

DOI:10.19651/j.cnki.emt.2210842

通道可分离残差网络的图像超分辨率重建^{*}

李 轩 刘小祎

(沈阳航空航天大学电子信息工程学院 沈阳 110136)

摘要: 针对现有图像超分辨率重建技术中存在的特征提取方式单一、中间层特征提取不充分等问题,提出了一种通道可分离残差网络。首先,利用多尺度卷积的思想设计出多分支卷积块,充分提取图像的低频信息;其次,利用通道压缩进行降维以精简特征信息,并引入坐标注意力机制对局部融合特征进行增强,通过长短跳跃连接,在加速收敛的同时使得主干网络专注于提取高频特征;最后通过上采样层重建出高分辨率图像。将本算法在 Set5、Set14、BSD100 和 Urban100 等 4 个超分辨率重建领域中公共数据集上进行对比分析,其中在 2 倍重建任务的 Set5 数据集上,与 DBPN 相比,参数量是它的 2/5,PSNR 和 SSIM 分别高出 0.09 dB 和 0.001 6。实验结果表明,该算法对图像特征充分提取,以较少的参数量实现了与其他大型模型性能相近甚至更好的重建效果。

关键词: 超分辨率重建;残差网络;通道压缩;特征融合;注意力机制

中图分类号: TP391 文献标识码: A 国家标准学科分类代码: 520.60

Image super-resolution reconstruction based on channel-separable residual network

Li Xuan Liu Xiaoyi

(College of Electronic and Information Engineering, Shenyang Aerospace University, Shenyang 110136, China)

Abstract: Aiming at the problems of single feature extraction method and insufficient feature extraction of middle layer in existing image super-resolution reconstruction techniques, a channel-separable residual network based on attention mechanism is proposed. Firstly, a diverse branch block is designed by using the idea of multi-scale convolution to fully extract the low-frequency information of the image. Secondly, channel compression is used to reduce dimension to simplify feature information, and coordinate attention mechanism is introduced to enhance local fusion features. The trunk network is focused on extracting high-frequency features while accelerating convergence through long and short jump connections. Finally, the high-resolution image is reconstructed by upsampling layer. The proposed algorithm is compared and analyzed on the public data sets of Set5, Set14, BSD100 and Urban100 in the super-resolution reconstruction field. On set5 dataset of $\times 2$ reconstruction task, compared with DBPN, parameters is 2/5 of DBPN, the PSNR and SSIM are improved by 0.09 dB and 0.001 6 respectively. Experimental results show that the proposed algorithm can fully extract image features and achieve similar or even better reconstruction results than other large-scale models with fewer parameters.

Keywords: super-resolution reconstruction; residual network; channel compression; feature fusion; attention mechanism

0 引言

近年来图像超分辨率技术在安防监控、卫星图像和生物医学成像等领域^[1]得到广泛应用。单幅图像超分辨率(single-image super-resolution, SISR^[2])是指由一幅低分辨率(low-resolution, LR)图像恢复出高分辨率(high-resolution, HR)图像。然而将 LR 图像空间映射到 HR 图

像时会产生多个解。为了解决这个问题,相关学者提出了大量的图像超分辨率(super-resolution, SR)算法。受益于强大的卷积神经网络(convolutional neural networks, CNN),诸多有效的算法在图像的超分辨率重建方向上应运而生。

Dong 等^[3]首次将 CNN 应用于超分图像,将其命名为 SRCNN。该方法通过学习 LR 和 HR 图像之间的非线性

收稿日期:2022-07-26

*基金项目:国家自然科学基金(61901284)、辽宁省重点研发计划项目(2020JH2/10100045)、辽宁省“兴辽英才计划”项目(XLYC1907022)资助

映射关系,获得了比传统方法更好的重建效果。受到此项工作的启发,Kim 等^[4-5]基于残差学习提出了 VDSR 和 DRCN 两种新的算法,通过引入梯度裁剪来缓解梯度爆炸问题。一味地增加深度容易导致训练不稳定,He 等^[6]提出了残差网络(ResNet),该模型在增加网络深度的同时使网络得到顺利收敛。随后 Lim 等^[7]借助去除 BN 层的残差块,构建了更宽的 EDSR 模型和更深的 MDSR 模型,同时也证明了网络深度对于图像的 SR 至关重要。Tai 等^[8-9]提出了深度递归残差网络(DRRN)和持久性记忆网络(MemNet)。前者主要利用递归学习使参数减少,后者通过叠加密集连接结构解决了 CNN 架构中的长期依赖性问题。Li 等^[10]提出了多尺度残差块(MSRB)的概念,通过跳跃连接共享不同尺度的特征来解决尺度单一的问题。为了充分融合高低频特征,Tian 等^[11]提出了非对称卷积网络(ACNet),在增强特征提取能力的同时并没有带来额外的计算量。

