

doi:10.6041/j.issn.1000-1298.2023.03.033

# 基于特征优选与机器学习的农田土壤含盐量估算研究

韩文霆<sup>1,2</sup> 崔家伟<sup>2,3</sup> 崔 欣<sup>1,2</sup> 马伟童<sup>2,3</sup> 李 广<sup>1,2</sup>

(1. 西北农林科技大学机械与电子工程学院, 陕西杨凌 712100;

2. 西北农林科技大学中国旱区节水农业研究院, 陕西杨凌 712100;

3. 西北农林科技大学水利与建筑工程学院, 陕西杨凌 712100)

**摘要:** 土壤盐渍化是影响农业可持续发展的重要制约因素, 为准确及时地获取土壤中盐分含量, 实现盐渍化精准监测, 以内蒙古自治区巴彦淖尔市五原县境内的覆被农田为研究对象, 探讨无人机多光谱遥感平台结合机器学习模型估测不同深度土壤含盐量的可行性。首先, 利用无人机搭载五波段多光谱相机获取研究区域高时空分辨率遥感图像数据, 并同步采集地面不同深度处土壤盐分数据, 使用皮尔逊相关系数法(PCC)、极端梯度提升(XGBoost)和灰色关联分析法(GRA)对构建的光谱指数进行优选; 然后, 采用决策树(DT)、反向传播神经网络(BPNN)、支持向量机(SVM)和随机森林(RF)4种机器学习方法建立植被覆盖下不同深度的农田土壤含盐量反演模型。结果表明, 使用方案3(XGBoost-GRA)变量优选方法可以有效地筛选出敏感光谱指数, 且基于此方法优选后的光谱指数建立含盐量估算模型的精度高于仅使用PCC或XGBoost法构建的反演模型。对比不同建模方法在不同土壤深度处的反演精度, 可知随机森林RF模型整体表现最优, 同时另外3种反演模型也取得了较好的预测效果, 0~20 cm土壤深度处的预测效果是3个土壤深度中最优的, 其中精度最高模型的决定系数R<sup>2</sup>、均方根误差(RMSE)和四分位数间距性能比(RPIQ)分别为0.820、0.044%和2.273, 且本文基于最佳反演模型绘制的0~20 cm土壤盐分空间分布图可以较真实地反映研究区内的土壤盐渍化程度。本研究表明特征变量优选结合机器学习模型能够较好地基于无人机遥感平台来估算覆被农田的土壤含盐量。

**关键词:** 无人机遥感; 盐分监测; 光谱指数; 变量筛选; 预测模型

中图分类号: S127

文献标识码: A

文章编号: 1000-1298(2023)03-0328-10

OSID:



## Estimation of Farmland Soil Salinity Content Based on Feature Optimization and Machine Learning Algorithms

HAN Wenting<sup>1,2</sup> CUI Jiawei<sup>2,3</sup> CUI Xin<sup>1,2</sup> MA Weitong<sup>2,3</sup> LI Guang<sup>1,2</sup>

(1. College of Mechanical and Electronic Engineering, Northwest A&amp;F University, Yangling, Shaanxi 712100, China

2. Institute of Water-saving Agriculture in Arid Regions of China, Northwest A&amp;F University, Yangling, Shaanxi 712100, China

3. College of Water Resources and Architectural Engineering, Northwest A&amp;F University, Yangling, Shaanxi 712100, China)

**Abstract:** Soil salinization is one of the important factors affecting agricultural sustainable development, to get the accurate and timely soil salinity content, and realize precision monitoring of salinization, taking covered fields in the territory of Wuyuan County, Bayinnaoer City in Inner Mongolia Autonomous Region as the research object, exploring UAV multispectral remote sensing platform combined with machine learning model to estimate the feasibility of different depths soil salinity. Firstly, UAV equipped with five-band multi-spectral camera was used to acquire high spatio-temporal resolution remote sensing image data, and soil salinity data at different depths of the ground were collected synchronously. Pearson correlation coefficient method (PCC), extreme gradient boosting (XGBoost) and gray correlation analysis (GRA) were used to optimize the spectral index. Then decision tree (DT), back propagation neural network (BPNN), support vector machine (SVM) and random forest (RF) machine learning methods were used to establish inversion models of soil salinity in farmland with different depths under vegetation coverage. The results showed that scheme 3 (XGBoost - GRA) variable optimization method can

收稿日期: 2022-05-10 修回日期: 2022-08-11

基金项目: 国家自然科学基金项目(51979233)和陕西省重点研发计划项目(2022NY-220、2022KW-47)

作者简介: 韩文霆(1972—), 男, 研究员, 博士生导师, 主要从事农情信息智能感知及精准灌溉技术研究, E-mail: hanwt2000@126.com

effectively screen out the sensitive spectral index, and the accuracy of the optimized spectral index based on this method was higher than that of the inversion model constructed by using only PCC or XGBoost method. By comparing the performance of different modeling methods at different soil depths, it can be seen that the RF model of random forest had the best overall performance, and the other three inversion models had also achieved better prediction effect. The prediction effect of 0~20 cm soil depth was the best among the three soil depths. Among them, the determination coefficient  $R^2$ , root mean square error (RMSE) and ratio of performance to inter-quartile distance (RPIQ) of the model with the highest accuracy were 0.820, 0.044% and 2.273, respectively. Moreover, the spatial distribution map of 0~20 cm soil salinity drawn based on the best inversion model could reflect the degree of soil salinization. The research result showed that the combination of feature variable optimization and machine learning model can better estimate the soil salt content based on the UAV remote sensing platform.

**Key words:** UAV remote sensing; salinity monitoring; spectral index; variables selection; prediction models

## 0 引言

土壤盐渍化是指土壤表层的盐分含量不断增加,以至超过某一限度的现象和过程。它是由气候变化、生态环境等自然条件以及不合理的灌溉技术、地下水开采等人为因素共同作用的结果<sup>[1]</sup>。目前土壤盐渍化已经成为世界范围内主要的土壤退化与环境破坏问题之一,在全球范围内有超过  $1.0 \times 10^9 \text{ hm}^2$  的土地遭受土壤盐渍化的影响<sup>[2]</sup>。在中国,盐渍化面积约占国土资源的 9%,主要分布在干旱、半干旱和半湿润地区<sup>[3]</sup>。河套灌区位于内蒙古自治区西部,是中国设计灌溉面积最大的灌区,也是重要的粮食生产基地之一,而其盐渍化土地已占灌区总面积的 1/3 以上<sup>[4]</sup>,严重制约了当地农业的可持续发展。因此,土壤中盐分含量的及时准确监测对灌区粮食生产和精准农业建设具有重要意义。

