

DOI:10.19651/j.cnki.emt.2211174

融合边缘检测的遥感图像超分辨率重建算法*

杨彬 赵倩 赵琰

(上海电力大学电子与信息工程学院 上海 201306)

摘要: 针对基于生成对抗网络的遥感图像超分辨率重建存在训练不稳定,参数冗余,图片纹理细节不够清晰等问题。提出一种融合边缘检测的遥感图像超分辨率重建算法。首先,在生成器网络中引入改进后的 Canny 边缘检测算子用于低分辨率图像特征提取,通过在 Canny 算子边缘提取流程中利用双边滤波和 3×3 邻域梯度以检测图像的边缘信息,使网络能够更好的表达高频特征;其次,为降低网络参数和提高网络训练的稳定性,去除判别器网络中冗余的 BN 层,同时将 Wasserstein 距离定义为对抗损失以解决生成对抗网络训练出现的梯度消失现象。在 NWPU RESISC45 数据集上,所提方法的峰值信噪比与结构相似性较 WDSR 和 CARN 算法分别提升了 1.22 dB、0.114 和 0.32 dB、0.013,且重建后的图像相比较 WDSR、CARN 等其他 SR 算法在图像纹理细节和主观视觉效果方面也均有提升。

关键词: 遥感;边缘检测;超分辨率重建;Wasserstein 距离;图像处理

中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 520.60

Super-resolution reconstruction of remote sensing image based on edge detection

Yang Bin Zhao Qian Zhao Yan

(College of Electronics and Information Engineering, Shanghai University of Electric Power, Shanghai 201306, China)

Abstract: Remote sensing image super-resolution reconstruction based on Generative adversarial networks has some problems, such as unstable training, redundant parameters and unclear texture details. This paper presents a super resolution reconstruction algorithm of remote sensing image based on edge detection. Firstly, the improved Canny edge detection operator is introduced into the generator network for low-resolution image feature extraction. Bilateral filtering and 3×3 neighborhood gradient are used to detect image edge information in the Canny operator edge extraction process, so that the network can better express high-frequency features. Secondly, in order to reduce the network parameters and improve the stability of network training, the redundant BN layer in the discriminator network is removed, and the Wasserstein distance is defined as adversarial loss to solve the gradient disappearance phenomenon in generating adversarial network training. On the NWPU RESISC45 dataset, Compared with WDSR and CARN, the peak signal-to-noise ratio and structural similarity of the proposed method are improved by 1.22 dB, 0.114 and 0.32 dB, 0.013, respectively. Moreover, compared with other SR algorithms such as WDSR and CARN, the reconstructed images are improved in texture details and subjective visual effects.

Keywords: remote sensing; edge detection; super resolution reconstruction; Wasserstein distance; image processing

0 引言

遥感图像作为信息时代传递消息的重要载体,在遥感成像、卫星识别等科技领域有着十分重要的地位^[1]。但由于昂贵的硬件制作成本,现有硬件设施不够完善等问题,难以获得更清晰,细节信息更丰富的检测图像,图像超分辨率

重建理论是改变现状的关键技术之一。超分辨率重建技术在医学影像^[2]、人脸识别^[3]、卫星成像^[4]等领域有着广泛应用,超分辨率重建可以把低分辨率的遥感图像转化成质量更高,纹理信息更丰富的高分辨率图像^[5]。

图像超分辨率重建技术^[6]主要由插值法、学习法和重建法组成。其中插值法和重建法是传统 SR 算法,虽然网

收稿日期:2022-08-25

* 基金项目:国家自然科学基金(61802250)项目资助

络结构简单,计算效率较快,但存在重建的图片边缘模糊,超分辨率效果较差、图像纹理细节丢失、对训练样本要求较高等问题。在 2014 年,Dong 等^[7]首次在图像超分辨率重建技术领域引入了卷积神经网络的思想,提出了 SRCNN 模型。这个模型虽一定程度上改善了图片重建的质量,但由于对图片的高频细节缺乏真实性,因而无法恢复更加真实的纹理细节。而在 2017 年 Ledig 等^[8]提出的 SRGAN 则有效解决了图片在恢复过程中忽略纹理细节的问题。之后, Kim 等^[9]通过加深网络层数来提高图片重建的质量,提出了卷积层数更深的网络模型 VDSR。

基于现有的超分辨率算法的模型,本文提出了一种基于融合边缘检测的遥感图像超分辨率重建算法,该算法在生成对抗网络基础上对生成器和判别器做出改进,引入改进的 Canny 算子模块,以双边滤波和 3×3 邻域梯度代替经典 Canny 算子中的高斯滤波和梯度计算模块,使网络能够更好地提取遥感图像中一些边缘信息,以提高网络感知图像高频信息的能力。其次,去除原生成器中冗余的批量归一化(batch normalization, BN)层,由于 BN 层并不适用于解决超分辨率这类低层的计算机视觉问题,去除之后有助于提高网络的鲁棒性和计算效率。最后,去除判别器中的 sigmoid 激活函数且在网络中引入 Wasserstein 距离,由此将原有判别网络的二分类任务转变为回归任务,以更好地平衡真样本和伪样本的差异,以提高网络训练的稳定性。

