doi:10.6041/j.issn.1000-1298.2026.23.003

基于单籽粒表型分布特征与理化信息融合的小麦容重预测方法

董德良[1]　赵江楠[1,2]　李晓亮[1,2]　李　炜[1]　牛润泽[2,3]　张　漫[2,3]
刘　刚[2,3]　王　岩[2,3]　李　寒[2,3]

（1. 中储粮成都储藏研究院有限公司，成都 610091；
2. 中国农业大学农业农村部农业信息获取技术重点实验室，北京 100083；
3. 中国农业大学智慧农业系统集成研究教育部重点实验室，北京 100083）

摘要：针对传统小麦容重测定方法操作繁琐、检测效率低等问题，结合容重为籽粒群体性状的特点，提出基于单籽粒表型分布特征与理化信息融合的小麦容重预测方法。以 2025 年全国粮食收储环节实际流通的 1 421 份商品小麦为研究对象，测定容重、含水率、不完善粒含量等理化指标，并采集籽粒图像。提取单籽粒颜色、纹理、形状共 28 维图像特征，分别采用均值聚合与分布统计聚合方法构建样本级图像特征，并与理化特征融合形成预测特征集。结合特征筛选与机器学习算法建立小麦容重预测模型，并利用 SHAP 方法解析关键影响因素。融合理化特征与图像特征的模型预测性能整体优于单一类型特征，表明理化参数与籽粒外观表型信息具有明显互补性。相比均值表征，基于分布统计量的样本级表征更适合描述容重这一群体性指标，其中 Combined dist 6 特征集表现最佳。经 Boruta 特征筛选后获得 25 个关键特征，基于该特征子集构建的 GBRT 模型经过贝叶斯优化后取得最佳预测性能，20 次蒙特卡洛交叉验证结果显示，测试集 R^2 为 0.941 5 ± 0.009 7，RMSE 为（5.911 6 ± 0.378 8）g/L。SHAP 分析表明，纹理特征、形状特征与理化特征是影响小麦容重预测的重要因素，其作用方向与粮食容重形成规律一致。该方法在真实收储场景的大样本商品麦数据上得到了验证，可为粮食收储环节容重快速检测和品质分级提供技术支持。

关键词：小麦；容重；机器视觉；特征分布表征；特征融合

中图分类号：S126　　**文献标识码**：A　　**文章编号**：1000-1298(2026)23-0034-13　　**OSID**：

Wheat Test Weight Prediction via Fusion of Distributional Features of Single-kernel Phenotypic Traits and Physicochemical Information

Dong Deliang[1]　Zhao Jiangnan[1,2]　Li Xiaoliang[1,2]　Li Wei[1]　Niu Runze[2,3]　Zhang Man[2,3]
Liu Gang[2,3]　Wang Yan[2,3]　Li Han[2,3]

(1. *Sinograin Chengdu Storage Research Institute Co., Ltd., Chengdu* 610091, *China*
2. *Key Laboratory of Agricultural Information Acquisition Technology, Ministry of Agriculture and Rural Affairs, China Agricultural University, Beijing* 100083, *China*
3. *Key Laboratory of Smart Agriculture Systems, Ministry of Education, China Agricultural University, Beijing* 100083, *China*)

Abstract: Conventional methods for determining wheat test weight are labor-intensive and inefficient for rapid evaluation in grain storage and procurement. Considering that test weight is a population-level trait determined by the collective characteristics of numerous kernels, a wheat test weight prediction framework was developed based on the fusion of distributional features of single-kernel phenotypes and physicochemical information. A total of 1 421 commercial wheat samples collected from grain storage and procurement systems across China in 2025 were used. Physicochemical parameters, including moisture content and unsound grain percentage, were measured, and kernel images were acquired. Twenty-eight

收稿日期：2026－07－07　修回日期：2026－07－18

基金项目：国家重点研发计划项目(2022YFD200150101)、中国农业大学 2115 人才工程项目、2024 年中储粮集团科技项目和 2024 年四川省“天府青城计划”青年科技人才项目

作者简介：董德良(1970—)，男，正高级工程师，主要从事粮油质量检测技术及相关仪器设备研究，E-mail：ddl318@126.com

通信作者：王岩(1990—)，女，副教授，博士，主要从事农业电气化与自动化研究，E-mail：yanwang@cau.edu.cn

color, texture, and shape features were extracted from individual kernels. To bridge the gap between kernel-level phenotypes and sample-level test weight, mean-based and distribution-statistical aggregation strategies were employed to construct sample-level image features, which were subsequently fused with physicochemical variables. Feature selection and machine learning algorithms were used to establish prediction models, and SHAP analysis was conducted to interpret key influencing factors. The results showed that models integrating physicochemical and image-derived phenotypic features consistently outperformed models based on a single information source, indicating the complementarity between the two types of features. Compared with conventional mean-based representations, distribution-statistical representations achieved superior predictive performance by preserving within-sample kernel heterogeneity. Among all feature sets, Combined dist6 achieved the best performance. After Boruta feature selection, totally 25 key variables were retained. The Bayesian-optimized GBRT model yielded the highest prediction accuracy, achieving an R^2 of 0.941 5 ±0.009 7 and an RMSE of (5.911 6 ±0.378 8) g/L in Monte Carlo cross-validation. SHAP analysis further revealed that texture, shape, and physicochemical features were the major determinants of wheat test weight. It proposed a distribution-statistical representation method for transforming single-kernel phenotypes into sample-level descriptors and demonstrated the complementary value of physicochemical and image information for wheat test weight prediction. The developed framework can provide an effective solution for rapid test weight evaluation and quality grading. Moreover, it offered a general methodology for population-trait analysis of agricultural products and may provide useful support for germplasm evaluation, superior cultivar identification, and intelligent breeding.

Key words: wheat; test weight; machine vision; distribution-based feature representation; feature fusion

0　引言

粮食容重是粮食、油料籽粒在单位容积内的质量,以克每升(g/L)表示[1]。在同类粮食中,粮食籽粒成熟度越好、结构越紧密、果实越饱满,对应的容重就越高;反之,则越低[2]。容重是衡量粮食籽粒品质与成熟饱满度的直接指标,也是判断粮食营养含量、筛选种质资源以及指导生物育种的重要参考性状[3]。在粮食收购、储运、贸易分级和仓储管理中,容重直接影响质量定级与定价,也可为粮堆孔隙度、导热性和耐储性判断提供依据[4]。

目前我国普遍依照国家标准《粮油检验 容重测定》(GB/T 5498—2013)对粮食容重进行人工测定,但是该方法存在操作流程繁琐、样品需求量大且人工依赖性高等局限性。现有研究主要集中在粮食容重自动化测量装置的开发和制造[5-6],相关装置可以降低人工劳动强度,但本质上仍是对标准人工方法的机械模拟,未能从根本上摆脱繁琐的操作流程与大量的样品需求,制约了其在快速、在线检测场景中的应用。

随着机器视觉与智能算法等技术的发展,粮油及其他农产品检验逐渐向无损检测、在线检测方向发展,也为容重测定提供了新思路。张玉荣等[7-8]于 2015 年提出了基于图像处理的小麦容重检测方法,然而其技术方案仅能实现对容重进行高、中、低等级的划分,无法输出精确的连续数值,难以满足实际质检中对精准量化的需求。王玉琦[2]基于图像分割提取小麦籽粒的像素比,结合岭回归分析构建小麦容重预测模型,但该模型的平均绝对百分比误差高达 9.154%,预测精度距离国家标准要求仍有差距。杨玮等[9-10]提出基于图像处理的 GBRT 模型的土壤容重预测方法,通过同态滤波技术预处理土壤表面图像,提取灰度直方图和灰度共生矩阵的纹理特征参数,结合土壤阻力数据构建 GBRT 预测模型,这一技术路径为粮食容重的预测提供了有价值的跨领域参考。

事实上,粮食容重受到籽粒形态、表面结构、含水率、杂质、不完善粒含量等因素的共同影响。籽粒成熟饱满、结构紧密、表面光滑、粒形短圆者容重大;而籽粒结构疏松、不饱满、表面粗糙、粒形细长者容重小[11-12];水分增加通常会降低容重[13-14],杂质[15]和不完善粒含量[16-17]也会不同程度影响容重。然而,目前尚未有研究将这些关键影响因素系统性融合,并构建一个精准、综合的容重预测模型。

基于此,本文面向粮食收储环节容重快速检测需求,构建一种融合理化参数与单籽粒图像表型特征的小麦容重预测方法。不同于已有研究主要依赖少量整体图像特征或仅进行容重等级判别,本研究将容重视为由大量籽粒共同决定的样本级群体性状,提出基于单籽粒特征分布统计的样本级图像表征方法,以保留样本内部籽粒间的异质性和结构差异;进一步融合含水率、不完善粒含量等理化参数与

