

基于无人机遥感图像纹理与植被指数的土壤含盐量反演

向友珍^{1,2} 李汪洋^{1,2} 台翔^{1,2} 安嘉琪^{1,2} 王辛^{1,2} 陈俊英^{1,2}

(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: 基于无人机遥感技术获取农田土壤盐分信息为盐渍化治理提供了快速、准确、可靠的理论依据。本文在内蒙古河套灌区沙壕渠灌域试验地上采集了取样点 0~20 cm 的土壤含盐量, 并使用 M600 型六旋翼无人机平台搭载 Micro-MCA 多光谱相机采集图像。利用 Otsu 算法对多光谱图像进行图像分类(土壤背景和植被冠层), 基于分类结果分别提取剔除土壤背景前后的光谱指数和图像纹理特征, 采用支持向量机(SVM)和极限学习机(ELM)构建土壤含盐量监测模型, 其 4 种建模策略分别为: 未剔除土壤背景的光谱指数(策略 1)、剔除土壤背景后的光谱指数(策略 2)、未剔除土壤背景的光谱指数+图像纹理特征(策略 3)、剔除土壤背景的光谱指数+图像纹理特征(策略 4), 通过比较 4 种建模策略的模型精度以筛选出最优变量组合。结果表明: 策略 3、4 所计算出的土壤含盐量反演精度高于策略 1、2, 策略 1~4 验证集决定系数 R_v^2 分别为 0.614、0.640、0.657、0.681, 因此利用图像纹理特征+植被指数对提高土壤含盐量的反演精度有重要意义。对比策略 3、4, 图像纹理特征+植被指数受到土壤背景的影响, 策略 4 精度低于策略 3 精度, 其 R_v^2 分别为 0.614、0.657; 各变量处理的最优模型均为 ELM 模型, 建模集 R_c^2 分别为 0.625、0.644、0.618、0.683, 标准均方根误差分别为 0.152、0.134、0.206、0.155。相比于 SVM 模型, ELM 模型提高了土壤含盐量的反演精度。

关键词: 土壤含盐量; 无人机遥感; 多光谱; 图像纹理特征; 植被指数; 全子集筛选

中图分类号: S127; TP79 文献标识码: A 文章编号: 1000-1298(2023)08-0201-10

OSID:



Inversion of Soil Salt Content Based on Texture Feature and Vegetation Index of UAV Remote Sensing Images

XIANG Youzhen^{1,2} LI Wangyang^{1,2} TAI Xiang^{1,2} AN Jiaqi^{1,2} WANG Xin^{1,2} CHEN Junying^{1,2}

(1. Key Laboratory of Agricultural Soil and Water Engineering in Arid and Semiarid 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: The acquisition of farmland soil salt information based on UAV remote sensing technology provides a rapid, accurate and reliable theoretical basis for salinization management. The soil salt content of 0~20 cm from the sampling point was collected on the test ground of Shahao canal irrigation field in Hetao Irrigation District, Inner Mongolia, and the images were collected by M600 hexarotor UAV platform equipped with Micro-MCA multispectral camera. Otsu algorithm was used to classify the multi-spectral images (soil background and vegetation canopy). Based on the classification results, the spectral index and image texture features before and after removing the soil background were extracted respectively. The soil salt content monitoring model was constructed by support vector machine (SVM) and extreme learning machine (ELM). The four modeling strategies were as follows: spectral index of the soil background was not removed (strategy 1); spectral index of the soil background was removed (strategy 2); spectral index of the soil background was not removed + image texture features (strategy 3); spectral index of the soil background was removed + image texture features (strategy 4). The optimal variable combination was selected by comparing the model accuracy of the four modeling strategies. The results showed that the inversion accuracy of soil salt content calculated by strategy 3 and strategy 4 was higher than that of strategy 1 and strategy 2, and their validation sets R_v^2 were 0.614,

收稿日期: 2022-11-22 修回日期: 2022-12-23

基金项目: 国家自然科学基金面上项目(52279047)

作者简介: 向友珍(1973—), 女, 副教授, 博士生导师, 主要从事遥感技术在农业水土工程应用研究, E-mail: Youzhenxiang@nwsuaf.edu.cn

0.640, 0.657 and 0.681, respectively. Therefore, it was of great significance to use image texture feature and vegetation index to improve the inversion accuracy of soil salt content. By comparing strategies 3 and 4, the image texture feature + vegetation index was affected by soil background. The accuracy of the strategy 4 was lower than that of the strategy 3, whose R_v^2 was 0.614 and 0.657, respectively. The optimal model for each variable processing was ELM model, and the modeling sets R_c^2 were 0.625, 0.644, 0.618, 0.683, and the standard root mean square errors were 0.152, 0.134, 0.206 and 0.155, respectively. Compared with the SVM model, the ELM model improved the inversion accuracy of soil salt content.

