doi:10.6041/j.issn.1000-1298.2026.13.023

# 融合无人机光谱、纹理特征与 LAI 的冬小麦单产估测方法

承达瑜[1,2]　陈帅琴[1]　付春晓[3]　苏　皓[4]　王建东[5]　宋　辞[2]

(1. 河北工程大学矿业与测绘工程学院, 邯郸 056038; 2. 地理信息科学与技术全国重点实验室, 北京 100101;
3. 河北工程大学水利水电学院, 邯郸 056038; 4. 河北工程大学信息与电气工程学院, 邯郸 056038;
5. 中国农业科学院农业环境与可持续发展研究所, 北京 100081)

**摘要**: 田块尺度冬小麦单产精准估测对大田农业生产管理具有重要现实意义。针对单一植被指数难以全面表征作物生长状况,引入多参数、多变量的无人机遥感估产方法已成为发展趋势。为此,本文采用“空-地一体”决策思路,以 2023—2024 年度冬小麦为研究对象,选取抽穗期和灌浆期的无人机多光谱影像,融合地面少量实测叶面积指数(Leaf area index,LAI)作为作物形态参数,构建植被指数单变量、植被指数 + 纹理特征双变量及植被指数 + 纹理特征 + LAI 三变量的单产估测模型,并采用随机森林(Random forest,RF)、极端梯度提升(Extreme gradient boosting,XGBoost)和支持向量机(Support vector machine,SVM)机器学习算法进行建模,对比分析不同模型和特征组合的估测效果。结果表明,基于“植被指数 + 纹理特征 + LAI”三变量组合的 RF 算法在两生育期数据中建模精度最高(抽穗期:$R^2$ = 0.729,RMSE 为 524.475 kg/hm$^2$,NRMSE 为 11.181%,RE 为 3.481%;灌浆期:$R^2$ = 0.779,RMSE 为 479.265 kg/hm$^2$,NRMSE 为 9.736%,RE 为 3.205%),显著优于 XGBoost 和 SVM 算法。基于最优模型最优组合获取 2023—2024 年度与 2024—2025 年度抽穗期和灌浆期单产空间分布图,结果显示,灌浆期估测精度整体高于抽穗期,两年度灌浆期估测单产与实测值的平均差异分别为 334.035、284.235 kg/hm$^2$。SHAP 分析表明,LAI 在不同生育期均对单产估测精度提升具有重要贡献。研究结果表明,本文提出的“空-地一体”多变量逐步融合决策思路可实现田块尺度冬小麦单产的精准估测,为智慧农业管理提供技术支撑。

**关键词**: 冬小麦; 田块尺度; 单产估测; 无人机遥感; 纹理特征; 机器学习

**中图分类号**: S512.1$^+$1; TP79　　**文献标识码**: A　　**文章编号**: 1000-1298(2026)13-0281-13　　**OSID**:

# Winter Wheat Yield Estimation Method Based on Integration of UAV Spectral Features, Texture Features and LAI

Cheng Dayu[1,2]　Chen Shuaiqin[1]　Fu Chunxiao[3]　Su Hao[4]　Wang Jiandong[5]　Song Ci[2]

(1. *School of Mining and Geomatics*, *Hebei University of Engineering*, *Handan* 056038, *China*
2. *State Key Laboratory of Geographic Information Science and Technology*, *Beijing* 100101, *China*
3. *School of Water Conservancy and Hydroelectric*, *Hebei University of Engineering*, *Handan* 056038, *China*
4. *School of Information and Electrical Engineering*, *Hebei University of Engineering*, *Handan* 056038, *China*
5. *Institute of Environment and Sustainable Development in Agriculture*, *Chinese Academy of Agricultural Sciences*, *Beijing* 100081, *China*)

**Abstract**: Precise estimation of winter wheat yield at the field plot scale was considered to be of significant practical importance for agricultural yield management under large-scale farming conditions. Given that single vegetation indices were insufficient to comprehensively characterize crop growth status, the development of multi-parameter and multi-variable UAV-based remote sensing yield estimation methods was regarded as an emerging trend. An air-ground integrated decision-making framework was adopted, and winter wheat from the 2023—2024 growing season was selected as the research object.