1 网络模型设计

1.1 GAN

生成对抗网络(generative adversarial networks, GAN)

主要由生成器和判别器组成,其训练流程如图 1 所示。低分辨率图片(LR)先是经过生成器 G 生成一个伪样本,此后这个伪样本和真实样本(HR)会通过判别器 D 的分辨,将输出结果反馈给生成器 G 和判别器 D 进行参数更新,以此来提高网络的生成能力和判别能力。

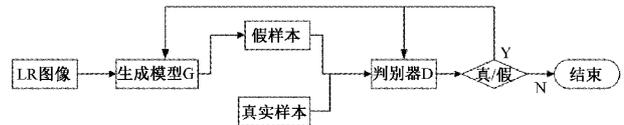


图 1 生成对抗网络训练流程

1.2 本文算法模型

本文遥感图像超分辨率模型以 SRGAN 网络结构为基础,由生成器和判别器两个模块构成。其中,生成器中包含提取图像特征信息的 4 个残差模块,与原 SRGAN 的残差网络相比,去除了原有残差块中的 BN 层,既释放了网络空间又提升了模型的计算效率。其次,经过用于放大特征图像的亚像素卷积层将图像恢复到原始图片的比例,最后在生成器的末尾引入了提取图像边缘结构的边缘检测层,分别提取 SR 图像(经过超分辨率重建后的图像)与 HR 图像(原始图像)经过边缘检测层提取出图像的边缘特征,以更好地计算图像的边缘损失。判别器包含 7 个相似的网络模块(由 Conv 层、PRELU 和 BN 层构成)用于提取遥感图像特征信息,去除原 SRGAN 判别器中的 sigmoid 层,且在判别器中引入了 Earth-Mover 距离将原有 SRGAN 判别器的二分类任务转为回归问题,以提高遥感图像超分辨率模型训练的稳定性。遥感图像超分辨率重建整体结构如图 2 所示。

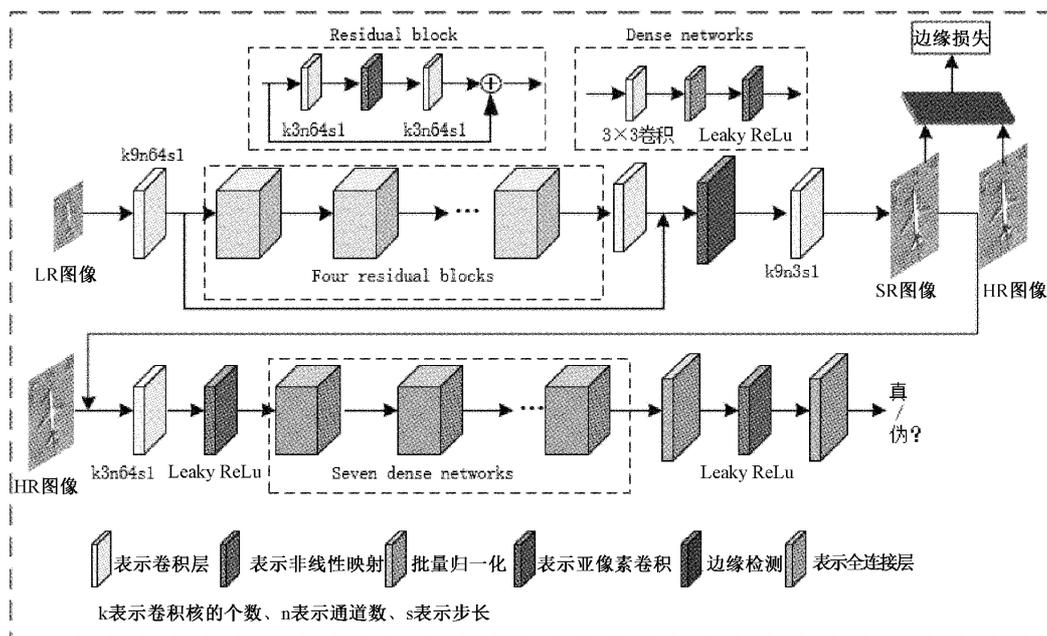


图 2 整体网络模型

1.3 改进的 Canny 算子

边缘检测^[10]作为计算机视觉领域中一种经典的图像处理算法, Sobel 算子^[11]、Prewitt 算子^[12]、Laplacian^[13]算子与 Canny 算子^[14]是常见的边缘检测工具,其原理是通过在训练过程中精准寻找图像中特征变化剧烈的像素点,以获取整个图片轮廓,用来识别图片中的人物、物体等特征信息^[15]。Canny 算子能够提取遥感图像多个角度的特征信息,其检测的边缘信息也更加丰富。然随着现实中对边缘检测技术的要求越来越高,传统 Canny 算子在图像处理领域的不足之处也逐渐显现出来,主要有以下 2 点:

