.9088	31.53/0.8920	29.88/0.9020
	VDSR	37.00/0.9558	32.63/0.9088	31.53/0.8920	29.88/0.9020
	LapSRN	37.52/0.9591	32.99/0.9124	31.80/0.8952	30.41/0.9103
	SRMDNF	37.79/0.9600	33.32/0.9150	32.05/0.8980	31.33/0.9200
	CARN	37.76/0.9590	33.52/0.9166	32.09/0.8978	31.92/0.9256
	CBPN	37.90/0.9590	33.60/0.9171	32.17/0.8989	32.14/0.9279
	本文算法	37.93/0.9601	33.63/0.9170	32.17/0.8987	32.09/0.9271
×3	Bicubic	30.93/0.8682	27.55/0.7742	27.21/0.7385	24.46/0.7349
	SRCNN	32.75/0.9090	29.28/0.8209	28.41/0.7863	26.24/0.7989
	FSRCNN	33.16/0.9140	29.43/0.8242	28.53/0.7910	26.43/0.8080
	VDSR	33.66/0.9213	29.77/0.8314	28.82/0.7976	27.14/0.8279
	LapSRN	33.81/0.9220	29.79/0.8325	28.82/0.7980	27.07/0.8275
	SRMDNF	34.12/0.9250	30.04/0.8370	28.97/0.8030	27.57/0.8398
	CARN	34.29/0.9255	30.29/0.8407	29.06/0.8034	28.06/0.8493
	CBPN	34.38/0.9274	30.35/0.8419	29.10/0.8048	28.14/0.8518
	本文算法	34.38/0.9274	30.35/0.8419	29.10/0.8048	28.14/0.8518
×4	Bicubic	28.42/0.8104	26.00/0.7027	26.96/0.6675	23.14/0.6577
	SRCNN	30.48/0.8628	27.49/0.7503	26.90/0.7101	24.52/0.7221
	FSRCNN	30.71/0.8657	27.59/0.7535	26.98/0.7150	24.62/0.7280
	VDSR	31.35/0.8838	28.01/0.7674	27.29/0.7251	25.18/0.7524
	LapSRN	31.54/0.8852	28.09/0.7700	27.32/0.7275	25.21/0.7562
	SRMDNF	31.96/0.8930	28.35/0.7770	27.49/0.7340	25.68/0.7730
	CARN	32.13/0.8937	28.60/0.7806	27.58/0.7349	26.07/0.7837
	CBPN	32.21/0.8944	28.63/0.7813	27.58/0.7356	26.14/0.7869
	本文算法	32.21/0.8945	28.64/0.7817	27.57/0.7359	26.15/0.7872

从表1可以得到,在放大倍数为2、3、4的情况下,与主流的8种SR算法相比,本文算法在Set5测试集上均可以获得最优的PSNR/SSIM值.具体地,在放大倍数为2倍和4倍情况下,本文算法比CBPN算法分别提升0.03 dB/0.0011和0 dB/0.0001.本文算法在Set14、BSD100和Urban100测试集的绝大部分情况下可以获得最优的PSNR/SSIM值.具体地,在Set14测试集放大倍数为4的情况下,本文算法比CBPN算法提升0.01dB/0.0004;在Urban100测试集放大倍数为4的情况下,本文算法比CBPN算法提升0.01dB/0.0003.在Set14、BSD100、Urban100测试集的特殊情况下,本文算法获得了次优的PSNR/SSIM值,这是由于不同测试集包含的多种不同的图像风格,不同算法对图像重建的侧重点不同,意味着对不

同风格图像的重建能力不同,导致本文算法在特殊情况下获得了次优的PSNR/SSIM值.

为了进一步评估本文算法重建的视觉效果,选取在放大倍数为4的情况下的Urban100测试集中Img004、Img070和Img076这三张图像进行对比测试,其实验结果如图6~图8所示.从图6可以看出,使用8种主流算法重建的图像具有严重的模糊现象,而使用本文算法重建的图像较清晰;从图7可以得到,使用8种主流算法重建的教堂柱子具有严重的变形现象,而使用本文算法重建的图像右侧的教堂柱子并不存在严重的变形现象;同样地,从图8可以观察到,使用8种主流算法重建的大楼外侧楼层存在严重的扭曲现象,并且同一楼层存在断连现象,而使用本文算法重建的大楼楼层中部仅存在轻微的扭曲现象.

