doi:10.6041/j.issn.1000-1298.2022.08.023

# 不同植被覆盖度下无人机多光谱遥感土壤含盐量反演

张智韬<sup>1,2</sup> 台 翔<sup>1,2</sup> 杨 宁<sup>1,2</sup> 张珺锐<sup>1,2</sup> 黄小鱼<sup>1,2</sup> 陈钦达<sup>1,2</sup>

(1. 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;

2. 西北农林科技大学水利与建筑工程学院,陕西杨凌 712100)

摘要:准确快速获取植被覆盖条件下农田土壤盐分信息,为土壤盐渍化治理提供依据。利用无人机遥感平台,获取 2019 年7、8、9 月内蒙古河套灌区沙壕渠灌域试验地的多光谱遥感图像以及取样点 0~10 cm、10~20 cm、20~40 cm、40~60 cm 深度处土壤含盐量,通过多光谱遥感图像计算得到光谱指数,选择归一化植被指数(NDVI-2)代入像元二分模型计算植被覆盖度,并划分为 T1(裸土)、T2(低植被覆盖度)、T3(中植被覆盖度)、T4(高植被覆盖 度)4 个覆盖度等级;同时,对光谱指数进行全子集变量筛选,并利用偏最小二乘回归算法和极限学习机算法,构建 不同覆盖度下各深度土壤含盐量反演模型。研究结果表明,裸土和高植被覆盖度下的反演模型精度高于低植被覆 盖度和中植被覆盖度下的反演模型精度;对比 PLSR 和 ELM 2 种 SSC 反演模型精度,ELM 模型的反演精度比 PLSR 模型高;覆盖度 T1、T2、T3 和 T4 的最佳反演深度分别为 0~10 cm、10~20 cm、20~40 cm、20~40 cm。研究结果为 无人机多光谱遥感监测农田土壤盐渍化提供了思路。

关键词:土壤含盐量;无人机多光谱;反演;植被覆盖度;像元二分模型;全子集筛选 中图分类号:S127;TP79 文献标识码:A 文章编号:1000-1298(2022)08-0220-11 0



## UAV Multispectral Remote Sensing Soil Salinity Inversion Based on Different Fractional Vegetation Coverages

ZHANG Zhitao<sup>1,2</sup> TAI Xiang<sup>1,2</sup> YANG Ning<sup>1,2</sup> ZHANG Junrui<sup>1,2</sup> HUANG Xiaoyu<sup>1,2</sup> CHEN Qinda<sup>1,2</sup> (1. The Key Laboratory of Agricultural Soil and Water Engineering in Arid Areas, Ministry of Education,

Northwest A&F University, Yangling, Shaanxi 712100, China

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

Abstract: Accurate and rapid acquisition of soil salinity information under vegetation coverage can provide a basis for soil salinization management. The UAV remote sensing platform was used to obtain multispectral remote sensing images of the Shahao Canal Irrigation Area in the Hetao Irrigation District of Inner Mongolia in July, August and September 2019 and the sampling points were 0 ~ 10 cm, 10 ~ 20 cm, 20 ~ 40 cm and 40 ~ 60 cm depths of soil salt content (SSC). The spectral index was calculated through multi-spectral remote sensing images, and the normalized vegetation index (NDVI -2) was selected and brought into the pixel binary model (PDM) to calculate the vegetation coverage (FVC). The coverage was divided into four coverage levels: T1 (bare soil), T2 (low vegetation coverage), T3 (medium vegetation coverage), and T4 (high value coverage). The spectral index was screened by a full subset of variables, and partial least squares regression (PLSR) and extreme learning machine (ELM) were used to construct inversion models of soil salinity at various depths under different coverages. The research results showed that the accuracy of the inversion model under bare soil and high vegetation coverage was higher than the accuracy of the inversion model under low vegetation and medium vegetation coverage; comparing the accuracy of the two SSC inversion models, PLSR and ELM, the inversion accuracy of the ELM model was higher than that of the PLSR model; the best inversion depths under the coverage of T1, T2, T3 and T4 were  $0 \sim 10$  cm,  $10 \sim 20$  cm,  $20 \sim 40$  cm,  $20 \sim 40$  cm, respectively. The research result can provide an idea for UAV multi-spectral remote sensing to monitor soil salinization.

Key words: soil salinity; UAV multispectrum; inversion; fractional vegetation coverage; pixel binary model; full subset selection

收稿日期: 2021-07-18 修回日期: 2021-09-14

基金项目:国家重点研发计划项目(2017YFC0403302)和国家自然科学基金项目(51979232)

作者简介:张智韬(1976—),男,副教授,博士,主要从事遥感技术在节水灌溉中的应用研究,E-mail: zhitaozhang@126.com

#### 0 引言

土壤盐渍化是常见于干旱、半干旱地区的生态 环境问题,其严重制约农业可持续健康发展<sup>[1-2]</sup>。 内蒙古河套灌区是中国最大的灌区,也是中国盐渍 化问题最突出的地区之一。及时、精确、动态地获取 土壤盐渍化信息,是盐渍化防治的前提<sup>[3]</sup>。遥感技 术可获得大范围、高精度的地面遥感影像,因此被广 泛应用于盐渍化监测研究<sup>[4-6]</sup>。

无人机遥感是遥感的重要分支,有不少学者将 其应用到土壤盐渍化监测。陈俊英等<sup>[7]</sup>采集向日 葵各生育期光谱图像构建光谱指数,并建立土壤含 盐量(Soil salt content,SSC)回归模型,达到了反演 向日葵根域 SSC 的目的;王新涛<sup>[8]</sup>将无人机多光谱 数据与卫星数据进行融合,提高了卫星反演 SSC 的 精度。杨宁等<sup>[9]</sup>基于改进光谱指数,建立 SSC 反演 模型,预测不同深度的土壤含盐量,结果显示,改进 光谱指数组建模结果优于原始光谱指数组。

在基于光谱变量构建 SSC 反演模型时,为降低 模型的复杂程度,需要对光谱变量进行筛选。传统 变量筛选方法[10-12]为局部最优筛选,而全子集筛选 法通过列举全部可能组合,建立全局最优模型,以包 含最少自由变量的模型解释因变量,最大限度消除 共线性的影响[13]。土壤盐渍化反演主要采用线性 回归和机器学习方法,梁静等<sup>[14]</sup>利用偏最小二乘回 归(Partial least squares regression, PLSR)模型对区域 尺度的土壤电导率进行了有效的定量估算: JFARIFTEH 等<sup>[15]</sup>基于土壤反射率数据建立了土壤 盐分的 PLSR 和人工神经网络 (Artificial neural network, ANN)反演模型,发现 PLSR 模型反演精度 优于 ANN 模型。极限学习机 (Extreme learning machine, ELM) 是一种高效的机器学习方法, 冯禹 等<sup>[16]</sup>发现 ELM 模型能很好地反映气象因子与参考 作物蒸散量间复杂的非线性关系。

植被覆盖度(Fractional vegetation coverage, FVC)对光谱反演有着重要影响。在裸土情况下,光 谱可直接反演土壤表层含盐量<sup>[17-19]</sup>,在植被覆盖情 况下,通过采集作物冠层光谱信息可间接反演土壤 含盐量<sup>[20]</sup>。AMALALLBED等<sup>[21]</sup>发现在低植被覆 盖和密集植被覆盖下光谱指数对土壤含盐量的响应 不同;HU等<sup>[22]</sup>反演不同植被覆盖度下的SSC,发现 SSC与植被覆盖度并非负相关关系。这说明,植被 覆盖度是影响土壤含盐量反演的重要因素。 ZHANG等<sup>[23]</sup>通过像元二分模型划分植被覆盖度, 并建立不同覆盖度下的盐分反演模型,发现稀疏植 被地的模型反演精度较低,而裸地和高植被覆盖下 的模型精度较高。像元二分模型是一种成熟的植被 覆盖度划分方法,但将其应用到无人机多光谱遥感 监测盐渍化方面的研究较少。

