

doi:10.6041/j.issn.1000-1298.2026.20.010

基于 Transformer 光谱匹配的星机协同滨海盐渍化农田土壤含盐量监测方法

顾晓鹤¹ 翟胜楠^{1,2} 刘星宇^{1,2} 张宝元¹ 屈旭洲¹ 吴文彪¹

(1.北京市农林科学院信息技术研究中心,北京 100097; 2.沈阳农业大学信息与电气工程学院,沈阳 110866)

摘要:星机协同遥感为滨海盐渍化农田土壤含盐量(Soil salinity content,SSC)空间监测提供了重要途径,但该类区域含盐量空间异质性强、地表覆盖复杂,Sentinel-2多光谱成像仪(Multispectral instrument,MSI)影像受波段设置、光谱分辨率和混合像元效应制约,含盐量敏感信息表达有限。为缓解跨传感器光谱差异对Sentinel-2 MSI影像SSC估算的影响,本文提出一种基于Transformer光谱匹配的星机协同土壤含盐量监测方法。以河北省黄骅市滨海盐渍化农田为研究区,同期获取实测SSC、无人机高光谱影像和Sentinel-2 MSI影像。将无人机高光谱影像重采样至10 m,并与Sentinel-2 MSI影像空间对齐;以无人机高光谱匹配波段反射率为参考,采用多层感知机(Multilayer perceptron,MLP)和Transformer构建Sentinel-2 MSI至无人机高光谱参考空间的非线性光谱匹配模型;最后构建原始波段和盐分光谱指数,筛选含盐量敏感特征,采用随机森林(Random forest,RF)模型估算SSC,并基于留一交叉验证评价模型精度。结果表明,Sentinel-2-RF模型决定系数(R^2)为0.37,均方根误差(Root mean square error, RMSE)和平均绝对误差(Mean absolute error,MAE)分别为0.82 g/kg和0.62 g/kg;经MLP光谱匹配后, R^2 提高至0.45, RMSE和MAE分别为0.77 g/kg和0.61 g/kg;经Transformer光谱匹配后, R^2 进一步提高至0.49, RMSE和MAE分别为0.74 g/kg和0.58 g/kg。与Sentinel-2-RF模型相比,Sentinel-2_Transformer-RF模型 R^2 提高0.12, RMSE降低0.08 g/kg。研究表明,Transformer光谱匹配能增强Sentinel-2 MSI影像的含盐量敏感信息表达,可为滨海盐渍化农田SSC空间分布推算提供方法层面参考。

关键词:土壤含盐量;星机协同;光谱匹配;Transformer;Sentinel-2

中图分类号: S127; TP79 文献标识码: A 文章编号: 1000-1298(2026)20-0108-10

OSID:



Satellite – UAV Collaborative Monitoring Method for Soil Salinity in Coastal Saline Farmland Based on Transformer Spectral Matching

Gu Xiaohu¹ Zhai Shengnan^{1,2} Liu Xingyu^{1,2} Zhang Baoyuan¹ Qu Xuzhou¹ Wu Wenbiao¹

(1. Information Technology Research Center, Beijing Academy of Agriculture and Forestry Sciences, Beijing 100097, China

2. College of Information and Electrical Engineering, Shenyang Agricultural University, Shenyang 110866, China)

Abstract: Satellite – UAV collaborative remote sensing provides an important approach for spatial monitoring of soil salinity content (SSC) in coastal saline farmland. However, in such regions, soil salinity shows strong spatial heterogeneity and surface cover is complex. Sentinel – 2 multispectral instrument (MSI) imagery was limited by band configuration, spectral resolution and mixed-pixel effects, resulting in limited expression of salt-sensitive information. To alleviate the influence of cross-sensor spectral differences on SSC estimation from Sentinel – 2 MSI imagery, a satellite – UAV collaborative soil salinity monitoring method was proposed based on Transformer spectral matching. Coastal saline farmland in Huanghua City, Hebei Province, China, was selected as the study area, and measured SSC, UAV hyperspectral imagery and Sentinel – 2 MSI imagery were acquired during the same period. Firstly, the UAV hyperspectral imagery was resampled to 10 m and spatially aligned with Sentinel – 2 MSI imagery. Then, using UAV hyperspectral matched-band reflectance as a reference, multilayer perceptron (MLP) and Transformer models were used to construct nonlinear spectral matching models from Sentinel – 2 MSI

收稿日期: 2026-06-14 修回日期: 2026-07-06

基金项目: 本文为退化耕地监测研究成果

作者简介: 顾晓鹤(1979—),男,研究员,博士,主要从事农业定量遥感研究,E-mail: guxh@nercita.org.cn

通信作者: 吴文彪(1981—),男,正高级农艺师,主要从事农业信息技术研究,E-mail: wuwb@nercita.org.cn

to the UAV hyperspectral reference space. Finally, original bands and salinity spectral indices were constructed, salt-sensitive features were selected, SSC was estimated by using a random forest (RF) model, and model accuracy was evaluated by leave-one-out cross-validation. Results showed that the coefficient of determination (R^2) of the original Sentinel-2-RF model was 0.37, and the root mean square error (RMSE) and mean absolute error (MAE) were 0.82 g/kg and 0.62 g/kg, respectively. After MLP spectral matching, R^2 was increased to 0.45, and RMSE and MAE were 0.77 g/kg and 0.61 g/kg, respectively. After Transformer spectral matching, R^2 was further increased to 0.49, and RMSE and MAE were 0.74 g/kg and 0.58 g/kg, respectively. Compared with the original Sentinel-2-RF model, the Sentinel-2_Transformer-RF model increased R^2 by 0.12 and reduced RMSE by 0.08 g/kg. The results indicated that Transformer spectral matching can enhance the expression of salt-sensitive information in Sentinel-2 MSI imagery and provide a methodological reference for SSC spatial distribution estimation in coastal saline farmland.

