doi:10.6041/j.issn.1000-1298.2026.18.032

基于热点效应融合多角度信息新指数的植被覆盖下不同深度土壤含盐量估计

张智韬[1,2]　叶苏蒙[1,3]　陈俊英[1,2]　李子龙[1,3]　经思思[1,3]　白旭乾[1,3]
钱　龙[1,3]　杨晓飞[1,3]　刘彦甫[1,3]

(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. 旱区农业新疆研究院, 乌鲁木齐 830091; 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: 及时、准确、高效监测土壤含盐量(Soil salt content, SSC),对于实现盐渍化治理至关重要。针对基于单一正射影像的土壤含盐量监测模型在作物覆盖条件下精度不足问题,本研究基于冠层光谱二向反射特性的热点效应可增强光谱信息理论,提出融合正射、热点和暗点 3 个观测方向的光谱数据,构建新指数提高不同土壤深度下含盐量监测精度。采集研究区 3 块试验地空中和田间数据,构建 8 种不同类型新指数,并与 14 种常用光谱指数进行对比,通过皮尔逊相关系数法评估新建指数应用潜力。基于特征权重算法(Resampling and feature elimination, Relief)与主成分分析(Principal component analysis, PCA)相结合方法筛选特征变量数量,采用广义回归神经网络(General regression neural network, GRNN)、随机森林(Random forest, RF)和极限梯度提升(Extreme gradient boosting, XGBOOST)3 种机器学习算法构建 4 个不同土壤深度下土壤含盐量估计模型,通过决定系数(Coefficient of determination, R^2)、均方根误差(Root mean square error, RMSE)和平均绝对误差(Mean absolute error, MAE)评估模型性能。结果表明:对不同土壤深度,新建指数相较光谱指数与含盐量的相关性更强,最大相关性系数绝对值分别提升 44.0%、72.9%、70.0% 和 67.7%。基于 Relief 和 PCA 结合的特征筛选,可有效剔除冗余信息,减少变量数量,提高模型效率。表层 0~10 cm 和 10~20 cm 模型精度远高于 20~40 cm 和 40~60 cm,最佳估计深度出现在 10~20 cm。GRNN 算法在不同土壤深度下表现均优于 RF 和 XG-BOOST 算法,在最佳深度下,GRNN 算法构建模型测试集 R^2 为 0.802,RMSE 为 0.046%,MAE 为 0.032%。研究结果为监测作物覆盖下不同深度土壤含盐量提供了新思路。

关键词: 土壤含盐量; 多角度光谱信息; 特征筛选; 机器学习

中图分类号: S156.4　　**文献标识码**: A　　**文章编号**: 1000-1298(2026)18-0373-12　　**OSID**:

Estimation of Soil Salinity at Different Depths under Vegetation Cover Using New Index Fused with Multi-angle Information Based on Hotspot Effect

Zhang Zhitao[1,2]　Ye Sumeng[1,3]　Chen Junying[1,2]　Li Zilong[1,3]　Jing Sisi[1,3]　Bai Xuqian[1,3]
Qian Long[1,3]　Yang Xiaofei[1,3]　Liu Yanfu[1,3]

(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. *Xinjiang Research Institute of Agriculture in Arid Areas, Urumqi* 830091, *China*
3. *College of Water Resources and Architectural Engineering, Northwest A&F University, Yangling, Shaanxi* 712100, *China*)

Abstract: Timely, accurate and efficient monitoring of soil salt content (SSC) is critical for the implementation of salinization remediation. Aiming at the insufficient accuracy of SSC estimation models established solely using nadir-view images under crop coverage conditions, relied on the theory that the hotspot effect within the bidirectional reflectance characteristics of canopy spectra can strengthen spectral information, a novel index integrating spectral data from three observation directions (nadir, hotspot and darkspot) was proposed to improve the estimation accuracy of soil salt content at various soil depths. Aerial and field datasets were collected from three experimental plots in the study area, based on which

收稿日期: 2025-06-24　修回日期: 2025-09-02

基金项目: 国家自然科学基金项目(52279047、52179044)和国家重点研发计划项目(2022YFD1900404)

作者简介: 张智韬(1976—),男,教授,博士,主要从事遥感技术在农业水土工程的应用研究,E-mail: zhitaozhang@126.com

eight indices of different types were constructed and further compared with 14 commonly used spectral indices. The Pearson correlation coefficient was adopted to evaluate the application potential of the newly developed indices. Subsequently, a hybrid feature screening method combining the resampling and feature elimination (Relief) algorithm and principal component analysis (PCA) was used to filter feature variables. Three machine learning algorithms, namely general regression neural network (GRNN), random forest (RF) and extreme gradient boosting (XG - BOOST), were employed to establish SSC estimation models corresponding to four distinct soil layers. Finally, the coefficient of determination (R^2)), root mean square error (RMSE) and mean absolute error (MAE) were utilized to quantify model performance. The results revealed that the newly constructed indices exhibited stronger correlations with soil salt content than conventional spectral indices across all soil depths. The maximum absolute values of correlation coefficients were increased by 44.0%, 72.9%, 70.0% and 67.7%, respectively. The Relief - PCA combined feature selection strategy effectively eliminated redundant information, reduced the number of input variables and accelerated model operation efficiency. Model accuracy for the topsoil layers of 0 ~ 10 cm and 10 ~ 20 cm was markedly higher than that for the 20 ~ 40 cm and 40 ~ 60 cm layers, with the optimal estimation depth identified as 10 ~ 20 cm. GRNN outperformed RF and XG - BOOST at all measured soil depths. At the optimal depth, the GRNN model achieved a test set R^2 of 0.802, an RMSE of 0.046% and an MAE of 0.032%. The research result can provide a novel strategy for estimating soil salt content at multiple depths under crop canopy coverage.

Key words: soil salt content; multi-angle spectral information; feature selection; machine learning

0 引言

土壤盐渍化是导致土壤退化、降低农业生产水平和破坏生态环境的重要全球性问题[1]。中国主要粮食产区之一的内蒙河套灌区,受气候、生态、黄河水长期超调灌溉以及不合理的灌溉方式综合作用,耕地普遍存在严重的原生盐渍化和次生盐渍化并存现象[2]。因此,及时、准确、高效地监测土壤含盐量(Soil salt content, SSC),对于盐碱地改良、粮食安全保障和生态修复具有重要意义。

实地采样测量方法耗时耗力,难以满足大范围同步监测需求。遥感技术的不断发展有效弥补了传统监测方法的一系列不足,在土壤盐渍化监测中得到广泛应用[3-4]。卫星遥感虽具有广域性和连续性监测优势,能够快速获取大范围土壤盐分信息,但卫星图像的低空间分辨率以及图像获取的周期性限制和卫星过境时天气的不可测性,限制了在 SSC 精细化监测中应用。近年来,无人机凭借低成本、实时监测与反馈、高分辨率图像获取等优势在土壤盐渍化监测中得到广泛关注。张智韬等[5]利用多光谱无人机遥感数据建立了不同植被覆盖度下不同深度 SSC 监测模型;向友珍等[6]结合多光谱无人机遥感图像的纹理特征与光谱指数,提升了表层 SSC 监测精度;Cui 等[7]利用无人机多光谱影像提出了一种快速的农田土壤盐渍化时间序列监测方法。尽管无人机多光谱监测 SSC 的研究相较于卫星具有更好表现,但仍难以满足定量遥感的高精度要求,且主要研究都是基于正射观测开展,而多角度观测对农田 SSC 监测的影响尚未充分探索。

