



陈猷,申晓晶,周博,等.基于遥感影像与随机森林算法的银北灌区土壤盐渍化监测方法研究[J].江西农业大学学报,2025,47(3):803-816.

CHEN Y, SHEN X J, ZHON B, et al. Monitoring method of soil salinization in Yinbei Irrigation Area based on remote sensing images and random forest algorithm[J]. Acta agriculturae universitatis Jiangxiensis, 2025, 47(3): 803-816.

# 基于遥感影像与随机森林算法的银北灌区土壤盐渍化监测方法研究

陈猷,申晓晶\*,周博,田佳珂,王拓,栾文杰

(宁夏大学 土木与水利工程学院,宁夏 银川 750021)

**摘要:**【目的】土壤盐渍化是影响农业生产和生态环境的重要问题,传统的大面积土壤盐渍化监测方法耗时耗力且成本高昂。随着遥感技术和机器学习算法的发展,快速、准确且非破坏性的土壤盐渍化监测成为可能,为相关农业生产活动及土地管理提供科学依据。【方法】以宁夏惠农区礼和乡的玉米地为研究对象,利用 Sentinel-2 SR 遥感影像和 Google Earth Engine (GEE) 平台数据,结合实地测得的土壤电导率(EC)值,开展基于随机森林算法的土壤盐渍化监测研究。通过筛选光谱特征,构建多种光谱特征组合模型,并采用随机森林算法进行训练与评估,对比  $R^2$ 、MSE 和 RMSE 等评价指标,以探寻最优的土壤盐渍化监测模型。【结果】(1)加入光谱指数的随机森林模型在玉米地提取中的总体精度从 0.876 (Kappa 系数为 0.842) 提升至 0.972 (Kappa 系数为 0.965), 提高约 9.6%, 分类结果边界更加清晰, 分辨能力显著提高。(2)在土壤含盐量估算模型中,基于随机森林算法的不同光谱指数组合表现各异。其中,组合 1 (SI-T, GRNDVI) 表现最佳,其决定系数 ( $R^2$ ) 达到 0.94, 均方误差 (MSE) 为 0.29, 均方根误差 (RMSE) 为 0.53; 组合 2 (SI-T, S7, NLI, GBNDVI) 和组合 3 (SI-T, GRNDVI, GBNDVI) 的表现依次递减。【结论】随机森林算法在土壤盐渍化监测中具有较高的预测精度和稳定性,能够有效捕捉土壤盐渍化的细微变化。研究为宁夏惠农区礼和乡的精准灌溉、盐渍化防治及土地管理提供了科学依据与技术支持,展示了遥感与机器学习技术在土壤盐渍化监测领域的良好应用前景。未来研究可进一步探索深度学习模型在土壤盐渍化监测中的应用,以提高模型的泛化能力和预测精度。

**关键词:** 遥感影像; 特征选择; 土壤盐渍化; 随机森林; 玉米地提取; 宁夏; GEE 平台数据

中图分类号: S159.2 文献标志码: A

开放科学(资源服务)标识码(OSID):

文章编号: 1000-2286(2025)03-0803-14

CSTR: 32399.14. auuj. 2025069



## Monitoring method of soil salinization in Yinbei Irrigation Area based on remote sensing images and random forest algorithm

CHEN You, SHEN Xiaojing\*, ZHOU Bo, TIAN Jiake, WANG Tuo, LUAN Wenjie

(School of Civil and Hydraulic Engineering, Yinchuan 750021, China)

收稿日期: 2024-12-16 修回日期: 2025-02-06

基金项目: 宁夏自然科学基金优秀青年项目(2024AAC05048)和国家重点研发计划项目(2021YFD1900600)

Project supported by the Outstanding Youth Project of Ningxia Natural Science Foundation(2024AAC05048) and National Key Research and Development Plan Project(2021YFD1900600)

作者简介: 陈猷, 硕士生, orcid.org/0009-0002-3530-9991, cy01144563@163.com; \*通信作者: 申晓晶, 讲师, 博士, 主要从事气候变化与水资源安全调控研究, orcid.org/0000-0001-8423-4338, sxj15191418250@126.com。

©《江西农业大学学报》编辑部, 开放获取 CC BY-NC-ND 协议

**Abstract:** [Objective] Soil salinization is a significant issue affecting agricultural production and the ecological environment. Traditional methods for large-scale soil salinization monitoring are time-consuming, labor-intensive, and costly. With the advancement of remote sensing technology and machine learning algorithms, rapid, accurate, and non-destructive soil salinization monitoring has become feasible, providing scientific support for agricultural activities and land management. [Method] Taking the cornfields in Lihe Township, Huinong District, Ningxia as the research object, this study utilized Sentinel-2 SR remote sensing imagery and Google Earth Engine (GEE) platform data, combined with field-measured soil electrical conductivity (EC) values, to conduct soil salinization monitoring based on the Random Forest algorithm. By screening spectral features, multiple spectral feature combination models were constructed, and the Random Forest algorithm was employed for training and evaluation. The  $R^2$ , MSE, and RMSE metrics were compared to identify the optimal soil salinization monitoring model. [Result] (1) The Random Forest model with added spectral indices improved the overall accuracy of cornfield extraction from 0.876 (Kappa coefficient: 0.842) to 0.972 (Kappa coefficient: 0.965), an increase of approximately 9.6%. The classification results exhibited clearer boundaries and significantly enhanced resolution. (2) In the soil salinity estimation models, different spectral index combinations based on the Random Forest algorithm showed varying performance. Among them, Combination 1 (SI-T, GRNDVI) performed the best, with a coefficient of determination ( $R^2$ ) of 0.94, a mean squared error (MSE) of 0.29, and a root mean squared error (RMSE) of 0.53. The performance of Combination 2 (SI-T, S7, NLI, GBNDVI) and Combination 3 (SI-T, GRNDVI, GBNDVI) decreased in that order. [Conclusion] The study demonstrates that the Random Forest algorithm has high predictive accuracy and stability in soil salinization monitoring, effectively capturing subtle changes in soil salinity. The research provides scientific and technical supports for precision irrigation, salinization control, and land management in Lihe Town. It also showcases the promising application of remote sensing and machine learning technologies in soil salinization monitoring. Future research could further explore the application of deep learning models to improve the generalization ability and predictive accuracy of soil salinization monitoring.

**Keywords:** remote sensing images; feature selection; soil salinization; random forest; cornfield extraction; Ningxia; GEE platform data

【研究意义】我国盐渍土面积广泛,种类繁多,盐渍化问题尤为突出,给农业生产和生态环境带来了不同程度的影响<sup>[1]</sup>。截至2021年,我国盐碱地总面积约为1亿 $\text{hm}^2$ ,其中具备近期农业利用潜力的盐碱地面积约为666.67万 $\text{hm}^2$ ,主要分布在宁夏、新疆、河北、内蒙古和吉林等地<sup>[2]</sup>。在这些地区中,宁夏引黄灌区的盐碱地面积已达到14.79万 $\text{hm}^2$ ,占该区域耕地总面积的33.54%<sup>[3]</sup>。受全球气候变暖及人类活动的双重影响,土壤盐渍化已成为制约农业发展和资源可持续利用的重要因素,也是土地退化的主要原因,严重影响区域生态环境的稳定、粮食安全及农业的可持续发展<sup>[4]</sup>。因此,精确获取土壤盐渍化在多尺度和多要素上的时空动态,对于深入分析自然因素与人为活动驱动下的盐渍化演变机制具有重要意义<sup>[1]</sup>。【前人研究进展】传统的土壤盐分监测方法依赖田间取样和实验室分析,尽管具有较高的精确度,但在大范围监测中往往耗时耗力且成本高昂,且难以实时获取动态数据。相比之下,遥感技术作为一种新兴的监测手段,在大尺度监测中具有显著优势。近年来,随机森林算法凭借其高效性、稳健性和精确性,逐渐被应用于土壤盐分估算领域<sup>[5]</sup>。该算法通过构建多个决策树并进行集成学习,不仅能有效减少过拟合风险,还能增强模型的泛化能力,因此在土壤盐分估算中表现出了优异的性能<sup>[6]</sup>。随机森林算法能够建立实测土壤盐分与土壤光谱信息之间复杂的非线性关系,有效处理大量高维数据,并充分利用传感器获取的光谱信息,从而显著提高了估算精度<sup>[7-9]</sup>。张智韬等<sup>[10]</sup>利用无人机多光谱影像对内蒙古河套灌区进行研究,发现随机森林算法在盐分反演中优于支持向量机和BP神经网络。Wang等<sup>[11]</sup>在塔里木河流域研究中,利用随机森林算法对不同土层(0.2~0.4 m、0.4~0.6 m、0.6~0.8 m和0.8~1 m)进行盐分预测,结果表明,EC的预测精度在表层和较深土层较高( $R^2 < 0.65$ )。刘霞等<sup>[12]</sup>以达拉特旗黄河南岸盐碱地为研究对象,基