传统野外土壤采样方法费时费力且无法进行大面积土壤盐渍化的监测<sup>[5]</sup>。近年来,在植被覆盖期,国内外学者利用遥感技术监测土壤盐渍化方面取得了一定的进展。文献[6]针对摩洛哥塔德拉平原东北部的盐渍化问题,利用 Landsat8-OLI 卫星影像提取得到盐分指数并进行归一化处理,再结合光谱反射率与实测土壤电导率数据对研究区盐渍化状况进行了整体评价。文献[7]基于 Sentinel-2 号多光谱影像多年数据,通过分析光谱反射率和 9 种植被指数与作物根区盐分含量之间的关系,建立了研究区土壤盐分评估的回归模型。文献[8]开展了灌区尺度的土壤盐分野外系统采样工作,结合实测数据进行基于卫星遥感的土壤盐分反演,并分析了土壤盐分的时空分布特征及其与灌溉、地下水埋深间的关系,探讨了土壤盐分含量对作物生长的影响。

已有研究表明,在光学遥感中使用光谱波段与光谱指数构建反演模型的过程中会产生大量冗余信息,为提高模型的监测效率与反演精度,对光谱特征

变量的筛选就显得尤为重要<sup>[9~10]</sup>。文献[11]采用皮尔逊相关性分析法挑选与土壤电导率显著相关的协变量,构建了关于电导率的 Cubist 和偏最小二乘回归模型。文献[12]通过灰色关联分析法(Grey relation analysis, GRA)计算关联度来筛选对土壤盐分敏感的波段或指数,进而利用极限学习机等方法构建了大田葵花不同生育期、不同指数类型以及不同土壤深度下的土壤盐分反演模型。文献[13]利用变量投影重要性分析等 4 种筛选方法得到敏感光谱信息,再结合偏最小二乘回归模型(PLSR)反演并绘制了研究区域盐分分布图。极端梯度提升(Extreme gradient boosting, XGBoost)算法是一个优化的分布式梯度增强库<sup>[14]</sup>,该算法不再使用一阶导数信息,而是基于二阶泰勒公式展开,同时在计算变量重要性上借鉴了随机森林的特征取样方法,来增加模型的多样性,减少过拟合现象,以提高模型效率<sup>[15]</sup>。但该算法在土壤含盐量建模特征筛选的研究中应用较少,其适用性需进一步验证。此外,机器学习算法凭借其在处理非线性问题上的优势,已经在土壤含盐量反演建模上得到应用<sup>[16~17]</sup>。同时,由于卫星遥感存在易受天气影响、重访周期长、时空分辨率低等缺点,导致其难以获取高时空分辨率农田尺度的土壤盐渍化信息,而无人机遥感作为一种新兴遥感形式,具有运行成本低、监测效率高、不影响田间作业等优势<sup>[18~19]</sup>,近年来在作物覆盖度估计<sup>[20]</sup>、玉米蒸散量估算<sup>[21]</sup>、倒伏信息提取<sup>[22]</sup>以及作物产量估算<sup>[23]</sup>等方面有着广泛的应用。一些学者将无人机遥感应用于土壤盐分反演,并取得了一定的成果<sup>[24~25]</sup>,但基于无人机遥感平台,应用多种变量优选方法结合不同机器学习模型反演覆盖农田不同深度土壤含盐量的研究有待进一步深入。

综上所述,本研究利用无人机遥感技术获取研究区多光谱影像数据以及作物覆盖下 3 个土壤深度盐分数据,应用 3 种变量筛选方法优选敏感光谱指

数,结合4种机器学习建模方法,针对3个土壤深度分别构建土壤盐分定量反演模型,对比分析变量优选结合不同建模方法的反演精度,并依据最优反演模型绘制研究区土壤盐分空间分布图,以期为研究区作物覆盖下农田土壤含盐量的精细化监测与评价提供参考。

## 1 材料与方法

### 1.1 研究区概况

河套灌区位于黄河上中游内蒙古段北岸的冲积平原,引黄控制面积 $1.162 \times 10^6 \text{ hm}^2$ ,是我国设计灌溉面积最大的灌区,也是重要的商品粮、油生产基地。研究区位于内蒙古自治区巴彦淖尔市五原县境内(图1),地理坐标为东经 $107^{\circ}35'70'' \sim 108^{\circ}37'50''$ ,北纬 $40^{\circ}46'30'' \sim 41^{\circ}16'45''$ ,海拔1030 m。该地区属于温带大陆性季风气候,具有光能丰富、日照充足、干燥多风少雨(年平均降雨量170 mm)的特点。由于灌区多年灌溉方式的不合理性,该区地下水位一直居高不下,加之气候条件、地质地貌等因素的影响,研究区半数以上的耕地正面临不同程度的土壤盐渍化问题,严重制约了当地农业生产的可持续发展。

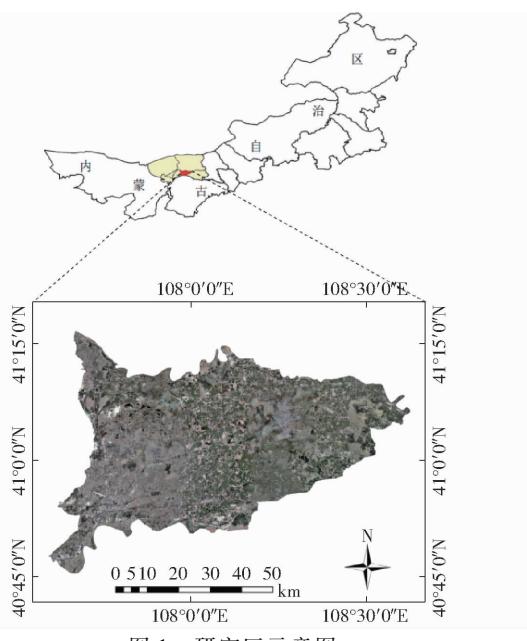


图1 研究区示意图

Fig. 1 Schematic of study area

### 1.2 试验数据采集与预处理

#### 1.2.1 地面数据采集与分析

本次试验于2021年7月18—21日在五原县境内进行。通过对境内耕地及作物生长情况进行实地考察后,选取4块具有代表性的区域作为采样区,每块采样区的面积为 $15 \text{ hm}^2$ 左右,样区内主要土壤类型为粉壤土、砂壤土和壤土,主要种植玉米、向日葵

和西葫芦3种作物。

地面实测土壤含盐量数据的样本采集时间集中于每天的11:00—13:00,每块试验地均匀布置采样点30个,每个采样点采集0~20 cm、20~40 cm和40~60 cm共3个深度的土壤样品,同时记录各采样点的地理位置坐标信息。将野外采集的土样经自然风干、研磨和过筛处理后,配置土壤溶液(土壤与蒸馏水的质量比为1:5),经搅拌、静置、沉淀、过滤后,采用电导率仪(DDS-307A型,上海仪电科学仪器股份有限公司)测定土壤溶液中的上清液电导率( $EC_{1:5}$ ),每个采样点测定3次,记录数据后取平均值作为该样点处的电导率,并通过前人研究成果中的经验公式<sup>[8,26]</sup>  $SSC = 0.288 2EC_{1:5} + 0.018 3$ 换算出土壤含盐量(Soil salinity content,  $SSC$ )。