尽管现有的基于 CNN 的方法有了很大的改进,但仍然存在一定的局限性。大部分网络在浅层特征提取时只采用 3×3 卷积,不能充分利用全局像素点的信息。一些基于 CNN 的超分方法在处理高低频信息时缺少一定的灵活性,LR 图像的通道特征被以同样的方式处理,这导致大量不必要的低频特征被计算,同时阻碍了深度网络的表征能力。

随着网络深度的增加,在多次的传递过程中会丢失部分图像特征,而目前大多数模型只是用残差学习来降低训练难度^[12],并没有充分利用中间层的特征去重建高频细节。针对上述问题,本文提出了一种基于通道可分离残差网络的算法,主要包含以下几点贡献:

1) 在浅层特征提取阶段,针对特征提取方式单一的问题,提出多分支卷积块,用该模块代替 3×3 卷积,并证明了其对 SR 的有效性。

2) 针对冗余参数问题,本文设计了一个多分支特征细化块。通过采用通道缩减策略在有效提取特征的同时对特征进行蒸馏,去除冗余参数。结合坐标注意力模块对从不同分支提取的特征信息进行加权,有助于最大限度地恢复纹理细节,并通过消融实验证明该模块可有效提高模型的能力。

3) 针对深度网络难以收敛的问题,选择将残差组作为该网络的基本模块。在每个残差组中,堆叠带有短跳连接的局部特征融合块以充分利用了中间层的特征,从而使整个网络能迅速地学习到更多可用的信息。

1 通道可分离残差网络

为了使模型的性能有进一步的提升,如图 1 所示,本文提出一种通道可分离残差网络。它由浅层特征提取、深层特征提取和特征的融合与重建 3 个模块构成。

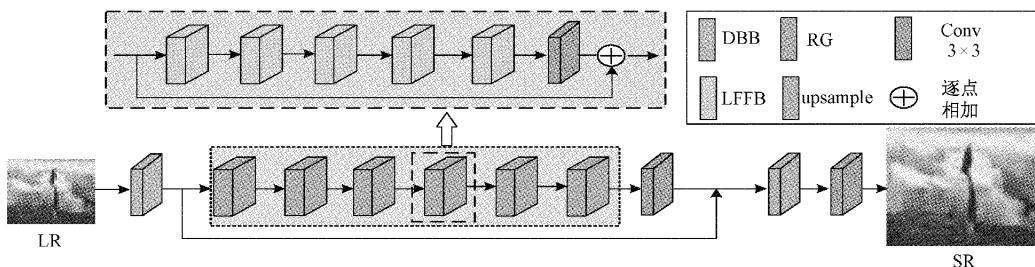


图 1 通道可分离残差网络结构

本节将具体介绍浅层特征提取的多分支卷积块(diverse branch block, DBB),深层特征提取中的多分支特征细化块(multibranch feature refinement block, MFRB)、局部特征融合块(local feature fusion block, LFFB)、残差组(residual group, RG)、坐标注意力(coordinate attention, CA)及损失函数。

1.1 多分支卷积块(DBB)

如图 2 所示,本文提出了一个通用的多分支卷积块来提高性能,它通过结合多尺度卷积、平均池化和最大池化来丰富特征空间,从而提高单个卷积的表征能力。

DBB 模块采用了多分支拓扑结构,利用多尺度卷积的思想将 LR 图像分别通过 3 个分支进行特征提取,并将各个分支做加法运算,这种包含不同感受野的结构可以获得更多丰富的特征空间。

设输入图像为 LR, 浅层特征提取阶段可以描述为:

