doi:10.6041/j.issn.1000-1298.2026.17.007

融合 Boruta－RFE 与注意力机制的玉米地上生物量无人机遥感估算与单产预测方法

边明博[1,2]　张益兴[1,2]　樊杰杰[1,2]　樊意广[1,2]　胡海棠[1,2]　冯海宽[1,2]　董　静[2]
（1.北京市农林科学院信息技术研究中心，北京 100097；2.农芯科技（北京）有限责任公司，北京 100097）

摘要：为提高我国东北黑土区保护性耕作条件下地上玉米生物量估算与单产预测精度，以吉林省梨树县春玉米试验区为对象，利用无人机获取的可见光影像（Red－Green－Blue，RGB）、多光谱和热红外等多源影像，构建融合 Boruta 递归特征消除法（Boruta-recursive feature elimination，Boruta－RFE）、极端梯度提升算法（eXtreme gradient boosting，XGBoost）地上生物量估算与轻量注意力机制的单产预测方法。结果表明：不同生育期的地上生物量敏感特征存在明显阶段差异，热红外温度统计特征、多光谱纹理特征和 RGB 颜色指数均具有较高重要性；基于 3 类特征融合的 XGBoost 模型在 3 个关键生育期均取得较好地上生物量估算效果，其中灌浆期验证集决定系数最高，成熟期验证集均方根误差（Root mean square error，RMSE）最低；仅采用无人机（Unmanned aerial vehicle，UAV）特征进行单产预测时，XGBoost 综合表现最佳，验证集 R^2 为 0.700；进一步融合关键生育期地上生物量估算值后，各模型精度均提升，其中轻量注意力神经网络（Lightweight attention neural network，LANN）最优，验证集 R^2 和 RMSE 分别达到 0.855 和 0.935 t/hm^2。研究表明，无人机多源影像与地上生物量信息融合可显著提升玉米单产预测精度。

关键词：玉米；无人机遥感；Boruta－RFE；地上生物量；单产预测；注意力机制
中图分类号：S25　　**文献标识码**：A　　**文章编号**：1000-1298(2026)17-0076-10　　**OSID**：

Maize Aboveground Biomass Estimation and Yield Prediction Using UAV Remote Sensing Imagery with Boruta－RFE and Lightweight Attention Mechanism

Bian Mingbo[1,2]　Zhang Yixing[1,2]　Fan Jiejie[1,2]　Fan Yiguang[1,2]　Hu Haitang[1,2]　Feng Haikuan[1,2]　Dong Jing[2]
（1. *Research Center of Information Technology, Beijing Academy of Agriculture and Forestry Sciences, Beijing* 100097, *China*
2. *Nongxin Science and Technology (Beijing) Co., Ltd., Beijing* 100097, *China*）

Abstract: Aiming to improve the accuracy of maize aboveground biomass estimation and yield prediction under conservation tillage in the black soil region of Northeast China, the research was conducted in a spring maize experimental area in Lishu County, Jilin Province. Based on RGB, multispectral, and thermal infrared images acquired by unmanned aerial vehicles (UAVs), a modeling framework integrating Boruta－RFE feature selection, stage-wise XGBoost aboveground biomass estimation, and a lightweight attention mechanism for yield prediction was developed. The results showed that the aboveground biomass-sensitive features exhibited clear stage-specific differences, and thermal infrared temperature statistics, multispectral texture features, and RGB color indices showed high importance. The XGBoost model based on the fusion of RGB, multispectral, and thermal infrared features achieved good aboveground biomass estimation performance at all three growth stages, with the highest validation R^2 at the grain-filling stage and the lowest validation NRMSE at the maturity stage. When only UAV-derived features were used for yield prediction, XGBoost showed the best overall performance, with a validation R^2 of 0.700. After further incorporating the predicted aboveground biomass values from the three stages, the prediction accuracy of all models improved, among which the lightweight attention-based neural network performed best, with validation R^2 and RMSE reaching 0.855 and 0.935 t/hm^2, respectively. These results indicated that integrating UAV multi-source imagery with stage-wise

收稿日期：2026－05－21　修回日期：2026－05－26
基金项目：国家重点研发计划项目（2024YFD1500802）
作者简介：边明博（1996—），男，博士生，主要从事农业定量遥感研究，E-mail：bianmingbo0515@163.com
通信作者：冯海宽（1982—），男，副研究员，博士生导师，主要从事农业定量遥感研究，E-mail：fenghaikuan123@163.com

aboveground biomass information can significantly improve maize yield prediction accuracy and provide technical support for maize growth monitoring and yield forecasting under conservation tillage conditions.

Key words: maize; UAV remote sensing; Boruta－RFE; aboveground biomass; yield prediction; attention mechanism

0　引言

玉米是全球重要粮食、饲料和能源作物，也是我国东北黑土区的主要旱作作物，对保障我国粮食安全具有重要意义[1]。东北黑土区长期高强度利用导致耕层变薄、地力下降和土壤结构退化等问题[2-3]。保护性耕作被认为是提升黑土地质量、稳定作物生产能力的重要途径，但不同耕作与施肥条件下玉米群体生长和单产形成过程具有显著空间异质性。因此，建立高效、无损、精确的玉米地上生物量估算和单产预测方法，对提高我国东北黑土区保护性耕作水平具有重要应用价值[4]。

无人机（Unmanned aerial vehicle，UAV）遥感兼具高空间分辨率、高时效性和灵活机动等优势，已广泛应用于作物长势监测、生物量估算和单产预测[5-6]。其中，红绿蓝（Red－Green－Blue，RGB）影像能够提供冠层颜色、覆盖度和纹理结构信息，多光谱影像能够通过红边和近红外波段表征叶绿素、氮素和冠层结构状态，热红外影像则能够反映冠层温度、水分胁迫和蒸腾调节过程[7-8]。与单一传感器相比，无人机多源影像融合能够从颜色、结构、光谱和温度等多个维度综合刻画作物生长状态，为提升地上生物量估算和单产预测精度提供数据基础[9-10]。

