



· 智能感知与计算 ·

面向遥感图像超分辨率重建的高效通道注意力算法

陈晓璇¹, 仝晓丹¹, 李耀维^{1,2}, 蔡誉涵¹, 姜 博^{1,2}

1. 西北大学 电子信息学院(人工智能学院), 陕西 西安 710127;

2. 生成式人工智能与混合现实陕西省高等学校重点实验室, 陕西 西安 710127

摘要 遥感成像设备普遍面临距离远、成像分辨率低的问题, 直接影响遥感图像质量和应用效果。针对这一问题, 提出一种基于高效通道注意力的特征增强超分辨率重建网络模型, 将图像超分辨率重建技术引入到遥感图像处理领域, 利用分组卷积特征增强模块对图像进行特征提取和增强, 然后利用高效通道注意力和非对称卷积并联构成的注意力模块, 建立起图像不同区域之间的相互关系, 重建出高分辨率图像。实验结果表明, 该算法在WHU-RS19测试集上的峰值信噪比和结构相似性分别为28.70 dB、0.753 9, 分别比次优方法提高了0.19 dB和0.006 6, 重建图像的细节也更加丰富, 从客观指标和主观视觉上验证了该算法的有效性。

关键词 遥感图像; 超分辨率; 分组卷积; 通道注意力

中图分类号: TP391 **DOI**: 10.16152/j.cnki.xdxbzr.2026-01-010

Efficient channel attention algorithm for super-resolution reconstruction of remote sensing image

CHEN Xiaoxuan¹, TONG Xiaodan¹, LI Yaowei^{1,2}, CAI Yuhan¹, JIANG Bo^{1,2}

1. School of Electronic Information (School of Artificial Intelligence), Northwest University, Xi'an 710127, China;

2. Shaanxi Key Laboratory of Higher Education Institution of Generative Artificial Intelligence and Mixed Reality, Xi'an 710127, China

Abstract Remote sensing imaging equipment generally faces the problems of long distance and low imaging resolution, which directly affects the quality and application effect of remote sensing images. In order to solve this problem, a super-resolution reconstruction network based on feature enhancement of efficient channel attention is proposed. It introduces image super-resolution reconstruction technology into the field of remote sensing image processing, uses the grouped convolution feature enhancement module to extract and enhance the features of the image, and then uses the attention module composed of efficient channel attention and asymmetric convolution in parallel to establish the relationship between different regions of the image, and reconstructs low-resolution remote sensing images to obtain idealized high-resolution images. Finally, the experimental results show that the peak signal-to-noise ratio and structural similarity of this algorithm on the WHU-RS19 test set are 28.70 dB and 0.753 9, which are 0.19 dB and 0.006 6 higher than those of the sub-optimal method, respectively, and the details of the reconstructed image are more abundant.

收稿日期: 2025-07-11 修回日期: 2025-09-08

基金项目: 国家自然科学基金(42271140); 陕西省重点研发计划(2023-YBGY-242)。

第一作者: 陈晓璇, 女, 副教授, 从事数字图像处理研究, chenxx@nwu.edu.cn。

Keywords remote sensing image; super resolution; group convolution; channel attention

随着遥感技术的飞速发展,越来越多的卫星发射升空,各种成像传感器采集了大量的遥感图像。这些遥感图像以不同的观测方式记录了地球的信息,为观测景象的解译提供了丰富的数据。迄今为止,这些图像已广泛应用于资源勘探、环境调查、战场侦察等诸多领域,并取得了巨大成功^[1]。然而由于目前成像传感器的局限性和复杂的大气条件,如光学系统畸变、大气干扰、运动等,得到的遥感图像总是失真^[2]。同时,获得的遥感图像往往分辨率较低,存在局部区域模糊和部分细节丢失等问题,无法满足各种遥感应用任务(如地图更新、道路提取和军事目标识别等)对图像的高质量要求。

超分辨率技术是用单幅低分辨率图像或低分辨率图像序列重建高分辨率图像。低分辨率图像序列的亚像素移动通常用于超分辨率重建,可以从不同传感器的同一区域图像中同时获取。在遥感成像应用中,高分辨率图像通常是遥感图像分析和处理过程中所需要的,而超分辨率技术可以突破图像采集设备的分辨率限制,在亚像素级实现低分辨率图像序列互补信息的图像重建。

