doi:10.6041/j.issn.1000-1298.2026.18.025

小样本条件下玉米单株干物质量无人机多光谱反演与模型稳定性分析

林　丽[1,2]　李圣杰[1,2]　曹　伟[1,2]　马瑞超[1,2]　俞丹丹[1,2]

(1.新疆农业大学水利与土木工程学院,乌鲁木齐 830052;
2.新疆水利工程安全与水灾害防治重点实验室,乌鲁木齐 830052)

摘要:为提升干旱区复播玉米单株尺度干物质量反演精度并支撑精准灌溉决策,针对小样本条件下模型稳定性不足的问题,以南疆复播玉米为研究对象,基于无人机多光谱影像开展单株干物质量预测研究。选取吐丝期、灌浆期和成熟期获取冠层影像,提取 NDVI、GNDVI、NDRE、LCI 和 OSAVI 等植被指数,并结合地面同步测定的株高与茎粗等结构变量,构建光谱-结构融合预测模型。在小样本条件下,采用岭回归(Ridge)、随机森林(RF)及集成模型进行建模,对不同变量组合及生育时期下模型精度与稳定性进行系统分析。结果表明:各植被指数与单株干物质量均呈显著正相关,其中 NDRE 与 LCI 表现最优,灌浆期相关性最高。结构变量能显著提升模型预测精度,且具有明显阶段性特征,吐丝期以株高主导,灌浆期和成熟期以茎粗贡献更为稳定。在灌浆期,模型预测效果最佳,Ridge 模型验证集决定系数 R^2 由 0.71 提升至 0.90,集成模型由 0.70 提升至 0.87,结构变量与光谱信息协同作用最为显著。单株尺度条件下模型精度对生育时期具有显著依赖性,整体由大到小依次为灌浆期、吐丝期、成熟期。研究结果表明,在小样本条件下,融合红边敏感植被指数与结构变量能够有效提升单株干物质量预测精度,灌浆期为最优建模时期。研究结果可为干旱区精准灌溉分区管理与水分调控提供数据支撑。

关键词:复播玉米;单株干物质量;无人机多光谱;小样本建模

中图分类号:S127　　**文献标识码**:A　　**文章编号**:1000-1298(2026)18-0299-12　　**OSID**:

Estimation of Maize Single Plant Dry Matter Using UAV Multispectral Data under Small Sample Conditions: Model Stability Analysis

Lin Li[1,2]　Li Shengjie[1,2]　Cao Wei[1,2]　Ma Ruichao[1,2]　Yu Dandan[1,2]

(1. *College of Hydraulic and Civil Engineering, Xinjiang Agricultural University, Urumqi* 830052, *China*
2. *Xinjiang Key Laboratory of Hydraulic Engineering Safety and Water Disaster Prevention, Urumqi* 830052, *China*)

Abstract: Aiming to improve the inversion accuracy of single-plant dry matter in relay-planted maize in arid regions and support precision irrigation decision-making, focusing on the insufficient stability of prediction models under small-sample conditions. Taking relay-planted maize in southern Xinjiang as the research object, single-plant dry matter prediction was conducted based on UAV multispectral imagery. Canopy images were acquired at the silking, grain-filling, and maturity stages, and vegetation indices, including NDVI, GNDVI, NDRE, LCI, and OSAVI were extracted. Meanwhile, structural variables such as plant height and stem diameter measured synchronously in the field were incorporated to construct spectral-structural fusion prediction models. Under small-sample conditions, ridge regression, random forest, and an ensemble model were used for modeling, and model accuracy and stability under different variable combinations and growth stages were systematically analyzed. The results showed that all vegetation indices were significantly positively correlated with single-plant dry matter, with NDRE and LCI performing best and the strongest correlations observed at the grain-filling stage. Structural variables improved model accuracy and showed clear stage-specific effects: plant height was more important at the silking stage, whereas stem diameter contributed more stably at the grain-filling and maturity stages. The best prediction performance was obtained at the grain-filling stage. The validation R^2 of the ridge model

收稿日期:2026-04-09　修回日期:2026-04-29

基金项目:新疆维吾尔自治区重大科技专项(20242126303-3)

作者简介:林丽(1977—),女,教授,博士,主要从事水利信息化和水资源规划与利用研究,E-mail:klmhll@126.com

was increased from 0.71 to 0.90, while that of the ensemble model increased from 0.70 to 0.87, indicating a strong synergistic effect between spectral and structural information. At the single-plant scale, model accuracy depended strongly on growth stage, with performance decreasing in the order of grain-filling, silking, and maturity stages. These findings suggested that integrating red-edge-sensitive vegetation indices with structural variables can effectively improve dry matter prediction under small-sample conditions, with the grain-filling stage being the optimal modeling period. The results can provide data support for precision irrigation zoning and water regulation in arid regions.

Key words: relay-planted maize; single-plant dry matter; UAV multispectral imagery; small-sample modeling

0 引言

粮食安全是国之大者。党的十八大以来,强调要始终把保障国家粮食安全摆在首位[1]。“十五五”期间中国粮食需求增长空间有限且将达到峰值[2]。玉米是我国第一大粮食作物,年产量占全国粮食总产量的40%,在保障国家粮食安全方面具有至关重要的作用[3]。据统计,2023 年新疆地区玉米播种面积 1 437 660 hm^2,较 2022 年增加 292 100 hm^2,增幅 25.5%,种植面积首次超过小麦,成为新疆第一大粮食作物,占粮食总面积的 51%[4]。随着现代农业技术的不断演进和应用,玉米种植已从传统的依赖自然条件和人力劳作模式,转变为高效、精准、智能化的现代农业种植模式[5]。在玉米种植模式向规模化、集约化和精准化转变背景下,准确获取作物空间分布信息在作物产量预估、农业生产管理与农业保险等方面具有重要科学与实践意义[6]。产量作为衡量作物生产水平的核心指标,其空间分布特征不仅反映作物生长差异,也为灌溉调控、施肥管理及产量评估提供关键依据。传统地上生物量估算常采用破坏性采样法,存在耗时长且成本较高的局限性[7]。

随着遥感技术发展,基于光谱信息的作物生长监测方法逐渐成为农业信息获取的重要手段。无人机多光谱遥感具有获取周期短、空间分辨率高和机动性强等优势,能在田间尺度精细获取作物冠层光谱信息,被广泛应用于作物长势监测、养分诊断及产量估测等研究领域[8-9],植被指数通过对不同波段信息的组合,能综合反映作物叶面积、叶绿素含量及光合活性,与作物产量形成过程密切相关,其中归一化植被指数(NDVI)及红边相关指数在玉米生长监测中表现出较好适用性[10-11]。尽管已有研究表明无人机多光谱植被指数在玉米反演中具有较大潜力[12],但现有研究多以小区或区域尺度产量为研究对象[13],在单株尺度条件下,由于样本数量有限且个体差异较大,模型稳定性和泛化能力易受到影响,相关研究仍相对不足。此外,随着机器学习方法的引入,非线性模型在干物质量反演中应用逐渐增多,同时,部分研究依赖多时相或全生育期数据构建模型,在单一生育期条件下模型稳定性和适用性仍有待进一步验证[14]。在小样本条件下开展单株尺度干物质量反演研究,不仅需兼顾模型精度与稳定性,还需明确不同生育时期植被指数对干物质积累的响应特征及其适用范围。同时,将干物质量反演结果与作物生长调控需求相结合,对于提升灌溉管理精细化水平具有重要意义。

基于此,本文以无人机多光谱数据为基础,融合植被指数与结构变量(株高、茎粗)构建多模型单株干物质量反演体系,包括在小样本条件下构建单株干物质量多模型反演体系,对比不同模型在精度与稳定性方面的差异;从生育时期角度分析植被指数与结构变量对干物质积累的阶段性响应特征,明确关键建模时期;基于红边敏感指数(NDRE、LCI)探讨反演体系在高覆盖度条件下响应优势及作用机制;结合单株干物质量反演结果,分析反演体系在精准灌溉分区管理中应用潜力,拓展遥感反演结果的工程应用价值。以期提升干旱区作物精细化监测与水分调控水平。

