doi:10.6041/j.issn.1000-1298.2026.02.028

基于低空遥感光谱与纹理信息的冬马铃薯冠层等效水厚度反演

陈绍民[1,2]　徐芝霖[1]　高嘉晨[1]　普秋雨[1]　李加念[1,3]　胡传旺[4]　谭　帅[1,2]

(1. 昆明理工大学现代农业工程学院, 昆明 650500; 2. 云南省农业水资源高效利用与智慧管控重点实验室, 昆明 650500;
3. 云南省智能农业工程技术与装备国际联合实验室, 昆明 650500; 4. 湖南理工学院土木建筑工程学院, 岳阳 414006)

摘要: 作物冠层水分状态监测对优化灌溉策略具有重要意义。本研究应用无人机低空遥感技术实现冬马铃薯冠层等效水厚度(Canopy equivalent water thickness, CEWT)反演,通过田间试验,采用无人机搭载多光谱相机获取不同灌水处理下各生育期冬马铃薯遥感影像,并同时测定 3 种水分指标:叶片含水率(Leaf water content, LWC)、叶片等效水厚度(Leaf equivalent water thickness, LEWT)和 CEWT。对多光谱遥感影像剔除土壤背景,获取平均反射率(Average spectral reflectance, ASR)、植被指数(Vegetation indices, VIs)和纹理信息(Textures),基于相关系数分析降低自变量共线性构建数据集,结合偏最小二乘回归(Partial least squares regression, PLSR)、随机森林(Random forest, RF)和极限学习机(Extreme learning machine, ELM)构建定量反演模型,并获得试验区冬马铃薯 CEWT 空间分布信息。结果表明,冬马铃薯冠层水分指标随灌溉量增加呈上升趋势,各生育阶段 ASR 随着波长增加呈现先降低后上升特征。相对于 LWC 和 LEWT,CEWT 与 ASR、VIs、Textures 的相关性更优。基于 ASR + VIs + Textures 的 RF 模型表现最佳,预测能力较强,校正集、预测集决定系数分别为 0.875 和 0.771,均方根误差分别为 0.062、0.065 mm,RPD 为 2.055。研究表明多变量融合可显著提高冬马铃薯 CEWT 反演准确性,为冬马铃薯冠层水分状态评估提供了参考。

关键词: 冬马铃薯; 冠层等效水厚度; 无人机; 多光谱; 随机森林

中图分类号: S532; TP79　　**文献标识码**: A　　**文章编号**: 1000-1298(2026)02-0290-11　　**OSID**:

Retrieval of Canopy Equivalent Water Thickness in Winter Potato Based on Low-altitude Remote Sensing and Spectral and Textural Information

CHEN Shaomin[1,2]　XU Zhilin[1]　GAO Jiachen[1]　PU Qiuyu[1]　LI Jianian[1,3]　HU Chuanwang[4]　TAN Shuai[1,2]

(1. *Faculty of Modern Agricultural Engineering*, *Kunming University of Science and Technology*, *Kunming* 650500, *China*
2. *Key Laboratory of Efficient Utilization of Agricultural Water Resources and Intelligent Control in Yunnan Province*, *Kunming* 650500, *China*
3. *International Joint Laboratory of Intelligent Agricultural Engineering Technology and Equipment in Yunnan Province*, *Kunming* 650500, *China*
4. *College of Civil Engineering and Architecture*, *Hunan Institute of Science and Technology*, *Yueyang* 414006, *China*)

Abstract: Monitoring crop canopy water status is crucial for optimizing irrigation strategies. Low-altitude remote sensing technology was applied via an unmanned aerial vehicle (UAV) to retrieve the canopy equivalent water thickness (CEWT) of winter potato. Field experiments were conducted by using a UAV with multispectral cameras to capture images of winter potato under different irrigation treatments across various growth stages. Simultaneously, three water indicators were determined: leaf water content (LWC), leaf equivalent water thickness (LEWT), and CEWT. Soil backgrounds were removed from the multispectral remote sensing images to obtain average spectral reflectance (ASR), vegetation indices (VIs), and Textures. A dataset was constructed by reducing multicollinearity among independent

收稿日期: 2024-10-08　修回日期: 2024-11-13

基金项目: 国家自然科学基金项目(52209056)、云南省基础研究计划项目(202501AT070378)、云南省兴滇英才支持计划项目(KKXX202523082)、云南省科技厅重大专项(202302AE090024)、湖南省教育厅一般项目(22C0360)和云南省大学生创新创业训练计划项目(S202410674184)

作者简介: 陈绍民(1989—),男,副教授,博士,主要从事水肥高效利用与农业遥感研究,E-mail: shaomin_ly24@126.com

通信作者: 谭帅(1990—),女,副教授,博士,主要从事作物水肥高效利用研究,E-mail: tans90@163.com

variables through correlation analysis. Quantitative inversion models were developed by using partial least squares regression (PLSR), random forest (RF), and extreme learning machine (ELM) to obtain spatial distribution information of winter potato canopy water content in the experimental area. The results showed that the canopy water indicators of winter potatoes were increased with the rising of irrigation amounts, while the ASR across growth stages exhibited a pattern of initial decrease followed by an increase with wavelength. Compared with LWC and LEWT, CEWT showed a better correlation with ASR, VIs, and Textures. The RF model based on ASR + VIs + Textures exhibited the best performance, demonstrating strong predictive capability. The determination coefficients of the calibration and prediction datasets were 0.875 and 0.771, respectively, the root mean square errors were 0.062 mm and 0.065 mm, respectively, and the RPD was 2.055. The research result demonstrated that multivariable fusion can significantly enhance the accuracy of CEWT retrieval for winter potato, providing a reference for assessing the winter potato canopy water status.

Key words: winter potato; canopy equivalent water thickness; unmanned aerial vehicle; multispectral; random forest

0　引言

马铃薯是全球重要的农作物，截至 2022 年底，我国马铃薯播种面积达 4.535×10^6 hm^2，产量达 1.788×10^9 t，稳居世界首位。冬马铃薯因其生育周期短和经济效益高，播种面积逐年增长，占全国总面积约 20%[1]。然而，冬马铃薯生长和产量受到水分状况的影响，因此准确监测其水分状态对优化农业管理和提高产量至关重要。

冠层水分状态作为作物水分亏缺监测的重要指标，衡量植被冠层水分状态的指标主要有等效水厚度(Equivalent water thickness, EWT)和质量含水率(Gravimetric water content, GWC)[2]。叶片含水率(Leaf water content, LWC)通过对比湿质量和干质量来确定叶片含水程度，EWT 包括叶片等效水厚度(Leaf equivalent water thickness, LEWT)和冠层等效水厚度(Canopy equivalent water thickness, CEWT)，分别用于评估单叶片和整个冠层的水分状态。比较 3 种水分指标的反演效果，可以揭示其在不同环境条件下的优势与局限，从而为精准农业提供更可靠的水分监测工具。无人机遥感技术通过远程操控实时监测作物水分，实现由“点”到“面”的信息监测[3]。多光谱基于波段可选择性，可根据作物监测需要选择合适的波段范围。植被指数(Vegetation indices, VIs)基于波段反射率计算，在提高作物信息提取的准确性和减少背景干扰方面发挥了重要作用。但随着作物生育期推进，作物冠层结构逐渐饱和从而限制了 VIs 估算[4]。GONG 等[5]发现基于 VIs 的水稻叶面积指数(LAI)估计模型受生长阶段的影响较大，从而限制了其在整个生育期的应用。遥感影像中的纹理信息(Textures)侧重反映图像中的结构细节和模式，能提供水分变化以外的线索[6]。DU 等[7]研究发现，Textures 对 LAI 的敏感性一般高于波段反射率和 VIs，这强调了 Textures 的关键作用。运彬媛等[8]通过融合多光谱的 VIs 和 Textures，发现比单一数据集更能提高玉米氮素含量估测精度，这说明多数据源的融合可以整合其优势，从而提高对反演模型的预测能力。遥感变量的特性差异(如抗饱和性和共线性)可能导致模型估计失真，因此优化输入因子对提高预测精度至关重要。刘杨等[9]通过筛选具有极显著水平($P < 0.01$)且相关系数绝对值大于 0.6 的光谱指数，从而提升了马铃薯地上生物量(Above ground biomass, AGB)模型估算精度。王耀民等[10]发现，变量筛选方法与不同机器学习算法结合产生了差异化的建模能力。因此在进行作物冠层水分状态反演时，应首先筛选合适的指标和回归方法组合以确定最优的建模方法。