Key words: soil salt content; satellite-UAV collaboration; spectral matching; Transformer; Sentinel-

2

0 引言

土壤盐渍化是滨海地区耕地质量退化的重要表现之一,会降低土壤生产力并影响农业可持续利用^[1]。土壤含盐量 (Soil salinity content, SSC) 反映土壤中可溶性盐分累积程度,是表征盐渍化农田含盐量空间异质性、开展盐渍化识别、治理评价和农业管理的重要指标。

传统土壤含盐量监测依赖野外采样与实验室测定,精度较高但难以反映区域尺度空间分布。遥感技术具有覆盖范围广、空间连续性强和时效性好等优势,已成为区域土壤含盐量监测的重要手段^[2]。Sentinel-2 多光谱成像仪 (Multispectral instrument, MSI) 影像具有较高空间分辨率、较短重访周期和开放共享等优势,已广泛用于土壤含盐量估算与盐渍化制图^[3-4]。近年来,结合 Sentinel 系列多源遥感数据和特征优化方法开展土壤含盐量估算已成为重要研究方向^[5]。然而, Sentinel-2 MSI 波段设置相对稀疏、光谱分辨率有限,且滨海农田地表覆盖复杂、含盐量空间异质性强,混合像元现象明显,削弱了卫星影像对土壤含盐量细微信息的表达能力^[6]。对于滨海盐渍化农田,作物残茬、植被覆盖、道路、养殖水面和盐碱裸地等混合地物会干扰 Sentinel-2 像元尺度 10 m 下含盐量响应。因此,增强 Sentinel-2 MSI 影像含盐量敏感信息表达,是提高滨海盐渍化农田 SSC 空间推算可靠性的关键问题之一。

无人机遥感具有高空间分辨率和近地精细观测优势,星机地协同观测为兼顾田间尺度精细监测与区域尺度宏观监测提供了可能^[7-9]。近年来,基于无人机与 Sentinel-2 遥感数据协同开展土壤含盐量监测的方法逐渐受到关注,为多尺度土壤含盐量估算提供了新的技术路径^[10]。无人机高光谱影像光谱连续性强、空间分辨率高,能捕捉土壤含盐量引

起的细微光谱变化,但覆盖范围有限,难以直接满足区域连续监测需求。星机协同监测可将 UAV 高光谱建立的精细光谱-含盐量关系传递至卫星影像,实现从田间尺度验证到区域尺度推算的空间扩展^[11]。

不同传感器之间存在光谱响应函数、波段设置、空间分辨率和成像条件差异,波段直接匹配和空间重采样难以完全消除跨传感器光谱偏差^[8,12]。现有多源遥感土壤含盐量监测研究多通过特征叠加、指数构建或机器学习模型提高反演精度,但对星机传感器光谱响应不一致问题考虑不足。因此,以 UAV 高光谱精细光谱信息为参考开展 Sentinel-2 MSI 光谱匹配,是缓解跨传感器差异、增强卫星影像含盐量敏感信息表达的重要环节。MLP 结构简单、训练稳定,可作为非线性映射基准模型;Transformer 基于自注意力机制,能捕捉多波段光谱序列间的依赖关系,更适合刻画 Sentinel-2 MSI 反射率到 UAV 高光谱参考反射率之间的非线性映射^[13]。

因此,本文选取 MLP 作为基准光谱匹配模型,选取 Transformer 作为改进光谱匹配模型,比较二者对 Sentinel-2 MSI 影像含盐量敏感特征表达和 SSC 估算精度的影响^[14]。以河北省黄骅市滨海盐渍化农田为研究区,以 UAV 高光谱影像为参考,构建 Sentinel-2 MSI 影像至 UAV 高光谱参考空间的光谱匹配模型,并在统一随机森林 (Random forest, RF) 估算框架下评价不同光谱匹配方法对 SSC 估算的影响。建立 UAV 高光谱影像与 Sentinel-2 MSI 影像的波段和空间尺度匹配关系;比较 MLP 与 Transformer 光谱匹配对 Sentinel-2 MSI 含盐量敏感特征的增强效果;分析光谱匹配前后 Sentinel-2 MSI 影像的 SSC 估算精度变化。

1 材料与方法

技术流程如图 1 所示。首先,同期获取 UAV 高




图 1 星机协同农田土壤含盐量遥感监测技术流程

Fig.1 Technical workflow of satellite - UAV collaborative soil salinity monitoring

光谱影像、Sentinel - 2 MSI 影像和实测 SSC 数据;其次,对 2 类影像进行预处理、波段匹配和空间尺度统一;然后,以 UAV 高光谱影像为参考,采用 MLP 和 Transformer 对 Sentinel - 2 MSI 影像进行光谱匹配;最后,构建含盐量敏感特征,采用 RF 模型估算 SSC,并对不同数据源条件下模型精度进行验证。

1.1 研究区概况

以河北省黄骅市滨海盐渍化农田为研究区(图 2),其中图 2b 底图为 Sentinel - 2 影像(2024 年 6 月),分辨率 10 m。黄骅市位于河北平原东部、环渤海西岸,地理范围为 38°08′54″~38°42′46″N、117°04′37″~117°51′17″E,地貌类型以滨海沉积平原和冲积平原为主,地势低平。研究区属暖温带半湿润季风气候,年均气温约 13.4℃,年均降水量 550~650 mm,降水主要集中于 7—9 月。区域土地利用类型以耕地为主,同时分布有盐碱滩涂、养殖水面和少量建设用地,主要种植制度为冬小麦-夏玉米轮作。受滨海沉积环境、浅埋地下水、强蒸发及灌排条件影响,研究区表层土壤易发生盐分累积,次生盐渍化问题较为突出。

