

基于生成对抗网络的遥感图像超分辨率重建改进算法

李强, 汪西原*, 何佳玮

宁夏大学物理与电子电气工程学院, 宁夏 银川 750021

摘要 为了获取包含更多高频感知信息与纹理细节信息的遥感重建图像,并解决超分辨率重建算法训练难和重建图像细节缺失的问题,提出一种融合多尺度感受野模块的生成对抗网络(GAN)遥感图像超分辨率重建算法。首先,使用多尺度卷积级联增强全局特征获取、去除GAN中的归一化层,提升网络训练效率去除伪影并降低计算复杂度;其次,利用多尺度感受野模块与密集残差模块作为生成网络的细节特征提取模块,提升网络重建质量获取更多细节纹理信息;最后,结合Charbonnier损失函数与全变分损失函数提升网络训练稳定性加速收敛。实验结果表明,所提算法在Kaggle、WHU-RS19、AID数据集上的平均检测结果较超分辨率GAN在峰值信噪比、结构相似性、特征相似性等方面分别高出约1.65 dB、约0.040(5.2%)、约0.010(1.1%)。

关键词 遥感; 超分辨率重建; 遥感图像; 生成对抗网络; 感受野网络; 密集残差网络

中图分类号 TP751.1

文献标志码 A

DOI: 10.3788/LOP213046

Improved Algorithm for Super-Resolution Reconstruction of Remote-Sensing Images Based on Generative Adversarial Networks

Li Qiang, Wang Xiyuan*, He Jiawei

College of Physics and Electronic Engineering, Ningxia University, Yinchuan 750021, Ningxia, China

Abstract A generation countermeasure network (GAN) remote-sensing image super-resolution reconstruction algorithm, integrating a multiscale receptive field module is proposed to obtain remote-sensing reconstructed images containing more high-frequency perceptual information and texture details. The GAN algorithm should also be able to solve the problems of training super-resolution reconstruction algorithms and missing reconstructed image details. First, a multiscale convolution cascade is used to enhance the global feature acquisition, remove the normalization layer from the generated countermeasure network, improve network training efficiency, remove artifacts, and reduce computational complexity. Then, the multiscale receptive field and dense residual module are used as the detail feature extraction modules to improve the quality of network reconstruction and obtain more detailed texture information. Finally, the Charbonnier and total variation loss functions are combined to improve the stability of network training and accelerate convergence. Consequently, experimental results show that the average detection outcomes of the proposed algorithm on the Kaggle, WHU-RS19, and AID datasets are higher than those of the super-resolution GAN in terms of peak signal-to-noise ratio, structural similarity, and feature similarity, respectively, by about 1.65 dB, 0.040 (5.2%), and 0.010 (1.1%).

Key words remote sensing; super-resolution reconstruction; remote sensing image; generative adversarial network; receptive fields block; residual dense block

1 引言

遥感图像拥有丰富的细节信息、感知信息,能够有效地进行场景感知与环境分析。在遥感领域中,图像超分辨率(SR)重建显得尤为重要。重建方法可用于其他遥感任务中,如环境监控^[1]、目标检测^[2]、场景分

类^[3]等领域。

随着深度学习被广泛应用于SR图像重建任务中^[4],其展现出卓越的性能,因此近年来很多自然图像SR重建方法相继被提出。Dong等^[5]提出超分辨率卷积神经网络(SRCNN)模型,将3层卷积神经网络(CNN)应用于重建任务中,利用CNN学习低分辨率

收稿日期: 2021-11-24; 修回日期: 2022-01-25; 录用日期: 2022-03-08; 网络首发日期: 2022-03-18

基金项目: 国家自然科学基金(41561087)

通信作者: *wangxiy@nxu.edu.cn

(LR)图像与高分辨率(HR)图像端到端特征映射,相较于传统方法计算复杂度大幅降低。随后,Dong等^[6]在此基础上又提出FSRCNN模型,进一步增加网络深度,可有效重建出更多高频细节,但网络训练难度也不断增加。Kim等^[7]提出深度卷积网络超分(VDSR)模型,利用多层CNN连接实现多层特征级联提升学习率、加快收敛速度,有效证明网络深度对SR重建的重要性。Ledig等^[8]提出超分辨率生成对抗网络(SRGAN)模型,将生成对抗网络(GAN)^[9]引入SR重建任务中,生成器与判别器相互协同训练,使网络更加注重与特征空间分布的相似程度,激励生成具有高感知质量的自然图像。在此基础上,Wang等^[10]提出增强型超分辨率生成对抗网络(ESRGAN),对SRGAN框架进行优化,采用残差密集模块(RDB)^[11]降低重建结果中产生的伪影,锐化边缘纹理。