Key words: soil salt content; UAV remote sensing; multispectrum; image texture feature; vegetation index; full subset selection

0 引言

土壤盐渍化是指在自然和人为作用下,盐分在土壤表层不断积累的现象,是造成土壤退化、农业减产和生态环境恶化的重要因素^[1]。河套灌区土壤盐渍化问题严重,对盐渍化土壤进行治理和开发利用是农业可持续发展与生态文明建设高质量发展的有力保障^[2]。实时、高效地监测土壤盐渍化状况,是治理土壤盐渍化的重要前提。

人工定点采样法是土壤盐渍化监测的方式之一,该方法监测周期长、工作量大,且监测的精度与采样点的数量、布设方式有很大关系,很难反映盐渍化在空间上的实际分布。随着科学技术的不断发展,遥感被广泛应用于盐渍化研究和监测,为大面积时空分布动态化的盐渍化监测提供了新的途径。然而广泛可用的卫星图像无法提供高空间分辨率和数据采集时间的灵活性,在农业应用方面有很大的局限性^[3]。

除卫星遥感外,利用无人机平台搭载的小型多光谱遥感设备对区域土壤盐渍化监测也是重要手段^[4-5]。与卫星图像相比,基于无人机多光谱图像的盐渍化监测具有空间分辨率高、光谱分辨率强、波段连续性强等优点,可以获得多维、高精度的盐渍化检测信息,实现对土壤盐渍化的动态监测;同时,无人机传感器携带多光谱相机平台,具有实时、高分辨率、移动性和灵活性的优势,在高精度盐渍化监测方面具有优势^[6]。刘旭辉等^[7]利用无人机多光谱遥感影像建立的机器学习模型反演土壤含盐量,得出不同季节的土壤含盐量会有所不同。刘楠等^[8]将局部区域的相关性分析和多维光谱变化特性采用二进制编码的形式来表征不同类型地物纹理特征,实现了区分和判别影像上不同纹理的目的,并证明该方法对提取地物纹理特性具有一定可行性。万亮等^[9]利用无人机多光谱融合植被指数和纹理特征提高了水稻含水量预测结果;周聪等^[10]通过实践证明,高分辨率遥感图像的纹理特征可以作为估算植

被生长参数的更有效指标。陈鹏飞等^[11]通过实践证实了基于无人机多光谱图像的剔除土壤背景和增加纹理特征处理可以提高棉花植株氮浓度的反演精度。但是基于无人机多光谱图像剔除土壤背景和纹理特征是否可以提高土壤含盐量精度方面研究较少。

本文以河套灌区沙壕渠灌域4块不同土壤盐渍化程度的典型盐渍化试验地为试验研究区,以灌区典型地物为研究对象,在灌区作物生长期采集试验区盐渍土样本并获取土壤盐渍化信息。同时利用无人机多光谱采集遥感数据,对比研究基于盐渍化土壤和耐盐作物光谱的土壤含盐量反演模型的性能,建立基于无人机多光谱遥感平台的区域盐渍化监测体系,为区域盐渍化研究提供可靠依据。

1 材料与方法

1.1 研究区概况

本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。灌域因不合理的灌排方式,气候、土质和地貌等因素的综合影响,土壤盐渍化问题突出。区内种植作物以向日葵、玉米等耐盐粮油作物为主。沙壕渠灌域土壤类型为粉壤土、砂壤土和壤土。沙壕渠灌域面积约52.4 km²,南北跨度约15.1 km,东西横跨4.2 km,为典型的温带大陆性气候,多年平均气温3.7~7.6℃,多年平均降水量210~290 mm,多年平均年蒸发量2 100~3 080 mm,多年平均日照时长为3 000~3 200 h。

1.2 试验地布设

将试验地以土壤含盐量为基础从低到高依次分为1、2、3、4,每块试验地面积为15.5 hm²左右。4块试验地主要种植作物为向日葵和玉米。每块试验地均匀布设30个土壤采样点。采样点布设见文献[12]。

1.3 光谱图像采集和处理

使用的无人机为深圳市大疆创新科技有限公司




图 1 研究区域示意图
Fig.1 Schematic of study area

生产的 M600 型六旋翼无人机,其最大上升速度 5 m/s,最大下降速度 3 m/s,最大飞行速度 18 m/s,飞行承载质量 6 000 g,飞行高度 2 500 m,单次飞行时间 35 ~ 40 min。多光谱遥感相机采用美国 Tetracam 公司生产的 6 通道 Micro - MCA 多光谱相机,包括蓝光波段、绿光波段、红光波段、红边波段、近红外 1 波段、近红外 2 波段共 6 个遥感波段,波长分别为 490、550、680、720、800、900 nm。试验时间为 2022 年 7 月 16—20 日。每次试验均在 11:00—14:00 进行,试验日晴朗无风,以确保充分的辐射强度,尽量减小植被阴影对光谱的影响。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。

1.4 光谱指数计算

光谱指数是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^[13]。分别选择 8 种植被指数和 10 种盐分指数,其计算公式如表 1 所示。