因此,本文通过高分辨率的无人机多光谱相机 获取内蒙古河套灌区沙壕渠灌域试验地的影像数据,利用像元二分模型计算 FVC 并划分4 个覆盖 度;利用全子集筛选法对建立的光谱变量进行最 优变量组合筛选,以最优变量组合为自变量,以采 样点土壤含盐量数据为因变量,建立4 个覆盖度 下不同深度土壤含盐量的 PLSR 和 ELM 模型,对 模型精度进行评价分析,以期提高土壤含盐量反 演模型的精度,并获得每个覆盖度下的最佳反演 模型和最佳反演深度,为诊断土壤盐渍化程度提 供依据。

### 1 材料与方法

#### 1.1 研究区概况

研究区域位于巴彦淖尔市沙壕渠灌域(40°52′~ 41°00′N,107°05′~107°10′E),隶属于河套灌区解 放闸灌域,如图1所示。沙壕渠灌域南北跨度约 15 km,东西跨度约4 km,其面积约为52.4 km²,为 典型的温带大陆性气候,年平均气温7℃,降水稀少 (年平均降雨量140 mm),蒸发强度大(年蒸发量 2000 mm)。研究区主要土壤类型为粉壤土、砂壤土 和壤土。由于不合理的灌排方式,气候、土质和地貌 等因素的综合影响,造成灌区严重的次生盐渍化问 题。研究区南部盐渍化程度较轻,北部盐渍化程度 加重,种植作物以向日葵、玉米和小麦等耐盐粮油作 物为主。



#### 1.2 试验地布设

试验地的布设充分考虑研究区土壤盐分特征和 土地利用方式等因素,在沙壕渠灌域选取4块具有 盐分梯度的试验地进行采样,编号分别为1、2、3、4, 每块试验地面积为16 hm<sup>2</sup>左右。试验地分布如图2 所示,土壤含盐量从小到大依次为1、2、3、4。4块试 验地主要种植作物为向日葵和玉米,且4号地含有 部分荒地,荒地与耕地占比分别为25%和75%。每 块试验地均匀布设30个土壤采样点。

#### 1.3 光谱图像采集和处理

无人机多光谱图像采集试验选择的无人机遥感 平台是深圳市大疆创新科技有限公司生产的经纬 M600型无人机,单次飞行最大续航时间为40min。 无人机搭载美国 Tetracam 公司生产的6通道 Micro-MCA 多光谱相机(490 nm 蓝光波段、550 nm 绿光波 段、680 nm 红光波段、720 nm 红边波段、800 nm 近红 外1波段、900 nm 近红外2波段),设备如图3所 示。试验在2019年7月、8月和9月各进行一次, 试验时间分别为7月16—20日、8月10—14日和9 月8—12日。每次试验均在无风的11:00—14:00 进行,确保充分的辐射强度。根据提前规划好的航 线,设置无人机飞行高度120 m,对应多光谱相机分 辨率为6.5 cm,相机拍摄速率为18~19幅/min,每 次试验均设有白板进行图像标定。









将拍摄的多光谱图像导入 Pixel Wrench2 软件, 进行提取、配准和合成,将获得的 TIF 图像和 GPS 数据导入 Pix4D 软件进行图像拼接,合成 4 块试验 地的多光谱 TIF 图像。将拼接的 TIF 图像导入 ENVI Classic 软件中,对图像进行校正,再将采样点 的坐标导入软件,获取每个采样点像元的灰度。用 样本点的 6 个波段灰度除以白板的灰度,得到每个 样本点 6 个波段的反射率。

#### 1.4 土样采集与处理

为了保持光谱数据和土壤含盐量数据的一 致性,采集光谱数据的同时,进行地面土样采集。 通过手持式 GPS 仪确定取样点位置,采集样本点 0~10 cm、10~20 cm、20~40 cm 和 40~60 cm 深度的土壤样本,装入干净的铝盒,并用密封袋 封装。

将带回实验室的土壤样本放置干燥箱 8 h 后, 去除土样中的石子和秸秆杂质,进行研磨处理,将研 磨后的土壤和蒸馏水按质量比 1:5混合,经过搅拌、 静置沉淀和过滤,提取上清液,用电导率仪(雷磁 DDS - 307A 型,上海佑科仪器分公司生产)测定土 壤溶液电导率(Electrical conductance,EC),根据经 验公式计算得到样本点各深度土壤含盐量数据,经 验公式见文献[24]。

#### 1.5 光谱指数计算

光谱指数综合考虑地物的各波段光谱特征,对 不同波段反射率进行数学变换组合,以增强地物特 定的信息<sup>[25]</sup>,其包括植被指数和盐分指数。研究涉 及的植被指数有归一化植被指数(NDVI)<sup>[26]</sup>、差异 化植被指数(DVI)<sup>[27]</sup>、比值植被指数(RVI)<sup>[28]</sup>、改 进型土壤调节植被指数(MSAVI)<sup>[29]</sup>、增强型植被指数(EVI)<sup>[30]</sup>、土壤调节植被指数(SAVI)<sup>[31]</sup>、冠层盐度响应植被指数(CRSI)<sup>[32]</sup>、大气阻抗植被指数(ARVI)<sup>[33]</sup>;盐分指数有归一化盐分指数(NDSI)<sup>[34]</sup>、盐分指数(SI - T)<sup>[35]</sup>、盐分指数(SI)<sup>[36]</sup>、盐分指数1(SI1)<sup>[37]</sup>、盐分指数2(SI2)、盐分指数3(SI3)、盐分指数S1、盐分指数S2<sup>[38]</sup>、盐分指数S1、盐分指数S2<sup>[38]</sup>、盐分指数S1、盐分指数S2<sup>[38]</sup>、盐分指数S1、型合式中包含近红外波段的指数,将Band5和Band6近红外波段的指数,将Band5和Band6近红外波段力加NDVI-1

#### 1.6 植被覆盖度计算

FVC 通常定义为植被(包括叶、茎、枝)在地面的垂直投影面积占统计区总面积的百分比<sup>[39]</sup>,是影响土壤盐分反演的重要因素。像元二分模型(Pixel dichotomy mode,PDM)是一种简单实用的遥感估算模型,用于计算植被覆盖度。NDVI 可用于检测植被生长状况和植被覆盖度<sup>[40]</sup>。本文通过基于 NDVI 的像元二分模型计算植被覆盖度。首先,假设遥感 图像的像元均由植被和裸土部分组成。根据像元二分模型,1 个像元的 NDVI 值可以表达为由绿色植被部分所贡献的信息 NDVIveg 与由无植被覆盖(裸土)部分所贡献的信息 NDVIsoil 这两部分组成,FVC 计算公式参照文献[41]。

根据《中国荒漠化治理国家报告》及相似地理特征和植被类型区域的分类方法<sup>[23,42]</sup>,并结合本研究的具体情况进行植被覆盖度划分。将数据划分为T1、T2、T3、T4,分别为:裸土(FVC 为[0,0.15))、低植被覆盖度(FVC 为[0.15,0.45))、中植被覆盖度(FVC 为[0.45,0.75))、高植被覆盖度(FVC 为[0.75,1))。

#### 1.7 全子集筛选法

全子集筛选法是利用全子集回归分析,对不同 自变量之间所有可能的组合方式,用最小二乘法对 所有变量组合进行拟合与建模分析,最终选择一个 最佳的监测模型。记*m*为自变量个数,对*m*中的*p* 个变量(*p*=1,2,…,*m*)与因变量做最小二乘拟合, 在所有的拟合模型中,选择最优的模型,为全子集筛 选结果。选择最优模型的评价标准为:①似然函数 最大化。②模型未知参数最小化,即寻求模型拟合 精度和模型复杂度之间的最佳平衡<sup>[43]</sup>。本文通过 R语言编程进行全子集筛选,利用决定系数*R*<sup>2</sup>和贝 叶斯信息准则(Bayesian information criterion, BIC)来 评价筛选结果,对比分析*R*<sup>2</sup>越大, BIC 越小的筛选 结果,为最优变量组合。