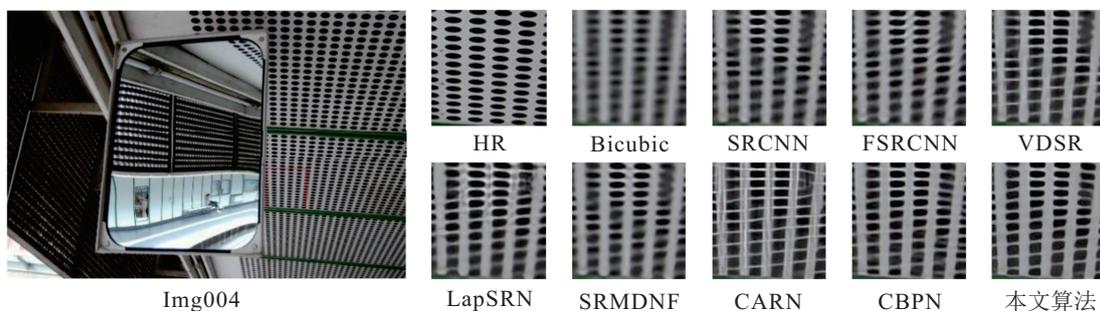


图6 9种算法在放大倍数为4时重建获得的Img004对比图像



图7 9种算法在放大倍数为4时重建获得的Img070对比图像

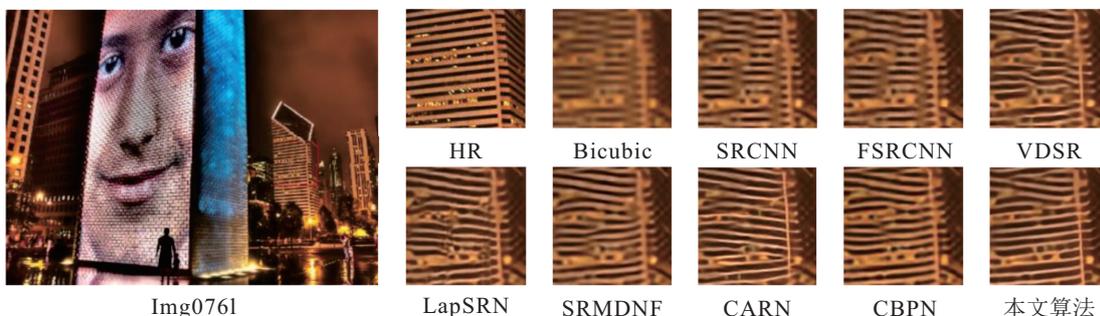


图8 9种算法在放大倍数为4时重建获得的Img076对比图像

2.3 网络模型参数分析

为了评估本文算法网络模型的轻量化,使用本文算法与主流的7种算法对放大倍数为4的Urban100

测试集进行参数量与PSNR值之间的对比测试分析,其结果如图9所示.从图9可以分析得到,对比主流的7种算法,本文算法在Urban100上得到了最高的

PSNR值,同时相比CBPN、CARN和SRMDNF算法,本文算法的网络模型拥有较少的参数量.虽然本文算法的网络模型比SRCNN、FSRCNN、VDSR和LapSRN拥有更多的参数量,但是实现了PSNR值的大幅提升,具体地,本文算法比SRCNN、FSRCNN、VDSR和LapSRN分别提升了1.63 dB、1.53 dB、0.97 dB和0.94 dB.

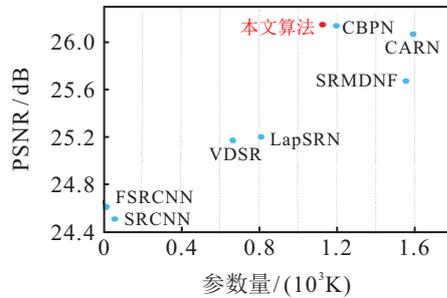


图9 本文算法与对比算法在放大倍数为4的Urban100测试集得到的参数量和PSNR值

3 结论

本文提出了一种多级信息补偿的U型网络图像超分辨率重建算法.该算法通过U型网络对低分辨率图像进行具有通道压缩和通道恢复的多层次的特征提取来获得低分辨率图像的多级特征;同时,通过多级信息补偿模型对通道压缩过程中丢失的信息和通道恢复过程中难以恢复的信息进行补偿来获得更丰富的低分辨率图像细节特征.在4个基准测试集上进行了对比测试,结果表明本文算法相比主流算法在评价性能指标和视觉效果上都获得了更好的效果.

参考文献(References)

