

基于对称视觉注意力网络的高效图像超分辨率重建

吴承旭, 胡靖

(成都信息工程大学 计算机学院, 成都 四川 610225)

摘要: 高效超分辨率的研究重点是改进深度小核卷积来降低模型复杂度、提升效率,但较小的感受野会限制网络细节重建能力,大核卷积虽能提供更大的感受野、提升图像重建质量,但计算成本过高。为了减少模型参数数量并实现高效超分辨率重建,提出一种对称视觉注意力网络SVAN。首先将大核卷积分解为3种不同的轻量高效卷积,在卷积组合中借助不同卷积的感受野尺寸形成瓶颈结构,并与注意力机制结合成瓶颈注意力模块来增强网络对特征的关注能力;其次,将瓶颈注意力模块对称排布构成对称大核注意力块,以进一步提升网络提取深层特征的能力。实验表明,所提模型相较于其他轻量化超分辨率方法定量指标提升明显,重建的图像纹理细节更丰富,参数量仅为183 K,是一个具有竞争力的轻量化高质量超分辨率模型,为高效超分辨率提供了新的解决思路。

关键词: 图像超分辨率重建;大核卷积;感受野;视觉注意力

DOI:10.11907/rjdk.241062

开放科学(资源服务)标识码(OSID):

中图分类号:TP391

文献标识码:A

文章编号:1672-7800(2025)001-0109-06



Efficient Image Super-Resolution Reconstruction via Symmetric Visual Attention Network

WU Chengxu, HU Jing

(School of Computer, Chengdu University of Information Technology, Chengdu 610225, China)

Abstract: The research focus of efficient super-resolution is to improve deep small kernel convolution to reduce model complexity and enhance efficiency. However, smaller receptive fields will limit the network's ability to reconstruct details, while large kernel convolution can provide larger receptive fields and improve image reconstruction quality, but the computational cost is too high. In order to reduce the number of model parameters and achieve efficient super-resolution reconstruction, a symmetric visual attention network (SVAN) is proposed. Firstly, the large kernel convolution is decomposed into three different lightweight and efficient convolutions. In the convolution combination, bottleneck structures are formed by using the receptive field sizes of different convolutions, and combined with attention mechanisms to form a bottleneck attention module to enhance the network's ability to focus on features; Secondly, the bottleneck attention modules are symmetrically arranged to form symmetric large kernel attention blocks, in order to further enhance the network's ability to extract deep features. The experiment shows that the proposed model has significantly improved quantitative indicators compared to other lightweight super-resolution methods, and the reconstructed images have richer texture details with only 183K parameters. It is a competitive lightweight high-quality super-resolution model that provides new solutions for efficient super-resolution.

Key Words: image super-resolution reconstruction; large kernel convolutional; receptive field; visual attention

0 引言

图像超分辨率(Super Resolution, SR)是从经过退化过程处理的低分辨率图像中恢复高分辨率图像,该技术提供

了更好的视觉保真度和图像细节信息,被广泛应用于各种计算机视觉任务和现实场景^[1]。随着深度学习技术在计算机视觉领域广泛应用并取得了一定的成绩,SRCNN(Super Resolution Convolutional Neural Network)率先将深度学习与SR技术相结合,得到了广泛关注和快速发展^[2]。然

收稿日期:2024-01-22

扫描二维码阅读全文:



基金项目:国家自然科学基金面上项目(42375148);四川省科技厅重点研发项目(2023YFG0305)

作者简介:吴承旭(1998-),男,成都信息工程大学计算机学院硕士研究生,研究方向为图像处理;胡靖(1986-),女,博士,成都信息工程大学计算机学院教授、硕士生导师,研究方向为图像处理、深度学习和强化学习及其应用。本文通讯作者:胡靖。

而,现有模型主要采用复杂、庞大的网络架构提升SR的性能,这意味着需要大量计算资源处理网络参数,一旦参数数量过小模型就容易发生欠拟合现象,导致特征提取能力下降,从而无法完成高质量的SR重建,阻碍了模型的应用和部署^[3,4]。因此,图像重建质量和参数数量间的平衡对模型的高效性至关重要。