#### 1.8 模型方法和评价指标

通过 R 语言编程构建 PLSR 和 ELM 土壤含盐 量反演模型,其中实测土壤含盐量为因变量,光谱变 量为自变量。在每个覆盖度各深度下随机选取 2/3 实测土壤含盐量样本数据和对应的光谱变量作为建 模集用于训练模型,剩余 1/3 实测土壤含盐量样本 数据和对应的光谱变量作为验证集用于验证,通过 调整模型参数,获得每个条件下最佳模型。建模流 程如图 4 所示。



PLSR 方法是一种多变量回归分析方法,可以同 时实现回归建模、简化数据结构和分析两组变量间 的相关性,给多元数据统计分析带来极大便利。对 于 t 个因变量  $y_1, y_2, \dots, y_t$  与 m 个自变量  $x_1, x_2, \dots,$  $x_{m}$ 的建模问题, PLSR 的基本做法是首先在自变量集 中提出第1成分 и1;同时在因变量集中也提取第1 成分 v1,并要求 u1 与 v1 相关程度达到最大。然后, 建立因变量  $y_1, y_2, \dots, y_i$ 与  $u_1$ 的回归式, 如果回归方 程已达到满意的精度,则算法终止。否则,继续第2 对成分的提取,直至能达到满意的精度为止。若最 终对自变量集提取 r 个成分 u1, u2, …, ur, 偏最小二 乘回归将通过建立  $y_1, y_2, \dots, y_r$ 与  $u_1, u_2, \dots, u_r$ 的回 归式,再将 y1, y2, …, y,表示为原自变量的回归方程 式,即偏最小二乘法回归方程式<sup>[44]</sup>。基于 PLSR 方 法的土壤含盐量多光谱反演的主要思想是,在减少 光谱变量的同时,能够从光谱数据中揭示最大土壤 含盐量变化的主控因子,使建立的模型具有更好的 鲁棒性<sup>[45-46]</sup>。本文 PLSR 模型采用 R 语言 pls 包构 建,通过决定系数  $R^2$ 和均方根误差 RMSE 指标评价 筛洗每个深度下最佳模型。

ELM 是一种单隐层前向传播的人工神经网络 模型训练算法,只有隐层神经元结点数需要学习调 整,并且整个过程无需迭代,具有"极端"快速的特点,学习时间显著优于反向神经网络算法和 PLSR 算法。同时,具有良好的泛化能力,已成功用于一些复杂系统的建模、辨识和控制等问题<sup>[47-48]</sup>。本文 ELM 模型亦采用 R 语言 elmNNRcpp 包构建,通过 *R*<sup>2</sup>和 RMSE 指标评价筛选每个深度下最佳模型。

#### 2 试验与结果分析

#### 2.1 土壤含盐量统计分析

将7月、8月和9月3次试验总计360个样本点

进行覆盖度分级,获得不同覆盖度 T1 ~ T4 的数据 集。对各覆盖度的土壤含盐量进行统计,对各数据 集样本按 2:1的比例划分建模集和验证集,并将各 数据集样本点土壤含盐量划分为4 个等级,分别为: 非盐土(0~0.2%)、轻度盐渍化(0.2%~0.5%)、 重度盐渍化(0.5%~1.0%)和盐土(大于 1.0%)<sup>[49]</sup>,结果如表1 所示。

从表1中可以看出,4个等级的盐土在不同数 据集中含盐量存在显著差异。T1、T2、T3、T4的4个 深度SSC平均值分别为0.86%、0.33%、0.31%和

	表1 土壤含盐量特征统计分析	
Tab. 1	Statistical analysis of soil salt content characteristics	s

				样本数(占比	女(占比/%)		土壤含盐量			
覆盖度	数据集	召开	非盐土	轻度盐渍化	重度盐渍化	盐渍土	最小值/	最大值/	均值/	亦巳亥勑
		心口	$(0 \sim 0.2\%)$	$(0.2\% \sim 0.5\%)$	$(0.5\% \sim 1.0\%)$	(>1.0%)	%	%	%	文开示奴
	总集	78	19(24.4)	31(39.7)	23(29.5)	5(6.4)	0.07	2.45	0.86	0. 99
T1(0~0.15)	建模集	52	12(23.1)	21(40.4)	16(30.8)	3(5.8)	0.07	2.34	0.85	0. 99
	验证集	26	7(26.9)	10(38.5)	7(26.9)	2(7.7)	0.08	2.45	0.87	0. 92
	总集	72	34(47.2)	26(36.1)	10(13.9)	2(2.8)	0.08	1.18	0.33	0. 79
T2(0.15~0.45)	建模集	48	22(45.8)	18(37.5)	7(14.6)	1(2.1)	0.08	1.04	0.32	0. 79
	验证集	24	12(50.0)	8(33.3)	3(12.5)	1(4.2)	0.08	1.18	0.34	0.72
	总集	109	84(77.1)	22(20.2)	3(2.8)	0(0)	0.07	0. 99	0.31	0.77
T3(0.45~0.75)	建模集	73	56(76.7)	18(24.7)	2(2.7)	0(0)	0.07	0.97	0.31	0.78
	验证集	36	28(77.8)	7(19.4)	1(2.8)	0(0)	0.08	0. 99	0.31	0.77
T4(0.75~1)	总集	101	98(97.0)	3(3.0)	0(0)	0(0)	0.06	0.31	0. 27	0. 59
	建模集	68	66(97.1)	2(2.9)	0(0)	0(0)	0.06	0.31	0.27	0.61
	验证集	33	32(97.0)	1(3.0)	0(0)	0(0)	0.08	0.26	0.26	0.56

0.27%,随着覆盖度的增加,土壤含盐量呈递减趋势。其中裸地 T1 土壤含盐量最高,高植被覆盖度 T4 的土壤含盐量最低。各数据集差异系数均处于 中等差异(变异系数反映样本点值的离散程度,变 异系数小于 0.1 为弱变异性;变异系数在 0~1之 间为中等变异;变异系数大于 1 为强变异)<sup>[50]</sup>。其 中,T1 数据集的变异系数最大,接近 1。T1 数据集 的样本点多属于 4 号地,4 号地含有耕地和荒地 2 种土地,耕地灌水在一定程度上会影响到附近荒 地土壤盐分的分布,土壤含盐量在空间上存在显 著差异,使 4 号地荒地土壤含盐量的变异系数相 对偏大。

2.2 光谱自变量与不同土壤深度 SSC 相关性分析

提取无人机多光谱图像的 6 个波段反射率和 31 个光谱指数(16 个植被指数和 15 个盐分指数), 构成覆盖度 T1、T2、T3、T4 下的各深度(1、2、3、4 分 别代表 0 ~ 10 cm、10 ~ 20 cm、20 ~ 40 cm、40 ~ 60 cm 深度,下同)自变量数据集。计算各数据集建模集 自变量与 SSC 的相关系数,绘制热图(图 5 ~ 7)分析 自变量与 SSC 之间的相关性。





分别对覆盖度 T1、T2、T3、T4 多光谱 6 波段反 射率与土壤含盐量进行相关性分析,如图 5 所示,热 图颜色越深,代表相关性越高。总体上,可见光波段 (B1、B2、B3)与 SSC 表现出较好的相关性;红边波 段(B4)对植被覆盖具有敏感响应,随着植被覆盖度





index and SSC

的增加,其与 SSC 的相关性不断增大;近红波段 (B5、B6)在覆盖度 T1 下与 SSC 表现出较高相关性, 在覆盖度 T2、T3 和 T4 下,随着覆盖度的增加,相关 性由小变大。对比各覆盖度下相关性,覆盖度 T1、 T4 波段反射率和 SSC 相关性高于 T2、T3。

