

# 融合无人机多时相参数的冬小麦单产估测方法

葛焱<sup>1,2</sup> 朱志畅<sup>2</sup> 臧晶荣<sup>3</sup> 张睿男<sup>3</sup> 金时超<sup>4</sup> 徐焕良<sup>2</sup> 翟肇裕<sup>2</sup>

(1. 南京农业大学工学院, 南京 210031; 2. 南京农业大学人工智能学院, 南京 210031;

3. 南京农业大学农学院, 南京 210095; 4. 南京农业大学前沿交叉学院, 南京 210095)

**摘要:** 为探讨无人机遥感与多时相参数融合在冬小麦单产预测中的潜力, 采集了冬小麦7个生育期的无人机RGB和多光谱数据, 从中分别提取光谱参数和形态参数, 采用5种机器学习算法建模, 比较不同生育期单产预测效果, 在此基础上, 筛选优势参数组合, 分别比较不同生育期及参数组合与单产预测之间的相关性。结果表明, 不同生育期及参数组合对冬小麦单产预测具有不同影响; 单生育期时, 灌浆期和开花期预测效果最佳, 其次为抽穗期、孕穗期、成熟期、拔节期和分蘖期; 多生育期时, 双生育期、三生育期、四生育期组合预测精度逐渐升高, 但考虑到增长幅度以及数据采集、算力开销、处理成本等因素, “拔节期+抽穗期+灌浆期”的三生育期组合经济性最高。5种机器学习算法整体预测精度从高到低分别为反向传播神经网络、随机森林、支持向量机、极端梯度提升和逐步多元回归, 通过机器学习可解释性方法SHAP优选的光谱和形态参数组合虽然不同生育期有所不同, 但除拔节期外, 均能提高单产预测精度。研究结果可为冬小麦单产预测提供方法依据和技术参考。

**关键词:** 冬小麦; 单产预测; 无人机遥感; 机器学习; 多时相参数; SHAP法

**中图分类号:** S333 **文献标识码:** A **文章编号:** 1000-1298(2025)01-0344-12

**OSID:**



## Yield Estimation of Winter Wheat Based on Multi-temporal Parameters by UAV Remote Sensing

GE Yan<sup>1,2</sup> ZHU Zhichang<sup>2</sup> ZANG Jingrong<sup>3</sup> ZHANG Ruinan<sup>3</sup> JIN Shichao<sup>4</sup> XU Huanliang<sup>2</sup> ZHAI Zhaoyu<sup>2</sup>

(1. College of Engineering, Nanjing Agricultural University, Nanjing 210031, China

2. College of Artificial Intelligence, Nanjing Agricultural University, Nanjing 210031, China

3. College of Agriculture, Nanjing Agricultural University, Nanjing 210095, China

4. Academy for Advanced Interdisciplinary Studies, Nanjing Agricultural University, Nanjing 210095, China)

**Abstract:** To comprehensively assess the potential of integrating unmanned aerial vehicle (UAV) remote sensing and multi-temporal parameters fusion in predicting winter wheat yield in the past, the RGB and multi-spectral data from UAVs spanning seven critical growth stages of winter wheat were collected. From these data, spectral and morphological parameters were directly extracted. Five machine learning algorithms were then employed to compare and evaluate the yield prediction performance at each individual growth stage. Subsequently, an in-depth analysis was conducted, based on the identified optimal parameter combinations, to examine the relationships between various growth stages and the accuracy of yield predictions. The results revealed that both individual growth stages and their combinations significantly impacted the prediction of winter wheat yield. Among the single growth stages, the filling and flowering stages achieved the highest prediction accuracy, followed by the heading, booting, maturity, jointing, and tillering stages. When considering multiple growth stages, the prediction accuracy was progressively increased from dual-stage to tri-stage and quad-stage combinations. However, balancing the marginal gains in accuracy against factors such as data acquisition and processing costs, as well as computational resources, the tri-stage combination of “jointing + heading + filling” emerged as the most cost-effective solution. In terms of the five machine learning algorithms employed, the overall prediction accuracy ranked from the highest to the lowest was as follows: BPNN, RF, SVM, XGBoost,

收稿日期: 2024-07-28 修回日期: 2024-09-23

基金项目: 江苏省自然科学基金项目(BK20231004)和中央高校基本科研业务费专项资金项目(KYCXJC2023007)

作者简介: 葛焱(1987—), 男, 博士生, 主要从事农业大数据分析利用研究, E-mail: geyan@njau.edu.cn

通信作者: 翟肇裕(1992—), 男, 副教授, 博士, 主要从事智慧农业、深度学习和决策支持系统研究, E-mail: zhaoyu.zhai@njau.edu.cn

and SMR. Notably, while the optimal combinations of spectral and morphological parameters identified through the SHAP method varied across growth stages, they consistently enhanced the yield prediction accuracy for all stages excepted the jointing stage. The research result can provide valuable methodological insights and technical references for the precise prediction of winter wheat yield per unit area in the past.

**Key words:** winter wheat; prediction of yield per unit area; UAV remote sensing; machine learning; multi-temporal parameters; SHAP

## 0 引言

中国为小麦生产大国,据中国国家统计局报道,2023年冬小麦种植面积超过 $2.3 \times 10^7 \text{ hm}^2$ ,单产达到约 $5.98 \text{ t/hm}^2$ ,总产量超过 $1.38 \times 10^8 \text{ t}$ 。小麦收获前对其进行精准测产一直是农业生产领域的重点和难点,对于优化农机调度、保持粮食市场稳定、合理确定收购价格等具有重要意义。然而,传统的小麦测产方法抽样成本高、人力耗费大、干扰因素多,且测产结果的时效性和精准性难以保证<sup>[1]</sup>。近年来,随着信息技术的发展,卫星遥感等手段逐渐应用于作物大面积生长监测中,其具有覆盖范围广、获取成本低和易于重复观测等特性,但受制于空间分辨率和云层、天气等因素影响,卫星遥感对于种植面积小、地块分散等区域的估产准确度不高<sup>[2]</sup>。无人机遥感具有操作简便、覆盖速度快、空间分辨率高、机动性强等特点<sup>[1-4]</sup>,能够准确、高通量获取作物生长信息,不仅降低了人工和时间成本,更提高了估产效率和精准度<sup>[5]</sup>。借助于无人机遥感平台,从采集的图像中提取特征信息,结合机器学习算法,可实现对作物单产的快速估测。甘甜等<sup>[6]</sup>通过获取冬小麦光谱数据,从中提取了61个光谱指数,发现除个别指数外,大部分都与单产密切相关,并且相对于高光谱和多光谱,RGB预测精度更高。杨楠等<sup>[7]</sup>通过采集小麦拔节期、抽穗期、开花期和灌浆期的无人机光谱数据,分别利用随机森林(Random forest, RF)、偏最小二乘回归(Partial least squares regression, PLSR)、反向传播神经网络(Back propagation neural network, BPNN)和支持向量机(Support vector machine, SVM)建立单产预测模型,发现在灌浆期基于RF算法的模型效果最好。为进一步提高单产预测精度,探索通过融合多源数据来提高估产效果。宋成阳等<sup>[8]</sup>采集了冬小麦灌浆期RGB和多光谱数据,利用岭回归、SVM、RF等6种机器学习算法分别建立基于单一来源数据和基于多源数据融合的估产模型,发现6种算法均在多源数据融合时精度最高。FEI等<sup>[9]</sup>发现仅使用RGB、多光谱或近红外等单一数据来源建模进行小麦单产估测时精度较低,但任意2种或3种数据的融合却可明显提高预测精度,

$R^2$ 最高达0.692。LI等<sup>[10]</sup>将从无人机RGB和多光谱遥感图像中提取的光谱参数和结构参数融合,结合小麦不同生育期,通过缩小目标性状和生长阶段来提高预测精度,取得了明显效果, $R^2$ 可达0.81。