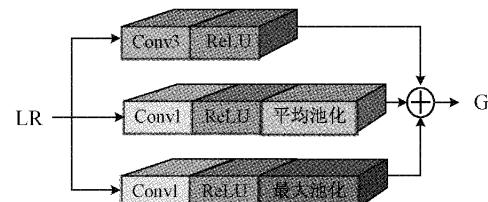


图 2 多分支卷积块

$$G = f_{3 \times 3}(LR) + GAP(f_{1 \times 1}(LR)) + GMP(f_{1 \times 1}(LR)) \quad (1)$$

其中, $f_{1 \times 1}$ 是 1×1 卷积, $f_{3 \times 3}$ 是 3×3 卷积,GAP 表示全局平均池化,GMP 表示全局最大池化, G 表示提取的特征。

1.2 多分支特征细化块(MFRB)

如图 3 所示,非对称块(asymmetric block, AB)由卷

积核为 $3 \times 1, 3 \times 3, 1 \times 1$ 的 3 个平行层组成, 相加后可以对 CNN 的骨架进行增强, 提高准确率。

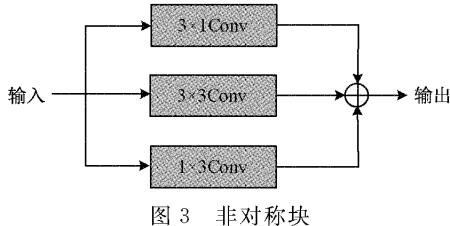


图 3 非对称块

如图 4 所示, 本文利用特征蒸馏的思想提出多分支特征细化块。其核心思想是首先通过 AB 块进行特征提取; 其次, 对所有的通道特征分别进行两支路处理, 一条支路通过 1×1 的卷积将通道压缩得到蒸馏特征, 另一支路通过 AB 模块恢复为原本的通道数继续进行特征提取; 最后通过级联操作得到每个阶段的蒸馏特征。之后, 结合坐标注意力模块(如 1.5 节)将位置信息嵌入到通道以获得更大的区域信息, 并对像素进行重新加权。该结构使得模型的冗余参数大大减少。

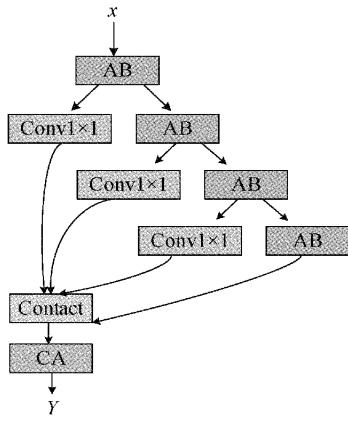


图 4 多分支特征细化块

假设输入为 x , 该过程可描述为:

$$x_1 = F_1^{AB}(x) \quad (2)$$

$$x_{i-1}, x_{i-2} = f_i^{1 \times 1}(x_i) \quad (3)$$

$$x_i = F_i^{AB}(x_{i-1}) \quad (4)$$

$$x_4 = F_4^{AB}(x_3) \quad (5)$$

$$Y = CA(H_{\text{concat}}(x_{i-2}, \dots, x_4)) \quad (i=1,2,3) \quad (6)$$

其中, F_i^{AB} 表示通过 AB 模块进行特征提取, $F_i^{AB}(i=2,3)$ 表示通过 AB 模块将输出通道恢复为 64, $F_i^{AB}(i=4)$ 表示通过 AB 模块将最后一个输出通道缩减为 16。 x_i 表示每经过一次 AB 模块所提取出来的特征。 $x_{i-1}, x_{i-2}(i=1,2,3)$ 分别表示第 i 次保留下来的特征和需要进一步处理的特征, $f_i^{1 \times 1}(i=1,2,3)$ 表示 1×1 卷积, H_{concat} 是沿通道维度上的连接操作, CA 为坐标注意力机制, Y 为通过注意力机制加权后的输出特征。

1.3 局部特征融合块(LFFB)

局部特征融合块是残差组(如 1.4 节)的核心组件。如

图 5 所示, 该模块通过 concat 操作将中间层特征沿通道维度进行特征融合, 再通过 1×1 卷积层进行降维, 使网络可以学习到更多有用的特征, 最后引入局部残差学习, 进一步促进了信息的传递。