1.2 土壤样本采集与预处理

野外土壤样本于 2024 年 6 月采集,此时大部




图 2 研究区位置及采样点分布

Fig.2 Location of study area and distribution of sampling sites

分农田处于裸露窗口期。根据研究区地表覆盖状况和盐渍化分布特征,选取 2 个滨海盐渍化农田地块作为试验地,每个地块布设 20 个采样点,共获得 40

份表层土壤样品。采样点位置采用手持全球定位系统(Global positioning system,GPS)记录,每个样点按照土层深度 0~20 cm 采样,去除表层粗石、植物残体及根系后,采用五点取样法混合形成 1 个土壤样品。土壤样品带回实验室后,经自然风干、去杂、研磨和 1 mm 筛分后测定 SSC。采用土水质量比 1:5 浸提法测定浸提液电导率,并换算为土壤含盐量。每个采样点对应 1 个实测 SSC,用于遥感特征提取、相关性分析和模型验证。

1.3 遥感影像获取与预处理

1.3.1 无人机高光谱影像获取与预处理

无人机高光谱影像于 2024 年 6 月 11 日获取,采用 DJI 经纬 M300 型无人机搭载 Cubert ULTRIS X20 Plus 型高光谱成像仪进行数据采集,采集时间为 12:00—13:00,主要飞行与传感器参数见表 1。飞行前后采集标准白板影像进行辐射定标。影像预处理在 Cube-Pilot 和 Agisoft PhotoScan 软件中完成,主要包括光谱格式整理、暗电流校正、噪声抑制、白板校正、几何校正、影像拼接和正射校正,最终生成无人机高光谱反射率正射影像,用于星机光谱匹配与含盐量敏感特征提取。

表 1 无人机高光谱影像采集参数

Tab.1 Acquisition parameters of UAV hyperspectral imagery

参数	数值/形式
无人机平台	DJI 经纬 M300 型
高光谱成像仪	Cubert ULTRIS X20 Plus 型
采集日期	2024 年 6 月 11 日
采集时间	12:00—13:00
飞行高度/m	30
航速/(m·s ⁻¹)	5
前/旁向重叠度/%	80/80
光谱范围/nm	350~1 002
波段数	164
光谱采样间隔/nm	约 4
光谱分辨率/nm	约 10
辐射定标	标准白板定标

1.3.2 Sentinel-2 MSI 影像获取与预处理

Sentinel-2 MSI 影像获取于 Google Earth Engine 平台,选取与地面采样和 UAV 飞行时间接近的 2024 年 6 月 12 日 Sentinel-2 Level-2A 地表反射率产品作为卫星数据。Sentinel-2 MSI 包含 13 个光谱波段,其中 B2、B3、B4 和 B8 空间分辨率为 10 m,B5、B6、B7、B8A、B11 和 B12 空间分辨率为 20 m。剔除 B1、B9 和 B10 波段,将其余波段反射率除以 10 000,并将 20 m 波段重采样至 10 m 后裁剪至研究区范围。为进行星机光谱匹配与含盐量敏感

特征构建,选取 B2、B3、B4、B5、B6、B7、B8 和 B8A 共 8 个波段作为主要分析波段。

1.4 星机波段与空间尺度匹配

为建立 UAV 高光谱影像与 Sentinel-2 MSI 影像间的光谱对应关系,依据 Sentinel-2 MSI 各波段中心波长,在 UAV 高光谱影像中选取最接近的对应波段,形成二者的波段匹配关系,结果见表 2。

表 2 无人机高光谱与 Sentinel-2 MSI 波段匹配关系
Tab.2 Band matching between UAV hyperspectral data and Sentinel-2 MSI

Sentinel-2 波段	中心波长	UAV 波长
B2	496.6/492.1	494
B3	560.0/559.0	558
B4	664.5/665.0	666
B5	703.9/703.8	702
B6	740.2/739.1	738
B7	782.5/779.7	778
B8	835.1/833.0	834
B8A	864.8/864.0	866

在空间尺度上,将 UAV 高光谱影像聚合至 Sentinel-2 10 m 像元尺度,并与 Sentinel-2 MSI 影像进行空间配准,使 2 类影像在同一空间单元内进行光谱比较。完成波段匹配与空间尺度统一后,从 UAV 与 Sentinel-2 重叠区域提取像元级配对光谱样本,用于星机光谱匹配模型训练。

1.5 星机光谱匹配方法

在完成波段匹配和空间尺度统一后,分别采用 MLP 和 Transformer 进行星机光谱匹配。2 类模型均以 Sentinel-2 MSI 的 B2、B3、B4、B5、B6、B7、B8 和 B8A 波段反射率为输入,以空间对应位置的 UAV 高光谱匹配波段反射率为输出,基于像元级配对光谱样本建立 Sentinel-2 MSI 反射率至 UAV 高光谱参考反射率的非线性映射关系。

MLP 作为常规非线性映射基准模型,Transformer 作为光谱序列建模方法,用于比较不同光谱匹配方法对 Sentinel-2 MSI 影像反射率表达的改善效果。2 类模型输入、输出和训练样本保持一致,训练完成后分别生成 Sentinel-2_MLP 和 Sentinel-2_Transformer 光谱匹配影像。

1.6 含盐量敏感特征构建与筛选

基于 UAV 高光谱影像、原始 Sentinel-2 MSI 影像、Sentinel-2_MLP 和 Sentinel-2_Transformer 4 类数据分别构建光谱特征集。特征变量包括原始波段反射率和含盐量相关光谱指数。土壤盐分累积会改变土壤表面反射率特征,尤其影响可见光和近红外波段的光谱响应^[15]。选取盐分指数(Salinity

index, SI) SI1 ~ SI10 和归一化差值盐分指数 (Normalized difference salinity index, NDSI) 共 11 个光谱指数参与特征构建,所用指数见表 3。

表 3 土壤含盐量光谱指数
Tab.3 Soil salinity spectral indices

光谱指数	计算式	文献序号
SI1	$SI_1 = (B_3 + B_4) / 2$	[15]
SI2	$SI_2 = (B_3 + B_4 + B_{8A}) / 3$	[15]
SI3	$SI_3 = \sqrt{B_2 + B_4}$	[15]
SI4	$SI_4 = \sqrt{B_3 B_4}$	[15]
SI5	$SI_5 = \sqrt{B_3^2 B_4^2}$	[15]
SI6	$SI_6 = B_2 / B_4$	[16]
SI7	$SI_7 = (B_3 - B_4) / (B_3 + B_4)$	[16]
SI8	$SI_8 = B_3 B_4 / B_2$	[16]
SI9	$SI_9 = B_2 B_4 / B_3$	[16]
SI10	$SI_{10} = B_4 B_{8A} / B_3$	[16]
NDSI	$NDSI = (B_4 - B_{8A}) / (B_4 + B_{8A})$	[17]

