doi:10.6041/j.issn.1000-1298.2023.09.034

基于敏感变量筛选的多光谱植被含水率反演模型研究

赵文举　段威成　王银凤　周　春　马　宏
（兰州理工大学能源与动力工程学院，兰州 730050）

摘要：植被含水率是农田生态系统敏感性的重要表征，为提高近地遥感植被含水率反演效率和精度，基于无人机多光谱影像数据，提取苜蓿、玉米 2 种植被覆盖的光谱反射率，在此基础上引入红边波段计算改进光谱指数。将 5 种光谱反射率及 25 个光谱指数利用变量投影重要性（Variable importance in projection，VIP）分析、灰色关联度（Gray relational analysis，GRA）分析与皮尔逊（Person）相关性分析进行筛选，并建立基于反向神经网络（Back-propagation neural network，BPNN）、偏最小二乘法（Partial least squares regression，PLSR）、支持向量回归（Support vector regression，SVR）和随机森林（Random forest，RF）4 种机器学习模型，以确定不同作物覆盖下的最佳植被含水率反演模型。结果表明，3 种筛选算法中 VIP 和 GRA 的模型精度明显优于 Person 相关性分析，且反演结果波动较小；在 4 种机器学习算法中，SVR 算法在非线性问题中相较于 BPNN、PLSR、RF 算法具有较强的解析能力和模型鲁棒性，验证集决定系数 R^2 达到 0.77 以上，其结果能较真实反映植被含水率；两种样地基于 GRA 的植被含水率反演模型精度最高，苜蓿覆盖地 GRA－SVR 验证集 R^2 达 0.889，RMSE 为 0.798%，MAE 为 0.533%；玉米覆盖地反演结果验证集 R^2 为 0.848，RMSE 为 0.668%，MAE 为 0.542%。研究结果可为植被含水率的快速、精准反演提供理论依据。

关键词：植被含水率；无人机多光谱；光谱指数；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(2023)09-0343-09　　**OSID**：

Multispectral Vegetation Water Content Inversion Model Based on Sensitive Variable Filtering

ZHAO Wenju　DUAN Weicheng　WANG Yinfeng　ZHOU Chun　MA Hong
(*College of Energy and Power Engineering*, *Lanzhou University of Technology*, *Lanzhou* 730050, *China*)

Abstract: Vegetation moisture content is an important characterization of the sensitivity of farmland ecosystem. The spectral reflectance of two vegetation covers, alfalfa and corn were extracted, based on the UAV multispectral image data, and on the basis of which the red-edge band was introduced to calculate the improved spectral indices in order to increase the efficiency and accuracy of the inversion of vegetation water content by near-earth remote sensing. A back-propagation neural network (BPNN) was created after the five spectral bands and 25 indices were filtered by using the variable importance in projection (VIP), gray relational analysis (GRA), and Pearson's correlation analysis. To find the optimum inversion model for vegetation water content under various crop covers, back-propagation neural network, partial least squares regression (PLSR), support vector regression (SVR), and random forest (RF) were used. The findings indicated that, among the three screening algorithms, the accuracy of the models following GRA and VIP was significantly higher than that of Pearson's correlation analysis, and the inversion results were less volatile. Among the four machine learning algorithms, the SVR algorithm had a stronger nonlinear problem resolution ability and model robustness than BPNN, PLSR, and RF algorithms. In the nonlinear problem, the SVR algorithm outperformed the BPNN, PLSR, and RF algorithms in terms of analytical ability and model robustness. The validation set coefficient of determination R^2 reached above 0.77 and its results can offer more accurate feedback on vegetation water content. The GRA－SVR based inversion model for vegetation water content had the highest accuracy in the two sample sites. The GRA－SVR validation set R^2 of alfalfa cover reached 0.889, RMSE of

收稿日期：2023－04－17　修回日期：2023－06－26
基金项目：国家自然科学基金面上项目(52379042)和甘肃省重点研发计划项目(20YF8ND141)
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

0.798%, and MAE of 0.533%; the inversion result validation set R^2 of corn cover was 0.848, RMSE of 0.668%, and MAE of 0.542%. The research results can provide a theoretical basis for rapid and accurate inversion of vegetation water content.

Key words: vegetation water content; UAV multispectral; spectral index; variable filtering; inversion model

0 引言

植被生理生态指标作为农田生态系统敏感性表征,植被含水率直接反映土壤干燥程度[1]。研究植被含水率对干旱的响应有助于理解全球气候变化背景下,植被对气候波动的响应机制特征,这对提高植被变化预测、农业估产和水肥调控的准确性具有重要意义[2]。

传统方法获取植被含水率分布及变化规律费时费力,易受地形限制[3]。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,可为植被含水率反演提供科学高效的技术手段[4-5]。引入红边波段(Red edge position, RedEdge)可提取新的光谱信息,将其替代 R 波段可衍生多种改进光谱指数[6]。赵文举等[7]将红边波段应用于不同植被覆盖土壤含盐量反演研究,结果表明该波段对植被响应敏感,改进光谱指数对模型精度提升显著。ZHANG 等[8]通过对比有无红边波段的 20 个植被指数,发现引入 RedEdge 的变量组精度提高 7 个百分点,且此波段能与植被覆盖下的耕地土壤盐分建立非线性关系,可提升植被含水率反演精度。

光学遥感因其高密度数据组合及复杂的地物构成,严重影响模型反演精度和效率[9]。敏感光谱变量作为反演模型的重要输入因子,其筛选方法一直是该领域的研究热点[7]。研究表明,使用适合的变量筛选算法可提高模型精度及学习效率[10]。代秋芳等[11]将 CARS 筛选变量与全波段组分别进行 CNN 模型运算,反演结果中敏感变量组相较于全变量组决定系数 R^2 和均方根误差(RMSE)分别提升 0.03、0.007,改进效果显著。WANG 等[12]利用变量投影重要性分析等 4 种筛选算法提取敏感光谱变量进而高效反演土壤含盐量。陈俊英等[13]利用灰色关联度分析筛选光谱指数,基于不同机器学习算法,反演不同生育期不同深度土壤含盐量,筛选变量组反演结果优于全变量组。ZHAO 等[6]使用皮尔逊相关性分析法选取相关性高的光谱指数构建不同植被覆盖表层土壤含盐量反演模型,所构建模型较好地反映真实土壤盐分含量。变量筛选模型及机器学习算法凭借其处理非线性问题的优势,已经在农业水土遥感上得到应用,但多种变量筛选算法在植被指数优选中应用较少,且不同算法对植被指数敏感表征的相关研究较少,变量筛选算法结合不同机器学习模型,反演不同植被覆盖含水率的响应机理还有待深入研究。