现有研究基于光谱信息的直接运用或组合变换,发展出 2 类主要的 SSC 监测模型构建方法:经验公式法和机器学习法。经验公式法通过统计分析方法建立光谱特征与 SSC 之间线性关系,主要包括 2 种实现方式:①单、多波段回归:选择与 SSC 相关性高的波段(如红波段、近红外波段和短波红外波段)直接建立回归模型。基于此,有研究利用陆地卫星 ETM7 波段预测 SSC(R^2 为 0.48),或采用双波段线性回归估算 SSC(R^2 为 0.32)[8]。这类方法虽简单易行,但精度较低。②光谱指数法:基于盐渍土在特定波段(如 505、920、1 415 nm 等)的光谱吸收特性[9],构建专门的盐度指数监测 SSC,研究表明,这些指数在干旱区土壤盐分监测中表现良好[10]。为提高精度,后续研究还尝试用红边波段替代红光波段构建新型光谱指数[11]。然而,经验公式法本质上依赖线性假设,难以充分表征土壤含盐量与光谱特征之间的复杂非线性关系。机器学习法因出色的非线性建模能力,近年来在 SSC 监测中得到广泛应用[12-13],然而机器学习算法性能高度依赖输入变量质量,过多自变量会造成信息冗余,从而降低模型构建效率和监测精度,因此,结合特征选择与机器学习算法构建 SSC 监测模型在农田定量遥感研究中具有更大应用潜力。

目前对于土壤含盐量的研究主要集中在裸土和作物覆盖土地,作物覆盖下含盐量预测更具有挑战。与裸土不同,作物冠层光谱信息受混合像元影响,包含阳光照射裸土、阴影裸土、阳光照射植被和阴影植被等多源光学信息,在一定程度上会降低作物覆盖下 SSC 监测精度。作物冠层光谱反射率会随着观

测视角变化而产生变化，同一时间，同一地点，不同观测视角会导致观测视场内作物和土壤信息比例变化，而这些变化会导致阴影隐藏和相干反向散射，会通过植被二向反射引起热点效应，最终对获取的冠层光谱信息产生影响[14]。相较于正射影像所获取的光谱信息，倾斜观测角度包含更多的冠层光谱和植被生理特性信息[15-16]。在所有倾斜观测角度中，存在热点和暗点 2 个特殊观测角度，暗点凭借最大阴影覆盖，导致在反射率上呈现最小值。而热点观测方向与太阳光线一致从而可获得最大反射率，同时作为冠层二向反射分布的热点区域，所包含的光谱信息最为丰富，利用热点信息或者基于热点效应利用热暗点信息构建光谱指数可有效估计作物叶面积指数、生物量等参数。因此，结合多角度观测的光谱特征，有望提升作物覆盖下 SSC 监测精度。

综上，本研究基于热点效应，融合正射、暗点和热点 3 个观测方向下光谱信息构建新指数，以期降低叶绿素和含水率对盐分监测影响，并结合特征选择和 3 种机器学习算法构建作物覆盖下 4 个不同深度土壤含盐量反演模型。基于热点效应，融合多角度观测光谱信息，考虑所有可能组合，构建 8 类新指数，并评估其在不同深度土壤含盐量监测中的可行性。基于特征权重算法（Resampling and feature elimination，Relief）与主成分分析（Principal component analysis，PCA）结合的特征筛选方法选择不同深度下最佳特征组合。分析不同机器学习算法在不同深度下监测土壤含盐量的表现差异，以期寻找最佳监测深度以及最佳算法。

1　材料和方法

1.1　研究区概况

研究区位于内蒙古西部解放闸灌域（图 1），该区域位于 40°52′～41°0′N，106°05′～107°05′E 之间，属于典型温带大陆性气候，夏季高温干旱，冬季严寒少雪，降水稀少，蒸发强度大。年均降水量 100～250 mm，蒸发量高达 2 400 mm。研究区北部土壤以粉质土、壤土和粘壤土为主，南部土壤以粘壤土为主，区域内主要农作物为向日葵，夹杂少量其他类型作物。由于地表坡度平缓，地下水径流不足，地表蒸发强烈以及农业灌溉的不合理性，导致该地区土地受到不同程度的盐渍化以及次生盐渍化影响，严重制约当地农业生产的健康可持续发展。

1.2　试验数据采集与预处理

1.2.1　田间数据获取与分析

试验于 2023 年 7 月 19—23 日进行。对解放闸灌域实地调研后，根据土壤盐渍化程度，选择 3 块具有不同梯度盐分分布试验地，并依次编号，分别为：1 号试验地（0.095%～0.316%）、2 号试验地（0.282%～0.650%）、3 号试验地（0.534%～1.116%）。1 号试验地面积约为 4.06 hm^2，2 号试验地面积约为 3.83 hm^2，3 号试验地面积约为 4.71 hm^2（图 1b～1d）。每块试验地均匀布设 30 个采样点，共计 90 个采样点。采样点均选在有植被覆盖区域内，1 号试验地中有 4 个采样点为玉米覆盖，其他均为向日葵覆盖，3 块试验地采样点平均覆盖度略有差异。

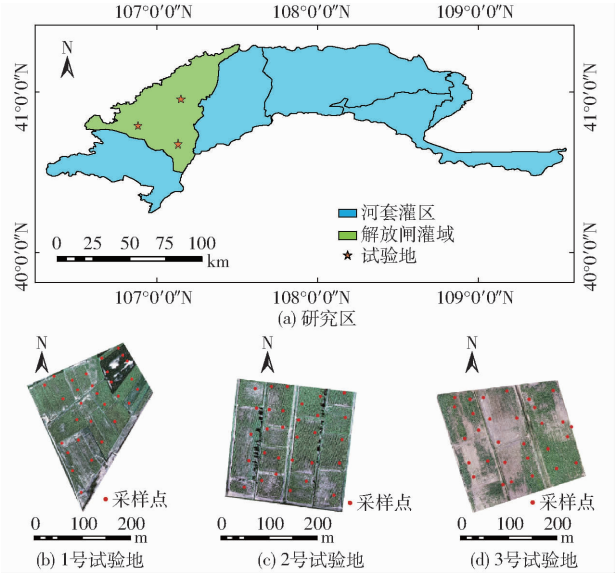

图 1　研究区示意图

Fig. 1　Schematic of study area

为保证试验准确与可靠性，采样时间与无人机飞行时间保持在同一天。为确保采样均匀性，采用 5 点法采集 0～10 cm、10～20 cm、20～40 cm 和 40～60 cm 4 个不同深度土壤，并放入铝盒中（已知铝盒质量），标记后迅速称量。同时在 5 点采样的中心位置，利用中海达 RTK 记录每个采样点地理位置信息。

取回土样在干燥箱中 105°干燥 8 h 后进行称量，冷却后研磨成颗粒直径大约为 1 mm 粉末。然后取 20 g 土样与 100 mL 蒸馏水配置成土壤溶液。随后经过玻璃棒搅拌，充分静置、沉淀和过滤后，使用电导率仪（DDS-307A 型）测量上清液，仪器所读数值为土壤溶液电导率（EC1:5，μS/cm），根据当地经验公式换算为土壤含盐量（SSC，%）[17]，计算式为

$$SSC = 0.288\,2EC_{1:5} + 0.018\,3 \tag{1}$$

式中　$EC_{1:5}$——土壤电导率

1.2.2　光谱数据采集与处理

（1）仪器选择

试验采用大疆精灵 4 多光谱版无人机，搭载 1

个多光谱相机(图 2b、2c),配有 5 个光谱通道:蓝(450 nm)、绿(560 nm)、红(650 nm)、红边(730 nm)和近红外(840 nm)。相机焦距为 5.74 mm,航向重叠率为 80%,旁向重叠率为 70%。飞行高度 90 m 所对应的图像空间分辨率为 5.85 cm×5.85 cm。

(2)航线设定

飞行时天气晴朗无风,阳光充足。每次飞行选择 3 条航线:正射、热点以及暗点观测方向(图 2a)。本试验中热点为观测天顶角为 -30°时观测方向,暗点为观测天顶角为 30°时观测方向。为减少飞行时间内太阳高度角和太阳方位角变化对反射率的影响,飞行时间选择在当天太阳高度角为 60°前后展开。所有航线飞行高度均保持 90 m,所获得多光谱图像均保存为 TIFF 格式。

(3)图像处理

将预处理后单波段多光谱遥感影像依次放入 ENVI 5.6 中,分别导入采样点 GPS 信息,确定所在像元点位置,并依次提取 5 个波段下像元点以及在试验地中灰布灰度,最后将不同采样点对应像元灰度转换成相应的反射率。

