doi:10.6041/j.issn.1000-1298.2026.17.012

基于多源特征融合与堆叠集成学习的冬油菜叶面积指数估测研究

陈桂鹏[1,2]　刘　杰[1,2]　张嘉豪[1,2]　吴尚蓉[3,4]　国佳欣[1,2]

(1.江西省农业科学院农业经济与信息研究所,南昌 330200;2.江西省农业智能感知工程研究中心,南昌 330200;
3.中国农业科学院农业资源与农业区划研究所,北京 100081;
4.北方干旱半干旱耕地高效利用全国重点实验室,北京 100081)

摘要:叶面积指数(Leaf area index,LAI)是评价作物生长状况与作物单产的关键生物学参数。针对基于无人机多光谱数据构建的植被指数特征在高 LAI 区易饱和的问题,本研究以甘蓝型冬油菜(*Brassica napus* L.)为研究对象,获取冬油菜苗期、蕾薹期、花期和角果期的多光谱图像,融合提取的 11 个光谱特征(Spectral features,SFs)、40 个纹理特征(Texture features,TFs)以及地面实测株高(Plant height,PH),结合随机森林(Random forest,RF)、梯度提升决策树(Gradient boosting decision tree, GBDT)、支持向量机回归(Support vector regression,SVR)以及 K 近邻(K-nearest neighbors regression,KNN)算法,构建了基于堆叠集成学习(Stacking ensemble learning,SEL)的冬油菜 LAI 估测框架,实现 LAI 精准估测。结果表明:SFs、TFs 与 PH 的多源特征融合能显著提高模型估测精度;在全生育期尺度下,SEL 模型精度最优,R^2 达到 0.93,MAE 和 RMSE 分别为 0.27 和 0.33;LAI 空间分布图能够清晰揭示 4 个生育期不同施肥、密度及播期处理下冬油菜长势的空间异质性。研究成果可为冬油菜生长的精准监测提供决策支持。

关键词:冬油菜;叶面积指数;多源特征融合;堆叠集成学习;无人机多光谱

中图分类号:TP79　　**文献标识码**:A　　**文章编号**:1000-1298(2026)17-0126-08　　**OSID**:

Estimation of Winter Rapeseed Leaf Area Index Based on Multi-source Feature Fusion and Stacking Ensemble Learning

Chen Guipeng[1,2]　Liu Jie[1,2]　Zhang Jiahao[1,2]　Wu Shangrong[3,4]　Guo Jiaxin[1,2]

(1. *Institute of Agricultural Economics and Information*, *Jiangxi Academy of Agricultural Sciences*, *Nanchang* 330200, *China*
2. *Jiangxi Province Engineering Research Center of Intelligent Perception in Agriculture*, *Nanchang* 330200, *China*
3. *Institute of Agricultural Resources and Regional Planning*, *Chinese Academy of Agricultural Sciences*, *Beijing* 100081, *China*
4. *State Key Laboratory of Efficient Utilization of Arid and Semi-arid Arable Land in Northern China*, *Beijing* 100081, *China*)

Abstract: Leaf area index (LAI) is a crucial biological parameter for evaluating crop growth status and predicting yield. Aiming at the common problem of spectral saturation in high LAI regions when using vegetation indices derived from unmanned aerial vehicle (UAV) multispectral data, winter rapeseed (*Brassica napus* L.) was taken as the research object. Based on multispectral images acquired at the seedling, bolting, flowering, and podding stages, a total of 11 spectral features (SFs), 40 texture features (TFs), and ground-measured plant height (PH) were fused systematically. By integrating random forest (RF), gradient boosting decision tree (GBDT), support vector regression (SVR), and K-nearest neighbors (KNN) algorithms, a stacked ensemble learning (SEL) framework was constructed to achieve efficient and precise LAI inversion. The results indicated that the multi-source feature fusion of SFs, TFs, and PH significantly improved the estimation accuracy and generalization ability of the model. At the scale of the whole growth period, the SEL model exhibited the highest accuracy, the coefficient of

收稿日期:2026-04-21　修回日期:2026-05-09

基金项目:江西省现代农业科研协同创新专项(JXXTCX202606)、江西省职业早期青年科技人才项目(S202510451)、江西省农业科学院基础研究与人才培养项目(JXSNKYJCRC202654)、江西省高层次高技能领军人才培养工程项目(赣人社字[2025]2 号)和国家自然科学基金面上项目(42271374)

作者简介:陈桂鹏(1983—),男,研究员,博士,主要从事智慧农业研究,E-mail:chenguipeng@jxaas.cn

通信作者:国佳欣(1996—),男,助理研究员,博士,主要从事农业遥感研究,E-mail:guojiaxin@jxaas.cn

determination (R^2) was 0.93, the mean absolute error (MAE) was 0.27, and the root mean square error (RMSE) was 0.33. The LAI spatial distribution maps clearly revealed the spatial heterogeneity of winter rapeseed growth under different fertilization, density, and sowing date treatments during the four growth stages. These research findings can provide valuable decision support for the field precision monitoring and efficient cultivation management of winter rapeseed growth.

Key words: winter rapeseed; leaf area index; multi-source feature fusion; stacking ensemble learning; unmanned aerial vehicle multispectral

0　引言

油菜作为全球重要的油料作物,其产量和品质直接关系到国家粮食安全和农业经济发展[1]。在油菜生长发育过程中,叶面积指数(Leaf area index, LAI)是反映作物冠层结构、光合潜力及生长状况的关键生物物理参数,LAI 的动态演变直接决定了光合效率,进而影响最终产量[2]。实现 LAI 的实时、精准监测,对于科学制定田间管理措施、优化种植密度及开展单产估测具有重要意义。然而,传统的 LAI 测量方法,如人工破坏性取样,虽然精度较高,但耗时耗力且难以实现大范围动态监测,无法满足现代精准农业对作物生长信息实时获取的需求[3]。