于 Sentinel-1、Sentinel-2、Landsat-8 和 SRTM DEM 多源数据运用 6 种模型进行春季裸土期与植被覆盖期土壤含盐量估算,发现随机森林算法的  $R^2$  可达到 0.73。洪国军等<sup>[13]</sup>利用 Sentinel-2 SR 和 Landsat-9 OLI 的多光谱遥感影像数据,采用穷举特征组合和交叉验证方法,比较 4 种机器学习模型(XGBoost, 随机森林,深度神经网络和 K-近邻)的土壤盐渍化反演精度,发现随机森林无论是在 Sentinel-2 SR 还是在 Landsat-9 OLI 都表现良好。李小雨等<sup>[6]</sup>以银川平原为研究区,利用谷歌地球引擎平台,基于随机森林算法,通过建立光谱指数特征与地面实测土壤含盐量之间的关系,进行土壤含盐量估算。近年来随机森林模型已作为一种集成土壤盐渍化的变化分析与预测的学习方法。

【本研究切入点】尽管机器学习和遥感技术在土壤盐渍化监测中取得了一定进展,但基于不同光谱指数组合的详细对比研究仍然较为有限。利用 Sentinel-2 SR 遥感影像和 Google Earth Engine(GEE)平台数据,结合实地测得的土壤电导率(EC)值,针对宁夏惠农区礼和乡的玉米地土壤盐渍化进行了遥感监测。研究通过筛选不同波段的光谱特征,评估并建立了多种光谱特征组合的模型,采用随机森林(RF)算法对这些模型进行训练与评估,从而构建了玉米地土壤盐渍化的估算模型。【拟解决的关键问题】通过对比分析不同组合的  $R^2$ 、MSE 和 RMSE 评价指标,旨在找到最优的盐渍化监测模型,以实现宁夏惠农区礼和乡玉米地土壤盐渍化的快速、准确和非破坏性监测。研究结果不仅为该区域的精准灌溉提供了科学依据,还为盐渍化防治和土地管理提供了重要的技术支持,具有较强的应用前景。

## 1 材料与方 法

### 1.1 研究区域概况

礼和乡( $38^{\circ}59' \sim 39^{\circ}06'N, 106^{\circ}45' \sim 106^{\circ}52'E$ )位于宁夏回族自治区石嘴山市惠农区,海拔 1 091~1 093 m。此地为黄河冲积平原,土壤黏重且渗透性不佳,导致地下水侧向流动受阻,部分土壤出现盐碱化现象<sup>[2]</sup>。境内河道属于黄河流域,惠农渠与滂渠纵贯南北,第七排水沟横穿东西。主要农作物有小麦、玉米和豆类,其中玉米的种植面积最大且分布广泛。气候上,夏季炎热干燥,冬季寒冷干燥,季节间温差较大。年均降水量约为 292 mm,年均蒸发量为 2 444 mm,年平均气温为  $8.3^{\circ}C$ ,蒸发量远超降水量,加

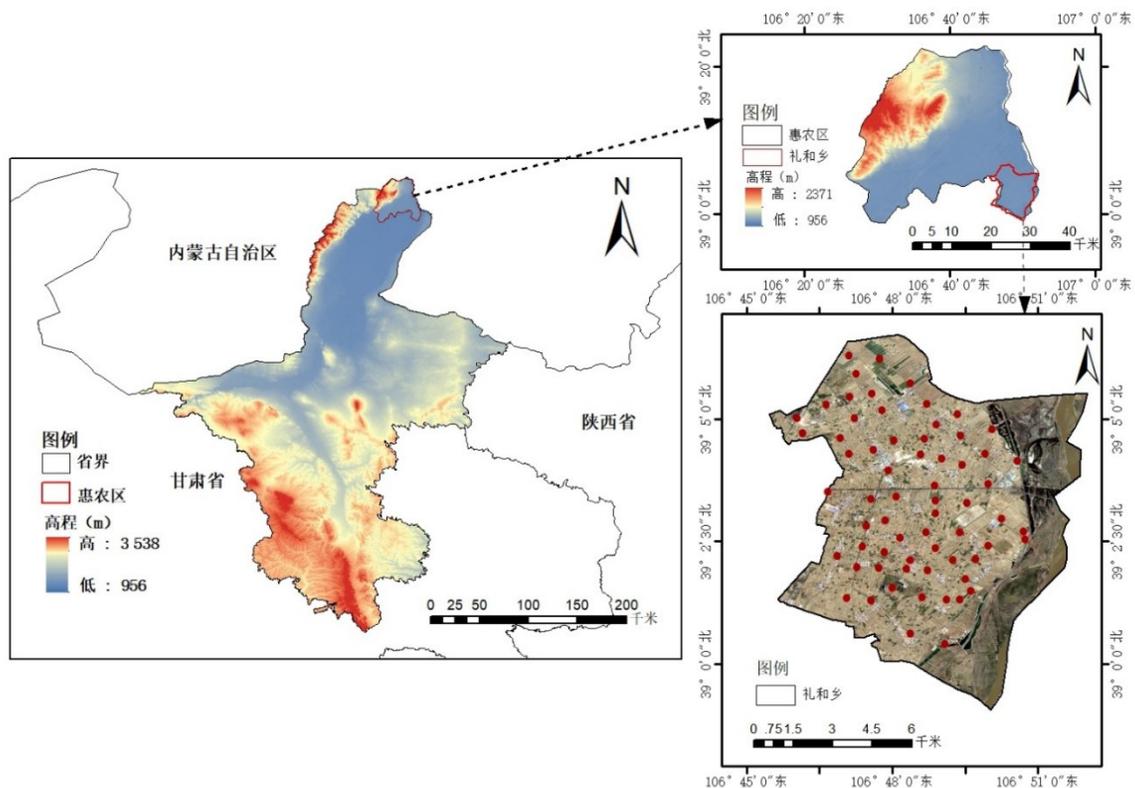


图1 研究区域概况及采样点分布

Fig.1 Overview of the study area and distribution of sampling points.

剧了土壤盐渍化。年平均无霜期为 159 d,年平均风速为 1.8 m/s。礼和乡为引黄灌区,灌溉水的平均矿化度约为 0.5 g/L。因黄河水的顶托作用,该地区地下水的矿化度较高,范围在 2.91~4.72 g/L,地下水埋深通常在 1.32~1.98 m<sup>[2]</sup>。

### 1.2 数据来源

样本采集时间为 2024 年 5 月 20 日,使用五点采样法采集 0~20 cm 表层土壤样本,在采样过程中,使用 GPS 手持仪记录采样点的经纬度,同时记录采样点的编号、土地利用、植被长势等信息。为避免采集杂质和表层覆盖物,将所有土壤样本剔除荒草和碎石块等后放入温度设置为 105°的烘箱,烘干 8 h 去除水分,研磨后 1 mm 筛,以水土比 5:1 配置提取液,使用电导率仪(MTD15 型)测量电导率。土壤含盐量(SSC,%)计算公式需要进行大量土壤电导率与烘干盐渍对应关系试验,标定出土壤电导率与土壤含盐量之间的关系为<sup>[14]</sup>:

$$Y=0.005\ 495\ 1\times X-0.001\ 31(R^2=0.998) \tag{1}$$

式(1)中:Y为土壤的含盐量,g/kg;X为土壤的电导率,μS/cm。

多光谱影像使用的是 Sentinel-2 SR 地表反射率数据,来自 GEE 云平台。这些数据基于 WGS84 基准面,并采用 UTM 投影方式。该数据集由两颗卫星(Sentinel-2A/B)共同提供,能够实现数据互补,确保每 5 天生成 1 张新的图像。作为极轨卫星,Sentinel-2A/B 的轨道周期为 100 min,轨道高度为 786 km,扫描宽度覆盖约 290 km 的广阔区域,且轨道倾角为 98.62°。MSI 传感器提供多种分辨率的波段数据,其中包括 3 个 60 m 空间分辨率的波段、4 个 10 m 空间分辨率的波段和 6 个 20 m 空间分辨率的波段。为了确保数据的质量,使用了 filter 函数筛选云量低于 10% 的影像。研究选取了 2024 年 5 月 15—25 日期间的影像数据,确保与野外采样时间(2024 年 5 月 20 日)相匹配,利用 QA 波段提供的云掩膜信息,进行去云处理。此外,这些影像在获取前已完成几何校正、辐射校正和大气校正,确保了数据的准确性和可靠性。