本文研究低空遥感的冬马铃薯 CEWT 反演方法，基于无人机搭载多光谱相机获取的遥感图像和实测地面数据，引入平均反射率(ASR)、植被指数(VIs)和纹理信息(Textures)作为模型输入变量，结合线性和非线性建模方法构建冬马铃薯 CEWT 定量反演模型，旨在提升对冬马铃薯冠层水分状况的监测精度，为精准农业提供科学依据。

1　材料与方法

1.1　研究区概况

试验地位于云南省文山州砚山县维摩乡试验田(23°50′20″N, 104°13′40″E，海拔 1 460 m)。该地区属亚热带季风气候，年平均气温 16.2℃，年平均日照时数 1 935 h，年平均降水量 1 050 mm，降雨集中在 6—9 月。试验田 0 ~ 60 cm 土层土壤类型为壤土。研究区概况如图 1 所示。

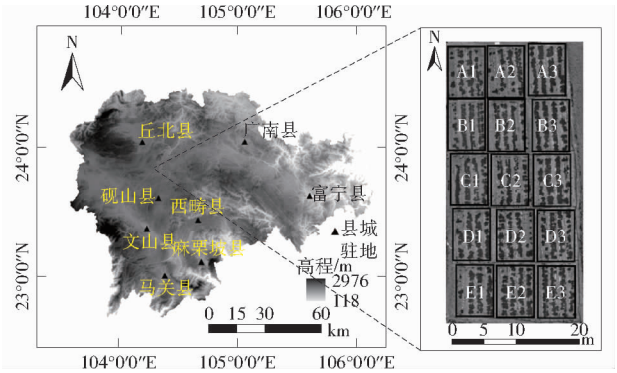

图 1 试验地概况

Fig. 1 Overview of experimental site

1.2 试验设计

选择马铃薯品种‘丽薯 6 号’为试验材料，播种时间为 2023 年 11 月 23 日，收获时间为 2024 年 4 月 19 日。试验灌水量设置 5 个水平，基于国家气象科学数据中心提供的气象数据，根据 FAO－56 Penman－Monteith 公式计算作物需水量 ET_c（$ET_c = K_c ET_0$，ET_0 为参考作物蒸散量（mm），K_c 为作物系数，冬马铃薯各生育阶段 K_c 分别为幼苗期 0.5、块茎形成期 0.8、块茎膨大期 1.2、淀粉积累期 0.95 和成熟期 0.75），ET_c 达到或接近 30 mm 时开始灌溉[11]。

图 1 中黑色小方框表示小区区域，A～E 表示不同灌溉处理，1～3 表示组别。其中 A1、A2、A3 采取亏缺灌溉（40% ET_c），B1、B2、B3 采取亏缺灌溉（60% ET_c），C1、C2、C3 采取亏缺灌溉（80% ET_c），D1、D2、D3 采取充分灌溉（100% ET_c），E1、E2、E3 采取过量灌溉（120% ET_c）。每个小区长、宽分别为 7、5 m，各小区内种植 4 垄，垄距 0.3 m，垄宽 0.9 m，采用一垄双行种植模式，垄上株距 0.3 m，行距0.25 m，并在行间铺设滴灌带，垄上覆膜（图 2）。滴灌为一膜一管布置，滴头间距为 0.2 m、流量为 3 L/h，采用旋翼式水表（精度 0.1 L）记录各处理灌水量（图 3）。其他栽培管理及施肥方案同当地高产田。

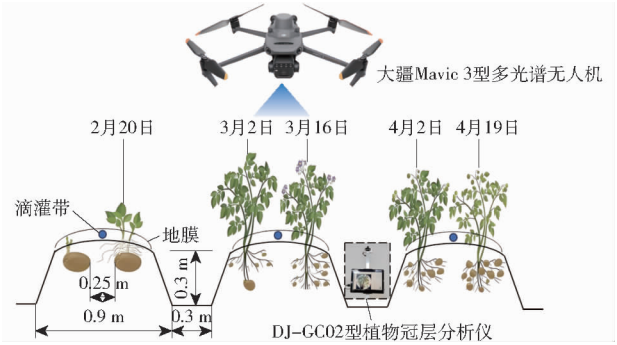

图 2 冬马铃薯田间试验和低空多光谱遥感观测模式示意图

Fig. 2 Schematic of winter potato field experiment and low altitude multispectral remote sensing observation mode

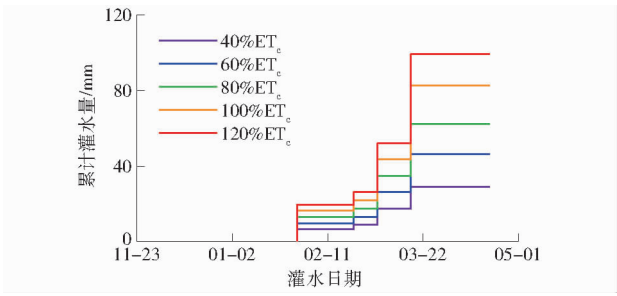

图 3 冬马铃薯累计灌水量

Fig. 3 Accumulated irrigation amount of winter potato

1.3 数据获取与分析

1.3.1 地面数据采集与处理

在无人机航拍后，立即在各小区采样点选取 10 片以上叶片装入自封袋，采集过程中同时采用植物冠层分析仪（DJ－GC02 型，中国点将科技公司）进行 LAI 测量，每次测定 30 个样点。采样完成后运回实验室称取鲜质量（Fresh weight，FW，g），并采用长宽积系数法测量叶面积（Leaf area，LA，cm^2），系数经过多次校正为 0.76。放入干燥箱 105℃ 杀青，75℃ 干燥至恒定质量测定干质量（Dry weight，DW，g），并计算叶片含水率（$LWC = (FW - DW)/FW \times 100\%$，%）、叶片等效水厚度（$LEWT = 10(FW - DW)/LA$，mm）及冠层等效水厚度（$CEWT = LEWT \times LAI$，mm）。基于 SPXY（Sample set partitioning based on joint x－y distances）[12] 将样本以比例 2∶1 划分为 2 个独立数据集，2/3 样本标记为校正集，其余样本标记为预测集。

1.3.2 低空多光谱遥感数据采集与图像处理

采用 DJI Mavic 3 型无人机遥感平台（深圳市大疆创新科技有限公司）获取遥感信息，4 个光谱采集通道中心波长为绿光（Green，G，560 nm）、红光（Red，R，650 nm）、红边（Red Edge，RE，730 nm）和近红外（Near Infrared，NIR，860 nm），该无人机遥感平台配有光强传感器。在冬马铃薯每个生育期进行无人机航拍和数据采集，选择天气晴朗、风力小于 3 级、阳光强度稳定时采集，采集时间为北京时间 12∶00—13∶00。共采集 5 次，分别为苗期（2024 年 2 月 20 日）、块茎形成期（2024 年 3 月 2 日）、块茎膨大期（2024 年 3 月 16 日）、淀粉积累期（2024 年 4 月 2 日）、成熟期（2024 年 4 月 19 日）（图 2）。无人机飞行选择航拍高度 30 m，每次影像采集都采用固定航线，航向和旁向重叠度均为 80%，并配有专门的反射率校正板（白板反射系数为 0.75，黑板反射系数为 0.03）。采集的无人机影像采用大疆智图（DJI Terra）软件进行辐射校正、拼接等处理，获得正射影像；然后采用 ENVI 5.3 对图像进行波段融合、图像裁剪、划定感兴趣区域，通过植被指数阈值法对各个

小区多光谱图像进行掩膜处理[13]，实现土壤背景剔除，获得采样点反射率光谱（经过多次调试，最终确定植被指数阈值为 0.7）。在每个小区选择 2 个感兴趣区域进行反射率采集，取平均反射率（ASR）为一个数据样本。

