

覆膜对无人机多光谱遥感反演土壤含盐量精度的影响

姚志华^{1,2}, 陈俊英^{1,2*}, 张智韬^{1,2}, 谭丞轩^{1,2}, 魏广飞¹, 王新涛¹

(1. 西北农林科技大学水利与建筑工程学院, 旱区农业水土工程教育部重点实验室, 杨凌 712100;

2. 西北农林科技大学中国旱区节水农业研究院, 杨凌 712100)

摘要:快速、准确地获取农田土壤盐分含量对指导合理灌溉及盐渍土的治理有重要意义。该文以内蒙古河套灌区沙壕渠灌域内的覆膜耕地为研究对象, 利用无人机多光谱相机获取研究区内5月和6月的多光谱遥感数据, 并同步采集区域内表层土壤含盐量数据, 研究覆膜对无人机多光谱遥感图像反演农田土壤盐分含量精度的影响。利用支持向量机(support vector machine, SVM)、反向传播神经网络(back propagation neural network, BPNN)和极限学习机(extreme learning machine, ELM)3种机器学习方法, 分别构建去膜前后基于原始光谱反射率和优选光谱指数的土壤含盐量估算模型。结果表明, 去膜前后的各模型均可有效估测土壤盐分含量, 但基于去膜处理后的数据构建的盐分含量估算模型精度较不去膜处理的有所提升, 同时, 基于光谱指数构建的盐分含量估算模型精度比基于光谱反射率构建的模型精度高; 利用ELM构建的盐分含量估算模型在6月份预测效果最佳, 其中基于光谱反射率和光谱指数的建模 R^2 和RMSE分别为0.695、0.663和0.182、0.191, 验证 R^2 和RMSE分别为0.717、0.716和0.171、0.169。研究结果可为无人机多光谱遥感估算覆膜状态下的农田土壤盐分含量提供参考。

关键词:遥感; 土壤盐分; 光谱反射率; 光谱指数; 机器学习

doi: 10.11975/j.issn.1002-6819.2019.19.011

中图分类号: S252⁺.9 文献标识码: A 文章编号: 1002-6819(2019)19-0089-09

姚志华, 陈俊英, 张智韬, 谭丞轩, 魏广飞, 王新涛. 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. doi: 10.11975/j.issn.1002-6819.2019.19.011 http://www.tcsae.org

Yao Zhihua, Chen Junying, Zhang Zhitao, Tan Chengxuan, Wei Guangfei, Wang Xintao. Effect of plastic film mulching on soil salinity inversion by using UAV multispectral remote sensing[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2019, 35(19): 89—97. (in Chinese with English abstract) doi: 10.11975/j.issn.1002-6819.2019.19.011 http://www.tcsae.org

0 引言

快速准确地获取盐渍土的盐分信息, 对于土壤盐渍化的监测和防治, 实现中国农业的可持续发展具有重要的意义^[1]。遥感技术具有响应速度快、成本低以及覆盖面积大等优势, 已逐渐成为土壤盐渍化监测领域的一种有效手段^[2-5]。早期的研究发现, 在电磁波谱的可见光和近红外区, 盐碱土比普通土反射更多的入射能, 具有明显的光谱特征^[6]。Farifteh等^[7]通过建立土壤性质与土壤光谱之间的关系, 发现不同盐度等级的土壤样品的光谱反射率存在着显著的差异。Srivastava等^[8]则利用印度恒河平原地区的卫星高光谱数据, 探究了适宜监测该区域土壤盐分类型的光谱反射率的波段范围。卢霞^[9]以典型滨海盐土为研究对象, 分析了盐土的光谱特征和盐分含量

的分布特点。张晓光等^[10]则通过建立土壤反射光谱与土壤盐分含量之间的偏最小二乘回归模型, 探讨了利用反射光谱预测土壤盐分含量的可行性。Allbed等^[11]针对沙特阿拉伯东部地区的土壤盐化问题, 利用IKONOS遥感影像提取了包含植被指数和土壤盐度指数的13个光谱指数, 探究了这些指标对于土壤盐度的预测能力。姚远等^[12]通过光谱变换和波段筛选, 最终构建了5种盐分指数并以此建立了区域土壤盐渍化监测模型, 达到了良好的监测效果。郭鹏等^[13]以山东省垦利县为研究区, 通过构建任意波段的光谱指数进而筛选出敏感光谱指数的方法, 构建了土壤盐分监测的随机森林(random forest, RF)模型, 以实现对该区域土壤盐分的定量光谱估测。

虽然上述研究已经取得了许多成果, 但这些研究大部分是以卫星遥感数据为基础, 卫星遥感技术也是目前为止大区域土壤盐渍化监测的一种常用手段。由于农田覆膜技术可以改变土壤的水、气、热、盐状况, 促进作物的生长, 在河套灌区农业生产中有着广泛的应用^[14]。此外, 各种遥感仪器所接收的地表目标反射、发射的电磁辐射能与地表目标的表面温度、湿度以及粗糙度等性质有着很大的联系^[15], 而地膜覆盖的土壤表面与裸土区域有着不同的光谱特性, 因此覆膜会对大区域土壤盐渍化的准

收稿日期: 2019-04-09 修订日期: 2019-08-29

基金项目: 国家重点研发计划项目(2017YFC0403302); 国家自然科学基金资助项目(41502225); 杨凌示范区科技计划项目(2018GY-03)
作者简介: 姚志华, 主要从事节水农业和水土资源高效利用研究。

Email: yaozhishua@nwfu.edu.cn

*通信作者: 陈俊英, 博士, 副教授, 主要从事节水农业和水土资源高效利用研究。Email: cgyrose@126.com

确监测造成一定影响,是一个不可忽略的因素。由于卫星遥感的分辨率相对较低,无法剔除土壤表层覆膜的影响,因此会降低遥感监测的精度。而无人机遥感的时空分辨率相对较高,在剔除覆膜影响方面有一定的可操作性,但关于这方面的研究还未见报道。

鉴于此,本文利用无人机遥感获取多光谱数据反演农田土壤盐分含量,同时对遥感影像进行去膜处理并结合机器学习算法构建去膜前后的土壤含盐量估算模型,通过对不同模型精度作对比分析,探究覆膜对无人机多光谱遥感反演农田土壤含盐量精度的影响,为利用无人机遥感实施覆膜农田的土壤盐渍化监测提供一定的科学基础。