1.5 灰度共生矩阵法

灰度共生矩阵(GLCM)是一种基于统计数据的图像纹理特征提取方法,由 HARALICK 等^[26]提出。

表 1 光谱指数
Tab.1 Spectral index

指数		公式	文献序号
植被指数	归一化植被指数(NDVI)	$(Nir - R)/(Nir + R)$	[14]
	差异化植被指数(DVI)	$Nir - R$	[15]
	比值植被指数(RVI)	Nir/R	[16]
	改进型土壤调节植被指数(MSAVI)	$\{2Nir - 1 - [2(2Nir + 1) - 8(Nir - R)]^{0.5}\}/2$	[17]
	增强型植被指数(EVI)	$2.5[(Nir - R)/(Nir + 6R - 7.5B + 1)]$	[18]
	土壤调节植被指数(SAVI)	$[(Nir - R)/(Nir + R + L)](1 + L)$	[19]
	冠层盐度响应植被指数(CRSI)	$[(NirR - GR)/(NirR + GR)]^{0.5}$	[20]
	大气阻抗植被指数(ARVI)	$(Nir - 2R + B)/(Nir + 2R - B)$	[21]
盐分指数	归一化盐分指数(NDSI)	$(R - Nir)/(R + Nir)$	[22]
	盐分指数(SI - T)	$(BR)^{0.5}$	[23]
	盐分指数 1(SI1)	$(RG)^{0.5}$	[24]
	盐分指数 2(SI2)	$(G^2 + R^2 + Nir^2)^{0.5}$	[24]
	盐分指数 3(SI3)	$(G^2 + R^2)^{0.5}$	[24]
	盐分指数(S1)	B/R	[24]
	盐分指数(S2)	$(B - R)/(B + R)$	[25]
	盐分指数(S3)	GR/B	[25]
	盐分指数(S5)	BR/G	[25]
	盐分指数(S6)	$RNir/G$	[25]

注: Nir 、 R 、 B 、 L 、 G 分别表示近红外波段反射率、红边波段反射率、蓝光波段反射率、土壤调节因子、绿光波段反射率。

GLCM 的元素是不同组合出现的频数,为了计算图像纹理的特征参数,对 GLCM 进行归一化。已知 i 、 j 分别为 (x, y) 、 $(x + \Delta x, y + \Delta y)$ 的像素值, (i, j) 的个数为 $V(i, j)$,将归一化 GLCM 记为 P ,则

$$P_{i,j} = \frac{V_{i,j}}{V_{sum}} \tag{1}$$
$$V_{sum} = \sum_{i,j=0}^{N-1} V_{i,j} \tag{2}$$

其中

式中 $V_{i,j}$ ——矩阵元素 N ——矩阵元素个数

参数,本研究采用 8 个纹理特征参数,其计算公式和特性如表 2 所示。

基于归一化灰度共生矩阵,计算图像纹理特征

表 2 图像纹理特征参数
Tab.2 Texture feature parameters of images

纹理特征参数	特性	公式	文献序号
均值	图像灰度平均值的度量	$\mu_i = \sum_{i,j=0}^{N-1} iP_{i,j} \quad \mu_i = \sum_{I,J=0}^{N-1} JP_{I,J}$	[27]
方差	图像灰度变化差异的度量	$\sigma_i^2 = \sum_{i,j=0}^{N-1} P_{i,j}(i-\mu_i)^2$ $\sigma_j^2 = \sum_{i,j=0}^{N-1} P_{i,j}(j-\mu_j)^2$	[27]
同质性	反映图像纹理的同质性,图像局部越均匀,其值越大	$HOM = \sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1+(i-j)^2}$	[27]
对比度	表征图像中的局部灰度变化总量	$CON = \sum_{i,j=0}^{N-1} P_{i,j}(i-j)^2$	[27]
相异性	与对比度类似,表征灰度级的差异,图像局部变化变大,其值越大	$DIS = \sum_{i,j=0}^{N-1} P_{i,j} i-j $	[28]
熵	图像的信息量表征,纹理越复杂、数量越多,熵越大	$ENT = \sum_{I,J=0}^{N-1} P_{I,J}(-\ln P_{i,j})$	[27]
角二阶矩	也称为能量,纹理粗时角二阶矩大,纹理细时角二阶矩小	$ASM = \sum_{i,j=0}^{N-1} P_{i,j}^2$	[27]
相关性	图像灰度线性的度量	$COR = \sum_{i,j=0}^{N-1} P_{i,j} \left[\frac{(i-\mu_i)(j-\mu_j)}{\sqrt{\sigma_i^2 \sigma_j^2}} \right]$	[27]

1.6 Otsu 算法

Otsu 算法是一种计算简单、自适应强且已得到最广泛使用的图像阈值自动选取方法^[29]。设某一灰度级对应阈值为 T ,类间方差计算公式为

$$\sigma_w^2 = W_b\sigma_b^2 + W_f\sigma_f^2 \tag{3}$$

式中 W_b ——阈值 T 下背景占整幅图像的比重
 σ_b^2 ——背景方差
 W_f ——阈值 T 下前景占整幅图像的比重
 σ_f^2 ——前景方差

1.7 全子集筛选法

全子集筛选法是利用全子集回归分析,对自变量不同的组合,用最小二乘法进行建模分析,筛选最优的变量组合。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^[30]。本文通过 R 编程语言进行全子集筛选,利用决定系数 R^2 和贝叶斯信息准则 (Bayesian information criterion, BIC) 来评价筛选结果,对比分析 R^2 越大、BIC 越小的筛选结果,为最优变量组合。

1.8 建模策略

建模策略分别为:未剔除土壤背景的光谱指数 (策略 1)、剔除土壤背景后的光谱指数 (策略 2)、未剔除土壤背景的光谱指数 + 图像纹理特征 (策略 3)、剔除土壤背景的光谱指数 + 图像纹理特征 (策略 4)。

1.9 模型方法和评价指标

极限学习机 (Extreme learning machine, ELM)