1.3.3　植被指数与纹理信息提取

植被指数（VIs）是 2 个或多个波段的光谱变换，旨在增强植被特征的贡献。根据无人机多光谱相机波段范围选取 9 种常用植被指数，其计算式如表 1 所示。

表 1　植被指数及其计算公式

Tab.1　Vegetation index and calculation formula

植被指数	计算公式	文献序号
归一化植被指数（NDVI）	$NDVI=(\rho_{NIR}-\rho_R)/(\rho_{NIR}+\rho_R)$	[14]
差值植被指数（DVI）	$DVI=\rho_{NIR}-\rho_R$	[15]
比值植被指数（RVI）	$RVI=\rho_{NIR}/\rho_R$	[16]
绿色归一化植被指数（GNDVI）	$GNDVI=(\rho_{NIR}-\rho_G)/(\rho_{NIR}+\rho_G)$	[17]
叶片叶绿素指数（LCI）	$LCI=(\rho_{NIR}-\rho_{RE})/(\rho_{NIR}+\rho_R)$	[18]
归一化差异红边指数（NDRE）	$NDRE=(\rho_{NIR}-\rho_{RE})/(\rho_{NIR}+\rho_{RE})$	[19]
优化土壤调节植被指数（OSAVI）	$OSAVI=(\rho_{NIR}-\rho_R)/(\rho_{NIR}+\rho_R+0.16)$	[20]
归一化绿红差值指数（NGRDI）	$NGRDI=(\rho_G-\rho_R)/(\rho_G+\rho_R)$	[21]
改进比值植被指数（MSR）	$MSR=(\rho_{NIR}/\rho_R-1)\cdot\sqrt{\rho_{NIR}/\rho_R+1}$	[22]

注：ρ_G、ρ_R、ρ_{RE}、ρ_{NIR}分别表示绿波段、红波段、红边波段以及近红外波段反射率。

图像纹理信息（Textures）主要依赖于灰度共生矩阵（Gray level co-occurrence matrix，GLCM）计算各种参数，包括各波段对比度（Contrast，CON）、熵（Entropy，ENT）、方差（Variance，VAR）、均值（Mean，MEA）、协同性（Homogeneity，HOM）、相异性（Dissimilarity，DIS）、二阶矩（Second moment，SEM）和相关性（Correlation，COR），利用 ENVI 5.3 实现相关计算。

1.3.4　相关系数分析

使用 Pearson 相关系数（Correlation coefficient，r）衡量每个遥感参数与水分指标之间的相关性。同时计算所有自变量的相关系数识别高度相关变量，通过剔除相关性强的变量，避免建模自变量重复提供信息，以实现降低变量间共线性、提升模型稳定性和预测精度的目的[23]。以 0.9 作为相关系数足够大的判断阈值，从而识别出自变量间存在显著的共线性。

1.4　建模方法

1.4.1　偏最小二乘法

偏最小二乘回归（PLSR）是一种集成主成分分析、多元线性回归和最小二乘回归的线性建模方法[24]。该方法将自变量压缩为潜在变量（Latent variables，LVs），因此，LVs 数量确定是 PLSR 应用的关键。本文基于 5 折交叉验证对应的最小均方根误差确定 LVs 数量。

1.4.2　随机森林

随机森林（RF）方法是一种基于多个决策树模型的集成学习算法[25]。该方法基于 bootstrap 重采样方法将输入数据集衍生为多个样本集，并对每个样本在所有决策树上进行预测，最终预测结果为所有决策树平均预测值。RF 的主要参数包括决策树数量 N_{tree}和内部节点分裂数量 m。将 N_{tree}以 50 为初值，并以 50 为步长增加至 500，结合 5 折交叉验证方法，经多轮训练，最终 N_{tree}确定为 100；m 取默认值，即输入变量的 1/3。

1.4.3　极限学习机

极限学习机（ELM）是一种基于随机化的单层前馈神经网络算法，利用随机初始化的连接权重和输入层与隐含层间的偏差，实现快速模型训练。隐含层输出通过输入数据与随机权重结合，并经 Sigmoid 激活函数处理，形成隐含层输出矩阵，并通过线性回归计算输出层权重[26]。本文隐含层神经元数量以 5 为步长，在 20 ~ 100 寻优，每个模型结构运行 1 000 次，以模型误差最小确定最终数量。

1.4.4　模型精度评估

采用决定系数（Coefficient of determination，R^2）、均方根误差（Root mean square error，RMSE）和相对分析误差（Relative prediction deviation，RPD）评估模型精度。精度较高的模型应具有较高的 R^2 和 RPD，以及较低的 RMSE。其中 RPD 为 0 ~ 1.0，模型没有预测能力；RPD 为 1.0 ~ 1.4，模型可用于定性分析；RPD 为 1.4 ~ 2.0，模型具有一般预测能力；当 RPD 大于 2.0，模型可用于定量分析[27]。

2　结果与分析

2.1　冬马铃薯水分指标和 ASR 定量分析

冬马铃薯全生育期 LWC、LEWT、CEWT 测定数据如表 2、3 所示，每个生育期获得 30 个样本，生育期累计获得 150 个。采用 SPXY 方法将样本按照比例 2∶1 划分为校正集和预测集，其中校正集样本数为 100，预测集样本数为 50。LWC 为 62.968% ~ 98.693%，均值为 85.936%；LEWT 为 0.172 ~ 0.404 mm，均值为 0.274 mm；CEWT 为 0.080 ~ 0.855 mm，均值为

表 2 不同样本 LWC 描述性统计

Tab. 2 Descriptive statistics of LWC with different samples

数据集	样本数	最小值/%	最大值/%	均值/%	标准差/%	变异系数/%
总样本	150	62.968	98.693	85.936	5.343	6.217
校正集	100	74.024	98.693	86.471	5.550	6.418
预测集	50	62.968	93.956	84.868	4.724	5.566

表 3 不同样本 LEWT 和 CEWT 描述性统计

Tab. 3 Descriptive statistics of LEWT and CEWT with different samples

水分指标	数据集	样本数	最小值/mm	最大值/mm	均值/mm	标准差/mm	变异系数/%
LEWT	总样本	150	0.172	0.404	0.274	0.033	12.044
	校正集	100	0.172	0.389	0.275	0.032	11.636
	预测集	50	0.209	0.404	0.273	0.035	12.821
CEWT	总样本	150	0.080	0.855	0.396	0.155	39.141
	校正集	100	0.080	0.855	0.402	0.165	41.045
	预测集	50	0.177	0.658	0.382	0.134	35.079

0.396 mm。所划分冬马铃薯水分指标数据集样本区间具有良好的代表性。

冬马铃薯各水分指标随生育期的变化而发生改变(图 4)。各处理 LWC 呈现先降低后增加的特征(图 4a),由苗期(94.805%,120% ET_c)降低至块茎形成期(75.318%,40% ET_c)后,在块茎膨大期、淀粉积累期逐渐增加,到成熟期(88.150%,120% ET_c)时趋于平稳。各处理 LEWT 在淀粉积累期差异最大(最大值 0.314 mm,120% ET_c;最小值 0.215 mm,40% ET_c)(图 4b)。各处理 CEWT 呈现先升高后降低的特征(块茎形成期最大,0.66 mm,120% ET_c;成熟期最小,0.231 mm,40% ET_c)(图 4c)。各水分指标变化差异明显,总体上冠层水分指标由小到大依次为亏缺灌溉、充分灌溉、过量灌溉。

冬马铃薯各生育期平均波段反射率(ASR)呈现随波长增加先降低后增大的特征(图 5)。由图 5 可见,整个生育期 RE 和 NIR 波段反射率远大于 G 和

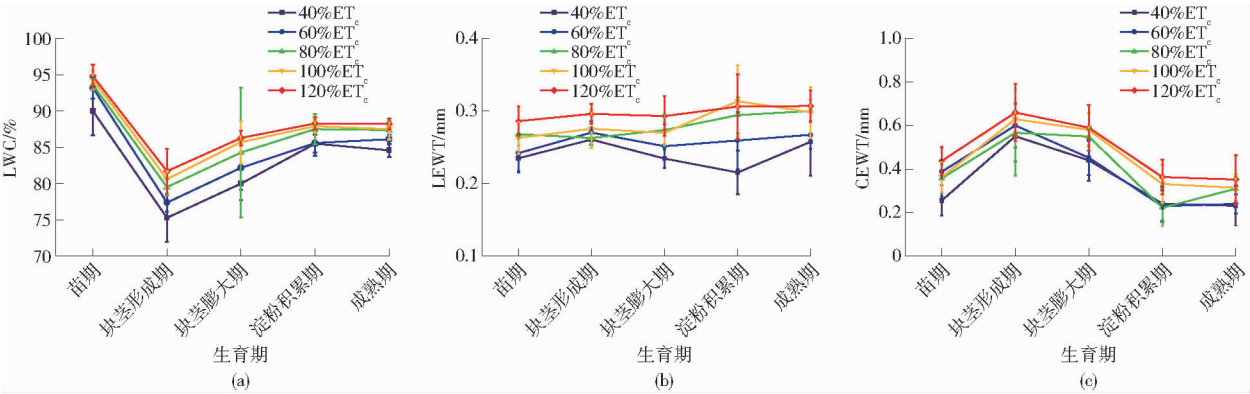

图 4 不同生育期和灌水处理下冬马铃薯各水分指标变化曲线

Fig. 4 Changes in various moisture indicators of winter potato under different growth stages and irrigation treatments