1 材料与方法

1.1 研究区概况

内蒙古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,也是重要的粮油作物生产基地之一。研究区位于河套灌区解放闸灌域内的沙壕渠灌区,是典型的黄土高原盐渍土灌区,地理位置介于东经107°05′~107°10′,北纬40°52′~41°00′之间(图1)。该地区地形平缓,平均坡度约为0.02%,土质类型以粉砂质黏壤土为主。气候类型为典型的大陆性干旱-半干旱气候,冬长夏短、干燥多风、昼夜温差较大。年平均气温7.1℃,平均相对湿度40%~50%,年均降水量155mm,年均蒸发量2000mm,全年无霜期约130~150d左右,主要作物包括小麦、玉米、西葫芦和向日葵等。近年来由于长期不合理的灌溉方式加上平缓的地形以及高蒸发量的自然条件,使得该地区约半数以上的土地都出现不同程度的盐渍化,严重影响了农业生产的发展。




图1 研究区位置图
Fig.1 Location map of study area

1.2 采样点设置与数据采集

本试验于沙壕渠灌域内选取4块不同盐分分布的试验地(1、2、3、4号地)作为采样区,每块试验地的面积约为16hm²。试验地以农田为主,主要种植作物为葵花。

试验于2018年5月和6月分2次进行,这个时期的农田已被覆膜,土壤盐分向表层聚集且地表绿色植被较少,采样时间分别为5月14日~18日、6月15日~19日。根据每块试验地的盐渍化程度和地形地貌特点,综合考虑采样点分布的代表性、均匀性等因素,在每块试验地布置13~14个采样点,采样方法为五点取样法,采样单元为16m×16m,采样深度为0~20cm,最终样本数据为五点取样的均值,其中5月份获得样本56个,6月份53个,共计获得109个试验数据。同时采用手持GPS仪记录相应的位置信息,试验田及采样点位置如图2所示。

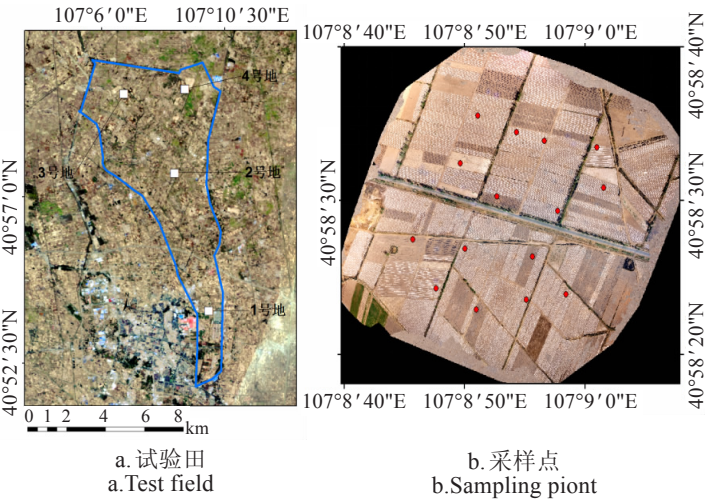


图2 试验田及采样点分布示意图
Fig.2 Schematic diagram of test field and sampling point distribution

土壤含盐量采用电导仪法测量,首先将获取的土样烘干研磨后过1mm筛,之后按照土水比1:5的比例配置土壤浸提液,静置8h后采用电导率仪(DDS-307A,上海佑科仪器公司)获取土壤溶液电导率(EC_{1:5},dS/m)值,最后通过经验公式换算得到土壤含盐量(SSC,%): $SSC=(0.2882EC_{1:5}+0.0183)^{[6]}$,土壤的盐渍化等级划分以SSC<0.2%为非盐土,0.2%≤SSC<0.5%为轻度盐渍化,0.5%≤SSC<1.0%为重度盐渍化,SSC≤1.0%为盐土,土壤采样点的具体盐分统计状况如表1所示。

1.3 遥感数据采集与处理

1.3.1 遥感数据的采集

遥感平台为深圳大疆创新科技有限公司生产的经纬M600六旋翼无人机,携带的遥感传感器为美国Tetracam公司生产的Micro-MCA多光谱相机(简称MCA)。MCA最多可安装6个通道,对应有6个镜头,可采集6种不同波长地物光谱反射信息,6种波长分别为490(蓝光)、550(绿光)、680(红光)、720(红边)、800(近红外)和900(近红外)nm。多光谱图像的采集时间与土样的采集时间一致,无人机的飞行高度为120m,多光谱相机镜头垂直向下,影像地面分辨率为0.065m,无人机每次飞行前在试验区域布置校正白板,用于对获取影像的辐射标定。

1.3.2 遥感图像的处理


使用与多光谱相机配套的软件PixelWrench2对获取的多光谱遥感影像进行提取、配准与合成,最后导出tif格式的六波段遥感影像。利用Pix4d软件将获取的试

表1 土壤采样点的盐分统计分析
Table 1 Statistical analysis of soil salinity of sampling points

数据 获取时间 Data acqui- sition time	样本数 Sample size					含盐量 Salinity						
	总计 Total	非盐土 None sali- nization	轻度盐渍化 Mild salinization	重度盐渍化 Severe salinization	盐土 Saline soil	最大值 Maxi- mum /%	最小值 Mini- mum /%	平均值 Mean / %	标准 差 SD / %	偏度 Skewness	峰度 Kurtosis	变异系 数 CV
5 月 May	56	4	16	24	12	1.366	0.121	0.642	0.330	0.200	-1.016	0.513
6 月 June	53	3	15	24	11	1.237	0.134	0.650	0.323	0.056	-1.216	0.497
总体 Total	109	7	31	48	23	1.366	0.121	0.646	0.327	0.130	-1.116	0.506

注:土壤盐渍化等级划分标准参考文献[16]。
Note: Classification standard of soil salinization according to reference [16].

