doi:10.6041/j.issn.1000-1298.2024.12.040

基于多光谱影像的苜蓿地不同生育期土壤含盐量反演模型研究

赵文举[1,2]　李钊钊[1,2]　马芳芳[1,2]　段威成[1,2]　马　宏[1,2]

(1.兰州理工大学能源与动力工程学院,兰州 730050;
2.农业农村部智慧农业节水灌溉装备重点实验室,兰州 730050)

摘要:为探究苜蓿地不同生育期不同深度的土壤含盐量快速反演模型,采集苜蓿地分枝期、现蕾期、初花期深度 0~15 cm、15~30 cm、30~50 cm 土壤含盐量,基于无人机多光谱影像数据,提取采样点光谱反射率,在此基础上引入红边波段代替红波段与近红外波段计算光谱指数,采用皮尔逊相关系数法(Pearson correlation corfficient,PCCs)、灰色关联度(Gray relational analysis, GRA)分析法进行指数筛选,构建 54 个基于极端梯度提升(Extreme gradient boosting,XGBoost)算法、反向传播神经网络(Back propagation neural network,BPNN)和随机森林(Random forest,RF)的机器学习模型,确定苜蓿地不同生育期不同深度土层的土壤含盐量最佳反演模型。结果表明:XGBoost 模型反演效果整体优于 BPNN 模型和 RF 模型,反演结果能真实反映不同生育期苜蓿地的土壤含盐量。从不同生育期反演来看,分枝期和初花期 XGBoost 模型反演效果优于其他模型,验证集决定系数(R_p^2)分别为 0.835、0.709,均方根误差(RMSE)分别为 0.042%、0.047%,平均绝对误差(MAE)分别为 0.046%、0.037%;现蕾期 RF 模型反演效果优于其他模型,R_p^2 为 0.717,RMSE 为 0.034%,MAE 为 0.042%。从不同深度反演来看,0~15 cm 土层 XGBoost 模型反演效果优于其他模型,R_p^2 为 0.835,RMSE 为 0.053%,MAE 为 0.043%;15~30 cm 和 30~50 cm 土层 XGBoost 和 RF 模型均优于 BPNN 模型,R_p^2 分别为 0.717、0.739,RMSE 分别为 0.034%、0.038%,MAE 分别为 0.042%、0.031%。分枝期为最佳反演生育期,0~15 cm 深度为最佳含盐量反演深度,且 PCCs 变量筛选方法与 XGBoost 机器学习算法的耦合模型精度最佳,建模集和验证集的 R^2 分别为 0.856、0.835,R_p^2/R_c^2 为 0.975,具有良好的鲁棒性。研究结果可为土壤含盐量的快速精确反演提供理论依据。

关键词:多光谱;苜蓿地;土壤含盐量;XGBoost;变量筛选;反演模型

中图分类号:S274.4　　**文献标识码**:A　　**文章编号**:1000-1298(2024)12-0418-12　　**OSID**:

Inversion Model of Soil Salinity at Different Fertility Stages in Alfalfa Fields Based on Multi-spectral Imagery

ZHAO Wenju[1,2]　LI Zhaozhao[1,2]　MA Fangfang[1,2]　DUAN Weicheng[1,2]　MA Hong[1,2]

(1. *College of Energy and Power Engineering*, *Lanzhou University of Technology*, *Lanzhou* 730050, *China*
2. *Key Laboratory of Smart Agriculture Irrigation Equipment*, *Ministry of Agriculture and Rural Affairs*, *Lanzhou* 730050, *China*)

Abstract: Soil salinization has always been an important factor restricting the sustainable development of agriculture in Northwest China. In order to explore the rapid inversion model of soil salinity at different depths in different growth stages of alfalfa land, soil salinity at the depths of 0~15 cm, 15~30 cm and 30~50 cm in the branching stage, budding stage and early flowering stage of alfalfa land was collected. Based on the multi-spectral image data of UAV, the spectral reflectance of sampling points was extracted. On this basis, the red band was introduced instead of the red band and the near-infrared band to calculate the spectral index. Pearson correlation corfficient (PCCs) and gray relational analysis (GRA) were used for index screening. A total of 54 machine learning models based on extreme gradient boosting (XGBoost) algorithm, back propagation neural network (BPNN) and random forest (RF) were constructed to determine the optimal inversion model of soil layers at different depths in different growth stages of alfalfa land. The results showed that the inversion effect of XGBoost model was better than that

收稿日期:2024-01-17　修回日期:2024-02-25

基金项目:国家自然科学基金面上项目(52379042)、甘肃省重点研发计划项目(23YFFA0019)和甘肃省东西协作专项(23CXNA0025)

作者简介:赵文举(1981—),男,教授,博士生导师,主要从事寒旱区生态水利研究,E-mail:wenjuzhao@126.com

of BPNN model and RF model, and the inversion results could truly reflect the soil salt content of alfalfa field at different growth stages. According to the inversion of different growth stages, the inversion effect of XGBoost model in branching stage and early flowering stage was better than that of other models. The determination coefficient of validation set (R_p^2) was 0.835 and 0.709, respectively, the root mean square error (RMSE) was 0.042% and 0.047%, respectively, and the mean absolute error (MAE) was 0.046% and 0.037%, respectively. The inversion effect of RF model was better than that of other models, with R_p^2 of 0.717, RMSE of 0.034% and MAE of 0.042%. From the perspective of different depths inversion, the inversion effect of XGBoost model in 0 ~ 15 cm soil layer was better than that of other models. The R_p^2 was 0.835, the RMSE was 0.053%, and MAE was 0.043%. The XGBoost and RF models were superior to the BPNN model in 15 ~ 30 cm and 30 ~ 50 cm soil layers, with R_p^2 of 0.717 and 0.739, RMSE of 0.034% and 0.038%, and MAE of 0.042% and 0.031%, respectively. The branching period was the best inversion growth period, and the depth of 0 ~ 15 cm was the best salinity inversion depth, and the coupling model of PCCs variable screening method and XGBoost machine learning algorithm had the best accuracy. The R^2 of the modeling set and the verification set were 0.856 and 0.835, respectively, and R_p^2/R_c^2 was 0.975, which had good robustness. The research results can provide a theoretical basis for rapid and accurate inversion of soil salinity.

Key words: multi-spectral; alfalfa field; soil salinity; XGBoost; variable selection; inversion model

0　引言

土壤盐碱化是一个时空动态的土壤变化过程，在气候和水文的变环境条件下，土壤盐分或者地下水中的盐分随着土壤中的水分蒸发至地表，造成了大面积耕地退化和作物减产[1]。据统计目前中国盐碱土面积约 3.6×10^7 hm^2，分布广泛，其中耕地面积占 26.6%[2-3]，严重制约农业和经济的发展，盐碱地治理迫在眉睫。因此，快速准确地获取土壤盐分信息对盐碱地治理具有重要意义。传统方法获取土壤盐分信息精度高，但费时费力，成本较高且时效性低，无法做到耕地区域内大范围性的土壤盐分监测。无人机搭载光谱仪器作为低空遥感的一种，可快速获取大范围光谱信息，进而实现土壤墒情和作物生长大范围、快速监测，可为土壤含盐量反演提供科学高效的技术手段[4]。

目前反演土壤含盐量的主要手段是通过地面实地测量的光谱数据或遥感监测得到的数据、结合土壤样品含盐量数据进行反演，而土壤含盐量反演模型精度的提升仍是目前研究的热点问题[5-6]。近年来，研究者通过引入红边波段构建新的光谱指数作为反演模型的输入组，从而提高了土壤含盐量反演的准确性[7-8]。敏感光谱变量作为反演模型的输入数据，使用合适的选择方法可以提高模型预测精度[9-10]。极端梯度提升(XGBoost)算法是一个优化分布式梯度增强库，该算法不再使用一阶导数信息，而是基于二阶泰勒展开式，来增加模型的多样性，减少过拟合现象，以提高模型效率[11-13]。但该算法在土壤含盐量建模研究中应用较少，且盐碱地在不同季节有不同的光谱特征，因此，利用多光谱影像结合不同机器学习模型，反演多生育期土壤含盐量的响应机理还有待深入研究。