1) 传统 Canny 算法在高斯滤波去除噪声的同时也会使得图像的边缘信息减弱,导致算子在提取过程中会漏掉一些弱边缘和孤立的边缘。

2) 传统 Canny 算法在图像降噪方面选用 2×2 邻域内的方差来计算梯度幅值,其计算结果不够精确,且忽略了滤波因子,对噪声没有一定的抑制能力。

针对高斯滤波在边缘检测中的不足,本文在图像降噪、梯度增强方面对 Canny 算子进行改进,算法流程如图 3 所示。首先选用双边滤波来平滑图像,在尽可能保持图像边缘特性的前提下去除噪声,以获取较为完整的待测图像。然后通过计算滤波后的图像梯度幅值来寻找图像中的强度梯度。之后通过对图像像素点进行非极大值抑制将图像模糊的边界变得清晰,以获取图像的边缘点。最后再根据图像像素点设置一个高阈值和一个低阈值,以更好的将图像进行强、弱边缘划分,既能够滤除图像噪声,又提高了边缘提取的准确率,改善图像质量。

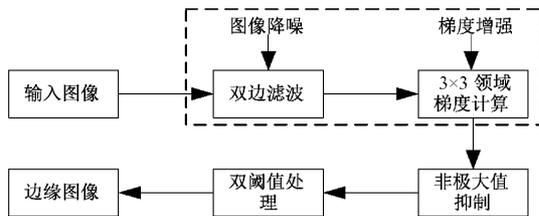


图 3 改进的 Canny 算子模型

1) 图像去噪

本文选用双边滤波对图像进行平滑操作,双边滤波是一种非线性滤波方法^[16],同时考量了空间分布信息和灰度相似性,并且在高斯滤波的基础上引入标准差 σ ,使得图像能够保持边缘结构并达到去噪的目的,表达式如下:

$$f_b(x, y) = \frac{\sum_{k,l} f(k, l) w(x, y, k, l)}{\sum_{k,l} w(x, y, k, l)} \quad (1)$$

$$d(x, y, k, l) = \exp\left(-\frac{(x-k)^2 + (y-l)^2}{2\sigma_d^2}\right) \quad (2)$$

$$r(x, y, k, l) = \exp\left(-\frac{\|f_b(x, y) - f(k, l)\|^2}{2\sigma_r^2}\right) \quad (3)$$

式中: $d(x, y, k, l)$ 为当前像素点距离滤波模板中心点的

欧氏距离, $r(x, y, k, l)$ 为像素点距离中心点差值的灰度距离,两者的乘积决定了权重系数 $w(x, y, k, l)$, $f(k, l)$ 为图像滤波前的像素值, $f_b(x, y)$ 为图像滤波后的像素值。

2) 计算梯度幅值和方向

常用的梯度幅值是在 2×2 邻域内计算有限差分所得,这类方法计算简单,但缺少对图像边缘细节信息的检测。本文采用了 Sobel 算子来优化梯度计算, Sobel 算子主要从水平边缘和垂直边缘这两个方面进行检测,能够有效减少图像边缘模糊度,以提高边缘检测的效果。Sobel 算子水平和垂直梯度模板如式(4)所示。

$$S_x = \begin{bmatrix} -1 & 0 & +1 \\ -2 & 0 & +2 \\ -1 & 0 & +1 \end{bmatrix} \quad S_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ +1 & +2 & +1 \end{bmatrix} \quad (4)$$

像素沿 X 方向的梯度为:

$$G_x = S_x * A \quad (5)$$

沿 Y 方向的梯度为:

$$G_y = S_y * A \quad (6)$$

式中: * 为卷积符号, A 为原始图像 3×3 像素点矩阵。

梯度幅值 G 和梯度方向 θ 为:

$$|G| = |G_x| + |G_y| \quad (7)$$

$$\theta = \arctan\left(\frac{G_y(x, y)}{G_x(x, y)}\right) \quad (8)$$

3) 仿真结果分析

实验在 Pycharm 2020 环境下运行,运用 OpenCV 模块,用不同边缘检测算子对同一张遥感图像数据进行仿真,对改进的 Canny 算子与传统 Canny 算子、Sobel 算子进行实验检测和评价分析,图 4 为不同算子对遥感图像进行边缘提取的结果对比。

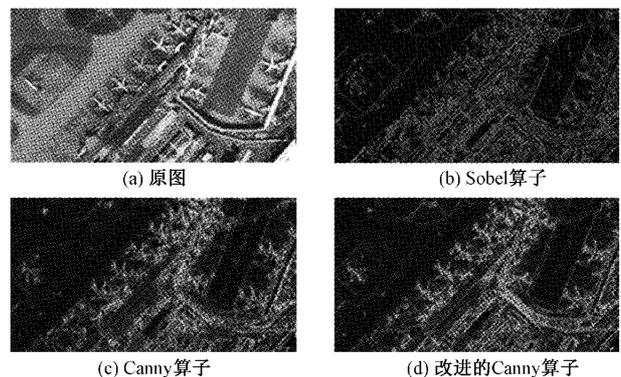


图 4 遥感图像边缘检测结果

由图 4 所示边缘结构提取的结果可知,经典 Canny 算子对遥感图像边缘特征提取明显有信息缺失现象,图像的边缘结构杂线较多; Sobel 算子对图像的检测效果较于传统 Canny 算子在图像的边缘细节上有一定的提升,边缘线条有较好的连续性,但是图像复杂边缘处检测比较模糊;