- [1] Pang Y W, Cao J L, Wang J, et al. JCS-net: Joint classification and super-resolution network for and Security[J]. IEEE Transactions on Information Forensics and Security, 2019, 14(12): 3322-3331.
- [2] Liu H, Gu Y F, Wang T F, et al. Satellite video super-resolution based on adaptively spatiotemporal neighbors and nonlocal similarity regularization[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(12): 8372-8383.
- [3] Yue L W, Shen H F, Li J, et al. Image super-resolution: The techniques, applications, and future[J]. Signal Processing, 2016, 128: 389-408.
- [4] Fritsch F N, Carlson R E. Monotone piecewise cubic interpolation[J]. SIAM Journal on Numerical Analysis, 1980, 17(2): 238-246.
- [5] Chang H, Yeung D Y, Xiong Y M. Super-resolution through neighbor embedding[C]. Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Washington, 2004: 1-8.
- [6] Yang J C, Wright J, Huang T S, et al. Image super-resolution via sparse representation[J]. IEEE Transactions on Image Processing: A Publication of the IEEE Signal Processing Society, 2010, 19(11): 2861-2873.
- [7] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [8] Anwar S, Khan S, Barnes N. A deep journey into super-resolution[J]. ACM Computing Surveys, 2021, 53(3): 1-34.
- [9] Wang Z H, Chen J, Hoi S C H. Deep learning for image super-resolution: A survey[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 43(10): 3365-3387.
- [10] Song Z Y, Zhao X Q, Jiang H M. Gradual deep residual network for super-resolution[J]. Multimedia Tools and Applications, 2021, 80(7): 9765-9778.
- [11] Song Z Y, Zhao X Q, Hui Y Y, et al. Progressive back-projection network for COVID-CT super-resolution[J]. Computer Methods and Programs in Biomedicine, 2021, 208: 106193.
- [12] 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.
- [13] Dong C, Loy C C, Tang X O. Accelerating the super-resolution convolutional neural network[C]. European Conference on Computer Vision. Amsterdam, 2016: 391-407.
- [14] 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]. IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, 2016: 1874-1883.
- [15] 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, 2016: 1646-1654.
- [16] Kim J, Lee J K, Lee K M. Deeply-recursive convolutional network for image super-resolution[C]. IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, 2016: 1637-1645.
- [17] Lim B, Son S, Kim H, et al. Enhanced deep residual networks for single image super-resolution[C]. IEEE Conference on Computer Vision and Pattern Recognition Workshops. Honolulu, 2017: 1132-1140.
- [18] 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, 2017: 105-114.

- [19] 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, 2018: 1664-1673.
- [20] Zhang Y L, Li K P, Li K, et al. Image super-resolution using very deep residual channel attention networks[C]. European Conference on Computer Vision. Salt Lake City, 2018: 286-301.
- [21] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, 2018: 7132-7141.
- [22] Dai T, Cai J R, Zhang Y B, et al. Second-order attention network for single image super-resolution[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach, 2019: 11057-11066.
- [23] Zhang X D, Zeng H, Guo S, et al. Efficient long-range attention network for image super-resolution[J/OL]. 2022, arXiv: 2203.06697.
- [24] Esteva A, Chou K, Yeung S, et al. Deep learning-enabled medical computer vision[J]. Npj Digital Medicine, 2021, 4(1): 1-9.
- [25] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]. IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, 2016: 770-778.
- [26] Mikolov T, Karafiát M, Burget L, et al. Recurrent neural network based language model[C]. The 11th Annual Conference of the International Speech Communication Association. Makuhari, 2010: 26-30.
- [27] Creswell A, White T, Dumoulin V, et al. Generative adversarial networks: An overview[J]. IEEE Signal Processing Magazine, 2018, 35(1): 53-65.
- [28] Agustsson E, Timofte R. NTIRE 2017 challenge on single image super-resolution: Dataset and study[C]. IEEE Conference on Computer Vision and Pattern Recognition Workshops. Honolulu, 2017: 1122-1131.
- [29] 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. Surrey, 2012: 1-10.
- [30] Zeyde R, Elad M, Protter M. On single image scale-up using sparse-representations[C]. International Conference on Curves and Surfaces. Avignon, 2010: 711-730.
- [31] 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 of 8th IEEE International Conference on Computer of Vision. Vancouver, 2001: 416-423.
- [32] Huang J B, Singh A, Ahuja N. Single image super-resolution from transformed self-exemplars[C]. IEEE Conference on Computer Vision and Pattern Recognition. Boston, 2015: 5197-5206.
- [33] 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.
- [34] Kingma D P, Ba J. Adam: A method for stochastic optimization[J/OL]. 2014, arXiv: 1412.6980.
- [35] Lai W S, Huang J B, Ahuja N, et al. Deep Laplacian pyramid networks for fast and accurate super-resolution[C]. IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, 2017: 5835-5843.
- [36] Zhang K, Zuo W M, Zhang L. Learning a single convolutional super-resolution network for multiple degradations[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, 2018: 3262-3271.
- [37] Ahn N, Kang B, Sohn K A. Fast, accurate, and lightweight super-resolution with cascading residual network[C]. European Conference on Computer Vision. Munich, 2018: 252-268.
- [38] Zhu F Y, Zhao Q J. Efficient single image super-resolution via hybrid residual feature learning with compact back-projection network[C]. IEEE/CVF International Conference on Computer Vision Workshop (ICCVW). Seoul, 2019: 2453-2460.

作者简介

宋昭漾(1995—),男,博士生,从事图像超分辨率重建和图像复原等研究, E-mail: szy@lut.edu.cn;

赵小强(1969—),男,教授,博士生导师,从事故障诊断、图像处理、数据挖掘等研究, E-mail: xqzhao@lut.edu.cn;

惠永永(1992—),男,副教授,博士,从事故障诊断、图像处理等研究, E-mail: hyylut@126.com;

蒋红梅(1976—),女,副教授,博士,从事故障诊断、图像处理等研究, E-mail: jhm@lut.edu.cn.