

基于自注意力深度网络的图像超分辨率重建方法

陈子涵¹, 吴浩博^{2*}, 裴浩东^{3**}, 陈榕¹, 胡佳新¹, 时亨通¹

¹深圳供电局有限公司福田供电局, 深圳 518001;

²西安电子科技大学工程学院, 陕西 西安 710071;

³中国科学院上海技术物理研究所中国科学院智能红外感知重点实验室, 上海 200083

摘要 针对现有图像超分辨重建方法难以充分重建图像的细节信息且易出现重建的图像缺乏层次的问题, 提出一种基于自注意力深度网络的图像超分辨重建方法。以深度神经网络为基础, 通过提取低分辨率图像特征, 建立低分辨率图像特征到高分辨率图像特征的非线性映射, 重建高分辨率图像。在进行非线性映射时, 引入自注意力机制, 获取图像中全部像素间的依赖关系, 利用图像的全局特征指导图像重建, 增强图像层次。在训练深度神经网络时, 使用图像像素级损失和感知损失作为损失函数, 以强化网络对图像细节信息的重建能力。在 3 类数据集上的对比测试结果表明, 所提方法能够提升图像超分辨重建结果的细节信息, 且重建图像的视觉效果更好。

关键词 图像处理; 图像超分辨; 自注意力机制; 感知损失; 深度网络; 卷积神经网络

中图分类号 TP391

文献标志码 A

doi: 10.3788/LOP202158.0410013

Image Super-Resolution Reconstruction Method Based on Self-Attention Deep Network

Chen Zihan¹, Wu Haobo^{2*}, Pei Haodong^{3**}, Chen Rong¹, Hu Jiixin¹, Shi Hengtong¹

¹ Futian Power Supply Bureau, Shenzhen Power Supply Bureau Co., Ltd., Shenzhen 518001, China;

² School of Electronic Engineering, Xidian University, Xi'an, Shaanxi 710071, China;

³ Key Laboratory of Intelligent Infrared Perception, Shanghai Institute of Technical Physics,

Chinese Academy of Sciences, Shanghai 200083, China

Abstract It is difficult to fully recover the image details using the existing image super-resolution reconstruction methods. Furthermore, the reconstructed images lack a hierarchy. To address these problems, an image super-resolution reconstruction method based on self-attention deep networks is proposed herein. This method, which is based on deep neural networks, reconstructs a high-resolution image using the features extracted from a corresponding low-resolution image. It nonlinearly maps the features of a low-resolution image to those of a high-resolution image. In the process of nonlinear mapping, the self-attention mechanism is utilized to obtain the dependence among all the pixels in the images, and the global features of the images are used to reconstruct the corresponding high-resolution image, which promotes image hierarchy. During the deep neural network training, a loss function comprising a pixel-wise loss and a perceptual loss is utilized to improve the image-detail reconstruction ability of the neural network. Experiments on three open datasets show that the proposed method outperforms the existing methods in terms of image-detail reconstruction. Furthermore, the visual impression of the reconstructed image is better than that of the images reconstructed using other existing methods.

Key words image processing; image super-resolution; self-attention mechanism; perceptual loss; deep network; convolution neural network

收稿日期: 2020-06-30; 修回日期: 2020-07-23; 录用日期: 2020-08-07

基金项目: 深圳供电局有限公司科技项目(0909002019030103FTPW00064)、中国科学院智能红外感知重点实验室开放课题

* E-mail: haobow@126.com; ** E-mail: peihaodong@sina.com

OCIS codes 100.6640; 100.3010; 060.4256

1 引言

图像超分辨率重建是指从一幅或多幅低分辨率图像中恢复出对应的包含更多纹理细节信息的高分辨率图像的过程。最初的图像超分辨率重建采用基于插值的方法,如最近邻插值、双线性插值、双三次插值等。插值方法思想简单、计算量小,可以有效提升图像的分辨率。但插值方法只是简单地实现像素点的增加,并不考虑图像内容,没有利用图像的先验信息。随后, Yang 等^[1]提出了一种基于稀疏编码的图像超分辨率重建方法,该方法在超分辨率领域获得了广泛关注,认为低分辨率图像经过字典后的稀疏表示系数和对应的高分辨率图像稀疏表示系数应当线性一致,以此来对图像超分辨率重建。该方法通过学习训练数据获得图像的先验知识,提升重建图像的效果,但计算开销较大,同时需要大量的训练样本。除此之外,还有学者提出了许多行之有效的重建方法,如 Freeman 等^[2]基于样本学习理论提出一种基于马尔可夫随机场的重建方法, Chang 等^[3]提出一种基于邻域嵌入的重建算法,该算法将流行学习理论引入到超分辨率领域中。

