

doi:10.6041/j.issn.1000-1298.2026.20.027

基于无人机多光谱信息与器官空间分布特征融合的油菜地上生物量估测

秦丁新 肖晓璐 黄方园 蒋展 段博 马霓

(中国农业科学院油料作物研究所, 武汉 430062)

摘要: 地上生物量 (Above-ground biomass, AGB) 是作物长势评估和产量预测的重要指标之一。为构建基于无人机多光谱遥感的油菜 AGB 估测模型, 本研究利用无人机搭载 6 波段多光谱传感器获取油菜苗期、蕾薹期、花期和角果期遥感影像, 通过影像傅里叶变换提取频谱特征, 研究不同生育期频谱特征和地上生物量之间的相关性, 提取表征叶、花、角果等器官空间分布的频谱特征分量, 并与光谱特征融合。然后, 利用反向传播 (Back propagation, BP) 神经网络、随机森林 (Random forest, RF) 和梯度提升算法 (eXtreme gradient boosting, XGBoost) 3 种机器学习算法构建不同生育期 AGB 估测模型, 比较不同模型输入变量下 AGB 估测精度。结果表明: 基于光谱和器官空间分布的融合特征构建 AGB 估测模型, 可以提高 AGB 估测精度; 3 种机器学习算法中, BP 更具稳定性, 对融合特征有较好的 AGB 拟合效果; 以 6 个波段反射率和频谱特征 (叶期、角果期选取低频分量, 花期选取高频分量, 全生育期选取低频和高频加权重构分量) 作为输入变量, 结合 BP 算法能准确估测油菜不同生育期 AGB, 叶期测试集决定系数 (R^2) 为 0.87, 均方根误差 (RMSE) 为 178.44 g/m²; 花期测试集 R^2 为 0.66, RMSE 为 357.76 g/m²; 角果期测试集 R^2 为 0.87, RMSE 为 258.71 g/m²; 全生育期测试集 R^2 为 0.79, RMSE 为 388.90 g/m²。研究结果可为精准、高效获取区域尺度油菜 AGB 提供技术支撑。

关键词: 油菜; 地上生物量; 无人机多光谱; 傅里叶频谱; 器官空间分布; 机器学习

中图分类号: S127 **文献标识码:** A **文章编号:** 1000-1298 (2026)20-0308-10

OSID:



Remote Estimation of Rapeseed Above-ground Biomass by Fusion of UAV Multi-spectral Information and Spatial Distribution Feature of Organs

Qin Dingxin Xiao Xiaolu Huang Fangyuan Jiang Zhan Duan Bo Ma Ni
(Oil Crops Research Institute, Chinese Academy of Agricultural Sciences, Wuhan 430062, China)

Abstract: Above-ground biomass (AGB) is one of the most important indicators for crop growth assessment and yield prediction. To establish the rapeseed AGB estimation model based on UAV multispectral data, a UAV equipped with a 6-band multispectral sensor was utilized to acquire remote sensing images during the seedling, elongation, flowering, and pod stages of rapeseed. The Fourier transform was conducted to UAV multispectral images, and frequency-domain features were extracted based on Fourier spectrum. Then, the correlation between the frequency-domain features and AGB was analyzed at different growth stages, and the frequency components representing the spatial distribution of organs (leaves, flowers, and pods) were extracted and fused with spectral features. Three machine learning algorithms of back propagation (BP) neural network, random forest (RF), and eXtreme gradient boosting (XGBoost) were employed to establish AGB estimation models for different growth stages and the accuracy of AGB estimation with different input variables was compared. The results indicated that the fusion of spectral features and organ spatial distribution features can improve the accuracy of AGB estimation model. Among the three machine learning algorithms, BP demonstrated more stable and better AGB fitting performance with the fused features. Using the reflectance of the six bands and specific frequency-domain features (low-frequency components for the leaf and pod stages; high-

收稿日期: 2025-09-30 修回日期: 2025-11-24

基金项目: 国家重点研发计划项目 (2021YFD1600503) 和湖北省自然科学基金项目 (2025AFB425)

作者简介: 秦丁新 (2001—), 女, 博士生, 主要从事油菜智慧农业研究, E-mail: 13001587069@163.com

通信作者: 段博 (1992—), 男, 助理研究员, 博士, 主要从事油菜智慧农业研究, E-mail: duanbo@caas.cn

frequency components for the flowering stage; weighted reconstruction of low and high frequency components for the entire growth stage) as input variables, BP achieved accurate estimation of rapeseed AGB across different growth stages. The test set results were as follows, coefficient of determination (R^2) of leaf stage was 0.87 with root mean square error (RMSE) of 178.44 g/m², R^2 of flowering stage was 0.66 with RMSE of 357.76 g/m², R^2 of pod stage was 0.87 with RMSE of 258.71 g/m² and R^2 of entire growth period was 0.79 with RMSE of 388.90 g/m². The results can provide technical support for the precise and efficient acquisition of rapeseed AGB at a regional scale.

Key words: rapeseed; above-ground biomass; UAV multi-spectral; Fourier spectrum; spatial distribution feature of organs; machine learning

0 引言

油菜是我国重要的油料作物,常年种植面积超 7×10^6 hm²,是国产食用植物油的主要来源^[1]。地上生物量(Above-ground biomass, AGB)不仅可以反映作物生长状况,还是估测产量、辅助田间栽培决策的重要指标^[2-4]。快速、准确获取油菜 AGB,对于精准监测油菜长势动态及优化栽培管理具有重要意义。但传统 AGB 获取方式主要依靠田间人工采样测量,不但耗时耗力,且样本采集受人为主观因素影响,精度较低。无人机遥感技术作为一种高通量的非接触测量技术,为作物 AGB 高效、精确获取提供了新的有效途径^[5-6]。无人机遥感以无人机为数据获取平台,可搭载可见光、多光谱、高光谱等不同类型传感器。其中,高光谱传感器可获取丰富的光谱信息,但价格相对昂贵,应用成本较高。可见光传感器成本低,但仅包含红、绿、蓝 3 个波段,可反映的作物信息有限。相比而言,多光谱传感器可根据用户需求自主配置多个光谱波段,且价格相对较低,在区域尺度的作物表型信息获取方面具有显著优势。

