

# 基于CMIFM的跨平台超分辨率高光谱影像重建及光谱定量评估——以岩溶湿地为例

孙习东<sup>1</sup>, 付波霖<sup>1</sup>, 李华剑<sup>1</sup>, 贾明明<sup>2</sup>, 孙伟伟<sup>3</sup>, 武炎<sup>1</sup>, 宋奕基<sup>1</sup>

1. 桂林理工大学测绘地理信息学院, 桂林 541006;

2. 中国科学院东北地理与农业生态研究所湿地生态与环境重点实验室, 长春 130000;

3. 宁波大学土木工程与地理环境学院, 宁波 315211

**摘要:** 高光谱遥感时序精准监测湿地植被和水体状况已成为准确评估和全面监测岩溶湿地生态系统状况的重要基础。然而, 现有星载高光谱影像的空间分辨率较低, 难以捕捉湿地植被复杂的空间细节, 已有超分辨率重建方法无法实现卫星和无人机跨平台影像重建, 且难以实现对大范围湿地场景的时序监测。为了解决上述问题, 本文提出一种跨平台的多尺度影像特征映射模块CMIFM (Cross-Sensor Multiscale Image Feature Mapping Module)。该模块统一了无人机高光谱影像AHSI (Aerial hyperspectral image) 和星载高光谱影像SHSI (Spaceborne hyperspectral image) 的空间尺度, 根据便携式地物光谱仪ASD (Analytical Spectral Devices) 的实测数据将AHSI和SHSI映射在同一个光谱特征空间中, 进而整合AHSI和SHSI的空谱特征信息, 构建影像特征数据集。通过使用超分辨率网络(ESRGAN和SwinIR)实现SHSI的高质量影像重建。同时, 本文采用最新的深度学习(DATFuse)和传统的融合方法(GS)对比在湿地场景下, Sentinel-2和OHS-02重建影像和融合影像中植被群落和水体的光谱和空间质量。研究结果表明: (1) 基于CMIFM的超分辨率网络能够通过学习AHSI特征, 实现跨平台提升SHSI中湿地植被和水体的空间纹理细节信息, 在视觉感知和定量指标方面均优于GS影像融合方法, 重建影像的平均PSNR和SSIM精度分别为11.06和0.3102; (2) 重建影像中狗牙根、华克拉莎和芒草3种典型湿地植被群落以及水体的光谱特征和实测ASD数据相比具有高稳定性和保真性, 且光谱波段的平均RMSE和 $R^2$ 精度值高于DATFuse和GS融合影像; (3) CMIFM+ESRGAN和CMIFM+SwinIR方法在空谱重建性能上具有较强的泛化能力, 能够在AHSI未覆盖的区域中完成影像的重建, 平均PSNR和 $R^2$ 分别为12.74和0.1897, 接近AHSI覆盖区域的精度数值范围。(4) 本文验证了基于CMIFM模块的超分辨率技术在复杂湿地高光谱影像重建中的可行性。

**关键词:** 岩溶湿地, CMIFM模块, 跨平台的超分辨率重建, DATFuse, 高光谱影像, 植被和水体的空谱重建质量定量评估

**中图分类号:** P2

**引用格式:** 孙习东, 付波霖, 李华剑, 贾明明, 孙伟伟, 武炎, 宋奕基. XXXX. 基于CMIFM的跨平台超分辨率高光谱影像重建及光谱定量评估——以岩溶湿地为例. 遥感学报, XX(XX): 1-22

SUN Xidong, FU Bolin, LI Huajian, JIA Mingming, SUN Weiwei, WU yan, SONG Yiji. XXXX. **Combination of CMIFM module and super-resolution network for cross-platform hyperspectral image reconstruction and spectral quantitative assessment——A case study of karst wetland.** National Remote Sensing Bulletin, DOI: 10.11834/jrs.20243431

## 1 引言

岩溶湿地作为全球湿地生态系统中重要的组成部分, 在全球碳固存和陆地碳循环中发挥着重要作用 (Sun等, 2023; Zhang等, 2023)。然而,

在全球气候变化、人类活动和岩溶区特有地质灾害 (岩溶塌陷、岩溶崩塌、地下水渗漏等) 的多重影响下 (Peng等, 2023), 目前中国典型的岩溶湿地, 均出现了面积萎缩、植物入侵、水位暴涨暴落、水体富营养化和生物多样性减退等严重的

收稿日期: XXXX-XX-XX; 预印本: XXXX-XX-XX

基金项目: 国家自然科学基金项目 (编号: 42371341; 42122009); 广西自然科学基金面上项目 (编号: 2023JJA150096), 广西博士研究生创新项目 (编号: YCSW2023353); 广西八桂学者团队项目和桂林理工大学科研启动基金项目 (编号: GUTQDJJ2017096)

第一作者简介: 孙习东, 研究方向为湿地遥感超分辨率重建算法开发和应用。E-mail: 2120211897@glut.edu.com

通信作者简介: 付波霖, 研究方向为主动湿地遥感应用。E-mail: fbl2012@126.com

生态问题 (Yang 等, 2023; Waheed 等, 2023; Daniel 等, 2023)。高光谱遥感作为新型的遥感技术, 星载高光谱影像 (SHSI) 拥有数十个甚至数百个光谱波段且单景幅宽较大, 精细捕捉不同生长期湿地植被和水质的细微光谱差异, 为有效解决多尺度、大范围估算和监测湿地生态系统状况提供了重要的技术手段 (Han 等, 2023)。但是, 由于我国西南地区存在长时间多雨、多云、多雾的气候条件, 星载高光谱影像波段光谱辐射率与真实地表反射率出现偏差, 最终导致对湿地植被和水体的监测精度较低, 而高质量的星载高光谱影像也会受到卫星往返周期的限制。因此, 如何有效整合将无人机高光谱影像 (AHSI) 和星载高光谱影像的信息优势 (Lassalle 等, 2023), 成为实现对岩溶湿地长期连续且精准监测的难题。

近年来, 整合无人机影像和星载影像优势互补的方法, 主要包括影像融合和超分辨率影像重建。其中, 基于像素级的影像融合方法在遥感领域具有重要意义。随着传统的像素级融合方法不断迭代和优化 (Ghassemian 等, 2016), 现主要可以分为三类, 成分替换 (CS) (Aiazzi 等, 2009), 小波变换 (WT) (Alparone 等, 2016) 和退化模型 (DM) (Bendoumi 等, 2014)。Fu 等 (2022) 通过小波变换融合了无人机 RGB 影像和吉林一号多光谱影像, 获得同时具有丰富空间纹理细节和频谱信息的重建影像, 提高了湿地场景的分类精度。然而, 传统的融合方法需要基于先验知识, 人为干涉因素较多, 且假设的输入影像和输出影像遵循线性映射关系。深度学习模型可以轻松提取高维复杂特征并学习影像间的非线性映射关系, 越来越多的深度神经网络 (DNN) 已经被证明在视觉感知和定量评估方面相对传统影像融合方法取得了领先。Sun 等 (2021) 提出一种多尺度低秩深度背投融合网络, 实现了低空间分辨率高光谱数据和空间分辨率多光谱数据的融合, 融合结果具有优越的空间和光谱保真度。基于深度学习的 DATFuse (Tang 等, 2023) 是一种对红外波段和可见光波段融合的端到端新型模型, 验证了 DATFuse 的融合性能优于传统融合方法, 然而, 缺少了对跨平台高光谱影像融合方案的进一步研究。本文使用 DATFuse 对星载多光谱和高光谱影像和无人机全色影像融合, 定量分析融合影像中湿地植被和水体光谱特征信息。然而, 传统的融

合方法和基于 DNN 的融合方法, 要求无人机影像和星载影像的地理坐标信息具有一致性, 当缺少高分辨率的无人机影像时, 融合方法受到限制。

超分辨率影像重建方法旨在从低分辨率影像 (LR) 中重建高分辨率 (HR) 影像 (Wang 等, 2022), 从超分辨率网络中建立 LR 和 HR 在空谱特征上的变化规律。对遥感影像的重建方法主要分为四类: 基于退化建模的超分辨率 (Gu 等, 2019), 基于影像对的超分辨率 (Chen 等, 2019), 基于域转换的超分辨率 (Maeda, 2020) 和基于自学习的超分辨率 (Soh 等, 2020)。Fu 等 (2023a) 使用 SRCNN 和 SRGAN 等超分辨率模型, 利用 GF-1 多光谱影像 (4 个光谱波段) 进行训练, 对 Landsat 9 OLI (10 个光谱波段) 等星载影像进行重建, 实验证明了超分辨率重建技术在提升影像空间分辨率的同时, 光谱保真性较高。目前, 对影像重采样的方法通常是使用双三次插值 (Bicubic), 然而, 由于缺少对高空间尺度影像纹理特征等信息的学习, 不同星载影像波段间的光谱范围存在差异, 导致使用星载影像训练模型存在一定的局限性。通过无人机平台获取 AHSI 作为一种解决波段光谱范围方案, 但是缺少关于构建跨平台影像数据间重建关系的研究。受到影像融合方法的启发, 本文基于光谱特征映射的思路将无人机影像和星载影像的地物特征信息整合, 增加超分辨率重建模型在训练时对跨平台高空间尺度影像细节的学习, 并提出一种跨平台的多尺度影像特征映射模块 CMIFM (A Cross-Platform Multiscale Image Feature Mapping Module)。CMIFM 首先统一了 AHSI, SMSI 和 SHSI 的空间尺度, 其次, 根据实测 ASD 数据将 AHSI, SMSI 和 SHSI 映射在同一个光谱特征空间中, 通过 Mixup 方法给定影像光谱波段间权重值, 将 AHSI, SMSI 和 SHSI 的空谱特征进行加权融合, 最后分别根据 AHSI 和 SMSI 以及 AHSI 和 SHSI 间的线性拟合关系, 结合超分辨率网络实现 SMSI 和 SHSI 的重建。

目前, 缺少对影像融合方法和超分辨率影像重建方法性能比较的研究, 对上述两个方法的精度评价指标主要包括峰值信噪比 (PSNR) 和结构相似性 (SSIM) (Hore 等, 2010)。该指标通过计算输入影像对间像素值的差异, 评价重建影像与原始影像的整体相似程度。然而, 对重建影像整体的精度评价不能反应单一地物类型的重建质量。

因此，本文根据实测样本点的分布区域评价狗牙根、华克拉莎和芒草3种典型湿地植被群落和研究区内水体的重建质量，并构建了一个对地物重建精度定量评价的体系。该体系根据实测样本点的ASD数据，从地物重建光谱特征的稳定性和保真性两个角度，实现对湿地植被群落和水体重建质量的定量评价。

本文以广西桂林会仙喀斯特国际重要湿地为研究区，基于高光谱无人机影像和实测湿地植被和水体 ASD 数据，使用 CMIFM+ESRGAN 和 CMIFM+SwinIR 重建模型提升 Sentinel-2 多光谱和 OHS-02 高光谱影像的空间分辨率，与基于深度学习的 DATFuse 融合算法和传统 GS 融合算法对比，定量评估 Sentinel-2 和 OHS-02 重建影像中湿地植被和水体的空间纹理特征提升和光谱特征变化。具体研究目标为：(1) 定量评估基于 CMIFM 模块的超分辨率影像重建方法在湿地场景中的性能；(2) 对比重建影像（CMIFM+ESRGAN 和 CMIFM+SwinIR）和融合影像（DATFuse 和 GS）的空谱精度差异，验证两种重建方法的性能差异；(3) 定量评价 CMIFM+ESRGAN 和 CMIFM+SwinIR 在相同

的空间分辨率下，对多光谱影像和高光谱影像的重建质量；(4) 根据实测 ASD 数据定量分析重建影像中湿地植被和水体光谱特征的稳定性和保真性，验证基于 CMIFM 模块的超分辨率影像重建方法在湿地场景中对不同地物光谱特征定量分析的可行性。

## 2 研究区概况与数据源

广西桂林会仙喀斯特国际重要湿地（地理位置 25° 05′ 20″~25° 06′ 55″ N、110° 10′ 50″~110° 14′ 21″ E，见图 1），属于典型的岩溶峰林平原地貌，是中国最大的岩溶湿地（Cai 等，2020）。湿地公园海拔 147 - 292 米，总面积 586.75 公顷，属亚热带季风气候，气候温和，雨量充沛，无霜期长，光照充足，热量丰富，夏长冬短，四季分明，雨热同季，年平均气温 16.5~20.5℃，年降水量 1897 毫米。目前已知的仙岩溶湿地共有管束植被 108 科 241 属 316 种，包括华克拉莎、狗牙根、芒草、苔草等植被群落，2023 年 2 月该湿地入选国际重要湿地名录。

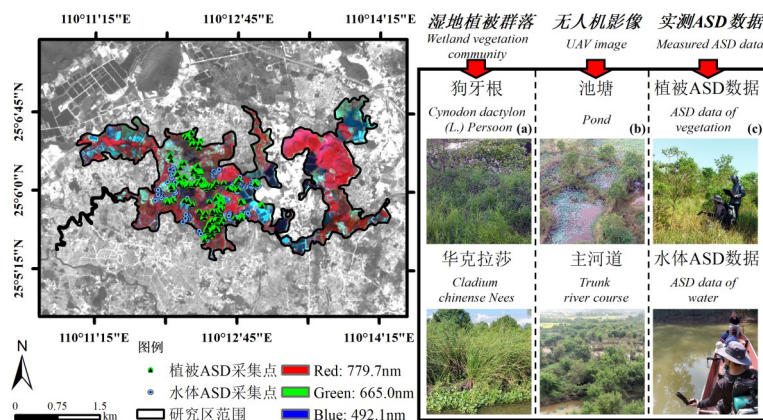


图 1 OHS-02 高光谱影像研究区概况及实测样本点数据的采集

Fig 1 Survey of OHS-02 hyperspectral image study area and collection of measured sample points data

