

网络出版时间:2025-09-29

网络出版地址:https://link.cnki.net/urlid/61.1359.S.20250929.0951.002

基于无人机多光谱影像和冠层形态的冬小麦叶绿素含量监测研究

王文辉,田超,鲁圣权,安月颖,王晓琦,赵松阳,袁盛华

(廊坊师范学院,河北廊坊 065000)

摘要:为了明确冠层形态和其他模态信息的耦合对冬小麦叶绿素含量(leaf chlorophyll content, LCC)监测的影响,以小麦品种石农 086 和和麦 2020 为材料,通过设置 4 个施氮水平(0、120、240、360 kg · hm⁻²)的冬小麦大田试验,应用低空无人机遥感平台搭载的多光谱影像机获取冬小麦关键生育时期光谱数据,结合数字高程模型(digital elevation model, DEM)计算冠层形态效应,并应用随机森林回归(random forest regression, RF)、分类提升决策树(categorical boosting, Catboost)和极端梯度提升决策树(eXtreme gradient boosting, XGBoost)3 种机器学习算法分析光谱信息、植被指数信息和冠层形态相结合的多模态数据对冬小麦 LCC 监测的贡献。结果表明,相较于光谱和植被指数特征,冠层形态特征可以提高 LCC 的监测精度($r^2 = 0.66$),且 DEM 对模型估测的影响优于坡度。相较于 RF 和 XGBoost,利用 Catboost 构建的 LCC 模型在单一特征、多源特征耦合、多生育时期的情况下均可获得较高的监测精度,尤其是以单一冠层形态特征作为输入变量的情景下。多源特征耦合并不能够显著提高 LCC 的监测精度,但冠层形态特征与其他特征耦合在一定程度上可以提高监测精度。

关键词: 无人机遥感系统;冬小麦;叶绿素含量;冠层形态;多模态数据

中图分类号:S512.1;S311

文献标识码:A

文章编号:1009-1041(2026)03-0404-09

Monitoring Leaf Chlorophyll Content of Winter Wheat Based on Multispectral Imagery and Canopy Morphology Derived from Unmanned Aerial Vehicles

WANG Wenhui, TIAN Chao, LU Shengquan, AN Yueying, WANG Xiaoqi,

ZHAO Songyang, YUAN Shenghua

(Langfang Normal University, Langfang, Hebei 0650000, China)

Abstract: In order to clarify the impact of coupling canopy morphology with other modal information on estimating winter wheat leaf chlorophyll content (LCC), two wheat varieties, Shinong 086 and He-mai 2020 were used as materials. Four nitrogen application levels (0, 120, 240, and 360 kg · hm⁻²) were set up in fields. This study used a low-altitude unmanned aerial vehicle (UAV) remote sensing platform equipped with a multispectral camera to obtain spectral data of winter wheat at key growth stages. The canopy morphology effect was calculated in combination with the digital elevation model (DEM), and Random Forest Regression (RF), Categorical Boosting (Catboost), and eXtreme Gradient Boosting (XGBoost) were applied to analyze the contribution of spectral information, index information, and canopy morphology information, among other multi-modal data, to the monitoring of LCC in winter wheat. The results showed that compared with spectral and vegetation index features, canopy morphology could improve the monitoring accuracy of LCC ($r^2 = 0.66$), and the importance of DEM was superior to that of slope. Among the three machine learning algorithms, the LCC model constructed by Catboost could achieve high monitoring accuracy both in the case of single feature and

收稿日期:2025-04-17 修回日期:2025-06-10

基金项目:河北省自然科学基金项目(C2023408010);河北省高等学校科学研究项目(QN2024158, QN2025034);廊坊市科学技术研究与发展计划项目(2023013221);廊坊师范学院博士(后)科研启动项目(XBQ202423)

第一作者 E-mail:1172139@lfnu.edu.cn(王文辉)

通讯作者 E-mail:1101657229@qq.com(袁盛华)

multi-source feature coupling, especially when a single canopy morphology feature was used as the input variable. Multi-source feature coupling does not improve the monitoring accuracy of LCC, but the coupling of other features with canopy morphology features can improve the monitoring accuracy to a certain extent.

