

基于超分辨率重建的农田遥感影像分类方法

韩昊¹ 冯子怡^{1,2} 刘永升¹ 许胜¹ 杜文^{1,2} 许童羽^{1,2}

(1. 沈阳农业大学信息与电气工程学院, 沈阳 110866;

2. 沈阳农业大学国家数字农业区域创新分中心(东北), 沈阳 110866)

摘要: 大尺度农业分类制图对保障粮食安全、优化灌溉管理、保护生态环境、高标准农田建设以及推动农业资源可持续发展具有不可替代的价值。中低分辨率卫星影像难以满足高精度田间观测, 高分辨率遥感影像获取成本通常较高, 为实现精准的农业种植区分类, 本文提出了基于超分辨率重建的农田遥感影像分类方法, 并系统评估了其提升分类准确率的潜力。聚焦 Sentinel-2 号数据, 设计了一种新型生成对抗网络(HM-PGGAN), 通过融合多尺度渐进生成与注意力机制, 以增强高倍率超分辨率重建的结构保真度。除评估重建后对影像分类结果的改进外, 进一步分析了超分辨率重建影像与基于 GLCM 的纹理特征在支持向量机(SVM)和随机森林(RF)分类器协同作用下综合效应。从视觉分析与定量对比双重视角评估了道路、建筑物、裸土等典型地物类型的分类性能。试验结果表明, 针对下采样至 40 m 的 Sentinel-2 号影像, 经 16 倍超分辨率重建并结合纹理特征后, 总体准确率从重建前的 95.45% (SVM) 和 96.76% (RF) 提升至 98.19% (SVM) 和 98.16% (RF); 在跨平台超分辨率影像重建分类试验中, 总体准确率从 77.79% (SVM) 和 78.50% (RF) 提升至 93.28% (SVM) 和 93.77% (RF)。研究结果显示, 超分辨率重建及添加纹理特征作为空间信息的辅助, 均可增强原始影像的分类制图精度, 但不同地物类别对高倍率超分辨率与特征融合的响应存在差异, 为农业种植区遥感影像高精度分类提供了新的技术思路。

关键词: 超分辨率重建; 生成对抗网络; 种植区分类; 跨平台影像重建

中图分类号: S126 文献标识码: A 文章编号: 1000-1298(2026)20-0041-13

OSID:



Method for Classifying Farmland Remote Sensing Images Based on Super-resolution Reconstruction

Han Hao¹ Feng Ziyi^{1,2} Liu Yongsheng¹ Xu Sheng¹ Du Wen^{1,2} Xu Tongyu^{1,2}

(1. College of Information and Electrical Engineering, Shenyang Agricultural University, Shenyang 110866, China

2. National Digital Agricultural Regional Innovation Sub-Center (Northeast), Shenyang Agricultural University, Shenyang 110866, China)

Abstract: Large-scale agricultural land classification mapping plays an irreplaceable role in ensuring food security, optimizing irrigation management, protecting the ecological environment, supporting the construction of high-standard farmland, and promoting the sustainable development of agricultural resources. However, the limited spatial resolution of freely available satellite data (e.g., Sentinel-2) hinders precise field-level observation, while high-resolution imagery remains costly. The potential of 16 × super-resolution (SR) reconstruction to overcome this limitation was investigated. High-magnification multi-scale progressive growing generative adversarial network (HM-PGGAN), a novel network integrating multi-scale progressive generation and attention mechanisms, was proposed to enhance the structural fidelity of high-magnification SR reconstruction from Sentinel-2 data. The research evaluated not only the classification improvement from SR-reconstructed imagery but also the synergistic effect of combining it with GLCM-based texture features, using both support vector machine (SVM) and random forest (RF) classifiers. Comparative experiments on typical land cover types (roads, buildings, bare soil) showed that 16 × SR reconstruction with texture features boosted the overall classification accuracy

收稿日期: 2026-07-06 修回日期: 2026-07-20

基金项目: 国家重点研发计划项目(2024YFD500602-2)

作者简介: 韩昊(1997—), 男, 博士生, 主要从事农业信息化研究, E-mail: 2022200007@stu.syau.edu.cn

通信作者: 许童羽(1967—), 男, 教授, 博士生导师, 主要从事农业信息化研究, E-mail: xutongyu@syau.edu.cn

(OA) for downsampled 40 m Sentinel-2 imagery from 95.45% (SVM) and 96.76% (RF) to 98.19% (SVM) and 98.16% (RF). In a cross-platform SR experiment, OA was improved from 77.79% (SVM) and 78.50% (RF) to 93.28% (SVM) and 93.77% (RF). The results demonstrated that while both SRR and the integration of texture features as ancillary spatial information enhanced classification accuracy, the responses varied significantly across different land cover types. The research result can provide a novel technical pathway for high-precision remote sensing classification of agricultural planting areas.

Key words: super-resolution reconstruction; generative adversarial network; planting area classification; cross-platform image reconstruction

0 引言

在农业资源监测与精准管理领域,准确获取地块尺度种植信息是实现作物估产、长势评估及管理决策的基础^[1]。特别在高标准农田建设与监管背景下,实现“集中连片、设施配套、高产稳产、生态友好、抗灾能力强”目标,依赖于对耕地空间分布、作物类型、种植结构及农田基础设施的精准识别与动态监测。当前,大范围作物分类主要依赖 Sentinel-2 等中分辨率卫星影像^[2],但其固有空间分辨率限制导致田块边界难以清晰刻画、破碎地块难以有效分离、复杂种植结构难以准确识别,分类结果普遍存在边界模糊、“椒盐噪声”等问题,制约分类准确率进一步提升^[3-4]。在低成本条件下突破中分辨率数据的空间约束、增强空间细节表达能力,已成为实现大范围农业区高精度自动解译的关键需求^[5]。

超分辨率重建技术是缓解空间分辨率限制的重要途径。超分辨率制图作为解决混合像元问题、提升地物空间表征精度的核心技术,早期研究主要基于线性空间相关性假设,采用空间吸引力模型、像元交换算法以及模拟退火、遗传算法等优化策略进行亚像元分类,但此类方法对非线性成像条件的适应性有限。Ge 等^[6]在遥感影像超分辨率制图综述中系统归纳了基于空间相关性、空间结构信息、神经网络及像元交换等亚像元制图方法的进展与局限,指出传统方法在非线性空间建模方面的不足,推动研究转向空间光谱协同建模。

随着深度学习技术的发展,基于卷积神经网络的方法在超分辨率重建领域取得重要突破。Zhang 等^[7]提出一种软信息约束的深度学习方法,采用双分支架构实现 Sentinel-2 时序影像的超分辨率制图,通过分层融合空间先验知识与光谱特征以提升作物类型分类背景下复杂边界重建效果。Liu 等^[8]通过卷积神经网络实现了端到端的超分辨率制图,有效挖掘了多源数据的互补优势。然而,现有研究多集中于低倍率(2~4 倍)重建与同源数据验证^[9-10],针对田块复杂空间结构与光谱特性的跨传