近年来,遥感技术凭借其非接触、大尺度、高效率的优势,在 LAI 估测领域得到广泛应用[2]。特别是无人机(Unmanned aerial vehicle, UAV)遥感技术,由于其平台灵活、操作便捷、分辨率高且成本相对较低,已成为田间尺度作物 LAI 监测的重要手段[4]。由无人机挂载多光谱、高光谱传感器等设备获取光谱数据,提取植被指数(Vegetation indices, VIs)用以反演作物 LAI 的方法已得到广泛应用[5]。Zhu 等[6]利用无人机高光谱数据构建植被指数用以估测油菜 LAI,其模型 R^2 达 0.81。Peng 等[7]基于无人机多光谱数据构建植被指数,结合机器学习模型反演油菜 LAI 并以此为基础预测单产,其 R^2 达 0.91。尽管植被指数在 LAI 反演上应用成效显著,但在高 LAI 郁闭冠层下易出现光谱饱和现象,导致估测精度下降[8]。研究表明,将光谱数据中的植被指数与反映冠层空间结构信息的纹理特征(Texture features, TFs)相结合能够有效弥补植被指数光谱饱和的局限性,从而有效提升油菜 LAI 的估测精度[9-10]。Sun 等[11]在玉米叶面积指数研究中发现,将由无人机多光谱影像提取的植被指数与纹理特征融合后 R^2 由 0.62 显著提升至 0.81。此外,株高(Plant height, PH)能够直接反映作物的生长量和垂直结构,为冠层内部的复杂结构提供补充,从而提升模型的准确性和鲁棒性[12]。Chen 等[13]研究结果表明,将多光谱数据和作物高度融合能够提升玉米叶面积指数的估测精度。综上所述,融合光谱特征、纹理特征及作物株高,可为油菜 LAI 的反演提供有效支撑。

模型构建方面,随机森林(Random forest, RF)[14]、支持向量机(Support vector machine, SVM)[15]和梯度提升决策树(Gradient boosting decision tree, GBDT)[16]等算法已广泛应用于 LAI 的估测,且优于传统回归模型的效果[17]。集成学习(Ensemble learning, EL)在处理非线性关系和高维复杂数据方面具备显著优势,能够通过结合多个基学习器的预测结果,显著提高模型的泛化能力和预测精度,对遥感数据的噪声和复杂场景具有较强的鲁棒性[18]。

然而,在冬油菜 LAI 估测过程中,受其冠层结构复杂多变的影响,多源特征融合的适用性仍需进一步探索。同时,机器学习尤其是集成学习算法在挖掘多维特征与冬油菜 LAI 间复杂非线性关系方面具有应用潜力,仍有待深入研究。基于此,本研究在江西省农业科学院高安试验基地开展油菜田间试验,在油菜关键生育期同步获取田间无人机多光谱数据,通过融合植被指数、纹理特征及株高构建基于堆叠集成学习(Stacking ensemble learning, SEL)的冬油菜 LAI 估测模型,旨在量化多源特征与冬油菜 LAI 的相关关系,筛选并确定最优特征组合;构建基于多源特征融合与堆叠集成学习的冬油菜 LAI 高精度估测模型,为冬油菜生长动态监测及田间精准管理提供技术支撑与方法参考。

1　材料与方法

1.1　研究区概况与试验设计

研究区设立在江西省农业科学院高安试验基地(28°25′27″N,115°12′15″E)进行冬油菜小区试验,供试品种为甘蓝型油菜(*Brassica napus* L.)。试验设置 3 个播种期(T1:10 月 1 日、T2:10 月 11 日、T3:10 月 21 日),每个播种期设 3 个种植密度(D1:30 万株/hm^2、D2:60 万株/hm^2、D3:90 万株/hm^2),每个密度下设置 3 个施肥水平(F1:0 kg/hm^2、F2:25 kg/hm^2、F3:50 kg/hm^2)。试验采用油菜专用缓释肥(N 25%、P_2O_5 7%、K_2O 8%)作为基肥,于播种前施用。试验采用裂区设计,共 81 个小区(3 播种

期×3 密度×3 施肥×3 重复),小区间以田垄分隔,单个小区面积为 10.35 m^2(4.14 m×2.50 m)。研究区位置和试验处理分别如图 1、2 所示。

1.2 冬油菜 LAI 及株高数据获取

在冬油菜苗期、蕾薹期、花期和角果期 4 个物候期,采用 LAI-2200C 冠层分析仪获取叶面积指数(LAI)。为减小太阳高度角对投射光测量的影响,测定工作选择在 08:00—10:00 进行。每个小区内沿对角线选取 3 个测量点,取其平均值作为该小区的 LAI。株高(PH)同步采用卷尺测量,记录由地面根茎交界处到油菜样本最高点的垂直距离。4 个生育期共获取 324 条数据,统计结果分别如表 1、2 所示。

1.3 无人机多光谱数据获取及预处理

采用大疆精灵 4 RTK 多光谱无人机同步获取多光谱数据,包含蓝(Blue,B,中心波长 450 nm)、绿(Green,G,中心波长 560 nm)、红(Red,R,中心波长 650 nm)、红边(Red edge,RE,中心波长 730 nm)、近红外(Near infrared,NIR,中心波长 840 nm)5 个多光谱波段以及 1 个 RGB 彩色传感器,所有波段的图像分辨率一致,均为 1 600 像素×1 300 像素。飞行任务规划于当地时间 10:00—14:00 进行,通过利用较小的太阳天顶角和相对稳定的太阳辐照度,降低阴影和大气散射对数据质量的影响。无人机在执行拍摄任务前,在距离地面 1 m 高度拍摄漫反射板用于辐射校正,飞行高度设定为 30 m。