Keywords: Unmanned aerial vehicle remote sensing system; Winter wheat; Leaf chlorophyll content; Canopy morphology; Multi-modal data

叶片叶绿素含量(leaf chlorophyll content, LCC)作为作物营养水平的重要参数,可直接反映作物生长发育情况。传统 LCC 的测定通常依赖于化学分析方法,虽然这种方法精确度高,但需要破坏性取样,费时费力^[1]。随着遥感技术的进步,通过测量作物叶片反射率,基于近地面高光谱可实现对 LCC 的快速无损监测,但这类技术的设备往往价格昂贵且测试步骤繁琐^[2]。相比之下,无人机平台具有操作简单、造价低的特点,可用于 LCC 监测。目前已有研究应用无人机搭载多光谱传感器实现作物 LCC 精准监测^[3]。例如,陈鹏等^[4]利用无人机影像光谱和纹理融合信息估算马铃薯 LCC;呼斯乐^[5]基于 UAV 高光谱遥感与集成学习模型对春小麦叶绿素含量进行反演研究;严薇等^[6]利用无人机对油菜 LCC 进行监测。

目前大多数研究集中于提高光谱监测精度,忽略其他因素对 LCC 监测的影响,仅有部分研究将纹理结构特征与光谱特征相结合,实现 LCC 的精准监测。但上述研究均忽略冠层形态特征对 LCC 的影响,已有研究认为冠层形态特征在一定程度上影响作物生物量的监测,尚不清楚冠层形态特征在 LCC 监测中的贡献。目前,许多研究均已证明多模态数据的结合可提高作物生化参数的监测精度,且相较于简单线性回归模型,机器学习算法因其较高的监测精度常用于作物生化参数监测,其中随机森林回归(random forest regression, RF)、分类提升决策树(categorical boosting, CatBoost)、极端梯度提升决策树(eXtreme gradient boosting, XGBoost)可用于作物生化参数监测和解释模态数据的重要贡献。例如,常升龙等^[7]通过不同模态的小麦数据集对小麦锈病图像识别和遥感监测;Zhang 等^[8]在光谱影像基础上引入地形因素对小麦进行研究;刘彦岑等^[9]利用图像颜色特征与纹理特征对大田哈密瓜 LCC 进行预测。

本研究以冬小麦为研究对象,基于不同品种和氮肥施用水平的大田试验,应用无人机获取冬

小麦关键生育时期多光谱影像,并利用机器学习算法建立多模态数据和 LCC 的监测模型,探究冠层形态特征对 LCC 监测的贡献,解析多模态数据组合对 LCC 监测的影响,通过比较 3 种机器学习算法的监测精度确定最优 LCC 监测模型,以期为农田作物 LCC 的精准监测提供参考。

1 材料与方法

1.1 试验区概况

本试验区为固安县农业农村局农业科技试验示范基地廊坊市丰产家庭农场(116°19'E, 39°22'N)(图 1)。该农场位于廊坊市中部,地处华北平原北部,属暖温带半干旱半湿润大陆性季风气候,年平均气温 13℃,年平均降雨量 540~600 mm。

本试验采用裂区设计(图 1),品种为主区(石农 086 和和麦 2020),施氮水平为副区,共设置 0、120、240 和 360 kg·hm⁻² 4 个施氮水平,分别用 N0、N1、N2 和 N3 表示。研究区共 24 个小区,小区面积 20 m² (5 m×4 m)。氮肥为尿素(含氮 46%),其中 60%基施,40%拔节期追施。磷肥(过磷酸钙,含 12%的 P₂O₅)和钾肥(硫酸钾,含 50%的 K₂O)的施用量分别为 150 kg P₂O₅·hm⁻² 和 150 kg K₂O·hm⁻²,全部基施。试验田其他管理措施与当地农户高产田一致。

1.2 数据获取

1.2.1 无人机多光谱传感器参数

本研究使用大疆 Mavic 3 多光谱版无人机系统采集数据。该传感器能够获取 4 个波段的信息,波长分别为 650 nm±16 nm(红光波段, R)、560 nm±16 nm(绿光波段, G)、730 nm±16 nm(红边波段, RE)、860 nm±26 nm(近红外波段, NIR)。该款无人机系统集成多光谱强光传感器和高精度 RTK,采集到的影像在保持高空间分辨率的同时,具有高精度位置坐标,因此不需设置地面控制点进行几何校正^[10]。

1.1.2 无人机多光谱影像采集

选择晴朗无云、无风的天气,在 10:00—14:00

应用大疆 Mavic3 Pro 进行影像采集,获取冬小麦分蘖期(2024 年 3 月 30 日)、孕穗期(2024 年 4 月 21 日)、开花期(2024 年 4 月 30 日)和灌浆期(2024 年 5 月 11)冠层光谱信息。本研究应用 DJI Go 软件设计无人机航线,其中旁向和航向重叠度分别为 85%和 90%,飞行速度为 $4\text{ m}\cdot\text{s}^{-1}$,飞行高度为 30 m,采集影像的空间分辨率为 0.8 cm。

