

基于部分特征卷积聚合的图像超分辨率重建方法

储 曦,王凤随

1. 安徽工程大学 电气工程学院, 安徽 芜湖 241000

2. 高端装备先进感知与智能控制教育部重点实验室, 安徽 芜湖 241000

摘 要:目的 随着深度学习的发展,单幅图像超分辨率重建网络的性能有显著的提升,但是这些网络往往伴随着高计算复杂度和内存消耗,这不利于其部署在边缘设备或者实时应用场景中。为了解决此问题,设计一种基于部分特征卷积聚合的图像超分辨率重建网络。方法 首先使用卷积提取低分辨率图像特征,然后利用部分特征卷积聚合块处理提取到的特征,最后利用上采样块重建高分辨率图像。部分特征卷积聚合块由部分特征卷积模块和特征聚合模块组成,前者进一步降低了网络的参数量与计算复杂度,后者充分混合卷积特征与未卷积特征以提高网络性能。结果 实验结果表明:与 ECBSR、RepSR 等先进轻量化网络相比,基于部分特征卷积聚合的图像超分辨率重建网络在 4 个标准测试数据集上的峰值信噪比与结构相似性指标均有提升。结论 提出的方法在参数量、计算复杂度与性能之间实现了更好的平衡,适合在手机、VR、AR 等资源有限的边缘设备上实现超分辨率重建任务。

关键词:图像超分辨率重建;部分特征卷积;特征聚合;轻量化

中图分类号:TP391.4 **文献标识码:**A **doi:**10.16055/j.issn.1672-058X.2026.0004.001

Image Super-Resolution Reconstruction Based on Partial Feature Convolutional Aggregation

CHU Xi, WANG Fengsui

1. School of Electrical Engineering, Anhui Polytechnic University, Wuhu 241000, Anhui, China

2. Key Laboratory of Advanced Perception and Intelligent Control of High-end Equipment, Ministry of Education, Wuhu 241000, Anhui, China

Abstract: **Objective** With the development of deep learning, the performance of single-image super-resolution reconstruction networks has been significantly improved. However, these networks are often accompanied by high computational complexity and memory consumption, which hinders their deployment on edge devices or in real-time application scenarios. To address this issue, an image super-resolution reconstruction network based on partial feature convolutional aggregation is designed. **Methods** First, a convolution was used to extract features from low-resolution images. Then, the extracted features were processed by partial feature convolutional aggregation blocks. Finally, an upsampling block was used to reconstruct the high-resolution image. The partial feature convolutional aggregation block consists of two modules: the partial feature convolution module, which further reduces the number of parameters and the computational complexity of the network, and the feature aggregation module, which fully mixes convolved features with

收稿日期:2025-04-12 **修回日期:**2025-08-25 **文章编号:**1672-058X(2026)04-0001-09

基金项目:安徽省自然科学基金项目资助(2108085MF197);安徽高校省级自然科学基金研究重点项目资助(KJ2019A0162);安徽工程大学国家自然科学基金预研项目资助(XJKY2022040)。

作者简介:储曦(1999—),男,安徽安庆人,硕士研究生,从事数字图像处理研究。

通信作者:王凤随(1981—),男,安徽宿州人,博士,教授,硕士生导师,从事图像与视频信息处理和计算机视觉等研究。Email: fswang@ahpu.edu.cn.

引用格式:储曦,王凤随. 基于部分特征卷积聚合的图像超分辨率重建方法[J]. 重庆工商大学学报(自然科学版), 2026, 43(4): 1-9.

Chu Xi, Wang Fengsui. Image super-resolution reconstruction based on partial feature convolutional aggregation[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2026, 43(4): 1-9.

unconvolved features to improve network performance. **Results** Experimental results showed that, compared with advanced lightweight networks such as ECBSR and RepSR, the proposed network achieved improvements in both peak signal-to-noise ratio (PSNR) and structural similarity index measure (SSIM) on four standard benchmark datasets.

Conclusion The proposed method achieves a better balance between the number of parameters, computational complexity, and performance. It is suitable for super-resolution reconstruction tasks on resource-constrained edge devices such as mobile phones, VR, and AR.