改进的 Canny 算子较前两者,检测的图像整体结构更加完整清晰,边缘高频信息更加丰富且未出现边界模糊的现象。

1.4 改进的残差网络

在生成器中对原始残差网络进行了改进,采用了 EDSR^[17]网络中的 ResBlock,残差模块内部卷积层结构基本一致,主要实现图像的特征提取,其网络内部参数 $n=64$ (通道数), $k=3$ (卷积核大小), $s=1$ (步长),这一部分共采用 4 个残差网络模块,残差网络如图 5 所示。本文比较了原始残差网络和 ResBlock 残差网络结构,其中原始残差网络使用了批归一化层,而 ResBlock 去除了 BN 层,没有对图像进行批归一化处理。因为在图像超分辨率重建这类低层的计算机视觉问题中,加入 BN 层对网络本身并无作用,反而会消耗更多的计算资源,所以 ResBlock 残差网络中去除了冗余的 BN 层,优化网络模型的计算效率,从而减少特征信息的丢失,使网络具备更好的学习能力。

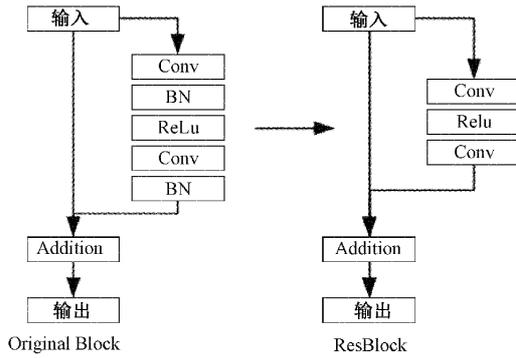


图 5 去除 BN 层的残差网络

1.5 去除 Sigmoid 的判别器网络

原 GAN 网络存在训练难,目标函数容易导致梯度消失的问题,为此文中设计判别网络时采用了 Wasserstein 距离作为对抗损失函数,去除判别网络最后的 Sigmoid 激活函数,由此将原有判别网络的二分类任务转变为回归任务,以提高网络训练的稳定性。如图 6 所示为优化后的判别器搭建流程图,其网络各部分具体参数如下:

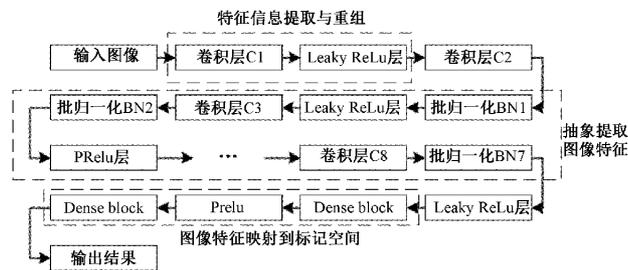


图 6 去除 sigmoid 的判别器

第 1 部分为卷积层 Conv 和 Leaky ReLU 层,主要实现图像特征信息提取和重组,其卷积层参数如下: $n=64$ (通道数), $k=3$ (卷积核大小), $s=1$ (步长)。判别器的激活操作是通过 Leaky ReLU 实现的,Leaky ReLU 和 ReLU 的区

别在于 Leaky ReLU 的负方向也有值,能够更精确的计算梯度,解决网络训练时由于参数更新而产生的梯度方向锯齿问题,提高训练的稳定性。

第 2 部分是由 7 组相似的网络模块构成的稠密网络,每一组网络都是由卷积层、BN 层和 Leaky ReLU 构成。其功能主要是通过低层次空间映射图像的特征信息以实现图像特征的抽象提取。其中稠密网络的卷积核个数都为 3,7 组网络输出通道数依次为 64、128、128、256、256、512 和 512,网络步长 s 交替为 1 或 2,且 BN 层和 Leaky ReLU 应用于每一组网络中。

第 3 部分为全连接层,中间为一个 Leaky ReLU 激活函数,实现特征空间到标记空间的转换,最后通过一个全连接层输出一个一维的张量。

1.6 损失函数

本文设定的损失函数除了考虑原有对抗损失、内容损失之外,为更好恢复原有的图像效果,考虑到图像边缘结构问题,根据边缘检测模型提取出的图像边缘,在原有损失函数的基础上加入了边缘损失和引入 Wasserstein 距离的判别器损失,如式(9)、(10)所示。

$$l_{rg} = \frac{1}{N} \sum_{x=1}^N \left(\frac{1}{L} \sum_{y=1}^L (E(I^{HR}_{x,y}) - E(I^{SR}_{x,y}))^2 \right) \quad (9)$$

$$L_D = E_{x \sim P_g} [D(x)] - E_{x \sim P_r} [D(x)] \quad (10)$$

式中: E 表示使用 Canny 算子对各通道计算边缘结构损失, L 为通道数量, N 为样本数量, I^{HR} 表示原始高分辨率图像, I^{SR} 表示经过超分辨率模型重建后的图像。