在遥感领域中,SR是一个严重不适定的问题,图像质量受到许多因素的影响,如大气扰动、超远程成像、光谱噪声等。Zhang等^[12]提出multi-scale attention network(MSAN)模型,引入尺度注意力网络提升场景自适应能力,增强对不同遥感场景细节的重建。Dong等^[13]提出dense sampling super-resolution(DSSR)模型,利用密集采样机制对多个低维特征进行上采样,使网络重建过程中融合多个先验特征。随后,Dong等^[14]又提出second-order multi-scale super-resolution(SMSR)模型,利用两阶段学习法聚合全局与局部的大尺度与小尺度特征信息,强化多尺度特征提取能力。对于GAN重建方法,Jiang等^[15]提出edge-enhanced GAN(EEGAN)模型,采用超密集子网络与边缘增强网络改进SRGAN,使其适用于遥感重建任务,提高遥感图像的边缘重建能力。而Lei等^[16]提出coupled-discriminated GAN(CDGAN)模型,采用耦合鉴别网络结构提升重建图片局部细节。

遥感图像对场景感知信息与细节信息有较高要

求,需要在LR图中提取更多的细节信息。针对当前遥感图像对高频细节信息重建存在的问题,本文在SRGAN基础上提出一种改进的遥感SR重建模型:引进感受野模块融合去除批归一化(BN)层的RDB构成生成网络,将各层提取的特征信息更好地共享,并能有效平衡小计算量与大感受野;引入相对判别器代替普通判别器;结合Charbonnier损失、感知损失、对抗损失、内容损失与全变分(TV)损失构成生成损失函数,进一步提升遥感重建图像的质量。

2 融合密集残差的多尺度感受野超分辨率重建网络

SR遥感图像重建旨在利用已有LR图像恢复出损失的高频细节信息,并同时保持感知信息的一致性。已有的大多数重建模型都是以峰值信噪比(PSNR)为基础设计的,从而导致SR图像边缘过于平滑丢失高频信息。与自然图像相比,遥感图像的结构更为复杂。遥感图像通常包含广泛的不同场景,如建筑物、农田、森林和机场。一幅完整的遥感图像可以由许多不同的场景组成,它们的纹理和结构信息差异很大,导致不同场景的HR和LR图像之间的映射关系不一致,并且遥感影像中地物尺度差异较大,如飞机和车辆等物体在遥感图像中只占几个像素,这与自然图像有很大的不同。SRGAN基于GAN进行图像超分重建,相较于其他基于深度学习的超分方法,可使重建出的图像更加接近真实图像,而非PSNR值更接近于真实图像。因此,GAN的引进能有效提升图像的感知质量,有利于遥感图像重建。针对现有SR重建在遥感图像方面存在的问题,本研究提出一种基于GAN的SR遥感图像重建网络模型,其总体结构如图1所示。该模型主要包括生成器与判别器。生成网络生成特定放大因数的SR图像,再将SR图像与HR图像同时输入判别网络,经由判别器鉴别图像真实与否。

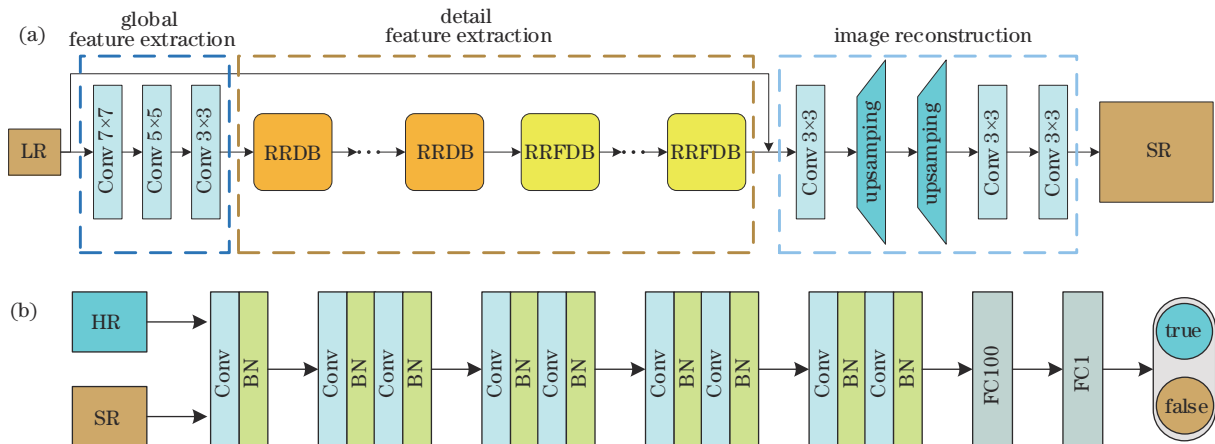


图1 改进的SR重建网络。(a)生成网络结构;(b)对抗网络结构

Fig. 1 Improved SR reconstruction network. (a) Structure of generating network; (b) structure of adversarial network

2.1 生成器设计

生成器网络是基于 SRGAN 中的生成器架构改进所得的,如图 1(a)所示,主要可分为 3 个模块:全局特征提取模块、细节特征提取模块和图像重建模块。ESRGAN 的生成器模型仅将一个 3×3 卷积层用于顶层特征提取,而小尺度 3×3 卷积核并不能有效提取全局特征,导致部分信息丢失。因此,为了更好地适配遥感高感知信息的要求,本实验利用不同尺度(7×7 、 5×5 、 3×3)的卷积内核构建串行卷积结构作为全局特征提取模块,替换原始模型中的 3×3 卷积,以获得更多的全局特征。