光谱特征,尤其是植被指数(Vegetation index, VI),被广泛用于构建基于无人机多光谱影像的作物表型估测模型^[7-8]。但有研究表明 VI 在高植被覆盖度下易出现“饱和”现象,造成高种植密度条件下作物表型获取精度降低^[9-11]。同时,多光谱影像的光谱波段有限,当作物冠层结构变化较大时,难以完整表征冠层形态的动态变化,造成作物全生育期表型估测精度较低^[12-13]。在此基础上,有研究者挖掘遥感影像纹理等空间特征,并通过光谱和空间特征融合,提高了水稻产量、油菜叶面积指数和地上生物量的遥感监测精度^[14-16]。但前期研究多从影像空间域分析角度出发,通过灰度共生矩阵、灰度级行程计算、分形或随机模型等方法统计像元邻域的灰度特性^[17],未探讨影像空间特征和作物器官、冠层等生长结构之间的关系,导致模型复杂度增加且缺乏机理支撑,泛化能力较差^[18-19]。遥感影像空间信息不仅依靠空间域中像元灰度变化程度表现,还可

通过频域中频谱能量描述,频谱能量中涵盖低频和 高频信息^[20],在表征目标形态、结构等特征上具有显著优势^[21-22]。已有研究表明,通过光谱和频域特征融合可以提高作物表型的遥感估测精度^[23]。油菜全生育期冠层结构变化显著,苗期至薹期主要表现为叶片扩张;花期亮黄色花朵开始显现,并逐渐充满冠层;角果期角果开始伸长、膨胀,并逐渐取代花朵,成为冠层的主要结构。除冠层颜色变化外,结构变化也是油菜生物学特性之一,频谱能量中包含的低频和高频分量,可用于描述影像局部细节信息和整体轮廓信息,有助于表征油菜冠层结构变化。因此,需探究遥感影像频域特征和油菜生长形态之间的关系,研究光谱-空间特征融合方法,提高油菜表型的遥感估测精度。

综上,本研究设置油菜田间栽培试验,利用无人机搭载多光谱传感器获取苗期、薹期、花期和角果期遥感影像。通过对影像傅里叶变换提取频域特征,研究不同生育期频域特征和地上生物量之间的相关性,提取表征叶、花、角果等器官空间分布的频域特征分量,并与光谱特征融合,利用机器学习算法构建不同生育期 AGB 估测模型,对比模型精度,筛选模型最优输入变量及建模方法。以期从频域角度刻画油菜器官(叶、花、角果)空间分布规律,建立光谱-频域特征融合建模框架,解决传统光谱指标在高覆盖度与花叶混合阶段的精度瓶颈,提出具有可推广性的多生育期 AGB 估测策略,为精准高效获取油菜 AGB 提供技术支撑。

1 材料与方法

1.1 研究区域

研究区位于湖北省荆州市(30°14'39"N, 112°21'14"E)和襄阳市(31°53'32"N, 112°1'35"E)的中国农业科学院油料作物研究所油菜试验基地(图 1)。试验对象为油菜,设置品种、播期、密度等不同栽培处理,每个处理 3 次重复。试验包含 2 个油菜品种:中油杂 19 和大地 199,3 个播期:9 月 30 日、10 月 15 日和 10 月 30 日,3 个种植密度:15、45、

75 株/m²。试验于 2021 年秋季播种,2022 年 5 月收获,小区面积为 2 m×10 m。除试验处理外,各小区施肥、除草、一促四防等田间管理措施保持一致,底肥施用 600 kg/hm² 油菜专用配方肥(N-P₂O₅-K₂O, 含 B),5 叶期追施 60 kg/hm² 尿素(含 N 46%)。




图 1 研究区域
Fig. 1 Study area

1.2 地上生物量数据获取

地上生物量通过田间取样,干燥、称量测定。在每个试验小区随机选取 5 株长势均匀的油菜植株,干燥箱干燥后,用天平称量地上部干质量,取 5 株平均值作为单株地上生物量(AGB_{plant}),根据小区种植密度计算该小区单位面积地上生物量,计算式为

$$AGB = AGB_{plant} d \tag{1}$$

式中 d ——种植密度,株/m²

在苗期、蕾薹期、花期和角果期等关键生育期进行数据采集,根据油菜冠层结构变化,苗期和蕾薹期统称为叶期。综合两地试验,叶期采集 162 个 AGB 数据,花期 126 个 AGB 数据,角果期 54 个 AGB 数据,如表 1 所示。

表 1 油菜各生育期 AGB 实测值统计				
Tab.1 Statistical descriptions of field measured rapeseed AGB at different growth stages				
生育期	样本数	AGB/(g·m ⁻²)		
		最小值	最大值	平均值
叶期	162	780.01	33 340.34	6 657.64
花期	126	1 426.22	28 813.09	9 880.24
角果期	54	2 344.50	23 877.93	7 917.54
全生育期	342	780.01	33 340.34	8 043.84

1.3 无人机影像采集和处理

田间取样当天,同步采集试验区域无人机遥感影像,数据获取采用 MS600 Pro 型 6 波段多光谱传感器,由 6 个独立的微型数码相机组成,每台相机中心波长分别为 450、555、660、720、750、840 nm,包含可见光 and 红边、近红外等植被敏感波段。无人机起飞前,在距离地面高度 1 m 拍摄辐射定标板正射影像,用于辐射校正。航拍时间为 10:00—14:00,飞

行高度为 60 m,飞行速度为 5 m/s,航向重叠率和旁向重叠率分别设置为 80% 和 75%,航拍时天气晴朗、无风。无人机影像采集后,利用传感器自带软件 Ysense Map 完成影像对齐、配准、辐射校正和拼接等操作,最终生成试验区域正射影像,空间分辨率为 4.33 cm。然后,利用 ENVI 软件对每个小区划分感兴趣区域,并利用 Matlab 软件计算各小区植被指数和傅里叶频谱特征。技术路线如图 2 所示。




图 2 技术路线
Fig. 2 Technical approach

1.4 研究方法

1.4.1 植被指数提取

植被指数是通过波段运算表征植物生长状况的指标^[8],常用于遥感反演叶面积指数、地上生物量、叶绿素含量和氮含量等作物长势参数^[24-26]。在前人研究基础上,同时结合 MS600 Pro 型多光谱传感器的波段配置(蓝、绿、红、红边、近红外波段),计算红边叶绿素指数(CI_{rededge})^[27]、绿波段叶绿素指数(CI_{green})^[27]、归一化差分植被指数(NDVI)^[28]、红边归一化差分植被指数(NDRE)^[29]、增强型植被指数(EVI)^[30]和双波段增强型植被指数(EVI2)^[31]6 种与作物长势密切相关的植被指数。基于试验区域正射影像,根据小区边界裁剪感兴趣区域,再划分为统一尺寸多光谱子图(384 像素×64 像素)。利用 Matlab 对子图进行波段运算,计算植被指数,子图内所有像素平均值作为小区植被指数。

