doi:10.6041/j.issn.1000-1298.2025.11.062

协同哨兵 1/2 多源遥感数据的土壤含盐量反演

黄　悦　李仙岳　高慧娟

(内蒙古农业大学水利与土木建筑工程学院, 呼和浩特 010018)

摘要: 快速监测区域土壤盐渍化信息,对于盐渍化治理与生态环境保护具有重要意义。针对单一数据源、指数、算法导致土壤含盐量反演精度不高的问题,本文以河套灌区义长灌域左三支渠 2022—2023 年土壤含盐量为研究对象,利用哨兵 1/2 协同反演土壤含盐量,再通过水云模型、灰度共生矩阵获得 Sentinel-1 的图像纹理和极化指数。以此为基础构建 3 种数据集,分别为 A(盐分指数)、B(盐分指数+图像纹理)、C(盐分指数+图像纹理+极化指数),将贝叶斯信息准则和全子集筛选法相结合筛选出敏感因子,结合 3 种机器学习方法构建最优土壤含盐量预估模型并绘制反演图。结果表明,除 B8、B11 和 B12 外土壤表层反射率与土壤含盐量呈弱负相关,植被指数和极化指数与土壤含盐量呈极显著正相关;Sentinel-1 不同极化波段的图像纹理均与土壤含盐量有较高相关性,其中 VH 波段最佳。盐分指数、图像纹理和极化指数在机理上具有互补性,与单一或 2 个组合相比,决定系数从 0.723、0.771 提升到 0.863,在土壤含盐量预估中具有很大潜力。基于盐分指数、图像纹理和极化指数构建的随机森林模型为土壤含盐量监测的最佳模型(决定系数为 0.863,平均绝对误差为 0.17%,均方根误差为 0.12%),显著改善了对土壤含盐量较低值的低估情况。研究结果为盐渍化地区土壤含盐量预测提供了理论依据。

关键词: 土壤含盐量; 盐分指数; 图像纹理; 极化指数; Sentinel-1/2; 机器学习

中图分类号: S127　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)11-0640-11　　**OSID**:

Soil Salinity Inversion with Sentinel-1/2 Multi-source Remote Sensing Data

HUANG Yue　LI Xianyue　GAO Huijuan

(*College of Water Conservancy and Civil Engineering*, *Inner Mongolia Agricultural University*, *Hohhot* 010018, *China*)

Abstract: Rapid monitoring of soil salinization information in the region is of great significance for salinization management and ecological environmental protection. To address the issue of low inversion accuracy of soil salinity due to single data sources, indices, and algorithms, the soil salinity in the left third branch canal of the Yichang irrigation area in the Hetao region from 2022 to 2023 was focused. Sentinel-1/2 data was utilized to collaboratively invert soil salinity, and then obtain the image texture and polarization indices of Sentinel-1 through the water cloud model and gray-level co-occurrence matrix. Based on this, three datasets were constructed: A (salinity index), B (salinity index with image texture), and C (salinity index with image texture and polarization index). The Bayesian information criterion and all-subsets selection method were combined to select sensitive factors, and three machine learning methods were used to construct the optimal soil salinity estimation model and produce inversion maps. The results showed that, except for bands B8, B11, and B12, the surface reflectance of the soil had a weak negative correlation with soil salinity, while the vegetation index and polarization index had a highly significant positive correlation with soil salinity; the image textures of Sentinel-1 different polarization bands were highly correlated with soil salinity, particularly in the VH band. The salinity index, image texture, and polarization index were complementary in mechanism, increasing the determination coefficient from 0.723 and 0.771 to 0.863 compared with that using a single or two combined factors, showing great potential in estimating soil salinity. The random forest model constructed based on the salinity index, image texture, and polarization index was the best model for monitoring soil salinity (with a determination coefficient of 0.863, mean absolute error of 0.17%, and root mean square

收稿日期: 2024-08-05　修回日期: 2024-09-06

基金项目: 国家重点研发计划项目(2022YFD1900802)和内蒙古科技计划项目(2022YFHH0039)

作者简介: 黄悦(1998—),男,硕士生,主要从事农业遥感应用研究,E-mail: 18604749760@163.com

通信作者: 李仙岳(1980—),男,教授,博士生导师,主要从事农业遥感应用研究,E-mail: lixianyue80@126.com

error of 0.12%), significantly improving the underestimation of low soil salinity values. The results can provide a theoretical basis for predicting soil salinity in salinized areas.

Key words: soil salinity; salinity index; image texture; polarization index; Sentinel - 1/2; machine learning

0　引言

土壤盐渍化是指土壤中的可溶性盐分因不合理的灌溉方式造成土壤盐分积累,使得土壤质量下降的过程[1]。我国作为农业大国[2],土壤盐渍化总面积达 3.69×10^7 hm^2[3]。内蒙古河套地区地处内陆,干旱少雨,农业生产灌溉主要依赖于农业生产者主动进行地面灌溉,由于缺乏科学的灌溉与种植知识,引起该地区严重的盐渍化[4]。及时准确地掌握土壤含盐量对于土地修复和提高农业生产力十分重要[5-6],提高土壤盐碱化程度监测准确性也是研究人员普遍关注的问题[7]。卫星遥感因其能实现对土壤含盐量相对快速和大面积反演而被广泛应用于土壤含盐量监测中[8-11]。目前应用在土壤含盐量监测方面的遥感卫星主要有光学卫星和雷达卫星,多光谱传感器受云雨天气影响程度强,无法在所有气候条件下准确监测大面积土壤含盐量[12];而合成孔径雷达传感器受云雨天气影响相对较弱,具备一定穿透性[13];水云模型提供了植被冠层和下层土壤后向系数解,可以较好地描述地表散射特征,反映植被覆盖下土壤含盐量[14]。为提高监测准确性,越来越多的研究协同光学卫星和雷达卫星共同反演土壤含盐量[15]。

随着多波段传感器的发展,诸多国内外学者基于土壤盐分与光谱特征间的关系及波段组合构建了大量土壤盐分指数,尝试用不同方法对区域土壤含盐量进行定量反演和预测。ALLBED 等[16]基于 IKONOS 卫星影像分析了 13 个土壤植被指数和盐分指数对沙特阿拉伯东部地区哈萨绿洲土壤盐度的预测能力,结果表明归一化盐分指数(Normalized differential salinity index, NDSI)和盐度指数(Salinity index T, SI - T)是评价植被密集均匀耕地土壤含盐量的最佳指标;ELIA 等[17]在对美国加利福尼亚州圣华金河谷地区土壤盐分的研究中发现,基于 Landsat7 ETM + 影像提取的冠层盐分响应指数(Canopy response salinity index, CRSI)对研究区土壤含盐量较敏感,预测精度较理想(决定系数 R^2 = 0.79);陈红艳等[18]在对黄河三角洲盐渍土的研究中引人短波红外波段对传统植被指数进行扩展,提出扩展的归一化植被指数(Extended normalized difference vegetation index, ENDVI),获得了较好的土壤含盐量空间反演结果;由于光谱信息极易随土壤表面色调和亮度等其它信息而改变,具有不稳定性,因此盐分指数在诊断土壤含盐量状况中存在一定局限性[19]。

图像纹理是一种用于量化相邻像素间数值变化的方法,可以有效反映物体表面细节和特定纹理特征[20-21]。有研究表明,光学卫星纹理特征不易被外界环境影响,稳定性比光谱信息更高,能用于有效反演土壤含盐量[22-23],向友珍等[24]利用图像纹理特征和植被指数构建模型提高土壤含盐量反演精度,预测精度提升较高(R^2 = 0.68);YANG 等[25]结合无人机多光谱和热红外信息,利用图像纹理反演水分胁迫下的夏玉米叶面积指数,发现图像纹理能显著提高反演精度。但图像纹理和盐分指数是基于二维影像数据计算所得,表达的信息不够全面。