注: B_2 、 B_3 、 B_4 和 B_{8A} 分别表示蓝光、绿光、红光和窄近红外波段反射率; UAV 高光谱影像及光谱匹配影像按表 2 对应波段计算。

采用 Pearson 相关分析计算各光谱变量与实测 SSC 之间的相关系数,并结合相关系数绝对值和显著性水平筛选含盐量敏感特征。以原始 Sentinel-2 MSI 影像中在 $p < 0.01$ 条件下与 SSC 显著相关的特征数量为基准,4 类数据均按相关系数绝对值排序筛选 7 个特征变量作为 SSC 估算模型输入。

1.7 土壤含盐量估算模型与精度评价

采用随机森林 (RF) 模型构建 SSC 估算模型,并以 RF 作为统一估算框架,比较 UAV 高光谱影像、原始 Sentinel-2 MSI 影像、Sentinel-2_MLP 和 Sentinel-2_Transformer 4 类数据源的 SSC 估算精度^[18]。分别以 1.6 节筛选得到的含盐量敏感特征作为输入变量,以采样点实测 SSC 作为因变量,建立不同数据源条件下 RF 估算模型。

RF 模型基于 Python 中 sklearn 库的 RandomForestRegressor 实现。结合已有遥感反演研究中常用 RF 参数设置、本文样本规模及预试验模型稳定性表现,最终确定统一参数:决策树数量 $n_estimators$ 为 500,最大树深度 max_depth 为 20,内部节点再划分所需最小样本数 $min_samples_split$ 为 5,叶节点最小样本数 $min_samples_leaf$ 为 3,最大特征数 $max_features$ 为 sqrt,采用 bootstrap 抽样,随机种子 $random_state$ 设置为 42。上述模型结构、参数设置和精度评价方法在 4 类数据源中保持一致。

采用留一交叉验证 (Leave-one-out cross-validation, LOOCV) 对 RF 模型进行精度评价。每次以 1 个样点作为验证样本,其余 39 个样点作为训

练样本,重复 40 次并汇总各样点预测结果。模型精度采用决定系数 (R^2)、均方根误差 (Root mean square error, RMSE) 和平均绝对误差 (Mean absolute error, MAE) 评价。

2 结果与分析

2.1 土壤含盐量统计特征

为明确研究区表层土壤含盐量的基本分布特征,对采集的 40 份土壤样品 SSC 进行统计分析,结果见表 4。由表 4 可知,研究区 SSC 变化范围为 0.42 ~ 4.21 g/kg,平均值为 1.71 g/kg,标准差为 1.05 g/kg,变异系数为 61.14%,表明研究区表层土壤含盐量离散程度较高,样点间存在明显空间差异。

表 4 研究区土壤含盐量统计特征
Tab.4 Statistical characteristics of SSC in study area

样本类型	样本数量	SSC/(g·kg ⁻¹)				变异系数/%
		最大值	最小值	平均值	标准差	
总样本	40	4.21	0.42	1.71	1.05	61.40
地块 1	20	4.21	0.42	1.46	0.87	59.59
地块 2	20	3.94	0.64	1.99	1.11	55.78

从不同地块来看,地块 2 SSC 平均值高于地块 1,说明 2 个典型耕作地块之间盐分累积程度存在差异。总体上,研究区样点 SSC 覆盖了不同含盐量水平,可为光谱特征相关性分析和土壤含盐量估算模型构建提供样本基础。

2.2 光谱匹配前后不同数据源波段反射率差异

为比较 UAV 高光谱影像、原始 Sentinel-2 MSI 影像及光谱匹配后影像之间的光谱差异,分别统计 UAV、Sentinel-2、Sentinel-2_MLP 和 Sentinel-2_Transformer 4 类数据在 B2、B3、B4、B5、B6、B7、B8 和 B8A 波段上的反射率分布特征,结果见图 3。




图 3 UAV、Sentinel-2 及光谱匹配后影像波段反射率分布
Fig.3 Band reflectance distributions of UAV, Sentinel-2 Transformer and spectrally matched images

由图 3 可知,UAV 高光谱影像与原始 Sentinel-2

2 MSI 影像在各波段反射率分布上存在明显差异。UAV 高光谱影像各波段反射率整体较低,波段均值由可见光向近红外方向逐渐升高;原始 Sentinel-2 MSI 影像反射率整体高于 UAV 高光谱影像,尤其在红边和近红外波段差异较为明显,说明 2 类影像受传感器光谱响应、空间分辨率和成像条件等因素影响,存在跨传感器光谱差异。

经光谱匹配后,Sentinel-2_MLP 和 Sentinel-2_Transformer 反射率分布均向 UAV 高光谱影像靠近。Sentinel-2_MLP 能在一定程度上降低原始 Sentinel-2 MSI 影像的反射率偏差,但部分波段的分布差异仍较明显。相比之下,Sentinel-2_Transformer 各波段反射率均值和分布范围与 UAV 高光谱影像更为接近,波段间变化趋势也更加一致,表明 Transformer 光谱匹配能较好保持多波段光谱结构的一致性。

总体来看,Transformer 光谱匹配能调整 Sentinel-2 MSI 影像反射率分布,减弱与 UAV 高光谱影像之间光谱偏差,为 SSC 估算提供光谱输入基础。

2.3 光谱匹配前后 Sentinel-2 影像重建效果

对原始 Sentinel-2 MSI、Sentinel-2_MLP 和 Sentinel-2_Transformer 影像进行可视化,比较不同光谱匹配方法对 Sentinel-2 MSI 影像光谱表达和局部地物色调差异的影响,结果见图 4。其中,左列为整体影像,右列为局部放大区域。