在开展多源数据融合的同时,多时相参数同样受到了关注。王晶晶等<sup>[11]</sup>利用筛选出的随机森林模型进行单产估测,发现冬小麦多时相预测效果明显优于单生育期,且从起身期至灌浆后期的8次遥感单产估算精度最好。WANG等<sup>[12]</sup>采集了水稻多个生育期的RGB和多光谱数据,发现单产与分蘖、拔节和抽穗期的叶绿素含量呈显著正相关,且使用多时相融合的模型实现了最佳的估测精度。LI等<sup>[13]</sup>利用SVM、RF等4种机器学习模型,结合多时相数据,构建小麦最佳单产预测模型,发现仅利用拔节期到抽穗期连续组合数据即可达到预测精度最高值。李阳等<sup>[14]</sup>基于多时相多参数融合对麦玉轮作中小麦单产进行估测,结果显示多生育期融合精度比单生育期最优模型 $R^2$ 提高0.01~0.03,多模态参数融合精度明显高于单一模态,且不同模态融合对模型精度影响不同,四模态参数融合 $R^2$ 最高达0.92。为此,在前期研究基础上,本文将基于多时相多参数融合理念,比较不同生育期与不同算法单产预测差异,通过SHAP法优选不同生育期最适光谱和形态参数组合,构建单生育期和多时相参数预测模型,提出最佳预测时间范围,以为冬小麦单产估测提供方法依据和技术参考。

## 1 材料与方法

### 1.1 试验设计

试验地点位于江苏省南京市溧水区南京农业大学白马教学科研基地( $31^\circ 37' \text{N}$ ,  $119^\circ 10' \text{E}$ ),年平均气温约 $16.4^\circ \text{C}$ ,年平均相对湿度约76%,年平均降水量约 $1204.3 \text{ mm}$ ,属北亚热带季风气候。试验区域布局如图1所示,采用随机区组设计,以56个小麦品种为试验材料,设置0、120、240  $\text{kg/hm}^2$  3个施氮水平(分别用 $\text{N}_0$ 、 $\text{N}_{120}$ 和 $\text{N}_{240}$ 表示)和3次重复试验,每个小区长 $1.2 \text{ m}$ 、宽 $1 \text{ m}$ 、行间距 $0.2 \text{ m}$ ,试验于2021年11月15日至2022年5月底开展。总体技术路线见图2。

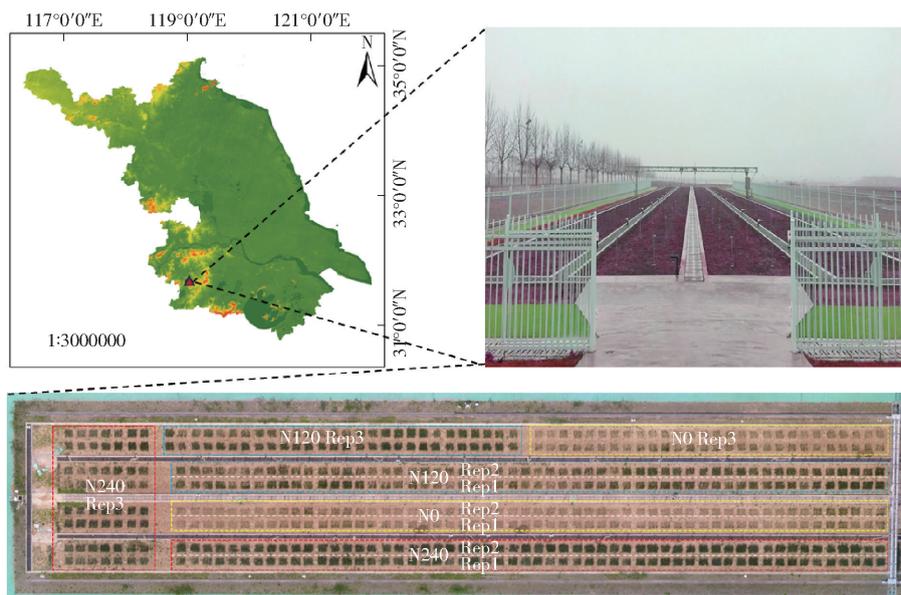


图1 试验区域布局图

Fig. 1 Layout map of experimental area

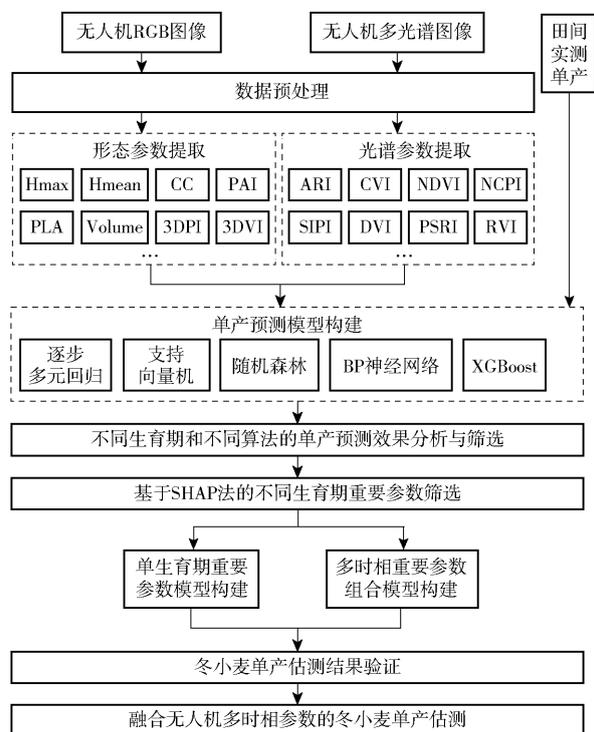


图2 总体技术路线图

Fig. 2 Overall technical roadmap

## 1.2 数据获取

RGB 图像使用大疆精灵 4 (DJI Phantom 4) 型无人机采集, 飞行采用交叉网络方式, 高度 20 m, 范围 120 m × 35 m, 相机倾斜角 80°, 正面和侧面重叠度均为 80%, 像素 1 240 万, 每次任务约耗时 15 min, 每次采集 RGB 原始影像 200 幅左右。多光谱图像采用八旋翼无人机 (Ecodrone UAS-8 型) 搭载五通道多光谱相机采集, 多光谱相机包含红光波段 ( $R$ : 波长 (650 ± 16) nm)、绿光波段 ( $G$ : 波长 (560 ± 16) nm)、蓝光波段 ( $B$ : 波长 (450 ± 16) nm)、红边波

段 ( $RE$ : 波长 (730 ± 16) nm) 和近红外波段 ( $NIR$ : 波长 (840 ± 16) nm), 分辨率 1 280 像素 × 960 像素, 视角 47.2°, 飞行参数设置和航线规划与 RGB 图像采集保持一致, 每次飞行前, 在地面放置光谱校正板, 便于后期图像辐射校正, 每次任务耗时约 30 min, 每次采集多光谱原始影像 3 000 幅左右。根据小麦生长状况, 分别于分蘖期 (3 月 8 日)、拔节期 (3 月 24 日)、孕穗期 (4 月 1 日)、抽穗期 (4 月 14 日)、开花期 (4 月 23 日)、灌浆期 (4 月 30 日) 和成熟期 (5 月 16 日) 开展图像采集。待小麦完全成熟后, 按小区人工进行整体切割收获, 自然晾晒至质量恒定, 脱粒后测定各小区实际单产。

## 1.3 数据处理

### 1.3.1 无人机影像预处理

(1) RGB 图像预处理: 利用 Pix4Dmapper 软件自动识别 RGB 原始影像的坐标和高度, 依次进行配准和拼接操作, 特征点影像比例设置为全面高精度处理; 随后进行几何校正, 结合前期试验区域固定设置的地面控制点, 在影像上进行标注, 保证获得的试验区域正射 RGB 影像精度达到厘米级别; 接着, 使用运动恢复结构算法对得到的正射影像进行点云重构, 生成试验区域三维点云重构图, 并根据小区坐标, 对得到的三维点云感兴趣区域进行裁剪, 提取全部小区的三维点云数据后, 分别进行去噪、滤波和归一化等处理。

(2) 多光谱图像预处理: 多光谱图像预处理与 RGB 大致相同, 在配准、拼接和几何校正后得到正射多光谱影像, 但由于大气散射、太阳角度变化等原因, 要结合各波段光谱反射系数, 利用 Pix4Dmapper