收稿日期: 2025-12-04　修回日期: 2026-01-30

**基金项目**: 河北省重大科技成果转化专项(22287401Z)、国家自然科学基金项目(42171212)和地理信息科学与技术全国重点实验室开放基金项目

**作者简介**: 承达瑜(1980—),男,副教授,博士,主要从事地理大数据挖掘、作物长势遥感监测及计算机视觉研究,E-mail: yuyumails@126.com

**通信作者**: 付春晓(1979—),女,讲师,博士,主要从事节水灌溉原理与技术研究,E-mail: chunxiao999999@163.com

UAV multispectral imagery acquired during the heading and grain filling stages was utilized and combined with a limited amount of ground-measured leaf area index (LAI) as a crop morphological parameter to construct yield estimation models, including single-variable models (vegetation index only), dual-variable models (vegetation index + texture features), and triple-variable models (vegetation index + texture features + LAI). Yield estimation modelling was conducted by using random forest (RF), extreme gradient boosting (XGBoost), and support vector machine (SVM) algorithms, and the estimation performance of different models and feature combinations was comparatively analyzed. The results indicated that the RF algorithm based on the three-variable combination of vegetation index, texture features, and LAI achieved the highest modelling accuracy at both growth stages (heading stage: $R^2$ = 0.729, RMSE = 524.475 kg/hm$^2$, NRMSE = 11.181%, RE = 3.481%; grain filling stage: $R^2$ = 0.779, RMSE = 479.265 kg/hm$^2$, NRMSE = 9.736%, RE = 3.205%), and significantly outperformed the XGBoost and SVM algorithms. Based on the optimal model-feature combination, spatial distribution maps of winter wheat yield for the 2023—2024 and 2024—2025 seasons during the heading and grain filling stages were generated. The results revealed that yield estimation accuracy during the grain filling stage was generally higher than that during the heading stage. The average differences between estimated and measured yields during the grain filling stage for the two seasons were 334.035 kg/hm$^2$ and 284.235 kg/hm$^2$, respectively. SHAP analysis further indicated that LAI contributed substantially to the improvement of yield estimation accuracy across all growth stages. Overall, the findings demonstrated that the proposed air-ground integrated multivariate stepwise fusion decision-making approach enabled rapid and accurate estimation of winter wheat yield at the field plot scale, thereby providing effective technical support for smart agricultural management.

**Key words**: winter wheat; field-scale; yield estimation; UAV remote sensing; texture features; machine learning

## 0 引言

小麦是我国三大主粮作物之一,在国民经济中地位重要[1]。实现田块尺度上及时、准确的单产估测,对冬小麦田间精准管理具有重要意义。传统单产估测主要依赖地面调查与统计数据,存在时间滞后、空间覆盖有限及数据获取困难等局限[2]。卫星遥感技术具有多时相、广覆盖的优势,已成为大范围农作物监测的重要手段,可用于作物单产估测[3]。但因卫星遥感数据获取周期长、空间分辨低,且易受气象条件限制,难以满足田块级农情管理的精准需求。相比之下,无人机遥感具备数据采集灵活、空间分辨率高等优势,可快速获取厘米级影像,有效揭示农田空间异质性,获取更精细的作物生长参数,为精准农业的实施提供有力支撑。因此,基于无人机遥感开展田块尺度小麦单产估测研究,具有重要的理论与实践价值[4]。

目前,无人机遥感估测小麦单产主要有 4 类方法:基于机器学习估测模型[1,5];采用遥感数据同化的作物模型[6];结合遥感数据、作物模型与机器学习的方法[7];多模态数据融合[8]。其中,基于数据同化作物模型是将遥感观测变量融入作物生长模型,实现遥感信息与过程模型的优势互补[6];遥感数据、作物模型与机器学习则是利用遥感获取得到的关键变量驱动作物模型输出,再将这些输出与遥感特征输入机器学习模型进行单产估测[9];近年来,融合多源异质遥感数据并进行多模态融合,再结合机器学习算法进行单产估测,也逐渐成为研究热点[8]。上述 3 种方法均能够取得较好的估产效果,但其对监测数据与地面样本质量要求较高,在实际的田块尺度农业生产中仍较难实现。基于机器学习的无人机遥感单产估测方法以多光谱影像为驱动[1],继承并拓展了传统植被指数经验模型,通过融合作物氮含量、水分含量、辐射利用效率及株高等多类辅助信息。从作物生育期数据利用视角,该类方法主要分为单生育期估测与多生育期联合估测 2 种策略。单生育期估产仅基于某一关键生育期影像为主进行估测,已有研究表明,抽穗期和灌浆期是冬小麦单产估测的关键遥感窗口期[10-11]。

