

文章编号: 1672-8785(2023)07-0046-06

基于深度学习的风云四号卫星 图像超分辨率重建

谢 梦^{1,3} 杨春蕾^{1,3*} 顾明剑^{1,2,3} 胡 勇^{1,2,3}

(1. 中科学技术物理苏州研究院, 江苏 苏州 215000;

2. 中国科学院上海技术物理研究所, 上海 200083;

3. 云遥动力科技(苏州)有限公司, 江苏 苏州 215000)

摘 要: 风云四号 A 卫星(FY-4A)部分通道的图像分辨率较低, 影响风云卫星多通道协同监测能力。针对该问题, 提出一种改进的超分辨率生成对抗网络(Enhanced Super-Resolution Generative Adversarial Networks, ESRGAN)算法来实现 FY-4A 影像的超分辨率重建。该方法基于 ESRGAN 的生成器架构, 利用迁移学习策略, 将预训练权重作为模型的初始值, 设计了一组包含 5 层空洞卷积层的残差密集模块(Residual-in-Residual Dense Block, RRDB), 并优化了损失函数。结果表明, 在 4 倍影像分辨率重建下, 相比于 ESRGAN 算法, 改进的 ESRGAN 算法在峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)、结构相似性(Structural Similarity, SSIM)、空间相关系数(Correlation Coefficient, CC)上分别提高了 0.704、0.029、0.002, 均方根误差(Root-Mean-Square Error, RMSE)降低了 10%, 且重建影像更加清晰自然, 纹理更加细致。

关键词: 风云四号; 深度学习; 图像重建; 超分辨率

中图分类号: P237 文献标志码: A DOI: 10.3969/j.issn.1672-8785.2023.07.008

Super Resolution Reconstruction for FY-4 Satellite Images Based on Deep Learning

XIE Meng^{1,3}, YANG Chun-lei^{1,3*}, GU Ming-jian^{1,2,3}, HU Yong^{1,2,3}

(1. Suzhou Institute of Technical Physics, Suzhou 215000, China;

2. Shanghai Institute of Technical Physics, Chinese Academy of Sciences, Shanghai 200083, China;

3. Yunyao Dynamic Technology (Suzhou) Company, Suzhou 215000, China)

Abstract: The image resolutions of some channels of Fengyun-4A (FY-4A) satellite are low, which affects the ability of multi-channel collaborative monitoring of Fengyun satellites. To solve this problem, enhanced super-resolution generative adversarial networks (ESRGAN) algorithm is proposed to implement the super-

收稿日期: 2023-03-24

基金项目: 苏州市科技项目(SYG202135)

作者简介: 谢梦(1994-), 女, 江苏徐州人, 硕士研究生, 助理工程师, 主要从事遥感图像处理方面的研究。

*通讯作者: E-mail: 15851813608@163.com

resolution reconstruction of FY-4A images. Based on the generator architecture of ESRGAN, the transfer learning strategy is used, and the pre-training weight is taken as the initial value of the model in this method. A set of residual-in-residual dense blocks (RRDB) containing 5 hollow convolutional layers is designed, and the loss function is optimized. The results show that under the reconstruction of 4 times image resolution, compared with ESRGAN algorithm, the peak signal-to-noise ratio (PSNR), structural similarity (SSIM) and correlation coefficient (CC) of the improved ESRGAN algorithm increase by 0.704, 0.029 and 0.002 respectively, while root-mean-square error (RMSE) decreases by 10%. The reconstructed images are clearer and more natural, and the texture is more detailed.