当前,图像超分辨率重建技术主要划分为 2 个类别:基于传统的算法和基于深度学习的算法。传统算法可以进一步细分为基于插值^[3]、基于重构^[4]和基于浅层学习的算法。常见的插值方法有最近邻插值、双线性插值和双三次插值等;重构法包括迭代反投影算法、最大先验概率算法等;基于浅层学习的方法有流形学习、稀疏编码等。传统算法主要依赖于低分辨率图像内固有的像素信息,并通过局部信息的利用来提升图像质量,这种方法在处理时未能充分考虑图像整体像素值的分布特征。而基于深度学习的遥感图像超分辨率重建算法,有引入多尺度结构^[5]学习图像中的物体细节和全局环境信息,也有引入残差结构^[6]提取图像的局部和全局信息,减少图像信息的损失。

上述方法已经在自然图像超分辨率重建上取得良好效果,但是遥感图像场景复杂、纹理特征丰富,现有的一些方法无法充分利用遥感图像的全局和细节信息,导致重建图像的边缘细节不清晰,甚至出现伪影,重建的图像质量不高。

不同于自然图像,遥感图像的场景较为复杂,主要目标的结构是变化的,如果网络中缺失几何变换的机制,则其建模能力受到限制。对此,本文提出了一种基于高效通道注意力(efficient channel attention, ECA)的特征增强遥感图像超分辨率重建网络模型,将超分辨率技术用于遥感图像重建,以获得高质量重建图像。具体地,利用卷积层提取低层特征,再通过基于高效通道注意力的分组卷积特征增强模块对深层特征进行提取,并与低层特征进行信息互补,最后用卷积和上采样操作对特征进行整合以获得重建的高分辨率图像。

1 基于高效通道注意力的特征增强超分辨率卷积神经网络

针对单帧遥感图像超分辨率重建问题,本文提出一种基于高效通道注意力的特征增强超分辨率卷积神经网络,结构图如图 1 所示,分为 2 个支路。图 1 上方是主支路:主要通过 6 组分组增强卷积模块(group enhanced convolutional block, GEB)获取有价值的特征;此外,使用卷积和激活函数的组合(Conv + ReLU)分别实现特征初步提取和特征整合的功能;利用上采样机制,获得从低分辨率(low resolution, LR)特征到高分辨率(high resolution, HR)特征的映射;最后的卷积层用于构建一个 HR 图像。图 1 下方的支路采用一个 Unet 网络^[7]作为特征提取模块,将提取到的特征分别送入分组卷积特征增强模块,实现补充浅层特征纹理信息的功能。




图 1 基于高效通道注意力的分组增强卷积神经网络

Fig. 1 Group-enhanced convolutional neural network based on efficient channel attention

具体地,在分组卷积增强模块 GEB 中,使用组卷积^[8]提高所获得低频信息在不同通道的相关性方面的表达能力,以平衡单帧图像超分辨率的性能和复杂性^[9],还可以防止所获得低频信息的过度增强。此外,在分组卷积增强模块里提出高效通道注意力模块,通过引入非对称卷积减少计算量,提高网络性能,同时将其与通道注意力结合,对相关特征进行增强,获得更多的细节内容。

2 分组增强卷积模块

现有的超分辨率重建网络中,有些网络是直接增强深层次的特征,而不是充分利用不同信道间的相关信息提高超分辨率重建性能,这样就会带来较高的计算代价。考虑到上述原因,本文尝试利用特征不同信道间的相关性,采用分组增强卷积块增强低频特征的表达能力,从而获得具有竞争力的图像超分辨率重建性能和速度。同时根据网络设计原则,采用信号增强的思想继承长距离特征,解决深层网络中浅层存储能力较差的问题。

本文采用的网络结构如图 2 所示,使用组卷积将从每个分组增强卷积模块 GEB 中的前 4 个卷积层获得的特征分为 2 组:Gconv1 为提取部分(当前卷积层获取特征的通道数的 1/4);Gconv2 为剩余部分(当前卷积层获取特征的通道数的 3/4)。Gconv1 是输入通道数为 16、输出通道数为 16、滤波器尺寸为 3×3 的群卷积;Gconv2 是输入通道数为 48、输出通道数为 48、滤波器大小为 3×3 的群卷积。具体地,只选择剩余部分作为主网络中下一卷积层的输入,用于提取更深的特征,提高 SR 模型的训练效率。同时,利用跳跃连接将经过高通道注意力 ECA 之后的特征与 Gconv2 输出的剩余部分特征进行相加操作,作为主网络中下一结构(ReLU + Conv + ECA Block)的输入,用于提取更深的特征,提高网络模型的训练效率。最后,将 4 个 Gconv1 输出的提取部分特征进行相加操作,并与最后一个 Gconv2 输出的剩余部分特征进行整合,实现浅层特征和深层特征的信息交互,具体步骤如下。