#### 1.2.2 无人机遥感图像数据采集与处理

数据采集应用自主研发的无人机多光谱遥感影像采集系统(图2),其参数设置参照文献[27],平台机架为大疆S900型,起飞质量为6 kg,最大续航时间为30 min。该系统搭载RedEdge-M型多光谱相机(MicaSense,美国),其具有5个光谱采集通道:475 nm(蓝光,blue)、560 nm(绿光,green)、668 nm(红光,red)、717 nm(红边,rededge)、840 nm(近红外,nir)。在无人机起飞前需对地面固定反射率校正板(Group VIII)进行拍摄,以便在图像拼接时导入正确的反射率修正系数,进而获取样区的多光谱图像。



图2 无人机多光谱影像采集系统

Fig. 2 UAV multispectral images acquisition system

无人机多光谱影像采集时间与地面土壤采样时间同步,试验时天空晴朗、无风无云且光照充足。无人机飞行高度为100 m,多光谱相机镜头垂直向下,航向和旁向重叠度均为85%,为获得精确的正射影像,起飞前在每个样区均匀布置4个地面控制点(Ground control point, GCP),并使用便携式RTK测

量仪(华测 CHCNAV)精确测量各控制点的三维坐标。飞行结束后的无人机影像由软件 Pix4Dmapper 进行拼接,其主要拼接过程为:首先导入无人机采集图像和地面控制点的三维坐标数据,在原始图像中找到 GCP 坐标的对应位置以配准相机位置进行几何校正,然后生成稀疏点云进行辐射校正,最后得到空间分辨率为 7 cm 的完整样区正射影像,如图 3 所示(编号:地块 A、地块 B、地块 C 和地块 D)。

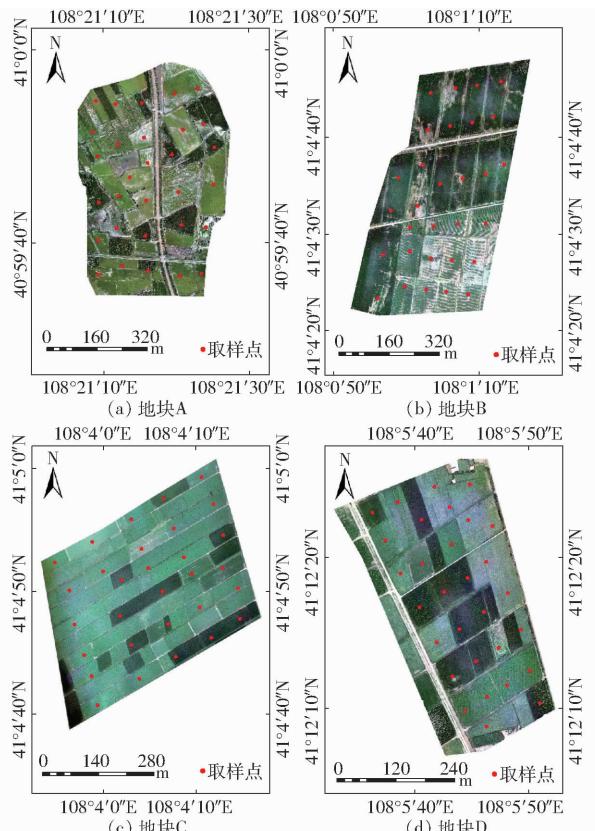


图 3 研究区取样点分布图

Fig. 3 Distribution maps of sampling points

### 1.3 光谱指数构建与筛选

#### 1.3.1 光谱指数构建

将正射影像和地面样点的坐标信息导入软件 ENVI 5.3 中,确定各样点的位置,并得到对应的 5 波段光谱反射率,通过不同数学组合可构建出光谱指数,依据前人成果<sup>[28~29]</sup>中提供的 7 种光谱指数公式(Spectral indices formula, SIF)计算共得到 180 种光谱指数,其计算公式为

$$SIF_1(R_a, R_b) = R_a / R_b \quad (1)$$

$$SIF_2(R_a, R_b) = R_a - R_b \quad (2)$$

$$SIF_3(R_a, R_b) = (R_a - R_b) / (R_a + R_b) \quad (3)$$

$$SIF_4(R_a, R_b, R_c) = R_a / (R_b R_c) \quad (4)$$

$$SIF_5(R_a, R_b, R_c) = R_a / (R_b + R_c) \quad (5)$$

$$SIF_6(R_a, R_b, R_c) = (R_a - R_b) / (R_b + R_c) \quad (6)$$

$$SIF_7(R_a, R_b, R_c) = (R_a - R_b)(R_b - R_c) \quad (7)$$

式中  $SIF_n$  —— 第  $n$  种光谱指数,  $n$  取 1~7

$R_a, R_b, R_c$ ——无人机遥感图像 5 波段中随机 3 个波段的光谱反射率

#### 1.3.2 光谱指数筛选方法

在统计学中,皮尔逊相关系数法(Pearson correlation coefficient, PCC)是指通过计算相关系数来度量两个变量  $X$  和  $Y$  之间的相关性,其值介于 -1~1 之间,相关系数的绝对值越接近于 1 代表两者相关性越大。此方法在变量筛选中应用较为广泛,并且能够有效减少冗杂变量。PCC 法通过数据处理软件 IBM SPSS Statistics 26 完成。

XGBoost 算法模型是由 FRIEDMAN<sup>[30]</sup> 依据梯度增强方法开发改进的,在求解损失函数极值时,采用牛顿法,将损失函数 Taylor 展开到二阶,并在损失函数中加入一个正则化项。训练时目标函数由两部分组成,一部分是梯度提升算法的损失函数,另一部分是正则化项。目标函数定义为

$$Obj = \sum_{i=1}^n l(y'_i, y_i) + \sum_{k=1}^K \Omega(f_k) \quad (8)$$

式中  $y'_i$  —— 样本  $i$  预测结果

$y_i$  —— 样本  $i$  真实值

$l(y'_i, y_i)$  —— 损失函数

$\Omega(f_k)$  —— 树的复杂度

由于该模型是通过许多加法函数进行预测的,因此预测得分是每棵树预测结果之和,即  $y'_i = \sum_{k=1}^K f_k(x_i)$ , 其中  $\sum_{k=1}^K f_k(x_i)$  为第  $i$  个样本的树,  $f_k$  代表第  $k$  棵树的函数;将全部  $K$  棵树的复杂度求和后作为正则化项加入到目标函数中,以避免模型过拟合。XGBoost 算法通过软件 R 语言 4.1.3 中“xgboost”包实现,各参数采用默认值。

GRA 是一种多因素统计分析方法<sup>[31]</sup>,其基本原理为:在系统发展过程中,如果两个因素的变化趋势一致,即同步变化程度高,则两个因素之间的关联度就高;否则,关联度较低。近年来 GRA 在土壤盐分的光谱分析以及敏感变量的筛选上得到广泛应用<sup>[12]</sup>。GRA 法通过数据处理软件 DPS 7.05 完成。

### 1.4 模型构建与精度评价

本研究以特征优选后的光谱变量为自变量,不同深度的土壤含盐量(SSC)为因变量,通过软件 R 语言 4.1.3 分别构建决策树(Decision tree, DT)、BP 神经网络(Back propagation neural network, BPNN)、支持向量机(Support vector machine, SVM)和随机森林(Random forest, RF)4 种回归模型,对比分析 4 种模型对土壤含盐量(SSC)的估算效果。DT 由“rpart”包实现,模型主要参数 method 为 anova, cp