随着深度学习的兴起,基于深度神经网络的图像超分辨率重建方法得到了越来越多研究者的关注^[4-27]。Dong 等^[4-5]将深度网络应用到图像超分辨率重建中,并提出一种基于卷积神经网络的图像超分辨率(SRCNN)方法。该方法首先对低分辨率图像进行双三次插值到目标分辨率大小,再输入到 CNN 中进行重建,其中 CNN 主要分为 3 部分,分别为低分辨率图像块提取、非线性映射、高分辨率图像重建。依靠神经网络强大的非线性映射能力,该方法得到的超分辨率重建图像效果显著提升。但由于需要先对低分辨率图像进行放大再输入到网络中,降低了网络的计算效率,同时该方法主要依靠卷积操作提取图像的局部特征,无法捕获图像中的全部依赖关系,从而在网络重建过程中未考虑到图像的全局特征,重建图像缺乏层次。随后, Dong 等^[6]又提出一种快速卷积神经网络图像超分辨率(FSRCNN)方法,对 SRCNN 方法进行了改进。该方法使用反卷积层、减小卷积核尺寸等策略来加速模型的计算,并改善重建图像的效果。此外, Johnson 等^[8]从损失函数的角度出发,提出了一种新的感知损失函数,该函数分别通过训练好的 VGG 网络提取生成图像和真实图像的特征,再通过对比特征来衡量生成图像和真实图像间的损失,以此达到增强特征所描述的纹理细节的目的。

2014 年,生成对抗网络(GAN)^[9]的提出为图像生成领域注入了新的活力,通过 GAN 生成的图像更加符合人类视觉感官效果,学者们也开始将 GAN 应用到图像超分辨率重建中^[10-12]。GAN 主要由生成器和判别器 2 部分组成,超分辨率生成对抗网络(SR-GAN)^[10]是 GAN 应用在图像超分辨率中的经典之作。传统图像超分辨率方法通过逐像素方均误差损失来衡量重建图像的质量,而 SRGAN 则通过判别器对重建图像进行判别,生成器和判别器相互对抗优化,使重建图像细节更好。随后, Wang 等^[11]通过引入密集残差块、去除归一化层、采用相对平均判别器对 SRGAN 进行改进,提出一种增强型超分辨率生成对抗网络(ESRGAN),从而得到了更加锐化、质量更好的图像。但同时 GAN 的优化函数是一个最大最小化问题,训练过程中容易出现梯度消失的问题,造成训练不稳定,另一方面,基于 GAN 的图像超分辨率网络均比较复杂、难以训练、不易移植。

近年来,基于空间、通道注意力机制的超分辨率重建受到许多学者的关注^[13-17]。与此同时,与空间、通道注意力机制不同的是,视觉图像领域中的自注意力机制在建模全局依赖关系中表现出良好的性能。自注意力机制^[28]可以建立当前关注的局部位置与图像中全部位置间的依赖关系,即获得图像中所有局部像素间的权重依赖特征图,从而获取图像的全局特征。受到自注意力机制的启发,针对超分辨率重建图像细节信息不足且缺乏层次的问题,本文提出一种基于自注意力机制的深度网络结构(SADeepNet)。首先在深度网络的映射过程中引入多个自注意力层来不断强化当前关注的局部区域位置和图像中所有其他位置间的依赖关系,使重建图像整体和各局部细节更加合理,增强图像层次;引入感知损失和像素方均误差损失两种损失函数来强化网络的细节保持能力。实验结果表明,所提方法能够实现内容更准确、视觉效果更好的图像重建。

2 相关工作

2.1 SRCNN

SRCNN 是一个基于 CNN 的超分辨率重建算法,该算法通过构建一个三层的 CNN 来学习低分辨率图像到高分辨率图像间的映射关系。该算法先将待重建图像插值放大至目标尺寸大小;接着通过第一层卷积核大小为 9×9 的卷积层对低分辨率图像特征块进行特征提取,通过第二层卷积层进行特征的非线性