软件中辐射校正功能模块完成校正,以降低失真现象对参数提取的影响;最后,使用 ENVI 5.1 软件对正射多光谱影像进行波段融合,便于后续光谱特征参数提取。

### 1.3.2 光谱参数提取

光谱参数是由不同波段反射率以代数形式组合而成的一种参数,可以提取多种有效信息<sup>[15-16]</sup>。本文选取广泛使用且与植物生长发育紧密相关的 14 种植被指数进行参数提取,分别为花青素反射指数 (Anthocyanin reflectance index, ARI)<sup>[17]</sup>、绿色叶绿素指数 (Chlorophyll indices, CIgreen)<sup>[18]</sup>、叶绿素植被指数 (Chlorophyll vegetation index, CVI)<sup>[19]</sup>、归一化叶绿素色素植被指数 (Normalized chlorophyll pigment index, NCPI)<sup>[20]</sup>、结构不敏感色素指数 (Structure insensitive pigment index, SIPI)<sup>[21]</sup>、改进土壤调节植被指数 (Modified soil adjusted vegetation index, MSAVI)<sup>[22]</sup>、绿光波段归一化差异植被指数 (Green normalized difference vegetation index, GNDVI)<sup>[23]</sup>、差异植被指数 (Difference vegetation index, DVI)<sup>[24]</sup>、归一化差异植被指数 (Normalized difference vegetation index, NDVI)<sup>[25]</sup>、归一化绿红差异植被指数 (Normalized green red difference index, NGRDI)<sup>[25]</sup>、近红外反射率植被指数 (Near-infrared reflectance of vegetation, NIRv)<sup>[26]</sup>、植被衰老反射指数 (Plant senescence reflectance index,

PSRI)<sup>[27]</sup>、比值植被指数 (Ratio vegetation index, RVI)<sup>[28]</sup> 和增强植被指数 (Enhanced vegetation index, EVI)<sup>[29]</sup>。以上光谱参数大致可分为 2 类,一类是以 ARI、CIgreen、CVI 等为代表的与植物内部色素含量高度相关的指数,它们与光合作用密切相关;另一类是以 DVI、NDVI、EVI 等为代表的与植物功能结构紧密相关的指数,它们反映植物生长发育的进展情况,这些指数已被证明在单产预测上显示出较强的潜力<sup>[30]</sup>。

### 1.3.3 形态参数提取

形态参数与作物形态结构、生理状态等密切相关<sup>[31]</sup>。本文基于前人研究中利用立体几何运算从 RGB 图像中直接提取形态结构参数的方法<sup>[32-33]</sup>,对每个小区生成的三维点云数据进行参数提取,共提取 28 种形态参数,详见表 1。为更好地与单产相关联,展现作物不同维度形态结构,提取以 Hmax、Hmean、H80 ~ H99 为代表的一维参数和以 CC、PAI、PLA 为代表的二维参数,以及以 Volume、3DVI、3DPI 为代表的三维参数。一维参数与高度相关,高度作为遗传育种和栽培管理的重要农艺性状,是单产的重要预测因子。二维参数很好地表示冠层和叶面积情况<sup>[32]</sup>,与植物生长和光合作用直接相关。三维参数为植物形态的立体空间展示,已用于小麦<sup>[13]</sup>、玉米<sup>[31]</sup>等作物单产和生物量的估算,有助于更加精准的单产预测。

表 1 形态参数

Tab.1 Morphological parameters

形态参数	释义	文献序号
最大高度 (Maximum height, Hmax)	所有归一化点高度 Z 最大值	[31]
平均高度 (Mean height, Hmean)	所有归一化点高度 Z 平均值	[32]
高度百分位数 (Height quantiles, H80 ~ H99)	从 80% 的分位数高度 (H80) 逐个到 99% 的分位数高度 (H99), 以 1% 间隔, 共 20 个	[34-35]
冠层覆盖度 (Canopy cover, CC)	单位面积中植物冠层所占比例	[33]
植物面积指数 (Plant area index, PAI)	植物叶片等地上部分各高度层密度之和	[36]
投影叶面积 (Projected leaf area, PLA)	植物叶面投影到 XY 平面所占面积	[37]
三维冠层体积 (3D canopy volume, Volume)	植物冠层体素点三维体积	[38]
三维体积指数 (3D volume index, 3DVI)	植株体素点占有所有体素点比例	[13]
三维轮廓指数 (3D profile index, 3DPI)	植物轮廓体素点占有所有体素点比例	[31]

## 1.4 模型构建

采用逐步多元回归 (SMR)、支持向量机 (SVM)、随机森林 (RF)<sup>[39]</sup>、反向传播神经网络 (BPNN)、极端梯度提升 (XGBoost) 5 种机器学习算法进行建模。研究随机选取 70% 作为训练集, 30% 作为验证集, 采用随机交叉验证方式对模型预测效果进行评估。

## 1.5 特征筛选

SHAP 是一种解释机器学习模型预测输出的统

一框架, 是一种根据预期表示一致性和局部准确性的可加特征归因方法<sup>[40]</sup>。SHAP 为模型特征变量分配一个特定的预测重要性值 (即 SHAP 值), 作为变量重要性的统一度量, SHAP 值计算公式为

$$Y_n = y_b + f(x_n, 1) + f(x_n, 2) + \dots + f(x_n, P) \quad (1)$$

式中  $Y_n$ ——SHAP 值

$y_b$ ——变量在样本上均值

$f(x_n, 1)$ ——第  $n$  个样本中第 1 个变量贡献值

$x_n$ ——输入样本的属性值

$P$ ——变量数量

研究采用 SHAP 方法对输入模型的光谱和形态参数分别计算得到 SHAP 值,量化各参数在单产预测中的重要性,并根据重要性排序对敏感特征参数进行筛选。

## 1.6 精度评价

采用决定系数 (Correlation of determination,  $R^2$ )、均方根误差 (Root mean square error, RMSE)、标准均方根误差 (Normalized root mean square error, NRMSE) 和平均绝对误差 (Mean absolute error, MAE) 作为模型精度评价指标。

## 2 结果与分析

### 2.1 不同生育期不同算法单产预测效果分析

基于 SMR、SVM、RF、BPNN、XGBoost 5 种算法建模的冬小麦不同生育期单产预测结果见表 2。可以看出,同一生育期不同算法预测效果不同,在分蘖期、拔节期、孕穗期、抽穗期、开花期、灌浆期、成熟期 7 个生育期中 BPNN 算法均有较好表现,以拔节期为例,SMR 算法的决定系数  $R^2$  为 0.558, BPNN 算法的  $R^2$  则达到 0.758,两者相差 0.2,并且  $R^2$  保持较高水平的同时, RMSE、NRMSE 和 MAE 也相对较低;除分蘖期外, RF 算法的预测效果仅次于 BPNN 算法,以抽穗期为例,5 种算法预测效果由好到差依次为 BPNN、RF、SVM、SMR、XGBoost,算法的选择对于预测精度的提升具有重要影响。

同一算法在不同生育期的估产效果也不同,随着小麦生长,各模型预测效果均有所提升,并在灌浆期达到顶峰,随后下降。以 BPNN 算法为例,分蘖期  $R^2$  为 0.541,灌浆期  $R^2$  达 0.812,增长超过 50%, RMSE、NRMSE 和 MAE 也进一步降低。对比发现,灌浆期和开花期预测效果最佳,其次为抽穗期,孕穗期和成熟期整体预测效果接近,拔节期好于分蘖期,生育期的选择是算法匹配和单产精准预测的重要前提。灌浆期作为小麦生长发育的关键时期,侧重于籽粒的形成和填充,直接影响籽粒发育与质量积累,进而影响小麦单产和品质;开花期中部分算法  $R^2$  虽略高于灌浆期,但结合提升幅度与稳定性等总体来看,灌浆期整体预测效果优于开花期,杨楠等<sup>[7]</sup>的研究也证明了这一点,其认为相比于开花期,灌浆期与单产的相关性更高;而分蘖期、拔节期和抽穗期更多是小麦植株的生长和生殖结构的发育,成熟期则是聚焦籽粒的品质形成和收获准备。为此,本文从 7 个生育期中选取拔节期、抽穗期、灌浆期和成熟期 4 个时期,结合优选的 BPNN 算法,进行后续研究。

表 2 冬小麦不同生育期不同算法单产预测对比

Tab.2 Comparison of yield prediction for winter wheat at various growth stages using different algorithms