综上所述,本研究基于无人机搭载多光谱成像系统获取苜蓿、玉米遥感影像,并对植被含水率进行同时段野外实测,通过引入红边波段构建 25 种传统及改进光谱指数,采用变量投影重要性(Variable importance in projection, VIP)、灰色关联度(Gray relational analysis, 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,构建基于反向神经网络(Back-propagation neural network, BPNN)、偏最小二乘法(Partial least squares regression, PLSR)、支持向量回归(Support vector regression, SVR)和随机森林(Random forest, RF)4 种机器学习算法的植被含水率反演模型,通过对反演效果评价,以讨赖河流域边湾农场为例,确定不同植被覆盖的含水率反演模型,以期为快速、精准反演植被含水率提供理论依据。

1 材料与方法

1.1 研究区概况

本研究区域位于甘肃省讨赖河流域边湾农场,该地区气候干旱,降雨稀少,蒸发量大,水资源时空分布不均。农场主要作物有:玉米、小麦、向日葵和苜蓿等,是河西走廊重要的粮食生产基地。无人机多光谱遥感监测及实地采样位置如图 1 所示。

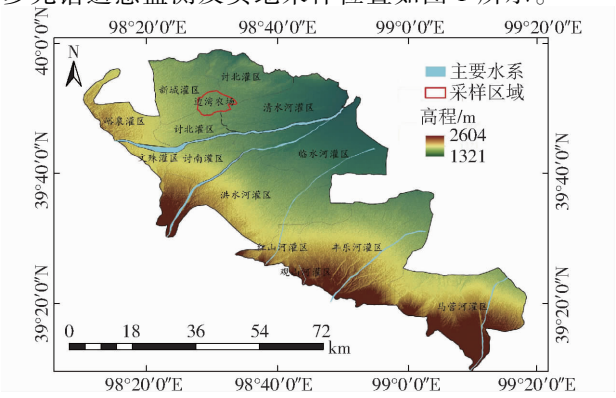

图 1 研究区示意图

Fig. 1 Schematic of study area

1.2　试验数据采集与预处理

1.2.1　无人机多光谱遥感影像

采样日试验区光照条件充足、均匀，所用遥测平台为 DJI 公司 Phantom 4 Multispectral 无人机，共搭载 6 个 1/2.9 英寸 CMOS 影像传感器，包含 1 个彩色 RGB 传感器和 5 个单色光谱传感器，详细波段参数如表 1 所示。设置飞行高度 40 m，航线重叠率 70%，旁像重叠率 65%，无人机平均速度 4 m/s，并采集白板数据用于辐射校正。通过 DJI Terra 及 ENVI 5.3 软件完成影像预处理。

表 1　机载光谱仪波段参数

Tab.1　Multispectral parameters of UAV

名称	波段/nm
R	650 ± 16
G	560 ± 16
B	450 ± 16
NIR	840 ± 26
RedEdge	730 ± 16

1.2.2　野外实测采样

2022 年 6 月 8—10 日在边湾农场进行实地采样，采样点分布见图 2。分别在苜蓿、玉米覆盖地均匀布设 60 个采样点。在获取无人机多光谱遥感影像后，对植被进行整株采样，并使用手持 RTK 进行打点定标。将采集样本用去离子水洗净称量鲜质量后，放入干燥箱 105℃杀青 30 min，然后 75℃干燥至恒定质量，测其干质量[14]。

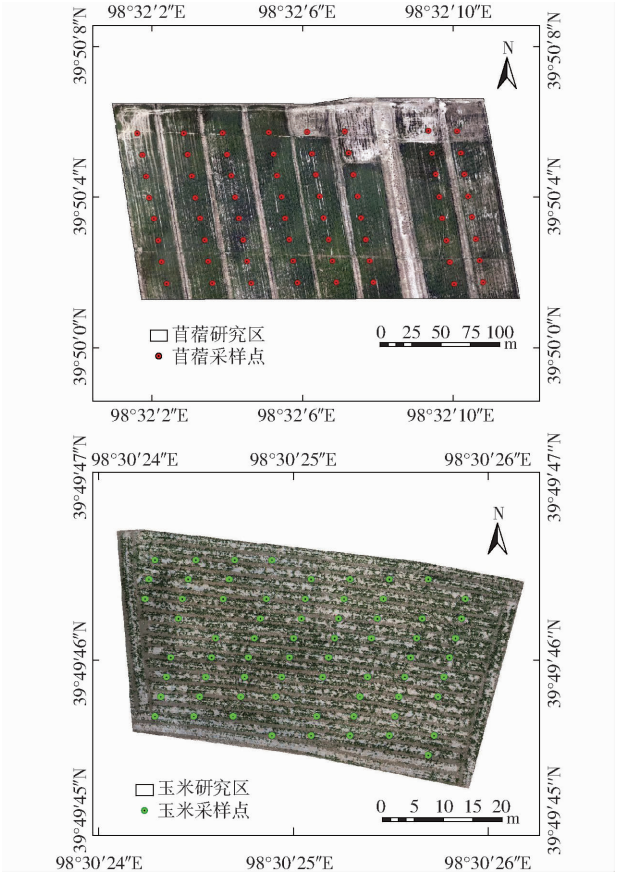

图 2　采样点分布图

Fig.2　Sampling point distribution

1.3　光谱指数构建与筛选

1.3.1　光谱指数构建

利用遥感影像中提取的光谱反射率，进行不同的波段组合。通过研究发现该红边波段可有效提升植被覆盖下反演模型精度[15]。本文将红边波段替换传统光谱指数中的 R 波段，进而衍生出改进光谱指数，共构成 25 个光谱指数如表 2 所示[16-19]。

表 2　光谱指数

Tab.2　Spectral index

光谱指数	表达式
归一化植被指数(NDVI)	$(NIR-R)/(NIR+R)$
改进归一化植被指数(NDVI-reg)	$(NIR-RedEdge)/(NIR+RedEdge)$
差值植被指数(DVI)	$NIR-R$
改进差值植被指数(DVI-reg)	$NIR-RedEdge$
增强植被指数(EVI)	$2.5(NIR-R)/(NIR+6R-7.5B+1)$
改进增强植被指数(EVI-reg)	$2.5(NIR-RedEdge)/(NIR+6RedEdge-7.5B+1)$
转换性植被指数(TVI)	$0.5[120(NIR-G)-200(R-G)]$
简单比值植被指数(SRVI)	$(1+L)(NIR-R)/(NIR+R+L)$
归一化差异绿度指数(NDGI)	$(G-R)/(G+R)$
归一化差异土壤指数(NDSI)	$(R-NIR)/(R+NIR)$
改进归一化差异土壤指数(NDSI-reg)	$(RedEdge-NIR)/(RedEdge+NIR)$
比值植被指数(SR)	NIR/R
覆盖度植被指数(CVI)	$(R/B)(G/B)$
修正叶绿素吸收指数(MCARI)	$[RedEdge-R-0.2(RedEdge-G)](RedEdge/R)$
优化土壤调节植被指数(OSAVI)	$(NIR-R)/(NIR+R+L)$
改进叶绿素指数(CI-reg)	$RedEdge/R-1$
类胡萝卜素吸收指数(TCARI)	$3[(RedEdge-R)-0.2(RedEdge-B)(RedEdge/R)]$
联合光谱指数(COSRI)	$(B+G)/(R+NIR)(NIR-R)/(NIR+R)$
绿叶指数(GLI)	$[(G-R)+(G-B)]/(2G)+R+B$
增强型土壤调节植被指数(MSAVI)	$[2NIR+1-2\mathrm{sqrt}((2NIR+1)-8(NIR-R)]/2$
归一化近红外指数(NNIR)	$NIR+R+G$
归一化比值植被指数(NR)	$R/(NIR+R+G)$
绿色叶绿素指数(GCI)	$NIR/G-1$
水体指数(NDWI)	$(G-NIR)/(G+NIR)$
改进湿度指数(NDMI-reg)	$(NIR-RedEdge)/(NIR+RedEdge)$

