

蒋艳玲, 石江, 唐善勇, 等. 基于表型性状的玉米穗质量预测模型[J]. 山西农业科学, 2025, 53(5):8-20.

JIANG Y L, SHI J, TANG S Y, et al. Phenotype-based prediction model for maize ear weight[J]. Journal of Shanxi Agricultural Sciences, 2025, 53(5):8-20.

doi:10.26942/j.cnki.issn.1002-2481.2025.05.02

基于表型性状的玉米穗质量预测模型

蒋艳玲¹, 石江¹, 唐善勇¹, 李申斐¹, 胡方乾¹, 谭先明¹,
夏超², 兰海², 杨宸尧¹, 杨峰¹

(1. 四川农业大学 农学院, 四川 成都 611130; 2. 四川农业大学 玉米研究所, 四川 成都 611130)

摘要:为构建精准的玉米穗质量预测模型,并为玉米高产育种及精准田间管理提供一定的决策支持,以281个玉米重组自交系为材料,测定花期、株型、穗位叶和果穗4个类别共32个农艺性状,分别采用多元线性回归(MLR)、随机森林(RF)、支持向量机(SVM)和人工神经网络(ANN)构建穗质量预测模型,并在不同训练集比例下进行超参数调优以评估模型表现,通过集成策略生成集合均值模型,并对影响穗质量的关键影响因子进行解析。结果表明,各模型经超参数调优后表现各异,RF与SVM在训练集与测试集间保持较好的稳健性;ANN表现依赖样本规模,在50%~70%训练集比例下易过拟合,而在80%训练集时误差显著降低。MLR虽整体拟合度低于非线性模型,但仍展现出较好的预测能力。集合均值模型表现普遍优于或接近最优单一模型。在训练集比例为80%下,基于果穗性状(粒质量为主要贡献因子)构建的穗质量集合均值模型预测精度最高(R^2 为0.95,均方根误差为7.6 g,相对均方根误差为5%)。基于株高、雄花主轴长、穗位高等株型性状构建的模型预测精度一般(R^2 为0.34),但可用于生育早期的穗质量预测;仅基于开花期或穗位叶性状构建的模型预测能力有限($R^2 \leq 0.11$)。

关键词:玉米;穗质量预测;农艺性状;机器学习;超参数调优;多模型集成

中图分类号:S513 **文献标识码:**A **文章编号:**1002-2481(2025)05-0008-13

Phenotype-Based Prediction Model for Maize Ear Weight

JIANG Yanling¹, SHI Jiang¹, TANG Shanyong¹, LI Shenfei¹, HU Fangqian¹,
TAN Xianming¹, XIA Chao², LAN Hai², YANG Chenyao¹, YANG Feng¹

(1. College of Agronomy, Sichuan Agricultural University, Chengdu 611130, China;

2. Institute of Maize, Sichuan Agricultural University, Chengdu 611130, China)

Abstract: To develop an accurate prediction model for maize ear weight, and provide a certain level of decision support for high-yield maize breeding and precision field management, in this study, 32 phenotypic (agronomic) traits—covering four categories (flowering time, plant morphology, ear-leaf traits, and ear characteristics)—were measured across 281 maize recombinant inbred lines. Multiple linear regression (MLR), random forest (RF), support vector machine (SVM), and artificial neural networks (ANN) were employed to construct a prediction model for maize ear weight. Models were optimized through hyper-parameter tuning under different training–testing splits and evaluated for their performance. An ensemble-mean model was subsequently generated to integrate the individual predictions, which was also applied for analyzing the key contributing factors in maize ear-weight predictions. The results showed that model performance varied after hyper-parameter tuning: RF and SVM remained robust between training and test sets, whereas ANN relied on sample size, which was prone to over-fitting at smaller training sizes (50%–70%) but showed markedly reduced errors at an 80% of training fraction. Although MLR

收稿日期: 2025-05-07

基金项目: 国家重点研发计划(2023YFD1201100); 中国博士后科学基金(2024M762265); 四川省科技厅国际港澳台科技创新合作项目(2025YFHZ0140); 成都国家农高区智慧农业综合服务平台研究及应用项目(2023-YF08-00003-SN); 国家级大学生创新创业训练计划项目(202310626042)

作者简介: 蒋艳玲, 在读本科, 智慧农业专业, E-mail: JYL5101122003@163.com

通信作者: 杨峰, 教授, 博士, 主要从事作物高产高效及信息化研究, E-mail: f.yang@sicau.edu.cn

generally achieved lower goodness-of-fit than the non-linear models, it still delivered reasonable predictive power. Across all splits, the ensemble-mean model outperformed or matched the best single model. With an 80% training fraction, the ensemble-mean model based on ear traits—where grain weight was the dominant contributing factor—achieved the best performance ($R^2=0.95$; RMSE=7.6 g; Relative RMSE=5%). Models constructed from plant morphology traits (e.g., plant height, tassel length, ear height) showed moderate accuracy (R^2 is about 0.34), but could support early-stage prediction of ear weight. Models relying solely on flowering or ear-leaf traits had limited predictive ability ($R^2 \leq 0.11$).

Keywords: maize; ear weight prediction; agronomic traits; machine learning; hyper-parameter tuning; model ensemble

近年来,我国的玉米种植面积迅速增加,2020年全国玉米播种面积高达4 126万 hm^2 ,是水稻的1.37倍、小麦的1.76倍^[1]。玉米作为我国种植面积最大、产量最高的主要粮食作物,实现其高产、稳产对保障我国粮食安全具有重要意义^[2-4]。然而,随着全球气候变化,极端天气频率逐渐增加,对粮食生产安全带来了重大影响^[5-7]。在此背景下,做好玉米产量预测对于保障作物正常生产及推动玉米市场和相关行业的可持续发展具有重要意义。

在玉米产量构成中,穗质量是决定玉米产量的核心性状之一,建立基于田间农艺性状与穗质量之间关系的预测模型,对于玉米产量预测、品种选育、精准管理等具有重要的科学价值和实践意义^[8]。已有研究表明,开花期、株型、穗位叶、果穗性状等多种表型特征对穗质量具有潜在影响^[9-12],然而,如何定量表达其关系、量化各性状对穗质量构成的影响仍是一个亟待解决的科学问题。

