

中图法分类号: P184.8 文献标识码: A 文章编号: 1006-8961(2025)09-3050-16

论文引用格式: Miao D R B, Yan J G, Tu Z G and Barriot Jean-Pierre. 2025. Adaptive multi-scale super-resolution reconstruction for lunar images captured by a narrow-angle camera. Journal of Image and Graphics, 30(9):3050-3065(苗丁锐博, 鄢建国, 涂志刚, Jean-Pierre Barriot. 2025. 窄角相机月球影像自适应多尺度超分辨率重建. 中国图象图形学报, 30(9):3050-3065)[DOI:10.11834/jig.250126]

窄角相机月球影像自适应多尺度超分辨率重建

苗丁锐博¹, 鄢建国^{1*}, 涂志刚¹, Jean-Pierre Barriot^{1,2}

1. 武汉大学测绘遥感信息工程全国重点实验室, 武汉 430000; 2. 塔希提大地测量天文台, 塔希提 98723, 法国

摘要: 目的 针对月球南极窄角相机(narrow-angle camera, NAC)影像因“求和”模式导致空间分辨率显著下降、关键地貌模糊的问题, 本文旨在通过超分辨率技术恢复其精细地貌, 为月球科学与探测任务提供高质量数据。方法 构建模拟NAC“求和”模式下多尺度退化的月球影像数据集, 通过模拟“求和”模式得到包含2倍、3倍和4倍下采样的退化影像, 用于模型训练和验证。进一步, 提出融合卷积神经网络(convolutional neural network, CNN)与Transformer的多尺度超分辨率模型(multi-scale super resolution Transformer, MSRT)。其创新性在于采用共享Transformer骨干提取跨尺度深度特征, 并为各尺度设计独立的轻量化上采样分支, 实现“主干共享、分支特化”的高效重建, 提升了对复杂退化的适应性与精度, 兼顾模型复杂度。结果 实验结果表明, MSRT在2倍、3倍及4倍超分任务中均显著优于对比方法。在最具挑战的4×任务(2 m/像素→0.5 m/像素)中, 峰值信噪比(peak signal-to-noise ratio, PSNR)达28.73 dB, 结构相似性指数(structural similarity index, SSIM)为0.923。消融研究验证了模型设计的有效性。可视化结果证实MSRT能有效抑制伪影, 清晰重建小型陨石坑、岩块等精细月表地貌。结论 本文提出的MSRT模型有效解决了月球NAC影像多尺度退化问题, 可显著提升月表微小地貌特征的重建质量, 为精细地质分析、着陆区评估和巡视器安全路径规划提供了高质量的数据支持和技术保障。

关键词: 超分辨率重建; 月球窄角相机; Transformer; 多尺度; 深度学习

Adaptive multi-scale super-resolution reconstruction for lunar images captured by a narrow-angle camera

Miao Dingruibo¹, Yan Jianguo^{1*}, Tu Zhigang¹, Jean-Pierre Barriot^{1,2}

1. State Key Laboratory of Information Engineering in Surveying, Mapping and Remote Sensing, Wuhan University, Wuhan 430000, China; 2. the Geodesy Observatory of Tahiti, Tahiti 98723, France

Abstract: Objective The lunar south polar region is a prime focus for international scientific inquiry and future exploration missions due to its unique geological setting and the potential for significant volatile resources, notably water ice within permanently shadowed regions (PSRs). High-resolution imagery is crucial for characterizing these terrains, enabling safe landing site selection, effective rover operations, resource prospecting, and the advancement of our understanding of lunar geology. The narrow-angle camera (NAC) aboard the lunar reconnaissance orbiter (LRO) provides vital high-resolution (up to 0.5 m/pixel) data. However, the south polar region's extreme illumination conditions—low sun angles and extensive shadowing—result in a poor signal-to-noise ratio (SNR) for NAC images. To compensate for this situation, the NAC

收稿日期: 2025-03-27; 修回日期: 2025-05-23; 预印本日期: 2025-05-30

* 通信作者: 鄢建国 jigyan@whu.edu.cn

基金项目: 国家重点研发计划资助(2022YFF0503202); 国家自然科学基金项目(42241116)

Supported by: National Key R&D Program of China(2022YFF0503202); National Natural Science Foundation of China(42241116)

often employs a pixel summation mode, especially in these polar areas, which averages or sums pixel values (e. g. , in 2×2 to 4×4 blocks) to enhance SNR. However, although this process improves image brightness, it also severely degrades the spatial resolution, reducing a 0.5 m/pixel image to 1~2 m/pixel or coarser. This loss of detail critically impairs the identification of fine-scale geomorphological features (small craters, rock distributions, subtle slopes) that are essential for scientific interpretation (e. g. , crater dating, regolith studies, volatile detection) and mission engineering (e. g. , hazard avoidance for landers, rover trafficability assessment, ISRU site evaluation). This research directly addresses this critical data deficiency by aiming to significantly enhance the spatial resolution of lunar south polar NAC images degraded by pixel summation mode. The core objective is to develop an advanced super-resolution technique to effectively restore fine geomorphological details, thereby acquiring high-quality data to support lunar scientific research and upcoming exploration endeavors in this challenging but scientifically rich domain. **Method** This study introduces a novel deep learning framework called the multi-scale super-resolution transformer (MSRT), alongside a purpose-built dataset to tackle the multi-scale degradation problem in lunar NAC imagery. First, a large-scale, multi-scale lunar NAC image super-resolution dataset was constructed. This process involved selecting high-quality nominal-resolution (approximately 0.5 m/pixel) LRO NAC images from diverse lunar terrains. The NAC's summation mode was emulated by downsampling these pristine images by factors of $2\times$, $3\times$, and $4\times$ using average pooling, closely mimicking the pixel aggregation process. A controlled level of Gaussian noise, based on real NAC image characteristics, was added to simulate sensor noise. This process yielded an extensive dataset of paired low-resolution and high-resolution ground truth images, which are crucial for training and evaluating super-resolution models specifically designed for this type of degradation. The dataset's unique focus on multiple, simulated summation mode degradation levels provides a robust platform for developing adaptive super-resolution solutions. Second, the MSRT model was proposed, strategically integrating the local feature extraction capabilities of convolutional neural networks (CNNs) with the global context modeling strengths of transformer architectures (specifically Swin transformer). MSRT's architecture begins with an initial CNN layer for shallow feature extraction. These features are then processed by a shared backbone of cascaded residual Swin transformer blocks, which learns powerful, generalizable deep feature representations common to all upscaling factors. The core innovation lies in its multi-scale reconstruction stage, where multiple parallel, independent, and learnable scale-specific spatial-aware upsampling (S^3U) modules are employed. Each S^3U branch, dedicated to a specific upscaling factor ($2\times$, $3\times$, or $4\times$), takes the shared deep features (combined with shallow features via skip connections) and uses scale-specific convolutional layers along with sub-pixel convolution to reconstruct the high-resolution image for its designated scale. This multi-branch reuse of deep features with unique terminal-scale adaptive upsampling structure enables a single MSRT model to efficiently handle various degradation levels, enhancing adaptability and reconstruction accuracy while managing model complexity, and is trained end-to-end using an L1 pixel loss function. **Result** The MSRT model's efficacy was rigorously assessed through comprehensive experiments on the custom-built multi-scale lunar NAC dataset. Quantitative comparisons were made against several leading super-resolution methods (blind super-resolution generative adversarial network (BSRGAN), enhanced super-resolution generative adversarial network (ESRGAN), super-resolution residual network (SRRResNet), deep plug-and-play super-resolution (DPSR), information multi-distillation network (IMDN)) using peak SNR (PSNR) and structural similarity index measure (SSIM) as key image quality metrics. Across all tested upscaling factors ($2\times$, $3\times$, and $4\times$), MSRT demonstrated statistically significant and visually apparent outperformance over all baseline methods. In the particularly challenging $4\times$ super-resolution task (recovering 0.5 m/pixel details from 2 m/pixel input), MSRT achieved a PSNR of 28.73 dB and an SSIM of 0.923 on the test set, substantially exceeding the performance of competing approaches (e. g. , an approximately 3.0 dB PSNR gain over BSRGAN). Consistent superiority was also observed for the $2\times$ and $3\times$ tasks, highlighting MSRT's robustness across varying degradation intensities. Detailed ablation studies were conducted to validate the contributions of MSRT's key architectural components, such as the Swin transformer backbone depth, network width, and the S^3U modules. These studies confirmed the effectiveness of the design choices and elucidated the impact of different parameters on performance across scales. Notably, the multi-scale training strategy for MSRT (simultaneously training all upsampling branches) proved effective, yielding results comparable to or better than those obtained by training separate single-scale MSRT instances, thus validating the efficiency of the shared-backbone multi-branch design. Qualitative assessments based on visual inspec-

tion of the reconstructed images further underscored MSRT's advantages. The model effectively suppressed artifacts and noise commonly seen in super-resolved images while successfully restoring fine-scale lunar surface details that are crucial for geological interpretation. These details included the clear delineation of small impact crater morphologies, rock size and distribution patterns, subtle regolith textures, and other minute topographical features that were indiscernible in the degraded input images. Successful application to real-world LRO NAC images not seen during training also demonstrated the MSRT's strong generalization capabilities. **Conclusion** This research successfully developed and validated the MSRT model, a novel transformer-based deep learning approach for adaptive multi-scale super-resolution of lunar NAC imagery degraded by the summation mode, which is particularly prevalent in the challenging illumination conditions of the lunar south pole. The MSRT effectively addresses this multi-scale degradation, thereby considerably improving the reconstruction quality of fine lunar geomorphological features. The MSRT model's innovative architecture, which combines a shared Swin transformer backbone for powerful cross-scale feature extraction with parallel, scale-specific S³U modules for tailored upsampling and reconstruction, forms its core technical contribution. This design enables a single model to efficiently and accurately handle multiple degradation levels, offering a practical and high-performing solution. The high-quality, high-resolution lunar surface data reconstructed by MSRT provides crucial support for detailed geological analyses (e. g., crater studies, regolith characterization), enhances the precision of landing site safety assessments, aids in safer and more efficient rover traverse planning, and facilitates more informed evaluations for potential in situ resource utilization. While MSRT shows significant promise, future work could explore more complex degradation models and the integration of physical or geometric priors. The architectural principles of the MSRT, particularly its strategy of using a shared backbone and specialized branches, offer valuable insights and a strong foundation for tackling similar multi-scale super-resolution challenges in other remote sensing applications, such as imagery from other planetary bodies or Earth observation systems. The MSRT thus represents a notable advancement in computational remote sensing and image restoration.

