

周 鱼,薛晓斌,宁 琳,等. 基于无人机多光谱遥感的赤霞珠葡萄黎明前叶片水势反演与验证[J]. 江苏农业学报,2026,42(4):745-755.

doi:10.3969/j.issn.1000-4440.2026.04.011

基于无人机多光谱遥感的赤霞珠葡萄黎明前叶片水势反演与验证

周 鱼¹, 薛晓斌², 宁 琳¹, 刘虹君¹, 胡宏远², 郑明鑫¹, 王振平¹, 李栋梅¹

(1.宁夏大学葡萄酒与园艺学院,宁夏 银川 750021; 2.宁夏大学生命科学学院,宁夏 银川 750021)

摘要: 本研究旨在利用无人机多光谱技术构建高精度反演模型,实现葡萄树的水分动态、无损和大尺度监测。以酿酒葡萄赤霞珠为试验材料,分析冠层单波段反射率、多光谱指数、可见光谱指数与葡萄不同发育时期(花后20~40 d、花后41~60 d、花后61~80 d)黎明前叶片水势(Ψ_{pre})的相关性,以筛选与不同时期 Ψ_{pre} 密切相关的遥感参数。采用一元线性回归、多元线性回归及偏最小二乘回归(PLSR)方法,构建各生育期 Ψ_{pre} 的估测模型。结果表明,基于3种模型构建的黎明前叶片水势预测模型均具有一定的预测能力,花后20~40 d、花后41~60 d、花后61~80 d的一元线性模型的决定系数(R^2)的最高值分别为0.560、0.448、0.641;多元线性模型的 R^2 的最高值分别为0.622、0.680、0.713;PLSR模型的 R^2 的最高值分别为0.695、0.777、0.763,对水势的预测精度较一元线性回归模型和多元线性模型提升了7.01%~73.44%。综上,基于无人机多光谱遥感的机器学习模型能够对黎明前叶片水势进行良好的预测,PLSR模型可通过融合多光谱特征与非线性关系显著提升葡萄黎明前叶片水势的预测精准度,且在花后41~60 d的表现最佳,可为葡萄园的大面积精准灌溉决策提供依据。

关键词: 赤霞珠;无人机;多光谱;黎明前叶片水势;偏最小二乘回归(PLSR)模型

中图分类号: S663.1 **文献标识码:** A **文章编号:** 1000-4440(2026)04-0745-11

Inversion and validation of pre-dawn leaf water potential for Cabernet Sauvignon grapes based on multispectral remote sensing by unmanned aerial vehicle

ZHOU Yu¹, XUE Xiaobin², NING Lin¹, LIU Hongjun¹, HU Hongyuan², ZHENG Mingxin¹, WANG Zhenping¹, LI Dongmei¹

(1.School of Enology and Horticulture, Ningxia University, Yinchuan 750021, China; 2.School of Life Sciences, Ningxia University, Yinchuan 750021, China)

Abstract: This study aimed to utilize unmanned aerial vehicle (UAV) multispectral technology to construct a high-precision inversion model for dynamic, non-destructive, and large-scale monitoring of grapevine water status. Cabernet Sauvignon wine grapes were used as the experimental material to analyze the correlations between canopy single-band reflectance, multispectral vegetation indices, visible light indices, and pre-dawn leaf water potential (Ψ_{pre}) at different developmental stages (20–40 days after anthesis, 41–60 days after anthesis, and 61–80 days after anthesis), thereby screening remote sensing parameters.

收稿日期:2025-06-19

基金项目:宁夏重点研发项目(2023BSB03032);国家自然科学基金项目(U20A2042);财政部和农业农村部国家葡萄产业技术体系水分生理与节水栽培岗位项目(CARS-29-zp-3)

作者简介:周 鱼(2001-),女,宁夏银川人,硕士研究生,研究方向为葡萄逆境生理与分子生物学。(E-mail)13209511934@163.com

通讯作者:王振平,(E-mail) wangzhp@nxu.edu.cn;李栋梅,(E-mail) ldm2022068@nxu.edu.cn

ters closely related to Ψ_{pre} at each stage. Univariate linear regression, multiple linear regression, and partial least squares regression (PLSR) were employed to construct Ψ_{pre} estimation models for each growth stage. The results showed that the pre-dawn leaf water potential prediction models constructed using the three methods all exhibited certain predictive capabilities. The coefficients of determination (R^2) for the univariate linear models were 0.560, 0.448, and 0.641 for 20–40 days after anthesis (DAA), 41–60 DAA, and 61–80 DAA, respectively. For the multiple linear models, the R^2 values were 0.622, 0.680, and 0.713, and the PLSR models achieved R^2 values of 0.695, 0.777, and 0.763, improving prediction accuracy by 7.01%–73.44% compared with univariate and multiple linear regression models. In summary, machine learning models based on UAV multispectral remote sensing can effectively predict pre-dawn leaf water potential. The PLSR model significantly improved prediction accuracy by integrating multispectral features and nonlinear relationships, with the best performance observed at 41–60 DAA, providing a basis for precision irrigation decision-making in large-scale vineyards.

Key words: Cabernet Sauvignon; unmanned aerial vehicle (UAV); multispectral; pre-dawn leaf water potential; partial least squares regression (PLSR) model

水分含量是影响作物生产的限制性环境因素之一^[1]。黎明前叶片水势(Ψ_{pre})是植物从土壤中吸取水分所需的负压力,为了保证水分通过木质部从根系持续流向叶片,并通过气孔进行蒸腾,葡萄植株各组织内部的水势须低于土壤水势。如果土壤中的有效水分减少,植株将降低自身水势,以获取所需水分,满足植株的正常生长需要^[2]。因此,植物叶片水势是衡量植株水分状态的重要指标,常被用于指导作物的水分管理,在植物水分移动过程中发挥着关键作用^[3]。传统的水势测量方法主要有热电偶湿度计法^[4]、压力室法^[5]和小液流法^[6],这些方法虽然准确,但耗时费力,采样成本高,且测点不具有代表性,还会对植株造成一定损伤,难以实现大面积、实时的监测。因此,开发一种快速、无损的叶片水势预测技术,对于提高葡萄园水分管理效率和农业管理水平具有重要意义。