将密集残差模块(RRDB)与密集感受野模块(RRFDB)串接构成细节特征提取模块。其中,每个 RRDB 均含有 3 个 RDB,而每个 RDB 均含有 5 层残差卷积,其具体结构如图 2 所示。通过去除 RDB 中的 BN 层,提升生成器性能、降低模型计算复杂度,并且 BN 层的存在会导致 SR 图中引入伪影影响重建效果从而限制网络泛化能力。使用 RRDB 作为初级细节特征提取模块,其密集的多级网络连接有效扩充了网络容量,并通过剩余缩放因子抑制训练阶段不稳定因素的影响。




图 2 RRDB 结构

Fig. 2 Structure of RRDB

RRFDB 的设计类似于 RRDB,将 RRDB 中的 RDB 模块用感受野堆叠模块(RFDB)替换,其具体网络结构如图 3 所示。感受野模块(RFB)^[17]利用多尺度小卷积核结构中不同感受野具有不同离心率性质,且在 RFB 中较小的卷积核分配较大的权重给靠近中心的区域,使这一部分比远距离的区域更重要,其网络结构如图 4 所示。这种特殊的结构使得 RFB 能够提取非常精细的高频特征,尤其是线性细节特征,如细丝、纹理、边缘等。将 RRDB 提取的特征,进一步使用 RRFDB 提取多尺度高频特征,并限制时间复杂度节省计算量,能够有效提升上下文信息细节信息提取精度,更有利于遥感图像丰富感知信息的重建。

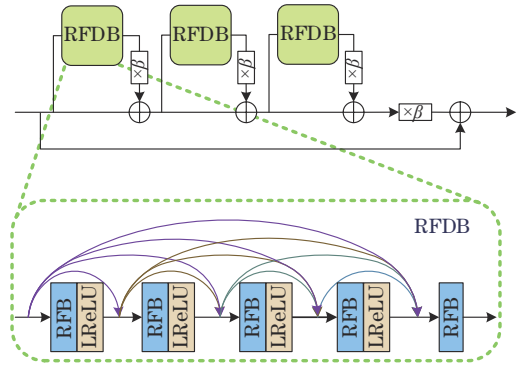


图 3 RRFDB 结构

Fig. 3 Structure of RRFDB

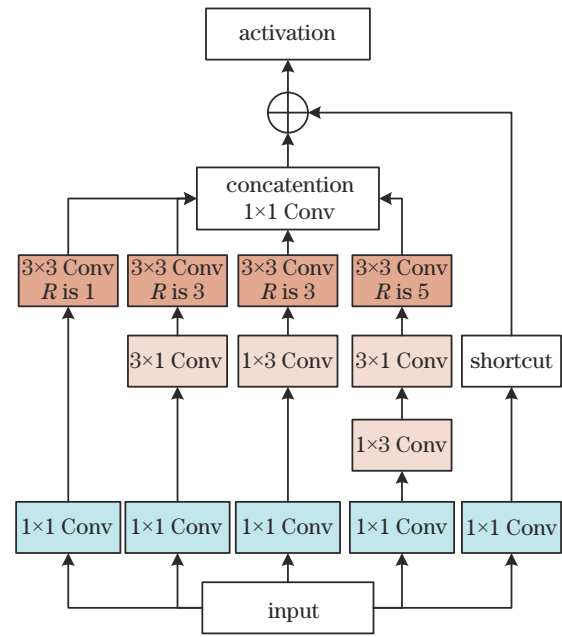


图 4 RFB 结构

Fig. 4 Structure of RFB

2.2 判别器设计

判别器采用 VGG-19 架构,如图 1(b)所示。本实验采用相对判别器,其与标准判别器不同之处在于标准判别器估计输入图像是否真实,而相对判别器预测的是真实图像相对于生图像更真实的概率。相对判别器约束函数表达式为

$$D_{Ra}(I_{HR}, I_{SR}) = \sigma \{ C(I_{HR}) - E_{I_{SR}} [C(I_{SR})] \} \rightarrow 1, (1)$$

$$D_{Ra}(I_{SR}, I_{HR}) = \sigma \{ C(I_{SR}) - E_{I_{HR}} [C(I_{HR})] \} \rightarrow 0, (2)$$

式中: I_{SR} 表示 SR 图; I_{HR} 表示 HR 图; $\sigma(\cdot)$ 表示 Sigmoid 函数; $C(\cdot)$ 表示判别器的原始输出结果; $D_{Ra}(\cdot)$ 表示相对判别器; $E(\cdot)$ 表示均值。式(1)表示 HR 图像相对于 SR 图像更加真实的概率,式(2)表示 SR 图像相对于 HR 图像更加虚假的概率。

