

DOI:10.13870/j.cnki.stbcb.2025.06.016

CSTR:32310.14.stbcb.2025.06.016

陈猷, 申晓晶, 周博, 等. 基于多源遥感宁夏引黄灌区季节性土壤盐分反演模型构建[J]. 水土保持学报, 2025, 39(6):444-454.

CHEN You, SHEN Xiaojing, ZHOU Bo, et al. Construction of seasonal soil salinity inversion models in Yellow River irrigation area of Ningxia based on multi-source remote sensing[J]. Journal of Soil and Water Conservation, 2025, 39(6):444-454.

## 基于多源遥感宁夏引黄灌区季节性 土壤盐分反演模型构建

陈猷, 申晓晶, 周博, 田佳珂, 姬金毓, 尚奋杰, 吴闰, 张静

(宁夏大学土木与水利工程学院, 银川 750021)

**摘要:** [目的] 土壤盐渍化问题已成为制约农业可持续发展与区域生态平衡的主要障碍。鉴于土壤盐渍化在不同季节具有显著的时空变化特征, 结合遥感技术与机器学习方法, 基于各季节光谱特征的差异性, 旨在为农业生产决策与土地资源管理提供精准支撑。[方法] 以宁夏回族自治区礼和乡为研究区, 基于 Sentinel-1 SAR 后向散射系数、Sentinel-2 多光谱反射率及衍生指数(盐分指数、植被指数、纹理特征)、Landsat-9 地表温度(LST)及 SRTM 地形因子构建多源遥感数据集。通过相关性分析与决定系数( $R^2$ )初步筛选光谱变量, 采用连续投影算法(SPA)对特征空间进行降维, 以实现预测变量集的优化。在此基础上, 分别利用随机森林(random forest, RF)、支持向量机回归(support vector regression, SVR)和反向传播神经网络(backpropagation neural network, BPNN)构建裸土期(春季)与植被覆盖期(秋季)的土壤盐分含量反演模型。[结果] 1)在裸土期, Sentinel-2 原始波段反射率与盐分指数的贡献最为显著, 而植被覆盖期, 地形因子与植被指数是土壤盐分反演的主要影响因子。2)综合模型性能对比发现, RF 模型在训练集和测试集上均表现优异, 其中裸土期和植被覆盖期训练集的决定系数( $R^2$ )分别达到 0.92 和 0.94。[结论] 多源遥感数据与机器学习的结合应用, 能够在不同季节条件下实现较为理想的土壤盐分反演精度, 为该地区土壤盐碱化监测与治理提供科学依据和技术支持。

**关键词:** 土壤盐渍化; 多源遥感; 变量筛选; 机器学习; 土壤盐分反演; 季节变化

中图分类号: S156.4 文献标识码: A 文章编号: 1009-2242(2025)06-0444-11

## Construction of Seasonal Soil Salinity Inversion Models in Yellow River Irrigation Area of Ningxia Based on Multi-Source Remote Sensing

CHEN You, SHEN Xiaojing, ZHOU Bo, TIAN Jiake, JI Jinyu, SHANG Fenjie, WU Run, ZHANG Jing

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

**Abstract:** [Objective] Soil salinization has become a major obstacle constraining sustainable agricultural development and regional ecological balance. Given the significant spatiotemporal variations in soil salinity across different seasons, this study integrates remote sensing technology and machine learning methods based on seasonal differences in spectral characteristics, aiming to provide precise support for agricultural production decision-making and land resource management. [Methods] Lihe Township in the Ningxia Hui Autonomous Region was selected as the study area. A multi-source remote sensing dataset was constructed based on Sentinel-1 SAR backscatter coefficients, Sentinel-2 multispectral reflectance and derived indices (salinity indices, vegetation indices, texture features), Landsat-9 land surface temperature (LST), and SRTM topographic factors. Spectral variables were preliminarily screened using correlation analysis and the coefficient of determination ( $R^2$ ). The successive projections algorithm (SPA) was then applied to reduce the dimensionality of the feature space, thereby optimizing the predictor variable set. Based on this, soil salinity inversion models were developed for the bare soil

收稿日期: 2024-04-29

修回日期: 2025-06-05

录用日期: 2025-06-26

网络首发日期(www.cnki.net): 2025-08-29

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

第一作者: 陈猷(1999—), 女, 硕士研究生, 主要从事土壤盐渍化监测研究。E-mail: cy01144563@163.com

通信作者: 申晓晶(1989—), 女, 博士, 讲师, 主要从事气候变化与水资源安全调控研究。E-mail: sxj15191418250@126.com

http://stbcb.alljournal.com.cn

period (spring) and the vegetation-covered period (autumn) using random forest (RF), support vector regression (SVR), and backpropagation neural network (BPNN), respectively. [Results] 1) During the bare soil period, Sentinel-2 original band reflectance and salinity indices contributed most significantly, while topographic factors and vegetation indices were the primary influencing factors for soil salinity inversion during the vegetation-covered period. 2) Comprehensive comparison of model performance revealed that the RF model performed excellently on both the training and testing sets, with  $R^2$  reaching 0.92 for the bare soil period and 0.94 for the vegetation-covered period. [Conclusion] The combined application of multi-source remote sensing data and machine learning can achieve relatively ideal soil salinity inversion accuracy under different seasonal conditions, thereby providing a scientific basis and technical support for monitoring and managing soil salinization in the region.

**Keywords:** soil salinization; multi-source remote sensing; variable selection; machine learning; soil salinity inversion; seasonal variation

Received: 2024-04-29

Revised: 2025-06-05

Accepted: 2025-06-26

Online(www.cnki.net): 2025-08-29

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不同程度的影响。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>[1]</sup>。受气候变暖与灌溉活动影响,盐渍化过程呈现显著的时空分异性<sup>[2]</sup>。其中土壤盐分存在明显的季节性动态,冬春裸土期盐分表聚,夏秋植被覆盖期则发生淋溶迁移。因此,精准捕捉这一盐分动态规律,对解析盐渍化驱动机制和制定分季调控策略至关重要。