颜色、形状、纹理等图像表型特征，分析多源信息在容重预测中的互补作用；并基于 2025 年全国粮食收储环节实际流通的 1 421 份商品小麦样本，结合特征筛选、机器学习建模和 SHAP 可解释性分析，建立一套面向真实收储场景的可解释容重预测框架。以期为粮食容重快速检测、品质分级以及粮食收储环节智能化发展提供理论依据和技术支撑。

1 材料与方法

1.1 样本来源与数据采集

本研究收集了 2025 年度全国粮食收储环节实际流通的 1 421 份商品小麦样本，兼顾春小麦与冬小麦两大生态类型，同时涵盖了红麦、白麦、软麦、硬麦、混合麦等主要商品小麦种类，覆盖了从一等至五等的全部容重等级。样品来源于国内主要小麦主产区，包括河南、山东、安徽、黑龙江、河北、江苏等 11 个省份。

使用 GHCS－1000 型谷物容重器按照《粮油检验 容重测定》[1]操作方法完成对所有样品的容重测定，获取容重真值；使用青浦绿洲 LDS－1G 型谷物水分测量仪测定各样本的含水率[18]；使用中储粮成都储藏研究院自主研发的粮食不完善粒（外观品质）检测仪[19－20]同步获取不完善粒含量数据和小麦籽粒图像数据。不完善粒含量是指未熟、虫蚀、霉变、破损等不完善粒的质量占试样总质量的质量分数[21]，该检测仪依据国家标准逻辑实现小麦不完善粒的自动识别与含量计算，其识别准确率、重复性与稳定性均满足相关标准要求。经过以上系列操作，最终获取各样品的容重、含水率、不完善粒含量及小麦籽粒图像（图 1）等全部实验数据。



图 1 小麦籽粒图像示例

Fig. 1 Example of wheat grain images

1.2 图像特征提取与数据组织

本研究采用 OpenCV 图像处理工具对小麦籽粒图像进行预处理。在图像特征提取环节，提取了与容重密切相关的籽粒外观特征，共获得 28 个籽粒级特征，分为颜色特征、形态特征和纹理特征 3 类。颜色特征包括 RGB 3 个颜色通道的均值与标准差，以及 HSV 3 个颜色通道的均值与标准差，共计 12 个参数。形态特征涵盖小麦籽粒图像的面积、周长、长轴长度、短轴长度、长宽比、等效圆直径、离心率、紧密度和伸展度，共 9 个参数[22]。纹理特征包括平均亮度、平滑度、对比度、同质性、能量、相关性和熵，共 7 个参数。

上述特征均基于单籽粒图像提取，属于籽粒级特征。然而，容重是样本级标签，每个样本包含大量籽粒。为了实现籽粒级特征到样本级特征的有效映射，使图像特征能够有效表征整份样本的群体信息，本研究构建了两种样本级图像特征聚合方式：

（1）均值法：对每份样本内所有籽粒的各图像特征计算算术平均值，以均值表征该样本的整体水平，作为该样本的特征值。

（2）分布统计指标法：考虑到容重本质上反映籽粒的群体特性，籽粒间特征的分布差异可能对容重产生影响。因此，本研究对每份样本的各图像特征计算多项分布统计量作为样本级特征，统计量包括中位数、众数、上四分位数、下四分位数、90% 分位数、四分位距、鲁棒变异系数、均值、中位数绝对偏差、正常比、异常比、峰度与偏度。通过不同统计指标的组合构建多组特征集[23－24]，探究其对容重预测效果的影响。

1.3 数据预处理

本研究整合了来自理化指标与图像特征的多维数据，这些特征具有不同的量纲与量级。为消除其差异对模型性能的影响，采用 Z-score 标准化[25]方法对所有特征进行统一处理。该方法将原始数据转换为均值为 0、标准差为 1 的分布，从而消除量纲与量级差异对模型的影响、增强数据可比性并加速模型收敛。

1.4 特征集构建

为了探究理化特征、图像特征以及二者融合对小麦容重预测性能的影响，以及不同样本级图像特征聚合方式的性能，本研究构建了 11 个特征集，分为理化特征集、图像特征集和融合特征集 3 大类。

特征集构建方式如图 2 所示。理化特征集仅包含含水率、不完善粒含量共 2 个特征。图像特征集依据 1.2 节所述的 2 种样本级图像特征聚合方式构建，包括特征均值和特征分布 2 类。采用单籽粒图像特征均值构建的样本级图像特征集记为 Image mean；采用单籽粒图像特征分布统计量构建的样本级图像特征集记为 Image dist。根据所选分布统计指标数量的不同，Image dist 进一步划分为 4 个特征集。其中，Image dist 3 对每个籽粒级图像特征计算

中位数、四分位距和鲁棒变异系数共 3 个统计指标；Image dist 6 在 Image dist 3 基础上增加上四分位数、下四分位数和众数；Image dist 9 进一步增加 90% 分位数、均值和中位数绝对偏差；Image dist 13 则采用全部 13 个分布统计指标进行表征。

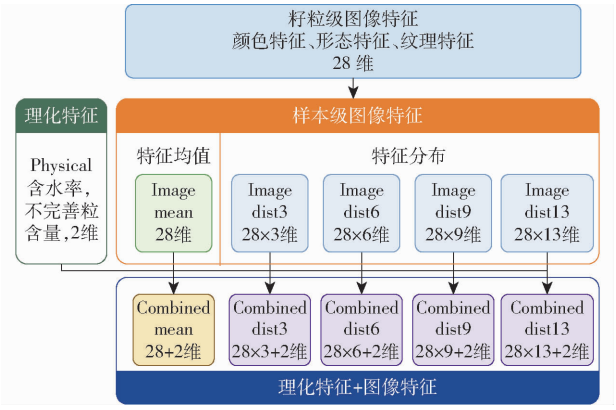

图 2　特征集构建示意图

Fig. 2　Feature set construction diagram

在此基础上，将理化特征集分别与各图像特征集进行特征融合，构建融合特征集。其中，理化特征与 Image mean 融合形成的特征集记为 Combined mean；理化特征与 Image dist 3、Image dist 6、Image dist 9 和 Image dist 13 融合形成的特征集分别记为 Combined dist 3、Combined dist 6、Combined dist 9 和 Combined dist 13。后文均采用上述简称进行表述，并基于这些特征集分别建立小麦容重预测模型以评估各特征组合的有效性。

1.5　特征筛选

特征筛选可以从原始特征集中去除不相关和冗余的特征，通过聚焦信息丰富的少量敏感特征，实现更高的预测精度、更好的泛化能力和更少的建模成本。本研究利用互信息、Boruta 算法和 LASSO 算法选择对小麦容重影响突出的特征。

1.5.1　互信息

互信息是过滤式特征筛选方法，源于信息论，可有效捕捉变量之间的非线性依赖关系，常用于特征选择、图像处理、通信系统等领域[26]。互信息的数值恒为非负，值越大表示变量之间的统计依赖性越强；接近于零则表示统计独立。本研究采用 scikit-learn 机器学习库，使用 SelectKBest 策略进行特征筛选，以 mutual_info_regression 作为评分函数，根据设定的特征数量阈值筛选出与小麦容重相关性最强的特征子集。

1.5.2　Boruta 方法

Boruta 方法是基于随机森林算法的封装式特征筛选算法，通过比较原始特征与影子特征的重要性差异，实现关键特征识别[27]。在使用 Boruta 进行特征筛选时，选用“RandomForestRegressor”作为模型训练的评估器，迭代次数设置为 100 次，树的最大深度（max_depth）为 12 以确保模型的稳定性，从而明确影响小麦容重的重要特征和次重要特征。

1.5.3　LASSO 方法

LASSO 方法是基于 L1 正则化的线性回归，是一种嵌入式筛选方法，通过在目标函数中加入 L1 正则项，对系数施加惩罚，将无关特征系数压缩至 0，实现具有可解释性的特征选择[28]。本研究基于 scikit-learn 机器学习库，运用 LASSO 回归模型进行特征筛选，以处理后的特征集和小麦容重数据作为模型输入参数，迭代次数设置为 100 次，使用“Lasso”作为模型训练评估器，通过 alpha 参数在 10^{-3} ~ 10^{1} 范围内按对数均匀方式生成 100 个候选值，以确定不同参数设置对模型性能或结果的影响。

1.6　小麦容重预测模型

本研究基于 K 近邻（K-nearest neighbors，KNN）[29]、支持向量回归（Support vector regression，SVR）[30-31]、多层感知机（Multilayer perceptron，MLP）[32-33]、梯度提升回归树（GBRT）[34-35]、极端梯度提升（XGBoost）[36-37]、类别特征提升（CatBoost）[38] 6 类机器学习回归算法分别建立小麦容重预测模型，覆盖基于距离度量、核函数、神经网络和集成树的典型建模路径。以特征筛选后确定的最优特征子集作为各模型的输入变量，对小麦容重进行预测建模。为获得各模型的最优参数组合，采用贝叶斯优化方法对模型超参数进行自动寻优。在模型构建过程中，首先将数据集按照 8∶2 的比例划分为训练集和测试集。其中，训练集用于模型训练及参数优化，测试集用于模型性能评价。为提高参数优化结果的可靠性，在训练阶段采用五折交叉验证对模型进行评估，并以交叉验证结果作为贝叶斯优化的目标函数。各模型超参数的搜索范围及最优参数组合如表 1 所示。