1 材料与方法

1.1 试验区概况

试验区位于新疆阿克苏地区沙雅县红旗镇(41°24′46″N,82°82′42″E)。试验区地势平坦,海拔约 970 m,属温带大陆性气候,气候干燥,降水稀少。年平均日照时数 3 031 h,年平均降水量 47.3 mm,年均蒸发量约 2 000.7 mm。该区域农作物 1 年 2 熟,10 月中下旬至次年 6 月上旬种植冬小麦,6 月中下旬至 10 月中旬种植复播玉米。

1.2 数据选择与处理

1.2.1 生育期选择

选取复播玉米典型生育进程的吐丝期、灌浆期和成熟期作为观测阶段,开展无人机多光谱数据采集与单株干物质量测定。上述生育时期覆盖了玉米从营养生长到生殖生长直至成熟的关键过程,能够

较全面反映作物干物质积累动态特征。

其中，吐丝期为生殖生长的关键转折阶段，冠层结构与叶绿素含量变化显著；灌浆期为产量形成的核心阶段[15]，光合产物大量向籽粒转运，干物质快速积累；成熟期植株逐渐衰老，叶片光合能力下降，干物质积累趋于稳定。不同生育时期在生理特征及光谱响应方面存在明显差异，因此在多个时期开展数据采集，有助于系统分析植被指数与单株干物质量之间的响应关系及其阶段性变化特征。

1.2.2　干物质量与结构参数测定

在田间布设 18 个试验小区，在各小区均匀选取代表性样株，并避开边行以减少边际效应影响。分别在吐丝期、灌浆期和成熟期开展单株取样测定，每个生育时期获取 54 株样本。

采用单株收获法测定干物质量（g/株）。对选定样株进行整株取样，获取地上部干物质量。同时，对对应样株同步测定株高和茎粗等结构参数，其中株高采用卷尺测量地表至植株顶部高度，茎粗在植株基部上方约 5 cm 处使用游标卡尺测定。

在各观测时期，对选定样株进行整株取样，获取地上部干物质量。为保证无人机数据与地面实测数据一致性，在同一作业日完成无人机多光谱影像获取与对应样株的地面采样。

1.2.3　无人机数据获取

无人机多光谱影像采用大疆御 3 m 多光谱无人机（DJI Mavic 3 Multispectral），可同步采集绿、红、红边及近红外 4 个波段的作物冠层光谱信息，航飞时间为 11:00—14:00，光照条件稳定，有效降低阴影对反射率的影响；飞行高度为 13 m，飞行速度为 1.5 m/s，航向重叠度为 80%，旁向重叠度为 70%。无人机多光谱影像经辐射定标、反射率校正和几何校正处理后，采用大疆智图（DJITerra）软件完成正射影像拼接；在此基础上，结合样株实地定位坐标，在 ArcGIS 平台上提取对应样株冠层区域的像元均值，并计算植被指数。

1.3　植被指数选取

基于多光谱数据特征及其对作物生长状况的表征能力选取植被指数。归一化植被指数（NDVI）用于反映作物冠层整体生长状况[16]，绿光归一化植被指数（GNDVI）对叶绿素含量变化更为敏感[17]；归一化红边植被指数（NDRE）基于红边波段构建，在高覆盖度条件下对作物生理状态具有更强指示能力[18]；叶片叶绿素指数（LCI）进一步强化叶绿素信息表达[19]；优化土壤调整植被指数（OSAVI）通过引入土壤调节因子，有助于降低背景土壤对植被信号的干扰[20]。上述植被指数能从不同角度反映复播玉米冠层结构及生理状态特征，并与干物质积累过程密切相关，适用于单株尺度干物质量反演分析。各指数计算公式见表 1。

表 1　植被指数计算公式

Tab. 1　Calculation formulas of vegetation indices

植被指数	计算公式	文献序号
NDVI	$NDVI = (NIR - Red)/(NIR + Red)$	[21]
NDRE	$NDRE = (NIR - RedEdge)/(NIR + RedEdge)$	[22]
GNDVI	$GNDVI = (NIR - Green)/(NIR + Green)$	[23]
LCI	$LCI = (NIR - RedEdge)/(NIR + Red)$	[24]
OSAVI	$OSAVI = (NIR - Red)/(NIR + Red + 0.16)$	[25]

1.4　模型构建与精度评价

以 NDRE、LCI、NDVI、GNDVI 和 OSAVI 植被指数为光谱特征变量，以单株干物质量为因变量，同时引入株高和茎粗作为结构变量，构建多变量融合模型进行建模分析。为评估不同变量信息对模型性能的影响，设置 4 种变量组合：①光谱变量（NDRE、LCI、NDVI、GNDVI、OSAVI）。②光谱变量 + 株高。③光谱变量 + 茎粗。④光谱变量 + 株高 + 茎粗。

在此基础上，分别构建岭回归（Ridge）、随机森林（RF）及复合模型进行建模分析。样本按比例 8:2 随机划分为训练集和测试集，并设置随机种子以保证结果可重复。

为提高模型稳定性，Ridge 模型通过引入 L2 正则化约束以减弱多重共线性影响[26-27]；RF 模型通过调节树数量、最大深度及叶节点样本数等参数进行优化[28]。各模型参数均通过网格搜索方法确定，并结合交叉验证（K-fold）进行最优参数筛选，以提高模型泛化能力[29]。

在单模型优化基础上，进一步构建集成模型。集成模型采用加权集成方法（Voting Regressor），将 SVR、Ridge 和 XGBoost 3 种模型预测结果进行融合，其中权重分别设为 2、3 和 1，以增强稳定性较高模型在整体预测中的贡献，从而提升模型综合性能[30]。

模型精度采用决定系数（R^2）和均方根误差（RMSE）进行评价。其中，R^2 用于衡量模型对观测值变化的解释能力，RMSE 用于反映预测误差。分别在训练集和测试集上计算评价指标，以综合分析模型拟合能力和泛化性能。

2　结果与分析

2.1　植被指数与复播玉米干物质量相关性分析

NDRE 与 LCI 在各生育时期均表现出较高相关性（表 2、图 1），说明基于红边波段构建的植被指数对干物质积累具有更强的敏感性。主要是由于红边

波段对叶绿素含量变化响应显著,在高覆盖度条件下能有效缓解 NDVI 易饱和问题,从而更准确地反映作物光合能力与生物量积累过程。相比之下,OSAVI 虽引入土壤调节因子,但在单株尺度条件下土壤背景影响相对减弱,对干物质量的指示能力有限。综合来看,各指数敏感性由大到小依次为 NDRE、LCI、GNDVI、NDVI、OSAVI,该结果与作物生理特征及光谱响应机制一致。

表 2 不同生育时期植被指数与单株干物质量相关系数

Tab. 2 Correlation coefficients between vegetation indices and single-plant dry matter at different growth stages

生育期	OSAVI	GNDVI	LCI	NDRE	NDVI
吐丝期	0.223 **	0.421 **	0.550 **	0.562 **	0.417 **
灌浆期	0.187 **	0.422 **	0.615 **	0.674 **	0.419 **
成熟期	0.207 **	0.368 **	0.510 **	0.552 **	0.215 **