近年来,多源遥感与机器学习的融合显著提升土壤盐分监测能力。在数据方面, Sentinel-2 光学影像、 Sentinel-1 雷达数据及地形环境参数的协同应用,可综合反映盐分的光谱响应、介电特性和运移路径<sup>[3-5]</sup>,整合这些多源数据,能够更全面地捕捉影响土壤盐分的关键信息,弥补单一数据源的局限性。在算法方面,机器学习模型展现出超越传统统计方法的优势,崔晓彤等<sup>[6]</sup>通过系统对比 RF、SVM 与 BPNN 模型,证实 RF 在冬小麦区不同土层盐分反演中均保持最高精度,凸显了集成学习对复杂非线性关系的建模能力;同时,张智韬等<sup>[7]</sup>进一步基于无人机多光谱数据验证了 RF 在河套灌区裸土期盐分估算的可靠性。尽管多源遥感与机器学习融合显著提升土壤盐分监测能力,当前方法仍面临许多挑战。多源数据的高维特征在提升信息量的同时,也加剧了变量冗余与共线性问题,而针对裸土期与植被覆盖期差异化的特征优选策略尚未系统建立<sup>[8-9]</sup>,同时,现有模型多忽略季节性反演机制的显式区分,难以有效协调植被覆盖期冠层遮蔽造成的间接响应与裸土期直接光谱响应的本质差异<sup>[4]</sup>;此外,主流算法在季节适应性方面的对比验证

仍不充分<sup>[6]</sup>。

针对上述不足,本研究提出“多源协同-季节分异-特征优选”的框架,以宁夏礼和乡为例,集成 Sentinel-1 SAR 后向散射系数、 Sentinel-2 多光谱反射率及衍生指数(盐分指数、植被指数、纹理特征)、 Landsat-9 地表温度(LST)以及 SRTM 地形因子多源遥感数据,通过相关性分析进行特征初筛,再利用连续投影算法进行二次降维,以优化特征选择,并分别建立裸土期与植被覆盖期的 RF、SVR、BPNN 盐分反演模型。以期显著提升该地区裸土期与植被覆盖期的土壤盐分反演精度,为土壤盐渍化的动态监测、分季节调控与精准治理提供科学依据和技术支撑。

## 1 材料与方 法

### 1.1 研究区概况

礼和乡(38°59'03"~39°06'43"N, 106°45'28"~106°52'01"E)位于宁夏回族自治区石嘴山市惠农区,海拔1091~1093 m(图1)。该地区属黄河冲积平原,土壤质地较为黏重,渗透性能较差,致使地下水侧向运动受限,从而在部分区域引发土壤盐碱化问题<sup>[1]</sup>。境内河流归属黄河水系,惠农渠和滂渠纵向贯穿南北方向,第7排水沟则横向连接东西区域。农业方面,当地以小麦、玉米和豆类等农作物种植为主,其中尤以玉米栽培最为广泛,种植面积最大。气候条件表现为夏季干热、冬季寒冷且干燥,四季温差显著。年平均降水量292 mm,而年蒸发总量则高达2444 mm,远超降水量,极大地加剧土壤的盐渍化进程。该地区年平均气温8.3℃,年平均无霜期159 d,平均风速1.8 m/s。礼和乡隶属于引黄灌区,灌溉所用黄河水的矿化度0.5 g/L。然而,由于黄河顶托效应的影响,导致该地地下水矿化度偏高,一般为2.91~4.72 g/L,地下水位埋深则大多为1.32~1.98 m<sup>[1]</sup>。

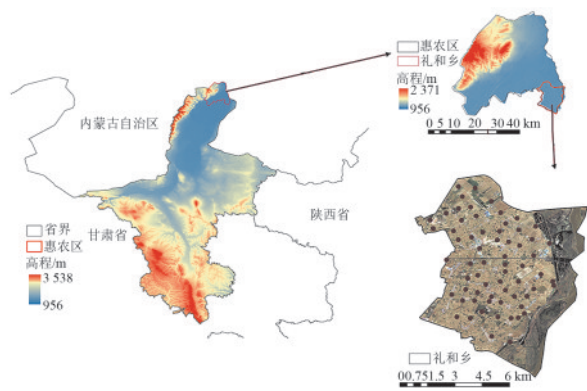


图 1 研究区域概况及采样点分布

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

1.2 数据获取

1.2.1 土壤数据采集与处理 根据宁夏引黄灌区典型物候特征,将春季(3—4月)作物种植前的时期定义为裸土期,将夏季(7—8月)作物生长茂盛的时期定义为植被覆盖期,以表征土壤盐分反演模型的季节性差异。本研究的土壤样本采集分别于2024年7月31日、2024年8月31日、2025年3月31日和2025年4月20日进行。使用五点采样法,分别采集0~20 cm土层土壤样本,数量分别为45、55、64和30。在采样过程中,使用GPS手持设备记录每个采样点的经纬度,并同时记录采样点的编号、土地利用类型及植被长势等相关信息。为避免采集杂质和表层覆盖物,所有样本在采集后剔除荒草、碎石等杂物,随后将土壤样本放入烘箱中,在105 °C下烘干8 h以去除水分。土壤样本研磨至通过1 mm筛网后,按照水土比5:1的比例配置提取液。使用电导率仪测量土壤提取液的电导率。

土壤盐分(SSC, g/kg)值通过建立土壤电导率与

烘干后盐分含量之间的定量关系获得,该关系基于大量试验确定。通过这些试验结果,能够建立土壤电导率与土壤盐分之间的定量关系,从而实现对含盐量的精准计算。标定公式为:

$$Y = 0.0054951X - 0.00131 \quad (R^2 = 0.998) \quad (1)$$

式中:Y为土壤盐分, g/kg;X为土壤的电导率,  $\mu\text{S}/\text{cm}$ 。

1.2.2 Sentinel-2 多光谱数据获取 本研究使用来自 Google Earth Engine(GEE)平台的 Sentinel-2 SR 数据,数据参考 WGS84 坐标系统,并采用 UTM 投影方式。数据由 Sentinel-2A、2B 2 颗卫星联合获取,具备约 5 d/次的重复观测周期。在数据预处理阶段,选用已完成辐射校正、大气校正和几何校正的影像,并确保影像与野外采样日期相匹配。通过分析 QA60 波段中的云掩码信息,有效剔除云层覆盖区域,从而提高影像的质量。其中影像的 B1-B9 波段分别为海岸带、蓝光、绿光、红光、红边 1、红边 2、红边 3、近红外, B8A 为红边 4 波段, B11 为短波红外 1, B12 为短波红外 2。

土壤盐渍化的形成机制较为复杂,不同地区土壤中盐分的类型及其成分组成也存在显著差异。相关研究<sup>[3]</sup>表明,在干旱和半干旱地区,基于遥感数据提取的各类光谱指数在土壤盐渍化监测中展现出良好的敏感性与应用潜力。同时,有学者<sup>[10]</sup>指出,影像的纹理特征在土壤盐分预测中同样具有重要的解释能力。因此,基于 Sentinel-2 表面反射率数据,本文共构建 20 种盐分指数和 20 种植被指数,相关公式见表 1 和表 2。目前,基于灰度共生矩阵(GLCM)来统计提取图像纹理特征是最流行和常用的<sup>[11]</sup>。因此,利用 GLCM 提取 Sentinel-2 8 个纹理特征(表 3)。