由图 4 可知,原始 Sentinel-2 MSI 影像中部分田块边界和局部地物色调差异相对不明显。经 MLP 和 Transformer 光谱匹配后,影像反射率表达有所调整,局部地物色调区分度增强,其中 Sentinel-2_Transformer 影像在田块边界、裸地与植被过渡区域的表达上更接近 UAV 高光谱参考影像。需要说明的是,光谱匹配主要改善 Sentinel-2 MSI 影像的反




图 4 Sentinel-2 影像光谱匹配前后及局部放大结果
Fig. 4 Sentinel-2 images before and after spectral matching and locally enlarged results

射率表达和光谱一致性,并未改变原始空间分辨率。

2.4 光谱匹配对土壤含盐量敏感特征相关性的影响

分别计算 UAV、原始 Sentinel-2 MSI 影像、Sentinel-2_MLP 和 Sentinel-2_Transformer 4 类数据中各光谱特征与实测 SSC 之间的 Pearson 相关系数,分析光谱匹配对土壤含盐量信息表达能力的影响,结果见图 5,蓝色柱表示正相关,红色柱表示负相关; ** 表示在 $p < 0.01$ 水平极显著, * 表示在 $p < 0.05$ 水平显著。

由图 5 可知,UAV 高光谱影像中多数原始波段和盐分指数与 SSC 呈正相关关系,且相关系数整体较高,其中 B2、B3、B4 以及 SI2、SI3、SI4、SI9 等特征




图 5 不同数据源光谱特征与土壤含盐量的 Pearson 相关系数

Fig. 5 Pearson correlation coefficients between spectral features and SSC from different data sources

表现出较强的含盐量敏感性,说明可见光波段及其组合指数是研究区土壤含盐量信息表达的重要特征。相比之下,原始 Sentinel-2 MSI 影像中部分波段和盐分指数与 SSC 的相关性有所减弱,说明受传感器光谱响应、波段宽度和空间尺度差异影响,对 SSC 变化的响应能力受到一定限制。

经光谱匹配后,Sentinel-2_MLP 和 Sentinel-2_Transformer 中多数特征与 SSC 的相关性均有所恢复,其中 Sentinel-2_Transformer 改善效果更明显,B3、B4、SI1、SI2、SI3、SI4 和 SI9 等特征与 SSC 保持较强相关性,整体相关性分布更接近 UAV 高光谱影像。结果表明,Transformer 光谱匹配不仅能调整 Sentinel-2 MSI 影像的反射率分布,也有助于增强含盐量敏感特征对 SSC 变化的统计响应能力。

依据 1.6 节特征筛选方法,分别选取 4 类数据源中相关系数绝对值较高的 7 个特征作为 RF 模型输入,筛选结果见表 5。

表 5 不同数据源土壤含盐量敏感特征筛选结果
Tab.5 Selected soil salinity-sensitive features from different data sources

数据源	筛选特征	特征数量
UAV	B2、B3、B4、SI2、SI3、SI4、SI9	7
Sentinel-2 MSI	B2、B3、SI1、SI3、SI4、SI5、SI9	7
Sentinel-2_MLP	B2、B3、B4、SI1、SI2、SI3、SI9	7
Sentinel-2_Transformer	B3、B4、SI1、SI2、SI3、SI4、SI9	7

由表 5 可知,不同数据源筛选出的含盐量敏感特征组合存在差异。UAV 高光谱影像筛选结果主要包括 B2、B3、B4 及多个盐分指数,表明可见光波段及其组合指数对 SSC 具有较强响应;原始 Sentinel-2 MSI 影像筛选结果更多依赖盐分指数,说明单波段特征对 SSC 的直接响应能力相对不足。经光谱匹配后,Sentinel-2_MLP 和 Sentinel-2_Transformer 筛选特征均包含可见光波段和多个盐分指数,其中 Sentinel-2_Transformer 筛选结果与 UAV 高光谱影像具有较高一致性,表明 Transformer 光谱匹配能增强 Sentinel-2 MSI 影像的含盐量敏感特征表达能力。

2.5 光谱匹配前后土壤含盐量估算精度

基于不同数据源筛选得到的含盐量敏感特征,分别构建 RF 模型估算 SSC,并采用 LOOCV 方法评价模型精度,结果见图 6。

由图 6 可知,不同数据源下 SSC 预测结果存在明显差异。UAV-RF 模型预测值与实测值整体更接近 1:1 参考线, R^2 为 0.58, RMSE 和 MAE 分别为 0.67 g/kg 和 0.54 g/kg,表明 UAV 高光谱影像在田间尺度 SSC 估算中具有较好的光谱表达能力。




图 6 不同数据 RF 模型土壤含盐量实测值与预测值
Fig.6 Measured and predicted SSC values using RF models with different data sources

Sentinel-2-RF 模型预测值与实测值离散程度较大, R^2 、RMSE 和 MAE 分别为 0.37、0.82 g/kg 和 0.62 g/kg,说明未经光谱匹配的 Sentinel-2 MSI 影像对田间尺度 SSC 的表征能力仍有提升空间。

MLP 光谱匹配后,Sentinel-2_MLP-RF 模型 R^2 提高至 0.45, RMSE 和 MAE 分别降为 0.77 g/kg 和 0.61 g/kg。经 Transformer 光谱匹配后,Sentinel-2_Transformer-RF 模型精度进一步提高, R^2 、RMSE 和 MAE 分别为 0.49、0.74 g/kg 和 0.58 g/kg。综合比较 4 类数据源的模型结果,估算精度由大到小依次为 UAV-RF、Sentinel-2_Transformer-RF、Sentinel-2_MLP-RF、Sentinel-2-RF。与 Sentinel-2-RF 相比,Sentinel-2_Transformer-RF R^2 提高 0.12, RMSE 和 MAE 分别降低 0.08 g/kg 和 0.04 g/kg。说明 Transformer 光谱匹配能在一定程度上改善 Sentinel-2 MSI 影像的含盐量敏感信息表达。