### 1.3 研究区预处理

牛乾坤等<sup>[15]</sup>基于 GEE 云计算平台,发现通过随机森林算法能够显著提升河套灌区作物分类精度与效率。此外,Abubakar 等<sup>[16]</sup>也利用 GEE 平台,采用随机森林、支持向量机和分类回归树等算法进行农作物分类,研究结果显示,随机森林在区分玉米农田与其他土地覆盖类型方面表现最佳。Luan 等<sup>[17]</sup>通过支持向量机和随机森林分类技术,对惠农区的玉米种植区进行了识别,并发现随机森林在农田识别中的表现优于支持向量机。

为了进一步提高土地分类的精度和效率,研究采用结合光谱指数的随机森林算法进行玉米地提取。将建筑物指数<sup>[18]</sup>(IBI)、增强型裸土指数<sup>[19]</sup>(BSI)、归一化差分水体指数<sup>[20]</sup>(NDWI)、归一化植被指数<sup>[21]</sup>(NDVI)、增强植被指数<sup>[21]</sup>(EVI)和数字高程模型(DEM)加入其中。该研究在 GEE 平台上建立了一个包含 63 个水体样本、100 个建筑样本、124 个道路样本、148 个玉米样本和 101 个其他作物样本的数据集,其中 70% 的样本用于训练,30% 用于测试。试验中,研究对比了 2 种随机森林模型:一种加入了光谱指数(表 1),另一种未加入光谱指数。

表 1 加入随机森林的光谱指数计算公式

Tab.1 Spectral index calculation formulas with random forest integration

光谱指数 Spectral index	计算公式 Calculation formula	作用 Function
NDVI	$(NIR-R)/(NIR+R)$	测量植被的密度和健康状况
NDWI	$(G-NIR)/(G+NIR)$	增强水体信息
EVI	$(1+M)\times(NIR-R)/(NIR+C_1\times R-C_2\times B+M)$	增强了对高密度植被的敏感度
BSI	$[(R+SWIR1)-(NIR+B)]/[(R+SWIR1)+(NIR+B)]$	区分裸露土壤与植被和水体
IBI	$IBI=[NDBI-(SAVI+NDWI)/2]/[NDBI+(SAVI+NDWI)/2]$	结合多个指数增强建筑物信息

B、G、R、NIR、SWIR1 分别为蓝、绿、红、红边 1、近红外、短波红外 1 波段。C<sub>1</sub>(大气校正系数,取 6)、C<sub>2</sub>(大气校正系数,取 7.5)、L(土壤调整因子,取 0.5)、M(地表背景校正系数,取 0.5)。

B, G, R, NIR, SWIR1 represent the blue, green, red, red-edge 1, near-infrared, and shortwave infrared 1 bands, respectively. C<sub>1</sub>(atmospheric correction coefficient, set to 6), C<sub>2</sub>(atmospheric correction coefficient, set to 7.5), L(soil adjustment factor, set to 0.5), M(surface background correction coefficient, set to 0.5).

### 1.4 计算光谱指数

土壤盐渍化成因复杂,盐分组成差异大,所以在进行土壤盐分遥感监测时,不同地区敏感波段的选择和盐分指数的运用会有不同。故而,选好合适的特征变量对监测结果的准确性极为关键<sup>[22]</sup>。尤其在干旱和半干旱地区,光谱指数已被证明是有效的土壤盐渍化监测工具<sup>[5]</sup>。

在遥感数据的处理过程中,基于 Sentinel-2 SR 数据计算了 20 个盐分光谱指数与 20 个植被指数:盐分指数<sup>[23]</sup>(SI、SI<sub>1</sub>、SI<sub>2</sub>、SI<sub>3</sub>、SI<sub>4</sub>、SI-T)、盐渍化指数<sup>[24]</sup>(S1、S2、S3、S5、S6、S7、S8、S9)、土壤盐分与碱度指数 1<sup>[21]</sup>(SSSI-1)、土壤盐分与碱度指数 2<sup>[21]</sup>(SSSI-2)、归一化盐分指数<sup>[21]</sup>(NDSI)、冠层响应盐分指数<sup>[25]</sup>(CRSI)、盐度反射指数(SRSI)、大气叠加盐度指数<sup>[21]</sup>(SAIO)。植被指数:比值植被指数<sup>[26]</sup>(RVI)、增强植被指数<sup>[26]</sup>(ENDVI)、红外百分比植被指数<sup>[21]</sup>(IPVI)、非线性指数<sup>[21]</sup>(NLI)、增强型归一化植被指数<sup>[21]</sup>(ENDVI)、广义植被指数<sup>[21]</sup>(GDVI)、红边拐点植被指数<sup>[27]</sup>(REIP)、修改型土壤调整植被指数<sup>[28]</sup>(MSAVI)、归一化植被指数<sup>[21]</sup>(NDVI)、全色增强植被指数<sup>[21]</sup>(GARI)、差值植被指数<sup>[25]</sup>(DVI)、绿光归一化差值植被指数<sup>[28]</sup>(GNDVI)、增强植被指数<sup>[21]</sup>(EVI)、增强型植被指数 2<sup>[29]</sup>(EVI2)、优化土壤调节植被指数<sup>[21]</sup>(OSAVI)、土壤调节型植被指数<sup>[13]</sup>(SA-VI)、全球植被水分指数<sup>[21]</sup>(GVMI)、绿-蓝波段归一化差值植被指数<sup>[13]</sup>(GBNDVI)、绿-红波段归一化差值植被指数<sup>[13]</sup>(GRNDVI)、扩展的增强型植被指数<sup>[30]</sup>(EEVI)这些指数在不同的土壤盐渍化监测研究中都有广泛应用。通过结合这些光谱指数,可以更全面、准确地评估土壤盐渍化程度。计算公式如表 2 与表 3 所示。

表 2 盐分指数计算公式  
Tab.2 Calculation formula for salt index

名称 Name	计算公式 Calculation formula	名称 Name	计算公式 Calculation formula
SI	$(G+R)^{0.5}$	S7	$(SWIR1-SWIR2)/(SWIR1+SWIR2)$
SI <sub>1</sub>	$(G \times R)^{0.5}$	S8	$(G+R)/2$
SI <sub>2</sub>	$(NIR^2+G^2+R^2)^{0.5}$	S9	$(G+R+NIR)/2$
SI <sub>3</sub>	$(G^2+R^2)^{0.5}$	SI-T	$(R/NIR) \times 100$
SI <sub>4</sub>	SWIR1/NIR	SSSI-1	R-NIR
S1	B/R	SSSI-2	$(R \times NIR - NIR \times NIR) / R$
S2	$(B-R)/(B+R)$	NDSI	$(NIR-SWIR1)/(NIR+SWIR1)$
S3	$(G \times R) / B$	CRSI	$[(NIR \times R - G \times B) / (NIR \times R + G \times B)]^{0.5}$
S5	$(B \times R) / G$	SRSI	$[(NDVI-1)^2+SI_2]^{0.5}$
S6	$(R \times NIR) / G$	SAIO	$(G-NIR)/(B+NIR)$

B、G、R、NIR、SWIR1、SWIR2 分别代表蓝、绿、红、近红外、短波红外 1、短波红外 2 波段。

B, G, R, NIR, SWIR1, and SWIR2 represent the Blue, Green, Red, Near Infrared, Shortwave Infrared 1, and Shortwave Infrared 2 bands, respectively.