是一种基于最小二乘学习算法的隐层前馈网络^[31]。ELM 收敛速度比传统算法快,因为它无需迭代即可学习,同时,随机隐藏节点保证了全局逼近能力^[32]。本文 ELM 模型采用 R 语言 elmnNncpp 包构建。支持向量机 (Support vector machines, SVM) 是用于监督学习的强大计算工具^[33]。本研究采用非线性支持向量机模型,利用 R 语言 e1071 包构建。通过决定系数 R^2 、均方根误差 (RMSE)、标准均方根误差 (NRMSE) 指标评价模型精度。 R^2 越接近 1, RMSE 越接近 0,说明模型效果越好。

本文利用 R 语言编程构建 SVM 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。将深度 0 ~ 20 cm 平均土壤含盐量按照比例 2:1 随机划分建模集和验证集,通过调整参数,获得每个条件下最佳模型。建模流程如图 2 所示。

2 结果与分析

2.1 土壤含盐量

对试验地总计 87 个采样点的土壤含盐量进行统计,将计算表层和深度 10 ~ 20 cm 实测土壤含盐量的平均值作为深度 10 ~ 20 cm 的平均土壤含盐量。将深度 0 ~ 20 cm 平均土壤含盐量按照比例 2:1 随机划分建模集和验证集,结果如表 3 所示。将各总集、建模集、验证集样本点土壤含盐量划分为 4 个等级:非盐土 (D1, SSC (土壤含盐量) 小于等于




图 2 建模流程图
Fig. 2 Model building flowchart

0.2%)、轻度盐渍化 (D2, SSC 为 (0.2%、0.5%])、

表 3 土壤含盐量特征统计分析
Tab.3 Statistical analysis of soil salt content characteristics

数据集	采样点数量					含盐量			
	总计	D1	D2	D3	D4	最小值/%	最大值/%	均值/%	变异系数
总集	87	41	37	9	0	0.076	0.849	0.281	0.79
建模集	58	28	24	6	0	0.076	0.835	0.277	0.77
验证集	29	13	13	3	0	0.077	0.849	0.288	0.73




图 3 土壤含盐量特征统计
Fig. 3 Statistical map of soil salinity characteristics

分类结果评价。分别对 40 个样本的多光谱图像进行 2.1 节的操作,获得分类结果,并在 ENVI 5.3 中对分类结果进行评价,得到 4 个植被指数的总体精度和 Kappa 系数。

如图 4 所示,4 个植被指数的精度存在显著差异,其中 NDVI 的图像分类精度最高,40 个样本的总体精度均大于 93.4%,均值为 96.9%;Kappa 系数在 0.84~0.99 之间,均值为 0.92。MSAVI 的分类精度略低于 NDVI,总体精度和 Kappa 系数均值分别为 95.8% 和 0.91;DVI 和 CRSI 2 个植被指数的分

重度盐渍化 (D3, SSC 为 (0.5%、1%]) 和盐土 (D4, SSC 大于 1.0%)^[34]。非盐土、轻度盐渍化、重度盐渍化和盐渍土占比分别为 34.1%、55.7%、9.1% 和 1.1%。含盐量变异系数均处于中等差异 (变异系数 C_v 反映样点值的离散程度, $C_v < 0.1$ 为弱变异性; $0.1 < C_v < 1$ 为中等变异性; $C_v > 1$ 为强变异性)^[34]。

对各盐渍化等级下建模集、验证集和总集的含盐量进行统计分析,如图 3 (图中 1.5IQR 表示 1.5 倍的四分位距) 所示。从图 3 可以看出, D1、D2、D3 等级的建模集、验证集和总集的含盐量分布、值域和均值相近,确保建模集和验证集数据的代表性。

2.2 不同植被指数分类结果

基于近红外和可见光波段构建 4 个植被指数,利用对土壤背景敏感的 4 个植被指数 (NDVI、MSAVI、DVI、CRSI) 进行图像分类,验证不同指数的图像分类精度。为了对比 4 个植被指数图像分类的精度,从 87 个采样点中随机选取 40 个样本,进行




图 4 基于不同植被指数的图像分类结果
Fig. 4 Evaluation based on image classification results of different vegetation indices

类效果相对较差,总体精度均值小于 91%,Kappa 系数均值均小于 0.88。基于以上分析,NDVI 图像分类结果表现最优。

2.3 图像纹理计算

灰度共生矩阵具有丰富的特征参数,能从不同的角度对纹理进行细致刻画^[35]。由盐渍化土壤覆盖植被冠层的光谱特征分析可知,植被冠层光谱中红光波段与土壤含盐量的相关性最高,对盐渍化的变化有最显著的响应,故选择波段 Band3 计算多光

谱图像纹理。为了更好地体现植株间冠层图像的纹理差异,纹理特征参数计算的窗口选择尺度为 11 像素×11 像素,尺寸为 71.5 cm;每个特征参数都有 4 个不同方向的值,取其平均值作为方向无关的特征值。将采样点的多光谱图像输入 ENVI 5.3 软件,利用二阶统计滤波工具计算 2 个波段灰度共生矩阵的 8 个特征参数。如图 5、6 所示,分别为剔除土壤背景的植被冠层图像(E1)和原始多光谱图像(E2)处理的可见光示意图,均值(MEA)、方差(VAR)、均匀性(HOM)、对比度(CON)、差异(DIS)、熵(ENT)、二阶矩(SEC)和相关性(COR)特征参数灰度图。从图中可看出,灰度共生矩阵的特征参数表现出图像丰富的纹理特征,剔除土壤背景前后的多光谱图像纹理特征存在明显差异,统计灰度图的纹理特征参数数值,对纹理特征进行进一步分析。