Key words: super-resolution reconstruction; lunar narrow-angle camera; Transformer; multi-scale; deep learning

0 引言

月球南极因其科学价值与资源潜力,成为国际深空探测重点,我国嫦娥六号、七号及国际月球科研站均将其作为核心目标(于登云等,2016;Liu等,2021;余后满等,2023;杨璐茜,2024)。高分辨率(high resolution, HR)遥感影像是关键地质特征识别、着陆区评估和资源勘查的基础。目前美国宇航局(National Aeronautics and Space Administration, NASA)的月球勘测轨道飞行器(lunar reconnaissance orbiter, LRO)搭载的窄角相机(narrow angle camera, NAC)能够获取最高0.5 m/像素的高分辨率影像,为月球研究提供重要数据(Robinson等,2010;Vondrak等,2010)。然而,月球南极地区因其特殊的轨道位置导致太阳高度角极低,大部分区域光照微弱甚至长期处于阴影之中,这使得NAC获取的影像信噪比(signal noise ratio, SNR)显著下降。在此严峻的成像条件下,NAC在对月球南极进行关键观测时,尤其是在探测蕴藏水冰等重要挥发性物质、具有极高科学价值的永久阴影区的边缘过渡带,以及评估未

来国际月球科研站、载人登月等重大任务的候选着陆区安全性与资源潜力时,为提升图像的可判读性和信噪比,常采用“求和”模式。如图1所示。该模式通过将预设范围(如 2×2 、 3×3 或 4×4)内的相邻像素信号值进行硬件或软件累加,虽然能在一定程度上改善信噪比,却以牺牲宝贵的空间分辨率为直接代价。这导致了对精细地质分析、着陆点安全性评估和月面活动规划至关重要的亚米级至米级地貌特征在影像中变得模糊不清,甚至完全无法辨识(Bickel等,2021)。此类细节信息的缺失不仅影响对月球地质演化历史的精细解读,也给着陆器精确




图1 NAC影像“求和”模式示意图

Fig. 1 Schematic diagram of the NAC image summation mode

选址、巡视器安全路径规划带来了潜在风险(Delgado-Centeno等, 2021)。因此,提高南极区NAC影像分辨率是亟待解决的问题。

提升月球NAC影像分辨率的方法主要分为两类:一类是发射搭载更先进成像设备和传感器的飞行器进行拍摄;另一类是利用现有数据进行超分辨率重建,以提升影像的分辨率。硬件升级可在理论上直接提升影像分辨率,但其实现面临诸多挑战。首先,先进成像设备与传感器的研发需大量技术创新与资金投入。其次,航天器的设计、制造、发射及轨道控制等环节复杂且高风险,任何失误均可能导致任务失败。此外,月球环境极端,无大气层保护、温差剧烈,严苛条件对成像设备的稳定性提出高要求,进一步增加技术难度与成本。相比之下,利用超分重建技术对现有数据提升分辨率,具备更高经济性与可行性。对于月球NAC影像,超分重建可提升视觉质量,并为地形分析、资源勘探等研究提供更丰富的数据支持。

根据输入低分辨率(low resolution, LR)影像的数量,超分辨率算法可以分为单影像超分辨率(single image super resolution, SISR)和多影像超分辨率(multi image super resolution, MISR)。近年来,基于深度学习的SISR技术在自然图像和遥感影像增强领域取得了显著进展,通过构建端到端的深度神经网络,学习LR图像到HR图像之间的复杂映射关系,从而实现图像细节的有效恢复(Ha等, 2018; Al-Mekhlafi和Liu, 2024)。首先,卷积神经网络(convolutional neural network, CNN)凭借其强大的局部特征提取能力,在超分辨率重建任务中得到了广泛应用(UI Hoque等, 2019; Dong等, 2016)。然而,CNN模型通常受限于固定大小的感受野,难以捕捉月球影像中广泛存在的长距离依赖关系(如陨石坑链、月海边缘等)。为了克服CNN的局限性,基于Transformer的模型被引入到超分重建领域,通过自注意力机制能够有效建模图像中的全局上下文信息,弥补了CNN在长程依赖关系建模方面的不足(Yang等, 2020; Chen等, 2021; Liang等, 2021)。然而,现有方法大多针对固定尺度因子进行设计,难以适应月球NAC影像因“求和”模式导致的多尺度分辨率退化问题。另外,MISR旨在利用同一场景的多个低分辨率观测结果重建高分辨率细节(Lepcha等, 2023)。然而,将MISR应用于月球NAC影像面临诸多挑战:1)南极区光照角度极低,阴影变化快,难以

融合不同时间影像;2)轨道误差导致影像错位,增加配准复杂性;3)尽管NAC影像数量较多,但月球表面变化极小,限制超分辨率所需的多帧信息。这些因素阻碍了MISR的精确配准和信息融合,使其应用难度加大。

为解决上述问题,本文首先构建了一个大规模、多尺度的月球NAC影像超分辨率数据集。该数据集包含从NASA获取的高质量原始NAC影像,并模拟了“求和”模式下2倍、3倍和4倍降采样的退化影像,为超分重建模型的训练和评估提供了坚实的基础。进一步地,针对NAC影像的多尺度退化特性,本文提出一种融合CNN和Transformer的多尺度超分辨率模型(multi-scale super-resolution transformer, MSRT)。该模型通过共享的Transformer层提取跨尺度深度特征,并针对不同NAC影像下采样尺度设计了独立的可学习上采样分支,实现了“多分支复用深层特征,末端上采样各不相同”。这种设计不仅提高了模型对多尺度退化问题的适应性,还在保持重建精度的同时显著降低了模型复杂度。

1 数据集构建

1.1 NAC影像分辨率统计分析

为评估全月球NAC影像空间分辨率的全局分布特性及其在关键区域(如月球南极)的实际情况,为本研究的超分辨率重建目标提供数据支撑与问题导向,首先对LRO NAC历史存档数据进行系统的统计分析。从行星数据系统(planetary data system, PDS)获取了截至目前(数据获取截止日期)超过250万幅NAC影像的元数据,并从中提取了每景影像的空间分辨率信息。为保证本研究后续统计分析所用NAC影像元数据的质量与代表性,我们实施了严格的筛选与预处理流程:1)剔除了元数据中地理坐标(经纬度)存在无效值(如“999.99”)的记录,这类数据通常指示影像定位信息不准确或缺失,若将其纳入分析,会直接影响后续空间分辨率地理分布图的准确性;2)基于研究需求,设定影像空间分辨率的有效分析上限为3 m/像素,高于此阈值的影像被滤除,以确保所分析的影像具备可识别地貌特征的潜力。因为本文研究的“求和”模式主要影响NAC获取的较高固有分辨率影像,且过低分辨率的影像已丧失了恢复亚米级至米级细节的潜力,超分辨率

处理的意义不大。此项筛选使得统计结果更能反映 NAC 影像在月球探测中的主流数据特性与面临的挑战。在上述数据预处理的基础上,对全球范围内的 NAC 影像分辨率数据进行了统计,并绘制了其概率密度分布图,如图 2 所示。

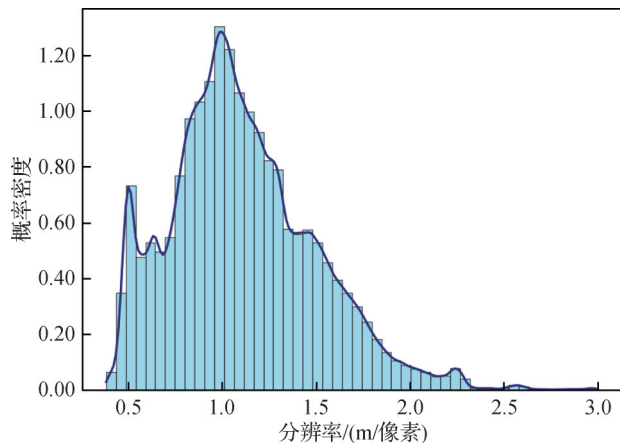


图 2 全月球 NAC 影像分辨率概率密度分布图

Fig. 2 Probability density distribution of lunar NAC image resolution

图 2 清晰地揭示了全球 NAC 影像空间分辨率的非均一性与多峰分布特征,反映了其获取过程受轨道高度、观测策略与光照条件等多种因素的动态影响。一个显著的主峰出现在约 1.0 ~ 1.2 m/像素区间,代表了 LRO 在常规模式下最常获取的分辨率。然而,NAC 理论上可达的 0.5 m/像素最佳分辨率(图

