

基于无人机多光谱遥感的玉米根域土壤含水率研究

张智韬^{1,2} 谭丞轩^{1,2} 许崇豪^{1,2} 陈硕博^{1,2} 韩文霆^{1,3} 李 宇²

(1. 西北农林科技大学旱区农业水土工程教育部重点实验室, 陕西杨凌 712100;
2. 西北农林科技大学水利与建筑工程学院, 陕西杨凌 712100;
3. 西北农林科技大学机械与电子工程学院, 陕西杨凌 712100)

摘要: 及时获取农田作物根域土壤墒情是实现精准灌溉的基础和关键。以内蒙古自治区达拉特旗昭君镇试验站大田玉米为研究对象,利用无人机遥感系统,分别在玉米营养生长期 (Vegetative stage, V 期)、生殖期 (Reproductive stage, R 期) 和成熟期 (Maturation stage, M 期) 获得 7 次玉米冠层多光谱正射影像,并同步采集玉米根域不同深度土壤含水率 (Soil moisture content, SMC);然后,采用灰色关联法对提取的多种植被指数 (Vegetation index, VI) 进行筛选,选取与土壤含水率敏感的植被指数;最后,分别采用多元混合线性回归 (Cubist)、反向传播神经网络 (Back propagation neural network, BPNN) 和支持向量机回归 (Support vector machine regression, SVR) 等机器学习方法,构建不同生育期的敏感植被指数与土壤含水率的关系模型。结果表明,3 种机器学习方法中 SVR 模型在各生育期的建模与预测精度均最优,BPNN 模型次之,Cubist 模型最差;其中 SVR 模型在 M 期效果最优,其建模集和验证集 R^2 分别为 0.851 和 0.875,均方根误差 (Root mean square error, RMSE) 均为 0.7%,标准均方根误差 (Normalized root mean square error, nRMSE) 分别为 8.17% 和 8.32%,R 期效果最差,其建模集和验证集 R^2 分别为 0.619 和 0.517。

关键词: 玉米; 土壤含水率; 无人机遥感; 植被指数; 机器学习

中图分类号: S152.7; TP79 **文献标识码:** A **文章编号:** 1000-1298(2019)07-0246-12

Retrieving Soil Moisture Content in Field Maize Root Zone
Based on UAV Multispectral Remote Sensing

ZHANG Zhitao^{1,2} TAN Chengxuan^{1,2} XU Chonghao^{1,2} CHEN Shuobo^{1,2} HAN Wenting^{1,3} LI Yu²

(1. Key Laboratory of Agricultural Soil and Water Engineering in Arid Areas, Ministry of Education, Northwest A&F University, Yangling, Shaanxi 712100, China
2. College of Water Resources and Architectural Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China
3. College of Mechanical and Electronic Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China)

Abstract: Rapid acquisition of soil moisture content (SMC) in crop root zone is the key to drought supervision and precision irrigation. The relationship between the unmanned aerial vehicle (UAV) multispectral remote sensing and SMC was mainly studied based on the field maize data of experimental station in Zhaojun Town, Dalate Qi, Inner Mongolia. The canopy images of field maize with five irrigation treatments were obtained at different growth stages (vegetative stage, reproductive stage and maturation stage) through the six-rotor UAV equipped with 5-band multispectral camera, and the SMC values at corresponding time was acquired by drying method on the field at five soil depth (10 cm, 20 cm, 30 cm, 45 cm and 60 cm). Then the spectral reflectance of field maize canopy was extracted to calculate a number of vegetation indexes (VIs). Firstly, data was adopted to analyze the grey relationships between SMC and the selected typical VIs, and the selected typical VIs were used to determine the sensitivity of different VIs to SMC at different growth stages. Secondly, machine learning models of Cubist, back propagation neural network (BPNN) and support vector machine regression (SVR) were constructed and verified. The result showed that the three machine learning models showed good performance on modeling and prediction at different growth stages. The effectiveness of the SVR model was optimal among the three machine methods. The effect of the BPNN model followed, and the Cubist model was relatively the worst.

The optimal model was the SVR model at M stage, the modeling R^2 and validation R^2 for the SVR model were 0.851 and 0.875, and the root mean square error (RMSE) both were 0.7%, and the normalized root mean square error (nRMSE) were 8.17% and 8.32%, respectively. The inversion accuracy of the SVR model at R stage performed badly, the modeling R^2 and validation R^2 for the SVR model were 0.619 and 0.517, respectively. The research result was of great significance to monitor the soil moisture content in root area of crops and meaningful to precision irrigation.

Key words: maize; soil moisture content; UAV remote sensing; vegetation index; machine learning

0 引言

农田土壤水分是作物生长发育的基本条件,也是农作物墒情监测和判断的重要指标^[1]。传统的土壤含水率测量方法,如干燥法、中子仪法、时域反射仪法等,存在耗时、费力和采样成本高等缺点^[2],而遥感技术具有简便、高效、无损等优势,在土壤含水率监测中具有广阔的应用前景和发展空间^[3]。

国内外学者对应用遥感技术监测土壤含水率进行了广泛探讨和深入研究,并建立了相应的经验或半经验模型^[4-7]。无人机遥感克服了卫星遥感时空分辨率不匹配^[8],以及地面非成像光谱仪耗时、费力等问题,具有机动灵活、实时图像采集、高时效性、高空间分辨率等优点^[9],可快速、高效获取农田厘米级遥感影像,更好地满足农田尺度上精准灌溉的要求。BIAN 等^[10]利用无人机搭载热红外和多光谱传感器,通过水分胁迫指数(Crop water stress index, CWSI)和多种植被指数共同诊断棉花的水分胁迫状况;陈俊英等^[11]通过棉花花蕾期不同时刻冠层无人机多光谱遥感影像,利用植被光谱反射率对水分胁迫指标——蒸腾速率(T_s)和气孔导度(G_s)等进行了反演;张智韬等^[12]利用六旋翼无人机搭载 MCA 多光谱传感器完成了对裸土土壤含水率的反演,且反演精度较高,决定系数在 0.7 以上;王敬哲等^[13]基于无人机高光谱传感器,分析了差值指数(Difference index, DI)、比值指数(Ratio index, RI)、归一化指数(Normalization index, NDI)和垂直植被指数(Perpendicular vegetation index, PVI)与土壤含水率之间的关系,构建了干旱区绿洲农田土壤含水率定量估算模型;陈文倩等^[14]基于植被反射率数据,计算了多种植被指数,从而构建了干旱区绿洲土壤含水率与植被光谱指数之间的估算模型,对浅层土壤含水率进行了反演。但利用无人机多光谱遥感,构建多种植被指数与大田玉米根域土壤含水率的估算模型的相关研究还鲜有报道。

灰度关联分析法是通过计算关联度来比较系统各因素之间主次关系的一种变量选择方法^[15],在光谱分析中可以更好地筛选敏感波段和光谱指数^[14,16-17]。该方法对样本的多少和样本有无规律