### 1.5 筛选算法构建

为让各特征在模型里量纲相同、影响力均衡,先对特征数据做标准化处理。用 StandardScaler 把数据归一化,让每个特征均值为 0,标准差为 1。再把处理后的数据集按 7:3 分成训练集与测试集。

构建模型时,选用 XGBoost(极端梯度提升)回归模型(XGBRegressor),借助 GridSearchCV 进行超参数调优。对树的数量(n\_estimators)、学习率(learning\_rate)、最大深度(max\_depth)、样本采样比例(subsample)以及特征采样比例(colsample\_bytree)等多个超参数加以探索。经 5 折交叉验证(cv=5),评定每组超参数的成效,进而选定最优超参数组合。

在获得最佳模型后,使用测试集对模型进行了预测,并计算了均方误差(MSE)和决定系数(R<sup>2</sup>),以评估模型的拟合效果。训练完成后,提取 XGBoost 模型的 feature\_importances 属性,评估各特征对土壤含盐量预测的贡献,并通过特征重要性得分的排序,识别出对预测结果影响最大的特征。

表 3 植被指数计算公式  
Tab.3 Vegetation index calculation formulas

名称 Name	计算公式 Calculation formula	名称 Name	计算公式 Calculation formula
RVI	NIR/R	OSAVI	(NIR-R)/(NIR+R+0.16)
ENDVI	(NIR+SWIR1-R)/(NIR+SWIR2+R)	GVMi	[(NIR+0.1)-(SWIR1+0.02)]/[(NIR+0.1)+(SWIR1+0.02)]
IPVI	NIR/(NIR+R)	GNDVI	(NIR-G)/(NIR+G)
GDVI	(NIR <sup>2</sup> -R <sup>2</sup> )/(NIR <sup>2</sup> +R <sup>2</sup> )	GBNDVI	(NIR-G-B)/(NIR+G+B)
NLI	NLI=(NIR <sup>2</sup> -R)/(NIR <sup>2</sup> +R)	GRNDVI	(NIR-G-R)/(NIR+G+R)
GARI	{NIR-[G+γ×(B-R)]}/[NIR+[G+γ×(B-R)]]	SA-VI	(1+L)×[(NIR-R)/(NIR+R+L)]
NDVI	(NIR-R)/(NIR+R)	REIP	700+[[40×(R+RE3)]/2-RE1]/RE2-RE1
DVI	NIR-R	EVI2	2.5×(NIR-R)/(NIR+2.4R+1)
EVI	(1+M)×(NIR-R)/(NIR+C <sub>1</sub> ×R- C <sub>2</sub> ×B +M)	ENDVI	(NIR+SWIR2-R)/(NIR+SWIR2+R)
MSAVI	{2×NIR+1-[(2×NIR+1) <sup>2</sup> -8×(NIR-R)] <sup>0.5</sup> }/2	EEVI	2.5×[(NIR+SWIR1-R)/(NIR+SWIR1+6R-7.5B+1)]

B、G、R、NIR、SWIR1、SWIR2、RE1、RE2、RE3 分别代表蓝、绿、红、近红外、短波红外 1、短波红外 2、红边 1、红边 2、红边 3 波段。γ(调整因子,取 0.5)、C<sub>1</sub>(大气校正系数,取 6)、C<sub>2</sub>(大气校正系数,取 7.5)、L(土壤调整因子,取 0.5)、M(地表背景校正系数,取 0.5)。

B, G, R, NIR, SWIR1, SWIR2, RE1, RE2, RE3 represent the blue, green, red, near-infrared, shortwave infrared 1, shortwave infrared 2, red-edge 1, red-edge 2, and red-edge 3 bands, respectively. γ (adjustment factor, set to 0.5), C1 (atmospheric correction coefficient, set to 6), C2 (atmospheric correction coefficient, set to 7.5), L (soil adjustment factor, set to 0.5), M (surface background correction coefficient, set to 0.5).

为了进一步探索不同特征组合的影响,使用递归算法 (getAllCombinations) 生成盐分指数与植被指数前 10 个特征的所有可能组合。对于每一个特征组合,使用随机森林分类器 (ee.Classifier.SmileRandomForest) 进行训练,并采用交叉验证评估每组组合的性能。数据集同样按 70% 用于训练,30% 用于测试。通过计算每组特征组合的分类准确率 (accuracy) 和决定系数 (R<sup>2</sup>),评估不同特征组合对模型性能的影响。

### 1.6 随机森林模型构建

随机森林 (random forest) 是一种基于树的集成模型,具有较好的泛化能力,可用于回归和分类。其基本思想是基于自助法 (bagging 算法) 生成分类树和回归树。随机选择的训练集被视为独立数据,而剩余的数据则作为袋外数据,用于估计预测误差。协变量也会被随机分成若干组,在每个节点上根据最小化分裂组的方差来进行树的分裂<sup>[31]</sup>:

步骤 1. 自助采样 (bootstrap sampling): 从原始训练数据集中随机抽取 N 个子训练集,每个子集通过有放回采样得到,部分样本可能被重复选择,部分样本可能未被选中。

步骤 2. 构建决策树: 对每个子训练集构建一棵决策树。在每个节点分裂时,随机选择 m 个特征 (m << M, M 为总特征数) 作为候选特征,选择最佳特征进行分裂。

步骤 3. 集成预测: 对于测试样本,每棵决策树给出一个预测结果,最终的预测结果为所有树的平均值 (回归问题) 或多数投票结果 (分类问题)。

### 1.7 模型评价指标

为量化土壤盐分反演模型的预测效果,利用 3 个常用指标决定系数 (R<sup>2</sup>)、均方误差 (MSE) 以及均方根误差 (RMSE) 来进行综合评价。R<sup>2</sup> 越接近 1, MSE, RMSE 越小,则模型拟合效果越好,预测效果越佳。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (2)$$

式(2)中:y<sub>i</sub>:实际值,ŷ<sub>i</sub>:模型预测值,ȳ<sub>i</sub>:实际值的均值,n:数据点的数量。

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3)$$

式(3)中: $y_i$ :实际值, $\hat{y}_i$ :模型预测值, $n$ :数据点的数量。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

式(4)中: $y_i$ :实际值, $\hat{y}_i$ :模型预测值, $n$ :数据点的数量。

## 2 结果与分析

### 2.1 玉米地提取对比分析

未加入光谱指数的模型的总体精度为0.876,Kappa系数为0.842;加入光谱指数的模型的总体精度为0.972,Kappa系数为0.965。这一结果表明,光谱指数在提升土地分类准确性方面发挥了关键作用。

图2a为加入光谱指数的玉米地提取,图2b为未加入光谱指数的玉米地提取,可以明显观察到加入光谱指数的分类结果显示了更加清晰的边界,尤其是在光谱特征相似的土地类型之间。光谱指数(如归一化植被指数(NDVI)、增强植被指数(EVI))有效增强了特定土地覆盖类型的光谱特征,提高了不同地物之间的分辨能力,从而减少了分类误差。相比之下,未加入光谱指数的分类结果在光谱特征接近的地物之间,边界较为模糊,容易出现混淆现象。在玉米地的提取中,使用光谱指数的影像能够更准确地界定玉米地的边界,误分类现象明显减少。加入光谱指数的玉米地更加连贯,几乎没有断裂或异常像素点。而未加入光谱指数的影像则可能出现孤立像素点或小片区域被错误标记为玉米地,导致分类结果不够连贯和准确。

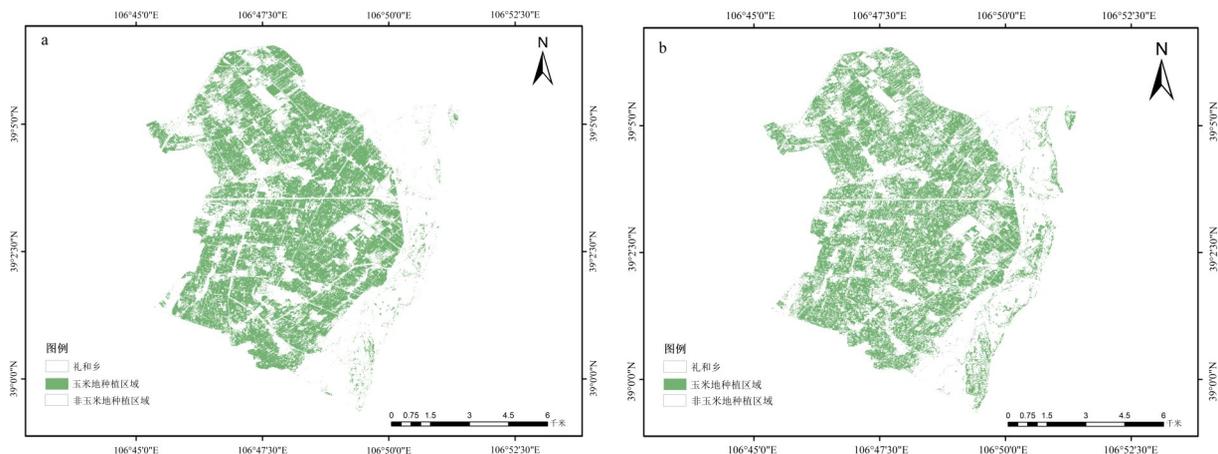


图2 加入光谱指数(a)与未加入光谱指数(b)的玉米地提取示意  
Fig.2 Cornfield extraction of added(a)and non-added(b)spectral index