注:** 表示在 0.01 水平下显著相关。下同。

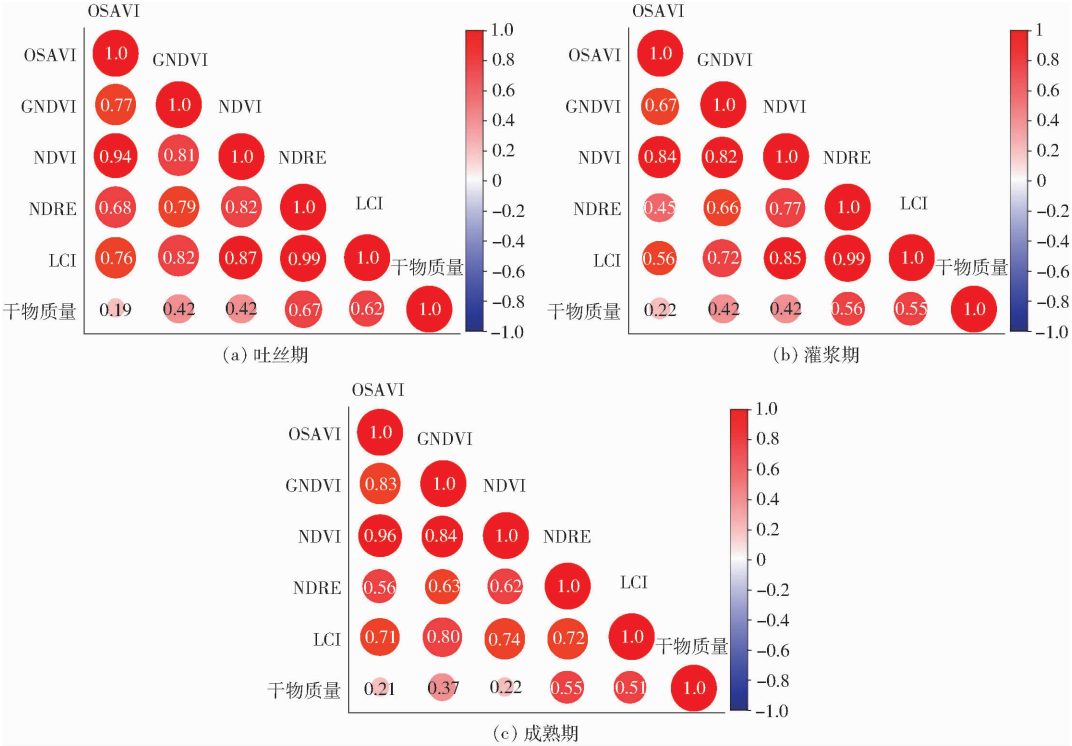

图 1 不同生育时期植被指数与单株干物质量相关性矩阵

Fig. 1 Correlation matrix of vegetation indices and single-plant dry matter across growth stages

2.2 结构变量与单株干物质量相关性分析

为分析结构变量对单株干物质量的表征能力,计算不同生育时期株高、茎粗与干物质量的相关系数 R(表 3)。由表 3 可知,2 类结构变量在各生育时期均与单株干物质量呈显著正相关关系,但相关性随生育进程变化明显。

表 3 不同生育时期结构变量与单株干物质量相关系数

Tab. 3 Correlation coefficients between structural variables and single-plant dry matter at different growth stages

生育期	茎粗	株高
吐丝期	0.642 **	0.898 **
灌浆期	0.871 **	0.852 **
成熟期	0.884 **	0.819 **

在吐丝期,株高与干物质量相关系数为 0.898,高于茎粗(0.642),表明该时期植株仍处于快速伸长阶段,株高对干物质积累具有较强指示作用;进入灌浆期后,茎粗相关性显著提高(R = 0.871),超过株高(R = 0.852);在成熟期,茎粗仍保持较高相关性(R = 0.884),而株高相关性有所下降(R = 0.819)。结果说明,随着生育进程推进,干物质积累逐渐由株高主导转向茎秆结构主导。

2.3 不同变量组合下模型预测精度

为系统评估结构变量对单株干物质量预测精度的影响,分别构建光谱变量、光谱变量 + 株高、光谱变量 + 茎粗及光谱变量 + 株高 + 茎粗 4 种变量组合模型,并基于 Ridge、RF 及集成模型进行建模分析,结果如表 4 所示。

总体来看,引入结构变量后,各模型预测精度均得到明显提升。相比仅采用光谱变量,加入株高后模型精度平均提升 0.10 ~ 0.30,而引入茎粗后提升更为稳定,多数情况下提升 0.10 ~ 0.25;当株高与茎粗同时引入时,模型表现最佳,较光谱模型整体提升约 0.20 以上,说明结构变量能够有效增强光谱信息对干物质量的解释能力。

表 4　不同生育时期各模型对单株干物质量的预测结果

Tab. 4　Prediction results of different models for single-plant dry matter at different growth stages

生育时期	模型	变量组合	训练集		验证集	
			R^2	RMSE/(g·株$^{-1}$)	R^2	RMSE/(g·株$^{-1}$)
吐丝期	Ridge	光谱变量	0.43	12.22	0.28	13.39
	Ridge	光谱变量 + 株高	0.84	6.22	0.86	6.01
	Ridge	光谱变量 + 茎粗	0.75	7.92	0.78	7.60
	Ridge	光谱变量 + 株高 + 茎粗	0.87	5.62	0.87	5.84
	RF	光谱变量	0.56	9.99	0.41	13.05
	RF	光谱变量 + 株高	0.73	8.39	0.55	10.54
	RF	光谱变量 + 茎粗	0.64	9.61	0.42	11.90
	RF	光谱变量 + 株高 + 茎粗	0.76	7.85	0.63	9.48
	集成	光谱变量	0.48	11.34	0.38	12.83
	集成	光谱变量 + 株高	0.88	5.42	0.86	6.07
	集成	光谱变量 + 茎粗	0.81	6.95	0.76	7.90
	集成	光谱变量 + 株高 + 茎粗	0.90	4.96	0.88	5.60
灌浆期	Ridge	光谱变量	0.70	14.71	0.71	12.55
	Ridge	光谱变量 + 株高	0.82	11.34	0.85	9.00
	Ridge	光谱变量 + 茎粗	0.91	8.12	0.80	10.38
	Ridge	光谱变量 + 株高 + 茎粗	0.93	7.04	0.90	7.27
	RF	光谱变量	0.55	16.03	0.50	22.51
	RF	光谱变量 + 株高	0.66	13.91	0.61	19.75
	RF	光谱变量 + 茎粗	0.73	12.51	0.63	19.33
	RF	光谱变量 + 株高 + 茎粗	0.78	11.29	0.70	17.40
	集成	光谱变量	0.73	14.04	0.70	12.88
	集成	光谱变量 + 株高	0.89	8.78	0.81	10.03
	集成	光谱变量 + 茎粗	0.95	6.26	0.75	11.80
	集成	光谱变量 + 株高 + 茎粗	0.96	5.00	0.87	8.38
成熟期	Ridge	光谱变量	0.41	25.87	0.35	23.08
	Ridge	光谱变量 + 株高	0.68	16.06	0.77	16.25
	Ridge	光谱变量 + 茎粗	0.88	9.93	0.83	13.86
	Ridge	光谱变量 + 株高 + 茎粗	0.92	7.92	0.85	13.08
	RF	光谱变量	0.38	23.05	0.32	25.38
	RF	光谱变量 + 株高	0.54	19.82	0.55	20.66
	RF	光谱变量 + 茎粗	0.65	17.30	0.54	20.75
	RF	光谱变量 + 株高 + 茎粗	0.71	15.69	0.66	17.80
	集成	光谱变量	0.61	17.92	0.44	25.34
	集成	光谱变量 + 株高	0.73	14.80	0.67	19.40
	集成	光谱变量 + 茎粗	0.93	7.40	0.82	14.09
	集成	光谱变量 + 株高 + 茎粗	0.97	4.79	0.83	13.74

以吐丝期为例，Ridge 模型在仅采用光谱变量时验证集 R^2 为 0.28，引入株高后提升至 0.86，显著提升 0.58；引入茎粗后提升至 0.78，提高 0.50；进一步融合结构变量后达到 0.87。集成模型在对应变量组合下由 0.38 提升至 0.88，提升 0.50，表明结构变量在该时期具有显著增强作用。

在灌浆期，各模型预测能力进一步提高。Ridge 模型在光谱变量条件下验证集 R^2 为 0.71，引入株高后提升至 0.85（提高 0.14），引入茎粗为 0.80（提高 0.09），融合结构变量后达到 0.90（提高 0.19）；集成模型 R^2 对应由 0.70 提升至 0.87（提高 0.17）。整体来看，灌浆期模型精度最高，验证集 R^2 普遍达到 0.80 以上，表明该时期结构变量与光谱信息协同作用最为显著。

在成熟期，模型精度整体有所下降。Ridge 模型验证集 R^2 由 0.35 提升至 0.77（株高）和 0.83（茎粗），融合后为 0.85；集成模型由 0.44 提升至 0.67、0.82 及 0.83。尽管结构变量仍能够提升模型精度（提升幅度 0.20 ~ 0.40），但绝对精度低于灌浆期，表明随着植株进入衰老阶段，光谱信息与结构变量对干物质量的表征能力均有所减弱。