综上所述，本研究利用多光谱相机获取研究区域遥感影像以及实测多生育期(分枝期、现蕾期、初花期)作物覆盖下多深度(0 ~ 15 cm、15 ~ 30 cm、30 ~ 50 cm)的含盐量数据，通过引入红边波段代替红波段与近红外波段，从而衍生出新的光谱指数。采用灰色关联度(GRA)与皮尔逊(Person)相关性分析算法对光谱指数进行筛选，将筛选后的敏感变量作为模型输入层，构建基于 XGBoost、反向神经网络(BPNN)和随机森林(RF)机器学习算法的土壤含盐量反演模型，通过对 54 个反演模型的反演效果进行评价，以讨赖河流域边湾农场为例，对比分析敏感变量优选结合不同建模方法的反演精度，确定灌区不同生育期苜蓿地不同土层的最佳含盐量反演模型，以期为快速精准反演土壤含盐量提供理论依据。

1　材料与方法

1.1　研究区概况

本研究区位于甘肃省讨赖河流域边湾农场，海拔约 1 390 m，总面积约 15.6 km^2，其中耕地面积约 5.4 km^2。该区域昼夜温差大，气候干燥寒冷，降水量少，蒸发量大，水资源总量少且时空分布不均。主要种植作物有苜蓿、玉米、小麦等，本研究以边湾农场种植的苜蓿作为主要研究对象。无人机多光谱遥感监测及实地采样位置如图 1 所示。

1.2　试验数据采集与预处理

1.2.1　无人机多光谱采样

试验所用遥感平台为大疆创新有限公司生产的

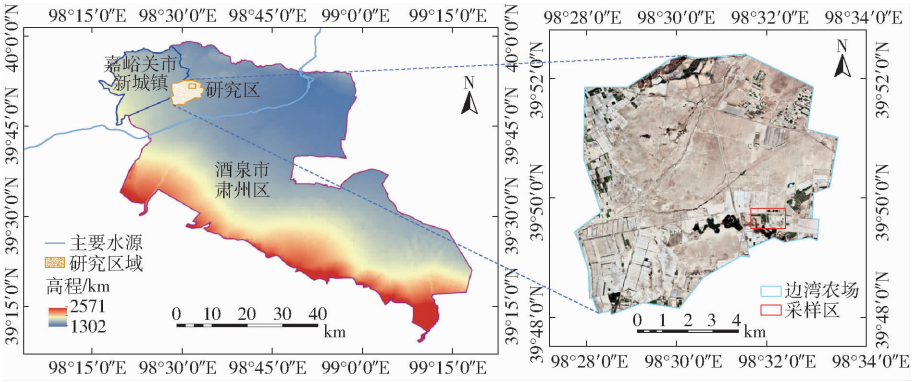

图 1 研究区示意图

Fig. 1 Schematic of study area

Phantom 4 型 Multispectral 无人机，同步搭载 6 个 1/2.9 英寸CMOS 影像传感器，该相机集成 1 个彩色 RGB 传感器以及红光((650 ± 16) nm)、绿光((560 ± 16)nm)、蓝光((450 ± 16) nm)、近红外((840 ±26)nm)以及红边((730 ±16)nm)传感器。

1.2.2 野外实测采样

2023 年 4、5、7 月在边湾农场对苜蓿地进行实地采样，采样点分布图如图 2 所示。苜蓿在该时间段分别处于分枝期、现蕾期、初花期。对每期苜蓿样地均布 66 个采样点，采样时使用土钻取土，采集包含 0 ~ 15 cm、15 ~ 30 cm、30 ~ 50 cm 3 个不同深度的土壤样本约 50 g，并使用手持 RTK 在采样点进行打点定标。

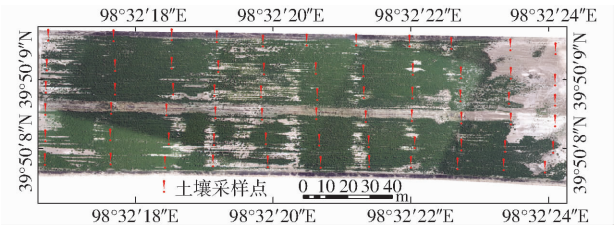

图 2 采样点分布图

Fig. 2 Sampling point distribution

将采集的样品均称取 30 g 置于铝盒中，放入干燥箱(105℃)8 h，晾晒后使用孔径 2 mm 筛子进行研磨过筛，将 150 mL 蒸馏水加入到筛好的土样中并充分搅拌，静置 10 h 后，使用雷磁 DJS - 1C 型电导率仪测定上层清液电导率($EC_{1:5}$，mS/cm)。并通过经验公式 $SSC = 0.288\,2EC_{1:5} + 0.018\,3$ 计算得出土壤样本的含盐量(SSC，%)[14]。

1.3 光谱指数构建与筛选

1.3.1 光谱指数构建

利用无人机遥感影像所提取的光谱反射率，将波段进行不同组合，选取 13 个盐分指数和 8 个植被指数。经研究发现红边波段包含有更加广泛的光谱信息，可以有效地提升土壤含盐量反演模型精度[15]。本研究将红波段和近红外波段使用红边波段进行替换，从而衍生出新的改良光谱指数，与传统光谱指数共计 51 个光谱指数参与筛选。51 个光谱指数分别为归一化盐分指数(NDSI)、改良归一化盐分指数(NDSI - reg)、改良归一化盐分指数(NDSI*)、强度指数(Int2)、改良强度指数(Int2 - reg)、改良强度指数(Lnt2*)、盐度指数(SI)、盐度指数(SI1)、盐度指数(SI2)、盐度指数(SI3)、改良盐度指数(SI - reg)、改良盐度指数(SI1 - reg)、改良盐度指数(SI2 - reg)、改良盐度指数(SI3 - reg)、改良盐度指数(SI2*)、盐分指数(S1)、盐分指数(S2)、盐分指数(S3)、盐分指数(S4)、盐分指数(S5)、改良盐分指数(S1 - reg)、改良盐分指数(S2 - reg)、改良盐分指数(S3 - reg)、改良盐分指数(S4 - reg)、改良盐分指数(S5 - reg)、简单比值指数(SR)、改良简单比值指数(SR - reg)、改良简单比值指数(SR*)、亮度指数(BI)、改良亮度指数(BI - reg)、改良亮度指数(BI*)、归一化差异植被指数(NDVI)、改良归一化差异植被指数(NDVI - reg)、改良归一化差异植被指数(NDVI*)、差值植被指数(DVI)、改良差值植被指数(DVI - reg)、改良差值植被指数(DVI*)、增强型植被指数(EVI)、改良增强型植被指数(EVI - reg)、改良增强型植被指数(EVI*)、覆盖度植被指数(CVI)、绿色归一化植被指数(GNDVI)、改良绿色归一化植被指数(GNDVI*)、绿叶指数(GLI)、改良绿叶指数(GLI - reg)、土壤改良植被指数(MSAVI)、土壤改良植被指数(MSAVI - reg)、土壤改良植被指数(MSAVI*)、近红外归一化植被指数(NIR)、改良近红外归一化植被指数(NIR - reg)、改良近红外归一化植被指数(NIR*)，其计算公式见文献[16 - 22]。

1.3.2 光谱指数筛选算法构建

在自然学科领域中，皮尔逊相关系数法(PCCs)广泛用于度量 2 个变量之间的相关程度，其值介于 -1 与 1 之间[12]。本研究 PCCs 法通过软件 IBM SPSS Statistics 27 完成。

GRA 分析是一种多因素统计分析方法。此方法优点在于思路明晰，可以在很大程度上减少由于信息不对称带来的损失，并且对数据要求较低，工作量较少[23]。本研究 GRA 法通过软件 Matlab R2021b 完成。

1.4　模型构建与精度评价

1.4.1　模型构建

XGBoost 算法是基于梯度提升树（GBDT）全面升级的新一代提升算法。在求解损失函数极值时，采用牛顿法，将损失函数 Taylor 展开到二阶。并在损失函数中加入一个正则化项[24]。XGBoost 作为 Boosting 算法，包含了 Boosting 三要素：损失函数，用以衡量模型预测结果与真实结果的差异；弱评估器，一般为决策树（CART 和 DART 树），依据不同 Boosting 算法使用不同的建树过程；综合集成结果，即集成算法具体输出集成结果。目标函数 Obj 定义为