为 0.005。BPNN 由“nnet”包实现,其具有高度自适应的能力,是一种常见的预测模型,模型主要参数 decay 为 0.001, size 为 4。SVM 由“e1071”包实现,其具有稳定性强、计算简洁高效等特点,近些年在盐分反演研究上应用广泛,模型主要参数 gamma 为 0.15, cost 为 1。RF 由“randomForest”包实现,是一种包含多棵决策树,输出类别由个别树输出的类别众数而决定的分类回归模型,模型主要参数 ntree 为 1 000,mtry 为 1。上述各模型的最优参数均是通过调用 R 语言中的“tune”函数,利用网格搜索与 10 折交叉验证法确定,其他模型参数均采用默认值,以尽可能减少人为因素的影响。

为保证训练集和验证集能够表示样本的统计数据特征,本文通过 R 语言“caret”包中的“createDataPartition”函数对 120 个地面实测数据进行划分,选取 2/3 的样本(80 个)作为训练集,1/3 的样本(40 个)作为验证集。

模型精度由 40 个验证集样本的实际值与预测值的拟合效果来验证,通过决定系数(Coefficient of determination,  $R^2$ )、均方根误差(Root mean square error, RMSE) 和四分位数间距性能比( Ratio of performance to inter-quartile distance, RPIQ)3 个指标对模型的验证精度进行评估。 $R^2$  和 RPIQ 越大, RMSE 越小,则说明模型效果越好。

## 2 结果与分析

### 2.1 研究区土壤含盐量实测数据统计结果

对研究区土壤样本的含盐量进行数学统计分析,结果如表 1 所示。研究区内土壤含盐量最大值范围为 0.503% ~ 0.632%, 中位数范围为 0.106% ~ 0.128%, 依据土壤盐渍化程度分级标准和前人研究成果<sup>[8]</sup>, 本研究区域多处于轻度盐渍化区域内, 局部存在重度盐渍化情况, 这与研究区内农作物的生长状况基本相符。

表 1 土壤含盐量实测数据统计分析

Tab. 1 Statistical analysis of measured soil salinity content

土壤深度/cm	样本数	最大值/%	最小值/%	平均值/%	标准差/%	中位数/%	变异系数
0 ~ 20	120	0.555	0.073	0.163	0.097	0.128	0.598
20 ~ 40	120	0.503	0.070	0.149	0.097	0.107	0.652
40 ~ 60	120	0.632	0.070	0.151	0.102	0.106	0.679

### 2.2 光谱指数筛选

首先,方案 1 是将土壤含盐量分别与 7 种指数计算公式下的光谱指数进行皮尔逊相关性分析(PCC),计算相关系数并依据最大相关性挑选敏感光谱指数作为模型输入变量,各深度处的模型输入变量如表 2 所示。

表 2 PCC 法筛选的不同土壤深度光谱变量

Tab. 2 Spectral variables of different depths screened by PCC method

土壤深度/cm	光谱指数
0 ~ 20	$SIF_1(R_{rededge}, R_{green})$ $SIF_2(R_{nir}, R_{rededge})$ $SIF_3(R_{rededge}, R_{nir})$ $SIF_4(R_{rededge}, R_{nir}, R_{green})$ $SIF_5(R_{rededge}, R_{blue}, R_{green})$ $SIF_6(R_{green}, R_{rededge}, R_{red})$ $SIF_7(R_{blue}, R_{nir}, R_{rededge})$
20 ~ 40	$SIF_1(R_{rededge}, R_{nir})$ $SIF_2(R_{nir}, R_{rededge})$ $SIF_3(R_{nir}, R_{rededge})$ $SIF_4(R_{rededge}, R_{nir}, R_{red})$ $SIF_5(R_{rededge}, R_{nir}, R_{red})$ $SIF_6(R_{rededge}, R_{nir}, R_{red})$ $SIF_7(R_{green}, R_{rededge}, R_{red})$
40 ~ 60	$SIF_1(R_{rededge}, R_{red})$ $SIF_2(R_{nir}, R_{rededge})$ $SIF_3(R_{nir}, R_{rededge})$ $SIF_4(R_{rededge}, R_{nir}, R_{red})$ $SIF_5(R_{rededge}, R_{nir}, R_{red})$ $SIF_6(R_{rededge}, R_{nir}, R_{red})$ $SIF_7(R_{nir}, R_{rededge}, R_{red})$

注:  $R_{blue}$ 、 $R_{green}$ 、 $R_{red}$ 、 $R_{rededge}$ 、 $R_{nir}$  分别为 475、560、668、717、840 nm 波长处的光谱反射率,下同。

其次,方案 2 则是通过使用 XGBoost 算法来计算所有 180 个光谱特征变量的重要性,依据特征重要性排序,针对不同土壤深度各筛选出 10 种光谱指数,如表 3 所示。 $0 \sim 20\text{ cm}$ 、 $20 \sim 40\text{ cm}$  和  $40 \sim 60\text{ cm}$  土壤深度处筛选得到的对应光谱指数分别编号为 A1 ~ A10、B1 ~ B10 和 C1 ~ C10。

最后,方案 3 则是将方案 2 中筛选出的 10 种光谱指数分别与对应深度的土壤含盐量(SSC)逐一进行灰色关联分析,进一步优选出敏感变量,计算出灰色关联度(Grey correlation degree, GCD)如图 4 所示,依据前人研究成果<sup>[9,31]</sup>,本文 GCD 阈值设置为 0.6, 各深度对应的优选变量见表 4。

### 2.3 基于特征优选的土壤含盐量反演模型

本研究依据 3 种建模方案建立了 DT、BPNN、SVM 和 RF 共 4 种土壤盐分反演模型。其中方案 1 是基于皮尔逊相关系数法(PCC), 将 7 种指数形式下对应相关性最高的光谱指数作为模型输入变量进行土壤含盐量的反演; 方案 2 则是直接使用经 XGBoost 算法筛选的 10 种光谱指数作为模型输入变量进行土壤含盐量的反演; 而方案 3 则是采用 XGBoost - GRA 法优选后的光谱指数作为模型输入

表3 XGBoost法筛选的不同土壤深度光谱变量

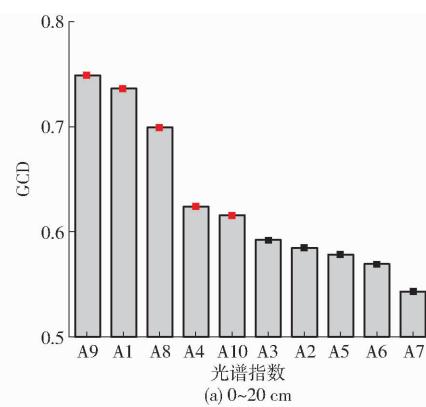
Tab. 3 Spectral variables of different depths screened by XGBoost

