

融合边缘特征和对抗网络的遥感影像超分辨率重建方法

李景文 陈文达 姜建武*

(广西空间信息与测绘重点实验室 广西 桂林 541004)

(桂林理工大学测绘地理信息学院 广西 桂林 541004)

摘要 遥感影像中含有较为丰富的高频信息,但受硬件设备限制和外界环境干扰,高频信息边缘部分较为模糊,影响遥感影像的空间分辨率质量。针对这一问题提出一种基于边缘检测和密集残差的遥感影像超分辨率重建方法。该方法利用边缘检测算子提取影像边缘细节特征,采用密集残差模块代残差网络复用底层特征,并将每一层的特征图进行加权融合,最后通过生成器完成遥感影像的超分辨率重构,实现遥感影像分辨率质量的提高。实验结果表明,该算法指标优于传统的双三次插值、SRCNN、VDSR 和 SRGAN,为遥感影像重建提供新的解决方法与技术思路。

关键词 遥感影像 超分辨率重建 生成对抗网络 边缘特征

中图分类号 TP391.4

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2023.02.038

REMOTE SENSING IMAGE SUPER-RESOLUTION RECONSTRUCTION METHOD COMBINING EDGE FEATURES AND ADVERSARIAL NETWORKS

Li Jingwen Chen Wenda Jiang Jianwu*

(Guangxi Key Laboratory of Spatial Information and Surveying, Guilin 541004, Guangxi, China)

(College of Geomatics, Guilin University of Technology, Guilin 541004, Guangxi, China)

Abstract Remote sensing images contain rich high-frequency information, but due to hardware limitations and external environmental interference, the edge of high-frequency information is blurred, which affects the spatial resolution quality of remote sensing images. Aiming at this problem, this paper proposes a remote sensing images super-resolution reconstruction method based on edge detection and dense residuals. This method used edge detection operators to extract image edge detail features, adopted dense residual module to replace the residual network to multiplex the underlying features, and weighted and fused the feature maps of each layer. The super-resolution of the remote sensing image was completed by the generator. It realized the improvement of the resolution quality of remote sensing images. The experimental results show that the index of the proposed method is superior to the traditional bicubic interpolation, SRCNN, VDSR and SRGAN. It provides a new solution and technical ideas for the reconstruction of remote sensing images.

Keywords Remote sensing image Super-resolution reconstruction Generative adversarial network Edge feature

0 引言

高质量的高分辨率遥感影像^[1]广泛应用于遥感测绘、侦察监视^[2]和公共安全监控识别^[3]等军民领域,然而实际条件下获取到的遥感影像通常会受到大气扰

动、系统噪声、相对运动及光学系统相差^[4]等因素的影响,引起图像的高频信息边缘模糊和空间分辨率的降低,无法满足实际对高质量的遥感影像的需要。目前提高遥感影像质量的主要途径有改良卫星的硬件设备和基于算法的图像处理,但改良卫星的硬件设备成本高昂,耗费时间长,因此利用超分辨率重建(super-reso-

lution, SR) 算法提高和恢复遥感影像分辨率已成为学者们研究的热点方向之一^[5]。基于生成对抗网络^[6-7]的图像超分辨率重建算法 (SRGAN) 是目前提升图像质量的主流算法之一, SRGAN 利用感知损失 (perceptual loss) 和对抗损失 (adversarial loss) 来提升图片的真实感。SRCNN^[8] 相比于深度卷积网络提高了图像超分辨率重建的速度和准确度, 可以通过更改网络模型结构或加入先验信息^[7] 来提高算法性能^[10-12]。由于遥感影像相比普通图像包含更丰富的空间细节信息和更多的目标边缘结构, 因此本文利用生成对抗网络对遥感影像进行超分辨率重建, 结合预处理的边缘检测^[13] 算子和分层特征融合的密集残差^[14] 结构进一步改进超分辨率算法, 通过多路径分层特征融合结构提取并复用边缘细节特征, 并采用输入图像作为先验特征, 使得训练出模型对图像退化机理的认知更贴近于现实场景, 解决了通过算法提高遥感影像空间分辨率质量的问题。