1.4.2 图像频域特征提取

基于小区边界裁剪的多光谱子图,通过傅里叶变换提取图像频域特征。首先,将多光谱子图转换为灰度图,并对像素值进行归一化处理,以确保各批

次图像具有可比性。然后,对每幅灰度子图执行二维傅里叶变换并中心化后,在频域平面以归一化径向频率进行同心环分桶。设频域坐标为 (u,v) ,图像宽、高为 W,H 。定义轴向归一化频率 $f_u = u/W$, $f_v = v/H$,则归一化径向频率为

$$\rho(u,v) = \sqrt{f_u^2 + f_v^2} \in [0, \rho_{\max}] \quad (2)$$

其中
$$\rho_{\max} = \frac{\sqrt{2}}{2}$$

将 $\tilde{\rho} = \rho/\rho_{\max}$ 线性归一化到 $[0,1]$,并将 $[0,1]$ 等宽划分为 K 个环,第 k 个环对应区间 $\tilde{\rho} \in [(k-1)/K, k/K]$ ($k=1,2,\dots,K$)。第 k 环对数能量特征定义为

$$E_k = \frac{1}{|\mathcal{B}_k|} \sum_{(u,v) \in \mathcal{B}_k} \lg(1 + |F_{\text{shift}}(u,v)|) \quad (3)$$

式中 $\mathcal{B}_k$ ——第 k 环内频点集合
 $|\mathcal{B}_k|$ ——基数

其中 $\lg(1 + |F_{\text{shift}}(u,v)|)$ 用于压缩动态范围并减小极极端频点对统计量的影响。将 $K=20$ 作为基线设置。

1.4.3 模型构建

利用 Matlab 进行模型构建及精度验证。本研究数据样本量相对较小、特征参数多,选用 BP 神经网络、随机森林 (RF) 和梯度提升算法 (XGBoost) 3 种各具差异的机器学习算法进行对比分析,并选取表现最优的算法开展后续研究。

为探究光谱特征和器官空间分布特征融合对 AGB 的估测效果,设置 4 类模型输入变量,分别为反射率、植被指数、反射率 + 频谱特征和植被指数 + 频谱特征。不同类型的模型输入变量具有不同估测精度。试验设计包含品种、密度、播期等不同处理,且 2 个试验点气候条件有所差异,导致相同生育期 AGB 具有一定差异性 (表 1),仅利用单个试验点数据训练模型没有较高的 AGB 估测空间,无法完全覆盖另一个试验点的 AGB 数值。因此,将 2 个试验点相同生育期数据混合,按照比例 8:2 随机划分训练集和测试集。然后,混合全生育期数据进行建模和测试,比较全生育期和各生育期 AGB 估测差异。

在全生育期模型构建中,为衡量高频和低频分量的贡献差异,对不同分量特征分别设置权重,全生育期输入向量为

$$\mathbf{X}_{\text{all}} = (S_F, E_L, \lambda E_H) \quad (4)$$

式中 S_F ——光谱特征 (反射率或植被指数)
 E_L, E_H ——低频和高频特征分量

其中权重 $\lambda \in [0,1]$ 采用无阶段标签先验确定:①样本占比先验: $\lambda = \alpha_{\text{flower}}$,为花期样本在全数据中占

比。②相关性先验: $\lambda = \frac{|\bar{\rho}_{\mathcal{H}}|}{|\bar{\rho}_{\mathcal{L}}| + |\bar{\rho}_{\mathcal{H}}|}$,其中 $|\bar{\rho}_{\mathcal{L}}|$ 、 $|\bar{\rho}_{\mathcal{H}}|$ 为在全生育期样本上计算的低频、高频特征与 AGB 平均斯皮尔曼相关系数绝对值。

在确定频谱特征之前,采用两步去冗余筛选:①相关性预筛:在训练集计算频谱特征两两斯皮尔曼相关系数 ρ ,若 $|\rho| > 0.85$,保留与 AGB 相关性更高且能量占比更大的特征。②方差膨胀系数 (VIF) 迭代:对标准化后的候选集计算 VIF,若存在 VIF 大于 5,则按 VIF 从高到低逐一剔除并重复,直至全部 VIF 小于等于阈值。完成去冗余后,进行 K 折交叉验证评估稳健性。

1.4.4 模型精度验证

为隔离频谱特征自身贡献并更客观评估频谱-光谱融合的增益,在不改变数据划分、训练配置与评价指标前提下,分别设置仅使用光谱特征和频谱特征的对照基线模型,用于比较融合特征的估测精度提升效果。模型精度验证采用决定系数 (R^2) 和均方根误差 (RMSE)。

所有阶段与输入组合共享同一网络与训练协议,以保证可比性与可复现性。网络采用 2 层全连接前馈结构,隐藏层规模 16-8,隐藏层激活函数 tansig,输出层 purelin,损失函数为 MSE。输入特征在训练前进行 z-score 标准化,目标 AGB 维持原量纲 (g/m^2)。优化算法为 Levenberg-Marquardt,最大 epochs 为 1 000,启用早停,以验证集 RMSE 为准则, max_fail 为 6 无改进则提前停止。L2 正则化系数设为 1×10^{-4} 。数据划分:全体样本先按比例 8:2 随机划分为训练集与测试集,全生育期模型在外部划分时对生育期比例分层以保持各阶段占比一致。其后,训练集内部再按比例 8:2 随机划分为子训练/验证集,用于早停与监控泛化。除固定划分测试集结果外,另行在训练集上执行 5 折交叉验证以评估稳定性与鲁棒性。全生育期权重融合仅重构输入向量 $\mathbf{X}_{\text{all}} = (S_F, E_L, \lambda E_H)$ (λ 取样本占比先验),网络与训练超参数与基线完全一致。