验地单幅遥感影像拼接为全景图。将获取的试验地全景图导入 ENVI 5.3 软件中,同时按照取样点标定的 GPS 信息在图像中导入取样点位置信息。以取样点为中心,在遥感图像上裁剪出 200×200(像素)、地面分辨率为 13 m×13 m 的遥感影像。同时考虑到遥感图像中覆膜对光谱反射率的影响,采用监督分类中的最大似然法首先对裁剪的遥感图像进行地膜和土壤的分类,之后导出只包含土壤层的遥感影像以达到去膜的目的(如图 3 所示)。在 ENVI 5.3 软件中分别提取出取样点去膜前后的灰度值均值,利用白板的灰度值进一步计算出对应的光谱反射率值。



a. 去膜前
a. Before film removal
b. 去膜后
b. After film removal
图 3 多光谱图像去膜前后对比图

Fig.3 Contrast before and after removing film of multispectral image

1.4 光谱指数的选取与计算

在裸地或者植被覆盖度极低的土壤中,通过土壤的光谱指数作为间接指标来对盐渍化区域盐分进行评价和作图,已取得良好的效果^[17]。而盐度指数作为直接的盐度指标,突出了土壤表面盐壳的光谱反射率,尤其是在电磁波谱的可见光和近红外范围内^[18]。因此,根据之前得到的土壤表层不同波段的光谱反射率数据,结合参考文献和经验,本文选取 13 种常见的光谱指数(包括 11 种盐度指数)作为土壤盐渍化监测模型的备选指标,其计算方法如表 2 所示。

1.5 机器学习算法

机器学习算法是随着计算机技术和互联网的快速发展,通过计算机模拟或实现人类的学习行为而使计算机程序能随着经验的积累自动提高性能,最终实现从大数据中提取特征、发现隐含规律的方法^[23]。由于盐渍化土壤的光谱信息与土壤参数间的转换函数是复杂的非线性关系,因此有越来越多的学者将机器学习算法应用到土壤盐渍化反演的模型构建上并取得了较好的效果^[24]。本文采用支持向量机、反向传播神经网络和极限学习机算法来构建土壤盐分的反演模型。

表2 土壤光谱指数汇总表
Table2 Soil spectral index summary

光谱指数 Spectral index	计算公式 Calculation formula	参考文献 References
Salinity index (S1)	$S1=B/R$	[19]
Salinity index (S2)	$S2=(B-R)/(B+R)$	
Salinity index (S3)	$S3=(G \times R)/B$	
Salinity index (S4)	$S4=\sqrt{B \times R}$	
Salinity index (S5)	$S5=(B \times R)/G$	
Salinity index (S6)	$S6=(R \times NIR)/G$	[20]
Salinity index1 (SI1)	$SI1=\sqrt{R \times G}$	
Salinity index2 (SI2)	$SI2=\sqrt{G^2+R^2+NIR^2}$	[11]
Salinity index3 (SI3)	$SI3=\sqrt{G^2+R^2}$	
Salinity index (SI-T)	$SI-T=(R/NIR) \times 100$	[21]
Simple ratio index (SR)	$SR=NIR/R$	
Brightness index (BI)	$BI=\sqrt{R^2+NIR^2}$	[22]
Normalized differential salinity index (NDSI)	$NDSI=(R-NIR)/(R+NIR)$	

注: B、G、R 和 NIR 分别为 490、550、680 和 800 nm 波长处的光谱反射率。
Note: B、G、R and NIR represent spectral reflectance at wavelengths of 490、550、680 and 800 nm, respectively.

1.6 建模集和验证集的划分

本次试验数据的采集时间为 2018 年 5 月和 6 月,需要分不同的月份进行建模和验证,5 月份可供分析样本数为 56 个,6 月份为 53 个,总样本数为 109 个,随机选取 70% 的样本作为建模集,30% 的样本作为验证集,具体划分情况如表 3 所示。

表 3 建模集和验证集
Table 3 Modeling and Verification sets

数据集 Data set	5 月 May	6 月 June	总体 Total
建模集 Modeling set	39	37	76
验证集 Verification set	17	16	33
总计 Total	56	53	109

1.7 模型精度评价

对于模型的建模和验证精度评估采用以下 3 个指标:决定系数 R^2 、均方根误差 RMSE 以及相对误差 RE。 R^2 越大, RMSE 和 RE 越小说明模型效果越好,其计算公式如式(1)~式(3)所示。

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \tag{1}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \tag{2}$$

$$RE = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{y}_i - y_i|}{y_i} \times 100\%$$

(3)

式中 y_i 为土壤含盐量实测值, \hat{y}_i 为土壤含盐量预测值, \bar{y} 为土壤含盐量平均值, n 为样本数。

2 结果与分析

2.1 光谱反射率与土壤含盐量的相关性分析

将不同数据集中不同波段的光谱反射率与对应的土壤含盐量进行相关性分析,其相关系数的变化如图 4 示。




图 4 光谱反射率与土壤含盐量的相关系数变化图
Fig.4 Change chart of correlation coefficient between spectral reflectance and soil salinity

表 4 不同光谱指数与土壤含盐量的相关系数

Table4 Correlation coefficients between different spectral indices and soil salinity

光谱指数 Spectral index	5月 May		6月 June		总体 Total	
	未去膜 No film removed (n=56)	去膜 Film removed (n=56)	未去膜 No film removed (n=53)	去膜 Film removed (n=53)	未去膜 No film removed (n=109)	去膜 Film removed (n=109)
S1	-0.223	0.071	-0.128	0.047	-0.189*	0.060
S2	-0.194	0.072	-0.111	0.084	-0.158	0.078
S3	0.553**	0.561**	0.546**	0.620**	0.542**	0.589**
S4	0.740**	0.741**	0.665**	0.674**	0.700**	0.703**
S5	0.491**	0.574	0.419**	0.485**	0.453**	0.529**
S6	0.720**	0.739**	0.701**	0.714**	0.703**	0.726**
SI1	0.730**	0.751**	0.712**	0.734**	0.713**	0.739**
SI2	0.757**	0.780**	0.755**	0.789**	0.753**	0.782**
SI3	0.737**	0.759**	0.708**	0.731**	0.716**	0.742**
SI-T	0.038	-0.154	-0.070	-0.188	-0.014	-0.171
BI	0.785**	0.803**	0.774**	0.808**	0.778**	0.804**
SR	-0.163	0.026	-0.028	0.069	-0.102	0.046
NDSI	0.090	-0.092	-0.026	-0.125	0.036	-0.108

注:**表示在 0.01 水平极显著相关; *表示在 0.05 水平显著相关; n 为样本个数。
Note: ** represents highly significant at the 0.01 level; * represents significant at the 0.05 level; n is the number of samples.