为了提升模型效率并降低模型复杂度,研究者们提出了结构重参数化、网络剪枝、神经结构搜索、知识蒸馏等方法,主要基于改进的深度小核卷积来降低模型复杂度^[4-12]。Shamsolmoali等^[13]指出,感受野相较于网络深度对图像质量的影响更大,较大的感受野能捕获更多全局特征信息,提升SR重建的精细度,且感受野大小与卷积核的大小呈正比,因此大卷积核对提升感受野更有效,但会增加模型计算量^[14]。

轻量级卷积是降低大核卷积计算成本的解决方法,其中深度卷积和深度扩张卷积更有效^[15]。如图1所示,一个大型卷积核可分解为局部空间中的深度卷积和远程空间中的深度扩张卷积。其中,前者仅在空间层面计算特征映射,无法扩展维度,虽然减少了不同特征映射间的信息交互,但难以捕获足够多的通道与空间交互信息;深度扩张卷积的卷积核通过稀疏扩张来获得更大的感受野,但会损失信息的连续性。为此,本文提出一种有效的对称视觉注意力网络(Symmetric Visual Attention Network, SVAN)方法,旨在降低网络参数数量的同时扩大感受野,通过3种面向空间和通道的轻量卷积构建轻量级卷积组合来提升图像SR的重建效率和质量。




Fig. 1 Analysis of large kernel convolution decomposition

图1 大核卷积分解析

此外,本文还设计了感受野瓶颈结构和对称注意力结构增强模型的特征提取能力,将 5×5 深度卷积、 5×5 深度扩张卷积和通道点卷积结合成轻量级卷积组合,以获得与 17×17 大核卷积相同的感受野,既增强了全局信息的提取能力、空间和通道信息的融合交互能力,又显著减少了参数数量。首先根据不同卷积层的感受野大小形成瓶颈结构以有效融合多尺度信息,其次利用不同感受野大小增强模型对全局信息和局部信息的感知能力,以进一步压缩、细化提取的特征,从而提升网络学习能力和表达能力^[16]。

本文为了更好地解决网络参数数量少导致的模型欠拟合现象,首先,将具有瓶颈结构的轻量卷积组合与视觉注意力机制结合起来形成瓶颈注意力模块,利用自适应乘

法加权提升图像高频特征的关注度,从而增强对局部上下文信息的提取能力;其次,将两组注意力块对称排列得到对称大核注意力块(Symmetric Large Kernel Attention Block, SLKAB),以提升网络表达能力、泛化能力和计算效率^[17]。本文贡献主要为:①SVAN方法采用了大核分解思想构建轻量卷积组合,可有效减少参数数量、扩大感受野尺寸,从而保证了SR的重建质量,使模型更轻量化、高效,有助于实现移动端实时图像SR任务;②提出基于瓶颈结构和对称结构的SLKAB,通过感受野瓶颈结构组合不同大小的感受野卷积来增强网络对深度特征的提取能力,对称注意力结构采用对称结构的自适应乘法加权来提升网络对高频图像信息的关注能力。

1 相关工作

由于高效SR网络的目标是降低模型复杂度和计算成本,KIM等^[18]引入跳跃连接进行残差学习,增加了SR网络的深度,提出VDSR(Very Deep Super-Resolution Convolution Neural Network)。TAI等^[19]通过递归结构提升重构性能提出DRRN(Deep Recursive Residual Network),缓解了网络过深导致训练参数数量过大的问题。Ahn等^[20]利用群卷积和循环网络消除冗余参数提出一种高效级联残差网络(Cascading Residual Network, CARN),但模型推理时间较长。Hui等^[11]提出一种信息蒸馏网络(Information Distillation Network, IDN),将提取的特征进行部分处理以获得良好的性能,但无法充分利用通道特征信息。Hui等^[12]改进信息多蒸馏块,提出了一种轻量级的信息多蒸馏网络(Information Multi-distillation Network, IMDN),但参数数量较大。虽然以上研究主要通过各种复杂的层间连接和改进的小核卷积来提升SR效率,但网络感受野较小会导致全局信息提取能力不足,从而限制了网络性能。