映射,将低分辨特征映射至高分辨特征;最后通过第三层卷积核大小为 5×5 的卷积层实现高分辨特征重组,得到重建图像。

2.2 FSRCNN

FSRCNN 在 SRCNN 的基础上进行了改进。首先不必对待重建的低分辨图像进行插值放大,而是将其直接输入到网络中,使网络计算在较小的尺寸中进行,减少了计算量。其次,该方法采用了较小的卷积核来提取低分辨图像特征块,接着通过 1×1 卷积对特征图的维度进行压缩,并进行非线性映射,之后再通过 1×1 卷积将特征图扩展回原来的维度。最后,该方法通过反卷积操作来对图像进行上采样。这样不仅提升了网络的运行速度还增强了重建效果。

3 所提方法

3.1 网络结构

提出的 SADeepNet 的整体结构如图 1 所示,




图 1 SADeepNet 的整体结构

Fig. 1 Overall structure of SADeepNet

3.2 自注意力层

自注意力层结构如图 2 所示。自注意力层的输入为网络中上一个卷积层的输出特征图,记为 x 。在自注意力层中,首先输入特征图 x 分别通过 3 个 1×1 卷积和 3 个不同的映射函数 $f(x) = W_f x + b_f$ 、 $g(x) = W_g x + b_g$ 和 $h(x) = W_h x + b_h$,得到三组特征图 $F(x)$ 、 $G(x)$ 和 $H(x)$,计算公式分别为

$$F(x) = W_f x + b_f, \quad (1)$$

$$G(x) = W_g x + b_g, \quad (2)$$

$$H(x) = W_h x + b_h. \quad (3)$$

接着对 $F(x)$ 与转置后的 $G(x)$ 进行矩阵乘法,再通过一个 Softmax 函数得到输入特征图 x 中两两像素间的权重依赖关系,以此来计算 $F(x)$ 和 $G(x)$ 间的相似度,获得注意力特征图 $M(x)$ 。 $M(x)$ 的计算过程可以表示为

$$M_{i',j'}(x) = \frac{\exp [F(x_{i'})^T G(x_{j'})]}{\sum_{j'} \exp [F(x_{i'})^T G(x_{j'})]}, \quad (4)$$

主要由卷积层、池化层及自注意力层组成。图中的 $n64k3p1$, 64 、 3 、 1 分别表示当前卷积层所采用的卷积核个数为 64 、卷积核大小为 3×3 、卷积补 0 个数为 1 ;横纹小块表示卷积层,用 Conv 标注;竖纹小块表示最大池化层,用 pool 标注;网格小块表示含有自注意力机制的自注意力层,用 self-attention 标注。在所提网络中,输入为经过双三次插值得到的 3 通道 RGB 图像,第一个卷积层采用 128 个大小为 9×9 的较大卷积核对输入的低分辨图像进行特征块提取,随后的卷积层均采用 64 个大小为 3×3 的卷积核进行非线性映射,最后一个卷积层采用 3 个大小为 5×5 的卷积核进行超分辨图像的重建。在所提网络结构中,自注意力层连续置于非线性映射过程中的最后三个卷积层之后,以获取图像的全局特征,使得生成图像的每个局部像素点与图像的全部像素点都产生依赖关系。

式中: $M_{i',j'}(x)$ 为 $F(x)$ 中第 i' 个元素和 $G(x)$ 中第 j' 个元素间的相似度。随后对 $H(x)$ 与注意力特征图 $M(x)$ 进行矩阵乘法,其结果经 $v(x) = W_v x + b_v$ 映射后,与自注意力层输入 x 拼接,得到自注意力层的输出 $O(x)$ 。其计算过程为

$$O(x) = W_v [H(x)M(x)] + b_v + x. \quad (5)$$

通过对自注意力层的分析可知,自注意力机制能捕获到图像中任意两个像素点间的依赖关系,因此可以在图像重建过程中引入全局特征,增强重建图像中局部区域的层次感,提升重建图像的质量,使得整个图像的视觉效果更好。