2.6 黄骅市耕地土壤含盐量空间分布

根据不同数据源 RF 模型的精度比较结果,选取 Sentinel-2 类数据源中精度较高的 Sentinel-2_Transformer-RF 模型,对黄骅市耕地区域 SSC 进行空间推算,结果见图 7。结合耕地范围对推算结果进行掩膜处理,仅对耕地区域内有效像元进行空间分布分析。

由图 7 可知,黄骅市耕地区域 SSC 呈斑块状分布,不同耕地地块之间含盐量差异较为明显。结合 Sentinel-2 影像表现来看,耕地区域内反射率较高、植被覆盖较低地块多对应较高 SSC 推算值,而植被覆盖较好地块 SSC 推算值相对较低^[19]。这与盐渍




图 7 基于 Sentinel-2_Transformer-RF 模型的黄骅市耕地土壤含盐量空间分布

Fig.7 Spatial distribution of cultivated land SSC in Huanghua City estimated by Sentinel-2_Transformer-RF model

化土壤表层盐分累积后反射率增强、植被覆盖削弱土壤背景光谱响应的特征基本一致。总体来看, Sentinel-2_Transformer-RF 模型能反映黄骅市耕地区域 SSC 的空间分异特征, 可为滨海盐渍化农田 SSC 空间分布推算提供方法参考。

3 讨论

与已有土壤含盐量遥感估算研究相比, 本文更侧重于在同步 UAV 高光谱与 Sentinel-2 MSI 观测条件下, 分析 Transformer 光谱匹配对卫星影像含盐量敏感信息表达的改善作用。已有研究表明, 卫星、无人机及多源遥感数据均可用于土壤含盐量估算, 但由于含盐量指标、数据源类型、观测时相、地表覆盖状况、建模方法和验证方式存在差异, 不同研究的估算精度具有一定差别^[7,20-22]。在此基础上, 本文在统一 RF 建模流程下比较原始 Sentinel-2 MSI、Sentinel-2_MLP 和 Sentinel-2_Transformer 数据源估算效果, 重点分析光谱匹配对 Sentinel-2 MSI 影像 SSC 估算的相对增益。结果表明, Transformer 光谱匹配能增强 Sentinel-2 MSI 影像的含盐量敏感信息表达, 并为滨海盐渍化农田星机协同 SSC 估算提供方法参考。

从不同光谱匹配方法看, Transformer 光谱匹配效果优于 MLP。MLP 能校正部分波段反射率偏差, 但对多波段光谱序列内部依赖关系的表达能力有限; Transformer 可将 Sentinel-2 MSI 多波段反射率视为光谱序列, 学习不同波段间的关联关系^[13]。本文结果显示, 经 Transformer 光谱匹配后, Sentinel-2 MSI 影像的波段反射率分布更接近 UAV 高光谱参考影像, 含盐量敏感特征与 SSC 的相关性增强, 说明 Transformer 光谱匹配能改善 Sentinel-2 MSI 影像对 SSC 的光谱响应表达能力^[23]。

从 SSC 估算结果看, UAV-RF 模型精度最高,

说明 UAV 高光谱影像在田间尺度土壤含盐量监测中具有更强的光谱表达能力^[24-25]。同时, UAV 影像还可提供田块纹理和局部空间结构信息, 有助于刻画田间尺度土壤含盐量空间异质性^[26]。但 UAV 影像覆盖范围有限, 难以直接支撑区域尺度连续制图。相比之下, Sentinel-2 MSI 影像具有区域连续覆盖优势, 但原始 Sentinel-2-RF 模型精度相对较低, 主要受波段设置、光谱分辨率和空间分辨率 10 m 限制。本文影像和样本获取于 6 月, 研究区农田处于裸露耕地与作物覆盖并存阶段, 且耕地、盐碱裸地、养殖塘、道路和建设用地交错分布, 不同地物易在 Sentinel-2 像元内混合, 削弱单一像元反射率与表层 SSC 的对应关系。已有研究指出, Sentinel-2 MSI 可用于土壤含盐量估算, 但精度受波段设置、地表覆盖和样本条件等因素影响^[27]。因此, 以 UAV 高光谱影像为参考开展光谱匹配, 有助于增强 Sentinel-2 MSI 影像的含盐量敏感信息表达。

从区域空间分布结果看, 基于 Sentinel-2_Transformer-RF 模型获得的黄骅市耕地 SSC 空间分布呈斑块状差异, 反射率较高、植被覆盖较低地块多对应较高 SSC 推算值, 而植被覆盖较好地块推算值相对较低, 这与盐渍化土壤表层盐分累积后反射率增强、植被覆盖削弱土壤背景光谱响应的特征基本一致^[19]。结果表明, Transformer 光谱匹配后 Sentinel-2 MSI 影像能反映滨海盐渍化农田耕地 SSC 的空间分异特征。后续可进一步增加多季节、多年份同步 UAV-Sentinel-2 观测数据^[28]; 引入 Sentinel-1 SAR、地形因子、土壤含水率和气象变量等辅助信息^[29]; 并结合波段注意力权重分析、更多像元级配对样本和区域尺度验证数据, 提升方法在不同农田场景下稳定性和泛化能力^[30]。

4 结论

(1) 光谱匹配能减弱 Sentinel-2 MSI 影像与 UAV 高光谱影像之间的跨传感器光谱差异。与原始 Sentinel-2 MSI 影像相比, Sentinel-2_MLP 和 Sentinel-2_Transformer 波段反射率分布均向 UAV 高光谱影像靠近, 其中 Sentinel-2_Transformer 在反射率分布和含盐量敏感特征相关性方面表现更优。

(2) Transformer 光谱匹配能在一定程度上提高 Sentinel-2 MSI 影像的 SSC 估算精度。Sentinel-2-RF、Sentinel-2_MLP-RF 和 Sentinel-2_Transformer-RF 模型 R^2 分别为 0.37、0.45 和 0.49, RMSE 分别为 0.82、0.77、0.74 g/kg。与 Sentinel-2-RF 相比, Sentinel-2_Transformer-RF 的 R^2 提高 0.12, RMSE 降低 0.08 g/kg, 说明 Transformer 光谱匹配能改善

Sentinel-2 MSI 影像的 SSC 估算效果。

(3) 基于 Sentinel-2_Transformer-RF 模型获得的黄骅市耕地 SSC 空间分布能反映研究区含盐量斑块状差异, 说明 Transformer 光谱匹配后 Sentinel-2 MSI 影像具有滨海盐渍化农田 SSC 空间分布推算潜力。后续可结合更多样本、多时相影像和多源辅助变量进一步提升方法的区域适用性。

参 考 文 献

[1] Rozema J, Flowers T. Crops for a salinized world[J]. *Science*, 2008, 322(5907): 1478-1480.