都同样适用,计算量小,不会出现量化结果与定性分析结果不符的情况。虽然不同植被指数与土壤含水率之间具有一定的关联性,但土壤含水率与植被光谱之间的关系复杂,并不一定是单一的线性关系。而机器学习算法在处理非线性、异方差性等复杂问题时较大的优势,具有对数据处理的智能化和对数据价值的充分挖掘性,可以提高模型的反演精度,在农业遥感领域广泛应用^[18-21]。前人大多利用机器学习方法进行农田作物参数的反演,而利用灰度关联和机器学习相结合的方法进行农田土壤含水率的反演研究较少。

本文利用无人机遥感平台获取不同生育期大田玉米冠层高分辨率多光谱遥感影像,并计算多种植被指数,然后采用灰度关联法筛选对根域土壤含水率敏感的植被指数,将其作为自变量,分别构建不同生育期条件下的多元混合线性回归(Cubist)、反向传播神经网络(Back propagation neural network, BPNN)以及支持向量机回归(Support vector machine regression, SVR)等机器学习模型,并进行验证,以期获得适应于大田玉米根域土壤墒情监测的最优模型,为农田土壤水分监测和灌溉管理提供理论依据和技术支持。

1 材料与方法

1.1 研究区概况

研究区域位于内蒙古自治区鄂尔多斯市达拉特旗昭君镇(40°26′0.29″N, 109°36′25.99″E, 海拔 1 010 m),属于典型温带大陆性气候。试验地土壤为砂壤土,平均田间持水率为 18.5% (体积含水率),土壤容重为 1.56 g/cm³。玉米种植品种为“钧凯 918”,其播种时间为 2018 年 5 月 11 日,出苗时间为 5 月 18 日,收获时间为 9 月 8 日,生育期(Day after planting, DAP)总共 114 d,其中 5 月 24 日—7 月 26 日为营养生长期(Vegetative stage, V 期),7 月 27 日—8 月 23 日为生殖期(Reproductive stage, R 期),8 月 24 日—9 月 8 日为成熟期(Maturation stage, M 期)。玉米播种深度约 5 cm,种植行距 50 cm、株距 25 cm,行向由东到西,试验地面积 1.13 hm²,采用中心轴式喷灌机进行灌溉。

试验地被均等划分为 5 个扇形区域,每个扇形区域再划分成 3 个 6 m × 6 m 的采样区(图 1),相当于 3 次重复,并以不同百分比的田间持水率在 V 期、R 期和 M 期对 5 个处理区进行不同梯度的水分处理,在营养生长期和成熟期进行了相应的水分胁迫处理,而 R 期为产量敏感期,为了避免造成玉米重大的减产,故在 R 期并未设置过多的胁迫处理,本文以田间持水率的 95% 为充分灌溉,各生育期的水分处理情况见表 1。其实际灌溉量和降雨量分别通过安装在喷灌机上的流量计(MIK-2000H 型)和试验地相邻的标准气象站采集。




图 1 试验小区示意图
Fig. 1 Layout of testing plots

表 1 水分处理情况 Tab. 1 Water treatment				%
水分处理区	V 期	R 期	M 期	
T1	100	100	100	
T2	65	100	65	
T3	40	100	80	
T4	65	65	65	
T5	40	100	40	

1.2 无人机多光谱系统

自主研发的无人机多光谱影像采集系统如图 2 所示,该系统采用开源飞控 Pixhawk,经纬 M600 型

机架,搭载 RedEdge (MicaSense, USA) 多光谱相机,该相机具有 475 nm (蓝光, B)、560 nm (绿光, G)、668 nm (红光, R)、717 nm (红边, RE)、840 nm (近红外, NIR) 等 5 个波长的光谱采集通道,且配有光强传感器和固定反射率校正板 (Group VIII, USA)。光强传感器可校正外界光线的变化对光谱影像造成的影响,固定反射率校正板可对多光谱影像进行辐射校正,以生成反射率影像图和植被指数正射影像图。



图 2 无人机多光谱系统
Fig. 2 UAV multispectral images acquisition system

数据采集时间为 2018 年 7 月 12 日 (DOY193)、7 月 17 日 (DOY198)、7 月 21 日 (DOY202)、8 月 2 日 (DOY214)、8 月 23 日 (DOY235)、8 月 28 日 (DOY240)、9 月 7 日 (DOY250) 的 11:00—13:00, 每日采集一次,全生育期共 7 次试验。期间天气晴朗无风,多光谱相机镜头垂直向下,飞行高度 70 m,地面分辨率为 4.77 cm/像素。每次都采用固定航线飞行,航向和旁向重叠度均为 85%。

1.3 数据采集与处理

在光谱信息采集完成后,及时在每个采样区的中心位置打钻取土,取土深度分别为 10、20、30、45、60 cm,采用干燥法测定玉米根域土壤含水率(体积含水率),将 5 个不同深度土层的土壤含水率取平均值,代表为 6 m × 6 m 采样区土壤含水率的均值。随机抽取 2/3 数据用于建模,1/3 数据用于验证,各生育期土壤含水率统计特征如表 2 所示。

表 2 土壤含水率统计特征 Tab. 2 Statistical characteristics of SMC							
生育期	样本类型	样本数	最大值/%	最小值/%	均值/%	标准差/%	变异系数/%
V 期	总体样本	45	17.43	4.91	10.38	3.1	29.82
	建模样本	30	17.43	4.91	10.41	3.1	30.00
	验证样本	15	15.03	4.92	10.31	3.0	29.32
R 期	总体样本	30	11.92	5.34	8.56	1.9	22.50
	建模样本	20	11.75	5.34	8.43	1.9	22.52
	验证样本	10	11.92	5.64	8.83	2.0	22.15
M 期	总体样本	30	12.30	5.52	9.00	1.9	20.84
	建模样本	20	11.60	5.52	9.01	1.9	21.00
	验证样本	10	12.30	5.98	8.99	1.8	20.51
全生育期	总体样本	105	17.43	4.91	9.48	2.6	27.62
	建模样本	70	17.43	4.91	9.49	2.6	27.83
	验证样本	35	15.03	4.92	9.44	2.5	27.17

1.4 植被指数的提取

植被指数的提取主要分以下几步：①采用 Pix4DMapper 软件对原始遥感影像进行拼接,通过对 RedEdge 相机拍摄的多光谱影像进行辐射校正、几何校正以及高斯均值滤波等处理,在 Pix4DMapper 软件中根据波段运算生成不同植被指数的正射影像图。②利用 R 软件读取各种植被指

数正射影像图以及 15 个采样区的面状矢量文件,以便对植被指数影像图进行分割处理。③提取分割后植被指数的栅格文件并计算其平均值,最后将不同生育期条件下的不同植被指数均值整理,以便与对应的土壤含水率数据进行统计分析。