生育期	算法	$R^2$	RMSE/ ( $\text{kg}\cdot\text{m}^{-2}$ )	NRMSE/ %	MAE/ ( $\text{kg}\cdot\text{m}^{-2}$ )
分蘖期	SMR	0.417	0.158	18.88	0.131
	SVM	0.504	0.151	19.84	0.122
	RF	0.496	0.143	16.88	0.114
	XGBoost	0.452	0.149	17.96	0.119
	BPNN	0.541	0.147	14.85	0.114
拔节期	SMR	0.558	0.142	16.55	0.108
	SVM	0.663	0.119	16.13	0.093
	RF	0.730	0.118	11.68	0.089
	XGBoost	0.604	0.139	14.43	0.106
	BPNN	0.758	0.103	13.53	0.075
孕穗期	SMR	0.628	0.137	13.69	0.105
	SVM	0.753	0.103	11.69	0.083
	RF	0.774	0.095	11.12	0.070
	XGBoost	0.733	0.106	13.64	0.073
	BPNN	0.787	0.091	11.69	0.070
抽穗期	SMR	0.716	0.104	10.32	0.075
	SVM	0.721	0.102	11.58	0.079
	RF	0.777	0.095	9.66	0.070
	XGBoost	0.703	0.109	11.09	0.086
	BPNN	0.801	0.094	12.42	0.074
开花期	SMR	0.731	0.107	13.85	0.081
	SVM	0.750	0.101	11.79	0.077
	RF	0.806	0.092	10.43	0.063
	XGBoost	0.759	0.100	10.15	0.074
	BPNN	0.814	0.092	10.43	0.065
灌浆期	SMR	0.709	0.113	11.54	0.085
	SVM	0.764	0.101	12.05	0.075
	RF	0.805	0.090	11.91	0.065
	XGBoost	0.771	0.098	11.52	0.073
	BPNN	0.812	0.092	10.91	0.070
成熟期	SMR	0.597	0.133	13.26	0.103
	SVM	0.671	0.123	13.93	0.096
	RF	0.740	0.106	12.02	0.079
	XGBoost	0.687	0.116	13.20	0.088
	BPNN	0.788	0.096	12.43	0.068

### 2.2 不同生育期优势参数筛选和模型构建

#### 2.2.1 不同生育期优势参数筛选

考虑到机器学习算法精度容易受数据集特征选择的影响<sup>[41]</sup>,采用 SHAP 法对所选 4 个生育期排名前 10 的特征参数进行重要性排序,以探究不同光谱和形态参数组合对单产估测的影响(图 3)。可以看出,4 个生育期特征参数重要性前 10 中既有光谱参数也有形态参数,光谱参数 ARI、CVI、CIgreen 在拔节期、抽穗期中重要性排序较高,与单产关联性较大;形态参数 Volume、3DPI 在灌浆期和成熟期中重要性逐渐显现,与光谱参数 ARI、DVI 等共同影响单

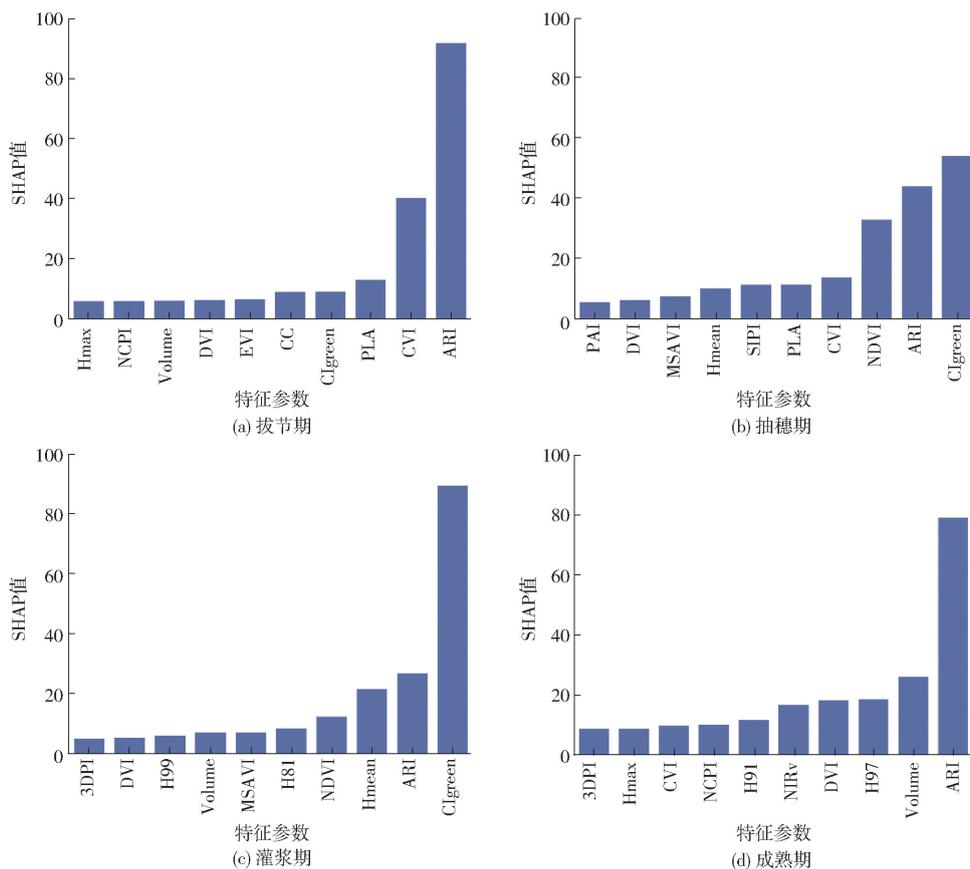


图 3 基于 SHAP 的不同生育期优势参数筛选

Fig. 3 Selection of dominant parameters at various growth stages based on SHAP

产估测效果。具体来看,拔节期重要性排序前 10 参数中,光谱参数 6 个 (ARI、CVI、CIgreen、EVI、DVI、NCPI),形态参数 4 个 (PLA、CC、Volume、Hmax);抽穗期排序前 10 参数中,光谱参数 7 个 (CIgreen、ARI、NDVI、CVI、SIPI、MSAVI、DVI),形态参数 3 个 (PLA、Hmean、PAI);灌浆期中光谱参数 (CIgreen、ARI、NDVI、MSAVI、DVI) 和形态参数 (Hmean、H81、Volume、H99、3DPI) 各为 5 个;成熟期中光谱参数 (ARI、DVI、NIRv、NCPI、CVI) 和形态参数 (Volume、H97、H91、Hmax、3DPI) 也各占一半。一方面,不同生育期光谱和形态参数重要性排序不同,以 CVI 为例,其在拔节期重要性排序第 2,抽穗期排第 4,成熟期第 8,但在灌浆期却未能进入前 10;另一方面,4 个生育期 SHAP 值最高的都为光谱指数,拔节期和成熟期为 ARI,抽穗期和灌浆期为 CIgreen,结构参数排序最高的为 Volume,其在成熟期排第 2,其余生育期结构参数排序都在第 3 及以后,拔节期 PLA 和灌浆期 Hmean 排第 3,抽穗期 PLA 排第 5,类似研究已经证实了光谱参数在谷物单产预测中的良好表现<sup>[16,42]</sup>。

光谱参数重要性排序高并不代表形态参数在估产方面可有可无。随着小麦生长发育进程的推进,CVI、EVI 等光谱参数重要性不断下降,

Volume、3DPI 等形态参数排序逐渐上升,高度分位数 (H81、H99、H97、H91) 等与单产的相关性日渐提高,这与 LI 等<sup>[43]</sup>的研究基本一致,形态参数提供了作物生长和空间结构的丰富信息,更加有利于单产预测。实际上,植物高度、株型结构与单产之间的关系一直是农学家关心的问题,作物高度的增加或冠层结构的优化,可以加大叶片表面积,提高光合作用效率,促使更多的光合产物转化为生物量进行积累。LAW 等<sup>[44]</sup>在 1978 年就发现植物高度与谷物单产存在相关性,如今,随着无人机技术的发展,可以利用其搭载的高分辨率成像平台,采集高质量数据信息,从中提取需要的光谱、结构等特征信息,并将其应用到单产预测、生长评估和病害防控等环节中去。

### 2.2.2 单生育期优势参数模型构建及评价

将图 3 中 4 个生育期重要性排序前 10 的特征参数作为输入变量,构建单生育期优势参数预测模型,比较不同生育期全特征参数与排序前 10 优势参数进行单产预测效果的差异。从图 4 可以看出,通过 SHAP 优选后 4 个生育期优势参数模型,拔节期、抽穗期、灌浆期和成熟期的  $R^2$  分别为 0.723、0.819、0.826 和 0.814,与表 2 中全特征输入模型  $R^2$  相比,除拔节期外,精度都有所提升,而且随着生育期推