感器高倍率重建研究仍十分有限^[11-12]。

在农业遥感应用方面,相关研究主要聚焦于作物类型识别与田块边界提取。部分学者采用深度学习网络对 Landsat-8、Sentinel-2 等中分辨率影像进行 4 倍重建,利用重建影像使作物分类准确率提升 5%~10%^[13-14]。但上述研究在重建倍率上仍存在局限,难以满足缺乏甚高分辨率遥感数据的小型农业区域精细尺度监测需求。而将超分辨率重建与分类网络集成的端到端方法,则面临训练数据需求量大、模型可解释性有限等挑战^[15-19]。

针对现有研究不足,本文利用分辨率 40 m 的 Sentinel-2 影像重建为等效 2.5 m 的 GF-1 数据,重点评估 16 倍超分辨率重建对田埂、沟渠、地块边界等农业关键地物形态的恢复效能,系统考察超分辨率重建影像在作物分类中实际提升价值。为此,提出集高倍率跨传感器超分辨率重建与分类验证于一体的技术框架。首先,针对高倍率重建需求,设计融合多尺度渐进与注意力机制的生成对抗网路(HM-PGGAN),实现 Sentinel-2 影像(40 m)至 GF-1 等效分辨率(2.5 m)的 16 倍重建,增强地表结构细节的重构保真度与生成影像的感知真实感;其次,构建融合灰度共生矩阵纹理特征与光谱信息的增强特征集;最后,基于支持向量机与随机森林分类器,从视觉质量与定量精度 2 个维度开展综合分析,评估原始影像、超分重建影像及特征融合影像在水田、道路、裸土、建设用地等多类地物上的分类性能。以期揭示高倍数跨传感器超分辨率重建对耕地分类边界锐化、图斑破碎度改善及总体准确率提升的具体贡献,阐明不同地物类型对超分因子及特征组合的差异化响应规律,为利用广泛可获取的中分辨率卫星数据实现高精度耕地制图提供可靠的技术方案与实证依据。

1 研究区域与数据

1.1 研究区域概况

在卫星间高倍数重建分类试验中,选取辽河种植区为主要研究区,辽河两岸冲积平原以大规

模种植水稻为主导,是我国重要的粳稻生产基地,并广泛存在部分玉米种植带;在辽河河口三角洲及其沿岸区域,同时分布着较大面积的天然湿地与人工湿地。共同构成了类型多样的地表景观。




图 1 研究区域

Fig. 1 Overview of research area

在高倍数跨平台超分分类试验中,选择沈阳农业大学辽中卡利玛水稻实验站作为跨平台超分辨率重建分类试验区,位于沈阳市辽中区城郊街道卡利玛村,北纬 41° 12′,东经 122° 23′,面积约为 0.342 km²。地处辽河下游盆地,辽河、浑河冲积平原,土壤肥沃,四季分明,水资源丰富,日照充足。地属北温带半湿润季风大陆性气候,年平均温度 8℃,降雨量 640 mm,无霜期 171 d。种植沈农 265、沈农 9816、沈农 016 等多个品种水稻。

1.2 数据源与预处理

在遥感数据采集方面,选取卫星与无人机 2 类平台数据构建多尺度观测体系。卫星数据方面,选取欧洲航天局“哥白尼计划”的 Sentinel-2 与我国 GF-1 号卫星。Sentinel-2 采用双星协同运行的太阳同步轨道设计,重访周期可缩短至 5 d,搭载的多光谱成像仪(MSI)具备 10 m 空间分辨率及对植被生长状况敏感的红边波段,在农业与生态环境监测中具有明显优势;GF-1 号作为我国首颗高分辨率对地观测卫星,兼具全色高分辨率 2 m 与大幅宽 800 km 观测能力,实现了空间精度与覆盖效率的平衡,表 1 为卫星数据波段信息^[20-22]。


表 1 卫星数据波段信息

Tab. 1 Satellite data band information

数据源	波段	中心波长/nm	空间分辨率/m
GF-1	1-全色	0.45~0.90	2
	2-蓝	0.45~0.52	8
	3-绿	0.52~0.59	
	4-红	0.63~0.69	
	5-近红外	0.77~0.89	
Sentinel-2	2-蓝	0.490	10
	3-绿	0.560	
	4-红	0.665	
	8-近红外	0.835	

无人机数据方面,采用大疆 M300-RTK 行业应

为农作物分类研究提供了涵盖农田、道路、建筑与湿地植被的多样地表覆盖场景,有助于检验相关方法在复杂农业景观中适用性和稳定性,图 1 为研究区域地理位置。



用平台获取厘米级超高分辨率影像,平台集成 RTK 实时动态差分定位与多传感器避障系统,水平定位精度达 1 cm,支持高精度重复航线飞行。本研究飞行高度约 50.83 m,对应地面分辨率达 0.016 3 m,为无人机-卫星跨平台超分辨率重建研究提供高精度的参照基准,表 2 为无人机参数。

表 2 大疆 M300-RTK 型无人机参数

Tab. 2 DJI M300-RTK drone specifications

参数	数值/方式
无人机尺寸(长×宽×高)/ (mm×mm×mm)	810×670×430(展开情况下)
最大起飞质量/kg	9
最大飞行高度/m	5 000
最大飞行时长/min	55
定位方式	GPS+GLONASS+北斗+Galileo
工作温度/℃	-20~50
最远信号传输距离/km	NCC/FCC;15;CE/MIC;8;SRRC;8
地面分辨率/m	0.016 3
飞行高度/m	50.83

1.3 超分辨率重建数据集构建

将 GF-1(2.5 m)影像与双三次下采样至 40 m 的 Sentinel-2 影像构成 16 倍分辨率差异的卫星数据集;同样地,将采样为 0.625 m 的无人机影像与 Sentinel-2(10 m)影像构成 16 倍分辨率差异的跨平台超分辨率数据集。获取相同日期 GF-1 和 Sentinel-2 影像各 5 组(2021 年 10 月 15 日,2022 年 1 月 10 日、8 月 22 日、9 月 26 日、12 月 17 日)制作训练数据集,标记为 GF-1_S2_16 数据集,获取相同日期(2023 年 9 月 13 日)无人机和 Sentinel-2 影像,标记为 UAV_S2 数据集。

2 研究方法

2.1 研究方案

如图 2 所示,由超分辨率重建与纹理增强分类

2 部分构成本文综合试验方案,第 1 阶段为超分辨率重建,使用裁剪后样本对超分辨率模型进行训练,使模型实现图像分辨率 16 倍的提升,生成分辨率 2.5 m 的宽幅高精度卫星图像以及 0.625 m 分辨率的无人机影像。第 2 阶段通过增强纹理特征的空间信息与重建后光谱数据构成分类集合^[23-24],采用成

熟且广泛应用的 SVM^[25]和 RF^[26-27]分类器对农业种植区进行精准分类^[28-30],并采用分层随机抽样方法计算总体准确率和用户准确率。将获取的地物类型 70% 的样本用于训练,30% 用于验证。试验中借助高德地图和天地图等辅助数据集采集这些抽样数据集。