土壤深度/cm	光谱指数
0~20(A1~A10)	$SIF_5(R_{red}, R_{nir}, R_{rededge})$
	$SIF_6(R_{nir}, R_{red}, R_{rededge})$
	$SIF_5(R_{nir}, R_{blue}, R_{red})$
	$SIF_5(R_{nir}, R_{red}, R_{rededge})$
	$SIF_6(R_{red}, R_{nir}, R_{rededge})$
	$SIF_3(R_{nir}, R_{red})$
	$SIF_7(R_{green}, R_{red}, R_{rededge})$
	$SIF_5(R_{blue}, R_{green}, R_{nir})$
	$SIF_1(R_{red}, R_{nir})$
	$SIF_4(R_{green}, R_{red}, R_{rededge})$
20~40(B1~B10)	$SIF_4(R_{green}, R_{red}, R_{rededge})$
	$SIF_5(R_{red}, R_{nir}, R_{rededge})$
	$SIF_1(R_{red}, R_{nir})$
	$SIF_2(R_{nir}, R_{red})$
	$SIF_1(R_{blue}, R_{red})$
	$SIF_7(R_{green}, R_{red}, R_{rededge})$
	$SIF_6(R_{green}, R_{nir}, R_{red})$
	$SIF_7(R_{nir}, R_{blue}, R_{red})$
	$SIF_2(R_{nir}, R_{blue})$
	$SIF_3(R_{rededge}, R_{red})$
40~60(C1~C10)	$SIF_4(R_{green}, R_{blue}, R_{red})$
	$SIF_4(R_{nir}, R_{red}, R_{green})$
	$SIF_1(R_{red}, R_{rededge})$
	$SIF_2(R_{blue}, R_{nir})$
	$SIF_3(R_{red}, R_{nir})$
	$SIF_6(R_{green}, R_{red}, R_{rededge})$
	$SIF_4(R_{red}, R_{blue}, R_{nir})$
	$SIF_4(R_{green}, R_{red}, R_{rededge})$
	$SIF_4(R_{red}, R_{nir}, R_{green})$
	$SIF_6(R_{green}, R_{nir}, R_{red})$

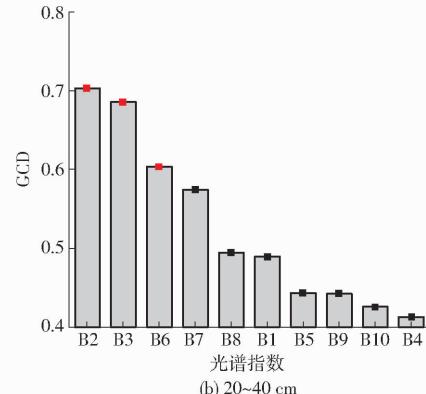
变量进行土壤含盐量的反演。以独立的验证集数据来检验各模型的反演精度(表5)。

通过表5可以得出,方案1中从建模方法上看,随机森林模型在3个土壤深度的反演精度均优于其他3种模型。从不同深度反演效果上看,0~20 cm的反演效果表现较好,20~40 cm次之,40~60 cm较差。土壤深度0~20 cm的RF模型反演效果最好(验证集 $R^2=0.794$ ,RMSE为0.049%,RPIQ为2.041),土壤深度40~60 cm的BPNN模型反演效果最差(验证集 $R^2=0.337$ ,RMSE为0.068%,RPIQ为1.0294)。

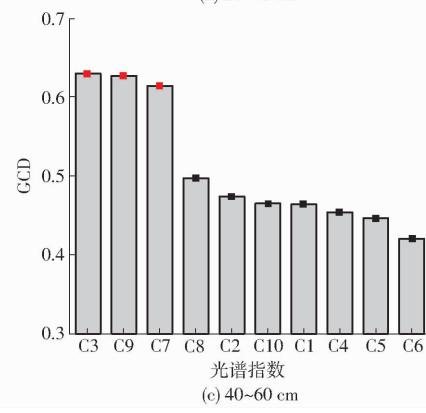
方案2中从建模方法上看,0~20 cm和20~40 cm,RF模型的反演精度最高,40~60 cm BPNN模型的反演精度最高。从不同深度反演效果上看,0~20 cm土壤深度的RF模型反演效果最好(验证集 $R^2=0.740$ ,RMSE为0.051%,RPIQ为1.961),



(a) 0~20 cm



(b) 20~40 cm



(c) 40~60 cm

图4 光谱变量与SSC的灰色关联度

Fig. 4 Gray correlation degree between spectral variables and SSC

表4 XGBoost-GRA法优选的光谱变量

土壤深度/cm	光谱指数
0~20	$SIF_1(R_{red}, R_{nir})$
	$SIF_5(R_{red}, R_{nir}, R_{rededge})$
	$SIF_5(R_{blue}, R_{green}, R_{nir})$
	$SIF_5(R_{nir}, R_{red}, R_{rededge})$
	$SIF_4(R_{green}, R_{red}, R_{rededge})$
20~40	$SIF_5(R_{red}, R_{nir}, R_{rededge})$
	$SIF_1(R_{red}, R_{nir})$
40~60	$SIF_7(R_{green}, R_{red}, R_{rededge})$
	$SIF_1(R_{red}, R_{rededge})$
	$SIF_4(R_{red}, R_{nir}, R_{green})$
20~40 cm and 40~60 cm	$SIF_4(R_{red}, R_{blue}, R_{nir})$

20~40 cm和40~60 cm两个土壤深度处的各模型

表 5 不同建模方案的土壤含盐量反演效果分析评价

Tab. 5 Analysis and evaluation of soil salinity inversion effect of different modeling schemes

土壤深度/cm	模型	方案 1 (PCC)			方案 2 (XGBoost)			方案 3 (XGBoost - GRA)		
		R <sup>2</sup>	RMSE/%	RPIQ	R <sup>2</sup>	RMSE/%	RPIQ	R <sup>2</sup>	RMSE/%	RPIQ
0 ~ 20	DT	0.489	0.072	1.389	0.290	0.078	1.282	0.575	0.061	1.639
	BPNN	0.486	0.072	1.389	0.350	0.073	1.370	0.523	0.066	1.515
	SVM	0.490	0.074	1.351	0.512	0.069	1.449	0.616	0.063	1.587
	RF	0.794	0.049	2.041	0.740	0.051	1.961	0.820	0.044	2.273
20 ~ 40	DT	0.572	0.059	1.492	0.512	0.077	1.143	0.566	0.073	1.205
	BPNN	0.517	0.063	1.397	0.459	0.088	1.000	0.493	0.078	1.128
	SVM	0.619	0.060	1.467	0.504	0.081	1.086	0.464	0.084	1.048
	RF	0.688	0.051	1.725	0.565	0.062	1.419	0.702	0.050	1.760
40 ~ 60	DT	0.440	0.062	1.419	0.545	0.096	0.917	0.536	0.097	0.907
	BPNN	0.337	0.068	1.294	0.662	0.091	0.967	0.541	0.094	0.936
	SVM	0.358	0.068	1.294	0.385	0.117	0.752	0.437	0.113	0.779
	RF	0.595	0.054	1.630	0.508	0.060	1.467	0.640	0.051	1.725