1 基于 SRGAN 与边缘特征的超分辨率重建算法

图像边缘是指相邻区域像素的集合, 包含不同灰度值的不同区域之间的灰度分割线, 遥感影像的边缘包含着大量高频信息, 是遥感图像特征判断和提取的重要依据。本文通过生成对抗网络完成遥感影像的超分辨率重建, 利用检测影像梯度边缘上的变化特性来增强影像的特征信息, 采用密集残差的方法减少网络参数加强高频信息的利用以提高重建影像质量, 主要包括基于 GAN 的重建、密集残差网络学习和边缘算子检测等三个核心过程。

1.1 基于 GAN 的重建过程

基于生成对抗网络的超分辨率重建算法由生成器网络 (Generator Network) 和判别器网络 (Discriminator Network) 两部分组成。其思路是: ① 通过生成器 G 学习训练集样本数据的分布, 将输入样本转化为真实训练集数据类似的样本。② 用判别器 D 判断样本真实概率, 判别器 D 是一个二分类模型, 其输入为生成器 G 的输出和真实样本。③ 在网络目标函数的指导下, 生成器超参数 θ_g 和判别器超参数 θ_d 在对抗中联合优化训练, 使判别器 D 无法判断生成器 G 的输出结果, 即最大化判别器 D 为训练数据和生成器 G 生成的假样本提供的正确标签概率。目标函数定义为:

$$\min_G \max_D V(D, G) = E_{x \sim p_{data}(x)} [\log D(x)] + E_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (1)$$

式中: x 表示真实样本; z 表示输入生成器 G 的图像; $G(z)$ 表示生成器 G 生成的图像; $D(x)$ 表示判别器 D 判断真实样本是否真实的概率, 而 $D(G(z))$ 是判别器 D 判断生成器 G 生成的图片的真实的概率。④ 通过损失函数计算生成样本和真实样本之间的误差反向传播更新网络参数。SRGAN 将感知损失 l_X^{SR} 定义为内容损失 l_X^{SR} (content loss) 和对抗损失 l_{Gen}^{SR} (adversarial loss) 的加权和。通过比较生成图片经过卷积神经网络后的特征和目标图片经过卷积神经网络后的特征的差别, 使生成图片和目标图片在语义和风格上更相似。加权和公式为:

$$l^{SR} = l_X^{SR} + 10^{-3} l_{Gen}^{SR} \quad (2)$$

内容损失函数为 VGG 特征间的欧氏距离, $\phi_{i,j}$ 表示提取的为第 i 最大池化层前的第 j 卷积层的特征, $W_{i,j}$ 和 $H_{i,j}$ 为提取出的特征层的维度。

$$l_{VGG/i,j}^{SR} = \frac{1}{W_{i,j} H_{i,j}} \sum_{x=1}^{W_{i,j}} \sum_{y=1}^{H_{i,j}} (\phi_{i,j}(I^{HR})_{x,y} - \phi_{i,j}(G_{\theta_G}(I^{LR}))_{x,y})^2 \quad (3)$$

对抗损失函数是基于判别器输出的概率, 其中: D_{θ_D} 代表影像属于真实高分率的概率; $G_{\theta_G}(I^{LR})$ 代表重建后的高清影像。

$$l_{Gen}^{SR} = \sum_{n=1}^N -\log D_{\theta_D}(G_{\theta_G}(I^{LR})) \quad (4)$$

1.2 密集残差网络

传统生成对抗网络中的生成器 G 包含多个残差块^[15], 每个残差块中包含两个 3×3 的卷积层, 卷积层之后是批规范化层 (batch normalization, BN) 和 PReLU 激活函数。但随着网络模型层数的加深, 每个卷积层中的特征将具有不同层级的感受野, 无法充分利用每层的信息。

因此本文通过对残差网络进行更深层次的融合来充分利用原始图像的所有分层特征, 即密集残差网络。密集残差网络由多个密集残差块 (RDB) 组成, 密集残差块由多个卷积层和激活层组成, 通过局部特征融合来学习到当前层和先前层中更有效特征。