[2] Metternicht G I, Zinck J A. Remote sensing of soil salinity: potentials and constraints[J]. *Remote Sensing of Environment*, 2003, 85(1): 1-20.

[3] Kaplan G, Gašparović M, Alqasemi A S, et al. Soil salinity prediction using machine learning and Sentinel-2 remote sensing data in hyper-arid areas[J]. *Physics and Chemistry of the Earth, Parts A/B/C*, 2023, 130: 103400.

[4] Jia P, Zhang J, Liang Y, et al. The inversion of arid-coastal cultivated soil salinity using explainable machine learning and Sentinel-2[J]. *Ecological Indicators*, 2024, 166: 112364.

[5] 张智韬, 贺玉洁, 殷皓原, 等. 基于 Sentinel-1/2 改进极化指数和纹理特征的土壤含盐量反演模型[J]. *农业机械学报*, 2024, 55(1): 175-185.

Zhang Zhitao, He Yujie, Yin Haoyuan, et al. Synergistic estimation of soil salinity based on Sentinel-1/2 improved polarization combination index and texture features[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(1): 175-185. (in Chinese)

[6] Lao C, Yu X, Zhan L, et al. Monitoring soil salinity in coastal wetlands with Sentinel-2 MSI data: combining fractional-order derivatives and stacked machine learning models[J]. *Agricultural Water Management*, 2024, 306: 109147.

[7] Qi G, Chang C, Yang W, et al. Soil salinity inversion in coastal corn planting areas by the satellite-UAV-ground integration approach[J]. *Remote Sensing*, 2021, 13(16): 3100.

[8] Ma Y, Zhu W, Zhang Z, et al. Fusion level of satellite and UAV image data for soil salinity inversion in the coastal area of the Yellow River Delta[J]. *International Journal of Remote Sensing*, 2022, 43(19-24): 7039-7063.

[9] Chen H, Ma Y, Zhu A, et al. Soil salinity inversion based on differentiated fusion of satellite image and ground spectra[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2021, 101: 102360.

[10] 董雨昕, 韩文霆, 崔欣, 等. 基于无人机与 Sentinel-2A 遥感数据协同的裸土期土壤含盐量反演[J]. *农业机械学报*, 2025, 56(6): 434-445.

Dong Yuxin, Han Wenting, Cui Xin, et al. Soil salinity inversion during bare soil period based on collaboration of UAV and Sentinel-2A remote sensing data[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2025, 56(6): 434-445. (in Chinese)

[11] 陈俊英, 王新涛, 张智韬, 等. 基于无人机-卫星遥感升尺度的土壤盐渍化监测方法[J]. *农业机械学报*, 2019, 50(12): 161-169.

Chen Junying, Wang Xintao, Zhang Zhitao, et al. Soil salinization monitoring method based on UAV-satellite remote sensing scale-up[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2019, 50(12): 161-169. (in Chinese)

[12] Roy D P, Kovalskyy V, Zhang H K, et al. Characterization of Landsat-7 to Landsat-8 reflective wavelength and normalized difference vegetation index continuity[J]. *Remote Sensing of Environment*, 2016, 185: 57-70.

[13] Aleissae A A, Kumar A, Anwer R M, et al. Transformers in remote sensing: a survey[J]. *Remote Sensing*, 2023, 15(7): 1860.

[14] Zhang S, Zhao G. A harmonious satellite-unmanned aerial vehicle-ground measurement inversion method for monitoring salinity in coastal saline soil[J]. *Remote Sensing*, 2019, 11(14): 1700.

[15] Bannari A, Guedon A M, El-Harti A, et al. Characterization of slightly and moderately saline and sodic soils in irrigated agricultural land using simulated data of advanced land imaging (EO-1) sensor[J]. *Communications in Soil Science and Plant Analysis*, 2008, 39(19-20): 2795-2811.

[16] Allbed A, Kumar L, Aldakheel Y Y. Assessing soil salinity using soil salinity and vegetation indices derived from IKONOS high-spatial resolution imageries: Applications in a date palm dominated region[J]. *Geoderma*, 2014, 230-231: 1-8.

[17] Bouaziz M, Matschullat J, Gloaguen R. Improved remote sensing detection of soil salinity from a semi-arid climate in Northeast Brazil[J]. *Comptes Rendus. Géoscience*, 2011, 343(11-12): 795-803.

[18] Breiman L. Random forests[J]. *Machine Learning*, 2001, 45(1): 5-32.

[19] Zhang J, Zhang Z, Chen J, et al. Estimating soil salinity with different fractional vegetation cover using remote sensing[J]. *Land Degradation & Development*, 2021, 32(2): 597-612.

[20] Duan C, Zhang Y, Hu C, et al. Soil salinity inversion by combining multi-temporal Sentinel-2 images near the sampling period in coastal salinized farmland[J]. *Frontiers in Environmental Science*, 2025, 13: 1533419.

[21] Hu X, Han D, Qin Q, et al. Coastal soil salinity inversion using UAV multispectral imagery and an interpretable stacking algorithm[J]. *Remote Sensing*, 2026, 18(5): 671.