从不同模型表现来看，随机森林模型在训练集

拟合能力较强，但在测试集上提升幅度相对有限，表现出一定过拟合趋势；岭回归模型在不同变量组合下表现出较好稳定性；集成模型在多数情况下取得较优结果，综合性能最佳。

总体而言，结构变量引入能显著提高单株干物质量预测精度，其中茎粗在中后期贡献更为稳定，而株高在吐丝期具有较好指示作用，两者联合能进一步提升模型性能。

2.4 生育时期差异

不同生育时期模型预测精度存在明显差异。综合各变量组合与模型结果可以看出，吐丝期、灌浆期和成熟期单株干物质量反演呈现显著的阶段性变化特征。整体上，灌浆期模型预测效果最佳，吐丝期次之，成熟期相对较低。

从变量作用角度分析，吐丝期植株处于快速生长阶段，株高对干物质量具有较强指示作用；灌浆期为干物质快速积累阶段，光谱信息与结构变量（株高与茎粗）对生物量变化的响应最为敏感，模型预测能力显著增强；成熟期植株逐渐衰老，光谱信息对干物质量的表征能力减弱，同时结构变量变化趋于稳定，导致模型精度有所下降。

总体而言，作物生育时期对单株干物质量反演具有显著影响，其中：灌浆期为单株干物质量反演的最优建模时期，吐丝期次之，成熟期相对较低，该结果为后续分时期模型分析提供了整体框架，并为精准灌溉决策中关键监测时期选择提供了依据。

2.4.1 吐丝期模型预测结果

吐丝期各模型预测结果见图 2。整体来看，在

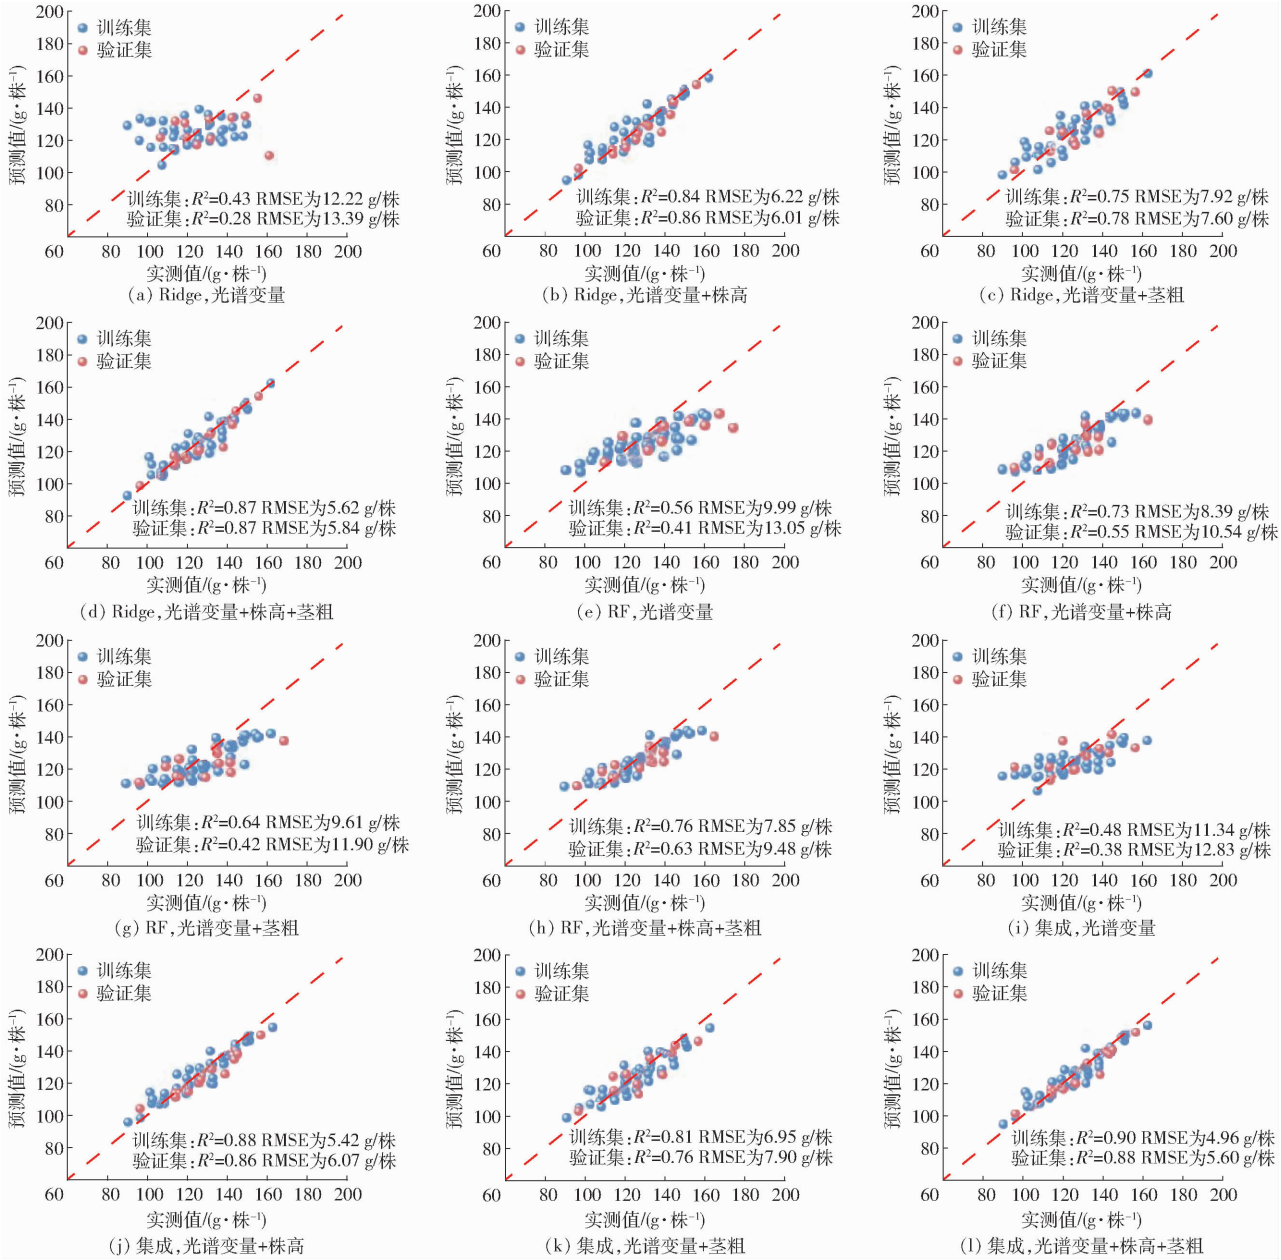

图 2 吐丝期不同模型与变量组合单株干物质量预测值与实测值

Fig. 2 Predicted and measured single-plant dry matter under different models and variable combinations at silking stage

仅采用光谱变量时，模型预测值与实测值之间离散较为明显，验证集 R^2 在 0.28 ~ 0.41 之间，尤其在中等偏高干物质量区间，部分样本偏离 1∶1 线较为明显，表明单一光谱信息在该时期对干物质量的表征能力仍然有限。结果与 2.3 节中光谱模型整体精度偏低的结论一致。

当引入结构变量后，散点分布明显向 1∶1 线收敛，模型精度得到显著改善。其中，光谱变量 + 株高组合提升最为明显，Ridge 模型验证集 R^2 由 0.28 提高至 0.86，提高 0.58；光谱变量 + 茎粗组合对应提升至 0.78，提高 0.50；当株高与茎粗同时引入时，R^2 进一步提高至 0.87，但相较于单独引入株高，其提升幅度仅增加 0.01，表明该时期模型精度主要受株高驱动。这一变化趋势与 2.2 节中结构变量相关性分析结果一致，即吐丝期株高与干物质量的相关性高于茎粗。