2.3 损失函数

HR 遥感图像含有丰富的高频信息、感知信息与

环境内容信息。为了使重建图像更细节地恢复,本实验结合内容损失、像素损失、对抗损失与 TV 损失共同约束生成器,提升整体模型的鲁棒性。

1) 内容损失

在生成网络中,生成对抗的学习方式能够保持生成图像的真实性,但是会导致大量的伪影和不确定的细节信息出现。为了确保生成的 SR 图像更加符合真实 HR 图像内容的分布,提升重建结果的质量、限制过多高频内容的产生,本实验进一步结合 Charbonier 损失函数^[18]来增强 SR 图像与 HR 图像的一致性。内容损失表达式为

$$L_{\text{cont}} = E_{I_{\text{SR}}}[\rho(\mathbf{I}_{\text{HR}} - \mathbf{I}_{\text{SR}})], \quad (3)$$

$$\rho(x) = (x^2 + \epsilon^2)^{1/2}, \quad (4)$$

式中: $\rho(\cdot)$ 表示 Charbonier 损失函数; ϵ 取 10^{-3} 。

2) 感知损失

SRGAN 模型在 VGG 的激活层前提取特征,而非 VGG 的激活层后提取特征。而随着网络的不断深入,大多数激活之后的特征信息会逐渐淡化,故激活前的特征包含更多的信息。感知损失能够激励网络恢复更多高频细节信息,以获取感知上的适配。本实验感知损失采用 SR 图与 HR 图激活前的 VGG 特征的 Charbonier 损失,表达式为

$$L_{\text{percep}} = E_{I_{\text{SR}}}\left\{\rho\left[v_{\text{feat}(n)}(\mathbf{I}_{\text{SR}}) - v_{\text{feat}(n)}(\mathbf{I}_{\text{HR}})\right]\right\}, \quad (5)$$

式中: $v_{\text{feat}(n)}(\cdot)$ 表示提取的 VGG-19 模型激活层之前的特征信息,本实验选用 VGG-19 模型中第 4 层最大的池化层之前、第 3 层卷积层之后的特征。

3) 对抗损失

判别网络的损失反馈能够优化生成网络,鼓励生成网络生成更加自然的图像,并同时优化判别网络的性能,因此对抗损失需要同时考虑生成网络与判别网络,对抗损失表达式为

$$L_{\text{adv}} = -E_{I_{\text{HR}}}\left\{\log\left[1 - D_{\text{Ra}}(\mathbf{I}_{\text{HR}}, \mathbf{I}_{\text{SR}})\right]\right\} - E_{I_{\text{SR}}}\left\{\log\left[D_{\text{Ra}}(\mathbf{I}_{\text{SR}}, \mathbf{I}_{\text{HR}})\right]\right\}, \quad (6)$$

判别损失表达式为

$$L_{\text{adv}} = -E_{I_{\text{HR}}}\left\{\log\left[D_{\text{Ra}}(\mathbf{I}_{\text{HR}}, \mathbf{I}_{\text{SR}})\right]\right\} - E_{I_{\text{SR}}}\left\{\log\left[1 - D_{\text{Ra}}(\mathbf{I}_{\text{SR}}, \mathbf{I}_{\text{HR}})\right]\right\}. \quad (7)$$

4) TV 损失

遥感图像获取过程中不免会受到噪声干扰,而重建过程会使这部分噪声放大,并且重建过程中会有一些新的噪声出现。图像中具有虚假信息的噪声有较高的总变化,而有噪图像的整体总变化量明显高于无噪图像,以此为基础通过最小化总量变化损失,能够去除图像中的噪声并保留边缘。因此,引入 TV 损失^[19-21],其表达式为

$$L_{\text{TV}} = \sum_{i,j} \left\| \mathbf{I}_{i+1,j}^{\text{SR}} - \mathbf{I}_{i,j}^{\text{SR}} \right\|_1 + \left\| \mathbf{I}_{i,j+1}^{\text{SR}} - \mathbf{I}_{i,j}^{\text{SR}} \right\|_1, \quad (8)$$

式中: $\mathbf{I}_{i,j}^{\text{SR}}$ 表示 (i,j) 点处的像素值, i 与 j 代表 SR 图水平方向与竖直方向对应坐标点。TV 损失的引入可以抑制 SR 图像伪影的生成,防止模型在训练中过拟合。

综上所述,生成损失表达式为

$$L_G = \lambda L_{\text{cont}} + L_{\text{percep}} + \eta L_{\text{adv}} + \gamma L_{\text{TV}}, \quad (9)$$

式中: λ, η, γ 为整体生成损失函数的平衡系数。

3 实验与测试结果分析

在不同数据集上进行实验,以验证所提算法的有效性。首先,在同一数据集下,改变所提算法中全局特征提取模块中卷积层大小,验证顶层卷积层对算法性能的影响;其次,对比融合 RFB 与 RRDB 对算法性能的影响;最后,在不同数据集下对比不同算法的性能,以验证所提算法的有效性。

3.1 数据集与参数设置

实验采用公开遥感 Kaggle 数据集进行训练, Kaggle 数据集由 324 个不同场景、尺寸为 3099 pixel × 2329 pixel 的 1820 张彩色遥感图像组成,分别选取其中 1300 张、200 张、320 张图像作为本实验的训练集、验证集与测试集,并在 WHU-RS19 数据集^[22]与 AID 数据集^[23]中随机各选取 100 张作为测试集。对 Kaggle 数据集进行滑动裁剪,将样本裁剪为 480 pixel × 480 pixel 作为 HR 图像,再将样本 4 倍双三次下采样为 120 pixel × 120 pixel 作为 LR 图像。