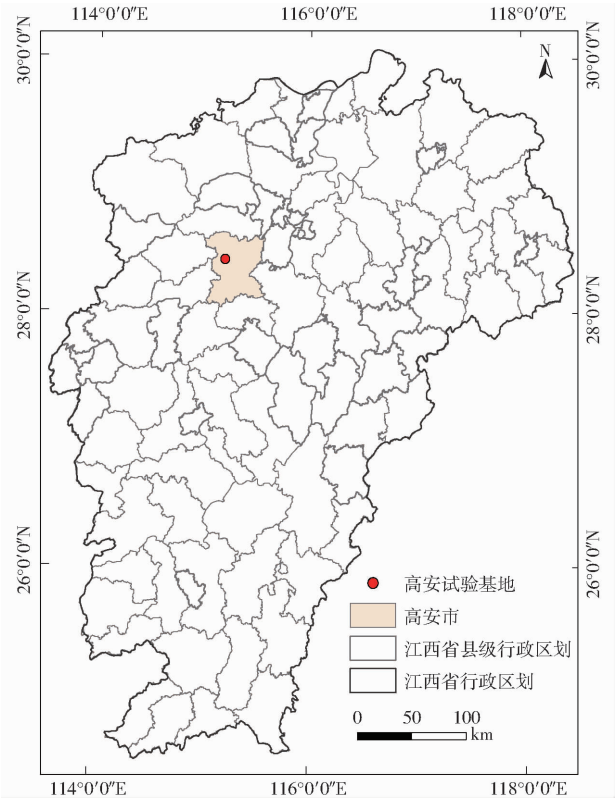

图 1 研究区位置

Fig. 1 Study area location

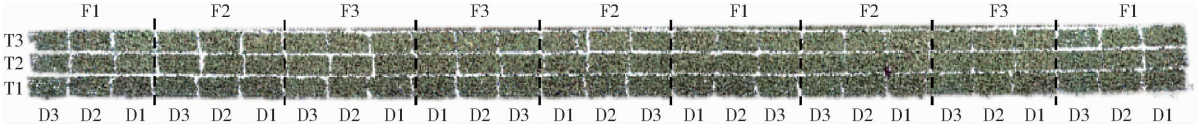

图 2 试验处理

Fig. 2 Experimental treatment

表 1 冬油菜 LAI 实测值描述性统计

Tab. 1 Descriptive statistics of measured LAI values for winter rapeseed

生育期	样本数/个	最小值	最大值	平均值	标准差	变异系数/%
苗期	81	0.90	3.23	2.41	0.44	18.26
蕾薹期	81	1.73	6.39	5.05	0.76	15.05
花期	81	3.15	5.33	4.37	0.43	9.84
角果期	81	1.97	4.40	2.93	0.49	16.72
全生育期	324	0.90	6.39	3.69	1.20	32.52

表 2 冬油菜株高实测值描述性统计

Tab. 2 Descriptive statistics of measured plant height values for winter rapeseed

生育期	样本数/个	最小值/cm	最大值/cm	平均值/cm	标准差/cm	变异系数/%
苗期	81	16.00	58.33	35.95	10.04	27.94
蕾薹期	81	33.67	71.00	56.61	8.35	14.75
花期	81	102.67	160.33	135.18	10.95	8.10
角果期	81	123.00	185.33	157.78	12.68	8.04
全生育期	324	16.00	185.33	121.41	49.78	41.04

采用 Agisoft Metashape Professional 软件对获取的多光谱影像进行预处理,其中包括辐射校正、影像对齐、生成密集点云、生成正射影像并导出。通过 ENVI 软件提取油菜冠层区域,计算各小区植被指数、波段反射率和纹理特征均值。

1.4 模型构建与精度评价

本研究中冬油菜 LAI 估测流程主要分为 3 部分:①对大疆精灵 4 RTK 无人机多光谱影像进行预处理,提取植被指数和纹理特征。②采用随机森林回归算法进行特征重要性评估,结合交叉验证确定最佳特征输入数量,以有效降低高维特征间的数据冗余。③融合随机森林、梯度提升决策树、支持向量回归和 K 近邻 4 种算法构建基学习器,引入岭回归作为元学习器,构建堆叠集成学习估测模型,经训练后用于冬油菜全生育期 LAI 估测。

1.4.1　特征构建

植被指数(VIs)是遥感领域常用的量化指标，通过对植被冠层不同反射光谱波段进行组合运算，实现地表植被覆盖度、健康状况和生长态势的定量评估[19]。本研究从无人机多光谱影像中提取包括归一化植被指数(Normalized difference vegetation index，NDVI)[20]、优化土壤调整植被指数(Optimized soil adjusted vegetation index，OSAVI)[21]、归一化差异红色边缘指数(Normalized difference red edge index，NDRE)[22]、增强型植被指数(Enhanced vegetation index，EVI)[23]、绿波段归一化植被指数(Green normalized difference vegetation index，GNDVI)[24]、差值植被指数(Difference vegetation index，DVI)[25]在内的 6 种植被指数，以及 5 个波段 B、G、R、RE、NIR 的反射率(Reflectance，REF)。上述植被指数和波段反射率在本研究中统称为光谱特征(Spectral features，SFs)。

纹理特征(TFs)能够反映作物冠层的精细结构，可有效弥补植被指数易饱和问题[26]。灰度共生矩阵(Gray-level co-occurrence matrix，GLCM)是应用较为广泛的纹理分析方法，通过统计图像中特定距离和方向上灰度值对的出现频率量化纹理的精细结构。基于灰度共生矩阵可提取对比度、能量、相关性等特征，能够反映纹理的粗糙度、方向性、规律性等感知属性[27]。本研究采用 ENVI 5.3 的灰度共生矩阵对 5 个波段分别进行均值(Mean，MEA)、方差(Variance，VAR)、同质性(Homogeneity，HOM)、对比度(Contrast，CON)、相异性(Dissimilarity，DIS)、信息熵(Entropy，ENT)、二阶矩(Second moment，SEC)与相关性(Correlation，COR)8 个纹理特征的提取。在灰度共生矩阵的计算中设定步长为 1、窗口大小为 3×3、灰度量化等级为 64 级，共获得 40 个纹理特征集(5 波段×8 特征)。