R 波段;各灌水处理之间波段反射率在 G 和 R 波段差异很小,在 RE 与 NIR 波段反射率差异较大;其中苗期各灌溉处理下 NIR 波段差异最大(图 5a),反射率差值达 4.962 个百分点。

2.2 遥感变量与不同水分指标相关性

提取的 ASR、VIs、Textures 与冬马铃薯各水分指标的相关性分析如表 4 所示。分析表明,ASR、VIs、Textures 与 LWC 相关系数绝对值最高的分别为 G(0.465)、NGRDI(0.382)和 RE - CON(0.611);ASR、VIs、Textures 与 LEWT 相关系数绝对值最高的分别为 NIR(0.372)、DVI(0.352)和 NIR - MEA(0.291);ASR、VIs、Textures 与 CEWT 相关系数绝对值最高的分别为 NIR(0.691)、NGRDI(0.797)和 NIR - MEA(0.707)。总体来看,各遥感变量与 CEWT 的相关性最好,共有 11 个变量相关性系数绝对值大于 0.6,其次为 LWC,各遥感变量与 LEWT 的相关性欠佳。基于结果,选用 CEWT 作为冬马铃薯冠层水分反演指标。

2.3 遥感变量筛选

在构建冬马铃薯 CEWT 反演模型前,对各遥感变量进行共线性诊断从而筛选变量。对 ASR、VIs、Textures 3 类自变量分别进行相关分析(图 6a ~ 6c),可见遥感变量间存在共线性。基于自变量相关系数矩阵,剔除存在共线性的变量,最终剔除 RE、NDVI、DVI、RVI、LCI、G - HOM、G - CON、G - ENT、R - HOM、R - CON、RE - MEA、RE - VAR、RE - HOM、RE - CON、RE - COR、NIR - HOM、NIR - CON、NIR - DIS、NIR - ENT。基于保留的遥感变量(图 6d ~ 6f),结合表 4 相关系数显著性结果,选择 ASR、VIs、Textures 保留变量中与 CEWT 相关系数显著($0.01 \leqslant P < 0.05$)和极显著($P < 0.01$)的变量构建数据集(表 5)。

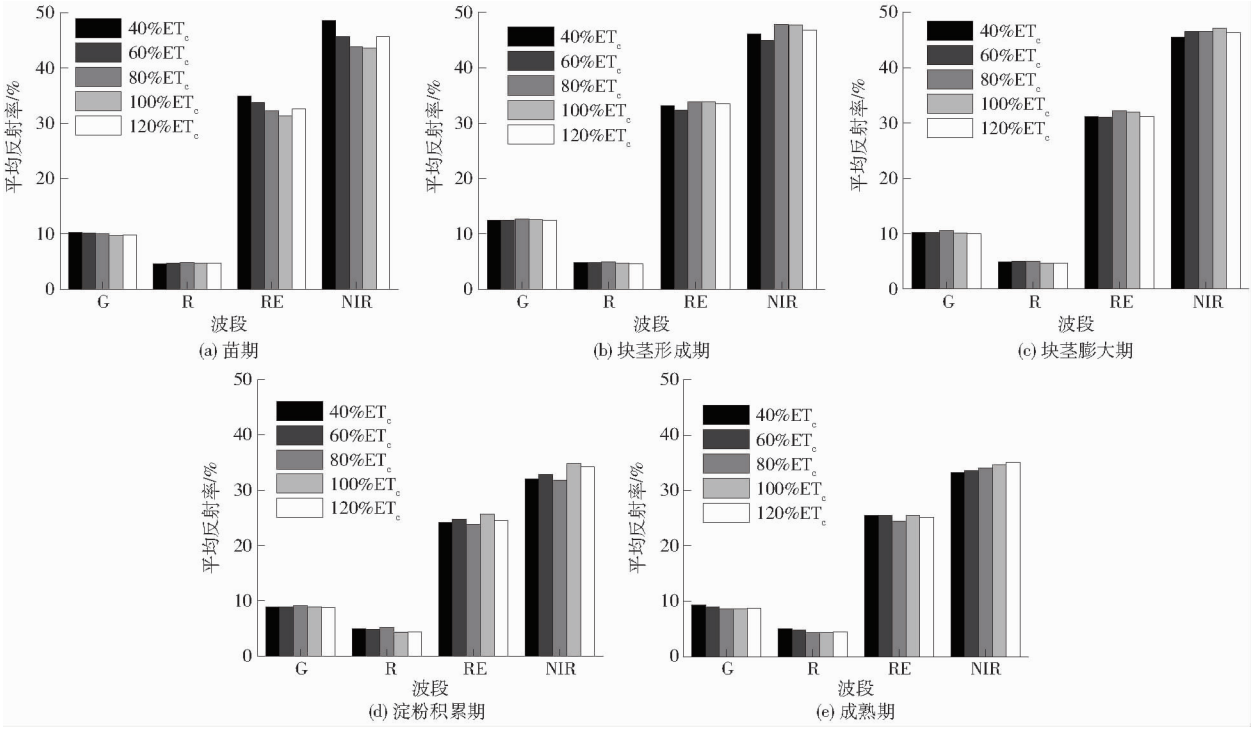

图 5　不同生育期和灌水处理下冬马铃薯冠层 ASR

Fig. 5　ASR of winter potato canopy under different growth stages and irrigation treatments

表 4　ASR、VIs、Textures 与各水分指标间相关系数

Tab. 4　Correlation coefficient between ASR, VIs, Textures, and various water status indicators

水分指标	ASR、VIs、Textures	|r|	ASR、VIs、Textures	|r|	ASR、VIs、Textures	|r|	ASR、VIs、Textures	|r|	ASR、VIs、Textures	|r|
LWC	G	0.465 **	NDRE	0.344 **	G − ENT	0.184 *	R − SEM	0.168 *	RE − COR	0.317 **
	R	0.123	OSAVI	0.078	G − SEM	0.099	R − COR	0.193 *	NIR − MEA	0.496 **
	RE	0.118	NGRDI	0.382 **	G − COR	0.147	RE − MEA	0.342 **	NIR − VAR	0.515 **
	NIR	0.211 **	MSR	0.129	R − MEA	0.025	RE − VAR	0.598 **	NIR − HOM	0.467 **
	NDVI	0.054	G − MEA	0.125	R − VAR	0.246 **	RE − HOM	0.488 **	NIR − CON	0.569 **
	DVI	0.203 *	G − VAR	0.386 **	R − HOM	0.396 **	RE − CON	0.611 **	NIR − DIS	0.547 **
	RVI	0.127	G − HOM	0.344 **	R − CON	0.240 **	RE − DIS	0.587 **	NIR − ENT	0.228 **
	GNDVI	0.102	G − CON	0.426 **	R − DIS	0.245 **	RE − ENT	0.242 **	NIR − SEM	0.112
	LCI	0.323 **	G − DIS	0.347 **	R − ENT	0.270 **	RE − SEM	0.060	NIR − COR	0.367 **
LEWT	G	0.280 **	NDRE	0.190 *	G − ENT	0.159	R − SEM	0.326 **	RE − COR	0.010
	R	0.296 **	OSAVI	0.273 **	G − SEM	0.175 *	R − COR	0.108	NIR − MEA	0.291 **
	RE	0.351 **	NGRDI	0.118	G − COR	0.071	RE − MEA	0.244 **	NIR − VAR	0.001
	NIR	0.372 **	MSR	0.216 **	R − MEA	0.042	RE − VAR	0.069	NIR − HOM	0.155
	NDVI	0.164 *	G − MEA	0.151	R − VAR	0.055	RE − HOM	0.215 **	NIR − CON	0.068
	DVI	0.352 **	G − VAR	0.108	R − HOM	0.148	RE − CON	0.095	NIR − DIS	0.094
	RVI	0.204 *	G − HOM	0.236 **	R − CON	0.040	RE − DIS	0.136	NIR − ENT	0.031
	GNDVI	0.036	G − CON	0.109	R − DIS	0.068	RE − ENT	0.136	NIR − SEM	0.033
	LCI	0.191 *	G − DIS	0.102	R − ENT	0.126	RE − SEM	0.038	NIR − COR	0.075
CEWT	G	0.683 **	NDRE	0.455 **	G − ENT	0.065	R − SEM	0.032	RE − COR	0.175 *
	R	0.137	OSAVI	0.678 **	G − SEM	0.058	R − COR	0.422 **	NIR − MEA	0.707 **
	RE	0.657 **	NGRDI	0.797 **	G − COR	0.170 *	RE − MEA	0.682 **	NIR − VAR	0.045
	NIR	0.691 **	MSR	0.668 **	R − MEA	0.299 **	RE − VAR	0.026	NIR − HOM	0.057
	NDVI	0.642 **	G − MEA	0.191 *	R − VAR	0.230 **	RE − HOM	0.088	NIR − CON	0.023
	DVI	0.697 **	G − VAR	0.083	R − HOM	0.376 **	RE − CON	0.056	NIR − DIS	0.038
	RVI	0.670 **	G − HOM	0.040	R − CON	0.225 **	RE − DIS	0.073	NIR − ENT	0.128
	GNDVI	0.079	G − CON	0.048	R − DIS	0.329 **	RE − ENT	0.063	NIR − SEM	0.162 *
	LCI	0.507 **	G − DIS	0.053	R − ENT	0.349 **	RE − SEM	0.034	NIR − COR	0.111