本文涉及了 18 种植被指数,其植被指数计算方法如表 3 所示。

表 3 植被指数汇总
Tab.3 Vegetation index summary

植被指数	计算公式	出处
改进比值植被指数 (MSR)	$MSR = (NIR/R - 1) / \sqrt{NIR/R + 1}$	文献[22]
归一化植被指数 (NDVI)	$NDVI = (NIR - R) / (NIR + R)$	文献[23]
优化土壤调节植被指数 (OSAVI)	$OSAVI = 1.16 (NIR - R) / (NIR + R + 0.16)$	文献[24]
比值植被指数 (RVI)	$RVI = NIR/R$	文献[25]
土壤调整植被指数 (SAVI)	$SAVI = 1.5 (NIR - R) (NIR + R + 0.5)$	文献[26]
比值植被指数 2 (RVI2)	$RVI_2 = NIR/G$	文献[27]
结构不敏感指数 (SIPI)	$SIPI = (NIR - B) / (NIR + B)$	文献[28]
三角形植被指数 (TVI)	$TVI = 60 (NIR - G) - 100 (R - G)$	文献[29]
增强型植被指数 (EVI)	$EVI = 2.5 (NIR - R) / (NIR + 6R - 7.5B + 1)$	文献[30]
改进叶绿素吸收指数 (MCARI)	$MCARI = [(RE - R) - 0.2(RE - G)](RE/R)$	文献[31]
转换叶绿素吸收指数 (TCARI)	$TCARI = 3[(RE - R) - 0.2(RE - G)(RE/R)]$	文献[31]
绿度指数 (GI)	$GI = G/R$	文献[32]
绿色归一化植被指数 (GNDVI)	$GNDVI = (NIR - G) / (NIR + G)$	文献[33]
简单比值色素指数 (SRPI)	$SRPI = B/R$	文献[28]
归一化色素叶绿素指数 (NPCI)	$NPCI = (R - B) / (R + B)$	文献[34]
归一化植被指数 2 (NDVI _{g-b})	$NDVI_{g-b} = (G - B) / (G + B)$	文献[35]
植被衰减指数 (PSRI)	$PSRI = (B - R) / G$	文献[36]
抗大气指数 (VARI)	$VARI = (G - R) / (G + R - B)$	文献[37]

注: B、G、R、RE 以及 NIR 分别为 475、560、668、717、840 nm 波长处的光谱反射率。

1.5 灰度关联法

灰色关联法是一种确定变量是否相关并确定其相关程度的一种分析方法。其基本思想是通过计算关联度找出系统各因素之间的主次关系,从而找出影响最大的因素。在系统发展过程中,如果两者相对变化基本相同,则认为两者的关联度大;反之,则认为两者关联度小。在计算灰色关联度之前,首先对数据进行灰度关联分析中常用的“均值化”预处理,以降低植被指数和土壤含水率间因量纲不一致而造成的分析误差^[15-17]。灰色关联度的主要计算步骤如下:设参考序列为 $X_0 = \{x_0(k), k = 1, 2, \dots, n\}$, 比较序列为 $X_i = \{x_i(k), k = 1, 2, \dots, n\}$, 则 X_0 和 X_i 之间的灰色关联度 (Gray correlation degree, GCD) 计算公式为

$$GCD = \frac{1}{n} \sum_{k=1}^n \gamma(x_0(k), x_i(k)) \tag{1}$$

其中

$$\gamma(x_0(k), x_i(k)) = \frac{\min_i \min_k |x_0(k) - x_i(k)| + \rho \max_i \max_k |x_0(k) - x_i(k)|}{|x_0(k) - x_i(k)| + \rho \max_i \max_k |x_0(k) - x_i(k)|} \tag{2}$$

式中 ρ ——分辨系数,取 0.5

1.6 机器学习算法

1.6.1 多元混合线性回归

多元混合线性回归 (Cubist) 是由 Rule Quest 公司开发的一种机器学习算法,其常应用于分类和回归分析当中,是一种改进的回归树系统^[38-39]。与 CART 算法相比,Cubist 模型与其最大的区别在于模型树的节点是一系列的线性模型,而回归树的节点上是一个具体的值,因而其建模的灵活性和精度都优于回归树模型。Cubist 模型用一种分段式的多元线性函数来预测变量,在解决非线性问题的同时,也提高了模型的预测精度。与单纯的线性回归相比,Cubist 模型可由算法自动对输入空间进行分割,且训练规则简单、有效,对高维属性的问题也有很好的解决办法。它很好地结合了回归树和多元线性回归,成功预测连续值^[40-41]。训练前对自变量进行了标准化处理,利用 R3.5.1 软件的 Cubist 包进行 Cubist 回归分析。

1.6.2 反向传播神经网络

反向传播神经网络是按照误差逆向传播算法训练的多层前馈神经网络,在数据分析时不需要建立数学模型,仿真性强,对各种非线性相关问题有很好

的解释性。它的基本思想是应用最速下降法和反向传播算法对网络的权值和偏差不断进行调整,在模型的实际输出值和期望输出值的误差最小时或者误差小于某一期望值时结束训练。BP 神经网络模型拓扑结构由输入层、输出层、隐含层构成,本文输入层选择为植被指数,输出层为土壤含水率,隐含层中的网络层数为 1,隐含层节点数通过交叉验证获得。为了消除量纲、数量级等对数据分析造成的影响,将各植被指数进行了归一化处理^[17-18,42]。采用 R3.5.1 软件中的 nnet 包进行 BP 回归分析。

1.6.3 支持向量机回归

支持向量机是基于结构风险最小化原理,逐渐发展起来用于分类和回归的一种有监督机器学习模型。它具有结构简单、适应性强和全局最优等特点,在处理小样本、非线性以及高维模式识别问题中有优势,在很大程度上克服了“维数灾难”和“过学习”等问题^[43-44]。利用 SVM 在解决回归问题时,支持向量机回归的基本思想是通过一个非线性变换将数据变换到一个高维特征空间,并在该特征空间建立线性模型来拟合回归函数。这种非线性变换是通过核函数来实现的,常用的核函数有线性核函数 (Linear)、多项式核函数 (Polynomial)、径向基核函数 (RBF) 等,而采用不同的核函数会导致不同的 SVR 算法,本文采用 RBF 核函数进行计算,并利用 R3.5.1 软件中的 e1071 包进行 SVR 分析^[19,45]。

1.7 模型精度评价

采用 3 个指标对模型的建模和验证精度进行评

估:决定系数 R^2 (Coefficient of determination)、均方根误差 (Root mean square error, RMSE) 以及标准均方根误差 (Normalized root mean square error, nRMSE)。 R^2 越接近 1, RMSE 和 nRMSE 越接近 0 说明模型效果越好,其中 nRMSE 小于 10% 表明模型几乎无差异;介于 10% ~ 20% 之间表明模型差异较小;介于 20% ~ 30% 之间表明模型差异一般;大于 30% 表明差异较大^[11,20]。其计算公式为

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

(3)

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

(4)

$$nRMSE = RMSE / \bar{y} \times 100\%$$

(5)