2 中次峰)的概率密度远低于主峰,表明此类理想高分辨率影像在全球数据集中占比较小。这种高质量 (high quality, HQ) 影像的稀缺性,对于依赖其进行精细月表地貌(如亚米级撞击坑、岩块细节)的解译与科学研究(如精确年龄测定、月壤特性分析)构成了显著制约,从而直接凸显了对现有 NAC 影像进行超分辨率重建以提升其有效信息量的重大研究意义与应用价值。此外,分布的尾部向更粗糙分辨率(直至 3 m/像素上限)延伸,这可能对应于较高轨道或大角度倾斜观测时获取的影像。

为更直观地展现全球 NAC 影像分辨率的空间分布格局,结合地理坐标绘制了相应的地理空间分布热力图,如图 3 所示。该热力图不仅在空间维度上印证了图 2 所示的统计认知,即分辨率的非均一性,更深化了对分布规律的理解。具体而言,部分特定区域(如科学兴趣点或任务区)可能因集中观测而展现出较优分辨率和更高覆盖密度;同时,中低纬度地区普遍享有相对较好且均一的分辨率(可能与 LRO 轨道特性及光照条件有关),而高纬度及极区则呈现更复杂、不均一且可能更差的分辨率覆盖。这种全局性的分辨率非均匀分布特征,尤其是高质量 0.5 m/像素影像的整体不足,以及高纬度区域本身可能固有的数据获取挑战,共同为后续针对极区(尤其是月球南极)的深入分析奠定了“问题背景”——即在这些本身就可能存在数据获取与质量挑战的区




图 3 全月球 NAC 影像分辨率地理空间分布热力图

Fig. 3 Global NAC image resolution geospatial distribution heatmap

域,若再普遍采用“求和”模式以牺牲分辨率换取信噪比,那么获取真正意义上的高分辨率、高质量影像将面临更为严峻的困难。

鉴于本文的研究重点聚焦于月球南极区域,故针对该区域的NAC影像特性进行了专项统计分析。利用月球轨道数据浏览器,本文搜集了南纬 $80^{\circ}\sim 90^{\circ}$ 、全经度范围内的NAC影像元数据共计183 679幅,并提取了每幅影像的空间分辨率与太阳入射角信息。太阳入射角定义为太阳光线与月面局部法线间的夹角,角度趋近 90° 时指示太阳高度角极低、光照微弱且易形成阴影,反之则光照条件较好。本文分别绘制了该区域NAC影像的空间分辨率频率分布直方图(图4)和太阳入射角频率分布直方图(图5)。

图4对南极区域NAC影像空间分辨率的分析显示,其标称分辨率分布与全球平均水平(图2)具有一定相似性,主峰亦位于约 $1.0\sim 1.2$ m/像素区间。然而,必须强调的是,图4所呈现的仅为影像元数据中记录的标称分辨率。在如此低的光照和低信噪比挑战下,大量NAC影像在南极区域实际上是以牺牲空间分辨率为代价的“求和”模式(例如 2×2 、 3×3 或 4×4 像素合并)拍摄的。这意味着,图3中例如 1.0 m/像素的标称分辨率,其在“求和”模式下的有效分辨率可能被显著降低至 2.0 m/像素、 3.0 m/像素甚至更差的水平。因此,尽管南极区域的标称分辨率分布与全球主峰区间看似接近,但考虑到“求和”模式为保证信噪比而进行的普遍降采样操作,该




图4 南极区域NAC影像分辨率频率分布直方图
Fig. 4 Histogram of NAC image resolution frequency distribution in the south pole region

区域实际可用的、能够分辨精细地貌的影像数据质量面临着远比标称数据显示更为严峻的挑战。

如图5所示,绝大多数影像的太阳入射角集中在非常高的数值区间。具体而言,分布的峰值出现在 $80^{\circ}\sim 85^{\circ}$ 附近,且超过 75° 入射角的影像占据了压倒性的比例。这一定量统计结果强有力地证实了月球南极区域光照条件的严苛性,即该区域绝大部分时间处于极低的太阳高度角照射之下。这种高入射角直接导致:1)光照强度微弱,到达相机传感器的光子数量少;2)地表因微小起伏即可产生大面积的拖长阴影,进一步减少有效光照面积和对比度。这两个因素共同作用,使得影像的信噪比急剧下降。

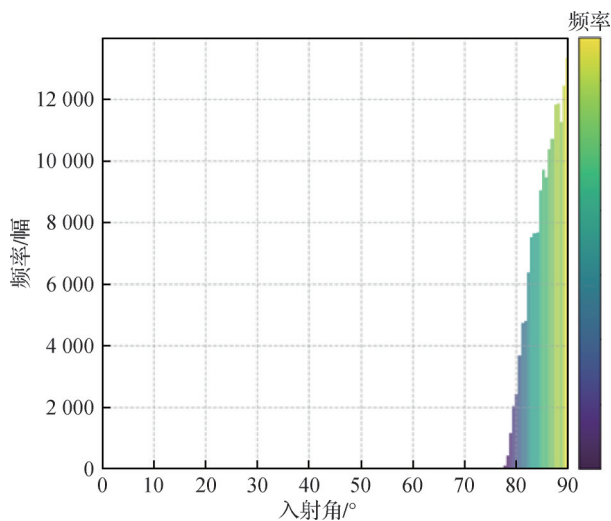


图5 南极区域NAC影像入射角频率分布直方图
Fig. 5 Histogram of NAC image incidence angle frequency distribution in the south pole region

1.2 多尺度NAC影像超分数据集构建

首先,在数据收集阶段,本文对NASA分发的8位深度NAC影像数据进行了系统筛选。针对月球南极区域,本文选取了分辨率在 $0.5\sim 0.6$ m/像素之间的影像,共计48幅,作为数据集的高质量参考图像(HR图像)。为了扩充数据量并增加数据多样性,本文进一步从全月球不同区域收集了500幅分辨率为 0.5 m/像素的NAC影像,这些图像均经过严格的预处理和质量检查,确保其在后续数据集构建中能够真实反映月球表面的细节特征。为了更加直观地观察采样数据的地理位置分布,本文使用热点图对NAC影像的位置进行了可视化,如图6所示。

为了便于模型训练和区域特征提取,每幅NAC影像均被裁剪为 1024×1024 像素小块,累计生成

57 428个图像块。为模拟LRO在南极区域拍摄NAC影像时采用的求和模式,对每个裁剪后的图像块分别进行下采样,生成分辨率为1 m/像素、1.5 m/像素和2 m/像素的低分辨率图像。采用均值池化作为主要的下采样方法,因为它能较好地模拟NAC相机“求和”模式下将邻近像素信号值进行累加平均以提高信噪比,从而导致空间分辨率降低的物理过程。例如,对于2倍下采样,将原始图像中每个 2×2 的像素块内的像素值取平均,生成一个像素值,从而得到分辨率减半的低分辨率图像;类似地,3倍和4倍下采样则对应 3×3 和 4×4 的像素块。此外,为了更真实地反映实际成像过程中可能引入的传感器噪声和

信号传输干扰,在下采样生成的低分辨率图像基础上,添加了少量零均值的高斯白噪声。噪声的方差根据对真实LRO NAC影像特性分析进行设定,以确保退化模型的逼真度,使训练得到的模型更能适应真实观测数据。构建多尺度数据集不仅能够充分再现南极区域NAC影像在实际获取过程中的多种分辨率情况,而且对于探索深度学习模型在跨尺度图像超分任务中的鲁棒性和泛化能力具有重要意义。通过这一系列预处理和模拟过程,本文在数据分辨率、细节保留及多尺度信息表达上均做到精准映射,为后续数据驱动模型训练提供了充分的、多样化的样本支持。

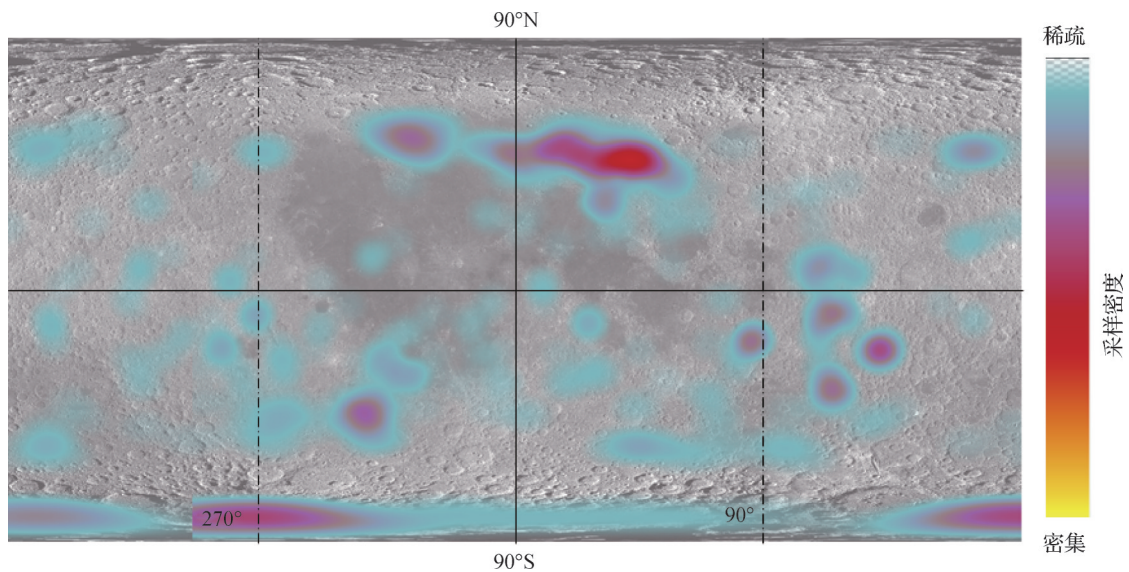


图6 数据集采样空间分布热点图

Fig. 6 Hotspot map of dataset sampling spatial distribution

如表1所示,最终数据集分为训练集、验证集和测试集,其中,训练集包含约47 428幅图像,验证集和测试集各包含5 000幅图像。每一幅HR图像都对应生成了2倍、3倍以及4倍下采样后的低分辨率图像。