### 2.2 土壤含盐量与反演因子相关性分析

利用XGBoost回归模型评估各遥感指数与植被指数对土壤含盐量预测的贡献,筛选出盐分指数SI-T(0.141 4)、S7(0.136 1)、S6(0.110 6)、CRSI(0.101 6)、S1(0.101 2)、NDSI(0.086 2)、SI2(0.086 1)、SAIO(0.051 4)、SI3(0.049 5)、SSSI-1(0.044 7)、S9(0.038 9)、S8(0.033 8)、S3(0.017 1)、S5(0.001 4),而SI、SI1、S2、SI4、SRSI、SSSI-2未呈现明显相关性。植被指数方面,筛选出GRNDVI(0.246 2)、NLI(0.113 9)、GBNDVI(0.089 7)、GNDVI(0.086 2)、EVI(0.081 8)、GVMI(0.078 0)、REIP(0.076 0)、ENDVI2(0.064 9)、GARI(0.048 7)、DVI(0.045 0)、ENDVI(0.035 6)、EVI2(0.033 9),其中RVI、GDVI、IPVI、MSAVI、NDVI、OSAVI、ENDVI1、SAVI无明显相关性。把得分排名前10的指数按从高到低顺序排列,如图3所示。

### 2.3 筛选最优特征子集

通过对所有特征组合的评估,选择表现最好的前3个特征组合。这些组合不仅在分类准确率上表现优异,而且在 $R^2$ 值上也体现了较强的预测能力,从而为后续模型优化提供了指导。这种方法相比于传统的单一特征选择方法,能够更全面地捕捉特征间的复杂非线性关系,提高模型的鲁棒性和解释性。最终,评估得出的最佳特征组合如表4所示。

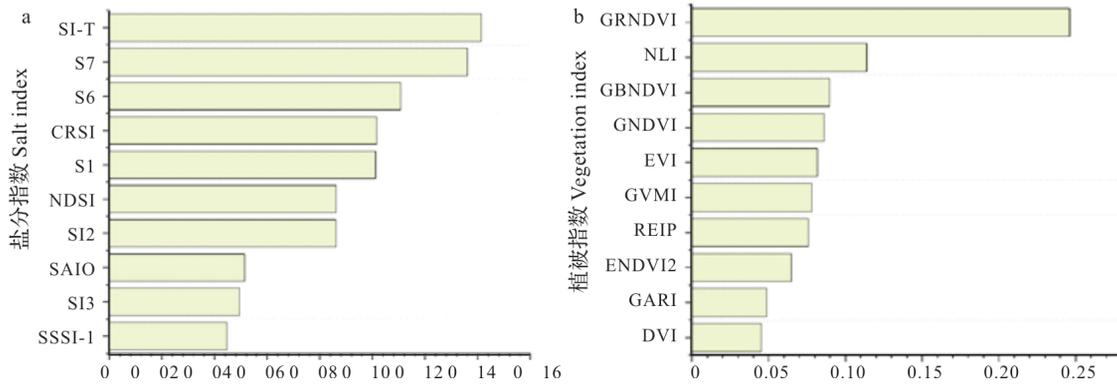


图3 土壤含盐量与反演因子相关性分析

Fig.3 Correlation analysis between soil salinity and inversion factors

表 4 最优特征子集

Tab.4 Optimal feature subset

遥感影像 Remote sensingImage	特征选择 Feature selection	相关性( $R^2$ ) Coefficient of determination	组合 Combination
	SI-T, GRNDVI	0.94	组合 1
Sentinel-2R	SI-T, S7, NLI, GBNDVI	0.92	组合 2
	SI-T, GRNDVI, GBNDVI	0.89	组合 3

### 2.4 实测土壤含盐量统计

根据第三次全国土壤普查盐渍度分类分级标准,盐碱地可划分为 5 个盐渍化等级<sup>[32]</sup>,见表 5。根据分级标准,研究区实测土壤盐渍化程度如图 4 所示,土壤含盐量范围为 0.34~8.99 g/kg,平均值为 1.87 g/kg。土壤盐分在空间分布上表现出显著的不均匀性,不同空间位置的土壤盐分变异特征差异明显。研究区土壤样本均为非盐土,其中非盐碱土占主导地位;盐碱化土壤样本以轻度盐碱土为主。具体而言,非盐碱土、轻度盐碱土、中度盐碱土和重度盐碱土的占比分别为 67%、18%、11% 和 4%。

表 5 土壤盐渍化程度分级标准

Tab.5 Classification standards for soil

含盐量/( $g \cdot kg^{-1}$ ) Salt content	0~2	2~4	4~6	6~10	>10
土壤盐渍化类型 Types of soil salinization	非盐碱土	轻度盐碱土	中度盐碱土	重度盐碱土	盐土

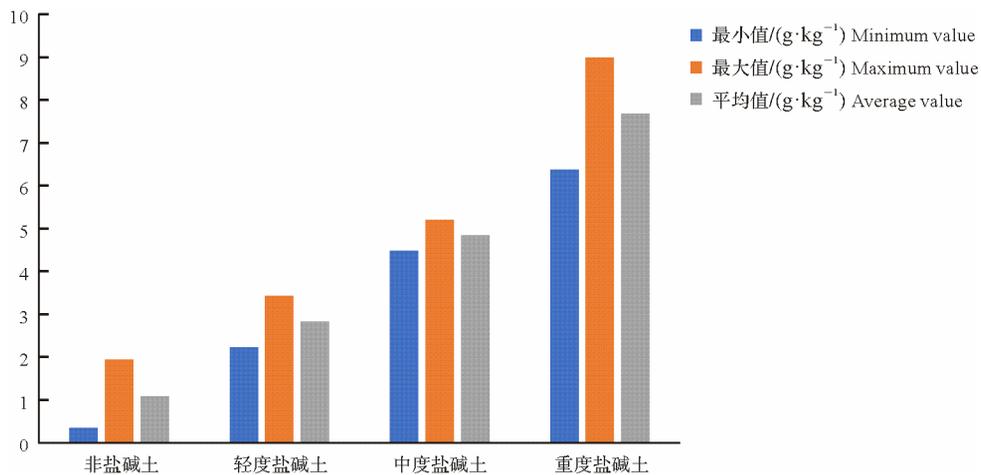


图 4 土壤含盐量统计

Fig.4 Statistics of soil salt content

## 2.5 土壤含盐量估算模型对比

依据上述分析结果,选择光谱指数与土壤含盐量评分居前3的最优组合,分别与RF构建土壤含盐量估算模型,其训练结果见表6。

表6 模型评价结果

Tab.6 Model evaluation results

数据源	模型	机器学习模型评价指标	组合1	组合2	组合3
Data source	Model	Machine learning model evaluation metrics	Combination 1	Combination 2	Combination 3
Sentinel-2 SR	RF	$R^2$	0.94	0.91	0.80
		MSE	0.29	0.30	0.44
		RMSE	0.53	0.54	0.58

根据上述分析结果,基于随机森林算法的土壤盐分估算模型在不同光谱指数组合下表现出明显的差异。组合1(SI-T,GRNDVI)在所有组合中表现最佳,其决定系数( $R^2$ )达到0.94,表明该模型能够解释94%的土壤盐分变异,具备极高的预测精度。此外,该组合的均方误差(MSE=0.29)和均方根误差(RMSE=0.53)均为最低,进一步表明该模型在土壤盐分估算中的误差较小,表现出较强的拟合能力和稳定性。

相比之下,组合2(SI-T,S7,NLI,GBNDVI)的表现略逊一筹, $R^2$ 为0.92,虽然仍能够解释92%的土壤盐分变异,但与组合1相比,模型的预测精度有所下降。该组合的MSE(0.30)和RMSE(0.54)也高于组合1,表明加入S7和NLI等额外光谱指数,虽然提升了模型的多样性,但在土壤盐分估算的精度上没有显著提高,且可能存在一定的冗余信息。

组合3(SI-T,GRNDVI,GBNDVI)在所有模型中表现最差, $R^2$ 为0.80,MSE为0.44,RMSE为0.58,说明该组合的预测误差相对较大,精度较低。这一结果表明,GBNDVI与GRNDVI之间可能存在一定的冗余或不足以有效提升土壤盐分估算精度的情况,因此该组合的预测能力较弱。

## 2.6 反演结果差异性分析

图5分别展示了组合1、组合2、组合3与随机森林反演生成的盐分分布。不同组合的反演结果存在差异,这源于不同模型在数据处理上的特性差异。组合1、组合2、组合3可能整体上拟合较好( $R^2$ 体现),但在局部区域,由于变量选择和权重分配不同,反演结果有所偏差。使用SI-T和GRNDVI组合反演时,相关系数为0.94,表明这2个变量在盐分反演中具有较强的针对性和互补性,a图结果与实际采样一致。随着变量数量增加(组合2和组合3),模型复杂度上升,容易出现过拟合,导致反演结果与组合1有较大偏差。不同模型在处理数据时的特性差异使得组合3虽然整体拟合较好,但局部结果与组合1、组合2差异较大。