式中 y_i ——土壤含水率实测值
 $\hat{y}_i$ ——土壤含水率预测值
 $\bar{y}$ ——土壤含水率平均值
 n ——样本数

2 结果与分析

2.1 基于灰度关联分析的植被指数选择

在不同生育期条件下,利用灰色系统对植被指数与土壤含水率进行灰色关联分析,各生育期的植被指数与土壤含水率 (SMC) 之间的灰色关联度见表 4。

表 4 不同生育期土壤含水率与植被指数的灰色关联度统计
Tab.4 Gray correlation degree (GCD) statistics between different vegetation index and soil moisture content (SMC) at different growth stages

植被指数	V 期		R 期		M 期		全生育期	
	关联度	排序	关联度	排序	关联度	排序	关联度	排序
MSR	0.922	5	0.875	3	0.942	3	0.858	4
NDVI	0.861	10	0.892	1	0.939	5	0.874	2
OSAVI	0.850	11	0.866	6	0.936	6	0.843	7
RVI	0.934	2	0.872	4	0.944	2	0.867	3
SAVI	0.916	6	0.862	8	0.933	7	0.838	8
RVI2	0.907	7	0.870	5	0.942	4	0.855	5
SIPI	0.929	3	0.886	2	0.945	1	0.885	1
TVI	0.893	9	0.799	14	0.931	9	0.819	9
EVI	0.904	8	0.830	13	0.922	11	0.793	11
MCARI	0.761	14	0.858	10	0.933	8	0.782	12
TCARI	0.844	13	0.698	16	0.912	13	0.726	14
GI	0.940	1	0.865	7	0.917	12	0.811	10
GNDVI	0.403	18	0.844	12	0.895	15	0.671	15
SRPI	0.846	12	0.844	11	0.908	14	0.744	13
NPCI	0.749	15	0.592	18	0.566	17	0.561	18
NDVI _{g-b}	0.928	4	0.861	9	0.928	10	0.845	6
PSRI	0.707	16	0.597	17	0.522	18	0.564	17
VARI	0.415	17	0.746	15	0.885	16	0.639	16

从表 4 可以看出,在同一生育期,不同植被指数与土壤含水率的 GCD 不尽相同,以及在不同的生育期,同一植被指数与土壤含水率的 GCD 也不相同;其次,利用可见光波段组合的植被指数的 GCD 总体较低,但 V 期有个别植被指数,如 GI 、 $NDVI_{g-b}$ 的 GCD 较高,而包含近红外波段的植被指数的 GCD 总体较高。分别在 V、R、M 以及全生育期 4 个不同的生育期内,筛选出 GCD 排序前 5 的植被指数分别进行建模分析。

2.2 植被指数变化

根据不同生育期植被指数与土壤含水率的 GCD 情况,每个生育期按 GCD 由大到小排序选择的植被指数如下:①V 期: GI 、 RVI 、 $SIPI$ 、 $NDVI_{g-b}$ 、 MSR 。②R 期: $NDVI$ 、 $SIPI$ 、 MSR 、 RVI 、 $RVI2$ 。③M 期: $SIPI$ 、 RVI 、 MSR 、 $RVI2$ 、 $NDVI$ 。④全生育期: $SIPI$ 、 $NDVI$ 、 RVI 、 MSR 、 $RVI2$ 。以上 4 个生育期总共选择了 $NDVI$ 、 MSR 、 RVI 、 $SIPI$ 、 $RVI2$ 、 $NDVI_{g-b}$ 、 GI 7 种不同的植被指数。5 个不同水分处理小区,每个小区

的 3 个采样方植被指数取平均值,不同的植被指数随时间的变化曲线如图 3 所示。

从图 3 可以看出,由可见光和近红外波段组合成的植被指数, $NDVI$ 、 MSR 、 RVI 、 $SIPI$ 、 $RVI2$ 总体趋势为:在生育前期先逐渐增大,生育后期再慢慢减小;由于在 DOY214 以及 DOY240 天气较为干旱,试验的水分胁迫比较严重,所以植被指数呈急剧下降的趋势。由于 T4 在 R 期设置了水分胁迫处理,因此 T4 在 DOY214 的植被指数“急剧下降”的程度更大; $NDVI$ 等 5 种指数都是充分灌溉区 T1 的植被指数大于其他水分处理小区,水分胁迫严重的 T4 的植被指数为 5 个水分处理小区的最小值。

由可见光波段组合的植被指数, $NDVI_{g-b}$ 、 GI 与 $NDVI$ 等近红外波段构成的植被指数的变化趋势不相同。 $NDVI_{g-b}$ 基本呈现出“先增大后减小,再增大”的变化规律,在 DOY 214 和 DOY 240 水分胁迫较为严重时呈谷。 GI 在生育前期先逐渐增大,在 DOY 214 形成一个峰值,之后在 DOY 235 呈现下降趋势,在 DOY 240 上升形成另一个峰值,随后呈下




图 3 植被指数变化曲线

Fig. 3 Changing curves of vegetation indices

降趋势;但是它与其他指数变化有差异,在 DOY 214 以及 DOY 240 水分胁迫比较严重的阶段,它反而上升,在 DOY 235 反而下降。NDVI_{g-b}、GI 与 NDVI 等近红外构成的植被指数变化不相同的原因是:在可见光谱段内,叶绿素、胡萝卜素等色素对植被光谱起着支配作用,尤其是叶绿素起着最重要的作用。叶绿素等色素吸收了以 450 nm 为中心的蓝波段以及以 670 nm 为中心的红波段的大部分光谱而呈吸收谷,而在 540 nm 的绿波段附近吸收较少而呈反射峰,若植物受到水分胁迫等形式的抑制,叶绿素含量会降低,使得在蓝、红波段吸收减少而反射增强,尤其是红反射率增强更为显著;而在近红外光谱区,叶片内部的细胞结构决定了植物的光谱特性,叶子的细胞壁和细胞空隙间多重反射导致了近红外光谱的高反射率。水分胁迫状况的不同和生育期的变化,近红外波段与可见光波段的反射率变化趋势和程度并不完全吻合,因此由不同波段构建的植被指数在生育期的变化会有较大的差异^[46]。

2.3 基于 Cubist 的土壤含水率模型构建

对于不同生育期选定的敏感植被指数建立多元混合线性回归(Cubist)分析,Cubist 模型的两个重要参数 committees 和 neighbors 通过 caret 包的 train 函数进行模型参数的优选,采用交叉验证和网格搜索法(Grid search)相结合的方法进行参数寻优,选取估算模型的 RMSE 最小为最终的模型参数。根据选定的模型参数建立不同生育期的 Cubist 回归模型(表 5)。

表 5 基于不同生育期土壤含水率的 Cubist 模型

Tab.5 Cubist regression model of soil moisture content at different growth stages

生育期	建模集			验证集		
	R^2	RMSE/ %	nRMSE/ %	R_v^2	RMSE _v / %	nRMSE _v / %
V 期	0.806	1.4	13.43	0.728	1.9	18.77
R 期	0.587	1.3	14.97	0.584	1.5	16.80
M 期	0.772	0.9	10.07	0.751	1.0	11.39
全生育期	0.774	1.3	13.39	0.686	1.4	15.47