Key words: Fengyun-4; deep learning; image reconstruction; super resolution

0 引言

随着我国风云卫星的发展,其载荷性能更加优越。风云卫星数据主要用于天气监测与预报、防灾减灾、气候变化应对、生态环境监测、“一带一路”建设等领域。因此,有必要对风云卫星进行图像超分辨率重建,提高其空间分辨率。这有助于提升天气监测预报和灾害性天气预警水平,尤其对突发性中小尺度天气系统监测具有重要意义^[1-2],同时可为国防安全、森林火灾检测、环境监控等提供更加精准的信息。

图像超分辨率重建^[3]是指将低分辨率数据在空间范围内重建为高分辨率数据,并且使后者的视觉效果远远超过前者,从而提高地物信息的分辨能力,反映出细节更好的地面信息。目前常见的超分辨率重建方法主要包括基于插值、基于重构和基于学习的方法。其中,基于插值的方法有最近邻插值法、双线性内插法和三次内插法等^[4-6]。采用该方法生成的高分辨率图像过于平滑,不能很好地保留原始图像的细节,也没有增加图像的细节信息,而且容易遗漏中小尺度天气信息和忽略局地地形特征^[7]。基于重构的方法(如最大后验概率估计法等)相对成熟^[8],但图像间的配准和计算效率有待优化。基于学习的方法通过制作高、低分辨率的数据集,主动学习低分辨率图像和高分辨率图像之间的点对点的映射关系。

近年来,深度学习展现出强大的复杂数据处理能力和特征提取的潜力^[9],在图像超分辨率方面取得很大的突破,极大提高了图像超分

辨率重建的准确性^[10-11]。文献[12]提出了基于深度学习的高分四号图像中波红外超分辨率重建方法。实验表明,该方法有效提高了中波红外波段的空间分辨率,使均方误差至少下降 7.54,且目视效果清晰。文献[13]通过设计卷积神经网络来重建单幅遥感影像。结果表明,单幅遥感图像重建结果细节表现较好。文献[14]提出用 Res2-Unet 深度学习网络对 RGB-高光谱图像进行重建。实验表明,在图像的低频平坦区和高频纹理区,该方法均获得了更好的视觉效果。文献[15]利用一种轻量化卷积神经网络对火星影像进行图像超分辨率重建。结果表明,在 4 倍和 8 倍场景下,PSNR 值均有所提高。文献[16]采用 SRGAN 模型完成了单幅遥感影像的超分辨率重建。文献[17]通过基于迁移学习的 ESRGAN 模型实现了高分辨率滑坡影像集的超分辨率重建,并取得了更优结果。因此,基于深度学习的方法在图像超分辨率重建中有着巨大的潜力。

本文针对风云卫星的特点,基于改进的 ESRGAN 模型,采用预训练权重作为模型初始值,并对模型参数进行微调,从而提升影像重建的精度。最后在试验区上取得了较好的定量和定性效果,有利于促进风云卫星在各行业的深入应用。

1 超分辨率重建方法

1.1 ESRGAN 模型

ESRGAN^[18]能够在单幅图像超分辨率期间生成真实感纹理。ESGRAN 模型基于 SRGAN 模型进行改进,引入没有批量归一化的

残差密集模块 (Residual-in-Residual Dense Block, RRDB) 作为基本的网络构建单元, 结合多层残差网络和密集连接, 并使用残差缩放和更小的初始化来促进训练一个非常深的网络。同时, ESRGAN 模型使用激活前的特征来改善感知损失, 可提供对亮度一致性和纹理恢复更强的监督力, 并使生成的图像有更加清晰的边缘。

1.2 ESRGAN-HD 模型

研究人员采用基于 ESRGAN 的生成器架构, 设计了一组包含 5 层空洞卷积层的残差密集模块并优化了损失函数, 得到了增强的超分辨率重建生成对抗模型——ESRGAN-HD 模型。该结构能提取更多丰富的特征信息, 且保持参数不变。ESRGAN-HD 模型结构如图 1 所示。