反演效果相差不大,  $R^2$  大多分布在 0.5 ~ 0.6 之间。

方案 3 相比于前两种方案, 模型反演效果大部分得到提升, 相比于其他模型, RF 模型在 3 个土壤深度的反演效果均为最好, 其中精度最高的为 0 ~ 20 cm(验证集  $R^2 = 0.820$ , RMSE 为 0.044%, RPIQ 为 2.273)。不同土壤深度反演模型中精度最差的为 40 ~ 60 cm 的 SVM 模型, 其  $R^2 = 0.437$ , RMSE 为 0.113%, RPIQ 为 0.779, 但相较于方案 1 与方案 2 其  $R^2$  分别提升 0.079 和 0.052。

## 2.4 模型综合评价与分析

就总体数据而言, 基于特征优选构建不同深度不同机器学习方法的土壤含盐量反演模型虽然精度相差不大, 但建模方案 3 的模型精度多数高于方案 1、2。同时, 基于 XGBoost - GRA 法构建的含盐量反演模型的稳定性整体上也优于 PCC 和 XGBoost 两种方法构建的模型。由此可以看出, 特征变量优选去除冗杂光谱数据对于提高含盐量反演模型的精度与效果具有重要作用。本文绘制了各模型的评价指标  $R^2$  的点线图, 以进一步直观分析各模型之间的区别。如图 5(图中 20-DT 表示 0 ~ 20 cm 土壤深度的 DT 模型, 其他以此类推)所示, 3 个深度依据 4 种回归模型方法建立的 12 个含盐量反演模型的稳定性大部分表现良好, 决定系数  $R^2$  处在合理范围内。对比 3 种方案的 4 种机器学习回归模型, 方案 3 整体表现较好,  $R^2$  介于 0.437 ~ 0.820 之间, 其中表层土壤(0 ~ 20 cm)RF 模型表现最好, 最适合本文构建土壤含盐量反演模型。

## 2.5 土壤盐分空间分布

为更好地反映模型的反演效果, 本文基于最优反演模型(RF 模型)绘制了研究区最佳反演深度(0 ~ 20 cm)的土壤盐分空间分布图, 从图 6 可见, 忽

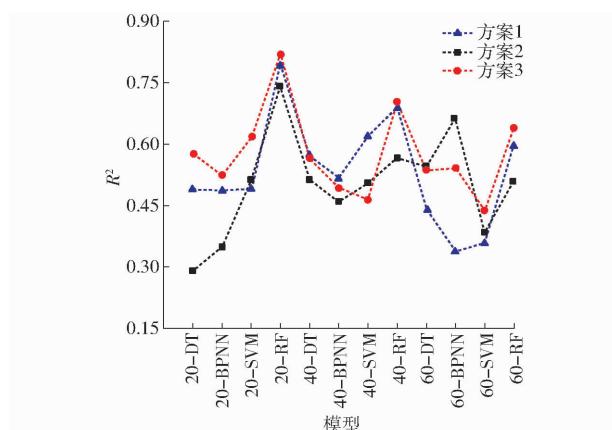


图 5 模型预测性能

Fig. 5 Predictive performance of models

略田间道路的影响, 4 块样区的土壤盐渍化状况多数处于轻度盐渍化, 局部存在重度盐渍化。地块 A 存在部分重度盐渍化地区, 影响了作物的正常生长, 地块 B 东南部集中存在一些盐渍化程度较重的地区, 该地区主要种植了耐盐作物向日葵, 这与实际勘察情况相一致。

## 3 讨论

本文基于无人机多光谱遥感技术反演了植被覆盖期不同深度的土壤盐分含量, 作物在可见光-近红外光谱波段中, 反射率主要受到作物色素、细胞结构和根域水盐含量等因素的影响, 特别是在可见光红光波段有较强的吸收波段, 在近红外波段有较强的反射特性, 这是植被所特有的光谱特性, 可以被用来进行作物长势、水分胁迫、盐分胁迫等方面监测<sup>[32-33]</sup>。作物吸收土壤中营养主要是由其根系完成的, 根系所在土层的土壤盐分会显著影响作物的营养吸收, 进而使其生长受到胁迫, 并且根区土壤含盐量越高, 土壤盐分胁迫越严重, 作物长势越差, 且

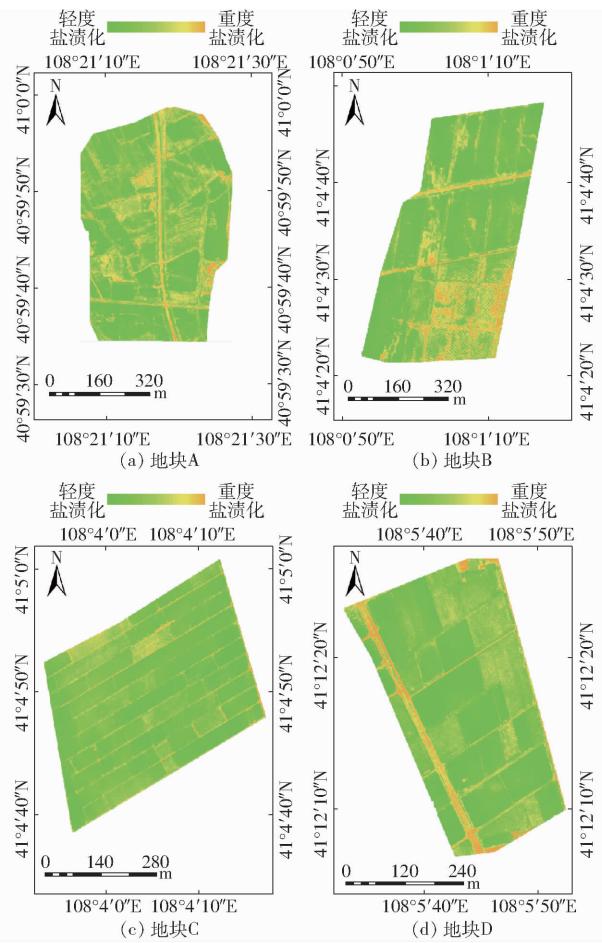


图 6 0~20 cm 土壤盐分空间分布图

Fig. 6 Map of soil salt spatial distribution in 0~20 cm

能够在冠层的光谱信息得到间接表现。本文利用无人机遥感平台获取研究区4块地高分辨率的多光谱正射图像,利用提取的波段反射率计算光谱指数,相比于前人仅依据几种特定光谱波段或植被指数进行盐分反演<sup>[34~35]</sup>,本文结合前人研究成果更为全面地整理计算了表征植被冠层光谱特性的光谱指数,依此构建的含盐量反演模型的精度也有所提升。在本研究中可以发现,土壤深度0~20 cm的反演效果是3个土壤深度中最优的,这与文献[5]的结果基本类似,土壤深度0~20 cm内包含着作物的主要根系层,而土壤盐分对作物生长的影响与其根系部分紧密相关。同时,在本研究中,20~40 cm和40~60 cm两个土壤深度处的各模型反演精度相差不大,而文献[12]在对大田葵花覆盖下的农田进行土壤盐分反演时发现土壤深度0~20 cm和20~40 cm处的模型反演效果整体优于深度40~60 cm处,这可能是因为在应用光学遥感监测土壤盐分信息时,光谱信息的获取主要是基于土壤表层的,随着深度增加,光谱特征对于底层土壤的代表性逐渐降低。