近年来,随着图像处理性能要求的提升,大核卷积利用大型卷积核扩大网络感受野,以获取更多全局信息,研究也证实了大卷积核的性能更优。Liu等^[21]使用 7×7 内核对标准 3×3 残差网络进行重新设计提出ConvNeXt,相较于Transformer具有一定的竞争力^[22]。Ding等^[14]构建了一个具有 31×31 卷积核的超大卷积核网络模型RePLKNet(Re-parameterization Large Kernel),结果优于Transformer。虽然大核卷积可更高效地提升感受野,解决了深度模型优化难的问题,但难以兼顾局部特征,容易出现过度平滑问题。

注意力机制是选择性关注特征内容的技术,通过学习得到注意力权重,并与输入数据相乘加权来帮助模型动态关注图像中的重要信息以提升重建图像质量。Guo等^[15]为视觉任务提出一种线性注意力机制VAN(Visual Attention Network),利用大核卷积注意力提升网络局部、全局结构信息的自适应性,但并未拓展至其他图像任务中。以上方法皆为SR模型设计提供了参考,但并未研究大核卷积

的轻量化这一工作。为此, 本文在高效 SR 中结合大核卷积轻量化与注意力机制, 在实现轻量化网络的同时, 提升模型感受野尺寸大小和局部特征提取能力。

2 网络结构

2.1 对称视觉注意力网络

图 2 为轻量级对称视觉注意力网络结构, 包含浅层特征提取模块、深层特征提取模块和像素重建模块。其中, I_{LR} 、 I_{SR} 表示 SVAN 的输入与输出。首先, 浅层特征提取模块使用 3×3 卷积进行特征提取。

$$x_0 = f_{ext}(I_{LR}) \quad (1)$$

式中: $f_{ext}(\cdot)$ 表示浅层特征提取模块; x_0 为提取的特征映射。

其次, 使用多个 SLKAB 进行深度特征提取。

$$x_n = f_{SLKAB}^n(f_{SLKAB}^{n-1}(\dots f_{SLKAB}^0(x_0)\dots)) \quad (2)$$

式中: $f_{SLKAB}^n(\cdot)$ 表示第 n 个 SLKAB 函数; x_n 表示第 n 个 SLKAB 输出的特征映射。

再次, 在深度特征提取阶段结束时使用扩张率为 3 的 3×3 深度扩张卷积 $f_{ref}(\cdot)$ 进行特征融合, 将深度特征与原始输入进行残差连接细化。

$$x_{map} = f_{ref}(x_n) + x_0 \quad (3)$$

最后, 使用重建模块对特征进行上采样以达到与 HR 相同的分辨率。

$$I_{SR} = f_{rec}(x_{map}) \quad (4)$$

式中: $f_{rec}(\cdot)$ 表示由 3×3 卷积层和 pixel-shuffle 层组成的像素重建模块^[23]; I_{SR} 为网络最终输出的 SR 结果。




Fig. 2 Architecture of symmetric visual attention network

图 2 对称视觉注意力网络结构

2.2 对称大核注意力块

SLKAB 利用 5×5 深度卷积、 5×5 深度扩张卷积和 1×1 点卷积实现与 17×17 大核卷积相同的感受野, 卷积组合充分提取了空间信息与通道信息, 极大减少了参数数量。本文模块在设计中对称地排列了两组感受野瓶颈注意力块, 形成了双注意力模块。通过大一一小一小的感受野排列, 形成了具有瓶颈结构的注意力结构, 实现了特征信息的交互提取, 增强了模块泛化能力, 在参数与性能之间取得了有效平衡。

图 3 为对称大核注意力模块结构, 当原始特征映射输入上瓶颈注意力块时, 首先通过深度卷积与深度扩张卷积提升感受野大小; 其次利用大感受野提取特征以最大化保留原始输入信息; 最后利用小感受野的点卷积层细化特

征, 并将结果输入下瓶颈注意力块。

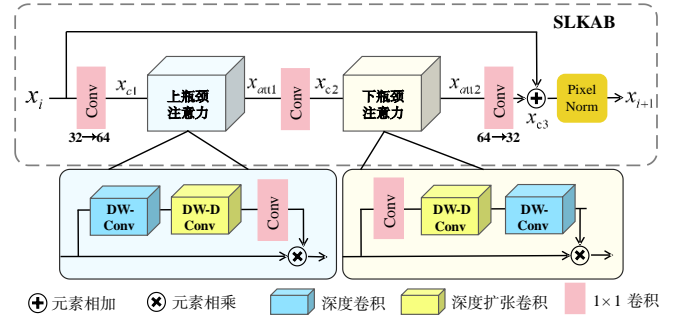


Fig. 3 Architecture of symmetric large kernel attention block

图 3 对称大核注意力模块结构

下瓶颈注意力块具有与上瓶颈注意力块相反的感受野排列, 从而形成了一个对称的瓶颈注意力结构, 具体为通过 1×1 卷积 $conv(\cdot)$ 与 GELU 激活函数 $gelu(\cdot)$ 将特征从 32 通道扩展到 64 通道, 以获得更多通道信息。