图 5 剔除土壤背景多光谱图像灰度共生矩阵特征参数灰度图

Fig.5 Gray scale of characteristic parameters of co-occurrence matrix of multispectral image with soil background eliminated

2.4 图像纹理特征

图像纹理是用于识别图像中感兴趣的对象或区域的重要特征之一^[36],为了对比剔除土壤背景以及不同盐渍化等级下多光谱图像纹理特征的差异,对 E1 和 E2 处理的多光谱图像 Band3 的纹理特征参数进行统计,计算 2 个处理下 3 个盐渍化等级样本点多光谱图像的纹理特征参数的平均值,如表 4 所示。分别对比 2 个处理下 3 个盐渍化等级的纹理特征参数平均值。整体上,相比剔除土壤背景前的 E2,剔除土壤背景后的 E1 处理的纹理特征值中,




图 6 原始多光谱图像灰度共生矩阵特征参数灰度图
Fig.6 Gray level co-occurrence matrix characteristic parameters gray level

表 4 多光谱图像纹理特征参数

Tab.4 Multispectral image texture feature parameters

特征参数	E1			E2		
	非盐土	轻度盐渍化	重度盐渍化	非盐土	轻度盐渍化	重度盐渍化
DIS	0.54	0.50	0.50	0.32	0.32	0.26
SEC	0.63	0.57	0.66	0.60	0.65	0.68
VAR	0.61	0.89	0.84	0.37	0.63	0.58
HOM	0.83	0.76	0.77	0.78	0.69	0.70
CON	0.83	0.96	0.97	1.27	1.33	1.49
ENT	4.27	4.56	5.52	0.55	1.26	1.27
COR	4.19	6.48	6.22	0.42	0.94	0.79
MEA	4.19	4.42	4.07	4.49	5.32	6.63

SEC、CON、MEA 特征值减小,DIS、VAR、ENT、COR、HOM 特征值增大。其中 CON、ENT、COR 3 个参数的变化最显著,CON 减小表示图像纹理沟纹变浅,图像清晰度下降;ENT 变大,表示图像纹理增多;COR 增大,表示图像纹理变粗。

2.5 基于全子集回归筛选光谱自变量

通过 R 语言全子集回归模型算法,分别对 E1 和 E2 处理的 a (植被指数)和 b (植被指数和图像纹理特征参数)数据集进行全子集变量筛选,筛选评价指标选择 R^2 和 BIC 两个指标。综合衡量 R^2 最大和 BIC 最小的变量组合,得到每个数据集中最优的变量组,结果如表 5 所示。

对比 E1 处理下 2 个变量种类的筛选结果,变量组 a 筛选得到的敏感变量组含有 NDVI、SRVI、NDSI 3 个植被指数;变量组 b 的敏感变量组中包含 NDVI、

表 5 全子集筛选最优变量组合统计

Tab.5 Optimal variable combination statistics
screened by full subset method

处理	变量组	最优变量组合	R^2	BIC
E1	a	NDVI、SRVI、NDSI	0.62	-45
	b	NDVI、SRVI、ARVI、TVI	0.69	-46
E2	a	DVI、EVI、SRVI	0.52	-33
	b	SRVI、NDSI、ENT、COR、SEC	0.71	-67

SRVI、ARVI、TVI 4 个植被指数,筛选掉了纹理特征参数。对比 E2 处理下 2 个变量种类的筛选结果,变量组 a 筛选得到的敏感变量组包含 DVI、EVI、SRVI 3 个植被指数;变量组 b 敏感变量组中包含 RVI、NDSI 两个植被指数和 ENT、COR、SEC 3 个图像纹理特征参数。

2.6 基于图像纹理特征和植被指数的 SSC 反演模型

通过不同植被指数分类结果分析可以得出 NDVI 可以达到良好的图像分类效果。因此,利用 NDVI 对多光谱图像进行分类,并对图像分类得到的土壤像元进行掩膜处理,剔除土壤像元,获得纯净度更高的植被冠层图像。分别将 E1 和 E2 输入 ENVI 5.3 软件提取 6 个波段的反射率。将多光谱可见光和近红外 1 波段的反射率代入植被计算公式(表 1),得到相应的植被指数,涉及的植被指数有 NDVI、DVI、RVI、MSAVI、ARVI、EVI、CRSI。并基于全子集回归变量模型筛选结果,构建基于敏感变量组的 SSC 反演模型。

基于 E1 和 E2 处理下 a、b 两种变量组全子集法筛选的变量结果,构建基于敏感变量的 SVM 和 ELM 土壤含盐量反演模型,各模型建模集和验证集的 R^2 和 NRMSE 如表 6 所示。

表 6 基于不同变量组的 SVM、ELM 反演模型精度

Tab.6 SVM and ELM inversion model based on
different variable groups

建模 方式	处理	变量组	建模集		验证集	
			R_c^2	NRMSE _c	R_v^2	NRMSE _v
SVM	E1	a	0.564	0.224	0.565	0.205
		b	0.583	0.162	0.614	0.188
	E2	a	0.558	0.235	0.532	0.229
		b	0.627	0.195	0.640	0.222
ELM	E1	a	0.625	0.152	0.602	0.181
		b	0.644	0.134	0.657	0.156
	E2	a	0.618	0.206	0.584	0.201
		b	0.683	0.155	0.681	0.191