进,提升效果越发明显;成熟期提升幅度最大,在RMSE、NRMSE和MAE相对稳定下, $R^2$ 比全特征高出0.026,灌浆期和抽穗期也分别高出0.014和

0.018;拔节期提升效果不明显,可能与拔节期小麦植株较小、光谱反射率不强有关,不能有效反映后期单产形成的变化趋势。

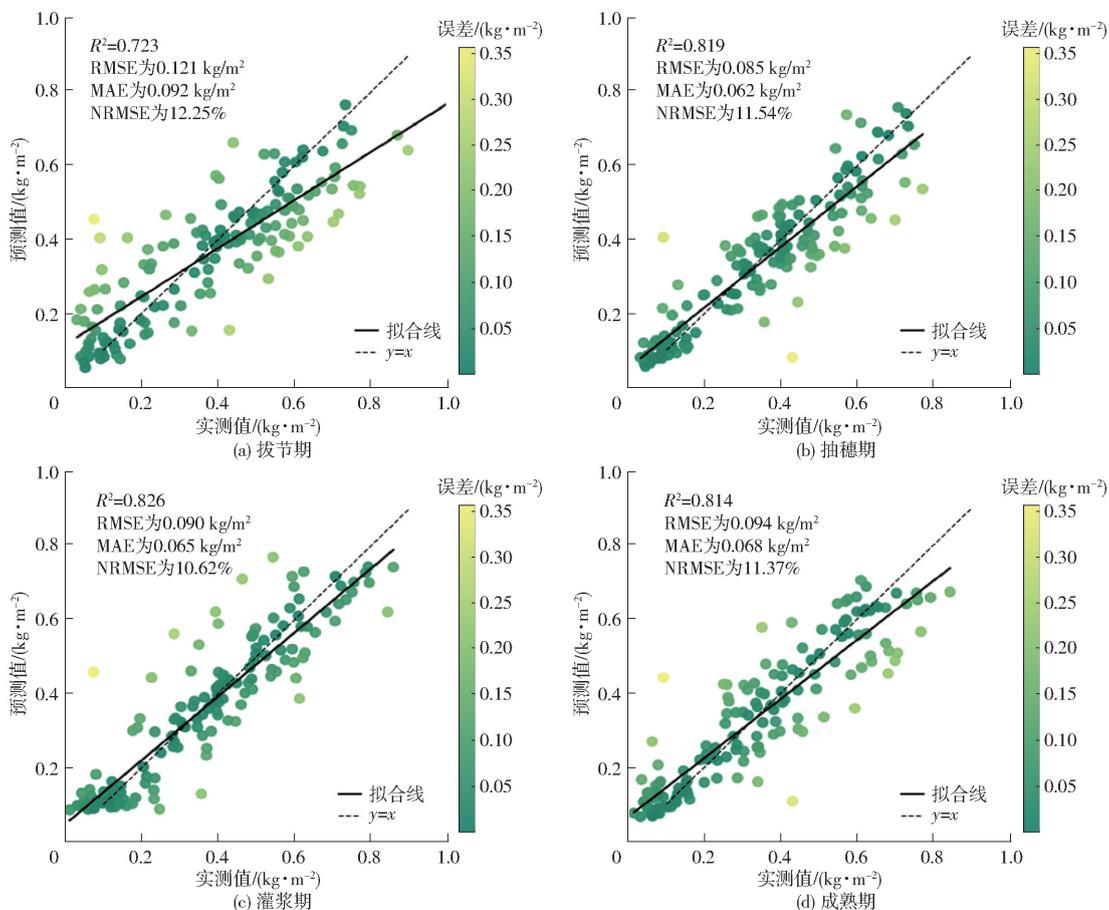


图4 单生育期优势参数模型预测结果

Fig. 4 Prediction performance of dominant parameter model for single growth stage

### 2.3 多时相参数组合模型构建及评价

相对于单生育期单产预测,将不同生育期组合条件下的优势特征参数作为输入变量进行单产估测,效果如图5所示。从双生育期融合来看,拔节期、抽穗期、灌浆期和成熟期的两两组合,大都比单生育期预测精度好;“拔节期+抽穗期”组合弥补了拔节期图像特征提取精度的不足,比拔节期单生育期优势参数模型 $R^2$ 高0.045、RMSE低0.025 kg/m<sup>2</sup>,但比抽穗期 $R^2$ 下降0.051、RMSE高0.011 kg/m<sup>2</sup>,这与拔节期图像容易受到土壤等外界因素干扰有关,随着植株的生长壮大,外在影响越来越小,参数越发稳定,预测精度不断提升;“抽穗期+灌浆期”组合,比抽穗期单生育期优势参数模型 $R^2$ 高0.020、RSME也高0.002 kg/m<sup>2</sup>,比灌浆期 $R^2$ 高出0.013、RSME低0.003 kg/m<sup>2</sup>,既填补了抽穗期排序前10中形态参数的不足,又发挥了灌浆期光谱和形态参数均衡的优势,预测效果均好于2个单生育期;“灌浆期+成熟期”组合, $R^2$ 比灌浆期和成熟期分别高出0.012和0.024, RMSE降低0.010 kg/m<sup>2</sup>和

0.014 kg/m<sup>2</sup>,在成熟期基础上,该组合融合了灌浆期对于植株高度、三维冠层体积等形态参数的预测优势,效果均好于单个生育期。

从三生育期参数融合来看,拔节期、抽穗期、灌浆期和成熟期的三三组合虽然组合间效果差异不大,但均好于两两组合,以“拔节期+抽穗期+灌浆期”为例,比“拔节期+抽穗期”、“抽穗期+灌浆期”的两两组合 $R^2$ 高出0.08和0.009, RMSE降低0.019 kg/m<sup>2</sup>和0.01 kg/m<sup>2</sup>,这与光谱和形态参数的进一步多元化融合有关,BPNN算法可捕获更多的动态输入信息,更好地用于单产评估之中。2个三生育期组合预测效果虽稍逊于“拔节期+抽穗期+灌浆期+成熟期”四生育期组合, $R^2$ 分别低0.002和0.01,但从算力资源高效分配角度来看,四生育期组合预测精度的提升与算力投入不相匹配,适当减少生育期范围或缩小生长阶段并没有显著降低模型精度,反而能更好地分配数据收集和处理的精力与资源。综合来看,以“拔节期+抽穗期+灌浆期”为代表的三生育期组合性价比最高,既比双生育期组合