第 1 步,整体网络结构图(见图 2)中第 j 个 GEB 中的第一个 Gconv2 的输出可以表示为

$$\begin{aligned} O_{Gconv2^1_j} = & \begin{cases} F_{\alpha}(C(R(C(I_{LR})))) , j = 1 \\ F_{\alpha}(E(C(O_{GEB_{j-1}}))) , j = 2, 3, 4, 5, 6 \end{cases} \quad (1) \end{aligned}$$




图 2 引入高效通道注意力的分组增强卷积模块
Fig.2 Group-enhanced convolution module with efficient channel attention

式中: I_{LR} 是低分辨率输入图像,经过 Conv + ReLU 操作后作为第 1 个 GEB 的输入特征; C 表示卷积操作; R 表示 ReLU 激活函数; F_{α} 表示按照比率 α 提取的卷积层信道数,通过实验选择 α 为 3/4,通道数 s 为 64; $O_{GEB_{j-1}}$ 表示第 $j-1$ 个 GEB 的输出,它是第 j 个 GEB 的输入。

此外,第 j 个 GEB 的第 i 个($i \neq 1$) 剩余部分特征可以表示为

$$O_{\text{Gconv}2_j^i} = O_{\text{Gconv}2_j^{i-1}} + F_a(E(C(R(O_{\text{Gconv}2_j^{i-1}})))) \quad (2)$$

式中: $i = 2, 3, 4$; E 表示高效通道注意力模块 ECA。

与 Gconv2 不同的是, GEB 中第 1 个 Gconv1 的输入来自第一卷积层输出的 $1/4$ 通道数的特征, 其他第 j 个 Gconv1 的输入都来自于第 $j-1$ 个 Gconv2 经过 ReLU + Conv + ECA 之后的输出特征, 公式为

$$O_{\text{Gconv}1_j^1} = \begin{cases} F_{1-\alpha}(C(R(C(I_{\text{LR}}))), & j = 1 \\ F_{1-\alpha}(C(O_{\text{GEB}_{j-1}})), & j = 2, 3, 4, 5, 6 \end{cases} \quad (3)$$

$$O_{\text{Gconv}1_j^i} = F_{1-\alpha}(E(C(R(O_{\text{Gconv}2_j^{i-1}}))), i = 2, 3, 4 \quad (4)$$

式中: $O_{\text{Gconv}1_j^i}$ 和 $O_{\text{Gconv}1_j^i}$ 分别表示来自第 j 个分组增强卷积模块的第 1 个和第 i 个提取部分的输出。

第 2 步, 使用 $\oplus$ 合并所有从 Gconv1 得到的特征, 以加强不同 Gconv1 的连接, 公式为

$$O_{\text{TGconv}1_j^4} = \sum_{i=1}^4 O_{\text{Gconv}1_j^i} \quad (5)$$

式中: $O_{\text{TGconv}1_j^4}$ 是第 j 个分组增强卷积模块的所有提取部分的总输出。

第 3 步, 利用级联操作整合最后的 Gconv1 和 Gconv2 的输出, 获得包含更多细节的特征, 公式为

$$O_{\text{EF}_j} = R(\text{Concat}(O_{\text{Gconv}2_j^4}, O_{\text{TGconv}1_j^4})) \quad (6)$$

式中: O_{EF_j} 是来自第 j 个 GEB 的输出特征, 输出通道数为 64; Concat 表示级联运算。另外, O_{EF_j} 后接 2 层 Conv + ReLU, 每层的输入、输出通道数均为