1.2.3 冬小麦 LCC 获取

无人机多光谱影像获取之后,于冬小麦关键生育时期(分蘖期、孕穗期、开花期和灌浆期),应用手持 SPAD 仪在每个小区随机选取 10 株冬小麦的顶三叶进行 SPAD 值测定,并利用公式(1)将测定的 SPAD 值转化为 LCC 值^[11]。

$$\text{LCC}=1.63\times\text{SPAD}-31.31 \tag{1}$$

1.3 数据预处理

1.3.1 光谱信息数据提取

冬小麦冠层多光谱影像获取后,应用大疆智

图对影像进行对齐、点云构建、数字高程模型(DEM)构建、拼接等操作。本研究借鉴 Li 等^[12]的方法,应用 5 块标准反射率白板(5%、10%、20%、30%和 40%)对影像进行辐射校正。本研究将预处理后的 4 个波段(绿、近红外、红和红边)在 ArcMap10.8 中,采用感兴趣区(region of interest,ROI)提取小区相应波段反射率。

1.3.2 植被指数信息获取

植被指数主要反映植被在可见光、近红外波段反射与土壤背景之间差异的指标,各植被指数在一定条件下能用来定量说明植被的生长状况^[13]。不同条件下不同的植被指数所带来的差异各不相同。本文基于前人研究成果,选取与 LCC 相关性较强的植被指数进行研究(表 1)。通过提取到的波段反射率,在 Excel 2024 中计算 6 个植被指数(NDVI、GNDVI、NDRE、OSAVI、SAVI、 $\text{CI}_{\text{red edge}}$)。




图 1 试验区区位图和试验设计

Fig. 1 Location map of study area and field experimental design

表 1 本研究应用的植被指数
Table 1 Vegetation indices applied in this study

植被指数 Vegetation index	公式 Formula	参考文献 Reference
归一化植被指数 Normalized vegetation index (NDVI)	$\frac{(R_{\text{nir}}-R_{\text{red}})}{(R_{\text{nir}}+R_{\text{red}})}$	[14]
绿色归一化干扰植被指数 Green normalized difference vegetation index (GNDVI)	$\frac{(R_{\text{nir}}-R_{\text{green}})}{(R_{\text{nir}}+R_{\text{green}})}$	[15]
红色边缘归一化指数 Normalized red edge index (NDRE)	$\frac{(R_{\text{nir}}-R_{\text{red}})}{(R_{\text{nir}}+R_{\text{red}})}$	[16]
优化的土壤调整植被指数 Optimized soil adjusted vegetation index(OSAVI)	$\frac{(R_{\text{nir}}-R_{\text{red}})}{(R_{\text{nir}}+R_{\text{red}}+0.16)}$	[17]
土壤调整植被指数 Soil adjusted vegetation index(SAVI)	$1.5\times\frac{(R_{\text{nir}}-R_{\text{red}})}{(R_{\text{nir}}+R_{\text{red}}+0.5)}$	[18]
红边比值植被指数 Red edge ratio vegetation index($\text{CI}_{\text{red edge}}$)	$\frac{R_{\text{nir}}}{R_{\text{red edge}}}-1$	[19]

R_{nir} 、 $R_{\text{red edge}}$ 、 R_{red} 和 R_{green} 分别为小区中的近红外、红边、红、绿波段反射率。
 R_{nir} , $R_{\text{red edge}}$, R_{red} , and R_{green} refer to the reflectance of the near-infrared, red edge, red, and green bands in the plot, respectively.

1.3.3 冠层形态特征提取

数字高程模型 (DEM) 可以体现作物局部冠层形态特征^[20]。本研究利用无人机多光谱影像拼接过程中的点云数据,在 ArcGIS 10.8 中的空间分析工具生成研究区域的 DEM 和坡度的冠层形态特征,通过数学运算最终得到平均高程 (DEM_{mean})、最大高程 (DEM_{max})、最小高程 (DEM_{min})、高程标准差 (DEM_{std})、高程变化区间 (DEM_{range})、高程差异系数 (DEM_{cv})、平均坡度 (Slope_{mean})、最大坡度 (Slope_{max})、最小坡度 (Slope_{min})、坡度标准差 (Slope_{std})、坡度变化区间 (Slope_{range})、坡移系数 (Slope_{cv})。

$$\text{DEM}_{\text{mean}} = \left(\frac{1}{n}\right) \times \sum_{i=1}^n H_i \quad (2)$$

$$\text{DEM}_{\text{max}} = \text{MAX} H_i \quad (3)$$

$$\text{DEM}_{\text{min}} = \text{MIN} H_i \quad (4)$$

$$\text{DEM}_{\text{std}} = \sqrt{\left(\frac{1}{n-1}\right) \times \sum_{i=1}^n (H_i - \text{DEM}_{\text{mean}})^2} \quad (5)$$

$$\text{DEM}_{\text{range}} = \text{DEM}_{\text{max}} - \text{DEM}_{\text{min}} \quad (6)$$

$$\text{DEM}_{\text{cv}} = \text{DEM}_{\text{std}} / \text{DEM}_{\text{mean}} \quad (7)$$