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

式中　y_i'——样本 i 预测值

y_i——样本 i 真实值

$l(y_i', y_i)$——损失函数

$\Omega(f_k)$——正则化项

n——样本总数量

K——正则化项样本数量

与传统梯度提升树相比，XGBoost 并不是向着损失函数最小的方向运行，而是向着目标函数最小化的方向运行。对于任意树 f_k，目标函数由两部分组成，一部分为可微的损失函数，用来评估模型预测值与真实值之间的损失或误差，控制模型的经验风险；另一部分为模型的复杂程度，正则化项倾向于选择简单模型，避免过拟合[25]。XGBoost 算法通过 R 语言4.3.1 版本中的“XGBoost”包以及其他辅助算法包配合计算，各参数采用默认值。

另外，本研究还加入 BPNN 和 RF 机器学习算法构建土壤含盐量反演模型。其中 BPNN 和 RF 等传统的机器学习算法作为 XGBoost 算法的对照组，以此更好地对比模型的反演精度。

1.4.2　模型精度评价

以苜蓿覆盖土壤样本的 70%（45 个）作为建模集，余下样本（21 个）作为验证集。利用模型的决定系数（Coefficient of determination，R^2）、均方根误差（Root mean squared error，RMSE）和平均绝对误差（Mean absolute error，MAE）来评价建模精度。R^2 越接近 1，RMSE 和 MAE 越小，表明预测值和实测值之间的偏差越小，模型反演效果越好。

2　结果与分析

2.1　土壤盐分数据统计特征

对苜蓿试验地共选取 66 个采样点，每个采样点采取 0～15 cm、15～30 cm、30～50 cm 3 个土层的土壤样本，采集 3 个生育期，共计 594 个样本点。所有的样本点土壤含盐量统计特征见表 1。本研究区 80% 以上区域常年处于中度盐碱化（土壤盐分含量为 0.2%～0.5%）程度，局部地区处于重度盐碱化（土壤含盐量为 0.2%～0.5%），这与研究区域内作物的生长情况基本相符。根据表 1 可知，研究区域内土壤在分枝期、现蕾期和初花期的土壤含盐量最大值范围分别为 0.600%～0.891%、0.486%～0.863% 和 0.756%～0.890%。且苜蓿在不同生育期的建模集、验证集和全集的土壤含盐量统计结果均保持相近，最大限度减小了模型的验证偏差。这表明建模集和验证集的土壤含盐量可以极大程度代表整个数据集，实测数据可以较为真实地反映研究区域的土壤含盐量。

2.2　光谱指数筛选

为了更好地检验模型的预测精度，选取 2 种传统的光谱指数筛选方法对光谱指数进行筛选。选取常见的 13 个传统的盐分指数（NDSI、Int2、SI、SI1、SI2、SI3、S1、S2、S3、S4、S5、SR、BI）和 8 个传统的植被指数（NDVI、DVI、EVI、CVI、GNDVI、GLI、MSAVI、NNIP）及其衍生的光谱指数作为变量筛选组。

2.2.1　皮尔逊相关性筛选

将计算所得的光谱指数分别与不同生育期苜蓿地的土壤含盐量实测值进行 PCCs 相关性分析，根据相关性筛选结果，保留每组相关性较好的光谱指数作为模型输入组。为避免模型所输入的光谱指数数量对模型精度分析产生影响，通过逐次增加筛选个数，发现保留 12 个光谱指数时，模型精度最好，为避免筛选特征数对模型产生影响，对每层土壤均筛选 12 个光谱指数作为模型的输入量。基于变量重要性排序所选取的光谱指数见表 2。

2.2.2　灰色关联度分析

在构建神经网络模型过程中，过多的输入层数据会影响模型的学习过程，降低模型收敛速度和预测精度，本文采用灰色关联度分析对数据进行筛选，达到去除冗余数据的目的。引入灰色关联度分析法对该区域的土壤含盐量进行定量分析[26]，计算灰色关联度系数（Gray correlation degree，GCD），分辨系数取 0.5。

将计算所得的光谱指数分别与各生育期苜蓿地的土壤含盐量实测值进行 GRA 相关性分析，将筛选

表 1 土壤含盐量统计特征

Tab. 1 Statistical characteristics of soil salt content

苜蓿生育期	土层深度/cm	数据集	样本数/个	最大值/%	最小值/%	均值/%	标准差/%	方差/%^{2}	变异系数/%
分枝期	0 ~ 15	全集	66	0.891	0.104	0.383	0.206	0.042	0.539
		建模集	45	0.891	0.104	0.413	0.224	0.050	0.543
		验证集	21	0.600	0.112	0.319	0.146	0.021	0.457
	15 ~ 30	全集	66	0.809	0.088	0.361	0.198	0.039	0.549
		建模集	45	0.809	0.119	0.401	0.202	0.041	0.504
		验证集	21	0.650	0.088	0.273	0.160	0.026	0.585
	30 ~ 50	全集	66	0.832	0.081	0.449	0.196	0.039	0.437
		建模集	45	0.832	0.081	0.493	0.197	0.039	0.399
		验证集	21	0.600	0.114	0.355	0.162	0.026	0.457
现蕾期	0 ~ 15	全集	66	0.863	0.055	0.224	0.159	0.025	0.710
		建模集	45	0.728	0.055	0.193	0.128	0.016	0.663
		验证集	21	0.863	0.106	0.291	0.198	0.039	0.682
	15 ~ 30	全集	66	0.624	0.059	0.211	0.116	0.013	0.551
		建模集	45	0.486	0.059	0.188	0.090	0.008	0.479
		验证集	21	0.624	0.106	0.258	0.149	0.022	0.578
	30 ~ 50	全集	66	0.788	0.024	0.174	0.139	0.019	0.798
		建模集	45	0.788	0.024	0.177	0.139	0.019	0.787
		验证集	21	0.595	0.050	0.169	0.143	0.020	0.843
初花期	0 ~ 15	全集	66	0.890	0.079	0.328	0.192	0.037	0.585
		建模集	45	0.890	0.079	0.311	0.184	0.034	0.591
		验证集	21	0.756	0.115	0.366	0.208	0.043	0.570
	15 ~ 30	全集	66	0.837	0.103	0.334	0.199	0.040	0.596
		建模集	45	0.837	0.103	0.318	0.185	0.034	0.580
		验证集	21	0.786	0.141	0.367	0.228	0.052	0.622
	30 ~ 50	全集	66	0.883	0.110	0.341	0.210	0.044	0.618
		建模集	45	0.883	0.110	0.330	0.188	0.035	0.569
		验证集	21	0.797	0.136	0.363	0.256	0.065	0.705

表 2 基于 PCCs 法筛选的不同生育期不同深度光谱变量

Tab. 2 Spectral variables at different depths at different growth stages based on PCCs method

排序	分枝期			现蕾期			初花期		
	0 ~ 15 cm	15 ~ 30 cm	30 ~ 50 cm	0 ~ 15 cm	15 ~ 30 cm	30 ~ 50 cm	0 ~ 15 cm	15 ~ 30 cm	30 ~ 50 cm
1	SI - reg	BI*	S5 - reg	Int2	Int2	Int2	GLI - reg	GLI - reg	GLI - reg
2	SI3 - reg	SI2*	BI*	Int2 - reg	Int2 - reg	Int2 - reg	SI2*	SI2*	SI2*
3	BI*	S5 - reg	SI - reg	SI2 - reg	SI2	SI2 - reg	BI*	Int2*	SI1 - reg
4	GLI - reg	GLI - reg	SI3 - reg	SI2	SI3	SI2	Lnt2*	BI*	BI*
5	SI2*	SI - reg	SI2*	BI - reg	S4	BI	SI1 - reg	SI3 - reg	SI3 - reg
6	SI1 - reg	S4 - reg	SI1 - reg	GLI - reg	GLI	SI3	SI - reg	SI - reg	Int2 - reg
7	Int2*	Int2*	Int2*	S4 - reg	S5	GLI - reg	Int2	Int2	Int2
8	SI2 - reg	S4	Int2	SI3 - reg	Int2*	SI1	BI - reg	SI2	SI2
9	Int2	GLI	S5	SI1	SI1 - reg	Int2*	S4 - reg	BI - reg	BI - reg
10	SI2	Int2	SI2 - reg	Int2*	S4 - reg	SI3 - reg	SI2	SI3	SI3
11	BI	SI3	S4	S4	GLI - reg	S4	SI3	S4 - reg	S4 - reg
12	BI - reg	SI1	GLI	GLI	BI*	GLI	SI1	SI1	SI1