注：L 为经验常数，本文 SRVI 取 0.5，OSAVI 取 0.16；sqrt 表示求平方根运算。

1.3.2 筛选算法构建

光谱数据普遍存在数据密度大、波段及组合繁杂等特点。在模型构建中,冗余及干扰变量均会影响植被含水率反演精度和准确性,进而需要进行变量筛选[9]。本文选取 VIP、GRA 与 Person 相关性分析对 25 个光谱指数进行筛选、对比。VIP 分析和 GRA 分析通过 Matlab R2016a 实现,Person 相关性分析则是使用 IBM SPSS 26 进行筛选运算。

1.4 植被含水率反演模型构建与精度评价

1.4.1 模型构建

将玉米、苜蓿覆盖地获取的 60 个样本数据,随机挑选 40 个划分为建模集,用于回归建模与训练,20 个划分为验证集,用于检验模型精度。

通过 Person 相关性分析、VIP 分析及 GRA 分析,将优选出的敏感光谱变量作为模型的输入层,实测的植被含水率作为模型的输出层,分别采用 BPNN、SVR、RF 和 PLSR 构建植被含水率反演模型,机器学习模型均通过 Matlab R2016a 实现。

1.4.2 模型精度评价

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 植被含水率统计特征

为了对预测模型进行训练和验证,将划分的建模集与验证集互补性进行对比检验。全集、建模集和验证集描述性统计结果如表 3 所示。

表 3 植被含水率统计特征

Tab. 3 Statistical characteristics of vegetation moisture content

样本	样本集	样本数量/个	最小值/%	最大值/%	平均值/%	标准差/%	变异系数/%
苜蓿	全集	60	64.96	72.25	68.52	2.19	3.19
	建模集	40	64.96	72.11	68.60	2.12	3.09
	验证集	20	65.03	72.25	68.35	2.31	3.38
玉米	全集	60	80.08	85.25	82.62	1.55	1.87
	建模集	40	80.08	85.14	82.68	1.54	1.87
	验证集	20	80.17	85.25	82.50	1.55	1.88

由表 3 可知,不同植被覆盖的建模集和验证集均保持和全集植被含水率相近的统计结果。最大限度地减小了建模集和验证集之间的偏差。这表明所选建模集和验证集的植被含水率可以代表整个数据集,采样数据可以较为真实地反映研究区的植被含水率。

2.2 敏感光谱变量筛选

2.2.1 皮尔逊相关性筛选

在遥感定量估算植被含水率的研究过程中,通常需要建立植被含水率与光谱指数之间的相关关系,并进行分析研究[6],选择出敏感光谱变量,各变量之间的相关关系由皮尔逊相关系数(Pearson correlation coefficient, PCCs)表示。

将计算获取的光谱指数分别与苜蓿、玉米的植被含水率进行相关性分析,反射率、光谱指数与含水率的 PCCs 分布矩阵如图 3 所示。

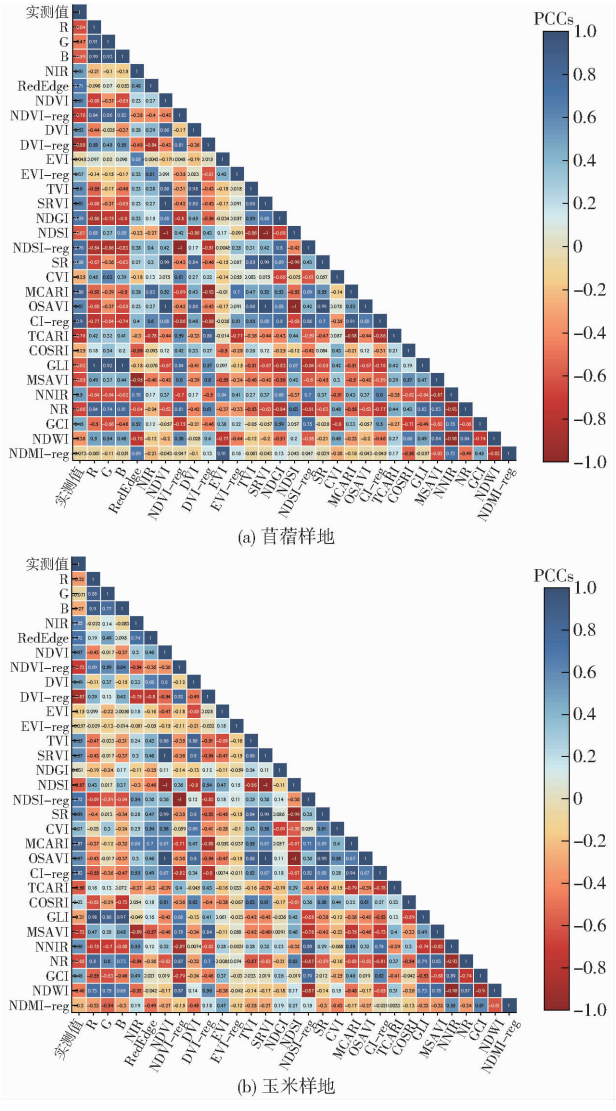

(a) 苜蓿样地

(b) 玉米样地

图 3 Person 相关系数矩阵

Fig. 3 Person correlation coefficient matrix

从图 3 可知,苜蓿地除 EVI、EVI − reg、CVI、COSRI 及 NDVI − reg 以外的 20 个光谱指数都通过了显著性检验;玉米地则去除 G 波段、EVI、EVI − reg、CVI、NDGI、COSRI 和 TVI,保留 18 个敏感变量作为模型输入层。

2.2.2　变量投影重要性筛选

变量投影重要性分析法是一种基于偏最小二乘算法的变量筛选方法，主要用于评估数据集中每个变量对于解释目标变量的重要性[12]。该方法通过计算每个变量在主成分分析或因子分析中的投影贡献，来评估变量的重要性。