表 1 盐分指数计算公式

Table 1 Calculation formulas for salinity indices

计算公式	参考文献	计算公式	参考文献
$SI = (G + R)^{0.5}$	[13]	$S_7 = (SWIR1 - SWIR2) / (SWIR1 + SWIR2)$	[13]
$SI_1 = (G \times R)^{0.5}$	[12]	$S_8 = (G + R) / 2$	[13]
$SI_2 = (NIR^2 + G^2 + R^2)^{0.5}$	[12]	$S_9 = (G + R + NIR) / 2$	[13]
$SI_3 = (G^2 + R^2)^{0.5}$	[12]	$SI-T = (R / NIR) \times 100$	[13]
$SI_4 = SWIR1 / NIR$	[13]	$SSSI-1 = R - NIR$	[13]
$S_1 = B / R$	[12]	$SSSI-2 = (R \times NIR - NIR \times NIR) / R$	[13]
$S_2 = (B - R) / (B + R)$	[12]	$NDSI = (NIR - SWIR1) / (NIR + SWIR1)$	[13]
$S_3 = (G \times R) / B$	[12]	$CRSI = [(NIR \times R - G \times B) / (NIR \times R + G \times B)]^{0.5}$	[13]
$S_5 = (B \times R) / G$	[12]	$SRSI = [(NDVI - 1)^2 + SI^2]^{0.5}$	[13]
$S_6 = (R \times NIR) / G$	[12]	$SAIO = (G - NIR) / (B + NIR)$	[13]

注: B、G、R、NIR、SWIR1、SWIR2 分别表示蓝、绿、红、近红外、短波红外 1、短波红外 2 波段。下同。

表 2 植被指数计算公式  
Table 2 Calculation formulas for vegetation indices

计算公式	参考文献	计算公式	参考文献
$RVI=NIR/R$	[13]	$OSAVI=(NIR-R)/(NIR+R+0.16)$	[13]
$DVI=NIR-R$	[13]	$GNDVI=(NIR-G)/(NIR+G)$	[14]
$IPVI=NIR/(NIR+R)$	[13]	$ENDVI=(NIR+SWIR2-R)/(NIR+SWIR1+R)$	[5]
$GDVI=(NIR^2-R^2)/(NIR^2+R^2)$	[13]	$GVMi=[(NIR+0.1)-(SWIR1+0.02)]/[(NIR+0.1)+(SWIR1+0.02)]$	[13]
$NLI=(NIR^2-R)/(NIR^2+R)$	[13]	$EVI2=2.5 \times (NIR-R)/(NIR+2.4R+1)$	[14]
$NDVI=(NIR-R)/(NIR+R)$	[13]	$GBNDVI=(NIR-G-B)/(NIR+G+B)$	[15]
$ENDVI=(NIR+SWIR1-R)/(NIR+SWIR2+R)$	[13]	$GRNDVI=(NIR-G-R)/(NIR+G+R)$	[15]
$GARI=\{NIR-[G+\gamma \times (B-R)]\}/\{NIR+[G+\gamma \times (B-R)]\}$	[13]	$SAVI=[(1+L) \times (NIR-R)]/[(NIR+R+L)]$	[15]
$EVI=(1+M) \times (NIR-R)/(NIR+C_1 \times R-C_2 \times B+M)$	[13]	$REIP=700+\{[40 \times (R+RE3)/2-RE1]/RE2-RE1\}$	[16]
$MSAVI=\{2 \times NIR-1-[(2 \times NIR+1)^2-8 \times (NIR-R)]^{0.5}\}/2$	[18]	$ENDVI2=(NIR+SWIR2-R)/(NIR+SWIR1+R)$	[17]

注:RE1、RE2、RE3分别表示红边1、红边2、红边3波段;γ为调整因子,取0.5;C<sub>1</sub>为大气校正系数,取6;C<sub>2</sub>为大气校正系数,取7.5;L为土壤调整因子,取0.5;M为地表背景校正系数,取0.5。

表 3 纹理指数计算公式  
Table 3 Calculation formulas for texture indices

计算公式	参考文献	计算公式	参考文献
$Asm=\sum_{i,j=0}^{N-1} iP_i^2$	[10]	$Mean=\sum_{i,j=0}^{N-1} iP_{i,j}$	[18]
$Dissimilarity=\sum_{i,j=0}^{N-1} iP_{i,j} i-j $	[10]	$Contrast=\sum_{i,j=0}^{N-1} iP_{i,j}(i-j)^2$	[18]
$Homogeneity=\sum_{i,j=0}^{N-1} i \frac{P_{i,j}}{1+(i-j)^2}$	[10]	$Variance=\sum_{i,j=0}^{N-1} (P_{i,j}-\mu)^2/(N-1)$	[10]
$Entropy=\sum_{i,j=0}^{N-1} iP_{i,j}(-\ln P_{i,j})$	[10]	$Correlation=\sum_{i,j=0}^{N-1} ijP_{i,j}-\mu_1\mu_2$	[10]

注:i,j为成对像素的灰度级别;P<sub>i,j</sub>为第(i,j)项的概率值;N为量化图像中不同灰度水平的数量;μ<sub>1</sub>为与i相关的变量的平均值;μ<sub>2</sub>为与j相关的变量的平均值。

1.2.3 Sentinel-1合成孔径雷达数据 Sentinel-1卫星搭载的合成孔径雷达(SAR)能够提供高时空分辨率的C波段数据,且能够在各种气象条件下稳定获取影像数据。本研究选择 Sentinel-1 IW 模式 Level-1 GRD 产品,该数据集已在GEE平台上完成热噪声去除、辐射校正等基本预处理步骤。

为提高后向散射系数与土壤盐分之间的相关性,本研究对植被覆盖期的 Sentinel-1 数据应用水云模型处理,以有效消除数据中的干扰因素<sup>[5]</sup>。通过选择合适的雷达极化方式并进行相应的转换和组合,进一步增强模型的预测精度。在此基础上,研究选用多种极化指数进行建模(表4)。

表 4 极化指数计算公式  
Table 4 Calculation formulas for polarization indices

指数	参考文献	指数	参考文献
VH	[5]	$(VV^2-VH^2)/(VV^2+VH^2)$	[19]
VV	[5]	VV/VH	[19]
I/VV	[5]	VV+VH	[20]
I/VH	[5]	VV-VH	[19]
VV <sup>2</sup>	[5]	$(VV-VH)/(VV+VH)$	[20]
VH <sup>2</sup>	[5]	VH/VV	[20]
VV <sup>2</sup> +VH	[5]	log VV-log VH	[20]
VH <sup>2</sup> -VV	[5]	$(VH/VV)^2$	[20]