1.7　模型性能评价指标

本研究采用平均绝对误差（MAE）、均方根误差（RMSE）、平均绝对百分比误差（MAPE）和决定系数 R^2 对模型性能进行评价。

1.8　基于 SHAP 的可解释性分析

SHAP（SHapley additive exPlanations）是一种机器学习模型事后解释方法，基于博弈论思想，通过计算模型中各特征对模型预测的贡献度 Shapley 值，依次衡量特征对最终输出值的影响[39]。SHAP 为每个样本提供局部解释，同时也可以给出全局的特征重要性评估，能够说明每个特征在模型预测过程中起到的作用和重要性，因此具有全局一致性和局部

表 1 各小麦容重预测模型超参数搜索空间与贝叶斯优化最优配置

Tab. 1 Hyperparameter search space and Bayesian optimization configuration for each wheat test weight prediction model

模型	超参数	搜索空间	最优值
KNN	n_neighbors	[3, 30]	4
	weights	uniform, distance	distance
	p	[1, 2]	1
	leaf_size	[10, 50]	41
MLP	hidden_layer_sizes_1	[16, 256]	231
	hidden_layer_sizes_2	[0,128]	6
	activation	ReLU, tanh	ReLU
	solver	Adam, lbfgs	Adam
	alpha	$[1\times10^{-5}, 0.1]$	0.065
	learning_rate_init	$[1\times10^{-4}, 0.1]$	0.001
	batch_size	[32, 256]	32
GBRT	n_estimators	[50, 500]	434
	max_depth	[3, 10]	10
	learning_rate	[0.01, 0.3]	0.02
	min_samples_split	[2, 20]	2
	min_samples_leaf	[1, 10]	2
	subsample	[0.6, 1.0]	0.9
	max_features	sqrt, log2, none	sqrt
XGBoost	n_estimators	[50, 500]	448
	max_depth	[3, 12]	10
	learning_rate	[0.01, 0.3]	0.02
	subsample	[0.6, 1.0]	0.610 3
	colsample_bytree	[0.6, 1.0]	0.829 5
	reg_alpha	$[1\times10^{-8}, 1]$	6.19×10^{-4}
	reg_lambda	$[1\times10^{-8}, 1]$	1.77×10^{-6}
	min_child_weight	[1, 10]	1
	gamma	$[1\times10^{-8}, 0.5]$	2.00×10^{-4}
CatBoost	n_estimators	[50, 500]	467
	max_depth	[3, 12]	8
	learning_rate	[0.01, 0.3]	0.05
	l2_leaf_reg	$[1\times10^{-5}, 10]$	2.13×10^{-5}
	subsample	[0.6, 1.0]	0.80
	colsample_bytree	[0.6, 1.0]	0.77
SVR	C	[0.01, 100]	6.66
	epsilon	[0.001, 1.0]	0.115 6
	gamma	scale, auto	auto
	kernel	rbf, linear, poly	rbf

解释性的特点。SHAP 算法可以应用于各种类型的机器学习模型进行解释工作,使得模型的特征贡献分析更加透明和易于理解。

2 结果与分析

2.1 特征集构成与特征融合策略对预测性能的影响

为了探究理化特征、图像特征以及二者融合对小麦容重预测性能的影响,同时分析不同样本级图像特征聚合方式的性能差异,本研究基于 1.4 节构建的 11 个特征集分别建立 GBRT 回归预测模型。各特征集都按 8∶2 比例划分训练集和测试集,且保持各组特征集的训练、测试样本完全对应。全程固定 GBRT 模型超参数,仅输入特征存在差异,通过控制变量方式确保结果的可比性,从而对比不同特征集对小麦容重预测效果的影响规律。各特征集的模型预测效果如表 2 所示。

表 2 不同特征集的模型预测精度对比

Tab. 2 Comparison of different feature sets and their model prediction accuracies

特征集	特征数	R^2	RMSE/(g·L^{-1})	MAE/(g·L^{-1})	MAPE/%
Physical	2	0.803 7	11.128 5	8.207 1	1.04
Image mean	28	0.898 4	8.004 7	5.854 0	0.74
Image dist 3	84	0.922 5	6.991 1	5.458 1	0.69
Image dist 6	168	0.918 0	7.193 1	5.349 1	0.68
Image dist 9	252	0.911 3	7.480 3	5.575 1	0.71
Image dist 13	364	0.903 1	7.820 3	5.745 9	0.73
Combined mean	30	0.925 9	6.837 4	4.962 3	0.63
Combined dist 3	86	0.929 3	6.679 8	4.972 8	0.63
Combined dist 6	170	0.931 4	6.580 7	5.017 8	0.63
Combined dist 9	254	0.927 7	6.755 5	4.989 7	0.63
Combined dist 13	366	0.924 4	6.907 9	5.192 9	0.66

由表 2 可知,相较于仅使用理化特征(Physical)或仅使用图像特征(Image)的特征集,融合特征集(Combined)整体表现出更优的预测性能,其决定系数 R^2 均高于对应的 Physical 组和 Image 组。这说明仅理化特征或仅图像特征都存在信息短板,而二者融合后能够有效弥补各自的信息缺失,充分发挥不同特征体系的优势。理化特征能够反映小麦样品的宏观品质信息,而图像特征则能够从颜色、形态及纹理等角度表征籽粒微观差异,因此两类特征之间具有较强的互补性与协同性,其融合能够更加全面、多维度地刻画影响小麦容重的关键因素,从而提升模型预测精度。

在融合特征集中,Combined dist 3、Combined dist 6 及 Combined dist 9 的 R^2 均高于 Combined mean,说明相比于单纯使用特征均值,利用单籽粒图像特征的分布信息能够更有效地表征样本内部差异,提高模型对小麦容重的预测能力。其原因在于,容重并非单个籽粒的局部性状,而是整份样本中大量籽粒在单位容积内共同堆积形成的样本级群体性指标。均值聚合只能反映某一图像特征的平均水平,容易将不同籽粒之间的大小、形态、纹理和饱满度差异相互抵消,从而削弱样本内部异质性对容重的影响表达;而分布统计表征通过中位数、四分位数、四分位距、鲁棒变异系数、众数等指标,同时描述

特征的集中趋势、离散程度和分布结构，能够保留样本内部籽粒群体的结构差异。因此，分布统计表征更符合容重由籽粒群体共同决定的属性。Combined dist 6 取得了最佳预测效果，其 R^2 达到 0.931 4，为所有特征集中的最高值，同时 RMSE 降低至 6.580 7 g/L，说明适量增加分布统计指标有助于增强样本特征表达能力，提高模型性能。然而，当分布统计指标继续增加至 9 个和 13 个时，模型性能反而有所下降，表现为 R^2 逐渐减小、RMSE 逐渐增大。这表明分布统计量并非越多越好，过多的统计指标可能引入冗余信息与噪声，降低特征有效性，从而导致模型泛化能力下降。因此，采用 6 个分布统计量构建样本级图像特征能够在特征表达能力与冗余信息之间取得较优平衡。

2.2　最优特征子集筛选

为精简特征维度、剔除冗余干扰特征，精准筛选出影响小麦容重预测的核心关键变量，本研究针对最优特征集 Combined dist 6 分别采用 1.5 节所述的互信息、Boruta 和 LASSO 共 3 种方法进行特征筛选。对于得到的不同特征子集，均使用 GBRT 模型进行回归预测。固定模型超参数与数据集划分方式，仅改变经特征筛选后输入模型的特征子集，以保证不同实验结果之间的可比性，有效对比不同筛选方法的优化效果，对各特征子集对应模型的预测性能进行评估，结果如表 3 所示。

表 3　各特征筛选方法保留特征子集的模型预测精度对比

Tab. 3　Comparison of model prediction accuracies of feature sets by various feature selection methods

筛选方法	特征数	R^2	RMSE/(g·L^{-1})	MAE/(g·L^{-1})	MAPE/%
互信息	22	0.901 4	7.885 4	5.815 6	0.73
Boruta	25	0.939 5	6.176 0	4.648 8	0.59
LASSO	15	0.937 5	6.277 5	4.914 0	0.61

3 种特征筛选方法均实现了特征维度的有效压缩。相比于原始 Combined dist 6 特征集的 170 维特征，经互信息、Boruta 和 LASSO 筛选后，特征维度分别降低至 22 维、25 维和 15 维，显著减少了模型输入参数量，提高了特征集的紧凑性。其中，LASSO 获得了最小的特征数量，而 Boruta 则在较低维度下仍保持了较高的预测性能。