$$\text{Slope}_{\text{mean}} = \left(\frac{1}{n}\right) \times \sum_{i=1}^n \text{Slope}_i \quad (8)$$

$$\text{Slope}_{\text{max}} = \text{MAX} \text{Slope}_i \quad (9)$$

$$\text{Slope}_{\text{min}} = \text{MIN} \text{Slope}_i \quad (10)$$

$$\text{Slope}_{\text{std}} = \sqrt{\left(\frac{1}{n-1}\right) \times \sum_{i=1}^n (\text{Slope}_i - \text{Slope}_{\text{mean}})^2} \quad (11)$$

$$\text{Slope}_{\text{range}} = \text{Slope}_{\text{max}} - \text{Slope}_{\text{min}} \quad (12)$$

$$\text{Slope}_{\text{cv}} = \text{Slope}_{\text{std}} / \text{Slope}_{\text{mean}} \quad (13)$$

式中, H_i 、 Slope_i 分别为小区范围内高程值和坡度值,其中 i 为小区内像元个数。

1.4 模型构建与评价

本研究按照 6:4 比例将数据分为建模数据集 (样本量 57) 和验证数据集 (样本量 39),应用 RF、CatBoost 和 XGBoost 3 种机器学习算法,以冠层形态特征输入与否作为限制条件,构建机器 LCC 预测模型。

(1) 基于单一特征变量进行建模,构建 3 个 LCC 模型 (光谱特征-LCC 模型、植被指数特征-LCC 模型、冠层形态特征-LCC 模型);

(2) 冠层形态特征与其他特征耦合进行建模,构建 2 个 LCC 模型 (冠层形态特征耦合光谱特征-LCC 模型、冠层形态特征耦合植被指数特征耦

合-LCC 模型);

(3) 冠层形态特征耦合所有特征进行建模,构建全部特征耦合的 LCC 模型。

3 种机器学习算法中,RF 通过构建多棵决策树,利用自助采样和特征随机选择生成不同的子数据集,最终预测结果为多棵树预测结果的平均值^[21];CatBoost 和 XGBoost 算法主要基于梯度提升,集成方式为 Boosting,但相较于 XGBoost, CatBoost 可以有效减少过拟合和预测偏移的问题^[22]。本研究所构建的 3 种机器学习模型均在 PyCharm 软件环境中,通过调用 Scikit-learn 库中的函数计算完成。

用决定系数 (r^2) 和均方根误差 (root mean squared error, RMSE) 用来验证不同模型的监测能力。

$$r^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2 (y_i - \bar{y})^2}{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2} \quad (14)$$

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (y_i - x_i)^2}{n}} \quad (15)$$

式中, y_i 和 x_i 分别为第 i 个样本点的冬小麦表型的测量值和预测值。 r^2 越接近 1, RMSE 数值越小,模型估算能力越强。

2 结果与分析

2.1 LCC 值描述统计结果

由图 2 可知,不同情景下 LCC 值变化均存在差异。建模和验证样本集间也存在差异,其中建模集的 LCC 平均值小于验证集,且同一数据集内部差异一致,建模集内部的差异略大于验证集,但这些差异不显著,表明两个样本集的独立性强,具有代表性 (图 2a)。不同生育时期 LCC 值存在变化,且整体上 LCC 值随生育进程呈增加趋势 (图 2a)。随施氮量的增加, LCC 值呈递增趋势,但 N2 和 N3 间差异较小。不同品种间,石农 086 的 LCC 平均值及其标准差小于和麦 2020。

2.2 多源特征与 LCC 的相关性

通过 SPSS 2024 对光谱特征、植被指数特征和冠层形态特征与 LCC 值间进行相关分析,结果 (表 2) 表明,本研究选取的多源特征与 LCC 的相关性均达到极显著水平 ($P < 0.01$),但异源特征和单一特征下相关性存在差异,其中冠层形态

特征中 DEM 与 LCC 的相关性较大(相关系数为 0.81),Slope 的相关性较小,Slope_{std} 最小(相关系数为 0.36)。光谱特征中,除近红外波段反射率外,其余波段光谱反射率与 LCC 呈负相关,且近

红外和红边波段的反射率与 LCC 的相关系数均为 0.59。在植被指数中,红边波段构建的植被指数(NDRE 和 CI_{red edge})的相关性优于其他植被指数,相关系数均为 0.68。




图 2 不同数据集(a)、生育时期(b)、氮肥施用水平(c)、品种(d)下 LCC 值的变化

Fig. 2 Variation of LCC values with different datasets(a), growth stages(b), nitrogen application levels(c) and varieties(d)