1.7 评价标准

本文实验选用峰值信噪比(peak signal-to-noise ratio, PSNR)、结构相似性(structural similarity, SSIM)作为评价图像超分辨率重建的两个标准。其中 PSNR 是基于误差敏感的图像质量评价,其值越高,生成图片的失真度越低,SSIM 是计算图像的亮度、对比度,值越大,图像的效果越好,式如(11)、(12)所示。

$$PSNR = 10 \times \lg \frac{255^2 \times W \times H \times C}{\sum_{i=1}^W \sum_{j=1}^H \sum_{z=1}^C [\bar{x}(i,j) - (i,j)]^2 + 1 \times 10^{-9}} \quad (11)$$

其中, H, W, C 为图片的长、宽和通道数, x 为重建后的图像(SR 图像), \bar{x} 为原始图像。

$$SSIM(X, Y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (12)$$

式中: μ_x, μ_y 为图像 X, Y 的均值, σ_x, σ_y 为图像 X, Y 的方差, σ_{xy} 分别为 X 图像和 Y 图像的协方差, C_1, C_2 为常数。

2 实验结果与分析

2.1 实验平台

本文实验的硬件平台为 NVIDIA RTX2060 GPU,软件搭建平台为 PyCharm 2020。实验采用 Adam 优化器,

$\beta_1 = 0.9, \beta_2 = 0.99, \epsilon = 10^{-8}$, 初始学习率设置为 0.0001。训练集为 NWPU RESISC45 遥感影像图片, NWPU RESISC45^[18] 是遥感图像领域广泛使用的数据集, 其涵盖了飞机、机场、桥梁等 45 个场景类别, 文中从每类场景中选取 200 张图片, 共 9 000 幅, 并随机选取 7 000 张训练集图片、1 500 张验证集图片和 500 张测试集图片作为模型训练的主要内容。其次, 以重建图片的主观视觉作为定性评价指标, 并采用峰值信噪比 (peak signal-to-noise ratio, PSNR) 和结构相似性 (structural similarity, SSIM) 作为客观评价指标。

2.2 实验与分析

1) 判别损失对比

本文网络判别器中去除了原始 GAN 的 sigmoid 层, 并将 Wasserstein 定义为网络模型的对抗损失, 以提高网络训练的稳定性。实验中分别用相同的数据集在原始 GAN 和本文模型进行训练, 得到的损失值如图 7 所示, 图 7(a) 中由于原始 GAN 存在 JS 散度距离衡量不合理、准确度惩罚不平衡的问题, 导致网络训练的损失值很难收敛。图 7(b) 为本文模型损失变化动态图, 可以看出本文网络在引入 Wasserstein 距离后成功解决了原始 GAN 网络产生的梯

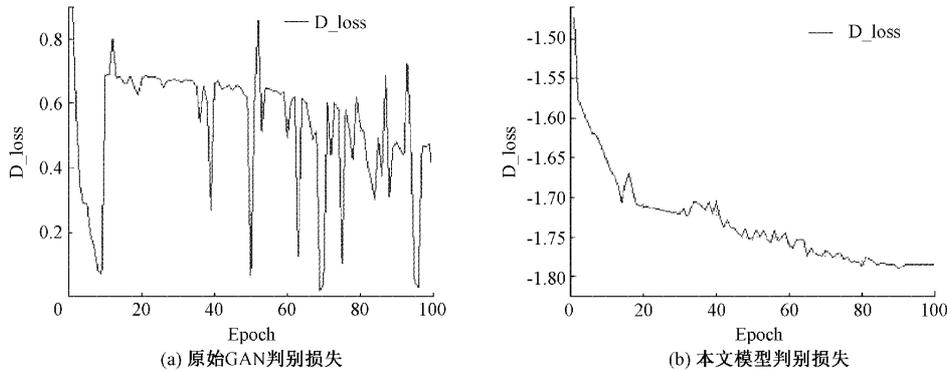


图 7 不同判别器的损失变化

度不稳定, 生成分布与真实分布有重叠的问题, 随着训练的进程, 损失值缓慢下降并逐渐趋于某一值开始收敛。

2) 主观评价

本次实验通过 PIL 库对低分辨率图像进行双三次差值重建, 并重建 SRResNet、SRGAN^[19]、ESRGAN、WDSR、CARN 模型进行实验对比, 实验结果如图 8、9 所

示, 分别展示了遥感图像经过各个算法重建后的效果, 其中图 8 从上往下依次表示飞机、港口、房屋遥感图像在经过下采样后, 通过不同模型所重建的高分辨率图像。为更直观感受不同模型所重建遥感影像的效果, 图 9 展示了飞机和房屋遥感影像在放大某一部分后的图像细节对比。