3.3 损失函数

所提方法所采用的损失函数表达式为

$$L = \alpha L_{mse} + \beta L_p, \quad (6)$$

式中: L 为总的损失函数; L_{mse} 为图像的像素级损失函数; L_p 为图像的感知损失; α 、 β 分别为不同损

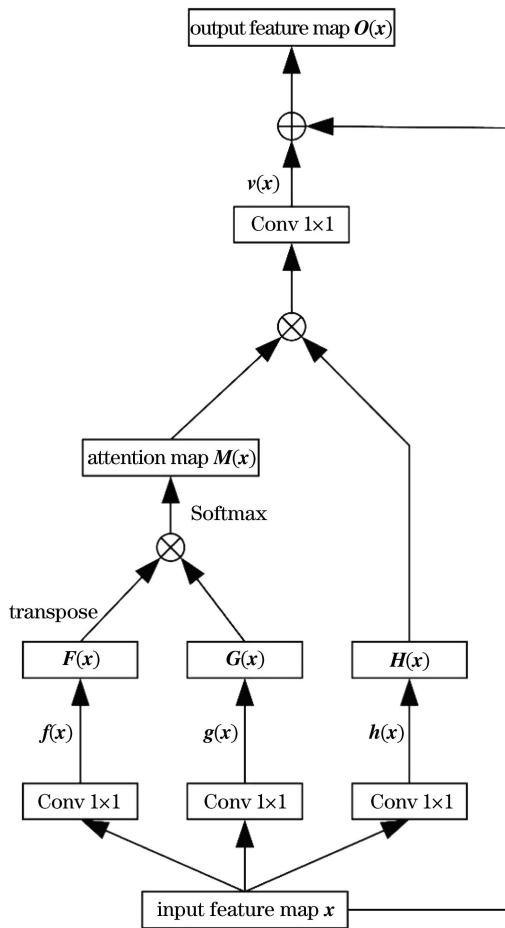


图 2 自注意力层结构

Fig. 2 Structure of self-attention layer

失对应的权重大小。

1) 图像像素级损失, 即重建图像 \mathbf{Y}' 和真实高分辨率图像 \mathbf{Y} 对应像素点的方均差。图像的像素级损失 L_{mse} 可以表示为

$$L_{\text{mse}}(\mathbf{Y}', \mathbf{Y}) = \frac{1}{WH} \sum_{i=1}^W \sum_{j=1}^H (\mathbf{Y}'_{i,j} - \mathbf{Y}_{i,j})^2, \quad (7)$$

式中: $\mathbf{Y}'_{i,j}$ 和 $\mathbf{Y}_{i,j}$ 分别为重建图像和真实高分辨图像中 (i, j) 处的像素值; W 、 H 分别为高分辨图像的宽度和高度。

2) 感知损失: 通过卷积网络分别对重建图像 \mathbf{Y}' 和真实高分辨图像 \mathbf{Y} 提取一组特征, 要求这两组特征尽可能相似, 同样采用方均误差来衡量对应特征的相似度。感知损失^[8]能获得图像感知和语义上的差距, 从而增强图像的纹理细节信息。采用 VGG-19 网络^[29]作为提取图像特征的卷积网络, 将全连接层之前的最后一个卷积层的输出作为特征, 用 $\varphi_{5,4}$ 表示该输出特征。则感知损失 L_p 可以表示为

$$L_p = \frac{1}{WH} \sum_{i=1}^W \sum_{j=1}^H [\varphi_{5,4}(\mathbf{Y}'_{i,j}) - \varphi_{5,4}(\mathbf{Y}_{i,j})]^2. \quad (8)$$

4 实验结果及分析

4.1 数据集介绍

从用于 ImageNet 竞赛的 ILSVRC2012 大型图像分类数据集中选取了 3 类数据作为本次实验数据, 分别为飞机 (Plane)、椅子 (Chair) 和蝴蝶 (Butterfly), 每个类别均有 1300 张图像, 对每个类别都进行放大倍数为 $\times 2$ 和 $\times 3$ 的两组实验。对于 $\times 2$ 实验, 首先对 1300 张图像进行双三次插值得到 128×128 大小图像, 选取其中的 1000 张图像作为训练图像, 对剩余的 300 张图像再次插值到 64×64 大小作为低分辨测试图像。对于 $\times 3$ 实验, 首先对 1300 张图像进行双三次插值得到 126×126 大小图像, 选取其中的 1000 张图像作为训练图像, 对剩余的 300 张图像再次插值到 42×42 大小作为低分辨测试图像。