图1 密集残差网络

图中 F_{d-1} 和 F_d 为第 d 个密集残差块的输入和输出, 第 c 个卷积层的输出表示为式(5), 其中 $H(\cdot)$ 表示了每一层的卷积及激活函数操作。

$$F_{d,c} = H(F_{d,1}, F_{d,2}, \dots, F_{d,c-1}) \quad (5)$$

最终通过 1×1 的卷积操作对最后的特征图进行压

缩得到 $F_{d,lr}$, 最终的输出表达为 $F_d = F_{d,c} + F_{d,lr}$, 通过密集残差网络自适应地保存信息来提取局部密集特征。

1.3 边缘算子检测过程

图像边缘是图像灰度或结构等信息的突变处, 体现了局部特性的不连续性。它存在于目标与背景、目标与目标、区域与区域、基元与基元之间。

边缘检测提取原始影像中不连续部分的特征, 将闭合的边缘提取出来作为一个区域, 以边缘信息为约束条件对影像进行超分辨率重建。Prewitt 算子是一种一阶微分算子的边缘检测, 利用像素邻点的灰度差, 在边缘处达到极值, 在图像空间两个方向模板与图像进行卷积, 分别检测水平边缘和垂直边缘。其图像 $f(x, y)$ 公式如下:

$$G(i) = \begin{vmatrix} [f(i-1, j-1) + f(i-1, j) + f(i-1, j+1)] \\ -[f(i+1, j-1) + f(i+1, j) + f(i+1, j+1)] \end{vmatrix} \quad (6)$$

$$G(j) = \begin{vmatrix} [f(i-1, j+1) + f(i, j+1) + f(i+1, j+1)] \\ -[f(i-1, j-1) + f(i, j-1) + f(i+1, j-1)] \end{vmatrix} \quad (7)$$

像素点 (x, y) 的梯度为:

$$G(x, y) = \max\{|G(i)|, |G(j)|\} \quad (8)$$

2 改进方法的具体步骤

基于改进边缘检测和生成对抗网络是影像超分辨率重建分为以下两个步骤:(1) 生成器学习阶段, 在训练样本中, 将输入影像的分层特征进行加权融合, 最后通过上采样得到超分辨率影像。(2) 判别器判别阶段, 通过卷积神经网络分别提取生成影像与真实样本的特征来判断真伪。算法整体流程如图 2 所示。

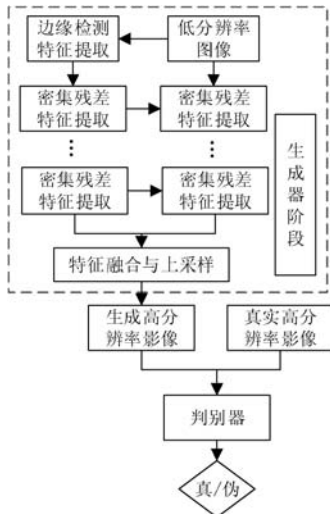


图2 算法流程

2.1 生成器学习阶段

在生成器学习阶段, 本文采用双通道加权融合的方案取代传统的单通道模型, 进一步利用到边缘检测

获取到的高频细节特征。其网络结构如图 3 所示。




图3 改进算法模型

生成器的网络结构分为主线 and 支线两层, 在支路上对输入的低分辨率影像 LR 进行边缘特征检测, 再将经过卷积层和激活函数的特征图进行第一步加权融合。主线第一阶段的输出 $L_{1,1}^{sr}$ 定义为:

$$L_{1,1}^{sr} = \sigma(L_0^{LR}) + \mu\sigma_1(L_0^{LR}) \quad (9)$$

式中: $L_{1,1}^{sr}$ 为主线第一个模块的输出; L_0^{LR} 为输入的低分辨率影像; σ 为包括卷积和 PReLU 激活函数; σ_1 包括边缘检测算子、卷积和 PReLU 激活函数。PReLU 定义为:

$$PReLU(x_i) = \begin{cases} x_i & x_i > 0 \\ a_i x_i & x_i \leq 0 \end{cases} \quad (10)$$

密集残差模块 (RDB) 分别在线上和支线上自适应的学习先前的有效特征, 稳定的网络训练将形成连续记忆机制。通过加权融合主线上每一个 RDB 模块不仅学习到先前的信息, 还融合了所有支线层的边缘信息特征。

$$L_{1,n}^{sr} = \sum_{i=1}^{n-1} F(L_{1,i}^{sr}) + \mu_n F(L_{2,i}^{sr}) \quad (11)$$