无人机遥感技术是依托无人机平台搭载遥感传感器的新型观测技术,采用自动化和智能化方式获取遥感信息^[7]。随着智慧农业技术的快速发展,无人机多光谱遥感技术作为一种高效、非破坏性的监测手段,在作物生长监测、生理状态评估中得到了广泛应用^[8],与田间测量方法相比,遥感技术具有操作便捷、时空分辨率高、成本低等优势,已经成为农情监测的重要手段^[9]。目前,许多遥感数据(可见光、多光谱和热红外等)已被用于估测作物参数,包括叶面积指数^[10]、叶绿素含量^[11]、生物量^[12]和叶片含水量^[13]等。王笑雪^[14]运用无人机多光谱遥感数据开展牧草产量、营养品质的预测建模研究,探明了混播草地最佳刈割时期的有效积温区间。Zhang等^[15]将无人机多光谱传感器提取的纹理、光谱、覆

盖度和热红外信息结合,提高了土壤水分的监测精度。刘易雪^[16]利用无人机遥感技术实现了高效的大规模葡萄园卷叶病的空间分布监测。Peng等^[17]研究发现,无人机多模态数据融合再利用随机森林算法模型在预测葡萄不同生长阶段的叶片含水量方面具有良好的应用效果。Lyu等^[18]利用遥感、近地观测数据及葡萄植株活力参数,实现了葡萄品质的无损、快速预测。上述研究结果为规模化预测植株水分情况提供了良好支撑。

为了及时精准地监测赤霞珠葡萄树冠层叶片水势,以表征植被的水分状况,本研究拟利用无人机多光谱技术获取冠层光谱数据,结合压力室法测定 Ψ_{pre} ,构建基于光谱数据的预测模型。通过分析不同植被指数与 Ψ_{pre} 之间的关系,筛选出最优预测变量,并评估模型在不同生长阶段、不同环境条件下的适用性。研究结果旨在为葡萄园精准灌溉和水分管理提供科学依据,同时为无人机多光谱技术在大面积葡萄园植株水分监测中的应用提供参考。

1 材料与方法

1.1 试验材料

本试验于2024年5–10月在宁夏贺兰山东麓玉泉营农场国家葡萄产业技术体系水分生理与节水栽培岗位(CARS-29-zp-3)试验基地(105°99'E, 38°12'N)进行,试验区概况见图1。本研究以12年生赤霞珠植株作为试验材料,按“厂”字形整形,按东西行向定植,株距×行距为0.5 m×3.0 m,灌溉方式为传统滴灌。

1.2 试验设计

在研究区域内选定12个样本小区,在地面使用



□ 测试区域

图1 试验区概况

Fig.1 Overview of the experimental zone

标记板标记。葡萄的盛花期为5月20日(简称0 DAA),分别在葡萄花后20~40 d(简称20~40 DAA)、花后41~60 d(简称41~60 DAA)、花后61~80 d(简称61~80 DAA)测量 Ψ_{pre} 。同步采集多光谱、可见光图像,为后续建模反演提供数据基础。每个时期测定5次 Ψ_{pre} ,共收集60组数据,在葡萄的整个生育期共获得180组数据。对光谱图像进行拼接校正处理后,计算各小区的平均反射率值,构建对应的植被指数。在完成各时期的数据采集工作后,采用随机抽样方法从样本中选取45组数据作为建模样本集,将剩余的15组数据组成验证样本集,用于评估模型的预测精度。

1.3 试验方法

1.3.1 黎明前叶片水势 在各试验小区内,挑选3株生长发育程度相近的植株,在黎明时间(05:00-05:30)快速采集葡萄枝条第6~8节位的健康、无病斑的叶片。将采集的叶片立即装入塑封袋中,密封后迅速转运至实验室内。用锋利刀片在叶柄基部斜向切割,随即将处理后的叶片置于3005型植物水分压力室(美国 Soil Moisture Equipment 公司产品)中,通过表盘读取叶片水势的绝对值,记录数据。每个样本均进行3次生物学重复^[19]。

1.3.2 无人机多光谱数据的获取 用大疆精灵4多光谱版无人机获取花后20~40 d、花后41~60 d、花后61~80 d的多光谱遥感影像。地面分辨率为7.62 cm,飞行高度为90 m,主航线的重叠度为85%,旁向重叠度为80%,拍摄时段为12:00-13:00。飞行前观察天气、风向、风速等因素,必要时重复采集影像供研究人员选择,以保证获取图像的质量。

获取的影像包括红光波段(650 nm)反射率(*RED*)、绿光波段(560 nm)反射率(*GREEN*)、蓝光波段(450 nm)反射率(*BLUE*)、红边波段(730 nm)反射率(*REDG*)和近红外波段(840 nm)反射率(*NIR*)。在拍摄过程中,基于太阳光辐射特征对无人机影像进行辐射校正。

1.3.3 多光谱影像的预处理 用大疆智图软件对无人机获取的多光谱影像进行自动化拼接与几何配准,生成试验小区的完整正射影像。基于辐射定标板的标准反射率数据,完成影像的辐射定标处理,并将原始数字量化值(*DN*)转换为地表反射率。在ENVI 5.3 遥感分析平台中,利用地面预设标记物精准定位采样小区,并划定感兴趣区域。为了区分葡萄冠层与背景土壤,采用阈值分割法结合低通滤波预处理技术,通过对比不同滤波算法的效果,最终选择低通滤波来消除高频噪声,以显著提升分类精度。进一步通过波段运算生成归一化植被指数(*NDVI*)影像,基于阈值分割与二值化处理提取葡萄冠层空间分布矢量文件。通过对各植被指数正射影像与冠层矢量文件进行空间叠加分析,最终生成适用于葡萄冠层的专属反射率影像数据。针对目标区域的反射率数据,提取所有有效像元的反射率值并导出至Excel 2021,剔除零值、异常值后,计算感兴趣区域内的反射率均值,作为当日无人机平台观测的冠层反射率表征值^[20]。

1.3.4 植被指数的选取 植被指数是一种通过遥感技术获取植物的辐射数据后计算而成的、常用来监测作物的生理生化参数^[21]。基于前期研究成果及本试验所用5波段摄像头的光谱特征,结合植物水分状态监测的相关理论,筛选出13种植被指数作为关键指标,包括6种多光谱指数、7种可见光谱指数,具体计算方法参考文献[22]~[29],详见表1。

1.3.5 模型的构建与检验 本试验采用一元线性回归、多元线性回归(*MLR*)和偏最小二乘法回归(*PLSR*)3种算法结合不同植被指数,分别在不同生育期建立模型。在多元线性回归模型的构建方面,采用逐步变量筛选策略,具体操作流程如下:每引入1个自变量即开展显著性检验,保留显著因子,同时剔除不显著的因子。通过交叉验证对比不同变量组合,筛选解释力强且共线性低的植被指数用于构建反演模型。针对不同生育期(花后20~40 d、花后41~60 d、花后61~80 d)分别建模,最终选择决定系

