

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

张智韬^{1,2} 贺玉洁^{1,2} 殷皓原^{1,2} 项茹^{1,2} 陈俊英^{1,2} 杜瑞麒^{1,2}

(1. 西北农林科技大学水利与建筑工程学院, 陕西杨凌 712100;

2. 西北农林科技大学旱区农业水土工程教育部重点实验室, 陕西杨凌 712100)

摘要: 目前 Sentinel-1/2 协同反演植被土壤含盐量的研究大多是基于 Sentinel-2 光谱信息和 Sentinel-1 后向散射系数, 没有考虑 Sentinel-2 光谱信息容易受土壤亮度等信息影响, Sentinel-1 后向散射系数容易受土壤粗糙度和水分影响。为进一步提高 Sentinel-1/2 协同反演植被土壤含盐量的精度, 用水云模型对雷达卫星后向散射系数进行校正, 消除植被影响; 然后协同 Sentinel-2 纹理特征, 基于 VIP、OOB、PCA 3 种变量筛选和 RF、ELM、Cubist 3 种机器学习回归模型构建植被土壤含盐量反演模型。研究结果表明: 经过水云模型去除植被影响后的雷达后向散射系数及其极化组合指数与土壤含盐量的相关性有一定程度的提高。不同变量选择方法与不同机器学习方法耦合模型在反演土壤含盐量中, OOB 变量筛选方法与 RF、ELM 和 Cubist 3 种机器学习方法的耦合模型精度最佳, 建模集和验证集的 R^2 都在 0.750 以上, 且验证集的 RMSE 和 MAE 均最小; 其中 OOB-Cubist 耦合模型精度最高, 且 R_v^2/R_c^2 为 0.955, 具有良好的鲁棒性。研究可为机器学习协同物理模型、光学卫星协同雷达卫星在土壤含盐量反演中的进一步应用提供思路。

关键词: 土壤含盐量; Sentinel-1/2; 纹理特征; 水云模型; 机器学习; 改进极化指数

中图分类号: S156.41; S127 文献标识码: A 文章编号: 1000-1298(2024)01-0175-11

OSID:



Synergistic Estimation of Soil Salinity Based on Sentinel-1/2 Improved Polarization Combination Index and Texture Features

ZHANG Zhitao^{1,2} HE Yujie^{1,2} YIN Haoyuan^{1,2} XIANG Ru^{1,2} CHEN Junying^{1,2} DU Ruiqi^{1,2}

(1. College of Water Resources and Architectural Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China

2. Key Laboratory of Agricultural Soil and Water Engineering in Arid and Semi-arid Areas,

Ministry of Education, Northwest A&F University, Yangling, Shaanxi 712100, China)

Abstract: Most of the current studies on Sentinel-1/2 synoptic inversion of vegetation soil salinity were based on Sentinel-2 spectral information and Sentinel-1 backscattering coefficients, without considering the two aspects that Sentinel-2 spectral information was susceptible to soil brightness and Sentinel-1 backscattering coefficients were susceptible to soil roughness and moisture. Therefore, in order to further improve the accuracy of Sentinel-1/2 synoptic inversion of vegetation soil salinity, the Sentinel-1 backscatter coefficients were corrected with a water cloud model to eliminate the influence of vegetation. Then, the corrected backscatter coefficients and Sentinel-2 texture features screened by VIP, OOB and PCA were used to construct soil salinity inversion models based on RF, ELM and Cubist. The results showed that the correlation between the radar backscatter coefficient and the soil salinity was improved to some extent after the removal of vegetation effects by the water cloud model. For the coupled models of different variable selection methods and different machine learning methods, OOB had the best performance in soil salinity inversion when being coupled with RF, ELM and Cubist, with R^2 above 0.750 for both modeling and validation sets. And OOB-Cubist model had the highest accuracy and R_v^2/R_c^2 was 0.955, which had good robustness. It provided some ideas for further applications of machine learning in collaboration with physical models and optical satellites in collaboration with radar satellites in soil salinity inversion.

Key words: soil salinity; Sentinel-1/2; texture features; water cloud model; machine learning; improving polarization index

0 引言

在干旱半干旱地区,土壤盐碱化是限制灌溉农业发展和导致农业生产力损失的最主要原因之一^[1-3],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^[4-5],提高土壤盐碱化程度监测准确性也是众多研究人员普遍关注的问题^[4]。卫星遥感由于其能实现对土壤含盐量相对快速和大面积的反演而被广泛应用于土壤含盐量监测^[6-10]。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,然而由于多光谱传感器容易受到云和雨的影响,无法在所有气候条件下准确监测大面积土壤含盐量^[11];而合成孔径雷达传感器极少受云雨天气的影响,并且能够穿透一定土壤深度^[12];因此为了提高监测准确性,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^[8,13-14]。

然而目前基于光学卫星和雷达卫星协同反演土壤含盐量的模型,大多数是基于光学卫星的光谱指数和雷达卫星的极化指数构建的。这样的模型存在两个主要缺陷:①光谱信息很容易随着土壤表面的色调和亮度等其它信息而改变,很不稳定。②土壤水分和植被(特别是土壤水分)对雷达后向散射信息有很大的干扰,限制了植被期土壤含盐量反演的精度^[15-16]。已有研究表明,光学卫星纹理特征不容易被外界环境影响,稳定性比光谱信息更高,能够用于有效反演土壤含盐量^[17-18]。并且,水云模型提供了植被冠层和下层土壤的后向系数的解,可以较好地刻画地表散射特征,较好地反映植被覆盖下土壤含盐量^[19-20]。因此,本文尝试利用水云模型将Sentinel-1传统的极化指数进行改进,以消除植被的影响,并结合Sentinel-2的纹理信息特征,共同构建植被期土壤含盐量反演模型,以期提升监测精度。

河套灌区是中国西部最大的灌区,也是西部重要的粮食产地,其盐渍化土地占灌区总面积1/3以上^[21],对当地农业的可持续发展有重大影响。基于此,本研究于2019年7月在河套灌区解放闸灌域沙壕渠进行实地土壤采样,提取Sentinel-2的8个纹理特征、10个光谱波段和6个植被指数,和Sentinel-1经过水云模型去除植被影响后的2个雷达后向散射系数及其8个极化组合指数。利用变量投影重要性(VIP)、袋外数据(Out-of-bag, OOB)和主成分分析(Principal component analysis, PCA)3种变量选择方法对这些协变量进行筛选,将选择后的变量作为输入变量,然后基于随机森林(Random forest, RF)、极限学习机

(Extreme learning machine, ELM)和多元混合线性回归决策树(Cubist)3种机器学习模型构建植被覆盖条件下的土壤含盐量反演模型。最后利用决定系数(R^2)、均方根误差(RMSE)和平均绝对误差(MAE)3种指标评价模型的性能,以得到最佳的土壤含盐量反演模型。

1 材料与方法

1.1 研究区概况

沙壕渠位于内蒙古自治区河套灌区解放闸灌域的中东部($40^{\circ}52' \sim 41^{\circ}0'N$, $107^{\circ}05' \sim 107^{\circ}10'E$)(图1),南北长15 km,东西宽4 km,总面积为 49.3 km^2 ,灌溉耕地面积约占总面积的70.39%。解放闸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^[22]。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 ^[23]。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^[24]。