本文共使用了三种类型的遥感数据（图 1），具体如下：(1) 星载影像：星载影像包括 Sentinel-2 多光谱影像和 OHS-02 高光谱影像，能够提供大范围的研究区信息。本文使用 Sentinel-2 系列 2B 星影像（下文简称 Sentinel-2）共 13 个波段，获取时间为 2022 年 4 月 7 日，光谱范围 442.3 - 2185.7nm，影像获取途径为 <https://scihub.copernicus.eu/> [2022-04-07]，本文使用的 OHS-02 影像空间分辨率 10m 共 32 个波段，获取时间为

2022 年 4 月 8 日，光谱范围 466.0 - 940.0nm，影像获取途径为 <https://www.obidata.com/> [2022-04-08]；(2) 无人机高光谱影像：数据采集时间为 2022 年 4 月 10 日 - 2022 年 4 月 17 日。无人机的型号为大疆经纬 M300 RTK，搭载 Nano-Hyperspec 微型无人机高光谱镜头，飞行高度 200 米，航带重叠率 30%，能够获取高精度的小范围研究区植被群落和水体光学信息（图 1 (b)）；(3) 地面实测 ASD 数据：本文利用美国 ASD FieldSpec 4 地物高

光谱仪（光谱范围为350 - 2500nm，间隔1nm，光谱分辨率为25nm）（图1（c））与星载影像和无人机影像的获取时间同步测量湿地植被和水体光谱，测量当天天气晴朗。使用上水法（Fu等，2023b）测量水面采样点的光谱值。通过样方法（1米×1米的样方块）均匀获取湿地植被群落的叶

片样本，在无光环境的实验室内测量同一样方内全部叶片样本的平均值光谱值作为该样本点植被的光谱值（图1（a）），该样本点数据拥有无人机数据和星载数据的共同特征，能够用于验证重建影像中。

表1 多源遥感影像和实测ASD数据具体参数

Table 1 Specific parameters of multi-source remote sensing images and measured ASD data

| 数据源              | 数据获取时间             | 空间分辨率         | 光谱范围             | 实测样本点总数 |
|------------------|--------------------|---------------|------------------|---------|
| 狗牙根 ASD 数据       | 2022年4月10日 - 4月15日 |               |                  | 22      |
| 华克拉莎 ASD 数据      | 2022年4月10日 - 4月15日 |               |                  | 23      |
| 芒草 ASD 数据        | 2022年4月10日 - 4月15日 | ∥             | 350.0 - 2500.0nm | 26      |
| 水体实测 ASD 数据      | 2022年4月15日 - 4月17日 |               |                  | 97      |
| 无人机高光谱影像         | 2022年4月10日 - 4月13日 | 0.05 米        | 400.0 - 1000.0nm | ∥       |
| Sentinel-2 多光谱影像 | 2022年4月7日          | 10米, 20米, 60米 | 442.3 - 2185.7nm | ∥       |
| OHS-02 高光谱影像     | 2022年4月8日          | 10 米          | 466.0 - 940.0nm  | ∥       |

本文使用SNAP 8.0软件对Sentinel-2影像进行辐射校正和重采样处理，获得10m空间分辨率的研究区多光谱影像。使用OpenOHS软件对OHS-02影像进行辐射校正和正射校正处理，获得10m空间分辨率的研究区高光谱影像。使用Pix4D Mapper软件对无人机高光谱影像进行辐射校正和斑块拼接处理，获得研究区0.05米的数字正射影像。通过在研究区内的RTK控制点对多光谱影像，高光谱影像和无人机影像进行影像配准，投影坐标系统一为WGS 1984 UTM Zone 49 N。

### 3 研究方法

#### 3.1 跨平台的多尺度影像特征映射模块(CMIFM)

在对星载影像进行重建时，由于无人机影像传感器的成像范围与星载影像（本文指Sentinel-2多光谱和OHS-02高光谱星载影像）存在差异，使用超分辨率模型直接学习无人机影像和星载影像间的光谱关系，在重建结果上会产生较多的噪声。使用双三次插值（Bicubic）构建无人机影像数据集进行模型训练，在重建结果上会缺失纹理特征信息。基于上述问题，本文提出一种跨平台的多尺度影像特征映射模块（CMIFM），该模块由3个影像映射层组成。在第一层中，构建无人机插值影像间（特征1和特征2）的映射关系；在第二层中，分别构建ASD数据（特征3）和无人机影像，

以及ASD数据和星载影像（特征4和特征5）间的映射关系；在第三层中，构建无人机影像和星载影像间的映射关系。将无人机数据作为参考影像，依次训练第一层（步骤1），第二层（步骤2）和第三层（步骤3）输出数据集。

##### 3.1.1 构建影像空间尺度特征关系

星载影像重建最主要的目的在于空间分辨率的提升以及像素间能够更加精确表达不同地物间的差异。Bicubic通过插值的手段可以提升或者降低影像中的像素数量，能够很好的初步构建重建前后像素间的数量关系，因此，本文选择首先使用Bicubic对无人机影像进行下采样处理（空间分辨率变化：从0.05米到1.25米到10米）。相对比对星载影像进行上采样处理（空间分辨率变化：从10米到1.25米），通过对无人机影像下采样能够更多的保留目标尺度（0.25米）的光谱地物特征。

##### 3.1.2 整合无人机影像和星载影像间的光谱特征信息

本文引入实测ASD数据作为无人机影像和星载影像之间光谱特征的桥梁。利用实测样本点提取相同地理空间位置上影像的光谱值，构建光谱值与ASD数据的数学拟合关系，并通过映射的方式实现无人机影像和星载影像光谱特征值在同一光谱特征空间中。本文使用Mixup数据增强算法

(Zhang等, 2017) 作为映射的方法, 分别给定无人机和星载影像的权重值, 对跨平台影像数据进行整合, 生成包含无人机空间纹理特征和高光谱地物光谱特征的影像。Mixup如公式(1)所示,

其中,  $x_i$ 为星载影像数据,  $y_i$ 为无人机影像数据, 本文将权重( $\lambda$ )值设置为0.5, 旨在目标影像包含的无人机影像和星载影像特征相同。

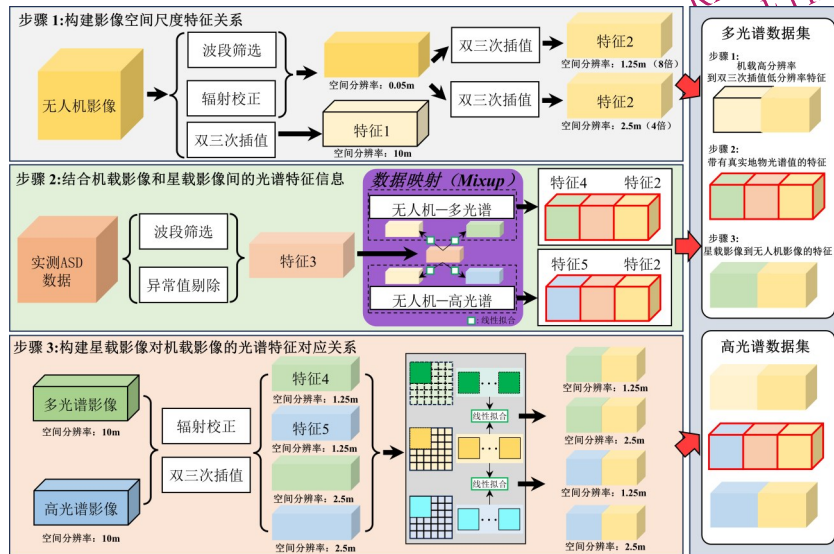


图2 跨平台的多尺度影像特征映射模块

Fig. 2 Cross-platform multi-scale image feature mapping module (CMIFM)

$$f(x_i, y_i) = \lambda x_i + (1 - \lambda) y_i \quad (1)$$

在图3中, 图I到V展示了Sentinel-2原始影像光谱值映射到ASD数据的前后光谱特征信息, 图VI到X展示了OHS-02原始影像光谱值映射到ASD数据的前后光谱特征信息。在图I和图VI中, 曲线代表样本点的平均值, Sentinel-2原始影像的光谱值分布在0.25附近, OHS-02原始影像的光谱值分布在0.35附近更加接近ASD数据, 在II和VII中, 展示映射后的Sentinel-2和OHS-02影像光谱值的平均值以及其最值范围, 在III和VIII中, 展示了映射后光谱值平均值和2倍标准差的范围, IV到V和IX到X展示了映射后无人机的光谱特征信息。其中, Sentinel-2映射后光谱值与ASD数据的RMSE和 $R^2$ 精度分别是0.1183和0.7695, OHS-02为0.1427和0.6568。

### 3.1.3 构建星载影像对无人机影像的光谱特征对应关系

为了保证模型在经过无人机重采样影像和Mixup混合影像训练后不会丢失星载影像的光谱特征, 本文进一步构建星载影像和无人机影像的线性拟合关系。使用 $n \times n$ 规格的矩阵块(本文使用将n设置为3)按照从左到右, 自上而下求取矩阵

内的光谱值的平均值并进行位置标记, 将星载影像作为y变量, 无人机影像作为x变量, 依次对具有相同位置标记的x和y值进行线性拟合, 最后构建星载影像对无人机影像的最小二乘多项式拟合方程。

## 3.2 超分辨率影像重建方法

### 3.2.1 对抗神经网络CMIFM+ESRGAN超分辨率重建方法

ESRGAN(Wang等, 2018)是一种生成式对抗网络, 其基本模型由残差密集块构建, 基于CMIFM模块的ESRGAN超分辨率网络见图4所示, 其中LReLU和Sigmoid属于不同类型的激活函数。在GAN框架中, 使用感知损失函数(公式(3))进行优化, 感知损失函数函数包括两个部分: 内容损失函数和对抗损失函数, 本文选择BCELoss作为内容损失函数(公式(4)), 选择MAELoss作为对抗损失函数(公式(5))。ESRGAN对抗网络由生成器和判别器两个部分组成, 将低分辨率(LR)影像放入生成器网络生成超分辨率(SR)影像, 将高分辨率(HR)影像和超分辨率(SR)影像放入判别器网络, 通过对抗让 $D_{00}$ 尽可能的越

大而  $G_{0G}$  尽可能的越小 (公式 (6)), 实现生成的影像接近高分辨率影像, 优化感知损失函数, 提

高生成器每次迭代的精度。公式如下所示:

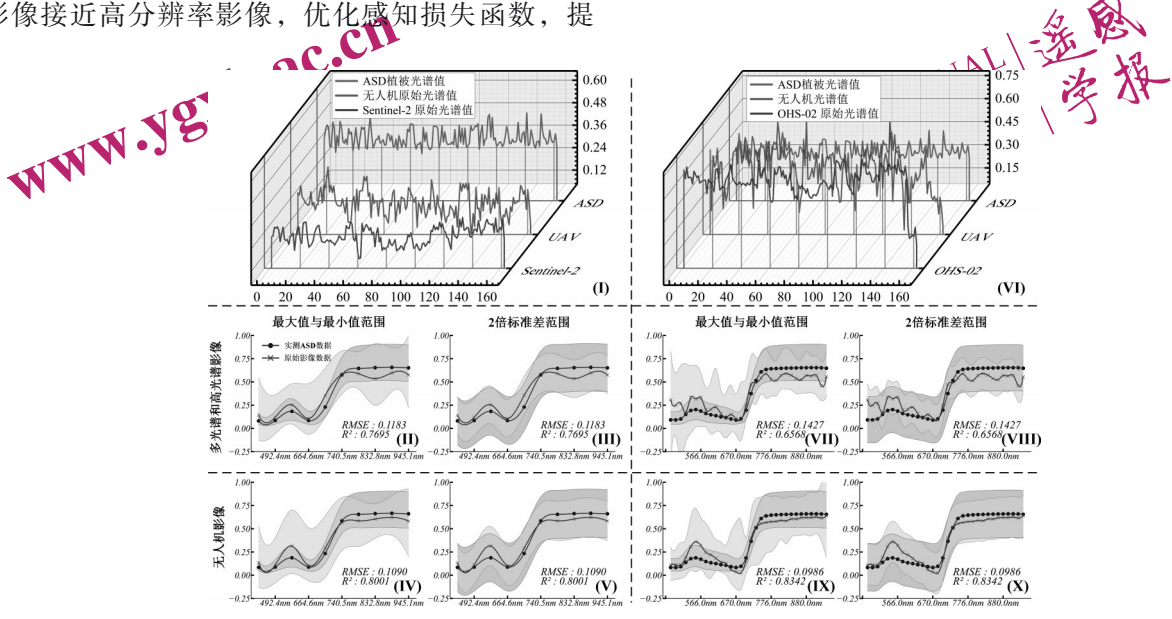


图3 基于ASD数据的无人机影像和星载影像映射前后光谱特征

Fig 3 Pre- and post-mapping spectral characteristics of UAV and satellite sensor based on ASD data

$$f_{SR} = F_{ESR}(f_{(H_{UAV}, W_{UAV}, scale)}, f_{(H_{Mixup}, W_{Mixup}, C)} + f_{(H_{multispec}, W_{multispec}, C)}) \quad (2)$$

$$l_{SR} = l_X^{SR} + 10^{-3} l_{Gen}^{SR} \quad (3)$$

$$L_{BCE} = -(y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)) \quad (4)$$

$$L_{MAE} = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \quad (5)$$

$$\min_{\theta G} \max_{\theta D} E_{f^{HR} \sim p_{min}(f^{HR})} [\log D_{\theta D}(f^{HR})] + E_{f^{LR} \sim p_c(f^{LR})} [\log(1 - D_{\theta D}(G_{\theta G}(f^{LR})))] \quad (6)$$