注：* 表示显著（$0.01 \leqslant P < 0.05$）；** 表示极显著（$P < 0.01$）。

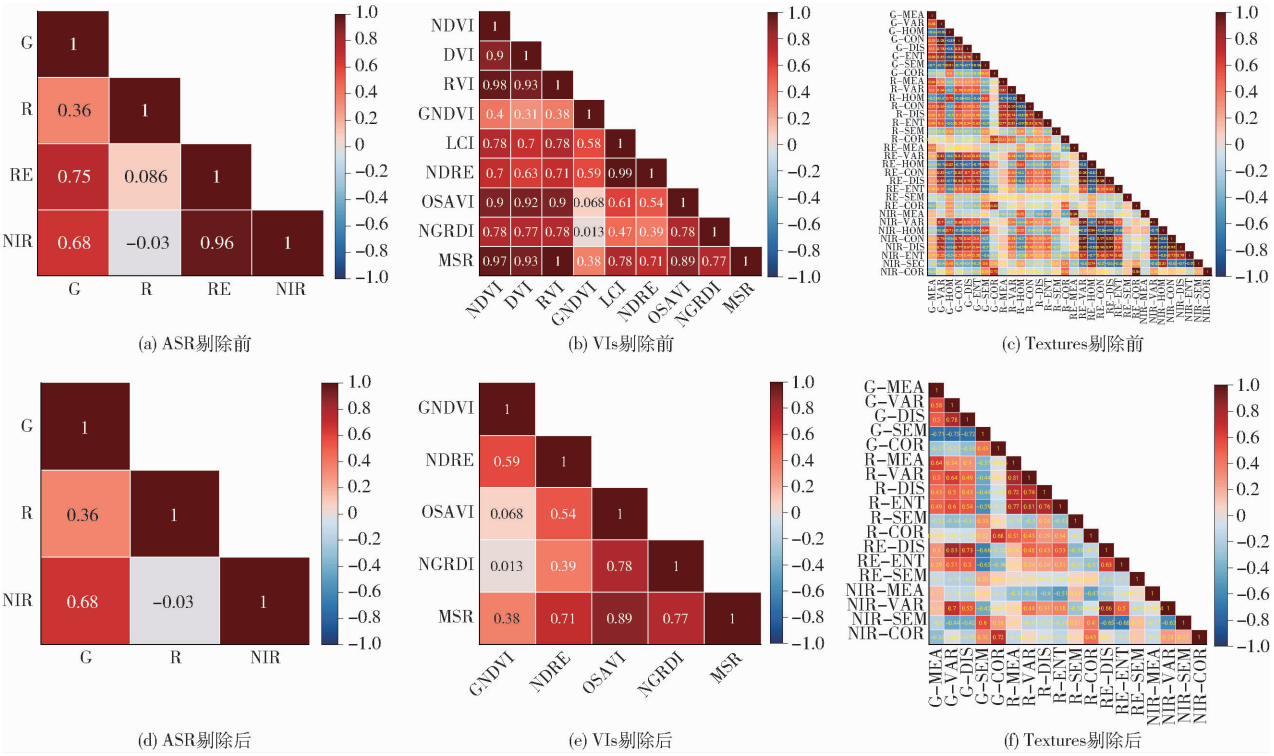

图 6 各遥感变量间相关系数

Fig. 6 Correlation coefficient between various remote sensing variables

表 5 模型输入数据集

Tab. 5 Model input datasets

遥感变量	输入变量
ASR	G、NIR
VIs	NDRE、OSAVI、NGRDI、MSR
Textures	G - MEA、G - COR、R - MEA、R - VAR、R - DIS、R - ENT、R - COR、NIR - MEA、NIR - SEM
ASR + VIs	G、NIR、NDRE、OSAVI、NGRDI、MSR
ASR + Textures	G、NIR、G - MEA、G - COR、R - MEA、R - VAR、R - DIS、R - ENT、R - COR、NIR - MEA、NIR - SEM
VIs + Textures	NDRE、OSAVI、NGRDI、MSR、G - MEA、G - COR、R - MEA、R - VAR、R - DIS、R - ENT、R - COR、NIR - MEA、NIR - SEM
ASR + VIs + Textures	G、NIR、NDRE、OSAVI、NGRDI、MSR、G - MEA、G - COR、R - MEA、R - VAR、R - DIS、R - ENT、R - COR、NIR - MEA、NIR - SEM

2.4 冬马铃薯 CEWT 反演模型建立与精度评价

为评估融合多类型遥感变量反演冬马铃薯 CEWT 的效果，通过完全组合 3 种类型遥感变量数据集（表 5）建立模型。不同变量组合的 PLSR、RF 和 ELM 模型反演精度如表 6 所示，可见与单一遥感变量模型相比，合并不同遥感变量提高了 CEWT 反演精度。

基于 PLSR 算法进行 CEWT 反演的结果表明，ASR + VIs + Textures 建模效果最好（R_c^2 = 0.658，$RMSE_c$ 为 0.096 mm，R_p^2 = 0.639，$RMSE_p$ 为 0.082 mm），而单一变量和 2 种变量组合都出现了欠拟合现象（R_c^2 小于 R_p^2）。采用 RF 方法，ASR + VIs + Textures 组合变量获得了最优结果（R_c^2 = 0.875，$RMSE_c$ 为 0.062 mm，R_p^2 = 0.771，$RMSE_p$ 为 0.065 mm，RPD 为 2.055），比 ASR、VIs、Textures 3 种单一变量模型的 R_c^2 提高 0.123、0.07、0.049，R_p^2 提高 0.059、0.017、0.01；比 ASR + VIs、ASR + Textures、VIs + Textures 3 种模型的 R_c^2 提高 0.069、0.025、0.008，R_p^2 提高 0.015、0.004、0.017。同样地，ELM 算法在多种变量组合方面表现出较强性能，ASR + VIs + Textures 的 R_c^2 和 R_p^2 分别达到 0.812 和 0.769，比 ASR、VIs、Textures 3 种单一遥感变量模型的 R_c^2 提高 0.032、0.029、0.024，R_p^2 提高 0.061、0.050、0.046；比 ASR + VIs、ASR + Textures、VIs + Textures 3 种模型的 R_c^2 提高 0.01、0.008、0.004，R_p^2 提高 0.024、0.023、0.021。