4.2 实验环境及参数配置

分别对 3 类数据集各进行 $\times 2$ 和 $\times 3$ 两种放大倍数处理共计 6 组实验。本实验在训练过程中的更新次数为 300 轮。训练时采用 Adam 优化器对网络的权重参数进行更新, 更新过程中初始学习率设置为 0.002, 指数衰减率设置为 $\beta_1 = 0.5, \beta_2 = 0.9$ 。对不同损失函数的权重进行多次尝试, 得到最优的权重为 $\alpha = 10, \beta = 1$ 。

在训练过程中, 会对 1000 张训练图像进行随机小块截取, 截取的小块大小为 65×65 , 每张图像截取 16 个小块, 共有 16000 个小块, 这些小块组成了训练集中的高分辨图像, 对这些小块进行下采样得到训练集中的低分辨图像。网络中的第一个卷积层和最后一个卷积层均不进行填充补 0 处理, 因此在训练过程中从输入到输出, 图像尺寸会减小。在测试过程中, 第一个卷积层和最后一个卷积层均进行填充补 0 处理, 因此在测试过程中不会影响输出图像的大小。

采用的硬件平台处理器为 Intel[®] Core i7-8700 CPU, 主频为 3.2GHz, 内存大小为 32GB, 显卡型号为 GeForce RTX 2080。软件平台为 Ubuntu 18.04, 所采用的编程语言为 Python 3.6, 在神经网络编程中采用目前比较流行的 Pytorch 库。

4.3 实验结果分析

对所提 SADeepNet、Bicubic 插值方法、SRCNN、FSRCNN 的性能进行对比, 主要从图像的

视觉效果和客观评价指标两方面对实验结果进行分析。其中,采用的客观评价指标包括:峰值信噪比(PSNR)衡量参考图像与重建图像之间的像素相似性;结构相似性(SSIM)^[30]从亮度、对比度及结构三个方面对重建图像进行评价。

图 3 展示了放大倍数为 $\times 2$ 时,飞机数据集中一张图像通过不同方法得到的重建结果。可以看出:与 Bicubic、SRCNN、FSRCNN 的重建结果相比,SADeepNet 得到的重建图像中飞机轮廓更加清

晰,且飞机的后轮、机翼都更加接近真实高分辨图像,边缘结构层次更好。整体来看,SADeepNet 得到的重建结果纹理细节信息丰富,整体图像视觉效果更好。

图 4 展示了放大倍数为 $\times 2$ 时,椅子数据集中一张图像通过不同方法得到的重建结果。与其他方法相比,SADeepNet 方法得到的图像中椅子更加清晰,视觉效果更好,重建出了更多的细节纹理,图像的层次更加合理。



图 3 不同方法重建的飞机图像。(a)经放大显示的低分辨输入图像;(b)Bicubic;(c)SRCNN;(d)FSRCNN;(e)SADeepNet;(f)真实高分辨图像

Fig. 3 Plane images reconstructed by different methods. (a) Low-resolution input image with enlarged display; (b) Bicubic; (c) SRCNN; (d) FSRCNN; (e) SADeepNet; (f) high-resolution original image




图 4 不同方法重建的椅子图像。(a)经放大显示的低分辨输入图像;(b)Bicubic;(c)SRCNN;(d)FSRCNN;(e)SADeepNet;(f)真实高分辨图像

Fig. 4 Chair images reconstructed by different methods. (a) Low-resolution input image with enlarged display; (b) Bicubic; (c) SRCNN; (d) FSRCNN; (e) SADeepNet; (f) high-resolution original image

图 5 展示了放大倍数为 $\times 3$ 时, 蝴蝶数据集中一张图像通过不同方法得到的重建结果。可以看出, 与其他方法相比, SADeepNet 能对蝴蝶的边缘进行增强, 特别是翅膀细节部分更加接近高分辨原图, 重建图像的层次更加合理。

表 1、2 分别展示了 3 类数据集在不同放大倍数

下的 PSNR 和 SSIM 对比。通过对比可以发现: Bicubic 方法得到的结果最差; SADeepNet 在不同数据和不同放大倍数下均超越了其他对比方法, 各项指标均有不同程度的提升。这进一步证明, 所提方法对重建结果有提升作用。



图 5 不同方法重建的蝴蝶图像。(a)经放大显示的低分辨率输入图像;(b)Bicubic;(c)SRCNN;(d)FSRCNN;(e)SADeepNet;(f)真实高分辨图像