实验网络训练采用 Adam 算法进行优化,参数 β_1 设置为 0.9、 β_2 设置为 0.99;总体损失函数 λ 设置为 10、 η 设置为 5×10^{-3} 、 γ 设置为 10^{-6} ;总体迭代 20 万次,输入批量大小设定为 16,初始学习率设定为 10^{-4} ,并且迭代 5 万次学习率减半。

3.2 实验环境与评价指标

为了验证本实验改进模型的有效性,使用 Intel (R) Xeon(R) 12 核 CPU E5v4@2.20 GHz 实验平台,显卡使用 8 个 TITAN Xp,编译环境为 PyTorch 1.1.0 与 MATLAB2018a。为确保实验对比模型的公正性与客观性,首先利用同一数据集独立对每个模型进行训练,然后通过端到端方式逐一进行测试。

评价指标采用 PSNR、结构相似性(SSIM)^[24]和特征相似性(FSIM)^[25],PSNR 的值越大则重建图像质量越高,SSIM 与 FSIM 越接近 1 则表示 SR 图与 HR 越相似。

3.3 实验结果定量分析

实验探究了不同卷积核对全局特征的影响,在 Kaggle 验证集上对比只采用 3×3 卷积、同时采用 5×5 、 3×3 卷积和同时采用 7×7 、 5×5 、 3×3 卷积的 4 倍超分重建的 PSNR 值,结果如图 5 所示。从图 5 可以看出,同时采用 7×7 、 5×5 、 3×3 卷积的串联结构,PSNR 值相较于其他更高、收敛速度更快。

本实验在 Kaggle 测试集上进行算法可行性实验

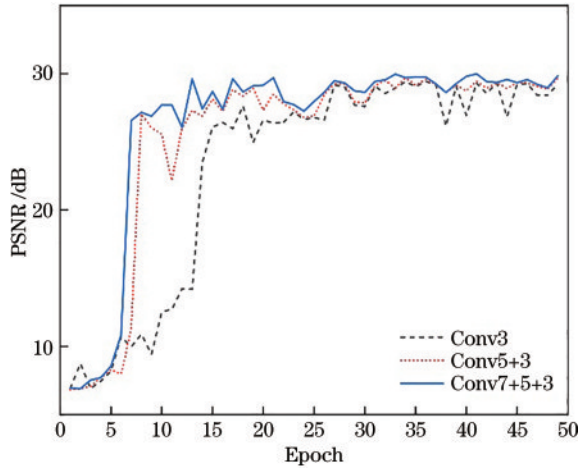


图 5 不同卷积组合的 PSNR 值

Fig. 5 PSNR values of different convolution combinations

分析,对比引入 RRDB 与 RFDB 对图像 4 倍 SR 重建性能的影响,不同模块配比下图像 SR 算法在 Kaggle 测试集上的 PSNR 值、SSIM 值与 FSIM 值如表 1 所示。ESRGAN 中引入 16 个 RRDB 作为生成网络细节特征提取结构,所提算法在此基础上进行细节特征提取结构的优化,分别使用 16 个 RRDB 与 4 个 RFDB、6 个 RFDB 和 8 个 RFDB 进行消融实验。从表 1 可以看出,使用 16 个 RRDB 与 8 个 RFDB、16 个 RRDB 与 4 个 RFDB,性能均未有较高提升。因此,为了降低运算复

表 1 不同模块配比下算法在 Kaggle 测试集上的性能

Table 1 Performance of algorithm on Kaggle test dataset under different module settings

Module	PSNR /dB	SSIM	FSIM
GAN+RFDB(16)	29.83	0.862	0.975
GAN+RRDB(16)	30.49	0.884	0.990
GAN+RRDB(16)+RFDB(4)	30.92	0.892	0.992
GAN+RRDB(16)+RFDB(6)	31.67	0.897	0.993
GAN+RRDB(16)+RFDB(8)	31.68	0.895	0.993

表 3 在 Kaggle、WHU-RS19 和 AID 上不同算法的 PSNR 平均值

Table 3 Average PSNR of different algorithms on Kaggle, WHU-RS19, and AID

Dataset	Scale	Bicubic	EDSR	SRGAN	ESRGAN	Proposed algorithm
Kaggle	2	29.01	37.51	36.91	37.76	37.99
	3	26.03	33.31	32.55	33.76	34.10
	4	24.34	30.71	30.16	31.23	31.67
WHU-RS19	2	25.59	27.86	27.15	28.75	29.06
	3	24.55	26.83	25.84	27.80	28.08
	4	22.96	24.74	23.94	25.71	26.08
AID	2	25.43	29.18	28.37	29.44	29.55
	3	22.82	25.91	25.02	26.33	26.52
	4	21.34	23.89	23.18	24.35	24.63