1.2.4 环境变量 农田土壤盐分的累积是一个受多种环境因素共同作用的复杂生态过程。在这一过程中,地形因子和地表温度常被视为预测土壤盐分的重要环境变量。地形因子通过影响水分和盐分在土壤中的运动、分布及其动态平衡,进而对土壤盐分的积累过程产生显著影响<sup>[21]</sup>。因此,本研究采用GEE平台提供的SRTM数字高程模型计算地形因子,包括坡向(aspect)、海拔(elevation)、LS因子(LS-Factor)、平面曲率(plan curvature)、剖面曲率(profile curvature)、粗糙度(roughness)、地形湿度指数(TWI)、坡度(slope)、地形位置指数(TPI)及SPI(水流强度指数)10个因子。这些地形因子与Landsat-9热红外影像计算得到的地表温度(LST)一起,共同构成模型中的环境变量。

### 1.3 反演因子筛选算法构建

针对6类、89个反演因子,采用2阶段变量筛选策略,优化土壤盐分反演因子的选择,以解决高维数据和共线性问题。首先,基于皮尔逊相关分析对光谱变量进行初筛。鉴于植被覆盖期地表遮蔽效应会削弱光谱参数与土壤盐分的关联性,设置差异化的筛选阈值:裸土期剔除 $|R^2| < 0.30$ 的弱相关变量,植被覆盖期剔除 $|R^2| < 0.20$ 的波段<sup>[8]</sup>,旨在快速去除信息量低或与目标变量关联性极弱的因子,以降低后续计算复杂度。

在此基础上,引入连续投影算法(SPA)实施二次特征优选。SPA是一种特征选择方法,旨在解决变量间的共线性问题并筛选最优变量组合<sup>[9]</sup>。其核心思想是通过迭代投影操作,选择包含最多有效信息且与其他变量共线性最小的特征子集。相较于传统的主成分分析(PCA)等降维方法,SPA的优势在于直接选择原始特征变量,更利于模型的物理解释。最后,采用RMSE作为评估指标,选取预测性能最优的特征子集作为建模变量。该方法通过分层筛选机制,有效平衡变量间的共线性与信息冗余问题,提升模型的解释性与泛化能力。

### 1.4 模型预测与验证

1.4.1 预测模型 随机森林(random forest, RF)是一种基于Bagging算法和CART决策树相结合的集成学习算法。通过随机抽样和特征选择,能够有效处理高维数据,且具有较强的抗过拟合能力<sup>[22]</sup>,近些年在土壤盐分的估算应用广泛。本研究中通过K折交叉验证( $k=5$ )训练100次模型,随机森林回归树设置为500,最小叶子数为1。

支持向量机回归(support vector regression, SVR)是通过在高维空间中寻找最优超平面来拟合数据,能够处理非线性问题并具有较好的泛化能力<sup>[23]</sup>,其基本

思想是通过最大化最优超平面分离边缘间的间隔来解决正确分开正例与反例的二分类问题。研究将样本数量70%为训练集,30%为测试集,通过网格搜索对SVM的超参数进行优化,采用5折交叉验证( $k=5$ )来选择最佳的超参数组合,训练次数为100次。

反向传播神经网络(backpropagation neural network, BPNN)是一种多层前馈神经网络,通过反向传播算法调整权重,适合处理复杂的非线性关系,能够在大规模数据集上取得较好的预测效果<sup>[24]</sup>。研究将样本数量70%为训练集,30%为测试集,采用交叉验证和Optuna超参数结合进行模型参数搜寻,BPNN模型迭代次数设置为1000次,误差阈值设置为0.00001,并进行100次训练。

1.4.2 模型验证 为了对反演模型精度进行评价,使用决定系数( $R^2$ )、平均绝对误差(MAE)、均方根误差(RMSE)3种验证指标对其进行精度评价。决定系数越接近1,均方根误差和均方误差越小,模型精度越高。

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

式中: $y_i$ 为实际值; $\hat{y}_i$ 为模型预测值; $\bar{y}$ 为实际值的平均值; $n$ 为数据点的数量。

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

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

## 2 结果与分析

### 2.1 实测土壤盐分

根据第三次全国土壤普查盐渍度分类分级标准<sup>[25]</sup>,将盐碱地划分为5个等级,分级标准见表5。根据分级标准,研究区实测土壤盐渍化程度见图2。裸土期土壤盐分为0.11~6.51 g/kg,平均值为1.98 g/kg,植被覆盖期土壤盐分为0.04~6.38 g/kg,平均值为1.37 g/kg。根据分级标准,研究区采集的裸土期和植被覆盖期土壤样本均属于非盐土,其中非盐碱土占主导地位;在盐碱化土壤样本中,以轻度盐碱土为主。

表5 土壤盐渍化程度分级标准

Table 5 Classification criteria for soil salinization levels

含盐量/(g·kg <sup>-1</sup> )	土壤盐渍化类型
0~2	非盐碱土
2~4	轻度盐碱土
4~6	中度盐碱土
6~10	重度盐碱土
>10	盐土




图 2 土壤盐分  
Fig.2 Soil salinity

2.2 土壤盐分与反演因子相关性筛选

由图 3 可知,在裸土时期, Sentinel-2 原始波段均呈正相关性,且大部分波段对盐分反应都比较强烈,筛选出 B1-B8 及 B8A 共 9 个波段,分别为 0.394、0.532、0.467、0.411、0.391、0.376、0.409、0.392、0.374,盐分指数除 CRSI 与  $SI_4$  呈负相关,其余均为正相关,并筛选出 CRSI(-0.480)、 $S_8$ (0.432)、 $S_5$ (0.494)、 $SI_4$ (-0.397)、SAIO(0.422)、 $SI_1$ (0.434)、SI(0.437)、 $SI_2$ (0.433)、 $S_9$ (0.429)、NDSI(0.404)、SRSI(0.437)、 $SI_3$ (0.439)、 $S_1$ (0.463)、 $S_2$ (0.464),植被指数与盐分指数相反,除 GVMi、REIP、NLI 以外,均为负相关,筛选出 ENDVI(-0.377)、ENDVI1(-0.377)、ENDVI2

(-0.481)、GARI(-0.417)、GBNDVI(-0.477)、GNDVI(-0.399)、GRNDVI(-0.357)、SAVI(-0.399)、GVMi(0.414)、REIP(0.323)、NLI(0.319),极化指数与环境变量分别筛选出  $VH^2$ (-0.300)、 $VV/VH$ (0.303)、 $plan\_curvature$ (0.302),而环境变量在此时期与盐分的关联性显著降低,共计 37 种反演因子。