表 2 多源特征与 LCC 的相关关系
Table 2 Correlation between multi-source features and LCC

特征 Feature	指标 Indicator	相关系数 Correlation coefficient
光谱特征 Spectral feature	R_{green}	-0.54**
	R_{nir}	0.59**
	R_{red}	-0.47**
	$R_{red\ edge}$	-0.59**
植被指数特征 Vegetation index feature	NDVI	0.47**
	GNDVI	0.53**
	NDRE	0.68**
	OSAVI	0.67**
	SAVI	0.54**
	CI _{red edge}	0.68**
冠层形态特征 Canopy morphology feature	DEM _{min}	0.61**
	DEM _{max}	0.81**
	DEM _{range}	0.52**
	DEM _{mean}	0.81**
	DEM _{std}	0.40**
	Slope _{min}	0.37**
	Slope _{max}	0.41**
	Slope _{range}	0.41**
	Slope _{mean}	0.44**
	Slope _{std}	0.36**

** : $P < 0.01$.

2.3 模型比较与分析

2.3.1 单一特征变量建模效果

由表 3 可知,利用不同特征构建 LCC 预测模型的效果存在差异。在相同算法下,冠层形态特征的建模精度最大,其次是植被指数特征的建模精度,光谱特征构建的建模精度最低;从 RMSE 看,三类特征的建模精度呈相反趋势,即冠层形态特征构建的模型的 RMSE 最小,植被指数特征构建模型的 RMSE 次之,光谱指数特征构建模型的 RMSE 最大。就不同机器学习算法而言,在相同特征下,CatBoost 算法构建的模型的 r^2 和 RMSE 分别最大和最小。综合来看,冠层形态特征中的 CatBoost 算法构建的模型和 XGBoost 算法构建的模型相差不大,优于其他模型,而基于 RF 算法构建的模型最差。

2.3.2 冠层形态特征与其他特征耦合建模效果

三种特征两两耦合下,当冠层形态特征加入时 LCC 模型的建模精度均优于另外两个特征单独构建的模型,且冠层形态特征与植被指数耦合的效果好于冠层形态特征与光谱指数耦合(表 4)。就算法而言,光谱与植被指数和冠层形态分别耦合构建的模型中,CatBoost 算法的建模精度

均最高,而植被指数和冠层形态特征耦合构建的模型中,RF 和 CatBoost 算法的建模精度相近,RF 算法略优($r^2=0.65$,RMSE=2.88 $\mu\text{g}\cdot\text{cm}^{-2}$),两种算法的建模精度均优于 XGBoost 算法。

2.3.3 全部特征耦合建模效果

三种特征耦合构建的 LCC 模型中,CatBoost 算法的建模精度最高, r^2 为 0.65, RMSE 为 2.92 $\mu\text{g}\cdot\text{cm}^{-2}$,标准差为 3.54;XGBoost 算法构建的模型精度最低, r^2 为 0.60, RMSE 为 3.10 $\mu\text{g}\cdot\text{cm}^{-2}$ (表 5)。

利用验证集对模型进行验证,结果(图 3)表明,不同机器学习算法构建的 LCC 模型的监测精度均较高,其中 Catboost 算法精度优于其他机器学习算法($r^2=0.65$),RF 算法的监测精度优于 XGBoost 算法,进一步证明了 Catboost 算法在监测冬小麦 LCC 的优势。

表 3 单一特征下建模精度的差异
Table 3 Accuracy difference of model construction with siagle feature

特征 Feature	模型 Model	r^2	RMSE/ ($\mu\text{g}\cdot\text{cm}^{-2}$)
光谱特征 Spectral feature	XGBoost	0.47	3.57
	RF	0.50	3.47
	CatBoost	0.54	3.33
植被指数特征 Vegetation index feature	XGBoost	0.53	3.36
	RF	0.52	3.39
	CatBoost	0.55	3.30
冠层形态特征 Canopy morphology feature	XGBoost	0.66	2.85
	RF	0.63	2.96
	CatBoost	0.66	2.84

表 4 两种耦合下建模精度的差异
Table 4 Accuracy differences model construction with two features

特征 Feature	模型 Model	R^2	RMSE/ ($\mu\text{g}\cdot\text{cm}^{-2}$)
光谱+植被指数特征 Spectral+vegetation index feature	XGBoost	0.49	3.49
	RF	0.50	3.45
	CatBoost	0.56	3.24
光谱+冠层形态特征 Spectral+canopy morphology feature	XGBoost	0.59	3.13
	RF	0.61	3.04
	CatBoost	0.65	2.94
植被指数+冠层形态特征 Vegetation index+ canopy morphology feature	XGBoost	0.64	2.94
	RF	0.65	2.88
	CatBoost	0.65	2.91

表 5 全部特征耦合下模型构建精度
Table 5 Accuracy of model construction with all features

模型 Model	r^2	RMSE/ ($\mu\text{g}\cdot\text{cm}^{-2}$)
XGBoost	0.60	3.10
RF	0.62	3.03
CatBoost	0.65	2.92