分别对覆盖度 T1、T2、T3、T4 植被指数与土壤 含盐量进行相关性分析,如图6所示。整体上,有植 被覆盖的 T2、T3、T4 相比裸土 T1 植被指数和 SSC 相关性更高。T2、T3、T4 中高植被覆盖度 T4 下植被 指数和 SSC 相关性最高。

分别对覆盖度 T1、T2、T3、T4 盐分指数与土壤 含盐量进行相关性分析,如图7所示。整体上,覆盖 度 T1 和 T4 盐分指数与 SSC 相关性最高,其中覆盖 度 T1 盐分指数与 SSC 相关性最显著。

对比图 6 和图 7 中覆盖度 T1.盐分指数与 SSC 的相关性显著高于植被指数:相应的高植被覆盖 度 T4 植被指数与 SSC 的相关性显著高于盐分指 数。

#### 2.3 全子集法筛选最优自变量组合

基于全子集回归算法,分别对4个覆盖度4个 深度的 37 个自变量进行筛选。基于 R 语言全子集 回归模型算法运行结果,综合考虑模型的评估参数  $R^2$ 和 BIC,筛选出每个条件下最优自变量组合,结果 如表2所示。从T1到T4,盐分指数在自变量中所 占比例分别为 71%、42%、23%、13%,其百分比逐 渐变小:植被指数在自变量中所占比例分别为5%、 21%、50%、63%,其百分比逐渐增大。说明随着植 被覆盖度的增加,盐分指数的敏感性逐渐降低,植被 指数的敏感度逐渐增加。

表 2 全	子集法筛选最优变量组合统计
-------	---------------

Tab. 2	Optimal	variable	combination	statistics	screened	by	full	subset	method
--------	---------	----------	-------------	------------	----------	----	------	--------	--------

覆盖度	深度/cm	自变量个数	最优变量组合	$R^2$	BIC
裸土(T1)	0~10	6	B1 *** , B5 ** , S5 * , SI *** , SI2 – 1 *** , SI2 – 2 ***	0. 75	- 54
	$10\sim\!20$	6	B1 ** , DVI2 , SI ** , SI2 – 1 ** , SI3 ** , SI **	0.69	- 38
	$20\sim\!40$	4	B3 *** , S1 ** , SI2 – 1 *** , SI1 ***	0. 55	- 28
	$40\sim\!60$	5	B3 ** , S1 ** , SI2 – 2 ** , SI3 ** , S3 ***	0.48	- 13
	0~10	6	B6, DVI1 * , S3 * , S1 , SI , SI 3 *	0. 57	-41
任持社(T2)	$10\sim\!20$	5	B5, S3 * , SI, SI3 ** , CRSI2 *	0. 59	- 49
低值做(12)	$20\sim\!40$	3	DVI1 * ,SI,SI3 *	0.54	- 28
	$40\sim\!60$	4	B6 , DVI1 * , SAVI2 , SI3 **	0.50	- 26
	0~10	6	B4 ** , DVI2 ** , MSAVI1 , SAVI2 * , SI3 ** , S5	0. 55	- 19
由持速(T2)	$10\sim\!20$	5	B4 ** , B6 , DVI2 ** , MSAVI1 ** , MSAVI2 *	0.65	- 20
甲值极(15)	$20\sim\!40$	5	B3 ** , DVI2 ** , MSAVI1 , SAVI2 ** , CRSI2 *	0.69	- 29
	$40\sim\!60$	6	B3 ** , B6 , DVI2 * , SAVI2 * , S5 , SI – T – 2	0.48	-11
	0~10	6	B1 *** ,RVI1 ** ,EVI1 *** ,ARVI1 ,DVI2 *** ,NDSI1 **	0. 69	- 49
高植被(T4)	$10 \sim 20$	5	B6 *** , RVI1 , MSAVI2 *** , ARVI1 * , DVI2 ***	0. 62	-46
	$20\sim\!40$	5	RVI1 *** ,EVI1 *** ,ARVI1 ,SI3 ,NDSI1 *	0.75	- 68
	$40\sim\!60$	5	MSAVI2 *** , RVI1 *** , S5 , SI3 *** , NDSI1 *	0.66	- 23

注: \* 表示显著性检验 p < 0.05, \*\* 表示 p < 0.01, \*\*\* 表示 p < 0.001, 下同。

#### 2.4 土壤含盐量反演模型构建

2.4.1 基于偏最小二乘算法

以各覆盖度下不同深度全子集法筛选的反射率

和光谱指数为自变量、SSC为因变量,建立 PLSR 土 壤含盐量反演模型,各模型建模集和验证集的 R<sup>2</sup>和 RMSE 如表 3 所示。

果

Tab. 3	PLSR model o	of soil salt	salinity with	different	coverage	levels and	depths
Labie	I LOI MOULI O	i son sur	Summey with	uniterent	coverage	ievens unu	acpuns

深度/		同归古理	建模集		验证集	
返皿反	四归万桯 cm		$R_c^2$	RMSEc/%	$R_v^2$	RMSEv/%
	$0 \sim 10$	$Y = 0.43X_1 - 3.89X_2 + 0.28X_3 - 3.31X_4 - 1.95X_5 + 6.88X_6 + 0.049$	0.651	0.172	0.663	0. 197
裸土	$10\sim\!20$	$Y = 0.9X_1 - 0.24X_2 + 4.5X_3 - 0.2X_4 - 3.65X_5 + 3.31X_6 - 0.027$	0.634	0.245	0.648	0.212
(T1)	$20\sim\!40$	$Y = 0.\ 13X_1 - 0.\ 23X_2 - 0.\ 34X_3 + 0.\ 83X_4 + 0.\ 06$	0.475	0. 225	0.455	0.219
	$40\sim\!60$	$Y = 1.\ 19X_1 - 0.\ 94X_2 - 0.\ 78X_3 + 2.\ 1X_4 - 0.\ 48X_5 + 0.\ 01$	0.447	0.214	0.434	0. 222
	$0 \sim 10$	$Y = 1.14X_1 - 4.26X_2 + 0.69X_3 - 0.23X_4 + 7.06X_5 - 6.29X_6 + 0.096$	0.532	0.265	0. 521	0.211
低植被	$10\sim\!20$	$Y = 0.17X_1 + 0.52X_2 + 2.96X_3 - 0.17X_4 - 1.66X_5 + 0.052$	0.558	0.205	0.530	0.179
(T2)	$20\sim\!40$	$Y = 0.49X_1 + 4.46X_2 - 2.88X_3 + 0.092$	0.476	0.248	0.461	0.202
	$40\sim\!60$	$Y = 0.74X_1 + 0.44X_2 + 0.66X_3 - 0.61X_4 + 0.09$	0.372	0.240	0.432	0.265
	$0 \sim 10$	$Y = 1.04X_1 - 0.05X_2 - 0.81X_3 - 0.58X_4 - 0.72X_5 - 0.54X_6 - 0.17$	0.486	0.246	0.452	0. 253
中植被	$10\sim\!20$	$Y = 0.01X_1 - 0.09X_2 - 1.52X_3 + 0.06X_4 + 0.64X_5 + 1.17$	0.458	0.257	0.424	0.234
(T3)	$20\sim\!40$	$Y = 0.57X_1 - 0.58X_2 - 1.13X_3 - 0.01X_4 - 0.007X_5 + 0.46$	0.521	0. 225	0.485	0.214
	$40\sim\!60$	$Y = 0.41X_1 - 1.06X_2 - 0.27X_3 + 0.14X_4 - 0.15X_5 - 0.11X_6 - 0.48$	0.410	0. 285	0.428	0. 227
	$0 \sim 10$	$Y = -0.51X_1 - 0.004X_2 - 0.1X_3 - 0.01X_4 - 0.34X_5 - 0.13X_6 + 0.53$	0.442	0.213	0.425	0. 252
高植被	$10\sim\!20$	$Y = 0.14X_1 - 0.51X_2 - 0.07X_3 - 0.17X_4 - 0.09X_5 + 0.416$	0.587	0.197	0.541	0.203
(T4)	$20\sim\!40$	$Y = 1.67X_1 - 0.54X_2 - 4.94X_3 + 4.2X_4 - 1.13X_5 - 4.32$	0.655	0.165	0.620	0.159
	$40\sim\!60$	$Y = 6.\ 25X_1 - 1.\ 02X_2 - 3.\ 7X_3 - 3.\ 31X_4 - 0.\ 89X_5 + 1.\ 41$	0.420	0. 225	0.483	0. 252