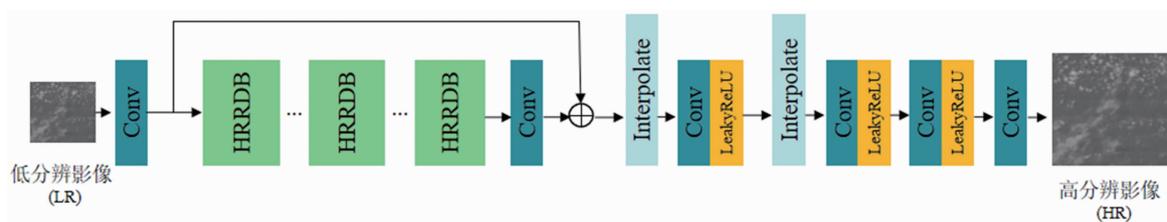


图 1 ESRGAN-HD 模型结构图

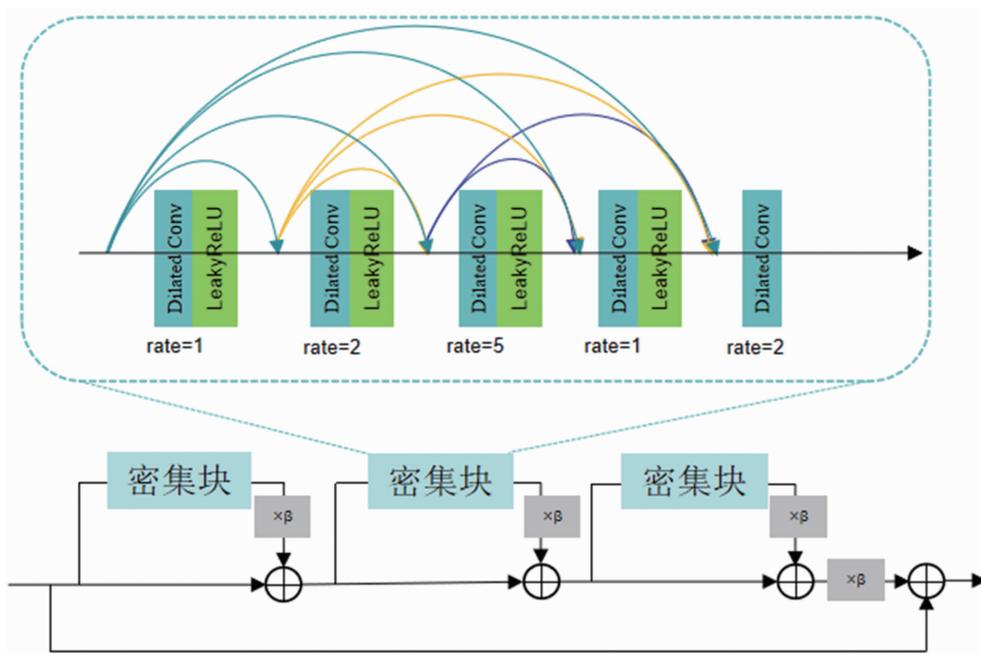


图 2 HD_RRDB 模块示意图

1.2.1 混合空洞残差密集模块

不同尺度的图像具有不同的特征, 这些丰富的特征有助于生成高质量的重建图像^[19-20]。因此, 本文设计了一组包含 5 层空洞卷积层的密集模块(空洞率为[1, 2, 5, 1, 2]), 即混合空洞残差密集模块 (Hybrid Dilated Residual-in-Residual Dense Block, HD_RRDB)。该模块借鉴混合空洞卷积 (Hybrid Dilated Convolution, HDC)^[21-22], 利用多层空洞卷积获得不同尺度的感受野和信息, 通过不同大小的感受野使得卷积层在更加细粒度级别表达多尺度特性, 从而在没有增加计算复杂度的同时更加有效地提取特征图信息。在 ESRGAN-HD 中使用了 23 个 HD_RRDB 模块。其中, HD_RRDB 包含 3 个密集块, 每一个密集块由 5 层空洞卷积进行密集连接, 缩放残差 β 为 0.2。HD_RRDB 模块如图 2 所示。