从表 5 可以看出,V 期、M 期、全生育期的建模和预测效果较好,建模和验证的决定系数都在 0.68 以上,并且建模集和验证集的 nRMSE 都介于 10%~20%之间,属于较小差异。R 期的效果相对较差,建模和验证决定系数分别为 0.587 和 0.584。就总体而言,M 期的模型为最佳监测模型,M 期土壤含水率的 Cubist 模型的建模决定系数为 0.772,稍小于 V 期的 0.806,但是,其验证决定系数 0.751 为 4 个模型中最高,验证集的 nRMSE_v 仅为 11.39% 属较小差

异, RMSE 仅为 1%,都为 4 个模型的最小值,且建模集和验证集的决定系数也比较接近。

2.4 基于 BP 神经网络的土壤含水率模型构建

利用 caret 调用 nnet 包训练单隐含层人工神经网络,最大迭代次数为 1 000,隐藏节点数和权值的衰减参数采用 10 次的 5 折交叉验证和网格搜索法(Grid search)进行参数寻优,选取估算模型的平均均方根误差最小的待选值作为最终的模型参数^[21],根据选定的模型参数建立不同生育期的 BPNN 回归模型(表 6)。

表 6 基于不同生育期土壤含水率的 BPNN 模型

Tab.6 BPNN regression model of soil moisture content at different growth stages

生育期	建模集			验证集		
	R^2	RMSE/ %	nRMSE/ %	R_v^2	RMSE _v / %	nRMSE _v / %
V 期	0.805	1.4	13.28	0.715	1.8	17.5
R 期	0.517	1.3	15.65	0.438	1.5	16.91
M 期	0.794	0.9	9.54	0.815	0.9	9.54
全生育期	0.752	1.3	13.89	0.725	1.4	14.74

由表 6 可知,基于不同生育期土壤含水率的 BPNN 回归模型,V 期、M 期以及全生育期建模和预测效果较好,建模集和验证集的决定系数都在 0.7 以上, RMSE 都在 2% 以下, nRMSE 都在 20% 以下,表示模型的精度具有较小差异。R 期建模和预测效果相较于其他生育期模型较差,其建模和验证的决定系数分别为 0.517 和 0.438。总体来看,M 期模型效果最优,其模型的建模集和验证集的决定系数最为接近,分别为 0.794 和 0.815,建模决定系数稍小于 V 期建模决定系数 0.805,但是验证集的决定系数为 4 个模型的最大值,验证集的精度指标 nRMSE_v 仅为 9.54%, RMSE 仅为 0.9%,都为 4 个模型的最小值。

2.5 基于支持向量机的土壤含水率模型构建

利用 e1071 包本身的 tune.svm 函数进行 SVR 参数的最优选取,利用格点搜索法选取模型参数 gamma 和成本参数 cost,选取交叉验证误差最小的模型所对应的参数,根据选定的模型参数建立不同生育期的 SVR 回归模型(表 7)。

从表 7 可以看出,基于不同生育期土壤含水率的 SVR 回归模型当中,V 期、M 期、全生育期的建模和验证效果比较好,建模和预测的决定系数达到了 0.7 以上,V 期、M 期的建模和验证的决定系数达到了 0.8 以上,建模集和验证集的 nRMSE 都在 15% 以下,R 期的效果相对最差,建模和验证决定系数分别为 0.619 和 0.571,不过建模和验证的 nRMSE 分

表 7 基于不同生育期土壤含水率的 SVR 模型

Tab.7 SVR model of soil moisture content at different growth stages

生育期	建模集			验证集		
	R^2	RMSE/ %	nRMSE/ %	R_v^2	RMSE _v / %	nRMSE _v / %
V 期	0.832	1.3	12.36	0.818	1.3	13.16
R 期	0.619	1.2	14.05	0.571	1.4	15.53
M 期	0.851	0.7	8.17	0.875	0.7	8.32
全生育期	0.781	1.2	13.09	0.729	1.4	14.75

别为 14.05% 和 15.53%，都属于较小差异精度，表明在 R 期利用 SVR 回归同样具有较强的建模和预测能力。就总体来看，M 期的建模和预测效果最优，建模集和验证集的决定系数分别为 0.851 和 0.875，都为 4 个模型的最大值，验证集的精度指标 nRMSE_v 仅为 8.32%，几乎无差异，RMSE_v 仅为 0.7%，都为 4 个模型的最小值。

2.6 模型的综合评价

由表 5~7 可知，3 种机器学习模型在玉米 V 期、M 期以及全生育期的建模决定系数 R^2 均在 0.75 以上，均方根误差 RMSE 均在 1.5% 以下，标准均方根误差 nRMSE 均小于 1.4%，都取得了较高的建模精度；而 3 种机器学习模型在 R 期的建模精度相对较差，建模决定系数 R^2 在 0.5~0.65 之间，RMSE 均小于 1.4%，nRMSE 介于 14%~16% 之间。相较而言，SVR 模型建模效果最优，其 R^2 在 4 个生育期的 3 种模型中都为最大值，RMSE 和 nRMSE 都为 4 个生育期的 3 种模型中的最小值。BPNN 模型的建模效果在 V 期和 M 期优于 Cubist 模型，而在 R 期和全生育期的建模效果 Cubist 模型优于 BPNN 模型。从模型验证结果看，3 种机器学习模型验证决定系数 R_v^2 与建模决定系数 R^2 总体差异不大，但 SVR 模型具有更好的稳定性，并且其 R_v^2 在 4 个生育期的 3 种模型中，除了 R 期小于 Cubist 模型的 R_v^2 ，其余都为最大值。3 种机器学习模型的验证均方根误差 RMSE_v 比建模均方根误差 RMSE 总体稍有增加，但 SVR 模型变化较小，且 SVR 模型的 RMSE_v 都为最小值。3 种模型的标准均方根误差 nRMSE_v 相较于建模标准均方根误差 nRMSE 也有所增加，SVR 模型的 nRMSE_v 除了在全生育期略大于 BP 模型的 nRMSE_v 之外，其余都为最小值。在 V 期、M 期以及全生育期，BPNN 模型的总体验证效果都优于 Cubist 模型，而在 R 期，Cubist 模型的验证效果优于 BPNN 模型。

4 个生育期 3 种机器学习模型的预测值和实测值比较如图 4 所示。从图 4 可以看出，除了在 R 期 3 种模型的拟合效果相对较差，其余 3 个生育期模

型的预测值与实测值的拟合效果均表现良好。V 期 SVR 模型的斜率接近 1，且拟合方程的决定系数为 0.818，为 3 种模型中的最大值。R 期 Cubist 模型的拟合方程的决定系数最大，为 0.584，但是线条也最为陡峭，BPNN 模型的拟合方程的决定系数最小，为 0.438，但是线条较为平缓，SVR 模型介于两者之间。M 期的 SVR 模型和 BPNN 模型的斜率都比较接近 1，且拟合方程的决定系数较大，Cubist 模型稍差。全生育期可以看出 BPNN 模型和 Cubist 模型的拟合回归直线近乎重合，SVR 模型的线条更为平缓，且拟合方程的决定系数最大，为 0.729。