极化指数是用于描述地物对雷达波散射特性的参数,通过水云模型可以有效地去除植被影响后的雷达后向散射系数及其极化组合形式。TRIPATHI 等[26]协同 Sentinel - 1 后向散射系数和 Sentinel - 2 多光谱数据,估算小麦生长早期的土壤含盐量,证明多源数据协同可以有效提高模型精度。马驰[27]通过 Sentinel - 1/2 影像融合构建土壤含盐量反演模型,结果表明融合影像可以显著提高波段信息与土壤含盐量间的相关性,从而提高模型反演精度。雷达和光谱数据互补可以弥补单一数据源的不足,获得更准确的反演效果。鉴于此,为优化土壤盐渍化监测精度,本研究以土壤含盐量作为土壤盐渍化划分指标,通过贝叶斯信息准则和全子集选法筛选盐分指数、图像纹理和极化指数及其组合得到最优指标组合,结合极限学习机、反向传播神经网络和随机森林 3 种机器学习方法构建土壤含盐量预估模型,基于最优土壤含盐量预估模型绘制左三支渠土壤盐渍化状况反演图,以期为卫星遥感监测土壤盐渍化状况提供科学依据和技术支持。

1　材料与方法

1.1　研究区概况

试验区位于内蒙古自治区河套灌区义和灌域左三支渠区域(41°07′~41°09′N,108°21′~108°22′E)(图 1),灌溉耕地约占总面积的 89.39%。属于温带大陆性干旱半干旱气候,日照时间长,昼夜温差

大,年平均降雨量 160 mm,年平均水分蒸发量 2 257 mm[28]。研究区灌溉方式以漫灌为主,灌溉用水为黄河水,盐度为 0.5 kg/m^3[29],干旱的气候条件、强烈的水分蒸发和不合理的灌溉是土壤盐分积累的主要原因[30]。

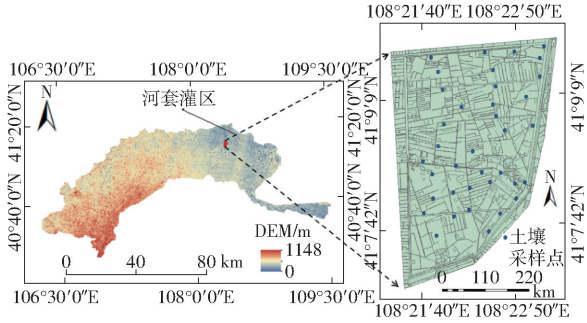


图 1 研究区位置及采样点位分布图

Fig. 1 Location of study area and distribution of sampling points

1.2 试验数据采集和预处理

1.2.1 卫星数据与预处理

Sentinel - 1 卫星搭载合成孔径侧视雷达(Synthetic aperture radar,SAR),所得到 C 波段产品受天气条件影响弱,可保持正常运行,从而获取具有高时空分辨率的图像。采用 IW(Interferometric wide swath)成像模式下的 GRD(Ground range detected)数据,图像覆盖范围为 250 km,地面分辨率为 5 m × 20 m,包含 2 种极化方式:垂直发射、垂直接收(Vertical transmit,vertical receive,VV)和垂直发射、水平接收(Vertical transmit,horizontal receive,VH)。Sentinel - 1A 数据在欧空局哥白尼数据中心获得(https://dataspace.copernicus.eu),经过轨道校正、热噪声去除、辐射校准、散斑滤波和地形校正预处理后,提取其后向散射系数。

Sentinel - 2 卫星携带多光谱成像仪(MSI),由 13 个不同空间分辨率的光谱带组成,包含可见光、近红外、短波红外波段;Sentinel - 2 分为 2A 和 2B 2 颗高分辨率多光谱卫星,轨道高度约 786 km。Sentinel - 2 数据下载时间接近野外土壤样本采集时间,云含量低于 5%,从美国 USGS 官方网站(https://www.usgs.gov/)下载,经过重采样、波段合成和裁剪等预处理后,提取其光谱反射率。

1.2.2 地面数据采集与分析

为避免土壤采样过程中受灌溉和降雨影响,同时保证地面土壤采样时间与卫星过境时间一致,于 2022 年 5 月 16 日、6 月 5 日、7 月 25 日、8 月 9 日、9 月 23 日,2023 年 5 月 11 日、6 月 10 日、7 月 15 日、8 月 9 日、9 月 13 日在左三支渠进行多次地面土壤采样试验。LAI 地面实测数据利用 LAI2000 型叶面积指数测量仪获得,在采样区选取 35 个样本点(图 1),通过手持 GPS 记录仪记录每个采样点的经纬度,实测数据采样点分布均匀,大小设置基本相同。在每个样本点附近随机进行 3 次测量,取平均值作为样本点最终值。土壤采样使用五点采样法[31]在土壤深度 0 ~ 10 cm 采集地表土样,每次采样选取 35 个相同采样点。取出土壤样本后,将其迅速放入带有编号的铝盒中保存,然后带回实验室进行处理。

室内土样处理主要包括以下步骤:首先,将土样在干燥箱中干燥 24 h,将完全干燥的土壤样品筛选去除杂质,放入研钵中充分研磨成粉末状;其次,将粉末状土壤样品放入带有编号的纸杯中进行溶液配置(土壤与水质量比为 1∶5),用搅拌棒充分搅拌配置的溶液,静置 24 h;然后,用滤纸过滤溶液,对上层透明层进行电导率(EC)测定(上海佑科仪器仪表有限公司生产的 DDS - 307A 型电导率仪);最后,用经验公式[19]计算每个土壤样品含盐量(Soil salt content,SSC),计算式为

$$SSC = (0.288\,2E_{C1:5} + 0.018\,3) \times 100\% \quad (1)$$

式中 $E_{C1:5}$——土壤电导率

1.3 数据获取

1.3.1 土壤盐渍化指数提取

研究发现遥感影像中的可见光和近红外波段对土壤盐渍化较为敏感,将其与土壤盐度关联构建土壤盐度指数,是监测裸地土壤盐渍化程度的一种有效方法[32]。另外,盐渍化土壤中的盐分对植物生长造成一定危害,盐渍化程度越重的地区植被覆盖度越低,因此植被覆盖状况是很好的盐渍化程度间接评价指标,据此判断土壤盐渍化程度的方法被广泛应用于土壤盐渍化遥感监测[33]。在查阅相关文献基础上,选取 NDSI、S1、S2、SI 等 10 种土壤盐度指数,NDVI 等 3 种植被指数以及基于 NDVI - SI 特征空间构建的土壤盐渍化遥感监测指数模型(Salinization detection index,SDI)共 13 种土壤盐分评价相关指数(表 1),分析其与土壤含盐量间的定量关系。

1.3.2 极化指数

在植被覆盖条件下,土壤水分和植被对雷达后向散射系数反演土壤含盐量产生影响。而水云模型为植被冠层和地表土壤的后向散射系数提供模型方法。水云模型最初由 ATTEMA 等[37]提出,该模型简化了微波在通过植被层时的复杂吸收和散射效应,仅考虑单次散射。PRÉVOT 等[38]对水云模型进行改进,改进水云模型的植被后向散射系数计算公式为