覆盖度 T1 下,0~10 cm 模型表现最佳, $R_c^2$  和  $R_v^2$ 分别为0.651 和0.663,均为覆盖度 T1 下建模集 和验证集的最大值, RMSEc 和 RMSEv 分别为 0.172% 和0.197%,均为各深度最小值。总体上, 0~10 cm 为各深度中表现最佳的模型。深度 10~ 20 cm 模型表现次之,20~40 cm 和 40~60 cm 模型 精度急剧下降。

覆盖度 T2 下,10~20 cm 建模集  $R_e^2$  和验证集  $R_e^2$  分别为 0.558 和 0.530,均为 T2 条件下最大值, RMSEc 和 RMSEv 分 别 为 0.205% 和 0.179%, RMSEv 为验证集各深度中最小值,而 RMSEc 对比 0~10 cm和 20~40 cm 2 个深度较大。但深度 0~ 10 cm 和 20~40 cm 的两个模型验证集的 RMSEc 和 RMSEv 均大于 0.2%,模型稳定性较差。综上 10~ 20 cm 模型的稳定性更高,是 T1 条件下的最佳土壤 含盐量反演深度。

覆盖度 T3 下,整体上所有模型精度偏低,除 20~40 cm 建模集的  $R_c^2$  大于 0.5,其余深度模型  $R^2$ 均小于 0.5。深度 20~40 cm 模型 RMSEc 和 RMSEv 分别为 0.225% 和 0.214%,为各深度建模验证集中 的最小值。综合考虑,20~40 cm 是中植被覆盖度 条件下的最佳土壤含盐量反演深度。

覆盖度 T4 下,深度 20~40 cm 的模型建模和预 测效果相对最好,其  $R_e^2$  和  $R_v^2$  分别为 0.655 和 0. 620, 均为 T4 条件下建模集和验证集的最大值。 RMSEc 和 RMSEv 分别为 0. 165% 和 0. 159%, 均为 各深度最小值。深度 10~20 cm 模型精度次之,  $R_c^2$ 和  $R_v^2$  分别为 0. 587 和 0. 541, 且 RMSE 大于深度 20~ 40 cm。综上, 深度 20~40 cm 模型最佳, 10~20 cm 次之。

2.4.2 基于极限学习机算法

以各覆盖度下不同深度全子集法筛选的反射率 和光谱指数为自变量、SSC 为因变量,运用 ELM 构 建土壤含盐量反演模型,各模型建模集和验证集的 *R*<sup>2</sup>和 RMSE 如表 4 所示。

覆盖度 T1 下,深度 0~10 cm 的模型建模和预 测效果最好, $R_e^2$  和  $R_e^2$  分别达到 0.762 和 0.755,均 为 T1 建模集和验证集的最大值, RMSE 分别为 0.164%和 0.185%,均为建模集和验证集的最小 值。深度 10~20 cm 的模型精度次之, $R_e^2$  和  $R_e^2$  均为 0.714, RMSEc 和 RMSEv 分别为 0.173%和 0.197%。随着深度的增加, $R^2$ 下降, RMSE 增大,模 型的精度急剧下降。总体而言,深度 0~10 cm 是裸 土条件下的最佳土壤含盐量反演深度,深度 10~ 20 cm 次之,深度 20~40 cm 和 40~60 cm 模型精度 急剧下降。

T2覆盖度下,4个深度中,仅10~20 cm 建模 集和验证集的决定系数均大于0.5, RMSEv 等于

Tab. 4 ELM model of soil salt salinity with different coverage levels and depths

	资 座 /	莫	建模集	马	金证集
復血戊	保度/cm	$R_c^2$	RMSEc/%	$R_v^2$	RMSEv/%
	0 ~ 10	0.762	0.164	0.755	0. 185
一一一	$10 \sim 20$	0.714	0.173	0.714	0.197
裸土(T1)	$20\sim\!40$	0.532	0.225	0.582	0.213
	$40\sim\!60$	0.521	0. 223	0.538	0.164
	0 ~ 10	0.502	0.187	0.494	0.187
	$10 \sim 20$	0.583	0.184	0.566	0.174
低值彼(12)	$20\sim\!40$	0.523	0.158	0.492	0.197
	$40\sim\!60$	0.487	0.225	0.464	0.241
	0~10	0.487	0.214	0.458	0.167
	$10 \sim 20$	0.524	0.217	0.575	0.158
甲值傚(13)	$20\sim\!40$	0.527	0.167	0.557	0.154
	$40\sim\!60$	0.465	0.132	0.454	0.138
	0 ~ 10	0.564	0.178	0.578	0.168
⇒持神(四4)	$10 \sim 20$	0.674	0. 193	0.635	0.145
<b>尚</b> 怚忉(14)	$20\sim\!40$	0. 697	0.155	0.680	0.142
	$40\sim\!60$	0.554	0.235	0.557	0.214

0.174%,为验证集中的最小值,RMSEc 虽略大于 20~40 cm 深度,但综合考虑,深度 10~20 cm 是 T2 条件下的最佳土壤含盐量反演深度。对比 0~10 cm 和 20~40 cm 2 个深度,深度 20~40 cm  $R_e^2$  和  $R_v^2$  差值为 0.031,显著大于深度 0~10 cm  $R_e^2$  和  $R_v^2$  差值 0.008,0~10 cm 模型稳定性更佳。综上,覆盖度 T2 下,10~20 cm 模型最佳,0~10 cm 次之。

覆盖度 T3 下, 仅2 个深度 10~20 cm 和20~40 cm 模型决定系数大于 0.5, 对比 2 个模型, 虽然深度 10~20 cm 验证集的决定系数略大于 20~40 cm, 但 深度 20~40 cm RMSE 均小于 0.2%, 所以深度 20~ 40 cm 模型稳定性更高。综上, 覆盖度 T3 下, 深度 20~40 cm 模型表现最佳, 深度 10~20 cm 次之。

覆盖度 T4 下,4 个深度模型建模集和验证集  $R^2$  均大于 0.5, 深度 40~60 cm 建模集和验证集 RMSE 大于 0.2%, 其余深度模型建模集和验证集 RMSE 均小于 0.2%。深度 20~40 cm 模型  $R_c^2$ 和  $R_v^2$ 分别 为 0.697 和 0.680, 为各深度中最大值, RMSEc 和 RMSEv 分别为 0.155 和 0.142, 均为各深度中最小 值, 深度 20~40 cm 模型表现最佳。深度 10~20 cm 模型相比 20~40 cm 略差, 深度 0~10 cm 和 40~ 60 cm 模型表现最差, 但也具备一定的预测能力。

#### 2.5 土壤含盐量反演模型综合评价

基于全子集的筛选结果,通过 ELM 和 PLSR 两种机器学习方法,构建 T1、T2、T3、T4 覆盖度 0 ~ 10 cm、10 ~ 20 cm、20 ~ 40 cm 和 40 ~ 60 cm 深度,总