本研究通过引入皮尔逊相关系数法(PCC)、极端梯度提升算法(XGBoost)和灰色关联分析法

(GRA)对光谱变量进行特征筛选,研究发现变量优选以去除冗杂光谱数据可有效提高含盐量反演模型的精度与稳定性。文献[24]在构建覆膜耕地含盐量估算模型时,同样发现基于优选光谱指数的反演模型精度高。此外,文献[36]在含盐量反演模型的构建上采用了多元逐步回归(MLR)以及反向传播神经网络(BPNN)和支持向量机(SVM)两种机器学习算法,结果表明,含盐量反演的机器学习模型精度高于MLR模型。机器学习方法具有良好的自主学习能力,可以有效处理土壤盐分监测中复杂的非线性函数逼近问题<sup>[37]</sup>,在本文所采用的4种机器学习模型中,随机森林(RF)模型表现最优,基于光谱变量构建的MLR、SVM、BPNN、RF共4种回归模型中,RF模型仍表现最优。因此,本研究表明通过特征变量优选结合机器学习算法对不同土壤深度进行含盐量估算可行的。

同时,本研究尚有不足之处,利用光学遥感对土壤含盐量进行监测,作物的冠层光谱特性不是土壤盐分的唯一表征方式,土壤水分、土壤类型和质地等都是影响反演精度的关键因素<sup>[38]</sup>。文献[39]研究表明土壤中的水分和盐分均能对光谱产生影响,且影响方式不同,其中水盐交互模型能明显地改善土壤光谱的模拟效果。因此,在后期的研究中,考虑将更多的环境协变量加入到盐分反演模型中。此外,光学遥感监测土壤含盐量可能存在信息缺失、特征不明显等问题,且不同覆盖度、不同作物种类均会对反演效果产生影响<sup>[40]</sup>,文献[41]基于多源遥感协同的方式监测了作物覆盖下的土壤盐分信息,分析了盐渍土的分布特点及对植被生长的影响。所以区分作物种类、多源遥感信息协同是今后研究的重点。同时,由于研究区的气候条件、地下水埋深以及数据采样方式和无人机飞行参数等方面存在的差异性,本研究的试验方法和结果是否同样适用于其他地区的土壤含盐量反演有待进一步验证。

## 4 结论

(1) 无人机多光谱遥感反演土壤含盐量时作物冠层的不同光谱特征变量所包含的信息存在一定的重复,应用PCC与XGBoost方法进行特征筛选可以去除相关冗杂光谱信息,以提升建模效率。

(2) 对比基于3种建模方案构建的含盐量反演模型预测效果,可以看出经方案3(XGBoost-GRA)变量优选后,模型的预测精度和稳定性在整体上有不同程度的提高和改善。土壤深度0~20 cm处的预测效果是3个土壤深度中最优的,其中精度最高模型的 $R^2$ 、RMSE和RPIQ分别为0.820、0.044%和

2.273。反演模型中精度最差的为土壤深度40~60 cm的SVM模型,其R<sup>2</sup>、RMSE和RPIQ分别为0.437、0.113%和0.779。

(3)比较分析4种机器学习算法在3种建模方案中的表现,可以看出RF模型整体表现最优,同时

另外3种反演模型也取得了较好的预测效果,这表明本文所选用的4种回归模型在无人机遥感反演农田土壤含盐量的研究中均具有一定的适用性,且基于最佳反演模型(RF)绘制的0~20 cm土壤盐分空间分布图可以较真实地反映研究区内土壤盐渍化程度。

## 参 考 文 献

- [1] 边玲玲,王卷乐,郭兵,等. 基于特征空间的黄河三角洲垦利县土壤盐分遥感提取[J]. 遥感技术与应用, 2020, 35(1): 211~218.  
BIAN Lingling, WANG Juanle, GUO Bing, et al. Remote sensing extraction of soil salinity in Yellow River Delta Kenli County based on feature space[J]. Remote Sensing Technology and Application, 2020, 35(1): 211~218. (in Chinese)
- [2] HASSANI A, AZAPAGIC A, SHOKRI N. Global predictions of primary soil salinization under changing climate in the 21st century[J]. Nature Communications, 2021, 12(1): 6663~6680.
- [3] WANG Zheng, ZHANG Xianlong, ZHANG Fei, 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.
- [4] 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)
- [5] 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 Ning, CUI Wenxuan, ZHANG Zhitao, et al. Soil salinity inversion at different depths using improved spectral index with UAV multispectral remote sensing[J]. Transactions of the CSAE, 2020, 36(22): 13~21. (in Chinese)
- [6] ENNAJI W, BARAKAT A, KARAOUI I, et al. Remote sensing approach to assess salt-affected soils in the north-east part of Tadla plain, Morocco[J]. Geology, Ecology, and Landscapes, 2018, 2(1): 22~28.
- [7] RAMOS T B, CASTANHEIRA N, OLIVEIRA A R, et al. Soil salinity assessment using vegetation indices derived from Sentinel-2 multispectral data. Application to Lezíria Grande, Portugal[J]. Agricultural Water Management, 2020, 241: 106387.
- [8] 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)
- [9] WEI Guangfei, LI Yu, ZHANG Zhitao, et al. Estimation of soil salt content by combining UAV-borne multispectral sensor and machine learning algorithms[J]. PeerJ, 2020, 8: e9087.
- [10] 徐红涛,陈春波,郑宏伟,等. 基于相关分析和自适应遗传算法的盐渍化建模变量和参数优选[J]. 地球信息科学学报, 2020, 22(7): 1497~1509.  
XU Hongtao, CHEN Chunbo, ZHENG Hongwei, et al. Correlation analysis and adaptive genetic algorithm based feature subset and model parameter optimization in salinization monitoring[J]. Journal of Geo-information Science, 2020, 22(7): 1497~1509. (in Chinese)
- [11] PENG Jie, BISWAS A, JIANG Qingsong, et al. Estimating soil salinity from remote sensing and terrain data in southern Xinjiang Province, China[J]. Geoderma, 2019, 337: 1309~1319.
- [12] 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)
- [13] WANG Jingzhe, DING Jianli, YU Danlin, et al. Capability of Sentinel-2 MSI data for monitoring and mapping of soil salinity in dry and wet seasons in the Ebinur Lake region, Xinjiang, China[J]. Geoderma, 2019, 353: 172~187.
- [14] JOHARESTANI M Z, CAO C, NI X, et al. PM2.5 prediction based on random forest, XGBoost, and deep learning using multisource remote sensing data[J]. Atmosphere, 2019, 10(7): 373~392.
- [15] 田美玲,葛翔宇,丁建丽,等. 耦合机器学习和机载高光谱数据的土壤含水量估算[J]. 激光与光电子学进展, 2020, 57(9): 232~241.  
TIAN Meiling, GE Xiangyu, DING Jianli, et al. Coupled machine learning and unmanned aerial vehicle based hyperspectral data for soil moisture content estimation[J]. Laser & Optoelectronics Progress, 2020, 57(9): 232~241. (in Chinese)
- [16] XU Hongtao, CHEN Chunbo, ZHENG Hongwei, et al. AGA-SVR-based selection of feature subsets and optimization of parameter in regional soil salinization monitoring[J]. International Journal of Remote Sensing, 2020, 41(12): 4470~4495.
- [17] 曹肖奕,丁建丽,葛翔宇,等. 基于光谱指数与机器学习算法的土壤电导率估算研究[J]. 土壤学报, 2020, 57(4): 867~877.  
CAO Xiaoyi, DING Jianli, GE Xiangyu, et al. Estimation of soil electrical conductivity based on spectral index and machine learning algorithm[J]. Acta Pedologica Sinica, 2020, 57(4): 867~877. (in Chinese)
- [18] 韩文霆,张立元,牛亚晓,等. 无人机遥感技术在精量灌溉中应用的研究进展[J]. 农业机械学报, 2020, 51(2): 1~14.  
HAN Wenting, ZHANG Liyuan, NIU Yaxiao, et al. Review on UAV remote sensing application in precision irrigation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(2): 1~14. (in Chinese)
- [19] SHAO Guomin, HAN Wenting, ZHANG Huihui, et al. Mapping maize crop coefficient Kc using random forest algorithm based on leaf area index and UAV-based multispectral vegetation indices[J]. Agricultural Water Management, 2021, 252: 106906.