在无人机多源影像建模过程中，植被指数、颜色指数、纹理特征和温度统计量等变量数量较多，容易产生特征冗余和过拟合问题，因此需要采用稳健的特征筛选方法。Boruta 特征筛选方法能够通过影子特征识别与目标变量稳定相关的变量，递归特征消除法（Recursive feature elimination，RFE）能够进一步递归剔除冗余特征，两者结合有利于获得更精简且更稳定的特征子集。与此同时，随机森林（Random forest，RF）、支持向量回归（Support vector regression，SVR）和极端梯度提升（eXtreme gradient boosting，XGBoost）等机器学习方法已在作物参数反演中得到广泛应用，其中 XGBoost 在处理中小样本、非线性关系和高维特征方面具有较强优势。近年来，注意力机制也逐渐被用于多源遥感融合建模，其核心作用是根据输入变量贡献差异自适应分配权重，从而增强模型对关键生育期和关键特征的识别能力。

基于上述分析，本文以保护性耕作条件下的玉米为研究对象，提出一种融合 Boruta－RFE 特征筛选与轻量注意力机制的无人机多源影像建模方法，实现玉米地上生物量估算与单产预测。

1　材料与方法

1.1　研究区概况

本试验于 2025 年开展，研究区位于吉林省四平市梨树县（43°02′～43°46′N，123°45′～124°53′E），小区试验分布见图 1。该区属于典型东北春玉米种植区，气候为北温带半湿润大陆性季风气候，玉米生长季光热资源较充足，降水主要集中在 7—8 月。当地春玉米一般于 5 月上旬播种，主要经历拔节期、大喇叭口期、抽雄吐丝期、灌浆期和成熟期等阶段；本研究重点选取大喇叭口期（7 月 22 日）、灌浆期（8 月 10 日）和成熟期（9 月 2 日）开展无人机遥感与地面农学参数同步观测。

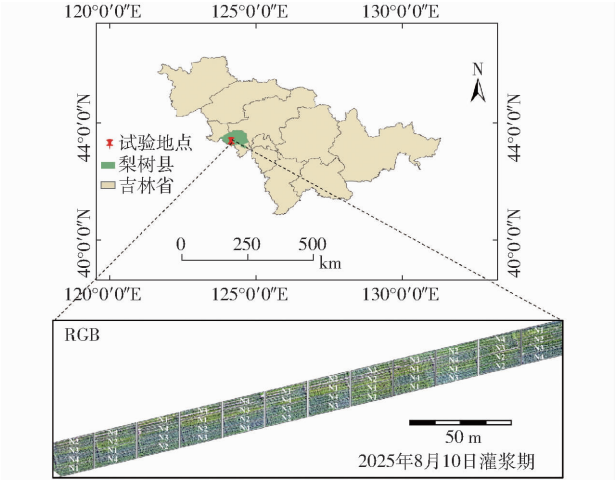

图 1　研究区位置及小区试验分布

Fig. 1　Location of study area and distribution of experimental plots

1.2　试验设计

本研究采用裂区试验设计，以耕作方式为主区、施氮水平为副区。主区设置 4 种耕作处理：W1，传统耕作（对照）；W2，深翻并秸秆粉碎还田；W3，免耕并秸秆覆盖；W4，免耕并秸秆条状覆盖。副区设置 4 个氮肥施用水平：N1，不施氮；N2，减量施氮，为当地常规施肥量的 50%；N3，常规施氮；N4，过量施氮，为当地常规施肥量的 150%。对应施氮量分别为：N1，0 kg/hm^2；N2，125 kg/hm^2；N3，250 kg/hm^2；N4，375 kg/hm^2。每种处理设置 3 次重复，每个小区尺寸为 3.6 m×20 m，共计 48 个小区。供试玉米为当地

主栽品种“良玉 66”,种植密度为 62 000 株/hm^2。除耕作方式和施氮量处理外,其余田间管理措施,包括灌溉、病虫草害防治等,均按当地常规生产标准执行。

1.3 数据获取与预处理

1.3.1 地面农学参数获取

本研究于玉米大喇叭口期(7 月 22 日)、灌浆期(8 月 10 日)和成熟期(9 月 2 日)同步开展无人机飞行试验和地面农学参数采集。每次无人机飞行结束后 2 h 内,在每个小区选取 3 株长势均匀且具有代表性的植株进行地面调查。每个生育期共调查 48 个小区,每小区 3 株,构建 144 株地上生物量测定样本,并以小区平均值作为模型样本单元。对于地上生物量测定,将样株齐地收割后测量株高,并分为茎和叶两部分,先于 105℃条件下杀青 30 min,再在 80℃条件下烘干至质量恒定后称量干质量,计算小区尺度单株地上生物量。成熟期对各小区进行单独收获并折算为小区平均单产,作为单产建模目标变量。建模过程中按比例 3∶1 划分建模集与验证集,并保持不同耕作和施氮处理在两类数据集中的代表性。

1.3.2 无人机遥感数据获取与预处理

本研究采用大疆精灵 4 多光谱版无人机(Phantom 4 Multispectral,P4M)获取试验区 RGB 和多光谱影像。P4M 集成 2 000 万像素 RGB 相机和五波段多光谱传感器,多光谱波段包括蓝光(约 450 nm)、绿光(约 560 nm)、红光(约 650 nm)、红边(约 730 nm)和近红外(约 840 nm),可同步获取高分辨率 RGB 影像和多光谱反射率数据,为作物长势监测提供多维信息支撑。

为获取冠层热状态信息,研究同步采集热红外影像,用于提取冠层表面温度及其空间分布特征,以表征植株热状况差异。热红外影像采用 DJI Mavic3T 无人机获取。该平台搭载非制冷氧化钒微测辐射热计(Uncooled VOx microbolometer),热红外影像分辨率为 640 像素 × 512 像素,像元尺寸为 12 μm。其测温范围在高增益模式下为 -20 ~ 150℃。飞行过程中获取的热红外影像主要用于提取冠层温度均值、标准差、分位数及温度纹理等特征,以表征不同处理下玉米冠层热状态差异。热红外采集时间尽量与 RGB 和多光谱飞行保持一致,以降低环境变化对多源数据一致性的影响。无人机影像如图 2 所示。

影像采集前利用 DJI GS Pro 进行航线规划,采用网格化飞行模式。飞行期间传感器垂直对地拍摄,曝光模式设为自动;所有作业均在晴朗、低风速天气的 10:00—14:00 进行。航向和旁向重叠率均设为 80%。无人机数码和多光谱影像飞行高度分别为 20 m 和 30 m,对应地面采样距离(Ground sampling distance,GSD)约为 0.5 cm 和 2.4 cm。每次飞行前后均拍摄 95% 标准反射率板,用于多光谱辐射定标。