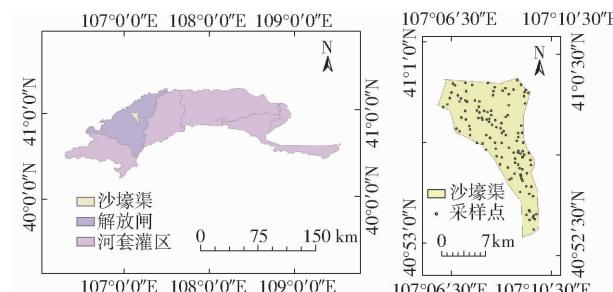


图1 研究区位置和采样点分布

Fig. 1 Study area location and distribution of sampling points in study area

1.2 试验数据采集和预处理

1.2.1 卫星数据下载和预处理

Sentinel-1具有交叉极化(VH)和垂直极化(VV)两种极化模式,由A和B两颗卫星组成,轨道高度约693 km,重访周期为6 d。这两颗卫星携带中心频率为5.405 GHz的C波段合成孔径雷达和4种成像模式(SM、IW、EWS和WV),可以提供全天候的陆地和海洋雷达图像。

哨兵2号(Sentinel-2)卫星携带多光谱成像仪(MSI),13个不同空间分辨率的光谱带,从可见光和近红外到短波红外;包含2A和2B两颗高分辨率多光谱卫星,轨道高度约786 km,重访期为5 d。Sentinel-1/2的数据下载时间接近野外土壤样本采集时间,云含量低于5%,从欧空局哥白尼哨兵科学中心下载(<https://scihub.copernicus.eu/userguide/>)。

Sentinel-1数据预处理在SNAP 7.0和ENVI

5.3 中完成, 主要步骤如下: ①轨道校正。②去除热噪声和边界噪声。③辐射地形校准。④使用 Refined Lee 滤波器散射滤波。⑤距离多普地形校正。⑥将图像重新采样到 10 m 空间分辨率。⑦雷达后向散射系数的提取和纹理特征的提取。Sentinel-2 L2A 和 L2B 级别的数据已经进行了大气校正, 因此 Sentinel-2 图像预处理主要包括以下步骤: ①将图像重新采样到 10 m 空间分辨率, 并将图像导出为 tif 格式。②提取反射率和纹理特征。

1.2.2 地面数据采集和分析

为了避免土壤采样过程中的灌溉和降雨, 并使地面土壤采样时间与卫星过境时间保持一致, 于 2019 年 7 月 11—16 日在沙壕渠进行了多次地面土壤采样试验。试验采用五点采样法^[25] 在土壤深度 0~10 cm 采集地表土样, 每次采样选取 120 个相同的采样点(图 1), 并使用手持 GPS 记录仪记录每个采样点的经纬度。取出土壤样本后, 将其迅速放入编号的铝盒中保存, 然后带回实验室进行处理。

表 1 土壤含盐量描述性统计

Tab. 1 Descriptive statistics of soil salinity

数据集	非盐渍土	轻度盐渍土	重度盐渍土	盐土	上四分位数/	下四分位数/	均值/	标准差/
	样本数	样本数	样本数	样本数	%	%	%	%
总样本集($n=120$)	60	39	11	10	0.124	0.379	0.359	0.410
建模集($n=80$)	42	25	7	6	0.119	0.372	0.368	0.428
验证集($n=40$)	18	14	4	4	0.125	0.400	0.355	0.373

从表 1 可以看出, 7 月获取的 120 个土壤样本中以非盐渍土和轻度盐渍土为主, 分别占总样本量的 50% 和 32.5%。随机划分的建模集和验证集在上四分位数、下四分位数、均值和标准差 4 个统计量上均展现相似的结果, 表明划分的建模集和验证集具有类似的分布结构, 所选取的两个数据集的土壤样本含盐量可以充分代表整个数据集。

1.3 协变量提取

1.3.1 雷达后向散射系数

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盐分含量产生影响, 而水云模型为植被冠层和土壤的后向散射系数提供了解决方案。水云模型最初由 ATTEMA 等^[27] 开发出, 该模型将冠层视为一个水云, 有大量相似水滴的随机分布, 它忽略了土壤和植被之间的多次散射的二阶贡献, 由 PRÉVOT 等^[28] 进行改进, 由水云模型改进的植被后向散射系数计算公式为

$$\sigma^o = \sigma_{veg}^o + L^2 \sigma_{soil}^o \quad (2)$$

其中

$$\sigma_{veg}^o = A V_1 \cos \theta_i (1 - L^2) \quad (3)$$

$$L^2 = \exp(-2 B V_2 \sec \theta_i) \quad (4)$$

室内土样处理主要包括以下步骤: ①将土样在干燥箱中干燥 24 h。②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。③将粉末状土壤样品放入编号的纸杯中进行溶液配置(土壤与水质量比为 1:5)。④用搅拌棒充分搅拌配置的溶液, 然后静置 24 h。⑤用滤纸过滤溶液, 对上层透明层进行电导率(EC_{1:5})的测定(电导率测定仪为上海优科仪器生产的 DDS-307A 型电导率仪)。⑥用经验公式^[15,26] 计算每个土壤样品的含盐量(Soil salt content, SSC), 计算式为

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

根据土壤盐渍化程度分级标准和前人研究成果^[26], 将 120 个土壤样本分为非盐渍土(含盐量 0~0.2%)、轻度盐渍土(0.2%~0.5%)、重度盐渍土(0.5%~1.0%)和盐土(>1.0%)4 类。将各类别的土壤含盐量按照比例 2:1 随机划分为建模集和验证集, 对植被期划分盐渍化等级后的土壤样本进行统计分析, 结果如表 1 所示。

$$\sigma_{soil}^o = (\sigma^o - \sigma_{veg}^o) / L^2 \quad (5)$$

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_{veg}^o ——仅由植被引起的后向散射系数

L^2 ——双向冠层传递因子

σ_{soil}^o ——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_i ——雷达入射角

在大多数研究中, 研究人员主要使用植被含水率(Vegetation water content, VWC)、叶面积指数(Leaf area index, LAI)和归一化植被指数(NDVI)来定义 V_1 和 V_2 。本研究采用 $V_1 = V_2 = LAI$, 其中, LAI 是利用 Sentinel-2 多光谱影像在 SNAP 7.0 软件中计算提取的。根据前人研究^[29], 估算各种类型植被的植被系数 A 和 B , 如表 2 所示。

由于本研究区域耕地面积约占 70.39%, 且样本均分布在耕作区, 因此 $A = 0.0018, B = 0.138$ 。由式(3)~(5)可以计算出植被条件下土壤后向散射系数。