$$x_{c1} = gelu(conv(x_i)) \quad (5)$$

式中: x_i 为第 n 个 SLKAB 的输入

随后将生成的全局信息关系特征使用元素乘法与输入原始特征 x_{c1} 融合, 基于输入自适应调整输出, 从而估计每个像素的重要性并生成注意力特征图 x_{att1} 。

$$x_{att1} = UAB(x_{c1}) = conv(DWD(DW(x_{c1}))) \otimes x_{c1} \quad (6)$$

式中: $DW(\cdot)$ 、 $DWD(\cdot)$ 分别为深度卷积和深度扩张卷积, 以较小计算成本与参数量获取全局信息关系; $UAB(\cdot)$ 表示上瓶颈注意力, 由 $DW(\cdot)$ 、 $DWD(\cdot)$ 的尺寸为 17 的感受野与 1×1 卷积 $conv(\cdot)$ 尺寸为 1 的感受野, 两者形成上瓶颈来最大化提取原始输入的特征信息。

下瓶颈注意力 $LAB(\cdot)$ 中使用相反的卷积排布进一步增强全局信息的特征提取, 具体计算公式为:

$$x_{att2} = LAB(x_{c2}) = DW(DWD(conv(x_{c2}))) \otimes x_{c2} \quad (7)$$

接下来, 由 1×1 卷积层将通道数调整至 32, 通过跳跃连接融合原始输入。最后, 利用像素归一化 $pn(\cdot)$ 提升模型的训练稳定性, 得到 SLKAB 的输出 x_{i+1} 。

$$x_{c3} = conv(x_{att2}) + x_i \quad (8)$$

$$x_{i+1} = pn(x_{c3}) \quad (9)$$

3 实验结果与分析

3.1 数据集与评价指标

本文使用 2 650 张图像的 Flickr2K^[24] 和 800 张图像的 DIV2K^[25] 组成实验训练数据集, 图像数据以 RGB 通道加载和训练, 并使用随机翻转和旋转进行数据增强。在测试阶段, 采用 Set5^[26]、Set14^[27]、BSD100^[28] 和 Urban100^[29] 等 5 个基准数据集进行测试, 以评估和比较各模型的性能。实验采用峰值信噪比 (Signal to Noise Ratio, PSNR) 和结构相似性 (Structural Similarity Index, SSIM) 作为定量评价指标,

计算SR图像在YCbCr空间中Y通道的性能^[31]。其中,PSNR是重建图像与HR间灰度值均方差相关的指标,指标越高越好;SSIM体现了HR与重建图像的相似度指标,取值范围为[0,1],值越大代表重建图像与HR相似度越高。

3.2 实验参数

通常情况下,SVAN中SLKAB的数量为7,通道数设置为32,本文为了更好地提取深度信息使用1×1卷积将通道数扩展到64个,重建模块的卷积层和pixel-shuffle层通道根据重建倍数进行调整。本文从LR图像中随机裁剪大小为64×64的图像作为训练输入,Batchsize设置为96,优化器为Adam。

训练阶段,首先使用L1损失函数训练2000轮,学习率设置为 1×10^{-3} ,每500轮减半;其次加载训练保存的模型参数,使用L1损失函数,学习率使用余弦退火策略进行周

期性动态调整,初始为 1×10^{-4} ,输入图像尺寸调整为128,训练3000次;最后使用L2损失函数微调,训练3000轮,初始学习率设置为 5×10^{-4} ,每300轮减半。