Keywords: image super-resolution reconstruction; partial feature convolution; feature aggregation; lightweight

单幅图像超分辨 (Single Image Super-Resolution, SISR) 重建算法是计算机视觉中的一个基础任务,其主要目的是将一幅低分辨率 (Low-Resolution, LR) 图像恢复成高分辨率 (High-Resolution, HR) 图像。其广泛应用于现实任务中,如医学图像超分辨重建^[1]、遥感图像超分辨重建^[2]等。随着卷积神经网络 (Convolutional Neural Network, CNN) 的发展,单幅图像超分辨率重建网络的性能有明显提升,但这些网络往往采用更复杂的结构,如金字塔渐进式上采样^[3]、特征蒸馏等^[4],或者添加注意力机制,如通道注意力^[5]、像素注意力等^[6]。这些改进虽然明显提升了网络的性能,但是加剧了网络的计算复杂度,同时占用了更大的内存消耗。

Dong 等^[7] 首先提出 SRCNN (Super-Resolution Convolutional Neural Network), 利用深度学习网络实现超分辨重建,相较于传统的插值算法,超分辨重建性能有显著地提升;Shi 等^[8] 提出 FSRCNN (Fast Super Resolution Convolutional Neural Networks), 直接使用 LR 图像作为输入,提取图像特征最后重建 HR 图像,显著降低了网络的计算量。随后的很多网络都使用 LR 图像直接提取特征最后重建 HR 图像。SRCNN 和 FSRCNN 虽然对图像超分辨重建网络有一定的研究,但网络设计较浅,无法充分挖掘特征中的有效信息以重建 HR 图像。Dong 等^[9] 提出 ESPCN (Efficient Sub-Pixel Convolutional Network), 使用一种新的上采样方式,即亚像素混洗上采样,进一步提升了网络性能;该方式被现有的大部分网络使用重建 HR 图像,但在处理深度特征时仅使用卷积层提取特征,较为单一,不利于最后的 HR 图像重建。Hui 等^[4] 提出 IMDN (Information Multi-distillation Network), 该网络首先增加了网络深度,并使用特征分离与聚合实现特征蒸馏以细化特征,同时采用方差均值混合通道注意力聚合特征,进一步增强了网络性能;但是,加入的特征蒸馏与注意力机制加剧了网络的计算成本,不利于在边缘设备上部署。Zhang 等^[10] 提出 ECBSR (Edge-Oriented Convolution Block Super-Resolution), 通过调节网络的深度与通道数,

训练不同大小的网络以应对不同的超分辨率重建场合,并且采用简约的网络结构进一步缩减网络复杂度与内存消耗;但是,在训练时采用 Sobel 算子与 Laplacian 算子,加剧了网络的训练耗时,同时导致网络性能有一定程度的下降。Wang 等^[11] 提出 RepSR (Re-Parameterization Super-Resolution), 通过分析 VGG (Visual Geometry Group) 网络同时设计结构重参化技术,使得网络运行速度得到提升;但是,所采用的 VGG 网络并不能很好地处理深度特征,且不能很好地平衡模型性能与复杂度之间的关系。上述网络通过加深网络层数、引入注意力机制等,增强了轻量化超分辨率重建网络的性能。其中,ESPCN 和 RepSR 网络通过简约的网络架构构建了不同参数量、计算复杂度的网络,加速实现了超分辨率重建网络的部署,但是没有充分实现模型性能与复杂度之间的平衡。所以如何设计一种更加简约、轻量,性能更强的超分辨率重建网络依旧是一个难题。

针对这些问题,本文提出基于部分特征卷积聚合的图像超分辨率重建网络。该网络使用部分卷积模块代替普通卷积处理深度提取特征,以降低网络的参数量与计算复杂度。部分卷积模块相较于普通卷积有着更高的计算效率,并且使网络注意力集中在部分特征上以更充分地学习特征。该网络使用特征混合模块以提高网络的深度,并且从像素与通道的角度分别混洗,以获得更优质的特征。使用部分卷积模块与特征混合模块能够充分地提高网络学习特征的能力,最后整合部分卷积模块与特征聚合模块构建网络,实现模型性能与模型复杂度之间的平衡。

1 超分辨率重建网络

1.1 部分特征卷积聚合网络

当前,大多数超分辨率重建网络使用普通卷积构建的残差块(卷积-激活函数-卷积)处理深度特征,这使得网络的参数量与计算复杂度较高。为降低网络的参数量与计算复杂度,需要重新设计一种模块处理深度特征。因此,提出利用部分特征卷积混合块 PACB

(Partial Feature Convolutional Aggregation Block)处理深度特征。所提出的模块能显著降低网络的参数量与计算复杂度,同时能提高特征的利用效率,以实现网络性能的提升。基于部分特征卷积聚合的图像超分辨率重建网络(Partial Feature Convolutional Aggregation Network, PCAN)结构如图1所示。