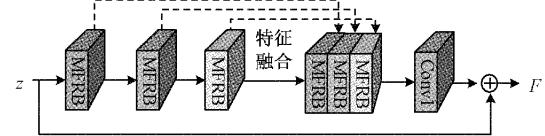


图 5 局部特征融合块

假设输入为 z , LFFB 的操作定义为:

$$f_1 = f_{MFRB}^1(z) \quad (7)$$

$$f_2 = f_{MFRB}^2(f_1) \quad (8)$$

$$f_3 = f_{MFRB}^3(f_2) \quad (9)$$

$$F = z + f_{1 \times 1}(H_{\text{concat}}(f_1, f_2, f_3)) \quad (10)$$

其中, f_i 为 LFFB 中第 i ($i=1,2,3$) 个 MFRB 的输出, f_i^{MFRB} 为第 i 个 MFRB 模块, $f_{1 \times 1}$ 是 1×1 卷积, H_{concat} 指沿通道方向的拼接, z 和 F 分别代表 LFFB 的输入和输出。

1.4 残差组(RG)

为了建立更深的网络模型并获得良好的性能, 受 RCAN^[13] 的启发, 本文把 RG 作为深度网络模型的基本模块(如图 1), 利用长短跳连接实现残差学习。每个 RG 中堆叠了 5 个包含短跳连接(short skip connection, SSC)的局部特征融合块, 这种结构能训练较深的卷积神经网络, 并得到高性能的 SR 图像。第 n 个 RG 可以表示为:

$$F_n = H_n(F_{n-1}) = H_n(H_{n-1}(\dots H_1(F_0) \dots)) \quad (11)$$

其中, H_n 表示第 n 个 RG 函数, F_{n-1} 和 F_n 分别是第 n 个 RG 函数的输入、输出, F_0 表示从 LR 中提取到的浅层特征。研究发现仅堆叠多个 RG 并不能获得理想的性能(如 2.3 节), 所以将长跳连接(long skip connection, LSC)应用在 RG 中。

$$F_{DF} = H + W_{LSC} H_N = H + W_{LSC} H_n(H_{n-1}(\dots H_1(F_0) \dots)) \quad (12)$$

其中, H 表示浅层特征的输出, W_{LSC} 为 RG 尾部的权重, F_{DF} 表示 RG 的输出。

1.5 坐标注意力(CA)

注意力机制应用于深度神经网络可以带来性能的提升。常用的通道注意力机制 SENet^[14] 只考虑内部通道信息并未关注位置信息。混合注意力结合了通道域、空间域等注意力形式形成更综合的注意力方法。Woo 等^[15] 提出的 CBMA 是在通道上进行全局池化以得到位置信息, 但这种方式只能获得局部信息, 无法获取长距离依赖信息。

本文在多分支特征细化块中结合 Hou 等^[16] 提出的坐标注意力(coordinate attention, CA), 如图 6 所示, 它对水平和垂直方向进行全局池化, 在通道上保留这两个方向的长距离依赖关系, 然后将二者拼接并进行卷积, 使两个方

向上的信息可以交互。在非线性激活函数之后,通过卷积在水平和垂直方向上同时对它进行关注,最后进入

Sigmoid 函数,得到的这两个注意力图可定位目标对象的位置。其中,卷积层的卷积核和步长分别设置为 1。

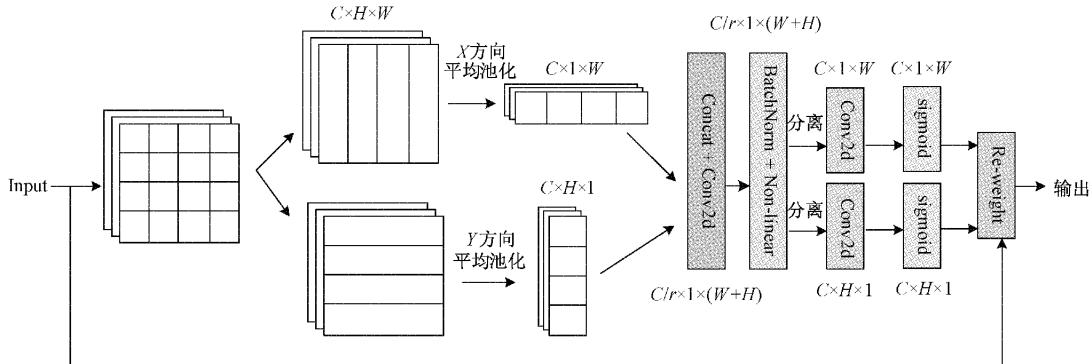


图 6 坐标注意力

1.6 损失函数

在训练过程中,选用 L1 损失函数进行优化。给定训练数据集,可以得到:

$$\hat{\theta} = \operatorname{argmin}_{\theta} \frac{1}{M} \| F_{\theta}(I_{LR}^i) - I_{HR}^i \|_1 \quad (13)$$