64, 滤波器尺寸为 3×3 , 公式为

$$O_{\text{DF}_j} = R(C(R(C(O_{\text{EF}_j})))) \quad (7)$$

式中, O_{DF_j} 是第 j 个分组增强卷积模块中的 Conv + ReLU 的输出, 并且 $j = 1, 2, 3, 4, 5, 6$ 。

随着网络结构加深, 浅层对深层的影响可能会越来越弱, 因此使用跳跃连接继承长距离特征, 即使用 $\oplus$ 将获得的浅层特征覆盖在深层特征上, 以提高浅层的重要性, 公式为

$$O_{\text{GEB}_j} = \begin{cases} O_{\text{DF}_1} + R(C(I_{\text{LR}})), & j = 1 \\ O_{\text{DF}_j} + O_{\text{GEB}_{j-1}}, & j = 2, 3, 4, 5, 6 \end{cases} \quad (8)$$

式中, O_{GEB_j} 表示第 j 个 GEB 的输出。

3 高效通道注意力模块

为了让网络更加关注包含关键信息的通道, 减少对没有重要信息通道的关注, 提高特征表示能力, 本文提出了一种高效通道注意力模块 ECA, 如图 3 所示。该模块参考 ECA-Net^[10] 中不降维的局部跨信道交互的思想, 在其基础上增加了一条包含非对称卷积的特征增强支路, 该支路首先将特征分为 2 组, 分别对其使用 3×3 和 5×5 的非对称卷积, 之后将得到的特征进行整合, 再通过 Conv + BN + Sigmoid 激活函数的组合模块, 最后将输出特征和上面的通道注意力支路得到的输出特征进行相乘操作并输出。该模块只增加了少量的参数, 避免了降维, 可以在显著降低模型复杂度的同时保持性能, 更加有效地捕获跨通道的交互信息。




图3 高效的非对称卷积和通道注意力结合模块

Fig. 3 Efficient asymmetric convolution and channel attention combination module

通道注意力^[11]可以有效地对每个通道的特征图的重要性进行建模,并赋予不同的权重,以达到增强或抑制不同通道的效果。通过将二维全局池化操作分解为 2 个一维编码过程,将任何中间特征张量作为输入并通过转换,输出与张量具有相同尺寸同时具有增强表征的特征,捕获位置信息和通道关系,以增强特征表示。

为了进一步提高性能,ECA 模块保证所有的通道共享权重信息,即使用统一的学习参数。此外,ECA 模块使用内核大小为 k 的一维卷积促进通道间的信息交互,其中,卷积核的大小 k 象征局部特征在通道间交互的覆盖范围。为了恰当地捕获局部特征信息,有必要确定卷积核大小 k 的值。尽管可以对不同 CNN 架构中的卷积块进行手动调整以适应不同数量的通道,但这种做法往往需要消耗大量的计算资源。另一方面,分组卷积已经被证明是一种优化 CNN 架构的有效方法,其中,高维通道与分组数量固定时的长距离卷积成正比。据此推断,在通道数 C 与一维卷积的内核大小 k 之间可能存在一种正比关系,即可能存在映射 ϕ :

$$C = \phi(k) \tag{9}$$

通道数 C 通常被设置为 2 的幂,因此通过将线性函数 $\phi(k) = \gamma k - b$ 扩展到非线性函数,引入一个可能的解,即

$$C = \phi(k) = 2^{(\gamma k - b)} \tag{10}$$

即可得出 k 的大小:

$$k = \phi(C) = \left\lfloor \frac{\log_2(C)}{\gamma} + \frac{b}{\gamma} \right\rfloor_{\text{odd}} \tag{11}$$

式中: $\lfloor \cdot \rfloor_{\text{odd}}$ 表示其最接近的奇数; k 为 3; γ 和 b 分别为 2 和 1。

此外,卷积神经网络结构需要大量的 GPU 资源消耗,在网络设计时需要考虑资源利用的合理性及所用模块的有效性,因此本文引入了非对称卷积^[12]来提升网络的精度和性能,如图 4 所示。非对称卷积通过替换传统的 3×3 卷积核,采用 1 个 3×1 卷积核、1 个 1×3 卷积核以及 1 个 3×3 卷积核的组合,将这 3 个卷积的输出整合成最终的卷积层输出。其中,引入的 1×3 的水平卷积核和 3×1 的竖直卷积核可以提升模型对图像翻转和旋转的鲁棒性。

在本文网络中,不仅使用了 3×1 卷积 + 1×3 卷积 + 3×3 卷积,也使用了 5×1 卷积 + 1×5 卷积 + 5×5 卷积,用不同尺寸的卷积实现对更多特