传统的穗质量预测模型主要依赖田间试验和统计建模方法,但这些方法往往受数据规模、变量间复杂关系及非线性因素的限制,难以充分揭示穗质量与不同自变量的内在联系。相比之下,多变量回归分析与机器学习建模能够从复杂的性状体系中识别并量化对穗质量最具影响力的关键性状,从而揭示其潜在作用机制,提升对穗质量形成机制的解析能力。近年来,随着遥感技术、物联网技术、基因测序和高通量表型测量技术的发展,基于机器学习的预测模型逐渐成为农业数据挖掘的重要工具^[13-21]。机器学习模型,如随机森林^[17]、支持向量机^[22]、人工神经网络^[18]等,因其能够有效建立复杂的非线性关系,提高预测精度,在作物表型预测中的应用逐渐增加。王鹏新等^[17]利用随机森林模型结合条件植被温度指数和叶面积指数,成功估测了河北省玉米单位面积产量(平均相对误差为9.85%);罗正媛等^[22]采用支持向量机,基于播种面积、机械动力等因子模拟了黑龙江省1983—2010年的玉米产量,研究发现,应用SVM预测模

型预测玉米产量的能力优于基于3次指数平滑预测模型和多元线性回归预测模型。此外,机器学习算法在我国西南地区玉米生产中,也被用于复杂环境监测、产量潜力解析等方面^[23-25]。MIAO等^[26]研究表明,相较于传统方法,机器学习模型在区域玉米产量预测中展现出更高的准确性。综合以上研究表明,机器学习技术,特别是其强大的非线性建模能力,在区域尺度的玉米产量预测中能够有效提升预测精度。

目前,基于环境因子、生理基础和管理措施的玉米产量预测模型已取得一定成效^[14,17,22],但以田间可直接测定的玉米农艺性状为特征变量的机器学习模型的研究仍较少^[18]。基于此,本研究以玉米重组自交系群体为研究对象,选取开花期、株型、穗位叶、果穗等农艺性状为自变量,穗质量为因变量,构建多元线性回归和多个机器学习模型,并以线性回归模型为基线,对比机器学习模型的预测能力。同时,通过模型的训练和验证,系统评估各性状对穗质量预测的贡献度,挖掘对穗质量有重要影响的农艺性状,旨在为玉米产量预测及育种改良提供理论支撑与重要依据。

1 材料和方法

1.1 试验材料

选用玉米品种ZNC442和SCML0849作为基础材料,以ZNC442为母本、SCML0849为父本进行杂交,获得 F_1 杂交种。通过 F_1 自交获得 F_2 群体,并在 F_2 及其后代中采用单粒传递法,连续自交6~7代,最终获得纯合的重组自交系(RIL)群体。ZNC442由广西省农业科学院培育,SCML0849由四川农业大学玉米研究所选育,重组自交系群体材料由四川农业大学玉米研究所提供。

1.2 试验地概况

将299个家系的 F_6 西南玉米RIL群体,于2022年5月在云南省楚雄市牟定县试验田(101.5°E、25.3°N,海拔约为1 900 m)进行种植。该区域年平

均温度为 16.27 °C, 年降水量 1 201.88 mm(图 1), 土壤类型为酸性红壤。




图 1 试验地 2022 年月平均温度与降雨量

Fig.1 Monthly mean temperature and monthly precipitation at the experimental site in 2022

1.3 试验设计

试验采用随机区组设计, 共设 3 次重复, 双行种植, 行长 3 m, 行距 0.80 m, 穴距 0.40 m, 每穴 2 株, 每行共种植 12 株。田间管理措施与常规大田管理方式一致。

1.4 自交系群体农艺性状测定

1.4.1 开花期性状 抽雄期为播种日期至小区内 1/2 以上植株雄穗尖端露出顶叶的天数, 散粉期为播种日期至小区 1/2 以上植株的雄穗开始散粉的天数, 吐丝期为播种日期至小区 1/2 以上植株花丝从苞叶抽出的天数。

1.4.2 株型性状 在玉米散粉结束 10 d 后, 每个家系连续选取 5 株测定株高、穗位高、穗上叶片数、雄花分枝数、雄花主轴长度。

1.4.3 穗位叶性状 在玉米散粉结束 10 d 后, 每个家系连续选取 5 株测定穗位下 1 叶叶长, 穗位叶长, 穗上 1、2、3 叶叶长, 穗位下 1 叶叶宽, 穗位叶宽, 穗上 1、2、3 叶叶宽, 穗上 1、2、3 叶叶夹角, 穗上 1、2、3 叶高点长度。

1.4.4 果穗性状 在成熟期后期, 每个家系连续收取 10 个果穗, 经晒干后(籽粒水分 15% 左右)测定穗质量、穗长、穗粗、穗行数、行粒数、凸尖数、籽粒质量、轴粗、百粒质量。

1.5 模型选择

1.5.1 多元线性回归模型 多元线性回归(Multiple Linear Regression, MLR)是一种用于分析多个自

变量与因变量之间关系的统计建模方法。其基本思路是在单变量线性回归的基础上引入多个自变量, 通过线性方程描述自变量(除穗质量外的测量性状)对因变量(穗质量)的综合影响^[27-28]。

$$y_i = b_0 + b_1 x_i + b_2 x_{i,2} + \cdots + b_k x_{i,k} + e_i \quad (1)$$

其中, y_i 为因变量, b_0 为常数(截距), $x_{i,k}$ 为自变量, b_k 为回归系数向量(斜率), e_i 是随机测量误差。

1.5.2 随机森林模型 随机森林(Random forest, RF)是一种集成学习方法, 通过多个决策树的集体预测来提高模型的预测精度^[17,19,29]。其原理是在训练阶段生成大量决策树, 首先是样本随机采样即对训练数据进行多次有放回采样, 生成多个不同的数据子集。然后, 是构建决策树即在每个数据子集上构建一棵回归决策树, 一般可采用均方误差作为分裂标准, 选择最优特征进行分裂。进一步在构建每棵树时, 随机选择部分特征进行分裂, 以增加模型的多样性并降低过拟合风险; 最后将所有决策树的预测结果进行平均, 作为最终预测结果^[19]。

$$\hat{y} = \frac{1}{N} \sum_{i=1}^N T_i(X) \quad (2)$$

其中, $\hat{y}$ 表示因变量, T_i 为基于输入 X 的第 i 棵决策树的预测值; N 为决策树数量。

1.5.3 支持向量机模型 支持向量机(Support vector machine, SVM)在回归任务中又叫支持向量回归(Support vector regression), 旨在揭示高维

度、非线性变量之间的复杂关系,其核心在于寻找数据集中与目标值偏差最小的超平面,并尽可能将预测误差控制在较低水平^[14,19-20,22]。

$$y = \sum_{i=1}^N W_i \text{Ker}(x_i, x_j) + b \quad (3)$$

其中, y 表示因变量, W_i 表示分配给每个预测变量的相应权重; $\text{Ker}(x_i, x_j)$ 表示核函数,用于对输入变量进行映射和处理,从而捕获输入变量之间的非线性关系; b 表示偏置项,用于调整回归平面在高维空间中的位置。