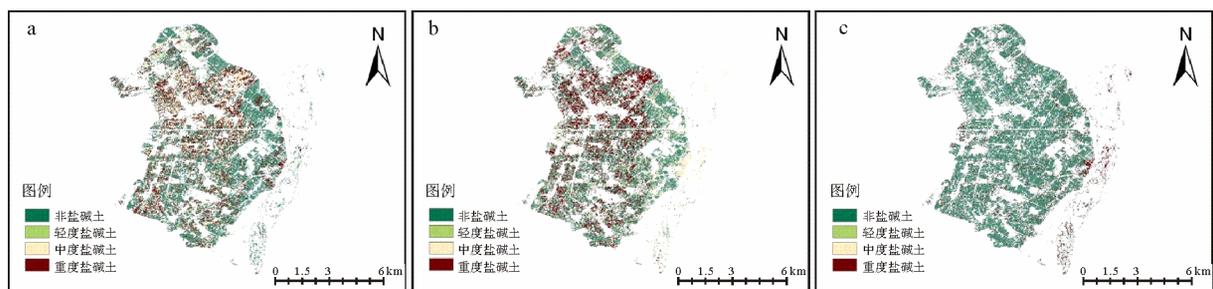


图5 不同组合盐分反演分析

Fig.5 Salinity inversion maps of different combinations

从图5a可知,非盐渍土是主要土壤类型,中度盐渍土和重度盐渍土的分布较小且零散。中度盐渍土以点状或小斑块分布,未形成大面积连片区域;重度盐渍土分布更为稀少,可能仅出现在局部小区域。这表明中度和重度盐渍土的形成受到更严格的条件限制,可能与土壤质地、排水条件和灌溉方式等因素相关。同时,这些高盐渍度土壤的分布与轻度盐渍土并不完全重合,存在空间差异,反映了不同盐渍土

的形成机制复杂性。观察发现,中度和重度盐渍土往往位于轻度盐渍土的过渡带,表明土壤盐分是逐步积累的过程,受到水源距离、土壤水分蒸发等多重因素影响。

### 3 讨论

#### 3.1 玉米地盐碱化遥感监测方法中的优势与不足

本研究利用 Sentinel-2 SR 多光谱遥感影像和 GEE 平台,结合随机森林算法进行玉米地盐碱化遥感监测,展现出显著优势。通过引入光谱指数,模型总体精度提升约 9.6%,Kappa 系数显著改善,分类边界更清晰,误分类现象减少。在土壤盐渍化反演中,随机森林模型预测精度较高,部分组合下  $R^2$  高达 0.94,均方误差(MSE)降低至 0.02,平均绝对百分比误差(MAPE)减少至 0.10,能够有效捕捉土壤盐渍化的细微变化,对盐碱化程度的判断和空间分布的刻画更加精确。

然而,研究方法存在一定局限性。在数据获取方面,依赖于特定的卫星影像数据,其时效性和稳定性受卫星发射、运行状况以及云层、大气等因素的影响。尽管采取了去云等处理措施,仍可能存在部分干扰无法完全消除,影响数据质量和反演精度。为此,有研究者<sup>[33-35]</sup>运用无人机遥感来去除卫星影像的影响,提高盐分反演的精度。此外,相关研究表明,深度学习模型在遥感反演中表现优异。例如,Miao 等<sup>[36]</sup>发现 LSTM-CNN 在有机质含量反演中验证集精度最高( $R^2=0.96$ ),而 Mohammadifar 等<sup>[37]</sup>在土壤盐度预测中证实深度学习模型(尤其是 DCNN, NSE=0.96)优于浅层机器学习模型。这些研究为后续探索深度学习模型在土壤盐渍化监测中的应用提供了重要参考。

本研究通过优化随机森林模型和特征组合,显著提升了土壤盐渍化监测的精度,但仍存在数据依赖性和模型泛化能力等局限性。未来研究可进一步比较深度学习模型与其余机器学习模型的性能,探索更高精度的监测方法。

#### 3.2 电导率来换算盐碱指标的机理

前人<sup>[4]</sup>通过大量土壤电导率与烘干盐渍对应关系试验,标定出研究区域土壤电导率( $X, \mu\text{S}/\text{cm}$ )与土壤含盐量( $Y, \text{g}/\text{kg}$ )的关系为: $Y=0.0054951 \times X - 0.00131 (R^2=0.998)$ 。土壤电导率指土壤溶液传导电流的能力,即土壤溶液的导电能力,是反映土壤溶液中含盐量的间接指标。通过测量土壤的电导率,就能间接反映土壤中的盐分含量。这种换算关系在一定程度上建立了土壤物理性质(电导率)与化学性质(含盐量)之间的联系,为快速获取土壤盐碱指标提供了可行的方法。但是该换算关系是基于特定区域、特定土壤样本试验得出的,具有一定的局限性。不同地区的土壤成分、性质差异较大,这种基于本地样本建立的关系可能不适用于其他地区,限制了其广泛应用。

#### 3.3 玉米地盐碱化治理

针对玉米地盐碱化问题,采取水利、农业和生物改良相结合的综合措施是行之有效的治理策略。通过优化灌溉系统和完善排水设施,调整种植结构和耕作方式,以及推广耐盐作物种植,可以有效改善土壤环境,促进作物生长。

在水利改良方面,优化灌溉系统和完善排水设施是关键。黄占城<sup>[38]</sup>指出,轻度盐碱化区域可通过引入喷灌、滴灌等节水灌溉技术,合理调控水盐运动,降低地下水位,促进脱盐;中度盐碱化区域需在此基础上结合农业和生物改良措施,如造林或种植耐盐植物;重度盐碱化区域因改造难度大、周期长,应采取先易后难策略,综合运用农艺、排水、灌溉及生物化学手段。贾壮壮等<sup>[2]</sup>也强调,喷灌、滴灌等技术能有效控制地下水位,减少盐分积累。刘伟等<sup>[39]</sup>的研究表明,节水改造工程显著减轻了沈乌灌域的土壤盐渍化程度,扩大了作物安全生长区。黄建成等<sup>[40]</sup>在红寺堡镇试验区采用沟植沟灌、综合培肥及排水孔渗滤措施,使土壤脱盐率达 40%,枸杞增产 28%~40%,进一步验证了水利改良的有效性。

在农业改良方面,调整种植结构和优化耕作方式是重要手段。选择耐盐碱玉米品种,结合深耕松耕、增施有机肥等措施,可改善土壤结构,增强保水保肥能力,减少盐分危害。郭永玲等<sup>[41]</sup>在惠农区的研究表明,枸杞与小麦、玉米、油菜轮作后,盐碱地作物产量显著提升,未种植枸杞的地块中,小麦、玉米、油菜产量分别为 11.98, 260, 240.5  $\text{kg}/\text{hm}^2$ ,而种植枸杞多年后,产量分别增至 449.8, 804.3, 310.8  $\text{kg}/\text{hm}^2$ ,证明了合理轮作对提高盐碱地作物产量的积极作用。

在生物改良方面,种植耐盐碱作物和利用微生物菌剂是有效途径。Li等<sup>[42]</sup>在白僵土中种植苜蓿1年后,土壤pH值、盐分量和体积质量分别降低0.6、0.5 g/kg和100 kg/cm<sup>3</sup>,表明耐盐碱作物通过吸收盐离子或分泌根分泌物,改善微生物群落和酶活性,间接改良土壤理化性质。班乃荣等<sup>[43]</sup>的研究也表明,种植耐盐作物可有效抑制土壤盐分,种植首年0~20 cm土层盐分下降37%~45%。Zhang等<sup>[44]</sup>在红寺堡区严重沙漠化盐碱地种植葡萄,发现葡萄种植不仅改善了土壤理化性质和微生物多样性,还吸收了土壤盐分并提升了肥力,为生物改良提供了参考。

针对玉米旱地盐碱化问题,应因地制宜,综合运用水利、农业和生物改良措施,优化灌溉排水系统,调整种植结构,推广耐盐作物种植,以实现土壤脱盐、肥力提升和作物增产的目标。