图 3 不同机器学习算法的模型验证精度差异
Fig. 3 Differences in LCC monitoring accuracy with heterogeneous coupling conditions

利用多源特征耦合下构建的模型对不同生育时期 LCC 进行估测,结果(表 6)表明,不同生育时期模型的估测精度存在差异,且随生育进程的推进,模型估测精度增加,其中灌浆期估测精度最高,分蘖期估测精度最低。不同模型中,CatBoost 模型的估测精度均优于 RF 和 XGBoost。不同生育时期,模型 LCC 估测值存在差异,且随生育进程的推进 LCC 高值呈聚集分布(图 4)。

表 6 多源特征耦合下构建的模型在不同生育时期 LCC 验证精度

Table 6 Monitoring accuracy of LCC derived from different growth stages with multi-source feature coupling

生育时期 Growth stage	模型 Model	r^2	RMSE/ ($\mu\text{g} \cdot \text{cm}^{-2}$)
分蘖期 Tillering stage	XGBoost	0.41	3.80
	RF	0.45	3.43
	CatBoost	0.56	3.24
孕穗期 Booting stage	XGBoost	0.50	3.31
	RF	0.57	3.22
	CatBoost	0.60	3.12
开花期 Anthesis stage	XGBoost	0.51	3.29
	RF	0.59	3.16
	CatBoost	0.61	3.05
灌浆期 Filling stage	XGBoost	0.56	3.23
	RF	0.60	3.11
	CatBoost	0.64	2.94

3 讨论

本研究分析冠层形态特征对冬小麦 LCC 监测的贡献,结果表明,相较于其他特征(光谱和植被指数特征),冠层形态特征构建的模型精度高于其他模型,这与 Zhang 等^[8]研究结果一致。究其原因,一方面由于冠层形态特征在一定程度上可以表征作物冠层结构变化,且这种结构变化影响冠层光合作用,进而影响冠层光谱反射率精度^[23];另一方面,冠层形态特征直接或间接影响植株干物质积累与转运,尤其是在生育后期,随着冠层郁闭度增加和营养生长开始,冠层形态特征的影响越大。坡度变化作为冠层形态的主要表现形式影响作物生化参数,尤其是作物生物量,但与前人研究结果^[24]不同。本研究表明,DEM 变化对 LCC 监测的影响强于坡度变化,这可能与作物




图 4 多源特征耦合下构建的 CatBoost 模型在不同生育时期 LCC 反演结果

Fig. 4 LCC inversion results from the CatBoost model constructed with multi-source feature coupling at different growth stages

本身特性相关,当作物营养生长,作物株高产生较大的变化,这种变化体现在冠层形态上的 DEM 变化,因此可以证明在冠层形态变化中 DEM 对 LCC 的影响较大,且建议今后作物 LCC 监测过程中需要考虑冠层形态特征,尤其是 DEM 变化特征。

此外,本研究对比了 3 种机器学习算法对 LCC 监测的影响,结果表明,Catboost 算法的拟合结果较为突出,这与 Dai 等^[20]对比机器学习算法的研究结果相同,说明 Catboost 在 LCC 监测方面较为适用,尤其作为小样本。而 RF 和 XGBoost 更偏向于大样本的计算^[25],且两者的运算方式与 Catboost 运算方式存在显著差异,这种差异导致二者对 LCC 的监测精度较低。本研究应用 Catboost 算法构建的 LCC 模型精度($r^2=0.66$)

远低于其他研究结果($r^2=0.85$)^[26],其原因可能是本研究数据量较少,且对机器学习算法而言,较小的样本会导致模型构建不稳定,造成模型精度降低。此外,本研究仅选取了光谱特征、植被指数特征和冠层形态特征 3 类变量输入,输入模型的变量类别较少,未来应增加其他类型变量,如纹理特征^[27]、物候特征^[28]等。

本研究通过不同的耦合策略解析了冠层形态特征对冬小麦 LCC 监测的贡献,结果显示,相较于单一的光谱和植被指数特征,耦合冠层形态特征能提高 LCC 监测精度,这主要归咎于冠层形态特征在冠层光合和植株干物质积累与转运方面的作用,且这种作用有效弥补光谱饱和效应,并在一定程度上表明冠层形态特征影响 LCC 监测精度。

然而,相较于单一的冠层形态特征,多源特征耦合并不能提高 LCC 的监测精度,这与薛宇飞等^[29]研究结果不一致。这可能是变量冗余造成的,冠层形态特征对 LCC 的贡献被光谱特征和植被指数特征所影响,导致在多源特征耦合过程中并不能提高监测精度,仅达到了与单一冠层形态建模相似的结果。