数(R^2)最高、均方根误差($RMSE$)最低和最优生育期作为核心模型要素^[30]。通过辐射定标将原始 DN 转换为反射率,计算各试验小区冠层反射率均值。用 ENVI 5.3 提取植被指数,构建光谱特征数据集。以植被指数为自变量,以 Ψ_{pre} 为因变量,用 SPSS 16.0、Unscrambler×10.4、Origin 2024、Office 2021 等软件构建并验证回归模型。模型性能的评估主要依赖于

R^2 、 $RMSE$,具体计算公式如下:

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

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

式中, \hat{y}_i 为预测值; \bar{y} 为实测均值; y_i 为实测值; n 为样本数。

表 1 本研究所用植被指数

Table 1 Vegetation indices used in this study

类别	植被指数	计算公式	参考文献
多光谱指数	归一化植被指数($NDVI$)	$(NIR-R)/(NIR+R)$	[22]
	重归一化植被指数($RNDVI$)	$(NIR-R)/\sqrt{NIR+R}$	[22]
	优化土壤调节植被指数($OSAVI$)	$(NIR-R)/(NIR+R+0.16)$	[23]
	绿度归一化植被指数($GNDVI$)	$(NIR-G)/(NIR+G)$	[24]
	叶面叶绿素植被指数(LCI)	$(NIR-REDG)/(NIR+REDG)$	[25]
	转换型叶绿素吸收反射率指数/优化土壤调节植被指数($TCARI/OSAVI$)	$\frac{3[NIR-R-0.2(NIR-G)(NIR/R)]}{(1+0.16)(REDG-R)/(REDG+R+0.16)}$	[26]
可见光谱指数	标准化红光(ρ)	$R/(R+G+B)$	[27]
	标准化绿光(γ)	$G/(R+G+B)$	[27]
	标准化蓝光(β)	$B/(R+G+B)$	[27]
	归一化红绿差异($NGRDI$)	$(\gamma-\beta)/(\gamma+\beta)$	[28]
	红绿比指数($RGRI$)	ρ/γ	[27]
	绿叶指数(GLI)	$(2\gamma-\rho-\beta)/(2\gamma+\rho+\beta)$	[29]
	可见大气阻力指数($VARI$)	$(\gamma-\rho)/(\gamma+\rho-\beta)$	[28]

R 、 G 、 B 、 NIR 、 $REDG$ 分别代表 650 nm、560 nm、450 nm、840 nm、730 nm 波段的光谱反射率。

2 结果与分析

2.1 单波段反射率与 Ψ_{pre} 的相关性分析

如图 2A 所示,在花后 20~40 d, Ψ_{pre} 与 $REDG$ 、 NIR 、 RED 、 $GREEN$ 均表现出极显著负相关关系,其中与 NIR 的相关性最高,相关系数达到 -0.73。如图 2B 所示,在花后 41~60 d, Ψ_{pre} 与 RED 呈显著负相关,与 $BLUE$ 呈极显著负相关,相关系数分别为 -0.31、-0.52。如图 2C 所示,在花后 61~80 d, Ψ_{pre} 仍与 $BLUE$ 、 RED 呈负相关。总体上看,在花后 20~80 d, Ψ_{pre} 与 NIR 、 RED 、 $BLUE$ 波段均呈显著或极显著负相关,其中与 RED 的相关系数绝对值最高,达 0.45(图 2D)。

2.2 多光谱指数与 Ψ_{pre} 的相关性分析

如图 3A 所示,在花后 20~40 d, Ψ_{pre} 与 $NDVI$ 、重归一化植被指数($RNDVI$)、优化土壤调节植被指数($OSAVI$)、绿度归一化植被指数($GNDVI$)呈极显著负相关,对应的相关系数依次为 -0.51、-0.72、

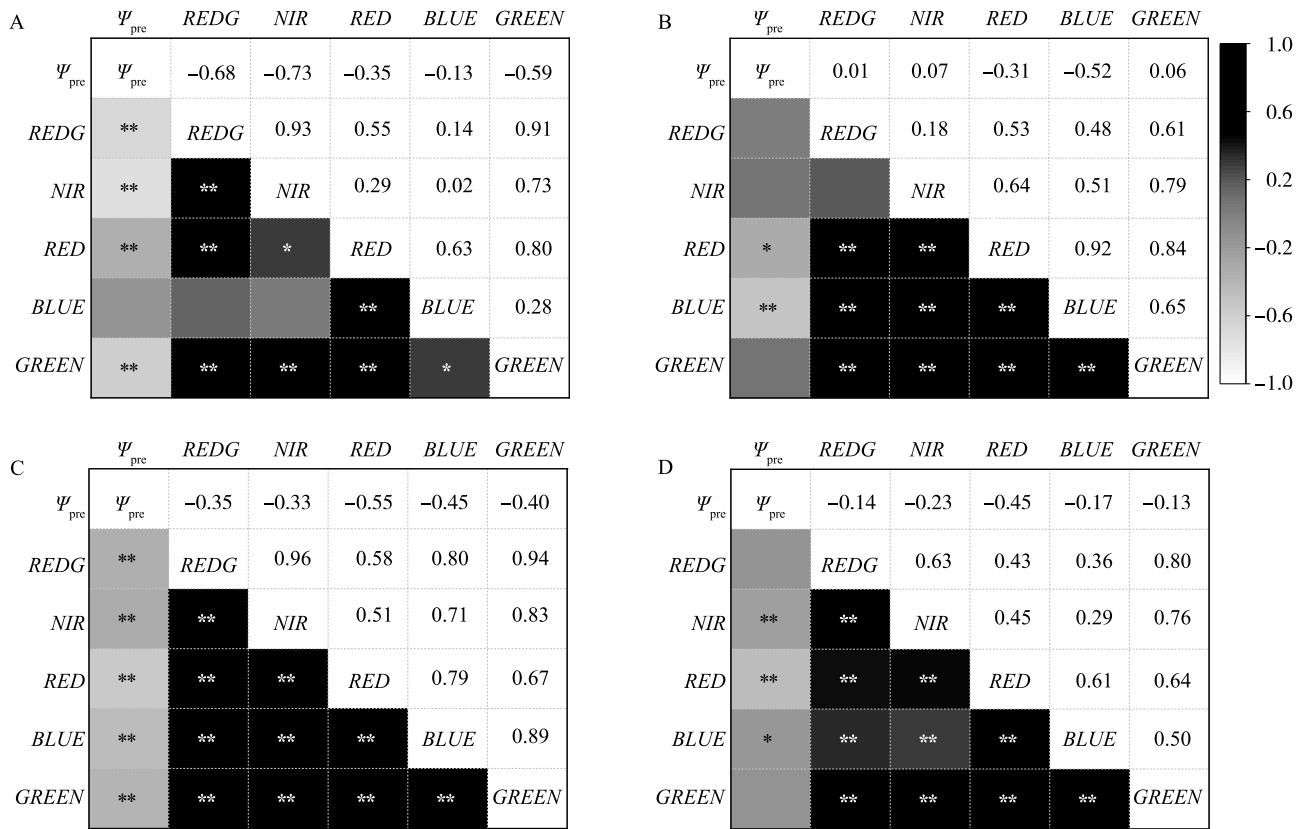
-0.71、-0.34。如图 3B 所示,在花后 41~60 d, Ψ_{pre} 与 $NDVI$ 呈极显著正相关,相关系数达到 0.42。如图 3C 所示,在花后 61~80 d, Ψ_{pre} 与 $NDVI$ 继续保持极显著正相关,同时与转换型叶绿素吸收反射率指数/优化土壤调节植被指数($TCARI/OSAVI$)呈极显著负相关,相关系数为 -0.50。如图 3D 所示, Ψ_{pre} 与 $NDVI$ 呈显著正相关,而与 $GNDVI$ 、 $TCARI/OSAVI$ 分别呈极显著、显著负相关。