1.2.2 损失函数设计

生成器中的损失函数是影响高分辨率影像视觉质量的重要指标^[17]。均方误差可以防止图像失真,但导数不连续会导致寻找最优解的过程低效;平均绝对误差在优化过程中更为稳定和准确,但是易使生成的图像更平滑。因此,为了优化生成器网络模型中的参数,设计了一个由均方误差和平均绝对误差组成的损失函数 Loss:

$$L_{MAE} = \frac{1}{N} \sum_{i=1}^N \|X_{HR}^i - D(X_{LR}^i)\|_1 \quad (1)$$

$$L_{MSE} = \frac{1}{N} \sum_{i=1}^N (X_{HR}^i - D(X_{LR}^i))^2 \quad (2)$$

$$Loss = L_{MAE} + L_{MSE} \quad (3)$$

式中, D 为网络模型, N 为训练对的个数, X_{HR} 为高分辨率图像, X_{LR} 为低分辨率图像。

2 试验

2.1 试验环境及训练数据

软件环境采用的操作系统为 Linux (2.6.18-164.el5 版本), 运行内存为 16GB。采用 Anaconda3 软件搭建 Python3.7 环境, 基于 PyTorch 深度学习框架进行训练测试。

FY-4A 是中国新一代静止气象卫星的首发星。本文使用 2018 年 7 月研究区域(35°N ~ 45°N, 110°E ~ 129°E)风云影像的 AGRI 可见光近红外通道进行训练和测试。其中, 2018 年可见光通道 4 km 的影像作为低分辨率影像用于模型的训练测试; 1 km 的影像作为高分辨率影像用于验证精度。数据集共计 832 张, 按照 7:2:1 被划分为训练集、验证集和测试集。

2.2 训练过程

本文基于 ESRGAN-HD 模型, 利用迁移学习策略, 并将文献[18]中的预训练权重作为模型的初始值。通过输入 FY-4A 可见光近红外通道信息对模型参数进行微调, 进而提取 FY-4A 影像的空间特征, 实现图像分辨率从 4 km 到 1 km 的重构, 并且保留 4 km 图像分辨率的所有通道信息。模型输入尺寸为 32×32,

输出尺寸为 128×128。经过多次试验后发现最优参数组合: 模型的批尺寸为 8, 学习率为 0.0001, 迭代次数为 40, 优化器为 Adam($\beta_1 = 0.9, \beta_2 = 0.999$), 激活函数为 LeakyReLU。

2.3 评价指标

本文使用 PSNR 和 SSIM 评价图像重建的质量, 并利用 RMSE 和 CC 对模型预测结果进行精度判定。PSNR 是目前使用最普遍的图像重建评价指标(单位为 dB)。一般情况下, PSNR 的数值越高, 表示重建图像与原始图像越接近。为了避免该方法的局限性, 同时采用 SSIM 评价图像质量。SSIM 表示超分辨图像与实际高分辨率图像的结构相似程度, 其取值不超过 1。SSIM 值越接近 1, 说明它们的结构越相似, 重建效果越好。RMSE 用于衡量预测值与实测值之间的偏差。RMSE 值越小, 则偏差越小, 代表模型精度越高; CC 值越接近 1, 则说明它们的相关性越高。

$$PSNR = 10 \lg \left(\frac{MAX_I^2}{MSE} \right) \quad (4)$$

式中, MAX_I^2 是表示图像点颜色的最大数值。若每个采样点用 8bit 表示, 则其值为 255。

$$SSIM = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_1)} \quad (5)$$

式中, μ_x, μ_y 为均值, σ_x, σ_y 为标准差, σ_{xy} 为协方差, $c_1 = (0.01L)^2, c_2 = (0.03L)^2, L$ 对于 8bit 灰度图的取值为 255。