在 Matlab R2016a 中对 5 个光谱反射率及 25 个光谱指数进行变量投影重要性分析，将筛选阈值设置为 1.0，筛选结果如图 4 所示。

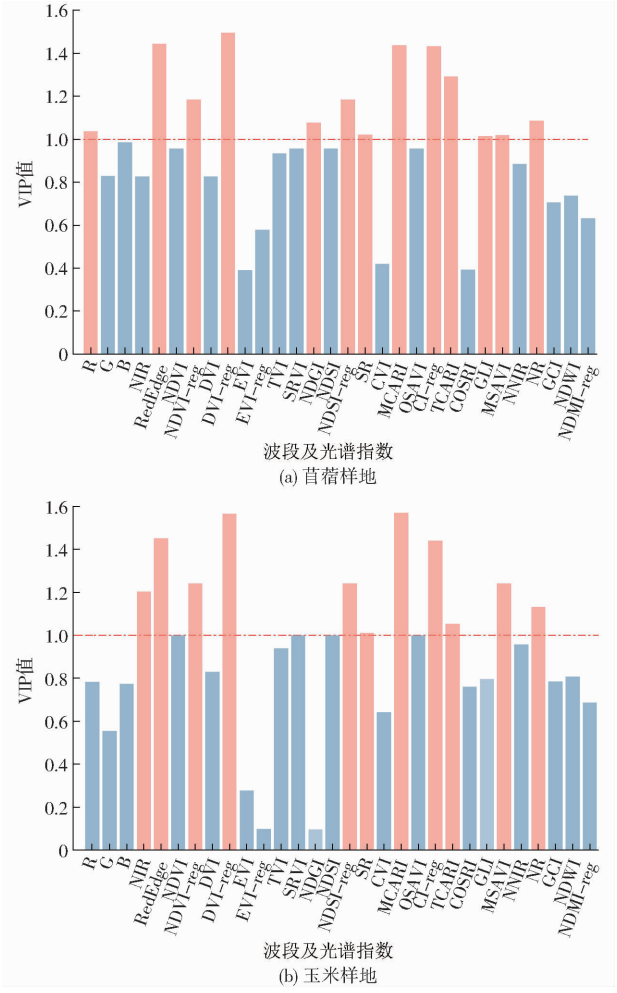

图 4　VIP 变量筛选结果

Fig. 4　VIP screening results

苜蓿覆盖地筛选出 R、RedEdge、NDVI－reg、DVI－reg、NDGI、NDSI－reg、SR、MCARI、CI－reg、TCARI、GLI、MSAVI、NR 共 13 个光谱波段及光谱指数。玉米地筛选出 NIR、RedEdge、NDVI－reg、DVI－reg、NDSI－reg、SR、MCARI、CI－reg、TCARI、MSAVI、NR 共 11 个光谱波段及指数，并分别作为模型输入层。

2.2.3　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，降低模型的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植被含水率进行了定量分析[20]，计算灰色关联度系数（Gray correlation degree，GCD），分辨系数取 0.5。

在 Matlab R2016a 中对光谱波段及指数进行灰色关联分析，将筛选敏感变量的 GCD 阈值设置为 0.7，苜蓿覆盖地筛选得 G、B、NIR、RedEdge、NDVI－reg、EVI－reg、NDSI－reg、SR、COSRI、MSAVI、NNIR、NDWI、NDMI－reg 共 13 个敏感变量作为模型输入层，玉米覆盖地则仅排除 DVI、EVI、TVI 和 TCARI。筛选结果如图 5 所示。

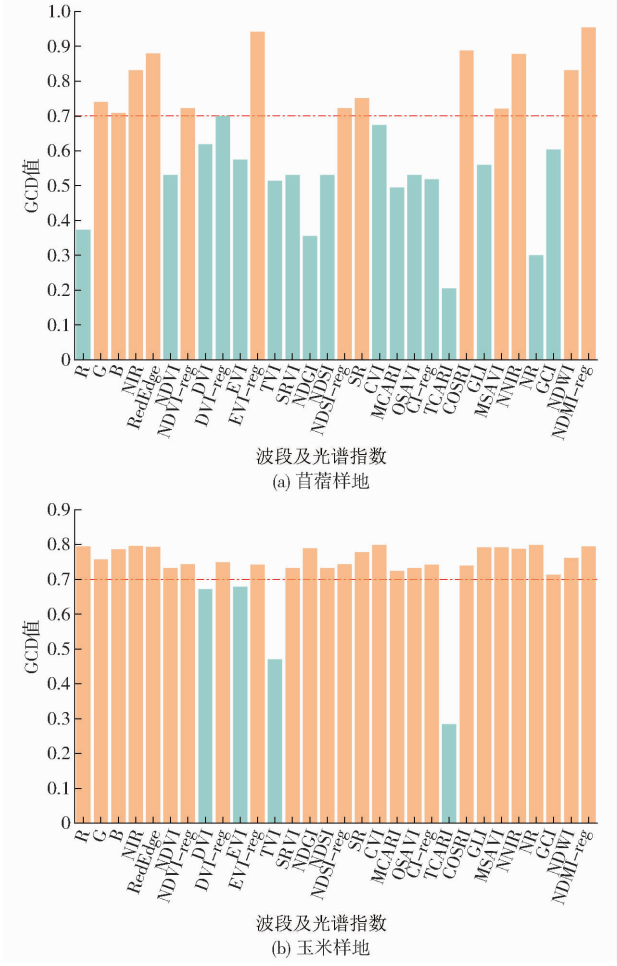

图 5　GRA 变量筛选结果

Fig. 5　GRA screening results

2.3　基于敏感变量的植被含水率反演模型

基于 VIP、GRA 和 Person 相关性分析 3 种筛选模型算法，建立波段及指数联合样本集，并对所选样本集构建 BPNN、PLSR、SVR 和 RF 共 4 种机器学习模型并进行精度验证，建模集和验证集的结果如表 4 所示。