其中,  $f_{SR}$  是影像重建结果,  $f_{(H_{UAV}, W_{UAV}, C)}$  是无人机高分辨率的影像,  $f_{(H_{Mixup}, W_{Mixup}, C)}$  是通过 Mixup 数据增强后的影像,  $f_{(H_{multispec}, W_{multispec}, C)}$  是多光谱和高光谱原始影像,  $C$  是影像的波段数,  $y_i$  是超分辨率重建影像, 包括  $f_{(H_{UAV}, W_{UAV}, scale)}$ 、 $f_{(H_{Mixup}, W_{Mixup}, C)}$  和  $f_{(H_{multispec}, W_{multispec}, C)}$ ,  $\hat{y}_i$  是高分辨率影像,  $F_{ESR}$  是ESRGAN重建网络。

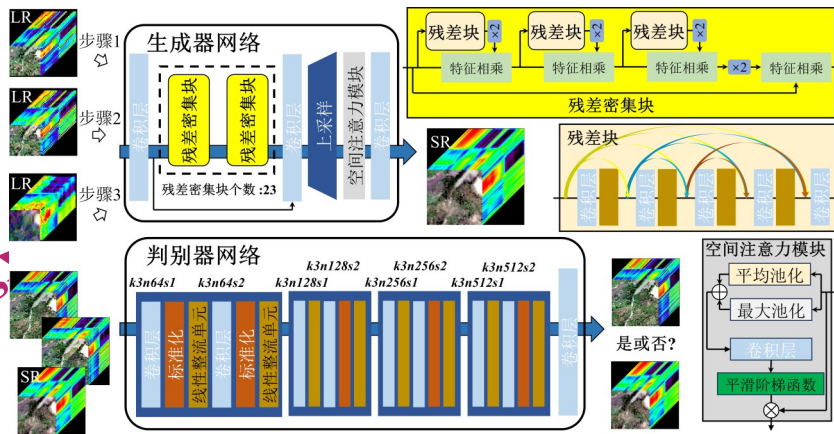


图4 CMIFM+ESRGAN超分辨率重建网络结构

Fig 4 Structure of CMIFM+ESRGAN super-resolution reconstruction network

3.2.2 卷积注意力网络 CMIFM+SwinIR 超分辨率重建方法

SwinIR (Liang 等, 2021) 整合了卷积网络和

Transformer的优势，使用Transformer的自注意力机制弥补了卷积神经网络中卷积核交互和模型对长距离学习的劣势。CMIFM+SwinIR的整体结构见图8所示，主要可以分为4个部分，通过CMIFM生成的影像数据集输入，浅层特征提取，深度特征提取和影像重建模块。本文选择使用3×3卷积模块作为影像的浅层特征提取层，使用子像素卷积方法作为影像重建的方法。损失函数选择MAELoss

(公式(5))。公式如下所示：

$$f_{SR} = F_{SwinIR} \left( f_{(H_{UAV}, W_{UAV}, C)}, f_{\left(\frac{H_{UAV}}{scale}, \frac{W_{UAV}}{scale}, C\right)} + f_{(H_{SwinIR}, W_{SwinIR}, C)} + f_{(H_{SwinIR}, W_{SwinIR}, C)} \right) \quad (7)$$

$$Feature = Conv(3 \times 3, \left( f_{\left(\frac{H_{UAV}}{scale}, \frac{W_{UAV}}{scale}, C\right)}, f_{(H_{SwinIR}, W_{SwinIR}, C)}, f_{(H_{SwinIR}, W_{SwinIR}, C)} \right)) \quad (8)$$

其中， $F_{SwinIR}$ 是SwinIR重建网络， $Feature$ 浅层特征的提取。

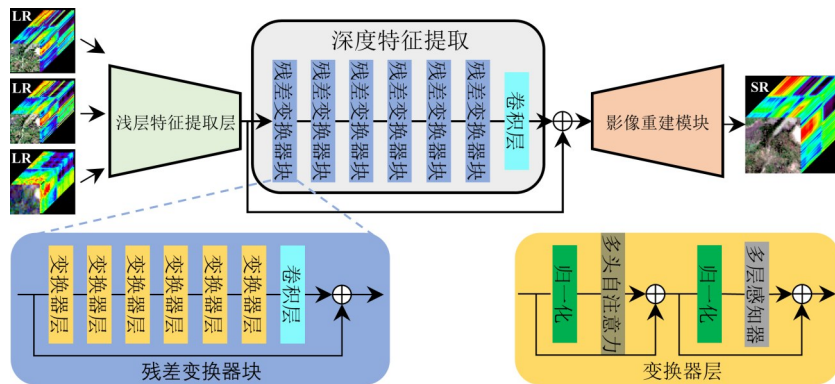


图5 CMIFM+SwinIR超分辨率重建网络结构

Fig. 5 Structure of CMIFM+SwinIR super-resolution reconstruction network

### 3.3 基于深度学习的DATFuse影像融合方法

DATFuse是一种目前最新的基于深度学习的端到端影像融合方法，模型主要由双注意剩余模块(DARM)和转换模块(TRM)组成(图6)，此外，由像素损失(公式11)、梯度损失(公式12)和结构损失(公式13)组成损失函数。虽然原文章已经验证在在相同传感器下DATFuse对红外单波段影像具有较好的融合效果。本文在保证模型架构不变的情况下，增加输入和输出端影像的通道数，同时将原文章浅层特征扩充通道由96增加到240。使用加权平均法从无人机高光谱影像中获取全色灰度影像，并和星载影像进行拼接，通过卷积处理后导入模型。

$$f_{SR} = F_{DATFuse} \left( f_{(H_{UAV}, W_{UAV}, C)}, f_{\left(\frac{H_{UAV}}{scale}, \frac{W_{UAV}}{scale}, C\right)} + f_{(H_{SwinIR}, W_{SwinIR}, C)} + f_{(H_{SwinIR}, W_{SwinIR}, C)} \right) \quad (9)$$

$$Loss = Loss_p + \lambda \cdot Loss_c + \gamma \cdot Loss_s \quad (10)$$

$$Loss_p = \frac{1}{HW} \| f_{Fusion} - f_{UAV-PAN} \|_F^2 + \alpha \cdot \frac{1}{HW} \| f_{Fusion} - f_{S2/OHS} \|_F^2 \quad (11)$$

$$Loss_c = \| \nabla f_{UAV-PAN} - \max \{ \nabla f_{UAV-PAN}, \nabla f_{S2/OHS} \} \|_2 \quad (12)$$

$$Loss_s = 1 - SSIM(f_{Fusion}, \max \{ f_{UAV-PAN}, f_{S2/OHS} \}) \quad (13)$$

其中， $\|\cdot\|_F$ 是弗罗贝尼乌斯范数， $\lambda$ 和 $\gamma$ 是损失函数的权重， $\alpha$ 是像素损失函数的权重文件， $\|\cdot\|_2$ 是L2范数。

### 3.4 超分辨率影像重建定量评价体系

#### 3.4.1 超分辨率影像重建方案设计

本文分别选取研究区内具有典型代表性的场景作为模型的训练区域和验证区域，同时选取没有无人机影像覆盖的区域用于进一步验证模型的性能。其中，训练区域约占无人机影像覆盖面积的80%，验证区域约占无人机影像覆盖面积的40%，训练和验证区域公共占有面积约占20%(见图7所示)。训练区域1处于农田和湿地植被交界处，训练区域2中主河道水体和块状水塘在研究区内具有典型代表，训练区域3包含较为丰富的水生湿地植被种群，训练区域4集中在块状水塘区域，训练区域5是浅水湿地植被集中区域。

由于Sentinel-2重采样后的影像空间分辨率与OHS-02影像一致，因此，本文选择根据星载多光谱重建影像的空谱精度作为参考，对比OHS-02星载高光谱重建影像在空间纹理特征细节上的提升幅度和光谱特征信息相对实测值的准确性，并根

据2种超分辨率重建方法和2种融合方法设计了14种影像重建方案(表2)。无人机影像拥有272个光谱波段,空间分辨率0.05米,光谱范围在400-1000nm。根据Sentinel-2影像光谱范围(442.3-943.2nm)选择10个范围接近的波段,OHS-02影像光谱范围(466.0-940.0nm)选择32个范围接近的波段。利用训练区域1-5栅格文件裁剪无人

机和星载影像,使用Bicubic方法将无人机影像重采样为1.25米(8倍)和2.5米(4倍),接着分别裁剪为 $C \times 128 \times 128$ ( $C$ 为波段数)和 $C \times 64 \times 64$ 两种尺寸,最后通过图像旋转、转置、Gamma变换等方法进行影像增强处理,裁剪总数 $1 \times 10^4$ ;星载影像裁剪为 $C \times 16 \times 16$ 尺寸,裁剪总数 $1 \times 10^4$ 。

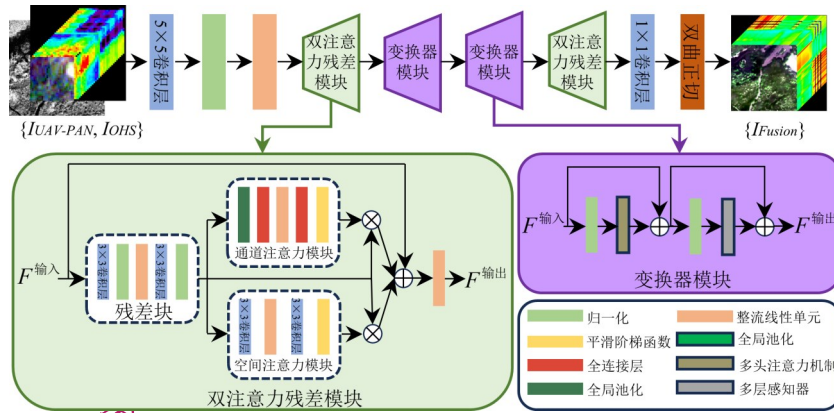


图6 DATFuse影像融合网络结构

Fig 6 Structure of DATFuse Image fusion network

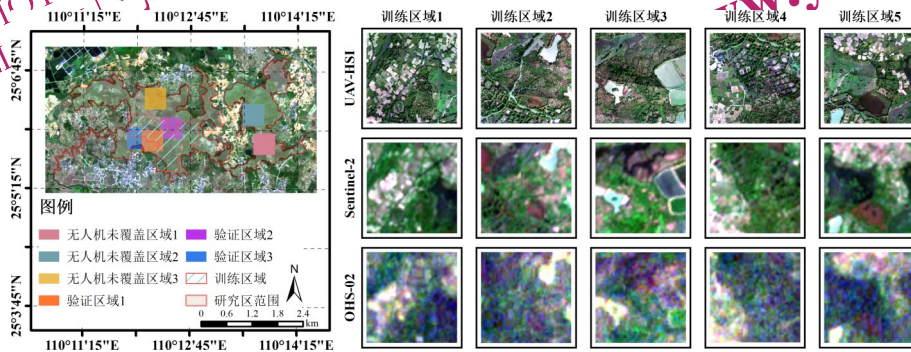


图7 研究区内无人机影像覆盖的区域(训练和验证区域)和未覆盖的区域

Fig 7 UAV images cover areas (training and validation areas) and un-covered in the study area.

### 3.4.2 湿地重建影像空谱质量定量分析

在空间重建质量的评估中,基于星载原始影像和无人机影像,计算星载重建影像(CMIFM+ESRGAN和CMIFM+SwinIR)和星载融合影像(DATFuse和GS)在不同尺度(4倍和8倍)下的峰值信噪比(PSNR)和结构相似性(SSIM)精度,分别定量评价超分辨率重建方法和融合方法对湿地遥感影像重建的空间质量, $MSE$ 的值接近零, $PSNR$ 值接近无穷大,表示影像越接近于原始影像的质量,反之, $PSNR$ 值接近零,表示影像间的差异越大, $PSNR$ 与SSIM的公式如下所示:

$$MSE(f, g) = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (f_{ij} - g_{ij})^2 \quad (14)$$

$$PSNR(f, g) = 10 * \log_{10} \left( \frac{255.0^2}{MSE(f, g)} \right) \quad (15)$$

其中“ $MN$ ”为影像的尺寸,“ $f$ ”是原始影像,“ $g$ ”是超分重建影像,“255.0”是指影像数据中的最大值,默认是8位无符号整数数据类型。

$$SSIM(f, g) = l(f, g)c(f, g)s(f, g) \quad (16)$$

其中, $l(f, g)$ 是亮度比较函数,用于测量两景影像的平均亮度; $c(f, g)$ 是对比度比较函数,用于测量两景影像对比度的接近度; $s(f, g)$ 用于测量两景影像之间的相关系数。



表2 超分辨率多光谱和高光谱影像重建方案

Table2 Super-resolution multispectral and hyperspectral image reconstruction schemes

| 重建和融合模型 | 重建影像       | 空间分辨率 | 光谱范围            | 无人机影像空间分辨率 | 放大尺度 | 无人机影像光谱范围       | 影像波段数 | 方案 |
|---------|------------|-------|-----------------|------------|------|-----------------|-------|----|
| CMIFM+  | Sentinel-2 | 10m   | 442.3 - 943.2nm | 1.25m      | 8    | 441.7 - 943.9nm | 10    | 1  |
|         |            |       |                 | 2.50m      | 4    |                 |       | 2  |
| SwinIR  | OHS-02     | 10m   | 466.0 - 940.0nm | 1.25m      | 8    | 466.1 - 937.2nm | 32    | 3  |
|         |            |       |                 | 2.50m      | 4    |                 |       | 4  |
| CMIFM+  | Sentinel-2 | 10m   | 442.3 - 943.2nm | 1.25m      | 8    | 441.7 - 943.9nm | 10    | 5  |
|         |            |       |                 | 2.50m      | 4    |                 |       | 6  |
| ESRGAN  | OHS-02     | 10m   | 466.0 - 940.0nm | 1.25m      | 8    | 466.1 - 937.2nm | 32    | 7  |
|         |            |       |                 | 2.50m      | 4    |                 |       | 8  |
| DATFuse | Sentinel-2 | 10m   | 442.3 - 943.2nm | 1.25m      | 8    | 441.7 - 943.9nm | 10    | 9  |
|         |            |       |                 | 2.50m      | 4    |                 |       | 10 |
|         | OHS-02     | 10m   | 466.0 - 940.0nm | 1.25m      | 8    | 466.1 - 937.2nm | 32    | 11 |
|         |            |       |                 | 2.50m      | 4    |                 |       | 12 |
| GS      | Sentinel-2 | 10m   | 442.3 - 943.2nm | 1.25m      | 8    | 441.7 - 943.9nm | 10    | 13 |
|         |            |       |                 | 2.50m      | 4    |                 |       | 14 |
|         | OHS-02     | 10m   | 466.0 - 940.0nm | 1.25m      | 8    | 466.1 - 937.2nm | 32    |    |