与土壤含盐量极显著相关且相关系数 $r>0.7$ 的 6 种光谱指数即 S4、S6、SI1、SI2、SI3、BI 作为最佳光谱指数用于土壤盐分模型的建模验证。

2.3 基于光谱反射率的土壤盐分估算模型

将不同处理得到的 6 波段光谱反射率作为自变量,对应的土壤含盐量作为因变量,分别利用支持向量机、反向神经网络和极限学习机 3 种机器学习方法建立基于光谱反射率的土壤盐分估算模型。3 种机器学习方法分别使用 R 语言软件中的 e1071、nnet 和 elmNNRcpp 包实现(下同),相关建模及验证结果如表 5 所示。

从表 5 可以看出,3 种机器学习模型中,建模集的决定系数均在 0.6 以上,均方根误差均在 0.2 以下,均取得

从图 5 中可以看出,在波段 490、550、680 和 800 nm 处的光谱反射率与土壤含盐量的相关性较高,均位于 0.5 以上,其中 680 nm 处的相关性最高,而在 720 和 900 nm 处的相关性则相对较低,这与前人的研究基本一致^[25]。从图中还可以看出,经过去膜处理的光谱反射率与土壤含盐量的相关性相比未去膜的有所提高,其中 5 月份平均提高 0.040,6 月份平均提高 0.013,总体平均提高 0.028。而 5 月份去膜处理后的数据在 680 nm 波段处的光谱反射率与土壤含盐量的相关系数最为 0.770。

2.2 光谱指数与土壤含盐量的相关性分析

根据不同光谱指数与土壤含盐量的相关性分析,得到不同处理的 13 个光谱指数与对应的土壤含盐量相关系数,结果如表 4 所示。

通过分析不同光谱指数与土壤含盐量的相关系数大小,可以得出对应的相关性显著程度。由表 4 可以看出,无论是 5 月、6 月还是总体,S3、S4、S5、S6、SI1、SI2、SI3、BI 这 8 个光谱指数与土壤含盐量均表现出了极显著相关的相关关系,而 S1、S2、SI-T、SR、NDSI 这 5 个光谱指数与土壤含盐量的相关性则较低。其中,S3 和 S5 与土壤含盐量的相关系数变化范围在 0.4~0.6 左右,因此,本文拟采用

了较好的建模效果。而验证集验证效果则相对较差,但验证 R^2 也都达到了 0.5 以上,验证均方根误差均在 0.25 以下,相对误差均在 50% 以下。同时可以看出,通过去膜处理的数据集建模验证效果要好于原始的数据集,其中基于 SVM 回归的 5 月份去膜数据达到了最好的建模效果,建模 R^2 和 RMSE 分别为 0.790 和 0.154,基于 ELM 回归的 6 月去膜数据达到了最好的验证效果,验证 R^2 和 RMSE 分别为 0.717 和 0.171。5 月未去膜数据的建模验证效果要好于 6 月,但通过去膜处理后,6 月的数据建模验证效果有明显提升,即 6 月的去膜效果好于 5 月份。而就 3 种机器学习方法而言,ELM 的建模与验证效果相对最稳定,建模集和验证集的决定系数最为接近。

表5 光谱反射率与土壤盐分的机器学习模型
Table 5 Estimation models for spectral reflectivity and soil salinity by machine learning

模型 Model	处理 Treatment	建模集 Modeling set			验证集 Verification set		
		R^2	RMSE	RE/%	R^2	RMSE	RE/%
支持向量机 Support vector machine (SVM)	5 月末去膜 No film removed in May	0.765	0.164	26.68	0.577	0.214	40.77
	5 月去膜 Film removed in May	0.790	0.154	23.50	0.627	0.215	40.52
	6 月末去膜 No film removed in June	0.713	0.176	33.13	0.549	0.210	44.27
	6 月去膜 Film removed in June	0.777	0.156	29.09	0.582	0.210	43.94
	总体未去膜 No film removed in total	0.679	0.187	32.87	0.616	0.203	29.98
	总体去膜 Film removed in total	0.730	0.172	28.76	0.634	0.197	30.67
反向传播神经网络 Back propagation neural network (BPNN)	5 月末去膜 No film removed in May	0.759	0.166	28.92	0.536	0.222	41.75
	5 月去膜 Film removed in May	0.766	0.161	26.96	0.551	0.226	41.83
	6 月末去膜 No film removed in June	0.674	0.193	40.11	0.564	0.211	43.88
	6 月去膜 Film removed in June	0.712	0.183	37.84	0.700	0.186	39.92
	总体未去膜 No film removed in total	0.648	0.197	37.34	0.629	0.200	34.23
	总体去膜 Film removed in total	0.717	0.175	30.66	0.642	0.193	32.04
极限学习机 Extreme learning machine (ELM)	5 月末去膜 No film removed in May	0.745	0.170	26.62	0.602	0.212	34.92
	5 月去膜 Film removed in May	0.743	0.171	26.53	0.631	0.205	37.50
	6 月末去膜 No film removed in June	0.660	0.192	39.67	0.580	0.203	41.76
	6 月去膜 Film removed in June	0.695	0.182	36.53	0.717	0.171	34.22
	总体未去膜 No film removed in total	0.651	0.194	36.92	0.616	0.204	35.46
	总体去膜 Film removed in total	0.702	0.179	32.04	0.653	0.190	33.48

2.4 基于光谱指数的土壤盐分估算模型

将 2.2 节筛选得到的 6 种光谱指数作为自变量,分别与对应的土壤含盐量建立支持向量机、反向神经网络和极限学习机机器学习模型,结果如表 6 所示。

由表 6 可知,基于不同机器学习方法构建的光谱指数与土壤盐分的估算模型中,建模集的决定系数都在 0.6 以上, RMSE 都在 0.25 以下,验证集的决定系数都在 0.5 以上, RMSE 都在 0.25 以下, RE 都在 50% 以下,通过去膜处