表 1　土壤盐渍化评价指数

Tab. 1　Evaluation index of soil salinization

名称	表达式	文献序号
归一化盐分指数	$NDSI=(R-NIR)/(R+NIR)$	[16]
盐分指数	$S1=B/R$	[16]
	$S2=(B-R)/(B+R)$	[16]
	$S3=GR/B$	[16]
	$S5=BR/G$	[16]
	$S6=BNIR/G$	[16]
	$SI=\sqrt{BR}$	[16]
	$SI1=\sqrt{GR}$	[16]
	$SI2=\sqrt{G^2+R^2+NIR^2}$	[16]
	$SI3=\sqrt{G^2+R^2}$	[16]
归一化植被指数	$NDVI=(NIR-R)/(NIR+R)$	[33]
扩展的归一化植被指数	$ENDVI=\frac{NIRSWIR2-R}{NIRSWIR2+R}$	[34]
冠层盐分响应指数	$CRSI=\sqrt{\frac{NIRR-GB}{NIRR+GB}}$	[35]
盐渍化遥感监测指数模型	$SDI=\sqrt{(NDVI-1)^2+SI^2}$	[36]

注：B、G、R、NIR、$SWIR1$ 和 $SWIR2$ 分别为蓝波段、绿波段、红波段、近红外波段及 2 个短红外波段反射率。

$$\sigma^o=\sigma^o_{veg}+L^2\sigma^o_{soil} \tag{2}$$

其中

$$\sigma^o_{veg}=AV_1\cos\theta(1-L^2) \tag{3}$$

$$L^2=\exp(-2BV_2\sec\theta) \tag{4}$$

式中　σ^o——SAR 传感器观测到的植被冠层上的总后向散射系数

σ^o_{veg}——仅由植被引起的后向散射系数

L^2——双向冠层衰减因子

σ^o_{soil}——植被下土壤后向散射系数

A、B——依赖于植被类型的系数

V_1、V_2——冠层描述符

θ——雷达入射角

在大多数研究中，主要使用植被含水率（Vegetation water content，VWC）、叶面积指数（Leaf area index，LAI）和 NDVI 确定模型参数，本研究采用 $A=B=LAI$，其中 LAI 利用仪器测量。根据文献[39]，估算各种类型植被的植被系数 A 和 B 如表 2 所示。

表 2　不同类型植被系数

Tab. 2　Vegetation coefficients for different types of vegetation

参数	所有植被	牧场	耕地	草地
A	0.001 2	0.000 90	0.001 08	0.001 40
B	0.091	0.032	0.138	0.084

由于本研究区域耕地面积约占 89.39%，且样本均分布在耕作区，因此 $A=0.001\ 08$，$B=0.138$。由式(2)～(4)可计算出植被覆盖条件下土壤的后向散射系数。有研究指出，对雷达影像的极化方式进行组合，可以提高雷达影像后向散射系数与土壤含盐量的相关性，从而达到预测土壤含盐量的较好效果[40]。因此本文提取 Sentinel－1 双极化波段（VH 和 VV）和 4 个极化指数组合 VH^2+VV、VH^2-VV、$(VV^2+VH^2)/VV$、$(VV^2+VH^2)/VH$[39]。

1.3.3　Sentinel－1 图像纹理特征

剔除作物阴影和土壤背景后的图像用于图像纹理提取，其中图像纹理采用灰度共生矩阵（Gray level co-occurrence matrix，GLCM）计算[15]。利用 GLCM 提取 Sentinel－1A 图像的 8 个纹理特征，分别为对比度（Contrast，CON）、非相似性（Dissimilarity，DIS）、同质性（Homogeneity，HOM）、角二阶矩（Angular second moment，ASM）、熵（Entropy，ENT）、均值（Mean，MEAN）、方差（Variance，VAR）、相关性（Correlation，COR）。其详细描述可参考文献[41]。

1.4　全子集筛选法与贝叶斯信息准则

全子集筛选法（All-subsets selection）是一种特征选择方法，用于建立预测模型时，考虑所有特征子集的可能性，从而选择出既定评估准则下表现最佳的子集[42]。该方法通过系统性地探索不同特征组合选择最合适的特征子集，以改进模型性能。贝叶斯信息准则（Bayesian information criterion，BIC）是一种模型选择准则，其结合了拟合度和模型复杂度评估不同模型性能，用于统计衡量模型性能。BIC 的核心思路是选择具有最小 BIC 值的模型，其能很好地拟合数据，又能保持模型的简洁性，避免过度拟合[43]。在选择最佳变量时，考虑 2 方面：①最大似然函数。②未知参数最小化。

1.5　机器学习模型构建与精度评价

为使各特征在模型中量纲相同、影响力均衡，先对特征数据进行标准化处理。采用 3 种常见且性能良好的机器学习算法：极限学习机（Extreme learning machine，ELM）、随机森林（Random forest，RF）和反向传播神经网络（Back propagation neural network，BPNN）进行建模分析，在相同部分输入同等变量，均为使用全子集筛选法筛选出结果后得出变量组合，达到模型拟合精度和复杂性间的最佳平衡。该方法通过软件 Matlab 2020a 代码实现，得出最佳变量筛选结果。

在模型中使用超参数调整、正则化和一折交叉验证，减小数据分割可能带来的偶然性，避免模型出现严重的过拟合或欠拟合问题。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）评价模型精度和误差，R^2 越接近 1，RMSE 和 MAE 越接近

0,表示预测值和实测值间误差越小,模型反演精度越高。

2 结果与分析

2.1 SSC 描述性统计分析与土壤盐渍化分类

将实测土壤含盐量样本集按大小顺序每 3 个一组进行排列,其中前 2 个样本作为建模集,第 3 个样本作为验证集,通过交替划分使样本数据均匀分布。表 3 为构建机器学习模型的建模集样本量和验证集样本量及其土壤含盐量统计特征。根据土壤盐渍化程度分级标准并结合前人研究成果[44],将 350 个土壤样本分为 4 类:非盐渍土(含盐量 0 ~ 0.2%)、轻度盐渍土(0.2% ~ 0.5%)、重度盐渍土(0.5% ~ 1.0%)和盐渍土(>1.0%)。结果显示研究区土壤样本中以轻度盐渍化和重度盐渍化土壤为主,合计占比 69.14%,整体样本的土壤 SSC 变异系数为 92%,属于中等变异水平,表明土壤含盐量变异较小。

表 3 土壤含盐量描述性统计

Tab. 3 Descriptive statistics of soil salinity

数据集	非盐渍土样本数	轻度盐渍土样本数	重度盐渍土样本数	盐渍土样本数	上四分位数/%	下四分位数/%	平均值/%	标准差/%	变异系数/%
总样本集(n=350)	70	164	78	38	0.66	0.22	0.52	0.48	92
建模集(n=233)	62	110	44	17	0.52	0.18	0.42	0.35	83
验证集(n=117)	8	54	34	21	0.81	0.32	0.71	0.62	88

2.2 土壤含盐量与反演因子相关性分析及变量筛选

由图 2a 可知,多光谱图像盐分指数均与土壤含盐量呈极显著正相关(P<0.01),而多光谱反射率除 B8、B11 和 B12 外均与土壤含盐量呈弱负相关,其中 B8、B11 和 B12 相关系数分别为 -0.45、-0.38 和 -0.46,由于大多数反射率和盐分指数与土壤含盐量间的相关性良好,因此将贝叶斯信息准则、全子集筛选法相结合,对数据集 A(盐分指数)进行筛选,最优变量为 ENDVI、S6、B12、S11、B1,其 BIC 分数评比如表 4 所示。

由图 2b 可知,Sentinel-1 图像纹理特征的双极化波段(2 个)不同类型的图像纹理(MEA、VAR、HOM、CON、DIS、ENT、SEM 和 COR)均与土壤含盐量有一定相关性,其中 VH 的图像纹理与土壤含盐量相关性最高,因此将贝叶斯信息准则、全子集筛选法相结合,对 VH 波段的图像纹理与盐分指数进行筛选,数据集 B(盐分指数 + 图像纹理)最优变量为 ENDVI、B12、VAR、MEA、CON,其 BIC 分数评比如表 4 所示。