2 结果与分析

2.1 基于光谱特征的油菜 AGB 估测模型构建

以多光谱传感器获取的 6 个波段反射率 (450、555、660、720、750、840 nm) 和计算的 6 个植被指数 (NDVI、NDRE、 $\text{CI}_{\text{rededge}}$ 、 CI_{green} 、EVI、EVI2) 分别作为模型输入变量,利用 BP、RF 和 XGBoost 算法构建叶期、花期、角果期和全生育期的 AGB 估测模型,结果如表 2 所示。BP、RF 和 XGBoost 训练集 R^2 分别为 0.43~0.71、0.38~0.64 和 0.41~0.68,测试集 R^2

分别为 0.38~0.80、0.20~0.50 和 0.27~0.57。其中 BP 模型表现最优。

表 2 不同机器学习算法构建的油菜 AGB 估测模型精度
Tab.2 Estimation accuracy of rapeseed AGB based on different machine learning algorithms

算法	输入变量	生育期	训练集		测试集	
			R^2	RMSE/ ($\text{g}\cdot\text{m}^{-2}$)	R^2	RMSE/ ($\text{g}\cdot\text{m}^{-2}$)
BP	反射率	叶期	0.63	272.52	0.80	212.43
		花期	0.56	479.22	0.61	558.65
		角果期	0.71	431.15	0.59	556.82
		全生育期	0.48	550.28	0.46	429.40
	植被指数	叶期	0.51	394.77	0.73	1 012.55
		花期	0.43	542.91	0.42	664.17
		角果期	0.60	515.77	0.64	355.88
		全生育期	0.54	488.03	0.38	411.10
RF	反射率	叶期	0.56	360.00	0.50	426.73
		花期	0.50	505.00	0.37	733.89
		角果期	0.64	460.00	0.28	423.72
		全生育期	0.43	580.00	0.36	539.44
	植被指数	叶期	0.47	418.00	0.42	481.02
		花期	0.38	570.00	0.26	609.54
		角果期	0.54	540.00	0.20	642.45
		全生育期	0.48	515.00	0.44	471.98
XGBoost	反射率	叶期	0.60	345.00	0.57	400.56
		花期	0.53	490.00	0.44	695.45
		角果期	0.68	445.00	0.34	461.82
		全生育期	0.46	565.00	0.42	510.30
	植被指数	叶期	0.50	405.00	0.49	455.32
		花期	0.41	555.00	0.33	580.64
		角果期	0.58	525.00	0.27	615.42
		全生育期	0.52	500.00	0.49	455.67

反射率和植被指数分别作为模型输入变量时, AGB 估测精度不同。反射率作为输入变量, BP、RF 和 XGBoost 训练集 R^2 分别为 0.48~0.71、0.43~0.64 和 0.46~0.68, 测试集 R^2 分别为 0.46~0.80、0.28~0.50 和 0.34~0.57。植被指数作为输入变量, BP、RF 和 XGBoost 训练集 R^2 分别为 0.43~0.60、0.38~0.54 和 0.41~0.58, 测试集 R^2 分别为 0.38~0.73、0.20~0.44 和 0.27~0.49。整体而言, 对于测试的 3 种算法, 反射率作为模型输入变量, 估测 AGB 精度更高。

反射率作为模型输入变量, 利用 BP 构建 AGB 估测模型的精度更高, 但在不同生育期估测效果不同。叶期测试集 R^2 最高, 达到 0.80, RMSE 为 212.43 g/m^2 , 花期和角果期次之, R^2 分别为 0.61、0.59, RMSE 分别为 558.65 、 556.82 g/m^2 。同时, 全生育期测试集 R^2 为 0.46, 低于单生育期; RMSE 为 429.40 g/m^2 , 优于花期和角果期, 但差于叶期。由

此表明, 基于影像光谱特征的 AGB 估测模型精度受不同生育期影响, 在全生育期估测效果不理想。

2.2 油菜器官空间分布特征选取

遥感影像进行二维傅里叶变换, 通过提取频谱特征, 描述油菜器官空间分布。如图 3 所示, 不同生育期傅里叶频谱差异较大。叶期和角果期傅里叶频谱集中在中心位置, 低频分量能量占比较大; 花期傅里叶频谱由中心向四周扩散, 高频分量能量占比增加。




图 3 油菜不同生育期无人机影像的傅里叶频谱
Fig.3 Fourier spectrum of UAV images at different rapeseed growth stages

在此基础上, 将傅里叶频谱按半径等间距划分为 20 个同心环, 各同心环能量值和 AGB 的相关性如图 4 所示。在叶期, 低频分量 (特征 1~10) 与 AGB 表现出较强的负相关性, 相关系数绝对值为 0.44~0.62; 在花期, 高频分量 (特征 11~20) 与 AGB 表现出较强的正相关性, 相关系数绝对值为 0.34~0.51; 在角果期, 低频分量 (特征 1~10) 与 AGB 表现出强正相关性, 相关系数绝对值为 0.66~0.80。对于全生育期, 低频分量 (特征 1~10) 与 AGB 表现出较强的负相关性, 相关系数绝对值为 0.35~0.44。由此表明, 低频分量可以用于表征叶、




图 4 傅里叶频谱各同心环能量值和 AGB 相关性热图
Fig.4 Correlation heatmap between AGB and concentric rings energy of Fourier spectrum

角果的空间分布特征,而高频分量可用于表征花的空间分布特征。

2.3 基于融合特征的油菜 AGB 估测模型构建

以反射率+频谱特征和植被指数+频谱特征分别作为模型输入变量,利用 BP 算法对全生育期 AGB 进行估测,结果如表 3 所示。反射率+频谱特

征训练集 R^2 为 0.63 ~ 0.87,测试集 R^2 为 0.66 ~ 0.87;植被指数+频谱特征训练集 R^2 为 0.55 ~ 0.83,测试集 R^2 为 0.46 ~ 0.59。植被指数+频谱特征训练集 R^2 波动较为剧烈,且测试集 R^2 较低。整体而言,反射率+频谱特征作为输入变量的估测效果更优,稳定性更高。

表 3 基于融合特征构建的油菜 AGB 估测模型精度
Tab.3 Estimation accuracy of rapeseed AGB based on fused features