3 讨论

土壤含水率是反映农业墒情以及指导灌溉的重要参数，而无人机遥感以其高时效性、高光谱分辨率以及高空间分辨率等性能可对作物根域土壤含水率的状况实施定点、定时监测，是实现精准灌溉的基础和关键。当光照、温度等条件变化不大时，植被生长状况主要受土壤含水率影响，此时可利用不同的植被指数来表征其水分胁迫状况，进而间接估算出土壤含水率，更为直接地影响土壤含水率的反演精度^[14,46-47]，而本文利用无人机采集大田玉米全生育期的多光谱影像，利用灰度关联法选择敏感植被指数，结合 3 种机器学习模型构建作物根域土壤含水率反演模型，结果表明 3 种模型均具有较高的精度和鲁棒性，其中 SVR 模型的精度最高，这与陈果等^[48]和丁世飞等^[43]研究 SVR 算法在小样本数据分析中具有较高精度的结果相一致。并且相较于鲍艳松等^[49]利用卫星数据构建 TVDI 反演土壤含水率和高中灵等^[7]构建 ATVDI 监测土壤含水率，本文所需要的数据和方法相对简单，仅需要无人机获取的作物冠层多光谱影像以及土壤水分数据，但是精度并未下降，表明利用无人机采集作物多光谱影像，构建敏感植被指数进行农田水分监测有其优势和潜力。

本文在各生育期筛选出的植被指数并不相同，原因为影响绿色植物叶片反射率变化的因素，在可见光谱段和近红外谱段有着较大的差异。在可见光谱段内，叶绿素、叶黄素等色素对植被光谱起着支配作用，尤其是叶绿素起着最重要的作用。而在近红外谱段内，植物的光谱特性主要受到叶子内部的细胞结构的影响，即叶子的细胞壁和细胞空隙间多重反射导致了近红外光谱的高反射率^[46,50]。因而水分胁迫状况的不同和随着生育期的变化，不同波段反射率的变化趋势和程度并不完全吻合，故基于不同波段光谱构建的植被指数，对水分胁迫的响应和随着生育期的变化有着较大的差异。所以，在同一




图 4 基于机器学习的土壤含水率实测值与预测值比较

Fig.4 Contrast of measured and predicted SMC based on machine learning

生育期,不同植被指数对水分胁迫的敏感程度并不相同;在不同生育期,筛选出的植被指数也有很大的差异。植被光谱与土壤水分在玉米 V 期和 M 期的模型效果较优,R 期效果较差。原因可能为玉米在 V 期处于快速生长阶段,玉米快速生长根系下扎,需求大量的养分和水分,故此时土壤含水率对植被光谱影响较大,二者相关性较好;而玉米处于 R 期时,考虑到 R 期为产量敏感期,为了避免玉米严重的减产,甚至是绝收,此时并未对所有小区都进行水分胁迫处理^[51-52],加上在 R 期降雨较多,各小区土壤水分之间几乎无差距,因此导致反演精度较差;而玉米在 M 期处于成熟期,地上部分生长茂盛,主要根系较深,根系可以从不同深度的土层吸取水分,加上此时植被基本达到了全覆盖,土壤像元影响较小,土壤含水率直接影响着植被指数,故此时效果较好。

然而本研究也存在许多不足,机器学习算法将变量之间的关系直接体现在算法之中,无法生成显性的数学公式或规则,因而可能会导致模型的解释性偏弱^[21]。此外,本文主要利用灰度关联法选择植被指数,通过机器学习模型来反演作物根域土壤含水率,并未与相关系数法选择敏感植被指数和其他建模方法(如偏最小二乘法)作对比,同时也没有考虑到温度、气象等因素对土壤含水率的影响。且由

于多光谱相机波段的限制,本文并未引入波段外对水分胁迫敏感的植被指数。故今后应将多光谱传感器与其他传感器相结合,同时参考温度、气象等参数,以期构建对水分胁迫更为敏感的指数,再运用不同的反演方法进一步验证,从而得到最优根域土壤含水率的反演模型。

4 结论

- (1) 经过灰度关联分析筛选出的植被指数有 NDVI、MSR、RVI、SIPI、RVI2、NDVI_{g-b} 和 GI,由于不同波段的光谱特征不同,故基于不同波段光谱构建的植被指数随生育期的变化会有所不同,对植被胁迫状况的响应也有所不同。
- (2) 对不同生育期内玉米根域土壤含水率的机器学习模型进行比较,结果表明,多元混合线性回归(Cubist)、反向传播神经网络(BPNN)、支持向量机回归(SVR)3 种机器学习方法均在 M 期取得了最高的精度,其次为 V 期,而 R 期模型的建模和预测效果最差,但在全生育期也有较高的建模和预测精度, R^2 均在 0.68 以上。说明利用灰度关联和机器学习相结合的方法,根据不同植被指数间接估算土壤含水率可行。
- (3) 在同一生育期内,SVR 模型的建模和验证

决定系数最高,且模型稳定性相对较好,均方根误差 RMSE 和标准均方根误差 nRMSE 最小;BPNN 模型效果次之;Cubist 模型相对较差。因此,SVR 模型为玉米根域土壤含水率的最优反演模型。

参 考 文 献

[1] 杨永民,邱建秀,苏红波,等. 基于热红外的四种土壤含水量估算方法对比[J]. 红外与毫米波学报, 2018, 37(4): 459–467.
YANG Yongmin, QIU Jianxiu, SU Hongbo, et al. Estimation of surface soil moisture based on thermal remote sensing: intercomparison of four methods[J]. Journal of Infrared and Millimeter Waves, 2018, 37(4): 459–467. (in Chinese)

[2] 杨曦光,于颖. 基于试验反射光谱数据的土壤含水率遥感反演[J]. 农业工程学报, 2017, 33(22): 195–199.
YANG Xiguang, YU Ying. Remote sensing inversion of soil moisture based on laboratory spectral reflectance data[J]. Transactions of the CSAE, 2017, 33(22): 195–199. (in Chinese)

[3] 陈仲新,任建强,唐华俊,等. 农业遥感研究应用进展与展望[J]. 遥感学报, 2016, 20(5): 748–767.
CHEN Zhongxin, REN Jianqiang, TANG Huajun, et al. Progress and perspectives on agricultural remote sensing research and applications in China[J]. Journal of Remote Sensing, 2016, 20(5): 748–767. (in Chinese)

[4] HASSAN-ESFAHANI L, TORRES-RUA A, JENSEN A, et al. Assessment of surface soil moisture using high-resolution multi-spectral imagery and artificial neural networks[J]. Remote Sensing, 2015, 7(3): 2627–2646.

[5] MILLARD K, THOMPSON D, PARISIEN M, et al. Soil moisture monitoring in a temperate peatland using multi-sensor remote sensing and linear mixed effects[J]. Remote Sensing, 2018, 10(6): 903.