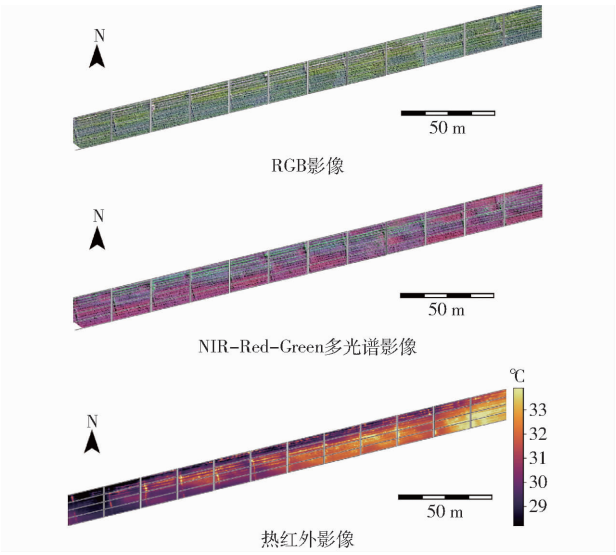

图 2 灌浆期 RGB、多光谱及热红外小区试验正射影像

Fig. 2 Positive projection imaging of RGB, multi-spectral, and thermal infrared colony experiments during plating phase

飞行结束后,利用 DJI Terra 完成辐射校正、影像配准、空三解算、点云生成以及数字正射影像图(Digital orthophoto map, DOM)和数字表面模型(Digital surface model,DSM)拼接。随后基于各小区矢量边界提取感兴趣区域(Region of interest,ROI)内有效像元均值,用于后续植被指数计算和模型构建。所有处理结果均以 GeoTIFF 格式存储,坐标系统一为 1984 世界大地坐标系(World geodetic system 1984, WGS84)/通用横轴墨卡托投影(Universal transverse Mercator,UTM)51N 分带。

1.4 无人机多源遥感特征提取与筛选

基于预处理后的无人机 RGB 影像分别提取了红、绿、蓝通道均值,冠层覆盖度,灰度共生矩阵纹理特征(Gray-level co-occurrence matrix,GLCM);多光谱影像提取了绿光、红光、红边和近红外波段的反射率均值及其纹理特征;在此基础上,进一步计算了多光谱植被指数,包括 NDVI[11]、GNDVI[11]、NDRE[11]、SAVI[11]、OSAVI[11]、MSAVI[11]、EVI2[12]、DVI[12]、RVI[12]、IPVI[12]、CIgreen[12]、CIrededge[12]、MTCI[12]、NLI[13]、TVI[13]、RDVI[13]、WDRVI[13]、MCARI[13]、TCARI[13]和 MTVI2[13]。此外,热红外影像用于提取冠层温度均值、标准差、最大值、最小值及不同分位数特征,并结合热红外纹理特征表征冠层温度空间异质性。所有影像特征均基于小区 ROI 进行统计提取,并作为后续机器学习模型的输入变量。

为增强对小区内部空间异质性的表征，部分特征进一步计算均值、标准差、分位数和纹理统计量。随后采用 Boruta 与 RFE 联合筛选关键变量：首先，Boruta 通过构建随机打乱的影子特征，并比较真实特征与影子特征的重要性，识别与目标变量稳定相关的候选变量；其次，RFE 以模型重要性为依据递归剔除贡献较低的冗余变量，获得用于地上生物量估算和单产预测的优选特征子集。本文对特征筛选过程重复 30 次，并以平均重要性表征特征稳定性。

1.5　模型构建方法

本文采用两阶段建模策略。第 1 阶段针对大喇叭口期、灌浆期和成熟期分别提取 RGB、多光谱和热红外特征，并利用 Boruta－RFE 筛选得到各时期地上生物量估算的优选特征子集；在此基础上，以实测地上生物量为目标变量，构建 XGBoost 模型，获得 3 个关键生育期的地上生物量估算值。

第 2 阶段以最终单产为目标变量，对 3 个生育期的多源遥感特征分别进行 Boruta－RFE 筛选，并构建 RF、SVR 和 XGBoost 单产预测模型。在此基础上，进一步建立轻量注意力神经网络模型，将 3 个生育期筛选后的遥感特征及对应地上生物量估算值共同输入，通过特征编码和注意力加权实现单产预测。

1.6　精度验证与评价指标

为保证不同模型结果可比，建模前对输入特征进行统一预处理，并采用一致的数据集划分方式进行训练和验证。模型性能采用决定系数（Coefficient of determination，R^2）、均方根误差（Root mean square error，RMSE）和归一化均方根误差（Normalized root mean square error，NRMSE）进行评价。

2　结果与分析

2.1　关键生育期地上生物量特征筛选结果

针对地上生物量目标变量，分别在大喇叭口期、灌浆期和成熟期 3 个关键生育期开展特征筛选。结果如图 3 所示，不同时期敏感特征具有明显阶段性差异，且 RGB、多光谱和热红外信息在不同生育阶段表现出较强的互补性。