模型输入变量	生育期	频谱特征 向量数量	训练集		测试集	
			R^2	RMSE/($\text{g}\cdot\text{m}^{-2}$)	R^2	RMSE/($\text{g}\cdot\text{m}^{-2}$)
反射率+低频分量	叶期	7	0.82	246.17	0.87	178.44
反射率+高频分量	花期	7	0.70	389.64	0.66	357.76
反射率+低频分量	角果期	8	0.63	309.75	0.87	258.71
反射率+低频分量	全生育期	7	0.87	258.71	0.78	395.40
植被指数+低频分量	叶期	9	0.55	485.28	0.46	263.40
植被指数+高频分量	花期	9	0.61	480.65	0.59	489.58
植被指数+低频分量	角果期	9	0.83	326.78	0.52	586.77
植被指数+低频分量	全生育期	9	0.63	453.66	0.56	476.83

根据频谱特征和 AGB 之间的相关性,不同生育期选择不同频谱分量和反射率融合。叶期、角果期和全生育期选择低频分量(特征 1 ~ 10),花期选择高频分量(特征 11 ~ 20)。结果显示,参与融合的频谱分量数量对各生育期 AGB 估测精度具有显著影响。以测试集 RMSE 作为精度评价指标,叶期 7 个低频分量(特征 1 ~ 7)和反射率融合后,AGB 估测精度最高,测试集 R^2 为 0.87,RMSE 为 178.44 g/m^2 ;花期融合 7 个高频分量(特征 11 ~ 17)估测精度最高,测试集 R^2 为 0.66,RMSE 为 357.76 g/m^2 ;角果期融合 8 个低频分量(特征 1 ~ 8)估测精度最高,测试集 R^2 为 0.87,RMSE 为 258.71 g/m^2 。在全生育期,7 个低频分量(特征 1 ~ 7)和反射率融合后,估测精度最高,测试集 R^2 为 0.78,RMSE 为 395.40 g/m^2 。由此表明,频谱特征分量类型(低频或高频)及数量选取共同影响 AGB 估测精度。

为比较光谱和频谱特征融合对 AGB 估测精度的提升效果,在统一评估协议下设置了仅光谱特征和频谱特征的对照基线模型,分析基于融合特征构建的估测模型精度。同时,为进一步优化全生育期建模精度,根据花期样本的占比先验,设置高频特征权重,重构了模型输入变量,结果如表 4 所示。光谱和频谱特征融合构建的模型精度提升效果明显,其中花期和角果期提升效果最为显著,测试集精度提升 35% 以上;叶期次之,提升 16%。全生育期最低,约为 8%。对全生育期采用阶段感知权重 λ 的轻量融合后, R^2 由 0.78 升至 0.79,RMSE 由 395.40 g/m^2 降至 388.90 g/m^2 ,表明高频信息对全生育期具有补偿

表 4 基于融合特征的油菜 AGB 估测模型估测精度提升效果

Tab.4 Accuracy improvement of AGB estimation based on fused features

模型输入变量	评估参数	叶期	花期	角果期	全生育期
频谱特征	R^2	0.82	0.64	0.76	0.62
	RMSE/($\text{g}\cdot\text{m}^{-2}$)	202.23	438.12	377.95	412.41
反射率	R^2	0.80	0.61	0.59	0.46
	RMSE/($\text{g}\cdot\text{m}^{-2}$)	212.43	558.65	556.82	429.40
反射率+频谱特征	R^2	0.87	0.66	0.87	0.79
	RMSE/($\text{g}\cdot\text{m}^{-2}$)	178.44	357.76	258.71	388.90

价值。因此,通过无人机遥感影像光谱特征和频谱特征融合,可以有效提升油菜叶期、花期和角果期等关键生育期及全生育期的 AGB 估测精度。

3 讨论

无人机遥感技术可自主搭载不同类型传感器,具有操作灵活、时空分辨率高等优势,在区域尺度的作物表型提取中应用广泛。本研究融合无人机多光谱影像提取的光谱特征和油菜器官空间分布特征,利用机器学习算法构建 AGB 估测模型,实现了全生育期 AGB 的精准动态监测。

利用机器学习算法构建 AGB 估测模型,不同建模方法显著影响估测精度。选用 3 种常见的机器学习算法(BP、RF 和 XGBoost)构建油菜 AGB 估测模型。其中,BP 模型整体精度高于 RF 和 XGBoost,原因可能是 AGB 与无人机遥感影像特征之间存在复杂的非线性关系。前人研究表明,BP 具有非线性映

射能力强、自适应能力突出的特点,在构建作物表型反演模型中表现出更强优势^[32]。例如,马爽等^[33]利用 BP 构建了冬小麦地上生物量、叶面积指数、叶片叶绿素含量和氮含量遥感估测模型;Duan 等^[34]利用 BP 构建了水稻叶面积指数、叶绿素含量、地上生物量和产量遥感估测模型。本研究中 BP 表现最优,结果与前人研究相似,表明可以将 BP 作为一种可靠的方法构建作物表型反演模型,提高作物表型遥感监测精度。

不同模型输入变量显著影响 AGB 估测精度。遥感影像的光谱特征,尤其是植被指数,被广泛应用于作物 AGB 估算研究^[35]。本研究分别利用反射率和植被指数作为模型输入变量,构建油菜 AGB 估测模型。BP、RF 和 XGBoost 模型测试结果均表明反射率作为模型输入变量时估测精度更高。一方面,使用 NDVI、NDRE、 $CI_{rededge}$ 、 CI_{green} 、EVI 和 EVI2 6 个植被指数,虽然涵盖蓝(450 nm)、绿(555 nm)、红(660 nm)、红边(750 nm)、近红外(840 nm)等植被敏感波段,但未完全包含传感器的 6 个波段(缺少 720 nm 波段),光谱信息覆盖不全,说明单一类型特征的数学变换难以提升 AGB 估测精度。另一方面,油菜生长过程形态结构发生明显变化,叶期叶片扩张、花期亮黄色花朵显现,角果期角果生长,除颜色变化之外,冠层结构也随之改变,仅利用光谱特征难以完整表征油菜不同生育期的生长状态,因此基于光谱特征构建的 AGB 估测模型在不同生育期表现不同。由此可以推断,为提高 AGB 估测精度,需引入影像空间域、频率域等其他维度特征。