从不同模型表现来看，Ridge 与集成模型预测结果较为稳定，散点分布集中在 1∶1 线附近，而随机森林模型在部分区间仍存在一定离散，验证集 R^2 提升幅度相对有限（0.01 ~ 0.22），表现出一定不稳定性。这与 2.3 节中模型对比结果一致。

从生长过程来看，吐丝期植株处于快速伸长期，株高变化幅度较大，能够较好反映作物生长状态及干物质积累水平，而茎粗在该阶段变化相对缓慢，对干物质量表征能力尚未充分体现。因此，在该时期模型精度的提升主要依赖于株高变量，而茎粗更多起到辅助作用。

总体来看，吐丝期模型预测能力在引入结构变量后得到明显改善，验证集 R^2 由 0.28 提升至 0.88，但整体仍低于灌浆期水平，表明该阶段虽具备一定预测基础，但尚不是单株干物质量反演的最优时期。

2.4.2　灌浆期模型预测结果

灌浆期各模型预测结果如图 3 所示。与吐丝期相比，各模型预测值与实测值的一致性明显提高，散点分布整体更加集中于 1∶1 线附近，尤其在中高干物质量区间，预测偏差显著减小，模型稳定性明显增强。结合 2.3 节结果可以看出，在仅采用光谱变量时，模型验证集 R^2 已达到 0.50 ~ 0.71，整体精度较吐丝期明显提高。

在引入结构变量后，模型性能进一步提升。其中，Ridge 模型验证集 R^2 由 0.71 提升至 0.85（引入株高），提升 0.14；引入茎粗后为 0.80，提升 0.09；当株高与茎粗同时引入时，R^2 进一步提高至 0.90，整体提升约 0.19。集成模型在对应变量组合下由 0.70 提升至 0.87，提升 0.17，变化趋势与 Ridge 模型一致。相比之下，随机森林模型在不同变量组合下虽有一定提升，但测试集结果波动较大，整体稳定性略低。

从变量作用来看，灌浆期株高与茎粗均对模型精度具有明显贡献。相较于吐丝期以株高主导的特征，灌浆期 2 类结构变量对模型的提升作用趋于接近，光谱变量 + 株高和光谱变量 + 茎粗组合均能有效改善模型表现，而光谱变量 + 株高 + 茎粗组合进一步增强模型精度，说明结构信息在该时期具有较强的协同作用。结果与 2.2 节中结构变量相关性分析相一致，即灌浆期茎粗与干物质量相关性显著增强（R = 0.871），与株高（R = 0.852）基本接近，表明此时茎秆结构已能够有效反映干物质积累过程。同时，结合 2.1 节中植被指数相关性结果，灌浆期 NDRE 与 LCI 相关性最高（分别达到 0.674 和 0.615），表明光谱信息与结构变量在该时期共同对干物质量变化具有较强响应能力。

从作物生长过程来看，灌浆期为干物质快速积累阶段，光合产物大量向籽粒和茎秆转运，植株结构与冠层光谱特征同步变化，使模型能同时利用光谱信息与结构变量对生物量变化进行有效表征。因此，该时期模型预测精度最高，验证集 R^2 普遍达到 0.80 以上，部分组合可达 0.90。

总体来看，灌浆期在不同变量组合与模型条件下均表现出最优预测效果，是单株干物质量反演的关键时期。结构变量与光谱信息在该阶段的协同作用最为显著，为后续精准灌溉调控提供了可靠的数据支撑。

2.4.3　成熟期模型预测结果

成熟期各模型预测结果如图 4 所示。与前 2 个生育时期相比，成熟期散点分布呈现出更为明显的分层特征：在低干物质量区间，预测值与实测值基本贴近 1∶1 线，拟合效果较为稳定；而随着干物质量增加，散点逐渐向两侧扩散，部分样本出现系统性偏离，表现为高值区间预测不稳定。这种由“集中”向“发散”的变化在不同模型中均有体现，说明模型在该时期对高生物量样本的刻画能力存在一定局限。

从变量组合角度进一步分析可以发现，结构变量的引入并未改变上述分布特征，但显著压缩了散点离散范围。以 Ridge 模型为例，验证集 R^2 由 0.35 提升至 0.77（加入株高）和 0.83（加入茎粗），融合后达到 0.85；集成模型 R^2 由 0.44 分别提升至 0.67、0.82 和 0.83。整体来看，茎粗在该时期的提升作用更加稳定，尤其在中高值区间能有效减少偏差，而株高对模型精度的改善主要体现在低值区间，对整体结构的贡献相对有限。