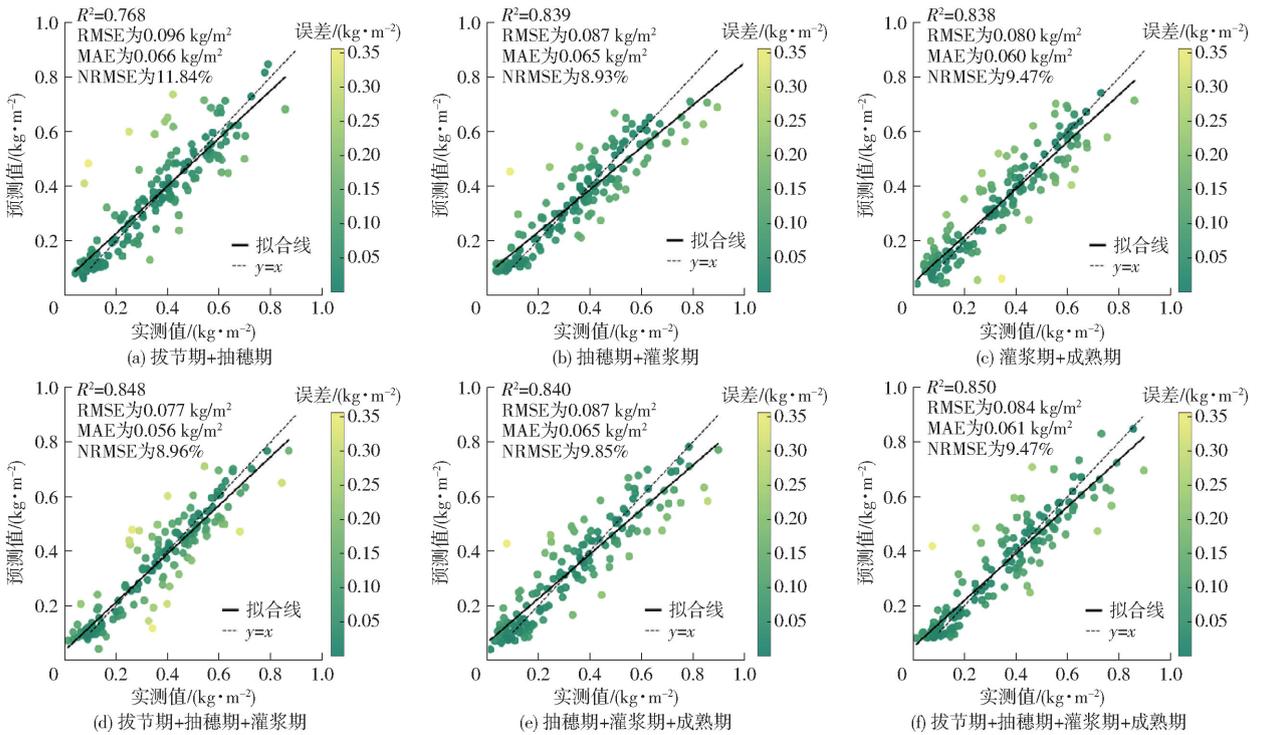


图 5 多时相优势参数模型预测结果

Fig. 5 Prediction performance of multi-temporal dominant parameter model

精度有所提升,又与四生育期组合差异不大,可用于冬小麦多时相参数的单产估测。在“拔节期+抽穗期+灌浆期”三生育期组合下,融合最佳模型、最佳参数的产量空间分布图如图 6 所示。图 6 展示了测试集的预测结果。为验证模型在不同氮肥施用条件

下的性能表现,分别从 N0、N120 和 N240 各随机选取了 50 个小区,共计 150 个组成测试集。考虑到数据划分的随机性,这些小区并非连续小区。在图 6 中,实测值和预测值的小区相对位置一一对应,便于比较实测值与预测值的差异。



图 6 冬小麦产量空间分布图

Fig. 6 Spatial distribution map of winter wheat yield

### 3 讨论

#### 3.1 模型选择对单产预测的影响

不同机器学习模型底层逻辑不同,适用范围和场景也不相同。本文采用逐步多元回归、支持向量机、随机森林、BP 神经网络、XGBoost 构建单产预测模型,随着冬小麦生长表型的差异,各模型预测效果不同,但伴随生长发育进程的推进,总体呈上升趋势。在生长发育早期,受到土壤裸露等因素干扰,不管何种模型,预测精度都相对较低,但随着植株的壮大,影响因素干扰越来越小,各模型估算精度不断提升。同样,冬小麦单产构成因素多样,这其中既有线性也有非线性关系存在。SMR 对于线性问题的解决具有优势,SVM、RF 和 XGBoost 对于非线性问题具有一定的回归和抗噪能力,但当样本数量不断增

加或样本特征参数输入过多时,SVM 和 RF 的预测能力明显下降。XGBoost 虽不易过拟合<sup>[45]</sup>,但其隐藏层连接权重学习不足带来了预测能力的下降。BPNN 因其泛化能力强、鲁棒性高等特点,能够从大量信息中获取更多的数据特征,实现对未知参数的有效预测,在面对复杂的非线性问题时,可以通过调整权重和偏置来优化模型,使其达到最佳状态。

本研究虽考虑到不同机器学习算法特征参数提取、优化和抗干扰能力不同,但忽视了模型在多模态变量中自我适应和自我学习,后续研究中应融合多源传感数据和集成学习算法,以消除外界因素干扰,更好地处理多模态变量之间的冗余和依赖性,提高预测精度。同时,还应对现有模型进一步优化,尝试引入注意力机制等模块,给予影响单产估算关键物

候期更大权重<sup>[46]</sup>,构建精度更高、算法及机理性更强的估产模型。另外,还可以探索更为先进的深度学习架构,以提取维度更加多元的多模态信息以便更好地开展单产预测。

### 3.2 参数确定对单产预测的影响

作物对不同光谱的反射率随着生长发育的不同而变化,通过近红外、红色、红边、绿色和蓝色等不同波段计算出的植被指数能够很好地反映作物长势状况<sup>[47]</sup>,利用植被指数建立模型以估算作物单产,是目前作物估产的有效方法之一<sup>[14]</sup>。但由于作物各生育期生长状态不同,植被指数对各生育期生长特征的敏感程度不同,基于各生育期构建的植被指数预测模型精度也不同,单一的光谱指数有时难以反映作物单产的全部信息,需要与形态参数一起,共同指示作物产量。光谱参数与形态参数的组合,不但丰富了样本数据的属性与维度,提高了数据的准确性、一致性和鲁棒性,而且能够解决由于生长阶段和渐进饱和带来的预测敏感性下降等问题<sup>[48]</sup>,有效提升模型精度,更加精准地分析作物的生长状况和健康情况。ADAMS等<sup>[49]</sup>认为合理的特征参数选择可以消除数据噪声,提高模型性能。为进一步提高预测精度,利用SHAP法对特征参数进行重要性排序,优选排名前10的光谱和形态参数作为输入变量,除拔节期外,单生育期优势参数模型预测精度都比全特征时高。SHAP作为一种博弈论方法,可对大部分机器学习模型预测结果进行解释,通过计算变量对单产预测的贡献程度来赋予SHAP值,并将该值相对公平地分配给输入变量,以此进行排序并针对性地提高预测效果<sup>[12]</sup>。

进一步从SHAP法优选的光谱与形态参数来看,在分蘖期、拔节期等小麦生长发育早期阶段,光谱参数对估产模型的贡献较大,模型精度的提高主要由光谱特征决定,但在灌浆期和成熟期,随着小麦植株和子实体等器官的基本发育成熟,形态参数对估产的重要性逐渐提高,通过与光谱参数的融合,提升模型对空间变化的适应性进而提高预测精度,MAIMAITIJIANG等<sup>[30]</sup>也证实了这一点,其发现在单产预测方面,无论采用何种建模方法,多模态数据融合效果比RGB或多光谱等单一传感器表现更佳。同时,还有研究发现,随着小麦叶面积的增加,光谱特征差异越来越不明显,行间差异完全被覆盖<sup>[50]</sup>,小麦生长中后期植被指数的饱和带来了预测效果的下降<sup>[51]</sup>,更加需要光谱和形态参数的融合以提高估测精度。目前,有学者提出将植被指数和纹理特征等进行融合,结合气象信息、土壤特性和种植密度、施肥量、灌溉策略等农艺信息<sup>[52,14]</sup>,进一步提升单

产预测精准性,这也是本研究接下来的努力方向。另外,考虑到SHAP作为事后可解释性方法,在后续研究中,为保证特征参数筛选的精准性,探索将事前和事后等不同可解释性方法进行比较与融合,以弥补单一方法所带来的解释偏差。

### 3.3 不同生育期对单产预测的影响

产量是作物干物质积累的结果,单个生育期的长势并不能代表最终单产<sup>[14]</sup>。WANG等<sup>[12]</sup>指出,生育期的选择将决定单产预测准确率的高低。小麦不同生育期营养生长和生殖生长需求不同,结合单生育期单产预测分析,本文把生育期组合数据引入到估产模型中,基于多生育期的模型不但提高了预测精度,还提升了模型的可解释性。双生育期组合中,“抽穗期+灌浆期”组合作为输入时,估产精度较高,而“拔节期+抽穗期”组合作为输入时,估产精度相对较低,从两生育期组合重要性排序前10的共同参数中可以看出端倪。拔节期和抽穗期排名前10参数中有5个共同参数,分别是ARI、CVI、PLA、CIgreen、DVI,其中,ARI在拔节期中SHAP值最高(92.58),在抽穗期中排第2(44.61),CIgreen在抽穗期中最高(54.57),但在拔节期排第4(9.66),同一参数在不同生育期SHAP值差异较大;虽然“拔节期+抽穗期”组合比拔节期单个生育期提供了更为丰富的参数输入,但却拉低了抽穗期的有效参数占比,导致组合预测精度没有抽穗期单个生育期高。抽穗期和灌浆期有6个共同参数,分别是CIgreen、ARI、NDVI、Hmean、MSAVI、DVI,两生育期排名前2位的都是CIgreen和ARI,两者在抽穗期和灌浆期的SHAP值分别为54.57和89.97、44.61和27.44,相互间SHAP值差异相对不大,这为该组合成为双生育期组合中预测效果最佳打下了基础。灌浆期和成熟期有ARI、Volume、DVI、3DPI 4个共同参数,CIgreen在灌浆期中重要性排第1(89.97),但在成熟期却未能排进前10(SHAP值只有6.4),ARI在成熟期中排第1(79.5),在灌浆期第2(27.44);虽然排名前2位参数SHAP值差异较大,但由于高度百分位数作用的发挥(灌浆期中H81、H99和成熟期H97、H91分别进入排名前10的优选参数),预测效率并没有降低。