经 Person 相关性分析的敏感变量样本集，由 4 种机器学习反演可得，建模集及验证集决定系数 R^2 均大于0.7，均方根误差（RMSE）存在小幅波动，多

表 4 植被含水率反演模型精度

Tab. 4 Inversion model accuracy of vegetation moisture content

样本	模型	建模集			验证集		
		R^2	RMSE/%	MAE/%	R^2	RMSE/%	MAE/%
苜蓿	PCCs－BPNN	0.731	1.755	1.284	0.720	2.563	1.961
	PCCs－PLSR	0.857	5.059	0.676	0.871	3.715	0.638
	PCCs－SVR	0.817	1.263	1.115	0.792	1.441	1.318
	PCCs－RF	0.895	0.898	0.742	0.869	1.135	0.885
	VIP－BPNN	0.840	0.880	0.423	0.814	1.190	0.839
	VIP－PLSR	0.886	4.530	0.606	0.882	3.561	0.581
	VIP－SVR	0.875	1.017	0.907	0.879	1.044	0.934
	VIP－RF	0.892	0.957	0.788	0.887	1.164	0.967
	GRA－BPNN	0.855	0.869	0.439	0.778	1.874	1.157
	GRA－PLSR	0.835	5.450	0.724	0.821	4.374	0.794
	GRA－SVR	0.893	0.650	0.322	0.889	0.798	0.533
	GRA－RF	0.897	1.001	0.791	0.590	1.181	0.876
玉米	PCCs－BPNN	0.805	0.719	0.542	0.707	0.899	0.743
	PCCs－PLSR	0.872	3.493	0.365	0.589	5.701	0.886
	PCCs－SVR	0.791	0.748	0.644	0.788	0.782	0.611
	PCCs－RF	0.738	0.884	0.688	0.775	0.847	0.687
	VIP－BPNN	0.887	0.523	0.348	0.820	0.692	0.534
	VIP－PLSR	0.840	3.904	0.447	0.774	3.298	0.549
	VIP－SVR	0.788	0.748	0.631	0.779	0.765	0.581
	VIP－RF	0.845	0.678	0.475	0.844	0.671	0.511
	GRA－BPNN	0.873	0.590	0.400	0.782	0.731	0.605
	GRA－PLSR	0.885	3.306	0.357	0.768	3.662	0.659
	GRA－SVR	0.771	0.748	0.530	0.848	0.668	0.542
	GRA－RF	0.745	0.876	0.688	0.776	0.864	0.707

处于 0.7% ~1.2%之间，玉米覆盖地 MAE 在 0.9%以内，苜蓿覆盖地在 2.0%以内。由 VIP 筛选的样本集，执行反演运算。结果表明，建模集、验证集 R^2 均高于 0.75。除 PLSR 反演结果异常，其余模型的 RMSE 均小于 1.2%，MAE 保持在 1.0%以内。对反演结果进行权重分析，此敏感变量组最佳反演模型为 RF。GRA 输入因子较多，由反演结果可得，建模集及验证集 R^2 除 RF 外均大于 0.75；模型 RMSE 多低于 1.2%；玉米覆盖地 MAE 在 0.7%以内。对评价指标进行权重分析，GRA 苜蓿地及玉米地最佳反演模型为 SVR。

基于 4 种变量筛选算法，分别绘制苜蓿、玉米覆盖地的机器学习反演结果散点图、拟合曲线，如图 6（图中阴影部分为反演结果置信区间）所示。苜蓿覆盖地的散点分布比较均匀且集中，与玉米反演结果相比，其距离置信区间偏差较小，拟合曲线斜率也较为一致。苜蓿含水率反演结果主要集中于置信区间的中央，范围为 66% ~70%。而玉米含水率分布则比较分散，PCCs－PLSR 反演结果的离散性较为明显，反演精度最差。在两种植被覆盖下，最佳反演模型均为 GRA－SVR，散点图分布均匀，置信区间合理，残值较少，所有模型的决定系数 R^2 都在 0.8 以上，反演效果较好。

2.4 模型综合评价

将不同植被覆盖条件下含水率反演结果与实测值进行对比。由图 7（图中误差棒长度表示 RMSE）可得，PLSR 在各类筛选模型中的 RMSE 最大，均大于 3.5%，精度最差。基于 GRA 和 VIP 筛选后建立的植被含水率反演模型多取得了较好的反演效果，Person 相关性分析筛选后的反演结果稍差，但苜蓿样地 GRA－RF 反演结果相较于其他两种筛选算法还有待改进。

综上所述，苜蓿、玉米覆盖地植被含水率最佳反演模型为基于灰色关联度分析的支持向量回归模型，苜蓿地建模集 R^2 为 0.893，RMSE 为 0.650%，MAE 为 0.322，验证集 R^2 为 0.889，RMSE 为 0.798%，MAE 为 0.533%；玉米覆盖地建模集 R^2 为 0.771，RMSE 为 0.748%，MAE 为 0.530%，验证集 R^2 为 0.848，RMSE 为 0.668%，MAE 为 0.542%，模型反演精度较高，可较真实反映不同植被覆盖的含水率变化情况。

3 讨论

近地遥感具有获取信息快、覆盖面积广及运行成本低等优势，在估算植被含水率方面有较大的发展潜力，是未来精准农业的发展方向[21]。但采用大量的光谱变量使模型的构建变得较为复杂，且大量的光谱变量往往含有冗余信息。因此，选择适宜的筛选算法及反演模型是提高植被含水率监测精度的有效途径。

敏感变量筛选可有效去除光谱变量中的冗余信息，降低植被含水率反演模型的复杂程度，达到提高反演模型精度的目的。综合对比分析基于 3 种变量筛选方法的反演模型精度，基于 VIP 建立的 4 种反演模型精度 R^2 较为统一，且均优于 PCCs 反演结果。但就整体而言，两块样地最佳反演模型均为 GRA－SVR，这与贾萍萍等[22]、LI 等[23]的研究结果一致。但 GRA 提取苜蓿、玉米敏感变量有较大差异，苜蓿样地筛选后敏感变量剩余 13 个，玉米样地筛选后仅排除 4 个冗余变量。主要原因是作物光谱特征因作物类型不同、植被覆盖差异，会表现出明显区别[13]，采样时苜蓿种植密度高，且正处于盛花期；玉米覆盖度低，大面积的土壤处于裸露状态。张智韬等[24]在研究植被覆盖程度对土壤含盐量反演的影响时，证实了这一点，随着植被覆盖度增加，盐分指数敏感性逐渐降低，植被指数敏感性逐渐增加。不同筛选模