图1 PCAN 结构

Fig. 1 Architecture of PCAN

首先使用卷积提取图像特征,如下所示:

$$\mathbf{F}_L = H_{C3}(\mathbf{I}_{LR}) \quad (1)$$

式(1)中, $H_{C3}(\cdot)$ 是一个卷积核大小为3的卷积层,输入和输出分别为 $\mathbf{F}_L, \mathbf{I}_{LR}$ 。

随后通过 N 个部分特征卷积混合块(Partial Feature Convolutional Aggregation Block, PACB)深度处理特征,该过程如下:

$$\mathbf{F}_D^i = H_{PCAB}^i(\mathbf{F}_D^{i-1}), i=1, 2, \dots, N \quad (2)$$

式(2)中, $H_{PCAB}(\cdot)$ 代表第 i 个 PCAB, $\mathbf{F}_D$ 为深度特征,特别地, $\mathbf{F}_D^0 = \mathbf{F}_L$ 。

最后通过一个长残差链接聚合 $\mathbf{F}_L$ 与 $\mathbf{F}_D$ 卷积与上采样重建 HR 图像,其过程如下:

$$\mathbf{I}_{SR} = H_{up}(H_{C3}(\mathbf{F}_L + \mathbf{F}_D)) \quad (3)$$

式(3)中, $\mathbf{I}_{SR}$ 为超分辨率重建之后的图像, $H_{up}(\cdot)$ 采用亚像素混洗上采样。

1.2 部分特征卷积与特征混合块

残差块结构有着一个短程的残差链接,这虽然能够稳定地训练网络,但是短程残差链接会使特征无法得到充分学习。提出的部分特征卷积聚合块不采用短程残差链接进行残差操作,而是利用一个远程残差链接代替短程残差链接,这使得特征在部分特征卷积聚合块中得到充分利用后再进行残差操作。部分特征卷积聚合块主要由部分特征卷积模块与特征聚合模块组成,其结构如图2所示。使用部分特征卷积模块代替普通卷积,以降低网络的参数量与计算复杂度,而且部分卷积模块会集中处理图像超分辨重建过程中所需要的信息,如边缘信息、图像纹理信息等;随后利用特征混合模块充分地混合卷积特征与未卷积特征,使得特征得到充分地利用。




图2 部分特征卷积与特征混合块结构

Fig. 2 Architecture of partial feature convolution and feature blending block

首先介绍部分特征卷积模块。从通道的角度分离得到两组特征,一组特征需要卷积,另一组不需要卷积,其过程如下:

$$\mathbf{F}_C, \mathbf{F}_I = \text{split}(\mathbf{F}) \quad (4)$$

式(4)中, $\mathbf{F} \in \mathbf{R}^{H \times W \times C}$ 为输入特征; split 代表特征分离操作; $\mathbf{F}_C \in \mathbf{R}^{H \times W \times (p \times C)}$ 为需要卷积的特征; $\mathbf{F}_I \in \mathbf{R}^{H \times W \times ((1-p) \times C)}$ 为不需要卷积的特征; p 是一个超参数,用于控制需要卷积特征的通道数。

使用一个 3×3 卷积与激活函数处理 $\mathbf{F}_C$ 学习特征,其过程如下:

$$\mathbf{F}'_C = \text{act}(H_{C3}(\mathbf{F}_C)) \quad (5)$$

式(5)中, $\mathbf{F}'_C$ 与 $\mathbf{F}_C$ 分别代表输入与输出特征, act 与 H_{C3} 分别代表激活函数与 3×3 卷积。

最后在通道维度上聚合 $\mathbf{F}_{PC} = \text{cat}(\mathbf{F}'_C, \mathbf{F}_I)$ 与 $\mathbf{F}_I$ 得到部分特征卷积模块的输出,其输出如下:

$$\mathbf{F}_{PC} = \text{cat}(\mathbf{F}'_C, \mathbf{F}_I) \quad (6)$$

式(6)中, cat 表示特征聚合, $\mathbf{F}_{PC}$ 为部分特征卷积模块的输出。

特征混合模块主要由一个 1×1 卷积与多层感知机(Multilayer Perceptron, MLP)组成。 1×1 卷积从像素的角度混洗通道聚合之后的特征如下:

$$\mathbf{F}_{C1} = \text{act}(H_{C1}(\mathbf{F}_{PC})) \quad (7)$$

式(7)中, 1×1 卷积用 H_{C1} 表示,输入输出分别为 $\mathbf{F}_{PC}$ 与 $\mathbf{F}_{C1}$ 。随后,MLP 从通道的角度混洗特征,如下所示:

$$\mathbf{F}_{MLP} = H_{MLP}(\mathbf{F}_{C1}) \quad (8)$$

式(8)中, H_{MLP} 代表 MLP,输入输出分别为 $\mathbf{F}_{C1}$ 与 $\mathbf{F}_{MLP}$ 。

最后通过残差链接聚合特征,如下所示:

$$\mathbf{F}_{out} = H_{FA}(H_{PC}(\mathbf{F}_{in})) + \mathbf{F}_{in} \quad (9)$$

式(9)中, H_{PC} 与 H_{FA} 分别代表部分特征卷积模块与特征混合模块,输入输出分别为 $\mathbf{F}_{in}$ 与 $\mathbf{F}_{out}$ 。

2 实验结果与分析

2.1 实验环境与网络设置

实验采用 DVI2K^[12] 数据集训练网络,其中包含 800

张 HR 图像。测试数据集选择 Set5^[13]、Set14^[14]、BSD100^[15]、Urban100^[16]。网络采用与 RepSR 与 ECBSR 相似的设置,便于与其他超分辨率重建网络比较。训练时,训练数据首先被预裁剪为 480×480 的 HR 图像与 120×120 的 LR 图像两者互为配对;输入网络的 LR 图像被随机裁剪为 64×64;PCAN 使用一块 NVIDIA GTX 3060 训练 1×10⁶ 个迭代次数,采用离散余弦退火降低学习率,最终学习率设置为 1×10⁻⁷;实验选择使用 Adan 优化器;实验系统为 Windows 10;实验代码使用 Pytorch 实现。

2.2 对比实验

为将 PCAN 与其他先进超分辨率重建方法进行对

比,按照参数量把网络分为 A、B、C、D 4 组进行比较。其中 A 组为参数量小于 25 K 的网络,包括 FSRCNN^[9]、SESR-M5C16^[17]、ECBSR-M4C16^[10]、RepSR-M4C16^[11];B 组为参数量在 25 K~75 K 之间的网络,包括 TPSR-NoGAN^[18]、IMDN-RTC^[4]、SESR-M11C16^[17]、ECBSR-M10C16^[10]、RepSR-M10C16^[11];C 组为参数量在 75 K~250 K 之间的网络,包括 EDSR-R5C32^[19]、SESR-M11C32^[17]、ECBSR-M10C32^[10]、RepSR-M10C32^[11];D 组为参数量在 250 K 以上的网络,包括 LapSRN^[1]、VDSR^[20]、CARN-M^[5]、IMDN^[4]、ECBSR-M16C64^[10]、RepSR-M16C64^[11]。最终定量结果比较如表 1 所示。

表 1 4 种不同数据集上定量比较×4 的结果
Table 1 Quantitative comparison results (×4) of different methods on four benchmark datasets