后的变量按照 GCD 阈值进行排序,为保证模型预测的准确性,每组数据依然选取 12 个高相关性的光谱指数(GCD 均大于 0.75,具有良好的相关性)作为模型的输入组。基于灰色关联度分析的光谱指数排序见表 3。

2.3 基于机器学习算法的土壤含盐量反演模型

为探究 XGBoost 回归模型在土壤含盐量反演中的适用性,将光谱指数基于 Person 相关性分析和 GRA 筛选后使用 XGBoost 建立的土壤含盐量反演模型与传统的 RF、BPNN 模型进行对比。其模型反

表 3　基于 GRA 法筛选的不同生育期不同深度光谱变量

Tab. 3　Spectral variables at different depths at different growth stages based on GRA method

排序	分枝期			现蕾期			初花期		
	0 ~ 15 cm	15 ~ 30 cm	30 ~ 50 cm	0 ~ 15 cm	15 ~ 30 cm	30 ~ 50 cm	0 ~ 15 cm	15 ~ 30 cm	30 ~ 50 cm
1	S5 – reg	S5 – reg	S5 – reg	SI3	SI3	S4 – reg	Int2	SI3	SI3
2	S4 – reg	S4 – reg	BI *	SI1	SI1	BI *	Int2 *	Int2	SI1
3	Lnt2 *	Lnt2 *	SI3 – reg	S4	Int2 – reg	SI2 *	SI1	GLI	Int2 *
4	SI1 – reg	SI2 *	GLI – reg	GLI	SI2 – reg	Int2	GLI	SI1	Int2
5	SI2 *	BI *	SI2 *	S3	S4	SI2	SI3	S4	S4 – reg
6	SI3	GLI – reg	S4 – reg	S4 – reg	Lnt2 *	Lnt2 *	SI2	S3	BI *
7	BI *	SI3 – reg	Lnt2 *	Int2	GLI	GLI – reg	BI	SI2	GLI – reg
8	GLI – reg	SI3	Int2 – reg	SI2	S3	SI3 – reg	SI2 *	BI	GLI
9	SI3 – reg	Int2	SI2 – reg	Int2 – reg	SI	Int2 – reg	BI *	S4 – reg	SI2
10	Int2 – reg	SI1	BI – reg	S5 – reg	SI2 *	S3 – reg	S5	BI *	SI1 – reg
11	SI	SI2	SI	SI	SI2	SI2 – reg	S4 – reg	SI1 – reg	SI3 – reg
12	SI2	SI	Int2	SI1 – reg	BI *	BI – reg	GLI – reg	GLI – reg	BI

演结果见表 4。由表 4 可知，将红边波段引入不同生育期作物覆盖下不同深度土壤含盐量反演模型的构建中可行。

对于分枝期，从不同深度土层来看，反演模型 R_p^2 分别在 0.517 ~ 0.835、0.501 ~ 0.737、0.518 ~ 0.739 之间，$RMSE_p$ 分别在 0.064% ~ 0.126%、0.042% ~ 0.159%、0.047% ~ 0.107% 之间，MAE_p 分别在 0.055% ~ 0.192%、0.046% ~ 0.163%、0.043% ~ 0.237% 之间。0 ~ 15 cm 土层的反演精度优于其他深度，其次是 30 ~ 50 cm 土层；从模型来看，对于 0 ~ 15 cm 和 30 ~ 50 cm 的土层含盐量反演模型，XGBoost 模型反演效果优于 RF 和 BPNN，其 R_p^2 分别为 0.835、0.702、0.739、0.643，$RMSE_p$ 分别为 0.088%、0.105%、0.107%、0.059%，MAE_p 分别为 0.064%、0.055%、0.083%、0.043%，其次是 RF。对于 15 ~ 30 cm 土层，RF 模型反演精度最高，R_p^2 分别 0.696、0.643，$RMSE_p$ 分别 0.149%、0.159%，MAE_p 分别为 0.046%、0.059%，其次是 XGBoost 模型。对于现蕾期，3 种不同深度下的反演模型依旧是 XGBoost 最优，其次是 RF 反演模型，但从不同筛选方法来看，PCCs 筛选方法下 15 ~ 30 cm 和 30 ~ 50 cm 与GRA 筛选方法下 30 ~ 50 cm 土层，RF 模型反演效果均优于 XGBoost 模型，其 R_p^2 分别为 0.609、0.705、0.637，其次是 XGBoost 模型。对于初花期，从筛选方法来看，GRA 筛选方法下 30 ~ 50 cm 土层 RF 模型反演效果略优于 XGBoost 模型。其余无论是从不同深度还是不同筛选方法，XGBoost 模型的表现均优于 RF 和 BPNN 模型。

综上，在不同生育期苜蓿地的土壤含盐量反演最佳生育期为分枝期，最佳反演深度为 0 ~ 15 cm，且 XGBoost 模型整体表现最优。各生育期不同深度土层最优预测结果如图 3 所示。

基于两种变量筛选算法，分别绘制不同生育期土壤的 XGBoost、BPNN 及 RF 机器学习反演结果的散点图、拟合线，如图 4 所示。在不同生育期苜蓿地的土壤含盐量反演模型中，分枝期反演模型预测值拟合程度最高，初花期反演模型预测值之间拟合程度最接近，拟合程度仅次于分枝期，其次是现蕾期。从不同的含盐量反演模型来看，XGBoost 模型在分枝期和初花期的土壤含盐量预测值拟合程度均高于 RF 和 BPNN 模型，其 R_p^2 分别在 0.617 ~ 0.835、0.569 ~ 0.709 之间，其次是 RF 反演模型。但 RF 反演模型在现蕾期 15 ~ 30 cm 和 30 ~ 50 cm 土层中土壤含盐量预测值的拟合效果表现优于 XGBoost 反演模型，其 R_p^2 在 0.489 ~ 0.705 之间，其次是 XGBoost 模型，BPNN 模型预测值拟合程度最差。综上，土壤含盐量最佳预测深度为 0 ~ 15 cm，最佳预测生育期为分枝期，且 XGBoost 反演模型预测效果最优。

2.4　模型综合评价

将不同生育期苜蓿地 3 个深度土层的含盐量反演结果与实测值进行对比。由图 5 可知，在 0 ~ 15 cm 土层的 6 种耦合模型中，PCCs – XGBoost 耦合模型的鲁棒性最好（R_p^2/R_c^2 = 0.975），其次为 GRA – XGBoost（R_p^2/R_c^2 = 0.960）、GRA – BPNN（R_p^2/R_c^2 = 0.769）。此外 GRA – RF、PCCs – BPNN 和 GRA – BPNN 的 R_p^2/R_c^2 均低于 0.85，这表明在 0 ~ 15 cm 土层中 GRA 变量筛选方法与 RF 的耦合模型鲁棒性较差，且两种变量筛选方法与 BPNN 耦合模型的鲁棒性都较差。两种变量筛选方法与 XGBoost 耦合模型在分枝期和初花期 R_p^2/R_c^2 均高于 0.90，但其在现蕾期 R_p^2/R_c^2 较低。综合得知 XGBoost 模型的精度最好，鲁棒性也最好，也最稳定；BPNN 模型精度和鲁