共 32 个模型。通过对表 3 和表 4 模型的对比分析, 选出 2 种机器学习方法在各覆盖度下最佳的土壤含 盐量反演深度的模型,结果如表 5 所示。

表 5 各覆盖度下最佳的土壤含盐量反演模型评价结果 Tab.5 Model of soil salinity inversion in each coverage degree

			0	0		
模型	覆盖度	深度/cm	$R_c^2$	RMSEc/%	$R_v^2$	RMSEv/%
PLSR	裸土(T1)	$0 \sim 10$	0.651	0.172	0.663	0. 197
	低植被(T2)	$10\sim\!20$	0.558	0.205	0.530	0.179
	中植被(T3)	$20\sim\!40$	0. 521	0.225	0.485	0.214
	高植被(T4)	$20\sim\!40$	0.655	0.165	0.620	0.159
ELM	裸土(T1)	$0 \sim 10$	0.762	0.164	0.755	0. 185
	低植被(T2)	$10\sim\!20$	0.583	0.184	0.566	0.174
	中植被(T3)	$20\sim\!40$	0.527	0.167	0.557	0.154
	高植被(T4)	$20\sim\!40$	0. 697	0.155	0.680	0.142

从表 5 可知, PLSR 和 ELM 2 个模型对应的各 覆盖度下的最佳土壤含盐量反演深度相同, T1 到 T4 对应的深度分别为 0 ~ 10 cm、10 ~ 20 cm、20 ~ 40 cm和 20 ~ 40 cm, 可以看出,随着覆盖度的增加, 最佳的土壤含盐量反演深度逐渐增加,从 T1 条件下 表层深度 0 ~ 10 cm 到中植被覆盖条件下的深度 20 ~ 40 cm, 之后随着覆盖度增加,最佳反演深度维 持在 20 ~ 40 cm, 且各覆盖度条件下最佳反演深度 均未出现 40 ~ 60 cm。各深度 PLSR 和 ELM 最佳反 演模型中,覆盖度 T1 和 T4 下反演模型精度均远远 大于覆盖度 T2 和 T3。覆盖度 T1、T2、T3、T4 下, ELM 模型的决定系数 *R*<sup>2</sup>均大于 PLSR 模型, 且 ELM 模型的 RMSE 均小于 0. 2%。综合来看, ELM 土壤 含盐量反演模型精度更高。

#### 3 讨论

通过无人机多光谱遥感数据进行土壤含盐量反 演,对盐渍化监测和治理起到积极的作用。本文将 试验地 7—9 月光谱数据用划分植被覆盖度的方式, 进行重新分集,探究不同植被覆盖度对反演 SSC 的 影响。

不同植被覆盖度条件下,模型最佳反演深度有 所不同。T1、T2、T3、T4 对应最佳土壤含盐量反演深 度分别为0~10 cm、10~20 cm、20~40 cm、20~ 40 cm。裸土期土壤表层无植被覆盖,无人机多光谱 遥感可以直接获取土壤表面的光谱信息,用于反演 土壤表层含盐量,所以最佳反演深度是土壤表 层<sup>[51-53]</sup>。植被覆盖期,植被吸收土壤水分主要是由 侧根系完成的,因此侧根所在土层的土壤盐分会显 著影响作物的水分吸收,进而使作物生长受到胁迫, 且土壤含盐量越高,土壤盐分胁迫越严重,植被长势

越差,并在植被冠层得到间接表现<sup>[54-57]</sup>。随着作物 的不断成熟,植被覆盖度逐渐增加,侧根分布深度逐 渐加深,最佳土壤含盐量反演深度从 10~20 cm 增 加到20~40 cm。因此,植被覆盖条件下,越高的覆 盖度对应植被成熟度越高,相应的最佳 SSC 反演深 度也越深。划分植被覆盖度,有效区分了光谱指数 对 SSC 的敏感性。植被指数和盐分指数对土壤含 盐量反演的贡献不同,盐分指数在裸土条件下与 SSC 的相关性更高,植被指数在植被覆盖条件下与 SSC 的相关性更高<sup>[23,58]</sup>。本研究通过全子集筛选 法,筛选出每个覆盖度各个深度最优的敏感光谱指 数和敏感波段组合,不同条件下筛选出的最佳波段 和光谱指数组合不同。在 T1 覆盖度下盐分指数数 量大于植被指数,盐分指数更加敏感。植被覆盖 T2、T3、T4 覆盖度下则表现为植被指数数量大于盐 分指数,植被指数更加敏感。

不同覆盖度下,反演模型的精度存在差异。本研究建立了4个覆盖度4个深度下基于全子集筛选敏感变量的PLSR和ELM2种SSC反演模型。对比发现,在各覆盖度下,ELM反演模型的*R*<sup>2</sup>大于PLSR反演模型,反演精度更高且模型稳定性更高。SSC与光谱变量存在复杂的非线性关系<sup>[22]</sup>,非线性算法ELM反演模型优于PLSR反演模型。分别对比PLSR和ELM2个模型各深度下反演模型的精度发现,覆盖度T1和T4下反演模型的精度高于T2和T3模型。T1对应裸土覆盖度,光谱中包含更多的纯裸土像元;T4对应高植被覆盖度,光谱中包含更

多的纯植被冠层像元;T2 和 T3 分别对应低植被覆 盖和中植被覆盖 2 个覆盖度,光谱像元均为混合像 元。相比于 T2 和 T3,包含更多纯净像元的覆盖度 T1 和 T4 更有利于 SSC 反演。包含土壤和冠层混合 光谱信息的反演模型精度较低,而含有纯裸地光谱 和纯植被冠层光谱的反演模型精度较高<sup>[59]</sup>。

本研究尚存在一定的不足。仅仅考虑了植被覆 盖度对土壤含盐量反演精度的影响,对于作物类型、 耕作方式、不同含水率对反演模型的影响尚未考虑。 因此,对于综合考虑更多影响因素的反演模型,还有 待进一步研究。

#### 4 结论

(1) 4 种覆盖度下 SSC 反演模型中,裸土和高 植被覆盖度下的 SSC 反演模型精度高于低植被覆 盖度和中植被覆盖度下的 SSC 反演模型。

(2)裸土覆盖时,无人机直接获取土壤表面光 谱,最佳土壤含盐量反演模型深度为土壤表层 0~ 10 cm;植被覆盖条件下,无人机获取植被冠层光谱, 最佳土壤含盐量反演模型深度为植被侧根生长的土 层深度,分别为 10~20 cm、20~40 cm、20~40 cm。

(3)通过全子集筛选法对每个覆盖度各深度模型自变量进行筛选,简化了模型。且筛选结果显示, 覆盖度越低,盐分指数对 SSC 越敏感;覆盖度越高, 植被指数对 SSC 越敏感。

(4)在各覆盖度下,ELM 反演模型的 R<sup>2</sup>大于 PLSR 反演模型,反演精度更高且模型稳定性更高。

#### 参考文献

[1] 王玉刚,肖笃宁,李彦,等. 新疆三工河流域尾闾绿洲地下水变化与土壤积盐的响应[J]. 生态学报, 2007, 27(10): 4036-4044.