分 组	方 法	参数量 /K	FLOPs /G	Set 5	Set 14	B100	Urban 100
				PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM
A0	FSRCNN ^[9]	12	5	30.70/0.865 7	27.59/0.753 5	26.96/0.712 8	24.60/0.725 8
A1	SESR-M5C16 ^[17]	18.32	1.05	30.99/0.876 4	27.81/0.762 4	27.11/0.719 9	24.80/0.738 9
A2	ECBSR-M4C16 ^[10]	11.9	0.69	31.04/0.880 5	27.78/0.769 3	27.09/0.728 3	24.79/0.742 2
A3	RepSR-M4C16 ^[11]	11.9	0.69	31.02/0.881 7	27.88/0.771 5	27.10/0.729 3	24.82/0.743 4
A4	PCAN-M4C16	15.9	0.92	30.89/0.874 3	27.81/0.762 5	27.05/0.717 9	24.75/0.737 1
B0	TPSR-NoGAN ^[18]	61	3.6	31.10/0.877 9	27.95/0.766 3	27.15/0.721 4	24.97/0.745 6
B1	IMDN-RTC ^[4]	21	1.22	31.22/0.884 4	27.92/0.773 0	27.18/0.731 4	24.98/0.750 4
B2	SESR-M11C16 ^[17]	32.14	1.85	31.27/0.881 0	27.94/0.766 0	27.20/0.722 5	25.00/0.746 6
B3	ECBSR-M10C16 ^[10]	26	1.5	31.37/0.886 6	27.99/0.774 0	27.22/0.732 9	25.08/0.754 0
B4	RepSR-M10C16 ^[11]	26	1.5	31.36/0.887 3	28.09/0.776 3	27.23/0.733 3	25.10/0.754 5
B5	PCAN-M10C16	28.65	1.7	31.33/0.882 6	28.06/0.768 7	27.22/0.723 7	25.08/0.750 1
C1	EDSR-R5C32 ^[19]	241.8	14.15	31.46/0.888 0	28.07/0.776 0	27.27/0.734 0	25.21/0.757 9
C2	SESR-M11C32 ^[17]	114.97	6.62	31.54/0.886 6	28.12/0.771 2	27.31/0.727 7	25.31/0.760 4
C3	ECBSR-M10C32 ^[10]	98.1	5.65	31.66/0.891 1	28.15/0.777 6	27.34/0.736 3	25.41/0.765 3
C4	RepSR-M10C32 ^[11]	98.1	5.65	31.66/0.892 0	28.28/0.781 1	27.35/0.737 2	25.46/0.767 4
C5	PCAN-M10C32	98.5	5.73	31.78/0.890 2	28.36/0.776 0	27.39/0.729 8	25.57/0.767 3
D0	LapSRN ^[1]	813	149.4	31.54/0.885 0	28.19/0.772 0	27.32/0.728 0	25.21/0.756 0
D1	VDSR ^[20]	665	612.6	31.35/0.883 8	28.02/0.767 8	27.29/0.725 2	25.18/0.752 5
D2	CARN-M ^[5]	412	46.1	31.92/0.890 3	28.42/0.776 2	27.44/0.730 4	25.62/0.769 4
D3	IMDN ^[4]	667.4	38.41	32.03/0.896 6	28.42/0.784 2	27.48/0.740 9	25.96/0.784 3
D4	ECBSR-M16C64 ^[10]	602.9	34.73	31.92/0.894 6	28.34/0.781 7	27.48/0.739 3	25.81/0.777 3
D5	RepSR-M16C64 ^[11]	602.9	34.73	31.94/0.896 1	28.44/0.785 3	27.48/0.782 5	25.88/0.782 5
D6	PCAN-M16C64	561.7	32.52	32.18/0.895 4	28.60/0.782 0	27.58/0.736 1	26.08/0.784 7

所有网络均在下采样倍数为 4 的设置下重建图像,在 Y 通道上计算峰值信噪比(Peak Signal-to-Noise

Ratio, PSNR)与结构相似性指标(Structure Similarity Index Measure, SSIM),定量地比较网络的性能。

FLOPs 在 1 280×720 的 HR 图像上计算,即输入 LR 图像大小为 360×180。

PCAN 是专为在边缘设备部署上所设计的。使用 MxCy 来设计不同大小的网络以便应对不同的部署环境,其中 x 表示 PACB 的数量, y 表示网络的通道数。

从表 1 可以看出,在 D 组中,PCAN 与 RepSR 在 B100 与 Urban100 数据集上,PSNR 分别提升 0.1 dB 与 0.2 dB,而参数量与计算量分别下降 41.2 K 与 2.21 G。这得益于部分特征卷积模块降低了运算复杂度,特征混合模块使卷积特征与未卷积特征充分混合得到了优质的结果。在 A 组、B 组和 C 组中,PCAN

在与先进算法有着相近的参数量与计算量的情况下,也保持着不错的性能。总体来说,PCAN 与最近的先进算法相比,实现了更好的模型性能与模型复杂度之间的平衡。

2.3 与先进算法的视觉效果比较

在测试数据集中选择 3 张图像,分别为 Set5: bird、Set14: ppt3、Urban100 (U100): img066。PCAN - M16C64 (PCAN) 将与 FSRCNN^[9]、TPSR - NoGAN^[18]、LapSRN^[1]、SESR - M11C32 (SESR)^[17]、CARN - M^[5]、VDSR^[20]、IMDN^[4]、ECBSR - M16C64 (ECBSR)^[10] 进行对比,其结果如图 3 所示。