表 2 不同类型植被的植被系数

Tab. 2 Values of vegetation coefficients for different types of vegetation

参数	所有植被	牧场	耕地	草场
A	0.001 2	0.000 9	0.001 8	0.001 4
B	0.091	0.032	0.138	0.084

1.3.2 极化组合指数

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^[30]。因此本文提取 Sentinel-1 双极化波段(VH 和 VV)和 8 个极化组合指数(VV + VH(P1)、VV - VH(P2)、VH² + VV(P3)、VH² - VV(P4)、(VV² + VH²)/VV(P5)、(VV² - VH²)/VV²(P6)、(VV² - VH²)/VH(P7)、VH/VV(P8))。

1.3.3 多光谱指数

本文构建的多光谱指数及其对应表达式如表 3 所示。

表 3 构建的光谱指数及其表达式

Tab. 3 Constructed spectral indices and their representation

指数名称	表达式	文献序号
归一化水指数(NDWI)	$(B_3 - B_8) / (B_3 + B_8)$	[31]
大气阻抗植被指数(ARVI)	$[B_8 - (2B_4 - B_2)] / (B_8 + 2B_4 - B_2)$	[32]
修正土壤植被指数(MSAVI)	$\{2B_8 - 1 - [(2B_8 + 1)^2 - 8(B_8 - B_4)]^{0.5}\} / 2$	[33]
增强植被指数(EVI)	$2.5(B_8 - B_4) / (B_8 + 6B_4 - 7.5B_2 + 1)$	[34]
归一化植被指数(NDVI)	$(B_8 - B_4) / (B_8 + B_4)$	[35]
冠层盐分响应指数(CRSI)	$[(B_8B_4 - B_3B_4) / (B_8B_4 + B_3B_4)]^{0.5}$	[36]

注: B_2 、 B_3 、 B_4 、 B_8 分别表示波段 2、波段 3、波段 4、波段 8 的反射率。

1.3.4 Sentinel-1/2 图像纹理特征

目前,基于灰度共生矩阵(Gray-level cooccurrence matrix, GLCM)来统计提取图像纹理特征是最流行和常用的^[13,37-38]。本文利用 GLCM 提取了 Sentinel-1 和 Sentinel-2 主成分图像的 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)。其详细描述见文献[39]。

已有研究证明,图像空间分辨率对提取纹理特征有较大影响^[39],因此为了更好地比较两个数据源在不同时期对土壤含盐量反演的影响,避免分辨率带来不必要的误差,将 Sentinel-1 和 Sentinel-2 的图像分辨率统一在 ENVI 5.3 中重采样至 10 m。

1.4 机器学习模型

RF 是一种综合算法,通过多个决策树对数据进行判别和分类^[40],这些决策树是由输入数据集的随机引导样本生成。它可以在不大幅提高计算能力的情况下提高预测精度,降低过拟合的风险,并在没有数据和非平衡情况下变得更加稳健。基本上,有两个重要的设置参数,即生长树数量(ntree)和预测器特征变量(mtry),用于 RF 算法调整^[41]。

ELM 被用来训练单隐层前馈神经网络,具有训练速度快、不易陷入局部最优解等优点。此外,ELM 在训练阶段随机采用输入层权值和节点偏置,以产

生明显的最优解^[42]。在本研究中,将 sigmoid 函数设置为激活函数,并尝试调整不同的隐层神经元节点数(2~50),以降低 ELM 模型的随机性。其他参数设为默认值。

Cubist 是一个片状线性树状模型,使用预测变量空间的递归划分^[43]。它采取分而治之的策略,力求使每个节点上的子集内部变化最小。立体模型的形式为:如果[条件],那么[线性模型]的方法,即如果与观测相关的预测变量观测值满足一组条件,则使用线性模型来预测响应。每个规则中条件集的优点为,它们能够通过允许不同的线性模型来捕捉预测变量空间各部分的局部线性,从而自动处理相互作用。这通常可以导致更小的树和比回归树更好的预测精度^[43-45]。决策树的大小也可以由 Cubist 中的两个参数控制,一个是对作为规则基础的最小观察数的可选约束,另一个是简洁系数,它使用启发式方法来控制模型^[44]。在过去的几十年里,Cubist 模型在许多土壤性质的预测和绘图中发挥了重要作用,它可以显著提高预测准确性^[45]。

1.5 技术路线

本研究目标的实现主要包括 3 个步骤:
①Sentinel-1/2 图像预处理和实际含盐量测量。
②获取经水云模型处理后的极化组合指数、光谱指数、纹理特征。
③构建土壤盐分含量反演模型,并进行精度和稳定性评价。所有步骤的整个技术路线如图 2 所示。

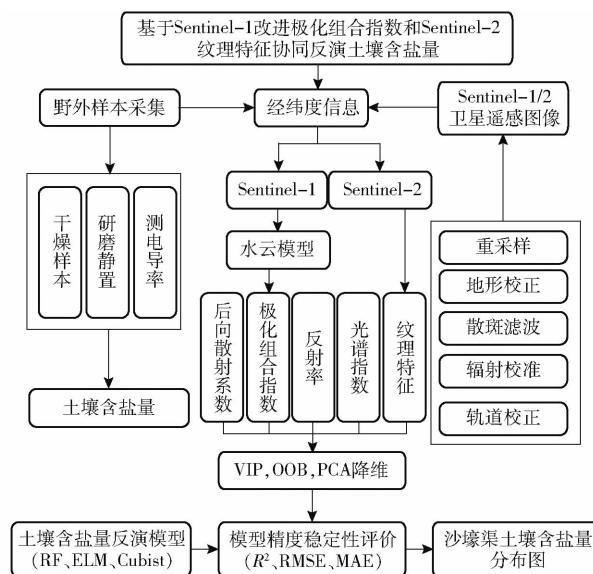


图 2 研究技术路线图

Fig. 2 Technology routine

2 结果与分析

2.1 雷达后向散射系数及其极化组合指数

将植被冠层上的总后向散射系数作为类别 I , 将经过水云模型计算的土壤后向散射系数作为类

别 II , 分析类别 I 和类别 II 的雷达后向散射系数及其极化组合指数 P1 ~ P8 与土壤含盐量的相关系数, 见表 4。

如表 4 所示, 经过水云模型消除植被的影响后, Sentinel-1 的 VH、VV 的后向散射系数和 8 个极化指数与植被土壤含盐量的相关性普遍显著提高。类别 I 的 10 个参数中, 只有 VH 与 SSC 在 0.05 水平显著, 而类别 II 的 10 个参数中, VV、P1、P2、P3、P4、P5 与 SSC 相关性达到 0.05 水平显著, VH 与 SSC 相关性达到 0.01 水平显著; 这表明剔除了由植被引起的后向散射系数有助于提高监测土壤含盐量的精度。

2.2 多光谱指数 Sentinel-2 图像纹理特征

提取 Sentinel-2 的 8 个纹理特征、10 个多光谱波段以及 6 个植被指数共 24 个协变量, 并分析其与植被土壤含盐量的相关性, 结果如表 5 所示。

从表 5 可以看出, Sentinel-2 所有纹理特征都和 SSC 显著相关, 其中 CON、MEAN、VAR 的显著性达到 0.001 水平, DIS、ENT、COR 的显著性达到 0.01 水平, HOM、ASM 的显著性达到 0.05 水平。Sentinel-2 除了 B6、B7、B8 光谱反射率与 SSC 不显