## 4 结 论

研究以宁夏惠农区礼和乡为研究区,使用加入遥感指数的随机森林对宁夏惠农区礼和乡玉米地进行提取。通过野外采集的土壤盐分数据以及Sentinel-2 SR遥感影像数据,比较了不同特征组合方式和建模策略在玉米地土壤盐渍化估算模型上的效能差异,通过分析不同特征组合的 $R^2$ 、MSE和RMSE值发现:

加入光谱指数的随机森林模型总体精度达到0.972,Kappa系数为0.965,而未加入光谱指数的随机森林模型总体精度为0.876,Kappa系数为0.842。引入光谱指数后,模型的总体精度提高了约9.6%,Kappa系数也有显著改善。这表明光谱指数在提升土地分类的准确性方面具有关键作用。这种方法为土地覆盖分类和农业监测提供了强有力的技术支持,未来在大规模遥感数据分析中具有广泛的应用前景。

在使用Sentinel-2 SR影像数据进行土壤盐渍化预测的研究中,结合了随机森林模型。发现在特征组合1(SI-T,GRNDVI)应用下,RF模型展现了显著的预测精度。其训练集的 $R^2$ 达到0.94,MSE降低至0.29,RMSE减少至0.53,这些指标不仅表明RF模型在特征组合1展现了极高的预测精度,也证实了其在精确捕捉和反映土壤盐渍化细微变化方面的敏锐性。这种方法为土地覆盖分类和农业监测提供了强有力的技术支持,未来在大规模遥感数据分析中具有广泛的应用前景。

## 参考文献 References:

- [1] 杨劲松,姚荣江,王相平,等.中国盐渍土研究:历程、现状与展望[J].土壤学报,2022,59(1):10-27.  
YANG J S, YAO R J, WANG X P, et al. Research on salt-affected soils in China: history, status quo and prospect [J]. Acta pedologica Sinica, 2022, 59(1): 10-27.
- [2] 贾壮壮,谭亚男,管孝艳,等.宁夏盐碱地成因及分区治理措施综述[J].灌溉排水学报,2023,42(5):122-134.  
JIA Z Z, TAN Y N, GUAN X Y, et al. Saline-alkali soil formation and its remediation strategies in different regions of Ningxia: a comprehensive review [J]. Journal of irrigation and drainage, 2023, 42(5): 122-134.
- [3] 刘涛.宁夏引黄灌区盐碱荒地水肥盐与植物根系调控技术研究[D].北京:北京林业大学,2020.  
LIU T. The control techniques of water-nutrient-salt and plant root in a saline-alkali wasteland of Ningxia Irrigation Area [D]. Beijing: Beijing Forestry University, 2020.
- [4] 黄晶,孔亚丽,徐青山,等.盐渍土壤特征及改良措施研究进展[J].土壤,2022,54(1):18-23.  
HUANG J, KONG Y L, XU Q S, et al. Progresses for characteristics and amelioration measures of saline soil [J]. Soils, 2022, 54(1): 18-23.
- [5] STAVI I, THEVS N, PRIORI S. Soil salinity and sodicity in drylands: a review of causes, effects, monitoring, and restoration measures [J]. Frontiers in environmental science, 2021, 9: 712831.
- [6] 李小雨,贾科利,魏慧敏,等.基于随机森林算法的土壤含盐量预测[J].干旱区研究,2023,40(8):1258-1267.  
LI X Y, JIA K L, WEI H M, et al. Prediction of soil salt content based on the random forest algorithm [J]. Arid zone research, 2023, 40(8): 1258-1267.
- [7] 黄晓宇,王雪梅,卡吾恰提·白山.基于Landsat8 OLI影像干旱区绿洲土壤含盐量反演[J].自然资源遥感,2023,35(1):189-197.

- HUANG X Y, WANG X M, KAWUQIATI B S. Inversion of soil salinity of an oasis in an arid area based on Landsat 8 OLI images[J]. *Remote sensing for natural resources*, 2023, 35(1): 189-197.
- [8] 杨宁, 崔文轩, 张智韬, 等. 无人机多光谱遥感反演不同深度土壤盐分[J]. *农业工程学报*, 2020, 36(22): 13-21.  
YANG N, CUI W X, ZHANG Z T, et al. Soil salinity inversion at different depths using improved spectral index with UAV multispectral remote sensing[J]. *Transactions of the Chinese society of agricultural engineering*, 2020, 36(22): 13-21.
- [9] 陈俊英, 姚志华, 张智韬, 等. 大田葵花土壤含盐量无人机遥感反演研究[J]. *农业机械学报*, 2020, 51(7): 178-191.  
CHEN J Y, YAO Z H, ZHANG Z T, et al. UAV remote sensing inversion of soil salinity in field sunflower[J]. *Transactions of the Chinese society for agricultural machinery*, 2020, 51(7): 178-191.
- [10] 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 Z T, WEI G F, YAO Z H, 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.
- [11] WANG F, YANG S, WEI Y, et al. Characterizing soil salinity at multiple depth using electromagnetic induction and remote sensing data with random forests: a case study in Tarim River basin of southern Xinjiang, China[J]. *Science of the total environment*, 2021, 754: 142030.
- [12] 刘霞, 胡宇, 张圣微, 等. 达拉特旗黄河南岸盐碱化土壤不同含盐量估算模型对比[J]. *农业机械学报*, 2024, 55(10): 360-370.  
LIU X, HU Y, ZHANG S W, et al. Comparison of different salinity estimation models for salinized soils on south bank of Yellow River in Dalat Banner[J]. *Transactions of the Chinese society for agricultural machinery*, 2024, 55(10): 360-370.
- [13] 洪国军, 谢俊博, 张灵等. 基于多光谱影像的阿拉尔垦区棉田土壤盐分反演[J]. *干旱区研究*, 2024, 41(5): 894-904.  
HONG G J, XIE J B, ZHANG L, et al. Monitoring soil salinization of cotton fields in the Aral Reclamation area using multi-spectral imaging[J]. *Arid zone research*, 2024, 41(5): 894-904.
- [14] 王拓, 申晓晶, 栾文杰. 基于 Sentinel-2 卫星对宁夏惠农区不同季节土壤含盐量定量反演[J]. *现代农业研究*, 2024, 30(5): 12-19.  
WANG T, SHEN X J, LUAN W J. Quantitative inversion of soil salinity in different seasons in Huinong District, Ningxia based on Sentinel-2 Satellite[J]. *Modern agricultural research*, 2024, 30(5): 12-19.
- [15] 牛乾坤, 刘浏, 黄冠华, 等. 基于 GEE 和机器学习的河套灌区复杂种植结构识别[J]. *农业工程学报*, 2022, 38(6): 165-174.  
NIU Q K, LIU L, HUANG G H, et al. Extraction of complex crop structure in the Hetao Irrigation District of Inner Mongolia using GEE and machine learning[J]. *Transactions of the Chinese society of agricultural engineering*, 2022, 38(6): 165-174.
- [16] ABUBAKAR G A, WANG K, KOKO A F, et al. Mapping maize cropland and land cover in semi-arid region in northern Nigeria using machine learning and Google Earth Engine[J]. *Remote sensing*, 2023, 15(11): 2835.
- [17] LUAN W J, SHEN X J, FU Y H, et al. Research on maize acreage extraction and growth monitoring based on a machine learning algorithm and multi-source remote sensing data[J]. *Sustainability*, 2023, 15(23): 16343.
- [18] 张晓东, 赵银鑫, 武丹, 等. 基于遥感的银川市建成区城市扩展及其热环境变化分析[J]. *干旱区地理*, 2020, 43(5): 1278-1288.  
ZHANG X D, ZHAO Y X, WU D, et al. Urban built-up area expansion and thermal environment variation in Yinchuan City based on remote sensing[J]. *Arid land geography*, 2020, 43(5): 1278-1288.
- [19] 李虎, 钟韵, 冯雅婷, 等. 无人机遥感的多植被指数土壤水分反演模型[J]. *光谱学与光谱分析*, 2024, 44(1): 207-214.  
LI H, ZHONG Y, FENG Y T, et al. Multi-vegetation index soil moisture inversion model based on UAV remote sensing[J]. *Spectroscopy and spectral analysis*, 2024, 44(1): 207-214.
- [20] 张珂, 吴星宇, 吴南, 等. 基于高分一号遥感影像的水体提取方法对比分析与改进[J]. *水资源保护*, 2024, 40(4): 9-16.  
ZHANG K, WU X Y, WU N, et al. Comparative analysis and improvement of water body extraction methods based on GF-1 remote sensing images[J]. *Water resources protection*, 2024, 40(4): 9-16.
- [21] WANG N, PENG J, XUE J, et al. A framework for determining the total salt content of soil profiles using time-series Sentinel-2 images and a random forest-temporal convolution network[J]. *Geoderma*, 2022, 409: 115656.