1.5.4 人工神经网络模型 人工神经网络(Artificial neural network, ANN)是一种模仿生物神经网络结构与功能的机器学习模型,其中基于反向传播算法的神经网络广泛应用于玉米产量预测^[14-15,18]。

$$y_j = f\left(\sum_{i=1}^n w_{ij} x_i + b_j\right) \quad (4)$$

其中, y_j 为第 j 个神经元的输出, x_i 为输入特征, w_{ij} 为第 j 个神经元下 x_i 的权重, b_j 为偏置项。

1.6 数据分析

基于表型性状对玉米穗质量进行预测的技术路线如图2所示。




图2 技术路线

Fig.2 The technical route

基于281个家系西南玉米RIL群体的花期、株型、穗位叶和果穗4类表型性状,采用多元线性回归、随机森林、支持向量机和人工神经网络4种算法构建穗质量预测模型;在不同训练集和测试集比例下(50%:50%、60%:40%、70%:30%、80%:

20%),通过超参数调优和多模型集成优化预测性能,解析各性状对穗质量预测的贡献度(图2)。

1.6.1 超参数调优 机器学习模型的性能受多种因素影响,其中,超参数的设定直接关系到模型的学习能力和泛化性能^[30]。根据不同环境下的实测数据调整并优化模型的超参数对确保模型的稳定性至关重要^[15,19,29-31]。本研究采用网格搜索(Grid search)法对超参数进行调优。它是基于Scikit-learn算法框架下的Grid search CV方法,通过在预设的超参数网格(预设的超参数取值范围的组合)中遍历所有可能的参数组合,并结合k-fold(本研究设置k=10)交叉验证评估模型表现。最终,依据均方误差评估不同参数组合的表现,进而选择最佳超参数配置。

1.6.2 模型评估 由于单一模型在不同数据集上的预测能力存在差异,本研究在多模型基础上计算集合模型均值(即所有模型模拟值的均值),以评估其是否能够综合不同模型的优势,提高泛化能力,增强对玉米穗质量的预测精度。评估统计指标包括平均绝对误差(MAE)、均方根误差(RMSE)、相对均方根误差(相对RMSE)和决定系数(R^2)。这些指标常用于评估模型对作物产量的预测精度和准确度^[14,19-20]。

1.6.3 穗质量预测的贡献度分析 采用置换重要性评估各输入性状对穗质量预测的贡献度。该方法通过对单个特征进行随机重组排列,保持其他特征和目标变量不变,观察模型预测误差的变化^[32]。若某个特征在置换后误差大幅上升,说明该特征对模型预测贡献较大;若变化不明显,则表明该特征重要性较低。基于Scikit-learn框架下的Permutation importance算法^[32],在测试集上进行随机特征置换(重复50次),并以均方误差作为评估指标。各性状特征在所有模型下分别计算置换重要性,并取各模型的结果中值,以综合评估各特征性状对穗质量预测的贡献度。

2 结果与分析

2.1 玉米农艺性状的统计分析

对RIL群体的农艺性状进行统计分析发现(表1),3个开花期性状的变异系数均 $\leq 3\%$,表明在群体分离过程中性状稳定性较好。在株型性状中,雄花分枝数在群体后代分离过程中变异系数较大,达36.07%,性状稳定性较差;而穗上叶片数

的变异系数为 8.34%, 是株型性状中变异系数最小的性状。穗位叶性状的变异系数为 10%~18%, 稳定性较好。在果穗性状中凸尖长度的变异系数最大, 为 78.69%, 稳定性较差; 穗粗的变异系数最小, 为 7.02%, 稳定性较好。以上结果说

明, RIL 群体性状变异生育期最稳定, 穗位叶中等, 株型与果穗部分性状波动大, 其中, 雄花分枝数与凸尖长度变异较大, 是群体分离差异的主要来源。

表 1 玉米自交系(n=281)的农艺性状分析

Tab.1 Agronomic trait analysis of maize inbred lines(n=281)

项目 Item	农艺性状 Agronomic traits	最小值 Minimum	最大值 Maximum	平均值 Average value	变异系数/% CV
开花期 Flowering	抽雄期/d Days to tasseling(DTT)	65.33	77.00	71.57	3.06
	散粉期/d Days to pollen-shedding(DTP)	69.00	80.67	74.52	2.84
	吐丝期/d Days to silking(DTS)	69.00	80.67	75.17	2.99
株型 Plant morphology	株高/cm Plant height(PH)	127.42	340.38	270.84	11.36
	穗位高/cm Ear position height(EPH)	58.84	147.71	113.61	13.41
	穗上叶片数/个 Number of leaves above ear(NLAE)	5.38	9.40	7.07	8.34
	雄花分枝数/个 Tassel branch number(TBN)	1.56	25.78	10.49	36.07
	雄花主轴长/cm Tassel length(TL)	21.54	39.67	30.67	10.09
	穗下 1 叶叶长/cm First leaf length below ear(FLLBE)	54.03	109.72	90.77	10.40
	穗下 1 叶叶宽/cm First leaf width below ear(FLWBE)	6.96	14.06	10.77	11.14
穗位叶 Ear leaves	穗位叶长/cm Leaf length positioned at ear(LLPAE)	49.61	103.43	85.19	11.08
	穗位叶宽/cm Leaf Width positioned at ear(LWPAE)	7.22	14.02	10.77	11.21
	穗上 1 叶叶夹角/° First leaf angle above ear(FLAAE)	17.86	44.49	25.51	14.95
	穗上 1 叶叶长/cm First leaf length above ear(FLLAE)	46.00	97.09	77.89	11.56
	穗上 1 叶叶宽/cm First leaf width above ear(FLWAE)	7.12	13.97	10.65	11.39
	穗上 1 叶高点长/cm First leaf tip to ear height(FLTEH)	46.00	89.44	67.51	11.89
	穗上 2 叶叶夹角/° Second leaf angle above ear(SLAAE)	16.04	37.79	24.56	17.02
	穗上 2 叶叶长/cm Second leaf length above ear(SLLAE)	43.87	89.86	69.82	11.93
	穗上 2 叶叶宽/cm Second leaf width above ear(SLWAE)	6.73	13.67	10.26	11.71
	穗上 2 叶高点长/cm Second leaf tip to ear height(SLTEH)	43.70	80.39	62.02	13.12
	穗上 3 叶叶夹角/° Third leaf angle above ear(TLAAE)	15.31	39.03	24.37	18.23
	穗上 3 叶叶长/cm Third leaf length above ear(TLLAE)	40.14	80.81	61.98	12.43
	穗上 3 叶叶宽/cm Third leaf width above ear(TLWAE)	6.11	12.94	9.55	12.29
	穗上 3 叶高点长/cm Third leaf tip to ear height(TLTEH)	37.97	76.01	56.03	13.28
	穗长/cm Ear length(EL)	8.63	21.41	14.95	12.35
	穗行数 Ear row number(ERN)	12.40	21.60	15.44	11.01
	行粒数 Grains per row(GPR)	18.58	45.33	30.95	14.49
果穗 Ear	穗粗/cm Ear diameter(ED)	3.64	5.62	4.65	7.02
	百粒质量/g Hundred grain weight(HGW)	13.02	43.22	29.92	17.23
	秃尖长度/cm Barren tip of the ear(BTE)	0.00	2.58	0.63	78.69
	轴粗/cm Ear axis diameter(EAD)	2.24	3.49	2.80	8.07
	粒质量/g Grain weight(GW)	30.80	241.56	119.11	29.47
	穗质量/g Ear weight(EW)	43.10	281.86	148.63	26.58