WANG Yugang, XIAO Duning, LI Yan, et al. Response of salt accumulation in soil to groundwater changes at the oasis in the lower reaches of Sangong River, Xinjiang[J]. Acta Ecologica Sinica, 2007, 27(10): 4036 - 4044. (in Chinese)

- [2] 丁建丽,姚远,王飞. 干旱区土壤盐渍化特征空间建模[J]. 生态学报, 2014, 34(16): 4620-4631.
  DING Jianli, YAO Yuan, WANG Fei. Detecting soil salinization in arid regions using spectral feature space derived from remote sensing data[J]. Acta Ecologica Sinica, 2014, 34(16): 4620-4631. (in Chinese)
- [3] 刘全明,成秋明,王学,等. 河套灌区土壤盐渍化微波雷达反演[J]. 农业工程学报, 2016, 32(16): 109-114.
  - LIU Quanming, CHENG Qiuming, WANG Xue, et al. Soil salinity inversion in Hetao irrigation district using microwave radar [J]. Transactions of the CSAE,2016, 32(16): 109 114. (in Chinese)
- [4] 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 inestuary area of Yellow River[J]. Transactions of the CSAE,2015, 31(5): 107 114. (in Chinese)
- [5] 张荣群,宋乃平,王秀妮,等. 盐渍土时空变化信息的图谱可视化分析[J]. 农业工程学报, 2012, 28(9): 230-235. ZHANG Rongqun, SONG Naiping, WANG Xiuni, et al. Visual analysis of saline soil spatio-temporal variation using Geoinformation TuPu[J]. Transactions of the CSAE, 2012, 28(9): 230-235. (in Chinese)
- [6] ZHANG Tingting, QI Jiaguo, GAO Yu, et al. Detecting soil salinity with MODIS time series VI data[J]. Ecological Indicators, 2015, 52: 480-489.
- [7] 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)
- [8] 王新涛. 基于空-天遥感数据尺度转换的土壤盐渍化监测方法研究[D]. 杨凌:西北农林科技大学, 2020.
  WANG Xintao. Research on monitoring method of soilsalinization based on scale conversion of space-air remote sensing data

[D]. Yangling: Northwest A&F University, 2020. (in Chinese)

- [9] 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)
- [10] 王海峰,张智韬,KARNIELI Amon,等. 基于灰度关联--岭回归的荒漠土壤有机质含量高光谱估算[J]. 农业工程学报, 2018, 34(14): 124 - 131. WANC Haitana, ZHANC Zhitao, KARNIELI Amon, et al. Human stall estimation of decent acil emprison metter content based
  - WANG Haifeng, ZHANG Zhitao, KARNIELI Arnon, et al. Hyperspectral estimation of desert soil organic matter content based on gray correlation ridge regression model[J]. Transactions of the CSAE,2018, 34(14): 124 131. (in Chinese)
- [11] 张智韬,王海峰,KARNIELI Arono,等. 基于岭回归的土壤含水率高光谱反演研究[J]. 农业机械学报, 2018, 49(5): 240-248.

ZHANG Zhitao, WANG Haifeng, KARNIELI Arono, et al. Inversion of soil moisture content from hyperspectra based on ridge regression[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(5): 240 - 248. (in Chinese)

- [12] UPADHYAYA S, RAMSANKARAN R. Modified-INSAT multi-spectral rainfall algorithm (M IMSRA) at climate region scale: development and validation[J]. Remote Sensing of Environment, 2016, 187: 186-201.
- [13] 张智韬,韩佳,王新涛,等. 基于全子集-分位数回归的土壤含盐量反演研究[J]. 农业机械学报, 2019, 50(10): 142-152.
  ZHANG Zhitao, HAN Jia, WANG Xintao, et al. Soil salinity inversion based on best subsets quantile regression model[J].
  Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(10): 142-152. (in Chinese)
- [14] 梁静,丁建丽,王敬哲,等. 基于反射光谱与 Landsat 8 OLI 多光谱数据的艾比湖湿地土壤盐分估算[J]. 土壤学报, 2019, 56(2): 320-330.
  LIANG Jing, DING Jianli, WANG Jingzhe, et al. Quantitative estimation and mapping of soil salinity in the Ebinur Lake Wetland based on Vis-NIR reflectance and Landsat 8 OLI data[J]. Acta Pedologica Sinica, 2019, 56(2): 320-330. (in Chinese)
- [15] JFARIFTEH A, VAN DER MEER A F, CATZBERGER B, et al. Quantitative analysis of salt-affected soil reflectance spectra: a comparison of two adaptive methods (PLSR and ANN)[J]. Remote Sensing of Environment, 2007, 110(1): 59-78.
- [16] 冯禹,崔宁博,龚道枝,等. 基于极限学习机的参考作物蒸散量预测模型[J]. 农业工程学报, 2015, 31(增刊1): 153-160.
  FENG Yu, CUI Ningbo, GONG Daozhi, et al. Prediction model of reference crop evapotranspiration based on extreme learning machine[J]. Transactions of the CSAE, 2015, 31(Supp. 1): 153-160. (in Chinese)
- [17] GORIJI T, YILDIRIM A, HAMZEHPOUR N, et al. Soil salinity analysis of Urmia Lake Basin using Landsat 8 OLI and Sentinel - 2A based spectral indices and electrical conductivity measurements [J]. Ecological Indicators, 2020, 112(10): 61-73.
- [18] ABBAS A, KHAN S, HUSSAIN N, et al. Characterizing soil salinity in irrigated agriculture using a remote sensing approach [J]. Physics and Chemistry of the Earth, 2013,57:43-52.
- [19] DOUAOUI A, NICOLAS H, WALTER C. Detecting salinity hazards within a semiarid context by means of combining soil and remote-sensing data[J]. Geoderma, 2017, 134(1-2): 217-230.
- [20] 贾科利,张俊华.不同碱化程度土壤对其上覆植被冠层光谱特征的影响[J].光谱学与光谱分析, 2014, 34(3): 782-786.
  JIA Keli, ZHANG Junhua. Impacts of different alkaline soil on canopy spectral characteristics of overlying vegetation[J].
  Spectroscopy and Spectral Analysis, 2014, 34(3): 782-786. (in Chinese)
- [21] AMALALLBED A, LALITKUMAR A, YOUSEFYALDAKHEEL B. 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, s 230 - 231(7): 1-8.
- [22] HU J, PENG J, ZHOU Y, et al. Quantitative estimation of soil salinity using UAV-Borne hyperspectral and satellite multispectral images[J]. Remote Sensing, 2019, 11(7): 10-36.
- [23] ZHANG J, ZHANG Z, CHEN J, et al. Estimating soil salinity with different fractional vegetation cover using remote sensing [J]. Land Degradation and Development, 2021, 32(2): 597-612.
- [24] 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.
- [25] 汪小钦,王苗苗,王绍强,等. 基于可见光波段无人机遥感的植被信息提取[J]. 农业工程学报, 2015, 31(5): 152-159.
  WANG Xiaoqin, WANG Miaomiao, WANG Shaoqiang, et al. Extraction of vegetation information from visible unmanned aerial vehicle images[J]. Transactions of the CSAE, 2015, 31(5): 152-159. (in Chinese)
- [26] VWRRELST J, SCHAEPMAN M, KOETZ B, et al. Angular sensitivity analysis of vegetation indices derived from CHRIS/ PROBA data[J]. Remote Sensing of Environment, 2008, 112(5): 2341-2353.
- [27] JRDAN C. Derivation of leaf-area index from quality of light on the forest floor [J]. Ecology, 1969, 50(4): 663-666.
- [28] BIRTH G, MCVEY G. Measuring the color of growing turf with a reflectance spectrophotometer [J]. Agronomy Journal, 1968, 60(6): 640-643.
- [29] QI J, CHEHBOUNI A, HUETE A, et al. A modified soil adjusted vegetation index [J]. Remote Sensing of Environment, 1994, 48(2): 119-126.
- [30] HUI Q, HUETE A. A feedback based modification of the NDVI to minimize canopy background and atmospheric noise[J]. IEEE Transactions on Geoscience & Remote Sensing, 1995, 33(2): 457-465.
- [31] HENAKA ARACHCHI M P N K, FIELD D J, MCBRATNEY A B, et al. Quantification of soil carbon from bulk soil samples to predict the aggregate-carbon fractions within using near- and mid-infrared spectroscopic techniques [J]. Geoderma, 2016, 267(8):207-214.
- [32] SCUDIERO E, SKAGGS T, CORWIN D. Regional scale soil salinity evaluation using Landsat 7, western San Joaquin Valley, California, USA[J]. Geoderma Regional, 2014, 2-3: 82-90.
- [33] KAUFMAN Y, TANRE D. Atmospherically resistant vegetation index (ARVI) for EOS-MODIS[J]. IEEE Trans. Geosci Remote Sens., 1992, 30(2): 261-270.
- [34] KHAN N, SATO Y. Environmental land degradation assessment in semi-arid Indus basin area using IRS 1B LISS II data [C]//IEEE International Geoscience & Remote Sensing Symposium. IEEE, 2001.
- [35] WEERAKOON K. GIS integrated spatio-temporal urban growth modelling: Colombo urban fringe, Sri Lanka[J]. Journal of

Geographic Information System, 2017, 9: 372-389.