1.4.2　特征筛选

本研究构建的特征包括 5 个波段反射率、6 个植被指数、株高以及 40 个纹理特征共计 52 个。为提高模型精度并降低计算复杂性，需对高维特征进行筛选。以往研究表明，遥感特征与 LAI 间多呈非线性关系[28]，且随机森林模型能够有效捕捉复杂的特征交互作用[17]。因此，本研究采用随机森林回归算法开展特征重要性分析，通过构建包含 10 棵决策树的模型(设置最大深度为 1 以防止过拟合)，计算基于基尼系数的特征重要性得分，量化各特征与 LAI 之间的非线性关联。相关研究指出，输入特征数量为 10～14 个可显著提升模型的性能，降低过拟合风险[29]。据此，本研究按随机森林重要性评分降序选取前 k 个特征(k 为 1～10)，并结合 3 折交叉验证构建特征子集，以随机森林模型在验证集上的平均 R^2 最高且模型稳定性为标准，确定最优特征数量。

1.4.3　模型构建

堆叠集成学习模型(SEL)是一种高效的机器学习方法，通过融合多个基学习器的预测结果训练元模型，从而进一步提升整体估测性能(图 3)。本研究将随机森林(RF)[14]、梯度提升决策树(GBDT)[15]、支持向量机回归(SVR)[16]和 K 近邻回归(K-nearest neighbors regression，KNN)[30]4 种模型作为基学习器，以岭回归模型(Ridge regression)[31]作为元学习器构建堆叠集成学习模型，并将 4 种基学习器模型单独训练以开展对比分析。

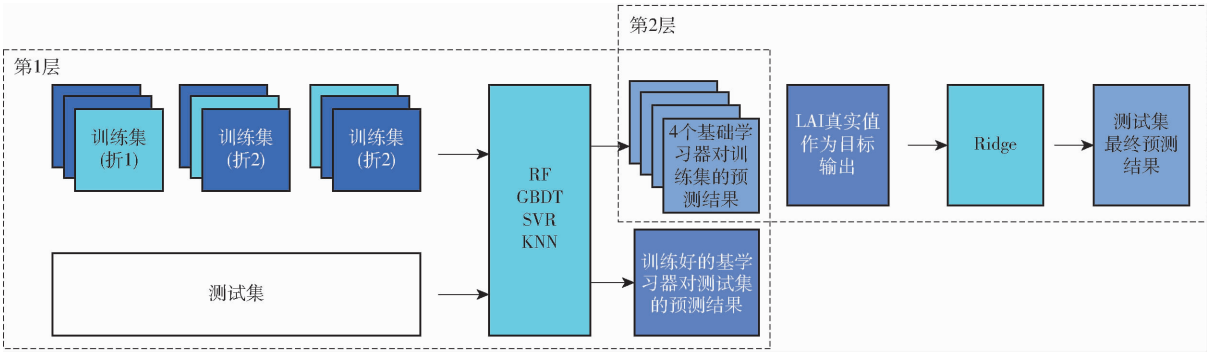

图 3　堆叠集成学习模型训练流程图

Fig. 3　Training flowchart of stacking ensemble learning model

基学习器中，RF 是一种基于决策树的集成学习算法，通过自助采样(Bagging)构建多棵相互独立的决策树，并以投票或均值方式融合输出结果，能够有效处理高维特征、抑制过拟合，适用于挖掘特征间非线性关系[14]。模型中设置决策树数量(n_estimators)为 100，决策树最大深度(max_depth)为 8，节点最小分裂样本数(min_samples_split)为 5，叶子节点最小样本数(min_samples_leaf)为 3。GBDT 采用前向分步迭代策略，通过串行训练多棵弱学习器，不断拟合前一轮残差以提升模型精度，对非线性

关系拟合效果较为突出[15]。模型中设置决策树数量为 100,学习率(learning_rate)为 0.1,决策树最大深度为 4,节点最小分裂样本数为 5,叶子节点最小样本数为 3,子样本比例(subsample)为 0.8。SVR 基于核函数将低维非线性数据映射至高维空间,构建最优分离超平面实现回归拟合,在小样本、高维数据场景下泛化能力稳定,适合处理复杂非线性映射关系[16]。模型中设置核函数(kernel)为径向基核函数(RBF),惩罚因子(C)为 50。KNN 通过计算样本与训练集间的距离选取近邻的均值进行预测,原理简单、对局部趋势敏感[30],模型中近邻数(n_neighbors)设置为 5。

模型训练过程如下:①数据划分,将原始数据集(324 个数据样本)按照训练集与测试集 8∶2的比例划分,随机种子设置为 42。②交叉验证,将训练集划分为 3 份,其中 1 份作为测试集,其余 2 份作为训练集。③基学习器训练(第 1 层),构建 RF、GBDT、SVR 和 KNN 4 种基学习器模型,通过交叉验证训练并生成元特征。④元学习器训练(第 2 层),以岭回归作为元学习器对元特征进行加权组合,构建 LAI 估测模型。

1.4.4 模型精度评价

采用决定系数(Coefficient of determination,R^2)、平均绝对误差(Mean absolute error,MAE)和均方根误差(Root mean square error,RMSE)作为评价指标来检验模型精度。

2 结果与分析

2.1 冬油菜 LAI 相关特征筛选

本研究利用随机森林回归算法计算了 52 个特征的重要性得分(图 4)。结果表明,纹理特征对冬油菜 LAI 的整体解释能力普遍高于光谱特征。其中绿光波段的相异性(G - DIS)及蓝光波段的对比度(B - CON)、方差(B - VAR)贡献度最高,重要性得分分别达 0.10、0.09 和 0.09。这表明在冬油菜中后期郁闭冠层下,利用图像的空间结构信息和阴影

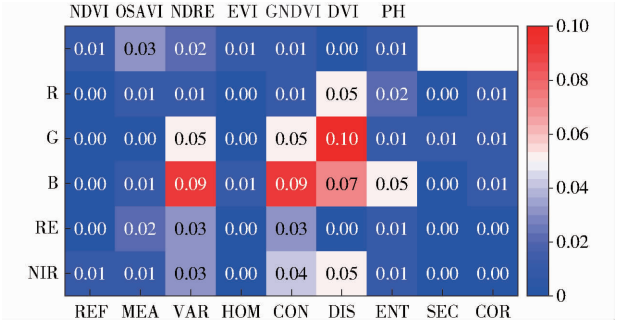

图 4 不同特征的重要性得分

Fig. 4 Importance scores for different features

分布能够更为有效地缓解光谱饱和问题。光谱特征中,优化土壤调节指数(OSAVI)和红边归一化差异指数(NDRE)表现优于传统 NDVI,体现了背景消除与红边信息在 LAI 估测中的优势。而株高作为垂直生长维度数据的补充,也具备一定的解释能力,重要性得分为 0.01。随后,通过 3 折交叉验证(图 5)确定当输入特征数为 8 时,模型能够兼顾预测精度与鲁棒性。