表1 数据集样本统计

Table 1 Dataset sample statistics

	/幅		
	训练集	验证集	测试集
HR(GT)	47 428	5 000	5 000
LR($\times 2$)	47 428	5 000	5 000
LR($\times 3$)	47 428	5 000	5 000
LR($\times 4$)	47 428	5 000	5 000

综上所述,本文构建的多尺度月球窄角相机(NAC)影像超分辨率数据集,在模拟真实性、数据规模和标注精度方面具有显著优势。该数据集紧密围绕NAC相机在特殊光照条件下(尤其是月球南极)的“求和”成像模式,通过模拟其多尺度分辨率退化(2倍、3倍、4倍)并引入噪声模型,确保了低分辨率样本的高度场景特异性与退化真实性。同时,数据集涵盖了从全月球不同区域筛选的超过50 000对高、低分辨率图像块,具有大规模和多样化的特点。每对图像均经过严格控制的下采样生成,保证了高、低分辨率影像间精确的像素级配准和清晰的多尺度对应关系,为深度学习模型的鲁棒训练、泛化能力验证及月球特定场景下高精度地貌恢复研究提供了高质量的数据支撑。

2 多尺度超分重建 Transformer 模型

Transformer 模型因其全局信息捕捉优势而备受关注, CNN 则擅长局部细节重建。为融合两者以应对多尺度超分辨率挑战, 本文提出自适应多尺度超分辨率 Transformer (MSRT) 模型。MSRT 虽然借鉴 SwinIR 的 Swin Transformer 骨干, 但针对月球 NAC 影像的多尺度“求和”模式退化及精细地貌恢复需求, MSRT 在架构和机制上实现了关键创新: 通过共享 Transformer 主干与多个并行的、针对各目标倍数独立优化的特定尺度空间感知上采样模块 (scale-specific spatial-aware upsampler, S^3U), 构建了单一模型处理多尺度任务的高效框架, 这与 SwinIR 通常为各尺度训练和部署不同模型的方式形成核心区别。同时, MSRT 的 S^3U 模块专为月表恢复设计, 能够将共享的通用跨尺度特征精准适配并重建为特定尺度下的高分辨率细节, 确保了不同退化程度下月表地貌的精确恢复。

2.1 MSRT 整体架构

为了同时处理月球 NAC 图像在 1 m/像素、1.5 m/像素和 2 m/像素等不同降采样尺度上的超分重建任务, 本文基于图像修复 Swin Transformer (swin Transformer for image restoration, SwinIR) 模型提出一种可多尺度同步训练的自适应超分网络结构——MSRT。该网络在充分利用 SwinIR 原有多层自注意力机制与残差连接结构的同时, 通过在末端设计特定尺度空间感知上采样模块 (S^3U), 实现了针对不同

尺度需求的精细重建。

MSRT 整体的结构如图 7 所示, 其核心思想是有效融合 CNN 的局部特征提取能力与 Transformer 的全局上下文建模优势。模型主体可划分为 3 个主要功能模块: 1) 浅层特征提取 (shallow feature extraction); 2) 深层特征提取 (deep feature extraction); 3) 多尺度重建 (multi-scale HQ image reconstruction)。其中, 第 1 个模块和第 2 个模块的设计思路大体与 SwinIR 保持一致, 用于从输入的低分辨率 NAC 图像中提取并编码多层次特征信息; 第 3 个模块则在此基础上引入可扩展的多分支上采样单元 S^3U , 以便针对不同降采样倍数独立地执行超分重建。

具体而言, 对于浅层特征提取部分, 首先对输入尺寸为 $H \times W$ 的低分辨率月球图像 I_1 进行一次 3×3 卷积操作, 用以获得初始浅层特征 $F_0 \in \mathbf{R}^{(H \times W \times C)}$ 。此 CNN 模块的核心作用是捕捉图像的局部基础信息, 如边缘、角点和纹理等低级特征, 并将其有效映射至更高维度的特征空间, 为后续的深层 Transformer 模块提供具有丰富局部细节的输入, 同时此步骤也有助于稳定初始训练阶段。

对于深层特征提取, 浅层特征 F_0 继而被送入一系列级联的 RSTB (residual swin Transformer block) 块。在每个 RSTB 内部, Swin Transformer 层 (Swin Transformer layer, STL) 通过其多头自注意力机制高效捕捉长距离依赖和全局上下文信息, 以识别大范围地貌特征, 其后的卷积层则负责局部信息整合与特征细化, 并通过残差连接增强表达。最终, RSTB 序列的输出经一个末端 3×3 卷积层深度融合, 形成

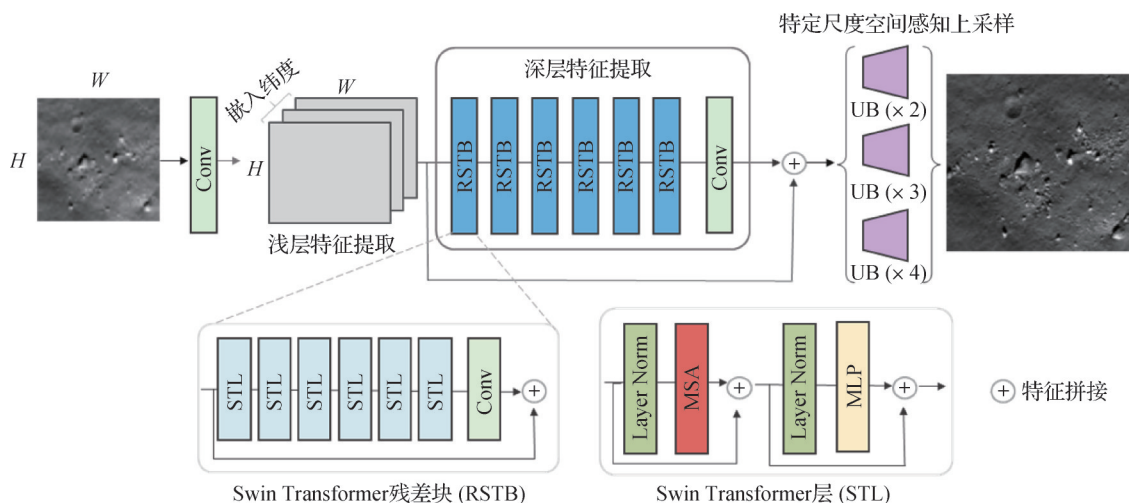


图7 MSRT架构图

Fig. 7 MSRT architecture diagram

兼具全局感知与局部细节的深层特征 F_D 。

对于多尺度超分重建,此阶段主要依赖 CNN 组件完成。首先,深层特征 F_D 与浅层特征 F_0 融合,形成全局复原基础特征 F_{in} ,以结合多层次信息。随后 F_{in} 被送入针对不同放大倍数设计的独立上采样分支。各分支内部的特定尺度空间感知上采样器 (S^3U) 均由可学习卷积层和子像素重排操作(均为 CNN 操作)构成,负责将特征高效上采样至目标分辨率,并精确重建图像细节。

2.2 特定尺度空间感知上采样模块

MSRT 模型的创新核心之一在于其共享的 Transformer 深度特征提取层与针对各放大倍数的独立特定尺度空间感知上采样模块 (S^3U) 之间的高效协同工作机制。这种设计精妙地实现了“多分支复用深层特征,末端上采样各不相同”的架构,不仅提升了模型对多尺度输入的适应性,也保证了各尺度下重建结果的质量。其具体的协同工作机制、信息传递与融合过程如下:

为了同时兼容 1 m/像素、1.5 m/像素和 2 m/像素等多种降采样倍率并充分挖掘月球 NAC 图像中丰富而复杂的地形信息,本文提出创新性的 S^3U 上采样模块。该模块旨在在共享深层特征的基础上,为每个放大倍数提供独立、自适应的上采样分支,实现了“多分支复用深层特征、末端上采样分支各不相同”的模型结构,既保证了多尺度任务的适用性,又能有效维护不同尺度下的重建性能。

首先本文将浅层卷积提取低频信息得到特征 F_0 和深层 Transformer 模块提取高频细节特征 F_D 相加,组成全局复原基础特征 F_{in} 。考虑到 NAC 图像在不同放大倍数下对于空间细节的需求不同,本文在每个分支内部引入了子像素重排与可学习卷积核相结合的策略。具体而言,首先对全局复原基础特征 F_{in} 进行一个卷积变换 ($W_{s_i} *$),再通过子像素重排算子将通道信息映射到更高的空间分辨率,其可表示为

$$F_{up,S_i} = R_{S_i}(W_{S_i} * F_{in}) \quad (1)$$

式中,*表示卷积操作, W_{S_i} 为针对放大倍数而设定的可学习卷积核(其尺寸和通道数与 S_i 相关,以便在子像素重排后得到正确的空间大小)。 $R_{S_i}(*)$ 将输入特征张量沿通道维度重新布局到空间维度,实现尺寸从 (H, W) 到 (H_{S_i}, W_{S_i}) 提升。最后再经过后处理卷积操作得到最终的经过超分的高分辨率影像,其可