- [36] KHAN N, RASTOSKUEV V, SATO Y, et al. Assessment of hydrosaline land degradation by using a simple approach of remote sensing indicators[J]. Agricultural Water Management, 2005, 77(1-3): 96-109.
- [37] SCARTH P, PHINN S. Determining forest structural attributes using an inverted geometric-optical model in mixed eucalypt forests, Southeast Queensland, Australia[J]. Remote Sensing of Environment, 2000, 71(2): 141-157.
- [38] BOUAZIZ M, CHTOUROU M, TRIKI I, et al. Prediction of soil salinity using multivariate statistical techniques and remote sensing tools[J]. Advances in Remote Sensing, 2018, 7(4): 313-326.
- [39] GITELSON A, KAUFMAN Y, STARK R, et al. Novel algorithms for remote estimation of vegetation fraction [J]. Remote Sensing of Environment, 2002, 80(1): 76-87.
- [40] 任立清,董国涛,谷佳贺,等. 黑河上游植被时空分布及驱动力分析[J]. 水土保持研究, 2021, 28(4): 244-250. REN Liqing, DONG Guotao, GU Jiahe, et al. Spatiotemporal distribution and driving force analysis of vegetation in the upper reaches of Heihe River[J]. Research on Soil and Water Conservation, 2021, 28(4): 244-250. (in Chinese)
- [41] 李苗苗,吴炳方,颜长珍,等. 密云水库上游植被覆盖度的遥感估算[J]. 资源科学, 2004(4): 153-159.
  LI Miaomiao, WU Bingfang, YAN Changzhen, et al. Estimation of vegetation fraction in the upper basin of Miyun Reservoir by remote sensing[J]. Resources Science, 2004(4): 153-159. (in Chinese)
- [42] 田海静,曹春香,戴晟懋,等. 准格尔旗植被覆盖度变化的时间序列遥感监测[J]. 地球信息科学学报, 2014, 16(1): 126-133.

TIAN Haijing, CAO Chunxiang, DAI Shengmao, et al. Analysis of vegetation fractional cover in Jungar Banner based on timeseries remote sensing data[J]. Journal of Geo-Information Science,2014,16(1):126-133. (in Chinese)

- [43] 谭丞轩.基于无人机多光谱遥感的大田玉米土壤含水率估算模型研究[D].杨凌:西北农林科技大学,2020. TAN Chengxuan. Research on the estimation model of field maize soil moisture content based on UAV multispectral remote sensing[D]. Yangling:Northwest A&F University, 2020. (in Chinese)
- [44] SURIENTY L, RAMAYAH T, LO M, et al. Quality of work life and turnover intention: a partial least square (PLS) approach [J]. Social Indicators Research, 2013, 119(1): 241 – 302.
- [45] 翁永玲, 戚浩平, 方洪宾, 等. 基于 PLSR 方法的青海茶卡--共和盆地土壤盐分高光谱遥感反演[J]. 土壤学报, 2010, 47 (6): 1255 1263.

WANG Yongling, QI Haoping, FANG Hongbin, et al. PLSR-Based hyperspectral remote sensing retrieval of soil salinity of Chaka – Gonghe Basin in Qinghai Province[J]. Acta Pedologica Sinica, 2010, 47(6): 1255 – 1263. (in Chinese)

- [46] WOLD S, SJ STR M M, EERKSSON L. PLS-regression: a basic tool of chemometrics [J]. Chemometrics & Intelligent Laboratory Systems, 2001, 58(2): 109-130.
- [47] 刘学艺,李平,部传厚. 极限学习机的快速留一交叉验证算法[J]. 上海交通大学学报, 2011,62(8):49-54. LIU Xueyi, LI Ping, GAO Chuanhou. Fast leave-one-out cross-validation algorithm for extreme learning machine[J]. Journal of Shanghai Jiaotong University, 2011, 62(8):49-54. (in Chinese)
- [48] MICHE Y, SORJAMAA A, BAS P, et al. Brief papers op-ELM: optimally pruned extreme learning machine [J]. IEEE Transactions on Neural Networks, 2010, 21(1):158-162.
- [49] 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)

[50] 李传华,赵军,师银芳,等. 基于变异系数的植被 NPP 人为影响定量研究——以石羊河流域为例[J]. 生态学报, 2016, 36(13): 4034-4044.

LI Chuanhua, ZHAO Jun, SHI Yinfang, et al. The impact of human activities on net primary productivity based on the coefficient of variation: a case study of the Shiyang River Basin[J]. Acta Ecologica Sinica,2016, 36(13): 4034-4044. (in Chinese)

[51] 姚志华,陈俊英,张智韬,等. 覆膜对无人机多光谱遥感反演土壤含盐量精度的影响[J]. 农业工程学报, 2019, 35 (19): 89-97.

YAO Zhihua, CHEN Junying, ZHANG Zhitao, et al. Effect of plastic film mulching on soil salinity inversion by using UAV multispectral remote sensing[J]. Transactions of the CSAE,2019, 35(19): 89-97. (in Chinese)

- [52] FARIFTEH J, VANDERMEER F, JMCARRANZA E. Similarity measures for spectral discrimination of salt-affected soils[J]. International Journal of Remote Sensing, 2007, 28(23): 5273 – 5293.
- [53] SRIVASTAVA R, SETHI M, YADAV R, et al. Visible-near infrared reflectance spectroscopy for rapid characterization of saltaffected soil in the indo-gangetic plains of Haryana, India[J]. Journal of the Indian Society of Remote Sensing, 2016(74): 1-9.
- [54] MUNNS R. Genes and salt tolerance: bringing them together [J]. New Phytologist, 2005, 167(3): 645-663.
- [55] 刘庆生,张敏,宁吉才,等. 翅碱蓬高光谱植被指数对土壤化学性质的响应[J]. 地理与地理信息科学, 2011, 27(3): 86-89.

LIU Qingsheng, ZHANG Min, NING Jicai, et al. Hyperspectral vegetation indices of *Suaeda Salsa* in response to changes of soil chemical properties [J]. Geography and Geo-information Science, 2011, 27(3): 86-89. (in Chinese)

- [56] WANG D, POSS J, DONOVAN T, et al. Biophysical properties and biomass production of elephant grass under saline conditions[J]. Journal of Arid Environments, 2002, 52(4): 447-456.
- [57] 张飞,西甫拉提·特依拜,丁建丽,等. 渭干河-库车河三角洲绿洲土壤盐渍化现状特征及其与光谱的关系[J]. 环境科学研究, 2009, 22(2): 227 235.

ZHANG Fei, Shipolati T, DING Jianli, et al. Relationships between soil salinization and spectra in the Delta Oasis of Weigan and Kuaa Rivers [J]. Environmental Science Research, 2009, 22(2): 227 – 235. (in Chinese)

- [58] ZHANG T, ZENG S, YU G, et al. Using hyperspectral vegetation indices as a proxy to monitor soil salinity [J]. Ecological Indicators, 2011, 11(6): 1552-1562.
- [59] JIE P, BISWAS A, JIANG Q, et al. Estimating soil salinity from remote sensing and terrain data in southern Xinjiang Province, China[J]. Geoderma, 2018, 337: 1309 - 1319.