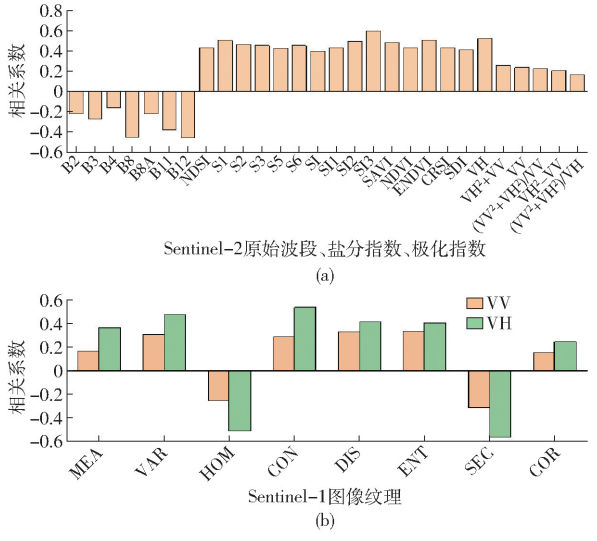


图 2 土壤含盐量与反演因子相关性分析

Fig. 2 Correlation analysis between soil salinity content and inversion factors

表 4 基于全子集筛选和贝叶斯信息准则结果统计

Tab. 4 Result statistics based on whole subset screening and Bayesian information criterion

数据集	类别	变量名称	数量	筛选结果	BIC 分数
A	盐分指数	B2、B3、B4、B8、B8A、B11、B12、NDSI、S1、S2、S3、S5、S6、SI、SI1、SI2、SI3、SAVI、NDVI、ENDVI、CRSI、SDI	22	ENDVI、S6、B12、B11、S1	-35
B	盐分指数 + 图像纹理	B2、B3、B4、B8、B8A、B11、B12、NDSI、S1、S2、S3、S5、S6、SI、SI1、SI2、SI3、SAVI、NDVI、ENDVI、CRSI、SDI、MEA、VAR、HOM、CON、DIS、ENT、SEC、COR	30	ENDVI、B12、VAR、MEA、CON	-39
C	盐分指数 + 图像纹理 + 极化指数	B2、B3、B4、B8、B8A、B11、B12、NDSI、S1、S2、S3、S5、S6、SI、SI1、SI2、SI3、SAVI、NDVI、ENDVI、CRSI、SDI、MEA、VAR、HOM、CON、DIS、ENT、SEC、COR、VH、VV、VH^2-VV、VH^2+VV、$(VV^2+VH^2)/VV$、$(VV^2+VH^2)/VH$	36	VH、S2、VAR、MEA、CON	-57

由图 2a 可知,Sentinel-1 极化指数(VH、VV)与土壤含盐量间相关系数分别为 0.53 和 0.26,极化指数组合(VH^2+VV、VH^2-VV、$(VV^2+VH^2)/VV$、$(VV^2+$

VH²)/VH)分别为 0.24、0.23、0.21 和 0.17，极化指数 VH 与土壤含盐量相关性较好。因此将贝叶斯信息准则、全子集筛选法相结合，对数据集 C(盐分指数 + 图像纹理 + 极化指数)进行筛选，最优变量为 VH、S2、VAR、MEA、CON，其 BIC 分数评比如表 4 所示。

2.3　基于盐分指数的土壤含盐量预估模型

将数据集 A 最优变量 ENDVI、S6、B12、B11、S1 设为自变量，土壤含盐量为因变量，构建基于 ELM、BPNN 和 RF 的土壤含盐量预估模型，得出各自建模集和验证集的 SSC。对比模型 SSC 预估值与实测值(图 3)，ELM 模型预估精度最低，其中建模集和验证集 R^2 分别为 0.658 和 0.667，BPNN 模型次之，RF 模型预估精度最高(R^2 为 0.723 和 0.734)；ELM、BPNN 和 RF 3 种模型具有一定的稳定性，RF 模型最优。由图 3 可得，与 ELM 模型和 BPNN 模型相比 RF 模型预测区间较窄，表明其预测精度更高。但 3 种模型的拟合线均偏向 1∶1线右侧，表明当 SSC 偏大时，模型预测 SSC 结果偏低。

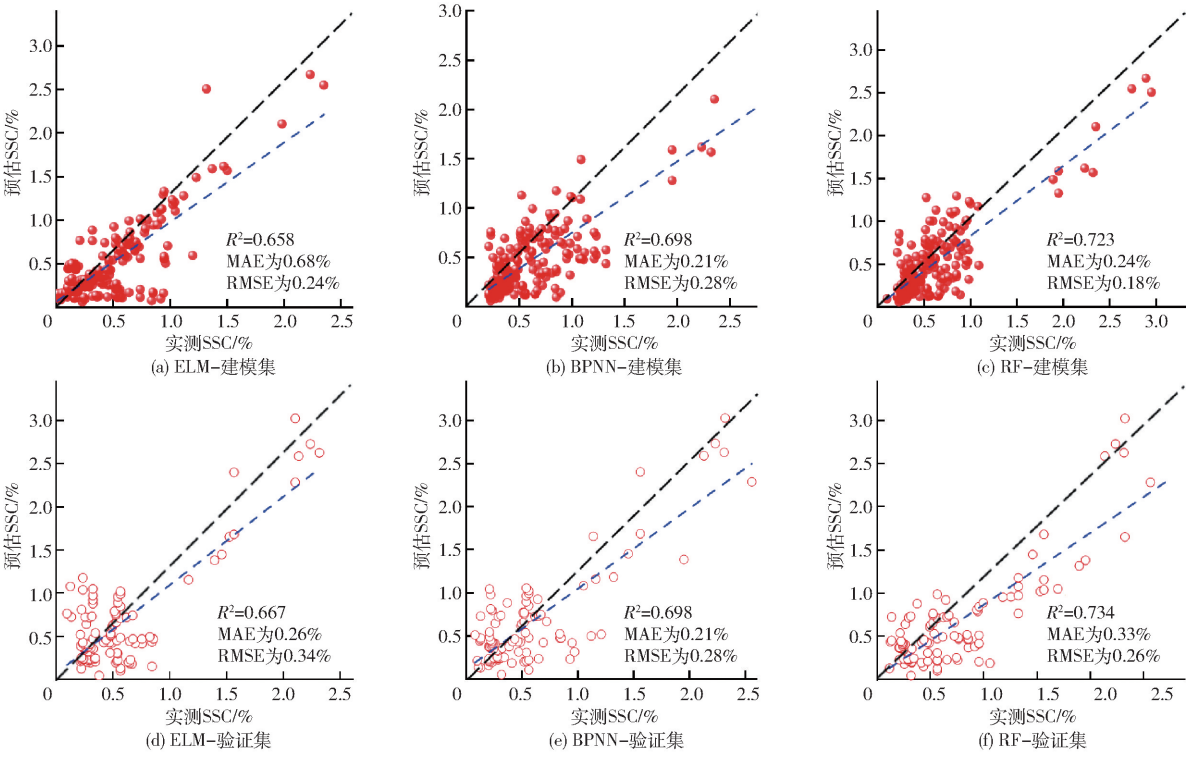


图 3　基于盐分指数构建 ELM、BPNN 和 RF 模型的 SSC 实测值与预估值比较

Fig. 3　Comparison of measured and estimated SSC values of ELM, BPNN and RF models based on salinity index

2.4　基于图像纹理和盐分指数的土壤含盐量预估模型

将数据集 B 最优变量 ENDVI、B12、VAR、MEA、CON 设为自变量，土壤含盐量为因变量，基于 ELM、BPNN 和 RF 构建土壤含盐量预估模型。引入图像纹理得出各自建模集和验证集的 SSC，对比模型 SSC 预估值与实测值(图 4)，3 种模型评价指标均高于图 3。RF 模型预估精度最高，其建模集和验证集 R^2 分别为 0.771 和 0.782；RMSE(建模集 0.15%、验证集 0.26%)和 MAE(建模集 0.21%、验证集 0.33%)均较低。ELM 模型(建模集 R^2 = 0.737，验证集 R^2 = 0.745)和 BPNN 模型(建模集 R^2 = 0.741，验证集 R^2 = 0.756)虽较为稳定，但 3 种模型对 SSC 较低值仍具有低估性。