在光谱重建质量的评估中，通过 ArcGIS 10.7 Extract Values to Points 随机生成采样点，提取在星载原始影像和无人机影像上的光谱值，计算采样点在重建影像和融合影像中相同地理位置光谱值的RMSE和R<sup>2</sup>精度。通过RMSE和R<sup>2</sup>指标，评价影像重建后湿地植被和水体光谱特征和实测值之间的离散程度，RMSE和R<sup>2</sup>计算公式如下：

$$RMSE(f, g) = \sqrt{MSE(f, g)} \quad (17)$$

$$R(f, g)^2 = \frac{\sum_{i=1}^M \sum_{j=1}^N (\hat{f}_{ij} - f_{ij})^2}{\sum_{i=1}^M \sum_{j=1}^N (g_{ij} - f_{ij})^2} \quad (18)$$

其中“MN”为影像的尺寸，“f”是原始影像，“g”是重建影像，“f”是带入回归方程后“f”的估计值。

### 3.4.3 湿地植被群落和水体重建光谱质量精细分析

本文计算星载原始影像和重建影像的植被和水体指数（表3），包括BNDVI（Wang等，2007）、GNDVI（Yang等，2004）、NDVI、NLI（Pu等，2008）和PPR（Metternicht等，2003）共5种植被指数以及NDWI水体指数，并跟实测ASD数据（与重建影像相同光谱波段范围）计算得到的植被和水体指数进行数学拟合（其中，指数运算中蓝

波段、绿波段、红波段和近红外波段光谱范围分别为：492.4 - 500.0nm、550 - 559.8nm、664.6 - 670.0nm和832.8 - 836.0nm）。根据使用不同波段组合计算得到的对比结果，探讨在不同波段范围下，实测样本点在重建影像上是否表达了相同湿地植被群落或水体的光谱特征，从而分析在湿地场景中典型植被群落（狗牙根、华克拉莎和芒草）和水体重建结果的光谱稳定性。

$$BNDVI = \frac{NIR - Blue}{NIR + Blue} \quad (19)$$

$$GNDVI = \frac{NIR - Green}{NIR + Green} \quad (20)$$

$$NDVI = \frac{NIR - Red}{NIR + Red} \quad (21)$$

$$NLI = \frac{NIR^2 - Red}{NIR^2 + Red} \quad (22)$$

$$PPR = \frac{Green - Blue}{Green + Blue} \quad (23)$$

$$NDWI = \frac{Green - NIR}{Green + NIR} \quad (24)$$

## 4 结果分析

### 4.1 CMIFM+超分辨率影像重建结果定量分析

#### 4.1.1 CMIFM+超分辨率重建影像空间定量分析

表3展示了训练区域和验证区域范围内全部重建结果（影像区域）的平均空间质量指标

(*MPSNR* 和 *MSSIM*) 数值, 参考影像分别是星载原始影像 (Sentinel-2 和 OHS-02) 和无人机高光谱影像。在 Sentinel-2 重建影像中, *MPSNR* 和 *MSSIM* 值分别在 10.13 - 19.04 和 0.139 - 0.655 之间, 在 OHS-02 重建影像中, *MPSNR* 和 *MSSIM* 值分别在 8.07 - 14.49 和 0.016 - 0.542 之间, 这说明 Sentinel-2 重建影像的空间重建质量优于 OHS-02 重建影像。基于 CMIFM+ESRGAN 和 CMIFM+SwinIR 方法的

Sentinel-2 和 OHS-02 重建影像精度 (*MPSNR* 和 *MSSIM*) 高于传统融合影像 (GS) 精度, 低于 DATFuse 融合影像精度, 其中, 8 倍重建尺度的精度 (*PSNR*: 11.54 - 17.54, *SSIM*: 0.057 - 0.620) 高于 4 倍重建尺度的精度 (*PSNR*: 8.45 - 11.74, *SSIM*: 0.046 - 0.225)。综上所述, 重建影像的空间质量高于 GS 融合影像, 而低于 DATFuse 融合影像。

表3 重建影像的空间质量定量评价(*MPSNR* 和 *MSSIM*)

Table3 Quantitative evaluation of spatial quality of reconstructed images (*MPSNR*&*MSSIM*)

| 星载影像       | 精度指标         | 参考影像  | 重建影像         |       |              |       | 融合影像    |       |       |
|------------|--------------|-------|--------------|-------|--------------|-------|---------|-------|-------|
|            |              |       | CMIFM+ESRGAN |       | CMIFM+SwinIR |       | DATFuse |       | GS    |
|            |              |       | 4x           | 8x    | 4x           | 8x    | 4x      | 8x    | 8x    |
| Sentinel-2 | <i>MPSNR</i> | 原始影像  | 10.56        | 17.14 | 10.13        | 17.10 | 11.19   | 18.18 | 19.04 |
|            |              | 无人机影像 | 11.74        | 17.54 | 10.77        | 13.48 | 12.19   | 18.92 | 13.48 |
|            | <i>MSSIM</i> | 原始影像  | 0.225        | 0.620 | 0.219        | 0.588 | 0.256   | 0.642 | 0.603 |
|            |              | 无人机影像 | 0.171        | 0.508 | 0.139        | 0.379 | 0.177   | 0.655 | 0.540 |
| OHS-02     | <i>MPSNR</i> | 原始影像  | 8.45         | 13.10 | 8.82         | 13.86 | 8.07    | 14.49 | 9.88  |
|            |              | 无人机影像 | 9.97         | 11.71 | 9.87         | 11.54 | 9.68    | 14.71 | 11.30 |
|            | <i>MSSIM</i> | 原始影像  | 0.183        | 0.542 | 0.163        | 0.353 | 0.226   | 0.535 | 0.496 |
|            |              | 无人机影像 | 0.102        | 0.214 | 0.046        | 0.057 | 0.016   | 0.214 | 0.480 |

图9展示了 Sentinel-2 和 OHS-02 重建影像和融合影像在验证区域 1~3 中的可视化结果, 以及每个区域中融合和重建影像的逐波段平均 *PSNR* 和 *SSIM* 精度值。其中, “ORI-” 是指参考影像为星载原始影像, “UAV-” 是指参考影像为无人机影像。从视觉感知上分析, CMIFM+ESRGAN 和 CMIFM+SwinIR 重建影像中湿地植被群落和水体的边界特征细节均得到了明显增强, 特别是河道两旁的湿地植被纹理特征变得更加的精细, 例见图 8 中红色方框标记的验证区域 3。

重建影像与融合影像相比, DATFusae 和 GS 融合影像对水塘分布密集区域的纹理特征清晰度优于重建影像; 然而, 在无人机影像条带交界处, 融合影像存在色差, 这是由于无人机采集时受到云雾等天气影响出现的常见情况, 例如 OHS-02 重建影像的验证区域 3 (图 9 黑色方框标记处), 传统的融合方法会导致条带间相同湿地植被群落和水体的光谱特征不一致, 而基于 CMIFM 模块的超分辨率影像重建能够有效降低光谱差异现象的程度。

#### 4.1.2 CMIFM+超分辨率重建影像光谱定量分析

本文选择从无人机影像覆盖范围内随机选取 200 个样本点进行光谱特征值的提取。其中, 56 个样本点在验证区域, 146 个样本点在训练区域, 用于分析并讨论 CMIFM+ESRGAN 和 CMIFM+SwinIR 重建方法与 DATFuse 和 GS 融合方法在湿地场景中对 Sentinel-2 和 OHS-02 影像中地物光谱的重建性能 (如图 10 和图 11 所示)。坐标图中的横轴表示标准影像 (原始影像和无人机影像) 的光谱值, 纵轴表示重建影像的光谱值, 绘制 1: 1 的拟合回归曲线, 当坐标点的颜色越接近红色, 重建影像和标准影像的光谱值的分布越密集, 当颜色越接近蓝色光谱值分布越离散。

在 Sentinel-2 影像中 (图 10), 基于 CMIFM 模型的超分辨率重建影像 (图 I 到图 VIII) 的 *RMSE* 和 *R<sup>2</sup>* 精度范围分别是 0.1187 - 0.1357 和 0.5497 - 0.6369, 平均精度低于 DATFuse 和 GS 融合影像 (图 i 到图 n) (*RMSE*: 0.0998 - 0.1482, *R<sup>2</sup>*: 0.6042 - 0.8234)。Sentinel-2 重建影像和融合影像的地物光谱值, 对比无人机影像更加接近于原始影像。根据原始影像计算的 DATFuse 和 GS 融合影像

$RMSE$  和  $R^2$  精度，远远高于根据无人机影像计算的  $RMSE$  和  $R^2$  精度 ( $RMSE$  和  $R^2$  最大差值分别是 0.0503 和 0.2221)，然而，重建影像中原始影像的  $RMSE$  和  $R^2$  精度相对更为接近无人机影像。

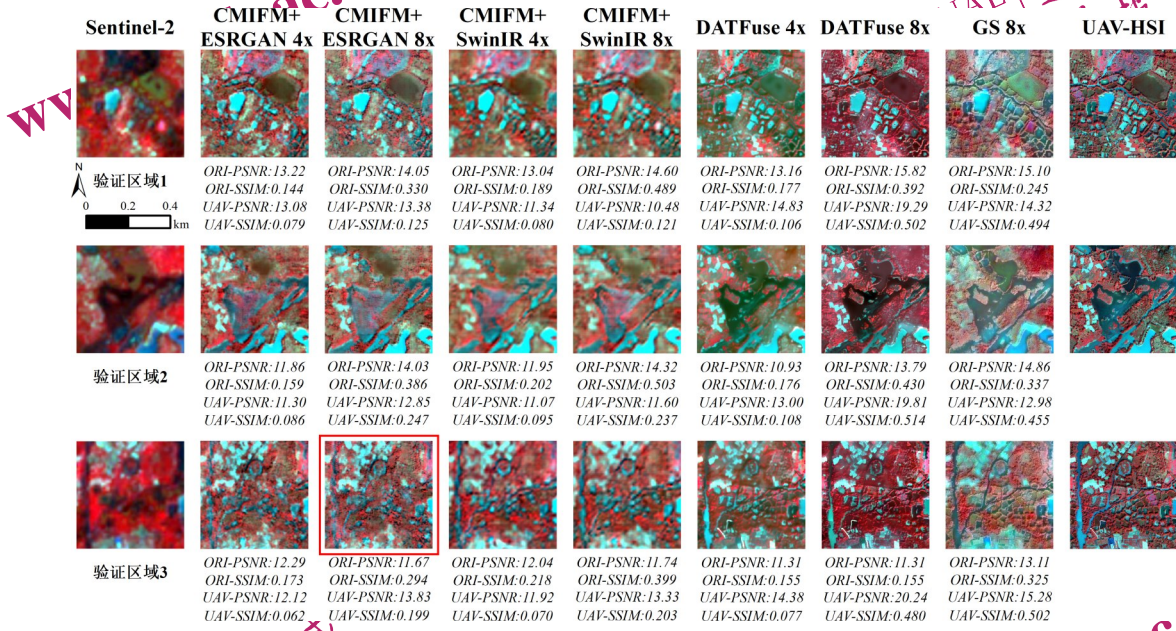


图8 Sentinel-2重建影像在验证区域的可视化结果

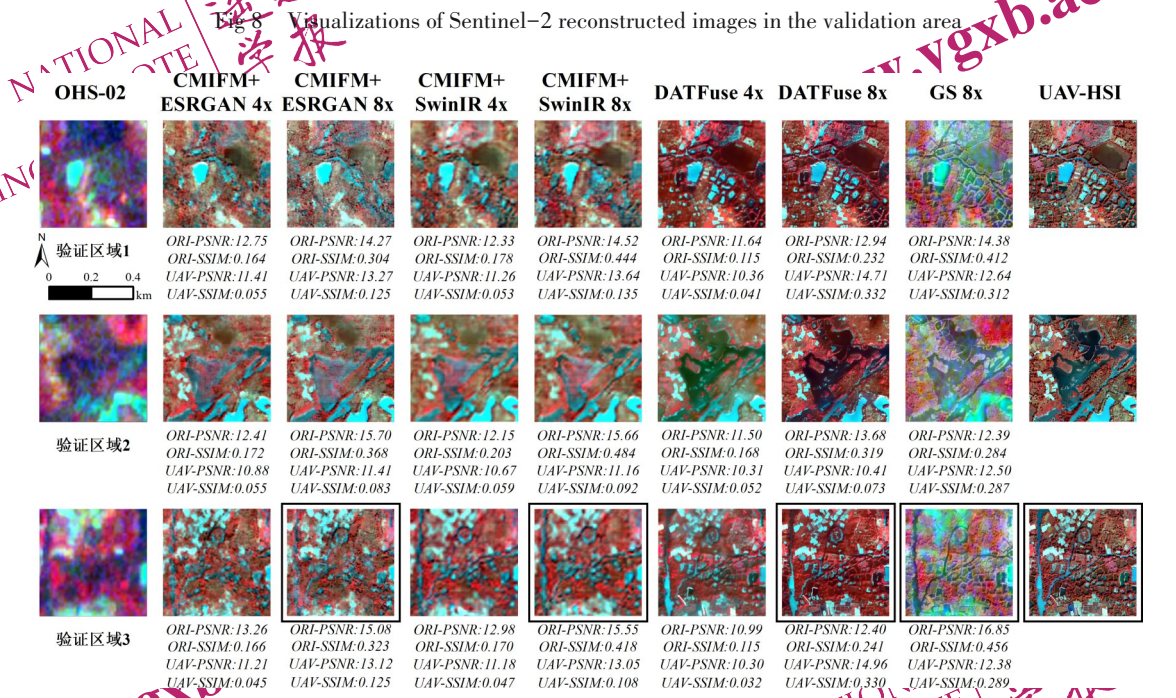


图9 OHS-02重建影像在验证区域的可视化结果

Figure 9 Visualizations of OHS-02 reconstructed images in the validation area

在 OHS-02 影像中 (图 11)，光谱波段数增加到 32 个，坐标点的个数增加到 6400 个 (32 个波段，每个波段 200 个样本点)，然而，OHS-02 重建影像和融合影像的  $RMSE$  和  $R^2$  精度低于 Sentinel-2 影像。其中，DATFuse 融合影像的  $RMSE$  和  $R^2$  精度降低幅度最高，CMIFM+ESRGAN 和 CMIFM+