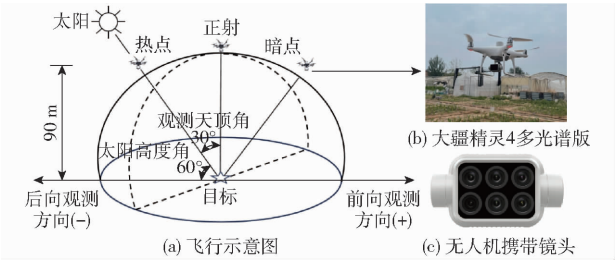

图 2 飞行示意图和无人机

Fig. 2 Flight schematic and DJI Phantom 4 multispectral UAV

1.3 指数构建

1.3.1 植被指数与盐分指数选取

获取的波段反射率可通过不同组合以及运算得到多种类型光谱指数,分别选取 7 个常用植被指数和 7 个常用盐分指数(表 1)。

表 1 植被指数和盐分指数

Tab. 1 Vegetation indices and salinity indices

光谱指数	公式	文献序号
归一化植被指数(NDVI)	$NDVI=(NIR-R)/(NIR+R)$	[18]
差异化植被指数(DVI)	$DVI=NIR-R$	[19]
大气阻抗植被指数(ARVI)	$ARVI=(NIR-2R+B)/(NIR+2R+B)$	[20]
增强型植被指数(EVI)	$EVI=2.5[(NIR-R)/(NIR+6R-7.5B+1)]$	[21]
绿光归一化植被指数(GNDVI)	$GNDVI=(G-B)/(G+B)$	[22]
植被衰减指数(PSRI)	$PSRI=(B-R)/R$	[23]
归一化岩石指数(NDRI)	$NDRI=(NIR-RE)/(NIR+RE)$	[24]
盐分指数(SI)	$SI=(BR)^{0.5}$	[25]
盐分指数(SI1)	$SI_1=(GR)^{0.5}$	[25]
盐分指数(SI2)	$SI_2=(G^2+R^2+NIR^2)^{0.5}$	[25]
盐分指数(SI3)	$SI_3=(G^2+R^2)^{0.5}$	[25]
盐分指数(S1)	$S_1=B/G$	[25]
盐分指数(S2)	$S_2=(B-R)/(B+R)$	[25]
盐分指数(S3)	$S_3=GR/B$	[25]

注:B 表示蓝光波段反射率,G 表示绿光波段反射率,R 表示红光波段反射率,RE 表示红边波段反射率,NIR 表示近红外波段反射率。

1.3.2 新指数构建

光谱指数均由同一观测方向下反射率构建,为充分利用正射、热点和暗点观测方向所蕴藏的光谱信息,分别构建 4 类热暗点指数(HDI,HDI_1 ~ HDI_4)和 4 类热暗正指数(HDNI,$HDNI_1$ ~ $HDNI_4$),每种类型所有可能的组合借助 Python 3.11 实现,表达式为

$$HDI_1=R_H-R_D \tag{2}$$

$$HDI_2=R_H/R_D \tag{3}$$

$$HDI_3=R_H/(R_H-R_D) \tag{4}$$

$$HDI_4=(R_H-R_D)/(R_H+R_D) \tag{5}$$

$$HDNI_1=(R_H-R_D)/(R_D+R_N) \tag{6}$$

$$HDNI_2=R_H/(R_D+R_N) \tag{7}$$

$$HDNI_3=R_H/(R_DR_N) \tag{8}$$

$$HDNI_4=(R_H-R_D)/(R_H+R_D+R_N) \tag{9}$$

式中 R_H——热点观测方向下不同波段反射率

R_D——暗点观测方向下不同波段反射率

R_N——正射观测方向下不同波段反射率

1.4 数据分析

1.4.1 统计分析

为分析不同深度下数据离散程度以及数据分布状态,采用 3 类常用统计指标:标准差(Standard deviation, SD)、变异系数(Coefficient of variation, CV)和 Pearson 偏斜度[7,26]。SD 适合判断数据集中每个数据点与平均值的离散程度,CV 适用于比较具

有不同单位或平均值数据集间差异。一般当 SD 大于 0.01 且 CV 为 10% ~100% 时，认为数据具有较好的分散程度。Pearson 偏斜度表示数据相对于平均值的不对称程度。

1.4.2　相关性分析

为分析新建指数对不同深度含盐量的预测潜力以及比较不同深度下新建指数与植被指数和盐分指数预测性能之间的差异，利用皮尔逊相关系数法分析变量之间的相关性[27]。

1.4.3　特征选择

合适的特征变量数量不仅能提高数据适用性，同时节约模型计算成本，消除不必要噪声，提高模型构建效率。因此采用 Relief 算法计算所有新建特征变量在不同深度下重要性权重，并基于特征重要性权重选择前 5% 特征作为主成分分析对象。利用 Matlab 中 pca(x)函数对重要性排序为前 5% 的新建指数进行主成分分析，选取累计贡献率为 95% 以上的主成分所对应的特征变量作为模型最终输入变量[28]。

1.5　模型构建

选用随机森林(Random forest, RF)、极限梯度提升(Extreme gradient boosting, XG - BOOST)和广义回归神经网络(General regression neural network, GRNN)3 种机器学习算法分别构建 4 个不同深度含盐量反演模型，每个深度下样本数量均为 90 个，为使训练集和测试集数据分布更加均匀且具有一定代表性，随机将训练集和测试集按比例 2∶1 划分，采用三折交叉验证保证模型稳定性。

1.6　模型评价

不同深度含盐量反演模型性能通过验证集决定系数(Coefficient of determination, R^2)、均方根误差(Root mean square error, RMSE)和平均绝对误差(Mean absolute error, MAE)进行评估，当 R^2 越接近 1，RMSE 和 MAE 越接近 0，模型精度越高[29]。

2　结果与分析

2.1　土壤含盐量统计特征

将不同深度采样点含盐量数据绘制成箱型图(图 3)，并按照土壤盐渍化等级分类标准划分为 4 个等级：非盐土(SSC < 0.2%)、轻度盐渍化土(0.2% ≤SSC <0.5%)、重度盐渍化土(0.5% ≤SSC < 1.0%)、盐土(SSC≥1.0%)。浅层主要为非盐土和轻度盐渍化土，深层主要为轻度和重度盐渍化土，各深度含盐量平均值分别为 0.257%、0.300%、0.369% 和 0.464%，在轻度盐渍化范围内且与深度呈正比。不同深度含盐量统计特征见图 3 左上方表，不同深度下 SD 和 CV 分别为 0.088 ~0.196 和 32.8% ~42.1%，表明不同深度下数据集具有足够离散度构建模型。虽然不同深度下数据集偏斜度均大于 0，呈现正偏态(表明平均值右侧属于重度盐土和盐土区间的值较少)，但与实际情况表现一致，仍然适合模型构建。

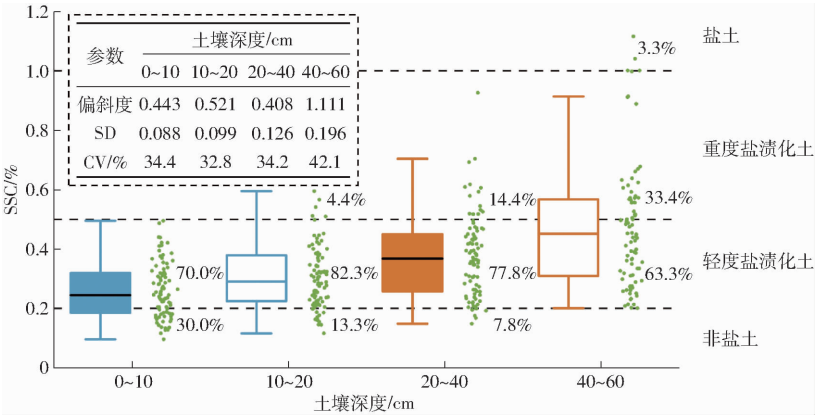

图 3　不同土壤深度含盐量分布箱型图以及数据集描述性统计

Fig. 3　Box plot of SSC distribution at different depths and descriptive statistics of dataset