从模型预测结果来看，不同特征筛选方法对模型性能的影响存在明显差异。相较于全特征建模结果，互信息筛选后的特征子集预测性能下降，R^2 仅为 0.901 4，RMSE 升高至 7.885 4 g/L，说明仅依据特征与目标变量之间的相关性进行筛选，可能会遗漏部分对模型具有协同作用的重要特征，导致模型表达能力下降。相比之下，经 Boruta 和 LASSO 筛选后的特征子集均取得了优于原始全特征模型的预测效果，表明原始 170 维特征中存在一定程度的冗余与噪声特征，合理的特征筛选不仅能够降低模型复杂度，还能够提升模型泛化能力。其中，Boruta 方法表现最佳，其 R^2 达到 0.939 5，较原始全特征模型进一步提升，同时 RMSE 降低至 6.176 0 g/L，MAE 降低至 4.648 8 g/L，MAPE 仅为 0.59%，均为 3 种筛选方法中的最优结果。这说明 Boruta 能够在有效压缩特征维度的同时，更充分地保留与小麦容重相关的重要信息，从而实现预测精度与模型简洁性的良好平衡。

图 3 展示了 3 种特征筛选方法保留特征的对比结果，其中横坐标特征名称采用“特征指标_统计量”的命名方式，后缀 q25、q50、q75 和 q90 分别表示相应特征在样本内单籽粒分布的 25%、50%、75% 和 90% 分位数，robust_cv 表示鲁棒变异系数，iqr 表示四分位距。总体来看，不同筛选方法保留的特征数量和组成存在明显差异，说明不同筛选机制对特征重要性的判定标准并不完全一致。从共同保留特征来看，含水率和 R 均值_q75 同时被 3 种方法选中，表明这两个特征与小麦容重之间具有稳定且显著的关联关系，是影响容重预测的重要变量。此外，能量_q25、纹理熵_q75 和伸展度_q50 同时被 Boruta 和互信息保留，不完善粒含量、长宽比_q50、伸展度_q25 和离心率_q75 同时被 Boruta 和 LASSO 保留，这说明这些特征在不同筛选策略下均表现出较高的重要性，具有较好的稳定性和可靠性。

进一步分析发现，Boruta 保留的特征覆盖了理化特征、颜色特征、形态特征和纹理特征等多个维度，而互信息和 LASSO 则倾向于保留部分与目标变量具有较强单变量相关性或线性贡献的特征。由于小麦容重的形成受到籽粒理化性质、形态结构及表面纹理等多因素共同作用，特征之间普遍存在复杂的非线性交互关系，因此 Boruta 能够更充分地保留与目标变量相关的有效信息，从而获得最佳预测性能。

2.3　基于机器学习的小麦容重预测性能分析

利用上述 1.6 节所述的 6 种机器学习算法，基于确定的最优特征子集进行小麦容重预测，结果见表 4 和图 4。由表 4 和图 4 可知，基于 Boruta 筛选后的最优特征子集构建的 6 种机器学习模型均取得了较好的预测效果，其测试集 R^2 均超过 0.92，MAPE 均不超过 0.66%，表明所构建的特征体系能够有效表征影响小麦容重的关键因素，各模型均具

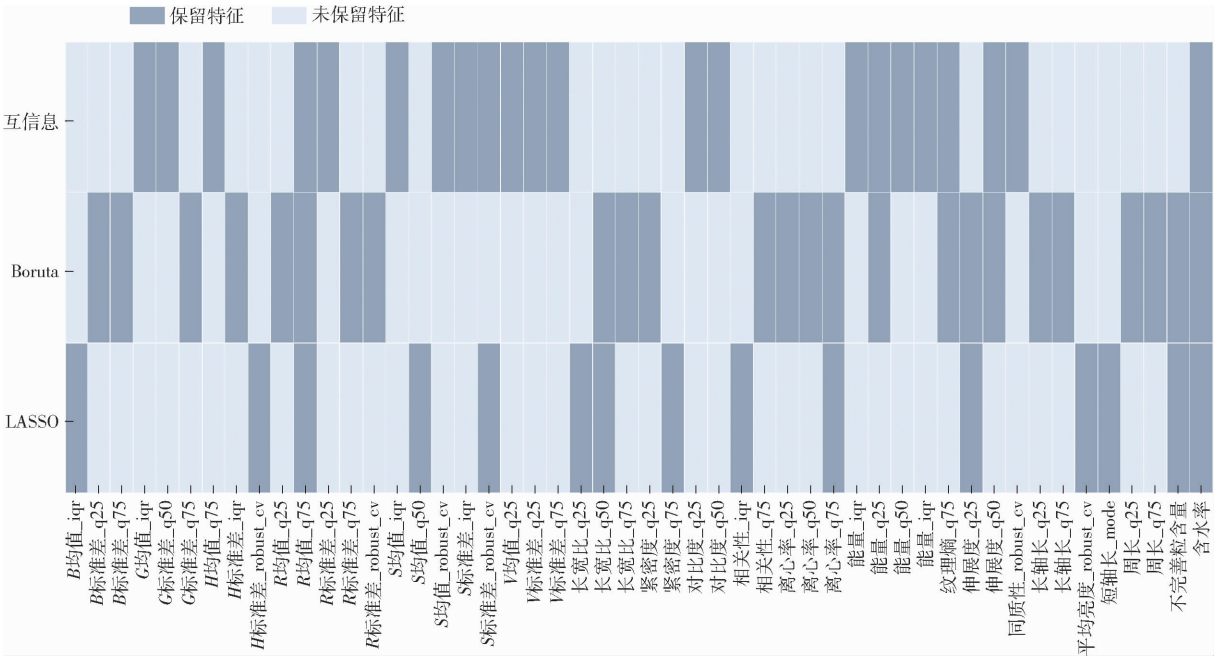

图 3 3 种特征筛选方法保留特征对比热力图

Fig. 3 Heatmap of retained features by three feature selection methods

备较高的预测能力。

表 4 不同小麦容重预测模型精度对比

Tab. 4 Comparison of prediction accuracies of different models

模型	R^2	RMSE/(g·L^{-1})	MAE/(g·L^{-1})	MAPE/%	训练时间/s
KNN	0.929 4	6.674 9	4.666 2	0.59	0.002 0
SVR	0.923 8	6.932 4	5.178 9	0.66	0.247 7
MLP	0.930 4	6.626 6	5.078 5	0.64	6.053 0
GBRT	0.942 3	6.035 7	4.508 1	0.57	5.692 4
XGBoost	0.938 8	6.213 7	4.607 5	0.58	6.258 2
CatBoost	0.938 2	6.245 8	4.712 8	0.60	7.521 7

从预测性能来看,GBRT 模型表现最佳,其测试集 R^2 达到 0.942 3,为所有模型中的最高值,同时 RMSE 和 MAE 分别为 6.035 7 g/L 和 4.508 1 g/L,说明 GBRT 能够最准确地刻画输入特征与小麦容重之间的非线性关系,在当前数据集上具有最优的拟合能力。XGBoost 和 CatBoost 模型的预测性能较为接近,R^2 分别为 0.938 8 和 0.938 2,RMSE 分别为 6.213 7 g/L 和 6.245 8 g/L。虽然两种模型均属于集成学习算法,并具有较强的非线性建模能力,但在本研究数据集上其预测性能略低于 GBRT,未表现出明显优势。

KNN、SVR 和 MLP 模型的预测结果较为接近。其中,MLP 模型的 R^2 为 0.930 4,高于 KNN(0.929 4)和 SVR(0.923 8),但其 MAE 达到 5.078 5 g/L,说明多层感知机模型在部分样本上的预测误差相对较大。KNN 模型取得了较低的 MAE(4.666 2 g/L)和 MAPE(0.59%),表明其整体预测误差较小,但由于 KNN 属于基于实例的学习方法,对局部样本分布敏感,其整体拟合能力逊于 GBRT 等集成学习模型。SVR 模型虽然能够有效处理非线性回归问题,但其 R^2 最低(0.923 8),RMSE 最高(6.932 4 g/L),表明其对复杂特征关系的表征能力相对有限。

从模型训练效率来看,各模型之间存在显著差异。KNN 模型训练时间仅为 0.002 0 s,远低于其他模型,这是由于 KNN 属于惰性学习算法,不需要复杂的训练过程,因此具有极高的训练效率。SVR 模型训练时间为 0.247 7 s,也表现出较高的计算效率。而集成学习模型 GBRT、XGBoost 和 CatBoost 由于需要迭代构建大量决策树,训练时间分别达到 5.692 4、6.258 2、7.521 7 s。MLP 模型训练时间为 6.053 0 s,与树模型接近。