图 2 研究整体流程图
Fig. 2 Overall flowchart of study

2.2 超分辨率重建 HM - PGGAN 模型构建

本文提出一种深度高倍数多尺度渐进增长式生成对抗网络 (HM - PGGAN),用于卫星间高倍数和无人机卫星跨平台超分辨率重建,结合了多尺度 Transformer 结构和渐进式训练的优点。低分辨率影像在进行重建时可能对应多个合理的超分辨率重建版本,多尺度结构可使所有尺度统一还原成 1 个超分辨率重建解,引导模型朝着最合理、最一致的结果进行重建,减少伪影并为重建结果提供强有力的约束;提取图像在不同倍数下多样特征,并进行特征融合,以此提高信息流动和训练效率;仅使用几个像素点即可实现图像深层特征提取。

HM - PGGAN 整体结构如图 3 所示。与大多数 GAN 模型一样, HM - PGGAN 模型由生成器和判别器 2 部分组成。首先使用多尺度 Swin - Transformer (MSTB) 从分辨率为 8 像素 × 8 像素的图像中提取深度特征,然后逐层训练并生成 128 像素 × 128 像素图像,用于 16 倍的超分辨率重建。其中,高倍数超分辨率重建任务需要同时协调不同级别的细节,包括宏观结构和微观纹理,因此仅从 8 像素 × 8 像素图像难以实现多样性的结构提取,所以生成器中添加了多层次特征提取结构。对于图像微观细节方面,通过在高分率、小感受野特征层捕捉有效缓解梯度消失和传递困难问题,即图 3 中生成器主干网络;对于物体整体形状、布局,通过在大感受野和分




图 3 HM - PGGAN 结构
Fig. 3 HM - PGGAN structure

辨率层级的特征层上进行捕捉,即图中 4 ×、8 × 分支网络部分,并将不同的特征在主干网络中特征融合,最终生成高分率遥感影像。在主干网络中,将 BN 层替换为像素归一化 PN 层,强制每个像素特征向量位于单位球面上,防止生成器因竞争导致信号幅度过大,稳定训练,且完全不依赖批次大小。

2.3 谱归一化方法

为进一步提升模型性能,在超分辨率重建框架

中引入谱归一化。通过约束权重矩阵的谱范数,控制每个网络层的利普希茨常数,从而有效稳定对抗训练过程并缓解梯度异常。对于给定的权重矩阵 W ,谱归一化操作可表示为

$$W_{SN} = W \frac{W}{\sigma(W) + \varepsilon}$$

(1)

其中

$$\sigma(W) \approx u^T W_v$$

(2)

$$v \leftarrow \frac{W^T u}{\|W^T u\|_2} \quad u \leftarrow \frac{W v}{\|W v\|_2}$$

式中 $u、v$ ——随机初始化的左右奇异向量
 $\sigma(W)$ ——谱范数
 ε ——微小常数,确保数值稳定性

谱归一化操作被集成至卷积层或全连接层中,通过对权重的重缩放,网络被约束以满足利普希茨连续性,进而增强对抗训练的稳定性,并提升重建质量。

谱归一化对于高倍率重建任务尤为关键,可显著减少生成图像的结构畸变与伪影,同时提升视觉真实感与纹理保真度。此外,谱归一化还起到隐式正则化的作用,提高模型的泛化能力,确保在复杂遥感场景下仍能保持稳健的性能。在计算层面,幂迭代近似法几乎不增加训练开销,使生成器与判别器能够维持长期的训练平衡。这些优势共同促进了重建质量的提升,为基于纹理特征的高精度地表覆盖分类提供了更为可靠的数据基础。

3 超分辨率重建试验与精度验证

3.1 试验数据集和参数配置

首先将 16 倍超分辨率重建网络 HM-PGGAN 应用于异源卫星遥感影像间高倍数超分辨率重建,将 HM-PGGAN 试验结果与 ESRGAN、Res-PGGAN、pix2pix、SwinIR 方法进行比较与评估,验证本文方法在异源卫星遥感影像高倍数超分辨率影像重建中的优越性。

试验采集对应平台的相同日期 GF-1 与

Sentinel-2 影响各 5 幅,相同日期的无人机与 Sentinel-2 影像各 1 幅,并将数据集下采样 16 倍制作对应训练数据集,共裁剪 GF-1_S2 预训练数据 16 500 对,UAV_S2 数据 1 500 对,用于 HM-PGGAN 模型的精细化训练。所提出的生成对抗网络模型使用 Tensorflow 实现,HM-PGGAN 模型在配备 CUDA 版本 12.0 和 16 GB 内存的 NVIDIA Quadro P5000 上以批量大小为 4 的小批量进行训练。采用 Adam 优化器,学习率设置为 0.000 2,VGG 感知损失权重为 0.000 3,迭代次数设置为 300。训练过程一直持续到生成的图像达到最佳质量且无法进一步提升为止,具体参数见表 3。

表 3 HM-PGGAN 训练参数

Tab. 3 HM-PGGAN training parameters

参数	数值	参数	数值
vgg 结构	vgg19	批量大小	4
vgg 损失权重	0.000 3	学习率	0.000 2
L1 权重	200	L2 权重	0.0
LR scale	0.000 1	depth	16
HR scale	0.000 1	迭代次数	300

3.2 遥感影像超分辨率重建精度

为全面评估不同方法在遥感图像超分辨率重建中性能表现,对所提出方法与若干主流模型进行定性分析。

(1)异源卫星间高倍重建:在 16 倍卫星影像超分辨率重建任务中,各方法展现出显著的定性差异,如图 4 所示。作为典型生成对抗网络方法的 ESRGAN,通过对抗训练展现出生成视觉自然图像纹理的能力。然而在高倍数上采样过程,输入信息严重丢失导致该方法易产生伪影和细节失真,图 4 中红色圆圈区域即为典型例证。在遥感影像中具有复杂物体轮廓的区域尤为突出,可能导致过度平滑或结构模糊现象。pix2pix 方法在全局轮廓重建方面表现稳定,但在 16 倍下恢复高频细节的能力仍显




图 4 卫星影像高倍数重建效果

Fig. 4 High-magnification super-resolution reconstruction effects for satellite imagery

不足,道路边缘、建筑边界等精细特征出现模糊化处理,且重建结果易受训练数据分布影响,导致局部纹理呈现不一致。

Res - PGGAN 在复杂区域(如农田或城市网格)中恢复精细纹理的能力存在不足,导致块状伪影或细节缺失现象(图 4 中红色圆圈)。基于 Swin Transformer 架构开发的 SwinIR 在捕捉长程依赖关系方面表现优异,在重建大规模土地覆盖轮廓时展现出强劲性能,但在高倍率下对局部高频细节的重建效果仍欠理想,且高计算复杂度限制了遥感影像中植被纹理与精细建筑结构的清晰呈现。

所提出方法在 16 倍重建过程有效保留了地面物体的整体结构,道路网络与建筑边缘的清晰度优于其他方法,同时抑制了伪影和畸变。渐进式优化机制能够在每个重建阶段迭代修正误差,避免了单阶段端到端方法中常见的误差累积问题。对 Sentinel - 2 重建为 GF - 1 的结果进行定量分析,如表 4 所示。

表 4 卫星遥感影像高倍数超分辨率重建精度
Tab. 4 High-magnification super-resolution accuracy for satellite remote sensing imagery