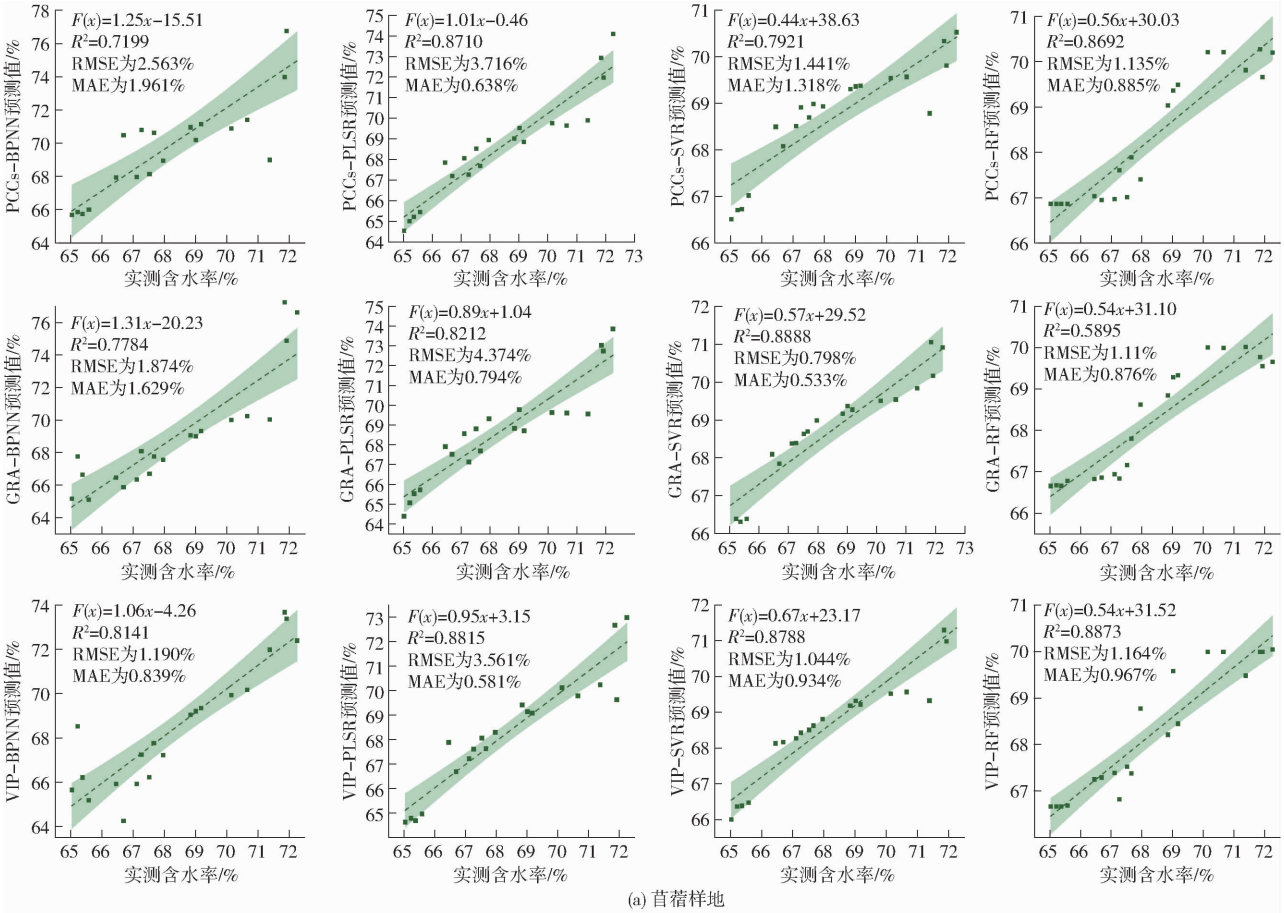

(a) 苜蓿样地

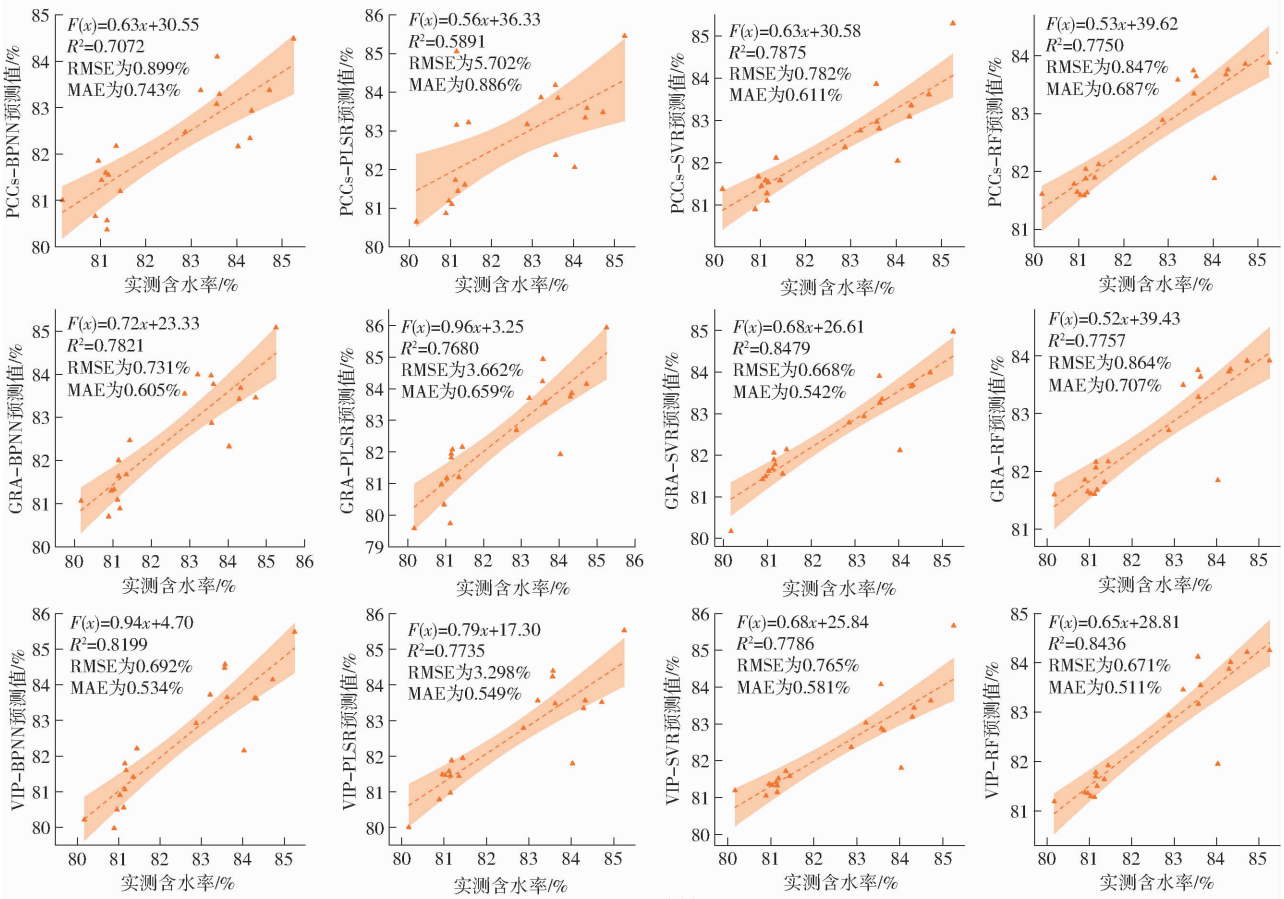

(b) 玉米样地

图 6　植被含水率实测值与预测值对比

Fig. 6　Comparison of measured and predicted vegetation moisture content

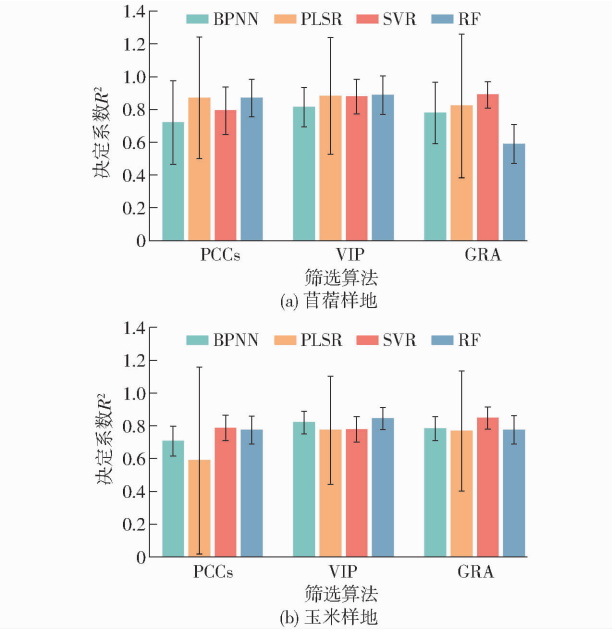

图 7 模型反演精度对比

Fig. 7 Comparisons of model inversion accuracy

型对光谱变量的响应差异较大[25]，红边波段及相关改进光谱指数复现率较高，而 DVI、NDSI 对模型贡献率较差，引入红边波段改进后，光谱指数的 Person 相关性及变量筛选评分明显提升。此次采样的玉米正处于拔节期，含水率为 75% ~85%，盛花期苜蓿为 60% ~75%，与 IMPOLLONIA 等[26]利用无人机遥感技术对 14 个芒果杂交品种进行基于光谱指数的含水率测定结果一致。当植被含水率超 30% 时，模型精度较为稳定且精度较高。AHMAD 等[27]以 TRMM 和 AVHRR 星载遥感数据为基础，分别建立支持向量回归、人工神经网络和多元线性回归模型反演土壤含水率，研究表明，SVR 反演结果最优，这与本研究最佳反演模型结果一致，支持向量回归具有较高的估测性能，在处理多类问题时准确性较高，可有效反演植被含水率。

本研究基于无人机多光谱影像，建立不同植被覆盖的植被含水率反演模型并取得了较好的反演结果，相较于 BPNN、PLSR 和 RF，通过 GRA - SVR 筛选、反演的植被含水率更真实地反映不同作物内水分变化情况。但就试验设计而言，仍然存在一定的改进空间，可考虑引入机载 LiDAR 进行植物表征监测，多源遥感数据的融合能进一步有效提高反演精度，同时探究不同植被、不同生长周期的含水率变化情况等[28-29]。进而以多源近地遥感为主要技术手段，构建多作物、少冗余、高精度的植被含水率反演模型，以期实现不同植被种类含水率的快速、精准获取。

4 结论

(1) 对比 Person 分析结果构建的模型，通过 VIP、GRA 筛选获取的输入数据所构建的植被含水率反演模型反演效果更好，均方根误差更小，训练速度也明显提高，表明 VIP、GRA 筛选算法应用于植被含水率反演及相关研究是可行的。

(2) 在 4 种机器学习算法中，SVR 算法在非线性问题中相较于 BPNN、PLSR、RF 算法具有较强的解析能力和较高的模型鲁棒性，验证集 R^2 在 0.779 ~0.889 之间，反演结果波动较小。故 SVR 对于不同作物覆盖下的植被含水率反演结果最能真实体现植被水分变化情况。

(3) 对比分析 24 个土壤含水率反演模型，在不同植被覆盖下，GRA - SVR 反演结果最佳，验证集苜蓿覆盖地 R^2 为 0.889，RMSE 为 0.798%，MAE 为 0.533%，玉米覆盖地 R^2 为 0.848，RMSE 为 0.668%，MAE 为 0.542%，且苜蓿覆盖下植被含水率反演精度略优于玉米覆盖地。

参 考 文 献

[1] 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)

[2] QI Guizeng, SONG Jinxi, LI Qi, et al. Response of vegetation to multi-timescales drought in the Qinling Mountains of China [J]. Ecological Indicators, 2022, 135: 108539 - 108548.

[3] DING Jianli, YU Danlin. Monitoring and evaluating spatial variability of soil salinity in dry and wet seasons in the Werigan-Kuqa Oasis, China, using remote sensing and electromagnetic induction instruments[J]. Geoderma, 2014, 235: 316 - 322.

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

[6] ZHAO Wenju, ZHOU Chun, ZHOU Changquan, 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.