2.2 最优超参数配置及模型表现

2.2.1 各模型最优超参数配置 通过网格搜索结合 10 fold 交叉验证, 基于所有性状获得不同训练集比例下各模型的最优超参数, 并推导多元线性

回归(MLR)方程(表 2)。RF 整体对超参数变化相对不敏感, 最优配置倾向于中等或较浅的树深(Max_depth), 较少的决策树数量(N_estimators), 以及较小的节点划分最小样本数(Min_samples_

split)和叶子节点最小样本数(Min_samples_leaf);SVM模型的最优配置显示出对核函数和正则化参数(C)的依赖性较强,最优配置倾向于选择线性核(Kernel=linear)并搭配较低的正则化强度(C=10)和核函数系数(Gamma=0.000 1);ANN在不同训练集比例下,对结构与训练超参较敏感,网络容量随样本量上升而增大,学习率始终

取小且随样本量增大进一步减小,保证了收敛稳定;MLR则分别给出不同训练集比例的最优回归方程以刻画性状与穗质量的线性关系。总体而言,RF参数鲁棒性较强,调优收益有限;SVM与ANN需精细搜索;MLR可提供可解释的线性基线。

表2 基于所有性状模型超参数调优结果及多元线性回归方程

Tab.2 Hyper-parameter tuning results based on all trait models and the multiple linear regression models

训练集比例/% Training fraction	模型名称 Model	模型的最优参数设置 Optimal parameter settings for models
50	MLR	$EW = -1.64DTT + 0.59DTP + 2.00DTS + 0.61PH - 1.87EPH - 0.50NLAE + 1.41TBN - 0.67TL - 1.36FLLBE + 6.78FLWBE + 7.93LLPAE - 7.88LWPAE - 2.96FLAAE - 5.16FLLAE - 2.82FLWAE - 0.01FLTEH + 1.59SLAAE - 4.75SLLAE + 5.92SLWAE - 0.24SLTEH + 0.66TLAAE + 4.03TLLAE - 1.95TLWAE + 0.65TLTEH + 0.98EL + 3.60ERN + 3.43GPR - 0.15ED + 6.23HGW - 0.0046BTE + 1.44EAD + 30.69GW + 147.86$
	RF	最大树深度=10,叶子节点最小样本数=2,节点划分所需的最小样本数=2,决策树数量=350
	SVM	正则化参数=10,核函数的常数项=0,核函数系数=0.000 1,核函数=linear
	ANN	激活函数=tanh,正则化参数=0.1,隐藏层大小=(100,50),初始学习率=0.000 1,优化算法=sgd
60	MLR	$EW = -1.33DTT + 0.57DTP + 1.66DTS - 0.85PH - 0.92EPH + 1.17NLAE + 1.13TBN - 0.57TL - 2.28FLLBE + 3.10FLWBE + 9.05LLPAE - 0.60LWPAE - 0.94FLAAE - 8.18FLLAE - 5.14FLWAE + 1.31FLTEH + 1.05SLAAE - 3.55SLLAE + 4.11SLWAE - 0.95SLTEH - 1.09TLAAE + 5.87TLLAE - 1.51TLWAE - 0.80TLTEH + 0.76EL + 3.01ERN + 4.07GPR + 0.78ED + 6.96HGW + 0.17BTE + 1.41EAD + 30.65GW + 148.20$
	RF	最大树深度=15,叶子节点最小样本数=1,节点划分所需的最小样本数=2,决策树数量=50
	SVM	正则化参数=10,核函数的常数项=0,核函数系数=0.000 1,核函数=linear
	ANN	激活函数=tanh,正则化参数=0.1,隐藏层大小=(100,50),初始学习率=0.000 1,优化算法=sgd
70	MLR	$EW = -1.91DTT + 2.02DTP + 0.84DTS - 0.71PH - 0.70EPH + 0.71NLAE + 0.98TBN - 0.53TL - 2.16FLLBE + 3.76FLWBE + 7.83LLPAE - 1.69LWPAE - 1.39FLAAE - 7.77FLLAE - 5.06FLWAE + 1.05FLTEH + 2.06SLAAE - 1.76SLLAE + 3.97SLWAE - 1.28SLTEH - 1.76TLAAE + 5.17TLLAE - 0.85TLWAE - 0.53TLTEH + 0.51EL + 3.31ERN + 4.44GPR + 0.09ED + 6.96HGW + 0.36BTE + 1.72EAD + 31.09GW + 148.42$
	RF	最大树深度=10,叶子节点最小样本数=2,节点划分所需的最小样本数=2,决策树数量=50
	SVM	正则化参数=10,核函数的常数项=0,核函数系数=0.000 1,核函数=linear
	ANN	激活函数=tanh,正则化参数=0.1,隐藏层大小=(150,100),初始学习率=0.000 1,优化算法=sgd
80	MLR	$EW = -1.56DTT + 1.62DTP + 1.03DTS - 0.59PH - 0.83EPH + 0.62NLAE + 1.00TBN - 0.42TL - 2.03FLLBE + 3.72FLWBE + 6.29LLPAE - 1.31LWPAE - 1.78FLAAE - 4.44FLLAE - 4.80FLWAE - 0.06FLTEH + 1.99SLAAE - 3.75SLLAE + 3.64SLWAE - 0.40SLTEH - 1.69TLAAE + 4.99TLLAE - 0.99TLWAE - 0.56TLTEH + 0.67EL + 2.64ERN + 4.21GPR + 0.46ED + 6.10HGW + 0.12BTE + 2.00EAD + 32.03GW + 149.55$
	RF	最大树深度=15,叶子节点最小样本数=2,节点划分所需的最小样本数=5,决策树数量=200
	SVM	正则化参数=1,核函数的常数项=0,核函数系数=0.000 1,核函数=linear
	ANN	激活函数=tanh,正则化参数= 1×10^{-5} ,隐藏层大小=(200,0),初始学习率= 1×10^{-5} ,优化算法=sgd