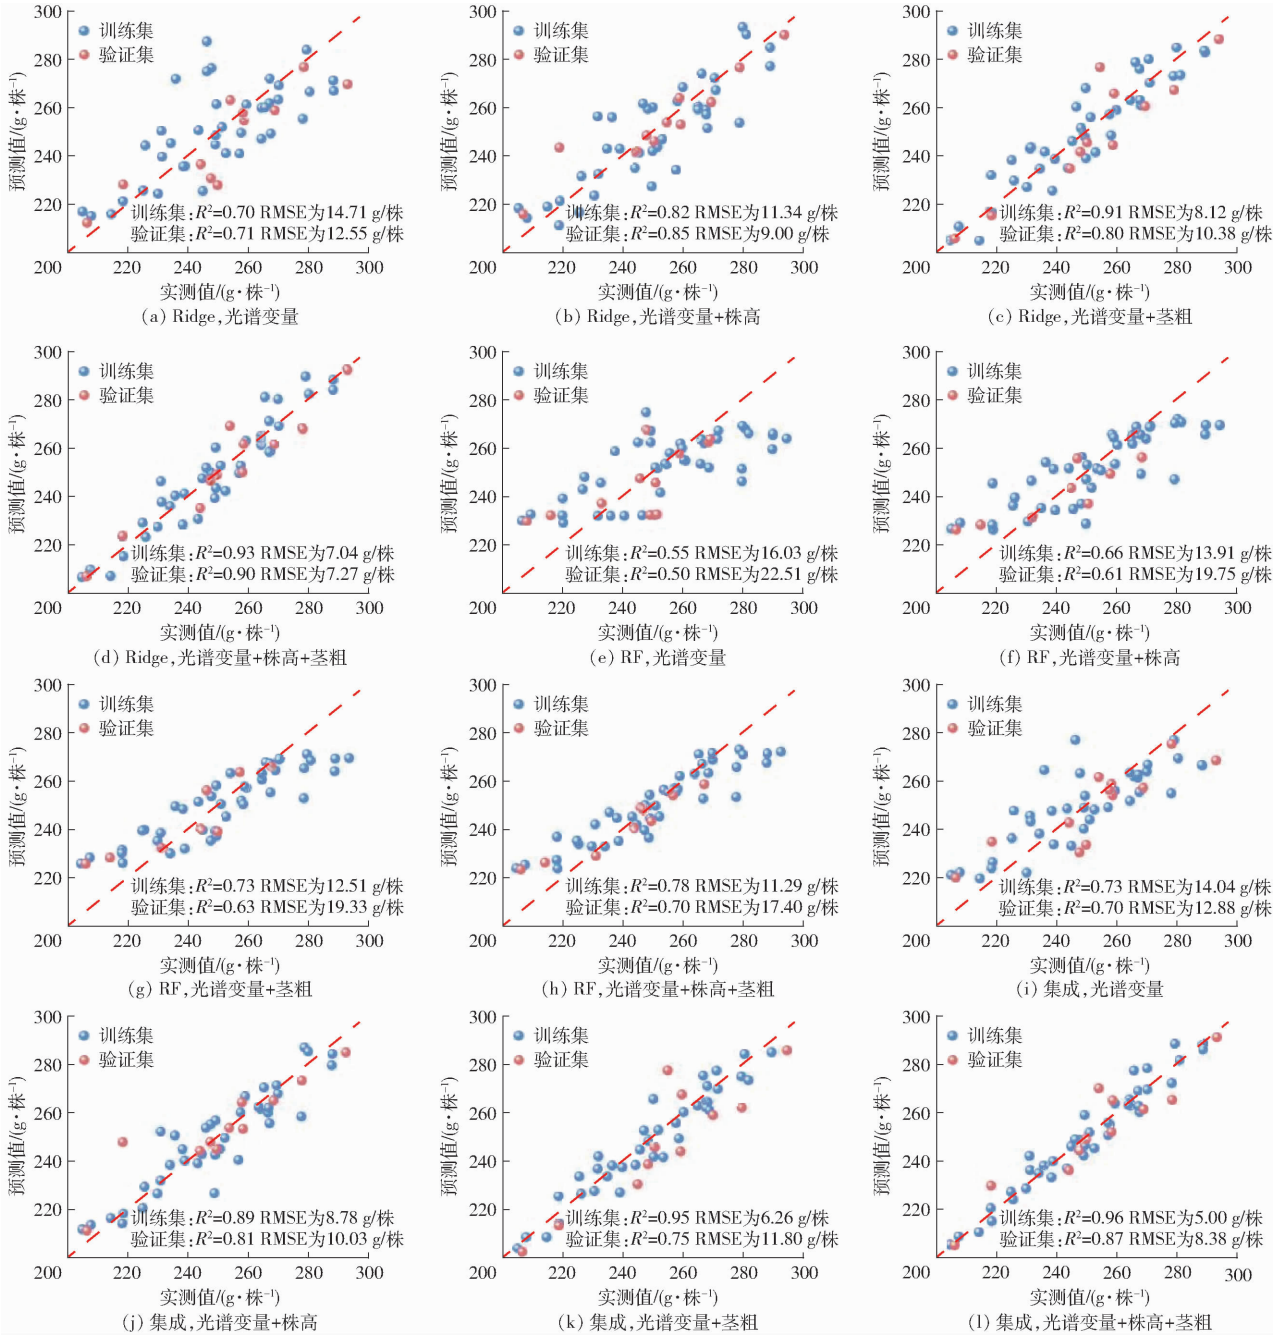

图 3 灌浆期不同模型与变量组合单株干物质量预测值与实测值

Fig. 3 Predicted and measured single-plant dry matter under different models and variable combinations at grain-filling stage

进一步对比不同变量组合可以发现,光谱变量 + 茎粗与光谱变量 + 株高 + 茎粗 2 种组合在散点分布形态上已较为接近,模型精度提升幅度趋于收敛,表明在成熟期单一结构变量已能提供主要有效信息,多变量叠加带来的边际增益明显减弱,与 2.3 节中变量组合提升幅度减小的趋势一致。

从模型角度来看,Ridge 与集成模型在该时期仍保持相对稳定的预测能力,散点分布围绕 1∶1线呈对称分布;而随机森林模型在高值区间存在一定离散现象,部分样本偏离程度较大,表明其对极端样本的适应能力相对较弱。这种差异在小样本条件下更为明显。

结合生育后期的生理特征可以解释上述现象。成熟期植株生长基本停止,株高变化趋于稳定,对干物质量的指示能力明显减弱;而茎秆结构仍保留一定差异,使茎粗能在一定程度上反映生物量水平。但与此同时,叶片逐渐衰老,叶绿素含量下降,光谱反射特征趋于一致,导致植被指数对干物质量变化的敏感性降低,进而影响模型对高值区间的判别能力。

此外,由于成熟期个体差异主要体现在籽粒充实程度等内部结构上,而这些变化难以通过表层光谱信息直接捕捉,也进一步限制了模型精度的提升空间。这也从侧面说明,仅依赖光谱信息难以完全

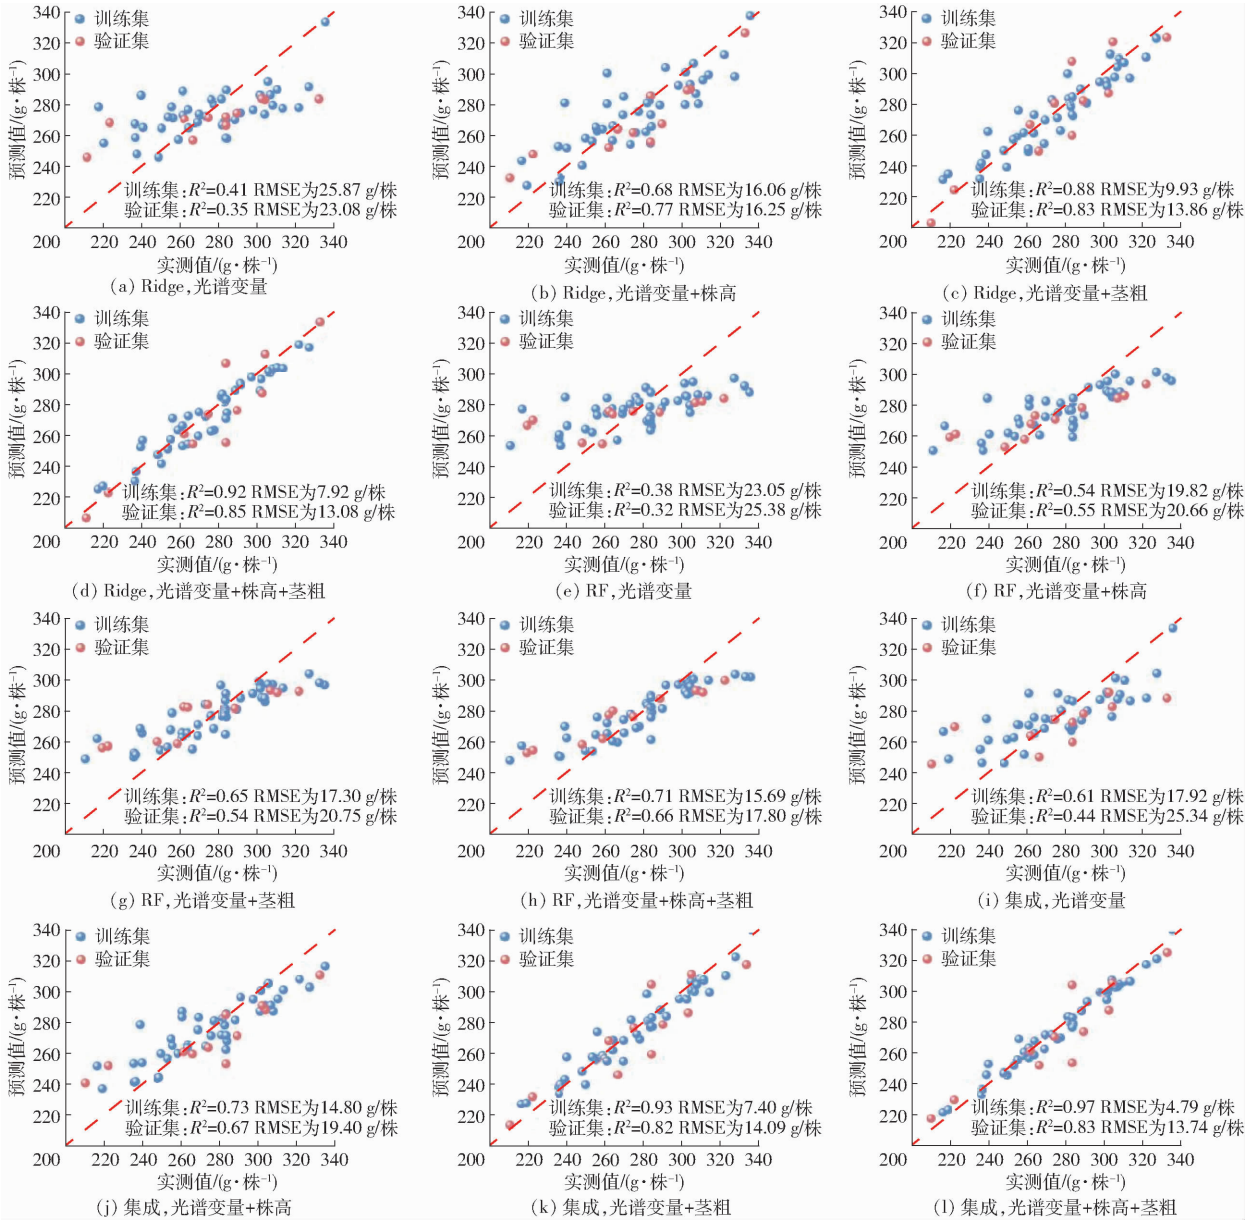

图 4　成熟期不同模型与变量组合单株干物质量预测值与实测值

Fig. 4　Predicted and measured single-plant dry matter under different models and variable combinations at maturity stage