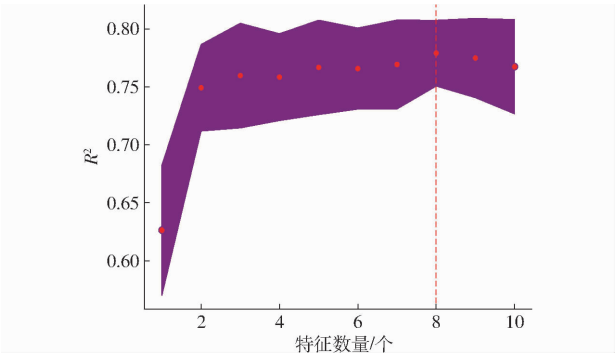

图 5 基于交叉验证的特征数量优化图

Fig. 5 Feature quantity optimization graph based on cross-validation

不同特征组合下的输入变量如表 3 所示,单一特征模式下主要依次选取重要性得分最高的特征。而双特征组合(SFs + TFs)和全特征融合(SFs + TFs + PH)采用分类筛选的模式,分别选取光谱特征和纹理特征排名靠前的特征变量构建 LAI 估测模型。

表 3 冬油菜 LAI 估测模型构成

Tab. 3 Composition of winter rapeseed LAI estimation models

特征组合	输入变量
PH	PH
SFs	OSAVI、NDVI、EVI、NIR、DVI、GNDVI、B、NDRE
SFs + PH	OSAVI、NDVI、EVI、NIR、DVI、GNDVI、B、PH
TFs	G - DIS、B - CON、B - VAR、B - DIS、B - ENT、NIR - DIS、G - VAR、G - CON
TFs + PH	G - DIS、B - CON、B - VAR、B - DIS、B - ENT、NIR - DIS、G - VAR、PH
SFs + TFs	OSAVI、NDVI、EVI、NIR、G - DIS、B - CON、B - VAR、B - DIS
SFs + TFs + PH	OSAVI、NDVI、EVI、NIR、G - DIS、B - CON、B - VAR、PH

2.2 不同特征组合和模型对冬油菜 LAI 估测影响

在冬油菜 LAI 估测中,不同特征组合和模型对估测精度具有显著影响(表 4)。在单一特征下,株高对 LAI 的估测能力最弱,R^2 仅在 0.50 ~ 0.58 之间;而光谱特征与纹理特征均表现出较强的估测性能,且二者估测精度相近(R^2 在 0.68 ~ 0.85 范围

表 4　不同特征组合的模型结果对比

Tab. 4　Comparison of model results with different feature combinations

模型	指标	PH	SFs	TFs	SFs + PH	TFs + PH	SFs + TFs	SFs + TFs + PH
RF	R^2	0.52	0.68	0.71	0.71	0.75	0.85	0.86
	MAE	0.61	0.56	0.46	0.53	0.48	0.37	0.36
	RMSE	0.88	0.72	0.62	0.68	0.63	0.49	0.46
GBDT	R^2	0.53	0.70	0.78	0.72	0.80	0.84	0.85
	MAE	0.62	0.54	0.40	0.51	0.42	0.40	0.38
	RMSE	0.87	0.69	0.54	0.67	0.55	0.51	0.48
SVR	R^2	0.53	0.80	0.77	0.84	0.83	0.84	0.86
	MAE	0.62	0.44	0.39	0.39	0.38	0.37	0.37
	RMSE	0.87	0.56	0.55	0.50	0.52	0.50	0.46
KNN	R^2	0.50	0.75	0.77	0.78	0.82	0.84	0.86
	MAE	0.62	0.48	0.46	0.46	0.40	0.40	0.36
	RMSE	0.89	0.63	0.60	0.59	0.53	0.51	0.46
SEL	R^2	0.58	0.85	0.85	0.88	0.86	0.89	0.93
	MAE	0.61	0.38	0.40	0.35	0.36	0.33	0.27
	RMSE	0.82	0.48	0.49	0.43	0.46	0.41	0.33

内），说明纹理特征能够有效量化冠层结构的异质性并缓解植被指数饱和影响。多源特征融合结果表明，在光谱或纹理特征基础上单独加入株高模型精度提升有限，但将光谱与纹理融合（SFs + TFs）后，各模型精度均得到显著提升（如 SEL 模型的 R^2 升至 0.89），充分反映了光谱信息与空间结构信息间的强互补性。当构建 SFs + TFs + PH 全特征方案时，各算法下模型估测精度均达到全生育期尺度下的最优水平，基准模型 RF、GBDT、SVR 和 KNN 的 R^2 均高于 0.85。SEL 模型展现出全场最优性能，相较单一光谱特征 R^2 由 0.85 提升至 0.93，提高了 9.41%，MAE 和 RMSE 分别降低至 0.27 和 0.33。这一结果也表明，株高虽然独立贡献度有限，但在光谱与纹理组合的基础上能提供垂直方向上的信息，实现三维信息的深度耦合，从而最大程度降低了估测残差。

不同模型精度对比结果显示，SEL 模型在所有特征组合下对于 LAI 的估测均优于单一算法。其中，在多源特征融合下估测精度较最优单一机器学习模型随机森林（R^2 = 0.86）相对提升了 8.14%，达到 0.93。即便在弱解释力特征（仅使用株高）下，SEL 的 R^2（0.58）仍优于基模型，体现了其对微弱信号的捕捉潜力。在信息充分的条件下，SEL 通过二级元学习器动态调整各模型权重，有效修正单一学习器在不同长势梯度下的系统偏差，为冬油菜 LAI 无损高精度监测提供了可行的技术方案。