融合光谱特征和器官空间分布特征能够有效提高油菜 AGB 估测精度。已有研究利用遥感影像光谱和空间特征融合方法提高作物表型估测精度,如齐浩等^[36]、谷晓博等^[37]融合无人机遥感影像提取的植被指数和纹理特征,提高了小麦叶面积指数、叶片含水量估测精度;刘骁驰等^[38]、Lu 等^[39]融合无人机影像提取的植被指数和纹理特征,提高了水稻叶面积指数、钾积累量和叶绿素含量估测精度。但前期研究常基于影像分析提取空间特征,很少考虑作物本身的生长特性。本研究利用不同生育期遥感影像的傅里叶频谱特征表征叶、花、角果等关键器官的空间分布,并与光谱特征融合,提升 AGB 估测模型精度。叶片是叶期主要器官,也是地上生物量的主要构成成分,冠层结构变化为叶片的平滑增长,低频特征可以反映图像的整体轮廓信息,因此与叶期地上生物量表现出较强相关性(相关系数绝对值达 0.62)。角果期与叶期相似,冠层结构变化为角果逐渐生长,低频特征也与地上生物量表现出较强相

关性(相关系数绝对值达 0.80)。而在花期,油菜亮黄色的花朵开始在冠层顶部显现,高频特征可以反映图像局部细节信息,因此与花期地上生物量表现出较强相关性(相关系数绝对值最高达 0.51)。叶期和角果期在全生育期占比较大,低频特征在全生育期与地上生物量表现出较强的相关性。整体而言,叶期低频特征可以表征叶片空间分布,花期高频特征可以表征花朵空间分布,而角果期低频特征可以表征角果空间分布。由此,结合油菜生长和冠层结构特性,构建了频谱特征和器官空间分布之间的关联。

在此基础上,利用光谱和器官空间分布的融合特征构建油菜 AGB 估测模型,在叶期、花期、角果期和全生育期均可显著提高 AGB 估测精度。对叶期、花期和角果期等单一时期而言,选取各自器官对应的频谱分量,与光谱特征融合,可以提高 AGB 估测精度。对全生育期而言,在无先验知识的通用场景下,采用光谱和低频特征融合更为稳健,与仅采用光谱特征建模相比,测试集 RMSE 降低 8%(表 4);当可获得先验知识时,可按样本占比或相关性先验对高频分量实施轻量加权融合,模型精度可进一步提升 2%,可以作为可选择的精度增强路径。此外,融合的频谱特征数量也会显著影响 AGB 估测精度。试验结果显示,选取 7~8 个频谱特征和光谱特征融合,AGB 估测模型精度提升效果最佳。本研究共选用 10 个低频特征和 10 个高频特征,分别选取 7~8 个低频或高频特征,已可以涵盖傅里叶频谱中的大部分频率分量。同时,为避免仅以模型 RMSE 判定“最优特征数”,本研究在去冗余筛选后的特征子集上执行 5 折交叉验证,并计算各折在不同生育期的 AGB 估测值和实测值的斯皮尔曼相关系数,结果如图 5(图中相关系数在 0.05 水平显著)所示。各生育期平均行(折间平均)处于中高水平,且折间波动受控,说明选取 7~8 个频谱特征的结论并非偶然划分导致。当特征数偏离 7~8 个或频段选择不当时,测试集指标明显退化,表明过多或不匹配的频域分量会引入噪声或共线性,降低泛化能力,因此可以选择 7~8 个特征作为稳健折中。同时,为进一步分析频域分桶方案对模型精度的影响,在保持流程与参数一致的前提下比较 $K=15$ 、20、25 频域分桶方案,如表 5 所示。不同环数划分方案并不改变叶期、花期、角果期的主导频段判定(叶期、角果期为低频、花期为高频),模型验证误差与相关性指标在 3 种划分之间差异较小,偏离均低于 2%(以 $K=20$ 为基线)。因此,综合精度与特征稳定性,采用 $K=20$ 作为频域分桶方案。




图 5 K 折交叉验证条件下 AGB 估测值和实测值相关性热图

Fig. 5 Correlation heatmap between AGB estimated and measured value of K-fold cross validation

表 5 不同频域分桶方案模型精度

生育期		分桶方案		
		K = 15	K = 20	K = 25
叶期	R^2	0.86	0.87	0.87
	RMSE / (g·m ⁻²)	179.51	178.44	179.44
花期	R^2	0.64	0.66	0.65
	RMSE / (g·m ⁻²)	360.80	357.76	358.71
角果期	R^2	0.86	0.87	0.87
	RMSE / (g·m ⁻²)	259.92	258.71	258.32
全生育期	R^2	0.77	0.79	0.78
	RMSE / (g·m ⁻²)	397.01	388.90	394.64

利用遥感影像的光谱和频域特征构建油菜不同生育期 AGB 估测模型,提高了 AGB 估测精度。但由于油菜生物学特性,全生育期中叶期占比较大,花期次之,角果期较小,导致角果期采集的样本数量少

于前 2 个时期,模型稳定性和泛化能力有待进一步验证。下一步研究有必要丰富田间试验,增设年度、生态区、施肥水平等不同栽培处理,扩充样本量,提升模型稳定性。同时,还需探索融合时序特征对精度的影响,进一步丰富特征类型。提出的光谱-频域特征融合的建模方法不仅适用于油菜,也可推广至冠层结构复杂、器官异质性强的作物(如大豆、棉花、油葵等),可结合高光谱、热红外或 LiDAR 数据,拓展应用至区域尺度的作物 AGB 遥感监测,为作物长势分析和产量评估提供精准的科学依据。

4 结论

(1)基于光谱和器官空间分布的融合特征构建油菜 AGB 估测模型,可以提高模型估测精度。叶期、角果期融合低频特征,花期融合高频特征。在无先验知识的通用场景下,全生育期融合低频特征更稳健;当可获得先验知识时,可按样本占比或相关性先验对高频分量实施轻量加权融合,作为精度增强路径。

(2)融合的频谱特征数量为 7 ~ 8 个,模型提升效果最佳。从能量角度来看,选取的低频或高频特征分量能量,在总能量中占比较大。

(3)BP 神经网络性能表现最佳,对不同类型输入特征均有较好的 AGB 拟合结果,以反射率 + 频谱特征作为模型输入变量,叶期测试集 R^2 为 0.87, RMSE 为 178.44 g/m²;花期测试集 R^2 为 0.66, RMSE 为 357.76 g/m²;角果期测试集 R^2 为 0.87, RMSE 为 258.71 g/m²;全生育期测试集 R^2 为 0.79, RMSE 为 388.90 g/m²。研究结果可为监测油菜长势及优化栽培技术提供技术支撑。

参 考 文 献

[1] 国家统计局. 中国统计年鉴[M]. 北京:中国统计出版社,2024.