基于这 2 个生育期构建的 RF、XGBoost 等模型在田块尺度表现出较高的估测精度[12-14]。多生育期估产通过整合多个生育阶段的遥感信息,在一定程度上优于单生育期方法,但其对数据时相和样本数量要求较高,应用成本相对较大[15-16]。相比之下,单生育期估产在观测成本和田间管理协同性方面更具实际优势。鉴于单一植被指数难以全面刻画作物生长状况,引入多变量特征,尤其是与作物形态结构和生理状态密切相关的参数,已成为估产方法的发展趋势[16-17]。前人研究表明,将 LAI 与光谱或热红外指标相结合,可显著提高冬小麦单

产估测精度[18-19]。

为此，本文采用“空-地一体化”实现高效决策的思路，选取冬小麦抽穗期和灌浆期无人机多光谱数据，优选植被指数并融合纹理特征克服多光谱“同谱异物”干扰[20]，同时引入地面实测 LAI 作为作物形态参数，构建可解释的单生育期多变量田块尺度冬小麦单产估测模型。首先，根据研究区的实测冬小麦单产数据，融合植被指数、纹理特征和叶面积指数等数据构建单产估测模型，通过设置植被指数单变量、植被指数 + 纹理特征双变量、植被指数 + 纹理特征 + LAI 三变量 3 种组合方式，进一步通过机器学习算法进行建模并对比分析，采用消融实验与 SHAP 方法揭示不同特征对单产估测的贡献。最后，将筛选出的最优模型结果应用到整个研究区并推广至不同年份冬小麦影像，以期为冬小麦单产估测提供较精确的方法依据。

## 1　材料与方法

### 1.1　研究区概况

研究区为河北省邱县古城营镇（36°53′N，115°07′E）某农场，占地 51.85 $hm^2$，区域内地势平坦，并按照均匀布点原则共布置 41 个采样点，如图 1 所示。该区域属于温带大陆性季风气候，四季分明，夏季炎热多雨，冬季寒冷干燥，降雨集中在 7—9 月。研究区农作物以夏玉米与冬小麦轮作为主，前茬农作物为玉米，耕种方式使用旋耕机，耕地深度小于 20 cm，作物供水方式为机井灌溉与雨养混合。

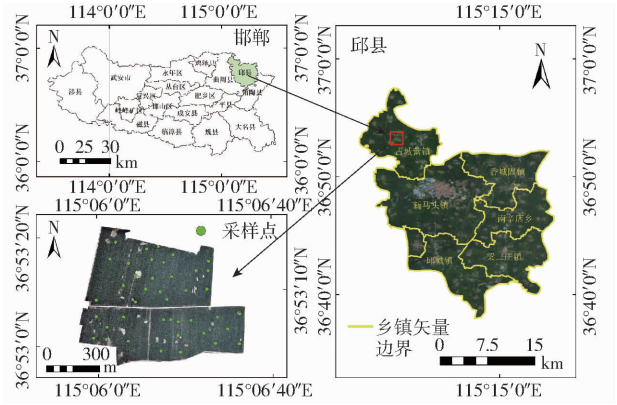


图 1　研究区概况

Fig. 1　Overview of research area

本研究的小麦品种为龙堂一号和马兰一号，播种时间分别为 2023 年 10 月 27 日和 2024 年 10 月 10 日，收获时间分别为 2024 年 6 月 10 日和 2025 年 6 月 7 日，关键物候期见表 1。