Fig. 5 Butterfly images reconstructed by different methods. (a) Low-resolution input image with enlarged display; (b) Bicubic; (c) SRCNN; (d) FSRCNN; (e) SADeepNet; (f) high-resolution original image

表 1 不同方法的 PSNR 对比

Table 1 PSNR comparison of different methods unit: dB

Dataset	Bicubic	SRCNN	FSRCNN	SADeepNet
Plane($\times 2$)	19.99	21.16	21.37	22.10
Plane($\times 3$)	18.39	19.21	20.08	21.22
Chair($\times 2$)	18.40	18.55	18.96	19.67
Chair($\times 3$)	17.32	17.92	18.04	18.46
Butterfly($\times 2$)	16.38	16.81	17.13	17.91
Butterfly($\times 3$)	16.23	16.72	17.07	17.75

表 2 不同方法的 SSIM 对比

Table 2 SSIM comparison of different methods

Dataset	Bicubic	SRCNN	FSRCNN	SADeepNet
Plane($\times 2$)	0.66	0.70	0.71	0.73
Plane($\times 3$)	0.62	0.64	0.66	0.69
Chair($\times 2$)	0.55	0.57	0.59	0.63
Chair($\times 3$)	0.52	0.52	0.55	0.58
Butterfly($\times 2$)	0.56	0.57	0.59	0.64
Butterfly($\times 3$)	0.53	0.55	0.58	0.60

5 结 论

针对现有超分辨率方法重建的图像缺乏细节信息和结构层次的问题,提出了一种基于自注意力机制的神经网络 SADeepNet。该方法在非线形映射时强化局部位置与图像中所有位置间的依赖关系,以此在重建过程中引入图像的全局特征,增强图像层次。同时在训练时,联合使用基于 VGG 网络的感知损失和图像的像素级误差损失,强化网络对图像细节信息重建能力。ImageNet 数据集中飞机、椅子、蝴蝶 3 类数据集上的 6 组对比实验表明,相比于插值方法、SRCNN、FSRCNN,所提方法不仅在客观评价指标 PSNR 和 SSIM 上有所提高,且在图像视觉效果上也有较大提升。下一步,将结合深度网络特性继续对自注意力机制在网络中的应用进行研究,以提高深度网络的超分辨率重建性能。

参 考 文 献

- [1] Yang J C, Wright J, Huang T S, et al. Image super-resolution via sparse representation [J]. IEEE Transactions on Image Processing, 2010, 19(11): 2861-2873.
- [2] Freeman W T, Jones T R, Pasztor E C. Example-based super-resolution [J]. IEEE Computer Graphics and Applications, 2002, 22(2): 56-65.
- [3] 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, June 27 - July 2, 2004, Washington, DC, USA. New York: IEEE Press, 2004.
- [4] Dong C, Loy C C, He K M, et al. Learning a deep convolutional network for image super-resolution [M] // Fleet D, Pajdla T, Schiele B, et al. Computer vision-ECCV 2014. Lecture notes in computer science. Cham: Springer, 2014, 8692: 184-199.
- [5] 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.
- [6] Dong C, Loy C C, Tang X O. Accelerating the super-resolution convolutional neural network [M] // Leibe B, Matas J, Sebe N, et al. Computer vision - ECCV 2016. Lecture notes in computer science. Cham: Springer, 2016, 9906: 391-407.
- [7] 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] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 1874-1883.
- [8] Johnson J, Alahi A, Li F F. Perceptual losses for real-time style transfer and super-resolution [M] // Leibe B, Matas J, Sebe N, et al. Computer vision - ECCV 2016. Lecture notes in computer science. Cham: Springer, 2016, 9906: 694-711.
- [9] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets [C] // Proceedings of the 27th International Conference on Neural Information Processing Systems, December 8-13, 2014, Montreal, Quebec, Canada. New York: Curran Associates, 2014, 2: 2672-2680.
- [10] Ledig C, Theis L, Huszár F, et al. Photo-realistic single image super-resolution using a generative adversarial network [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 105-114.
- [11] Wang X T, Yu K, Wu S X, et al. ESRGAN: enhanced super-resolution generative adversarial networks [M] // Leal-Taixé L, Roth S. Computer vision-ECCV 2018 workshops. Lecture notes in computer science. Cham: Springer, 2019, 11133: 63-79.
- [12] Yuan P Y, Zhang Y P. Imagesuper-resolution reconstruction method using dual discriminator based on generative adversarial networks [J]. Laser & Optoelectronics Progress, 2019, 56(23): 231010. 袁飘逸, 张亚萍. 双判别器生成对抗网络图像的超分辨率重建方法 [J]. 激光与光电子学进展, 2019, 56(23): 231010.
- [13] Lu Y, Zhou Y, Jiang Z Q, et al. Channel attention and multi-level features fusion for single image super-resolution [C] // 2018 IEEE Visual Communications and Image Processing (VCIP), December 9-12, 2018, Taichung, Taiwan, China. New York: IEEE Press, 2018.
- [14] Liu Y, Wang Y C, Li N, et al. An attention-based approach for single image super resolution [C] // 2018 24th International Conference on Pattern Recognition (ICPR), August 20-24, 2018, Beijing, China. New York: IEEE Press, 2018: 2777-2784.
- [15] Zhang Y L, Li K P, Li K, et al. Image super-resolution using very deep residual channel attention