理的数据集建模和验证的效果都要优于原始数据。其中,在 6 月份,基于 ELM 构建的盐分估算模型未去膜前的建模 R^2 和 RMSE 分别为 0.639 和 0.198,验证 R^2 和 RMSE 分别为 0.617 和 0.194,通过去膜处理后的建模 R^2 和 RMSE 分别为 0.663 和 0.191,验证 R^2 和 RMSE 分别为 0.716 和 0.169,去膜前后模型精度提升最为明显。而就总体数据而言,基于不同机器学习方法构建的盐分估算模型虽然精度相差不大,但通过去膜处理后的模型精度都有所提升。

表6 光谱指数与土壤盐分的机器学习模型
Table 6 Estimation models for spectral index and soil salinity by machine learning

模型 Model	处理 Treatment	建模集 Modeling set			验证集 Verification set		
		R^2	RMSE	RE/%	R^2	RMSE	RE/%
支持向量机 Support vector machine (SVM)	5 月末去膜 No film removed in May	0.765	0.163	24.53	0.612	0.214	34.23
	5 月去膜 Film removed in May	0.792	0.154	25.26	0.641	0.195	33.06
	6 月末去膜 No film removed in June	0.610	0.210	42.40	0.624	0.201	40.01
	6 月去膜 Film removed in June	0.674	0.189	36.76	0.687	0.177	35.50
	总体未去膜 No film removed in total	0.683	0.187	35.27	0.652	0.197	31.63
	总体去膜 Film removed in total	0.726	0.172	29.72	0.675	0.185	28.79
反向传播神经网络 Back propagation neural network (BPNN)	5 月末去膜 No film removed in May	0.745	0.171	30.69	0.594	0.207	36.06
	5 月去膜 Film removed in May	0.769	0.162	28.17	0.601	0.214	37.87
	6 月末去膜 No film removed in June	0.630	0.200	40.70	0.611	0.196	40.15
	6 月去膜 Film removed in June	0.685	0.185	38.19	0.698	0.175	36.77
	总体未去膜 No film removed in total	0.701	0.180	32.55	0.636	0.198	34.18
	总体去膜 Film removed in total	0.719	0.174	32.69	0.681	0.184	31.44
极限学习机 Extreme learning machine (ELM)	5 月末去膜 No film removed in May	0.746	0.170	29.08	0.618	0.208	34.89
	5 月去膜 Film removed in May	0.786	0.156	23.20	0.645	0.199	33.42
	6 月末去膜 No film removed in June	0.639	0.198	40.07	0.617	0.194	39.09
	6 月去膜 Film removed in June	0.663	0.191	40.24	0.716	0.169	34.93
	总体未去膜 No film removed in total	0.609	0.206	39.68	0.654	0.191	33.84
	总体去膜 Film removed in total	0.718	0.174	31.87	0.672	0.186	31.59

2.5 模型的综合评价


通过对表 5 和表 6 的综合分析可以发现,3 种机器学习模型对基于光谱反射率和光谱指数来反演土壤盐分均可以达到较好的建模验证效果,且无论是光谱反射率还是光谱指数,通过去膜处理均能使模型的预测效果有所

提升。同时,基于光谱指数建立的盐分估算模型的稳定性整体要优于直接采用光谱反射率建立的盐分模型。从表 5 可以看出基于光谱反射率建立的盐分模型的建模 R^2 大多分布在 0.6~0.7 之间,而验证 R^2 则大多分布于 0.5~0.6 之间,从表 6 可以发现,基于光谱指数建立的盐分模型的

建模 R^2 大多分布在0.6~0.7之间,验证 R^2 同样大多分布于0.6~0.7之间。

基于光谱反射和光谱指数的3种机器学习模型的预测值和实测值比较如图5和图6所示。从图5中可以看出,在5月份,基于光谱反射率的3种机器学习模型的拟合效果相差不多,拟合曲线几乎重合。而在6月份用去膜处理后的数据建立的BP模型和ELM模型的拟合效果明显要优于其他模型,曲线斜率更加接近于1。基

于总体数据建立的3种机器学习模型的决定系数均大于0.6,表现出了较好的拟合效果。从图6可以看出,就5月份和总体的数据而言,基于光谱指数的3种机器学习模型拟合效果相差不多,拟合回归直线近似于重合分布。而以6月份的数据建立的预测模型中,通过去膜处理的ELM模型预测效果最好,拟合方程的决定系数为0.716,未去膜的BP模型预测效果最差,拟合方程的决定系数为0.611。



注: R_1^2 、 R_2^2 、 R_3^2 、 R_4^2 、 R_5^2 和 R_6^2 分别代表数据集去膜前后SVM、BPNN和ELM 3种机器学习模型的确定系数,下同。
Note: R_1^2 , R_2^2 , R_3^2 , R_4^2 , R_5^2 and R_6^2 represent the determination coefficient of the three machine learning models SVM, BPNN and ELM before and after the data set is removed membrane, the same below.

图5 基于机器学习的 光谱反射率反演土壤含盐量预测值与实测值比较

Fig.5 Comparison of measured and predicted SSC by spectral reflectance based on machine learning




图6 基于机器学习的 光谱指数反演土壤含盐量预测值与实测值比较

Fig.6 Comparison of measured and predicted SSC by spectral index based on machine learning

3 讨论

本文研究发现无论是直接提取得到的光谱反射率,还是进一步构建的光谱指数,均能够与实测的土壤含盐量达到良好相关性,对土壤盐渍化的定量分析有一定的指示作用,这与前人的研究基本一致^[16, 26-28],同时发现基于光谱反射率进一步构建光谱指数来反演土壤盐分的整体反演效果优于直接使用光谱反射率反演。Triki等^[29]在突尼斯东南部利用获取的多光谱遥感数据构建光谱指数反演土壤盐分,发现SI3和S3与土壤盐度的相关性最高,而本研究中S3则不是最优指数,可能与试验区域地理位置及取样方法的不同有关。Allbed等^[30]在利用IKONOS高分辨率图像建立基于光谱反射率的土壤盐分综合反演模型来反演试验区盐分的空间变化时,发现可见光波段中的红波段能更好地表征土壤盐分格局和分布特点,而