### 1.2　数据获取与预处理

#### 1.2.1　无人机数据获取预处理

采用大疆经纬 Matrice300RTK 型四旋翼无人机，搭载 MS600PRO 型多光谱相机。大疆 Matrice300RTK 型无人机最大飞行承载质量为 2.7 kg，可在 -20 ~ 50℃ 环境下工作，可承受最大风速为 15 m/s，每架次工作时间为 45 ~ 55 min。多光谱相机可同时获取 6 个光谱通道的波段遥感影像（表 2），配有下行光传感器和白板，光谱采集范围为 400 ~ 900 nm。遥感影像的获取时间为 2024 年 4 月 24 日（抽穗期）和 2024 年 5 月 17 日（灌浆期），2025 年 4 月 26 日（抽穗期）和 2025 年 5 月 14 日（灌浆期）。飞行作业时间为 10:00—14:00，此时天气晴朗、无风无云。根据研究区的范围规划飞行航线，进行白板矫正，飞行速度设置为 5.6 m/s，飞行高度设置为 100 m，选用自动捕获模式，地面空间分辨率为 7.21 cm，航向和旁向的重叠率分别为 80%、70%。获取影像的范围包含整个研究区，略大于 51.85 $hm^2$。

表 1　冬小麦关键物候期时间

Tab. 1　Key phenological periods for winter wheat

| 物候期 | 2023—2024 年度 | | 2024—2025 年度 | |
|---|---|---|---|---|
| | 开始日期 | 结束日期 | 开始日期 | 结束日期 |
| 苗期 | 2023-11-07 | 2023-11-30 | 2024-10-24 | 2024-11-16 |
| 分蘖 | 2023-12-01 | 2023-12-15 | 2024-11-17 | 2024-12-01 |
| 越冬 | 2023-12-16 | 2024-02-25 | 2024-12-02 | 2025-02-19 |
| 返青 | 2024-02-26 | 2024-04-07 | 2025-02-20 | 2025-03-31 |
| 拔节 | 2024-04-08 | 2024-04-19 | 2025-04-01 | 2025-04-25 |
| 抽穗 | 2024-04-20 | 2024-04-27 | 2025-04-26 | 2025-05-07 |
| 开花 | 2024-04-28 | 2024-05-03 | 2025-05-08 | 2025-05-13 |
| 灌浆 | 2024-05-04 | 2024-05-20 | 2025-05-14 | 2025-05-30 |
| 成熟 | 2024-05-21 | 2024-06-01 | 2025-05-31 | 2025-06-06 |

表 2　MS600PRO 型多光谱相机波段信息

Tab. 2　MS600PRO multispectral camera band information

| 波段号 | 波段名称 | 带宽/nm | 中心波长/nm | 白板反射率 |
|---|---|---|---|---|
| B1 | Blue | 35 | 450 | 0.64 |
| B2 | Green | 25 | 555 | 0.62 |
| B3 | Red | 20 | 660 | 0.61 |
| B4 | Red edge | 10 | 720 | 0.61 |
| B5 | Red edge750 | 15 | 750 | 0.61 |
| B6 | Near IR | 35 | 840 | 0.57 |

将获取的无人机多光谱影像，运用 YusenseRef 软件完成图像的辐射定标，采用 Pix4D 软件对定标好的图像进行拼接，得到 6 个单波段影像，后文红边 1、红边 2、近红外分别用 Red-1、Red-2、Nir 表示。使用 ENVI 软件对这 6 个单波段影像分别进行波段运算实现图像增强，改善图像质量和可视化效果，以便更好地观察和分析。根据地面采样点在图像上的位置，构建感兴趣区域（Region of interest，ROI），将各波

段下感兴趣区域内平均光谱反射率作为该采样点的冬小麦光谱反射率,从而得到各采样点的光谱数据。

### 1.2.2 田间数据获取

#### 1.2.2.1 冬小麦叶面积指数测量

叶面积指数表征了作物冠层结构特征,是反映作物长势与预报作物单产的重要农学参数。LAI 虽并不直接描述作物冠层几何形状,但是量化其结构的一个重要组成部分,不仅反映作物生长发育的动态特征和健康状况,而且与作物冠层光量截取、蒸腾作用、光合作用和呼吸作用等许多生态过程直接相关[21]。为此,本文采用 LAI 作为表征冬小麦形态参数的指标。根据划分的 41 个采样点,每个点覆盖范围为 1 m×1 m,该范围内随机选取 5 株长势均匀且具有代表性的冬小麦植株,在不损坏植株情况下根据长宽系数法逐片测量各叶片的叶长和最大叶宽[22],单片叶面积初步估测为叶长与最大叶宽的乘积,再累加计算得出单株冬小麦的总叶面积。结合系数 0.83 进行经验校正,最终通过 1 $m^2$ 的株数折算出采样点群体叶面积指数[23]。计算式为