式中: $L_{1,n}^{sr}$ 为主线第 n 个模块的输出; $L_{2,n}^{sr}$ 为支线上第 n 个模块的输出; $F()$ 为上文提到的 RDB 模块学习; μ_n 为比例系数。对于每一个主线上的密集残差块的输出 $L_{1,n}^{sr}$ 都通过局部特征融合获得了所有之前密集残差块 $L_{1,i}^{sr}$ 和当前支线上的密集残差块 $L_{2,i}^{sr}$ 的特征信息, 因此该方法充分利用了所有层累积的特征信息。

在 7 个密集残差模块后网络合并为一层, 特征图经过 1×1 的卷积后空间维度降低, 上采样模块通过亚像素卷积层对特征图进行上采样, 得到重建后的超分辨率影像。最终生成器网络由式 (12) 求解, $L_{1,i,n}^{sr}$ 代表第 n 幅图片在主线上第 i 层的输出特征图, $G()$ 包含了整个上采样操作。

$$\hat{\theta}_g = \operatorname{argmin}_{\theta_g} \frac{1}{N} \sum_{n=1}^N L^{SR} G\left(\sum_{i=1}^7 F(\mu_n L_{2,i,n}^{sr} + L_{1,i,n}^{sr})\right) \quad (12)$$

该部分的关键代码如算法 1 所示。

算法 1 特征提取关键代码

kernelx, kernely 为边缘检测算子; img 为 DataLoader 加载的数据集

```
def edge_enhance(img):
    n = img.shape[0]
    imgs = img
    for i in range(n):
```

```

img = imgs[i:i + 1, :, :, :] #读取指定的维度
img = img.squeeze(0) #去掉第零维
grayImage = img.cpu().numpy()
img = np.transpose(img, (1,2,0)) #调换数组索引
grayImage = np.transpose(grayImage, (1,2,0))
(x, y) = cv2.filter2D(grayImage, cv2.CV_16S, (kernelx,
kernely)) #卷积
(absX,absY) = cv2.convertScaleAbs(x,y) #转 uint8
Prewitt = cv2.addWeighted(absX,0.5,absY,0.5,0)
Prewitt = np.expand_dims(Prewitt,axis = 2) #添加第二维
(R,G,B) = img[:, :, (0,1,2)]
(R1,G1,B1) = Prewitt[:, :, (0,1,2)]
(L,L1) = 0.2126 * (R,R1) + 0.7152 * (G,G1) + 0.0722 *
(B,B1)
#转 RGB 三通道
(Rratio,Gratio,Bratio) = (R,G,B) * (1/L)
(R2,G2,B2) = (Rratio,Gratio,Bratio) * L1
Prewitt = np.dstack((R2,G2,B2)) #叠加矩阵
Prewitt = cv2.add(Prewitt,img)
Prewitt = np.transpose(Prewitt, (2,0,1))
Prewitt = Prewitt.unsqueeze(0) #得到边缘特征图
if (i == 0):
    out = Prewitt
else:
    out = torch.cat((out,Prewitt),0) #叠加检测的特征图
return out
    
```

2.2 判定器检测阶段

判定器主要是用于二分类检测,用于判别生成图像与原图像的真伪属性。其网络结构如图 4 所示,其中包含步长为 2 和 1 的卷积层。除第一个卷积层之外,每个卷积层之后通过批量规范化(Batch Normalization)加快了模型收敛速度。在 6 个密集连接块(DDB)之后网络通过全连接层和 Sigmoid 激活函数完成对图像真伪的判别。




图 4 判别器模型

优化后的模型中不再包含 BN 层,因此可以使用 Wasserstein 距离去衡量生成数据分布和真实数据分布之间的距离,并通过每个训练样本添加单独的梯度来缓解遇到的梯度爆炸和梯度消失问题,最终网络目

标函数的表达如下:

$$L = -E_{x \sim p_r} [D(x)] + E_{x \sim p_g} [D(x)] + \lambda E_{x \sim p_g} [\| \nabla_x D(x) \|_p - 1]^2 \quad (13)$$