SwinIR 重建影像的  $RMSE$  和  $R^2$  精度分别在 0.1263 - 0.1575 和 0.1293 - 0.3797 之间。这说明，基于 CMIFM+ESRGAN 和 CMIFM+SwinIR 的高光谱重建影像较好的还原了原始影像和无人机影像的地物光谱值，且在能够更好的将 Sentinel-2 多光谱和 OHS-02 高光谱影像跟无人机影像的光谱特征

整合。

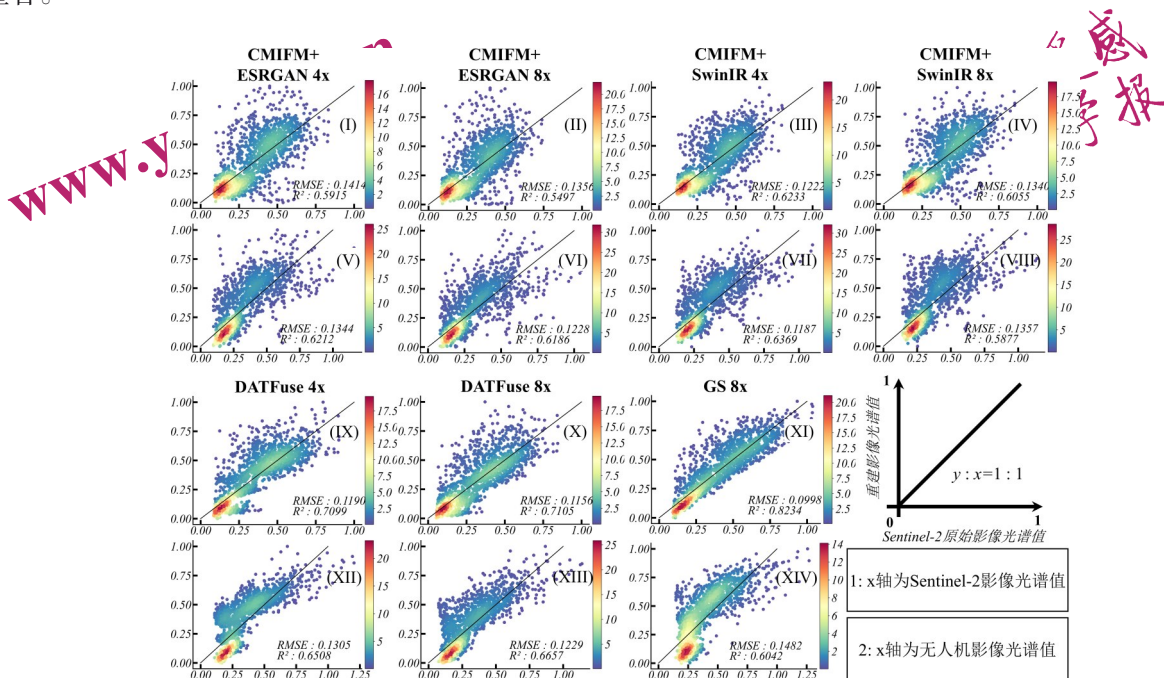


图 10 Sentinel-2 多光谱重建影像的光谱特征

Fig 10 Spectral characteristics of Sentinel-2 multi-spectral reconstruction images

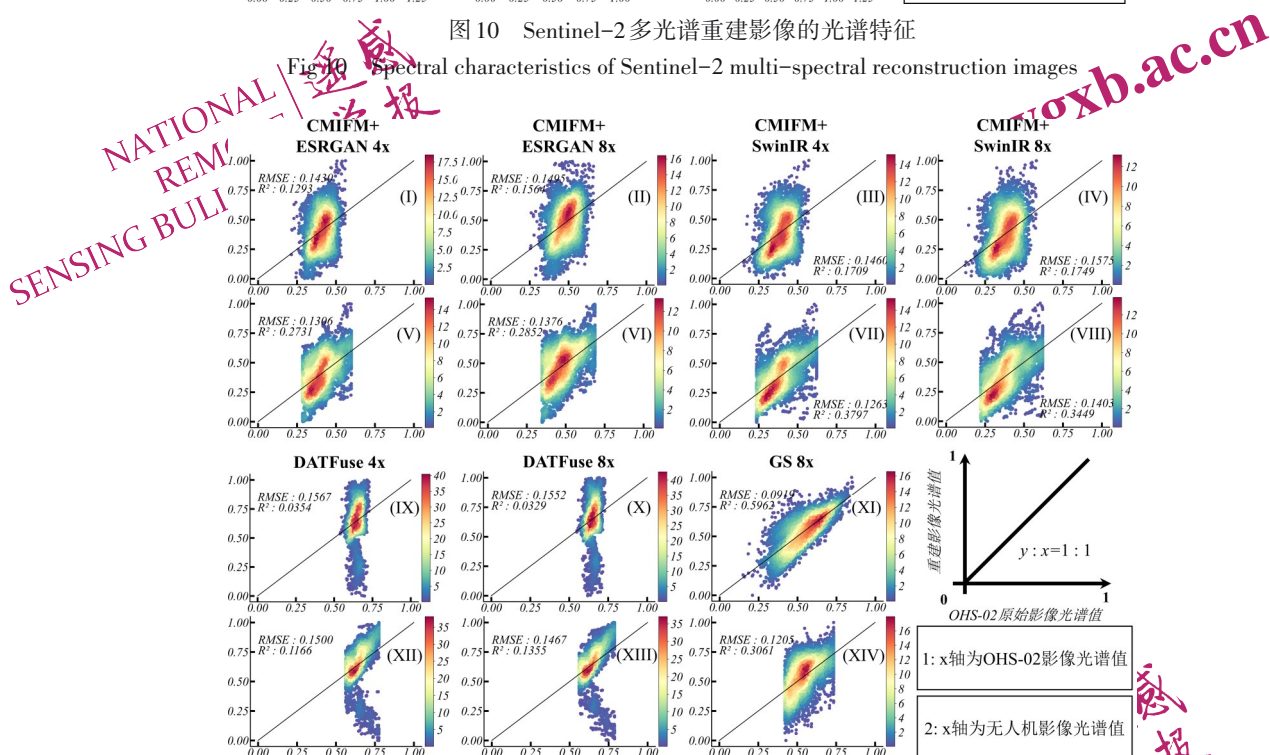


图 11 OHS-02 高光谱重建影像的光谱特征

Fig 11 Spectral characteristics of OHS-02 hyper-spectral reconstruction images

#### 4.2 CMIFM+超分辨率重建影像泛化性评价

本文进一步利用 CMIFM+ESRGAN 和 CMIFM+SwinIR 在训练区域（无人机覆盖区域）的权重，对研究区内无人机影像无法覆盖的 Sentinel-2 和 OHS-02 影像区域进行重建。选择具有典型代表地物的 3 个区域作为定性定量的研究对象，分别计算

每个区域重建影像的空间质量（PSNR 和 SSIM），并分别在 3 个区域中随机生成 200 个样本点，统计其光谱特征，绘制原始影像和重建影像的拟合 1:1 回归曲线。在 Sentinel-2 重建影像中（图 12），从视觉感知角度分析，水塘和植被交界处的纹理特征得到明显的提升，然而，存在部分水体光谱重

建失真的现象，空谱质量的精度数值范围和无人机覆盖区域内的精度数值范围一致，平均 *PSNR* (*MPSNR*) 和 *SSIM* (*MSSIM*) 分别为 13.58 和

0.3104，平均 *RMSE* (*MRMSE*) 和  $R^2$  ( $MR^2$ ) 分别为 0.1406 和 0.6662。

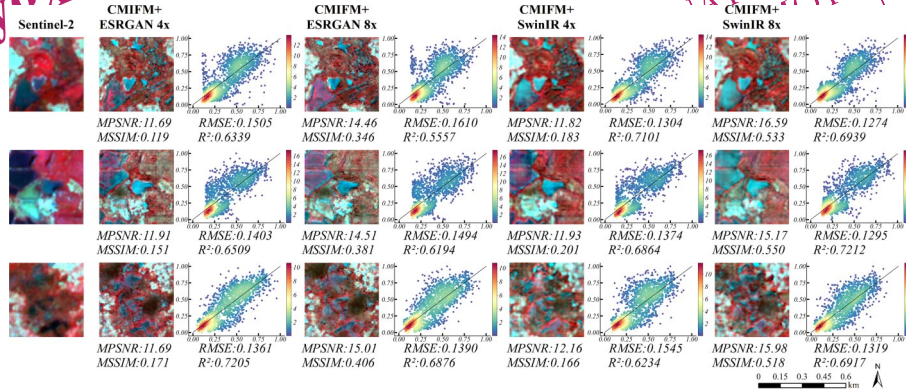


图 12 Sentinel-2 重建影像在无人机未覆盖区域的重建质量定量分析

Fig 12 Quantitative analysis of Sentinel-2 reconstructed images in areas not covered by UAV

在 OHS-02 重建影像中 (图 13)，从视觉感知角度分析，CMIFM+SwinIR 重建影像相对 CMIFM+ESRGAN 重建影像的噪声较少，主要集中在大范围水体表面以及连续的湿地植被群落密集区域，平均 *MPSNR* 和 *MSSIM* 精度数值分别为 12.75 和 0.2637，*MRMSE* 和  $MR^2$  精度数值分别为 0.1648

和 0.1897，空谱质量的精度数值范围和无人机覆盖区域内的精度数值范围一致。这说明 CMIFM+超分辨率重建方法能够在具有相同地物特征的不同区域中，实现对星载影像中湿地植被和水体的重建处理，表明该方法具有一定的泛化能力。

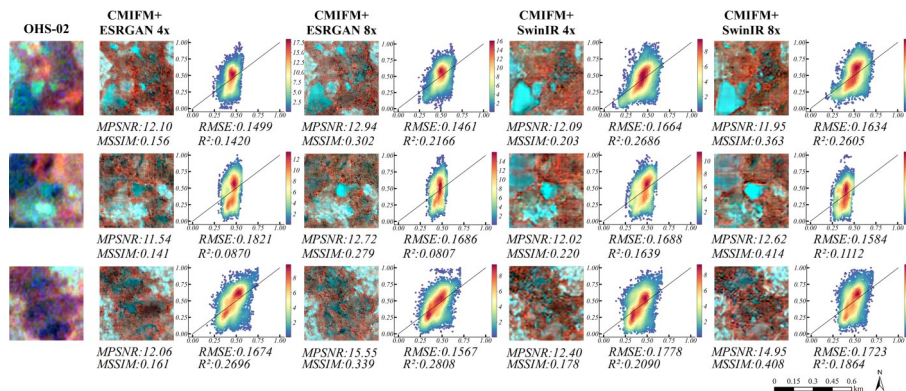


图 13 OHS-02 重建影像在无人机未覆盖区域的重建质量定量分析

Fig 13 Quantitative analysis of OHS-02 reconstructed images in areas not covered by UAV

### 4.3 岩溶湿地植被群落重建结果

#### 4.3.1 湿地植被光谱重建稳定性定量分析

表 4 展示了基于星载 (Sentinel-2 和 OHS-02) 空间分辨率在 8 倍提升幅度下的重建影像和融合影像计算的 5 种植被指数 (BNDVI、GNDVI、NDVI、NLI 和 PPR) 与实测 ASD 数据在狗牙根群落中的数学拟合结果。本文将原始影像和无人机影像的植被指数计算结果值作为参考值，对重建指数值进

行定量分析。CMIFM+ESRGAN 和 CMIFM+SwinIR 重建影像的 *RMSE* 和  $R^2$  拟合精度的范围分别在 0.1536 - 0.2986 和 0.0655 - 0.5933 之间，精度的平均值分别为 0.2405 和 0.3333，低于 DATFuse 融合影像的精度平均值 (*RMSE*: 0.2298,  $R^2$ : 0.4497)，高于 GS 融合影像的精度平均值 (*RMSE*: 0.2418,  $R^2$ : 0.2636)。

在 NDVI 植被指数中，OHS-02 原始影像和 ASD 之间的  $R^2$  (0.4109) 以及无人机影像和 ASD 之

间的  $R^2$  (0.6571) 较高, CMIFM+重建影像和 ASD 之间的  $R^2$  精度高于 GS 融合影像。接近 DATFuse 融合影像, 在 NLI 植被指数中, OHS-02 原始影像和无人机影像的  $R^2$  (0.2892 和 0.1271) 较低,