$$LAI = 0.83\rho \frac{\sum_{i=1}^{m}\sum_{j=1}^{n} L_{ij}B_{ij}}{am} \tag{1}$$

式中 $LAI$——叶片的叶面积指数

$L_{ij}$——观测叶长,cm

$B_{ij}$——叶子最大宽度,cm

$m$——观测株数

$n$——每株总叶片数

$\rho$——植株种植密度

$a$——单位换算系数,取 10 000

#### 1.2.2.2 冬小麦单产测量

冬小麦单产数据来源于实地采样,根据划分的 41 个采样点,每点面积 1 $m^2$,将样点内的植株全部采集,2023—2024 年度由于部分地块在采样期前受到倒伏、管理干扰等因素影响,无法获得完整数据,最终有效样本数为 35 个点。将采集的小麦经过脱粒、晾晒、测干质量等一系列处理,最后计算出采样点处冬小麦的单产值,单位为 kg/$hm^2$。

### 1.3 研究方法

田块尺度的冬小麦估产基本思路是在确保一定估测精度的基础上,尽可能少采样,达到精度与实测样本的最优情况,便于在实际的农业生产环境下实现。为此,本文基于单生育期多变量理念开展研究。首先选取冬小麦估测的重要生育期,通过分析现有的研究[10-11],发现最佳遥感窗口期为抽穗期、灌浆期,因此,选取 2023—2024 年度冬小麦的无人机多光谱影像计算并提取出冬小麦在抽穗期和灌浆期的植被指数和纹理特征。同时,引入同期地面实测 LAI。在此基础上,采用 RF、SVM 和 XGBoost 3 种机器学习算法构建基于植被指数、植被指数 + 纹理特征和植被指数 + 纹理特征 + LAI 融合参数作为估测小麦单产的特征输入变量,通过计算、结果对比选出最佳的估测模型,并应用到整个研究区域,获取冬小麦单产空间分布图,并以 SHAP 方法解释其估测结果。同时,基于最佳估测模型绘制出 2024—2025 年度冬小麦单产空间分布图,以此验证模型的有效性。具体研究方法如图 2 所示。