表 4 土壤含盐量反演模型精度

Tab. 4 Accuracy of soil salinity inversion model

生育期	土层深度/cm	模型	建模集			验证集		
			R_c^2	$RMSE_c$/%	MAE_c/%	R_p^2	$RMSE_p$/%	MAE_p/%
分枝期	0 ~ 15	PCCs - XGBoost	0.856	0.040	0.031	0.835	0.088	0.064
		PCCs - BPNN	0.629	0.091	0.263	0.561	0.123	0.192
		PCCs - RF	0.679	0.085	0.039	0.589	0.126	0.076
		GRA - XGBoost	0.731	0.063	0.048	0.702	0.105	0.055
		GRA - BPNN	0.553	0.068	0.144	0.517	0.125	0.213
		GRA - RF	0.675	0.087	0.093	0.562	0.064	0.131
	15 ~ 30	PCCs - XGBoost	0.720	0.091	0.075	0.637	0.163	0.129
		PCCs - BPNN	0.615	0.057	0.079	0.570	0.042	0.163
		PCCs - RF	0.718	0.131	0.042	0.696	0.149	0.046
		GRA - XGBoost	0.678	0.089	0.073	0.617	0.095	0.069
		GRA - BPNN	0.513	0.084	0.060	0.501	0.082	0.071
		GRA - RF	0.679	0.128	0.039	0.643	0.159	0.059
	30 ~ 50	PCCs - XGBoost	0.750	0.043	0.034	0.739	0.107	0.083
		PCCs - BPNN	0.605	0.051	0.331	0.518	0.065	0.237
		PCCs - RF	0.630	0.069	0.039	0.548	0.078	0.049
		GRA - XGBoost	0.771	0.011	0.084	0.643	0.059	0.043
		GRA - BPNN	0.649	0.021	0.077	0.594	0.047	0.127
		GRA - RF	0.681	0.058	0.062	0.649	0.094	0.127
现蕾期	0 ~ 15	PCCs - XGBoost	0.794	0.016	0.012	0.697	0.121	0.088
		PCCs - BPNN	0.664	0.034	0.157	0.537	0.062	0.219
		PCCs - RF	0.677	0.074	0.083	0.612	0.115	0.097
		GRA - XGBoost	0.774	0.012	0.018	0.659	0.065	0.043
		GRA - BPNN	0.651	0.042	0.113	0.601	0.062	0.169
		GRA - RF	0.643	0.111	0.048	0.581	0.123	0.058
	15 ~ 30	PCCs - XGBoost	0.698	0.068	0.049	0.513	0.148	0.106
		PCCs - BPNN	0.652	0.047	0.134	0.507	0.034	0.135
		PCCs - RF	0.643	0.059	0.056	0.609	0.043	0.042
		GRA - XGBoost	0.796	0.011	0.057	0.717	0.159	0.067
		GRA - BPNN	0.629	0.065	0.079	0.521	0.138	0.105
		GRA - RF	0.532	0.096	0.156	0.489	0.068	0.212
	30 ~ 50	PCCs - XGBoost	0.781	0.092	0.057	0.604	0.174	0.113
		PCCs - BPNN	0.679	0.109	0.079	0.652	0.156	0.100
		PCCs - RF	0.722	0.074	0.05	0.705	0.110	0.073
		GRA - XGBoost	0.671	0.079	0.074	0.461	0.148	0.031
		GRA - BPNN	0.589	0.147	0.094	0.568	0.198	0.103
		GRA - RF	0.692	0.074	0.097	0.637	0.109	0.137
初花期	0 ~ 15	PCCs - XGBoost	0.773	0.102	0.072	0.697	0.137	0.095
		PCCs - BPNN	0.644	0.129	0.104	0.548	0.146	0.114
		PCCs - RF	0.716	0.101	0.066	0.631	0.134	0.149
		GRA - XGBoost	0.773	0.018	0.037	0.709	0.101	0.071
		GRA - BPNN	0.673	0.063	0.082	0.518	0.072	0.152
		GRA - RF	0.707	0.045	0.046	0.646	0.053	0.92
	15 ~ 30	PCCs - XGBoost	0.720	0.089	0.055	0.685	0.121	0.088
		PCCs - BPNN	0.601	0.044	0.108	0.584	0.079	0.142
		PCCs - RF	0.573	0.059	0.051	0.493	0.093	0.058
		GRA - XGBoost	0.786	0.015	0.042	0.569	0.047	0.037
		GRA - BPNN	0.579	0.049	0.099	0.494	0.129	0.141
		GRA - RF	0.735	0.042	0.062	0.637	0.057	0.051
	30 ~ 50	PCCs - XGBoost	0.762	0.111	0.073	0.622	0.146	0.110
		PCCs - BPNN	0.609	0.089	0.098	0.560	0.038	0.204
		PCCs - RF	0.742	0.087	0.060	0.685	0.136	0.021
		GRA - XGBoost	0.716	0.016	0.056	0.596	0.132	0.085
		GRA - BPNN	0.587	0.068	0.028	0.532	0.124	0.059
		GRA - RF	0.666	0.065	0.087	0.610	0.085	0.060

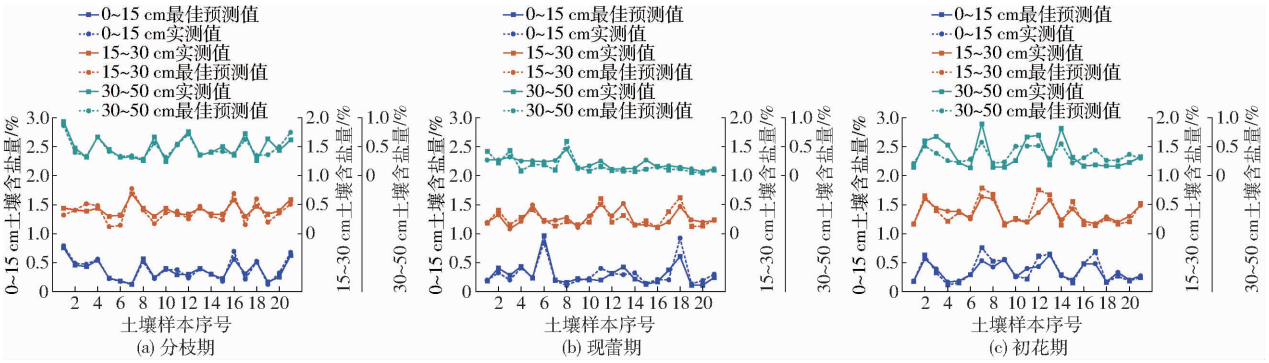

图 3　苜蓿样地土壤含盐量实测值与预测值对比

Fig. 3　Comparison of measured and predicted soil salinities of alfalfa plot

棒性都比 RF 模型差，稳定性也较差。因此，在分枝期和现蕾期苜蓿地 0 ~ 15 cm 土层中 PCCs - XGBoost 为反演该研究区域土壤含盐量的最佳耦合模型，在初花期苜蓿地 0 ~ 15 cm 土层中 GRA - XGBoost 为反演该研究区域土壤含盐量的最佳耦合模型。同理，在 15 ~ 30 cm 土层中，分枝期和现蕾期最佳土壤含盐量反演耦合模型为 PCCs - RF，初花期最佳土壤含盐量反演耦合模型为 PCCs - XGBoost。在 30 ~ 50 cm 土层中，分枝期最佳土壤含盐量反演耦合模型为 PCCs - XGBoost，现蕾期和初花期最佳土壤含盐量反演耦合模型为 PCCs - RF。

3　讨论

无人机遥感具有高效、灵活、成本低等优点，而多光谱相机能够获取地物在不同波长范围内的反射率，为反演土壤含盐量提供了新的手段。在植被生长的不同生育期内，土壤中的含盐量会随作物根系生长而产生变化，进而影响到作物生长[27]。因此准确反演土壤含盐量在不同生育期植被覆盖下不同深度土壤含盐量具有重要意义。本研究选取苜蓿地土壤作为研究对象，利用无人机搭载多光谱相机所采集的光谱指数构建了基于多生育期、多深度及多模型的土壤含盐量反演模型，以期为实现农耕土壤含盐量的精确、快速获取提供理论依据。

本研究发现基于光谱反射率所构建的光谱指数能够与实测的土壤含盐量达到良好的相关性，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[28-29]，同时基于光谱反射率优化的光谱指数来反演土壤含盐量的整体反演效果优于直接使用传统的光谱指数，而敏感变量的筛选可以有效地去除多光谱变量中的冗杂变量，为土壤含盐量准确反演提供更有优势的基础数据[30]。WEI 等[31]利用无人机多光谱图像定量估算土壤含盐量，通过不同变量选择方法对盐分指数进行筛选，并建立了含盐量反演模型，赵文举等[8]构建了基于全变量与筛选变量的土壤含盐量反演模型，其结果均表明经变量筛选后的含盐量反演模型精度高于全变量组模型。本研究选取 PCCs 与 GRA 法筛选高相关性的变量作为模型的输入组，有效提高了模型的预测精度，且 PCCs 与 XGBoost 模型取得了较好的耦合效果。