表 4 雷达后向散射系数及其极化组合指数与土壤含盐量的相关系数

Tab. 4 Correlation coefficients of radar backscatter coefficient and its polarization combination index with SSC

类别	VV	VH	P1	P2	P3	P4	P5	P6	P7	P8
I	-0.140	-0.200 *	-0.150	-0.130	-0.140	0.140	-0.150	0.004	-0.084	-0.016
II	-0.210 *	-0.270 **	-0.220 *	-0.190 *	-0.210 *	0.210 *	-0.210 *	-0.002	-0.110	-0.010

注: ** 表示在 0.01 水平上显著, * 表示在 0.05 水平上显著, 下同。

表 5 协变量与土壤含盐量的相关系数

Tab. 5 Correlation coefficients between covariates and soil salinity

协变量	CON	DIS	HOM	ASM	ENT	MEAN	VAR	COR
r	-0.330 ***	-0.290 **	0.210 *	0.220 *	-0.300 **	0.380 ***	0.390 ***	0.300 **
协变量	B2	B3	B4	B5	B6	B7	B8	B8A
r	0.480 ***	0.420 ***	0.420 ***	0.400 ***	-0.027	-0.170	-0.160	-0.220 *
协变量	B11	B12	NDWI	ARVI	MSAVI	EVI	NDVI	CRSI
r	0.320 ***	0.330 ***	0.460 ***	-0.400 ***	-0.410 ***	-0.400 ***	-0.430 ***	-0.480 ***

注: *** 表示在 0.001 水平上显著, 下同。

著相关, 其它波段反射率都与 SSC 显著相关; 构建的 6 个植被指数也全部在 0.001 水平上与含盐量显著相关。一般而言, 模型输入自变量与因变量之间的相关系数越高, 模型精度越高。因此, 本研究选用 Sentinel-2 的 8 个纹理特征、10 个光谱波段和 6 个植被指数作为模型自变量, 并在将其作为模型自变量之前对各协变量之间的自相关性进行分析, 结果如图 3 所示。

由图 3 可知, 所有纹理特征、大部分光谱波段以及所有植被指数之间都存在极显著的相关性, 而变

量选择方法可以消除不必要的变量信息, 减少模型的过拟合或欠拟合, 即变量选择可以提高模型精度且可以提高模型鲁棒性^[46]。因此本文利用 VIP、OOB 和 PCA 3 种协变量降维方法对 24 个协变量进行筛选降维。

2.3 不同筛选降维方法结果分析

分别利用 VIP、OOB 和 PCA 3 种方法对 34 个协变量(2 个后向散射系数、8 个 Sentinel-1 极化组合指数、8 个 Sentinel-2 纹理特征、10 个光谱波段和 6 个植被指数)进行筛选降维, 筛选结果如图 4 所

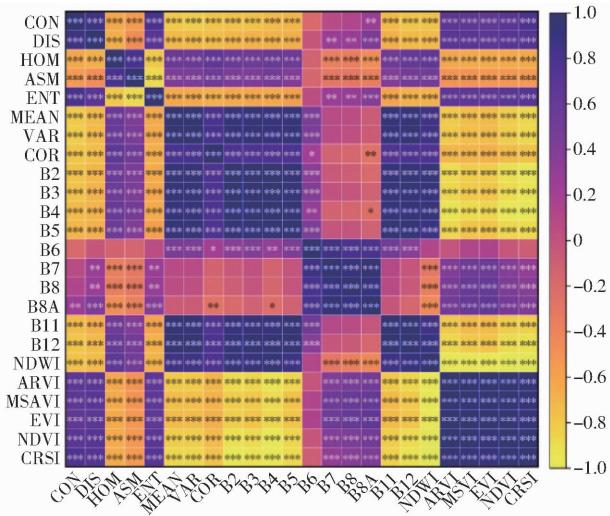


图 3 Sentinel-2 协变量之间的自相关性

Fig. 3 Autocorrelation between Sentinel-2 covariates

示。图 4c 中柱状图表示每个主成分的贡献率,折线表示主成分的累计贡献率。

从图 4a 可以看出,植被指数和部分光谱指数的 VIP 值均比较高,其中 B2 的 VIP 值最大,为 1.549,而雷达后向散射系数及其极化组合指数的 VIP 值较小。本研究选取 VIP 值大于 1 的协变量作为模型输入变量,共选取 15 个协变量,VIP 值从大到小依次为:B2、CRSI、NDWI、NDVI、B4、B3、MSAVI、B5、EVI、ARVI、VAR、MEAN、CON、B12、B11。

从图 4b 可以看出,极化组合指数和大部分植被指数 IncMSE 值都较大,纹理特征和部分光谱波段的 IncMSE 值较小,其中 IncMSE 值最大的是 P1,为 5.948,最小的是 B8,为 -0.627。本研究选取 IncMSE 值大于 5 的协变量作为模型的输入变量,共有 12 个,IncMSE 值从大到小依次为 P1、CRSI、P5、B2、P3、NDVI、ARVI、MSAVI、NDWI、VV、P4、P2。

图 4c 为雷达后向散射系数及其极化组合指数、Sentinel-2 图像纹理特征、光谱波段和植被指数这 3 部分协变量的降维结果。协变量经过 PCA 降维后,数量减少至 2~4 个,其累计贡献率均在 95% 以上,PCA 降维后的协变量共 9 个,分别为 PC1~PC9。