其中, M 为图像数, θ 表示模型的参数集, $F_{\theta}(\cdot)$ 表示通道可分离残差网络, I_{LR}^i 表示低分辨率图像, I_{HR}^i 表示高分辨率图像。

2 实验分析

2.1 数据集和评价指标

本文选择 DIV2K 数据集作为训练数据集,数据预处理阶段会把训练集转换成 480×480 尺寸的重叠子图像块。通过利用 MATLAB 中的双三次插值函数对测试集的每幅图像进行 $\times 2 \times 3 \times 4$ 的退化处理,并依次裁剪成 240×240 、 160×160 、 120×120 得到相应的 LR 子图像块。此外,扩展了有限的训练集,通过将训练数据集中的图像随机旋转 90° 、 180° 和 270° 以及水平翻转来避免过拟合测试时采用标准数据集 Set5、Set14、BSD100 和 Urban100 进行测试,将 PSNR 和 SSIM 作为判断图像质量的两种指标,所有的测试数据都是在 YCbCr 的 Y 通道上计算。

2.2 训练配置和参数细节

本文使用的深度学习框架是 pytorch, 操作系统为 Ubuntu,

模型由 NVIDIA Tesla V100(32 G)显卡训练完成。训练时,随机选择 32 个分辨率为 64×64 的低分辨率图像块作为输入,模型用 Adam 进行优化,超参数设置为 $\beta_1 = 0.9$, $\beta_2 = 0.999$, $\epsilon = 1 \times 10^{-8}$, Batch size 设置为 32, 初始学习率为 5×10^{-4} , 训练阶段共迭代 40 万次, 每 20 万次迭代将学习率进行减半处理。

2.3 模型分析

为了验证本文所提出的多分支卷积块和引用的坐标注意力机制的有效性, 使用 3×3 卷积来代替 DBB, 分别用 SENet 和 CBAM 替换 CA。SENet 和 CBAM 是前面提到的两种常用的注意力机制。如表 1 所示, 在浅层特征提取时用 DBB 模块来替换 3×3 卷积, PSNR 和 SSIM 在 $\times 2$ 的数据集上均有提升, 其中, PSNR 平均增加 0.12 dB, SSIM 平均增加 0.0026, 这表明 DBB 模块能充分提取低频信息; 通过将“Conv3 \times 3”和“Conv3 \times 3 + SE”对比发现, 注意力机制使模型的性能得到提升; 将“Conv3 \times 3 + SE”、“Conv3 \times 3 + CBAM”、“Conv3 \times 3 + CA”对比可知, 本文选择的 CA 相较于 SE、CBAM 性能得到进一步的提升, PSNR 平均增加了 0.02~0.04 dB, SSIM 平均增加 0.0008~0.001。实验结果表明, 本文提出的“DBB+CA”的组合方式, 使该网络模型达到更好的效果。

为了验证网络模型中长短跳跃连接的有效性, 将主干网络中的 LSC 和 RG 中的 SSC 分别移除进行实验。如表 2

表 1 基本模块的验证

算法	重建因子	Set5	Set14	BSD100	Urban100
		PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM
Conv3 \times 3		37.98/0.9592	33.58/0.9166	32.17/0.8993	32.10/0.9271
Conv3 \times 3 + SE		38.09/0.9601	33.65/0.9172	32.19/0.8996	32.15/0.9275
Conv3 \times 3 + CBAM	$\times 2$	38.11/0.9603	33.81/0.9185	32.24/0.9011	32.22/0.9290
Conv3 \times 3 + CA		38.13/0.9611	33.98/0.9196	32.33/0.9025	32.37/0.9213
DBB		38.10/0.9618	33.99/0.9215	32.51/0.9036	32.45/0.9327
DBB+CA		38.18/0.9616	33.94/0.9199	32.36/0.9018	32.99/0.9364