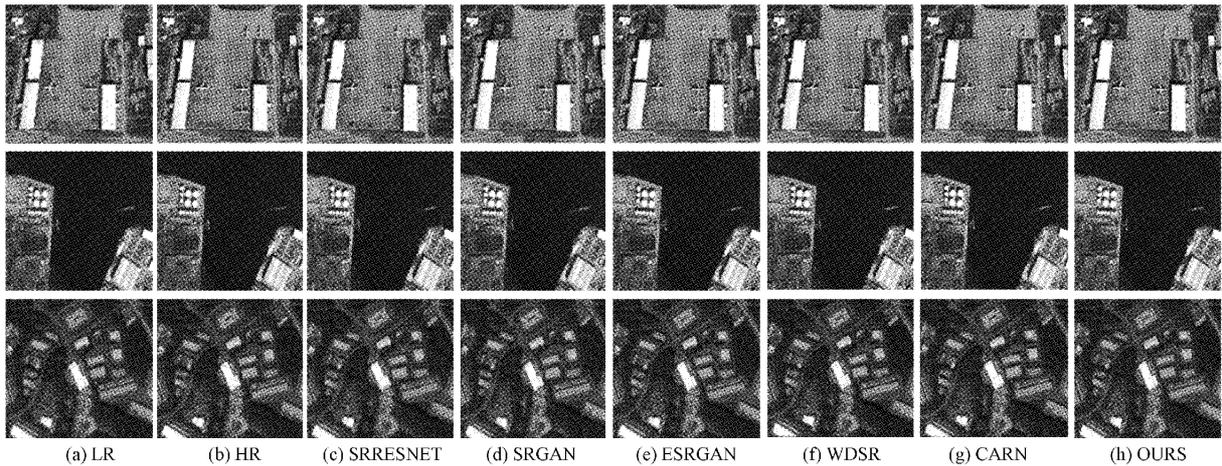


图 8 整体效果对比图

由图 8、9 可知, SRResNet、SRGAN 所生成的图像整体视觉效果较为模糊, 在重建图像的纹理细节方面丢失大量的高频信息, 图像失真严重, 重建图像的质量较差。ESRGAN 采用 RaGAN 中的相对损失函数来优化网络模

型, 以提高图像的相对真实性, 虽能够获取与原始图像视觉上近似的效果且图片的整体质量都高于前两个方法, 然而图像重建过程中包含噪声且容易产生失真, 重建后的遥感影像未能产生较清晰的纹理细节。相比以上方法, 本文

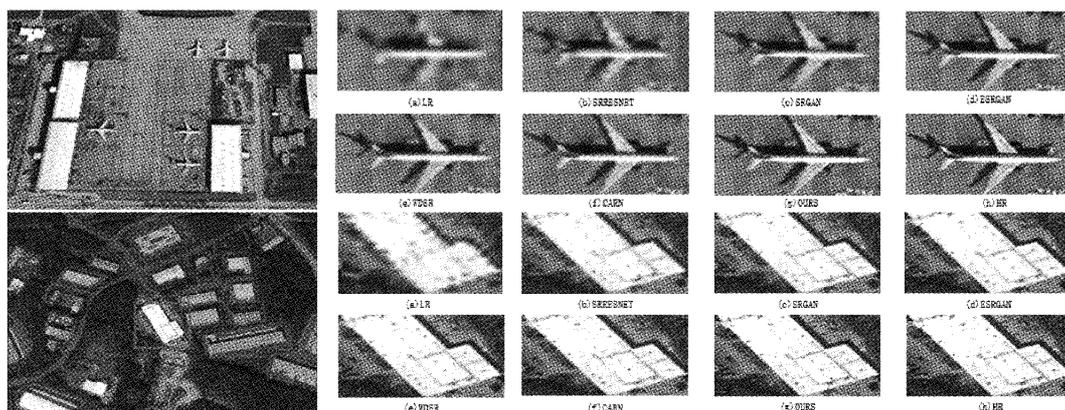


图 9 细节效果对比图

模型产生的图像不仅整体感官最好,在整体视觉上与原图像最相近,且图像始终能够产生更清晰的边缘和细节。

3) 客观评价

更严谨比较各 SR 模型算法的优劣性,选用 PSNR、SSIM 客观指标从定量上对比各算法重建遥感影像的质量,PSNR 与 SSIM 的值越高代表网络在训练过程中越稳定,不易产生失真,重建的图像结构越相似于原始图像。表 1 是各算法在飞机、港口、房屋 4 倍重建图像的 PSNR、SSIM 得分,为更客观表现每个算法的优劣性,在表中的