变量组 a 模型中,E1 处理下 E1 - a - SVM 模型的 R_c^2 和 R_v^2 分别为 0.564 和 0.565,大于 E2 处理的 E2 - a - SVM 模型,同时 E1 - a - SVM 模型 NRMSE_c 和 NRMSE_v 分别为 0.224 和 0.205,均小于 E2 - a -

SVM 模型。总体上变量组 a 模型中,E1 - a 模型精度更高,模型误差更小。E1 处理下 E1 - a - ELM 模型的 R_c^2 和 R_v^2 分别为 0.625 和 0.602,大于 E2 处理的 E2 - a - ELM 模型,同时 E1 - a - ELM 模型的 NRMSE_c、NRMSE_v 分别为 0.152 和 0.181,均小于 E2 - a - ELM 模型。综上所述,变量组 a 模型中,E1 - a 模型精度更高,模型误差更小。

变量组 b 模型中,E2 处理模型表现最佳,E2 - b - SVM 模型的 R_c^2 和 R_v^2 分别为 0.627 和 0.640,均大于 E1 处理模型的 R^2 ,E1 - b - SVM 模型 NRMSE_c 和 NRMSE_v 分别为 0.162 和 0.188,均小于 E2 - b。总体上,变量组 b 模型中,E2 模型的精度最高,E1 模型误差最小。

E2 处理模型表现最佳,E2 - b - ELM 模型的 R_c^2 和 R_v^2 分别为 0.683 和 0.681,均大于 E1 - b - ELM 处理模型建模集和验证集的 R^2 ,E1 - b - ELM 模型 NRMSE_c 和 NRMSE_v 分别为 0.134 和 0.156,均小于 E2 - b。总体上,变量组 b 模型中,E2 模型的精度最高,E1 模型误差最小。

基于全子集筛选的 2 种敏感变量组,利用 SVM 和 ELM 两种机器学习方法,构建 E1 和 E2 处理共 8 个土壤含盐量反演模型,验证集实测值和模拟值如图 7 所示。

E1、E2 处理下 2 个变量组的 SVM 和 ELM 机器学习土壤含盐量反演模型中,ELM 算法的 E1 - a、E1 - b、E2 - a、E2 - b 模型的 R^2 分别为 0.602、0.657、0.584、0.681,均大于对应的 SVM 模型。ELM 模型的标准均方根误差分别为 0.181、0.156、0.201、0.191,均小于 SVM 模型验证集的标准均方根误差。综上,ELM 模型的表现更好。

3 讨论

孟沌超等^[37]发现采用基于 PLSR 植被指数加纹理特征模型可以快速准确提取玉米冠层 SPAD,从而更好地反演叶绿素。本研究在剔除土壤背景前后两种处理下分别采用植被指数 a 组、采用植被指数和图像纹理特征参数 b 组 2 个自变量组,来探究不同变量下土壤含盐量的反演精度。对比 2 个变量组的建模集和验证集发现,E1、E2 处理下两个变量组的 SVM 和 ELM 机器学习土壤含盐量反演模型中,E1 - b 和 E2 - b 处理组的 R_c^2 和 R_v^2 均大于多对应的 E1 - a 和 E2 - a 处理组的 R_c^2 和 R_v^2 ,植被指数 + 纹理特征反演土壤含盐量相比于植被指数的反演精度更高,与文献[37]研究结果相似。但张智韬等^[38]通过对比剔除土壤背景前后的冬小麦根域土壤含水率遥感反演精度发现,剔除土壤背景可以提高土壤含




图 7 土壤含盐量实测值和模拟值对比

Fig. 7 Comparison of measured and simulated soil salt contents

水率的反演精度。本研究对各个变量组进行全子集筛选,剔除土壤背景后的 2 个自变量组的筛选结果中均不包含图像纹理特征参数,结果说明剔除土壤背景后的图像纹理特征对土壤含盐量的敏感程度低于植被指数。陈鹏飞等^[11]基于低空无人机影像光谱和纹理特征反演棉花氮素诊断指标时表明,土壤背景会影响棉花的冠层光谱,从而影响植株氮浓度的反演精度。可能是因为土壤背景会影响向日葵和玉米的冠层光谱,剔除土壤背景降低了图像纹理特征 + 植被指数与土壤含盐量的相关性。通过计算并观察剔除土壤背景前后的图像纹理特征参数平均值(表 7)可知,剔除土壤背景后的 E1 处理,相比剔除前 SEC、CON、MEA 特征值减小,其中减小最多的是 MEA,从 5.48 减小至 4.23;DIS、VAR、ENT、COR、HOM 特征值增大,其中增加最为显著的是 COR 和 ENT,COR 从 0.72 增加到 5.63,ENT 从 1.03 增加到 4.78。CON 减小表示图像纹理沟纹变浅,图像的清晰度下降;ENT 变大,表示图像的纹理增多;COR 增大,表示图像的纹理变粗。此外,随着盐渍化程度的加深,图像沟纹加深,图像清晰度增