2.5　基于极化指数、图像纹理和盐分指数的土壤含盐量预估模型

将数据集 C 最优变量 VH、S2、VAR、MEA、CON 设为自变量，土壤含盐量作为因变量，基于 ELM、BPNN 和 RF 构建土壤含盐量预估模型。引入极化指数得出各自建模集和验证集的 SSC，对比模型 SSC 预估值与实测值(图 5)，3 种模型评价指标均高于图 4 且 R^2 均大于 0.8，表明基于极化指数、图像纹理和盐分指数构建的土壤含盐量预估模型效果最优。RF 模型预估精度最高(建模集 R^2 = 0.863，MAE 为 0.17%，RMSE 为 0.12%；验证集 R^2 = 0.886，MAE 为 0.24%，RMSE 为 0.19%)，SSC 较低值的低估性得到显著改善，表明基于极化指数、盐分指数和图像纹理构建的 RF 模型具有极大应用潜力，可以有效地估算土壤含盐量分布状况。

2.6　基于最优模型的 SSC 反演分布图

基于极化指数、盐分指数和图像纹理(VH、S2、VAR、MEA、CON)构建的 RF 模型反演土壤含盐量分布状况，绘制左三支渠土壤含盐量反演图(图 6)。结果表明，2022 年研究区土壤以非盐渍

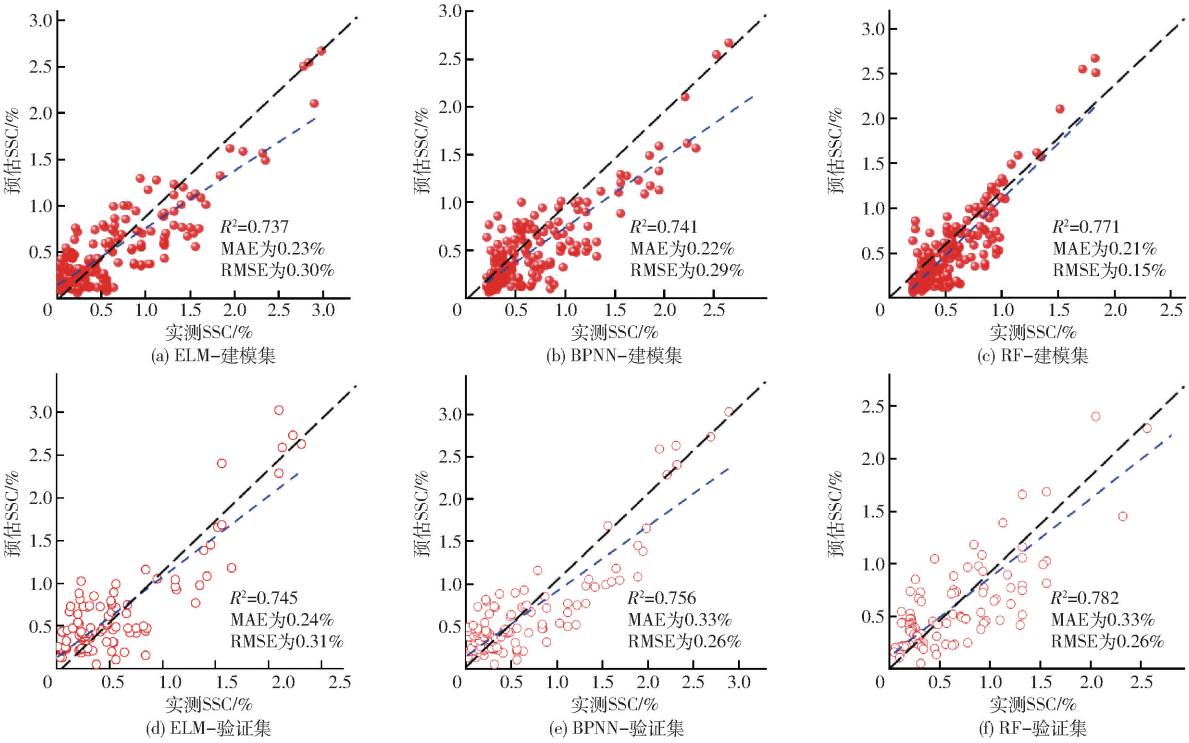


图 4 基于图像纹理和盐分指数构建 ELM、BPNN 和 RF 模型的 SSC 实测值与预估值比较

Fig. 4 Comparison of measured and estimated SSC values of ELM, BPNN and RF models based on image texture and salinity index

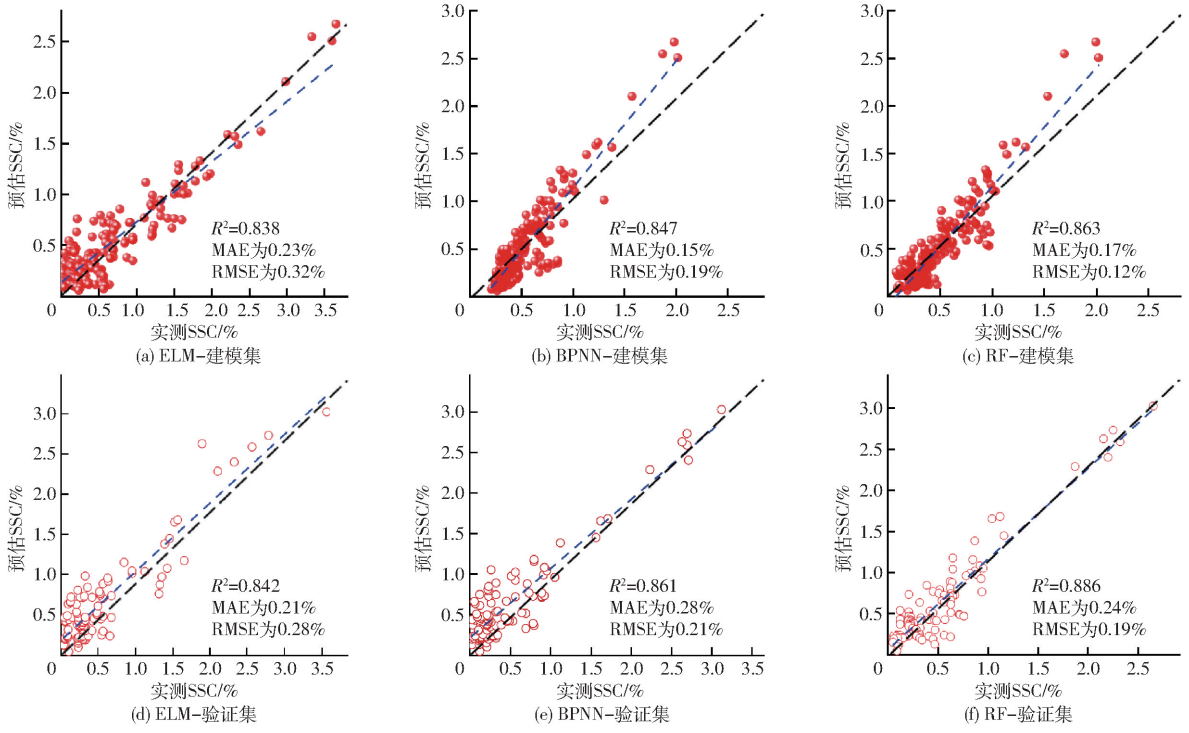


图 5 基于极化指数、图像纹理和盐分指数构建 ELM、BPNN 和 RF 模型的 SSC 实测值与预估值比较

Fig. 5 Comparison of measured and estimated SSC values of ELM, BPNN and RF models based on polaricity index, image texture and salinity index