图 3 视觉对比结果

Fig. 3 Visual comparison results

从图 3 可以看出,PCAN 的视觉重建效果比其他超分辨率重建网络有着更好的图像纹理细节。这主要归功于部分卷积模块能高效地提取超分辨率重建所需要的特征。具体来说,部分卷积模块得到的卷积特征有着更丰富的纹理细节以提高超分辨率重建效果。特征混合模块保证卷积特征与未卷积特征从像素和通道的

角度进行混洗,学习低分辨率与高分辨率图像的映射关系,从而保证超分辨率的重建效果。

2.4 消融实验结果

为验证部分特征卷积模块与特征混合模块的有效性,进行了大量的消融实验。消融实验采用 PCAN - M10C32 在 DVI2K 数据集上重新训练 1×10^6 个迭代次

数。表 2 展示了特征混合模块的消融实验结果。

表 2 部分卷积模块与特征混合模块消融实验结果表
Table 2 Ablation experiment results of partial convolution module and feature mixing module

部分特征卷积模块	特征混合模块	参数量 /K	FLOPs /G	Set 5
				PSNR(dB)/SSIM
×	×	117.8	6.8	31.70/0.889 1
✓	×	77.4	4.5	31.48/0.872 8
✓	✓	98.5	5.7	31.78/0.890 2

注:当不采用部分卷积模块时,部分卷积将被一个普通卷积代替。

从表 2 可以看出,同时使用部分特征卷积模块与特征混合模块较仅使用普通卷积模块,PSNR 提高了 0.08 dB,网络参数量与计算复杂度分别下降了 19.3 K 与 1.1 G。这证明部分特征卷积模块与特征混合模块能增强网络的性能,同时降低网络的参数量与计算复杂度。当仅采用部分特征卷积模块时,虽然网络的参

数量明显下降,但是网络性能出现极大的损耗。这主要是因为部分卷积仅对部分特征进行处理,不能够充分学习低分辨率与高分率图像的映射关系。

为对比残差链接对网络的影响,使用卷积-激活-卷积的结构,其结构如图 4 所示。基于该结构,设计一个与 PCAN 参数量相近的短程残差网络(记为网络 1),并与 PCAN 在参数量、残差块中的层数 l ,以及 PSNR 和 SSIM 指标进行对比,结果如表 3 所示。




图 4 卷积-激活-卷积的结构图

Fig.4 Structure of convolution-activation-convolution

表 3 残差链接的消融实验结果表


Table 3 Ablation experiment results for residual links

方 法	参数量/K	l	Set 5	Set 14	B 100	Urban 100
			PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM
网络 1	107.2	3	31.54/0.885 9	28.21/0.772 2	27.30/0.726 7	25.31/0.758 1
PCAN	98.5	6	31.78/0.890 2	28.36/0.776 0	27.39/0.729 8	25.57/0.767 3


从表 3 可以看出,网络 1 所采用的短程残差链接,残差块中的层数为 3;采用远程残差链接的 PCAN 残差块中的层数为 6。网络 1 与 PCAN 在参数量相近的情况下,PCAN 在 Set5 测试数据集上的 PSNR 和 SSIM 较网络 1 高 0.24 dB 和 0.004 3;在 Urban100 数据集上,PSNR 和 SSIM 较网络 1 分别高 0.26 dB 和 0.009 2。显然,采用远程残差链接的 PCAN 能更充分地实现特征的交互。

接下来对网络中的超参数进行消融实验。网络中的主要超参数有两个,分别为部分特征卷积中的 p 与

多层感知机中隐藏层的维度。在部分卷积特征模块中,需卷积的特征与不需要卷积的特征通道数分别为 $p \times C_{in}$ 与 $(1-p) \times C_{in}$,这两个参数必须是整数,实验设置 $C_{in} = 32$,所以 p 的取值仅能为 0.25、0.5、0.75、1。当 $p = 1$ 时,部分卷积模块等同于普通卷积块,故此不进行消融实验,最终选取 p 值为 0.25、0.5、0.75 进行消融实验。对比不同设置下网络的参数量以及在测试数据集 Set5 上的 PSNR 和 SSIM 指标,结果如图 5 所示。超参数 p 详细消融实验结果如表 4 所示。