2.3 可见光谱指数与 Ψ_{pre} 的相关性分析

如图 4A 所示,在葡萄花后 20~40 d, Ψ_{pre} 与标准化红光(ρ)、红绿比指数($RGRI$)表现出极显著正相关关系,相关系数分别达到 0.51、0.55,而与标准化绿光(γ)、绿叶指数(GLI)、可见大气阻力指数($VARI$)则表现为极显著负相关。如图 4B 所示,在葡萄花后 41~60 d, Ψ_{pre} 与 γ 、归一化红绿差异($NGRDI$)、 GLI 、 $VARI$ 均呈极显著正相关,其中 $NGRDI$ 与 Ψ_{pre} 的相关性最强,相关系数高达 0.70;同时, Ψ_{pre} 与 ρ 、标准化蓝光(β)、 $RGRI$ 呈极显著负相关,相关系数分别为 -0.47、-0.69、-0.65。

如图 4C 所示,在花后61~80 d, Ψ_{pre} 与 γ 、 β 、 GLI 、 $VARI$ 表现出显著或极显著正相关,与 ρ 、 $RGRI$ 则呈现极显著负

相关。如图 4D 所示,在花后20~80 d, Ψ_{pre} 与 γ 、 GLI 、 $VARI$ 呈现稳定的正相关关系。



A: 花后20~40 d 的单波段反射率与 Ψ_{pre} 的相关性; B: 花后41~60 d 的单波段反射率与 Ψ_{pre} 的相关性; C: 花后61~80 d 的单波段反射率与 Ψ_{pre} 的相关性; D: 花后20~80 d 的单波段反射率与 Ψ_{pre} 的相关性。RED 表示红光波段(650 nm)反射率, GREEN 表示绿光波段(560 nm)反射率, BLUE 表示蓝光波段(450 nm)反射率, REDG 表示红边波段(730 nm)反射率, NIR 表示近红外光波段(840 nm)反射率。* 表示在 0.05 水平显著相关, ** 表示在 0.01 水平极显著相关。

图 2 单波段反射率与叶片水势 (Ψ_{pre}) 的相关性

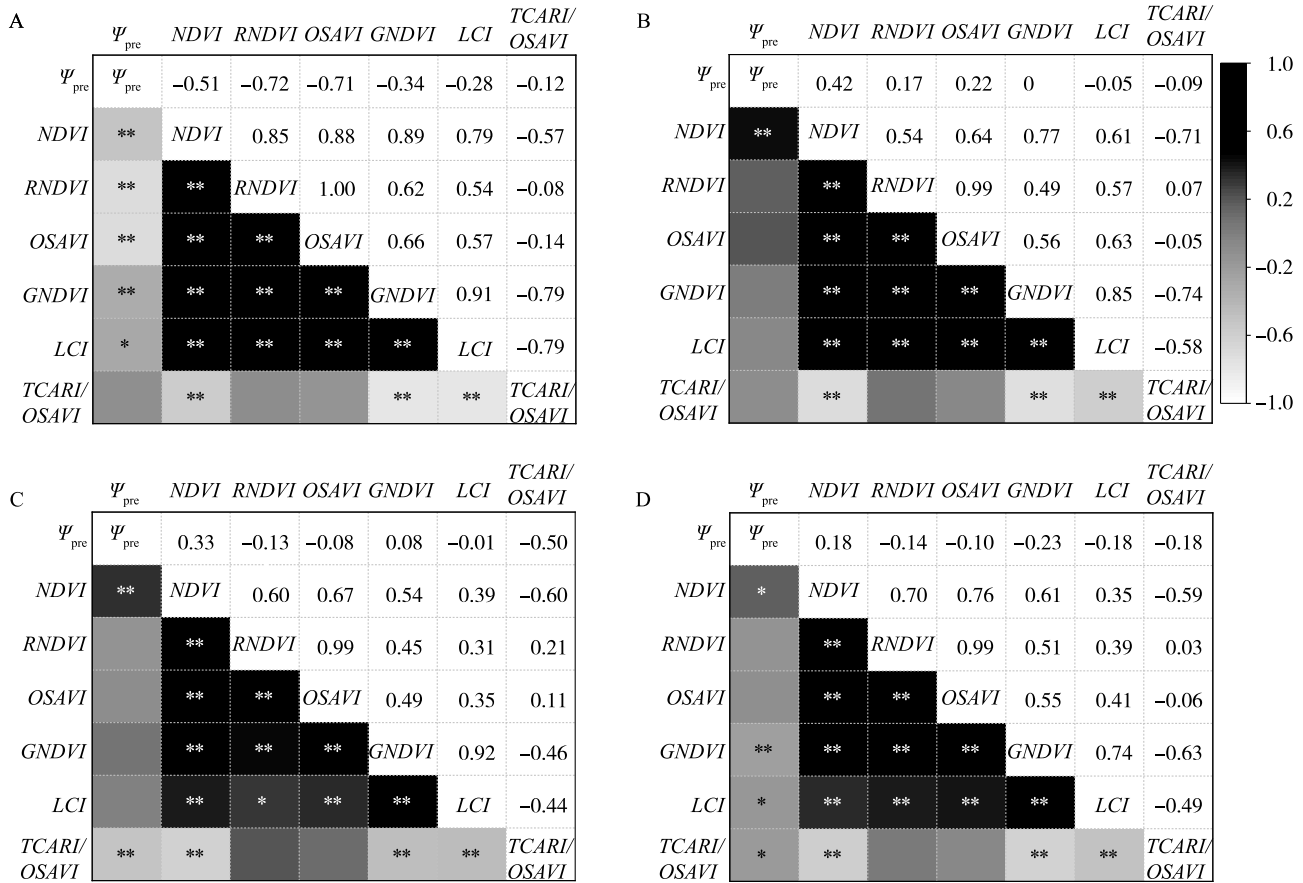
Fig.2 Correlation between single-band reflectance and leaf water potential (Ψ_{pre})