综合预测精度与计算效率分析,虽然 KNN 和 SVR 具有较高的计算效率,但 GBRT 模型在 R^2、RMSE 等关键评价指标上均表现最优,展现出更强的预测能力和泛化性能。当前数据集中既包含理化变量,也包含大量由颜色、形态和纹理统计量构成的连续型图像特征,特征之间可能存在非线性关系和局部交互作用。GBRT 通过逐步拟合残差的方式构建多棵回归树,能够较好地捕捉此类非线性映射和特征交互关系,对中等规模表格型数据具有较强适应性,因此更适合当前小麦容重预测数据分布。与 XGBoost 和 CatBoost 相比,GBRT 在本研究数据集上取得了略高的预测精度,同时训练时间低于 XGBoost、MLP 和 CatBoost,在预测精度与计算成本

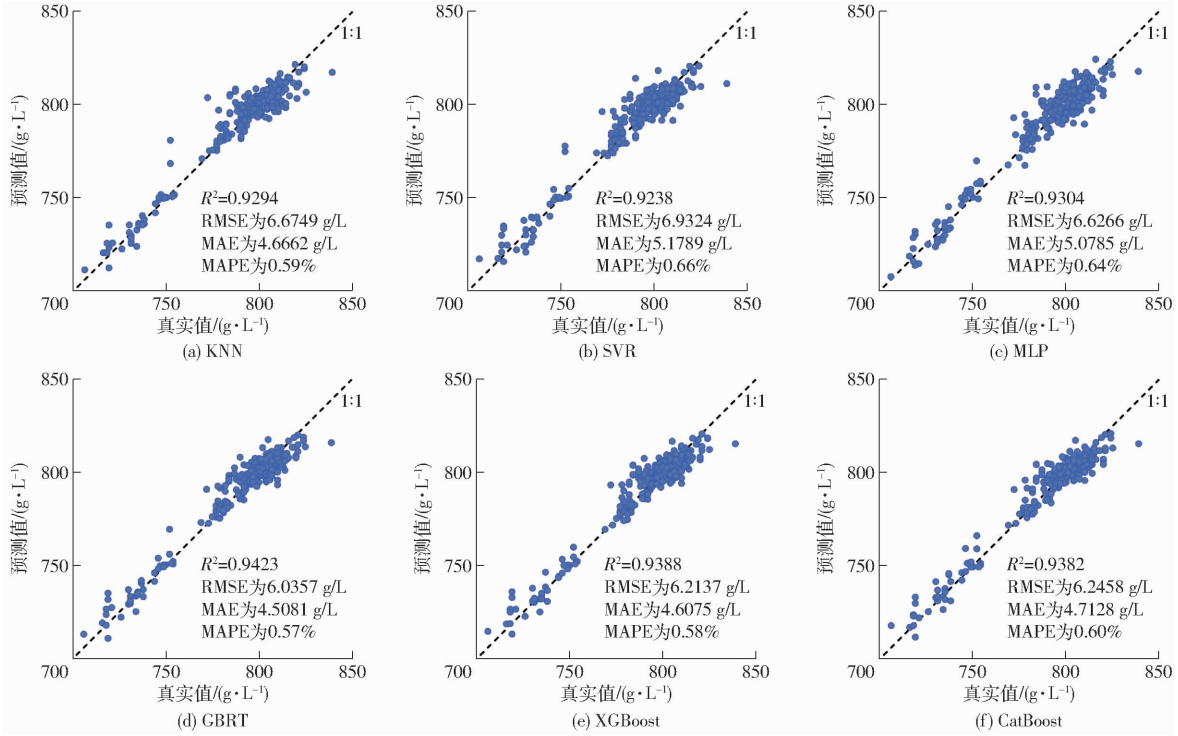

图 4　不同小麦容重预测模型真实值与预测值散点图

Fig. 4　Scatter plots of actual and predicted values of different wheat test weight prediction models

之间取得了较好的平衡。因此，本研究认为 GBRT 模型是预测小麦容重的最优模型，后续分析均基于 GBRT 模型展开。

为进一步验证不同样本级图像特征构建方式对模型性能的影响，并评估模型在不同数据划分条件下的稳定性与泛化能力，采用蒙特卡洛交叉验证（Monte Carlo cross-validation，MCCV）对 Combined mean 和 Combined dist 6 2 种特征方案进行比较分析。具体而言，对于 Combined mean 特征方案采用与 Combined dist 6 相同的建模流程，即分别进行特征筛选、模型优化和模型选择，确定其最优特征子集和最优预测模型；随后，在保持训练集与测试集比例为 8∶2的条件下，对整个数据集随机划分 20 次。每次划分均仅利用训练集重新完成模型训练，并在对应测试集上进行性能评估，统计 20 次重复实验的 R^2、RMSE 和 MAE 等评价指标的均值及标准差。通过比较两种特征方案在多次随机划分下的预测性能及其波动情况，评价不同样本级图像特征表征方法的有效性和稳定性。

结果如表 5 所示，2 种特征方案在 20 次随机划分条件下均表现出较好的预测稳定性，但 Combined dist 6 方案整体表现优于 Combined mean 方案。对于 Combined dist 6 特征集，经 Boruta 特征筛选和 GBRT 建模后，平均 R^2 达到 0.941 5，平均 RMSE、MAE 和 MAPE 分别为 5.911 6 g/L、4.418 4 g/L 和 0.560 0%；相比之下，Combined mean 特征集经 LASSO 特征筛选和 XGBoost 建模后，平均 R^2 仅为 0.925 3，平均 RMSE、MAE 和 MAPE 分别为 6.579 8 g/L、4.698 9 g/L 和 0.590 0%。

表 5　蒙特卡洛交叉验证结果

Tab. 5　Monte Carlo cross-validation results

特征集	特征数	最优模型	评价指标	均值	标准差
Combined dist 6	25	GBRT	R^2	0.941 5	0.009 7
			RMSE/(g·L⁻¹)	5.911 6	0.378 8
			MAE/(g·L⁻¹)	4.418 4	0.257 2
			MAPE/%	0.560 0	0.032 7
Combined mean	7	XGBoost	R^2	0.925 3	0.012 2
			RMSE/(g·L⁻¹)	6.579 8	0.436 1
			MAE/(g·L⁻¹)	4.698 9	0.291 2
			MAPE/%	0.590 0	0.036 1

由于 2 种特征方案在蒙特卡洛交叉验证过程中采用相同的 20 次随机数据划分，因此对两组对应实验结果进行配对样本 t 检验。结果表明，两种方案在预测性能上的差异达到极显著水平（$P = 1.30 \times 10^{-7}$，$P < 0.01$）。这说明 Combined dist 6 相对于 Combined mean 所获得的性能提升并非来源于随机数据划分造成的偶然波动，而是源于其特征构建方式本身的优势。换言之，基于单籽粒特征分布统计量构建的样本级图像特征能够稳定且显著地提高小麦容重预测精度。

此外，Combined dist 6 方案在各评价指标上的标准差均小于 Combined mean 方案，说明基于分布统计特征构建的样本级图像特征不仅能够提高模型

预测精度,而且具有更好的鲁棒性和稳定性。与表 4 的单次数据划分实验结果(R^2 = 0.942 3,RMSE 为 6.035 7 g/L,MAE 为 4.508 1 g/L,MAPE 为 0.57%)相比,Combined dist 6 方案各评价指标的变化较小,这说明模型预测性能并未显著依赖于特定的数据划分方式,具有良好的稳定性和泛化能力。在 20 次交叉验证中,各评价指标的标准差均较小,R^2、RMSE、MAE 和 MAPE 的标准差分别仅为 0.009 7、0.378 8 g/L、0.257 2 g/L 和 0.032 7%,表明模型在不同训练集和测试集组合下均能够保持稳定的预测精度。

上述结果进一步验证了前文基于单次数据划分实验得到的结论,即相比于采用特征均值描述样本整体特征,利用单籽粒特征的分布统计信息能够更充分地表征样本内部籽粒群体的差异信息,从而提高小麦容重预测模型的准确性和泛化能力。对于同一平均特征水平的样本,不同籽粒之间的变异程度、分位结构和异常比例可能存在显著差异,这些差异会影响籽粒堆积紧密程度和单位容积质量。均值表征会弱化甚至消除这种群体内部结构信息,而分布统计表征能够保留样本内籽粒大小、形态和纹理等表型差异,因此更符合容重作为样本级群体性状的形成机制。该结果表明,基于特征分布构建样本级图像特征是本研究获得高精度容重预测的重要原因之一。