[7] 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 UAV multispectral images[J]. Transactions of the CSAE，2022，38(24)：93－101.（in Chinese）

[8] ZHANG Huanxue，LI Qiangzi，LIU Jiangui，et al. Image classification using rapideye data：integration of spectral and textual features in a random forest classifier[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing，2017，10(12)：5334－5349.

[9] 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）

[10] HONG Yongsheng，CHEN Yiyun，YU Lei，et al. Combining fractional order derivative and spectral variable selection for organic matter estimation of homogeneous soil samples by VIS－NIR spectroscopy[J]. Remote Sensing，2018，10(3)：1－20.

[11] 代秋芳，廖臣龙，李震，等. 基于 CARS－CNN 的高光谱柑橘叶片含水率可视化研究[J]. 光谱学与光谱分析，2022，42(9)：2848－2854.
DAI Qiufang，LIAO Chenlong，LI Zhen，et al. Hyperspectral visualization of citrus leaf moisture content based on CARS－CNN[J]. Spectroscopy and Spectral Analysis，2022，42(9)：2848－2854.（in Chinese）

[12] 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 Lake region，Xinjiang，China[J]. Geoderma，2019，353：172－187.

[13] 陈俊英，姚志华，张智韬，等. 大田葵花土壤含盐量无人机遥感反演研究[J]. 农业机械学报，2020，51(7)：178－191.
CHEN Junying，YAO Zhihua，ZHANG Zhitao，et al. UAV remote sensing inversion of soil salinity in field of sunflower[J]. Transactions of the Chinese Society for Agricultural Machinery，2020，51(7)：178－191.（in Chinese）

[14] 赵文举，马锋，曹伟，等. 水肥耦合对基质栽培番茄产量及品质的影响[J]. 农业工程学报，2022，38(2)：95－101.
ZHAO Wenju，MA Feng，CAO Wei，et al Effects of water and fertilizer coupling on the yield and quality of tomatoes[J]. Transactions of the CSAE，2022，38(2)：95－101.（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 Yinghai，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 Huiqing，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] 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）

[21] REJEB A，ABDOLLAHI A，REJEB K，et al. Drones in agriculture：a review and bibliometric analysis[J]. Computers and Electronics in Agriculture，2022，198：107017－107036.