最后一行添加了总测试集的平均 PSNR、SSIM 得分。从表 1 中的数据可以看出 SRResNet、SRGAN 的两个客观指标都远低于其他算法,WDSR 和 CARN 相较于 SRResNet 更侧重于边缘,纹理结构的恢复,无论是 PSNR 还是 SSIM 均有提升,而本文方法相较于 CARN 模型的测试集平均 PSNR 值高出 0.32 dB,SSIM 值高出 0.013,实验结果证明本文算法相比其他模型具备更高的客观质量评估值,能够有效提升遥感图像超分辨率重建算法的准确率。

表 1 不同 SR 算法 PSNR/SSIM 的值

测试集	评价指标	SRRESNET	SRGAN	ESRGAN	WDSR	CARN	OURS
飞机	PSNR	23.52	25.67	26.34	27.86	27.80	28.84
	SSIM	0.636	0.732	0.723	0.765	0.856	0.905
港口	PSNR	24.01	25.73	26.98	27.41	28.02	28.96
	SSIM	0.611	0.686	0.701	0.803	0.897	0.889
房屋	PSNR	23.59	25.34	26.09	27.63	28.43	28.69
	SSIM	0.646	0.702	0.739	0.806	0.883	0.907
测试集平均值	PSNR	24.11	25.59	26.18	27.55	28.45	28.77
	SSIM	0.658	0.703	0.728	0.792	0.893	0.906

4) 重建时间的比较

原有 GAN 网络结构的加深使模型复杂度增加,导致速度减慢。本文算法在去除 BN 层后减少了网络参数,降低了网络计算复杂度,进而提高了网络训练的收敛速度。表 2 所示为本文网络与 SRRESNET、SRGAN、ESRGAN 等图像超分辨率重建网络分别在飞机、港口、房屋遥感影像的重建时间对比。结果显示 SRGAN 算法的重建时间较长,因为该算法采用了结构较复杂的深度残差网络,模

型参数过多,特征冗余,运算复杂度很高,导致整个重建时间速度较慢。CARN 相比较 SRGAN 采用了一种轻量级网络结构,将 Resnet 残差块变成了级联残差网络,有效减少了模型参数量,从而大幅度缩短了重建时间,而本文算法较 CARN 在港口和房屋图像上的重建速度分别提高了 0.07 和 0.27 s,这充分说明了本文网络相比其他遥感图像超分辨率重建网络在重建时间方面速度更快,效果更好。

表 2 不同算法的重建时间对比

图像	SRRESNET	SRGAN	ESRGAN	WDSR	CARN	OURS
飞机	5.43	4.98	4.05	4.59	3.51	3.52
港口	5.49	5.11	4.08	4.87	3.46	3.39
房屋	5.51	5.13	4.16	5.03	3.68	3.41

5) 消融实验

为验证滤波函数和梯度计算在边缘检测中对遥感影像超分辨率重建结果的影响,本文分别用双边滤波(bilateral filter, BF)与 Sobel 梯度(3×3)进行了消融实验,将高斯滤波(Gaussfilter, GF)、传统梯度(2×2 邻域)与本文所选用的 BF 和 Sobel 梯度进行不同的组合,分为 GF+传统梯度、GF+Sobel 梯度、BF+传统梯度、BF+Sobel 梯度,对比的客观指标实验结果如表 3 所示,表中 GF+传统梯度的客观评估指标最低,这是因为传统 2×2 邻域内的方差来计算梯度幅值,计算结果不够精确,且对噪声敏感,无法提取图像的边缘高频信息,而 BF+Sobel 梯度在遥感影像超分辨率重建中相比较其他方法的 PSNR 值和 SSIM 值都有所提高,对于 GF+Sobel 梯度的 PSNR 值高出 3.793 dB,SSIM 值高出 0.223。

除客观评价之外,实验还对重建图像的质量进行主观

表 3 边缘检测模块评价指标对比结果

Algorithm	PSNR	SSIM	MSE
GF+传统梯度	20.341	0.598	362.582
GF+Sobel 梯度	24.346	0.659	300.731
BF+传统梯度	22.265	0.709	224.351
BF+Sobel 梯度	28.139	0.882	195.423

视觉效果的评价,使用不同方法进行重建的图像结果如图 10 所示,图中 GF+传统梯度重建后的图像无论是整体结构还是纹理细节都比较模糊,图 10(c)在加入双边滤波后,重建图像的质量得到了一定的改善,边缘结构得到了较好的恢复,但同时也存在一些不连续的线条。而本文方法在重建图像的过程中能够从一定程度上改善这种不连续边缘细节,保持图片结构的平滑,能够较好地恢复图像的边缘高频信息,得到了更加清晰的图片。