2.2.2 训练集拟合度分析 在训练集上,各模型调优后拟合度表现如图3所示,MLR模型拟合度(R^2)在各比例下保持稳定,但整体表现低于非线性模型。SVM模型的RMSE为7 g左右,相对RMSE为5%左右, R^2 在各比例下均超过0.95。RF在训练集上的RMSE小于5 g,相对RMSE小于3%, R^2 始终超过0.95。ANN在50%~70%训

练集比例下保持着极低的误差(相对RMSE接近于0), R^2 大于0.95,但在80%比例训练集下展现出一定误差。集合均值模型拟合表现较好,误差较小(MAE为2~4 g, RMSE为4~5 g, 相对RMSE为3%左右),展现了多模型融合在样本内拟合中的优势。因此,在进行穗质量预测中优选集合均值模型。




图3 基于所有性状训练的模型在训练集上对穗质量的预测表现

Fig.3 Predictive performance of models trained on all measured traits for ear weight across different training sets

2.2.3 测试集预测表现 在测试集上,各模型调

优后预测性能如图4所示。




图4 基于所有性状训练的模型在测试集上对穗质量的预测表现

Fig.4 Predictive performance of models trained on all measured traits for ear weight across different test sets

由图4可知,MLR与SVM的预测性能在各训练集比例下接近,MAE为5~6 g, RMSE为8 g左右,相对RMSE为5%~6%, R^2 大于0.95,体现了良好的预测能力。RF的MAE小于7 g, RMSE为7~10 g,相对RMSE为5%~7%, R^2 大于0.95,但其表现略逊于(除80%训练集比例以外)MLR和SVM。ANN模型在50%~70%训练集比例下展示出较大的误差(各模型中表现最差),MAE为9~10 g, RMSE为15~17 g,相对RMSE为10%~12%, R^2 约为0.85;结合其在训练集上的表现(图3),说明ANN在50%~70%训练集比例下可能存在过拟合。但在80%训练集比例下,ANN的预测误差显著降低,表明大样本下ANN能有效学习复杂非线性模式。集合均值模型在测试集中的预测性能普遍优于或接近最优单一模型(MAE约为5 g, RMSE为6~8 g,相对RMSE约为5%, R^2 约为

0.95),充分体现了多模型融合在提升样本预测能力方面的有效性与稳健性。在80%训练集比例下,集合均值模型的预测误差(MAE、RMSE、相对RMSE)均为各比例中最小。

2.3 集合均值模型穗质量预测表现

2.3.1 基于单一性状的穗质量预测 由图5可知,在80%训练集比例下,基于果穗性状构建的集合均值模型其预测性能最佳,MAE为5.5 g, RMSE为7.6 g,相对RMSE为5%, R^2 为0.95。基于株型性状构建的模型预测能力有限,MAE和RMSE分别为24.8、30.4 g,相对RMSE为21%, R^2 为0.34。基于开花期、穗位叶等性状构建的模型预测性能均较差,MAE和RMSE最高,分别为29.9、37.0 g,相对RMSE分别为23%、26%, $R^2 \leq 0.11$ 。表明基于果穗性状构建的模型较能更好预测该自交系群体的玉米穗质量。




图5 基于单一类性状构建的集合均值模型对穗质量的预测表现

Fig.5 Predictive performance of ensemble-mean models built with a single trait category for ear weight

2.3.2 基于所有性状的穗质量预测 基于所有性状构建的集合均值模型对穗质量的预测表现如图 6 所示。




图 6 基于所有性状构建的集合均值模型对穗质量的预测表现

Fig.6 Predictive performance of the ensemble-mean model built with all trait categories for ear weight

图 6 展示了在 80% 训练集比例下,基于所有性

状训练的集合均值模型在测试集上的玉米穗质量预测表现,该综合模型展现了优异的预测性能,MAE 为 5.3 g, RMSE 为 7.0 g, 相对 RMSE 为 5%, R^2 高达 0.96。模型表现显著优于大部分仅基于单一性状类别(开花期、株型、穗位叶)构建的模型,但仅略优于基于果穗性状建立的模型,表明穗质量的可解释变异可能主要由果穗类性状驱动,其他性状仅提供边际增益。

2.4 性状对穗质量预测的贡献度分析

由于不同模型在结构上存在差异,即使输入相同的数据,不同模型计算得到的各性状贡献率也会有所不同。因此,本研究所呈现的标准化贡献值是基于多模型结果的中值,以确保对各性状预测重要性的综合性评价。此外,鉴于不同训练集比例下模型表现存在差异,以下结果均是在 80% (最优) 训练集比例下进行分析的。

2.4.1 基于单一类性状构建的穗质量预测模型中各性状预测穗质量的贡献度 基于单一类性状构建的穗质量预测模型中各性状的贡献值如图 7 所示。




图 7 基于单一类性状构建的穗质量预测模型中各性状的贡献值

Fig.7 Normalized contribution value of individual measured traits in ear-weight prediction models built with a single trait category

由图7可知,在果穗性状中,粒质量是预测玉米穗质量贡献度最高的性状,其重要性显著高于其他果穗性状,达到了0.97,突显了粒质量作为产量主导性状的核心作用。其中,百粒质量也具有一定的贡献度,但其贡献值远低于粒质量。在株型性状中,株高和雄花主轴长是穗质量预测贡献度较高的性状,株高达0.7左右,雄花主轴长为0.25左右,穗位高(EPH)的贡献度较低,表明了植株整体生长势与生殖器官结构对产量的综合影响相对较低。在穗位叶性状中,穗下1叶叶长、穗上2叶叶长和穗上3叶叶长是穗质量预测贡献度较高的性状,表明穗位叶长度(作为光合面积的代理指标)对籽粒灌浆与产量积累具有直接作用。但需要注意的是,基于穗位叶构建的模型解释度较低。在开花期性状中,模型主要依赖抽雄期(DTT)或吐丝期(DTS)进行预测,其中,抽雄期贡献度最高(约0.6),吐丝期次之(约0.4),散粉期贡献度最低。