2.3　冬油菜 LAI 时空分布特征

表 5 和图 6 展示了冬油菜 4 个生育期内叶面积指数（LAI）的时空分布与统计特征。从时间维度来看，冬油菜从苗期（2.67 ± 0.78）到蕾薹期（4.95 ± 0.28），LAI 呈显著上升趋势并在蕾薹期达到峰值，这是因为该阶段是冬油菜快速分枝与叶片扩展的营养生长关键期。进入花期（4.11 ± 0.42）和角果期（3.42 ± 0.38）后，随着黄色花瓣的遮挡增强及下部叶片逐步凋落，LAI 呈现下降趋势，光合中心由叶片向角果皮转移。

表 5　冬油菜 LAI 估测值描述性统计结果

Tab. 5　Descriptive statistics of estimated LAI values for winter rapeseed

生育期	最小值	最大值	平均值	标准差	变异系数/%
苗期	1.80	4.84	2.67	0.78	29.21
蕾薹期	2.54	5.59	4.95	0.28	5.66
花期	1.81	4.21	4.11	0.42	10.22
角果期	2.34	4.33	3.42	0.38	11.11
全生育期	1.80	5.59	3.79	0.98	25.86

从空间分布来看，在不同施肥处理下，冬油菜 LAI 呈现出随肥力梯级递增的规律：不施肥处理（F1）下的 LAI 整体显著低于高施肥处理（F3），表明土壤养分的充足供应是维持高 LAI 的基础。在相同施肥条件下，种植密度（D）与播期（T）对 LAI 的调控表现出显著的交互效应。早播（T1）处理在苗期具有明显的先行优势，进而具备较高的 LAI 值；而高密度（D3）则有助于迅速提升田间冠层覆盖度。然而，过量密植与延迟播种的叠加可能会对生长产生负面影响：图中晚播高密高肥处理（T3D3F3）的 LAI

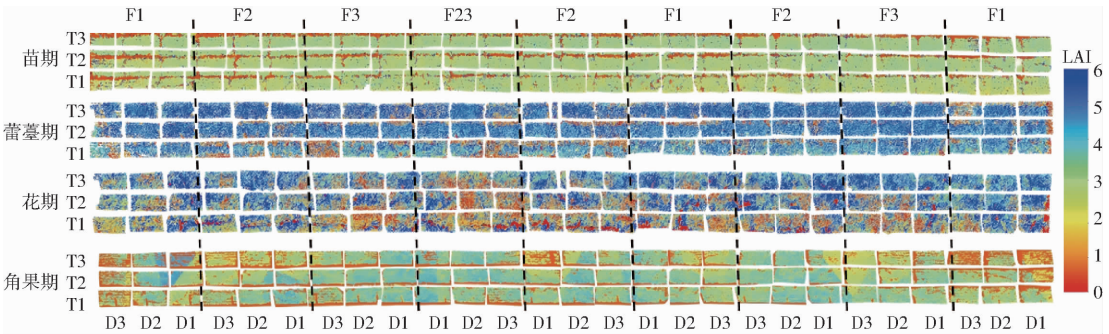

图 6　冬油菜 LAI 时空分布图

Fig. 6　Spatiotemporal distribution map of LAI for winter rapeseed

均值略低于预期的最优组合。这种因极高密度导致的个体竞争加剧以及晚播积温不足引发的生长障碍,不仅会增加田间生产的经济成本,还会限制冬油菜单产的提升。

总体而言,上述研究结果能有效观测不同施肥、密度和播期处理下冬油菜的生长动态变化,为农田科学施肥、合理密植及适期播种提供指导。

3 讨论

3.1 多源特征融合在冬油菜 LAI 估测中应用分析

多源数据的融合能够显著提升作物生长信息监测的精度。在本研究中,通过联合使用无人机多光谱影像提取的光谱特征(SFs)、纹理特征(TFs)以及地面实测株高(PH)来共同估测冬油菜 LAI。结果显示,相较于单一光谱特征,多源特征融合方案显著提升了估测性能,R^2 提升至 0.85 ~ 0.93,MAE 降低至 0.27 ~ 0.38,RMSE 降低至 0.33 ~ 0.48。与前人在玉米[29]和小麦[32]中的研究结果中发现融入纹理特征和株高后能够有效提升 LAI 估测精度相一致。

从遥感物理机理分析,多源特征的互补性是提升精度的关键。传统的植被指数主要依赖于红光和近红外波段对叶绿素吸收和叶片细胞结构的敏感性,但在冬油菜蕾薹期及花期,当冠层高度郁闭时,光谱饱和会导致其灵敏度下降[11]。纹理特征作为对空间异质性的量化,能够有效捕捉由叶片重叠、分枝角度变化所产生的微小阴影与空间粗糙度信息,从而在物理层面弥补光谱饱和局限[10]。此外,株高作为表征作物三维结构的垂直维度指标,与叶面积在生理上存在显著正相关关系,能够有效校准花期花瓣遮挡或下部叶片凋落导致的光谱差异[33]。

此外,尽管全生育期模型对于 LAI 整体估测精度较高(R^2 = 0.93),但各生育期的估测表现存在差异。苗期冠层覆盖度低、叶片直立性强,导致模型估测偏差相对较大;进入蕾薹期后,随着冠层快速郁闭,光谱和结构特征与 LAI 的响应关系显著增强,模型精度得到明显提升。该结果表明低 LAI 条件下基于多光谱遥感估测仍存在局限,后续研究将融合激光雷达点云数据进一步提升苗期 LAI 的估测精度。