4 结论

本研究基于不同品种和施氮量组合试验,应用低空无人机遥感平台搭载的多光谱相机获取冬小麦关键生育时期光谱数据和冠层形态特征,基于机器学习算法分析光谱信息、植被指数信息和冠层形态信息等多模态数据对冬小麦 LCC 监测的贡献。结果表明,相较于光谱和植被指数特征,冠层形态特征可以提高 LCC 的监测精度($r^2=0.66$),且 DEM 的重要性优于坡度。3 种机器学习算法中,Catboost 构建的 LCC 模型在单一特征和多源特征耦合的情况下均可获得较高的监测精度,尤其是在单一冠层形态特征作为输入变量的情况下。多源特征耦合并不能够提高 LCC 的监测精度,但其他特征与冠层形态特征耦合可以在一定程度上提高监测精度。

参考文献:

- [1]张 伏,张亚坤,毛鹏军,等.植物叶绿素测量方法研究现状及发展[J].农机化研究,2014,36(4):238.
ZHANG F,ZHANG Y K,MAO P J,*et al.* Status and development of measuring method in plant chlorophyll content [J]. *Journal of Agricultural Mechanization Research*, 2014, 36(4):238.
- [2]ZHANG H C,GE Y F,XIE X Y,*et al.* High throughput analysis of leaf chlorophyll content in sorghum using RGB,hyper-spectral, and fluorescence imaging and sensor fusion [J]. *Plant Methods*, 2022, 18(1):60.
- [3]张 建,谢田晋,尉晓楠,等.无人机多角度成像方式的饲料油菜生物量估算研究 [J]. 作物学报,2021,47(9):1816.
ZHANG J,XIE T J,WEI X N,*et al.* Research on biomass estimation of feed rapeseed by multi-angle imaging of unmanned aerial vehicles [J]. *Acta Agronomica Sinica*, 2021, 47(9):1816.
- [4]陈 鹏,冯海宽,李长春,等.无人机影像光谱和纹理融合信息估算马铃薯叶片叶绿素含量[J]. 农业工程学报,2019,35(11):63.
CHEN P,FENG H K,LI C C,*et al.* Estimation of chlorophyll content in potato using fusion of texture and spectral features derived from UAV multispectral image [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2019, 35(11):63.
- [5]呼斯乐.基于 UAV 高光谱遥感与集成学习模型的春小麦叶绿素含量反演研究[D].呼和浩特:内蒙古师范大学,2024.
HU S L. Research on inversion of chlorophyll content in spring wheat based on UAV hyperspectral remote sensing and ensemble learning model [D]. Hohhot: Inner Mongolia Normal University, 2024.
- [6]严 薇,唐 乐,彭佳元,等.无人机可见光谱识别越冬期油菜叶片叶绿素含量估测研究[J]. 作物研究,2022,36(6):514.
YAN W,TANG L,PENG J Y,*et al.* Identification of chlorophyll content in leaves of rapeseed in overwintering period by UAV visible spectrum [J]. *Crop Research*, 2022, 36(6):514.
- [7]常升龙.基于深度学习的小麦锈病图像识别和遥感监测研究[D].郑州:河南农业大学,2024.
CHANG S L. Research on wheat rust disease image recognition and remote sensing monitoring based on deep learning [D]. Zhengzhou: Henan Agricultural University, 2024.
- [8]ZHANG S H,HE L,DUAN J Z,*et al.* Aboveground wheat biomass estimation from a low-altitude UAV platform based on multimodal remote sensing data fusion with the introduction of terrain factors [J]. *Precision Agriculture*, 2024, 25(1):119.
- [9]刘彦岑,郭俊先,郭 阳,等.基于数字图像的大田哈密瓜不同时期冠层相对叶绿素含量检测研究[J]. 浙江农业学报,2024,36(3):651.
LIU Y C,GUO J X,GUO Y,*et al.* Research on detection of relative chlorophyll content in canopy of field-grown Hami melons at different growth stages based on digital images [J]. *Zhejiang Journal of Agricultural Sciences*, 2024, 36(3):651.
- [10]于博文.国产卫星高分一号数据几何校正与融合研究[D].北京:中国地质大学(北京),2015.
YU B W. Research on geometric correction and fusion of domestic satellite Gaofen-1 data [D]. Beijing: China University of Geosciences, 2015.
- [11]LI D,CHENG T,ZHOU K,*et al.* WREP: A wavelet-based technique for extracting the red edge position from reflectance spectra for estimating leaf and canopy chlorophyll contents of cereal crops [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2017, 129:103.
- [12]LI D,WU Y P,BERGER K,*et al.* Estimating canopy nitrogen content by coupling PROSAIL-PRO with a nitrogen allocation model [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2024, 135:104280.
- [13]AL-SHAMMARI D,WHELAN B M,WANG C,*et al.* Assessment of red-edge based vegetation indices for crop yield prediction at the field scale across large regions in Australia [J]. *European Journal of Agronomy*, 2025, 164:127479.
- [14]QI J,KERR Y H,MORAN M S,*et al.* Leaf area index estimates using remotely sensed data and BRDF models in a semiarid region [J]. *Remote Sensing of Environment*, 2000, 73(1):18.