表 2 验证长短跳跃连接和坐标注意力

LSC	×	√	×	√	×	√	×	√
SSC	×	×	√	√	×	×	√	√
CA	×	×	×	×	√	√	√	√
PSNR(dB)	37.32	37.65	37.79	37.85	37.49	37.83	37.84	37.89

所示,当同时删除 LSC 和 SSC 时,无论是否去除坐标注意力模块,在 2 倍重建任务的 Set5 数据集上,PSNR 的值都相对较低。在第 1 列中,PSNR 的值是 37.32 dB,当加入 LSC 和 SSC 时,PSNR 是 37.85 dB。当加入 CA 后,使用 LSC 和 SSC 可以使模型性能从 37.49 dB 提高到 37.89 dB。这表明同时使用 LSC 和 SSC 能获得更好的效果,也证明了

本文提出网络模型的有效性。

2.4 方法对比

为了验证本文模型,将其与 9 种先进的算法进行比较,包括 SRCNN、VDSR、DRRN、ACNet、EDSR^[17]、DBPN^[18]、RDN^[19]、RCAN、RFANet^[20]。如表 3 所示,不同算法在标准数据集上分别进行 $\times 2$ 、 $\times 3$ 、 $\times 4$ 放大后的

表 3 4 个基准数据集上的平均 PSNR/SSIM

算法	重建因子	参数量	Set5	Set14	BSD100	Urban100
			PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM
Bicubic	—	—	33.66/0.929 9	30.24/0.868 8	29.56/0.843 1	26.88/0.840 3
SRCNN	8 K	36.66/0.954 2	32.45/0.906 7	31.36/0.887 9	29.50/0.894 6	
VDSR	666 K	37.53/0.959 0	33.05/0.913 0	31.90/0.896 0	30.77/0.914 0	
DRRN	298 K	37.74/0.959 1	33.23/0.913 6	32.05/0.897 3	31.23/0.918 8	
ACNet	1.5 M	37.72/0.958 8	33.41/0.916 0	32.06/0.897 8	31.79/0.924 5	
EDSR	$\times 2$	40 M	38.11/0.960 2	33.92/0.919 5	33.32/0.901 3	32.93/0.935 1
DBPN	10 M	38.09/0.960 0	33.85/0.919 0	32.27/0.900 0	32.55/0.932 4	
RDN	22.6 M	38.24/0.961 4	34.01/0.921 2	32.34/0.901 7	32.89/0.935 3	
RCAN	15.4 M	38.27/0.961 4	34.12/0.921 6	32.41/0.902 7	33.34/0.938 4	
RFANet	10.7 M	38.26/0.961 5	34.16/0.922 0	32.41/0.902 6	33.33/0.938 9	
本文算法	4.6 M	38.18/0.961 6	33.94/0.919 9	32.36/0.901 8	32.99/0.936 4	
Bicubic	—	30.39/0.868 2	27.55/0.774 2	27.21/0.738 5	24.46/0.734 9	
SRCNN	8 K	32.75/0.909 0	29.30/0.821 5	28.41/0.786 3	26.24/0.798 9	
VDSR	666 K	33.67/0.921 0	29.78/0.832 0	28.83/0.799 0	27.14/0.829 0	
DRRN	298 K	34.03/0.924 4	29.96/0.834 9	28.95/0.800 4	27.53/0.837 8	
ACNet	1.8 M	34.14/0.924 7	30.19/0.839 8	28.98/0.802 3	27.97/0.848 2	
EDSR	$\times 3$	43.6 M	34.65/0.928 0	30.52/0.846 2	29.25/0.809 3	28.80/0.865 3
RDN		22.6 M	34.71/0.929 6	30.57/0.846 8	29.26/0.809 3	28.80/0.865 3
RCAN		15.6 M	34.74/0.929 9	30.65/0.848 2	29.32/0.811 1	29.09/0.870 2
RFANet	10.9 M	34.79/0.930 0	30.67/0.848 7	29.34/0.811 5	29.15/0.872 0	
本文算法	4.6 M	34.67/0.929 6	30.61/0.847 4	29.27/0.810 4	28.94/0.866 8	
Bicubic	—	28.42/0.810 4	26.00/0.702 7	25.96/0.667 5	23.14/0.657 7	
SRCNN	8 K	30.48/0.862 8	27.50/0.751 3	26.90/0.710 1	24.52/0.722 1	
VDSR	666 K	31.35/0.883 0	28.02/0.768 0	27.29/0.725 1	25.18/0.752 4	
DRRN	298 K	31.68/0.888 8	28.21/0.772 0	27.38/0.728 4	25.44/0.763 8	
ACNet	1.8 M	31.83/0.890 3	28.46/0.778 8	27.48/0.732 6	25.93/0.779 8	
EDSR	$\times 4$	43.1 M	32.46/0.896 8	28.80/0.787 6	27.71/0.742 0	26.64/0.803 3
DBPN		10 M	32.47/0.898 0	28.82/0.786 0	27.72/0.740 0	26.38/0.794 6
RDN		22.6 M	32.47/0.899 0	28.81/0.787 1	27.72/0.741 9	26.61/0.802 8
RCAN		15.6 M	32.63/0.900 2	28.87/0.788 9	27.77/0.743 6	26.82/0.808 7
RFANet	10.9 M	32.66/0.900 4	28.88/0.789 4	27.79/0.744 2	26.92/0.811 2	
本文算法	4.6 M	32.53/0.900 0	28.83/0.788 0	27.75/0.743 5	26.75/0.805 4	