2.4 光谱数据与 Ψ_{pre} 回归模型的构建

由表 2 可以看出,在花后20~40 d,一元线性模型中以 NIR 为变量的模型拟合效果最佳, $R^2 = 0.560$, $RMSE = 0.038$ 。在多元线性回归模型中,以 GREEN、NIR、OSAVI 及 RGRI 为变量构建的模型 R^2 为 0.622。与一元线性模型的最高 R^2 相比,多元线性模型的最高 R^2 增加了 11.07%, 对应的 $RMSE$ 降低了 7.89%。在花后41~60 d,一元线性模型中以 NGRDI 为单变量的模型表现最佳, $R^2 = 0.448$, $RMSE = 0.099$ 。对于多元线性模型而言,引入 ρ 、 β 、 $NDVI$ 、 $RGRI$ 、 NIR 5 个变量后,模型决定系数提高了 51.79% ($R^2 = 0.680$, $RMSE = 0.075$)。在花后 61~

80 d, $TCARI/OSAVI$ 一元线性模型的精度最高, R^2 为 0.641, $RMSE$ 为 0.045。在多元线性模型中,整合 NIR、RED、 $NDVI$ 、 ρ 4 个变量的多元线性模型的表现最优, R^2 为 0.713, $RMSE$ 为 0.040, 其中最高 R^2 较一元线性模型提高了 11.23%, 对应的 $RMSE$ 较一元线性模型降低了 11.11%。

利用验证集数据评估多元线性回归模型的性能。由图 5 可以看出,该模型在不同生育期对 Ψ_{pre} 的预测结果具有良好一致性。尤其在花后 41~60 d,模型的拟合效果最佳, R^2 为 0.680 26, 说明该模型在黎明前叶片水势的预测方面表现出较高的准确性和稳定性。



A: 花后20~40 d 的多光谱指数与 Ψ_{pre} 的相关性; B: 花后41~60 d 的多光谱指数与 Ψ_{pre} 的相关性; C: 花后61~80 d 的多光谱指数与 Ψ_{pre} 的相关性; D: 花后20~80 d 的多光谱指数与 Ψ_{pre} 的相关性。NDVI、RNDVI、OSAVI、GNDVI、LCI、TCARI/OSAVI 见表 1。* 表示在 0.05 水平显著相关, ** 表示在 0.01 水平极显著相关。

图 3 多光谱指数与叶片水势 (Ψ_{pre}) 的相关性

Fig.3 Correlation between multispectral indices and leaf water potential (Ψ_{pre})