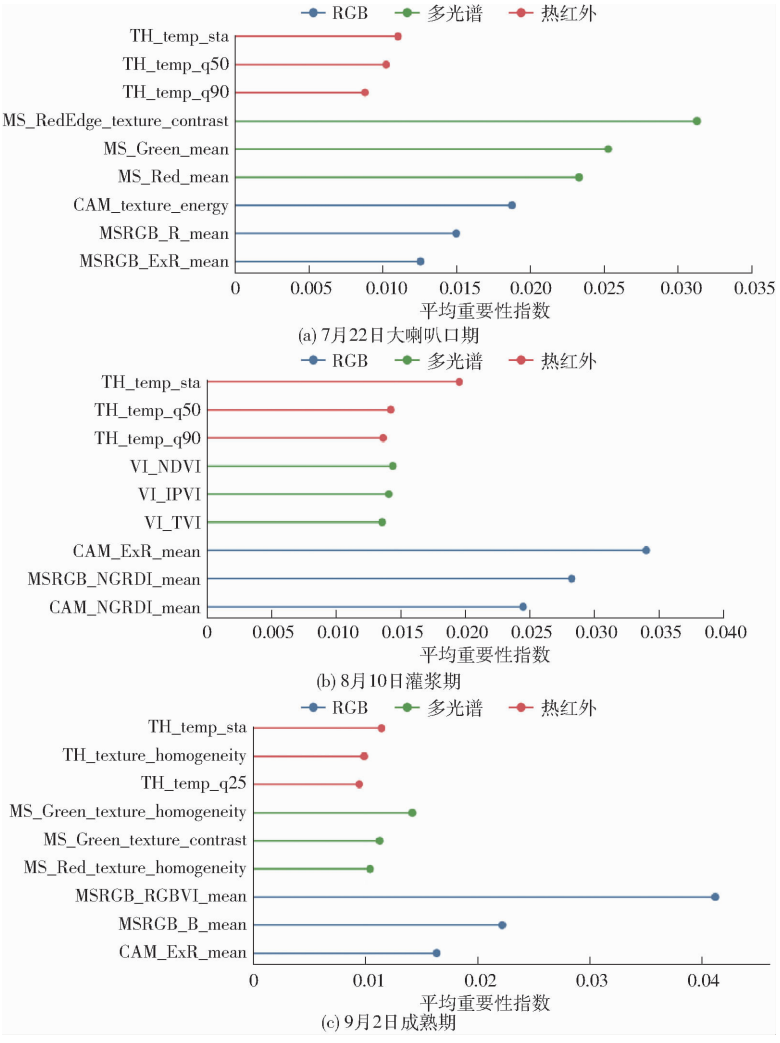

图 3　关键生育期地上生物量特征的 30 次重复筛选平均重要性指数

Fig. 3　Average importance of 30-repeated screening of aboveground biomass characteristics at critical crop growth stages

在大喇叭口期，RGB 特征中，CAM_texture_energy、MSRGB_R_mean 和 MSRGB_ExR_mean 的平均重要性位居前列，说明该时期地上生物量对冠层纹理能量、红光均值及超额红指数较为敏感；多光谱特征中，MS_RedEdge_texture_contrast、MS_Green_mean 和 MS_Red_mean 表现最优，表明红边纹理与可见光波段均值对早期地上生物量表征具有较强作用；热红外特征中，TH_temp_std、TH_temp_q90 和 TH_temp_q50 的平均重要性较高，说明温度离散程度及高、中位分位温度能够较好反映该时期植株长势差异。

在灌浆期，RGB 特征中，CAM_ExR_mean、MSRGB_NGRDI_mean 和 CAM_NGRDI_mean 综合表现最佳，说明中期地上生物量与颜色指数特征的关系进一步增强；多光谱特征中，VI_NDVI、VI_TVI 和 VI_TCARI 排名靠前，表明灌浆期地上生物量更容易被植被指数类特征刻画；热红外特征中，TH_temp_mean、TH_temp_q05 和 TH_temp_q75 的平均重要性较高，说明该时期地上生物量与冠层整体热状态及温度分位特征关系更加密切。

在成熟期，RGB 特征中，MSRGB_RGBVI_mean、MSRGB_B_mean 和 CAM_ExR_mean 的平均重要性位列前位，说明成熟期地上生物量仍对颜色指数和蓝光信息较为敏感；多光谱特征中，MS_Green_texture_homogeneity、MS_Green_texture_contrast 和 MS_Red_mean 排名靠前，表明后期地上生物量更多受到多光谱纹理和局部波段信息表征；热红外特征中，TH_temp_std、TH_temp_q25 和 TH_temp_mean 表现较优，说明成熟前后地上生物量与冠层温度波动及温度统计量仍保持较强关联。

总体看，地上生物量相关特征呈现明显的时序变化规律：大喇叭口期更多体现为红边纹理、可见光均值和温度离散特征；灌浆期以颜色指数、植被指数和温度统计特征为主；成熟期则更多表现为综合指数与纹理特征占优。这表明，随着生育进程推进，不同传感器特征对地上生物量的响应机制发生动态变化，多源遥感特征融合有助于提高地上生物量表征的完整性和稳定性。

2.2 关键生育期地上生物量估算结果

基于 RGB、多光谱和热红外特征融合的 XGBoost 模型在大喇叭口期、灌浆期和成熟期对地上生物量进行估算，结果如表 1 所示。估算结果散点图如图 4 所示，总体来看，3 个生育期模型均取得了较好的拟合与估算效果，表明多源遥感特征能够较好表征玉米冠层生长状态及其与地上生物量之间的响应关系。

表 1 融合无人机多源遥感信息估算玉米地上生物量

Tab. 1 Estimating maize aboveground biomass with integrated UAV multi-source telemetry information

生育期	建模集			验证集		
	R^2	RMSE/(t·hm^{-2})	NRMSE/%	R^2	RMSE/(t·hm^{-2})	NRMSE/%
大喇叭口期	0.913 **	0.365	13.82	0.739 **	0.689	25.41
灌浆期	0.895 **	0.585	14.63	0.841 **	0.668	17.49
成熟期	0.867 **	1.339	17.28	0.816 **	1.218	15.80

注：* 和 ** 分别表示实测值与估算值之间的相关性在 0.05 和 0.01 水平上显著，样本量 $n=48$，下同。

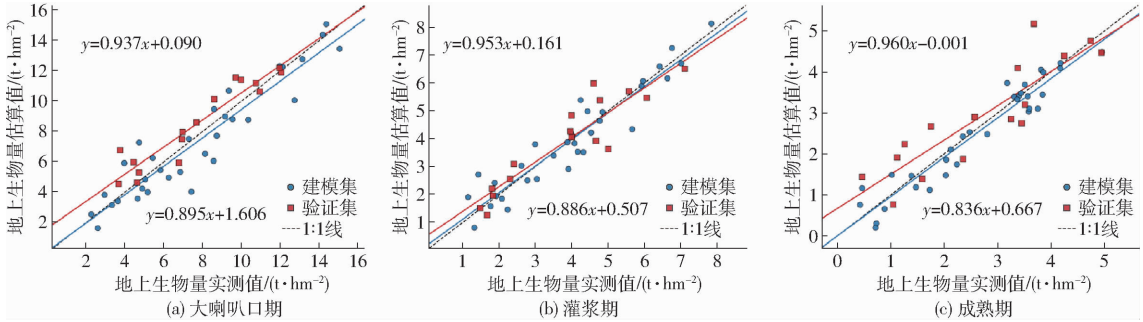

图 4 融合无人机多源遥感信息的玉米地上生物量估算值和实测值散点图

Fig. 4 Scatter plots of real measurements and estimated values for maize aboveground biomass at three growth stages using UAV remote sensing information