3 实验结果与分析

实验环境为 Google Colaboratory 平台,Ubuntu16 系统,内存为 60 GB,显卡为 Tesla K80,显存 12 GB,编程语言为 Python 3.6,由 PyTorch 1.0 框架与 CUDA10.1 架构完成算法。

实验数据集 A、B、C 共包含 1 万幅 2018 年 Google Earth 高分辨率多光谱(RGB)遥感影像,影像来源于 Maxar Technologies 并包含整个桂林市,整体分辨率为 0.14 米/像素,单幅影像分辨率为 400 × 400。

为了评价本文方法的重建效果,对高分辨率遥感影像的 RGB 三通道图像进行下采样操作获得低分辨率数据集,进行 4 倍采样下的超分辨率重建实验。

3.1 主观对比分析

本实验采用 VGG19^[16] 模型作为初始化模型。训练过程中,生成器和判别器交替训练,batch_size 为 128,学习率为 0.000 2,epochs 为 300,Total Variation loss 权重为 2e - 8,adversarial loss 权重为 0.001,perception loss 权重为 0.006,分层融合系数为 0.01,总融合系数为 1,训练时长为 24 小时。

图 5 - 图 7 为 4 倍采样下的不同影像在不同算法下的超分辨率重建效果图。从不同重建方法的视觉效果可以看出,双三次插值法重建的图像各方面都较为模糊,SRGAN 好于双三次插值但难以恢复细节特征,SRGAN 可以恢复部分纹理细节,但影像边缘仍存在模糊的现象。而经过本文改进后的算法,重建影像在边缘区域有较大改进,不仅具有较高对比度,而且增强了轮廓和细节,可以看出影像的高频信息得到了更好的保存。

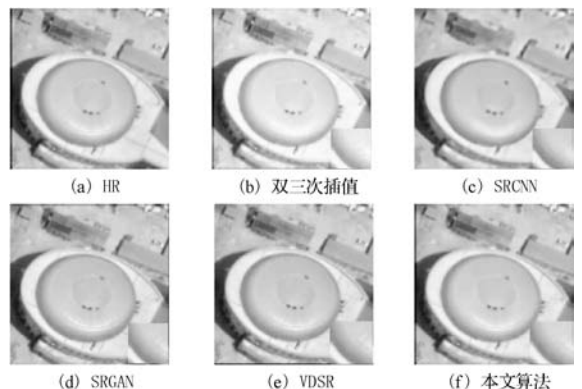


图 5 不同算法下的影像超分辨率重建效果

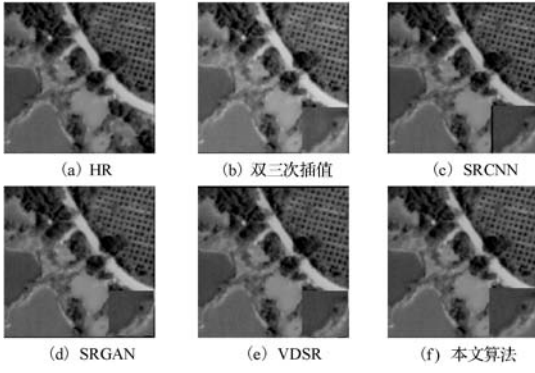


图6 不同算法下的影像超分辨率重建效果

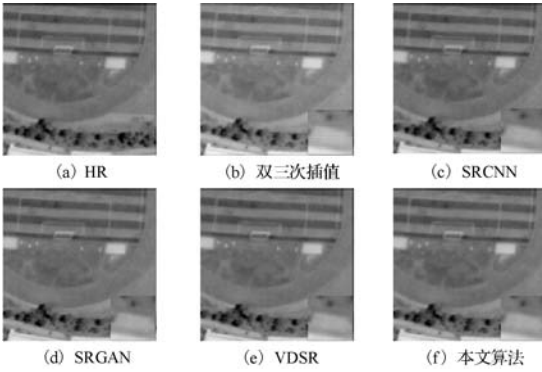


图7 不同算法下的影像超分辨率重建效果

3.2 客观评价指标

本文选用峰值信噪比 (PSNR)^[17] 及结构相似性 (SSIM)^[18] 作为实验评价指标,对比双三次插值方法、SRCNN、VDSR、SRGAN 方法及本文改进的算法对得到的超分辨率重建结果。通常情况下 PSNR 和 SSIM 越高,表明重建结果越好。