数据源	方法	SSIM	PSNR/dB	SAM	SRE
Sentinel - 2 (40 m)	ESRGAN	0. 609	20. 335	11. 007	73. 102
	pix2pix	0. 643	22. 917	11. 046	74. 512
\	Res - PGGAN	0. 703	24. 583	8. 053	75. 119
	SwinIR	0. 707	24. 727	4. 459	75. 294
GF - 1 (2. 5 m)	HM - PGGAN	0. 714	24. 934	2. 919	75. 383

由表 4 可知,本文方法 HM - PGGAN 在 4 个核心评估指标结构相似性指数 SSIM^[31]、峰值信噪比 PSNR^[32]、光谱角制图 SAM^[33]、信号重建误差 SRE^[34]上均取得最佳性能,展现出全面且显著的优势。在图像结构保真度方面,本文方法 SSIM 为 0. 714,为所有方法中最高值。相较于表现其他方法 Res - PGGAN(0. 703)和 SwinIR(0. 707),本文方法分别提升 0. 011 和 0. 007,表明在亮度、对比度及结构感知相似性方面具有更优表现。在像素级精度方面,本文方法 PSNR 为 24. 934 dB,较 Res - PGGAN(24. 583 dB)提升 0. 351 dB,较 SwinIR(24. 727 dB)提升 0. 207 dB。

本文方法在光谱信息保真度方面展现出显著优势。其 SAM 为 2. 919,在所有方法中表现最优,远低于次优方案 SwinIR(4. 459)和 Res - PGGAN(8. 053),充分体现了重建过程光谱失真最小化与光谱保真度最大化的特点。此外,本文方法获得最高 SRE 为 75. 383,较 SwinIR(75. 294)和 Res -

PGGAN(75. 119)分别提升 0. 089 和 0. 264,进一步验证了在信号重建精度方面的卓越性能。

(2)跨平台高倍重建:由图 5 可知,基于深度学习的 PGGAN、Res - PGGAN 以及 HM - PGGAN 方法重建效果普遍优于传统插值方法,本文方法在分辨率提升、细节恢复和风格迁移方面表现良好。Res - PGGAN 在视觉上(图 5c)与原始图像(图 5e)最为接近,特别是在高倍率超分辨率任务中表现稳定。而图 5d 中, HM - PGGAN 在农田复杂纹理区域展现出更优的细节恢复能力, Sentinel - 2 卫星影像中原本模糊的种植结构与田间小路得到更清晰的还原。然而,在建筑与道路等结构清晰的区域, HM - PGGAN 与 Res - PGGAN 的区分度不明显,部分场景下边缘与结构完整性仍有提升空间。因此在复杂农田场景中, HM - PGGAN 能更精细地重建耕种纹理;在农田、道路与建筑混合区域,亦能取得优于其他方法的效果。综合来看, HM - PGGAN 在农田细节重建方面表现突出,但在结构化区域的视觉区分度与边缘保持方面尚有优化空间。




图 5 16 倍重建结果

Fig. 5 16 × super-resolution reconstruction results

表 5 为 16 倍跨平台超分辨率重建任务中不同算法在稻田、道路及建筑以及整体准确率上评估结果。由表 5 可知, HM - PGGAN 在多项关键指标上均取得了最优性能,特别是在衡量人类视觉感知质量的 UIQ 指标方面,表现出了显著优势,验证了模型在复杂场景细节与整体视觉自然度重建方面的有效性。

在稻田类别中, HM - PGGAN 取得了全部 3 项指标的绝对最优值。与传统 Bicubic 方法相比,提升极为显著;相较于深度学习方法 ESRGAN、PGGAN 以及表现优异的 Res - PGGAN, HM - PGGAN 在 SSIM、PSNR 和 UIQ 上均实现了最优。定量结果有力佐证了前文定性分析的结论,即 HM - PGGAN 多尺度融合的架构设计可适用于处理具有多层次纹理和弱结构特征的农田场景,能够从宏观布局到微观细节进行特征重建,从而生成更丰富、更逼真的纹理信息。

表 5 跨平台超分辨率重建结果

Tab. 5 Results of cross-platform super-resolution reconstruction

方法	类别	SSIM	PSNR/dB	UIQ
Bicubic	稻田	0. 851	38. 178	-0. 045
ESRGAN		0. 970	44. 501	0. 098
PGGAN		0. 972	44. 832	0. 123
Res - PGGAN		0. 978	45. 773	0. 154
HM - PGGAN		0. 980	46. 160	0. 256
Bicubic	道路及建筑	0. 851	37. 280	0. 021
ESRGAN		0. 836	35. 209	0. 049
PGGAN		0. 844	36. 010	0. 067
Res - PGGAN		0. 846	37. 131	0. 103
HM - PGGAN		0. 863	39. 353	0. 211
Bicubic	整体	0. 899	41. 123	-0. 009
ESRGAN		0. 966	43. 871	0. 027
PGGAN		0. 969	44. 323	0. 041
Res - PGGAN		0. 973	44. 797	0. 042
HM - PGGAN		0. 979	45. 856	0. 061

在道路与建筑等更具挑战性的重建任务中,不同方法之间的性能差异较为明显。HM - PGGAN 在该类场景中客观指标表现相对更优。其中,SSIM 为 0. 863,PSNR 为 39. 353 dB,UIQ 为 0. 211,在所有方法中均处于最高水平。从整体重建结果看,HM - PGGAN 在综合指标上表现较为均衡。其 SSIM 达到 0. 979,UIQ 为 0. 061,PSNR 为 45. 856 dB,均优于其他方法。

本文方法与 ESRGAN、PGGAN、Res - PGGAN

相比,各项指标均呈现出稳定提升的趋势。总体而言,多尺度设计在跨平台图像特征建模与重建中是有效的,也为兼顾结构保真与视觉质量的超分辨率方法提供了一种可行方案。

4 农田遥感影像重建分类试验

4.1 卫星影像间高倍数超分辨率重建

在高倍遥感影像超分辨率重建分类试验中,通过 HM - PGGAN 将重采样为 40 m 分辨率的 Sentinel - 2 影像重建为 2. 5 m,并提取纹理特征,并与原始影像光谱信息融合,输入 SVM 和 RF 分类器中进行分类。参照 GB/T 21010—2017《土地利用现状分类》基准共分为水稻、道路、建筑、湿地、水体、土壤 6 类。

(1)定性分析

为深入评估 16 倍高倍数超分辨率重建技术对遥感影像实际分类效果的影响,并直观展示在恢复空间细节、增强地物边界与改善分类结果方面的作用,对重建前后影像分类结果进行定性对比分析。结果如图 6 所示,基于 SVM 和 RF 的分类结果细节,如图 7 所示。

从图 7 可看出,基于重建影像的实际分类效果有显著的性能提升:原始 40 m 分辨率影像在道路、土壤等结构复杂区域分类结果呈明显破碎化与边界模糊现象,并伴随大量椒盐噪声。经 16 倍超分辨率重建后,重建影像有效恢复了地表要素的空间细节




图 6 卫星影像间高倍数超分辨率重建下 SVM 与 RF 算法分类结果

Fig. 6 Classification results of SVM and RF algorithms under high-magnification super-resolution reconstruction of satellite images