本研究也发现红光波段与土壤盐分具有较高的相关性。除此之外,通过去膜处理后的数据建立的盐分反演模型整体上相较于原始数据,在模型稳定性及反演效果上均有所提升,印证了在无人机遥感监测领域剔除相应的干扰背景的必要性^[31]。而在不同月份数据的对比上,出现了5月份整体数据建模效果优于6月份但6月份的去膜效果好于5月份的现象,分析原因可能5月份试验区只有裸土和地膜,无其他干扰因素,而在6月份的地膜上已长出部分作物幼苗,使得未去膜地面的光谱反射情况更加复杂,去膜后数据变化幅度更大,去膜效果也就更明显。此外,不少学者在土壤盐渍化遥感监测的研究中均引入机器学习方法来建模验证,并取得了较好的预测效果^[24, 32],但是在无人机遥感领域的应用则相对较少。因此,本文在建模方法上对机器学习算法的应用不仅是对前人研究方法的肯定,同时也是对相关研究领域的必要

补充。

然而,本研究也存在许多不足之处。张同瑞等^[33-34]以黄河三角洲为研究区,基于不同光谱参数构建的盐分估算模型精度的相对误差RE变化范围仅为6.64%~13.64%和18.56%~22.42%。王瑾杰等^[35]利用相对误差RE对艾比湖流域土壤剖面电导率的模型精度进行验证,认为当RE小于30%时,模拟效果较好。而本文研究结果中的建模集和验证集的相对误差RE多集中于20%~40%,相较于其他人的研究出现了偏大的情况。但是,由于野外试验条件的限制以及土壤盐分分布的复杂性,本研究中在数据采集的过程中难免会出现一些误差。同时,土壤盐分数据采集的面积广、无人机传感器飞行的高度高等因素都会产生一定的随机误差,这些误差都会导致最终构建的模型精度低于传统的小区域或近地试验的精度,因此,本文的相对误差针对本研究而言,尚在合理的范围之内,依然具有一定的代表意义。此外,相较于王飞等^[36]和哈学萍等^[37]基于光谱指数构建特征空间来反演土壤盐渍化的方式,本试验缺乏对盐渍化的空间分布监测。此外,单一的多光谱遥感形式的监测也会导致信息收集的不完整,有不少学者已经开始尝试使用多种遥感形式来综合进行盐渍化的监测,逐渐成为了今后的研究重点^[38-39]。最后,由于研究区温度、气候、土壤水分等自然条件的差异,本试验的试验方法以及研究结论是否适用于其它地区的土壤盐渍化状况还有待进一步探讨。

4 结 论

1)农田覆膜会对无人机多光谱遥感反演土壤盐分产生一定的影响,经过去膜处理后的数据构建的模型反演效果要优于原始的数据,基于光谱反射率进一步构建光谱指数来反演土壤含盐量,也可以提高盐分模型的反演精度。其中最佳模型的建模 R^2 和RMSE分别为0.695和0.182,验证 R^2 和RMSE分别为0.717和0.171。

2)基于不同处理的不同月份数据构建的盐分反演模型预测效果不同,基于整体数据构建的模型与各月份数据构建的模型反演效果也有所差异。总体而言5月份的数据构建的模型反演效果最好,其中最佳模型的建模 R^2 和RMSE分别为0.792和0.154,验证 R^2 和RMSE分别为0.641和0.195。6月份数据去膜处理的效果最为明显,其中最佳模型的建模 R^2 和RMSE分别为0.663和0.191,验证 R^2 和RMSE分别为0.716和0.169。

3)比较3种机器学习方法构建的盐分反演模型精度,发现ELM模型的反演效果最好,SVM模型效果次之,BPNN模型反演效果相对较差。但3种模型均可在一定程度上对土壤盐分取得不错的反演效果,表明这3种机器学习方法在无人机多光谱遥感监测农田土壤含盐量方面均具有一定的适用性。

[参 考 文 献]

- [1] 王静,刘湘南,黄方,等. 基于ANN技术和高光谱遥感的盐渍土盐分预测[J]. 农业工程学报, 2009, 25(12): 161—166.
Wang Jing, Liu Xiangnan, Huang Fang, et al. Salinity forecasting of saline soil based on ANN and hyperspectral remote sensing[J]. Transactions of the Chinese Society of Agricultural Engineering, 2009, 25(12): 161—166. (in Chinese with English abstract)
- [2] Metternicht G I, Zinck J A. Remote sensing of soil salinity: Potentials and constraints[J]. Remote Sensing of Environment, 2003, 85(1): 1—20.
- [3] 史舟,梁宗正,杨媛媛,等. 农业遥感研究现状与展望[J]. 农业机械学报, 2015, 46(2): 247—260.
Shi Zhou, Liang Zongzheng, Yang Yuanyuan, et al. Status and prospect of agricultural remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(2): 247—260. (in Chinese with English abstract)
- [4] 彭杰,刘焕军,史舟,等. 盐渍化土壤光谱特征的区域异质性及盐分反演[J]. 农业工程学报, 2014, 30(17): 167—174.
Peng Jie, Liu Huanjun, Shi Zhou, et al. Regional heterogeneity of hyperspectral characteristics of salt-affected soil and salinity inversion[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2014, 30(17): 167—174. (in Chinese with English abstract)
- [5] Dehaan R L, Taylor G R. Field-derived spectra of salinized soils and vegetation as indicators of irrigation-induced soil salinization[J]. Remote Sensing of Environment, 2002, 80(3): 406—417.
- [6] Rao B R M, Sharma R C, Ravi Sanker T, et al. Spectral behaviour of salt-affected soils[J]. International Journal of Remote Sensing, 1995, 16(12): 2125—2136.
- [7] Farifteh J, Vander Meer F, Carranza E J M. Similarity measures for spectral discrimination of salt-affected soils[J]. International Journal of Remote Sensing, 2007, 28(23): 5273—5293.
- [8] Srivastava R, Sethi M, Yadav R K, et al. Visible-near infrared reflectance spectroscopy for rapid characterization of salt-affected soil in the indo-gangetic plains of Haryana, India[J]. Journal of the Indian Society of Remote Sensing, 2017, 45(2): 307—315.
- [9] 卢霞. 滨海盐土盐分含量与其光谱特征的关系研究[J]. 水土保持通报, 2012, 32(5): 186—190.
Lu Xia. Relationship between saline concentration and its reflectance spectra for seashore saline soil[J]. Bulletin of Soil and Water Conservation, 2012, 32(5): 186—190. (in Chinese with English abstract)
- [10] 张晓光,黄标,季峻峰,等. 基于可见近红外高光谱的东北盐渍土盐分定量模型研究[J]. 光谱学与光谱分析, 2012, 32(8): 2075—2079.
Zhang Xiaoguang, Huang Biao, Ji Junfeng, et al. Quantitative prediction of soil salinity content with visible-near infrared hyperspectra in northeast china[J]. Spectroscopy and Spectral Analysis, 2012, 32(8): 2075—2079. (in Chinese with English abstract)
- [11] Allbed A, Kumar L, Aldakheel Y Y. Assessing soil salinity using soil salinity and vegetation indices derived from IKONOS high-spatial resolution imageries: Applications in a date palm dominated region[J]. Geoderma, 2014, 230—231: 1—8.
- [12] 姚远,丁建丽,张芳,等. 基于高光谱指数和电磁感应技术的区域土壤盐渍化监测模型[J]. 光谱学与光谱分析, 2013(6): 1658—1664.
Yao Yuan, Ding Jianli, Zhang Fang, et al. Research on model of soil salinization monitoring based on hyperspectral index and EM38[J]. Spectroscopy and Spectral Analysis, 2013(6): 1658—1664. (in Chinese with English abstract)