2.2　指数与土壤含盐量相关性分析

2.2.1　光谱指数与含盐量相关性分析

图 4 为不同土壤深度不同观测角度下含盐量与植被指数和盐分指数之间的相关性，热图颜色越偏向红色且越深，正相关性越强，越偏向蓝色且越深，负相关性越强。4 个不同深度下，植被指数和含盐量的相关性在热点观测方向大于正射和暗点观测方向，但盐分指数和含盐量相关性在 3 个不同观测角度下未显现明确的变化规律。前 3 个深度下，植被指数与含盐量相关性整体优于盐分指数与含盐量相关性，而在深度 40 ~60 cm 下，呈现相反规律。4 个深度下光谱指数与含盐量最大相关性均出现在热点观测方向，相关系数分别为 - 0.50(GNDVI)、- 0.48(NDVI)、- 0.30(NDVI)和 0.30(SI)、0.31(PSRI)，相较于正射观测方向，与含盐量相关性分别提升 66.7%、45.5%、57.9% 和 24.0%。

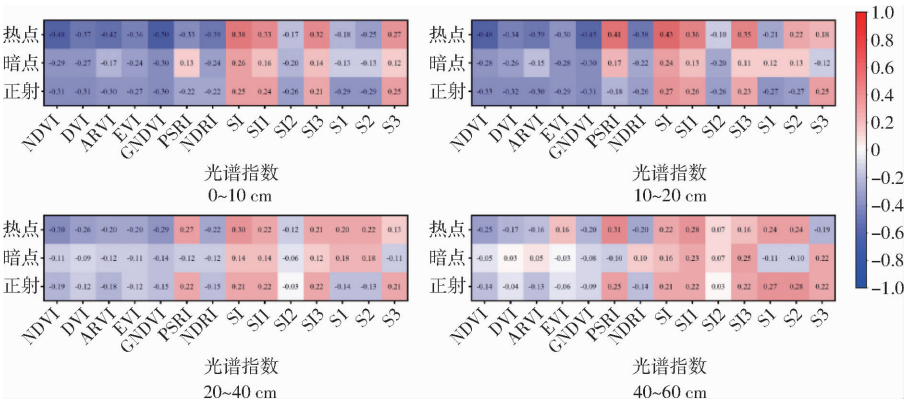

图 4 不同土壤深度不同观测视角下光谱指数与含盐量相关性热图

Fig. 4 Correlation heat map of spectral indices and soil salt content at various soil depths and viewing angles

2.2.2 新建指数与含盐量相关性分析

不同观测角度下植被指数和盐分指数与不同深度含盐量之间的相关性较低,难以作为模型输入变量准确反演不同深度土壤含盐量。因此利用热点、暗点和正射观测数据构建新指数,充分考虑所有类型的可能组合,并分别将各类型新指数与不同深度含盐量相关系数绘制成热图(图 5)。横坐标中,HDI_1 ~ HDI_4每种类型有 25 个指数,$HDNI_1$ ~ $HDNI_4$每种类型有 125 个指数。热图颜色越偏向深红色,正相关性越高,越偏向深蓝色,负相关性越高。

8 种类型新指数相较于不同观测角度下光谱指数在不同深度上与含盐量的相关系数变化区间均有不同程度延伸,而且最大相关系数绝对值也均有提升。不同深度下,最大正相关系数依次为 0.77(HDI_4)、0.83(HDI_4)、0.51(HDI_2、HDI_4、$HDNI_1$)和 0.38($HDNI_1$);最大负相关系数分别为 −0.74($HDNI_4$)、−0.78($HDNI_4$)、−0.46($HDNI_4$)和 −0.52($HDNI_3$)。新构建指数相较于不同观测角度下光谱指数,不同深度与含盐量相关系数绝对值最大值分别提升 44.0%、72.9%、70.0% 和 67.7%。虽然在深度 20 ~ 40 cm、40 ~ 60 cm 上,新建指数与含盐量最大相关系数仅为 0.5 左右,但 20 ~ 40 cm 和 40 ~ 60 cm 相关性依然表现出较大提升。8 类新构建指数在不同深度上与含盐量的相关性呈现一致规律:0 ~ 10 cm 和 10 ~ 20 cm 下各指数与含盐量相关性相较于 20 ~ 40 cm 和 40 ~ 60 cm 更强。HDI_4和$HDNI_4$在 4 个深度的整体表现优于其他新构建指数。

通过相关性分析,新建指数在综合热点、暗点和正射观测信息,并进行不同波段运算后,相较于植被和盐分指数展现出更强的应用潜力。

2.3 新建指数特征选择

通过 Relief 算法计算不同土壤深度下特征变量

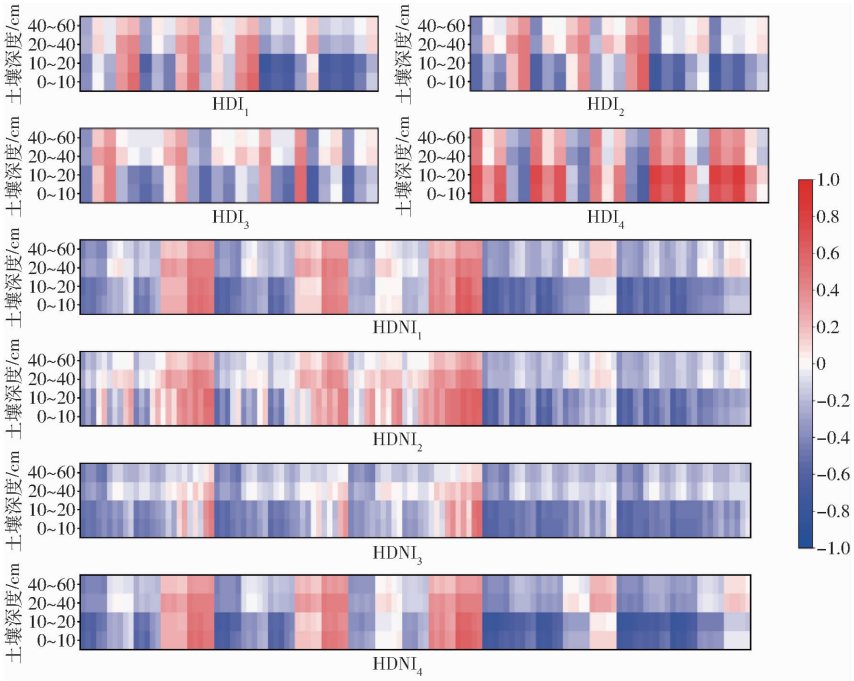

图 5 不同土壤深度下新建指数与含盐量相关性热图

Fig. 5 Correlation heat map of spectral indices and soil salt content across various soil depths

的重要性权重，并绘制重要性分布图（图 6）。对于深度 0 ~ 10 cm 和 10 ~ 20 cm，不同类型指数重要性呈现大致相同的变化规律，HDI_4 和 $HDNI_4$ 相较于其他类型指数表现出更高的重要性，分别有 61.1% 和 57% 特征变量对各自深度的含盐量产生正向作用。在深度 20 ~ 40 cm 下，$HDNI_3$ 类型指数展现出更高重要性，仅有 27.5% 特征变量对含盐量产生负向作用。对于深度 40 ~ 60 cm，无明显重要性更突出的新建类型指数，同时，对含盐量产生正向作用的特征变量仅占 40.9%。选取各深度下重要性为前 5% 的特征变量作为主成分分析方法的分析对象，以此确定最终模型输入变量数量。主成分分析结果如图 6 所示。对于不同深度，通过主成分分析，当主成分累计贡献率达到 95% 以上时，特征变量数量可以降低