(a) 超参数 p 关于参数量的变化曲线



(b) 超参数 p 关于 FLOPs 的变化曲线




图 5 超参数 p 的消融实验结果图

Fig. 5 Ablation experiment results for hyperparameter p

表 4 超参数 p 的消融实验结果表


p	参数量/K	FLOPs/G	Set 5	Set 14	B 100	Urban 100
			PSNR (dB)/SSIM	PSNR (dB)/SSIM	PSNR (dB)/SSIM	PSNR (dB)/SSIM
0.25	52.29	3.05	31.60/0.886 9	28.23/0.772 7	27.32/0.727 0	25.33/0.758 8
0.5	69.65	4.06	31.71/0.889 0	28.30/0.774 4	27.36/0.728 5	25.44/0.766 9
0.75	98.5	5.73	31.78/0.890 2	28.36/0.776 0	27.39/0.729 8	25.57/0.767 3


从图 5 可以看出,当 $p=0.25$ 时,虽然网络的参数量较低,但是模型的性能出现相当大的损耗。当 $p=0.75$ 时,与 $p=0.5$ 相比,参数量增加 28 K, FLOPs 增加 1.67 G, PSNR 提升 0.06 dB, SSIM 提升 0.012。进一步,在其他测试数据集上进行测试,其结果如表 5 所示。

从表 4 可以看出,当超参数 $p=0.75$ 时,较于 $p=0.25$ 与 $p=0.75$,在 Urban100 数据集上,PSNR 分别提升 0.24 dB 和 0.013 dB, SSIM 分别提升 0.008 5 和 0.000 4。在其他


数据集上,超参数 $p=0.75$ 的 PSNR 和 SSIM 指标也远优于 $p=0.25$ 与 $p=0.5$ 时。综上所述,为实现网络最优性能与参数量之间的平衡,最终选取 $p=0.75$ 。

多层感知机中的隐藏层维度分别设置为 $C/4=8$ 、 $C/2=16$ 、 $C=32$ 、 $C\times 2=64$ (“/”表示“除”)进行消融实验,采用两个指标进行对比,分别为网络的参数量与在测试数据集 Set5 上重建后图像的 PSNR 值。隐藏层维度的消融实验结果如图 6 所示。隐藏层维度的详细消融实验结果如表 5 所示。





(c) 隐藏层维度关于 PSNR 的变化曲线



(d) 隐藏层维度关于 SSIM 的变化曲线

图 6 隐藏层维度消融实验结果图

Fig. 6 Ablation experiment results for hidden layer dimension

表 5 隐藏层维度的消融实验结果表

Table 5 Ablation experiment results for hidden layer dimension

C	参数量/K	FLOPs/G	Set 5	Set 14	B100	Urban 100
			PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM
8	82.93	4.81	31.50/0.885 3	28.17/0.770 8	27.27/0.725 4	25.22/0.755 2
16	88.13	5.12	31.68/0.888 4	28.29/0.774 2	27.35/0.728 1	25.43/0.762 7
32	98.5	5.73	31.78/0.890 2	28.36/0.776 0	27.39/0.729 8	25.57/0.767 3
64	119.3	6.94	31.81/0.891 1	28.38/0.776 6	27.43/0.730 6	25.60/0.767 9

从图 6 可以看出,隐藏层维度为 32 时,网络性能相比于隐藏层维度为 8 和 16,PSNR 分别提高 0.28 dB 与 0.11 dB,SSIM 分别提高 0.005 9 与 0.001 8;而参数量仅增加了 16 K 和 6 K,FLOPs 增加 0.92 G 和 0.49 G。隐藏层维度为 64 时,网络性能较隐藏层维度为 32 时,PSNR 和 SSIM 仅增加了 0.03 dB 与 0.009,但网络的参数量增加 21 K,FLOPs 增加 1.21 G。

从表 5 可以看出,隐藏层维度为 32 时,较隐藏层维度为 16 时,在 4 个测试数据集上 PSNR 至少有 0.07 dB 的提升,SSIM 至少有 0.001 8 的提升。而隐藏层维度为 64 时,较隐藏层维度为 32 时,在 4 个测试数据集上 PSNR 仅提升 0.03 dB,SSIM 仅有 0.006 的提升。综上,隐藏层维度最终设置为 $C=32$ 。

表 2 证明了 PCAN 中部分特征卷积模块与特征混合模块的作用以及重要性。表 3 证明了 PCAN 中远程残差链接能更有效地处理特征。图 5 和表 4 证明了 PCAN 中超参数 p 的设置对网络性能与参数数量的影响,并选择了最优的结果实现网络。图 6 和表 5 比较了隐藏层维度对网络性能与参数数量的影响,通过实验选取隐藏层维度为 $C=32$ 构建网络,实现了网络性能与参