2.4.2 基于所有性状构建的穗质量预测模型中各性状预测穗质量的贡献度 基于所有性状构建的穗质量预测模型中各性状的贡献值如图8所示。




图8 基于所有性状构建的穗质量预测模型中各性状的贡献值

Fig.8 Normalized contribution value of individual measured traits in the ear-weight prediction model built with all trait categories

由图8可知,粒质量是预测玉米穗质量的唯一主导性状,贡献度达到了0.85,凸显其在产量形成中的核心地位。除粒质量外,仅有少数性状表现出一定的重要性,包括百粒质量、行粒数、穗上1叶叶长、散粉期和穗下1叶叶宽,但其贡献度均明显

低于粒质量(贡献度小于0.5%的性状未展示)。值得注意的是,尽管在单一性状类别模型中部分株型性状(如株高、雄花主轴长)显示出一定预测价值,但在整合所有性状后,株型性状的预测贡献几乎可忽略不计,表明在多性状融合条件下模型可能更倾向于依赖直接反映产量构成的性状。

3 结论与讨论

本研究基于含281个家系的RIL群体,选取开花期、株型、穗位叶及果穗性状作为玉米单株穗质量预测的自变量,通过多元线性回归、随机森林、支持向量机和人工神经网络4种算法构建预测模型,并对各模型进行超参数调优,并分析了调优对模型拟合和预测性能的影响。同时,评估基于单一类别性状(开花期、株型、穗位叶、果穗)及多性状融合的集合均值模型对玉米穗质量的预测表现,并定量解析了各性状在模型中的贡献度,旨在为玉米穗质量预测及育种提供参考。

超参数调优在确定机器学习模型的精度和预测效能方面具有至关重要的作用。通过优化超参数的组合,模型在测试数据集或未知数据中的预测性能和稳健性得以提升^[16,19,30]。本研究在不同训练集与测试集比例下,系统分析了模型预测性能,研究发现,MLR虽是线性模型,但在多性状(尤其是果穗性状)模型中仍表现良好,这表明当自变量(如粒质量、百粒质量等)与因变量存在较强线性关系时,传统的多元线性模型依然具备良好的预测能力。SVM总体表现稳健,在训练集各比例下均展现出较好的拟合度($R^2 > 0.95$, $RMSE \approx 7$ g, 相对 $RMSE \approx 5\%$),且在测试集中的预测表现($R^2 \geq 0.95$, $RMSE \approx 8$ g, 相对 $RMSE$ 为 $5\% \sim 6\%$)与训练集基本一致,80%训练集时最佳。RF的表现也比较稳定,训练集上 $R^2 > 0.95$, $RMSE < 5$ g, 相对 $RMSE < 3\%$;测试集上 $R^2 > 0.95$, $RMSE$ 为 $7 \sim 10$ g, 相对 $RMSE$ 为 $5\% \sim 7\%$ 。RF的稳健性可能与多树集成及随机特征子空间带来的内在正则化有关,可在多性状共线性背景下保持较强泛化能力^[25]。ANN显著依赖样本规模,在 $50\% \sim 70\%$ 训练集比例下易过拟合(训练误差极低而测试集上误差偏高),但在80%训练集时,其预测误差显著下降。这可能是因为ANN随网络结构与优化超参的细化,对复杂非线性关系的表征能力增强,预测能力得到了提高^[19,31]。集合均值模型通过集

成多模型结果,充分融合了各模型优势,其预测能力优于或接近最优单一模型的表现。本研究结果发现,模型融合在提升预测精度与稳健性方面的有效性,突显了多模型互补性在数据模式建模中的重要作用。这与当前多模型集成研究的结论相一致^[14,16,19]。

本研究系统评估了基于单一性状类别与多性状融合构建的集合均值模型对玉米穗质量的预测能力,并在多模型基础上解析了各性状在穗质量预测中的贡献度。研究发现,基于所有类别性状构建的集合均值模型在测试集上表现出较好的预测能力(MAE=5.3 g, RMSE=7.0 g, 相对 RMSE=5%, $R^2=0.96$)。多性状融合显著优于基于单一性状类别(开花期、株型或穗位叶)构建的模型,但预测性能与基于果穗性状训练的模型相似。这表明多性状融合并未显著提升模型的整体预测性能,模型较高的预测能力主要来源于果穗性状的贡献。其他性状的加入可能引入了噪声或特征冗余,干扰了模型对穗质量的有效预测。MORA-POBLETE 等^[33]基于 258 个玉米自交系的研究结果表明,相较单性状和单一环境,多性状模型准确度提高 14.4%,但在多环境框架下单性状模型较多性状分析的预测精度反而提高 6.4%。表明穗质量预测的主要信息来自果穗性状,叠加其他性状不能提升模型的预测能力。

基于果穗性状构建的模型表现最优(R^2 达到了 0.95),这与玉米产量形成的生理机制高度契合。粒质量、百粒质量等指标则是产量构成的重要组成部分,因此,模型对果穗性状高度依赖。OLIVOTO 等^[34]采用序列通径分析在多性状中筛选出共线性最低、解释力最高的关键因子,发现每穗粒数和千粒质量对玉米产量具有较大的影响。这与本研究筛选出的重要果穗性状,如粒质量、百粒质量、行粒数相吻合。李清超等^[35]研究发现,单穗粒质量对玉米产量构成占主要作用,这与本研究中粒质量为最重要贡献因子的结果一致。

基于株型性状构建的模型有一定的预测能力, R^2 达到 0.34。尽管整体预测效果弱于果穗性状,但在生长前期即可依据株型特征对玉米产量进行初步预测,具备一定应用价值。株高适宜有助于抗倒伏并改善冠层结构促进光合效能;较长的雄花主轴有助于提升群体花粉量和散粉覆盖,减少授粉盲区;适宜的穗位高度有利于提高授粉

成功率与结实率,尤其在高密度种植条件下更为关键。因此,株型模型虽非最终高精度预测的最优方案,但可在拔节—抽雄期用于分层管理与材料筛选。

基于穗位叶和开花期性状构建的模型误差较大、解释性欠佳,可能主要受 2 个方面因素制约:一是样本量不足,二是性状与穗质量之间缺乏直接的生理联系。统计层面上,样本规模偏小可能放大随机误差、降低统计功效,从而削弱模型稳健性;生理层面上,穗位叶指标多为特定时点的局部静态形态量,难以表征灌浆期整株光合同化物分配、籽粒库强等决定穗质量的“源—库—流”动态,存在明显的时空尺度不匹配^[11,36]。开花期更可能通过环境胁迫(热/旱/涝)对授粉与灌浆产生间接影响^[37-40],与产量形成的相关性较弱,致使仅以花期表型进行预测的信号较弱、适用性较差。上述模式在其他作物中也有体现。DAS 等^[20]在 518 份小扁豆材料上采用 ANN 和 SVR 构建了混合机器学习模型,发现花期与产量相关性小于 0.1,而植株一级/二级分枝数与产量的相关性亦未超过 0.5。