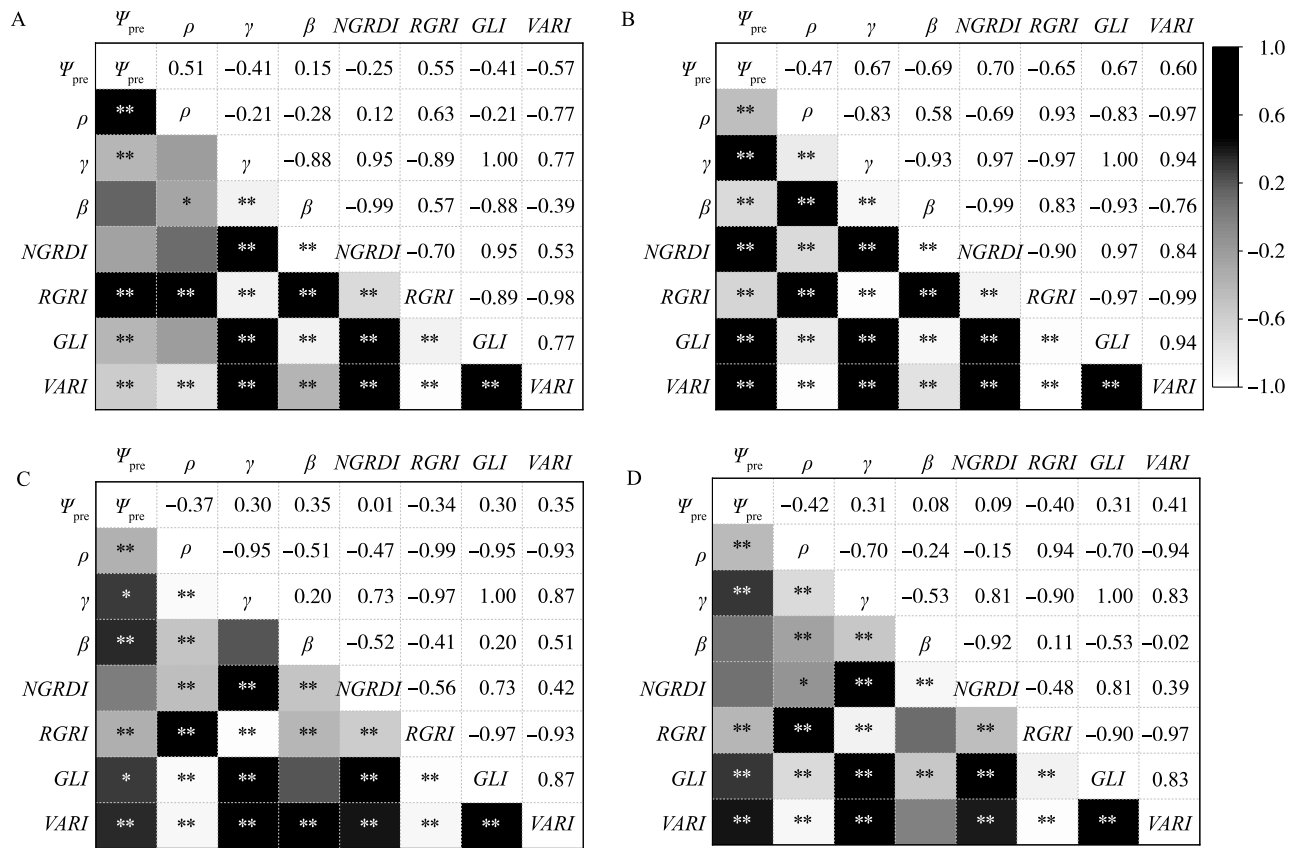
2.5 光谱数据与 Ψ_{pre} 的偏最小二乘回归 (PLSR) 模型的构建

如表 2、表 3 所示,相较于多元线性回归模型,基于偏最小二乘回归 (PLSR) 建立的 Ψ_{pre} 反演模型在预测精度、稳定性方面表现出显著优势。具体表现为:在花后 20~40 d,该模型的 R^2 较多元线性回归模型的最高 R^2 提升了 0.073,相应 $RMSE$ 降低了 0.004。在花后 41~60 d,PLSR 模型的性能则进一步优化, R^2 值较多元线性回归模型的最高 R^2 增加了 0.097,相应 $RMSE$ 下降了 0.013;在花后 61~80 d, R^2 较多元线性回归模型的最高 R^2 提升了 0.050,相应 $RMSE$ 较多元线性回归模型降低了 0.004。整体而言,PLSR 模型在各生育期的 R^2 均高于多元线性回归模型。尤其在花后 41~60 d,其预测能力最强。基于 PLSR 模型的 Ψ_{pre} 预测值与实测值的关系见图

6,可见花后 41~60 d 的模型对 Ψ_{pre} 的预测效果最优,表明该建模方法具备更优的泛化性能和实用价值。

3 讨论

水分是植物进行光合作用、营养运输的基本要素,植物叶片的水分状况会直接影响植物的生长过程。常见的水势测量指标主要为黎明前叶片水势、正午叶片水势、茎水势等。正午叶片水势易受蒸腾、气孔导度动态调控,波动明显。无人机技术在植物生理参数的监测中主要依赖冠层尺度的外部表型信号,难以直接或可靠检测茎水势。黎明前叶片水势则是植物夜间蒸腾停止后水分平衡的指标,能够直接反映根系可利用的土壤水分。本研究运用无人机搭载的多光谱传感设备,在葡萄树的 3 个生育阶段



A: 花后20~40 d的可见光谱指数与 Ψ_{pre} 的相关性; B: 花后41~60 d的可见光谱指数与 Ψ_{pre} 的相关性; C: 花后61~80 d的可见光谱指数与 Ψ_{pre} 的相关性; D: 花后20~80 d的可见光谱指数与 Ψ_{pre} 的相关性。 $\gamma, \rho, \beta, NGRDI, RGRI, GLI, VARI$ 见表1。* 表示在 0.05 水平显著相关, ** 表示在 0.01 水平极显著相关。

图 4 可见光谱指数与叶片水势 (Ψ_{pre}) 的相关性

Fig.4 Correlation between visible light indices and leaf water potential (Ψ_{pre})

表 2 基于线性回归模型的叶片水势 (Ψ_{pre}) 回归结果


Table 2 Regression results of leaf water potential (Ψ_{pre}) based on linear regression model

花后天数(d)	模型	变量	R^2	RMSE	显著性
20~40	1	NIR	0.560	0.038	0
	2	GREEN	0.085	0.055	0.029
	3	NDVI	0.274	0.049	0
	4	RNDVI	0.502	0.040	0
	5	OSAVI	0.490	0.041	0
	6	REDG	0.400	0.044	0
	7	ρ	0.308	0.047	0
	8	γ	0.082	0.055	0.031
	9	RGRI	0.267	0.049	0
	10	GLI	0.082	0.055	0.031
	11	VARI	0.326	0.048	0
	12	GREEN、LCI、 γ 、NIR、OSAVI、RGRI	0.615	0.035	0
	13	GREEN、LCI、NIR、OSAVI、RGRI	0.620	0.035	0
	14	GREEN、NIR、OSAVI、RGRI	0.622	0.035	0

续表2 Continued2

花后天数(d)	模型	变量	R^2	RMSE	显著性
41~60	1	BLUE	0.253	0.115	0
	2	NDVI	0.174	0.121	0.003
	3	ρ	0.163	0.121	0.003
	4	γ	0.398	0.103	0
	5	β	0.437	0.100	0
	6	NGRDI	0.448	0.099	0
	7	RGRI	0.357	0.106	0
	8	GLI	0.398	0.103	0
	9	VARI	0.302	0.111	0
	10	BLUE、 ρ 、 β 、NDVI、RGRI、NIR	0.679	0.075	0
	11	ρ 、 β 、NDVI、RGRI、NIR	0.680	0.075	0
	12	ρ 、 β 、RGRI、NIR	0.672	0.076	0
61~80	1	REDG	0.303	0.063	0
	2	NIR	0.206	0.067	0.001
	3	RED	0.573	0.049	0
	4	BLUE	0.502	0.053	0
	5	GREEN	0.452	0.056	0
	6	NDVI	0.016	0.069	0.004
	7	TCARI/OSAVI	0.641	0.045	0
	8	ρ	0.117	0.071	0.012
	9	γ	0.049	0.073	0.077
	10	β	0.150	0.069	0.005
	11	RGRI	0.082	0.072	0.032
	12	VARI	0.090	0.072	0.026
	13	NIR、 β 、TCARI/OSAVI、RED、NDVI、 ρ	0.708	0.040	0
	14	NIR、 β 、RED、NDVI、 ρ	0.709	0.040	0
	15	NIR、RED、NDVI、 ρ	0.713	0.040	0

LCI、 γ 、NIR、OSAVI、RVNDI、RGRI、 β 、GLI、NDVI、 ρ 、VARI、NGRDI、TCARI/OSAVI 见表 1。GREEN: 绿光波段(560 nm)反射率; REDG: 红边波段(730 nm)反射率; RED: 红光波段(650 nm)反射率; BLUE: 蓝光波段(450 nm)反射率; R^2 : 决定系数; RMSE: 均方根误差。



A: 花后20~40 d 基于多元线性回归的 Ψ_{pre} 预测值与实测值的关系; B: 花后41~60 d 基于多元线性回归的 Ψ_{pre} 预测值与实测值的关系; C: 花后61~80 d 基于多元线性回归的 Ψ_{pre} 预测值与实测值的关系。 R^2 : 决定系数; RMSE: 均方根误差; Y: 黎明前叶片水势预测值; x: 黎明前叶片水势实测值。

图5 基于多元线性回归的叶片水势 (Ψ_{pre}) 预测值与实测值的关系


Fig.5 The relationship between predicted and measured values of leaf water potential (Ψ_{pre}) based on multiple linear regression

表 3 基于偏最小二乘回归 (PLSR) 模型的叶片水势 (Ψ_{pre}) 反演结果Table 3 Leaf water potential (Ψ_{pre}) inversion results based on partial least squares regression (PLSR) model