- [13] 郭鹏,李华,陈红艳,等. 基于光谱指数优选的土壤盐分定量光谱估测[J]. 水土保持通报, 2018, 38(3): 193—199.
Guo Peng, Li Hua, Chen Hongyan, et al. Quantitative spectral estimation of soil salinity based on optimum spectral indices[J]. Bulletin of Soil and Water Conservation, 2018, 38(3): 193—199. (in Chinese with English abstract)
- [14] 梁建财,李瑞平,史海滨,等. 河套灌区覆盖对盐渍土壤养分迁移与分布的影响[J]. 农业机械学报, 2016, 47(2): 113—121.
Liang Jiancai, Li Ruiping, Shi Haibin, et al. Effect of mulching on transfer and distribution of salinized soil nutrient in hetao irrigation district[J]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(2): 113—121. (in Chinese with English abstract)
- [15] 赵英时. 遥感应用分析原理与方法, 第二版[M]. 北京: 科学出版社, 2003.
- [16] 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, Lu Lingjiao, et al. Soil salinity distribution based on remote sensing and its effect on crop growth in Hetao Irrigation District[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2018, 34(1): 102—109. (in Chinese with English abstract)
- [17] Allbed A, Kumar L. Soil salinity mapping and monitoring in arid and semi-arid regions using remote sensing technology: A review [J]. Advances in Remote Sensing, 2013, 2(4): 373—385.
- [18] Taghadosi M M, Hasanlou M, Eftekhari K. Retrieval of soil salinity from Sentinel-2 multispectral imagery[J]. European Journal of Remote Sensing, 2019, 52(1): 138—154.
- [19] Abbas A, Khan S. Using Remote Sensing Techniques for Appraisal of Irrigated Soil Salinity[C]. International Congress on Modelling and Simulation (MODSIM), Modelling and Simulation Society of Australia and New Zealand Brighton, 2007: 2632-2638.
- [20] Douaoui A E K, Nicolas H, Walter C. Detecting salinity hazards within a semiarid context by means of combining soil and remote-sensing data[J]. Geoderma, 2006, 134(1/2): 217—230.
- [21] Chen J M. Evaluation of vegetation indices and a modified simple ratio for boreal applications[J]. Canadian Journal of Remote Sensing, 1996, 22(3): 229—242.
- [22] Khan N M, Rastoskuev V 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(1/2/3): 96—109.
- [23] 李运. 机器学习算法在数据挖掘中的应用[D]. 北京: 北京邮电大学, 2015.
Li Yun. Application of Machine Learning Algorithms in Data Mining[D]. Beijing: Beijing University of Posts and Telecommunications, 2015(in Chinese with English abstract).
- [24] 姜红,玉素甫江·如素力,热伊莱·卡得尔,等. 基于神经网络模型的干旱区绿洲土壤盐渍化评价分析[J]. 地球信息科学学报, 2017, 19(7): 983—993.
Jiang Hong, Yusufjiang Rusuli, Reyilai Kadeer, et al. Evaluation and analysis of soil salinization in the arid zones based on neural network model[J]. Journal of Geo-information Science, 2017, 19(7): 983—993. (in Chinese with English abstract)
- [25] Csillag F, Pasztor L, Biehl L L. Spectral band selection for the characterization of salinity status of soils[J]. Remote Sensing of Environment, 1993, 43(3): 231—242.
- [26] Farifteh, Meer V D, Atzberger, 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.
- [27] Bouaziz, Moncef, Matschullat, et al. Improved remote sensing detection of soil salinity from a semi-arid climate in Northeast Brazil [J]. Comptes Rendus Geosciences, 2011, 343(11): 795—803.
- [28] Wang H, Chen Y, Zhang Z, et al. Quantitatively estimating main soil water-soluble saltions content based on Visible-near infrared wavelength selected using GC, SR and VIP[J]. PeerJ, 2019, 7: e6310.
- [29] Triki Fourati H, Bouaziz M, Benzina M, et al. Modeling of soil salinity within a semi-arid region using spectral analysis[J]. Arabian Journal of Geosciences, 2015, 8(12): 11175—11182.
- [30] Allbed A, Kumar L, Sinha P. Mapping and modelling spatial variation in soil salinity in the Al Hassa Oasis based on remote sensing indicators and regression techniques[J]. Remote Sensing, 2014, 6(2): 1137—1157.
- [31] 张智韬,边江,韩文霆,等. 剔除土壤背景的棉花水分胁迫无人机热红外遥感诊断[J]. 农业机械学报, 2018, 49(10): 257—267.
Zhang Zhitao, Bian Jiang, Han Wenting, et al. Unmanned aerial vehicle(UAV) thermal infrared diagnostic cotton water stress after removing soil background[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(10): 257—267. (in Chinese with English abstract)
- [32] 王海江,蒋天池,Yunger Tohn A,等. 基于支持向量机的土壤主要盐离子高光谱反演模型[J]. 农业机械学报, 2018, 50(5): 263—270.
Wang Haijiang, Jiang Tianchi, Yunger Tohn A, et al. Hyperspectral inverse model for soil salt ions based on support vector machine[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 50(5): 263—270. (in Chinese with English abstract)
- [33] 张同瑞,赵庚星,高明秀,等. 基于近地面多光谱的黄河三角洲典型地区土壤含盐量估算研究[J]. 光谱学与光谱分析, 2016(1): 248—253.
Zhang Tongrui, Zhao Gengxing, Gao Mingxiu, et al. Soil salinity estimation based on near-ground multispectral imagery in typical area of the Yellow River Delta[J]. Spectroscopy and Spectral Analysis, 2016(1): 248—253. (in Chinese with English abstract)
- [34] 张同瑞,赵庚星,高明秀,等. 基于近地面多光谱和OLI影像的黄河三角洲冬小麦种植区盐分估算及遥感反演—以山东省垦利县和无棣县为例[J]. 自然资源学报, 2016, 31(6): 1051—1060.
Zhang Tongrui, Zhao Gengxing, Gao Mingxiu, et al. Soil salinity estimation and remote sensing inversion based on near-ground multispectral and TM imagery in winter wheat growing area in the yellow river delta-Case study in Kenli county and Wudi county, Shandong province[J]. Journal of Natural Resources, 2016, 31(6): 1051—1060. (in Chinese with English abstract)
- [35] 王瑾杰,丁建丽,张喆,等. 基于多源遥感数据的艾比湖流域盐土 SWAT 模型参数修正[J]. 农业工程学报, 2017, 33(23): 139—144.
Wang Jinjie, Ding Jianli, Zhang Zhe, et al. SWAT model parameters correction based on multi-source remote sensing data in sa-