征信息的提取。非对称卷积模块理论上可以融合无数个卷积层,不断逼近现有网络的效果极限,以实现细化梯度,强化原始网络的特征提取能力,虽然训练时间增加了一点,但是换来了对推理的精度提升。




图 4 多尺度非对称卷积模块

Fig. 4 Multiscale asymmetric convolution module

4 特征提取模块

为了更加有效地利用浅层的纹理信息,使采样过程中丢失的特征在一定程度上得到补充,从而得到更加丰富的特征信息,本文使用 Unet 网络模型对浅层特征进行再次提取,并加入到主支路中进行特征增强,利用低分辨率图像推测最佳目标图,生成相应的超分辨率输出。

Unet 网络模型结构如图 5 所示,采用的是 Encoder-Decoder 结构^[13]。其中,编码部分位于图 5 左侧,用来进行特征提取,由卷积操作和下采样操作组成,下采样可以增加对输入图像一些小扰动的鲁棒性,比如图像旋转、平移等,减少过拟合的风险,降低运算量,增加感受野的大小。图 5 右侧为解码部分,用来进行上采样操作,而上采样的最大作用是逐步减少特征的通道数,把抽象的特征再还原解码到原图的尺寸,最后使用 1×1 卷积得到最终的结果图。图 5 中的 64、128、256、512 分别表示通道数。

网络训练时使用 L1 损失函数,也被称为平均绝对值误差(mean absolute error, MAE),其对离

群点或者异常值有很好的鲁棒性。总的来说,它是把目标值即真实高分辨率遥感图像 y_i 与网络重建出的超分辨率图像 $f(x_i)$ 的绝对差值的总和

最小化,其公式如下:

$$L = \sum_{i=1}^n |y_i - f(x_i)| \quad (12)$$




图 5 Unet 网络结构

Fig. 5 The architecture of Unet

5 实验

5.1 数据集及实验环境

本文所使用的图像来自 AID 和 WHU-RS19 数据集。AID 数据集^[14]由华中科技大学和武汉大学于 2016 年发布,是一个大规模航拍的遥感影像数据集,包含 30 个类别的场景图像,共计 10 000 张,每张图像大小为 600×600 像素。WHU-RS19 数据集^[15]来源于谷歌卫星影像上获取的遥感影像,于 2011 年由武汉大学发布,包含 19 个类别的场景,共计 1 005 张,每张图像大小为 600×600 像素。

本文实验使用 Adam 进行优化,初始学习率为 0.000 2,学习率随着轮数达到 150、250、450 时减半,数据集的批量大小设置为 8,训练轮数为 500 轮。本文采用翻转、旋转、中心剪裁等方式对数据集进行数据增强。本文的实验结果为平均值,所有实验均在 Xeon(R) Platinum 8255C CPU @ 2.50 GHz 平台上借助显存为 11 GiB 的 NVIDIA GeForce RTX 2080Ti、Python3.8 以及 Pytorch 1.7.0 框架完成的。

5.2 实验结果与分析

本文采用常用的超分辨率重建算法的评价指

标,包含峰值信噪比 (peak signal to noise ratio, PSNR) 和结构相似性 (structure similarity index measure, SSIM)。PSNR 计算重建后的图像与原始图像之间的相似性^[16],其公式为

$$R_{\text{PSNR}} = 20 \lg \frac{P_{\text{MAX}}}{\sqrt{E_{\text{MSE}}}} \quad (13)$$

式中: P_{MAX} 是图像的最大可能像素值; E_{MSE} 是重建后的图像 I_{out} 和原始图像 I_{in} 之间的均方误差,计算公式为

$$E_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (I_{\text{out}} - I_{\text{in}})^2 \quad (14)$$

SSIM 对重建后的图像和原始图像之间亮度、对比度、结构进行比较^[17],其计算公式是 3 个属性的加权组合:

$$M_{\text{SSIM}} = [l(x, y)]^\alpha [c(x, y)]^\beta [s(x, y)]^\gamma \quad (15)$$

式中: $l(x, y)$ 、 $c(x, y)$ 、 $s(x, y)$ 分别表示重建后的图像 I_{out} 和原始图像 I_{in} 的亮度、对比度和结构的差异值。