建模集结果主要用于反映模型拟合能力。3 个生育期建模集 R^2 均高于 0.86，说明融合特征能够较好拟合地上生物量变化；但模型泛化能力应主要依据验证集结果进行判断，因此下文重点分析验证集 R^2、RMSE 和 NRMSE。

验证集结果表明，大喇叭口期、灌浆期、成熟期模型的 R^2 分别为 0.739、0.841、0.816，RMSE 分别为 0.689、0.668、1.218 t/hm^2，NRMSE 分别为

25.41%、17.49%、15.80%。其中，灌浆期验证集 R^2 最高，表明该时期模型具有最优的泛化能力；成熟期验证集 NRMSE 最低，说明模型在该时期的相对误差控制更优。相比之下，大喇叭口期虽然建模集拟合精度较高，但验证集误差相对较大，说明该时期模型稳定性仍略弱于灌浆期和成熟期。小区及反演图如图 5 所示。

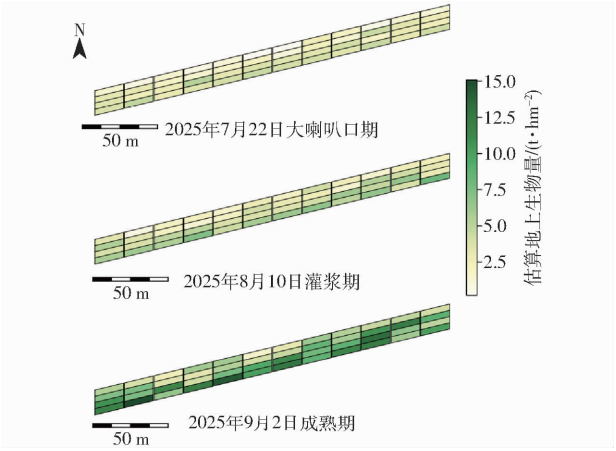

图 5　XGBoost 模型 3 个生育期地上生物量估算结果

Fig. 5　Aboveground biomass estimation results of XGBoost model across three growth stages

2.3　单产特征筛选结果

针对单产目标变量，本文将 3 个关键生育期的遥感特征共同输入同一轮筛选流程，以 30 次重复筛选的平均重要性指数作为主评价指标。结果如图 6 所示，最终单产形成受到多时期冠层信息的共同影响，其中大喇叭口期特征整体贡献较高，灌浆期和成熟期部分颜色指数及覆盖度特征也进入前列。

在 RGB 特征中，MSRGB_RGBVI_mean_0810、MSRGB_RGBVI_mean_0902、CAM_canopy_cover_0810 和 MSRGB_B_mean_0902 的平均重要性指数相对较高，说明中后期颜色指数与冠层覆盖信息对最终单产具有较强指示作用。

在多光谱特征中，MS_RedEdge_texture_contrast_0722、MS_Green_texture_contrast_0722、MS_Red_mean_0722 和 MS_Red_texture_contrast_0722 排名靠前，其中红边纹理对比度的平均重要性最高，表明早期红边纹理变化与最终单产之间具有最紧密的联系；绿光纹理与红光均值同样能够较好反映与单产相关的冠层结构和光谱差异。

在热红外特征中，TH_temp_std_0722、TH_temp_mean_0810、TH_temp_q05_0810 和 TH_temp_q50_0810 的平均重要性相对较高。虽然热红外特征整体弱于多光谱特征，但早期冠层温度离散程度以及中期温度统计量仍表现出一定筛选优势，说明植株热状态差异对最终单产具有补充指示作用。

2.4　不同模型的单产预测结果

2.4.1　基于筛选特征的不同模型单产预测结果

表 2 给出了仅采用 UAV 特征时不同模型的单产预测结果，其中包括 RF、SVR、XGBoost 以及轻量神经网络-注意力模型。建模及验证的散点图如图 7 所示。

建模集结果主要用于表征模型拟合能力。仅采用 UAV 特征时，不同模型在建模集上均能获得一定拟合效果，其中 XGBoost 拟合效果较优；但考虑到建模集结果不能代表泛化能力，本文重点依据验证集结果比较不同模型性能。

从验证集结果看，RF、SVR、XGBoost 和轻量神经网络-注意力模型的 R^2 分别为 0.639、0.642、0.700、0.699，RMSE 分别为 1.478、1.472、1.347、

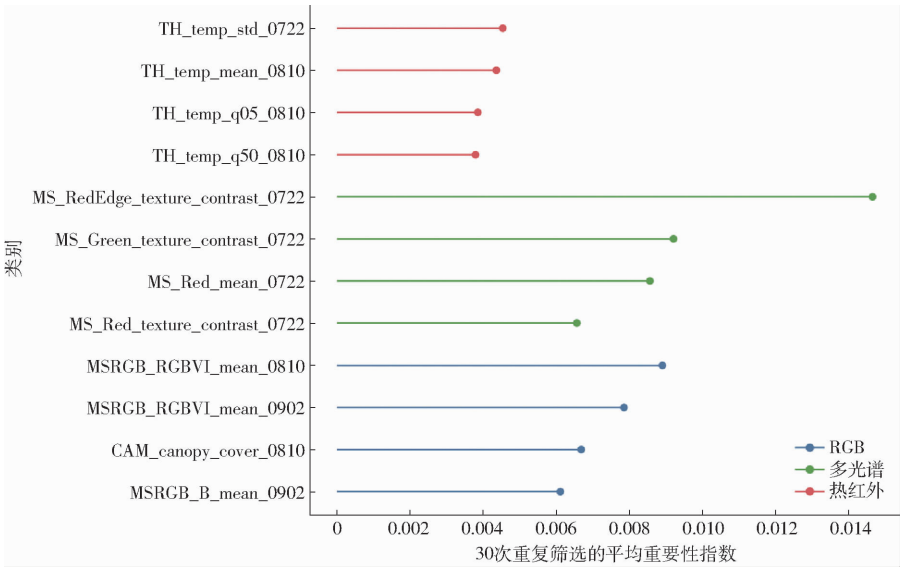

图 6　3 个关键生育期单产特征的 30 次重复筛选平均重要性指数

Fig. 6　Average importance of 30-repeated screening for yield characteristics at three critical growth stages

1.349 t/hm^2，NRMSE 分别为 14.93%、14.86%、13.61%、13.63%。总体上，各模型均表现出一定的单产预测能力，但不同模型间仍存在差异。其中，XGBoost 与轻量神经网络-注意力模型在验证集上的表现接近，XGBoost 的 R^2 略高，而 RF 和 SVR 模型整体略低。