- line soil in Ebinur Lake Watershed[J]. Transactions of the Chinese Society of Agricultural Engineering, 2017, 33(23): 139—144. (in Chinese with English abstract)
- [36] 王飞,丁建丽,伍漫春,等. 基于NDVI—SI特征空间的土壤盐渍化遥感模型[J]. 农业工程学报, 2010, 26(8): 168—173.
Wang Fei, Ding Jianli, Wu Manchun, et al. Remote sensing monitoring models of soil salinization based on NDVI-SI feature space [J]. Transactions of the Chinese Society of Agricultural Engineering, 2010, 26(8): 168—173. (in Chinese with English abstract)
- [37] 哈学萍,丁建丽,塔西甫拉提·特依拜,等. 基于SI—Albedo特征空间的干旱区盐渍化土壤信息提取研究—以克里雅河流域绿洲为例[J]. 土壤学报, 2009, 56(3): 381—390.
Ha Xueping, Ding Jianli, Tashpolat·Tiyip, et al. SI-Albedo space-based extraction of salinization information in arid area[J]. Acta pedologica Sinica, 2009, 56(3): 381—390. (in Chinese with English abstract)
- [38] Ivushkin K, Bartholomeus H, Bregt A K, et al. UAV based soil salinity assessment of cropland[J]. Geoderma, 2018, 38: 502—512.
- [39] 冯雪力,刘全明. 基于多源遥感协同反演的区域性土壤盐渍化监测[J]. 农业机械学报, 2018, 49(7): 127—133.
Feng Xueli, Liu Quanming. Regional soil salinity monitoring based on multi-source collaborative remote sensing data[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(7): 127—133. (in Chinese with English abstract)

Effect of plastic film mulching on soil salinity inversion by using UAV multispectral remote sensing

Yao Zhihua^{1,2}, Chen Junying^{1,2*}, Zhang Zhitao^{1,2}, Tan Chengxuan^{1,2}, Wei Guangfei¹, Wang Xintao¹

(1. College of Water Resources and Architectural Engineering, Key Laboratory of Agricultural Soil and Water Engineering in Arid Areas Subordinated to the Ministry of Education, Northwest A&F University, Yangling 712100, China; 2. Institute of Water Saving Agriculture in Arid Regions of China, Northwest A&F University, Yangling 712100, China)

Abstract: Estimating soil salinity is imperative for scheduling irrigation and remediating saline soil but difficult at large scales. Remote sensing can bridge this gap because of its advantages in low cost and large-area coverage; it has become an efficient method for assessing soil salinization in field. One issue in use of remote sensing to assess saline soil is the presence of plastic film mulch and bare soil because of their difference in reflecting waves in the spectral bands. In order to investigate the effect of plastic film mulch on soil salinity inversion using UAV multispectral remote sensing, we studied four plots with plastic film mulch at the Shahaoqu Irrigation area in the Hetao Irrigation District, Inner Mongolia of China. From each plot, we took soil samples and measured their salt contents from May to July. We also flew a drone to simultaneously take multispectral images of the sampling sites and extracted the spectral reflectance to calculate the spectral indices. Correlation analysis found that the S4, S6, SI1, SI2, SI3 and BI indices can be used to calculate soil salinity. Six-band spectral reflectances and six spectral indices obtained from different datasets were used as independent variables to calculate the salt content with the support vector machine (SVM), the back propagation neural network (BPNN) and the extreme learning machine (ELM), respectively, before and after the mulch film was removed. We compared the three models based on their determination coefficient (R^2), root mean squared error (RMSE) and relative error (RE). The results showed that plastic film mulch did impact on soil salinity inversion. Although all three models could adequately estimate the soil salt contents before and after the film removal, they worked better after the film removal than before the film removal. Models based on the spectral indices were more accurate than those based on the spectral reflectances, and the accuracy of the inversely calculated salt content varied with sampling time and treatment. The inversion results based on monthly data differed from those based on by pooling all data. After the film was removed in June, the salt content estimated using the model was most accurate, with its associated R^2 and RMSE being 0.695 and 0.182 respectively for the spectral reflectance-based method, and 0.663 and 0.191 respectively for the spectral indices-based method. The salt content estimated by BPNN was least accurate in May, with its associated R^2 and RMSE being 0.766 and 0.161 respectively for the spectral reflectance-based method, and 0.769, 0.162 respectively for the spectral indices-based method. Comparison of the three models revealed that ELM was most accurate, followed by SVM and BPNN, although their errors were within the tolerable range. In summary, this paper provides an effective method to inversely calculate soil salinization at large mulched farmland using UAV multispectral remote sensing.

Keywords: remote sensing; soil salt; spectral reflectance; spectral index; machine learning