对给定的 $m \times n$ 图像 I 和噪声 K 来说,PSNR 定义为:

$$MSE = \frac{\sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [I(i,j) - K(i,j)]^2}{m \times n} \quad (14)$$

$$PSNR = 10 \times \log_{10} \left(\frac{Max_I^2}{MSE} \right) \quad (15)$$

SSIM 比较样本 x 和 y 的亮度 (luminance)、对比度 (contrast) 和结构 (structure),定义为式 (16),其中: μ_x 、 μ_y 为 x 、 y 的均值, σ_x^2 、 σ_y^2 为 x 、 y 的方差, σ_{xy} 为 x 和 y 的协方差。


$$SSMI(x,y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (16)$$

表 1 为 4 种算法下测试集影像的指标值,其中每个测试集包含影像 100 幅,取平均值。可以看出,在不同数据集上本文算法重建影像指标均优于其他对比算法,其中 PSNR 有较大提升,SSIM 略有提升。本文方法的 PSNR 比 SRGAN 高 0.8 dB 左右,这说明将边缘检测和密集残差网络应用到遥感影像超分辨率重建中


拥有更好的复原效果,重建图像也更加清晰,恢复了更多的纹理细节,建筑物、道路以及植被的边缘轮廓更加清晰。图 8 为不同融合系数对指标的影响。

表 1 各算法评价指标

算法	TestA		TestB		TestC	
	PSNR /dB	SSIM	PSNR /dB	SSIM	PSNR /dB	SSIM
双三次插值	24.362 8	0.912	24.492 9	0.897	25.550 6	0.882
SRCNN	24.681 7	0.957	24.811 2	0.918	25.965 0	0.923
VDSR	36.514 2	0.958	34.025 7	0.949	35.843 6	0.921
SRGAN	36.602 5	0.966	34.247 6	0.952	35.982 1	0.934
本文算法	37.431 9	0.967	35.925 7	0.959	37.126 7	0.948



(a) 不同系数对PSNR的影响



(b) 不同系数对SSIM的影响

图8 不同融合系数对算法的影响

4 结 语

遥感影像中的高频信息较为丰富,包含更多的颜色、形状和纹理特征,本文将边缘特征和对抗网络进行融合,提出了一种基于结合边缘检测算子和密集残差网络的影像重建方法。该方法利用边缘检测算子提取影像边缘细节特征,采用密集残差模块复用前层的底层特征,以“博弈论”的方式训练网络,最终达到纳什平衡状态完成遥感影像的超分辨率重建。本文将该超分辨率算法应用于 Google Earth 提供的高分辨率遥感影像,成功地提升了其空间分辨率。根据实验结果显示其主观感受与客观指标均优于其他算法,PSNR 相比 SRGAN 高 0.8 dB,实验证明了该模型的有效性,为遥感影像重建提供了新的解决方法与技术思路。