[6] 高培霞,张吴平,梁爽,等. 基于温度植被干旱指数(TVDI)的土壤干湿反演[J]. 灌溉排水学报, 2018, 37(10): 123–128.
GAO Peixia, ZHANG Wuping, LIANG Shuang, et al. Retrievably calculating soil moisture based on temperature vegetation drought index of vegetative land[J]. Journal of Irrigation and Drainage, 2018, 37(10): 123–128. (in Chinese)

[7] 高中灵,郑小坡,孙越君,等. 利用地表温度与 LAI 的新型土壤湿度监测方法[J]. 光谱学与光谱分析, 2015, 35(11): 3129–3133.
GAO Zhongling, ZHENG Xiaopo, SUN Yuejun, et al. A novel method of moisture content monitoring by land surface temperature and LAI[J]. Spectroscopy and Spectral Analysis, 2015, 35(11): 3129–3133. (in Chinese)

[8] YU N, LI L, SCHMITZ N, et al. Development of methods to improve soybean yield estimation and predict plant maturity with an unmanned aerial vehicle based platform[J]. Remote Sensing of Environment, 2016, 187: 91–101.

[9] 刘建刚,赵春江,杨贵军,等. 无人机遥感解析田间作物表型信息研究进展[J]. 农业工程学报, 2016, 32(24): 98–106.
LIU Jiangang, ZHAO Chunjiang, YANG Guijun, et al. Review of field-based phenotyping by unmanned aerial vehicle remote sensing platform[J]. Transactions of the CSAE, 2016, 32(24): 98–106. (in Chinese)

[10] BIAN J, ZHANG Z, CHEN J, et al. Simplified evaluation of cotton water stress using high resolution unmanned aerial vehicle thermal imagery[J]. Remote Sensing, 2019, 11(3): 267.

[11] 陈俊英,陈硕博,张智韬,等. 无人机多光谱遥感反演花蕾期棉花光合参数研究[J/OL]. 农业机械学报, 2018, 49(10): 230–239.
CHEN Junying, CHEN Shuobo, ZHANG Zhitao, et al. Retrieving photosynthetic parameters in cotton during budding period by multi-spectral remote sensing of unmanned aerial vehicle[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(10): 230–239. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20181026&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2018.10.026. (in Chinese)

[12] 张智韬,王海峰,韩文霆,等. 基于无人机多光谱遥感的土壤含水率反演研究[J/OL]. 农业机械学报, 2018,49(2):173–181.
ZHANG Zhitao, WANG Haifeng, HAN Wenting, et al. Inversion of soil moisture content based on multispectral remote sensing of UAVs[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(2): 173–181. http://www.jcsam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20180223&flag=1&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2018.02.023. (in Chinese)

[13] 王敬哲,丁建丽,马轩凯,等. 基于光谱指数的绿洲农田土壤含水率无人机高光谱检测[J/OL]. 农业机械学报, 2018, 49(11): 164–172.
WANG Jingzhe, DING Jianli, MA Xuankai, et al. Detection of soil moisture content based on UAV-derived hyperspectral imagery and spectral index in oasis cropland [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(11): 164–172. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20181119&flag=1&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2018.11.019. (in Chinese)

[14] 陈文倩,丁建丽,谭娇,等. 干旱区绿洲植被高光谱与浅层土壤含水率拟合研究[J/OL]. 农业机械学报, 2017, 48(12): 229–236.
CHEN Wenqian, DING Jianli, TAN Jiao, et al. Fitting of hyperspectral reflectance of vegetation and shallow soil water content in oasis of arid area [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(12): 229–236. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20171227&flag=1&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2017.12.027. (in Chinese)

[15] 刘思峰,杨英杰,吴利丰. 灰色系统理论及其应用[M]. 7 版. 北京: 科学出版社, 2015.

- [16] 王海峰,张智韬,ARNON K,等. 基于灰度关联-岭回归的荒漠土壤有机质含量高光谱估算[J]. 农业工程学报, 2018, 34(14): 124 – 131.
WANG Haifeng, ZHANG Zhitao, ARNON K, et al. Hyperspectral estimation of desert soil organic matter content based on gray correlation-ridge regression model[J]. Transactions of the CSAE, 2018, 34(14): 124 – 131. (in Chinese)
- [17] WANG X, ZHANG F, KUNG H, et al. New methods for improving the remote sensing estimation of soil organic matter content (SOMC) in the Ebinur Lake Wetland National Nature Reserve (ELWNNR) in northwest China[J]. Remote Sensing of Environment, 2018, 218: 104 – 118.
- [18] 李媛媛,常庆瑞,刘秀英,等. 基于高光谱和 BP 神经网络的玉米叶片 SPAD 值遥感估算[J]. 农业工程学报, 2016, 32(16): 135 – 142.
LI Yuanyuan, CHANG Qingrui, LIU Xiuying, et al. Estimation of maize leaf SPAD value based on hyperspectrum and BP neural network[J]. Transactions of the CSAE, 2016, 32(16): 135 – 142. (in Chinese)
- [19] ZHANG C, LIU J, SHANG J, et al. Capability of crop water content for revealing variability of winter wheat grain yield and soil moisture under limited irrigation[J]. Science of the Total Environment, 2018, 631 – 632: 677 – 687.
- [20] 屈莎,李振海,邱春霞,等. 基于开花期氮素营养指标的冬小麦籽粒蛋白质含量遥感预测[J]. 农业工程学报, 2017, 33(12): 186 – 193.
QU Sha, LI Zhenhai, QIU Chunxia, et al. Remote sensing prediction of winter wheat grain protein content based on nitrogen nutrition index at anthesis stage[J]. Transactions of the CASE, 2017, 33(12): 186 – 193. (in Chinese)
- [21] 崔日鲜,刘亚东,付金东. 基于机器学习和可见光光谱的冬小麦叶片氮积累量估算[J]. 光谱学与光谱分析, 2016, 36(6): 1837 – 1842.
CUI Rixian, LIU Yadong, FU Jindong. Estimation of winter wheat leaf nitrogen accumulation using machine learning algorithm and visible spectral[J]. Spectroscopy and Spectral Analysis, 2016, 36(6): 1837 – 1842. (in Chinese)
- [22] 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.
- [23] ROUSE J W, HAAS R W, SCHELL J A, et al. Monitoring the vernal advancement and retrogradation (greenwave effect) of natural vegetation[R]. NASA, 1973.
- [24] RONDEAUX G, STEVEN M, BARET F. Optimization of soil-adjusted vegetation indices [J]. Remote Sensing of Environment, 1996, 55(2): 95 – 107.
- [25] MISHRA S, MISHRA D R. Normalized difference chlorophyll index: a novel model for remote estimation of chlorophyll-a concentration in turbid productive waters[J]. Remote Sensing of Environment, 2012, 117: 394 – 406.
- [26] HUETE A R. A soil-adjusted vegetation index (SAVI)[J]. Remote Sensing of Environment, 1988, 25(3): 295 – 309.
- [27] XUE L, CAO W, LUO W, et al. Monitoring leaf nitrogen status in rice with canopy spectral reflectance[J]. Agronomy Journal, 2004, 96(1): 135 – 142.
- [28] PENUELAS J, BARET F, FILELLA I. Semiempirical indexes to assess carotenoids chlorophyll-a ratio from leaf spectral reflectance[J]. Photosynthetica, 1995, 31: 221 – 230.
- [29] 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.
- [30] HUETE A, DIDAN K, MIURA T, et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices[J]. Remote Sensing of Environment, 2002, 83(1): 195 – 213.
- [23] HABOUDANCE D, MILLER J R, TREMBLAY N, et al. Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture[J]. Remote Sensing of Environment, 2002, 81(2): 416 – 426.
- [32] ZARCOTEJADA P, BERJON A, LOPEZLOZANO R, et al. Assessing vineyard condition with hyperspectral indices: leaf and canopy reflectance simulation in a row-structured discontinuous canopy[J]. Remote Sensing of Environment, 2005, 99(3): 271 – 287.
- [33] WANG F, HUANG J, TANG Y, et al. New vegetation index and its application in estimating leaf area index of rice[J]. Rice Science, 2007, 14(3): 195 – 203.
- [34] RANJAN R, CHOPRA U K, SAHOO R N, et al. Assessment of plant nitrogen stress in wheat (*Triticum aestivum* L.) through hyperspectral indices[J]. International Journal of Remote Sensing, 2012, 33(20): 6342 – 6360.
- [35] VERRELST J, SCHAEPMAN M E, KOETZ B, et al. Angular sensitivity analysis of vegetation indices derived from CHRIS/PROBA data[J]. Remote Sensing of Environment, 2008, 112(5): 2341 – 2353.
- [36] SIMS D A, GAMON J A. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages[J]. Remote Sensing of Environment, 2002, 81(2): 337 – 354.
- [37] SCHNEIDER P, ROBERTS D A, KYRIAKIDIS P C. A VARI-based relative greenness from MODIS data for computing the fire potential index[J]. Remote Sensing of Environment, 2008, 112(3): 1151 – 1167.
- [38] FRANK E, WANG Y, INGLIS S, et al. Using model trees for classification[J]. Machine Learning, 1998, 32(1): 63 – 76.
- [39] GRAY J M, BISHOP T F A, WILFORD J R. Lithology and soil relationships for soil modelling and mapping[J]. CATENA, 2016, 147: 429 – 440.