基于 Combined dist 6 特征集,经 Boruta 特征筛选和 GBRT 构建的小麦容重预测模型的预测误差分布如图 5 所示。整体来看,预测误差主要集中在零附近,呈近似钟形分布,表明模型预测值与真实值具有较高的一致性,未出现明显的系统性高估或低估现象。统计结果显示,50% 的样本预测误差分布在 -2.99 ~ 3.34 g/L 范围内,说明对于约一半的小麦样本,模型预测值与真实值的偏差不超过 3.34 g/L;90% 的样本预测误差分布在 -8.90 ~ 12.04 g/L 范围内,表明绝大多数样本均能够获得较为准确的预测结果,仅有少量样本存在较大的预测偏差。误差分布主要集中于 ± 10 g/L 范围内,相对于小麦容重通常 700 ~ 850 g/L 的取值区间而言,占比不足 1.5%,进一步验证了模型在实际应用中的可行性和可靠性。从误差分布形态来看,误差峰值位于零附近,且大部分误差集中于较窄区间内,说明模型整体预测稳定性较好。同时,误差分布两侧仅存在少量离群样本,表明模型对绝大多数样本均具有良好的适应能力。结合前述蒙特卡洛交叉验证结果,进一步说明基于 Boruta 特征筛选和 GBRT 构建的小麦容重预测模型具有较高的预测精度、良好的泛化能力和稳定性,能够满足小麦容重快速预测与品质评价的应用需求。

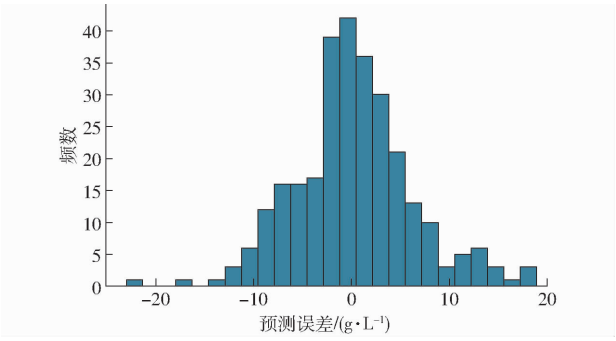

图 5 小麦容重预测模型预测误差分布图

Fig. 5 Prediction error distribution of wheat test weight prediction models

2.4 基于 SHAP 的小麦容重影响因素分析

为解析模型决策机理、揭示各特征对小麦容重预测结果的贡献规律,采用 SHAP 对最优模型进行可解释性分析。通过 SHAP 贡献值量化各输入特征对预测结果的正向与负向影响,明确关键影响因子及其作用方式,实现对黑箱模型的可视化解析。

选用前文确定的最佳 GBRT 小麦容重预测模型进行 SHAP 可解释性分析,以揭示预测机理。图 6a 展示了各特征的 SHAP 分布情况,图 6b 展示了特征重要性排序结果。特征重要性按照平均绝对 SHAP 值进行排序,数值越大表示该特征对模型预测结果的贡献越大。

由图 6b 可知,能量_q25、纹理熵_q75、不完善粒含量、周长_q75 和伸展度_q50 是影响小麦容重预测的前 5 个关键特征。其中,能量_q25 和纹理熵_q75 的重要性显著高于其他特征,表明纹理特征是驱动模型预测的主要信息来源。与此同时,不完善粒含量作为唯一进入前 3 位的理化特征,其重要性仅次于两个纹理特征,说明理化指标仍对容重形成具有重要影响。结合图 6a 进一步分析发现,高能量_q25 样本对应的 SHAP 值主要分布于正值区域,而高纹理熵_q75 样本对应的 SHAP 值主要分布于负值区域,表明能量_q25 与容重呈正相关关系,而纹理熵_q75 与容重呈负相关关系。

能量是指纹理能量,反映籽粒表面灰度分布的均匀程度,能量越高表示纹理越均匀;纹理熵,反映纹理复杂程度,熵值越低表示表面纹理越规则。综合来看,较高的能量和较低的纹理熵均表明籽粒表面更加光滑,而表面光滑的籽粒更容易形成紧密堆积,从而提高粮堆密度和容重;相反,表面粗糙的籽粒在堆积过程中颗粒间空隙增大,导致粮堆密度下降,容重降低。不完善粒含量的高取值同样表现出明显的负向贡献,即随着不完善粒比例增加,模型预

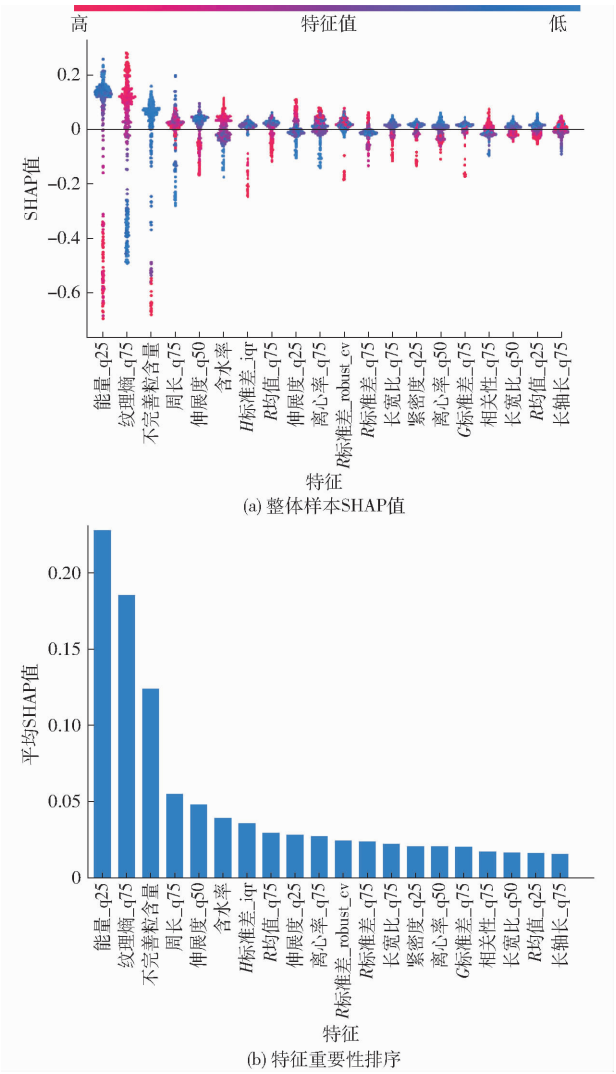

图 6　整体样本 SHAP 值和特征重要性排序

Fig. 6　Overall samples' SHAP values and driving feature importance ranking

测容重逐渐降低。这是因为不完善粒通常存在籽粒发育不充分、结构疏松或瘪粒等问题，会降低粮堆整体的紧密程度，从而导致容重下降。对于形状特征而言，周长_q75 和伸展度_q50 均表现出较高的重要性，且其高取值对应的 SHAP 值主要分布于正值区域，表明两者对容重预测具有正向促进作用。其中，周长反映籽粒轮廓尺寸，伸展度表示籽粒面积与外接矩形面积之比，可表征籽粒的充实程度和形态规整性。较大的周长和伸展度通常意味着籽粒发育更加充分、颗粒更加饱满、内部结构更加紧密，而在同类粮食中，成熟饱满、结构致密的籽粒往往具有更高的容重。

总体来看，纹理特征、形态特征与理化特征共同作用于小麦容重形成过程，其中纹理特征贡献最大，理化特征起辅助补充作用，三者共同构成了小麦容重预测的重要信息基础。SHAP 分析揭示的影响规律与粮食容重形成的实际物理机制高度一致。

图 7 展示了随机选取的一个小麦样本的 SHAP 瀑布图，用于解释各特征对单个样本预测结果的贡献方向及贡献程度。各特征对应的 SHAP 值表示该特征当前取值相对于基准值对预测结果产生的边际贡献，正值表示提高预测结果，负值表示降低预测结果。基准值 $E[f(X)]$ 为模型在训练样本上的平均预测值，经归一化处理后为 0；$f(x)$ 表示模型对当前单个样本的最终预测输出，由基准值与各特征的 SHAP 贡献值累加得到。该样本最终预测值的归一化结果为 $f(x) = 0.148$，说明该样本预测容重高于总体平均水平。

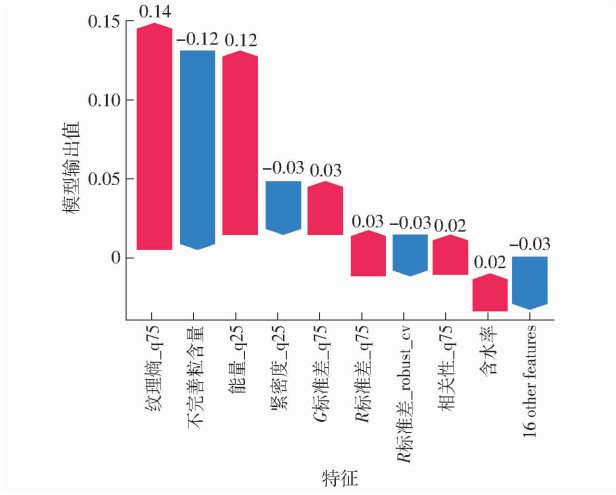

图 7　单样本 SHAP 瀑布图

Fig. 7　Single-sample SHAP waterfall plot

从各特征贡献来看，纹理熵_q75 和能量_q25 对该样本预测结果的影响最为显著，其 SHAP 值分别为 0.14 和 0.12，是推动预测值高于总体平均水平的主要因素。同时，*G* 标准差_q75 和 *R* 标准差_q75 均产生 0.03 的正向贡献，对预测值具有一定提升作用。相反，不完善粒含量对预测结果产生了最显著的负向影响，其 SHAP 值为 −0.12，是拉低预测值的主要因素。此外，紧密度_q25 和 *R* 标准差_robust_cv 均产生 −0.03 的负向贡献，说明这些特征的当前取值进一步拉低了模型预测结果。总体来看，该样本同时受到促进因素和抑制因素的共同作用。其中，纹理熵_q75、能量_q25 和 *G* 标准差_q75 等特征带来的正向贡献明显大于不完善粒含量等特征带来的负向贡献，因此最终预测结果高于总体平均水平。该结果进一步表明，模型能够综合考虑理化特征、纹理特征、颜色特征及形态特征之间的复杂作用关系，从个体样本层面揭示小麦容重形成的主要驱动因素。