本文采用双三次插值、LGCNet^[18]、VDSR^[19]、PAN^[20]和 ESRGCNN^[9]这 5 种方法作为对比,得到的重建结果见图 6,评价结果见表 1。其中, PSNR 和 SSIM 均是指标值越大,图像质量越好。




图 6 不同方法在测试集不同类别的图像上的重建结果

Fig.6 Reconstruction results of different methods on different types of images in the test set

在数据预处理阶段,由于实验进行的是 4 倍放大倍数的遥感图像超分辨率重建,因此需要对尺寸为 600×600 的 2 个数据集进行双三次下采样(即双三次插值)得到对应的低分辨率图像,大小为 150×150 像素。

图 6 展示了采用不同方法在 AID 测试集上的重建结果。第 1 行和第 2 行是 AID 测试集中的真实高分辨率遥感图像和低分辨率的插值图像,包含 4 种不同类别,分别是汽车、河流、建筑和立

交桥,不同类别图像的信息丰富度不同。可以看出,LGCNet 网络对图像的恢复效果一般,纹理细节还是模糊的,而 VDSR、PAN 和 ESRGCNN 网络在汽车和河流区域恢复效果较好,但是在细节恢复上(如树木和立交桥)效果较差。而本文所提算法在 4 个类别上得到的重建结果比其他方法视觉效果更好,保留了高分辨率图像的细节信息,轮廓边缘的模糊较少,重建后的图像质量更高。

表 1 不同方法在测试集上的重建性能比较

Tab. 1 Comparison of reconstruction performance of different methods on test set								
数据集	放大倍数	评价指标	双三次插值	LGCNet	VDSR	PAN	ESRGCNN	Ours
WHU-RS19	$\times 4$	PSNR/dB	27.90	28.31	28.96	29.14	29.28	29.47
		SSIM	0.723 1	0.728 4	0.763 5	0.770 5	0.776 2	0.782 8
AID	$\times 4$	PSNR/dB	27.30	27.55	28.25	28.43	28.56	28.70
		SSIM	0.702 7	0.703 6	0.736 6	0.742 6	0.748 7	0.753 9

从表 1 可以看出,本文所提方法相较次优方法在 WHU-RS19 测试集上 PSNR 提高了 0.19 dB,SSIM 提高了 0.006 6,在 AID 测试集上 PSNR 提高了 0.14 dB,SSIM 提高了 0.005 2。根据上述量化结果可知,本文所提算法相较其他对比方法,重建效果最好。

为了更好地观察上述几种超分辨率重建方法对低分辨率遥感图像重建的对比结果,使得对比

更加明显和有说服力,图 7 和图 8 分别展示了图 6 中汽车和建筑图像同一区域的原高分辨率图、低分辨率的插值图像和 5 种方法的重建结果的放大处理图。从图 7 和图 8 的结果中可以看出,其他几种方法会存在噪声,并且物体的结构轮廓不够清晰,而本文所提的方法能够重建出更多的空间细节信息和几何结构信息,表达这些图像的轮廓和边缘的像素数目更密集。




图 7 汽车图像同一区域在不同方法上的重建结果的放大细节图

Fig. 7 Comparison of enlarged details of reconstruction results of the same area in the car image by different methods




图 8 建筑图像同一区域在不同方法上的重建结果的放大细节图

Fig. 8 Comparison of enlarged details of reconstruction results of the same area in the building image by different methods

6 结语

本文针对遥感图像获取过程中可能出现失真以及重建细节不清晰等问题,提出了一种基于高效通道注意力的分组卷积特征增强网络模型。首先,设计了分组卷积增强模块来增强低频特征的表达能力,以平衡单帧图像超分辨率的性能和复杂性;其次,引入特征增强模块进行特征提取和增强,更加有效地利用低层的纹理信息,使采样过程中丢失的特征在一定程度上可以得到补充;最后,将高效的通道注意力和非对称卷积模块结合,有效捕获跨通道的交互信息,提升网络推理的精度。经实验证明,本文所提方法在遥感图像超分辨率重建中性能表现良好。

参考文献

[1] 景源, 宫玉莹. 基于深度学习的单幅图像超分辨率重建方法研究[J]. 辽宁大学学报(自然科学版), 2022, 49(3): 225-231.
JING Y, GONG Y Y. Research on super-resolution reconstruction of single image based on deep learning [J]. Journal of Liaoning University (Natural Science Edition), 2022, 49(3): 225-231.