所提算法与 4 种对比算法在 Kaggle 测试数据集、WHU-RS19 数据集和 AID 数据集上进行 4 倍图像重

杂度并保持较高性能,采用 16 个 RRDB 模块与 6 个 RFDB 模块作为图像 SR 重建算法的细节提取模块,以保证所提算法性能达到最佳。

在全部特征提取结构选用 7×7 、 5×5 、 3×3 卷积模型、细节特征提取结构采用 16 个 RRDB 与 8 个 RFDB 的情况下,探究内容损失 L_{cont} 、感知损失 L_{percep} 、对抗损失 L_{adv} 与 TV 损失 L_{TV} 对超分重建性能的影响。表 2 给出了不同损失函数搭配在 Kaggle 测试集上 4 倍超分重建的 PSNR 值、SSIM 值与 FSIM 值,其中 SRGAN original loss 表示 SRGAN 算法的生成网损失函数。通过表 2 可以看出,同时使用 4 种损失函数约束,重建性能最优。

表 2 不同损失函数配比下算法在 Kaggle 测试集上的性能

Table 2 Performance of algorithm on Kaggle test datasets with different loss function settings

Module	PSNR /dB	SSIM	FSIM
SRGAN original loss	29.71	0.844	0.930
L_{cont}	30.63	0.874	0.931
$L_{cont}+L_{percep}$	31.21	0.883	0.931
$L_{cont}+L_{percep}+L_{adv}$	31.42	0.886	0.964
$L_{cont}+L_{percep}+L_{adv}+L_{TV}$	31.67	0.897	0.993

将所提算法与 Bicubic、EDSR、SRGAN、ESRGAN 等 4 种重建算法在 Kaggle 测试数据集、WHU-RS19 数据集和 AID 数据集上的图像重建结果进行定量数值对比。表 3~5 分别给出了 5 种重建算法在不同数据集上的平均 PSNR 值、SSIM 值与 FSIM 值。从不同评价指标可以看出,深度学习重建算法性能高于传统 Bicubic 算法,所提算法性能在 2 倍重建、3 倍重建与 4 倍重建上的效果均高于其他对比算法。计算 3 个测试集的 4 倍重建的平均评价指标可以得出,所提算法比 SRGAN 算法的 PSNR 值高出约 1.65 dB,SSIM 值高出约 0.040 (5.2%),FSIM 值高出约 0.010 (1.1%)。

建的运行时间如表 6 所示。从表 6 可以看出:SRGAN 算法由于网络结构中含有 BN 层,重建速度最慢、消耗

表 4 在 Kaggle、WHU-RS19 和 AID 上不同算法的 SSIM 平均值

Table 4 Average SSIM of different algorithms on Kaggle, WHU-RS19, and AID

Dataset	Scale	Bicubic	EDSR	SRGAN	ESRGAN	Proposed algorithm
Kaggle	2	0.856	0.970	0.960	0.962	0.972
	3	0.794	0.927	0.906	0.918	0.935
	4	0.737	0.874	0.848	0.881	0.897
WHU-RS19	2	0.800	0.942	0.844	0.834	0.854
	3	0.742	0.900	0.797	0.796	0.822
	4	0.689	0.848	0.746	0.764	0.788
AID	2	0.712	0.978	0.802	0.790	0.798
	3	0.660	0.935	0.757	0.754	0.767
	4	0.613	0.881	0.708	0.724	0.736

表 5 在 Kaggle、WHU-RS19 和 AID 上不同算法的 FSIM 平均值

Table 5 Average FSIM of different algorithms on Kaggle, WHU-RS19, and AID

Dataset	Scale	Bicubic	EDSR	SRGAN	ESRGAN	Proposed algorithm
Kaggle	2	0.861	0.993	0.994	0.998	0.999
	3	0.850	0.990	0.990	0.993	0.997
	4	0.834	0.983	0.981	0.986	0.993
WHU-RS19	2	0.832	0.910	0.910	0.914	0.915
	3	0.822	0.907	0.906	0.909	0.912
	4	0.806	0.901	0.898	0.903	0.908
AID	2	0.824	0.903	0.904	0.908	0.906
	3	0.814	0.900	0.900	0.903	0.903
	4	0.798	0.894	0.892	0.897	0.899

表 6 在 Kaggle、WHU-RS19 和 AID 上不同算法的运行时间

Table 6 Running time of different algorithms on Kaggle, WHU-RS19, and AID unit: s

Algorithm	Kaggle	WHU-RS19	AID
Bicubic	128.607	40.322	58.169
EDSR	224.036	81.723	119.134
SRGAN	283.547	89.812	128.725
ESRGAN	271.077	84.853	121.321
Proposed algorithm	280.324	87.465	125.364

时间最长; Bicubic 算法仅是插值操作所以所需时间最短; 所提算法因添加全局特征提取模块并引入 RFB,

检测所需时间略高于 ESRGAN 算法, 但如表 3~5 所示, 所提算法相较于 ESRGAN 算法未增加太多时间的情况下, PSNR、SSIM 和 FSIM 值均高于其他算法, 说明所提算法重建图像质量优于其他算法。