花后天数 (d)	建模集		验证集	
	R^2	RMSE	R^2	RMSE
20~40	0.695	0.031	0.655	0.055
41~60	0.777	0.062	0.773	0.048
61~80	0.763	0.036	0.738	0.051

R^2 : 决定系数; RMSE: 均方根误差。

对黎明前叶片水势进行动态监测,构建了基于冠层光谱特征的水分状态评估体系。Tuccio 等^[30]研究认为,黎明前叶片水势比正午叶片水势更能反映葡萄藤的水分状况。由于黎明前叶片水势能够充分展示植株经过夜间水分恢复后的稳定水势,能够有效消除蒸腾引起的日变化干扰^[31],因此,本研究采用黎明前叶片水势反映植株水分状况。选择在正午采集冠层多光谱数据是由于黎明采集多光谱数据时光线不足,同时叶片表面结露等导致反射率发生变化,



A: 花后20~40 d 基于 PLSR 模型 Ψ_{pre} 的预测值与实测值的关系; B: 花后41~60 d 基于 PLSR 模型 Ψ_{pre} 的预测值与实测值的关系; C: 花后61~80 d 基于 PLSR 模型 Ψ_{pre} 的预测值与实测值的关系。 R^2 : 决定系数; RMSE: 均方根误差; Y: 黎明前叶片水势预测值; x: 黎明前叶片水势实测值。

图 6 基于偏最小二乘回归 (PLSR) 模型叶片水势 (Ψ_{pre}) 预测值与实测值间的关系

Fig.6 The relationship between predicted and measured values of leaf water potential (Ψ_{pre}) based on partial least squares regression (PLSR) model

此时的光谱信息无法反映植株的真实生理状态。当无人机传感器观测方向与太阳直射方向存在偏差时,无人机影像中会出现冠层阴影,此类阴影会降低光谱的信号强度,导致反演模型精度下降。然而,正午获取的冠层光谱数据能最大程度地降低冠层阴影干扰,提升光谱信噪比,最能反映植株的实际状态^[32]。因此,基于正午冠层光谱预测黎明前叶片水势具有科学可行性。李美炫等^[33]研究证实,引入归一化冠层阴影指数可有效消除冠层阴影干扰,显著提升无人机多光谱影像的氮素反演精度。

以相关系数较高的植被指数组合作为输入特征,采用多元机器学习算法进行建模,能够显著提升模型的预测精度^[34]。本研究利用相关性分析筛选与赤霞珠葡萄叶片水势相关性较高的植被指数,筛选出的植被指数在各生育期差异明显,可能是由于

葡萄植株的生长状态、叶面积及叶片冠层覆盖度在不同生育期间存在差异。这与 Xu 等^[35]针对水稻的研究结果一致。此外,本研究结果显示,NDVI 在葡萄各生育期与黎明前叶片水势均呈现稳定的相关性,可能由于 NDVI 作为表征植被生长状况和覆盖程度的重要指标,能够有效反映植被在红光波段与近红外波段反射率的差异,是估算植被丰度、长势的主要手段^[36-37]。2 种波段与叶绿素含量、生理状态相关^[38],因此在葡萄不同生育阶段都与水势有较稳定的相关性。

本研究将 PLSR 算法应用于黎明前叶片水势反演建模中,探索了用 PLSR 算法构建黎明前叶片水势反演模型的可行性。结果表明,用 PLSR 算法构建的模型验证集的 R^2 为 0.655~0.773, RMSE 为 0.048~0.055,而多元线性回归模型验证集的 R^2 在

为0.605 60~0.680 26, $RMSE$ 为0.017 0~0.073 5。PLSR算法有效提高了反演模型的精度,与多元线性回归模型相比, R^2 提高,可能由于PLSR能够进一步融合多元线性回归分析、典型相关性分析和主成分分析的核心优势,缓解自变量之间的共线性,从而提高模型的预测能力与泛化能力^[39]。Zheng等^[40]研究发现,融合多个变量的模型可以显著提升预测精度。Feng等^[41]通过多光谱植被指数预测冬小麦产量发现,PLSR模型优于人工神经网络模型(ANN),在产量预测中的表现更稳定,精度更高。在PLSR模型中,葡萄不同生长阶段的预测精度存在差异,叶片水势在花后41~60 d(膨大期)的预测效果最佳,在花后61~80 d的预测效果略有降低,这与Peng等^[17]的研究结果一致,在果实膨大阶段后,植株的叶面积趋于稳定。在叶面积有较大动态变化的生长阶段,树冠特征与水分流动之间存在密切关系。在花后61~80 d,PLSR模型的预测效果有所下降,可能因为在转色期、成熟期,叶片逐渐变黄,用于蒸腾作用的有效叶面积开始减少。在生长后期,作物水分动力学主要集中在果实中,导致冠层结构与其他生长阶段不同^[41],使得预测精度略有降低。

4 结论

本试验利用单波段反射率、多光谱指数和可见光谱指数预测葡萄黎明前叶片水势。结果显示,PLSR模型的预测精度较一元线性回归模型、多元线性回归模型呈现显著优势。在花后41~60 d,多元线性模型($R^2=0.680$)与PLSR模型($R^2=0.777$)的表现较优。PLSR模型通过融合多光谱特征与非线性关系,显著提升了葡萄叶片水势的预测精度。

参考文献:

- [1] 耿康奇. 水分胁迫下酿酒葡萄果实糖分转运机理研究[D]. 银川:宁夏大学,2024.
- [2] 詹振楠. 水分亏缺对酿酒葡萄果实苹果酸代谢的调控机理研究[D]. 银川:宁夏大学,2024.
- [3] BALBOA K, BALLESTEROS G I, MOLINA-MONTENEGRO M A. Integration of physiological and molecular traits would help to improve the insights of drought resistance in highbush blueberry cultivars[J]. *Plants*, 2020, 9(11):1457.
- [4] 王 军, 孟祥增. 热电偶水势测定仪[J]. *传感器技术*, 1997(5):41-42.
- [5] 柏新富, 卜庆梅, 谭永芹, 等. 植物4种水势测定方法的比较及可靠性分析[J]. *林业科学*, 2012, 48(12):128-133.
- [6] 韦善君, 农钧琇, 马廷娟, 等. 小液流法测定植物组织水势的优化[J]. *植物生理学报*, 2014, 50(12):1899-1902.
- [7] 齐 浩, 孙海芳, 吕亮杰, 等. 基于无人机多光谱信息与纹理特征融合的小麦叶面积指数估测[J]. *农业机械学报*, 2025, 56(3):334-344.
- [8] 王佳丽. 基于无人机多光谱的烟叶烟碱含量预测[D]. 北京:中国农业科学院,2024.
- [9] 余兴娇, 樊 凯, 霍雪飞, 等. 基于无人机影像多特征融合的夏玉米LAI动态估计[J]. *农业工程学报*, 2025, 41(4):124-134.
- [10] DUAN B, LIU Y T, GONG Y, et al. Remote estimation of rice LAI based on Fourier spectrum texture from UAV image[J]. *Plant Methods*, 2019, 15:124.
- [11] ZHU W X, SUN Z G, YANG T, et al. Estimating leaf chlorophyll content of crops via optimal unmanned aerial vehicle hyperspectral data at multi-scales[J]. *Computers and Electronics in Agriculture*, 2020, 178:105786.
- [12] SHU M Y, SHEN M Y, DONG Q Z, et al. Estimating the maize above-ground biomass by constructing the tridimensional concept model based on UAV-based digital and multi-spectral images[J]. *Field Crops Research*, 2022, 282:108491.
- [13] LIU Q S, CHEN F, CUI N B, et al. Inversion of *Citrus* SPAD value and leaf water content by combining feature selection and ensemble learning algorithm using UAV remote sensing images[J]. *Agricultural Water Management*, 2025, 314:109524.
- [14] 王笑雪. 基于无人机多光谱影像预测混播草地牧草产量和品质[D]. 兰州:兰州大学,2024.
- [15] ZHANG Y, HAN W T, ZHANG H H, et al. Evaluating soil moisture content under maize coverage using UAV multimodal data by machine learning algorithms[J]. *Journal of Hydrology*, 2023, 617:129086.
- [16] 刘易雪. 基于无人机的酿酒葡萄卷叶病检测方法研究[D]. 杨凌:西北农林科技大学, 2024.
- [17] PENG X L, HU X T, CHEN D Y, et al. Prediction of grape sap flow in a greenhouse based on random forest and partial least squares models[J]. *Water*, 2021, 13(21):3078.
- [18] LYU H Y, GRAFTON M, RAMLAN T, et al. Using remote and proximal sensing data and vine vigor parameters for non-destructive and rapid prediction of grape quality[J]. *Remote Sensing*, 2023, 15(22):5412.
- [19] 薛晓斌, 李栋梅, 张艳霞, 等. 水分胁迫对马瑟兰葡萄果实品质及花色苷合成代谢的影响[J]. *果树学报*, 2023, 40(5):919-931.
- [20] 刘鸿阳, 孔德国, 罗华平, 等. 基于多光谱图像角度融合测定库尔勒香梨理化指标[J]. *光谱学与光谱分析*, 2024, 44(3):649-655.
- [21] 落莉莉. 基于地面和低空无人机的玉米生理生化参数遥感研究[D]. 杨凌:西北农林科技大学, 2022.
- [22] ROUSE J, HAAS R H, DEERING D, et al. Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation[R]. *Greenbelt*:NASA, 1974.

- [23] RONDEAUX G, STEVEN M, BARET F. Optimization of soil-adjusted vegetation indices[J]. *Remote Sensing of Environment*, 1996, 55(2):95-107.
- [24] WANG F M, HUANG J F, TANG Y L, et al. New vegetation index and its application in estimating leaf area index of rice[J]. *Rice Science*, 2007, 14(3):195-203.
- [25] DAUGHTRY C S T, WALTHALL C L, KIM M S, et al. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance[J]. *Remote Sensing of Environment*, 2000, 74(2):229-239.
- [26] 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.
- [27] SABERIOON M M, AMIN M S M, ANUAR A R, et al. Assessment of rice leaf chlorophyll content using visible bands at different growth stages at both the leaf and canopy scale[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2014, 32:35-45.
- [28] GITELSON A A, KAUFMAN Y J, STARK R, et al. Novel algorithms for remote estimation of vegetation fraction[J]. *Remote Sensing of Environment*, 2002, 80(1):76-87.
- [29] LOUHAICHI M, BORMAN M M, JOHNSON D E. Spatially located platform and aerial photography for documentation of grazing impacts on wheat[J]. *Geocarto International*, 2001, 16(1):65-70.
- [30] TUCCIO L, PICCOLO E L, BATTELLI R, et al. Physiological indicators to assess water status in potted grapevine (*Vitis vinifera* L.)[J]. *Scientia Horticulturae*, 2019, 255:8-13.
- [31] MACIEL D A, SILVA V A, ALVES H M R, et al. Leaf water potential of coffee estimated by landsat-8 images[J]. *PLoS One*, 2020, 15(3):e0230013.
- [32] 张 洁. 基于无人机多光谱遥感的苹果树水分估测与空间反演[D]. 泰安:山东农业大学, 2022.
- [33] 李美炫, 朱西存, 白雪源, 等. 基于无人机影像阴影去除的苹果树冠层氮素含量遥感反演[J]. *中国农业科学*, 2021, 54(10):2084-2094.
- [34] 马彦鹏, 边明博, 樊意广, 等. 基于无人机 RGB 影像的马铃薯植株钾含量估算[J]. *农业机械学报*, 2023, 54(7):196-203.
- [35] XU T Y, WANG F M, SHI Z, et al. Dynamic estimation of rice aboveground biomass based on spectral and spatial information extracted from hyperspectral remote sensing images at different combinations of growth stages[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2023, 202:169-183.
- [36] JIANG Z Y, HUETE A R, CHEN J, et al. Analysis of NDVI and scaled difference vegetation index retrievals of vegetation fraction[J]. *Remote Sensing of Environment*, 2006, 101(3):366-378.
- [37] 徐 灿, 胡笑涛, 陈滇豫, 等. 基于无人机多光谱遥感估算西北半湿润区葡萄基础作物系数研究[J]. *干旱地区农业研究*, 2023, 41(4):106-117.
- [38] CLEVERS J G P W, KOOISTRA L, SCHAEPMAN M E. Estimating canopy water content using hyperspectral remote sensing data[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2010, 12(2):119-125.
- [39] 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.
- [40] ZHENG H B, MA J F, ZHOU M, et al. Enhancing the nitrogen signals of rice canopies across critical growth stages through the integration of textural and spectral information from unmanned aerial vehicle (UAV) multispectral imagery[J]. *Remote Sensing*, 2020, 12(6):957.
- [41] FENG H K, TAO H L, FAN Y G, et al. Comparison of winter wheat yield estimation based on near-surface hyperspectral and UAV hyperspectral remote sensing data[J]. *Remote Sensing*, 2022, 14(17):4158.

(责任编辑:徐 艳)