CMIFM+ESRGAN 重建影像和 ASD 之间的  $R^2$  精度高于 DATFuse 和 GS 融合影像。这说明基于 CMIFM 模块的超分辨率影像重建方法在单一湿地植被群落的不同植被指数间具有稳定性。

表 4 重建影像中狗牙根的植被指数与实测 ASD 数据的拟合精度

Table 4 The accuracy of vegetation index of *Cynodon-dactylon* in reconstructed images

| 湿地植被   | 特征指数  | 重建影像       | 精度指标   | 原始影像   | 无人机影像  | CMIFM+ESRGAN | CMIFM+SwinIR | DATFuse | GS     |
|--------|-------|------------|--------|--------|--------|--------------|--------------|---------|--------|
| 湿地植被   | BNDVI | Sentinel-2 | RMSE   | 0.2672 | 0.2245 | 0.2591       | 0.2662       | 0.2636  | 0.2486 |
|        |       |            | $R^2$  | 0.2344 | 0.5527 | 0.1847       | 0.2921       | 0.3616  | 0.3339 |
|        |       | OHS-02     | RMSE   | 0.2571 | 0.2296 | 0.2710       | 0.2727       | 0.2433  | 0.2138 |
|        |       |            | $R^2$  | 0.3750 | 0.5612 | 0.1969       | 0.1649       | 0.4751  | 0.1931 |
|        |       | Sentinel-2 | RMSE   | 0.2881 | 0.2022 | 0.2719       | 0.2737       | 0.2490  | 0.2847 |
|        |       |            | $R^2$  | 0.1549 | 0.7389 | 0.4035       | 0.3456       | 0.5480  | 0.2911 |
| OHS-02 | RMSE  | 0.2058     | 0.2298 | 0.2957 | 0.2960 | 0.2408       | 0.2938       |         |        |
|        | $R^2$ | 0.1821     | 0.6293 | 0.1652 | 0.1576 | 0.5958       | 0.1966       |         |        |
| 狗牙根    | NDVI  | Sentinel-2 | RMSE   | 0.2487 | 0.2022 | 0.2391       | 0.2094       | 0.2290  | 0.2094 |
|        |       |            | $R^2$  | 0.1449 | 0.5937 | 0.3082       | 0.5528       | 0.4788  | 0.5528 |
|        |       | OHS-02     | RMSE   | 0.1869 | 0.1943 | 0.1536       | 0.1631       | 0.2104  | 0.2567 |
|        |       |            | $R^2$  | 0.4109 | 0.6571 | 0.5892       | 0.5539       | 0.5793  | 0.1439 |
|        |       | Sentinel-2 | RMSE   | 0.1808 | 0.1936 | 0.1910       | 0.2387       | 0.1927  | 0.1622 |
|        |       |            | $R^2$  | 0.2816 | 0.5721 | 0.2729       | 0.2696       | 0.2418  | 0.4529 |
| OHS-02 | RMSE  | 0.1834     | 0.1827 | 0.1556 | 0.1634 | 0.1824       | 0.1919       |         |        |
|        | $R^2$ | 0.4253     | 0.3131 | 0.5328 | 0.4732 | 0.3180       | 0.1582       |         |        |
| NLI    | PPR   | Sentinel-2 | RMSE   | 0.2615 | 0.2971 | 0.2386       | 0.2826       | 0.2144  | 0.2858 |
|        |       |            | $R^2$  | 0.4004 | 0.2385 | 0.5933       | 0.2957       | 0.6904  | 0.1690 |
|        |       | OHS-02     | RMSE   | 0.2880 | 0.2717 | 0.2702       | 0.2986       | 0.2728  | 0.2711 |
|        |       |            | $R^2$  | 0.2892 | 0.1271 | 0.2478       | 0.0655       | 0.2078  | 0.1446 |

表 5 展示了 5 种植被指数与实测 ASD 数据在华克拉莎群落中的数学拟合结果。华克拉莎在原始影像中的  $RMSE$  和  $R^2$  精度的范围分别是 0.1994 - 0.2786 和 0.0725 - 0.6012, CMIFM+ 重建影像的  $RMSE$  和  $R^2$  精度的范围分别是 0.1929 - 0.2816 和 0.1103 - 0.4522, 融合影像的  $RMSE$  和  $R^2$  精度的范围分别是 0.2014 - 0.2783 和 0.0208 - 0.5536, 华克拉莎在 CMIFM+ 重建影像上的  $RMSE$  和  $R^2$  精度低于狗牙根 ( $RMSE$ : 0.1536 - 0.2986,  $R^2$ : 0.0655 - 0.5933)。

表 6 展示了 5 种植被指数与实测 ASD 数据在芒草群落中的数学拟合结果。芒草在原始影像中的  $RMSE$  和  $R^2$  精度的范围分别为 0.1994 - 0.2786 和 0.0725 - 0.6012, CMIFM+ 重建影像的  $RMSE$  和  $R^2$  精度的范围分别为 0.1929 - 0.2816 和 0.1103 -

0.4522, 融合重建影像的  $RMSE$  和  $R^2$  精度的范围分别为 0.2014 - 0.2783 和 0.0208 - 0.5536。芒草在 CMIFM+ 重建影像上的  $RMSE$  和  $R^2$  精度低于狗牙根, 接近华克拉莎。

由于不同湿地植被群落采集的实测点数不同, 在 CMIFM 模块中用于构建影像间映射关系的狗牙根、华克拉莎和芒草样本点数存在差异, 因此, 本文进一步研究在 CMIFM 模块中, 随着湿地植被样本点数的提升, 能否提升植被指数在不同植被群落上稳定性。在表 1 中可知, 狗牙根在训练区域内样本点数 (16) 与总样本点数 (22) 比例约为 72.72%, 华克拉莎的比例约为 43.48% (训练区: 10, 总点数: 23), 芒草的比例约为 50% (训练区: 13, 总点数: 26)。

表5 重建影像中华克拉莎的植被指数与实测ASD数据的拟合精度

Table.5 The accuracy of vegetation index of *Cladium-chinense*-*Nees* in reconstructed images

| 湿地<br>植被 | 特征<br>指数 | 重建影像       | 精度<br>指标   | 原始影像   | 无人机影<br>像 | CMIFM+<br>ESRGAN | CMIFM+<br>SwimR | DATAFuse | GS     |        |
|----------|----------|------------|------------|--------|-----------|------------------|-----------------|----------|--------|--------|
| 华克拉莎     | BNDVI    | Sentinel-2 | RMSE       | 0.2152 | 0.2105    | 0.2402           | 0.2091          | 0.2413   | 0.2151 |        |
|          |          |            | $R^2$      | 0.1452 | 0.0749    | 0.1367           | 0.1390          | 0.1003   | 0.1472 |        |
|          |          | OHS-02     | RMSE       | 0.2112 | 0.2221    | 0.2174           | 0.2297          | 0.2484   | 0.2483 |        |
|          |          |            | $R^2$      | 0.3314 | 0.1216    | 0.2345           | 0.4467          | 0.0961   | 0.1014 |        |
|          |          | GNDVI      | Sentinel-2 | RMSE   | 0.2786    | 0.2629           | 0.2499          | 0.2603   | 0.2783 | 0.2749 |
|          |          |            |            | $R^2$  | 0.0725    | 0.1391           | 0.2072          | 0.1652   | 0.0830 | 0.1758 |
|          | OHS-02   |            | RMSE       | 0.2312 | 0.2174    | 0.2452           | 0.2539          | 0.2692   | 0.2560 |        |
|          |          |            | $R^2$      | 0.5272 | 0.6012    | 0.3946           | 0.3078          | 0.1850   | 0.2816 |        |
|          | NDVI     | Sentinel-2 | RMSE       | 0.2098 | 0.2233    | 0.1929           | 0.1981          | 0.2304   | 0.2330 |        |
|          |          |            | $R^2$      | 0.1425 | 0.3454    | 0.2611           | 0.1323          | 0.1821   | 0.1064 |        |
|          |          | OHS-02     | RMSE       | 0.2013 | 0.2109    | 0.2303           | 0.2409          | 0.2495   | 0.2014 |        |
|          |          |            | $R^2$      | 0.3043 | 0.5456    | 0.1181           | 0.4225          | 0.3448   | 0.3026 |        |
|          | NLI      | Sentinel-2 | RMSE       | 0.1999 | 0.2102    | 0.2094           | 0.1999          | 0.2099   | 0.2110 |        |
|          |          |            | $R^2$      | 0.1099 | 0.0911    | 0.1249           | 0.1103          | 0.1029   | 0.1111 |        |
|          |          | OHS-02     | RMSE       | 0.1994 | 0.2197    | 0.2406           | 0.2343          | 0.2149   | 0.2049 |        |
|          |          |            | $R^2$      | 0.3257 | 0.5248    | 0.1686           | 0.4194          | 0.5536   | 0.2371 |        |
|          | PPR      | Sentinel-2 | RMSE       | 0.2732 | 0.2030    | 0.2816           | 0.2443          | 0.2632   | 0.2443 |        |
|          |          |            | $R^2$      | 0.3588 | 0.4316    | 0.2700           | 0.4522          | 0.2783   | 0.2593 |        |
| OHS-02   |          | RMSE       | 0.2389     | 0.2673 | 0.2486    | 0.2531           | 0.2014          | 0.2511   |        |        |
|          |          | $R^2$      | 0.3484     | 0.1154 | 0.2192    | 0.1144           | 0.0208          | 0.1700   |        |        |

在OHS-02原始影像中，狗牙根5种植被指数的平均 $RMSE$ 和 $R^2$ 精度分别为0.2242和0.3970（表5）；华克拉莎的平均 $RMSE$ 和 $R^2$ 精度分别为0.2164和0.3674（表6）；芒草的平均 $RMSE$ 和 $R^2$ 精度分别为0.1714和0.5241。可以看到，狗牙根、华克拉莎和芒草3种湿地植被之间具有相近的精度。在OHS-02重建影像中，狗牙根，华克拉莎和芒草的5种植被指数平均 $RMSE$ 精度分别是0.2340，0.2394和0.1832，平均 $R^2$ 精度分别是0.3255，0.2846和0.4596。狗牙根、华克拉莎和芒草3种湿地植被在影像重建前后的精度均符合芒草>狗牙根>华克拉莎，这说明，基于CMIFM模块的超分辨率影像重建方法在相同植被指数的不同湿地植被群落间同样具有稳定性。

#### 4.3.2 湿地植被光谱重建保真性定量分析

图14展示了狗牙根，华克拉莎和芒草3种湿地植被的重建光谱值和实测ASD数据在442.7 - 943.9nm光谱范围内，波段的平均 $RMSE$

( $MRMSE$ )和 $R^2$ ( $MR^2$ )精度。在图3中，Sentinel-2原始影像中湿地植被的 $MRMSE$ 和 $MR^2$ 精度分别为0.1183和0.7695之间，OHS-02原始影像中湿地植被的 $MRMSE$ 和 $MR^2$ 精度分别为0.1427和0.6568之间。CMIFM+重建影像中湿地植被的 $MRMSE$ 和 $MR^2$ 精度范围分别为0.0436 - 0.1251和0.7538 - 0.9747，3种湿地植被的 $MRMSE$ 和 $MR^2$ 均高于在原始影像，DATAFuse和GS融合影像中的精度值。这说明，CMIFM+重建影像中湿地植被相对实测ASD数据的光谱保真性高于DATAFuse和GS融合影像。

#### 4.4 湿地水体重建结果

##### 4.4.1 湿地水体光谱重建稳定性定量分析

作为湿地场景中重要的组成因素。本文创新性的对CMIFM+重建影像中会仙岩溶湿地水体的光谱信息做进一步的定量分析。表7展示了基于实测水体ASD数据计算和基于影像计算的NDVI和NDWI指数的拟合精度。Sentinel-2和OHS-02原始

影像以及无人机影像的  $RMSE$  精度在 0.1983 - 0.2349 之间,  $R^2$  精度在 0.093 - 0.2269 之间, CMIFM+重建影像的平均  $RMSE$  和  $R^2$  精度分别为 0.2211 和 0.1245。在原始影像和无人机影像的精度