土和轻度盐渍土为主,面积占比 50% 以上,集中分布于中部及南部;重度盐渍土和盐渍土面积占比较小,集中分布于东部和南部,5、9 月较为明显。2023 年研究区土壤以非盐渍土和轻度盐渍土为主,面积占比 50% 以上,集中分布于中部及北部;重度盐渍土和盐渍土占比较小,集中分布于南部。2023 年 9 月与 2022 年同期相比土壤盐碱化程度降低,盐碱土零散分布于北部,与野外实际调查结

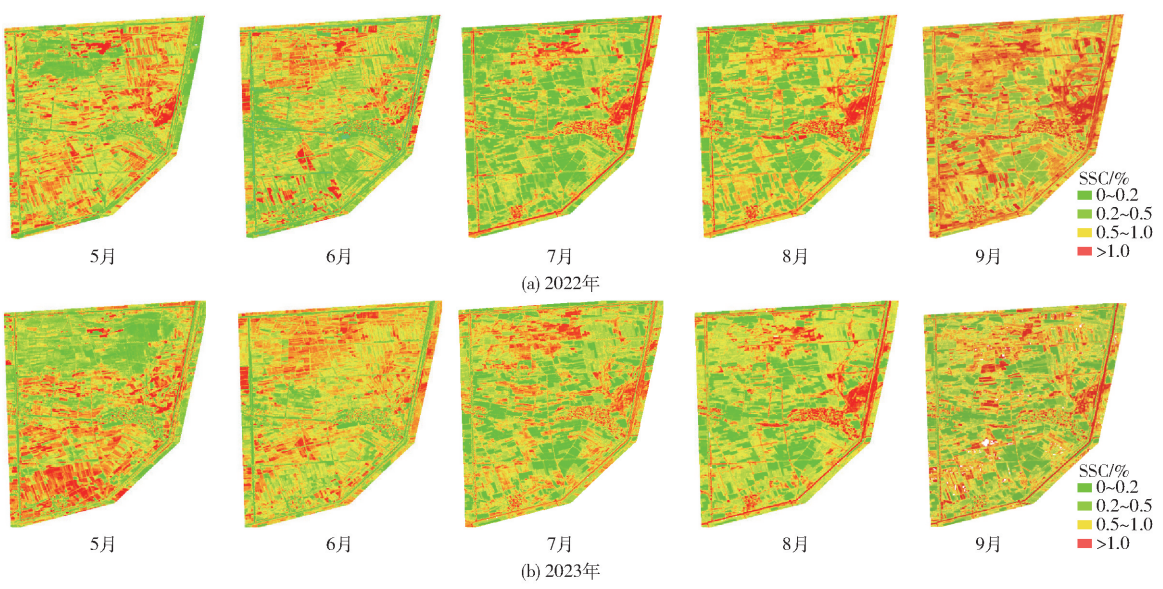


图 6　基于最优土壤含盐量预估模型的 2022—2023 年 SSC 分布反演图

Fig. 6　Inversion maps of SSC distribution in 2022—2023 based on optimal soil salt content estimation model

果基本相吻合。从空间分布来看，土壤盐碱化程度从北向南、从西向东呈逐渐扩大趋势，靠近支渠附近一侧最为严重。春季裸土期土壤盐渍化面积大于植被覆盖期，由于裸土期气候干燥、蒸发强烈，盐分随着包气带、毛管水向上运动，最终聚集在表层，出现积盐现象；研究区雨量集中于 7、8 月，由于地下水位处于年中最低，利于土壤脱盐，因此植被覆盖期盐渍化减轻。

3　讨论

3.1　Sentinel－1/2 多源遥感数据协同对 SSC 的响应

多源遥感数据为土壤含盐量预测提供了多种类型解释变量，通过数据互补和信息融合，可以显著提高土壤含盐量预测精度和适用范围[45]。光谱和雷达数据协同使用已成为提高模型预测精度的有效手段，然而，现有研究多聚焦于无植被覆盖的裸土条件，忽略了植被覆盖情况和土壤盐分的空间异质性，致使植被覆盖条件下，卫星影像无法直接获取土壤信息。因此，本研究协同 Sentinel－1 雷达数据、Sentinel－2 多光谱数据融合，Sentinel－1 经过水云模型校正后提取的纹理信息和极化指数是监测土壤含盐量的有价值特征，纹理特征和极化指数相较于光谱指数更稳定，更容易对土壤含盐量类别进行区分。REN 等[46] 和 PANAYIOTOPOULOS 等[47] 研究结果表明，土壤盐分可以影响土壤的开裂过程，而 CON 能很好地反映土壤表面开裂程度，因此其与土壤含盐量高度相关；刘思瑶等[48] 研究结果表明，土壤盐碱化与周边环境之间存在明显的灰度差异，不同盐碱化程度对应的差异水平也不相同，在这一背景下 MAE 和 CON 成为关键的图像纹理特征，两者能够有效地描述图像中相邻像素灰度级别的规则性和差异性。在 SSC 估算中，由于 Sentinel－1 传感器的后向散射系数对土壤表面粗糙度的敏感性较高，图像纹理和极化指数特征能够及时反映土壤盐渍化程度的空间分布，因此，土壤含盐量也是影响土壤表面粗糙度的重要因素。本研究整合不同数据源的优势为土壤含盐量预测提供了可能变量。然而，利用遥感技术监测土壤的影响因素较多，不同作物在不同生育期内对盐分胁迫的敏感性不同，未来研究可以考虑精准划分不同作物类型及其生育期，以减少预测过程中的不确定性，为农业可持续发展提供参考依据和数据支撑。

3.2　基于 SSC 最优预估模型应用潜力展望

在本研究中，基于盐分指数、雷达数据和光谱数据筛选出的最优变量（VH、S2、VAR、MEA、CON）构建的 RF 模型为土壤含盐量最优预估模型，该模型在建模集和验证集上决定系数均超过 0.80，而图 3 和图 4 中的 R^2 均未达到 0.8，表明只基于盐分指数和图像纹理构建的模型精度相对较低，引入极化指数后可以有效提高精度，且模型对土壤含盐量较低值的低估性显著改善，有效提高了植被覆盖条件下的土壤含盐量监测，为非裸土条件下的土壤含盐量监测提供了一种有效方法。S2 成为最优变量之一的原因可能是土壤盐分对红光的吸收较高并在蓝光波段表现出较高的反射率[49]，而 S2 是蓝光波段与红光波段的反射率组合，所以 S2 是评估土壤含盐量的关键因素。同时，盐分指数分析利用高分辨率遥感图像，通过高频信息捕捉土壤含盐量的空间分布特征，但在植被覆盖条件下，表达信息不全面，而经校正后的雷达后向散射系数、极化指数和图像纹理

能够很好地消除植被覆盖对土壤含盐量反演的影响,这与张智韬等[39]研究结果一致。由于图像纹理对土壤地表空间结构特征十分敏感,图像中存在明显的明暗区域对比和丰富的纹理结构,而 VAR、MEA 和 CON 反映整体亮度分布和纹理复杂性,这可能使它们成为最优指标组合之一,与谢坪良等[50]研究结果一致。因此,这 3 种信息源相互补充作为自变量,以土壤含盐量作为因变量,基于 RF 机器学习方法构建的最优预估模型能够有效监测土壤盐渍化状况。

但当前研究还具有许多不确定性,主要有两方面:①土壤盐分特征与遥感数据间关系的不确定性。由于土壤盐渍化的机制相当复杂,通过卫星图像获取的土壤盐分信息可能会受到土壤类型、土壤表面粗糙度和其他土壤特性的影响。其根本原因是卫星传感器在信息获取方面存在先天缺陷,不能表达出土壤的定性指标。②由于试验条件限制,仅在支渠尺度开展研究,未来应将采样区域扩大至灌区尺度,以提升模型空间普适性。