[2] Meng Lin, Ming Bo, Liu Yuan, et al. Maize biomass estimation by integrating spectral, structural, and textural features from unmanned aerial vehicle data[J]. European Journal of Agronomy, 2025,168:127647.

[3] 周敏姑,闫云才,高文,等. 基于多光谱遥感和 CNN 的玉米地上生物量估算模型[J]. 农业机械学报,2024,55(9):238 - 248. Zhou Mingu, Yan Yuncai, Gao Wen, et al. Estimating aboveground biomass of maize based on multispectral remote sensing and convolutional neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(9):238 - 248. (in Chinese)

[4] 向友珍,安嘉琪,赵笑,等. 基于无人机多光谱遥感的大豆生长参数和产量估算[J]. 农业机械学报,2023,54(8):230 - 239. Xiang Youzhen, An Jiaqi, Zhao Xiao, et al. Soybean growth parameters and yield estimation based on UAV multispectral remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023,54(8):230 - 239. (in Chinese)

[5] 李德仁,李明. 无人机遥感系统的研究进展与应用前景[J]. 武汉大学学报(信息科学版),2014,39(5):505 - 513,540. Li Deren, Li Ming. Research advance and application prospect of unmanned aerial vehicle remote sensing system[J]. Geomatics and Information Science of Wuhan University, 2014,39(5):505 - 513,540. (in Chinese)

[6] Sishodia R P, Ray R L, Singh S K. Applications of remote sensing in precision agriculture: a review[J]. Remote Sensing, 2020, 12(19):3136.

[7] Xue Jinru, Su Baofeng. Significant remote sensing vegetation indices: a review of developments and applications[J]. Journal of Sensors, 2017, 2017:1 - 17.

- [8] Jae-Hyun R Y U, Dohyeok O H, Jaeil C H O. Simple method for extracting the seasonal signals of photochemical reflectance index and normalized difference vegetation index measured using a spectral reflectance sensor[J]. *Journal of Integrative Agriculture*, 2021, 20(7): 1969 – 1986.
- [9] Qiao Lang, Tang Weijie, Gao Dehua, et al. UAV-based chlorophyll content estimation by evaluating vegetation index responses under different crop coverages[J]. *Computers and Electronics in Agriculture*, 2022, 196: 106775.
- [10] 邵亚杰, 汤秋香, 崔建平, 等. 融合无人机光谱信息与纹理特征的棉花叶面积指数估测[J]. *农业机械学报*, 2023, 54(6): 186 – 196.
Shao Yajie, Tang Qiuxiang, Cui Jianping, et al. Cotton leaf area index estimation combining UAV spectral and textural features[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(6): 186 – 196. (in Chinese)
- [11] 张子泰, 李振海, 樊意广, 等. 利用无人机多光谱和生物量分配规律的马铃薯地上生物量估算[J]. *光谱学与光谱分析*, 2025, 45(8): 2348 – 2356.
Zhang Zitai, Li Zhenhai, Fan Yiguang, et al. Estimation of potato above-ground biomass using UAV multispectral imagery and biomass allocation patterns[J]. *Spectroscopy and Spectral Analysis*, 2025, 45(8): 2348 – 2356. (in Chinese)
- [12] Duan Bo, Fang Shenghui, Zhu Renshan, et al. Remote estimation of rice yield with unmanned aerial vehicle (UAV) data and spectral mixture analysis[J]. *Frontiers in Plant Science*, 2019, 10: 204.
- [13] Duan Bo, Xiao Xiaolu, Xie Xiongze, et al. Remote estimation of rapeseed phenotypic traits under different crop conditions based on unmanned aerial vehicle multispectral images[J]. *Journal of Applied Remote Sensing*, 2024, 18(1): 19.
- [14] 承达瑜, 何伟德, 付春晓, 等. 融合无人机光谱信息与纹理特征的冬小麦综合长势监测[J]. *农业机械学报*, 2024, 55(9): 249 – 261.
Cheng Dayu, He Weide, Fu Chunxiao, et al. Comprehensive growth monitoring of winter wheat by integrating UAV spectral information and texture features[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(9): 249 – 261. (in Chinese)
- [15] 付新阳, 崔利华, 董雨昕, 等. 去除土壤背景影响的多光谱遥感影像玉米叶面积指数估算[J]. *农业机械学报*, 2025, 56(5): 384 – 394.
Fu Xinyang, Cui Lihua, Dong Yuxin, et al. Estimation of maize leaf area index from multi-spectral remote sensing with soil background effects removed[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2025, 56(5): 384 – 394. (in Chinese)
- [16] 陈洪, 王亚昆, 姚一飞, 等. 基于光谱和纹理信息空间尺度优化的夏玉米冠层 EWT 反演模型[J]. *农业机械学报*, 2024, 55(12): 257 – 267.
Chen Hong, Wang Yakun, Yao Yifei, et al. EWT inversion model of summer maize based on spatial scale optimization of spectral and texture information[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(12): 257 – 267. (in Chinese)
- [17] 刘丽, 匡纲要. 图像纹理特征提取方法综述[J]. *中国图象图形学报*, 2009, 14(4): 622 – 635.
Liu Li, Kuang Gangyao. Overview of image textural feature extraction methods[J]. *Journal of Image and Graphics*, 2009, 14(4): 622 – 635. (in Chinese)
- [18] Qiao Lang, Gao Dehua, Zhao Ruomei, et al. Improving estimation of LAI dynamic by fusion of morphological and vegetation indices based on UAV imagery[J]. *Computers and Electronics in Agriculture*, 2022, 192: 106603.
- [19] Zheng Hengbiao, Cheng Tao, Zhou Meng, et al. Improved estimation of rice aboveground biomass combining textural and spectral analysis of UAV imagery[J]. *Precision Agriculture*, 2019, 20: 611 – 629.
- [20] 许夙晖, 慕晓冬, 赵鹏, 等. 利用多尺度特征与深度网络对遥感影像进行场景分类[J]. *测绘学报*, 2016, 45(7): 834 – 840.
Xu Suhui, Mu Xiaodong, Zhao Peng, et al. Scene classification of remote sensing image based on multi-scale feature and deep neural network[J]. *Acta Geodaetica et Cartographica Sinica*, 2016, 45(7): 834 – 840. (in Chinese)
- [21] 佃袁勇, 杨光, 方圣辉. 傅里叶谱纹理和光谱信息结合的高分辨率遥感影像地表覆盖分类[J]. *武汉大学学报(信息科学版)*, 2017, 42(3): 362 – 368.
Dian Yuanyong, Yang Guang, Fang Shenghui. Combining Fourier spectrum texture and spectral information for land cover classification with high resolution remote sensing images[J]. *Geomatics and Information Science of Wuhan University*, 2017, 42(3): 362 – 368. (in Chinese)
- [22] 吴桂平, 肖鹏峰, 冯学智, 等. 基于光谱空间变换的遥感图像目标探测方法研究[J]. *光谱学与光谱分析*, 2013, 33(3): 741 – 745.
Wu Guiping, Xiao Pengfeng, Feng Xuezhi, et al. A method of object detection for remote sensing imagery based on spectral space transformation[J]. *Spectroscopy and Spectral Analysis*, 2013, 33(3): 741 – 745. (in Chinese)
- [23] Duan Bo, Liu Yating, Gong Yan, et al. Remote estimation of rice LAI based on Fourier spectrum texture from UAV image[J]. *Plant Methods*, 2019, 15: 124.
- [24] 于海琳, 兰玉彬, 李京谦, 等. 基于无人机遥感数据和机器学习的向日葵 LAI 反演[J]. *农业机械学报*, 2025, 56(1): 356 – 365.
Yu Hailin, Lan Yubin, Li Jingqian, et al. Sunflower LAI inversion based on unmanned aerial vehicle remote sensing data and