- [22] 贾萍萍,尚天浩,张俊华,等.利用多源光谱信息反演宁夏银北地区干湿季土壤含盐量[J].农业工程学报,2020,36(17):125-134.
- JIA P P, SHANG T H, ZHANG J H, et al. Inversion of soil salinity in dry and wet seasons based on multi-source spectral data in Yinbei Area of Ningxia, China [J]. Transactions of the Chinese society of agricultural engineering, 2020, 36(17): 125-134.
- [23] LI J, ZHANG T, SHAO Y, et al. Comparing machine learning algorithms for soil salinity mapping using topographic factors and Sentinel-1/2 data: a case study in the Yellow River delta of China [J]. Remote sensing, 2023, 15(9): 2332.
- [24] 齐翟硕,傅新,张浩然,等.黄河三角洲引黄灌区土壤盐分遥感反演及空间分布特征[J].济南大学学报(自然科学版),2024(5):1-7.
- QI Z S, FU X, ZHANG H R, et al. Remote sensing inversion and spatial distribution characteristics of soil salinity in the Yellow River Irrigation Area of the Yellow River Delta [J]. Journal of university of Jinan (science and technology), 2024(5): 1-7.
- [25] GUO Z, LI Y, WANG X, et al. Remote sensing of soil organic carbon at regional scale based on deep learning: A case study of agro-pastoral ecotone in northern China [J]. Remote sensing, 2023, 15(15): 3846.
- [26] 杨丽萍,任杰,王宇,等.基于多源遥感数据的居延泽地区土壤盐分估算模型[J].农业机械学报,2022,53(11):226-235.
- YANG L P, REN J, WANG Y, et al. Soil salinity estimation model in Juyanze based on multi-source remote sensing data [J]. Transactions of the Chinese society for agricultural machinery, 2022, 53(11): 226-235.
- [27] 高林,王晓菲,顾行发,等.植冠下土壤类型差异对遥感估算冬小麦叶面积指数的影响[J].植物生态学报,2017,41(12):1273-1288.
- GAO L, WANG X F, GU X F, et al. Exploring the influence of soil types underneath the canopy in winter wheat leaf area index remote estimating [J]. Chinese journal of plant ecology, 2017, 41(12): 1273-1288.
- [28] 边慧芹,王雪梅.基于多光谱影像的干旱区绿洲耕层土壤盐分估算[J].干旱区资源与环境,2022,36(5):110-118.
- BIAN H Q, WANG X M. Estimation of soil salinity in cultivated layers of oasis in arid areas based on multispectral images [J]. Journal of arid land resources and environment, 2022, 36(5): 110-118.
- [29] 朱婉雪,孙志刚,李彬彬,等.基于无人机遥感的滨海盐碱地土壤空间异质性分析与作物光谱指数响应胁迫诊断[J].地球信息科学学报,2021,23(3):536-549.
- ZHU W X, SUN Z G, LI B B, et al. Analysis of spatial heterogeneity for soil attributes and spectral indices-based diagnosis of coastal saline-alkaline farmland using UAV remote sensing [J]. Journal of Geo-information science, 2021, 23(3): 536-549.
- [30] 赵巧珍,丁建丽,韩礼敬,等.MODIS和Landsat时空融合影像在土壤盐渍化监测中的适用性研究:以渭干河—库车河三角洲绿洲为例[J].干旱区地理,2022,45(4):1155-1164.
- ZHAO Q Z, DING J L, HAN L J, et al. Exploring the application of MODIS and landsat spatiotemporal fusion images in soil salinization: a case of Ugan River-Kuqa River Delta Oasis [J]. Arid land geography, 2022, 45(4): 1155-1164.
- [31] ZHOU Y, XUE J, CHEN S C, et al. Fine-resolution mapping of soil total nitrogen across China based on weighted model averaging [J]. Remote sensing, 2019, 12(1): 85.
- [32] 国务院第三次全国土壤普查领导小组办公室.第三次全国土壤普查土壤类型名称校准技术规范(修订版)[EB/OL].(2023-02-27)[2025-02-11].<https://nyncej.beijing.gov.cn/nyj/snxx/ztlz/dscqgtrpc/gcgf/436227670/index.html>.
- Office of the Leading Group for the Third National Soil Census of the State Council. Technical Specification for Calibration of Soil Type Names in the Third National Soil Census (Revised Edition) [EB/OL]. (2023-02-27) [2025-02-11]. <https://nyncej.beijing.gov.cn/nyj/snxx/ztlz/dscqgtrpc/gcgf/436227670/index.html>.
- [33] 王玮莹,彭金榜,朱婉雪,等.基于无人机遥感的盐渍化土壤有机质反演方法研究[J].地球信息科学学报,2024,26(3):736-752.
- WANG W Y, PENG J B, ZHU W X, et al. Study on retrieval method of soil organic matter in salinity soil using unmanned aerial vehicle remote sensing [J]. Journal of Geo-information science, 2024, 26(3): 736-752.
- [34] 韩文霆,崔家伟,崔欣,等.基于特征优选与机器学习的农田土壤含盐量估算研究[J].农业机械学报,2023,54(3):328-337.

- HAN W T, CUI J W, CUI X, et al. Estimation of farmland soil salinity content based on feature optimization and machine learning algorithms[J]. Transactions of the Chinese society for agricultural machinery, 2023, 54(3): 328-337.
- [35] 赵文举, 马芳芳, 马宏, 等. 基于无人机多光谱影像的土壤盐分反演模型[J]. 农业工程学报, 2022, 38(24): 93-101.
- ZHAO W J, MA F F, MA H, et al. Soil salinity inversion model based on the multispectral images of UAV[J]. Transactions of the Chinese society of agricultural engineering, 2022, 38(24): 93-101.
- [36] MIAO T Y, JI W J, LI B G, et al. Advanced soil organic matter prediction with a regional soil NIR spectral library using long short-term memory-convolutional neural networks: a case study[J]. Remote sensing, 2024, 16(7): 1256.
- [37] MOHAMMADIFAR A, ZHANG X L, LI Y Q, et al. Spatial modelling of soil salinity: deep or shallow learning models?[J]. Environmental science and pollution research, 2021, 28: 39432-39450.
- [38] 黄占城. 基于最大似然法的盐碱化发展态势与治理模式探析[J]. 中国农村水利水电, 2019(12): 5-9.
- HUANG Z C. An analysis of the development trend and governance mode of salinization based on maximum likelihood method[J]. China rural water and hydropower, 2019(12): 5-9.
- [39] 刘伟, 史海滨, 苗庆丰, 等. 基于 Landsat 8 的节水改造背景下盐渍化土壤含盐量反演[J]. 农业机械学报, 2024, 55(1): 294-304.
- LIU W, SHI H B, MIAO Q F, et al. Inversion of salt content in salinized soil under background of water-saving transformation based on Landsat 8[J]. Transactions of the Chinese society for agricultural machinery, 2024, 55(1): 294-304.
- [40] 黄建成, 桂林国. 宁夏红寺堡土壤次生盐渍化综合改良技术研究[J]. 宁夏农林科技, 2010, 51(2): 1-2.
- HUANG J C, GUI L G. Research on comprehensive improvement technology of soil secondary salinization in Hongsibao, Ningxia[J]. Ningxia journal of agriculture and forestry science and technology, 2010, 51(2): 1-2.
- [41] 郭永玲, 朱学双. 盐碱地改良措施及枸杞种植效益分析[J]. 防护林科技, 2013(10): 91-92.
- GUO Y L, ZHU X S. Improvement measures of saline-alkali land and benefit analysis of wolfberry planting[J]. Protection for-est science and technology, 2013(10): 91-92.
- [42] LI F X, GUO Y Z, WANG Z J, et al. Influence of different phytoremediation on soil microbial diversity and community composition in saline-alkaline land[J]. International journal of phytoremediation, 2022, 24(5): 507-517.
- [43] 班乃荣, 陈兴会, 张永宏, 等. 耐盐植物对盐碱地的改良效果试验[J]. 宁夏农林科技, 2004, 45(1): 26-27.
- BAN N R, CHEN X H, ZHANG Y H, et al. Experiment on the improvement effect of salt-tolerant plants on saline-alkali land [J]. Ningxia journal agriculture and forestry science and technology, 2004, 45(1): 26-27.
- [44] ZHANG L, XUE T T, YUAN L, et al. The effect of vineyard reclamation on soil properties and microbial communities in de-sertified land in Hongsibu, Ningxia[J]. Catena, 2022, 211: 106002.