4 结论

(1)盐分指数、图像纹理和极化指数在机理上具有互补性,与单一或 2 个组合相比,决定系数分别从 0.723、0.771 提升到 0.863,在土壤含盐量预估中具有极大潜力。

(2)多光谱图像的土壤表层反射率与土壤含盐量呈弱负相关,B8、B11 和 B12 与土壤含盐量呈显著负相关,盐分指数和极化指数与土壤含盐量呈极显著正相关,Sentinel-1 不同极化波段的图像纹理与土壤含盐量有较高的相关性,其中 VH 波段最佳。

(3)基于 3 种互补信息源(VH、S2、VAR、MEA、CON)构建的随机森林模型是土壤含盐量监测最优模型,验证集 R^2 为 0.886,MAE 为 0.24%,RMSE 为 0.19%,土壤含盐量较低值的低估性得到显著改善。

(4)利用最优模型绘制的土壤 SSC 反演图能够便捷准确地监测土壤盐渍化状况。研究结果为盐渍化地区土壤含盐量预测提供了理论依据,也为河套灌区及西北干旱盐渍化地区盐碱地改良提供了重要参考。

参 考 文 献

[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 Jinsong, YAO Rongjiang, WANG Xiangping, et al. Research on salt-affected soils in China: history, status quo and prospect[J]. Acta Pedologica Sinica, 2022, 59(1): 10-27. (in Chinese)

[2] 刘海启. 加快我国由农业大国向农业强国转变的战略思考和工作举措[J]. 中国农业资源与区划, 2020, 41(3): 7-11.
LIU Haiqi. Strategic thinking and working initiatives to accelerate the transformation of China from a large agricultural country to a strong agricultural country[J]. Chinese Journal of Agricultural Resources and Regional Planning, 2020, 41(3): 7-11. (in Chinese)

[3] 张海欧. 浅析中国盐渍土分布及演变特征[J]. 农业与技术, 2022, 42(5): 104-107.
ZHANG Haiou. Distribution and evolutionary characteristics of saline soils in China[J]. Agriculture and Technology, 2022, 42(5): 104-107. (in Chinese)

[4] 史海滨,杨树青,李瑞平,等. 内蒙古河套灌区水盐运动与盐渍化防治研究展望[J]. 灌溉排水学报, 2020, 39(8): 1-17.
SHI Haibin, YANG Shuqing, LI Ruiping, et al. Soil water and salt movement and soil salinization control in Hetao Irrigation District: current state and future prospect[J]. Journal of Irrigation and Drainage, 2020, 39(8): 1-17. (in Chinese)

[5] WANG Z, ZHANG X, ZHANG F, et al. Estimation of soil salt content using machine learning techniques based on remote-sensing fractional derivatives, a case study in the Ebinur Lake Wetland National Nature Reserve, Northwest China[J]. Ecological Indicators, 2020, 19: 106869.

[6] GORJI T, SERTEL E, TANIK A. Monitoring soil salinity via remote sensing technology under data scarce conditions: a case study from Turkey[J]. Ecological Idicators, 2017, 74: 384-391.

[7] 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.

[8] GE X, DING J, TENG D, et al. Updated soil salinity with fine spatial resolution and high accuracy: the synergy of Sentinel-2 MSI, environmental covariates and hybrid machine learning approaches[J]. CATENA, 2022, 212: 106054.

[9] 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.

[10] WANG N, PENG L, CHEN S, et al. Improving remote sensing of salinity on topsoil with crop residues using novel indices of optical and microwave bands[J]. Geoderma, 2022, 422: 115935.

[11] LI Y, CHANG C, WANG Z, et al. Remote sensing prediction and characteristic analysis of cultivated land salinization in different seasons and multiple soil layers in the coastal area[J]. International Journal of Applied Earth Observation and Geoinformation, 2022, 111: 102838.

[12] ORYNBAIKYZY A, PLANK S, VETRITA Y, et al. Joint use of Sentinel-2 and Sentinel-1 data for rapid mapping of volcanic eruption deposits in Southeast Asia[J]. International Journal of Applied Earth Observation and Geoinformation, 2023,

116：103166.
[13] PERIASAMY S, RAVI K P, TANSEY K. Identification of saline landscapes from an integrated BPNN approach from a novel 3D classification schema using Sentinel－1 dual-polarized SAR data[J]. Remote Sensing of Environment, 2022, 279: 113144.
[14] WU W, MUHAIMEED A S, Al-SHAFIE W M, et al. Using L-band radar data for soil salinity mapping a case study in central Iraq[J]. Environmental Research Communications, 2019, 1(8): 081004.
[15] YIN H, CHEN C, HE Y, et al. Synergistic estimation of soil salinity based on Sentinel－1image texture and Sentinel－2 salinity spectral indices[J]. Journal of Applied Remote Sensing, 2023, 17(1): 018502.
[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] ELIA S, TODD H S, DENNIS L C. Regional-scale soil salinity assessment using Landsat ETM + canopy reflectance[J]. Remote Sensing of Environment, 2015, 169(9): 335－343.
[18] 陈红艳,赵庚星,陈敬春,等. 基于改进植被指数的黄河口区盐渍土盐分遥感反演[J]. 农业工程学报,2015,31(5): 107－114.
CHEN Hongyan, ZHAO Gengxing, CHEN Jingchun, et al. Remote sensing inversion of saline soil salinity based on modified vegetation index in estuary area of Yellow River[J]. Transactions of the CSAE, 2015, 31(5): 107－114. (in Chinese)
[19] DU R, CHEN J, ZHANG Z, et al. Simultaneous estimation of surface soil moisture and salinity during irrigation with the moisture-salinity-dependent spectral response model[J]. Agricultural Water Management, 2022, 265: 107538.
[20] 万亮,杜晓月,陈硕博,等. 基于无人机多源图谱融合的水稻稻穗表型监测[J]. 农业工程学报,2022,38(9): 162－170.
WAN Liang, DU Xiaoyue, CHEN Shuobo, et al. Rice panicle phenotyping using UAV-based multi-source spectral image data fusion[J]. Transactions of the CSAE, 2022, 38(9): 162－170. (in Chinese)
[21] YANG G, LI C, WANG Y, et al. The DOM generation and precise radiometric calibration of a UAV-mounted miniature snapshot hyperspectral imager[J]. Remote Sensing, 2017, 9(7): 642.
[22] HOA P V, GIANG N V, BINH N A, et al. Soil salinity mapping using SAR Sentinel－1 data and advanced machine learning algorithms: a case study at Ben Tre Province of the Mekong River Delta (Vietnam)[J]. Remote Sensing, 2019, 11(2): 128.
[23] TAGHADOSI M M, HASANLOU M, EFTEKHARI K. Soil salinity mapping using dual-polarized SAR Sentinel－1 imagery[J]. International Journal of Remote Sensing. 2019, 40(1): 237－252.
[24] 向友珍,李汪洋,台翔,等. 基于无人机遥感图像纹理与植被指数的土壤含盐量反演[J]. 农业机械学报, 2023, 54(8): 201－210.
XIANG Youzhen, LI Wangyang, TAI Xiang, et al. Inversion of soil salt content based on texture feature and vegetation index of UVA remote sensing images[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(8): 201－210. (in Chinese)
[25] YANG N, ZHANG Z, ZHANG J, et al. Improving estimation of maize leaf area index by combining of UAV-based multispectral and thermal infrared data: the potential of new texture index[J]. Computers and Electronics in Agriculture, 2023, 214: 108294.
[26] TRIPATHI A, TIWARI R K. A simplified sub-surface soil salinity estimation using synergy of Sentinel－1 SAR and Sentinel－2 multispectral satellite data, for early stages of wheat crop growth in Rupnagar, Punjab, India[J/OL]. Land Degradation & Development, 2021. DOI: 10.1002/ldr.4009.
[27] 马驰. 基于 Sentinel－1 双极化雷达影像的土壤含盐量反演[J]. 农业工程学报, 2018, 34(2): 153－158.
MA Chi. Quantitative retrieval of soil salt content based on Sentinel－1 dual polarization radar image[J]. Transactions of the CSAE, 2018, 34(2): 153－158. (in Chinese)
[28] LAO C, CHEN L, ZHANG Z, et al. Predicting the contents of soil salt and major water-soluble ions with fractional-order derivative spectral indices and variable selection[J]. Computers and Electronics in Agriculture, 2021, 182: 106031.
[29] 张智韬,黄小鱼,陈钦达,等. 基于遥感数据同化的土壤含盐量估算方法[J]. 农业机械学报,2022,53(7): 197－207.
ZHANG Zhitao, HUANG Xiaoyu, CHEN Qinda, et al. Soil salinity estimation method based on assimilation of remote sensing data[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(7): 197－207. (in Chinese)
[30] 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 Junying, YAO Zhihua, ZHANG Zhitao, et al. UVA remote sensing inversion of soil salinity in field of sunflower[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(7): 178－191. (in Chinese)
[31] 赵保卫,王刚. 白银市郊区农田土壤重金属污染初步调查与评价[J]. 环境科学与技术,2010,33(11): 79－81, 105.
ZHAO Baowei, WANG Gang. Preliminary investigation and assessment of farmland soils contaminated by heavy metal around Baiyin City[J]. Environmental Science & Technology, 2010, 33(11): 79－81, 105. (in Chinese)
[32] 张智韬. 基于遥感技术的灌区动态信息监测[D]. 杨凌:西北农林科技大学,2005.
ZHANG Zhitao. Dynamic information monitoring in irrigation distract base on remote sensing[D]. YangLing: Northwest A&F University, 2005. (in Chinese)
[33] 蒲智,于瑞德,尹昌应,等. 干旱区典型盐碱土壤含盐量估算的最佳高光谱指数研究[J]. 水土保持通报, 2012, 32(6): 129－133.