因此,用 VIP、OOB 和 PCA 3 种方法对协变量进行筛选或降维,可以较大程度减少最终所选的变量

数量,最终模型输入变量的数量分别为 15、12、9, VIP 比 OOB 和 PCA 选择更多的协变量。选取变量结果如表 6 所示。

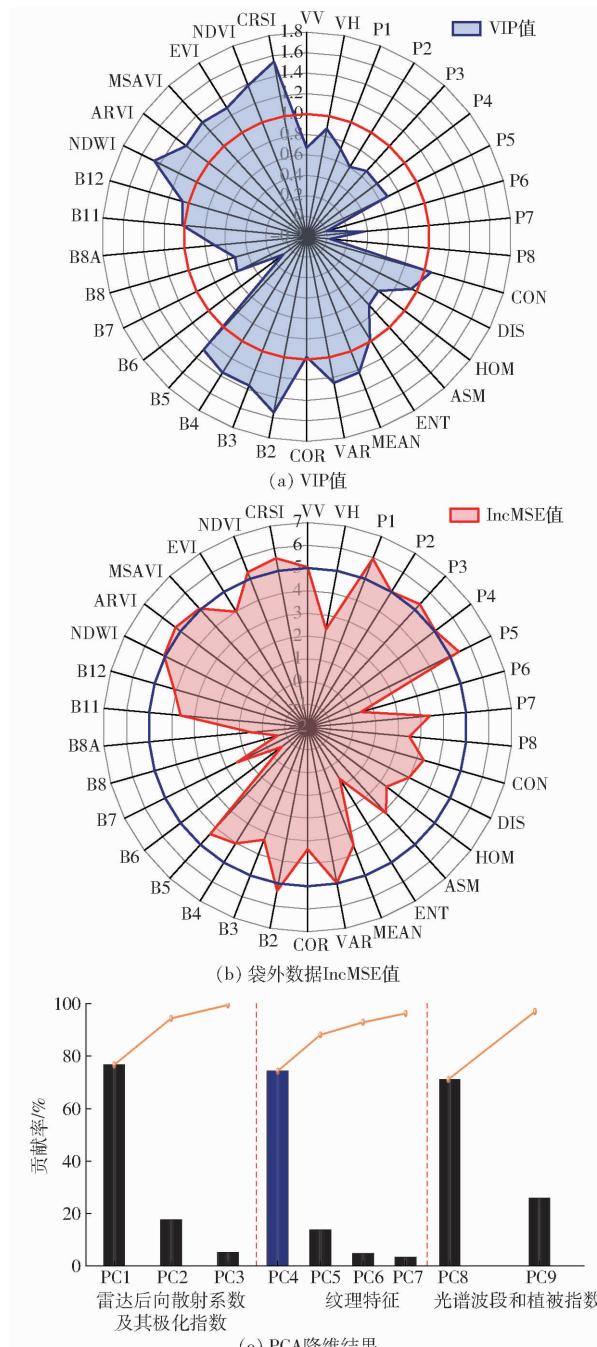


图 4 用于估算 SSC 的协变量的降维结果

Fig. 4 Graphs of screening and downscaling results of covariates used to estimate SSC

表 6 基于降维方法的变量选择结果

Tab. 6 Results of variable selection based on filtering and dimensionality reduction methods

降维方法	选取变量的数量	降维后选取的变量
VIP	15	B2 ***、CRSI ***、NDWI ***、NDVI ***、B4 ***、B3 ***、MSAVI ***、B5 ***、EVI ***、ARVI ***、VAR ***、MEAN ***、CON ***、B12 ***、B11 ***
OOB	12	P1 *、CRSI ***、P5 *、B2 ***、P3 *、NDVI ***、ARVI ***、MSAVI ***、NDWI ***、VV *、P4 *、P2 *
PCA	9	PC1、PC2、PC3、PC4 ***、PC5 ***、PC6 ***、PC7 ***、PC8 ***、PC9 *

2.4 模型综合评价与分析

2.4.1 模型精度比较

将2.3节基于3种变量筛选降维方法得到的组合变量(表6)作为3种机器学习模型(RF、ELM和Cubist)的最终输入变量,以构建植被期土壤含盐量

反演模型。为了研究3种变量选择方法和3种机器学习耦合模型反演含盐量的效果,在相同的建模集和验证集上构建9种耦合模型,并以 R^2 、RMSE和MAE3种指标来评价模型的准确性,结果如表7所示。

表7 基于不同变量筛选方法的土壤含盐量反演耦合模型精度

Tab. 7 Coupled model performance of soil salinity inversion based on different variables screening for dimensionality reduction methods

变量筛选方法	耦合模型	建模集($n=80$)			验证集($n=40$)		
		R_c^2	RMSE _c /%	MAE _c /%	R_v^2	RMSE _v /%	MAE _v /%
VIP	VIP-RF	0.888	0.135	0.079	0.739	0.195	0.146
	VIP-ELM	0.740	0.171	0.137	0.667	0.225	0.169
	VIP-Cubist	0.787	0.174	0.108	0.719	0.203	0.150
OOB	OOB-RF	0.914	0.113	0.066	0.758	0.188	0.131
	OOB-ELM	0.806	0.147	0.103	0.781	0.192	0.144
	OOB-Cubist	0.920	0.095	0.070	0.879	0.134	0.092
PCA	PCA-RF	0.905	0.126	0.071	0.725	0.200	0.142
	PCA-ELM	0.749	0.169	0.130	0.680	0.211	0.167
	PCA-Cubist	0.818	0.160	0.089	0.752	0.188	0.121

从表7可以看出,基于OOB筛选与3种机器学习模型的耦合效果均最好,PCA和VIP与3种机器学习模型的耦合效果次之。在OOB与3种机器学习方法的耦合模型中,OOB-Cubist效果最好,具有最高的反演精度,误差较小,模型较稳定(建模集和验证集的 R^2 均在0.87以上,且RMSE和MAE都较小);OOB-ELM模型反演精度次之(建模集和验证集决定系数分别为0.806、0.781);OOB-RF模型反演效果最差,出现“过拟合”现象(建模集 $R_c^2=0.914$,验证集 $R_v^2=0.758$)。

2.4.2 模型稳定性比较

由表7可知,各耦合模型反演土壤含盐量的效果均较好,3种变量筛选方法耦合3种机器学习方法反演土壤含盐量的建模集 R_c^2 都在0.7以上, RMSE_c均在0.175%以下,MAE_c均在0.14%以下;验证集 R_v^2 均在0.65以上, RMSE_v均在0.225%以下,MAE_v均在0.17%以下。好的模型通常同时有较好的反演精度和稳定性,因此还需要对模型稳定性进行分析,其中 R_v^2/R_c^2 越接近1,表明模型鲁棒性越好,模型越稳定。

从图5可知,9种耦合模型中,OOB-ELM鲁棒性最好($R_v^2/R_c^2=0.969$);其次为OOB-Cubist($R_v^2/R_c^2=0.955$);PCA-RF鲁棒性最低($R_v^2/R_c^2=0.801$)。此外,VIP-RF、OOB-RF和PCA-RF的 R_v^2/R_c^2 均低于0.85,这表明3种变量筛选方法与RF的耦合模型鲁棒性都较差。3种变量筛选方法与Cubist耦合模型的 R_v^2/R_c^2 均高于0.90,且相对应的

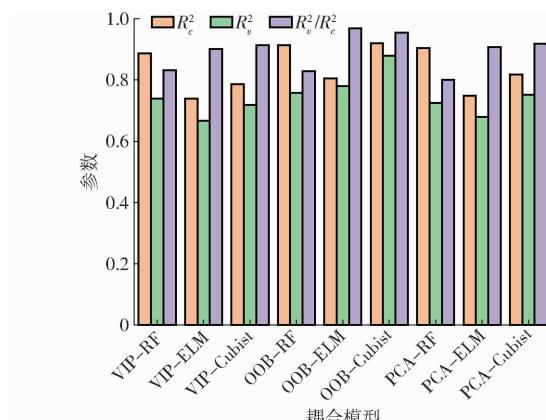


图5 不同耦合模型的反演效果

Fig. 5 Comparison of inversion effects of different coupling models

R_c^2 和 R_v^2 都较高。3种变量筛选方法与ELM耦合模型的 R_v^2/R_c^2 同样都高于0.90,但其相对应的 R_c^2 和 R_v^2 都较低。综合得知,Cubist模型精度最好,鲁棒性最好,也最稳定;ELM模型精度比RF模型差,但鲁棒性比RF好,比RF稳定。因此,OOB-Cubist是反演该研究区土壤含盐量的最好模型。