三生育期比双生育期组合预测效果进一步提升,且“拔节期+抽穗期+灌浆期”优于“抽穗期+灌浆期+成熟期”,这一方面与两组合共同参数数量有关,前一组合有ARI、CIgreen、DVI 3个共同参数,后一组合有ARI、DVI 2个共同参数;另一方面,2个三生育期组合本质上为拔节期、成熟期分别与“抽穗期+灌浆期”组合的比较,拔节期单个生育期

预测效果虽低于成熟期,但与“抽穗期+灌浆期”组合融合后,整体预测效果好于后者,这与“拔节期+抽穗期+灌浆期”组合中结构参数变化较大有关,更有利于模型动态捕获输入信息的差异,以更好地开展单产评估。下一步,将在多时相参数融合预测基础上,借助于无人机、无人车和龙门架等表型平台,结合热成像、激光雷达、叶绿素荧光、3D深度相机等多模态信息,探索不同品种、不同播期等对最佳单产预测生育期的影响,并扩大采集植株高度、叶面积指数、生物量、氮素含量等田间实测数据,丰富模型输入信息,以此来促进冬小麦估产的更加精准、有效和便捷。

## 4 结论

(1)在冬小麦7个生育期内,不同建模方法预

测效果不同,BPNN算法表现出对不同生育期的较强适应性和对非线性问题处理的鲁棒性,整体效果优于RF、SVM、XGBoost、SMR算法。

(2)采用SHAP法筛选出的不同生育期重要性排序前10优势参数作为输入的模型,除拔节期外,均比对应全特征输入生育期模型预测效果好,且不同生育期优势光谱和形态参数组合差异较大,这也为下一步多时相参数融合打下了基础。

(3)当生育期输入数量增加时,除“拔节期+抽穗期”组合比抽穗期单生育期优势参数模型预测效果稍差之外,其余不管是双生育期、三生育期还是四生育期组合均好于单生育期,可见多生育期参数融合对模型精度的提升具有一定价值。考虑到数据收集处理与算力资源投入的平衡,采用“拔节期+抽穗期+灌浆期”的三生育期组合性价比最高。

## 参 考 文 献

- [1] SELSAM P, SCHAEFER W, BRINKMANN K, et al. Acquisition and automated rectification of high-resolution RGB and near-IR aerial photographs to estimate plant biomass and surface topography in arid agro-ecosystems[J]. *Experimental Agriculture*, 2017, 53(1): 144–157.
- [2] GUAN S, FUKAMI K, MATSUNAKA H, et al. Assessing correlation of high-resolution NDVI with fertilizer application level and yield of rice and wheat crops using small UAVs[J]. *Remote Sensing*, 2019, 11(2):112.
- [3] BENINCASA P, ANTOGNELLI S, BRUNETTI L, et al. Reliability of NDVI derived by high resolution satellite and UAV compared to in-field methods for the evaluation of early crop n status and grain yield in wheat[J]. *Experimental Agriculture*, 2018, 54(4): 604–622.
- [4] YUE J, YANG G, LI C, et al. Analyzing winter-wheat biochemical traits using hyperspectral remote sensing and deep learning [J]. *Computers and Electronics in Agriculture*, 2024, 222: 109026.
- [5] 申洋洋,陈志超,胡昊,等. 基于无人机多时相遥感影像的冬小麦产量估算[J]. *麦类作物学报*, 2021, 41(10): 1298–1306.  
SHEN Yangyang, CHEN Zhichao, HU Hao, et al. Estimation of winter wheat yield based on UAV multi-temporal remote sensing images[J]. *Journal of Triticeae Crops*, 2021, 41(10): 1298–1306. (in Chinese)
- [6] 甘甜,李雷,李红叶,等. 基于多源遥感数据和机器学习算法的冬小麦产量预测研究[J]. *麦类作物学报*, 2022, 42(11): 1419–1428.  
GAN Tian, LI Lei, LI Hongye, et al. Research on winter wheat yield prediction based on multi-source remote sensing data and machine learning algorithms[J]. *Journal of Triticeae Crops*, 2022, 42(11): 1419–1428. (in Chinese)
- [7] 杨楠,周萌,陈欢,等. 基于无人机RGB影像的小麦叶面积指数与产量估算研究[J]. *麦类作物学报*, 2023, 43(7): 920–932.  
YANG Nan, ZHOU Meng, CHEN Huan, et al. Research on estimation of wheat leaf area index and yield based on UAV RGB imagery[J]. *Journal of Triticeae Crops*, 2023, 43(7): 920–932. (in Chinese)
- [8] 宋成阳,耿洪伟,费帅鹏,等. 基于多源数据的小麦品种产量估测研究[J]. *光谱学与光谱分析*, 2023, 43(7): 2210–2219.  
SONG Chengyang, GENG Hongwei, FEI ShuaiPeng, et al. Research on wheat variety yield estimation based on multi-source data[J]. *Spectroscopy and Spectral Analysis*, 2023, 43(7): 2210–2219. (in Chinese)
- [9] FEI S, HASSAN M A, XIAO Y, et al. UAV-based multi-sensor data fusion and machine learning algorithm for yield prediction in wheat[J]. *Precision Agriculture*, 2023, 24(1): 187–212.
- [10] LI J, VEERANAMPALAYAM-SIVAKUMAR A N, BHATTA M, et al. Principal variable selection to explain grain yield variation in winter wheat from features extracted from UAV imagery[J]. *Plant Methods*, 2019, 15(1): 123.
- [11] 王晶晶,李长硕,卓越,等. 基于多时相无人机遥感生育时期优选的冬小麦估产[J]. *农业机械学报*, 2022, 53(9): 197–206.  
WANG Jingjing, LI Changshuo, ZHUO Yue, et al. Yield estimation of winter wheat based on optimization of growth stages by multi-temporal UAV remote sensing[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(9): 197–206. (in Chinese)
- [12] WANG Z, TAN X, MA Y, et al. Combining canopy spectral reflectance and RGB images to estimate leaf chlorophyll content and grain yield in rice[J]. *Computers and Electronics in Agriculture*, 2024, 221: 108975.