土壤含盐量反演模型作为预测土壤含盐量的重要组成部分，选取高精度、高效率的土壤含盐量反演模型，是实现土壤含盐量反演的关键[32]。ZHOU 等[33]利用可见近红外光谱在美国西部和欧盟西南部进行土壤含盐量定量反演，建立了基于 PLSR、Cubist、RF 和 XGBoost 预测模型，其结果表明 XGBoost 模型预测精度最高（R^2 = 0.71），其次 RF 模型也表现出了良好的模型性能，但比 XGBoost 模型稍差，这与本研究苜蓿地土壤含盐量反演结果一致，主要原因是 XGBoost 模型在求解时将损失函数 Taylor 展开到二阶，这使得其精度大大提高，能够在区域尺度上对不同生育期植被覆盖下土壤含盐量进行快速反演。在本研究中 XGBoost 模型在整体上表现出优秀的预测能力，在苜蓿分枝期 0 ~ 15 cm 土层表现最好。许多学者在比较相似模型时均认为 XGBoost 模型反演精度比较高，具有较强的稳定性，能克服非线性小样本的影响[34-35]。李春泽等[36]利用 Sentinel - 1、Sentinel - 2 MSI 多源遥感数据和 DEM 数据，结合 borutaShap 特征优选算法，构建了基于 GWR 与 XGBoost 土壤盐渍化反演模型，结果表明，XGBoost 模型精度优于 GWR 模型，而耦合 GWR 与 XGBoost 回归构建的土壤盐渍化反演模型预测精度得到显著提高。本研究利用低空无人机遥感数据构建基于敏感变量筛选与机器学习算法耦合模型，其中 XGBoost 模型与 PCCs 变量筛选方法耦合模型的鲁棒性最好（R_p^2/R_c^2 = 0.975），这表明在不同数据源土壤含盐量反演中，耦合模型均能够有效提高土壤含盐量的反演精度。故相比于 BPNN 和 RF，基于 XGBoost 算法构建的土壤含盐量反演模型更能真实地表达讨赖河流域作物覆盖下的土壤含盐量。