- [40] 刘佳凤,田娜娜,赵玉杰,等. 基于 Cubist 多元混合回归的稻米富集 Cd 模型构建研究[J]. 农业环境科学学报, 2018, 37(6): 1059 – 1065.
LIU Jiafeng, TIAN Nana, ZHAO Yujie, et al. Evaluation of cadmium accumulation in rice using a Cubist multivariate mixed regression model[J]. Journal of Agro-Environment Science, 2018, 37(6): 1059 – 1065. (in Chinese)
- [41] 戴舒,付迎春,赵耀龙. 基于 Cubist 模型树的城市不透水面百分比遥感估算模型[J]. 地球信息科学学报, 2016, 18(10): 1399 – 1409.
DAI Shu, FU Yingchun, ZHAO Yaolong. The remote sensing model for estimating urban impervious surface percentage based on the Cubist model tree[J]. Journal of Geo-Information Science, 2016, 18(10): 1399 – 1409. (in Chinese)
- [42] 吕雅慧,郎文聚,张超,等. 基于 TOPSIS 和 BP 神经网络的高标准农田综合识别[J/OL]. 农业机械学报, 2018, 49(3): 196 – 204.
LÜ Yahui, YUN Wenju, ZHANG Chao, et al. Multi-characteristic comprehensive recognition of well-facilitied farmland based on TOPSIS and BP neural network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(3): 196 – 204. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20180324&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2018.03.024. (in Chinese)
- [43] 丁世飞,齐丙娟,谭红艳. 支持向量机理论与算法研究综述[J]. 电子科技大学学报, 2011, 40(1): 2 – 10.
DING Shifei, QI Bingjuan, TAN Hongyan. An overview on theory and algorithm of support vector machines[J]. Journal of University of Electronic Science and Technology of China, 2011, 40(1): 2 – 10. (in Chinese)
- [44] 魏丽冉,岳峻,李振波,等. 基于核函数支持向量机的植物叶部病害多分类检测方法[J/OL]. 农业机械学报, 2017, 48(增刊): 166 – 171.
WEI Liran, YUE Jun, LI Zhenbo, et al. Multi-classification detection method of plant leaf disease based on kernel function SVM[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(Supp.): 166 – 171. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=2017s027&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2017.S0.027. (in Chinese)
- [45] 刘旭,吴迪,梁曼,等. 基于高光谱的酿酒葡萄果皮花色苷含量多元回归分析[J/OL]. 农业机械学报, 2013, 44(12): 180 – 186.
LIU Xu, WU Di, LIANG Man, et al. Multiple regression analysis of anthocyanin content of winegrape skins using hyperspectral image technology[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(12): 180 – 186. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20131230&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2013.12.030. (in Chinese)
- [46] 赵英时. 遥感应用分析原理与方法[M]. 2 版. 北京: 科学出版社, 2003.
- [47] ZHANG N, HONG Y, QIN Q, et al. VSDI: a visible and shortwave infrared drought index for monitoring soil and vegetation moisture based on optical remote sensing[J]. International Journal of Remote Sensing, 2013, 34(13): 4585 – 4609.
- [48] 陈果,周伽. 小样本数据的支持向量机回归模型参数及预测区间研究[J]. 计量学报, 2008, 29(1): 92 – 96.
CHEN Guo, ZHOU Jia. Research on parameters and forecasting interval of support vector regression model to small sample[J]. Acta Metrologica Sinica, 2008, 29(1): 92 – 96. (in Chinese)
- [49] 鲍艳松,严婧,闵绍忠,等. 基于温度植被干旱指数的江苏淮北地区农业旱情监测[J]. 农业工程学报, 2014, 30(7): 163 – 172.
BAO Yansong, YAN Jing, MIN Jinzhong, et al. Agricultural drought monitoring in north Jiangsu by using temperature vegetation dryness index[J]. Transactions of the CSAE, 2014, 30(7): 163 – 172. (in Chinese)
- [50] 王俊霞,潘耀忠,朱秀芳,等. 土壤水分反演特征变量研究综述[J]. 土壤学报, 2019, 56(1): 23 – 25.
WANG Junxia, PAN Yaozhong, ZHU Xiufang, et al. A review of researches on inversion of eigenvariance of soil water[J]. Acta Pedologica Sinica, 2019, 56(1): 23 – 25. (in Chinese)
- [51] HAN M, ZHANG H, DEIONGE K C, et al. Estimating maize water stress by standard deviation of canopy temperature in thermal imagery[J]. Agricultural Water Management, 2016, 177: 400 – 409.
- [52] HAN M, ZHANG H, DEIONGE K C, et al. Comparison of three crop water stress index models with sap flow measurements in maize[J]. Agricultural Water Management, 2018, 203: 366 – 375.