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - S_i)^2}{n}} \quad (6)$$

$$CC = \frac{\sum_{i=1}^n (O_i - \bar{O})(S_i - \bar{S})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^n (S_i - \bar{S})^2}} \quad (7)$$

式中, n 是像素数; O_i 和 S_i 分别是观测值和预测值; \bar{O} 和 \bar{S} 分别是相应的平均值。

2.4 结果与分析

2.4.1 统计对比

本文选择研究区域(35°N~45°N, 110°E~129°E)的 FY-4A 影像进行验证测试。该区域

内的地物类型丰富, 包含水、裸地等。本文选用 2018 年 7 月 16 日 4 个时刻的影像作为测试集(影像尺寸为 1200×784), 并计算 PSNR、SSIM、RMSE 和 CC 指标, 最后对其取平均值。表 1 列出了 FY-4A 可见光近红外通道的超分辨率重建统计结果。

本文将测试结果和已有方法(包括最近邻插值、双三次插值、ESRGAN 算法)作对比, 测试结果均是以 4 倍分辨率重建后的影像。从表 1 可以看出, ESRGAN 算法在 4 个指标上均优于传统插值方法, 表明基于深度学习的方法能更准确地重构出较高分辨率的遥感影像, 并且具备提取历史空间相关性的能力。与预训练权重的 ESRGAN 算法相比, ESRGAN-HD 算法的 PSNR、SSIM、CC 分别提高了 0.704、0.008、0.001, RMSE 降低了 10%, 说明 ESRGAN-HD 算法采用的 HD_RRDB 模块和损失函数能有效地提取 FY-4A 更丰富的空间特征。

2.4.2 个例分析

为验证本文方法的有效性, 选用 2018 年 7 月 16 日 8 时 19 分北京、天津地区的 FY-4A 通道 2 作为个例进行分析。表 2 列出了采用不同方法在 FY-4A 通道 2 进行超分辨率重建的统计结果。图 3 所示为采用多种算法获得的高分辨率影像结果。

从图 3 可以明显看出, 相比于传统插值方法, 在 4 倍分辨率重建场景下基于深度学习的

方法能更准确地重构出较高分辨率的遥感影像。采用最近邻插值和双三次插值算法重建的影像较为模糊, 缺少细节信息。与其他几种算法相比, ESRGAN-HD 算法重建结果的边缘更清晰, 细节更完整, 结构相似度更高, 图像的细节纹理更突出且边缘锐化效果较好。通过局部放大细节可以看出, 重建影像与真实高分辨率影像更接近。从表 2 可以看出, 与 ESRGAN 算法相比, ESRGAN-HD 方法的 PSNR、SSIM、CC 指标分别提高了 0.746、0.02、0.002, RMSE 指标降低了 4%。结果表明, 在 4 倍分辨率重建下, 本文方法的有效性得到了验证。通过加入风云影像进行训练及参数微调, 能提取更加丰富的可见光通道的空间信息, 并可保持定量化及纹理特征, 对影像重建有一定的提升效果。

3 结束语

本文针对 FY-4A 卫星的特点, 提出了一种改进的 ESRGAN 模型。基于迁移学习策略, 将预训练作为初始值, 设计了一组包含 5 层空洞卷积层的残差密集模块并优化了损失函数。将风云卫星影像输入模型训练, 可实现端到端的 4 倍影像超分辨率重建, 即将 FY-4A 的空间分辨率由 4 km 重构至 1 km, 并保留所有通道信息。本文以研究区域作为试验对象, 采用传统插值方法、ESRGAN 算法以及 ESRGAN-

表 1 可见光近红外通道的超分辨率重建统计结果

采用方法	PSNR	SSIM	RMSE	CC
最近邻插值	32.415	0.808	0.024	0.986
双三次插值	33.911	0.849	0.020	0.990
ESRGAN(预训练权重)	34.035	0.870	0.020	0.991
ESRGAN-HD	34.739	0.878	0.018	0.992