PU Zhi, YU Ruide, YIN Changying, et al. Optimal hyperspectral indices for soil salt content estimation on typical saline soil in arid areas[J]. Bulletin of Soil and Water Conservation, 2012, 32(6):129 - 133. (in Chinese)

[34] 王飞,丁建丽. 基于土壤植被光谱协同分析的土壤盐度推理模型构建研究[J]. 光谱学与光谱分析, 2016, 36(6):1848 - 1853.
WANG Fei, DING Jianli. Research on the construction of soil salinity inference model based on spectral synergy analysis of soil vegetation[J]. Spectroscopy and Spectral Analysis, 2016, 36(6):1848 - 1853. (in Chinese)

[35] 王飞,丁建丽,魏阳,等. 基于 Landsat 系列数据的盐分指数和植被指数对土壤盐度变异性的响应分析——以新疆天山南北典型绿洲为例[J]. 生态学报,2017,37(15):5007 - 5022.
WANG Fei, DING Jianli, WEI Yang, et al. Response analysis of salinity index and vegetation index to soil salinity variability based on Landsat series data—a case study of a typical oasis in the north and south Tianshan Mountains of Xinjiang[J]. Journal of Ecology, 2017, 37(15):5007 - 5022. (in Chinese)

[36] 王飞,丁建丽,伍漫春. 基于 NDVI - SI 特征空间的土壤盐渍化遥感模型[J]. 农业工程学报,2010,26(8):168 - 173, 8.
WANG Fei, DING Jianli, WU Manchun. Remote sensing model of soil salinization based on NDVI - SI feature space[J]. Transactions of the CSAE, 2010, 26(8):168 - 173, 8. (in Chinese)

[37] ATTEMA E P W, ULABY F T. Vegetation modeled as a water cloud[J]. Radio Science, 1978, 13(2): 357 - 364.

[38] PRÉVOT L, CHAMPION I, GUYOT G. Estimating surface soil moisture and leaf area index of a wheat canopy using a dual-frequency (C and X bands) scatter meter[J]. Remote Sensing of Environment, 1993, 46(3): 331 - 339.

[39] 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)

[40] 陈鹏,冯海宽,李长春,等. 无人机影像光谱和纹理融合信息估算马铃薯叶片叶绿素含量[J]. 农业工程学报,2019, 35(11):63 - 74.
CHEN Peng, FENG Haikuan, LI Changchun, et al. Estimation of chlorophyll content in potato using fusion of texture and spectral features derived from UAV multispectral image[J]. Transactions of the CSAE, 2019, 35(11): 63 - 74. (in Chinese)

[41] ZHANG C, HUANG C, LI H, et al. Effect of textural features in remote sensed data on rubber plantation extraction at different levels of spatial resolution[J]. Forests, 2020, 11(4): 399.

[42] 谭丞轩,张智韬,许崇豪,等. 无人机多光谱遥感反演各生育期玉米根域土壤含水率[J]. 农业工程学报,2020,36(10): 63 - 74.
TAN Chengxuan, ZHANG Zhitao, XU Chonghao, et al. UAV multispectral remote sensing inversion of soil water content in the root zone of maize at various fertility stages[J]. Transactions of the CSAE, 2020, 36(10):63 - 74. (in Chinese)

[43] BURNHAM K P, ANDERSON D R. Multi model inference:understanding AIC and BIC in model selection[J]. Sociological Methods & Research, 2004,33(2):261 - 304.

[44] 黄权中,徐旭,吕玲娇,等. 基于遥感反演河套灌区土壤盐分分布及对作物生长的影响[J]. 农业工程学报,2018,34(1): 102 - 109.
HUANG Quanzhong, XU Xu, LÜ Lingjiao, et al. Soil salinity distribution based on remote sensing and its effect on crop growth in Hetao lrrigation District[J]. Transactions of the CSAE, 2018, 34(1):102 - 109. (in Chinese)

[45] 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 Liping, REN Jie, WANG Yu, 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. (in Chinese)

[46] REN J, LI X, ZHAO K, et al. Study of an on-line measurement method for the salt parameters of soda-saline soils based on the texture features of cracks[J]. Geoderma, 2016, 263: 60 - 69.

[47] PANAYIOTOPOULOS K P, LEIINAS D. Influence of aggregate size, electrolyte concentration, and sodium adsorption ratio on crack parameters of a vertisol[J]. Communications in Soil Science and Plant Analysis, 2009, 40(11 - 12): 1712 - 1721.

[48] 刘思瑶,王晓燕,陈相安,等. 用动态图层融合与纹理-灰度梯度能量模型的果树行识别[J]. 农业工程学报,2022, 38(8):152 - 160.
LIU Siyao, WANG Xiaoyan, CHEN Xiang'an, et al. Fruit tree row recognition with dynamic layer fusion and texture - gray gradient energy model[J]. Transactions of the CSAE, 2022, 38(8):152 - 160. (in Chinese)

[49] 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 Xiaoyu, JIA Keli, WEI Huimin, et al. Soil salinity prediction based on random forest algorithm[J]. Arid Zone Research, 2023, 40(8):1258 - 1267. (in Chinese)

[50] 谢坪良,张智韬,巴亚岚,等. 基于无人机图像纹理和表型参数的夏玉米水分胁迫诊断[J]. 农业工程学报, 2024, 40(10):136 - 146.
XIE Pingliang, ZHANG Zhitao, BA Yalan, et al. Diagnosis of summer maize water stress based on UAV image texture and phenotypic parameters[J]. Transactions of the CSAE, 2024, 40(10):136 - 146. (in Chinese)