图6为基于不同耦合模型验证集的SSC实测值与预测值的散点图,阴影部分表示95%置信区间。由图6e、6f可知,OOB变量筛选方法与ELM和Cubist两种机器学习方法耦合可以使SSC的实测值与预测值的散点更接近1:1线。然而,由图6b、6h可知,VIP和PCA两种变量选择方法与ELM机器学习方法耦合模型的实测SSC与预测SSC的散点明显比较分散,其拟合线偏离于1:1线。

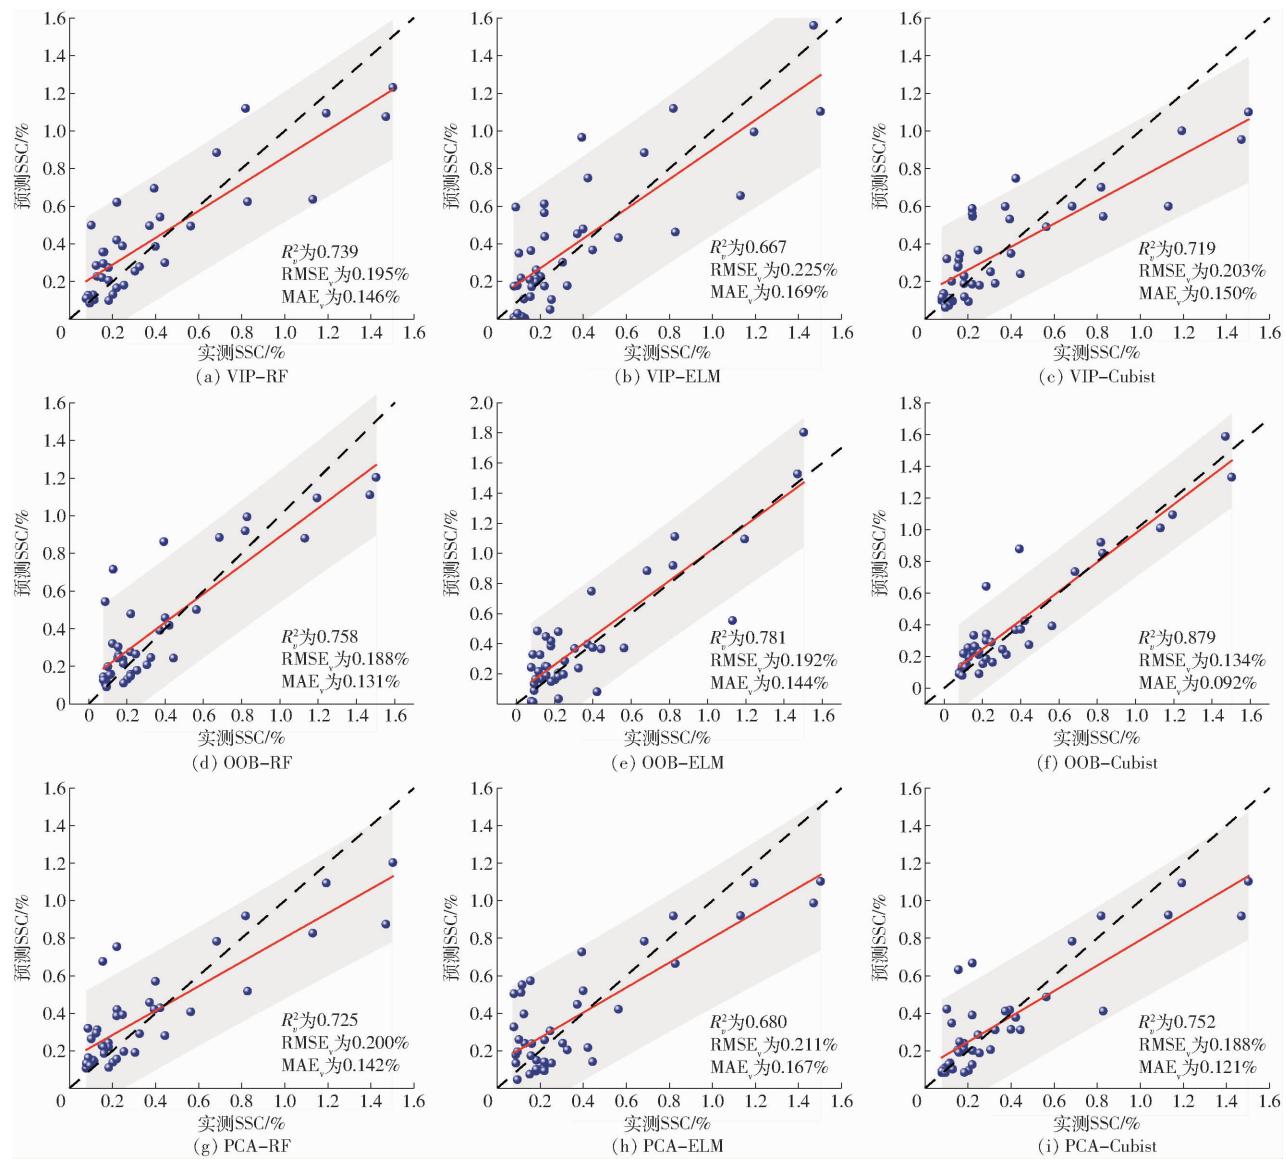


图 6 不同耦合模型验证集的实测 SSC 和预测 SSC 的散点图

Fig. 6 Scatter plots of measured SSC and estimated SSC based on different coupled model validation sets

2.5 基于 OOB – Cubist 模型反演的研究区 SSC 分布图

根据图 6 最优耦合模型 OOB – Cubist 模型, 进行研究区表层土壤含盐量估测, 得到土壤含盐量反演图(图 7), 通过盐渍土分类标准, 可以将研究区盐渍化土壤划分为 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%)、盐土(>1.0%)^[47]。其中轻度盐渍土占最大比例, 其次是非盐渍土和中度盐渍土占比一般, 重度盐渍土占比最小, 这与以前研究结论相符合^[48]。其中北部土壤含盐量普遍比南部含盐量高, 研究区中部含盐量比东部和西部含盐量更高。

3 讨论

本文研究结果表明, 经校正后的雷达后向散射系数及其极化组合指数与土壤含盐量的相关性有一

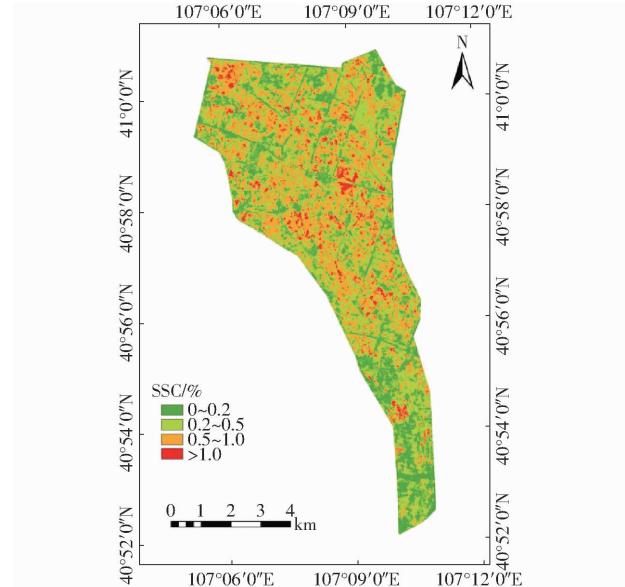


图 7 沙壕渠 2019 年 7 月 SSC 分布反演图

Fig. 7 Soil salinity distribution map of Shahaoqu in July, 2019

定程度的提高;这是因为在植被覆盖的条件下,植被对雷达后向散射信息的干扰是影响土壤含盐量反演精度的重要因素。不同耦合模型反演土壤含盐量的精度结果表明,OOB 变量筛选方法与 RF、ELM 和 Cubist 这 3 种机器学习方法的耦合模型精度最佳;其中,OOB-Cubist 耦合模型效果最好,可以作为估算本研究区域 7 月土壤含盐量的模型。