表征成熟期生物量差异，引入结构变量虽能改善模型表现，但难以完全弥补信息不足。

总体来看，成熟期模型在引入结构变量后仍能够维持较高预测水平（验证集 R^2 为 0.54 ~ 0.85），但提升幅度与稳定性均低于灌浆期，且在高值区间存在一定不确定性。因此，该时期更适合作为模型验证与补充分析阶段，而非单株干物质量反演的最优建模阶段。

2.5　不同生育时期模型预测差异与适用性

综合不同生育时期模型预测结果可以看出，在单株尺度条件下，干物质量反演表现出明显的阶段性差异。吐丝期、灌浆期与成熟期在模型精度、稳定性以及变量响应特征等方面均存在差别，这种差异不仅来源于作物生长过程本身，也与单株尺度下样本离散性较大、个体差异显著等特点密切相关。

在吐丝期，模型精度在引入结构变量后得到明显改善，但整体仍存在一定波动。由于单株尺度下个体间生长差异较为明显，光谱信息易受到局部冠层结构不均一性的影响，使得模型在不同样本区间表现不稳定。该时期植株处于快速伸长阶段，株高对干物质量变化具有较强指示作用，因此光谱变量 + 株高组合表现较为突出。但由于干物质尚未大量积累，光谱信息与结构变量之间的耦合关系仍不稳定，使得吐丝期更适合作为单株生长差异识别与趋势判断阶段。

在灌浆期，模型预测效果达到最佳水平，各变量组合与不同模型之间表现出较高一致性。相较于吐丝期，单株尺度下个体差异对模型的干扰有所减弱，

光谱信息与结构变量能够更加稳定地反映干物质变化过程。此时干物质快速积累,植被指数与结构变量响应同步增强,使模型在不同区间均能保持较好的拟合能力。因此,在单株尺度条件下,灌浆期不仅具有较高预测精度,同时也表现出较好稳定性,是开展精细化监测与模型构建的最优时期。

在成熟期,模型精度虽仍保持在较高水平,但整体表现较灌浆期有所下降。在单株尺度上,成熟期个体差异更多体现在籽粒充实程度等内部结构上,而这些变化难以通过表层光谱信息直接获取,从而导致模型对高值区间的识别能力下降。同时,株高变化趋于稳定,对干物质量的指示能力减弱,而茎粗虽仍保留一定结构差异,但增益作用逐渐趋于饱和。因此,成熟期更适合作为单株尺度模型结果验证与补充分析阶段。

从整体适用性来看,在单株尺度条件下,不同生育时期在干物质量反演中的功能定位更加明确:吐丝期适用于个体差异识别与早期监测,灌浆期适用于高精度建模与决策支持,成熟期则适用于模型稳定性检验与结果补充。该结果表明,在精细化农业管理中,应结合单株尺度特征合理选择观测时期,以充分发挥无人机多光谱与结构变量融合模型的应用价值。

3 讨论

3.1 光谱与结构变量协同作用机制

本研究结果表明,在单株尺度条件下,仅依赖植被指数对干物质量进行反演存在一定局限性,而引入结构变量后模型精度得到显著提升。这一现象在吐丝期与灌浆期尤为明显,与 2.1 节中植被指数相关性分析及 2.2 节结构变量作用结果相一致。

从机理上看,植被指数主要反映冠层叶绿素含量及光合状态,对生物量变化的表征具有一定间接性;而株高与茎粗分别从形态结构角度刻画植株生长特征,能够补充光谱信息中难以表达的空间结构信息。在单株尺度下,由于个体间差异较大,单一光谱信号易受到局部冠层不均一性的影响,而结构变量能够在一定程度上平衡这种波动,从而提高模型稳定性。

进一步分析发现,不同结构变量在各生育时期的作用存在差异。吐丝期以株高为主导,而灌浆期和成熟期茎粗贡献更为稳定,这种差异反映了作物生长过程由“形态扩展”向“物质积累”的转变。因此,光谱信息与结构变量融合,本质上是将“生理状态”与“形态结构”信息进行耦合,从而提升单株干物质量反演能力。

3.2 生育时期对模型性能的影响机制

不同生育时期模型预测能力存在显著差异,其中灌浆期表现最优,这一结果在 2.4 节中已得到验证。从作物生长过程来看,这种差异主要与干物质积累速率及光谱响应特征密切相关。

在吐丝期,植株仍处于快速生长阶段,干物质积累尚未达到高峰,光谱信息对生物量变化的响应相对较弱,同时单株间差异较大,导致模型稳定性较低。进入灌浆期后,光合产物大量向籽粒与茎秆转运,干物质快速积累,植被指数与结构变量对生物量变化的响应同步增强,使模型在不同区间均能保持较高精度与一致性。

相比之下,成熟期植株逐渐衰老,叶片光合能力下降,光谱信息趋于饱和,同时株高变化趋于稳定,导致模型对干物质量变化的敏感性降低。此外,成熟期个体差异更多体现在籽粒充实等内部结构上,而这些信息难以通过表层光谱获取,从而限制了模型性能的进一步提升。

因此,从模型构建角度来看,单株干物质量反演精度整体由大到小依次为灌浆期、吐丝期、成熟期,其中灌浆期为反演模型关键时期,而吐丝期与成熟期分别对应模型建立前期与后期验证阶段。

3.3 小样本与单株尺度建模特征

本研究在单株尺度和小样本条件下开展建模分析,相较于小区或区域尺度研究,其数据分布更加离散,对模型稳定性提出更高要求。从结果来看,随机森林在训练集上表现出较高拟合能力,但在测试集上存在一定波动,而岭回归与集成模型整体表现更为稳定,这与小样本条件下模型泛化能力的差异有关。

在单株尺度下,每个样本代表 1 个独立个体,生长状态受微环境影响较大,如局部土壤水分、养分分布及群体竞争等因素均可能导致个体差异扩大。这种差异在吐丝期尤为明显,而在灌浆期有所减弱,使得模型在不同生育阶段表现出不同稳定性特征。

从建模角度来看,结构变量的引入在一定程度上降低了单株尺度数据的随机波动,提高了模型对个体差异的适应能力。同时,采用相对简单且具有正则化约束的模型(如 Ridge)或集成方法,有助于在小样本条件下获得更稳定的预测结果。

4 结论

(1)不同植被指数对单株干物质量的表征能力存在显著差异,其中 NDRE 与 LCI 在各生育时期均表现出较高相关性,且在灌浆期相关性最强(NDRE 相关系数达 0.674),表明红边指数在高覆盖度条件

下具有更好的生物量指示能力。

（2）结构变量能显著提升单株干物质量预测能力，且其作用具有明显阶段性特征。吐丝期以株高为主导，而灌浆期与成熟期以茎粗贡献更为稳定，说明结构信息在中后期对干物质积累的表征更为直接。

（3）引入结构变量后模型精度明显提高，在灌浆期表现最为突出。Ridge 模型验证集 R^2 由 0.71 提升至 0.90，集成模型由 0.70 提升至 0.87，说明光谱变量 + 结构变量融合能有效增强模型对单株干物质量的解释能力。

（4）单株干物质量反演具有显著的生育时期依赖性，整体由大到小依次为灌浆期、吐丝期、成熟期。在单株尺度与小样本条件下，灌浆期模型精度与稳定性最佳，适合作为关键监测时期，可为精准灌溉与精细化农业管理提供可靠依据。

参 考 文 献

[1] 王俏. 提高全社会对依法保障粮食安全重要性的深刻认识[N]. 人民法院报, 2023 - 12 - 27.