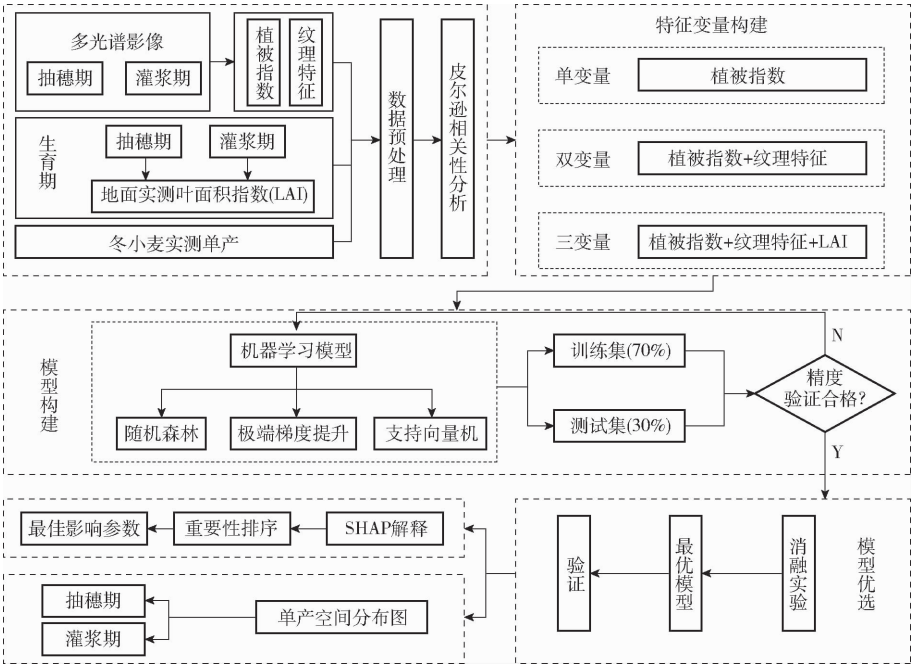


图 2 技术路线图

Fig. 2 Technical roadmap

**1.3.1** 植被指数选取

植被指数是通过遥感影像中不同波段的反射率组合计算得出的数值，可以简单有效地估测农作物单产等特征。本文基于已有的研究成果，筛选 15 种在估产方面较好的植被指数[24]，分别为归一化差异植被指数（NDVI）[23]、蓝色归一化植被指数（BNDVI）[23]、绿色归一化植被指数（GNDVI）[10]、标准化蓝指数（NormB）[25]、绿叶植被指数（GLI）[26]、绿红比值指数（GR）[27]、改进简单比值植被指数（MSR）[14]、三角植被指数（TVI）[14]、比值植被指数（RVI）[4]、重归一化植被指数（RDVI）[23]、叶绿素指数（LCI）[16]、宽动态范围植被指数（WDRVI）[28]、转换叶绿素吸收反射率指数（TCARI）[14]、归一化叶绿素色素植被指数（NCPI）[15]、结构不敏感色素指数（SIPI）[15]。

**1.3.2** 纹理特征提取

基于灰度共生矩阵（Gray-level cooccurrence matrix，GLCM）提取纹理特征探究其与冬小麦单产之间的关联[29]，GLCM 通过统计像素对在特定方向和距离上的灰度级联合分布，能够充分挖掘图像灰度变化规律反映纹理的不同特性。分别提取每个生育期的红、绿、蓝、红边 1、红边 2、近红外 6 个单波段的纹理特征：均值（Mean）、方差（Var）、协同性（Hom）、对比度（Con）、相异性（Dis）、信息熵（Ent）、二阶矩（Se－mo）、相关性（Cor），提取窗口大小设置为 7×7 进行分析，分析方向选择 90°，空间相关矩阵偏移 $X$ 与 $Y$ 都默认为 1。

**1.3.3** 基于多特征的单产估测模型构建

本文研究的特征变量与目标变量存在非线性关系，对于非线性问题，RF、SVM、XGBoost 算法具有较好的解释性，因此模型构建选用了这 3 种机器学习算法。结合 LAI 和单产实测采样数据，最终确定 35 个样点进行实验。为确保模型稳定性和可靠性，模型执行轮次设置为 1 000 次，模型执行稳定区间的最优模型作为该模型性能判断依据。每次执行时样本训练集和测试集按照比例 7∶3进行随机划分，即 24 个样本用作训练集构建模型，11 个样本用作测试集评估模型性能。

分别采用随机森林 $g_1(V, T, LAI, b)$、支持向量机 $g_2(V, T, LAI, b)$、梯度提升决策树 $g_3(V, T, LAI, b)$ 3 种回归算法计算估测后的单产，再进行模型的选择，计算式为

$$\begin{aligned} Y_{\text{day}} &= \min\{C(g(V,T,LAI,b))\} \\ &\text{and } \max\{R^2(g(V,T,LAI,b))\} \end{aligned} \tag{2}$$

其中 $g(V, T, LAI, b) = \{g_1(V, T, LAI, b), g_2(V, T, LAI, b), g_3(V, T, LAI, b)\}$

式中 $Y_{\text{day}}$——生育期小麦估测单产

$V$——植被指数　　$T$——纹理特征

$b$——调节系数

$C(g(V,T,LAI,b))$——计算 $g(V,T,LAI,b)$ 的 RMSE、NRMSE、RE 函数

$R^2(g(V,T,LAI,b))$——计算 $g(V,T,LAI,b)$ 的 $R^2$ 函数

and——与运算符号

**1.3.4** SHAP 方法理论

SHAP 方法的核心思想是将模型估测视为一个合作博弈[30]，计算每个特征的参与度，量化各个特征的重要性，并提供一致且公平的解释。对于每个估测，SHAP 考虑所有可能的特征子集，计算有无某个特征时的估测差异，将这些差异加权平均，得到该特征的特定估测重要性值，即 SHAP 值，计算式为

$$y_i = y_b + f(x_i,1) + f(x_i,2) + \cdots + f(x_i,M) \tag{3}$$

式中 $y_i$——SHAP 值

$y_b$——目标变量在所有样本中的均值

$f(x_i,1)$——第 $i$ 个样本中第 1 个特征变量的重要值

$M$——特征变量的数量

**1.3.5** 模型精度评价

模型精度检验选用决定系数（Coefficient of determination，$R^2$）、均方根误差（Root mean square error，RMSE）、归一化均方根误差（Normalized root mean square error，NRMSE）和平均相对误差（Relative error，RE）作为评价指标。$R^2$ 越接近于 1，该模型拟合精度越高；RMSE 越小，该模型估测能力越高；NRMSE 和 RE 越接近 0，表明模型估测值越接近实测值。