对比不同多元回归建模方法结果，可以看出 RF 模型反演效果最好，其次是 ELM 模型，PLSR 模型精

表 6　基于不同数据集的模型精度评价

Tab. 6　Evaluation of model accuracy based on different datasets

建模方法	数据集	校正集		预测集		RPD	变量数
		R_c^2	$RMSE_c$/mm	R_p^2	$RMSE_p$/mm		
PLSR	ASR	0. 616	0. 102	0. 701	0. 073	1. 834	2
	VIs	0. 644	0. 099	0. 783	0. 065	1. 991	4
	Textures	0. 656	0. 097	0. 774	0. 065	1. 991	9
	ASR + VIs	0. 647	0. 098	0. 779	0. 064	1. 995	6
	ASR + Textures	0. 655	0. 097	0. 776	0. 065	1. 991	11
	VIs + Textures	0. 656	0. 097	0. 782	0. 063	1. 994	13
	ASR + VIs + Textures	0. 658	0. 096	0. 639	0. 082	1. 742	15
RF	ASR	0. 752	0. 084	0. 712	0. 072	1. 855	2
	VIs	0. 805	0. 075	0. 754	0. 067	1. 993	4
	Textures	0. 826	0. 078	0. 761	0. 076	1. 757	9
	ASR + VIs	0. 806	0. 075	0. 756	0. 066	2. 023	6
	ASR + Textures	0. 850	0. 068	0. 767	0. 067	1. 993	11
	VIs + Textures	0. 867	0. 063	0. 754	0. 067	1. 993	13
	ASR + VIs + Textures	0. 875	0. 062	0. 771	0. 065	2. 055	15
ELM	ASR	0. 780	0. 077	0. 708	0. 096	1. 576	2
	VIs	0. 783	0. 077	0. 719	0. 094	1. 572	4
	Textures	0. 788	0. 076	0. 723	0. 090	1. 571	9
	ASR + VIs	0. 802	0. 073	0. 745	0. 087	1. 687	6
	ASR + Textures	0. 804	0. 073	0. 746	0. 089	1. 682	11
	VIs + Textures	0. 808	0. 072	0. 748	0. 082	1. 689	13
	ASR + VIs + Textures	0. 812	0. 070	0. 769	0. 078	1. 869	15

度最差。PLSR 模型泛化能力不如 RF 和 ELM 模型，显示出明显的欠拟合现象，不适合本研究冬马铃薯 CEWT 预测。RF 和 ELM 模型在准确反演冬马铃薯 CEWT 都表现出强大能力。RF 较 ELM 对冬马铃薯 CEWT 反演结果精度更优。

2.5　冬马铃薯 CEWT 反演模型应用

使用最优反演模型 RF(ASR + VIs + Textures)绘制 2024 年 5 个采样日期无人机图像的 CEWT 空间分布图(图 7)，在灌溉水平较高的处理下，CEWT 一般较高，灌溉水平低则相反。以图 7b 为例，在 120% ET_c灌水量较大处理下，冬马铃薯 CEWT 均值为 0. 654 mm，在 40% ET_c灌水量处理下 CEWT 均值为 0. 583 mm。通过可视化预测图，直观展示出不同生育期不同灌水水平下冬马铃薯冠层水分状态的变化情况，CEWT 反演的空间分布和变化与图 4c 的 CEWT 变化基本一致。由于土壤和作物生育期推进的影响，水分胁迫水平也表现出差异性，这也表明冬马铃薯 CEWT 分布图对田间灌溉的精准管理具有重要意义。

3　讨论

3.1　作物水分状态反演指标结果分析

众多学者基于作物对水分胁迫的响应，开展了气孔导度、活可燃物含水量、叶绿素荧光等指标的反演研究[28]。气孔导度能反映植物的蒸腾能力与水分利用效率，但其受环境因素影响较大，易产生波

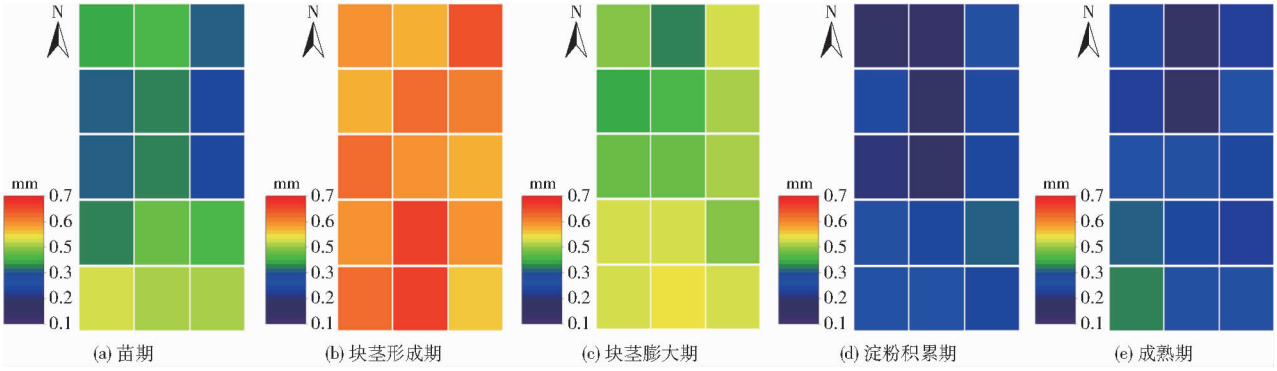

图 7　基于 RF(ASR + VIs + Textures)模型的试验区冬马铃薯 CEWT 空间分布图

Fig. 7　Distribution of CEWT of winter potato in experimental area based on RF(ASR + VIs + Textures) model

动[29];活可燃物含水量多用于森林火灾风险评估,适合特定场景,应用范围较窄[30];叶绿素荧光受温度、光照因素影响较大,且测量通常是局部的,可能无法完全代表整个冠层或作物的水分状态[31]。以上指标大多受环境因素影响,作物水分状态以作物自身水分含量变化为依据的诊断方法最为直接和准确。此外,不同作物的生育期和冠层结构对水分反演指标有显著影响。小麦在拔节期和灌浆期对水分需求不同,此时 LWC 的变化能够准确反映水分胁迫[32];玉米在抽雄期,冠层密度增加使得 CEWT 对水分状况的指示更为敏感[33];苹果的冠层结构在生长初期较稀疏,叶片数量较少,而在生长后期叶片增多,冠层更为密集,因此 LEWT 在不同生育阶段的表现也会有所不同[34]。这些变化强调了监测指标需结合作物的生育期和冠层特性进行分析。本文 CEWT 最能综合反映各生育期冬马铃薯冠层的水分状态,形成的 ASR、VIs 和 Textures 与 CEWT 表现出较强的相关性,能有效反映冬马铃薯水分状况变化。与 LWC 和 LEWT 相比,CEWT 对作物水分状况的反演能力最好,这与前人研究结果相似[35]。

3.2 反演模型变量选择的影响因素

自变量间的共线性会导致模型稳定性降低,高度相关的变量使得很难判断每个变量的独立贡献。筛选合适的输入因子可以提高模型预测精度和解释能力,同时减少过拟合风险。方差膨胀因子(Variance inflation factor,VIF)用于量化每个自变量的多重共线性程度,但 VIF 仅提供了一个相对指标,无法直接判断哪些变量应被剔除,在高维数据中的解释相对复杂[9]。相比之下,基于相关系数剔除共线性的方法通过直接分析变量间的相关性,能够直观地识别冗余特征,并便于特征选择和模型简化,提升了模型的可解释性和实用性[23]。在此基础上,本研究根据 CEWT 与各遥感变量间相关系数显著性检验来选择模型变量。结果显示,冬马铃薯在不同灌水量下的波段反射率在 NIR 波段差异显著(图 5)。这一现象源于 NIR 波段对水分的吸收敏感性较高,主要是由于水分子独特的分子结构和振动特性,在近红外区域产生特定的吸收峰[36]。本文采用 9 种常见植被指数,其中 NDVI、DVI、RVI、GNDVI、LCI、NDRE、OSAVI、MSR 均与 CEWT 相关性显著(表 4),NIR 参与了除 NGRDI 以外的植被指数构建(表 1)。范梅凤等[37]关于冬小麦冠层叶片含水率监测中 NIR 波段参与构建的植被指数表现较其他波段更好,这与本文的研究结果一致。所有纹理信息中,MEA 和 COR 与 CEWT 的相关性表现较其他纹理更好(表 4)。MEA 反映图像中像素值平均水平,不仅可以用于评估作物的整体健康和水分含量,还可以弱化背景噪声带来的影响;COR 则衡量不同像素间的相似性,能够揭示作物表面纹理变化,这些变化往往与水分分布密切相关[38]。