土壤含盐量与光谱、雷达的协变量之间有着非常复杂的非线性关系,尽管变量选择方法可以减少协变量的数量,简化模型结构,但这并不能改变 SSC 与协变量之间的非线性关系,而 Cubist 算法可以很好地解决这些非线性问题,有着令人比较满意的表现。目前,已有许多研究表明,Cubist 算法是估算土壤含盐量的有利工具。例如,ZHANG^[49] 在探究卫星遥感监测不同植被覆盖度土壤含盐量时发现,Cubist 算法的估算效果最好。PENG^[50] 比较了两种模型在电导率(EC)、土壤含水量和植被覆盖率的不同区间下的验证结果,发现 Cubist 模型在可变环境下预测 EC 的准确性和稳定性优于 PLSR。本文研究同样证实了 Cubist 模型的优越性。

然而,本研究只证实了水云模型在 Sentinel-1/2

协同反演植被土壤含盐量的有效性,而水分、土壤微生物、天气等也都会影响卫星反演的精度^[51-52]。因此,将考虑更多因素的物理模型和机器学习结合,是未来卫星反演土壤含盐量的重要研究方向。

4 结论

(1) 经过水云模型去除植被影响后的雷达后向散射系数及其极化组合指数与土壤含盐量的相关性有一定程度的提高。

(2) 与雷达图像纹理特征相比,多光谱图像的纹理特征与土壤含盐量的相关性明显更高。

(3) 将不同变量选择方法与不同机器学习方法耦合模型反演土壤含盐量的性能进行比较,OOB 变量筛选方法与 RF、ELM 和 Cubist 这 3 种机器学习方法的耦合模型精度最佳,而 VIP 和 PCA 与 3 种机器学习方法的耦合精度较低,效果较差。

(4) 在 OOB 变量筛选方法与 RF、ELM 和 Cubist 这 3 种机器学习方法耦合的模型中,OOB-Cubist 耦合模型精度最高且具有良好的鲁棒性。OOB-Cubist 耦合模型可以有效地估算本研究区域 7 月的 SSC。

参 考 文 献

- [1] DALIAKOPoulos I N, TSANIS I K, KOUTROULIS A, et al. The threat of soil salinity: a European scale review[J]. *Science of the Total Environment*, 2016, 573: 727-739.
- [2] AKÇA E, AYDIN M, KAPUR S, et al. Long-term monitoring of soil salinity in a semi-arid environment of Turkey[J]. *CATENA*, 2020, 193: 104614.
- [3] GU S, JIANG S, LI X, et al. Soil salinity simulation based on electromagnetic induction and deep learning[J]. *Soil and Tillage Research*, 2023, 230: 105706.
- [4] 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, 119: 106869.
- [5] GORJI T, SERTEL E, TANIK A. Monitoring soil salinity via remote sensing technology under data scarce conditions: a case study from Turkey[J]. *Ecological Indicators*, 2017, 74: 384-391.
- [6] 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.
- [7] 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.
- [8] 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.
- [9] WANG N, PENG J, 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.
- [10] 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.
- [11] 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.
- [12] PERIASAMY S, RAVI K P, TANSEY K. Identification of saline landscapes from an integrated SVM approach from a novel 3D classification schema using Sentinel-1 dual-polarized SAR data[J]. *Remote Sensing of Environment*, 2022, 279: 113144.
- [13] YIN H, CHEN C, HE Y, et al. Synergistic estimation of soil salinity based on Sentinel-1 image texture and Sentinel-2 salinity spectral indices[J]. *Journal of Applied Remote Sensing*, 2023, 17(1): 018502.
- [14] ARJASAKUSUMA S, KUSUMA S S, VETRITA Y, et al. Monthly burned-area mapping using multi-sensor integration of

- Sentinel - 1 and Sentinel - 2 and machine learning: case study of 2019's fire events in South Sumatra Province, Indonesia [J]. *Remote Sensing Applications: Society and Environment*, 2022, 27: 100790.
- [15] 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.
- [16] LI J, WANG S, GUNN G, et al. A model for downscaling SMOS soil moisture using Sentinel - 1 SAR data [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2018, 72: 109 - 121.
- [17] 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.
- [18] 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.
- [19] PERIASAMY S, SHANMUGAM R S. Multispectral and microwave remote sensing models to survey soil moisture and salinity [J]. *Land Degradation & Development*, 2017, 28(4): 1412 - 1425.
- [20] 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.
- [21] 邹超煜, 白岗栓. 河套灌区土壤盐渍化成因及防治 [J]. *人民黄河*, 2015, 37(9): 143 - 148.
ZOU Chaoyu, BAI Gangshuan. Formation cause and control methods about soil salinization in Hetao Irrigation Area [J]. *Yellow River*, 2015, 37(9): 143 - 148. (in Chinese)
- [22] LAO C, CHEN J, 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.
- [23] 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. Estimation method of soil salinity based on remote sensing data assimilation [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(7): 197 - 207. (in Chinese)
- [24] 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. UAV 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)
- [25] 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)
- [26] 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 irrigation district [J]. *Transactions of the CSAE*, 2018, 34(1): 102 - 109. (in Chinese)
- [27] ATTEMAT E P W, ULABY F T. Vegetation modeled as a water cloud [J]. *Radio Science*, 1978, 13(2): 357 - 364.
- [28] 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) scatterometer [J]. *Remote Sensing of Environment*, 1993, 46(3): 331 - 339.
- [29] BINDLISH R, BARROS A P. Multifrequency soil moisture inversion from SAR measurements with the use of IEM [J]. *Remote Sensing of Environment*, 2000, 71(1): 67 - 88.
- [30] 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)
- [31] MCFEETERS S K. The use of the normalized difference water index (NDWI) in the delineation of open water features [J]. *International Journal of Remote Sensing*, 1996, 17(7): 1425 - 1432.
- [32] KAUFMAN Y J, TANRE D. Atmospherically resistant vegetation index (ARVI) for EOS - MODIS [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1992, 30(2): 261 - 270.
- [33] QI J, CHEHBOUNI A, HUETE A R, et al. A modified soil adjusted vegetation index [J]. *Remote Sensing of Environment*, 1994, 48(2): 119 - 126.
- [34] LIU H Q, HUETE A. Feedback based modification of the NDVI to minimize canopy background and atmospheric noise [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1995, 33(2): 457 - 465.
- [35] SHAFIZADEH-MOGHADAM H, MINAEI F, TALEBI-KHIYAVI H, et al. Synergetic use of multi-temporal Sentinel - 1, Sentinel - 2, NDVI, and topographic factors for estimating soil organic carbon [J]. *CATENA*, 2022, 212: 106077.
- [36] SCUDIERO E, SKAGGS T H, CORWIN D L. Regional scale soil salinity evaluation using Landsat 7, western San Joaquin Valley, California, USA [J]. *Geoderma Regional*, 2014, 2 - 3: 82 - 90.
- [37] YUE J, YANG G, TIAN Q, 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.
- [38] OHANIAN P P, DUBES R C. Performance evaluation for four classes of textural features [J]. *Pattern Recognition*, 1992, 25(8): 819 - 833.
- [39] 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.
- [40] GHOSH A, DEY P. Flood severity assessment of the coastal tract situated between muri ganga and saptamukhi estuaries of