在植被覆盖时期, Sentinel-2 原始波段的光谱响应呈现两极分化特征, B1-B5 波段与盐分呈正相关,其余呈负相关,其中 B7、B9 与 B8A 的相关性最强,分别为 -0.249、-0.390、-0.268。盐分指数与土壤盐分的关联呈现双向特性,与之相反,植被指数普遍与盐分呈负相关。盐分指数与植被指数分别筛选出 CRSI(-0.236)、SI-T(0.206)、SAIO(0.211)、ENDVI(-0.228)、ENDVI1(-0.228)、ENDVI2(-0.222)、MSAVI(-0.206)、GARI(-0.203)、GBNDVI(-0.210)、GNDVI(-0.209)、NLI(-0.240)。针对纹理特征筛选出  $entropy$ (-0.291)、 $asm$ (0.289)、 $homogeneity$ (0.217)。18 个极化指数绝大部分与盐分呈正相关,其中筛选出  $VV$ (0.237)、 $I/VV$ (-0.237)、 $VV^2$ (0.207)、 $VV^2+VH$ (0.236)。环境变量中的地形因子在植被覆盖期发挥显著作用,除 TWI 其余都是负相关,其中  $aspect$ (-0.277)、 $elevation$ (-0.259)、 $profile\_curvature$ (-0.230)、 $SPI$ (-0.242)、 $Slope$ (-0.242)、 $TPI$ (-0.213)、 $TWI$ (0.299),共计 28 种反演因子。




图 3 土壤盐分与反演因子相关性分析

Fig.3 Correlation analysis between soil salinity and inversion factors

2.3 敏感反演因子筛选

利用 SPA 算法对以上反演变量进行二次筛选,去除冗余变量,选择最佳变量及个数。裸土时期共选出 21 个最佳变量,分别为  $VH^2$ 、REIP、B7、 $SI_1$ 、 $S_8$ 、

CRSI、 $SI_2$ 、SAIO、GARI、 $S_1$ 、B3、B2、NDSI、ENDVI2、GVMi、GBNDVI、B5、B6、B4、 $S_5$ 、 $plan\_curvature$ 。植被覆盖期共选出 15 个最佳变量,分别为 B9、GBNDVI、GRSI、GARI、SI-T、TWI、

VV、NLI、SAIO、profile\_curvature、aspect、B8A、MSAVI、GNDVI、homogeneity(图4)。




图4 反演因子SPA筛选

Fig. 4 SPA screening results of inversion factors

2.4 土壤盐分估算模型筛选

由表6、图5可知,在裸土期,RF模型展现出显著优势, $R^2$ 高达0.92, RMSE与MAE分别为0.558 5, 0.356 6 g/kg,表明模型对训练数据拟合程度极佳;测试集 $R^2$ 为0.75,显著高于SVR和BPNN,测试集

RMSE与MAE虽较训练集有所上升,但仍是3个模型中的最小值,表明其在裸土期具备最强的泛化能力。SVR模型次之,训练集 $R^2$ 为0.78,误差指标表现尚可,甚至MAE低于RF训练集,但测试集 $R^2$ 降至0.50, RMSE与MAE显著升高,暴露其对训练数据噪声过度敏感的过拟合问题。BPNN表现最差,训练集 $R^2$ 仅0.46, RMSE与MAE分别达1.146 4、0.775 7 g/kg,显著高于其他模型;测试集 $R^2$ 几乎无变化,但误差指标剧增,模型完全丧失盐分反演能力。

表6 裸土时期土壤盐分反演模型评价

Table 6 Evaluation of soil salinity inversion models during bare soil period

模型	训练集			测试集		
	$R^2$	RMSE/ ( $g \cdot kg^{-1}$ )	MAE/ ( $g \cdot kg^{-1}$ )	$R^2$	RMSE/ ( $g \cdot kg^{-1}$ )	MAE/ ( $g \cdot kg^{-1}$ )
RF	0.92	0.558 5	0.356 6	0.75	0.884 3	0.899 1
SVR	0.78	0.668 3	0.294 5	0.50	0.985 5	0.725 7
BPNN	0.46	1.146 4	0.775 7	0.44	2.218 6	1.887 6

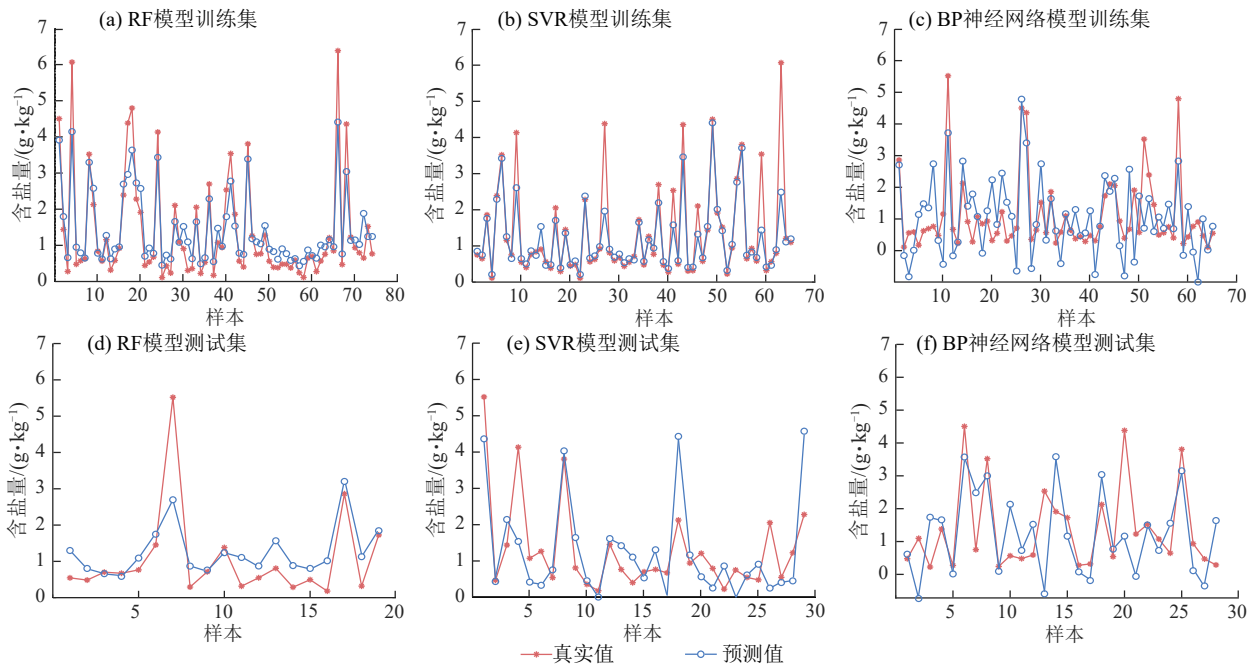


图5 裸土期训练集与测试集预测结果对比

Fig.5 Comparison of predicted results between training and testing sets during bare soil period