3.3 不同模型对 CEWT 反演精度的影响

ASR 为水分监测提供了基础数据,但其信息主要局限于光谱域,单一的 ASR 变量无法全面反映作物水分状态;VIs 对水分变化敏感,但在高水分条件下可能出现饱和,降低反演能力;引入 Textures 后,模型从空间结构的角度深入理解作物水分分布,显著提高反演精度[39]。在 2.4 节的建模过程中,基于单一 Textures 的 CEWT 估算模型精度高于单一 ASR 或 VIs(表 6),表明 Textures 能有效补充遥感信息,增强模型预测能力,这与 DU 等[7]的结果相似。将 ASR、VIs 与 Textures 组合显著提升了模型预测能力,表现优于任何单一或双变量组合,验证了信息融合的有效性[8]。PEI 等[40]发现将 VIs、Textures 和纹理指数(Texture indexs,TIs)相结合可以显著提高棉花冠层水分的估计精度,这与本文研究结果一致,表明信息融合是提升作物水分监测精度的重要手段。基于不同灌溉水平,本研究中 CEWT 的范围相对较宽(表 3),由于作物冠层光谱反射率与 CEWT 间存在非线性关系,本文线性回归(PLSR)方法对于光谱反演作物水分具有一定局限性,这与其他学者的研究结果类似[41]。PLSR 建模结果表明,模型稳定性较差($R_c^2 < R_p^2$),ASR 精度最低,且 ASR 与其他变量组合(如 VIs 或 Textures)未能提高模型精度,这表明 ASR 可能未有效贡献信息。此外,VIs 与 Textures 组合表现优于包含 ASR 的组合,进一步表明 ASR 的特征在该线性模型框架下无法充分显示其与 CEWT 间的关系。就非线性模型而言,RF 和 ELM 模型在预测冬马铃薯 CEWT 方面优于 PLSR。在本研究中,ELM 预测 CEWT 精度低于 RF(表 6),RF 模型的优势在于其通过结合多棵决策树,有效剔除异常值,确保在复杂数据处理中的高鲁棒性;同时,对噪声的处理能力强,减少了单棵树对数据波动的敏感性,提升了预测稳定性。另一方面,RF 模型的低方差特性使其在不同环境中表现一致,具备良好的泛化能力[42]。相比之下,ELM 虽然训练速度快,但存在对噪声敏感和稳定性较弱的特点,使其在本文数据集上对冬马铃薯 CEWT 预测方面受限。此外,RF 的特征选择机制能够自动识别对水分指标预测影响显著的变量,从而提高预测精度,使 RF 在本研究中优于 ELM。

4 结论

(1)冬马铃薯冠层水分指标表现出随灌水量增

加而增大的特征，冬马铃薯在各生育期的 ASR 随波长增大呈先降低后增加的特征。

（2）相关性分析结果表明，3 个遥感变量（ASR、VIs、Textures）与 CEWT 的相关性较 LWT 和 LEWT 更优。ASR、VIs、Textures 与 CEWT 相关系数绝对值最高的分别为 NIR（0.691）、NGRDI（0.797）和 NIR－MEA（0.707）。

（3）多变量融合显著提高了冬马铃薯 CEWT 反演准确性，非线性模型精度优于线性模型，且提高模型稳定性。基于 ASR + VIs + Textures 数据集的 RF 模型对 CEWT 反演精度最高（R_c^2 = 0.875，$RMSE_c$ 为 0.062 mm，R_p^2 = 0.771，$RMSE_p$ 为 0.065 mm，RPD 为 2.055）。

参　考　文　献

[1] 谢春霞，李灿辉，杨雄，等. 中国马铃薯战略储备的意义及体系构建[J]. 农业展望，2024，20(4)：43－48.
XIE Chunxia, LI Canhui, YANG Xiong, et al. Significance and system construction of strategic reserve of potatoes in China [J]. Agricultural Outlook, 2024, 20(4): 43－48. (in Chinese)

[2] LIU Liangyun, ZHANG Su, ZHANG Bing. Evaluation of hyperspectral indices for retrieval of canopy equivalent water thickness and gravimetric water content[J]. International Journal of Remote Sensing, 2016, 37(14): 3384－3399.

[3] COLOMINA I, MOLINA P. Unmanned aerial systems for photogrammetry and remote sensing: a review[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2014, 92: 79－97.

[4] 刘畅，杨贵军，李振海，等. 融合无人机光谱信息与纹理信息的冬小麦生物量估测[J]. 中国农业科学，2018，51(16)：3060－3073.
LIU Chang, YANG Guijun, LI Zhenhai, et al. Biomass estimation in winter wheat by UAV spectral information and texture information fusion[J]. Scientia Agricultura Sinica, 2018, 51(16): 3060－3073. (in Chinese)

[5] GONG Yan, YANG Kaili, LIN Zhiheng, et al. Remote estimation of leaf area index (LAI) with unmanned aerial vehicle (UAV) imaging for different rice cultivars throughout the entire growing season[J]. Plant Methods, 2021, 17(1): 1－16.

[6] 李健，江洪，罗文彬，等. 融合无人机多光谱和纹理特征的马铃薯 LAI 估算[J]. 华南农业大学学报，2023，44(1)：93－101.
LI Jian, JIANG Hong, LUO Wenbin, et al. Potato LAI estimation by fusing UAV multi-spectral and texture features[J]. Journal of South China Agricultural University, 2023, 44(1): 93－101. (in Chinese)

[7] DU Xiaoyue, ZHENG Liyuan, ZHU Jiangpeng, et al. Enhanced leaf area index estimation in rice by integrating UAV-based multi-source data[J]. Remote Sensing, 2024, 16(7): 1138.

[8] 运彬媛，谢铁娜，李虹，等. 融合无人机光谱与纹理信息的玉米氮素营养估测[J]. 中国农业科学，2024，57(16)：3154－3170.
YUN Binyuan, XIE Tiena, LI Hong, et al. Nitrogen nutrition estimation of maize based on UAV spectrum and texture information[J]. Scientia Agricultura Sinica, 2024, 57(16): 3154－3170. (in Chinese)

[9] 刘杨，冯海宽，孙乾，等. 不同分辨率无人机数码影像的马铃薯地上生物量估算研究[J]. 光谱学与光谱分析，2021，41(5)：1470－1476.
LIU Yang, FENG Haikuan, SUN Qian, et al. Estimation study of above ground biomass in potato based on UAV digital images with different resolutions[J]. Spectroscopy and Spectral Analysis, 2021, 41(5): 1470－1476. (in Chinese)

[10] 王耀民，陈皓锐，陈俊英，等. 光谱指数筛选方法与统计回归算法结合的水稻估产模型对比[J]. 农业工程学报，2021，37(21)：208－216.
WANG Yaomin, CHEN Haorui, CHEN Junying, et al. Comparation of rice yield estimation model combining spectral index screening method and statistical regression algorithm[J]. Transactions of the CSAE, 2021, 37(21): 208－216. (in Chinese)

[11] 畅利毛，郭克贞，魏占民，等. 干旱荒漠草原应用 Penman－Monteith 与 Penman 修正式计算 ET_0 的偏差分析[J]. 灌溉排水学报，2007，26(1)：55－58.
CHANG Limao, GUO Kezhen, WEI Zhanmin, et al. Deviation of the reference crop evapotranspiration estimated by the Penman－Monteith and Penman methods in arid pasture[J]. Journal of Irrigation and Drainage, 2007, 26(1): 55－58. (in Chinese)

[12] GALVAO R K H, ARAUJO M C U, JOSE G E, et al. A method for calibration and validation subset partitioning[J]. Talanta, 2005, 67(4): 736－740.

[13] HUANG Xi, LIN Dong, MAO Xiaomin, et al. Multi-source data fusion for estimating maize leaf area index over the whole growing season under different mulching and irrigation conditions[J]. Field Crops Research, 2023, 303: 109111

[14] BLACKBURN G A. Quantifying chlorophylls and caroteniods at leaf and canopy scales: an evaluation of some hyperspectral approaches[J]. Remote Sensing of Environment, 1998, 66(3): 273－285.

[15] 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.