3.2 堆叠集成学习模型在冬油菜 LAI 估测中应用分析

与单一机器学习模型相比,堆叠集成学习在冬油菜 LAI 估测中展现出显著的性能提升(R^2 = 0.93),其核心在于整合多个基学习器,通过多层级的模型结构捕捉多源特征间的复杂非线性关系[34]。单一机器学习算法受限于固定的模型结构,易在特征空间中学习到不准确的映射关系,从而导致系统性的预测偏差。相较之下,将多个基学习器集成能更充分地挖掘因光谱饱和或环境背景干扰而变得微弱的信号[35]。堆叠集成学习的核心优势在于引入的元学习器,能够有效识别并采纳各基模型的最佳解释模式[36]。通过该动态权重分配机制,模型能够针对输入数据的不同量程自发选择最优算法进行组合,从而有效提升模型精度[37]。

堆叠集成学习模型的构建涉及多个学习器的分布式训练,虽然在处理多源数据时表现出其优越的性能,但同时也增加了计算复杂度。同时,其“黑箱”特性也制约了模型的规模化应用。后续研究将聚焦模型轻量化设计,并结合 SHAP 等可解释性分析工具,在维持模型高精度的同时提升决策过程的透明度,从而推动其在现代农业生产中的实际应用。

4 结论

(1)多源特征融合能够显著提升冬油菜叶面积指数的估测精度。融合光谱特征、纹理特征和株高时模型精度最高,相较于单一光谱特征 R^2 提升了 9.41%,达到 0.93,MAE 和 RMSE 分别为 0.27 和 0.33。纹理特征包含的空间异质信息与株高提供的垂直信息能有效弥补冬油菜郁闭冠层下光谱特征对 LAI 的估测不足。

(2)堆叠集成学习算法在冬油菜叶面积指数估测中具备较好的性能优势,在多源特征融合下估测精度较最优单一机器学习模型(随机森林)提升了 8.14%。通过元学习器有效识别各基学习器的局部拟合优势,实现了对复杂非线性特征模式的深度挖掘。

(3)冬油菜叶面积指数空间分布图能够有效反映农田微尺度不同栽培处理下油菜长势空间差异,揭示冬油菜叶面积指数随生育期先升后降的时序规律以及随施肥水平梯度递增的正向驱动效应,为田间精准管理与决策提供直观的数字化底图。

参 考 文 献

[1] Wang C, Xu M, Wang Y, et al. Long-term optimal management of rapeseed cultivation simulated with the CROPGRO-canola model[J]. Agronomy, 2022, 12(5): 1191.

[2] Zhang W, Li Z, Pu Y, et al. Estimation of the leaf area index of winter rapeseed based on hyperspectral and machine learning [J]. Sustainability, 2023, 15(17): 12930.

[3] Song B, Liu L, Du S, et al. ValLAI_Crop, a validation dataset for coarse-resolution satellite LAI products over Chinese cropland[J]. Scientific Data, 2021, 8(1): 243.
[4] Wang C, Ling L, Kuai J, et al. Integrating UAV and satellite LAI data into a modified DSSAT-rapeseed model to improve yield predictions[J]. Field Crops Research, 2025, 327: 109883.
[5] Liu S, Jin X, Nie C, et al. Estimating leaf area index using unmanned aerial vehicle data: shallow vs. deep machine learning algorithms[J]. Plant Physiology, 2021, 187(3): 1551 – 1576.
[6] Zhu H, Lin C, Dong Z, et al. Early yield prediction of oilseed rape using UAV-based hyperspectral imaging combined with machine learning algorithms[J]. Agriculture, 2025, 15(10): 1100.
[7] Peng Y, Zhu T, Li Y, et al. Remote prediction of yield based on LAI estimation in oilseed rape under different planting methods and nitrogen fertilizer applications[J]. Agricultural and Forest Meteorology, 2019, 271: 116 – 125.
[8] Yuan W, Meng Y, Li Y, et al. Research on rice leaf area index estimation based on fusion of texture and spectral information [J]. Computers and Electronics in Agriculture, 2023, 211: 108016.
[9] Liu Y, Feng H, Yue J, et al. Remote-sensing estimation of potato above-ground biomass based on spectral and spatial features extracted from high-definition digital camera images[J]. Computers and Electronics in Agriculture, 2022, 198: 107089.
[10] Cheng Q, Ding F, Xu H, et al. Quantifying corn LAI using machine learning and UAV multispectral imaging[J]. Precision Agriculture, 2024, 25(4): 1777 – 1799.
[11] Sun X, Yang Z, Su P, et al. Non-destructive monitoring of maize LAI by fusing UAV spectral and textural features[J]. Frontiers in Plant Science, 2023, 14: 1158837.
[12] Zhai W, Li C, Cheng Q, et al. Exploring multisource feature fusion and stacking ensemble learning for accurate estimation of maize chlorophyll content using unmanned aerial vehicle remote sensing[J]. Remote Sensing, 2023, 15(13): 3454.
[13] Chen Z, Zhai W, Cheng Q. Enhancing maize LAI estimation accuracy using unmanned aerial vehicle remote sensing and deep learning techniques[J]. Artificial Intelligence in Agriculture, 2025, 15(3): 482 – 495.
[14] Breiman L. Random forests[J]. Machine Learning, 2001, 45(1): 5 – 32.
[15] Friedman J H. Greedy function approximation: a gradient boosting machine[J]. Annals of Statistics, 2001, 29(5): 1189 – 1232.
[16] Cortes C, Vapnik V. Support-vector networks[J]. Machine Learning, 1995, 20(3): 273 – 297.
[17] 刘帅兵, 金秀良, 冯海宽, 等. 病害胁迫下玉米 LAI 遥感反演研究[J]. 农业机械学报,2023, 54(3): 246 – 258.
Liu Shuaibing, Jin Xiuliang, Feng Haikuan, et al. Research on remote sensing retrieval of maize LAI under disease stress[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(3): 246 – 258. (in Chinese)
[18] 涂丽珍, 郭小燕, 冯浩, 等. 基于集成学习的甘肃省粮食产量预测[J]. 智慧农业导刊, 2025, 5(5): 9 – 13.
Tu Lizhen, Guo Xiaoyan, Feng Hao, et al. Research on grain yield prediction in Gansu Province based on ensemble learning [J]. Journal of Smart Agriculture, 2025, 5(5): 9 – 13. (in Chinese)
[19] Wang F, Yang M, Ma L, et al. Estimation of above-ground biomass of winter wheat based on consumer-grade multi-spectral UAV[J]. Remote Sensing, 2022, 14(5): 1251.
[20] Carlson T N, Ripley D A. On the relation between NDVI, fractional vegetation cover, and leaf area index[J]. Remote Sensing of Environment, 1997, 62(3): 241 – 252.
[21] Rondeaux G, Steven M, Baret F. Optimization of soil-adjusted vegetation indices[J]. Remote Sensing of Environment, 1996, 55(2): 95 – 107.
[22] Ljubičić N, Popović V, Kostić M, et al. The normalized difference red edge index (NDRE) in grain yield and biomass estimation in maize (*Zea mays* L.)[C]// Proceedings of the XV International Scientific Agricultural Symposium Agrosym, 2024: 373 – 378.
[23] Gurung R B, Breidt F J, Dutin A, et al. Predicting enhanced vegetation index (EVI) curves for ecosystem modeling applications[J]. Remote Sensing of Environment, 2009, 113(10): 2186 – 2193.
[24] Shaver T, Khosla R, Westfall D. Utilizing green normalized difference vegetation indices (GNDVI) for production level management zone delineation in irrigated corn[C]// Proceedings of the 18th World Congress of Soil Science, 2006.
[25] Barati S, Rayegani B, Saati M, et al. Comparison the accuracies of different spectral indices for estimation of vegetation cover fraction in sparse vegetated areas[J]. The Egyptian Journal of Remote Sensing and Space Science, 2011, 14(1): 49 – 56.
[26] Wei C, Huang J, Mansaray L R, et al. Estimation and mapping of winter oilseed rape LAI from high spatial resolution satellite data based on a hybrid method[J]. Remote Sensing, 2017, 9(5): 488.
[27] Kanaparthi S K, Raju U S N. Image retrieval by using texture and shape correlated hand crafted features[J]. International Journal of Computational Vision and Robotics, 2023,13(4):437 – 468.
[28] 王鹏新, 王静怡, 郭丰玮, 等. 基于遥感多参数和 Stacking 集成学习的冬小麦单产估测[J]. 农业机械学报, 2025, 56(11): 369 – 377.
Wang Pengxin, Wang Jingyi, Guo Fengwei, et al. Estimation of winter wheat yield based on remote sensing multi-parameters and Stacking ensemble learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(11): 369 – 377. (in Chinese)