图 7 基于 SVM 和 RF 的分类结果细节

Fig. 7 Classification result details based on SVM and RF

与形态结构特征。图中道路的线性特征趋于连续完整,建筑轮廓更为清晰锐利。不同地物在 16 倍尺度下可解译程度存在明显差异,整体分类准确率显著提高,重建影像显著缓解了因云层遮挡导致的类别误判问题,分类图斑的纯净度得到明显改善,重建后影像中田块边界更为明确,地块间粘连情况得到大幅缓解。各地物类别间的可区分度明显增强,相应地物类别的空间位置精度亦显著提高。

引入灰度共生矩阵 (GLCM) 纹理信息^[23-24]有效提升了分类图面的视觉质量与分类一致性,由图 7 中 SVM 的细节图可见,在仅使用超分影像时,分类结果仍存在若干“同谱异物”误判现象。例如,部分光谱特征相似的水体与阴影被误判为建设用地。小面积池塘与稻田之间的混淆则在纹理特征辅助下得到明显纠正。实地采样过程发现个别池塘在成像时刻存在水面浮萍覆盖现象。水体、稻田边界的整体分类效果在纹理特征的加持下得到了明显改善。如图 7 中 RF 分类器所示,纹理特征通过提供关键的空间上下文信息,能有效区分光谱响应相近但纹理模式迥异的地物类别,抑制了分类结果中椒盐噪声,促使稻田、水体、道路等地物斑块内部更均质、边界更平滑。

(2)定量评价

为评估高倍数超分辨率重建技术及纹理特征结合对地物分类的改善效果,分析了 4 种数据源在 2 种分类器下准确率。4 种数据源分别为原始 GF-1 影像、原始 Sentinel-2 号 40 m 影像、16 倍超分辨率重建影像以及结合纹理特征的超分辨率重建影像,结果见表 6。

由表 6 可知,超分辨率重建与融合纹理特征的策略显著提升了遥感影像的分类整体性能,且不同地物类型对各分类算法的响应呈现显著差异。基准试验表明,空间分辨率是决定复杂地物分类准确率的关键因子。凭借原生高分辨率优势,原始 GF-1 影像在总体准确率(OA)上表现优越,SVM 与 RF 分类准确率分别达到 96.92% 与 94.95%。这种优势在对空间细节敏感的地类中尤为突出:在 SVM 分类器下,GF-1 对道路的生产者准确率(PA)达

表 6 卫星间超分辨率影像分类结果

Tab. 6 Classification results using inter-satellite

super-resolution images			%	
影像数据	指标	类别	SVM	RF
原始 GF-1 锐化影像	生产者准确率	水稻	98.49	97.96
		湿地	99.69	99.22
		道路	55.92	60.12
		水体	95.42	87.96
		土壤	83.81	72.07
		建筑	95.86	95.81
	总体准确率		96.92	94.95
Sentinel-2 号影像下采样 40 m	生产者准确率	水稻	94.05	96.40
		湿地	99.18	98.53
		道路	51.58	69.68
		水体	98.80	98.13
		土壤	57.89	63.16
		建筑	91.72	94.08
	总体准确率		95.45	96.76
Sentinel-2 号(40 m)16 倍超分辨率重建影像	生产者准确率	水稻	97.27	96.67
		湿地	99.73	97.55
		道路	58.18	74.27
		水体	98.35	99.42
		土壤	52.31	67.97
		建筑	97.20	97.07
	总体准确率		97.61	97.26
融合纹理特征的 Sentinel-2 号 16 倍超分辨率重建影像	生产者准确率	水稻	98.23	97.93
		湿地	99.46	98.70
		道路	62.14	84.43
		水体	99.73	99.52
		土壤	67.10	73.96
		建筑	97.09	96.77
	总体准确率		98.19	98.16

55.92%,较 Sentinel-2 40 m 影像提升 4.34 个百分点;对土壤的 PA 更是从 57.89% 提升至 83.81%,增幅达 25.92 个百分点。表明原始空间分辨率的不足是制约低分辨率影像在复杂场景下进行精细分类的主要因素。

应用 16 倍超分辨率重建影像后,多地物分类准确率得到显著改善,尤以对空间细节敏感的地类提升最为明显。超分重建有效恢复了地物的边缘结构与纹理细节,使得道路、建筑及土壤等类别的识别准确率大幅提高。具体而言,RF 对道路的 PA 从

69.68% 提升至 74.27%，增幅为 4.59 个百分点；SVM 对建筑的 PA 从 91.72% 提升至 97.20%，已接近 GF-1 影像的 95.86%。值得注意的是，空间分辨率的增强虽提升了几何识别能力，但重建过程亦可能引入光谱扰动，例如，SVM 对土壤的 PA 由 57.89% 降至 52.31%。在超分辨率重建基础上进一步融合纹理特征，构成了本研究的最优技术方案。纹理特征的引入提供了关键的空间上下文语义信息，显著增强了分类结果的稳健性与精细化程度。一方面，纹理信息有效缓解了超分引起的光谱失真，使 RF 对水体的 PA 进一步提升至 99.52%；另一方面，显著改善了 SVM 在土壤等异质性复杂地表上的识别能力，其 PA 从 57.89% 提升至 67.10%。从整体性能来看，融合后的影像数据配合 SVM 和 RF 分类器取得了较高的总体准确率 98.19% 和 98.16%。随机森林则在道路、土壤等特定地物上表现更优，道路达 84.43%，较原始 GF-1 影像高出 24.31 个百分点。

总的来看，纹理特征与超分辨率重建的融合能够协同优化分类性能，在增强空间细节识别能力的同时，也较好地保持了光谱特征的稳定性，为高分辨率遥感影像缺乏条件下精细地物分类提供了有效的技术路径。

4.2 跨平台高倍数超分辨率重建分类试验

跨平台农业遥感应用中，融合多源数据实现高精度农田监测面临诸多挑战。卫星影像具备大范围覆盖与高重访能力，但空间分辨率通常不足以分辨田块内部结构、作物垄行等细节特征。无人机影像可提供厘米级细节，却受续航能力和作业范围限制，难以实现大区域连续观测。不同平台的辐射定标系数之间往往缺乏直接可比性。为突破上述瓶颈，本研究提出一种融合跨平台超分辨率重建与多特征协同的分类框架。以构建的 HM-PGGAN 模型为基础，首先将 10 m 分辨率 Sentinel-2 卫星影像重建至 0.625 m（无人机级别）的高空间分辨率，有效弥合平台间的尺度鸿沟。针对重建后影像，进一步提取多尺度纹理特征，并与光谱信息融合，构建具有更强判别力的特征集，通过支持向量机与随机森林等分类器实现地物的精细分类。

(1) 定性评价

为充分评估跨平台高倍数超分辨率重建技术在农业场景下实际分类性能，并直观对比与原始分辨率影像在空间细节恢复与地物判别能力方面的差异，对跨平台 16 倍超分辨率重建影像的分类效果进行定性分析，结果如图 8 所示。




图 8 跨平台高倍数超分辨率重建影像下 SVM 与 RF 算法的分类结果

Fig. 8 Classification results of SVM and RF algorithms under cross-platform high-magnification super-resolution reconstructed images

从图 8 可以看出，相比原始 10 m 分辨率影像，经过 16 倍超分辨率重建至 0.625 m 后，影像的视觉质量与可解释性得到显著改善。原始 10 m 分辨率影像中，空间细节缺乏，田块无法精细识别，道路、田埂等线状地物，以及建筑、温室大棚等结构性地物，