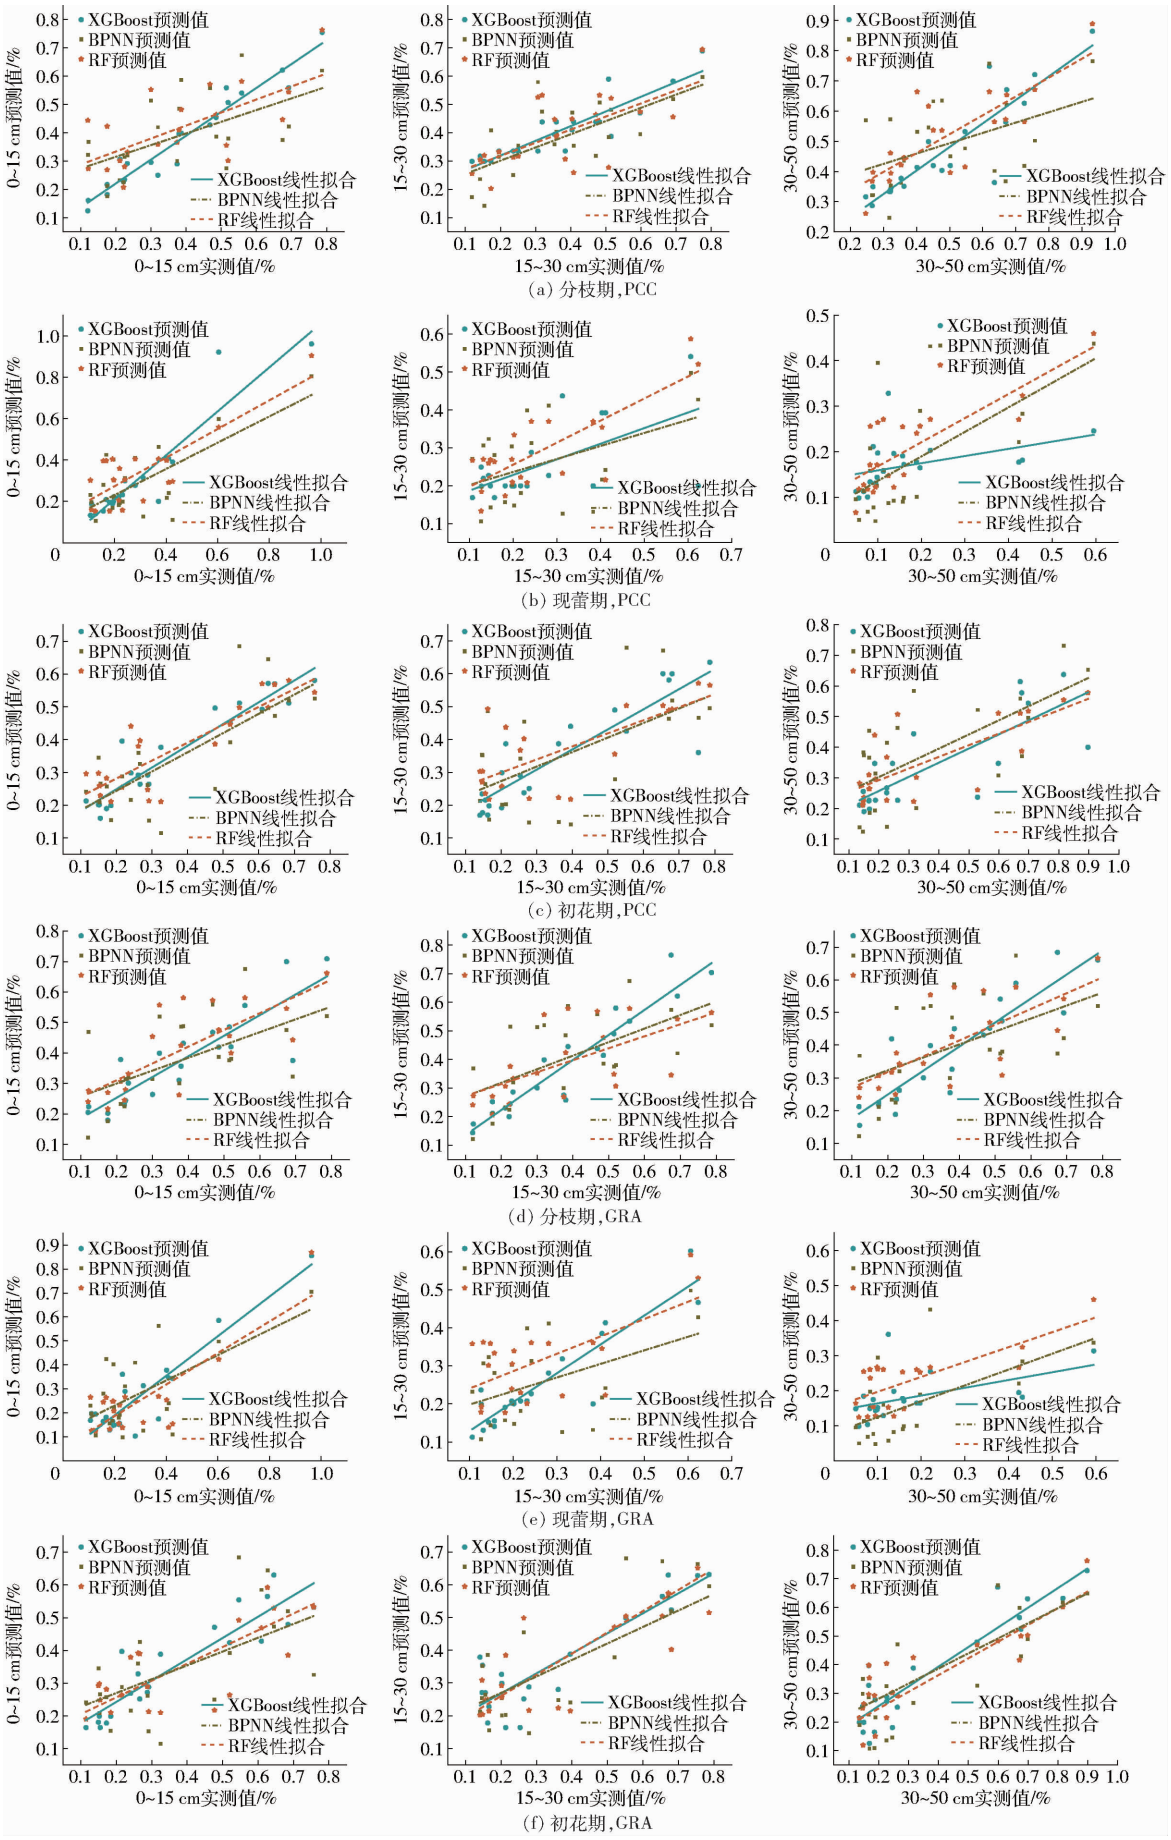

图 4 土壤含盐量实测值与预测值对比

Fig. 4 Comparison of measured value and predicted value of soil salt content

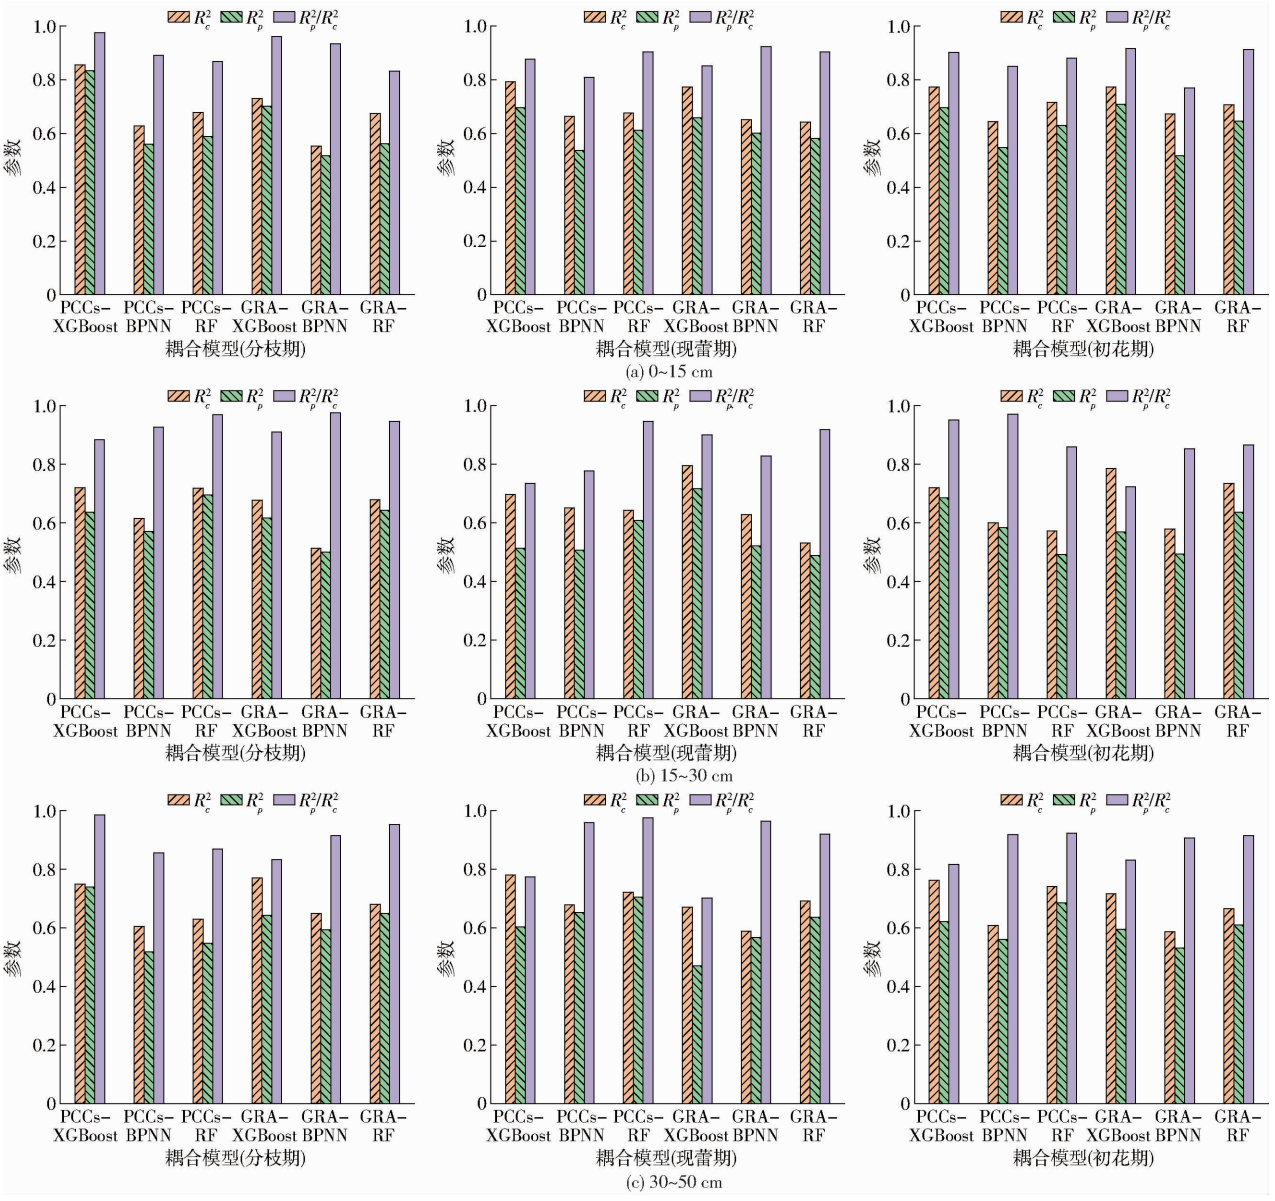

图 5　不同耦合模型反演效果

Fig. 5　Comparison of inversion effects of different coupling models

本文主要研究基于多光谱影像的不同生育期苜蓿地不同深度土壤含盐量反演模型，并取得了较好的反演结果，但利用多源遥感及环境因素构建反演模型有待进一步研究，今后可考虑与 Landsat 或 Sentinel 卫星遥感相结合，同时将植被纹理特征、土壤含水率、温度等参数加入到模型中，构建由田间尺度向流域尺度转换的“天-空-地”一体化土壤含盐量反演模型，并且本研究的试验方法与结论对其他植被覆盖下的土壤含盐量反演的适用性还有待进一步研究。

4　结论

（1）以 PCCs、GRA 筛选方法优选出的光谱指数作为模型输入组，对比模型性能，XGBoost 模型所构建的土壤含盐量反演模型的反演综合效果更好，均方根误差更小，训练速度也更快。这表明将 XGBoost 反演模型应用于土壤含盐量反演研究中可行。

（2）对比 XGBoost、BPNN、RF 机器学习算法所构建的土壤含盐量反演模型预测效果，可以看出 XGBoost 模型的预测精度和稳定性在整体上有不同程度的提高和改善。其中分枝期苜蓿地 0 ~ 15 cm 土层的预测效果最优，而 30 ~ 50 cm 土层预测效果较差。

（3）比较分析在 PCCs、GRA 变量筛选算法下的 XGBoost、BPNN、RF 机器学习算法的耦合模型反演效果，发现在 0 ~ 15 cm 土层中，PCCs - XGBoost 耦合模型的鲁棒性整体较好，其 R_p^2/R_c^2 最高为 0.975。而 GRA - BPNN 耦合模型较差。同理，在 15 ~ 30 cm 和 30 ~ 50 cm 土层的耦合模型中鲁棒性较好的均为 PCCs - RF 模型。

参 考 文 献

[1] GU S, JIANG S, LI X, et al. Soil salinity simulation based on electromagnetic induction and deep learning[J]. Soil and Tillage Research, 2023, 230: 105706.

[2] 卢秉林, 包兴国, 车宗贤, 等. 长期留茬免耕对河西绿洲灌区春小麦产量及稳定性的影响[J]. 农业工程学报, 2022, 38(7): 117 - 126.
LU Binglin, BAO Xingguo, CHE Zongxian, et al. Effects of long-term no-tillage with crop stubbles on yield and stability of spring wheat in Hexi Oasis Irrigated Areas[J]. Transactions of the CSAE, 2022, 38(7): 117 - 126. (in Chinese)

[3] 邓铭江, 陶汪海, 王全九, 等. 西北现代生态灌区建设理论与技术保障体系构建[J]. 农业机械学报, 2022, 53(8): 1 - 13.
DENG Mingjiang, TAO Wanghai, WANG Quanjiu, et al. Theory and technical guarantee system construction of modern ecological irrigation district in Northwest China[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(8): 1 - 13. (in Chinese)

[4] 刘奇, 张智韬, 刘畅, 等. 基于无人机遥感的夏玉米水分胁迫指数改进方法[J]. 农业工程学报, 2023, 39(2): 68 - 77.
LIU Qi, ZHANG Zhitao, LIU Chang, et al. Improved method of crop water stress index based on UAV remote sensing[J]. Transactions of the CSAE, 2023, 39(2): 68 - 77. (in Chinese)

[5] GE X, WANG J, DING J, et al. Combining UAV-based hyperspectral imagery and machine learning algorithms for soil moisture content monitoring[J]. PeerJ, 2019, 7: 6926 - 6953.