表 2 FY-4A 通道 2 超分辨率重建的统计结果

采用方法	PSNR	SSIM	RMSE	CC
最近邻插值	31.298	0.787	0.027	0.986
双三次插值	32.582	0.831	0.023	0.988
ESRGAN(预训练权重)	32.540	0.851	0.023	0.988
ESRGAN-HD	33.286	0.871	0.022	0.990

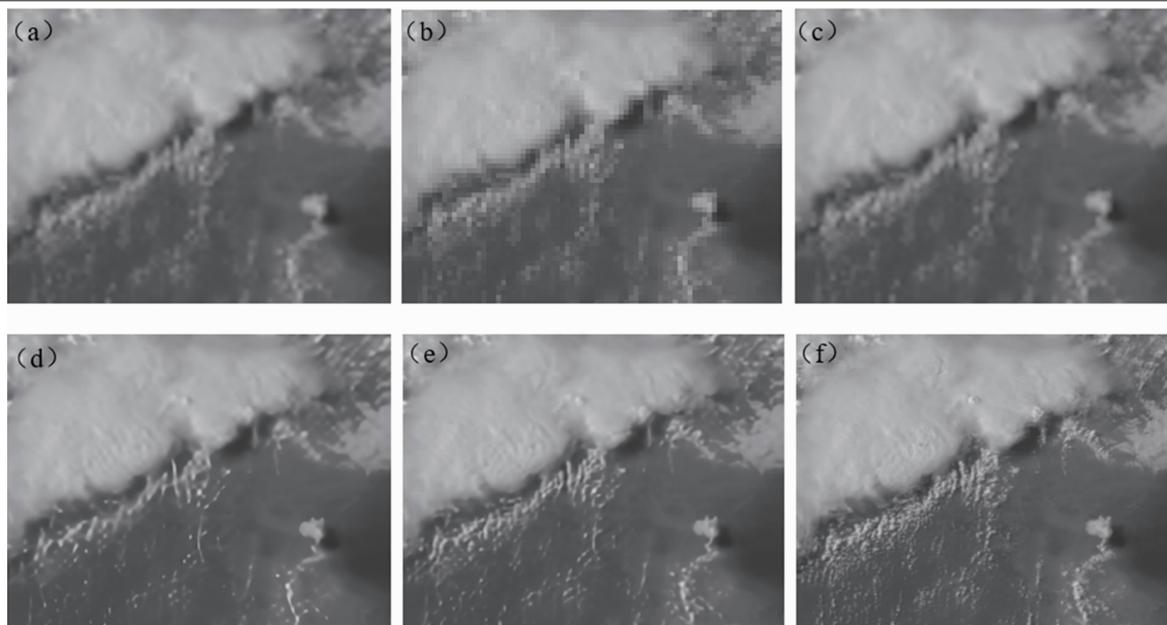


图 3 2018年7月16日8时19分 FY-4A 通道 2 的超分辨率重建局部结果图: (a) FY-4A 影像(分辨率为 4 km); (b)采用最近邻插值法得到的高分辨率影像; (c)采用双三次插值法得到的高分辨率影像; (d)基于 ESRGAN 预训练权重得到的高分辨率影像; (e)采用 ESRGAN-HD 方法得到的高分辨率影像; (f) FY-4A 影像(分辨率为 1 km)

HD 算法对重建结果进行了定量和定性评价。结果表明, 本文算法重建影像的目视效果更清晰、细节信息更丰富, 与实际高分辨率影像更接近。未来将用该算法验证风云卫星的长波红外通道, 并增加长波红外通道数据来提高中长红波外通道的重建效果, 从而扩大风云卫星红外通道在遥感气象领域的潜力和应用范围。