- machine learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(1): 356–365. (in Chinese)
- [25] 牛庆林, 张合兵, 邓炯, 等. 结合无人机数码影像与 PROSAIL 模型的夏玉米 LAI 反演[J]. 光谱学与光谱分析, 2025, 45(8): 2335–2347.
Niu Qinglin, Zhang Hebing, Deng Jiong, et al. Combining UAV digital imagery with PROSAIL modeling for LAI inversion in summer maize[J]. Spectroscopy and Spectral Analysis, 2025, 45(8): 2335–2347. (in Chinese)
- [26] 范耀冰, 吴尚蓉, 匡炜, 等. 基于无人机高光谱影像的稻谷氮含量估算研究[J]. 农业机械学报, 2025, 56(1): 332–343, 423.
Fan Yaobing, Wu Shangrong, Kuang Wei, et al. Estimation of nitrogen content in rice grains based on UAV hyperspectral imagery[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(1): 332–343, 423. (in Chinese)
- [27] Gitelson A A, Andre's V, Veron'ica C, et al. Remote estimation of canopy chlorophyll content in crops[J]. Geophysical Research Letters, 2025, 32(8): 1–4.
- [28] Rouse J W, Haas R H, Schel J A. Monitoring vegetation systems in the great plains with ERTS[J]. NASA Spec, 1973, 351: 309–317.
- [29] Glenn F, Daniel R, Garry O L. Measuring and predicting canopy nitrogen nutrition in wheat using a spectral index—the canopy chlorophyll content index (CCCI)[J]. Field Crops Research, 2010, 116(3): 318–324.
- [30] Liu Huiqing, Alfredo R H. A feedback based modification of the NDVI to minimize canopy background and atmospheric noise [J]. IEEE Transactions on Geoscience and Remote Sensing, 1995, 33(2): 457–465.
- [31] Jiang Zhangyan, Alfredo R H, Kamel D, et al. Development of a two-band enhanced vegetation index without a blue band[J]. Remote Sensing of Environment, 2008, 112(10): 3833–3845.
- [32] 王鹏新, 田惠仁, 张悦, 等. 基于深度学习的作物长势监测和产量估测研究进展[J]. 农业机械学报, 2022, 53(2): 1–14.
Wang Pengxin, Tian Hui ren, Zhang Yue, et al. Crop growth monitoring and yield estimation based on deep learning: state of the art and beyond[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(2): 1–14. (in Chinese)
- [33] 马爽, 张卓然, 张钧泳, 等. 理化复合参数和神经网络结合的冬小麦长势遥感监测[J]. 农业工程学报, 2024, 40(14): 91–99.
Ma Shuang, Zhang Zhuoran, Zhang Junyong, et al. Remote sensing monitoring of winter wheat growth using physico-chemical composite parameter and neural network[J]. Transactions of the CSAE, 2024, 40(14): 91–99. (in Chinese)
- [34] Duan Bo, Fang Shenghui, Gong Yan, et al. Remote estimation of grain yield based on UAV data in different rice cultivars under contrasting climatic zone[J]. Field Crops Research, 2021, 267: 108148.
- [35] Tao Huilin, Feng Haikuan, Xu Liangji, et al. Estimation of crop growth parameters using UAV-based hyperspectral remote sensing Data[J]. Sensors, 2020, 20(5): 1296.
- [36] 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.
Qi Hao, Sun Haifang, Lü Liangjie, et al. Wheat leaf area index estimation based on fusion of UAV multispectral information and texture features[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(3): 334–344. (in Chinese)
- [37] 谷晓博, 徐洋, 程智楷, 等. 基于无人机多光谱遥感的覆膜冬小麦叶片含水率反演[J]. 农业机械学报, 2025, 56(9): 547–556, 565.
Gu Xiaobo, Xu Yang, Cheng Zhikai, et al. Inversion of leaf water content for mulched winter wheat based on multi-spectral remote sensing of unmanned aerial vehicle[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(9): 547–556, 565. (in Chinese)
- [38] 刘骁驰, 黄向阳, 金明, 等. 融合无人机多光谱与纹理特征解析开花期大豆叶片氮浓度的垂直分布[J]. 农业工程学报, 2025, 41(14): 174–183.
Liu Xiaochi, Huang Xiangyang, Jin Ming, et al. Integrating UAV-derived multispectral and texture features for vertical distribution of nitrogen concentration in soybean leaves during flowering[J]. Transactions of the CSAE, 2025, 41(14): 174–183. (in Chinese)
- [39] Lu Jingshan, Jan U E, Mary E, et al. Improving unmanned aerial vehicle (UAV) remote sensing of rice plant potassium accumulation by fusing spectral and textural information [J]. International Journal of Applied Earth Observation and Geoinformation, 2021, 104: 102592.