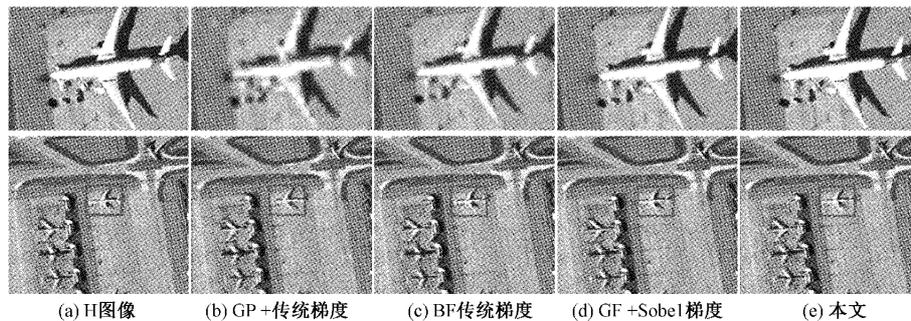


图 10 主观视觉效果对比图

3 结 论

本文提出了一种融合边缘检测的遥感图像超分辨率重建网络,在网络中加入了改进的 Canny 算子用来提取高频特征,并且在残差网络中用 Leaky Relu 代替 Prelu 防止出现梯度消失现象,移除了冗余的 BN 层,提高特征复用率,优化训练的效率。同时采用了 Wasserstein 距离的思想,重新设计了损失函数,把 Wasserstein 距离定义为对抗损失来提高网络训练的稳定性。最后通过在公开数据集上进行测试来验证本文算法无论在客观指标 PSNR 和 SSIM,还是主观视觉效果上均优于 SRGAN、ESRGAN、WDSR 等其他 SR 算法。

参考文献

- [1] JI H, GAO Z, MEI T, et al. Vehicle detection in remote sensing images leveraging on simultaneous super-resolution [J]. IEEE Geoscience and Remote Sensing Letters, 2020, 17(4): 676-680.
- [2] LI Y, SIXOU B, PEYRIN F. A review of the deep learning methods for medical images super-resolution problems [J]. IRBM, 2021, 42(2): 120-133.
- [3] CHEN Y, PHONEVILAY V, TAO J, et al. The face

image super-resolution algorithm based on combined representation learning [J]. Multimedia Tools and Applications, 2020(12): 1-23.

- [4] SHIN C, KIM S, KIM Y. Satellite image target super-resolution with adversarial shape discriminator [J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 3042238.
- [5] CHANG-SHENG H, SHU Z, CONG-ZHONG W. Image super-resolution based on deep learning features [J]. Acta Automatica Sinica, 2017, 43(5): 814-821.
- [6] MA L, LIU Y, ZHANG X, et al. Deep learning in remote sensing applications: A meta-analysis and review [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2019, 152: 166-177.
- [7] DONG C, LOY C C, HE K, et al. Image super-resolution using deep convolutional networks [J]. IEEE Trans Pattern Anal Mach Intell, 2016, 38(2): 295-307.
- [8] LEDIG C, TGEIS L, HUSZAR F, et al. Photo Realistic single image super-resolution using a generative adversarial network [C]. Proceeding of 2017 Conference on Computer Vision and Pattern

- Recognition. Honolulu, IEEE:2017.
- [9] 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.
- [10] RAHMAWATI S, DEVITA R, ZAIN R H, et al. Prewitt and canny methods on inversion image edge detection: An evaluation [C]. Journal of Physics: Conference Series, IOP Publishing, 2021, 1933(1):012039.
- [11] 李洁,袁知博,秦嘉悦. 基于 Sobel 算子边缘检测的太阳能电池缺陷特征提取方法[J]. 太阳能学报, 2021, 42(1):63-68.
- [12] 巨志勇,薛永杰,张文馨,等. 自适应阈值 Prewitt 的石榴病斑检测算法[J]. 农业工程学报, 2020, 36(8):135-142.
- [13] 周俊杰,余建波. 基于机器视觉的加工刀具磨损量在线测量[J]. 上海交通大学学报, 2021, 55(6):741-749.
- [14] 张愉玲,邢会林,李三忠,等. 基于蚁群和 Canny 边缘检测算子混合算法的二维岩石图像裂隙特征提取与修复研究[J]. 大地构造与成矿学, 2021, 45(1):242-251.
- [15] DAVID B, FELIX H, PATRICK M, et al. Image segmentation and robust edge detection for collision avoidance in machine tools [J]. Tmtechnisches Messen, 2021, 88(6):374-385.
- [16] GONG S, LI G, ZHANG Y, et al. Application of static gesture segmentation based on an improved canny operator[J]. The Journal of Engineering, 2019, 2019(15):543-546.
- [17] LIM B, SON S, KIM H, et al. Enhanced deep residual networks for single image super-resolution [C]. Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops. Washington D. C., USA: IEEE Press, 2017:136-144.
- [18] 钱晓亮, 李佳, 程焱, 等. 特征提取策略对高分辨率遥感图像场景分类性能影响的评估[J]. 遥感学报, 2018, 22(5):758-776.
- [19] 陈晓, 荆茹韵. 单图像超分辨率方法综述[J]. 电子测量技术, 2022, 45(9):104-112.

作者简介

杨彬, 硕士, 主要研究方向为图像处理。

E-mail: 969018083@qq.com

赵倩, 博士, 副教授, 主要研究方向为图像检测与识别、视频图像、基于 FPGA 数字系统设计等。

E-mail: zhaoqian@shiep.edu.cn