由表7、图6可知,在植被覆盖期,RF训练集 $R^2$ 为0.94,误差指标优于裸土期,但测试集 $R^2$ 下降至0.51,为3模型中降幅最大,反映其过度记忆训练数据特征的过拟合问题。SVR训练集 $R^2$ 高达0.93, RMSE=0.382 1 g/kg, MAE=0.110 9 g/kg为植被覆盖期最优值,尤其MAE表现突出;测试集 $R^2$ 仅0.35,但RMSE与MAE分别为0.635 4、0.577 1 g/kg,绝对误差稳定性优于RF。BPNN持续处于劣势,训练集 $R^2$ 为0.50,测试集 $R^2$ 降至0.28, RMSE与MAE达1.315 3、1.058 1 g/kg,为植被期最差表现,模型泛化能力完全

失效。综上,裸土期首选RF;植被期需权衡,重误差选SVR,重趋势可优化RF;BPNN均不适用。

表7 植被覆盖期土壤盐分反演模型评价指标

Table 7 Evaluation indicators of soil salinity inversion models during vegetation-covered period

模型	训练集			测试集		
	$R^2$	RMSE/ ( $g \cdot kg^{-1}$ )	MAE/ ( $g \cdot kg^{-1}$ )	$R^2$	RMSE/ ( $g \cdot kg^{-1}$ )	MAE/ ( $g \cdot kg^{-1}$ )
RF	0.94	0.468 0	0.325 4	0.51	0.840 3	0.604 7
SVR	0.93	0.382 1	0.110 9	0.35	0.635 4	0.577 1
BPNN	0.50	1.032 4	0.662 4	0.28	1.315 3	1.058 1

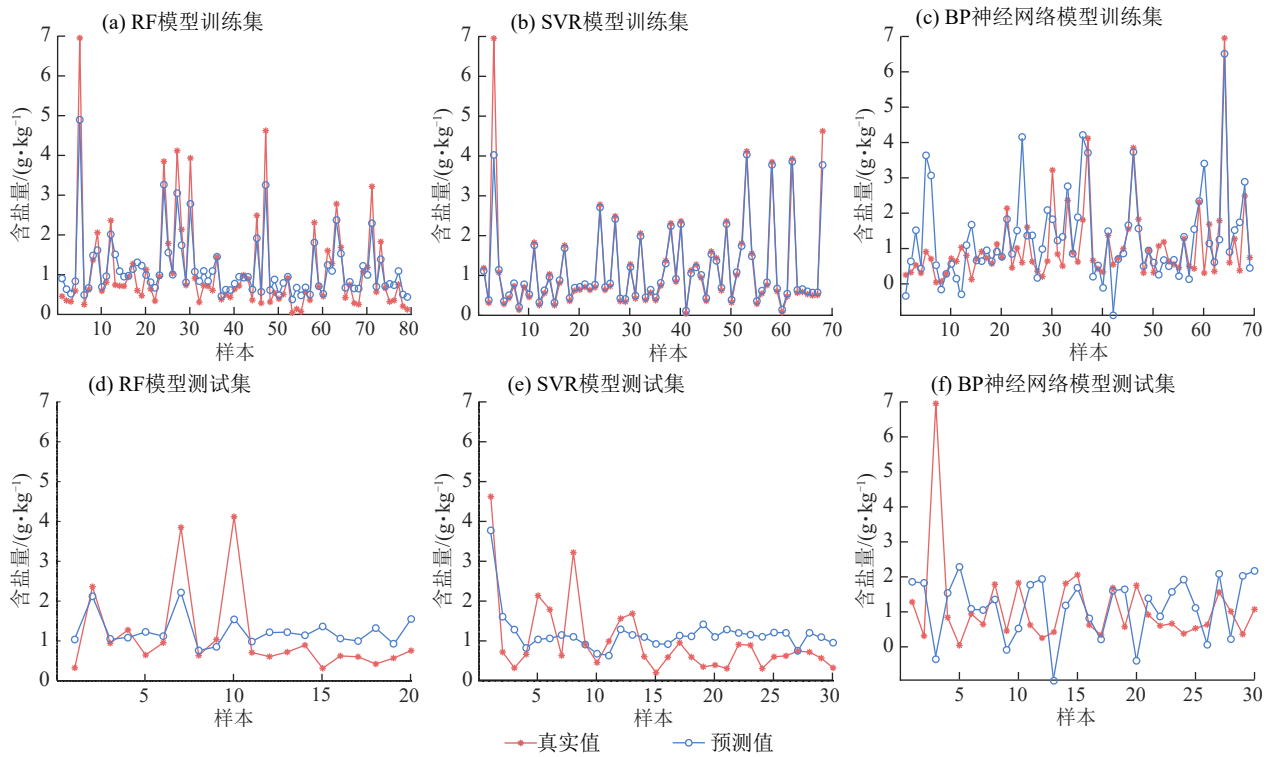


图 6 植被覆盖期训练集与测试集预测结果对比

Fig. 6 Comparison of predicted results between training and testing sets during vegetation-covered period

### 3 讨论

#### 3.1 多源数据协同反演优势

本研究核心在于构建一个集成多源遥感数据、利用高效特征选择SPA算法和机器学习的季节性土壤盐分反演框架。相较于单一数据源,整合光学、微波、热红外及地形多维信息<sup>[5]</sup>,显著提升模型应对季节变化的适应能力,预测准确性及泛化能力<sup>[4]</sup>。已有研究<sup>[26]</sup>表明,光学传感器与合成孔径雷达联合观测在多时相、多尺度应用中展现出强大的潜力。但土壤盐分与Sentinel-1雷达因子间的相关性易受影像-采样时间差、植被覆盖变化及地表条件影响而不稳定<sup>[8]</sup>。在裸土时期,土壤的光谱反射与微波散射特性能够直接反映盐分状况,通常与电导率具有显著统计相关性,遥感精准度高。相比之下,在植被覆盖期,由于冠层的遮蔽,盐渍化特征的识别需依赖植被指数、水分指数和极化分解参数等间接因子,并且受到土壤湿度、粒径组成及植被结构等多重因素的干扰,这些都影响模型的稳定性。