[16] ZARCO-TEJADA P J, BERNI J A J, SUAREZ L, et al. Imaging chlorophyll fluorescence with an airborne narrow-band multispectral camera for vegetation stress detection[J]. Remote Sensing of Environment, 2009, 113(6): 1262－1275.

[17] 韩文霆，彭星硕，张立元，等. 基于多时相无人机遥感植被指数的夏玉米产量估算[J]. 农业机械学报，2020，51(1)：148－155.
HAN Wenting, PENG Xingshuo, ZHANG Liyuan, et al. Summer maize yield estimation based on vegetation index derived from multi-temporal UAV remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(1): 148－155. (in Chinese)

[18] 李淑贞，徐大伟，范凯凯，等. 基于无人机与卫星遥感的草原地上生物量反演研究[J]. 遥感技术与应用，2022，37(1)：272－278.
LI Shuzhen, XU Dawei, FAN Kaikai, et al. Research of grassland aboveground biomass inversion based on UAV and satellite remoting sensing[J]. Remote Sensing Technology and Application, 2022, 37(1): 272－278. (in Chinese)

[19] ZHANG Ke, GE Xiaokang, SHEN Pengcheng, et al. Predicting rice grain yield based on dynamic changes in vegetation indexes during early to mid-growth stages[J]. Remote Sensing, 2019, 11(4): 387.

[20] HABOUDANE 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(2-3): 416-426.
[21] PAZHANIVELAN S, KUMARAPERUMAL R, SHANMUGAPRIYA P, et al. Quantification of biophysical parameters and economic yield in cotton and rice using drone technology[J]. Agriculture, 2023,13(9): 1668.
[22] 靳亚红,吴鑫淼,甄文超,等. 基于采样点光谱信息窗口尺度优化的土壤含水率无人机多光谱遥感反演[J]. 农业机械学报,2024,55(1):316-327.
JIN Yahong, WU Xinmiao, ZHEN Wenchao, et al. UAV multispectral remote sensing inversion of soil moisture content based on window size optimization of spectral information at sampling points[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(1):316-327. (in Chinese)
[23] 程介虹,陈争光,衣淑娟. 最小相关系数的多元校正波长选择算法[J]. 光谱学与光谱分析, 2022,42(3): 719-725.
CHENG Jiehong, CHEN Zhengguang, YI Shujuan. Wavelength selection algorithm based on minimum correlation coefficient for multivariate calibration[J]. Spectroscopy and Spectral Analysis, 2022,42(3): 719-725. (in Chinese)
[24] YE X, ABE S, ZHANG S. Estimation and mapping of nitrogen content in apple trees at leaf and canopy levels using hyperspectral imaging[J]. Precision Agriculture, 2020,21(1): 198-225.
[25] BREIMAN L. Random forests[J]. Machine Learning, 2001,45(1): 5-32.
[26] HUANG Gao, HUANG Guangbin, SONG Shiji, et al. Trends in extreme learning machines: a review[J]. Neural Networks, 2015,61: 32-48.
[27] RAZAKAMANARIVO R H, GRINAND C, RAZAFINDRAKOTO M A, et al. Mapping organic carbon stocks in eucalyptus plantations of the central highlands of Madagascar: a multiple regression approach[J]. Geoderma, 2011,162(3-4): 335-346.
[28] 韩文霆,张立元,牛亚晓,等. 无人机遥感技术在精量灌溉中应用的研究进展[J]. 农业机械学报, 2020,51(2): 1-14.
HAN Wenting, ZHANG Liyuan, NIU Yaxiao, et al. Review on UAV remote sensing application in precision irrigation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020,51(2): 1-14. (in Chinese)
[29] 毋海梅,闫浩芳,张川,等. 温室滴灌黄瓜产量和水分利用效率对水分胁迫的响应[J]. 农业工程学报, 2020,36(9): 84-93.
WU Haimei, YAN Haofang, ZHANG Chuan, et al. Responses of yield and water use efficiency of drip-irrigated cucumber in greenhouse to water stress[J]. Transactions of the CSAE, 2020,36(9): 84-93. (in Chinese)
[30] 张峰,周广胜. 植被含水量高光谱遥感监测研究进展[J]. 植物生态学报, 2018,42(5): 517-525.
ZHANG Feng, ZHOU Guangsheng. Research progress on monitoring vegetation water content by using hyperspectral remote sensing[J]. Chinese Journal of Plant Ecology, 2018,42(5):517-525. (in Chinese)
[31] IHUOMA S O, MADRAMOOTOO C A. Recent advances in crop water stress detection[J]. Computers and Electronics in Agriculture, 2017, 141: 267-275.
[32] 史博,马祖凯,刘小军,等. 小麦植株水分状况遥感监测研究进展与展望[J]. 麦类作物学报, 2022,42(4): 495-503.
SHI Bo, MA Zukai, LIU Xiaojun, et al. Progress and prospects of wheat plant water status monitoring by remote sensing[J]. Journal of Triticeae Crops, 2022,42(4): 495-503. (in Chinese)
[33] 马建新,孟庆岩,李响,等. 玉米冠层最佳水分指数优选[J]. 遥感信息, 2016,31(5): 96-102.
MA Jianxin, MENG Qingyan, LI Xiang, et al. Optimization research on optimum corn canopy water content index[J]. Remote Sensing Information, 2016,31(5):96-102. (in Chinese)
[34] 冯海宽,李振海,金秀良,等. 基于 EFAST 和 PLS 的苹果叶片等效水厚度高光谱估算[J]. 农业工程学报, 2016,32(12): 165-171.
FENG Haikuan, LI Zhenhai, JIN Xiuliang, et al. Estimating equivalent water thickness of apple leaves using hyperspectral data based on EFAST and PLS[J]. Transactions of the CSAE, 2016,32(12): 165-171. (in Chinese)
[35] ZHOU Huailin, ZHOU Guangsheng, SONG Xingyang, et al. Dynamic characteristics of canopy and vegetation water content during an entire maize growing season in relation to spectral-based indices[J]. Remote Sensing, 2022,14(3): 584.
[36] 邓孺孺,何颖清,秦雁,等. 近红外波段(900~2 500 nm)水吸收系数测量[J]. 遥感学报, 2012,16(1): 192-206.
DENG Ruru, HE Yingqing, QIN Yan, et al. Measuring pure water absorption coefficient in the near-infrared spectrum (900~2 500 nm)[J]. Journal of Remote Sensing, 2012,16(1):192-206. (in Chinese)
[37] 范梅凤,蔡焕杰,李志军. 基于高光谱遥感水分指数的叶片与土壤含水率监测研究[J]. 灌溉排水学报, 2014,33(4/5): 213-217.
FAN Meifeng, CAI Huanjie, LI Zhijun. Monitoring leaf and soil moisture status based on hyperspectral-derived vegetation moisture indices[J]. Journal of Irrigation and Drainage, 2014, 33(4/5): 213-217. (in Chinese)
[38] XU Sizhe, XU Xingang, ZHU Qingzhen, et al. Monitoring leaf nitrogen content in rice based on information fusion of multi-sensor imagery from UAV[J]. Precision Agriculture, 2023,24(6): 2327-2349.
[39] KHOSRAVI I, ALAVIPANAH S K. A random forest-based framework for crop mapping using temporal, spectral, textural and polarimetric observations[J]. International Journal of Remote Sensing, 2019,40(18): 7221-7251.
[40] PEI Shengzhao, DAI Yulong, BAI Zhentao, et al. Improved estimation of canopy water status in cotton using vegetation indices along with textural information from UAV-based multispectral images[J]. Computers and Electronics in Agriculture, 2024, 224: 109176.
[41] 齐浩,吕亮杰,孙海芳,等. 基于无人机高光谱遥感与机器学习的小麦品系产量估测研究[J]. 农业机械学报, 2024, 55(7): 260-269.
QI Hao, LÜ Liangjie, SUN Haifang, et al. Yield estimation of wheat lines based on UAV hyperspectral remote sensing and machine learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(7): 260-269. (in Chinese)
[42] 韩兆迎,朱西存,房贤一,等. 基于 SVM 与 RF 的苹果树冠 LAI 高光谱估测[J]. 光谱学与光谱分析, 2016,36(3): 800-805.
HAN Zhaoying, ZHU Xicun, FANG Xianyi, et al. Hyperspectral estimation of apple tree canopy LAI based on SVM and RF regression[J]. Spectroscopy and Spectral Analysis, 2016, 36(3): 800-805. (in Chinese)