表 2 融合无人机多源遥感信息预测玉米单产统计结果

Tab. 2 Predicting maize yield with integrated UAV multi-source remote sensing information

机器学习算法	建模集			验证集		
	R^2	RMSE/(t·hm^{-2})	NRMSE/%	R^2	RMSE/(t·hm^{-2})	NRMSE/%
RF	0.668 **	1.489	15.09		1.478	14.93
SVR	0.605 **	1.624	16.47	0.642 **	1.472	14.86
XGBoost	0.785 **	1.187	12.14	0.700 **	1.347	13.61
轻量神经网络	0.738 **	1.322	13.40	0.699 **	1.349	13.63

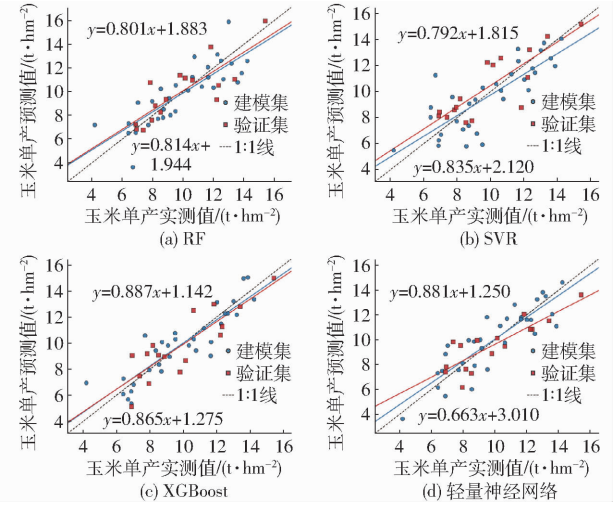

图 7 融合无人机多源遥感信息的不同模型玉米单产预测值和实测值散点图

Fig. 7 Scatter plots of real measurements and predicted values for maize yield using integrated UAV multi-source remote sensing information

2.4.2 融合关键生育期地上生物量估算值后的不同模型单产预测结果

在 UAV 特征基础上进一步引入 3 个生育期地上生物量估算值后，各模型预测精度均有所提升，表明不同生育期地上生物量信息能够增强对单产过程的表征能力。模型建模和验证精度如表 3 所示，建模及预测散点图如图 8 所示。

融合 3 个生育期地上生物量估算值后，建模集结果显示各模型拟合能力均有所提升，说明分期地上生物量信息能够为单产建模提供额外的生长积累信息。考虑到模型应用更关注外部预测能力，以下重点分析验证集结果。

从验证集结果看，融合特征后的提升更加明显。RF、SVR、XGBoost 和轻量神经网络模型的 R^2 分别达到 0.769、0.706、0.794 和 0.855，较仅采用 UAV 特征时分别提升 20.5%、10.0%、13.4% 和 22.4%；对应 RMSE 分别降至 1.181、1.333、1.117、0.935 t/hm^2，降幅分别为 20.1%、9.4%、17.1% 和 30.7%。其中，轻量神经网络模型在验证集上表现最优，且相较基线方案提升幅度最大，其 R^2、RMSE 分别为 0.855 和 0.935 t/hm^2，说明该模型在融合分期地上生物量信息后具有最优的泛化性能。

进一步从轻量神经网络模型的权重分配结果看，多光谱特征、地上生物量、RGB 特征和热红外特征的注意力权重占比分别为 0.32、0.26、0.24 和 0.18，说明在多源融合条件下，多光谱特征贡献最大，地上生物量次之，RGB 和热红外也提供了有效补充。融合无人机多源遥感信息与地上生物量轻量级神经网络模型小区级单产预测反演图如图 9 所示。

表 3 融合无人机多源遥感信息与地上生物量的玉米单产预测统计结果

Tab. 3 Estimation of maize yield through combining UAV multi-source remote sensing data and aboveground biomass information

机器学习算法	建模集			验证集		
	R^2	RMSE/(t·hm^{-2})	NRMSE/%	R^2	RMSE/(t·hm^{-2})	NRMSE/%
RF	0.738 **	1.324	13.89	0.769 **	1.181	13.53
SVR	0.744 **	1.181	14.47	0.706 **	1.333	15.26
XGBoost	0.819 **	1.100	12.64	0.794 **	1.117	13.02
轻量神经网络	0.821 **	1.093	12.20	0.855 **	0.935	11.58

2.5 不同模型综合比较

综合不同特征组合结果可知，融合分期地上生物量估算值优于仅使用 UAV 特征，且不同模型对特征融合的响应程度存在明显差异。

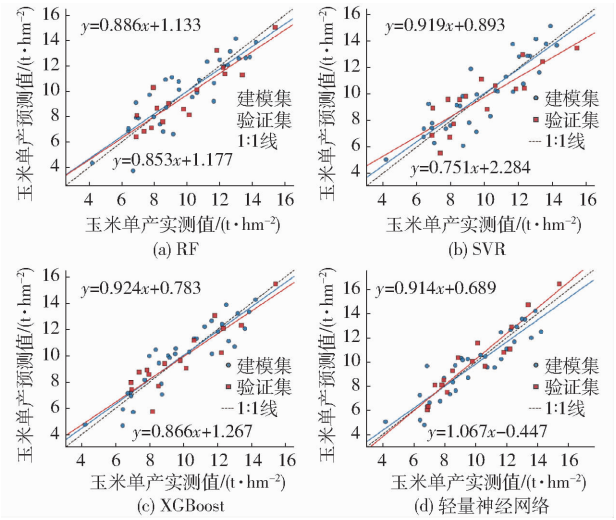

图 8　基于多源信息融合的不同模型玉米单产预测值与实测值散点图

Fig. 8　Scatter plots of measured and predicted maize yield for different models based on multi-source information fusion

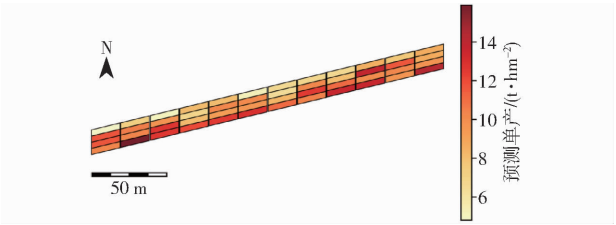

图 9　融合无人机多源遥感信息与地上生物量轻量神经网络单产预测结果

Fig. 9　Yield prediction results based on lightweight neural network integrating UAV multi-source remote sensing information and aboveground biomass