(下转第 164 页)

Li Yang, Zhao Bo, Zhou Liming, et al. Combining multiple type parameters for estimating winter wheat SPAD values at jointing stage[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(7): 513 - 521. (in Chinese)

[34] Zhu Y, Huang X, Yin C, et al. Key parameters determination based on seed movement process simulation for rice strip aerial seeding via UAV[J]. Computers and Electronics in Agriculture, 2025, 237: 110596.

[35] 黄小毛,刘宇,朱耀宗,等. 稻油兼用型成条飞播装置设计与试验[J]. 农业机械学报,2023,54(9):111 - 121.
Huang Xiaomao, Liu Yu, Zhu Yaozong, et al. Design and experiment of striped aerial seeding device for rice and oil rape[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(9): 111 - 121. (in Chinese)

[36] 曹兰芹,伍晓明,杨睿,等. 不同氮吸收效率品种油菜氮素营养特性的差异[J]. 作物学报,2012,38(5):887 - 895.
Cao Lanqin, Wu Xiaoming, Yang Rui, et al. Differences of nitrogen status between different N uptake efficiency rapeseed (*Brassica napus* L.) cultivars[J]. Acta Agronomica Sinica, 2012, 38(5): 887 - 895. (in Chinese)

[37] 王玉乾,巢成生,代晶,等. 不同氮效率油菜苗期碳氮代谢差异[J]. 中国油料作物学报,2022,44(3):589 - 601.
Wang Yuqian, Chao Chengsheng, Dai Jing, et al. Difference in carbon and nitrogen metabolism of rapeseed (*Brassica napus* L.) with contrasting nitrogen efficiency at seedling stage[J]. Chinese Journal of Oil Crop Sciences, 2022, 44(3): 589 - 601. (in Chinese)

[38] 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)

(上接第 133 页)

[29] Zhang X, Zhang K, Sun Y, et al. Combining spectral and texture features of UAS-based multispectral images for maize leaf area index estimation[J]. Remote Sensing, 2022, 14(2): 331.

[30] Cover T, Hart P. Nearest neighbor pattern classification[J]. IEEE Transactions on Information Theory, 1967, 13(1): 21 - 27.

[31] Hoerl A E, Kennard R W. Ridge regression: biased estimation for nonorthogonal problems[J]. Technometrics, 1970, 12(1): 55 - 67.

[32] Zhang J, Qiu X, Wu Y, et al. Combining texture, color, and vegetation indices from fixed-wing UAS imagery to estimate wheat growth parameters using multivariate regression methods[J]. Computers and Electronics in Agriculture, 2021, 185: 106138.

[33] Xu J, Quackenbush L J, Volk T A, et al. Forest and crop leaf area index estimation using remote sensing: research trends and future directions[J]. Remote Sensing, 2020, 12(18): 2934.

[34] Du R, Lu J, Xiang Y, et al. Estimation of winter canola growth parameter from UAV multi-angular spectral-texture information using stacking-based ensemble learning model[J]. Computers and Electronics in Agriculture, 2024, 222: 109074.

[35] Han Y, Zhang J, Bai Y, et al. Ensemble learning-driven and UAV multispectral analysis for estimating the leaf nitrogen content in winter wheat[J]. Agronomy, 2025, 15(7): 1621.

[36] Li Z, Zhou X, Cheng Q, et al. A machine-learning model based on the fusion of spectral and textural features from UAV multi-sensors to analyse the total nitrogen content in winter wheat[J]. Remote Sensing, 2023, 15(8): 2152.

[37] Tang Z, Lu J, Abdelghany A E, et al. Winter oilseed rape LAI inversion via multi-source UAV fusion: a three-dimensional texture and machine learning approach[J]. Plants, 2025, 14(8): 1245.