3.4 实验结果定性分析

从 Kaggle 测试数据集、WHU-RS19 数据集和 AID 数据集 4 倍重建结果中各选取 2 幅图进行局部细节放大对比, 结果如图 6~8 所示。从图 6~8 可以看出: Bicubic 算法的重建结果较为模糊, 缺少细节信息; SRGAN 算法与 EDSR 算法相较于 Bicubic 算法重建结果包含较多的细节信息, 但 SRGAN 算法在一些边缘细节出现伪影与噪声; ESRGAN 算法重建结果较优,

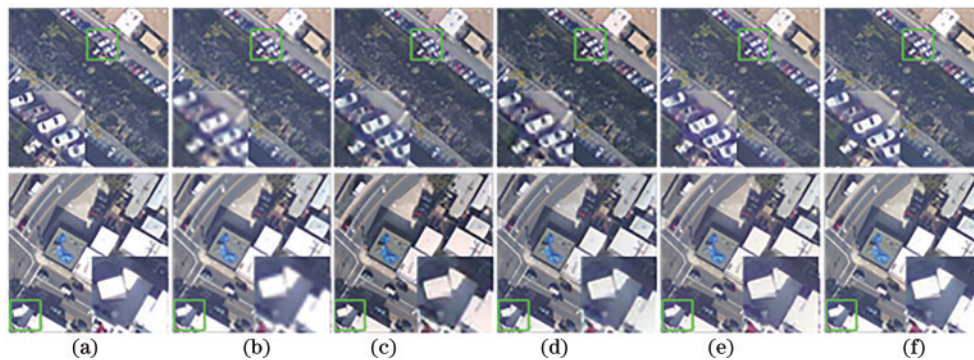


图 6 不同算法在 Kaggle 测试数据集上的重建图像。(a) HR 图; (b) Bicubic; (c) SRGAN; (d) EDSR; (e) ESRGAN; (f) 所提算法
Fig. 6 Image reconstruction of different algorithms on Kaggle test dataset. (a) HR; (b) Bicubic; (c) SRGAN; (d) EDSR; (e) ESRGAN; (f) proposed algorithm

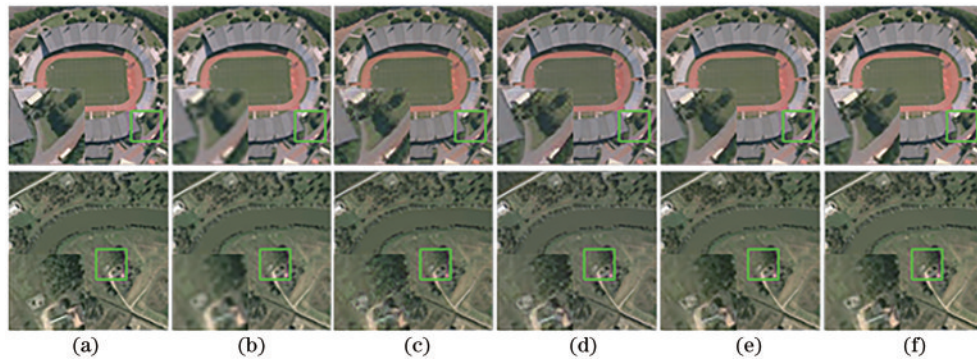


图 7 不同算法在 WHU-RS19 数据集上的重建图像。(a) HR 图; (b) Bicubic; (c) SRGAN; (d) EDSR; (e) ESRGAN; (f) 所提算法

Fig. 7 Image reconstruction of different algorithms on WHU-RS19 dataset. (a) HR; (b) Bicubic; (c) SRGAN; (d) EDSR; (e) ESRGAN; (f) proposed algorithm

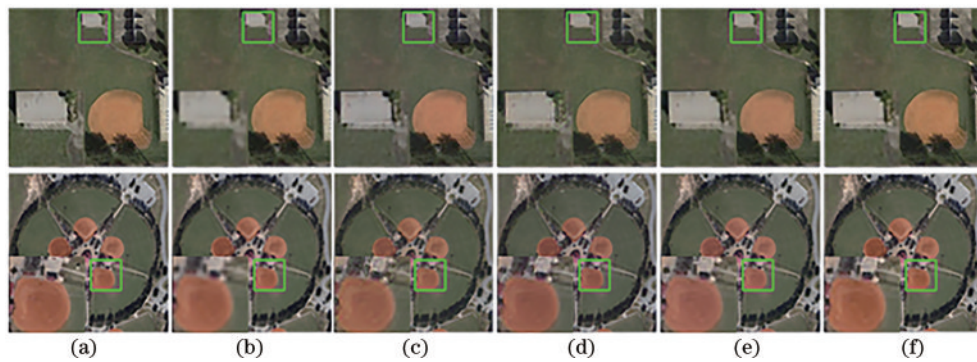


图 8 不同算法在 AID 数据集上的重建图像。(a) HR 图; (b) Bicubic; (c) SRGAN; (d) EDSR; (e) ESRGAN (f) 所提算法

Fig. 8 Image reconstruction of different algorithms on AID dataset. (a) HR; (b) Bicubic; (c) SRGAN; (d) EDSR; (e) ESRGAN; (f) proposed algorithm