3.3 定量实验

本文提出的SVAN与现有高效SR模型在多个基准数据集上进行重建倍数为×2、×3和×4的定量性能比较,包括SRCNN^[2]、VDSR^[18]、DRRN^[19]、IDN^[11]和LESRCNN^[30],实验结果如表1所示。其中,SRCNN将深度学习与SR相结合;VDSR使用跳跃连接进行残差学习,提升网络深度;DRRN利用递归结构提升SR重建效率;IDN利用信息蒸馏结构提升SR的重建效率;LESRCNN增强高低频信息以提升SR的重建效果。表1中还记录了参数数量与FLOPs,FLOPs是在256×256图像上计算得到的网络浮点操作总数,参数数量和FLOPs越低说明模型运算效率越高,加粗部分为最好结果。

Table 1 Quantitative results of different methods on benchmark datasets

表1 不同方法在基准数据集的定量结果

倍数	方法	参数量/K	FLOPs/G	Set5	Set14	BSD100	Urban100
				PSNR/SSIM	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM
×2	Bicubic	-	-	33.66/0.929 9	30.24/0.868 8	29.56/0.843 1	26.88/0.840 3
	SRCNN ^[2]	57	3.80	36.66/0.954 2	32.45/0.906 7	31.36/0.887 9	31.36/0.887 9
	VDSR ^[18]	666	43.64	37.53/0.958 7	33.03/0.912 4	31.90/0.896 0	30.76/0.914 0
	DRRN ^[19]	298	483.76	37.74/0.959 1	33.23/0.913 6	32.05/0.897 3	31.23/0.918 8
	IDN ^[11]	553	49.61	37.83/0.960 0	33.30/0.914 8	32.08/0.898 5	31.27/0.919 6
	LESRCNN ^[30]	533	275.07	37.65/0.958 6	33.32/0.914 8	31.95/0.896 4	31.45/0.920 6
	SVAN(ours)	173	11.00	37.81/0.959 2	33.40/0.915 8	32.10/0.900 4	31.46/0.923 0
×3	Bicubic	-	-	30.39/0.868 2	27.55/0.774 2	27.21/0.738 5	24.46/0.734 9
	SRCNN ^[2]	57	3.80	32.75/0.909 0	29.30/0.821 5	28.41/0.786 3	26.24/0.798 9
	VDSR ^[18]	666	43.64	33.66/0.921 3	29.77/0.831 4	28.82/0.797 6	27.14/0.827 9
	DRRN ^[19]	298	483.76	34.03/0.924 4	29.96/0.834 9	28.95/0.800 4	27.53/0.837 8
	IDN ^[11]	553	67.80	34.11/0.925 3	29.99/0.835 4	28.95/0.801 3	27.42/0.835 9
	LESRCNN ^[30]	533	275.07	33.93/0.923 1	30.12/0.838 0	28.91/0.800 5	27.70/0.841 5
	SVAN(ours)	177	11.30	34.07/0.924 6	30.13/0.838 2	28.96/0.802 1	27.67/0.840 8
×4	Bicubic	-	-	28.42/0.810 4	26.00/0.702 7	25.96/0.667 5	23.14/0.657 7
	SRCNN ^[2]	57	3.80	30.48/0.862 6	27.50/0.751 3	26.90/0.710 1	24.52/0.722 1
	VDSR ^[18]	666	43.64	31.35/0.883 8	28.01/0.767 4	27.29/0.725 1	25.18/0.752 4
	DRRN ^[19]	298	483.76	31.68/0.888 8	28.21/0.772 0	27.38/0.728 4	25.44/0.763 8
	IDN ^[11]	553	93.25	31.82/0.890 3	28.25/0.773 0	27.41/0.729 7	25.41/0.763 2
	LESRCNN ^[30]	552	275.07	31.88/0.890 3	28.44/0.777 2	27.45/0.731 3	25.77/0.773 2
	SVAN(ours)	183	11.70	31.91/0.893 5	28.41/0.775 8	27.47/0.733 8	25.79/0.776 3

由表1可知,SVAN相较于比较方法具有最少的参数数量和FLOPs,实现了模型轻量化和计算高效性。SVAN在×4重建时参数数量、FLOPs仅为LESRCNN的33.15%、4.25%,超越了大部分比较方法,得到了具有竞争力的结果。在显著减少参数数量的情况下,本文模型仍能与先进模型进行竞争,实现了轻量化与高效SR重建效果之间的平衡。