数的最佳平衡。

3 结 论

提出基于部分特征卷积聚合的图像超分辨率重建网络。该方法通过部分特征卷积与特征混合块处理特征,其中部分特征卷积模块使用部分特征卷积进一步减少网络的参数量和复杂度,特征混合模块充分地混合特征以得到更优的特征,提升网络的性能。实验数据表明,PCAN 与现有轻量化超分辨率重建网络相比,在性能指标、视觉效果上更优,在模型参数量与计算复杂度上更低,做到了网络性能与复杂度之间的平衡。并且,该方法设计了不同参数数量的 PCAN 网络以充分应对不同超分辨率重建的应用环境,在边缘设备的部署上有着很大的应用价值。在未来的工作中,将进一步分析网络,尽量降低网络的参数量与计算复杂度,并且提高网络的性能,加速算法实现在边缘设备上的部署,以应用于不同的场景之中。

参考文献(References):

- [1] 李众,王雅婧,马巧梅. 基于空洞卷积的医学图像超分辨率重建算法[J]. 计算机应用, 2023, 43(9): 2940-2947.

- Li Zhong, Wang Yajing, Ma Qiaomei. Super-resolution reconstruction algorithm of medical images based on dilated convolution[J]. Journal of Computer Applications, 2023, 43(9): 2940–2947.
- [2] 刘杰, 祁箬, 韩轲. 融合边缘增强与非局部模块的遥感图像超分辨率重建生成对抗网络[J]. 光学精密工程, 2023, 31(14): 2080–2092.
- Liu Jie, Qi Ruo, Han Ke. Generate adversarial network for super-resolution reconstruction of remote sensing images by fusing edge enhancement and non-local modules[J]. Optics and Precision Engineering, 2023, 31(14): 2080–2092.
- [3] Lai W S, Huang J B, Ahuja N, et al. Deep Laplacian pyramid networks for fast and accurate super-resolution[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2017: 5835–5843.
- [4] 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. New York: ACM, 2019: 2024–2032.
- [5] Ahn N, Kang B, Sohn K A. Fast, accurate, and lightweight super-resolution with cascading residual network[C]//Computer Vision ECCV 2018. Cham: Springer, 2018: 256–272.
- [6] Zhao H, Kong X, He J, et al. Efficient image super-resolution using pixel attention[C]//Computer Vision-ECCV 2020 Workshops. Cham: Springer, 2020: 56–72.
- [7] 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.
- [8] Shi W, Caballero J, Huszar F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2016: 1874–1883.
- [9] Dong C, Loy C C, Tang X. Accelerating the super-resolution convolutional neural network[C]//Computer Vision-ECCV 2016. Cham: Springer, 2016: 391–407.
- [10] Zhang X, Zeng H, Zhang L. Edge-oriented convolution block for real-time super resolution on mobile devices[C]//Proceedings of the 29th ACM International Conference on Multimedia. New York: ACM, 2021: 4034–4043.
- [11] Wang X, Dong C, Shan Y. RepSR: training efficient VGG-style super-resolution networks with structural re-parameterization and batch normalization[C]//Proceedings of the 30th ACM International Conference on Multimedia. New York: ACM, 2022: 2556–2564.
- [12] Agustsson E, Timofte R. NTIRE 2017 challenge on single image super-resolution: dataset and study[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. Piscataway: IEEE Press, 2017: 1122–1231.
- [13] 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. British Machine Vision Association, 2012.
- [14] Zeyde R, Elad M, Protter M. On single image scale-up using sparse-representations[C]//Curves and Surfaces. Berlin, Heidelberg: Springer, 2012: 711–730.
- [15] 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 IEEE International Conference on Computer Vision. Piscataway: IEEE Press, 2001.
- [16] Huang J B, Singh A, Ahuja N. Single image super-resolution from transformed self-exemplars[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2015.
- [17] Bhardwaj K, Milosavljevic M, O'neil L, et al. Collapsible linear blocks for super-efficient super resolution[J]. Proceedings of Machine Learning and Systems, 2022(4): 529–547.
- [18] Lee R, Dudziak E, Abdelfattah M, et al. Journey towards tiny perceptual super-resolution[C]//Computer Vision-ECCV 2020. Cham: Springer, 2020: 85–102.
- [19] 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. Piscataway: IEEE Press, 2017: 1132–1140.
- [20] Kim J, Lee J K, Lee K M. Accurate image super-resolution using very deep convolutional networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2016: 1646–1654.

责任编辑:李翠薇