但部分细节信息也出现伪影与噪声,边缘锐化效果较差;所提算法较其他几种算法重建结果较为清晰,包含更多的细节信息与纹理信息,且边缘锐化效果较好。通过图 6 中局部放大细节可以看出,所提算法重建图像色彩亮度更加贴近真实 HR 图,图中对于汽车边缘的处理较好。从图 7、8 可以看出,所提算法重建出的建筑物细节纹理较为清晰。

4 结 论

基于 GAN 的 SR 重建算法,提出一种改进的彩色遥感图像重建算法。引入 RRDB 进行初级细节特征提取,利用密集的多级网络连接有效扩充网络容量,使用剩余缩放因子实现不同层的特征共享、增加网络深度,有利于提取图像中的细节特征。引入多尺度 RFB,利用多尺度小卷积核结构中不同感受野具有不同离心率性质,提取非常精细的高频特征。去除网络中的 BN 层、提升网络训练效率,结合 Charbonnier 损失函数与 TV 损失函数提升网络训练稳定性,并选用相对鉴别器以提升重建遥感图像的局部纹理与细节匹配度。定量分析与定性分析结果表明:全局特征提取模块采用多重卷积串联结构能有效提升重建效果;细节特征提取同时选用 RRFDB 与 RRDB 可以提升重建质

量。所提算法重建图像质量相较于其他算法均有所提高。后续将针对其他领域场景的图像进行 HR 重建,进一步提升重建算法的泛化能力。

参 考 文 献

- [1] 吉长东, 康仲林. 高分六号卫星城市建成区提取方法[J]. 激光与光电子学进展, 2021, 58(4): 0428003.
Ji C D, Kang Z L. Extraction method of urban area from GF-6 satellite[J]. Laser & Optoelectronics Progress, 2021, 58(4): 0428003.
- [2] 黎经元, 厉小润, 赵辽英. 融合空频域特征的光学遥感图像舰船目标检测[J]. 激光与光电子学进展, 2021, 58(4): 0415005.
Li J Y, Li X R, Zhao L Y. Ship target detection in optical remote sensing images based on spatial and frequency features[J]. Laser & Optoelectronics Progress, 2021, 58(4): 0415005.
- [3] 朱淑鑫, 周子俊, 顾兴健, 等. 基于 RCF 网络的遥感图像场景分类研究[J]. 激光与光电子学进展, 2021, 58(14): 1401001.
Zhu S X, Zhou Z J, Gu X J, et al. Scene classification of remote sensing images based on RCF network[J]. Laser & Optoelectronics Progress, 2021, 58(14): 1401001.
- [4] Guo D E, Xia Y, Xu L M, et al. Remote sensing image

- super-resolution using cascade generative adversarial nets [J]. *Neurocomputing*, 2021, 443: 117-130.
- [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] 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, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 1646-1654.
- [8] 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.
- [9] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[J]. *Communications of the ACM*, 2020, 63(11): 139-144.
- [10] 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.
- [11] Liu S T, Huang D, Wang Y H. Receptive field block net for accurate and fast object detection[M]//Ferrari V, Hebert M, Sminchisescu C, et al. *Computer vision-ECCV 2018*. Lecture notes in computer science. Cham: Springer, 2018, 11215: 404-419.
- [12] Zhang S, Yuan Q Q, Li J, et al. Scene-adaptive remote sensing image super-resolution using a multi-scale attention network[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(7): 4764-4779.
- [13] Dong X Y, Sun X, Jia X P, et al. Remote sensing image super-resolution using novel dense-sampling networks[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(2): 1618-1633.
- [14] Dong X Y, Wang L G, Sun X, et al. Remote sensing image super-resolution using second-order multi-scale networks[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(4): 3473-3485.
- [15] Jiang K, Wang Z Y, Yi P, et al. Edge-enhanced GAN for remote sensing image super-resolution [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(8): 5799-5812.
- [16] Lei S, Shi Z W, Zou Z X. Coupled adversarial training for remote sensing image super-resolution[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(5): 3633-3643.
- [17] Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2016: 2261-2269.
- [18] Lai W S, Huang J B, Ahuja N, et al. Deep Laplacian pyramid networks for fast and accurate super-resolution [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 5835-5843.
- [19] Chen M, Pu Y F, Bai Y C. Low-dose CT image denoising using residual convolutional network with fractional TV loss[J]. *Neurocomputing*, 2021, 452: 510-520.
- [20] Zhou C, Gu Z H, Gao Y, et al. An improved style transfer algorithm using feedforward neural network for real-time image conversion[J]. *Sustainability*, 2019, 11(20): 5673.
- [21] Zhang N, Wang Y C, Zhang X, et al. An unsupervised remote sensing single-image super-resolution method based on generative adversarial network[J]. *IEEE Access*, 2020, 8: 29027-29039.
- [22] Dai D X, Yang W. Satellite image classification via two-layer sparse coding with biased image representation[J]. *IEEE Geoscience and Remote Sensing Letters*, 2011, 8(1): 173-176.
- [23] 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.
- [24] 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.
- [25] Zhang L, Zhang L, Mou X Q, et al. FSIM: a feature similarity index for image quality assessment[J]. *IEEE Transactions on Image Processing*, 2011, 20(8): 2378-2386.