3.4 定性实验

在×4重建倍数下对Set14、BSD100和Urban100进行的定性比较结果如图4所示。由此可见,大多数方法产生了明显的伪影和模糊效果,纹理细节重建能力较差。图像“img_068”中DRRN和IDN在纹理的恢复上存在困难,重

建细节模糊;LESRCNN重建内容准确,但在纹理边缘存在模糊现象;SVAN可正确恢复细节信息,对纹理、线条边缘的重建更真实准确,图像具有更好的视觉效果。综上,SVAN能在显著减少参数数量的情况下,准确重建图像纹理细节,实现轻量化、高质量的SR重建。

3.5 消融实验

为了探究SLKAB中的瓶颈和对称结构的有效性,基于×4重建倍数在Set5数据集上进行实验,通过改变SLKAB中不同感受野大小卷积层顺序,以验证瓶颈结构和感受野对称排列的合理性和有效性,实验结果如表2所示。其中,17表示通过5×5深度卷积和5×5深度扩张卷积组合得到的感受野尺寸;1表示通过1×1点卷积得到的感受野




图 4 重建尺度为 $\times 4$ 时不同方法的图像

图 4 重建尺度为 $\times 4$ 时不同方法的图像

尺寸。本文将注意力模块中的感受野大小排序为 17-1-17 表示感受野具有瓶颈结构和对称结构, 即 1-17-1-17、17-1-17-1 和 1-17-17-1 分别代表感受野无瓶颈和对称结构、只有瓶颈结构、只有对称结构。实验表明, 17-1-1-17 的排列效果最好。

Table 2 Ablation experimental results of bottleneck structure and symmetrical structure

表 2 瓶颈结构与对称结构的消融实验结果

排布顺序	瓶颈结构	对称结构	Set5 PSNR
1-17-1-17			31.72
17-1-17-1	√		31.73
1-17-17-1		√	31.74
17-1-1-17	√	√	31.76

图 5 为 4 种结构的视觉比较结果, 从左至右依次为 1-17-1-17、17-1-17-1、1-17-17-1、17-1-1-17。由此可见, 17-1-1-17 排列的文字边缘细节更多, 重建结果更好, 再次验证了感受野瓶颈结构和对称结构的有效性。



Fig. 5 Visual comparison between bottleneck structure and symmetrical structure

图 5 瓶颈结构与对称结构的视觉比较

最后, 为了证明所提方法卷积组合的有效性和高效性, 将普通大核卷积与轻量卷积组合进行比较, 实验结果如表 3 所示。其中, 5-DW、5-DW-D 表示本文模型卷积组合中的 5×5 深度卷积和 5×5 深度扩张卷积。由此可知, 本文模型中的卷积组合具有与 17×17 卷积相同的感受野尺

寸, 但参数数量仅为传统 17×17 卷积的 6%, FLOPs 明显更低, 参数数量甚至相较于 5×5 卷积核更少, 表明了该卷积组合更具轻量化和高效性, 是实现 SR 网络高效性的一种可选方案, 再次验证了将大核卷积分解为深度卷积和深度扩张卷积组合的正确性和有效性。

Table 3 Performance comparison between convolution combination and ordinary convolution

表 3 卷积组合与普通卷积的性能比较

卷积	感受野	参数量/K	FLOPs/G
5×5	5	0.228	0.014 3
17×17	17	2.604	0.149 8
5-DW & 5-DWD	17	0.156	0.009 8

4 结语

本文为了在减少参数数量的同时扩大网络感受野, 使用不同轻量化卷积组合确保重建质量, 提出了一个轻量级的对称视觉注意力网络 SVAN。首先根据每层卷积的感受野大小形成瓶颈注意力块, 其次通过对称结构设计获得对称大核注意力块 SLKAB。

实验表明, SVAN 实现了轻量化且高效的 SR 重建效果, 仅使用 183 KB 的参数数量就能取得相较于现有方法更具竞争力的结果。未来, 将重点研究如何进一步提升 SVAN 模型的定量结果, 使得模型更具竞争力。

参考文献:

[1] SHEN K T, MIN T Y, HU D M. Super-resolution reconstruction of wide-range infrared images by fusing lightweight ViT and CNN [J]. Software Journal, 2023, 22(2): 21-27.