#### 3.2 不同季节主导反演因子的差异及其成因

本研究发现,裸土时期与植被覆盖期在盐分反演机制及主导因子上存在明显差异。裸土期地表裸露,使传感器可直接捕获与盐分相关的光谱响应特征(如反射率、盐分指数),显著提升反演敏感性。本研究表明,该时期盐分反演的主要因子为Sentinel-2原始波段反射率与盐分指数,LI等<sup>[27]</sup>进一步证实盐

分指数对盐分变化高度敏感。相比之下,植被覆盖期土壤盐分反演的主要影响因子为地形因子与植被指数,与已有研究<sup>[8]</sup>结论一致。其中,植被指数常与土壤盐分呈负相关,反映盐分胁迫对植被生长的抑制作用;地形因子则通过调控地下水运移与地表径流过程,间接影响盐分空间分异<sup>[28]</sup>。基于上述差异,裸土期应优先利用高响应光谱波段与盐分指数直接表征盐分特征,可辅以地形信息修正空间异质性;植被覆盖期则需侧重结合地形与植被参数进行间接反演。环境因子在土壤盐分变化中的作用不可忽视,尤其是降水量、地下水埋深等因素对盐分的时空分布具有显著影响。然而,本文未考虑这些因素对土壤盐分变化的影响,未来研究可进一步整合多源环境数据,以提升模型的机理解释能力与预测普适性。

#### 3.3 模型性能差异分析

RF在裸土期和植被覆盖期均表现优异,在裸土期的训练效果显著优于SVR与BPNN,与崔晓彤等<sup>[6]</sup>研究结果一致,在植被覆盖期,RF的综合表现与SVR相当,但均显著优于BPNN。有研究<sup>[29]</sup>表明,RF优势源于集成学习架构的鲁棒性,通过Bootstrap采样和随机子空间策略构建多棵决策树,在裸土期可精准捕捉盐分指数与地形因子的非线性协同效应,在植被期则通过特征重要性排序自适应筛选关键变量,缓解植被遮蔽导致的数据信噪比降低问题。相比之下,SVR在测试集与训练集在测试集与训练

集上的性能差异较大,核心症结在于核函数对超参数的高度敏感性,当裸土期盐分空间异质性超出训练数据分布范围时,其泛化能力急剧下降。BPNN在2个时期均表现不佳,可能是由于其训练过程容易陷入局部最优解,且对参数设置较为敏感,在处理大规模复杂数据时,需要更多的训练时间和数据量来优化模型<sup>[21]</sup>。此外,数据的噪声和样本的不均衡性也可能影响BPNN模型的性能。未来,可以探索一维卷积神经网络(1DCNNs)、深度神经网络(DNN)、极端梯度提升模型(XGBoost)、轻量梯度提升机模型(LightGBM)等算法<sup>[8]</sup>,这些模型在时序特征提取、高维非线性关系建模及计算效率方面具有优势,有望进一步提升复杂场景下的盐分反演精度。

## 4 结论

1)通过皮尔逊相关性分析与连续投影算法相结合的两阶段变量筛选策略,成功优化不同季节的反演因子集。裸土期土壤盐分反演主要依赖于Sentinel-2原始波段反射率(如B2, $R^2=0.532$ )和盐分指数(如 $S_2$ , $R^2=0.464$ );植被覆盖期则主要受地形因子(如TWI, $R^2=0.299$ )和植被指数(如ENDVI, $R^2=-0.228$ )驱动,为精准监测不同土地覆盖条件下的土壤盐分提供关键指标依据。

2)对比RF、SVR和BPNN 3种模型,RF模型在裸土期和植被覆盖期均表现较优且稳定。其在裸土期训练集和测试集的 $R^2$ 分别达到0.92(RMSE=0.558 5 g/kg)和0.75(RMSE=0.884 3 g/kg);在植被覆盖期训练集和测试集的 $R^2$ 分别为0.94(RMSE=0.468 0 g/kg)和0.51(RMSE=0.840 3 g/kg)。RF模型展现出对宁夏引黄灌区复杂条件下土壤盐分含量的较强估算能力。

3)本研究提出的集成Sentinel-1 SAR、Sentinel-2多光谱、Landsat-9 LST和SRTM地形环境多源遥感数据,并结合SPA特征优选与RF等机器学习建模,有效实现不同季节(裸土期与植被覆盖期)土壤盐分的较高精度反演,该方法为区域农田盐渍化动态监测提供一种高效的技术支撑。

### 参考文献:

- [1] 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.
- [2] TOMAZ A, PALMA P, FIALHO S, et al. Risk assessment of irrigation-related soil salinization and sodification

in Mediterranean areas[J]. Water, 2020, 12(12): e3569.

- [3] 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: e712831.
- [4] 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.
- [5] 巴亚岚,张智韬,谢坪良,等.集成Sentinel-1/2和环境变量的新疆农田土壤含盐量反演[J].农业工程学报,2024,40(16):171-179.  
BA Y L, ZHANG Z T, XIE P L, et al. Inverting soil salinity of farmland in Xinjiang by integrating Sentinel-1/2 and environmental variables[J]. Transactions of the Chinese Society of Agricultural Engineering, 2024, 40(16): 171-179.
- [6] 崔晓彤,靳亚红,兰凤,等.基于多光谱影像的冬小麦地土壤含盐量反演研究[J].河北农业大学学报,2025,48(1):107-115.  
CUI X T, JIN Y H, LAN F, et al. Inversion of salt content in winter wheat soil based on multi-spectral images [J]. Journal of Hebei Agricultural University, 2025, 48(1): 107-115.
- [7] 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.
- [8] 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.
- [9] 姜传礼,赵健赞,丁圆圆,等.SPA算法与机器学习的黄河源土壤水分反演[J].光谱学与光谱分析,2023,43(6):1961-1967.  
JIANG C L, ZHAO J Y, DING Y Y, et al. Study on soil water retrieval technology of Yellow River source based on SPA algorithm and machine learning [J]. Spectroscopy and Spectral Analysis, 2023, 43(6): 1961-1967.
- [10] 殷皓原.基于Sentinel系列卫星遥感数据的河套灌区土壤含盐量反演模型[D].陕西杨凌:西北农林科技大学,