[2] 王睿琪. 图像超分辨率重建综述[J]. 计算机科学与应用, 2024, 14(2): 350-359.
WANG R Q. A review of image super-resolution reconstruction [J]. Computer Science and Applications,

2024, 14(2): 350-359.

[3] 何阳, 黄玮, 王新华, 等. 稀疏阈值的超分辨率图像重建[J]. 中国光学, 2016, 9(5): 532-539.
HE Y, HUANG W, WANG X H, et al. Super-resolution image reconstruction based on sparse threshold [J]. Chinese Optics, 2016, 9(5): 532-539.

[4] 孙旭, 李晓光, 李嘉锋, 等. 基于深度学习的图像超分辨率复原研究进展[J]. 自动化学报, 2017, 43(5): 697-709.
SUN X, LI X G, LI J F, et al. Review on deep learning based image super-resolution restoration algorithms [J]. Acta Automatica Sinica, 2017, 43(5): 697-709.

[5] 吴磊, 吕国强, 薛治天, 等. 基于多尺度递归网络的图像超分辨率重建[J]. 光学学报, 2019, 39(6): 90-97.
WU L, LYU G Q, XUE Z T, et al. Image super-resolution reconstruction based on multi-scale recursive network [J]. Acta Optica Sinica, 2019, 39(6): 90-97.

[6] HAUT J M, PAOLETTI M E, FERNÁNDEZ-BELTRAN R, et al. Remote sensing single-image superresolution based on a deep compendium model [J]. IEEE Geoscience and Remote Sensing Letters, 2019, 16(9): 1432-1436.

[7] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation [C] // International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2015, 9351: 234-241.

- [8] IOANNOU Y, ROBERTSON D, CIPOLLA R, et al. Deep roots: Improving CNN efficiency with hierarchical filter groups[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, HI; IEEE, 2017: 1231-1240.
- [9] TIAN C W, YUAN Y X, ZHANG S S, et al. Image super-resolution with an enhanced group convolutional neural network[J]. Neural Networks, 2022, 153: 373-385.
- [10] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, WA, USA; IEEE, 2020: 11531-11539.
- [11] GUO M H, XU T X, LIU J J, et al. Attention mechanisms in computer vision: A survey[J]. Computational Visual Media, 2022, 8(3): 331-368.
- [12] DING X H, GUO Y C, DING G G, et al. ACNet: Strengthening the kernel skeletons for powerful CNN via asymmetric convolution blocks[C]//2019 IEEE/CVF International Conference on Computer Vision. Seoul, Korea; IEEE, 2019: 1911-1920.
- [13] PARK S H, MOON Y S, CHO N I. Perception-oriented single image super-resolution using optimal objective estimation[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, BC, Canada; IEEE, 2023: 1725-1735.
- [14] XIA G S, HU J W, HU F, et al. AID: A benchmark data set for performance evaluation of aerial scene classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(7): 3965-3981.
- [15] XIA G S, YANG W, DELON J, et al. Structural high-resolution satellite image indexin[C]//ISPRS TC VII Symposium-100 Years. Vienna, Austria; ISPRS, 2010: 298-303.
- [16] SHEIKH H R, SABIR M F, BOVIK A C. A statistical evaluation of recent full reference image quality assessment algorithms[J]. IEEE Transactions on Image Processing, 2006, 15(11): 3440-3451.
- [17] 王宇庆,刘维亚,王勇. 一种基于局部方差和结构相似度的图像质量评价方法[J]. 光电子·激光, 2008, 19(11): 1546-1553.
- WANG Y Q, LIU W Y, WANG Y. Image quality assessment based on local variance and structure similarity[J]. Journal of Optoelectronics · Laser, 2008, 19(11): 1546-1553.
- [18] LEI S, SHI Z W, ZOU Z X. Super-resolution for remote sensing images via local-global combined network[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(8): 1243-1247.
- [19] KIM J, LEE J K, LEE K M. Accurate image super-resolution using very deep convolutional networks[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA; IEEE, 2016: 1646-1654.
- [20] ZHAO H Y, KONG X T, HE J W, et al. Efficient image super-resolution using pixel attention[C]//Computer Vision-ECCV 2020 Workshops. Cham; Springer, 2020: 56-72.

(编辑 李静)