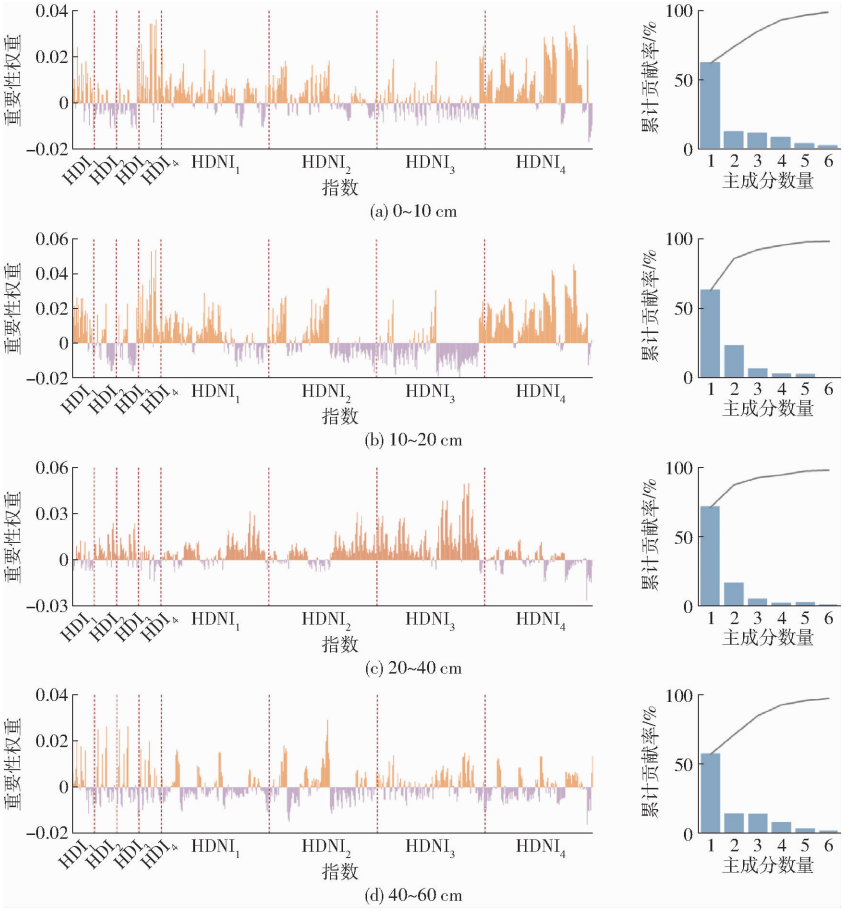

图 6　不同土壤深度下各新建指数重要性排序图以及累计贡献率与主成分数量关系

Fig. 6　Ranking plot of newly constructed index importance at various soil depths and plot of cumulative contribution rate versus principal component quantity

至 5、4、4、5 个。

2.4　土壤含盐量模型构建

将经过 Relief 和 PCA 方法特征筛选后不同深度下特征变量组合作为模型最佳输入变量，使用 RF、XG - BOOST 和 GRNN 机器学习算法建立不同土壤深度 SSC 反演模型。

从不同土壤深度建模效果（图 7）可知，SSC 最佳反演深度出现在 10 ~ 20 cm，R^2 在 0.785 ~ 0.802 范围内波动，平均值为 0.791。0 ~ 10 cm R^2 变化范围为 0.760 ~ 0.772，平均值为 0.766，相对最佳深度下降 3.2%。20 ~ 40 cm、40 ~ 60 cm 表现较差，R^2 变化范围分别为 0.496 ~ 0.537 和 0.478 ~ 0.522，平均值分别为 0.516 和 0.507，最大 R^2 相对于最佳深度分别下降 33.0% 和 34.9%。在不同深度下，GRNN 表现均为最优，RF 和 XG - BOOST 算法在 0 ~ 10 cm 和 10 ~ 20 cm 下反演性能无太大差异，但对于 20 ~ 40 cm 和 40 ~ 60 cm，RF 性能相较于 XG - BOOST 较差。

对于 0 ~ 10 cm 和 10 ~ 20 cm，不同算法下，训练集和测试集，R^2、RMSE 和 MAE 三者变化范围和趋势一致；但对于 20 ~ 40 cm 和 40 ~ 60 cm，当 R^2 变化区间大致相同时，40 ~ 60 cm 的 RMSE 和 MAE 相对于 20 ~ 40 cm 有非常大的突变，训练集 RMSE 和 MAE 分别提升 32.5% 和 49.0%，测试集 RMSE 和 MAE 分别提升 62.1% 和 49.7%。表明随着土壤深度增加，含盐量增大，预测值和实测值偏差将会显著增大。对于 20 ~ 40 cm 和 40 ~ 60 cm，从散点图可以看出（图 8），3 种算法下，1∶1 线与 95% 置信区间的

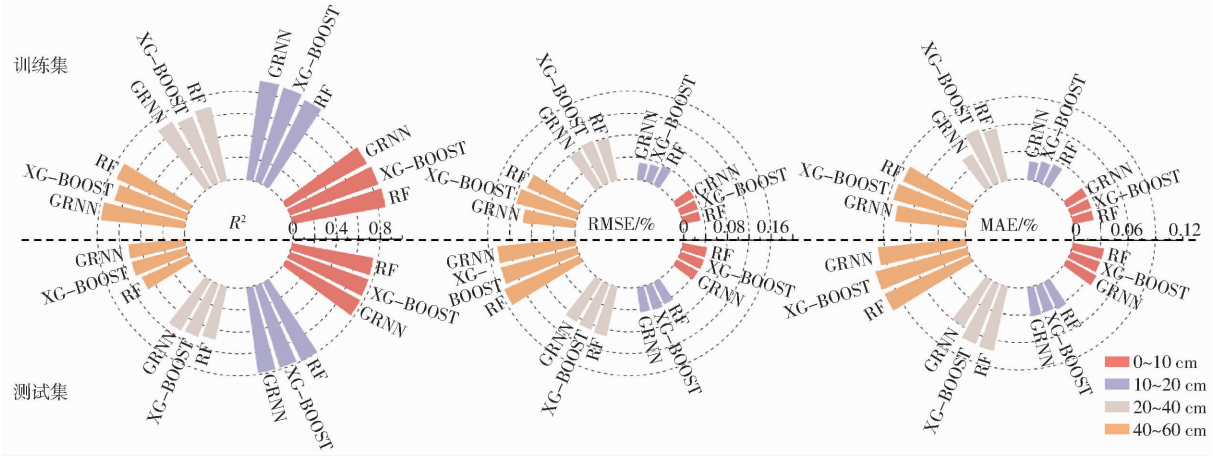

图 7 不同深度下不同算法训练集和验证集 R^2、RMSE 和 MAE

Fig. 7 R^2, RMSE and MAE of different algorithm training sets and validation sets at different depths

灰色拟合线都形成较大角度的交叉形态,尤其是随着含盐量实测值增大,预测值较 1∶1线的分布更加分散。不过对于浅层 0 ~ 10 cm 和 10 ~ 20 cm,RF 和 XG - BOOST 算法对于高值点的拟合也存在一定偏差,但在 GRNN 算法中得到修正:0 ~ 10 cm 和 10 ~ 20 cm 深度下 1∶1线与 95% 置信带区间内灰色拟合线几乎重合。综上可推测当实测含盐量大于 0.5% 后,预测值与实测值偏差将会迅速变大,点的分布较 1∶1线更加分散,模型预测精度也快速下降。

2.5 不同土壤深度含盐量反演图

基于最佳反演模型绘制不同深度下 3 块试验地土壤含盐量空间分布图(图 9)。由图 9 可知,1 号试验地平均含盐量最低,3 号试验地平均含盐量最高,而且随着土壤深度增加,3 块试验地土壤含盐量均呈上升趋势,这与实地调查结果一致。在同一个试验地内,植被覆盖度高的地区,平均含盐量相对于植被覆盖度低的地区较低。这是由于盐碱化影响作物正常生长,从而导致植被覆盖度与盐碱化程度呈反比。因此融合热点、暗点和正射观测下光谱数据,通过构建新指数并基于 GRNN 机器学习算法所构建的土壤含盐量估算模型可用于该试验地土壤含盐量反演。

3 讨论

3.1 新指数应用潜力

利用植被指数和盐分指数构建含盐量反演模型具有可行性,但在本研究中 3 个不同观测视角下 14 个光谱指数和不同深度土壤盐分响应关系并不突出(图 4)。可能是由于植被结构特征以及土壤复杂理化特性影响传感器所获取的光谱信息,并且受限于正射观测下光谱信息的有限性以及不完整性,导致光谱指数和盐分之间相关性表现较差。

本研究采用随机方法遍历所有可能组合以充分挖掘出不同观测视角下不同波段所隐藏的光谱信息。经过筛选所保留的特征指数组成波段主要集中在蓝光、红光和近红外波段(图 10c)。虽然红边波段在耕地土壤盐分监测中存在潜力[22,30],但本研究中红边波段表现并不突出。可能原因是研究区域盐渍化样本不到总样本的 1%,含盐量总体属于轻度盐渍化水平,红边波段对于高含盐量具有更好的预测能力。蓝光、红光和近红外波段在本研究中对盐分展现出较高的敏感性(图 10a)。