[2] 姜长云, 李俊茹, 巩慧臻. 中国粮食安全形势演变及“十五五”粮食需求研判[J]. 改革, 2025(8): 35 - 51.
Jiang Changyun, Li Junru, Gong Huizhen. The evolution of China's food security situation and judgement of the food demand during the 15th Five-Year Plan period[J]. Reform, 2025(8): 35 - 51. (in Chinese)

[3] 李少昆, 赵久然, 董树亭, 等. 中国玉米栽培研究进展与展望[J]. 中国农业科学, 2017, 50(11): 1941 - 1959.
Li Shaokun, Zhao Jiuran, Dong Shuting, et al. Advances and prospects of maize cultivation in China[J]. Scientia Agricultura Sinica, 2017, 50(11): 1941 - 1959. (in Chinese)

[4] 吴鹏昊. 新疆玉米种植大面积单产提升的措施研究[J]. 种子科技, 2025, 43(24): 195 - 197.

[5] 刘建国. 玉米种植过程中现代农业技术运用与发展创新的系统分析[J]. 种子世界, 2026(2): 84 - 86.

[6] 车红岩, 潘耀忠, 夏兴生, 等. 基于集成和置信学习的半监督作物遥感分类方法[J]. 农业机械学报, 2025, 56(11): 418 - 432.
Che Hongyan, Pan Yaozhong, Xia Xingsheng, et al. Semi-supervised crop remote sensing classification based on ensemble and confident learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(11): 418 - 432. (in Chinese)

[7] 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 maize based on multisource remote sensing and meteorological parameters[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(12): 436 - 449. (in Chinese)

[8] 赵经华, 马世骄, 房城泰. 基于熵权-模糊综合评价法的无人机多光谱春玉米长势监测模型研究[J]. 农业机械学报, 2024, 55(8): 214 - 224.
Zhao Jinghua, Ma Shijiao, Fang Chengtai. Growth monitoring of spring maize using UAV multispectral imaging based on entropy weight - fuzzy comprehensive evaluation method[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(8): 214 - 224. (in Chinese)

[9] 王伟康, 张嘉懿, 汪慧, 等. 基于固定翼无人机多光谱影像的水稻长势关键指标无损监测[J]. 中国农业科学, 2023, 56(21): 4175 - 4191.
Wang Weikang, Zhang Jiayi, Wang Hui, et al. Non-destructive monitoring of rice growth key indicators based on fixed-wing UAV multispectral images[J]. Scientia Agricultura Sinica, 2023, 56(21): 4175 - 4191. (in Chinese)

[10] 陈盛德, 陈一钢, 徐小杰, 等. 基于无人机多光谱遥感的玉米 LAI 监测研究[J]. 华南农业大学学报, 2024, 45(4): 608 - 617.
Chen Shengde, Chen Yigang, Xu Xaojie, et al. Monitoring of corn leaf area index based on multispectral remote sensing of UAV[J]. Journal of South China Agricultural University, 2024, 45(4): 608 - 617. (in Chinese)

[11] Sharma L K, Bu H, Denton A, et al. Active-optical sensors using red NDVI compared to red-edge NDVI for prediction of corn grain yield[J]. Sensors, 2015, 15(11): 27832 - 27853.

[12] 程雪. 基于无人机高光谱数据的玉米叶面积指数估算模型研究[D]. 西安: 长安大学, 2020.
Cheng Xue. Research on estimation model of corn leaf area index based on UAV image[D]. Xi'an: Chang'an University, 2020. (in Chinese)

[13] 严海军, 卓越, 李茂娜, 等. 基于机器学习和无人机多光谱遥感的苜蓿产量预测[J]. 农业工程学报, 2022, 38(11): 64 - 71.
Yan Haijun, Zhuo Yue, Li Maona, et al. Alfalfa yield prediction using machine learning and UAV multispectral remote sensing[J]. Transactions of the CSAE, 2022, 38(11): 64 - 71. (in Chinese)

[14] 马俊伟, 陈鹏飞, 孙毅, 等. 基于无人机多光谱影像和机器学习方法的玉米叶面积指数反演研究[J]. 作物学报, 2023, 49(12): 3364 - 3376.
Ma Junwei, Chen Pengfei, Sun Yi, et al. Comparing different machine learning methods for maize leaf area index (LAI)

prediction using multispectral image from unmanned aerial vehicle(UAV)[J]. Acta Agronomica Sinica, 2023, 49(12): 3364 – 3376. (in Chinese)

[15] 白岚方, 路战远, 张向前, 等. 不同玉米品种灌浆期穗位叶光合特性日变化及青贮产量差异研究[J]. 河南农业科学, 2020, 49(4): 29 – 37.
Bai Lanfang, Lu Zhanyuan, Zhang Xiangqian, et al. Diurnal variation of photosynthetic characteristics of panicle position leaf during filling period and difference of silage yield of different maize varieties[J]. Journal of Henan Agricultural Sciences, 2020, 49(4): 29 – 37. (in Chinese)

[16] 许童羽,洪雪,陈春玲,等. 基于冠层 NDVI 数据的北方粳稻产量模型研究[J]. 浙江农业学报,2016,28(10):1790 – 1795.
Xu Tongyu, Hong Xue, Chen Chunling, et al. Study on northern japonica rice yield model based on canopy data of NDVI[J]. Acta Agriculturae Zhejiangensis, 2016, 28(10): 1790 – 1795. (in Chinese)

[17] 苏伟, 赵晓凤, 孙中平, 等. 基于 Sentinel – 2A 影像的玉米冠层叶绿素含量估算[J]. 光谱学与光谱分析, 2019, 39(5): 1535 – 1542.
Su Wei, Zhao Xiaofeng, Sun Zhongping, et al. Estimating the corn canopy chlorophyll content using the Sentinel – 2A image [J]. Spectroscopy and Spectral Analysis, 2019, 39(5): 1535 – 1542. (in Chinese)

[18] 马龙飞, 胡乃月, 李伟, 等. 利用无人机多光谱数据监测玉米对不同灌溉模式的响应差异[J]. 植物营养与肥料学报, 2022, 28(4): 743 – 753.
Ma Longfei, Hu Naiyue, Li Wei, et al. Using multispectral drone data to monitor maize's response to various irrigation modes [J]. Journal of Plant Nutrition and Fertilizers, 2022, 28(4): 743 – 753. (in Chinese)

[19] 冯海宽, 陶惠林, 赵钰, 等. 利用无人机高光谱估算冬小麦叶绿素含量[J]. 光谱学与光谱分析, 2022, 42(11): 3575 – 3580.
Feng Haikuan, Tao Huilin, Zhao Yu, et al. Estimation of chlorophyll content in winter wheat based on UAV hyperspectral [J]. Spectroscopy and Spectral Analysis, 2022, 42(11): 3575 – 3580. (in Chinese)

[20] Barzin R, Pathak R, Lotfi H, et al. Use of UAS multispectral imagery for corn yield prediction[J]. Remote Sensing, 2020, 12(15): 2392.

[21] Carlson T N, Ripley D A. On the relation between NDVI and vegetation cover[J]. Remote Sensing of Environment, 1997, 62(3): 241 – 252.

[22] Fitzgerald G J, Rodriguez D, Christensen L K, et al. Spectral sensing for nitrogen and water status[J]. Precision Agriculture, 2006, 7(4): 233 – 248.

[23] Gitelson A A, Merzlyak M N, Lichtenthaler H K. Detection of red edge position and chlorophyll content[J]. Journal of Plant Physiology, 1996, 148(3): 501 – 508.

[24] Zebarth B J, Younie M, Paul J W, et al. Leaf chlorophyll index for nitrogen recommendation[J]. Communications in Soil Science and Plant Analysis, 2002, 33(5 – 6): 665 – 684.

[25] Rondeaux G, Steven M, Baret F. Optimization of soil-adjusted vegetation index[J]. Remote Sensing of Environment, 1996, 55(2): 95 – 107.

[26] Zou H, Hastie T. Regularization and variable selection via the elastic net[J]. Journal of the Royal Statistical Society, 2005, 67(2): 301 – 320.

[27] Smola A J, Schölkopf B. A tutorial on support vector regression[J]. Statistics and Computing, 2004, 14(3): 199 – 222.

[28] Belgiu M, Drăguţ L. Random forest in remote sensing[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2016, 114: 24 – 31.

[29] Varma S, Simon R. Bias in error estimation using cross-validation[J]. BMC Bioinformatics, 2006, 7: 91.

[30] Zhou Z H. Ensemble methods: foundations and algorithms[M]. Chapman and Hall/CRC, 2025.