PSNR/SSIM。其中,EDSR 模型的参数量达到四千万以上,DBPN 的参数量也达到一千万以上,本文所提模型的参数量仅有四百万,是 EDSR 参数量的 1/10,是 DBPN 参数量的 2/5。以 Set5 数据集为例,EDSR 和 DBPN 的 PSNR 值分别是 38.11 和 38.09 dB,SSIM 分别是 0.9602 和 0.9600。而本文模型的 PSNR 值是 38.18 dB,分别高出 0.07 和 0.09 dB,SSIM 值为 0.9616,高出 EDSR 和 DBPN。模型 RDN、RCAN、RFANet 的 PSNR 值均略高于本文模型,其中指标最高的 RCAN 仅高出 0.09 dB,但本文模型的参数量是其的 1/3,本文模型的 SSIM 值均高于其他模型。RFANet 在参数量和指标上兼顾较好的模型,而本文所提模型的 PSNR 值略低 0.08 dB,参数量不到 RFANet 的 1/2。综合来看,本文所提模型在参数量和性能上达到了更好的平衡。

在定量分析之余,实验通过在 DIV2K 数据集上随机选取几张图片,将其 4 倍上采样的测试结果与其他方法进行对比。如图 7 所示,HR、Bicubic、SRCNN、VDSR、ACNet、EDSR、IMDN^[21]和本文方法对局部区域放大后的可视化结果,进一步说明了通道可分离残差网络的有效性。早期的模型如 Bicubic 和 SRCNN 存在严重的模糊和

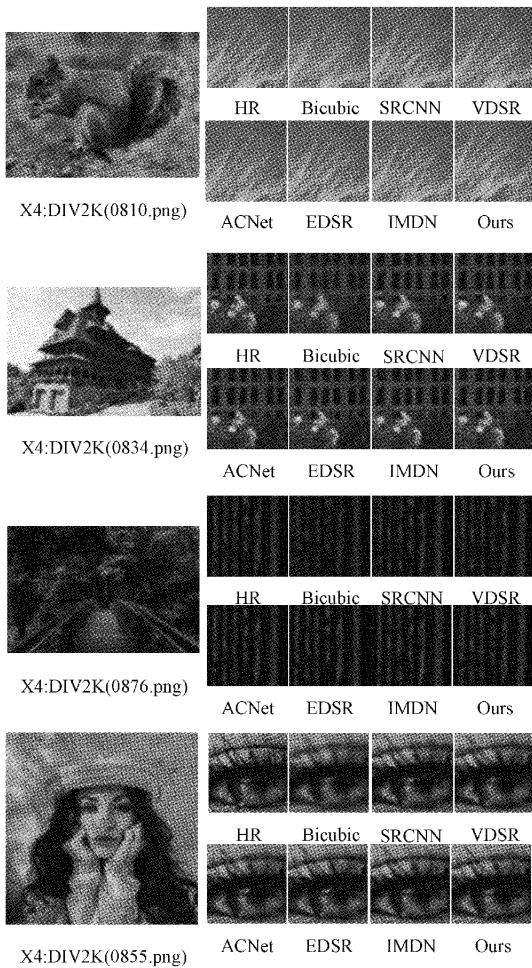


图 7 4 倍上采样效果对比

伪影,甚至是图像信息的丢失。最近的方法如 VDSR、EDSR、ACNet、IMDN 虽能恢复出主要的轮廓,但无法恢复出更多精细的纹理细节。从视觉效果来看,本文的模型能够得到更清晰的结果,重建出更多的细节。