构建指数时并没有像其他研究对波段先进行敏感性分析,从而选择高敏感性波段或者剔除与干扰因素重合的高敏感波段进行指数构建。而是试图通过不同形式组合,利用不同观测视角间所包含的光谱信息差异,在一定程度上降低或者消除某些因素干扰。Song 等[31] 通过比值形式,利用 NDRE 和 FWBI 构建新指数,以此消除 FWBI 对叶片氮含量估算的影响;Zhang 等[32] 通过随机组合利用 3 个不同红边波段构建新比值指数,降低冠层结构和土壤背景的影响,提高叶片叶绿素含量估算精度。本研究融合多角度数据,在有效增加数据维度和信息量的同时,通过不同波段组合形式进一步挖掘光谱信息。经过特征筛选后所保留的新建指数,主要为归一化以及比值形式。利用热暗点光谱信息构建归一化热暗点指数、比值热暗点指数以及添加正射光谱信息改进这些指数在作物表型监测中取得了满意的效果[33-34],而在本研究中,参照这些指数构建的新指数在植被覆盖下对土壤盐分监测取得了较好的效果,一方面可能的原因是利用热暗点和正射下光谱信息组合运算,可有效消除土壤和作物阴影影响以及光线多次无关的散射和折射,本研究的植被覆盖度大都处于中高植被覆盖,新建指数在一定程度上也会缓解植被指数的饱和现象。另一方面,也可能与新建指数在一定程度上降低了土壤含水率对于盐

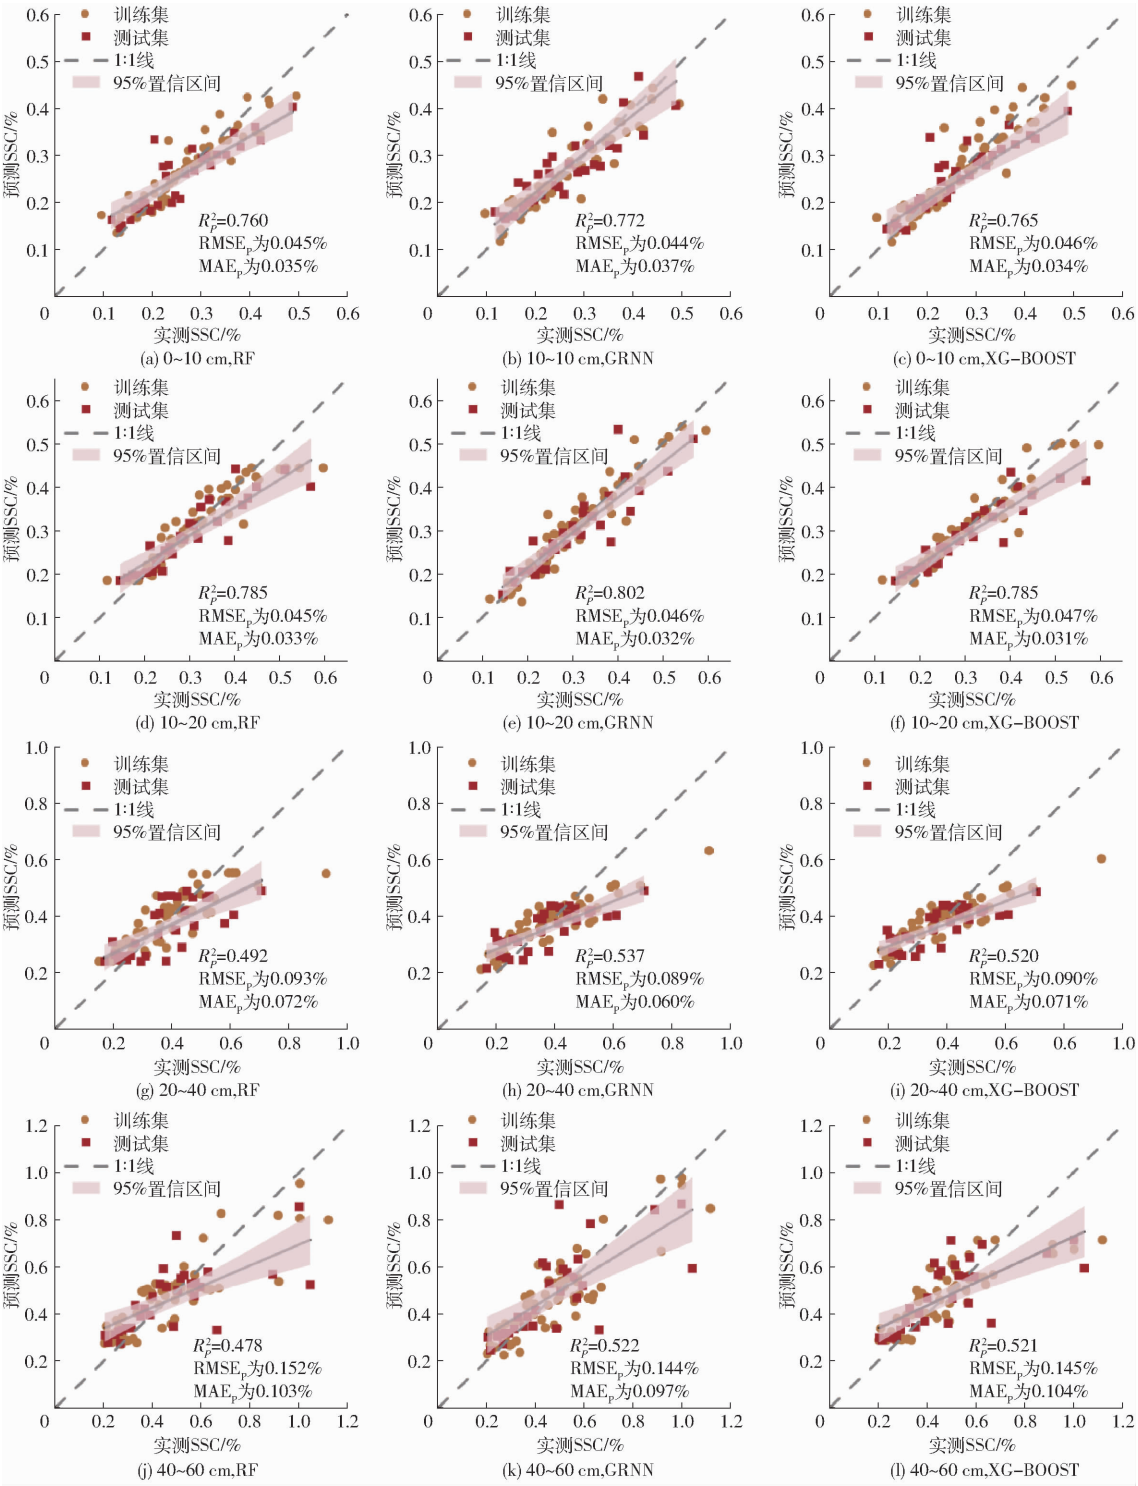

图 8　不同土壤深度下不同算法所构建含盐量估计模型性能

Fig. 8　Performance of SSC estimation models at different depths constructed by various algorithms

分监测的干扰有关，将土壤含水率与波段进行敏感性分析（图 10b），发现蓝光、红光和近红外波段在本研究中对盐分展现出较高的敏感性，而对土壤含水率及其敏感的红边波段在构成新建指数的波段中占比较低（图 10c），同时对于盐分敏感的蓝光和红光波段对土壤含水率显示极低的敏感性。因此基于热点效应，融合多角度信息，随机遍历所有组合可以构建出更加有效的盐分监测指数。

3.2　土壤深度与盐分分布以及反演精度的关系

盐碱化土地盐分在正常情况下会随着水分蒸发积聚到表层导致表层盐分大于深层盐分。但在本试验中，SSC 与土壤深度成正比（图 11），4 个深度含盐量平均值为 0.257%、0.300%、0.369% 和 0.464%，这和此前多数研究的土壤盐分分布表现出不一样的规律。引起这种变化的可能原因是：试验时间 7 月正值河套灌区农田每天引水灌溉时间段，由于盐与