- [15] SAHU G, GARANAYAK M, PAIKARAY B K. Green vegetation detection in satellite imagery using the normalized difference vegetation index method [J]. *International Journal of Bioinformatics Research and Applications*, 2023, 19(4):327.
- [16] ROTH L, AASEN H, WALTER A, *et al.* Extracting leaf area index using viewing geometry effects: A new perspective on high-resolution unmanned aerial system photography [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2018, 141:161.
- [17] RONDEAUX G, STEVEN M, BARET F. Optimization of soil-adjusted vegetation indices [J]. *Remote Sensing of Environment*, 1996, 55(2):95.
- [18] HUETE A R. A soil-adjusted vegetation index (SAVI) [J]. *Remote Sensing of Environment*, 1988, 25(3):295.
- [19] GITELSON A A, GRITZ Y, MERZLYAK M N. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves [J]. *Journal of Plant Physiology*, 2003, 160(3):271.
- [20] DAI W, HU J H, WANG B, *et al.* Effects of digital elevation model resolution on unmanned aerial vehicle-based topographic change detection in human-altered landscapes [J]. *Drones*, 2024, 8(11):610.
- [21] 王文辉. 福建省植被盖度的动态变化及驱动因子分析[D]. 福州: 福建农林大学, 2017.
- WANG W H. Dynamic change of vegetation coverage and its driving factors in Fujian Province [D]. Fuzhou: Fujian Agriculture and Forestry University, 2017.
- [22] 曾书玉, 谢涛, 孔瑞瑶. 基于 CatBoost 和 XGBoost 组合模型的水深反演[J]. 海洋测绘, 2023, 43(3):59.
- ZENG S Y, XIE T, KONG R Y. Water depth inversion based on CatBoost-XGBoost combined model [J]. *Hydrographic Surveying and Charting*, 2023, 43(3):59.
- [23] LU N, WANG W H, ZHANG Q F, *et al.* Estimation of nitrogen nutrition status in winter wheat from unmanned aerial vehicle based multi-angular multispectral imagery [J]. *Frontiers in Plant Science*, 2019, 10:1601.
- [24] 李军立. 基于 DEM 的地形因子算法在喀斯特地形分析中的差异与适应性研究[D]. 南宁: 南宁师范大学, 2020.
- LI J L. Study on difference and adaptability of terrain factor algorithm based on DEM in karst terrain analysis [D]. Nanning: Nanning Normal University, 2020.
- [25] LE NGUYEN K, SHAKOURI M, HO L S. Investigating the effectiveness of hybrid gradient boosting models and optimization algorithms for concrete strength prediction [J]. *Engineering Applications of Artificial Intelligence*, 2025, 149:110568.
- [26] 冯伟, 朱艳, 田永超, 等. 基于高光谱遥感的小麦籽粒产量预测模型研究[J]. 麦类作物学报, 2007, 27(6):1076.
- FENG W, ZHU Y, TIAN Y C, *et al.* Model for predicting grain yield with canopy hyperspectral remote sensing in wheat [J]. *Journal of Triticeae Crops*, 2007, 27(6):1076.
- [27] 祝清霞, 朱艳秋, 王爱臣, 等. 基于无人机多光谱植被指数与纹理特征的水稻叶绿素含量反演[J]. 农业机械学报, 2024, 55(12):287.
- ZHU Q Z, ZHU Y Q, WANG A C, *et al.* Accurate inversion of rice chlorophyll content by integrating multispectral and texture features derived from UAV multispectral imagery [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(12):287.
- [28] 张焱, 王焕炯, 高成蹊, 等. 中国东北地区植被绿度与光合春季物候特征及其对水热因子的响应[J]. 地理科学进展, 2024, 43(12):2507.
- ZHANG Y, WANG H J, GAO C X, *et al.* Vegetation greenness and photosynthetic phenological characteristics in spring and their responses to hydrothermal factors in Northeast China [J]. *Progress in Geography*, 2024, 43(12):2507.
- [29] 薛宇飞, 张声哈, 白娜娜, 等. 耦合 Sentinel-1/2 多源时序遥感影像特征的红树林物种分类方法[J]. 地球信息科学学报, 2024, 26(11):2626.
- XUE Y F, ZHANG S H, BAI N N, *et al.* Classification of mangrove species using coupled Sentinel-1/2 multi-source time-series remote sensing image features [J]. *Journal of Geo-Information Science*, 2024, 26(11):2626.