3 结 论

本文提出了一种通道可分离残差网络的超分辨率重建算法。针对特征提取方式单一的问题,结合多尺度卷积的思想提出多分支卷积块,与大多数模型使用的传统卷积相比,不仅扩大感受野,还能充分提取特征信息。同时,利用通道压缩思想提出多分支特征细化块,并将坐标注意力机制集成到该模块中,在减少冗余参数时进一步提高了模型的辨析能力。此外,利用长短跳跃连接和残差策略的思想,使该结构不但促进了特征的重用,而且高低频信息被区别对待,从而使主干网络聚焦于高频特征。实验结果表明,本文所提模型在在参数量和性能指标上达到一种更好的平衡。从主观视觉来看,所提算法重建出的图像更加真实、纹理清晰、细节更加丰富。接下来将进一步从参数量和计算量的角度优化网络模型。

参考文献

- [1] 李浩然,刘琨,常世龙,等.基于残差混合域注意力网络的 PET 超分辨率重建方法[J].电子测量技术,2021,44(14):103-110.
- [2] 刘正男,王凤随,付林军.改进的联合型图像超分辨率重建算法[J].电子测量与仪器学报,2020,34(1):111-120.
- [3] DONG C, CHEN C L, HE K, et al. Learning a deep convolutional network for image super-resolution[C]. European Conference on Computer Vision (ECCV), Zurich, Switzerland, September 6-12, 2014:184-199.
- [4] KIM J, LEE J K, LEE K M, et al. Accurate image super-resolution using very deep convolutional networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 1646-1654.
- [5] KIM J, LEE J K, LEE K M, et al. Deeply-recursive convolutional network for image super-resolution[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition(CVPR), Las Vegas, Nevada, June 27-30, 2016: 1637-1645.
- [6] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2016: 770-778.
- [7] LIM B, SON S, KIM H, et al. Enhanced deep residual networks for single image super-resolution [C]. Proceedings of the IEEE Conference on Computer

- Vision and Pattern Recognition Workshops, 2017: 136-144.
- [8] TAI Y, YANG J, LIU X, et al. Image super-resolution via deep recursive residual network [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 3147-3155.
- [9] TAI Y, YANG J, LIU X, et al. Memnet: A persistent memory network for image restoration [C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 4539-4547.
- [10] LI J, FANG F, MEI K, et al. Multi-scale residual network for image super-resolution [C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018: 517-532.
- [11] TIAN C, XU Y, ZUO W, et al. Asymmetric CNN for image super resolution [J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2021, 52(6): 3718-3730.
- [12] 韩冉,曾广森,王荣杰.基于残差块网络的图像去雨算法[J].仪器仪表学报,2021,41(8):175-182.
- [13] ZHANG Y, LI K, LI K, et al. Image super-resolution using very deep residual channel attention networks [C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018: 286-301.
- [14] HU J, SHEN L, SUN G, et al. Squeeze-and-excitation networks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 7132-7141.
- [15] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module [C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018: 3-19.
- [16] HOU Q, ZHOU D, FENG J, et al. Coordinate attention for efficient mobile network design [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2021: 13713-13722.
- [17] LIJIM B, SON S, KIM H, et al. Enhanced deep residual networks for single image super-resolution [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2017: 136-144.
- [18] HARIS M, SHAKHNAROVICH G, UKITA N, et al. Deep back-projection networks for super-resolution [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 1664-1673.
- [19] ZHANG Y, TIAN Y, KONG Y, et al. Residual dense network for image super-resolution [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 2472-2481.
- [20] LIU J, ZHANG W, TANG Y, et al. Residual feature aggregation network for image super-resolution [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 2359-2368.
- [21] HUI Z, GAO X, YANG Y, et al. Lightweight image super-resolution with information multi-distillation network [C]. Proceedings of the 27th ACM International Conference on Multimedia, 2019: 2024-2032.

作者简介

李轩,副教授,主要研究方向图像处理与传输技术。

E-mail:1041291632@qq.com

刘小祎(通信作者),硕士研究生,主要研究方向为图像获取与图像处理。

E-mail:1074609685@qq.com