在仅采用 UAV 特征时，XGBoost 模型综合表现相对更优，与轻量神经网络模型整体接近。这表明 XGBoost 在处理中小样本条件下的高维非线性特征时具有较强优势，能够较好挖掘 UAV 遥感数据中与单产相关的有效信息。

在引入 3 个关键生育期地上生物量估算值后，轻量神经网络模型优势最为突出，其验证集 R^2 提升至 0.855，明显高于 RF、SVR 和 XGBoost，对应 RMSE 也降至最低。这说明在多源变量共同参与建模的情况下，注意力机制能够根据不同特征的重要性进行自适应加权，强化对关键变量的提取与利用，从而提升模型对复杂特征耦合关系的表达能力。相比之下，RF 和 SVR 虽然在融合特征后也有所改善，但提升幅度和最终精度均低于 XGBoost 和轻量神经网络模型，表明传统机器学习模型在面对多源异构信息时，对高阶交互关系的学习能力仍存在一定局限。

因此，在本研究条件下，若仅基于 UAV 遥感数据开展快速预测，XGBoost 是较优选择；若进一步引入 3 个生育期地上生物量估算值并开展多源协同建模，则轻量神经网络模型更适合作为最终单产预测模型。

3　讨论

3.1　多源遥感特征对地上生物量估算精度提升的作用机制

本研究中，基于 RGB、多光谱和热红外特征融合的 XGBoost 模型在 3 个生育期均取得较高精度的地上生物量估算结果，说明多源遥感信息在反映作物长势方面具有较强互补性。验证集 R^2 分别为 0.739、0.841 和 0.816，其中灌浆期相关性最高，成熟期 NRMSE 最低，表明中后期模型具有更好的泛化能力和误差控制能力。

从机理上看，RGB 特征反映冠层颜色和纹理差异，多光谱特征表征叶片生化组成和冠层光谱响应，尤其红边和近红外波段与叶绿素状态、群体结构、干物质积累密切相关；热红外特征则反映冠层温度分布以及蒸腾和水分代谢状态。3 类特征融合后可从颜色、结构、光谱和温度多个维度共同刻画作物生长过程，因此有利于提高地上生物量估算精度[14－15]。

不同生育时期模型表现的差异说明，作物生长阶段会影响遥感特征对地上生物量的敏感程度。大喇叭口期植株处于快速营养生长阶段，样本差异开始显现，因此建模集拟合能力较强；但由于群体结构尚未完全稳定，验证集 R^2 相对较低。相比之下，灌浆期和成熟期植株群体结构及地上生物量积累更稳定，遥感变量与目标变量关系更明确，因此模型精度更高。

3.2　关键生育期地上生物量估算值对单产预测的增益作用

单产形成受多因素共同作用，仅依赖 UAV 表型特征虽能反映冠层外在状态，但对植株生长积累过程的刻画仍有限。本研究表明，在 UAV 特征基础上引入 3 个生育期地上生物量估算值后，各模型验证集 R^2 均有所提升，其中轻量神经网络模型由 0.699 提升至 0.855，增幅最大，说明分期地上生物量信息在单产预测中具有显著增益作用。

从机理上看，地上生物量反映了不同生育阶段的干物质积累水平，是最终形成单产的重要物质基础。将 3 个关键时期的地上生物量估算值引入单产模型，相当于在遥感表型特征基础上补充了作物生长过程信息，使模型能够更完整地描述从冠层表征到物质积累再到单产的传递路径，因此更有助于提高对单产差异的解释能力[16－17]。

轻量神经网络模型在融合分期地上生物量特征后取得最优结果，说明当特征来源更丰富、变量关系

更复杂时,具备权重分配能力的模型更有利于挖掘多源变量之间的耦合关系。

3.3 不同模型性能差异的原因分析

本研究中,不同模型在两类任务中表现出不同优势。对于地上生物量估算,XGBoost 在处理中小样本、多特征输入及非线性映射关系方面具有较好适应性,3 个生育期验证集 R^2 分别达到 0.739、0.841 和 0.816,说明其在农业遥感建模中具有较高适用性。这一结论与 XGBoost 在玉米地上生物量估测和单产预测中的已有应用结果相一致[18-19]。

对于单产预测,在仅使用 UAV 特征时,XGBoost 与轻量神经网络-注意力模型表现接近,均优于 RF 和 SVR;在进一步引入 3 个生育期地上生物量估算值后,轻量神经网络-注意力模型优势明显,验证集 R^2 提升至 0.855。这表明传统机器学习算法虽能捕捉部分非线性关系,但在高阶特征组合和异构特征协同表达方面仍有限;注意力机制则能够对不同来源特征进行动态加权,从而更有效地提取关键变量[20-21]。

因此,不同模型的适用性与特征体系密切相关:在特征维度较有限、样本量较小时,集成学习模型更具优势;在多源异构特征融合场景下,具备特征自适应加权能力的神经网络模型更具潜力。

4 结论

(1)本文以保护性耕作条件下的玉米为研究对象,基于 RGB、多光谱和热红外无人机多源影像,构建了融合 Boruta-RFE 特征筛选、分期地上生物量估算与轻量注意力机制的玉米地上生物量估算和单产预测方法。该方法将多源遥感表型特征与关键生育期地上生物量信息相结合,可从冠层表征和干物质积累两个层面刻画玉米单产形成过程。

(2)3 个关键生育期的地上生物量敏感特征存在明显阶段差异。大喇叭口期主要表现为红边纹理和温度离散特征敏感,灌浆期颜色指数和温度统计特征作用增强,成熟期则更多体现为综合指数与纹理特征占优。其中灌浆期验证集 R^2 最高,成熟期验证集 RMSE 最低。

(3)在仅采用 UAV 特征进行单产预测时,XGBoost 综合表现相对更优,验证集 R^2 为 0.700;进一步融合 3 个生育期地上生物量估算值后,各模型单产预测精度均有所提升,其中轻量神经网络-注意力模型表现最优,验证集 R^2 和 RMSE 分别达到 0.855 和 0.935 t/hm^2,说明分期地上生物量信息能够有效补充遥感表型特征对单产形成过程的表征。