参 考 文 献

- [1] 李亮,舒宁,王凯,等.融合多特征的遥感影像变化检测方法[J].测绘学报,2014,43(9):945-953,959.
- [2] 彭晏飞,梅金业,王恺欣,等.基于区域注意力机制的遥感图像检索[J].激光与光电子学进展,2020,57(10):180-188.
- [3] 杨孟京,唐云祁,姜晓佳.基于卷积神经网络的鞋型识别方法[J].激光与光电子学进展,2019,56(19):203-210.
- [4] 林瑶瑶,唐新明,薛玉彩,等.高分辨率测绘卫星遥感影像星上压缩质量评价[J].测绘科学,2020,45(5):165-174.
- [5] 朱红,宋伟东,谭海,等.多尺度细节增强的遥感影像超分辨率重建[J].测绘学报,2016,45(9):1081-1088.
- [6] 宋廷强,李继旭,张信耶.基于深度学习的高分辨率遥感图像建筑物识别[J].计算机工程与应用,2020,56(8):26-34.
- [7] Song T Q, Li J X, Zhang X Y. High-resolution remote sensing image building recognition based on deep learning[J]. Computer Engineering and Applications,2020,56(8):26-34.
- [8] Ledig C, Theis L, Huszar F. Photo-realistic single image super-resolution using a generative adversarial network[C]//IEEE Conference on Computer Vision and Pattern Recognition,2017:105-114.
- [9] Dong C, Loy C C, Tang X. Accelerating the super-resolution convolutional neural network[EB]. arXiv:1608.00367v1, 2016.
- [10] 高媛,刘志,秦品乐,等.基于深度残差生成对抗网络的医学影像超分辨率算法[J].计算机应用,2018,38(9):2689-2695.
- [11] 张杨忆,林泓,管钰华,等.改进残差块和对抗损失的GAN图像超分辨率重建[J].哈尔滨工业大学学报,2019,51(11):128-137.
- [12] 高波,陈忠,刘思思.基于位置先验信息配准和视觉显著性的港口舰船目标检测研究[J].计算机与数字工程,2018,46(4):818-821,850.
- [13] 张素素,倪建成,周子力,等.融合语义标签和噪声先验的图像生成[J].计算机应用,2020,40(5):1431-1439.
- [14] 刘丽霞,李宝文,王阳萍,等.改进Canny边缘检测的遥感影像分割[J].计算机工程与应用,2019,55(12):54-58,180.
- [15] 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,2018:2472-2481.
- [16] Lim B, Son S. Enhanced deep residual networks for single image super-resolution[C]//IEEE Conference on Computer Vision and Pattern Recognition Workshops,2017:1132-1140.
- [17] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB]. arXiv:1409.1556v6, 2014.
- [18] 赵岩,孟丽茹,王世刚,等.符合人眼视觉感知特性的改进PSNR评价方法[J].吉林大学学报(工学版),2015,45(1):309-313.
- [19] 闫乐乐,李辉,邱聚能,等.基于区域对比度和SSIM的图像质量评价方法[J].应用光学,2015,36(1):58-63.
- ~~~~~
- (上接第157页)
- [3] Wang F, Xu J, Wang X, et al. Joint offloading and computing optimization in wireless powered mobile-edge computing systems[C]//2017 IEEE International Conference on Communications (ICC),2017.
- [4] Hu X, Wong K K, Yang K. Wireless powered cooperation-assisted mobile edge computing[J]. IEEE Transactions on Wireless Communications,2018,17(4):2375-2388.
- [5] Mao Y, Zhang J, Song S H, et al. Power-delay tradeoff in multi-user mobile-edge computing systems[C]//2016 IEEE Global Communications Conference (GLOBECOM),2016.
- [6] Zhou F, Wu Y, Hu Q R, et al. Computation rate maximization in UAV-enabled wireless powered mobile-edge computing systems[J]. IEEE Journal on Selected Areas in Communications,2018,36(9):1927-1941.
- [7] Janatian N, Stupia I, Vandendorpe L. Optimal resource allocation in ultra-low power fog-computing SWIPT-based networks[C]//2018 IEEE Wireless Communications and Networking Conference (WCNC),2018.
- [8] Zhang Y, He J, Guo S. Energy-Efficient dynamic task offloading for energy harvesting mobile cloud computing[C]//2018 IEEE International Conference on Networking, Architecture and Storage (NAS),2018.
- [9] Mao S, Huang X, Yang K, et al. Fair Energy-efficient scheduling in wireless powered full-duplex mobile-edge computing systems[C]//2017 IEEE Global Communications Conference(Globecom),2017.
- [10] You C, Huang K, Chae H. Energy efficient mobile cloud computing powered by wireless energy transfer[J]. IEEE Journal on Selected Areas in Communications,2016,34(5):1757-1771.
- [11] Wang J, Liu B, Feng L. Secure MISO Cognitive-Based mobile edge computing with wireless power transfer[J]. IEEE Access, 2020,8:15518-15528.
- [12] Wu H, Lyu X, Tian H. Online optimization of wireless powered mobile-edge computing for heterogeneous industrial internet of things[J]. IEEE Internet of Things Journal,2019,6(6):9880-9892.
- [13] Wu D, Wang F, Cao X, et al. Joint communication and computation optimization for wireless powered mobile edge computing with D2D offloading[J]. Journal of Communications and Information Networks,2019,4(4):72-86.