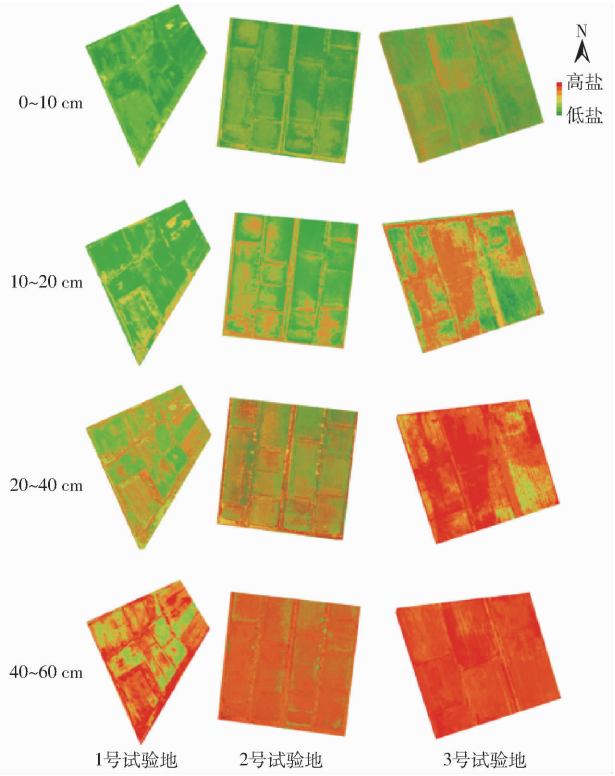

图 9 基于 GRNN 算法绘制的不同深度试验地含盐量反演图

Fig. 9 GRNN-based inversion maps of soil salinity in experimental fields across different soil depths

水之间存在复杂交互关系,盐会随着水下渗,使得盐分向深层积聚。当在白天太阳充分照射时,有植被覆盖土壤受到阳光直射影响较小,相对于裸土,蒸发速率较慢。而且在进行采样时,采样点处的农田土壤大都属于潮湿状态,并未经历充分的蒸发。多方面因素造成了本试验中农田盐分分布与深度成正比。

本研究中,0 ~ 10 cm 和 10 ~ 20 cm 下反演精度表现较好,20 ~ 40 cm 和 40 ~ 60 cm 表现相对较差,Cui 等[35]认为 0 ~ 20 cm 比 20 ~ 40 cm 具有更好的含盐量反演精度以及杨宁等[11]认为在 0 ~ 10 cm 和 10 ~ 20 cm 含盐量反演精度相较于 20 ~ 40 cm 和 40 ~ 60 cm具有更高一致性。造成这种差异的原因,一方面可能为所采用的多光谱镜头独有的光学特性,对于地物的穿透能力有限,所获得的光谱信息,主要包含 0 ~ 10 cm 和 10 ~ 20 cm 2 个深度的表层信息,而对于更深层的信息获取较少[36]。另一方面,作物根系所处深度以及根系分布密度也在一定程度上影响含盐量反演精度。由于作物根系对于盐分非常敏感,因此土壤盐分对于作物生长状况的影响与根域密切相关。研究区域内向日葵根系主要位于 0 ~ 20 cm 表层深度,极少量侧根可达到 40 cm。本研究中 0 ~ 10 cm 和 10 ~ 20 cm 下反演精度显著高

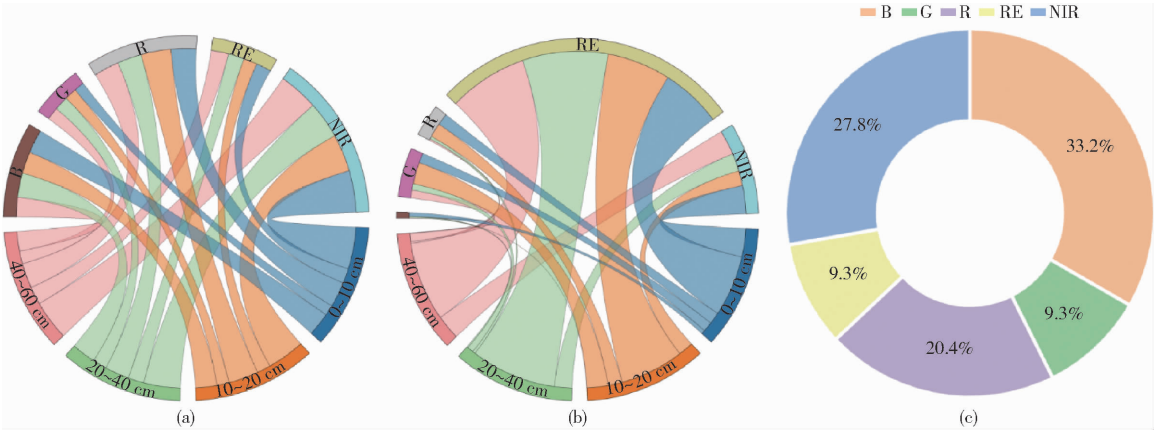

图 10 不同深度下各波段与含盐量和含水率的敏感性分析及新建指数各波段数量占比

Fig. 10 Sensitivity analysis of each waveband to soil salinity and soil moisture content at different soil depths, and proportion of waveband numbers for constructed indices

于 20 ~ 40 cm 和 40 ~ 60 cm,在 10 ~ 20 cm 下反演精度略高于 0 ~ 10 cm(图 11)。可能是由于 10 ~ 20 cm 处根系密度相较于 0 ~ 10 cm 更大,对于盐分的敏感性更高。

3.3 不足与展望

本研究为监测植被覆盖条件下不同深度土壤盐分提供了新思路,但依然存在一些不足。在后续研究中,应以不同覆盖度作为依据分类进行讨论;同时本试验采用的机器学习方法,需大量样本作为支撑,为提高该方法的可行性和适用性,应考虑增加其他研究对象,并在不同气候、不同土壤质地条件下,收集多年期数据,作更进一步验证。

本研究中深层土壤含盐量监测精度较低,难以满足定量遥感要求,在未来研究中,可考虑下述方法提升监测精度:采用低频电磁波或者长波红外波段提升光波地物穿透能力,增强光谱信息有效性;采集试验地土壤质地、容重等参数,分析与土壤盐分的响应关系,消除基质效应对于监测精度的影响;改进模型构建方法,将表层高精度数据作为先验知识约束深层模型构建。

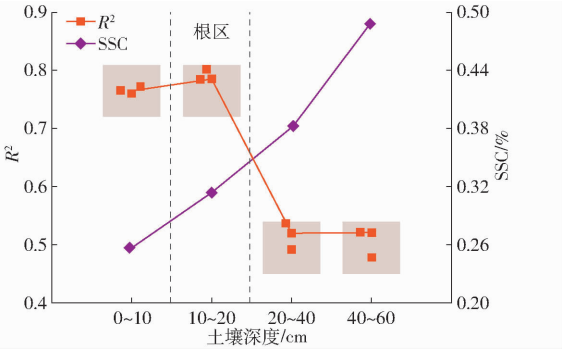

图 11　不同土壤深度下平均含盐量以及 R^2 分布

Fig. 11　Average soil salinity and R^2 distribution at different soil depths

4　结论

(1)在热点观测方向上，新建指数和光谱指数与盐分相关性高于正射和暗点方向。在不同深度上，新建指数相较光谱指数与盐分的相关性更强，最大相关性系数绝对值分别提升 44.0%、72.9%、70.0% 和 67.7%。

(2)Relief 和 PCA 结合的特征筛选方法可有效去除不相关冗余光谱信息，并将变量数量控制在 5 个之内，不同深度下，最终保留变量数量依次为 5、4、4、5 个。

(3)0 ~ 10 cm 和 10 ~ 20 cm 下各模型精度远高于 20 ~ 40 cm 和 40 ~ 60 cm，最佳反演深度为 10 ~ 20 cm。不同土壤深度下，GRNN 算法表现均优于 RF 和 XG - BOOST。在最佳反演深度下，GRNN 模型测试集 R^2 为 0.802，RMSE 为 0.046%，MAE 为 0.032%。

参　考　文　献

[1] Ren Dongyang, Wei Boyu, Xu Xu, et al. Analyzing spatiotemporal characteristics of soil salinity in arid irrigated agro-ecosystems using integrated approaches[J]. Geoderma, 2019, 356: 113935.