- [13] LI Q, JIN S, ZANG J, et al. Deciphering the contribution of spectral and structural data to wheat yield estimation from proximal sensing[J]. *The Crop Journal*, 2022, 10(5): 1334 – 1345.
- [14] 李阳,苑严伟,赵博,等. 基于多时相多参数融合的麦玉轮作小麦产量估算方法[J]. *农业机械学报*, 2023, 54(12): 186 – 196.  
LI Yang, YUAN Yanwei, ZHAO Bo, et al. Estimation of wheat yield in wheat-maize rotation based on multi-temporal and multi-parameter fusion[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(12): 186 – 196. (in Chinese)
- [15] 臧少龙,刘淋茹,高越之,等. 基于无人机影像多时相的小麦品种氮效率分类识别[J]. *中国农业科学*, 2024, 57(9): 1687 – 1708.  
ZANG Shaolong, LIU Linru, GAO Yuezhi, et al. Classification and identification of wheat variety nitrogen use efficiency based on multi-temporal UAV imagery[J]. *Scientia Agricultura Sinica*, 2024, 57(9): 1687 – 1708. (in Chinese)
- [16] CANICATTI M, VALLONE M. Drones in vegetable crops: a systematic literature review[J]. *Smart Agricultural Technology*, 2024, 7:100396.
- [17] GITELSON A A, MERZLYAK M N, CHIVKUNOVA O B. Optical properties and nondestructive estimation of anthocyanin content in plant leaves[J]. *Photochemistry & Photobiology*, 2001, 74(1): 38 – 45.
- [18] GITELSON A A, VERMA S B, VINA A, et al. Novel technique for remote estimation of CO<sub>2</sub> flux in maize[J]. *Geophysical Research Letters*, 2003, 30(9):1486.
- [19] BLACKMER T M, SCHEPERS J S, VARVEL G E. Light reflectance compared with other nitrogen stress measurements in corn leaves[J]. *Agronomy Journal*, 1994, 86(6): 934 – 938.
- [20] PEUELAS J, GAMON J A, FREDEEN A L, et al. Reflectance indices associated with physiological changes in nitrogen- and water-limited sunflower leaves[J]. *Remote Sensing of Environment*, 1994, 48(2): 135 – 146.
- [21] PENUELAS J, BARET F, FILELLA I. Semiempirical indexes to assess carotenoids chlorophyll-a ratio from leaf spectral reflectance[J]. *Photosynthetica*, 1995, 31(2): 221 – 230.
- [22] QI J G, CHEHBOUNI A R, HUETE A R, et al. A modified soil adjusted vegetation index [J]. *Remote Sensing of Environment*, 1994, 48(2): 119 – 126.
- [23] GITELSON A A, KAUFMAN Y J, MERZLYAK M N. Use of a green channel in remote sensing of global vegetation from EOS – MODIS[J]. *Remote Sensing of Environment*, 1996, 58(3): 289 – 298.
- [24] RICHARDSON A J, WIEGAND C L. Distinguishing vegetation from soil background information [J]. *Photogrammetric Engineering and Remote Sensing*, 1977, 43(12): 1541 – 1552
- [25] TUCKER C J. Red and photographic infrared linear combinations for monitoring vegetation [J]. *Remote Sensing and Environment*, 1979, 8(2): 127 – 150.
- [26] BADGLEY G, FIELD C B, BERRY J A. Canopy near-infrared reflectance and terrestrial photosynthesis [J]. *Science Advances*, 2017, 3(3): e1602244.
- [27] MERZLYAK M N, CHIVKUNOVA O B, GITELSON A A, et al. Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening[J]. *Physiologia Plantarum*, 1999, 106(1): 135 – 141.
- [28] JORDAN C F. Derivation of leaf-area index from quality of light on the forest floor[J]. *Ecology*, 1969, 50(4): 663 – 666.
- [29] HUETE A, DIDAN K, MIURA T, et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices[J]. *Remote Sensing of Environment*, 2002, 83(1 – 2): 195 – 213.
- [30] MAIMAITIJIANG M, SAGAN V, SIDIKE P, et al. Soybean yield prediction from UAV using multimodal data fusion and deep learning[J]. *Remote Sensing of Environment*, 2020, 237: 111599.
- [31] JIN S, SU Y, SONG S, et al. Non-destructive estimation of field maize biomass using terrestrial lidar: an evaluation from plot level to individual leaf level[J]. *Plant Methods*, 2020, 16(1): 69.
- [32] JIN S, SU Y, ZHANG Y, et al. Exploring seasonal and circadian rhythms in structural traits of field maize from LiDAR time series[J]. *Plant Phenomics*, 2021, 2021(4): 9895241 – 9895256.
- [33] JIN S, SU Y, WU F, et al. Stem-leaf segmentation and phenotypic trait extraction of individual maize using terrestrial LiDAR data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(3): 1336 – 1346.
- [34] PUTTONEN E, BRIESE C, MANDLBURGER G, et al. Quantification of overnight movement of birch (*Betula pendula*) branches and foliage with short interval terrestrial laser scanning[J]. *Frontiers in Plant Science*, 2016, 7: 222.
- [35] ZLINSZKY A, MOLNÁR B, BARFOD A S. Not all trees sleep the same-high temporal resolution terrestrial laser scanning shows differences in nocturnal plant movement[J]. *Frontiers in Plant Science*, 2017, 8:1814.
- [36] SU Y, WU F, AO Z, et al. Evaluating maize phenotype dynamics under drought stress using terrestrial LiDAR [J]. *Plant Methods*, 2019, 15: 11.
- [37] DU M, NOGUCHI N. Monitoring of wheat growth status and mapping of wheat yield's within-field spatial variations using color images acquired from UAV-camera system[J]. *Remote Sensing*, 2017, 9(3): 289.
- [38] VAN KLOMPENBURG T, KASSAHUN A, CATAL C. *Computers and electronics in agriculture*[M]. Elsevier B. V., 2020.
- [39] SCORNET E, BIAU G, VERT J P. Consistency of random forests[J]. *Annals of Statistics*, 2015, 43(4): 1716 – 1741.

- [40] LUNDBERG S, LEE S. A unified approach to interpreting model predictions[C]//Proceedings of 31st Annual Conference on Neural Information Processing Systems, 2017.
- [41] CHANDRASHEKAR G, SAHIN F. A survey on feature selection methods[J]. Computers and Electrical Engineering, 2014, 40(1): 16–28.
- [42] FERNANDEZ-GALLEGO J A, KEFAUVER S C, VATTER T, et al. Low-cost assessment of grain yield in durum wheat using RGB images[J]. European Journal of Agronomy, 2019, 105: 146–156.
- [43] LI B, XU X, ZHANG L, et al. Above-ground biomass estimation and yield prediction in potato by using UAV-based RGB and hyperspectral imaging[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2020, 162: 161–172.
- [44] LAW C N, SNAPE J W, WORLAND A J. The genetical relationship between height and yield in wheat[J]. Heredity, 1978, 40(1): 133–151.
- [45] CHENG X, LEI H. Remote sensing scene image classification based on mmsCNN–HMM with stacking ensemble model[J]. Remote Sensing, 2022, 14(17):4423.
- [46] 刘照,李华朋,陈慧,等. 基于时序影像及不同模型的玉米早期估产研究[J]. 光谱学与光谱分析,2023,43(8):2627–2637.  
LIU Zhao, LI Huapeng, CHEN Hui, et al. Research on early yield estimation of maize based on time-series imagery and different models[J]. Spectroscopy and Spectral Analysis, 2023,43(8): 2627–2637. (in Chinese)
- [47] HASSAN M A, YANG M, RASHEED A, et al. Time-series multispectral indices from unmanned aerial vehicle imagery reveal senescence rate in bread wheat[J]. Remote Sensing, 2018, 10(6): 809.
- [48] FU Y, YANG G, LI Z, et al. Winter wheat nitrogen status estimation using UAV-based RGB imagery and Gaussian processes regression[J]. Remote Sensing, 2020, 12(22): 1–27.
- [49] ADAMS S, BELING P A. A survey of feature selection methods for Gaussian mixture models and hidden Markov models[J]. Artificial Intelligence Review, 2019, 52(3): 1739–1779.
- [50] LIU T, YANG T, ZHU S, et al. Estimation of wheat biomass based on phenological identification and spectral response[J]. Computers and Electronics in Agriculture, 2024, 222:198–203.
- [51] YANG K, MO J, LUO S, et al. Estimation of rice aboveground biomass by UAV imagery with photosynthetic accumulation models[J]. Plant Phenomics, 2023, 5:0056.
- [52] LONGFEI Z, RAN M, XING Y, et al. Improved yield prediction of ratoon rice using unmanned aerial vehicle-based multi-temporal feature method[J]. Rice Science, 2023, 30(3): 247–256.

~~~~~  
(上接第 331 页)

- [25] 王晓晖,蒋虎忠,苗森春,等. 基于熵产理论的多级液力透平能量耗散机理分析[J]. 农业机械学报, 2024, 55(3): 162–172.  
WANG Xiaohui, JIANG Huzhong, MIAO Senchun, et al. Analysis of energy dissipation mechanism of multistage hydraulic turbine based on entropy production theory[J]. Transactions of the Chinese Society for Agricultural Machinery,2024,55(3): 162–172. (in Chinese)
- [26] FEI Z, ZHANG R, XU H, et al. Energy performance and flow characteristics of a slanted axial-flow pump under cavitation conditions[J]. Physics of Fluids, 2022, 34(3): 035121.
- [27] KAN K, ZHAO F, XU H, et al. Energy performance evaluation of an axial-flow pump as turbine under conventional and reverse operating modes based on an energy loss intensity model[J]. Physics of Fluids, 2023, 35(1): 015125.