表 7 剔除土壤背景前后纹理特征参数平均值								
Tab.7 Average value of image texture characteristic parameters before and after removing soil background								
处理	DIS	SEC	VAR	HOM	CON	ENT	COR	MEA
E1	0.51	0.62	0.78	0.79	0.92	4.78	5.63	4.23
E2	0.30	0.64	0.53	0.72	1.36	1.03	0.72	5.48

强,纹理强度增强,纹理数量增多,进而影响了图像纹理特征反演土壤含盐量的精度。

本研究仅基于无人机遥感多光谱反射率、图像纹理特征与植被指数的土壤含盐量反演,对于作物的耕种方式、作物不同生育期受土壤盐渍化的影响,灌水量对土壤含盐量的影响尚未考虑。本研究建立了特定情形下的土壤含盐量反演模型,模型结果较好,但模型是否具有广泛的适用性,不仅需要更加深入的研究,还需要综合考虑更多因素,进一步提高反演模型精度。

4 结论

(1)利用图像纹理特征 + 植被指数计算的土壤含盐量反演精度高于单一的植被指数,其验证集 R_v^2 分别为 0.614、0.640、0.657、0.681,因此利用图像纹理特征 + 植被指数对提高土壤含盐量的反演精度有重要意义。

(2)对比未剔除土壤背景的光谱指数 + 图像纹理特征(策略 3)、剔除土壤背景的光谱指数 + 图像纹理特征(策略 4)两组建模策略,图像纹理特征 + 植被指数受到土壤背景的影响,策略 4 精度低于策略 3,其 R_v^2 分别为 0.614、0.657。

(3)各变量处理的最优模型均为 ELM 模型,建模集 R_c^2 分别为 0.625、0.644、0.618、0.683,NRMSE_v 分别为 0.152、0.134、0.206、0.155。相比于 SVM 模型,ELM 模型提高了土壤含盐量的反演精度。

and salinity in Qingtongxia Irrigation Area based on indicator Kriging[J/OL]. China Rural Water and Hydropower;1 – 15[2022 – 11 – 22]. <http://kns.cnki.net/kcms/detail/42.1419.TV.20221115.1855.054.html>. (in Chinese)

[2] 孙亚楠,李仙岳,史海滨,等. 基于遥感的节水改造下河套灌区土壤盐渍化演变分析[J]. 农业机械学报, 2022, 53(1): 366 – 379.

SUN Ya'nan, LI Xianye, SHI Haibin, et al. Evolution mechanism of soil salinization in Hetao Irrigation District under condition of water-saving reform based on remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(1): 366 – 379. (in Chinese)

[3] KONSTANTIN I, HARM B, ARNOLD K, et al. UAV based soil salinity assessment of cropland[J]. Geoderma,2018,338: 502 – 512.

[4] WEI G F, LI Yu, ZHANG Z T, et al. Estimation of soil salt content by combining UAV-borne multispectral sensor and machine learning algorithms[J]. PeerJ, 2020, 8: e9087.

[5] 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)

[6] YAN D D, LI J T, YAO X Y, et al. Integrating UAV data for assessing the ecological response of *Spartina alterniflora* towards inundation and salinity gradients in coastal wetland[J]. The Science of the Total Environment, 2021, 814: 152631.

[7] 刘旭辉,白云岗,柴仲平,等. 典型绿洲灌区棉田土壤盐分多光谱遥感反演与季节差异性研究[J/OL]. 农业资源与环境学报;1 – 15[2022 – 11 – 20]. DOI:10.13254/j.jare.2022.0248.

LIU Xuhui, BAI Yungang, CHAI Zhongping, et al. Multispectral remote sensing inversion and seasonal difference in soil salinity of cotton field in typical oasis irrigation area[J]. Journal of Agricultural Resources and Environment;1 – 15[2022 – 11 – 20]. DOI:10.13254/j.jare.2022.0248. (in Chinese)

[8] 刘楠,舒宁. 多光谱影像纹理特征编码的算法研究[J]. 武汉大学学报(信息科学版), 2005, 30(1): 15 – 18.

[9] 万亮,岑海燕,朱姜蓬,等. 基于纹理特征与植被指数融合的水稻含水量无人机遥感监测[J]. 智慧农业(中英文), 2020, 2(1): 58 – 67.

[10] 周聪,龚龔,方圣辉,等. 融合纹理信息的无人机遥感影像水稻叶面积指数精准监测[C]//第八届高分辨率对地观测学术年会论文集, 2022: 316 – 329.

ZHOU Cong, GONG Yan, FANG Shenghui, et al. Accurate monitoring of rice leaf area index in UAV remote sensing images fused with texture information[C]// Proceedings of the Eighth Annual Conference on High Resolution Earth Observation, 2022: 316 – 329. (in Chinese)

[11] 陈鹏飞,梁飞. 基于低空无人机影像光谱和纹理特征的棉花氮素营养诊断研究[J]. 中国农业科学, 2019, 52(13): 2220 – 2229.

CHEN Pengfei, LIANG Fei. Cotton nitrogen nutrition diagnosis based on spectrum and texture feature of images from low altitude unmanned aerial vehicle[J]. Scientia Agricultura Sinica, 2019, 52(13): 2220 – 2229. (in Chinese)

[12] 张智韬,张翔,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 vegetation coverage[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(8): 220 – 230. (in Chinese)

[13] VERRELST J, SCHAEPMAN M E, 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.