- Sundarban delta of India using frequency ratio (FR), fuzzy logic (FL), logistic regression (LR) and random forest (RF) models[J]. *Regional Studies in Marine Science*, 2021, 42: 101624.
- [41] GHOLIZADEH M, JAMEI M, AHMADIANFAR I, et al. Prediction of nanofluids viscosity using random forest (RF) approach[J]. *Chemometrics and Intelligent Laboratory Systems*, 2020, 201: 104010.
- [42] PRASAD R, DEO R C, LI Y, et al. Soil moisture forecasting by a hybrid machine learning technique: ELM integrated with ensemble empirical mode decomposition[J]. *Geoderma*, 2018, 330: 136–161.
- [43] MA Z, SHI Z, ZHOU Y, et al. A spatial data mining algorithm for downscaling TMPA 3B43 V7 data over the Qinghai-Tibet plateau with the effects of systematic anomalies removed[J]. *Remote Sensing of Environment*, 2017, 200: 378–395.
- [44] HENDERSON B L, BUI E N, MORAN C J, et al. Australia-wide predictions of soil properties using decision trees[J]. *Geoderma*, 2005, 124(3): 383–398.
- [45] BUI M, LIU Z. Simple allele-discriminating PCR for cost-effective and rapid genotyping and mapping[J]. *Plant Methods*, 2009, 5(1): 1–8.
- [46] RAJ A, CHAKRABORTY S, DUDA B M, et al. Soil mapping via diffuse reflectance spectroscopy based on variable indicators: an ordered predictor selection approach[J]. *Geoderma*, 2018, 314: 146–159.
- [47] 陈俊英, 王新涛, 张智韬, 等. 基于无人机-卫星遥感升尺度的土壤盐渍化监测方法[J]. *农业机械学报*, 2019, 50(12): 161–169.
- CHEN Junying, WANG Xintao, ZHANG Zhitao, et al. Soil salinization monitoring method based on UAV – satellite remote sensing scale-up[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2019, 50(12): 161–169. (in Chinese)
- [48] 张智韬, 陈钦达, 黄小鱼, 等. 基于加权算法的空-天遥感升尺度土壤含盐量监测模型[J]. *农业机械学报*, 2022, 53(9): 226–238, 251.
- ZHANG Zhitao, CHEN Qinda, HUANG Xiaoyu, et al. UAV – satellite remote sensing scale-up monitoring model of soil salinity based on dominant class variability-weighted method [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(9): 226–238, 251. (in Chinese)
- [49] ZHANG J, ZHANG Z, CHEN J, et al. Estimating soil salinity with different fractional vegetation cover using remote sensing [J]. *Land Degradation & Development*, 2021, 32(2): 597–612.
- [50] PENG J, BISWAS A, JIANG Q, et al. Estimating soil salinity from remote sensing and terrain data in southern Xinjiang, China[J]. *Geoderma*, 2019, 337: 1309–1319.
- [51] 张智韬, 杜瑞麒, 杨帅, 等. 水盐交互作用对河套灌区土壤光谱特征的影响[J]. *农业工程学报*, 2020, 36(18): 153–164.
- ZHANG Zhitao, DU Ruiqi, YANG Shuai, et al. Effects of water-salt interaction on soil spectral characteristics in Hetao Irrigation Areas of Inner Mongolia, China[J]. *Transactions of the CSAE*, 2020, 36(18): 153–164. (in Chinese)
- [52] HE Y, ZHANG Z, XIANG R, et al. Monitoring salinity in bare soil based on Sentinel-1/2 image fusion and machine learning [J]. *Infrared Physics & Technology*, 2023, 131: 104656.

(上接第 174 页)

- [22] 孙威, 王鹏新, 韩丽娟, 等. 条件植被温度指数干旱监测方法的完善[J]. *农业工程学报*, 2006, 22(2): 22–26.
- SUN Wei, WANG Pengxin, HAN Lijuan, et al. Further improvement of the approach to monitoring drought using vegetation and temperature condition indexes from multi-years' remotely sensed data[J]. *Transactions of the CSAE*, 2006, 22(2): 22–26. (in Chinese)
- [23] 王鹏新, 荷兰, 李俐, 等. 基于时间序列叶面积指数傅里叶变换的作物种植区域提取[J]. *农业工程学报*, 2017, 33(21): 207–215.
- WANG Pengxin, XUN Lan, LI Li, et al. Extraction of planting areas of main crops based on Fourier transformed characteristics of time series leaf area index products[J]. *Transactions of the CSAE*, 2017, 33(21): 207–215. (in Chinese)
- [24] 贺志将, 李前, 王彦超, 等. 基于 VMD-LSTM 的奶牛动态称量算法[J]. *农业机械学报*, 2022, 53(增刊2): 234–240.
- HE Zhijiang, LI Qian, WANG Yanchao, et al. Cow dynamic weighing algorithm based on VMD-LSTM[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(Supp. 2): 234–240. (in Chinese)
- [25] 王俊, 李霞, 周昔东, 等. 基于 VMD 和 LSTM 的超短期风速预测[J]. *电力系统保护与控制*, 2020, 48(11): 45–52.
- WANG Jun, LI Xia, ZHOU Xidong, et al. Ultra-short-term wind speed prediction based on VMD-LSTM[J]. *Power System Protection and Control*, 2020, 48(11): 45–52. (in Chinese)
- [26] 王鹏新, 王婕, 田惠仁, 等. 基于遥感多参数和门控循环单元网络的冬小麦单产估测[J]. *农业机械学报*, 2022, 53(9): 207–216.
- WANG Pengxin, WANG Jie, TIAN Huiren, et al. Yield estimation of winter wheat based on multiple remotely sensed parameters and gated recurrent unit neural network[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(9): 207–216. (in Chinese)
- [27] ASUERO A G, SAYAGO A, GONZÁLEZ A G. The correlation coefficient: an overview[J]. *Critical Reviews in Analytical Chemistry*, 2007, 36(1): 41–59.