[6] 张智韬, 贺玉洁, 殷皓原, 等. 基于 Sentinel - 1/2 改进极化指数和纹理特征的土壤含盐量反演模型[J]. 农业机械学报, 2024, 55(1): 175 - 185.
ZHANG Zhitao, HE Yujie, YIN Haoyuan, et al. Synergistic estimation of soil salinity based on Sentinel - 1/2 improved polarization combination index and texture features[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(1): 175 - 185. (in Chinese)

[7] ZHAO W, ZHOU C, ZHOU C, et al. Soil salinity inversion model of oasis in arid area based on UAV multispectral remote sensing[J]. Remote Sensing, 2022, 14(8): 1 - 13.

[8] 赵文举, 马芳芳, 马宏, 等. 基于无人机多光谱影像的土壤盐分反演模型[J]. 农业工程学报, 2022, 38(24): 93 - 101.
ZHAO Wenju, MA Fangfang, MA Hong, et al. Soil salinity inversion model based on the multispectral images of UAV[J]. Transactions of the CSAE, 2022, 38(24): 93 - 101. (in Chinese)

[9] 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.

[10] 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)

[11] 田美玲, 葛翔宇, 丁建丽, 等. 耦合机器学习和机载高光谱数据的土壤含水量估算[J]. 激光与光电子学进展, 2020, 57(9): 232 - 241.
TIAN Meiling, GE Xiangyu, DING Jianli, et al. Coupled machine learning and unmanned aerial vehicle based hyperspectral data for soil moisture content estimation[J]. Laser & Optoelectronics Prpgress, 2020, 57(9): 232 - 241. (in Chinese)

[12] ZAMANI J M, CAO C, NI X, et al. PM2.5 prediction based on random forest, XGBoost, and deep learning using multisource remote sensing data[J]. Atmosphere, 2019, 10(7): 373.

[13] 韩文霆, 崔家伟, 崔欣, 等. 基于特征优选与机器学习的农田土壤含盐量估算研究[J]. 农业机械学报, 2023, 54(3): 328 - 337.
HAN Wenting, CUI Jiawei, CUI Xin, et al. Estimation of farmland soil salinity content based on feature optimization and machine learning algorithms[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(3): 328 - 337. (in Chinese)

[14] 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)

[15] 陈俊英, 王新涛, 张智韬, 等. 基于无人机-卫星遥感升尺度的土壤盐渍化监测方法[J]. 农业机械学报, 2019, 50(12): 161 - 169.
CHEN Junying, WANG Xintao, ZHANG Zhitao, et al. Soil salinization monitoring method based on UAV - satellite remote sensing scale-up[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(12): 161 - 169. (in Chinese)

[16] KE Y, IM J, LEE J, et al. Characteristics of Landsat 8 OLI-derived NDVI by comparison with multiple satellite sensors and in-situ observations[J]. Remote Sensing of Environment, 2015, 164: 298 - 313.

[17] LIU H, 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.

[18] BROGE N H, LEBLANC E. Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density[J]. Remote Sensing of Environment, 2001, 76(2): 156 - 172.

[19] ALLBED A, KUMAR L, ALDAKHEEL Y Y. Assessing soil salinity using soil salinity and vegetation indices derived from IKONOS high-spatial resolution imageries: applications in a date palm dominated region[J]. Geoderma, 2014, 230: 1 - 8.

[20] 付虹雨,王薇,卢建宁,等.基于无人机多光谱遥感和机器学习的苎麻理化性状估测[J].农业机械学报,2023,54(5):194 - 200,347.
FU Hongyu, WANG Wei, LU Jianning, et. al. Estimation of ramie physicochemical property based on UAV multi-spectral remote sensing and machine learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023,54(5):194 - 200,347. (in Chinese)

[21] SULIK J J, LONG D S. Spectral considerations for modeling yield of canola[J]. Remote Sensing of Environment, 2016, 184: 161 - 174.

[22] BEBDIG J, YU K, AASEN H, et al. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley[J]. International Journal of Applied Earth Observation and Geoinformation, 2015, 39:79 - 87.

[23] 杨玮,孙红,郑立华, 等.基于土壤参数的冬小麦产量预测模型[J].农业工程学报,2013,29(23):118 - 123.
YANG Wei, SUN Hong, ZHENG Lihua, et. al. Prediction model of winter wheat yield based on soil parameters[J]. Transactions of the CSAE, 2013,29(23):118 - 123. (in Chinese)

[24] FRIEDMAN J H. Greedy function approximation: a gradient boosting machine[J]. Annals of Statistics, 2001,29(5): 1189 - 1232.

[25] XU H, CHEN C, ZHENG H, et al. AGA - SVR-based selection of feature subsets and optimization of parameter in regional soil salinization monitoring[J]. International Journal of Remote Sensing, 2020, 41(12): 4470 - 4495.

[26] 依力亚斯江·努尔麦麦提, 师庆东, 阿不都拉·阿不力孜, 等. 灰色评估模型定量评价于田绿洲土壤盐渍化风险[J]. 农业工程学报, 2019, 35(8): 176 - 184.
ILYAS Nurmemet, SHI Qingdong, ABDULLA Abliz, et al. Quantitative evaluation of soil salinization risk in Keriya Oasis based on grey evaluation model[J]. Transactions of the CSAE, 2019, 35(8): 176 - 184. (in Chinese)

[27] 陆培榕,邢玮麟,杨玉杰, 等.棚内微咸水覆膜滴灌下带间土壤水盐分布特征模拟[J].农业机械学报,2023,54(7):360 - 371.
LU Peirong, XING Weilin, YANG Yujie, et al. Simulation of soil water and salt distribution characteristics within area between drip tapes under mulched brackish water drip irrigation in greenhouses[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023,54(7):360 - 371. (in Chinese)

[28] 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)

[29] 侯晨悦,王勇,李凡,等.冻结状态下盐渍化土壤中水溶性盐基离子含量高光谱反演[J].农业工程学报,2023,39(1):100 - 107.
HOU Chenyue, WANG Yong, LI Fan, et al. Hyperspectral inversion of water-soluble salt ion contents in frozen saline soil[J]. Transactions of the CSAE, 2023,39(1):100 - 107. (in Chinese)

[30] 赵文举,段威成,王银凤, 等. 基于敏感变量筛选的多光谱植被含水率反演模型研究[J].农业机械学报, 2023, 54(9): 343 - 351,385.
ZHAO Wenju, DUAN Weicheng, WANG Yinfeng, et al. Multispectral vegetation water content inversion model based on sensitive variable filtering[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(9): 343 - 351,385. (in Chinese)

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

[32] YAO R, GAO Q, LIU Y, et al. Deep vertical rotary tillage mitigates salinization hazards and shifts microbial community structure in salt-affected anthropogenic-alluvial soil[J]. Soil and Tillage Research, 2023, 227: 105627.

[33] ZHOU Y, CHEN S, HU B, et al. Global soil salinity prediction by open soil vis-NIR spectral library[J]. Remote Sensing, 2022, 14(21): 5627.

[34] CUI B,YE Z,ZHAO H, et al. Used car price prediction based on the iterative framework of XGBoost + LightGBM[J]. Electronics,2022,11(18):2932.

[35] ZHU X, CHU J, WANG K, et al. Prediction of rockhead using a hybrid N - XGBoost machine learning framework[J]. Journal of Rock Mechanics and Geotechnical Engineering,2021,13(6):1231 - 1245.

[36] 李春泽,张超,张皓源,等.基于 XGBoost 与地理加权回归的吉林省西部土壤盐渍化反演[J].中国农业大学学报, 2024, 29(2):1 - 10.
LI Chunze, ZHANG Chao, ZHANG Haoyuan, et al. Inversion of soil salinization in western Jilin Province based on XGBoost and geographically weighted regression[J]. Journal of China Agricultural University, 2024, 29(2):1 - 10. (in Chinese)