[2] 郝远远，徐旭，任东阳，等. 河套灌区土壤水盐和作物生长的 hydrus - epic 模型分布式模拟[J]. 农业工程学报，2015，31(11)：110 - 116.
Hao Yuanyuan, Xu Xu, Ren Dongyang, et al. Distributed modeling of soil water-salt dynamics and crop yields based on hydrus - epic model in Hetao Irrigation District[J]. Transactions of the CSAE, 2015,31(11): 110 - 116. (in Chinese)

[3] 刘勤，王宏卫，丁建丽，等. 干旱区区域土壤盐渍化监测研究进展及其未来热点[J]. 新疆大学学报(自然科学版)，2014,31(1)：108 - 115.
Liu Qin, Wang Hongwei, Ding Jianli, et al. Research advances on regional soil salinization monitoring in arid area[J]. Journal of Xinjiang University (Natural Science Edition), 2014,31(1): 108 - 115. (in Chinese)

[4] 韩文霆，邵国敏，马代健，等. 大田玉米作物系数无人机多光谱遥感估算方法[J]. 农业机械学报，2018，49(7)：134 - 143.
Han Wenting, Shao Guomin, Ma Daijian, et al. Estimating method of crop coefficient of maize based on UAV multispectral remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(7): 134 - 143. (in Chinese)

[5] 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)

[6] 向友珍，李汪洋，台翔，等. 基于无人机遥感图像纹理与植被指数的土壤含盐量反演[J]. 农业机械学报，2023，54(8)：201 - 210.
Xiang Youzhen, Li Wangyang, Tai Xiang, et al. Inversion of soil salt content based on texture feature and vegetation index of UAV remote sensing images[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(8): 201 - 210. (in Chinese)

[7] Cui Xin, Han Wenting, Zhang Huihui, et al. Estimating soil salinity under sunflower cover in the Hetao Irrigation District based on unmanned aerial vehicle remote sensing[J]. Land Degradation & Development, 2023, 34(1): 84 - 97.

[8] Shrestha R P. Relating soil electrical conductivity to remote sensing and other soil properties for assessing soil salinity in Northeast Thailand[J]. Land Degradation & Development, 2006, 17(6): 677 - 689.

[9] 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.

[10] 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 - 3): 96 - 109.

[11] 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)

[12] 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)

[13] 厉彦玲, 赵庚星, 常春艳, 等. OLI 与 HSI 影像融合的土壤盐分反演模型[J]. 农业工程学报,2017, 33(21): 173 - 180.
Li Yanling, Zhao Gengxing, Chang Chunyan, et al. Soil salinity retrieval model based on OLI and HSI image fusion[J]. Transactions of the CSAE, 2017, 33(21): 173 - 180. (in Chinese)

[14] Du Ruiqi, Lu Junsheng, Xiang Youzhen, et al. Estimation of winter canola growth parameter from UAV multi-angular spectral-texture information using stacking-based ensemble learning model[J]. Computers and Electronics in Agriculture, 2025, 222: 109074.

[15] He Li, Song Xiao, Feng Wei, et al. Improved remote sensing of leaf nitrogen concentration in winter wheat using multi-angular hyperspectral data[J]. Remote Sensing of Environment, 2016, 174: 122 - 133.

[16] Salcedo F P, Cutillas P P, Cabanero J J A, et al. Use of remote sensing to evaluate the effects of environmental factors on soil salinity in a semi-arid area[J]. Science of the Total Environment, 2022, 815: 152524.

[17] Zhang Junrui, Zhang Zhitao, Chen Junying, et al. Estimating soil salinity with different fractional vegetation cover using remote sensing[J]. Land Degradation & Development, 2021, 32(2): 597 - 612.

[18] 白燕英, 高聚林, 张宝林. 基于 NDVI 与 EVI 的作物长势监测研究[J]. 农业机械学报,2019, 50(9): 153 - 161.
Bai Yanying, Gao Julin, Zhang Baolin. Monitoring of crops growth based on NDVI and EVI[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(9): 153 - 161. (in Chinese)

[19] 谢俊博, 王兴鹏, 何帅, 等. 基于光谱指数建模的沙井子灌区土壤盐分反演[J]. 干旱区地理,2024, 47(7): 1199 - 1209.
Xie Junbo, Wang Xingpeng, He Shuai, et al. Soil salinity inversion in the Shajingzi irrigation district based on spectral index modeling[J]. Arid Land Geography, 2024, 47(7): 1199 - 1209. (in Chinese)

[20] 冯娟, 丁建丽, 杨爱霞, 等. 干旱区土壤盐渍化信息遥感建模[J]. 干旱地区农业研究,2018, 36(1): 266 - 273.
Feng Juan, Ding Jianli, Yang Aixia, et al. Remote sensing modeling of soil salinization information in arid areas[J]. Agricultural Research in the Arid Areas, 2018, 36(1): 266 - 273. (in Chinese)

[21] 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. 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)

[22] 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, 36(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, 36(1): 248 - 253. (in Chinese)

[23] Sidike A, Zhao Shuhe, Wen Yuming. Estimating soil salinity in Pingluo County of China using QuickBird data and soil reflectance spectra[J]. International Journal of Applied Earth Observation and Geoinformation, 2014, 26: 156 - 175.

[24] Cho K H, Beon M S, Jeong J C. Dynamics of soil salinity and vegetation in a reclaimed area in Saemangeum, republic of Korea[J]. Geoderma, 2018, 321: 42 - 51.

[25] 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.

[26] Zhang Liyuan, Niu Yaxiao, Zhang Huihui, et al. Maize canopy temperature extracted from UAV thermal and RGB imagery and its application in water stress monitoring[J]. Frontiers in Plant Science, 2019, 10: 1270.

[27] Ye Sumeng, Zhang Zhitao, Chen Junying, et al. Inversion of winter wheat canopy chlorophyll content using angle-insensitive UAV-based spectral indices[J]. Computers and Electronics in Agriculture, 2025, 230: 109902.

[28] Bai Xuqian, Chen Yinwen, Chen Junying, et al. Optimal window size selection for spectral information extraction of sampling points from UAV multispectral images for soil moisture content inversion[J]. Computers and Electronics in Agriculture, 2021, 190: 106456.

[29] Liu Yang, Feng Haikuan, Yue Jibo, et al. Improved potato AGB estimates based on UAV RGB and hyperspectral images[J]. Computers and Electronics in Agriculture, 2023, 214: 108260.

[30] 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 Iake Region, Xinjiang, China[J]. Geoderma, 2019, 353: 172 - 187.

[31] Song Xiao, Feng Wei, He Li, et al. Examining view angle effects on leaf N estimation in wheat using field reflectance spectroscopy[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2016, 122: 57 - 67.

[32] Zhang Xuan, Sun Hui, Qiao Xinxin, et al. Hyperspectral estimation of canopy chlorophyll of winter wheat by using the optimized vegetation indices[J]. Computers and Electronics in Agriculture, 2022, 193: 106654.

[33] Chen J M, Liu J, Leblanc S G, et al. Multi-angular optical remote sensing for assessing vegetation structure and carbon absorption[J]. Remote Sensing of Environment, 2003, 84(4): 516 - 525.

[34] Chen J M, Menges C H, Leblanc S G. Global mapping of foliage clumping index using multi-angular satellite data[J]. Remote Sensing of Environment, 2005, 97(4): 447 - 457.

[35] Cui Jiawei, Chen Xiangwei, Han Wenting, et al. Estimation of soil salt content at different depths using UAV multi-spectral remote sensing combined with machine learning algorithms[J]. Remote Sensing, 2023, 15(21): 5254.

[36] Luo Linyu, Li Yijie, Guo Fei, et al. Research on robust inversion model of soil moisture content based on GF-1 satellite remote sensing[J]. Computers and Electronics in Agriculture, 2023, 213: 108272.