- [20] 张宏鸣,陈丽君,刘雯,等.基于Stacking集成学习的夏玉米覆盖度估测模型研究[J].农业机械学报,2021,52(7):195–202.  
ZHANG Hongming, CHEN Lijun, LIU Wen, et al. Estimation of summer corn fractional vegetation coverage based on Stacking ensemble learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(7):195–202. (in Chinese)
- [21] TANG Jiandong, HAN Wenting, ZHANG Liyuan. UAV multispectral imagery combined with the FAO-56 dual approach for maize evapotranspiration mapping in the North China Plain[J]. Remote Sensing, 2019, 11(21): 2519.
- [22] LI Guang, HAN Wenting, HUANG Shenjin, et al. Extraction of sunflower lodging information based on UAV multi-spectral remote sensing and deep learning[J]. Remote Sensing, 2021, 13(14): 2721.
- [23] PENG Xingshuo, HAN Wenting, AO Jianyi, et al. Assimilation of LAI derived from UAV multispectral data into the SAFY model to estimate maize yield[J]. Remote Sensing, 2021, 13(6): 1094.
- [24] 张智韬,台翔,杨宁,等.不同植被覆盖度下无人机多光谱遥感土壤含盐量反演[J].农业机械学报,2022,53(8): 220–230.  
ZHANG Zhitao, TAI Xiang, YANG Ning, et al. UAV multispectral remote sensing soil salinity inversion based on different fractional vegetation coverages[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(8): 220–230. (in Chinese)
- [25] WANG Danyang, CHEN Hongyan, WANG Zhuoran, et al. Inversion of soil salinity according to different salinization grades using multi-source remote sensing[J]. Geocarto International, 2020, 37: 1–20.
- [26] 王伦平,陈亚新.内蒙古河套灌区灌溉排水与盐碱化防治[M].北京:水利电力出版社,1993.
- [27] ZHANG Liyuan, ZHANG Huihui, NIU Yaxiao, et al. Mapping maize water stress based on UAV multispectral remote sensing [J]. Remote Sensing, 2019, 11(6): 605.
- [28] 杜瑞麒,陈俊英,张智韬,等. Sentinel-2 多光谱卫星遥感反演植被覆盖下的土壤盐分变化[J].农业工程学报,2021,37(17): 107–115.  
DU Ruiqi, CHEN Junying, ZHANG Zhitao, et al. Inversing soil salinity under vegetation cover using Sentinel-2 multispectral satellite remote sensing[J]. Transactions of the CSAE, 2021, 37(17): 107–115. (in Chinese)
- [29] 张磊,宫兆宁,王启为,等. Sentinel-2 影像多特征优选的黄河三角洲湿地信息提取[J].遥感学报,2019,23(2): 313–326.  
ZHANG Lei, GONG Zhaoning, WANG Qiwei, et al. Wetland mapping of Yellow River Delta wetlands based on multi-feature optimization of Sentinel-2 images[J]. Journal of Remote Sensing, 2019, 23(2): 313–326. (in Chinese)
- [30] FRIEDMAN J. Greedy function approximation: a gradient boosting machine[J]. Annals of Statistics, 2001, 29(5): 1189–1232.
- [31] WANG Xiaoping, ZHANG Fei, KUNG H T, et al. New methods for improving the remote sensing estimation of soil organic matter content (SOMC) in the Ebinur Lake Wetland National Nature Reserve (ELWNNR) in Northwest China[J]. Remote Sensing of Environment, 2018, 218: 104–118.
- [32] 韩文霆,汤建栋,张立元,等. 基于无人机遥感的玉米水分利用效率与生物量监测[J]. 农业机械学报, 2021, 52(5): 129–141.  
HAN Wenting, TANG Jiandong, ZHANG Liyuan, et al. Maize water use efficiency and biomass estimation based on unmanned aerial vehicle remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(5): 129–141. (in Chinese)
- [33] ZHANG Liyuan, HAN Wenting, NIU Yaxiao, et al. Evaluating the sensitivity of water stressed maize chlorophyll and structure based on UAV derived vegetation indices[J]. Computers and Electronics in Agriculture, 2021, 185: 106174.
- [34] 张智韬,魏广飞,姚志华,等. 基于无人机多光谱遥感的土壤含盐量反演模型研究[J]. 农业机械学报, 2019, 50(12): 151–160.  
ZHANG Zhitao, WEI Guangfei, YAO Zhihua, et al. Research on soil salt inversion model based on UAV multispectral remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(12): 151–160. (in Chinese)
- [35] 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: 1–8.
- [36] 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): 107–112.  
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): 107–112. (in Chinese)
- [37] WANG Fei, YANG Shengtian, YANG Wei, et al. Comparison of machine learning algorithms for soil salinity predictions in three dryland oases located in Xinjiang Uyghur Autonomous Region (XJUAR) of China[J]. European Journal of Remote Sensing, 2019, 52(1): 256–276.
- [38] 王小芳,李毅,姚宁,等.生物炭改良棉花-甜菜间作土壤理化性质与盐分效果分析[J].农业机械学报,2022,53(4):352–362.  
WANG Xiaofang, LI Yi, YAO Ning, et al. Effects of biochar on soil physical and chemical properties and salt in cotton sugarbeet intercropping field[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(4): 352–362. (in Chinese)
- [39] 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)
- [40] HU Jie, PENG Jie, ZHOU Yin, et al. Quantitative estimation of soil salinity using UAV-borne hyperspectral and satellite multispectral images[J]. Remote Sensing, 2019, 11(7): 736.
- [41] IVUSHKIN K, BARTHOLOMEUS H, BREGT A K, et al. UAV based soil salinity assessment of cropland[J]. Geoderma, 2019, 338: 502–512.