- 沈恺涛, 闵天悦, 胡德敏. 融合轻量级ViT与CNN的广范围红外图像超分辨率重建[J]. 软件导刊, 2023, 22(2): 21-27.
- [2] DONG C, LOY C C, TANG X. Accelerating the super-resolution convolutional neural network [C]// Proceedings of the European Conference on Computer Vision, 2016: 391-407.
- [3] LIANG J, CAO J, SUN G, et al. Swinir: image restoration using swin transformer [C]// Proceedings of the IEEE International Conference on Computer Vision, 2021: 1833-1844.
- [4] 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, 2021: 4034-4043.
- [5] LI Y, ZHANG Y, TIMOFTE R, et al. NTIRE 2023 challenge on efficient super-resolution: methods and results [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2023: 1921-1959.
- [6] LI Y, ZHANG K, RADU T, et al. NTIRE 2022 challenge on efficient super-resolution: methods and results [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2022: 1062-1102.
- [7] WANG Y. Edge-enhanced feature distillation network for efficient super-resolution [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2022: 777-785.
- [8] YU L, LI X, LI Y, et al. DIPNet: efficiency distillation and iterative pruning for image super-resolution [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2023: 1692-1701.
- [9] GUO Y, LUO Y, HE Z, et al. Hierarchical neural architecture search for single image super-resolution [J]. IEEE Signal Processing Letters, 2020, 27: 1255-1259.
- [10] CHU X, ZHANG B, MA H, et al. Fast, accurate and lightweight super-resolution with neural architecture search [C]// 25th International Conference on Pattern Recognition, 2021: 59-64.
- [11] HUI Z, WANG X, GAO X. Fast and accurate single image super-resolution via information distillation network [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 723-731.
- [12] 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.
- [13] SHAMSOLMOALI P, LI X, WANG R. Single image resolution enhancement by efficient dilated densely connected residual network [J]. Signal Processing: Image Communication, 2019, 79: 13-23.
- [14] DING X, ZHANG X, HAN J, et al. Scaling up your kernels to 31x31: revisiting large kernel design in cnns [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2022: 11963-11975.
- [15] GUO M H, LU C Z, LIU Z N, et al. Visual attention network [J]. Computational Visual Media, 2023, 9(4): 733-752.
- [16] ZHOU D, HOU Q, CHEN Y, et al. Rethinking bottleneck structure for efficient mobile network design [C]// Proceedings of the European Conference on Computer Vision, 2020: 680-697.
- [17] GAO G, WANG Z, LI J, et al. Lightweight bimodal network for single-image super-resolution via symmetric CNN and recursive transformer [DB/OL]. <https://arxiv.org/abs/2204.13286>.
- [18] 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, 2016: 1646-1654.
- [19] TAI Y, YANG J, LIU X. Image super-resolution via deep recursive residual network [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 3147-3155.
- [20] AHN N, KANG B, SOHN K A. Fast, accurate, and lightweight super-resolution with cascading residual network [C]// Proceedings of the European Conference on Computer Vision, 2018: 252-268.
- [21] LIU Z, MAO H, WU C Y, et al. A convnet for the 2020s [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2022: 11976-11986.
- [22] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [DB/OL]. <https://arxiv.org/abs/1706.03762>.
- [23] SHI W, CABALLERO J, HUSZÁR 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, 2016: 1874-1883.
- [24] 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.
- [25] 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, 2017: 126-135.
- [26] BEVILACQUA M, ROUMY A, GUILLEMOT C, et al. Low-complexity single-image super-resolution based on nonnegative neighbor embedding [EB/OL]. https://people.rennes.inria.fr/Aline.Roumy/publi/12bmv-Bevilacqua_lowComplexitySR.pdf.
- [27] ZEYDE R, ELAD M, PROTTER M. On single image scale-up using sparse-representations [C]// 7th International Conference on Curves and Surfaces, 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 8th IEEE International Conference on Computer Vision, 2001: 416-423.
- [29] 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, 2015: 5197-5206.
- [30] TIAN C, ZHUGE R, WU Z, et al. Lightweight image super-resolution with enhanced CNN [J]. Knowledge-Based Systems, 2020, 205: 106235.
- [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, 2004, 13(4): 600-612.

(责任编辑:刘嘉文)