综上，SHAP 分析从整体样本和单个样本两个层面揭示了小麦容重预测模型的决策依据。结果表明，模型识别出的关键影响因子及其作用方向均与

粮食容重形成的实际物理规律保持一致,验证了模型学习到的是具有实际意义的表型信息,而非数据中的偶然相关关系。其中,表面纹理特征对容重形成的贡献最为显著,其次为籽粒形态特征和理化特征,说明单籽粒图像中蕴含的大量表型信息能够有效表征小麦容重差异。同时,不完善粒含量、纹理均匀性以及籽粒饱满度等因素被证明是影响容重的重要驱动因子,为传统经验性认知提供了数据支撑和量化依据。该结果进一步说明,本研究提出的基于多源特征融合与样本级图像表征的小麦容重预测方法不仅能够实现高精度预测,而且具备良好的可解释性,为粮食容重快速检测及影响机理研究提供了新的技术路径。

3 结论

(1)理化参数与图像表型特征在小麦容重预测中具有明显互补性。相较于仅使用理化特征或仅使用图像特征,融合理化特征与图像特征能够显著提高小麦容重预测精度。含水率和不完善粒含量等理化指标反映样品宏观质量状态,颜色、形状和纹理等图像特征反映籽粒外观表型差异,两类特征具有较强的互补性与协同性,能够更加全面地表征影响小麦容重的关键因素。

(2)针对容重的样本级群体性状特点,采用单籽粒图像特征分布统计量构建样本级图像特征能够有效提升模型预测性能。与特征均值聚合方式相比,基于特征分布信息构建的样本级特征能够保留籽粒群体内部的异质性和结构差异,避免均值表征对样本内部差异的过度平滑。其中,Combined dist 6 特征集取得最佳预测效果(R^2 为 0.941 5 ± 0.009 7,RMSE 为(5.911 6 ± 0.378 8)g/L)。研究表明,适量引入分布统计信息有助于增强样本特征表达能力,但过多统计指标会引入冗余信息并降低模型泛化性能。该结果说明,基于单籽粒特征分布的样本级图像表征方法适合用于粮食容重等群体性品质指标预测,也为其他群体样本图像分析问题提供了新的特征构建思路。

(3)Boruta 特征筛选方法能够有效识别影响小麦容重的关键变量。在将特征维度由 170 维压缩至 25 维的同时,进一步提升了模型的预测性能,表明原始特征集中存在一定程度的冗余信息,合理的特征筛选有助于提高模型泛化能力并降低模型复杂度。

(4)在 KNN、SVR、MLP、GBRT、XGBoost 和 CatBoost 共 6 种机器学习模型中,GBRT 模型表现最佳。基于 Boruta 筛选特征构建的 GBRT 模型经贝叶斯优化后获得最高预测精度,蒙特卡洛交叉验证得:R^2 为 0.941 5 ± 0.009 7,RMSE 为(5.911 6 ± 0.378 8)g/L,GBRT 能够较好地适应当前包含理化变量和分布统计图像特征的中等规模表格型数据,在非线性关系拟合、模型泛化能力和训练效率之间取得较优平衡。

(5)SHAP 可解释性分析表明,能量_q25、纹理熵_q75、不完善粒含量、周长_q75 和伸展度_q50 是影响小麦容重的主要因素。其中,较高的纹理能量、较低的纹理熵以及更饱满的籽粒形态均有助于提高容重,而不完善粒含量增加则会降低容重。相关影响规律与粮食颗粒堆积特性和容重形成机理保持一致,从数据驱动角度验证了传统经验认知,并为小麦容重形成机制研究提供了定量依据。

参 考 文 献

[1] GB/T 5498—2013 粮油检验 容重测定[S].

[2] 王玉琦. 基于图像分割的小麦容重检测算法研究[D]. 郑州:河南工业大学, 2024.
Wang Yuqi. Research on wheat test weight detection algorithm based on image segmentation[D]. Zhengzhou: Henan University of Technology, 2024. (in Chinese)

[3] 张小华, 段晓亮, 侯春雨, 等. 小麦籽粒植酸和无机磷含量的变异及其与千粒重、容重的相关性[J]. 中国农业大学学报, 2014, 19(5): 8 – 12.
Zhang Xiaohua, Duan Xiaoliang, Hou Chunyu, et al. Variation of phytic acid and inorganic P contents in wheat grain and their relationship with test weight and 1000-kernel weight[J]. Journal of China Agricultural University, 2014, 19(5): 8 – 12. (in Chinese)

[4] 乔胜秋. 基因型、环境及其互作对小麦籽粒容重稳定性的影响[J]. 园艺与种苗, 2025, 45(4): 83 – 85.
Qiao Shengqiu. Effect of genotype, environment and their interaction on the stability of wheat grain test weight[J]. Horticulture & Seed, 2025, 45(4): 83 – 85. (in Chinese)

[5] 许蒙蒙, 宋杨, 吴悦, 等. 粮食容重自动分析仪的研究及性能验证[J]. 现代食品, 2025(15): 21 – 25, 48.
Xu Mengmeng, Song Yang, Wu Yue, et al. Research and properties verification of grain bulk density automatic analyzer[J]. Modern Food, 2025(15): 21 – 25, 48. (in Chinese)

[6] 荣云, 陈戈, 马浩然, 等. 粮食收购智能检验系统设计与研究[J]. 粮食储藏, 2024, 53(2): 8 – 12.
Rong Yun, Chen Ge, Ma Haoran, et al. Design and research of intelligent system for grain purchase[J]. Grain Storage, 2024,

53(2)：8 – 12. (in Chinese)

[7] 张玉荣，陈赛赛，姜忠丽，等. 基于图像处理的小麦容重检测方法研究[J]. 中国粮油学报，2015，30(3)：116 – 121.
Zhang Yurong，Chen Saisai，Jiang Zhongli，et al. Detection method of test weight of wheat by image processing[J]. Journal of the Chinese Cereals and Oils Association，2015，30(3)：116 – 121. (in Chinese)

[8] 周鸿达，张玉荣，王伟宇，等. 基于机器视觉技术预测玉米质量等级的方法研究[J]. 粮油食品科技，2016，24(6)：50 – 56.
Zhou Hongda，Zhang Yurong，Wang Weiyu，et al. Identification method of maize quality grades based on machine vision[J]. Science and Technology of Cereals，Oils and Foods，2016，24(6)：50 – 56. (in Chinese)

[9] 杨玮，兰红，李民赞，等. 基于图像处理和 GBRT 模型的表土层土壤容重预测[J]. 农业机械学报，2020，51(9)：193 – 200.
Yang Wei，Lan Hong，Li Minzan，et al. Prediction of top soil layer bulk density based on image processing and gradient boosting regression tree model[J]. Transactions of the Chinese Society for Agricultural Machinery，2020，51(9)：193 – 200. (in Chinese)

[10] 杨玮，兰红，李民赞，等. 基于图像处理和 SVR 的土壤容重与土壤孔隙度预测[J]. 农业工程学报，2021，37(12)：144 – 151.
Yang Wei，Lan Hong，Li Minzan，et al. Prediction bulk density and porosity of soil using image processing and support vector regression[J]. Transactions of CSAE，2021，37(12)：144 – 151. (in Chinese)

[11] 刘保华，马永安，赵勇，等. 普通小麦籽粒比重的 QTL 分析[J]. 河北农业大学学报，2013，36(5)：1 – 5.
Liu Baohua，Ma Yongan，Zhao Yong，et al. QTLs mapping for grain specific gravity in common wheat[J]. Journal of Hebei Agricultural University，2013，36(5)：1 – 5. (in Chinese)

[12] 戴晓红. 浅谈影响粮食容重、粮堆平均密度的因素[J]. 黑龙江粮食，2019(3)：48 – 49.

[13] 司建中. 小麦水分含量对容重及硬度的影响[J]. 粮食储藏，2011，40(5)：47 – 49.
Si Jianzhong. Effect of wheat moisture content on bulk density and kernel hardness[J]. Grain Storage，2011，40(5)：47 – 49. (in Chinese)

[14] 门奎斌. 影响容重测定的因素[J]. 科技传播，2011(3)：42.