在分类结果中无法正确呈现。原始分辨率难以支持清晰的地物区分，不同作物在 10 m 尺度下光谱混合程度存在较大差异。相比之下，16 倍超分重建影像有效增强了田间地表要素的形态与结构信息，图中道路的线性轮廓变得连续完整，建筑区域的几何边

界更为清晰锐利,地块间的分割也更加明确,整体分类图的视觉效果和空间一致性因此大幅提高。重建影像还有效缓解了因混合像元导致的类别模糊问题,分类图斑的纯净度得到改善。地物细节的丰富度、边界的锐利度以及类别内部均质性方面均进一步提升,更高倍数的超分辨率重建能更充分地恢复影像的纹理与结构细节,有利于田间地物类别的准确划分。

(2)定量评价

为评估跨平台影像分辨率重建后的分类效果,表 7 为 3 种数据源分类准确率。3 种数据源分别为 Sentinel-2 分辨率 10 m 影像、跨平台超分辨率重建后的 0.625 m 影像以及无人机 0.625 m 原生影像。分类器采用支持向量机与随机森林。以 Sentinel-2 分辨率 10 m 影像的分类结果作为性能基线进行分析,由表 7 可知,对于水稻这类光谱特征鲜明的地物,支持向量机分类器表现出较高的 PA (96.10%),而随机森林相对较低(91.34%)。然而,在面对道路、建筑等空间结构复杂的地物类型时,分类准确率普遍偏低,SVM 对道路的生产者准确率仅为 59.46%,RF 分类器下建筑 PA 为 76.56%。温室大棚和水体在 10 m 分辨率下分类效果极不理想,SVM 对温室大棚的分类准确率为 0,对水体也为 0,说明原始影像的空间分辨率严重不足已成为实现精细地物分类的主要制约因素,尤其对具有复杂空间结构或较小尺寸的地物类型。重建到分辨率 0.625 m 影像后,分各地物分类准确率得到了显著改善。分辨率的大幅提升有效恢复了地物在空间结构上的精细特征,使道路、建筑等类别的 PA 大幅提升。其中,SVM 对道路的 PA 从 59.46% 提高至 75.31%,RF 对建筑的 PA 从 76.56% 提升至 91.19%。温室大棚和水体这些在 10 m 分辨率下无法识别的地物,在重建高分辨率影像中取得了突破性进展,RF 对水体的 PA 达到 41.27%,SVM 对温室大棚的 PA 达到 49.72%。OA 则分别从 77.79% 和 78.50% 提升至 93.77% 和 93.77%,显示出分辨率提升对分类性能的重大影响。

与 0.625 m 无人机原始数据相比,无人机影像在绝对准确率上略有优势(总体准确率 95.02% 和 95.18%)。重建影像与其差距不足 2 个百分点,微小差距与重建技术带来的巨大成本优势形成鲜明对比。在建筑和水稻等主要地物分类上,重建影像的分类准确率与无人机影像相差无几(建筑类别 PA 相差 5~7 个百分点)。证实了超分辨率重建技术在保持关键地物分类准确率方面的可靠性,提出高质量的重建算法能够在很大程度上弥补分辨率不足

表 7 跨平台超分辨率影像农田分类结果				
Tab. 7 Farmland classification results using cross-platform super-resolution images				%
影像数据	指标	类别	SVM	RF
Sentinel-2 10 m	生产者准确率	水稻	96.10	91.34
		道路	59.46	48.65
		建筑	84.83	76.56
		大棚	0	48.57
		其他	83.33	58.33
		水体	0	14.29
	总体准确率		77.79	78.50
跨平台超分重建 0.625 m 影像	生产者准确率	水稻	99.58	99.27
		道路	75.31	73.34
		建筑	90.28	91.19
		大棚	49.72	52.28
		其他	82.04	76.58
		水体	0.75	41.27
	总体准确率		93.28	93.77
无人机 0.625 m 原 始数据	生产者准确率	水稻	98.87	99.90
		道路	86.65	77.69
		建筑	98.28	96.49
		大棚	57.10	69.64
		其他	97.79	97.24
		水体	5.66	10.57
	总体准确率		95.02	95.18

的问题。试验结果表明,本文方法能够在跨平台条件下实现种植区高准确率分类,为构建空天地一体化的农业遥感监测体系提供了重要的方法支撑。

4.3 敏感性分析

在农业遥感影像分类中,不同作物类型和生长阶段常常表现出相似的光谱信号。单纯依赖原始影像的波段信息,易受到作物生育期、土壤背景和管理方式的影响,导致分类准确率受限。引入灰度共生矩阵(GLCM)纹理特征,可以描述作物冠层和其他不同地物在空间上结构差异,有助于提高不同类别的可区分性。GLCM 特征的效果高度依赖窗口尺寸。尤其是当纹理与波段信息叠加形成联合特征空间时,窗口尺寸对分类结果的影响会更加敏感和复杂,因此着重进行本文分类任务中对纹理特征的敏感性分析。

在纹理窗口对地物分类应用的敏感性分析中,试验以 16 倍超分辨率重建方法生成的 2.5 m 空间分辨率影像数据为例,采用随机森林分类器系统探究灰度共生矩阵纹理特征提取窗口尺寸对多类别分类准确率的影响机制,结果如表 8 所示。结果表明,在重建影像所提供的增强空间细节表征能力下,纹理特征的引入能有效补偿单纯光谱特征在区分光谱混淆地物时局限性,对重建时造成的光谱混淆情况在空间信息上进行了一定的补偿,对不同地物纹理

表 8 纹理窗口对分类准确率敏感性分析

Tab. 8 Sensitivity analysis of texture window size on classification accuracy

%

类别	指标	纹理特征提取窗口尺寸								
		5 × 5	7 × 7	9 × 9	11 × 11	13 × 13	15 × 15	17 × 17	19 × 19	21 × 21
水稻	生产者准确率	97.38	97.93	98.13	98.18	98.35	98.57	98.81	98.67	98.63
道路		85.39	85.43	86.31	86.37	87.10	87.14	87.60	85.58	84.77
建筑		96.70	96.77	97.12	97.18	97.38	97.40	97.49	97.56	97.28
湿地		98.27	98.70	98.84	98.62	99.09	99.14	99.21	99.30	99.44
裸地		73.56	77.96	83.31	83.88	84.51	84.72	85.24	83.62	83.97
水体		99.51	99.52	99.52	99.46	99.50	99.50	99.50	99.52	99.54
	总体准确率	97.804	98.162	98.310	98.317	98.485	98.610	98.752	98.721	98.740

窗口的尺寸均有一定影响。

总体准确率分析显示,窗口尺寸与分类性能之间存在显著的非线性依赖关系,总体准确率 OA 曲线如图 9 所示。随着纹理特征提取窗口从 5 × 5 逐步扩大至 17 × 17,OA 呈现单调递增趋势,从 97.804% 提升至 98.752%,增幅 0.948 个百分点。结果表明,在 10 m 分辨率尺度上,适度扩大邻域窗口能够有效聚合像元间的空间自相关信息,提取更具地表表征能力的纹理特征,从而增强分类器对水稻田垄行结构、建筑群规则排列等空间模式的辨识能力。然而,当窗口尺寸进一步增至 19 × 19 与 21 × 21 时,OA 分别微降至 98.721% 与 98.740%。该拐点的出现揭示了纹理统计中尺度饱和效应,即过大的窗口会超越单一地类斑块的典型空间范围,导致纹理特征向量中包含异质性地物信息,从而模糊分类器的决策边界,抑制模型性能的进一步提升。