区内, 高于 DATFuse 和 GS 融合影像的平均  $R^2$  精度 (0.1023)。CMIFM+影像重建方法在水体的光谱重建中具有一定的稳定性。

表 6 重建影像中芒草的植被指数与实测 ASD 数据的拟合精度

Table.6 The accuracy of vegetation index of *Miscanthus* in reconstructed images

| 湿地植被 | 特征指数       | 重建影像       | 精度指标   | 原始影像   | 无人机影像  | CMIFM+ESRGAN | CMIFM+SwinIR | DATFuse | GS     |
|------|------------|------------|--------|--------|--------|--------------|--------------|---------|--------|
| 芒草   | BNDVI      | Sentinel-2 | $RMSE$ | 0.1928 | 0.1974 | 0.2066       | 0.1946       | 0.1912  | 0.2227 |
|      |            |            | $R^2$  | 0.2174 | 0.2052 | 0.2752       | 0.3919       | 0.3180  | 0.1218 |
|      |            | OHS-02     | $RMSE$ | 0.1465 | 0.1896 | 0.1412       | 0.1936       | 0.1840  | 0.1743 |
|      |            |            | $R^2$  | 0.6498 | 0.1977 | 0.6807       | 0.2713       | 0.3089  | 0.4264 |
|      | GNDVI      | Sentinel-2 | $RMSE$ | 0.2430 | 0.2440 | 0.2353       | 0.2242       | 0.2363  | 0.2419 |
|      |            |            | $R^2$  | 0.2319 | 0.1944 | 0.2494       | 0.4327       | 0.2325  | 0.2330 |
|      |            | OHS-02     | $RMSE$ | 0.1968 | 0.2641 | 0.1627       | 0.2240       | 0.2484  | 0.2108 |
|      |            |            | $R^2$  | 0.4747 | 0.1661 | 0.6653       | 0.4548       | 0.1557  | 0.3334 |
|      | NDVI       | Sentinel-2 | $RMSE$ | 0.1850 | 0.1760 | 0.2143       | 0.2042       | 0.1869  | 0.2075 |
|      |            |            | $R^2$  | 0.0713 | 0.3612 | 0.1589       | 0.2671       | 0.3482  | 0.1838 |
|      |            | OHS-02     | $RMSE$ | 0.1456 | 0.2136 | 0.1491       | 0.1953       | 0.2206  | 0.1581 |
|      |            |            | $R^2$  | 0.6248 | 0.1963 | 0.6003       | 0.3776       | 0.1740  | 0.5301 |
| NDWI | Sentinel-2 | $RMSE$     | 0.2019 | 0.2000 | 0.2115 | 0.2302       | 0.1985       | 0.2315  |        |
|      |            | $R^2$      | 0.1672 | 0.2131 | 0.1551 | 0.3637       | 0.2459       | 0.1506  |        |
|      | OHS-02     | $RMSE$     | 0.1567 | 0.2098 | 0.1753 | 0.2155       | 0.2135       | 0.1799  |        |
|      |            | $R^2$      | 0.6473 | 0.0839 | 0.5783 | 0.3846       | 0.1094       | 0.5199  |        |
| PPR  | Sentinel-2 | $RMSE$     | 0.1976 | 0.2177 | 0.2117 | 0.2042       | 0.2172       | 0.2256  |        |
|      |            | $R^2$      | 0.0975 | 0.1255 | 0.2618 | 0.2025       | 0.1404       | 0.0314  |        |
|      | OHS-02     | $RMSE$     | 0.2113 | 0.1935 | 0.1793 | 0.1957       | 0.2147       | 0.2003  |        |
|      |            | $R^2$      | 0.2240 | 0.2149 | 0.4253 | 0.1575       | 0.1538       | 0.0352  |        |

图 15 和图 16 分别展示了 Sentinel-2 和 OHS-02 重建影像的 NDVI 和 NDWI 指数计算结果。在图 15 中, 从视觉感知上分析, 在真彩色展示中, CMIFM+重建影像的色调接近无人机影像, DATFuse 融合影像的色调偏暗色, GS 融合影像中部分区域水体的色调偏向暗色调, 且基于 GS 方法的 OHS-02 融合影像中不同区域的水体色调存在差异。在 NDVI 展示中, DATFuse 和 GS 影像计算结果的水体边界模糊, CMIFM+ESRGAN 计算结果的水体边界纹理细节最好。

在图 15 中, 从视觉感知上分析, 在假彩色展示中, CMIFM+ESRGAN 在 Sentinel-2 影像中的色调最接近无人机影像, 然而, 在 OHS-02 影像中会存在噪点, 基于 DATFuse 方法的 OHS-02 融合影像中水体的色调出现偏差。在 NDWI 展示中, OHS-

02 原始影像中水体的边界信息是无法获取的, 而在重建影像和融合影像中能够清晰的识别水体, CMIFM+重建影像在块状水体密集区的 NDWI 数值范围 (NDWI 数值更加接近 1) 相对比融合影像更加接近无人机。

#### 4.4.2 湿地水体光谱重建保真性定量分析

图 17 展示了在 CMIFM+重建影像中, 实测 ASD 数据和影像中水体光谱值的拟合精度 ( $RMSE$  和  $R^2$ ), 其中,  $MRMSE$  和  $MR^2$  是指逐波段的平均拟合精度。在 Sentinel-2 和 OHS-02 影像中, 无人机影像和 ASD 数据的拟合精度高于原始影像, 融合影像和重建影像的拟合精度高于原始影像低于无人机影像, CMIFM+ESRGAN 和 CMIFM+SwinIR 重建影像的  $RMSE$  和  $R^2$  精度 ( $MRMSE$ : 0.0147 -



0.0170,  $MR^2$ : 0.6066 - 0.6457) 高于原始 DATFuse 和 GS 融合影像 ( $MRMSE$ : 0.0185 - 0.0234,  $MR^2$ : 0.2071 - 0.4863)。在 500nm 到 670nm 光谱波段范围内, 原始影像中水体的光谱变化规律和 ASD 数据存在明显的差异, 虽然这个差异在重建影像和融合影像中依然存在, 然而, 从光谱平均值的 2 倍标准差范围可以看到, CMIFM+重建影像较好的整

合了无人机影像的光谱特征。因此, 基于 CMIFM 模块的超分辨率影像重建方法在对 Sentinel-2 和 OHS-02 影像重建时, 湿地水体的光谱重建值在稳定性和保真性方面优于 DATFuse 和 GS 融合方法, 然而, 在 CMIFM+重建影像中, 湿地水体光谱重建值和 ASD 数据的稳定性和保真性低于湿地植被。

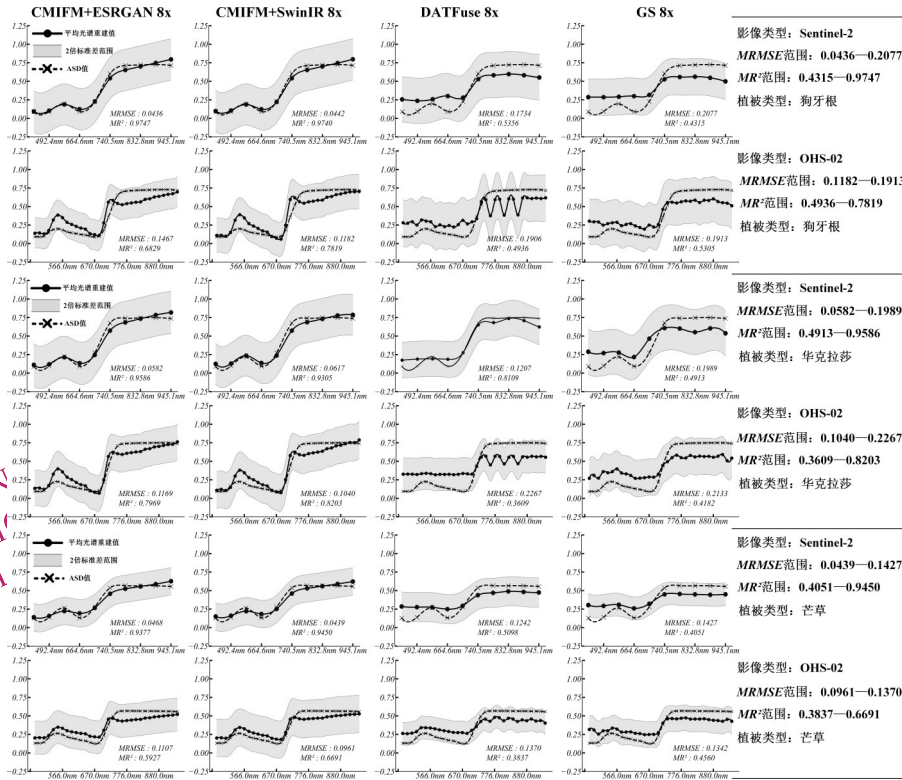


图 14 3 种典型湿地植被的光谱特征重建曲线

Fig 14 Three typical wetland vegetation spectral characteristics of reconstruction curves

表 7 重建影像中 NDVI 和 NDWI 指数与实测 ASD 数据的拟合精度

Table.7 The accuracy of NDVI and NDWI index in reconstructed images

| 地物类型 | 特征指数       | 重建影像       | 精度指标   | 原始影像   | 无人机影像  | CMIFM+ESRGAN | CMIFM+SwinIR | DATFuse | GS     |
|------|------------|------------|--------|--------|--------|--------------|--------------|---------|--------|
| 水体   | NDVI       | Sentinel-2 | RMSE   | 0.1983 | 0.2265 | 0.2421       | 0.2264       | 0.2309  | 0.2248 |
|      |            |            | $R^2$  | 0.0983 | 0.1173 | 0.1297       | 0.0466       | 0.0734  | 0.0516 |
|      | OHS-02     | RMSE       | 0.2079 | 0.2264 | 0.2291 | 0.2061       | 0.1991       | 0.2331  |        |
|      |            | $R^2$      | 0.0938 | 0.1244 | 0.1915 | 0.0513       | 0.1087       | 0.0913  |        |
| NDWI | Sentinel-2 | RMSE       | 0.2349 | 0.2076 | 0.2076 | 0.2046       | 0.2109       | 0.2014  |        |
|      |            | $R^2$      | 0.1595 | 0.2269 | 0.1181 | 0.0760       | 0.0447       | 0.1904  |        |
|      | OHS-02     | RMSE       | 0.2124 | 0.2048 | 0.2457 | 0.2074       | 0.2115       | 0.2091  |        |
|      |            | $R^2$      | 0.1385 | 0.1588 | 0.2282 | 0.1543       | 0.0862       | 0.1725  |        |




图 15 重建影像中水体 NDVI 指数可视化结果

Fig 15 Visualization results of water NDVI index in reconstructed images




图 16 重建影像中水体 NDWI 指数可视化结果

Fig 16 Visualization results of water NDWI index in reconstructed images

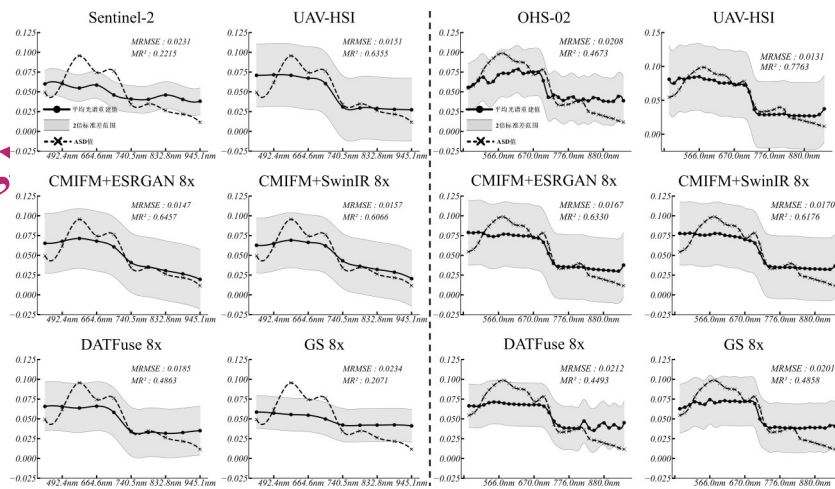


图 17 湿地水体的光谱特征重建曲线

Fig 17 The wetland water spectral characteristics of reconstruction curves

## 5 结论

本文以广西桂林会仙喀斯特国际重要湿地为研究区，讨论并分析了基于 CMIFM 模块的超分辨率影像重建方法实现在 Sentinel-2 多光谱和 OHS-02 高光谱影像中，对湿地场景高精度空谱重建的可能性。在对 Sentinel-2 和 OHS-02 影像整体的重建质量评价方面，分别从空间质量 (PSNR 和 SSIM) 和光谱质量 (RMSE 和  $R^2$ ) 两个方面进行了讨论和分析。在对湿地植被群落和水体光谱重建质量的评价方面，也分别从稳定性 (光谱特征指数) 和保真性 (光谱波段特征) 两个方面进行了讨论和分析。本文得到以下的结论：(1) CMIFM+ESRGAN 和 CMIFM+SwinIR 方法对 Sentinel-2 多光谱影像和 OHS-02 高光谱影像的空间和光谱重建质量较好，在没有无人机影像覆盖区域，重建影像依旧拥有较高的空间和光谱质量，论证了基于 CMIFM 模块的超分辨率方法在湿地场景下对高光谱影像具有较好的性能；(2) 在 CMIFM+ESRGAN 和 CMIFM+SwinIR 重建高光谱影像中，狗牙根、华克拉莎和芒草等湿地植被以及水体的光谱特征指数 (BNDVI、GNDVI、NDVI、NLI、PPR 和 NDWI) 与根据实测 ASD 数据计算特征指数的拟合精度较好，论证了基于 CMIFM 模块的超分辨率重建网络对湿地植被和水体光谱重建的稳定性；(3) 在 442.7 - 943.9nm 光谱范围内，CMIFM+ESRGAN 和 CMIFM+SwinIR 方法对狗牙根、华克拉莎和芒草等湿地植被以及水体的重建光谱值和实测 ASD 数据的拟合精度高于原始影像和融合影像，论证了

基于 CMIFM 模块的超分辨率重建网络对湿地植被和水体光谱重建的保真性；(4) 本文探究并验证了基于 CMIFM 模块的超分辨率影像重建技术在高光谱影像中对湿地场景下，对湿地植被和水体光谱特征定量分析的可行性。

本文提出的 CMIFM 模块能够灵活根据样本点类型构建不同平台影像间的光谱特征关系，进而实现在不同湿地场景下，对跨平台影像的超分辨率重建。然而，依然存在一些不足的地方，例如，缺少对更多更广光谱范围的高光谱影像的重建精度验证，CMIFM 模块缺乏在更多超分辨率重建算法上的验证，没有进一步讨论对不同湿地类型场景的适用性和泛化性，以及与基于深度学习的融合方法对比的数量较少。

**志 谢** 此次珠海一号高光谱数据的获取感谢珠海欧比特卫星大数据有限公司的支持和帮助，无人机高光谱影像数据的获取感谢南宁市华测导航技术有限公司支持和帮助。

## 参考文献 (References)

Aiazzi B, Baronti S, Lotti F, Selva M. 2009. A comparison between global and context-adaptive pansharpening of multispectral images. IEEE Geoscience and Remote Sensing Letters. 6(2): 302-306. [DOI: 10.1109/LGRS.2008.2012003]

Alparone L, Baronti S, Aiazzi B, Garzelli A. 2016. Spatial methods for multispectral pansharpening: Multiresolution analysis demystified. IEEE transactions on geoscience and remote sensing. 54(5): 2563-2576. [DOI: 10.1109/TGRS.2015.2503045]