- 2023.
- YIN H Y. Inversion model of soil salt content in Hetiao irrigation area based on Sentinel series satellite remote sensing data [D]. Yangling, Shaanxi: Northwest A&F University, 2023.
- [11] YUE J B, YANG G J, TIAN Q J, et al. Estimate of winter-wheat above-ground biomass based on UAV ultrahigh-ground-resolution image textures and vegetation indices [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2019, 150: 226-244.
- [12] 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)*, 2025, 39(3): 339-345.
- 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)*, 2025, 39(3): 339-345.
- [13] 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: e115656.
- [14] 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 stress using UAV remote sensing [J]. *Journal of Geo-Information Science*, 2021, 23(3): 536-549.
- [15] 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 multispectral imaging [J]. *Arid Zone Research*, 2024, 41(5): 894-904.
- [16] 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.
- [17] 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.
- [18] 丁斌彬.基于深度学习的无人机多光谱遥感估算土壤含盐量方法[D].陕西,杨凌:西北农林科技大学,2024.
- DING B B. A method for estimating soil salinity using unmanned aerial vehicle multispectral remote sensing based on deep learning [D]. Yangling, Shaanxi: Northwest A&F University, 2024.
- [19] ZHANG Q Q, LI L, SUN R Z, et al. Retrieval of the soil salinity from sentinel-1 dual-polarized SAR data based on deep neural network regression [J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 19: e4006905.
- [20] WANG J J, WU F, SHANG J L, et al. Saline soil moisture mapping using Sentinel-1A synthetic aperture radar data and machine learning algorithms in humid region of China's east coast [J]. *Catena*, 2022, 213: e106189.
- [21] WANG N, XUE J, PENG J, et al. Integrating remote sensing and landscape characteristics to estimate soil salinity using machine learning methods: A case study from southern Xinjiang, China [J]. *Remote Sensing*, 2020, 12(24): e4118.
- [22] 宁可欣,孙晨曦,万华伟,等.协同空一天遥感的荒漠草原植被覆盖度反演方法研究[J].*遥感技术与应用*, 2024, 39(5): 1054-1063.
- NING K X, SUN C X, WAN H W, et al. Research on the inversion method of desert grassland fractional vegetation cover based on collaborative UAV-satellite remote sensing [J]. *Remote Sensing Technology and Application*, 2024, 39(5): 1054-1063.
- [23] HUANG Y, ZHAO L. Review on landslide susceptibility mapping using support vector machines [J]. *Catena*, 2018, 165: 520-529.
- [24] 卢琪,苏凯新,张继旺,等.基于BP神经网络和遗传算法的简单链型悬挂接触网结构优化[J].*机械工程学报*, 2024, 60(12): 313-320.
- LU Q, SU K X, ZHANG J W, et al. Structural optimization of simple catenary based on BP neural network and genetic algorithm [J]. *Journal of Mechanical Engineering*, 2024, 60(12): 313-320.
- [25] 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). <https://nyncj.beijing.gov.cn/nycj/snxx/ztl/dscqgtrpc/gcgf/436227670/index.html>.
- Office of the Leading Group for the Third National Soil Census, State Council. Technical specifications for the calibration of soil type names in the Third National Soil Census (Revised Edition) [EB/OL]. (2023-02-27). <https://nyncj.beijing.gov.cn/nycj/snxx/ztl/dscqgtrpc/gcgf/>

- 436227670/index.html.
- [26] CHENG G, DING H, YANG J, et al. Crop type classification with combined spectral, texture, and radar features of time-series Sentinel-1 and Sentinel-2 data [J]. *International Journal of Remote Sensing*, 2023, 44(4): 1215-1237.
- [27] LI J, ZHANG T 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): e2332.
- [28] CALLOW J N, HIPSEY M R, VOGWILL R I J. Surface water as a cause of land degradation from dryland salinity [J]. *Hydrology and Earth System Sciences*, 2020, 24(2): 717-734.
- [29] WANG P, ZHANG N C. Decision tree classification algorithm for non-equilibrium data set based on random forests [J]. *Journal of Intelligent and Fuzzy Systems*, 2020, 39(2): 1639-1648.
- (上接第 443 页)
- [31] WANG Y, DAI E, GE Q, et al. Spatial heterogeneity of ecosystem services and their trade-offs in the Hengduan Mountain region, southwest China [J]. *Catena*, 2021, 207: e105632.
- [32] 高春莲, 胡宝清, 黄思敏, 等. 山江海耦合关键带生态系统服务评价及服务簇识别研究: 以桂西南喀斯特: 北部湾为例 [J]. *环境工程技术学报*, 2024, 14(4): 1346-1356.
- GAO C L, HU B Q, HUANG S M, et al. Evaluation and service cluster identification of ecosystem services in mountain-river-sea coupled critical zones: A case study of Karst-Beibu Gulf in southwest Guangxi [J]. *Journal of Environmental Engineering Technology*, 2024, 14(4): 1346-1356.
- [33] CHEN C, LIU Y. Spatiotemporal changes of ecosystem services value by incorporating planning policies: A case of the Pearl River Delta, China [J]. *Ecological Modelling*, 2021, 461: e109777.
- [34] DING Y, DONG X, FENG W, et al. Tetrabromobisphenol S alters the circadian rhythm network in the early life stages of zebrafish [J]. *Science of the Total Environment*, 2022, 806: e150543.
- [35] 赵忠旭, 张燕杰, 潘影, 等. 夜间灯光数据支持下西藏人类活动强度变化对生态系统调节服务的影响 [J]. *地球信息科学学报*, 2020, 22(7): 1544-1554.
- ZHAO Z X, ZHANG Y J, PAN Y, et al. Impact of human activity intensity changes on ecosystem regulation services in Xizang supported by nighttime light data [J]. *Journal of Geo-information Science*, 2020, 22(7): 1544-1554.
- [36] 冯娟. 基于 InVEST 模型和 SWAT 模型的秦岭北麓水源涵养时空格局分析 [D]. 西安: 西北大学, 2021.
- FENG J. Spatiotemporal pattern of water conservation in the northern foot of Qinling Mountains based on InVEST and SWAT models [D]. Xi'an: Northwest University, 2021.
- [37] 邢笑天, 王琪, 赵佳俊, 等. 耦合 InVEST-PLUS 模型的济南都市圈土地利用及碳储量变化研究 [J]. *自然资源遥感*, 2025, 37(4): 118-130.
- XING X T, WANG Q, ZHAO J J, et al. Land use and carbon storage changes in Jinan metropolitan area based on coupled InVEST-PLUS models [J]. *Remote Sensing for Natural Resources*, 2025, 37(4): 118-130.
- [38] CONANT JR B, ROBINSON C E, HINTON M J, et al. A framework for conceptualizing groundwater-surface water interactions and identifying potential impacts on water quality, water quantity, and ecosystems [J]. *Journal of Hydrology*, 2019, 574: 609-627.