参考文献

- [1] 茅志仁. 基于深度学习图像超分辨的气象数据空间降尺度研究 [D]. 武汉: 武汉大学, 2019.
- [2] 周康, 丁立新, 程建新. 基于深度学习超分辨率网络的降水时间降尺度预测方法: CN112734648A [P]. 2021-04-30.
- [3] 陈博洋. 超分辨率图像重建分析和应用 [J]. 红外, 2006, **27**(3): 39-43.
- [4] 李新, 程国栋, 卢玲. 空间内插方法的比较 [J]. 地球科学进展, 2000, **25**(13): 261-265.
- [5] 彭彬, 周艳莲, 高苹, 等. 气温插值中不同空间插值方法的适用性分析——以江苏为例 [J]. 地球信息科学学报, 2011, **13**(4): 539-547.
- [6] 徐振亚, 任福民, 杨修群, 等. 日最高温度统计降尺度方法的比较研究 [J]. 气象科学, 2012, **32**(4): 395-402.
- [7] 程文聪, 史小康, 张文军, 等. 基于深度学习的数值模式降水产品降尺度方法 [J]. 热带气象学报, 2020, **36**(3): 307-316.
- [8] 郑蓉珍, 赵芳, 李波, 等. 混合高斯/泊松最大似然函数下的 CBCT 图像重建 [J]. 光学精密工程, 2020, **28**(2): 457-464.
- [9] 陈睿敏, 孙胜利. 基于深度学习的红外遥感信息自动提取 [J]. 红外, 2017, **38**(8): 37-43.
- [10] 刘凑华, 林建, 曹勇, 等. 网格降水预报时间降尺度方法改进 [J]. 暴雨灾害, 2021, **40**(6): 617-625.
- [11] 蔡体健, 彭潇雨, 石亚鹏, 等. 通道注意力与残差级联的图像超分辨率重建 [J]. 光学精密工程, 2021, **29**(1): 142-151.
- [12] 贺智, 贺丹. 基于深度学习的高分四号卫星图像超分辨率重建 [J]. 遥感学报, 2020, **24**(12): 1500-1510.
- [13] 李欣, 韦宏卫, 张洪群. 结合深度学习的单幅遥感图像超分辨率重建 [J]. 中国图象图形学报, 2018, **23**(2): 209-218.
- [14] 宋蓓蓓, 马穗娜, 何帆, 等. Res2-Unet 深度学

- 习网络的 RGB-高光谱图像重建 [J]. *光学精密工程*, 2022, **30**(13): 1606-1619.
- [15] 耿铭昆, 吴凡路, 王栋. 轻量化火星遥感影像超分辨率重建网络 [J]. *光学精密工程*, 2022, **30**(12): 1487-1498.
- [16] 韩志晟, 孙丕川, 唐超. 面向单幅遥感图像的生成对抗网络超分辨率重建 [J]. *测绘通报*, 2021, **66**(8): 106-110.
- [17] 方留杨, 刘天逸, 赵鑫, 等. 基于增强生成对抗网络的滑坡影像集超分辨率重建 [J]. *测绘通报*, 2023, **68**(1): 45-51.
- [18] Wang X, Yu K, Wu S. ESRGAN: Enhanced Super-Resolution Generative Adversarial Networks [C]. Munich: Computer Vision-ECCV 2018 Workshops, 2018.
- [19] Lai W S, Huang J B, Ahuja N, et al. Deep Laplacian Pyramid Networks for Fast and Accurate Super-Resolution [C]. Honolulu: 2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017.
- [20] Chollet F. Xception: Deep Learning with Depthwise Separable Convolutions [C]. Honolulu: 2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017.
- [21] Wang P, Chen P, Yuan Y, et al. Understanding Convolution for Semantic Segmentation [C]. Stateline: 2018 IEEE Winter Conference on Applications of Computer Vision, 2018.
- [22] Huang B, He B, Wu L, et al. Deep Residual Dual-Attention Network for Super-Resolution Reconstruction of Remote Sensing Images [J]. *Remote Sensing*, 2021, **13**(14): 2784.