Bendoumi M A, He M, Mei S. 2014. Hyperspectral image resolution

- enhancement using high-resolution multispectral image based on spectral unmixing. *IEEE Transactions on Geoscience and Remote Sensing*. 52(10): 6574-6583. [DOI: 10.1109/TGRS.2014.2298056]
- Cai J T, Fu B L, Chen T X, Gong R F, Li Y, He H C, Fan D L, Deng T F. 2020. Inversion of phytochemical parameters of Huixian Karst wetland based on Sentinel-2 satellite multi-spectral data. *Wetland Science*. 18(06):693-705. (蔡江涛, 付波霖, 陈铁喜, 耿仁方, 李颖, 何宏昌, 范冬林, 邓腾芳. 2020. 基于 Sentinel-2 卫星多光谱数据的会仙喀斯特湿地植物理化参数反演研究. *湿地科学*. 18(06):693-705. [DOI:10.13248/j.cnki.wetlandsci.2020.06.008])
- Chen C, Xiong Z W, Tian X M, Zha Z J, Wu F. 2019. Camera lens super-resolution. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 1652-1660).
- Daniel T J, Richendrerfer J, Falta R, Murdoch L, Lin H, Darnault C J. 2023. Hydrogeologic and geomorphic processes in a karst landscape and seasonably-cold climate: Linking spatial distribution and morphometric dynamics of closed depressions to bedrock fractures in a wastewater spray irrigated agricultural and forest system located at the site of the Living Filter in Central Pennsylvania, United States. *Agricultural Water Management*. 279. 108170. [https://doi.org/10.1016/j.agwat.2023.108170]
- Fu B L, Li S Z, Lao Z N, Yuan B Y, Liang Y Y, He W, Sun W W, He H C. 2023b. Multi-sensor and multi-platform retrieval of water chlorophyll a concentration in karst wetlands using transfer learning frameworks with ASD, UAV, and Planet CubeSat reflectance data. *Science of The Total Environment*. 901: 165963. [https://doi.org/10.1016/j.scitotenv.2023.165963]
- Fu B L, Sun X D, Li Y Y, Lao Z N, Deng T F, He H C, Sun W W, Zhou G Q. 2023a. Combination of super-resolution reconstruction and SGA-Net for marsh vegetation mapping using multi-resolution multispectral and hyperspectral images. *International Journal of Digital Earth*. 16(1): 2724-2761. [https://doi.org/10.1080/17538947.2023.2234340]
- Fu B L, Zuo P P, Liu M, Lan G W, He H C, Lao Z N, Zhang Y, Fan D L, Gao E T. 2022. Classifying vegetation communities karst wetland synergistic use of image fusion and object-based machine learning algorithm with Jilin-1 and UAV multispectral images. *Ecological Indicators*. 140, 108989. [https://doi.org/10.1016/j.ecolind.2022.108989]
- Ghassemian H. 2016. A review of remote sensing image fusion methods. *Information Fusion*. 32: 75-89. [https://doi.org/10.1016/j.inffus.2016.03.004]
- Gu J J, Lu H N, Zuo W M, Dong C. 2019. Blind super-resolution with iterative kernel correction. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 1604-1613).
- Han Y, Ke Y H, Wang Z P, Liang D Y, Zhou D M. 2023. Classification of wetland landscape in the Yellow River Delta from the Ziyi-02D satellite hyperspectral data. *National Remote Sensing Bulletin*. 27(6):1387-1399. (韩月, 柯樱海, 王展鹏, 梁德印, 周德民. 2023. 资源一号 02D 卫星高光谱数据黄河三角洲湿地景观分类. *遥感学报*. 27(6): 1387-1399. [DOI:10.11834/jrs.20211071])
- Hore A, Ziou D. 2010. Image quality metrics: PSNR vs. SSIM. In 2010 20th international conference on pattern recognition (pp. 2366-2369). IEEE.
- Lassalle G, Ferreira M P, La Rosa L E C, Scafuto R D P M, de Souza Filho C R. 2023. Advances in multi-and hyperspectral remote sensing of mangrove species: A synthesis and study case on airborne and multisource spaceborne imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*. 195: 298-312. [https://doi.org/10.1016/j.isprsjprs.2022.12.003]
- Liang J Y, Cao J Z, Sun G L, Zhang K, Van Gool L, Timofte R. 2021. Swinir: Image restoration using swin transformer. In *Proceedings of the IEEE/CVF international conference on computer vision* (pp. 1833-1844).
- Maeda S. 2020. Unpaired image super-resolution using pseudo-supervision. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 291-300).
- Metternicht G. 2003. Vegetation indices derived from high-resolution airborne videography for precision crop management. *International Journal of Remote Sensing*, 24(14), 2855-2877. [https://doi.org/10.1080/01431160210163074]
- Peng K F, Jiang W G, Hou P, Wu Z F, Ling Z Y, Wang X H, Niu Z G, Mao D H. 2023. Continental-scale wetland mapping: A novel algorithm for detailed wetland types classification based on time series Sentinel-1/2 images. *Ecological Indicators*, 148, 110113. [https://doi.org/10.1016/j.ecolind.2023.110113]
- Pu R, Gong P, Yu Q. 2008. Comparative analysis of EO-1 ALI and Hyperion, and Landsat ETM+ data for mapping forest crown closure and leaf area index. *Sensors*, 8(6), 3744-3766. [https://doi.org/10.3390/s8063744]
- Soh J W, Cho S, Cho N I. 2020. Meta-transfer learning for zero-shot super-resolution. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 3516-3525).
- Sun W W, Liu W W, Wang Y S, Zhao R, Huang M Z, Wang Y, Yang G, Meng X C. 2023. Research progress and prospects of hyperspectral remote sensing in global wetlands from 2010 to 2022. *National Remote Sensing Bulletin*. 27(06):1281-1299. (孙伟伟, 刘围围, 王煜森, 赵锐, 黄明珠, 王耀, 杨刚, 孟祥超. 2023. 2010年—2022年全球湿地高光谱遥感研究进展与展望. *遥感学报*. 27(06): 1281-1299.)
- Sun W W, Ren K, Meng X C, Yang G, Xiao C, Peng J T, Huang J F. 2022. MLR-DBPFN: A multi-scale low rank deep back projection fusion network for anti-noise hyperspectral and multispectral image fusion. *IEEE Transactions on Geoscience and Remote Sensing*. 60: 1-14. [DOI: 10.1109/TGRS.2022.3146296]
- Tang W, He F Z, Shi Y, Duan Y S, Si T Z. 2023. DATFuse: Infrared and visible image fusion via dual attention transformer. *IEEE Transactions on Circuits and Systems for Video Technology*. [DOI: 10.1109/TCSVT.2023.3234340]
- Waheed M, Haq S M, Arshad F, Bussmann R W, Ali H M, Siddiqui M H. 2023. Phyto-ecological distribution patterns and identification of alien invasive indicator species in relation to edaphic factors from semi-arid region. *Ecological Indicators*. 148. 110053. [https://doi.org/10.1016/j.ecolind.2023.110053]

- [//doi.org/10.1016/j.ecolind.2023.110053](https://doi.org/10.1016/j.ecolind.2023.110053)]
- Wang F M, Haung J F, Tang Y L, Wang X Z. 2007. New vegetation index and its application in estimating leaf area index of rice. *Rice Science*, 14(3), 195-203. [[https://doi.org/10.1016/S1672-6308\(07\)60027-4](https://doi.org/10.1016/S1672-6308(07)60027-4)]
- Wang P J, Bayram B, Sertel E. 2022. A comprehensive review on deep learning based remote sensing image super-resolution methods. *Earth-Science Reviews*. 104110. [<https://doi.org/10.1016/j.earsci-rev.2022.104110>]
- Wang X T, Yu K, Wu S X, Gu J J, Liu Y H, Dong C, Qiao Y, Change Loy C. 2018. Esrgan: Enhanced super-resolution generative adversarial networks. In *Proceedings of the European conference on computer vision (ECCV) workshops* (pp. 0-0).
- Xu T Y, Wang F M, Shi Z, Xie L L, Yao X P. 2023. Dynamic estimation of rice aboveground biomass based on spectral and spatial information extracted from hyperspectral remote sensing images at different combinations of growth stages. *ISPRS Journal of Photogrammetry and Remote Sensing*. 202: 169-183. [<https://doi.org/10.1016/j.isprsjprs.2023.05.021>]
- Yang C, Everitt J H, Bradford J M, Murden D. 2004. Airborne hyperspectral imagery and yield monitor data for mapping cotton yield variability. *Precision Agriculture*, 5(5), 445-461. [doi: 10.13031/2013.16111]
- Yang W L, Fu B L, Li S X, Lao Z N, Deng T F, He W, He H C, Chen Z K. 2023. Monitoring multi-water quality of internationally important karst wetland through deep learning, multi-sensor and multi-platform remote sensing images: A case study of Guilin, China. *Ecological Indicators*. 154. 110755. [<https://doi.org/10.1016/j.ecolind.2023.110755>]
- Zhang H Y, Cisse M, Dauphin Y N, Lopez-Paz D. 2017. mixup: Beyond empirical risk minimization. *arXiv preprint arXiv: 1710.09412*. [<https://doi.org/10.48550/arXiv.1710.09412>]
- Zhang Z, Jiang W G, Peng K F, Wu Z F, Ling Z Y, Li Z. 2023. Assessment of the impact of wetland changes on carbon storage in coastal urban agglomerations from 1990 to 2035 in support of SDG15. *1. Science of The Total Environment*, 877, 162824. [<https://doi.org/10.1016/j.scitotenv.2023.162824>]

## Combination of CMIFM module and super-resolution network for cross-platform hyperspectral image reconstruction and spectral quantitative assessment——A case study of karst wetland

SUN Xidong<sup>1</sup>, FU Bolin<sup>1</sup>, LI Huajian<sup>1</sup>, JIA Mingming<sup>2</sup>, SUN Weiwei<sup>3</sup>, WU yan<sup>1</sup>, SONG Yiji<sup>1</sup>

1. Guilin University of Technology, College of Geomatics and Geoinformation, Guilin 541006, China;

2. Northeast Institute of Geography and Agroecology, Chinese Academy of Sciences, Changchun, 130000, China;

3. Department of Geography and Spatial Information Techniques, Ningbo, 315211, China

**Abstract:** Time-series accurate monitoring of vegetation and water conditions by hyperspectral remote sensing is the key and foundation for accurate assessment and comprehensive monitoring of karst wetland ecosystem. However, the spatial resolution of the existing satellite hyperspectral images is low, which could hardly capture the complex spatial details of the wetland vegetations, while the super-high-resolution UAV images could hardly realize the time-sequence monitoring of the large-scale wetland scenes. The existing fusion methods could not well realize the non-destructive fusion of the spatial and spectral features of the hyperspectral images from the above two kinds of platforms. In order to solve the problems, this paper propose a cross-platform multi-scale image feature mapping module (Cross-Sensor Multiscale Image Feature Mapping Module, CMIFM). This module unifies the spatial scale of UAV hyperspectral image (Aerial hyperspectral image, AHSI) and satellite hyperspectral image (Spaceborne hyperspectral image, SHSI), maps AHSI and SHSI into the same spectral characteristic space according to the measured ASD (Analytical Spectral Devices) data, integrates the spatial- and spectral- feature fusion data of AHSI and SHSI to construct the image feature datasets. The high-quality image reconstruction of SHSI could be achieved by training feature datasets into super-resolution networks (ESRGAN and SwinIR). Meanwhile, this study used the latest deep-learning (DATFUSE) and traditional (GS) fusion methods to compare the spatial- and spectral- quality of vegetations and water between the reconstructed and fused images in wetland scenes. This study highlights that: (1) CMIFM-based super-resolution network could realize cross-platform enhancement of spatial characteristics of detail information for wetland vegetation and water in SHSI by learning AHSI features, which could outperform the GS image fusion method in visual perception and quantitative indexes, and the average *PSNR* and *SSIM* accuracies of the reconstructed images are 11.06 and 0.3102, respectively. (2) the spectral features of three typical wetland vegetation communities (*Cynodon-dactylon*, *Cladium chinense* Nees and *Miscanthus*) and wetland water in the reconstructed images exhibit higher stability and fidelity based on the measured ASD data, and the average *RMSE* and *R*<sup>2</sup> accuracies of the spectral bands are higher than the DATFUSE and GS fusion images. (3) the CMIFM+ESRGAN and CMIFM+SwinIR methods provide strong generalization ability in terms of spatial- and spectral- reconstruction performance, and could be able to complete the reconstruction of the image in wetland scenes where AHSI is not covered, with the average *PSNR* and *R*<sup>2</sup> of 12.74 and 0.1897, respectively, which are close to the range of accuracies' values for the AHSI-covered area. (4) this paper verified the feasibility of CMIFM based super-resolution technology in hyperspectral reconstruction

images of complex wetlands.

**Key words:** karst wetland, CMIFM module, cross-platform super-resolution reconstruction, DATFuse fusion algorithm, hyperspectral images, quantitative evaluation of spatial-spectral reconstruction quality

**Supported by** National Natural Science Foundation of China (Grant number 42371341; 42122009) (Grant number Guikexu-D20159037), Guangxi Natural Science Foundation Upper-level Project (Grant number 2023JJA150096), Innovation Project of Guangxi Graduate Education (Grant number YCSW2023353), 'Ba Gui Scholars' program of the provincial government of Guangxi, and the Guilin University of Technology Foundation (Grant number GUTQDJJ2017096).

NATIONAL  
REMOTE  
SENSING BULLETIN | 遥感学报

www.ygxb.ac.cn

NATIONAL  
REMOTE  
SENSING BULLETIN | 遥感学报

www.ygxb.ac.cn