表示为

$$\hat{I}_{H,S_i} = C_{S_i}(F_{up,S_i}) \quad (2)$$

式中, $C_{S_i}()$ 是为特定放大倍数 S_i 下的后处理卷积操作,用于将子像素重排后的特征进一步融合、提升输出图像的细节表现。最后本文通过最小化 L_l 像素损失来优化 MSRT 的权重参数,具体为

$$L = \left\| \hat{I}_{H,S_i} - I_{HQ} \right\|_1 \quad (3)$$

式中, \hat{I}_{H,S_i} 是低分辨率图像 I_L 输入 MSRT 后得到的超分结果, I_{HQ} 是对应的真实高分辨率影像。

共享 Transformer 层与 S^3U 模块协同机制的核心在于首先由共享的 Transformer 主干网络深度提取具有跨尺度普适性的高级特征。这些统一的高级特征随后被完全相同地分发给各个并行的、针对特定放大倍数的上采样模块。每个 S^3U 模块内部通过独立学习的参数,将接收到的共享特征进行尺度专属的调整和上采样,并精细重建出对应目标分辨率的图像细节。这种设计使得计算密集的深度特征提取只需执行一次,而各尺度特化的重建任务则由相对轻量的独立模块高效完成,实现了全局信息共享与局部细节特化重建的有机结合。

3 实验结果

3.1 实验对比模型

BSRGAN(blind super-resolution generative adversarial network)(Zhang 等,2021)是一种基于生成对抗网络(generative adversarial network, GAN)的盲超分辨率方法,旨在解决真实图像中的复杂退化问题。该方法通过设计一种新的退化模型,涵盖了模糊、下采样和噪声等多种退化因素,并引入了随机打乱策略以模拟真实图像中的多样化退化。BSRGAN 首先训练一个峰值信噪比(peak signal-to-noise ratio, PSNR)导向的 BSRNet 模型,随后在此基础上训练感知质量导向的 BSRGAN 模型,以生成视觉上更逼真的高分辨率图像。实验表明,BSRGAN 在处理具有多种退化的真实图像时表现出色,尤其在去除噪声和恢复细节方面具有显著优势。

DPSR(deep plug-and-play super-resolution)(Zhang 等,2019)是一种基于深度学习的超分辨率方法,其创新性地将一种即插即用框架与深度学习的超分辨率模型相结合。该方法首先提出一种新的图像退化

模型,使其能够利用现有的盲去模糊方法估计模糊核。通过半二次分裂算法对能量函数进行优化,将任意模糊核的超分辨率问题分解为去模糊和超分辨率两个子问题。其中,去模糊子问题在傅立叶域中有闭式解,而超分辨率子问题则通过一个经过修改的SRResNet+网络进行求解。该方法能够有效处理具有任意模糊核的低分辨率图像的超分辨率重建问题。

SRResNet (super-resolution residual network) (Ledig等,2017)是一个基于深度残差网络的超分辨率重建网络。该网络采用16个残差块的深层架构,每个残差块包含两个带批归一化的 3×3 卷积层和参数化ReLU(rectified linear unit)激活函数。网络使用子像素卷积层进行上采样,最终输出超分辨率图像。网络在跳跃连接的设计上,每个残差块采用元素级加法将输入直接连接到输出,有效缓解了深度网络的梯度消失问题,使得模型能够更好地学习残差信息。

IMDN (information multi-distillation network) (Hui等,2019)是一种轻量级的单图像超分辨率网络,主要通过信息多级蒸馏实现高效的特征提取。该方法设计了信息多级蒸馏模块,通过逐步细化特征并引入对比度感知通道注意力机制来聚合不同层次的特征信息。网络采用级联IMDB (information multi-distillation block)结构,并通过中间特征收集方案来保证信息的完整性。此外,为了处理任意尺度因子的超分辨率问题,该网络提出自适应裁剪策略。实验表明,IMDN在视觉质量、运行速度和内存占用等实用性指标上取得了很好的平衡。

ESRGAN (enhanced super-resolution generative adversarial network) (Wang等,2018)是在SRGAN基础上改进的生成对抗网络方法,主要通过3个方面的改进提升超分辨率重建的视觉质量。首先,在网络架构上提出RRDB (residual-in-residual dense block)结构,并移除了批归一化层,使网络具有更强的特征提取能力。其次,采用相对判别器替代标准判别器,使其不仅判断图像的真实性,还要判断图像的相对真实程度。最后,改进了感知损失的计算方式,使用激活前的特征而不是激活后的特征计算损失。此外,该方法还提出网络插值策略来平衡感知质量和失真度。

3.2 训练设置细节

本节实验环境基于Ubuntu 20.04.6 LTS操作系统构建,采用Intel(R) Xeon(R) Gold 6348处理器作为计算核心,配备512 GB内存和8块NVIDIA GeForce RTX 4090显卡(每卡24 GB GDDR6X显存)。软件环境方面,使用Anaconda管理Python 3.9环境,深度学习框架采用PyTorch 1.13,并配置CUDA 11.6及相应版本的cuDNN库以优化GPU计算性能。该软硬件配置为深度学习模型的训练与验证提供了高效且稳定的计算平台。

对于本文所构建模型的训练采用如下设置:训练过程中选用L1损失函数,并使用Adam优化器进行参数优化,初始学习率设为 $2E-4$ 。学习率采用MultiStepLR衰减策略,在训练步数达到250 000、400 000、450 000、475 000和500 000时,学习率依次降低为当前值的0.5倍。训练阶段的批次大小设为20,输入数据切片尺寸为 144×144 像素,嵌入维度设置为180个通道,RSTB设置为6层。考虑到训练效率,采用双显卡并行训练策略,数据加载器的工作线程数设为16。为了监控训练过程,每200步打印一次训练状态,每5 000步进行一次验证和模型权重保存。对比的其他模型均严格按照原文中的训练方法和参数设置分别对2、3和4倍超分重建模型进行训练,以确保实验对比的公平性。

3.3 评估指标

本文实验中,对于各个模型的重建结果将使用峰值信噪比(PSNR)和结构相似性指数(structural similarity index measure, SSIM)作为客观评价指标。PSNR基于均方误差计算,反映重建图像与原始高分辨率图像在像素级别的差异,数值越高表明重建图像与原始图像的像素值越接近。SSIM则着重评估图像的结构信息保持程度,其值域为0到1,数值越接近1表明重建图像越好地保留了原始图像的结构、纹理和局部相关性特征。这两个指标互为补充,共同反映了超分辨率重建的客观质量:PSNR值越高、SSIM值越接近1,说明重建结果在细节保真度和结构完整性方面越优秀。

3.4 实验结果分析

从表2—表4的实验结果可知,提出的MSRT模型在2倍、3倍和4倍月球NAC影像超分重建任务中均展现出显著优势。在最具挑战的4倍超分任务中(模拟NAC影像从2 m/像素恢复至0.5 m/像素),

MSRT 的测试集平均 PSNR 达到 28.73 dB, 较次优方法 BSRGAN (25.73 dB) 提升 3.0 dB (相对误差降低 11.7%); SSIM 指标亦以 0.923 显著领先其他方法。

3 倍超分任务中, MSRT 的 PSNR 与 SSIM 分别达到 29.86 dB 和 0.933, 较 DPSR (26.82 dB, 0.871) 具有 3.04 dB 和 0.062 的提升幅度。随着降采样倍率的增大 (即分辨率退化程度加深), MSRT 模型在细节恢复与结构一致性方面的优势更为显著。

表 2 不同方法在 4 倍超分重建下的评估结果

Table 2 Evaluation results of different methods for 4× super-resolution reconstruction

方法	验证集		测试集	
	PSNR/dB	SSIM	PSNR/dB	SSIM
BSRGAN	26.01	0.896	25.73	0.898
ESRGAN	23.89	0.833	23.92	0.837
SRResNet	23.88	0.830	23.87	0.837
DPSR	23.35	0.825	23.37	0.835
IMDN	23.22	0.826	23.59	0.832
MSRT(本文)	29.12	0.929	28.73	0.923

注: 加粗字体表示各列最优结果。

表 3 不同方法在 3 倍超分重建下的评估结果

Table 3 Evaluation results of different methods for 3× super-resolution reconstruction

方法	验证集		测试集	
	PSNR/dB	SSIM	PSNR/dB	SSIM
BSRGAN	29.13	0.939	28.33	0.912
ESRGAN	25.98	0.866	24.42	0.858
SRResNet	26.66	0.887	25.85	0.859
DPSR	27.33	0.901	26.82	0.871
IMDN	26.96	0.898	26.27	0.867
MSRT(本文)	30.02	0.941	29.86	0.933

注: 加粗字体表示各列最优结果。

MSRT 性能优势源于以下设计机制: 1) 本文创新性地融合了 Transformer 和 CNN 的优势。深层 Transformer 模块通过自注意力机制捕捉月表陨石坑链、撞击溅射纹等大尺度地质特征的全局拓扑关系; 而 CNN 的局部感受野则更适合提取月壤纹理等精细的局部特征。这种优势互补的设计使得 MSRT 能够同时兼顾全局结构和局部细节的重建。2) 针对