[14] WANG Z, ZHANG F, ZHANG X L, et al. Regional suitability prediction of soil salinization based on remote-sensing derivatives and optimal spectral index[J]. Science of the Total Environment, 2021, 775: 145807.

[15] JORDAN C F. Derivation of leaf-area index from quality of light on the forest floor[J]. Ecology, 1969, 50(4): 663 – 666.

[16] BIRTH G S, MCVEY G R. Measuring the color of growing turf with a reflectance spectrophotometer I[J]. Agronomy Journal, 1968, 60(6): 640 – 643.

[17] 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.

[18] HUI Q L, ALFREDO R H. 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.

[19] HENAKA A M P N K, FIELD D J, MCBRATNEY A B. 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: 207 – 214.

[20] ELIA S, TODD H S, DENNIS L. Regional scale soil salinity evaluation using Landsat 7, western San Joaquin Valley, California, USA[J]. Geoderma Regional, 2014, 2 – 3: 82 – 90.

[21] 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.

[22] 巴艳君. 基于盐分指数与归一化植被指数的土壤盐渍化遥感监测指数模型构建[J]. 北京农业, 2015(17): 159 – 160.

[23] NASIR M K, VICTOR V, RASTOSKUEV Y, et al. Assessment of hydrosaline land degradation by using a simple approach of

remote sensing indicators[J]. *Agricultural Water Management*,2004,77(1): 96 – 109.

[24] ABD E K D, HERVE N, CHRISTIAN W. Detecting salinity hazards within a semiarid context by means of combining soil and remote-sensing data[J]. *Geoderma*,2005,134(1): 217 – 230.

[25] 刘旭辉,白云岗,柴仲平,等. 基于多光谱遥感的典型绿洲棉田春季土壤盐分反演及验证[J]. *干旱区地理*,2022,45(4): 1165 – 1175.

LIU Xuhui, BAI Yungang, CHAI Zhongping, et al. Inversion and validation of soil salinity based on multispectral remote sensing in typical oasis cotton field in spring[J]. *Geography of Arid Zone*, 2022,45(4):1165 – 1175. (in Chinese)

[26] HARALICK R M, SHANMUGAM K, DINSTEN H. Textural features for image classification[J]. *IEEE Transactions on Systems, Man, and Cybernetics*,1973,3(6): 610 – 621.

[27] 张楼香,阮仁宗,夏双. 洪泽湖湿地纹理特征参数分析[J]. *国土资源遥感*,2015,27(1):75 – 80.

ZHANG Louxiang, RUAN Renzhong, XIA Shuang. Parameter analysis of image texture of wetland in the Hongze Lake[J]. *Remote Sensing of Land Resources*, 2015, 27(1): 75 – 80. (in Chinese)

[28] 王晓蕾,杜智涛. 云图纹理特征参数提取方法和分析[J]. *气象水文海洋仪器*,2006(1):39 – 42.

WANG Xiaolei, DU Zhitao. Method for cloud texture characteristic pick-up [J]. *Meteorological, Hydrological and Oceanographic Instruments*,2006(1):39 – 42. (in Chinese)

[29] MA G Y, YUE X F. An improved whale optimization algorithm based on multilevel threshold image segmentation using the Otsu method[J]. *Engineering Applications of Artificial Intelligence*,2022,113: 104960.

[30] 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 estimation model of soil moisture content of field corn based on UAV multi-spectral remote sensing[D]. Yangling: Northwest A&F University, 2020. (in Chinese)

[31] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications[J]. *Neurocomputing*, 2006, 70(1/3): 489 – 501.

[32] WANG J, LU S Y, WANG S H, et al. A review on extreme learning machine[J]. *Multimedia Tools and Applications*,2021, 81: 41611 – 41660.

[33] SHAO Y H, ZHANG C H, WANG X B, et al. Improvements on twin support vector machines[J]. *IEEE Transactions on Neural Networks*,2011,22(6): 962 – 968.

[34] 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)

[35] ZAHRA J, AMIRHOSSEIN A, PHILIPPE C, et al. Monitoring the coefficient of variation: a literature review[J]. *Computers & Industrial Engineering*,2021,161: 107600.

[36] CHEN J, OU J S, ZENG H Q, et al. A fast algorithm based on gray level co-occurrence matrix and gabor feature for hevc screen content coding[J]. *Journal of Visual Communication and Image Representation*,2021,78: 103128.

[37] 孟沌超,赵静,兰玉彬,等. 基于无人机可见光影像的玉米冠层 SPAD 反演模型研究[J]. *农业机械学报*,2020,51(增刊 2):366 – 374.

MENG Dunchao, ZHAO Jing, LAN Yubin, et al. SPAD inversion model of corn canopy based on UAV visible light image[J]. *Transactions of the Chinese Society for Agricultural Machinery*,2020,51(Supp. 2):366 – 374. (in Chinese)

[38] 张智韬,周永财,杨帅,等. 剔除土壤背景的冬小麦根域土壤含水率遥感反演方法[J]. *农业机械学报*,2021,52(4):197 – 207.

ZHANG Zhitao, ZHOU Yongcai, YANG Shuai, et al. Inversion method for soil water content in winter wheat root zone with eliminating effect of soil background[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021,52(4):197 – 207. (in Chinese)