[15] 张敏，杨茜，姜涛，等. 大麦容重与杂质的相关性研究[J]. 食品安全质量检测学报，2015，6(2)：491 – 493.
Zhang Min，Yang Xi，Jiang Tao，et al. Influence of foreign matter on the bulk density of barley[J]. Journal of Food Safety and Quality，2015，6(2)：491 – 493. (in Chinese)

[16] 丁卫新. 浅析新版容重国家标准[J]. 现代面粉工业，2014，28(3)：35 – 36.

[17] 王琳. 玉米容重相关性分析[J]. 粮油仓储科技通讯，2009，25(3)：37 – 38.

[18] 安晓飞，代均益，李立伟，等. 基于 GA – BP 的联合收获机小麦含水率检测模型研究[J]. 农业机械学报，2025，56(2)：325 – 332.
An Xiaofei，Dai Junyi，Li Liwei，et al. Wheat moisture content prediction model for combine harvester based on GA – BP method[J]. Transactions of the Chinese Society for Agricultural Machinery，2025，56(2)：325 – 332. (in Chinese)

[19] 李晓亮，赵艳妍，董德良，等. 稻谷外观品质检测技术研究及快检仪器开发[J]. 粮油仓储科技通讯，2023，39(5)：47 – 52.

[20] 李晓亮，石恒，董德良，等. 小麦不完善粒图像采集技术及检测设备研发[J]. 粮食储藏，2019，48(5)：46 – 51.
Li Xiaoliang，Shi Heng，Dong Deliang，et al. Research and development of image acquisition technology and detection equipment for unsound kernels of wheat[J]. Grain Storage，2019，48(5)：46 – 51. (in Chinese)

[21] GB/T 5494—2019　粮油检验 粮食、油料的杂质、不完善粒检验[S].

[22] 徐法虎，王一晖，蒋佳玮，等. 小麦籽粒外观品质检测装置设计与试验[J]. 农业机械学报，2026，57(12)：222 – 232.
Xu Fahu，Wang Yihui，Jiang Jiawei，et al. Design and experiment of detection device for wheat kernel appearance quality [J]. Transactions of the Chinese Society for Agricultural Machinery，2026，57(12)：222 – 232. (in Chinese)

[23] Desalvio A J，Matabuena M，Adak A，et al. Distributional data analysis uncovers hundreds of novel and heritable phenomic features from temporal cotton and maize drone imagery[PP/OL]. bioRxiv (2025 – 09 – 07)[2026 – 07 – 18]. https://doi.org/10.1101/2025.09.05.674557.

[24] McDonald L S，Assadzadeh S，Panozzo J F. Images，features，or feature distributions? A comparison of inputs for training convolutional neural networks to classify lentil and field pea milling fractions[J]. Biosystems Engineering，2021，208：16 – 27.

[25] Henderi H. Comparison of min-max normalization and z-score normalization in the K-nearest neighbor (KNN) algorithm to test the accuracy of types of breast cancer[J]. IJIIS：International Journal of Informatics and Information Systems，2021，4(1)：13 – 20.

[26] 黄朋，林佳瑜，梁祖红. 基于互信息和提示学习的中文无监督对比学习方法[J]. 计算机应用，2025，45(10)：3101 – 3110.
Huang Peng，Lin Jiayu，Liang Zuhong. Unsupervised contrastive learning for Chinese with mutual information and prompt learning[J]. Journal of Computer Applications，2025，45(10)：3101 – 3110. (in Chinese)

[27] Manikandan G, Pragadeesh B, Manojkumar V, et al. Classification models combined with Boruta feature selection for heart disease prediction[J]. Informatics in Medicine Unlocked, 2024, 44: 101442.

[28] 李鱼强, 潘天红, 李浩然, 等. 近红外光谱 LASSO 特征选择方法及其聚类分析应用研究[J]. 光谱学与光谱分析, 2019, 39(12): 3809 - 3815.
Li Yuqiang, Pan Tianhong, Li Haoran, et al. NIR spectral feature selection using LASSO method and its application in the classification analysis[J]. Spectroscopy and Spectral Analysis, 2019, 39(12): 3809 - 3815. (in Chinese)

[29] 胡念三, 刘克稻, 张鑫宇, 等. 基于 KNN 回归的高炉推移系统推移性能预测[J]. 重型机械, 2025(1): 70 - 78.
Hu Niansan, Liu Kedao, Zhang Xinyu, et al. Pushing performance prediction of a blast furnace pushing system based on KNN regression[J]. Heavy Machinery, 2025(1): 70 - 78. (in Chinese)

[30] Fan Guofeng, Peng Liling, Hong Weichiang, et al. Electric load forecasting by the SVR model with differential empirical mode decomposition and auto regression[J]. Neurocomputing, 2016, 173: 958 - 970.

[31] Üstün B, Melssen W J, Buydens L M C. Visualisation and interpretation of support vector regression models[J]. Analytica Chimica Acta, 2007, 595(1 - 2): 299 - 309.

[32] 承达瑜, 陈帅琴, 付春晓, 等. 融合无人机光谱、纹理特征与 LAI 的冬小麦单产估测方法[J]. 农业机械学报, 2026, 57(13): 281 - 293.
Cheng Dayu, Chen Shuaiqin, Fu Chunxiao, et al. Winter wheat yield estimation method based on integration of UAV spectral features, texture features and LAI[J]. Transactions of the Chinese Society for Agricultural Machinery, 2026, 57(13): 281 - 293. (in Chinese)

[33] Yan Zhao. Research and application on BP neural network algorithm [C]// Proceedings of the 2015 International Industrial Informatics and Computer Engineering Conference. Xi'an: Atlantis Press, 2015:1444 - 1447.

[34] Song Jiang, Li Jinyuan, Zhang Sai, et al. Landslide risk prediction by using GBRT algorithm: application of artificial intelligence in disaster prevention of energy mining[J]. Process Safety and Environmental Protection, 2022, 166: 384 - 392.

[35] 何宁, 王剑, 卢宪菊, 等. 基于无人机多源数据的花生表型估算模型[J]. 农业机械学报, 2026, 57(1): 114 - 124.
He Ning, Wang Jian, Lu Xianju, et al. Peanut phenotype estimation model based on multi-source data from unmanned aerial vehicles[J]. Transactions of the Chinese Society for Agricultural Machinery, 2026, 57(1): 114 - 124. (in Chinese)

[36] Yaseen Z M. An insight into machine learning models era in simulating soil, water bodies and adsorption heavy metals: review, challenges and solutions[J]. Chemosphere, 2021, 277: 130126.

[37] 文嘉意, 薛经纬, 李晓璇. XGboost 辅助的变电站底部薄弱型设备抗震快速评估[J]. 高压电器, 2025, 61(12): 9 - 16.
Wen Jiayi, Xue Jingwei, Li Xiaoxuan. Rapid seismic assessment of vulnerable bottom-mounted equipment in substation assisted by XGBoost[J]. High Voltage Apparatus, 2025, 61(12): 9 - 16. (in Chinese)

[38] 杨正雄, 张显云, 任明亚. 基于 CatBoost 的四川木里县森林火灾预测[J]. 科学技术与工程, 2025, 25(21): 8823 - 8832.
Yang Zhengxiong, Zhang Xianyun, Ren Mingya. Forest fire prediction in Muli County, Sichuan based on CatBoost[J]. Science Technology and Engineering, 2025, 25(21): 8823 - 8832. (in Chinese)

[39] Edoardo M, Ferenc S, Stella T, et al. SHAP-based explanation methods: a review for NLP interpretability[C]// Proceedings of the 29th International Conference on Computational Linguistics. Gyeongju: International Committee on Computational Linguistics, 2022:4593 - 4603.

(上接第 33 页)

[27] Sharma R, Kamra A. A review on CLAHE based enhancement techniques[C]// 2023 6th International Conference on Contemporary Computing and Informatics (IC3I). Gautam Buddha Nagar: IEEE, 2023: 321 - 325.

[28] Devi T G, Patil N, Rai S, et al. Gaussian blurring technique for detecting and classifying acute lymphoblastic leukemia cancer cells from microscopic biopsy images[J]. Life, 2023, 13(2): 348.

[29] Jing J, Ren H. Defect detection of printed fabric based on RGBAAM and image pyramid[J]. Autex Research Journal, 2021, 21(2): 135 - 141.

[30] 吴宪君. 基于 SIFT 的阈值匹配的人脸识别算法[J]. 计算机光盘软件与应用, 2013, 16(24): 191 - 192.
Wu Xianjun. Face recognition algorithm based on threshold matching with SIFT[J]. Computer CD Software and Applications, 2013, 16(24): 191 - 192. (in Chinese)

[31] Bakurov I, Buzzelli M, Schettini R, et al. Structural similarity index (SSIM) revisited: a data-driven approach[J]. Expert Systems with Applications, 2022, 189: 116087.