表 4 不同方法在 2 倍超分重建下的评估结果

Table 4 Evaluation results of different methods for 2× super-resolution reconstruction

方法	验证集		测试集	
	PSNR/dB	SSIM	PSNR/dB	SSIM
BSRGAN	35.02	0.972	34.39	0.965
ESRGAN	33.78	0.949	33.20	0.949
SRResNet	34.12	0.958	33.55	0.951
DPSR	33.93	0.955	33.32	0.950
IMDN	34.23	0.960	33.66	0.952
MSRT(本文)	35.12	0.977	34.54	0.967

注: 加粗字体表示各列最优结果。

NAC 影像在不同“求和”模式下呈现的多尺度分辨率退化问题, MSRT 模型提出 S³U 上采样模块。该模块针对不同退化尺度独立优化像素重排策略, 实现了对不同尺度特征的精细化处理, 有效克服了固定卷积核在跨尺度特征映射中的泛化瓶颈。

对比传统方法可见, BSRGAN 和 ESRGAN 这两种基于 GAN 的方法虽然在自然图像超分中表现出色, 但在处理 NAC 影像时容易产生伪影和细微失真。这主要是因为 GAN 的训练目标是生成视觉上逼真的图像, 而非追求像素级的精确重建。对于月球遥感数据而言, 客观准确地恢复各尺度纹理信息至关重要, 而 GAN 生成的不稳定性可能导致重构误差, 影响后续科学分析; SRResNet、IMDN 等纯 CNN 方法由于感受野受限, 难以恢复陨坑边缘的锐利特征; 而 DPSR 的盲复原能力在面对 NAC 影像特有的混合退化 (硬件降采样叠加斜射光阴影) 时表现欠佳。

为进一步直观地对比不同方法对月球 NAC 影像超分辨率重建的效果, 本文从测试集中随机选取了部分样本进行可视化, 结果如图 8 所示。观察可知, 无论从整体结构的清晰度、边缘锐利程度, 还是微小细节 (如石块纹理) 的还原能力来看, 本文提出的 MSRT 模型均展现出显著优势。具体而言, MSRT 重建的影像不仅有效抑制了噪声和伪影, 而且最大程度地保留了原始高分辨率影像中的地质特征信息, 视觉效果更接近真实情况。

表 5 对比了 MSRT 模型采用多尺度训练 (ms) 和单尺度训练 (ss) 的性能差异, 其中“ms”代表多尺度训练, “ss”代表单尺度训练, “×*”代表缩放尺度。

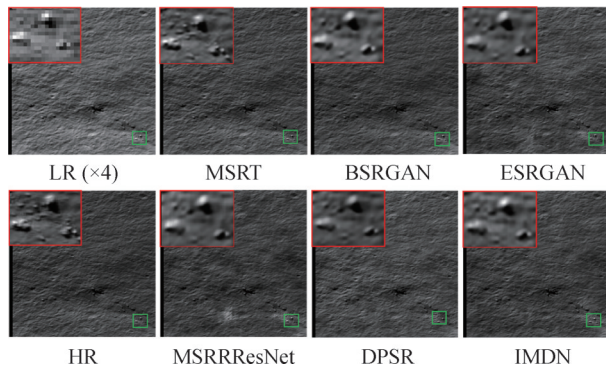


图8 不同超分重建方法的可视化结果

Fig. 8 Visualization results of different super-resolution reconstruction methods

MSRT模型在同时训练多尺度分支(ms)时展现出与单尺度训练(ss)相近甚至更优的性能。在3倍超分任务中,多尺度训练模型的测试集PSNR(29.86 dB)与SSIM(0.933)较单尺度模型(29.89 dB, 0.935)仅存在0.03 dB和0.002的微小差异;而在4倍超分任务中,多尺度模型的SSIM(0.923)反而优于单尺度模型(0.919)。这一结果表明,MSRT模型的多尺度训练策略不仅能够实现一次训练处理多种尺度,而且在性能上与单尺度训练相当,甚至在某些情况下略有提升。这主要得益于MSRT模型中共享的Transformer层能够有效提取跨尺度特征,使得不同尺度的训练任务能够相互促进,提高模型的泛化能力,同时共享特征提取层的参数复用机制迫使模型学习更本质的月表特征表达,抑制了过拟合倾向。另外,不同退化尺度间的特征分布差异通过联合优化实现隐性对齐,增强了模型对未知退化模式的泛化能力;最后,多任务学习框架下的梯度融合效应产生知识迁移,使各分支在优化过程中获得跨尺度正则化约束。值得注意的是,在2倍超分任务中,单尺度模型的SSIM(0.969)略优于多尺度模型(0.967),这可能源于低倍率超分任务对局部细节敏感度更高,而多尺度联合训练中引入的跨任务干扰略微削弱了高频信息恢复的专注度。但整体而言,多尺度联合训练在保证性能的前提下显著降低了模型复杂度,验证了该策略在工程应用中的高效性。

为了更加直观地展示MSRT模型在多尺度超分重建任务中的性能,本文对其在2倍、3倍和4倍超分任务中的重建结果进行了可视化分析,结果如图9所示。从图中可以清晰地观察到,MSRT模型在不同放大倍数下均展现出卓越的重建能力。MSRT

表5 MSRT模型采用多尺度和单尺度训练评估结果对比
Table 5 Comparison of MSRT model evaluation results using multi-scale and single-scale training

模型尺度	验证集		测试集	
	PSNR/dB	SSIM	PSNR/dB	SSIM
MSRT(ms_×2)	35.12	0.977	34.54	0.967
MSRT(ms_×3)	30.02	0.941	29.86	0.933
MSRT(ms_×4)	29.12	0.929	28.73	0.923
MSRT(ss_×2)	35.11	0.978	34.56	0.969
MSRT(ss_×3)	30.02	0.942	29.89	0.935
MSRT(ss_×4)	29.10	0.918	28.69	0.919

注:加粗字体表示各列最优结果。

模型能够有效重建月球表面影像中的微小地貌特征。MSRT的重建结果显著增强了细节的清晰度,使得纹理和结构特征更加鲜明。MSRT模型能够在不同倍数下自适应地调整特征提取和重建策略,确保结果的合理性和准确性。

为进一步验证MSRT模型在真实场景中的泛化能力,本文在月球南极区域随机选择了一幅分辨率为2.13 m/像素的NAC影像(ID: M1446219541RC, 中心坐标: 79.0°S, 241.72°E)进行超分重建评估,结果如图10所示。面对未见过的月球南极区域影像,MSRT不仅能够有效恢复陨石坑边缘、坑内纹理和地表裂缝等细节,还能抑制噪声并保持重建影像的真实性和准确性。这种在复杂地貌和光照条件下的优异表现,表明MSRT具备强大的跨数据集适应能力,为月球地貌分析提供了可靠的高分辨率影像数据支持。

3.5 消融实验

为深入探究MSRT模型中各关键组件及超参数对月球南极NAC影像超分辨率重建性能的影响,本节开展了一系列消融实验,重点关注训练步数、切片大小、RSTB数量以及嵌入维度这4个关键因素,并评估了它们在2倍、3倍和4倍超分任务下对模型性能指标峰值信噪比(PSNR)的影响。实验结果见图11所示的4幅折线图,每一幅图都清晰地展示了特定参数变化时,模型在不同超分尺度下的PSNR表现。

图11(a)展示了PSNR随训练步数的变化趋势。可见,在训练初期,所有尺度的PSNR值均快速上升,表明模型在快速学习NAC影像的特征分布。随

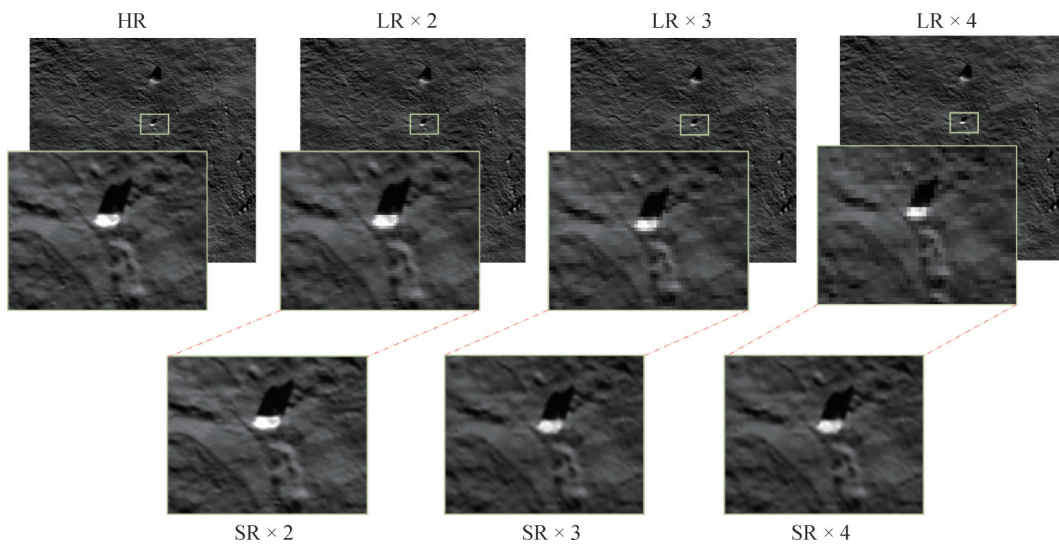


图9 MSRT多尺度超分重建结果可视化

Fig. 9 Visualization of MSRT multi-scale super-resolution reconstruction results

ID: M1446219541RC, 分辨率: 2.13 m/像素, 中心坐标: (79.0°S, 241.72°E)