- networks[M]//Ferrari V, Hebert M, Sminchisescu C, et al. Computer vision - ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11211: 294-310.
- [16] Xi Z H, Yuan K P. Super-resolution image reconstruction based on residual channel attention and multilevel feature fusion[J]. Laser & Optoelectronics Progress, 2020, 57(4): 041504.
席志红, 袁昆鹏. 基于残差通道注意力和多级特征融合的图像超分辨率重建[J]. 激光与光电子学进展, 2020, 57(4): 041504.
- [17] Liu K W, Ma Y, Xiong H X, et al. Medical-image super-resolution reconstruction method based on residual channel attention network [J]. Laser & Optoelectronics Progress, 2020, 57(2): 021014.
刘可文, 马圆, 熊红霞, 等. 基于残差通道注意力网络的医学图像超分辨率重建方法[J]. 激光与光电子学进展, 2020, 57(2): 021014.
- [18] Shocher A, Cohen N, Irani M. Zero-shot super-resolution using deep internal learning [C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 3118-3126.
- [19] Bulat A, Yang J, Tzimiropoulos G. To learn image super-resolution, use a GAN to learn how to do image degradation first[M]//Ferrari V, Hebert M, Sminchisescu C, et al. Computer vision - ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11210: 187-202.
- [20] Yuan Y, Liu S Y, Zhang J W, et al. Unsupervised image super-resolution using cycle-in-cycle generative adversarial networks [C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), June 18-22, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 814-823.
- [21] Haris M, Shakhnarovich G, Ukita N. Deep back-projection networks for super-resolution [C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 1664-1673.
- [22] Lai W S, Huang J B, Ahuja N, et al. Fast and accurate image super-resolution with deep laplacian pyramid networks[EB/OL]. (2018-08-09)[2020-05-29]. <https://arxiv.org/abs/1710.01992>.
- [23] Hu S Y, Wang G D, Zhao Y, et al. Image super-resolution network based on dense connection and squeeze module [J]. Laser & Optoelectronics Progress, 2019, 56(20): 201005.
胡诗语, 王国栋, 赵毅, 等. 基于密集连接与激励模块的图像超分辨率网络[J]. 激光与光电子学进展, 2019, 56(20): 201005.
- [24] Chen Y, Tai Y, Liu X M, et al. FSRNet: end-to-end learning face super-resolution with facial priors[C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 2492-2501.
- [25] Kim J, Lee J K, Lee K M. Deeply-recursive convolutional network for image super-resolution[C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 1637-1645.
- [26] Li J C, Fang F M, Mei K F, et al. Multi-scale residual network for image super-resolution [M] // Ferrari V, Hebert M, Sminchisescu C, et al. Computer vision - ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11212: 527-542.
- [27] Zhang Y L, Tian Y P, Kong Y, et al. Residual dense network for image super-resolution[C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 2472-2481.
- [28] Wang X L, Girshick R, Gupta A, et al. Non-local neural networks[C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 7794-7803.
- [29] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2015-04-10)[2020-05-29]. <https://arxiv.org/abs/1409.1556>.
- [30] Ye Y X, Shan J, Bruzzone L, et al. Robust registration of multimodal remote sensing images based on structural similarity[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(5): 2941-2958.