[22] 贾萍萍，尚天浩，张俊华，等. 利用多源光谱信息反演宁夏银北地区干湿季土壤含盐量[J]. 农业工程学报，2020，36(17)：125－134.
JIA Pingping，SHANG Tianhao，ZHANG Junhua，et al. Inversion of soil salinity in dry and wet seasons based on multi-source spectral data in Yinbei area of Ningxia，China[J]. Transactions of the CSAE，2020，36(17)：125－134.（in Chinese）

[23] LI Mingliang，LI Xican，TIAN Ye，et al. Grey relation estimating pattern of soil organic matter with residual modification based on hyper-spectral data[J]. The Journal of Grey System，2016，28(4)：27－39.

[24] 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. Inversion of soil salt content by UAV multispectral remote sensing under different vegetation coverage[J]. Transactions of the Chinese Society for Agricultural Machinery，2022，53(8)：220－230.（in Chinese）

（下转第 385 页）

ZHU Meizhuang, WANG Genxu, XIAO Yao. Study on soil water infiltration change of alpine meadow in permafrost region of Qinghai－Tibet Plateau[J]. Journal of Glacier and Frozen Soil, 2017, 39(6):1316－1325. (in Chinese)

[34] 曹红霞, 康绍忠, 武海霞. 同一质地(重壤土)土壤水分特征曲线的研究[J]. 西北农林科技大学学报(自然科学版), 2002, 30(1):9－12.
CAO Hongxia, KANG Shaozhong, WU Haixia. Study on soil water characteristic curve of the same texture (heavy loam)[J]. Journal of Northwest A&F University (Natural Science Edition), 2002, 30(1): 9－12. (in Chinese)

[35] FU Q, ZHAO H, LI T X, et al. Effects of biochar addition on soil hydraulic properties before and after freezing-thawing[J]. CATENA, 2019, 176: 112－124.

[36] EDEH I G, MAEK O. The role of biochar particle size and hydrophobicity in improving soil hydraulic properties[J]. European Journal of Soil Science, 2022, 73(1): e13138.

[37] YARGICOGLU E N, SADASIVAM B Y, REDDY K R, et al. Physical and chemical characterization of waste wood derived biochars[J]. Waste Management, 2015, 36: 256－268.

[38] BODNER G, SCHOLL P, KAUL H P. Field quantification of wetting-drying cycles to predict temporal changes of soil pore size distribution[J]. Soil and Tillage Research, 2013, 133: 1－9.

[39] 田丹, 屈忠义, 李波. 生物炭对砂土水力特征参数及持水特性影响试验研究[J]. 灌溉排水学报, 2013, 32(3):135－137.
TIAN Dan, QU Zhongyi, LI Bo. Experimental study on the influence of biochar on hydraulic characteristic parameters and water retention characteristics of sand[J]. Journal of Irrigation and Drainage, 2013, 32(3):135－137. (in Chinese)

[40] 王红兰, 唐翔宇, 张维. 施用生物炭对紫色土坡耕地耕层土壤水力学性质的影响[J]. 农业工程学报, 2015, 31(4): 107－112.
WANG Honglan, TANG Xiangyu, ZHANG Wei. Effect of biochar application on the hydraulic properties of topsoil in purple soil slope farmland[J]. Transactions of the CSAE, 2015, 31(4):107－112. (in Chinese)

[41] OBIA A, BORRESEN T, MARTINSEN V, et al. Effect of biochar on crust formation, penetration resistance and hydraulic properties of two coarse-textured tropical soils[J]. Soil and Tillage Research, 2017, 170: 114－121.

[42] 孙召军, 李金山, 贾艳辉. 干湿交替次数对土壤干密度和饱和导水率的影响[J]. 灌溉排水学报, 2022, 41(6): 89－96.
SUN Shaojun, LI Jinshan, JIA Yanhui. Effect of dry-wet alternation times on soil dry density and saturated hydraulic conductivity[J]. Journal of Irrigation and Drainage, 2022, 41(6): 89－96. (in Chinese)

[43] 张伟, 马建刚, 王开德. 滇西南不同土地利用方式坡地土壤大孔隙特征及与饱和导水率的关系[J]. 西北农林科技大学学报(自然科学版), 2023, 51(4): 84－93.
ZHANG Wei, MA Jian'gang, WANG Kaide. Characteristics of soil macropore and its relationship with saturated hydraulic conductivity in sloping land with different land use patterns in southwest Yunnan[J]. Journal of Northwest A&F University (Natural Science Edition), 2023, 51(4): 84－93. (in Chinese)

[44] 王浩飞, 王黎, 朱习爱. 橡胶-益智复合林土壤饱和导水率空间分布格局及其影响因子[J/OL]. 生态学杂志, 2022: 1－11. https://kns.cnki.net/kcms/detail/21.1148.q.20221018.1650.010.html.
WANG Haofei, WANG Li, ZHU Xiai. Spatial distribution pattern of soil saturated hydraulic conductivity and its influencing factors in rubber－Yizhi compound forest[J/OL]. Journal of Ecology, 2022:1－11. https://kns.cnki.net/kcms/detail/21.1148.q.20221018.1650.010.html. (in Chinese)

(上接第 351 页)

[25] 冯权泷, 牛博文, 朱德海, 等. 土地利用/覆被深度学习遥感分类研究综述[J]. 农业机械学报, 2022, 53(3): 1－17.
FENG Quanlong, NIU Bowen, ZHU Dehai, et al. Review for deep learning in land use and land cover remote sensing classification[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(3): 1－17. (in Chinese)

[26] IMPOLLONIA G, CROCI M, MARTANI E, et al. Moisture content estimation and senescence phenotyping of novel Miscanthus hybrids combining UAV-based remote sensing and machine learning[J]. GCB Bioenergy, 2022, 14(6): 639－656.

[27] AHMAD S, KALRA A, STEPHEN H. Estimating soil moisture using remote sensing data: a machine learning approach[J]. Advances in Water Resources, 2010, 33(1):69－80.

[28] 李艳坤, 董汝南, 张进, 等. 光谱数据解析中的变量筛选方法[J]. 光谱学与光谱分析, 2021, 41(11): 3332－3338.
LI Yankun, DONG Runan, ZHANG Jin, et al. Variable screening methods in spectral data analysis[J]. Spectroscopy and Spectral Analysis, 2021, 41(11): 3332－3338. (in Chinese)

[29] 靳宁, 张东彦, 李振海, 等. 基于多光谱卫星模拟波段反射率的冬小麦水分状况评估[J]. 农业机械学报, 2020, 51(11): 243－252.
JIN Ning, ZHANG Dongyan, LI Zhenhai, et al. Evaluation of water status of winter wheat based on simulated reflectance of multispectral satellites[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(11): 243－252. (in Chinese)