图10 真实场景下MSRT超分重建结果可视化

Fig. 10 Visualization of MSRT super-resolution reconstruction results in real-world scenarios

随着训练步数的增加, PSNR 增速逐渐放缓并趋于稳定。值得注意的是, 2倍超分的 PSNR 曲线始终高于3倍和4倍, 且更早达到饱和。这表明低倍数超分任务相对简单, 模型收敛更快。而4倍超分任务的 PSNR 曲线在整个训练过程中都处于相对较低的位置, 并且在经过400 000步的训练后, 仍然没有完全达到饱和的迹象。这强烈暗示着4倍超分辨率重建的难度更大, 需要模型进行更长时间、更充分的训练, 才能使其参数得到充分的优化, 从而更好地恢复图像中更加精细的细节信息。这一观察结果与超分辨率重建领域普遍存在的规律相符, 即图像的放大

倍数越高, 需要恢复的细节信息越多, 重建的难度也就越大, 模型需要更强的学习能力和更长的训练时间。对于月球 NAC 影像而言, 由于其自身可能存在的噪声以及相对较弱的纹理特征, 高倍数的超分任务对模型的特征提取和细节恢复能力提出更高的要求。

图 11(b)~(d) 分别展示了切片大小、RSTB 数量和嵌入维度对 PSNR 的影响。总体而言, 这3个参数的增加均能在一定程度上提升各尺度下的 PSNR 值, 但提升幅度和饱和点存在差异。对于切片大小, 2倍超分在较小的切片尺寸(如 32×32) 下就能获得

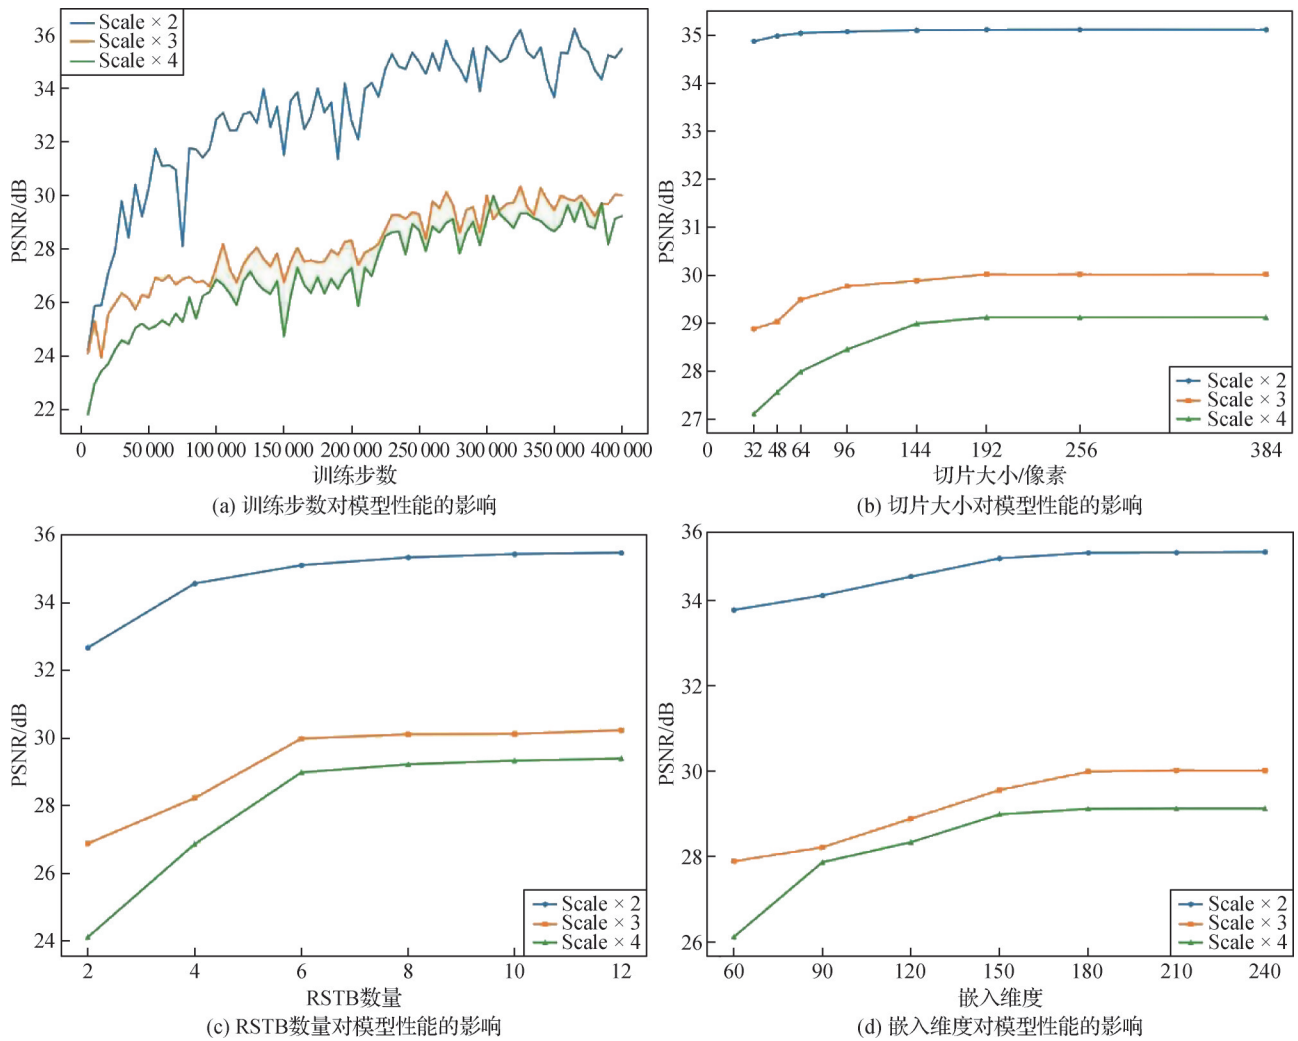


图 11 消融实验结果折线图

Fig. 11 Line chart of ablation experiment results ((a) effect of training steps on model performance; (b) effect of training patch size on model performance; (c) effect of RSTB number on model performance; (d) effect of embedding dimension on model performance)

较高的 PSNR, 而 4 倍超分则需要更大的切片 (如 144×144 以上) 才能达到最佳性能。这表明高倍数超分对感受野的需求更大, 较小的切片限制了模型捕捉长距离依赖关系的能力。3 倍超分任务的表现则介于 2 倍和 4 倍之间, 随着切片尺寸的增加, PSNR 也呈现出上升的趋势, 但其对切片尺寸的需求不如 4 倍超分那样显著。这进一步印证了超分倍数越高, 模型对感受野的需求也越大的规律。对于 RSTB 数量, 各尺度下的 PSNR 均随 RSTB 数量增加而上升, 并在一定数量后趋于饱和。其中, 4 倍超分的 PSNR 曲线在 RSTB 数量较少 (如 2~6) 时上升最为显著, 这表明更深的网络能够提取到更抽象、更复杂的特征, 这对于恢复图像中更加精细和难以捕捉的细节信息至关重要。对于嵌入维度, 2 倍超分在较低维度 (如 60) 下就能获得较好的性能, 而 4 倍超分则

需要更高的维度 (如 180 以上) 才能充分发挥模型的表现能力。这表明对于低倍数的超分任务, 模型对于特征的精细度和多样性的要求可能相对较低, 而高倍数的超分任务对于特征的精细度和多样性有着更高的要求, 需要模型能够表示更加复杂和细致的特征信息, 才能更好地恢复图像中的细节。

综合来看, 消融实验结果表明, MSRT 模型在不同尺度下的超分性能对各参数的敏感度存在差异。高倍数超分 (4 倍) 对切片大小、RSTB 数量和嵌入维度均更为敏感, 需要更大的切片、更深的网络和更高的嵌入维度才能充分发挥模型的性能。这主要是因为 4 倍超分需要重建更多的细节, 对模型感受野、特征提取能力和表达能力都提出更高要求。而低倍数超分 (2 倍) 对这些参数的敏感度相对较低, 较小的切片、较浅的网络和较低的嵌入维度也能获得较好

的性能。这些发现为 MSRT 模型在实际应用中的参数选择提供了重要参考。针对月球南极 NAC 影像这一具体任务,为了兼顾计算效率和重建精度,可以针对不同超分倍数选择不同的参数组合。例如,对于 4 倍超分,可以优先考虑较大的切片、较多的 RSTB 和较高的嵌入维度;而对于 2 倍超分,则可以适当减小这些参数的值。