[22] Alamdar S, Ghazban F, Zarei A. Efficiency of machine learning algorithms in soil salinity detection using Landsat-8 OLI

- imagery[J/OL]. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2023. <https://doi.org/10.5194/isprs-annals-X-4-W1-2022-49-2023>.
- [23] Wang Y, Qu Z, Yang W, et al. Inversion of soil salinity in the irrigated region along the southern bank of the Yellow River using UAV multispectral remote sensing[J]. *Agronomy*, 2024, 14(3): 523.
- [24] Hu J, Peng J, Zhou Y, et al. Quantitative estimation of soil salinity using UAV-borne hyperspectral and satellite multispectral images[J]. *Remote Sensing*, 2019, 11(7): 736.
- [25] 张智韬, 魏广飞, 姚志华, 等. 基于无人机多光谱遥感的土壤含盐量反演模型研究[J]. *农业机械学报*, 2019, 50(12): 151–160.
- Zhang Zhitao, Wei Guangfei, Yao Zhihua, et al. Soil salt inversion model based on UAV multispectral remote sensing[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2019, 50(12): 151–160. (in Chinese)
- [26] Zhai J, Wang N, Hu B, et al. Estimation of soil salinity by combining spectral and texture information from UAV multispectral images in the Tarim River Basin, China[J]. *Remote Sensing*, 2024, 16(19): 3671.
- [27] Mzid N, Boussadia O, Albrizio R, et al. Salinity properties retrieval from Sentinel-2 satellite data and machine learning algorithms[J]. *Agronomy*, 2023, 13(3): 716.
- [28] Li Y, Chang C, Wang Z, et al. Upscaling remote sensing inversion and dynamic monitoring of soil salinization in the Yellow River Delta, China[J]. *Ecological Indicators*, 2023, 148: 110087.
- [29] Mohamed S A, Metwaly M M, Metwalli M R, et al. Integrating active and passive remote sensing data for mapping soil salinity using machine learning and feature selection approaches in arid regions[J]. *Remote Sensing*, 2023, 15(7): 1751.
- [30] He Y, Zhang Z, Xiang R, et al. Monitoring salinity in bare soil based on Sentinel-1/2 image fusion and machine learning[J]. *Infrared Physics & Technology*, 2023, 131: 104656.

(上接第 93 页)

- [21] Ma G, Ding J, Han L, et al. Digital mapping of soil salinization based on Sentinel-1 and Sentinel-2 data combined with machine learning algorithms[J]. *Regional Sustainability*, 2021, 2(2): 177–188.
- [22] Duan M, Song X, Liu X, et al. Mapping the soil types combining multi-temporal remote sensing data with texture features[J]. *Computers and Electronics in Agriculture*, 2022, 200: 107230.
- [23] 刘浩, 杨锡震, 张蓓, 等. 基于分数阶微分光谱指数的冬小麦根域土壤含水率估算模型[J]. *农业工程学报*, 2023, 39(13): 131–140.
- Liu Hao, Yang Xizhen, Zhang Bei, et al. Estimation model of soil moisture content in root domain of winter wheat using a fractional-order differential spectral index[J]. *Transactions of the CSAE*, 2023, 39(13): 131–140. (in Chinese)
- [24] Ångström A. The albedo of various surfaces of ground[J]. *Geografiska Annaler*, 1925, 7(4): 323–342.
- [25] Sheridan R P, Wang W M, Liaw A, et al. Extreme gradient boosting as a method for quantitative structure-activity relationships[J]. *Journal of Chemical Information and Modeling*, 2016, 56(12): 2353–2360.
- [26] Wang L, Zhang Y, Yao Y, et al. GBRT-based estimation of terrestrial latent heat flux in the Haihe River Basin from satellite and reanalysis datasets[J]. *Remote Sensing*, 2021, 13(6): 1054.
- [27] Bartlett P L, Traskin M. AdaBoost is consistent[J]. *Journal of Machine Learning Research*, 2007, 8: 2347–2368.
- [28] Prakash R, Singh D, Pathak N P. A fusion approach to retrieve soil moisture with SAR and optical data[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2012, 5(1): 196–206.
- [29] Li S, Zhu P, Song N, et al. Regional soil moisture estimation leveraging multi-source data fusion and automated machine learning[J]. *Remote Sensing*, 2025, 17(5): 837.
- [30] Wang J, Ding J L, Chen W Q, et al. Microwave modeling of soil moisture in oasis regional scale based on Sentinel-1 radar images[J]. *Journal of Infrared and Millimeter Waves*, 2017, 36(1): 120–126.
- [31] Das A, Bhattacharya B K, Setia R, et al. A novel method for detecting soil salinity using AVIRIS-NG imaging spectroscopy and ensemble machine learning[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2023, 200: 191–212.
- [32] Azizi K, Garosi Y, Ayoubi S, et al. Integration of Sentinel-1/2 and topographic attributes to predict the spatial distribution of soil texture fractions in some agricultural soils of western Iran[J]. *Soil and Tillage Research*, 2023, 229: 105681.
- [33] Shokati H, Mashal M, Noroozi A, et al. Random forest-based soil moisture estimation using Sentinel-2, Landsat-8/9, and UAV-based hyperspectral data[J]. *Remote Sensing*, 2024, 16(11): 1962.
- [34] Zribi M, Muddu S, Bousbih S, et al. Analysis of L-Band SAR data for soil moisture estimations over agricultural areas in the tropics[J]. *Remote Sensing*, 2019, 11(9): 1122.
- [35] Lal P, Singh G, Das N N, et al. A multi-scale algorithm for the NISAR mission high-resolution soil moisture product[J]. *Remote Sensing of Environment*, 2023, 295: 113667.
- [36] 周鹏, 丁建丽, 王飞, 等. 植被覆盖地表土壤水分遥感反演[J]. *遥感学报*, 2010, 14(5): 966–981.
- Zhou Peng, Ding Jianli, Wang Fei, et al. Retrieval methods of soil water content in vegetation covering areas based on multi-source remote sensing data[J]. *Journal of Remote Sensing*, 2010, 14(5): 966–981. (in Chinese)