本研究在多性状建模、超参数调优与模型融合等方面的探索为玉米穗质量预测提供了参考,但需要注意的是本研究仅基于表型数据构建模型,存在一定的局限性。未来应引入遗传数据(如基因型标记)和环境数据(天气、土壤等),以充分捕获基因型—环境互作($G \times E$)对表型的影响,深入揭示基因型、环境与表型之间的关系,从而建立具有更强解释性和通用性的作物表型预测模型,助力智能育种与数据驱动型农业的发展。

参考文献:

- [1] 曾智勇. 我国玉米生产现状分析及建议[J]. 粮油与饲料科技, 2022(3):4-8.
ZENG Z Y. Analysis and suggestions on the current situation of corn production in China[J]. Grain Oil and Feed Technology, 2022(3):4-8.
- [2] 孟战赢,王育红,郭党,等. 不同种植密度对夏玉米产量及农艺性状的影响[J]. 山西农业科学, 2025, 53(3):50-57.
MENG Z Y, WANG Y H, GUO D, et al. Effects of different planting densities on yield and agronomic traits of summer maize[J]. Journal of Shanxi Agricultural Sciences, 2025, 53(3):50-57.
- [3] 李志,路浩冉,杨官官,等. 河南省夏玉米花期高温热害时空分布特征[J]. 河南农业科学, 2024, 53(7):10-20.
LI Z, LU H R, YANG G G, et al. Spatial and temporal distribu-

- tion characteristics of heat damage at flowering stage of summer maize in Henan Province[J]. *Journal of Henan Agricultural Sciences*, 2024, 53(7):10-20.
- [4] 张丽光, 杨亚星, 范雅琦, 等. 不同覆膜方式对旱作玉米产量与土壤理化性质的影响[J]. *山西农业科学*, 2025, 53(4):11-19.
ZHANG L G, YANG Y X, FAN Y Q, et al. Effects of different film mulching methods on yield and soil physical and chemical properties of dryland maize[J]. *Journal of Shanxi Agricultural Sciences*, 2025, 53(4):11-19.
- [5] 王天雪. 近30年来气候变化对中国主要种植区春-夏玉米产量的影响[D]. 杨凌:西北农林科技大学, 2021.
WANG T X. Impacts of climate change on spring and summer maize yields of main planting zone in China in recent 30 years [D]. Yangling: Northwest A&F University, 2021.
- [6] WU J Z, ZHANG J, GE Z M, et al. Impact of climate change on maize yield in China from 1979 to 2016[J]. *Journal of Integrative Agriculture*, 2021, 20(1):289-299.
- [7] 王雅坤, 李鸿萍, 徐真真, 等. 高温干旱复合胁迫对玉米光合生理的影响[J]. *河南农业科学*, 2023, 52(5):17-23.
WANG Y K, LI H P, XU Z Z, et al. Effects of combined stress of high temperature and drought on photosynthetic physiology of maize[J]. *Journal of Henan Agricultural Sciences*, 2023, 52(5):17-23.
- [8] 谭静, 陈洪梅, 韩学莉, 等. 玉米杂交种产量与产量构成因素的相关和通径分析[J]. *华北农学报*, 2009, 24(S2):155-158.
TAN J, CHEN H M, HAN X L, et al. Correlation and path analysis on yield and yield component traits of maize hybrid[J]. *Acta Agriculturae Boreali-Sinica*, 2009, 24(S2):155-158.
- [9] YUAN Y B, CAIRNS J E, BABU R, et al. Genome-wide association mapping and genomic prediction analyses reveal the genetic architecture of grain yield and flowering time under drought and heat stress conditions in maize[J]. *Frontiers in Plant Science*, 2019, 9:1919.
- [10] 陈勇. 玉米主要株型性状与产量的相关及通径分析[J]. *广东农业科学*, 2012, 39(12):15-16.
CHEN Y. Correlation and path analysis of major plant characters and yield of maize[J]. *Guangdong Agricultural Sciences*, 2012, 39(12):15-16.
- [11] TIAN J G, WANG C L, CHEN F Y, et al. Maize smart-canopy architecture enhances yield at high densities[J]. *Nature*, 2024, 632:576-584.
- [12] 郝茹雪, 王健, 武宝悦, 等. 不同春玉米品种产量及其构成因素通径分析[J]. *黑龙江农业科学*, 2020(1):9-11.
HAO R X, WANG J, WU B Y, et al. Path analysis of yield and its component traits of different spring maize varieties[J]. *Heilongjiang Agricultural Sciences*, 2020(1):9-11.
- [13] 高海荣, 张钟莉莉, 岳焕芳, 等. 基于Bayesian-XGBoost的生菜作物系数估算方法[J]. *山西农业科学*, 2022, 50(10):1482-1488.
GAO H R, ZHANG Z L L, YUE H F, et al. Estimation method of lettuce crop coefficient based on Bayesian-XGBoost [J]. *Journal of Shanxi Agricultural Sciences*, 2022, 50(10):1482-1488.
- [14] 邹扬锋. 基于机器学习的中国玉米产量预测研究[D]. 南京: 南京信息工程大学, 2024.
ZOU Y F. Research on maize yield prediction in China based on machine learning[D]. Nanjing: Nanjing University of Information Science & Technology, 2024.
- [15] 金佳宣. 基于数据挖掘的玉米产量预测模型的研究[D]. 长春: 吉林农业大学, 2020.
JIN J X. Research on the prediction model of corn yield based on data mining[D]. Changchun: Jilin Agricultural University, 2020.
- [16] SHAWON S M, EMA F B, MAHI A K, et al. Crop yield prediction using machine learning: an extensive and systematic literature review[J]. *Smart Agricultural Technology*, 2025, 10:100718.
- [17] 王鹏新, 齐璇, 李俐, 等. 基于随机森林回归的玉米单产估测[J]. *农业机械学报*, 2019, 50(7):237-245.
WANG P X, QI X, LI L, et al. Estimation of maize yield based on random forest regression[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2019, 50(7):237-245.
- [18] 方惠敏, 张守涛, 丁文珂. 基于BP神经网络的玉米区试产量预测研究[J]. *安徽农业科学*, 2007, 35(34):10969-10970.
FANG H M, ZHANG S T, DING W K. Study on forecasting the yield in maize regional test based on BP neural network[J]. *Journal of Anhui Agricultural Sciences*, 2007, 35(34):10969-10970.
- [19] GAWDIYA S, KUMAR D, AHMED B, et al. Field scale wheat yield prediction using ensemble machine learning techniques[J]. *Smart Agricultural Technology*, 2024, 9:100543.
- [20] DAS P, JHA G K, LAMA A, et al. Crop yield prediction using hybrid machine learning approach: a case study of lentil (*Lens culinaris* Medik.) [J]. *Agriculture*, 2023, 13(3):596.
- [21] SÁNCHEZ J C M, ACOSTA MESA H G, ESPINOSA A T, et al. Improving wheat yield prediction through variable selection using support vector regression, random forest, and extreme gradient boosting[J]. *Smart Agricultural Technology*, 2025, 10:100791.
- [22] 罗正媛, 汤洋. 黑龙江省玉米产量变化的预测分析: 基于支持向量机的实证研究[J]. *农机化研究*, 2013, 35(2):30-34.
LUO Z Y, TANG Y. The prediction analysis on maize yield changes in Heilongjiang Province: empirical research based on support vector machine (SVM) [J]. *Journal of Agricultural Mechanization Research*, 2013, 35(2):30-34.
- [23] 申哲, 韩天富, 曲潇林, 等. 我国小麦和玉米相对产量差时空变异及其对氮肥的响应[J]. *中国农业科学*, 2023, 56(14):2724-2737.
SHEN Z, HAN T F, QU X L, et al. Spatial-temporal variation of relative yield gap of wheat and maize and its response to nitrogen fertilizer in China[J]. *Scientia Agricultura Sinica*, 2023, 56(14):2724-2737.
- [24] 姚玉霞. 中国西南地区玉米蒸散发遥感估算及其对干旱的响应[D]. 重庆: 西南大学, 2023.
YAO Y X. Remote sensing estimation of maize evapotranspiration in southwest China and its response to drought[D].