(4)注意力权重结果表明,多光谱特征、地上生物量、RGB 特征和热红外特征均对单产预测具有贡献,其中多光谱特征贡献最大,地上生物量信息次之。本文提出的地上生物量估算和地上生物量辅助单产预测方法,可为保护性耕作条件下玉米长势监测和单产预测提供技术参考。

参 考 文 献

[1] 刘丽平,张克寒,佟玲,等. Meta 分析滴灌灌溉量及品种对玉米产量和水分利用效率的影响[J]. 中国农业大学学报,2025,30(1):1-13.
Liu Liping, Zhang Kehan, Tong Ling, et al. Effects of drip irrigation amount and cultivars on maize yield and water use efficiency: a Meta-analysis[J]. Journal of China Agricultural University, 2025, 30(1): 1-13. (in Chinese)

[2] Dong Q G, Yang Y C, Yu K, et al. Effects of straw mulching and plastic film mulching on improving soil organic carbon and nitrogen fractions, crop yield and water use efficiency in the Loess Plateau, China[J]. Agricultural Water Management, 2018, 201: 133-143.

[3] Song Y, Gao M X, Li Z. Impacts of straw return methods on crop yield, soil organic matter, and salinity in saline-alkali land in North China[J]. Field Crops Research, 2025, 322: 109752.

[4] 王来刚,徐建华,贺佳,等. 基于无人机遥感的玉米叶面积指数与产量估算[J]. 玉米科学,2020,28(6):88-93.
Wang Laigang, Xu Jianhua, He Jia, et al. Estimation of maize leaf area index and yield based on UAV remote sensing[J]. Journal of Maize Sciences, 2020, 28(6): 88-93. (in Chinese)

[5] 邵国敏,韩文霆,周蓓蓓,等. 基于无人机多源遥感与气象参数的大田玉米地上生物量估算研究[J]. 农业机械学报,2025,56(12):436-449.
Shao Guomin, Han Wenting, Zhou Beibei, et al. Estimation of aboveground biomass of field maize based on UAV multi-source remote sensing and meteorological parameters[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(12): 436-449. (in Chinese)

[6] 葛焱,朱志畅,臧晶荣,等. 融合无人机多时相参数的冬小麦单产估测方法[J]. 农业机械学报,2025,56(1):344-355.
Ge Yan, Zhu Zhichang, Zang Jingrong, et al. Estimation method of winter wheat yield by integrating UAV multi-temporal parameters[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(1): 344-355. (in Chinese)

[7] Ali M, Ali S M I, Singh B. Wheat grain yield and nitrogen uptake prediction using at Leaf and GreenSeeker portable optical sensors at jointing growth stage[J]. Information Processing in Agriculture, 2020, 7(3): 375-383.

[8] Zhang S, Wang X R, Lin H, et al. A review of the application of UAV multispectral remote sensing technology in precision agriculture[J]. Smart Agricultural Technology, 2025, 12: 101406.

[9] 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. Estimation model of maize aboveground biomass based on multispectral remote sensing and CNN[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(9): 238－248. (in Chinese)

[10] 王天一,路梦源,贺刚,等. 融合植被三维结构与光谱特征的草原地上生物量估算模型[J]. 农业机械学报,2025,56(11):76－83.
Wang Tianyi, Lu Mengyuan, He Gang, et al. Estimation model of grassland aboveground biomass by integrating vegetation three-dimensional structure and spectral features[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(11): 76－83. (in Chinese)

[11] Lichtenthaler H K. Chlorophylls and carotenoids: pigments of photosynthetic biomembranes[M]// Methods in enzymology. San Diego: Academic Press, 1987: 350－382.

[12] Qi H, Wu Z, Zhang L, et al. Monitoring of peanut leaves chlorophyll content based on drone-based multispectral image feature extraction[J]. Computers and Electronics in Agriculture, 2021, 187: 106292.

[13] 孙诗睿,赵艳玲,王亚娟,等. 基于无人机多光谱遥感的冬小麦叶面积指数反演[J]. 中国农业大学学报,2019,24(11):51－58.
Sun Shirui, Zhao Yanling, Wang Yajuan, et al. Inversion of leaf area index of winter wheat based on UAV multispectral remote sensing[J]. Journal of China Agricultural University, 2019, 24(11): 51－58. (in Chinese)

[14] 刘杨,黄珏,孙乾,等. 利用无人机数码影像估算马铃薯地上生物量[J]. 遥感学报,2021,25(9):2004－2014.
Liu Yang, Huang Jue, Sun Qian, et al. Estimation of potato aboveground biomass using UAV digital images[J]. Journal of Remote Sensing, 2021, 25(9): 2004－2014. (in Chinese)

[15] 陶惠林,徐良骥,冯海宽,等. 基于无人机数码影像的冬小麦株高和生物量估算[J]. 农业工程学报,2019,35(19):107－116.
Tao Huilin, Xu Liangji, Feng Haikuan, et al. Plant height and biomass estimation of winter wheat based on UAV digital image[J]. Transactions of the CSAE, 2019, 35(19): 107－116. (in Chinese)

[16] Li Z, Chen Z, Cheng Q, et al. Deep learning models outperform generalized machine learning models in predicting winter wheat yield based on multispectral data from drones[J]. Drones, 2023, 7(8): 505.

[17] Tan H, Kou W, Xu W, et al. Improved estimation of aboveground biomass in rubber plantations using deep learning on UAV multispectral imagery[J]. Drones, 2025, 9(1): 32.

[18] Kulpanich N, Worachairungreung M, Thanakunwutthirot K, et al. The application of unmanned aerial vehicles (UAVs) and extreme gradient boosting (XGBoost) to crop yield estimation: a case study of Don Tum District, Nakhon Pathom, Thailand[J]. International Journal of Geoinformatics, 2023, 19(2): 65－77.

[19] Li Z M, Ding D W, Zhai W G, et al. Estimation of soybean phenotypic parameters across growth stages using UAV-based multi-source feature fusion and XGBoost[J]. Climate Smart Agriculture, 2026, 3(1): 100098.

[20] Li X K, Lyu Y F, Zhu B X, et al. Maize yield estimation in Northeast China's black soil region using a deep learning model with attention mechanism and remote sensing[J]. Scientific Reports, 2025, 15: 12927.

[21] Aviles Toledo C A, Crawford M M, Tuinstra M R. Integrating multi-modal remote sensing, deep learning, and attention mechanisms for yield prediction in plant breeding experiments[J]. Frontiers in Plant Science, 2024, 15: 1408047.