图 9 纹理特征提取窗口尺寸对分类准确率的影响

Fig. 9 Impact of texture feature extraction window scale on classification accuracy

从地物类别特异性角度观察,不同地物类型对纹理尺寸的敏感性存在显著分异,图 9 中 PA 曲线的不同形态展示了这一特征。水体类别在光谱与纹理维度均具有高度同质性与独特性,PA 始终维持在 99.46% ~ 99.54% 之间,对应图 9 中近乎水平的水体分类变化曲线。水体对窗口尺度变化呈现惰性响应,仅凭光谱特征已可实现近乎完美的可分性。

道路与裸地等地物表现出强烈的尺寸依赖性。道路作为线性地物,其 PA 在 17 × 17 窗口达到峰值 87.60%,该尺寸可能最优地平衡了道路自身宽度特

征及其与周边地物的灰度对比关系;当窗口过大时,过多邻近背景信息的纳入导致纹理统计量失真,分类准确率显著衰退。裸地类别则呈现出对小尺寸窗口极为敏感的特性,其 PA 从 5 × 5 窗口的 73.56% 提升至 9 × 9 窗口的 83.31%,增幅达 9.75 个百分点,并在 13 × 13、15 × 15 窗口区间趋于稳定,这一剧烈变化体现在图 9 中橙色曲线的陡峭上升段,图 9 中曲线进一步量化了这种改善效果。对于水稻、湿地与建筑等类别,其 PA 随窗口的扩大变化趋势相对平缓,且存在明确的局部最优区间,水稻与建筑的 PA 峰值均出现在 17 × 17 窗口,分别为 98.81% 和 97.49%;湿地则在 21 × 21 窗口取得最高准确率 99.44%。此类差异可能源于各地类内部空间异质性程度的差异:稻田具有规则的周期性结构,建筑屋顶呈现均质的纹理与几何形态,中等尺度窗口足以捕捉其主导空间模式;而湿地植被群落分布往往具有更强的空间变异性与更大规模的斑块结构,因而需要更大范围的纹理统计以整合整体空间特征。

综上所述,在基于超分辨率重建影像与随机森林分类器的技术框架内,纹理窗口尺寸的选择是影响分类模型性能的关键超参数。试验结果证实了 17 × 17 窗口在本文数据与模型配置下相对最优性,OA 达到 98.752%。该窗口下水稻 PA 为 98.81%,建筑为 97.49%,道路为 87.60%,裸地为 85.24%。这些关键地物类别均达到或接近各自准确率峰值。该尺度与 10 m 分辨率重建影像的有效空间信息量能够较好匹配。既充分提取了鉴别性纹理特征,又避免了跨类别信息混淆和空间细节过度平滑。当窗口尺寸超过 17 × 17 后,各类别 PA 普遍出现停滞或下降,说明过大的窗口并未提高性能增益。敏感性分析为结合纹理特征的超分辨率影像在农业遥感精细分类中的特征尺寸选取提供了试验依据和参数化参考。

5 结论

(1)提出的 HM - PGGAN 模型能实现 16 倍高

倍数超分辨率重建,结合 GLCM 纹理特征后可显著提升中低分辨率遥感影像的地物分类准确率。试验结果表明,本文方法有效恢复了田块边界、道路等空间细节,在 16 倍重建结合纹理的方案中 SVM、RF 的 OA 分别达到 98.19% 和 98.16%,验证了高倍率超分在农业遥感分类中的实用价值。

(2)不同地物类型对超分重建与纹理特征的响应存在显著差异,在道路、土壤等空间结构复杂的类别受益最为明显,而水体等光谱均一的地物对纹理窗口尺度变化呈惰性响应。纹理特征的引入为分类器

提供了关键的空间信息,有效缓解了裸地、建筑等地物因光谱混淆导致的误分问题,增强了模型的鲁棒性。

(3)通过对不同倍数重建模型与 2 种分类器的组合试验,证实了本文方法具有良好的可迁移性和稳定性。所有基于超分重建的处理方案,OA 均超过原始 GF-1 锐化影像,多种地物 PA 均取得显著提升。敏感性分析进一步表明,纹理提取窗口尺度与分类性能存在非线性关系,17×17 窗口在本文数据与模型配置下为相对最优尺度,为实际业务化应用提供了参数参考。

参 考 文 献

[1] 杨颖频,吴志峰,骆剑承,等. 时空协同的地块尺度作物分布遥感提取[J]. 农业工程学报, 2021, 37(7): 166–174.
Yang Yingpin, Wu Zhifeng, Luo Jiancheng, et al. Parcel-based crop distribution extraction using the spatiotemporal collaboration of remote sensing data[J]. Transactions of the CSAE, 2021, 37(7): 166–174. (in Chinese)

[2] Drusch M, Del U, Carlier S, et al. Sentinel-2: ESA's optical high-resolution mission for GMES operational services[J]. Remote Sensing of Environment, 2012, 120: 25–36.

[3] 罗锡文,谷秀艳,胡炼,等. 大田无人化智慧农场农田边界识别技术研究现状与展望[J]. 农业机械学报,2025,56(2):1–18.
Luo Xiwen, Gu Xiuyan, Hu Lian, et al. Research status and outlook of farmland boundary recognition technology in large-scale unmanned smart farms[J]. Transactions of the Chinese Society for Agricultural Machinery,2025,56(2):1–18. (in Chinese)

[4] Cai Z Q, Hu Q, Zhang X, et al. Improving agricultural field parcel delineation with a dual-branch spatiotemporal fusion network by integrating multimodal satellite data[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2023, 205: 34–49.

[5] 侯新刚,王勤,令伟锋. 基于多尺度注意力视觉 Mamba U-Net 的耕地遥感分割方法[J]. 农业机械学报,2026,57(4): 279–286.
Hou Xin'gang, Wang Qin, Ling Weifeng. Remote sensing segmentation of cultivated land based on multi-scale attention vision Mamba U-Net[J]. Transactions of the Chinese Society for Agricultural Machinery,2026,57(4): 279–286. (in Chinese)

[6] Ge Y, Chen Y, Li X, et al. A review of super-resolution mapping of remotely sensed imagery: from pixel to subpixel[J]. GIScience & Remote Sensing, 2023, 60(1): 2169657.

[7] Zhang C, Wei S, Ji S, et al. Deep learning-based super-resolution mapping for improving crop type classification from Sentinel-2 time series[J]. Remote Sensing of Environment, 2022, 279: 113112.

[8] Liu X, Wang L, Chen X, et al. Multilevel feature exploration network for image superresolution[J]. Scientific Programming, 2022, 2022: 2014627.