- Chongqing:Southwest University,2023.
- [25] 秦肖伟. 基于时序遥感影像的地块尺度作物识别研究:以重庆市潼南区为例[D]. 兰州:兰州交通大学,2023.
- QIN X W. Research on identification of parcel-scale crop types based on time series remote sensing images[D]. Lanzhou:Lanzhou Jiatong University,2023.
- [26] MIAO L J, ZOU Y F, CUI X F, et al. Predicting China's maize yield using multi-source datasets and machine learning algorithms[J]. Remote Sensing, 2024,16(13):2417.
- [27] 钱莹,方秀男. 多元线性回归模型及实例应用[J]. 中国科技信息,2022(4):73-74.
- QIAN Y, FANG X N. Multivariate linear regression model and its application[J]. China Science and Technology Information,2022(4):73-74.
- [28] MATSUMURA K, GAITAN C F, SUGIMOTO K, et al. Maize yield forecasting by linear regression and artificial neural networks in Jilin, China[J]. The Journal of Agricultural Science,2015,153(3):399-410.
- [29] PROBST P, WRIGHT M N, BOULESTEIX A L. Hyperparameters and tuning strategies for random forest[J]. WIREs Data Mining and Knowledge Discovery,2019,9(3):e1301.
- [30] YANG L, SHAMI A. On hyperparameter optimization of machine learning algorithms: Theory and practice[J]. Neurocomputing,2020,415:295-316.
- [31] NEMATZADEH S, KIANI F, TORKAMANIAN-AFSHAR M, et al. Tuning hyperparameters of machine learning algorithms and deep neural networks using metaheuristics: a bioinformatics study on biomedical and biological cases[J]. Computational Biology and Chemistry,2022,97:107619.
- [32] GAURIAU O, GALÁRRAGA L, BRUN F, et al. Comparing machine-learning models of different levels of complexity for crop protection: a look into the complexity-accuracy tradeoff[J]. Smart Agricultural Technology,2024,7:100380.
- [33] MORA-POBLETE F, MALDONADO C, HENRIQUE L, et al. Multi-trait and multi-environment genomic prediction for flowering traits in maize: a deep learning approach[J]. Frontiers in Plant Science,2023,14:1153040.
- [34] OLIVOTO T, NARDINO M, CARVALHO I R, et al. REML/BLUP and sequential path analysis in estimating genotypic values and interrelationships among simple maize grain yield-related traits[J]. Genetics and Molecular Research,2017,16(1):1-19.
- [35] 李清超,马浪浪,文琼,等. 玉米杂交组合产量性状与产量的相关及通径分析[J]. 中国农学通报,2015,31(27):59-62.
- LI Q C, MA L L, WEN Q, et al. Correlation and path analysis of yield and yield characteristics of maize hybrids[J]. Chinese Agricultural Science Bulletin,2015,31(27):59-62.
- [36] 王璟璐. 玉米穗部“源一流一库”性状表型互作网络构建与遗传解析研究[D]. 武汉:华中农业大学,2024.
- WANG J L. Phenotypic interaction network construction and genetic analysis of "source-flow-sink" traits in maize ear[D]. Wuhan:Huazhong Agricultural University,2024.
- [37] SHAO R X, YU K K, LI H W, et al. The effect of elevating temperature on the growth and development of reproductive organs and yield of summer maize[J]. Journal of Integrative Agriculture,2021,20(7):1783-1795.
- [38] WANG H Q, LIU P, ZHANG J W, et al. Endogenous hormones inhibit differentiation of young ears in maize (*Zea mays* L.) under heat stress[J]. Frontiers in Plant Science,2020,11:533046.
- [39] 寸玉洁,郑大圣,王瑞. 氮素对开花期受旱玉米根系特性及产量形成的影响[J]. 干旱地区农业研究,2025,43(1):139-150.
- CUN Y J, ZHENG D S, WANG R. Effects of nitrogen on root characteristics and yield formation in drought-stressed maize during the flowering stage[J]. Agricultural Research in the Arid Areas,2025,43(1):139-150.
- [40] 王会涛,袁刘正,柳家友,等. 花期高温对玉米的影响研究进展[J]. 河南农业科学,2022,51(9):1-9.
- WANG H T, YUAN L Z, LIU J Y, et al. Research progress on effect of high temperature on maize at flowering stage[J]. Journal of Henan Agricultural Sciences,2022,51(9):1-9.