4 结论

本研究针对月球南极 NAC 影像因“求和”模式导致的多尺度分辨率退化问题,系统性地开展了数据构建、模型设计与算法验证工作,旨在突破现有超分辨率方法在长程依赖建模与多尺度适应性方面的局限性。通过理论分析、实验验证与工程化探索,本文的主要研究成果与发现如下:1)构建了一个大规模、多尺度的月球 NAC 影像超分辨率数据集。基于 NASA 公开的高质量影像,采用严格的数据质量筛选和预处理方法,模拟了实际“求和”模式下出现的 2 倍、3 倍和 4 倍空间分辨率退化情况,为后续模型训练和验证提供了高质量基础数据。该数据集的构建充分考虑了月球影像的真实退化特性,有效提升了模型训练的泛化能力。2)提出一种自适应多尺度超分辨率 Transformer 模型(MSRT)。MSRT 创新性地将 Transformer 与 CNN 相结合,通过 Transformer 的全局感受野捕获陨石坑链、撞击溅射纹等全局地质结构关系,CNN 则有效恢复月壤纹理等亚像素级局部特征。针对 NAC 影像多尺度退化特性,设计了尺度特定的空间感知上采样模块(S³U),实现不同降采样倍率的精细化重建与参数共享,大幅降低了模型复杂度。3)通过与多个主流超分辨率方法的对比实验分析,验证了所提 MSRT 方法的有效性。同时,详细的消融实验分析了模型参数(如切片大小、Transformer 模块深度、嵌入维度)对重建质量的影响规律,为模型在实际应用中的参数选择提供了科学依据。

尽管本文研究取得了上述成果,但实验与分析过程中依然存在一些不足之处:1)当前数据集主要基于模拟退化生成,未充分纳入实际成像中的阴影动态变化与噪声干扰;2)当前研究仅关注影像空间分辨率提升,而未充分考虑月球影像中噪声、光照不均等其他退化因素对重建效果的影响。

未来拟开展以下研究工作:1)结合辐射传输模型,构建更贴近物理成像过程的多模态退化数据集;2)深入研究月球影像中光照条件、噪声及其他复杂退化因素的影响机制,构建更全面的退化模型,提升模型对真实场景影像退化的适应性与重建质量,以更好地满足未来月球探测任务的科学需求;3)结合月球自转和光照变化规律,研究时空联合超分辨率重建方法,利用多时相 NAC 影像之间的相关性,进一步提升重建精度和细节信息。

致谢:本文为第 27 届中国科协年会学术论文,感谢中国科学技术协会的支持。

参考文献(References)

- Al-Mekhlafi H and Liu S G. 2024. Single image super-resolution: a comprehensive review and recent insight. *Frontiers of Computer Science*, 18(1): #181702 [DOI: 10.1007/s11704-023-2588-9]
- Bickel V T, Moseley B, Lopez-Francos I and Shirley M. 2021. Peering into lunar permanently shadowed regions with deep learning. *Nature Communications*, 12(1): #5607 [DOI: 10.1038/s41467-021-25882-z]
- Chen H T, Wang Y H, Guo T Y, Xu C, Deng Y P, Liu Z H, Ma S W, Xu C J, Xu C and Gao W. 2021. Pre-trained image processing transformer//*Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Nashville, USA: IEEE: 12294-12305 [DOI: 10.1109/CVPR46437.2021.01212]
- Delgado-Centeno J I, Sanchez-Cuevas P J, Martinez C and Olivares-Mendez M A. 2021. Enhancing lunar reconnaissance orbiter images via multi-frame super resolution for future robotic space missions. *IEEE Robotics and Automation Letters*, 6(4): 7721-7727 [DOI: 10.1109/LRA.2021.3097510]
- Dong C, Loy C C, He K M and Tang X O. 2016. Image super-resolution using deep convolutional networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 38(2): 295-307 [DOI: 10.1109/TPAMI.2015.2439281]
- Ha V K, Ren J C, Xu X Y, Zhao S, Xie G and Vargas V M. 2018. Deep learning based single image super-resolution: a survey//*Proceedings of the 9th International Conference on Advances in Brain Inspired Cognitive Systems*. Xi'an, China: Springer International Publishing: 106-119 [DOI: 10.1007/978-3-030-00563-4_11]
- Hui Z, Gao X B, Yang Y C and Wang X M. 2019. Lightweight image super-resolution with information multi-distillation network//*Proceedings of the 27th ACM International Conference on Multimedia*. Nice, France: Association for Computing Machinery: 2024-2032 [DOI: 10.1145/3343031.3351084]
- Ledig C, Theis L, Huszar F, Caballero J, Cunningham A, Acosta A, Aitken A, Tejani A, Totz J, Wang Z H and Shi W Z. 2017. Photo-

- realistic single image super-resolution using a generative adversarial network//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE: 105-114 [DOI: 10.1109/cvpr.2017.19]
- Lepcha D C, Goyal B, Dogra A and Goyal V. 2023. Image super-resolution: a comprehensive review, recent trends, challenges and applications. *Information Fusion*, 91: 230-260 [DOI: 10.1016/j.inffus.2022.10.007]
- Liang J Y, Cao J Z, Sun G L, Zhang K, van Gool L and Timofte R. 2021. SwinIR: image restoration using Swin transformer [EB/OL]. [2025-03-20]. <https://arxiv.org/pdf/2108.10257.pdf>
- Liu J J, Zeng X G, Li C L, Ren X, Yan W, Tan X, Zhang X X, Chen W L, Zuo W, Liu Y X, Liu B, Liu D W, Zhou Q and Ouyang Z Y. 2021. Landing site selection and overview of China's lunar landing missions. *Space Science Reviews*, 217(1): #6 [DOI: 10.1007/s11214-020-00781-9]
- Robinson M S, Brylow S M, Tschimmel M, Humm D, Lawrence S J, Thomas P C, Denevi B W, Bowman-Cisneros E, Zerr J, Ravine M A, Caplinger M A, Ghaemi F T, Schaffner J A, Malin M C, Mahanti P, Bartels A, Anderson J, Tran T N, Eliason E M, McEwen A S, Turtle E, Jolliff B L and Hiesinger H. 2010. Lunar reconnaissance orbiter camera (LROC) instrument overview. *Space Science Reviews*, 150(1): 81-124 [DOI: 10.1007/s11214-010-9634-2]
- Tai Y, Yang J and Liu X M. 2017. Image super-resolution via deep recursive residual network//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE: 2790-2798 [DOI: 10.1109/CVPR.2017.298]
- UI Hoque M R, Burks R, Kwan C and Li J. 2019. Deep learning for remote sensing image super-resolution//Proceedings of the 10th IEEE Annual Ubiquitous Computing, Electronics and Mobile Communication Conference (UEMCON). New York, USA: IEEE: 286-292 [DOI: 10.1109/UEMCON47517.2019.8993047]
- Vondrak R, Keller J, Chin G and Garvin J. 2010. Lunar reconnaissance orbiter (LRO): observations for lunar exploration and science. *Space Science Reviews*, 150(1): 7-22 [DOI: 10.1007/s11214-010-9631-5]
- Wang X T, Yu K, Wu S X, Gu J J, Liu Y H, Dong C, Qiao Y and Change Loy C. 2018. ESRGAN: enhanced super-resolution generative adversarial networks//Proceedings of 2018 European Conference on Computer Vision Workshops. Munich, Germany: Springer: 630-645 [DOI: 10.1007/978-3-030-11021-5_5]
- Yang F Z, Yang H, Fu J L, Lu H T and Guo B N. 2020. Learning texture transformer network for image super-resolution//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, USA: IEEE: 5790-5799 [DOI: 10.1109/CVPR42600.2020.00583]
- Yang L Q. 2024. Chang'e-6: embarking on humanity's first lunar South Pole sample return journey. *Space International*, (6): 4-5 (杨璐茜. 2024. 嫦娥六号: 开启人类首次月背采样返回之旅. *国际太空*, (6): 4-5) [DOI: 10.3969/j.issn.1009-2366.2024.06.002]
- Yu D Y, Wu X Y and Wu W R. 2016. Review of technology development for Chinese lunar exploration program. *Journal of Deep Space Exploration*, 3(4): 307-314 (于登云, 吴学英, 吴伟仁. 2016. 我国探月工程技术发展综述. *深空探测学报*, 3(4): 307-314) [DOI: 10.15982/j.issn.2095-7717.2016.04.002]
- Yu H M, Rao W, Zhang Y Y and Xing Z Y. 2023. Mission analysis and spacecraft design of Chang'e-7. *Journal of Deep Space Exploration*, 10(6): 567-576 (余后满, 饶炜, 张益源, 邢卓异. 2023. “嫦娥七号”探测器任务综述. *深空探测学报(中英文)*, 10(6): 567-576) [DOI: 10.15982/j.issn.2096-9287.2023.20230119]
- Zhang K, Liang J Y, Van Gool L and Timofte R. 2021. Designing a practical degradation model for deep blind image super-resolution//Proceedings of 2021 IEEE/CVF International Conference on Computer Vision. Montreal, QC, Canada: IEEE: 4791-4800 [DOI: 10.1109/ICCV48922.2021.00475]
- Zhang K, Zuo W M and Zhang L. 2019. Deep plug-and-play super-resolution for arbitrary blur kernels//Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, CA, USA: IEEE: 1671-1681 [DOI: 10.1109/CVPR.2019.00177]

作者简介

苗丁锐博,男,博士研究生,主要研究方向为深空探测和计算机视觉。E-mail: miaodrb@whu.edu.cn

鄢建国,通信作者,男,教授,博士生导师,主要研究方向为行星科学。E-mail: jgyan@whu.edu.cn

涂志刚,男,研究员,博士生导师,主要研究方向为计算机视觉和视频理解。E-mail: tuzhigang@whu.edu.cn

Jean-Pierre Barriot,男,教授,博士生导师,主要研究方向为大地测量和行星科学。E-mail: jean-pierre.barriot@upf.pf