[9] 孙卫东,韩晓琳. 高分高光谱遥感图像计算成像:从融合到光谱超分[J]. 遥感学报,2025,29(6):1636–1648.
Sun Weidong, Han Xiaolin. Computational imaging of high-spatial-resolution hyperspectral remote sensed images: from fusion to spectral super-resolution[J]. National Remote Sensing Bulletin, 2025,29(6):1636–1648. (in Chinese)

[10] 王鹏,姚红雨,张弓. 超像元尺度下的多光谱图像超分辨率洪水淹没制图[J]. 遥感学报,2021,25(2):641–652.
Wang Peng, Yao Hongyu, Zhang Gong. Super-resolution flood inundation mapping for multispectral image based on super-pixel scale[J]. National Remote Sensing Bulletin,2021,25(2):641–652. (in Chinese)

[11] Wu P H, Yin Z X, Lu J, et al. Spectral-spatial collaborative learning for subpixel mapping from coarse resolution imagery[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2025, 213: 78–94.

[12] 赵耀,葛小三,金满库. 改进生成式对抗网络的高分遥感影像超分辨率重建[J]. 经纬天地, 2023(4): 18–22.
Zhao Yao, Ge Xiaosan, Jin Manku. Super-resolution reconstruction of high-resolution remote sensing images based on improved generative adversarial networks[J]. Survey World, 2023(4): 18–22. (in Chinese)

[13] Jia X, Hao Z, Li X, Wang Z, et al. Enhancing cropland mapping with spatial super-resolution reconstruction by optimizing training samples for image super-resolution models[J]. Remote Sensing, 2024, 16(24): 4678.

[14] 王佳玥,蔡志文,王文静,等. 协同多源国产高分影像和面向对象方法的南方农作物遥感识别[J]. 中国农业科学, 2023, 56(13): 2474–2490.
Wang Jiayue, Cai Zhiwen, Wang Wenjing, et al. Remote sensing identification of southern crops by integrating multi-source domestic high-resolution images and object-oriented methods[J]. Scientia Agricultura Sinica, 2023, 56(13): 2474–2490. (in Chinese)

[15] 杜培军,夏俊士,薛朝辉,等. 高光谱遥感影像分类的深度学习方法:进展与展望(2023 重印版)[J]. 测绘学报, 2023, 52(10): 1689–1708.
Du Peijun, Xia Junshi, Xue Chaohui, et al. Deep learning methods for hyperspectral remote sensing image classification:

- progress and prospects (2023 reprint) [J]. *Acta Geodaetica et Cartographica Sinica*, 2023, 52(10): 1689 – 1708. (in Chinese)
- [16] Zhong Y, Zhang L, Lu X, et al. Deep learning-based image super-resolution in remote sensing: progresses and challenges [J]. *Journal of Remote Sensing*, 2023, 5: 128.
- [17] 张依涵, 沈占锋, 寇雯齐, 等. 基于多源遥感数据的林农间作种植结构精细分类[J]. *农业机械学报*, 2025, 56(10): 429 – 436.
Zhang Yihan, Shen Zhanfeng, Kou Wenqi, et al. Fine classification under pattern of forest and crops intercropping based on multi-source remote sensing data [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2025, 56(10): 429 – 436. (in Chinese)
- [18] Ma L, Liu Y, Zhang X, et al. Deep learning in remote sensing applications: a meta-analysis and review (2023 update) [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2023, 198: 200 – 218.
- [19] 张震洲, 高昆, 李维, 等. 光学遥感图像的超分辨率处理技术综述[J]. *航天返回与遥感*, 2020, 41(6): 21 – 33.
Zhang Zhenzhou, Gao Kun, Li Wei, et al. A survey on the optical remote sensing image super-resolution technology [J]. *Spacecraft Recovery & Remote Sensing*, 2020, 41(6): 21 – 33. (in Chinese)
- [20] 林镠鹏, 李杰, 沈焕锋. 基于多尺度注意力机制的遥感深度学习超分辨率模型[J]. *遥感学报*, 2024, 28(9): 2362 – 2371.
Lin Liaopeng, Li Jie, Shen Huanfeng. A remote sensing deep learning super-resolution model based on multi-scale attention mechanism [J]. *Journal of Remote Sensing*, 2024, 28(9): 2362 – 2371. (in Chinese)
- [21] He Y, Zhang T, Lin Z, et al. Multi-scale attention GAN for remote sensing image super-resolution [J]. *Sensors*, 2023, 23(14): 6342.
- [22] 刘子雨. 基于生成对抗网络的遥感影像光谱超分辨率重建方法研究[D]. 武汉: 武汉大学, 2023.
Liu Ziyu. Research on adversarial spectral super-resolution for remote sensing imagery [D]. Wuhan: Wuhan University, 2023. (in Chinese)
- [23] Haralick R M, Shanmugam K, Dinstein I. Textural features for image classification [J]. *IEEE Transactions on Systems, Man, and Cybernetics*, 1973, SMC-3(6): 610 – 621.
- [24] 赵英时. 遥感应用分析原理与方法[M]. 2版. 北京: 科学出版社, 2013.
- [25] Cortes C, Vapnik V. Support-vector networks [J]. *Machine Learning*, 1995, 20(3): 273 – 297.
- [26] Breiman L. Random forests [J]. *Machine Learning*, 2001, 45(1): 5 – 32.
- [27] 杨鹏, 韩丙顺, 张裕, 等. 基于 Sentinel-2 多时相影像与随机森林的水稻种植区提取[J]. *农业工程学报*, 2023, 39(12): 145 – 154.
Yang Peng, Han Bingshun, Zhang Yu, et al. Extraction of rice planting areas based on Sentinel-2 multi-temporal images and random forest [J]. *Transactions of the CSAE*, 2023, 39(12): 145 – 154. (in Chinese)
- [28] 陈晋, 何春阳, 卓莉. 基于变化向量分析(CVA)的土地利用/覆盖变化动态监测(II)——变化类型的确定方法[J]. *遥感学报*, 2001, 5(5): 346 – 352, 403.
Chen Jin, He Chunyang, Zhou Li. Land use/cover change detection with change vector analysis (CVA): change type determining [J]. *Journal of Remote Sensing*, 2001, 5(5): 346 – 352. (in Chinese)
- [29] Foody G M. Status of land cover classification accuracy assessment [J]. *Remote Sensing of Environment*, 2002, 80(1): 185 – 201.
- [30] 阎菩提, 邱实, 岳程斐. 结合局部高清图像的遥感集群目标区域超分辨率重建[J]. *南京航空航天大学学报*, 2023, 55(6): 1021 – 1030.
Yan Puti, Qiu Shi, Yue Chengfei. Remote sensing image super-resolution reconstruction with local high-resolution clustered object images [J]. *Journal of Nanjing University of Aeronautics and Astronautics*, 2023, 55(6): 1021 – 1030. (in Chinese)
- [31] 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.
- [32] Eskicioglu A M, Fisher P S. Image quality measures: an overview [J]. *Proceedings of SPIE*, 2000, 4311: 75 – 93.
- [33] Kruse F A, Lefkoff A B, Boardman J W, et al. The spectral image processing system (SIPS): interactive visualization and analysis of imaging spectrometer data [J]. *Remote Sensing of Environment*, 1993, 44(2/3): 145 – 163.
- [34] Wald L. Data fusion for remote sensing applications [M]. Paris: École des Mines de Paris, 2002.