## 2 结果与分析

### 2.1 相关性分析

**2.1.1** 植被指数、叶面积指数与单产的相关性

抽穗期和灌浆期的植被指数与冬小麦单产的相关性有一定差异，相关系数在 0.023 ~ 0.721 区间（图 3，图中相关系数值取绝对值，* 表示在 0.05 水平上显著，** 表示在 0.01 水平上显著）。在抽穗期，植被指数与单产相关系数在 0.023 ~ 0.460 之间。其中植被指数 NormB 与单产的相关性最高（$|r|=0.46$），其次为：TCARI、RDVI、TVI，相关系数分别为 0.411、0.409、0.407，LAI 与单产呈现显著的相关性，相关系数为 0.721（图 3a）；在灌浆期，总体相关性偏显著，相关系数在 0.384 ~ 0.653 之间。其中 GR 与单产的相关性最高（$|r|=0.653$），其次为：

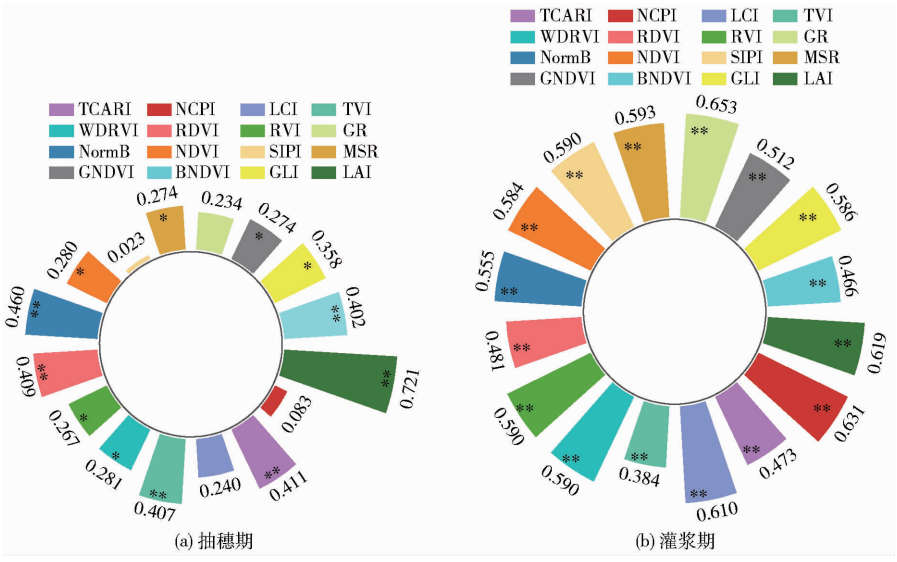


图 3 各生育期植被指数、LAI 与单产相关性分析结果($n$ = 35)

Fig. 3 Correlation analysis results between vegetation indices, LAI and yield atvarious growth stages ($n$ = 35)

NCPI、LCI、MSR,相关系数分别为 0.631、0.610、0.593。叶面积指数与单产的相关系数为 0.619(图 3b)。

### 2.1.2 纹理特征与单产的相关性

采用"_"来连接波段和纹理特征,抽穗期和灌浆期各波段的纹理特征与单产数据的相关性如图 4 所示,从图 4 可以看出,单一纹理特征与单产的直接相关性较弱,抽穗期 Red-1_Mean、Red-2_Mean 以及灌浆期 Red_Mean、Blue_Mean、Red-1_Mean 与冬小麦单产相关系数大于 0.5,灌浆期纹理特征与冬小麦单产的相关系数普遍高于抽穗期。

抽穗期大部分相关系数呈现正相关,Green_Mean、Nir_Mean、Red-1_Mean、Red-2_Mean 与单产的相关系数分别为 0.472、0.484、0.571、0.535,均通过了 0.01 显著性水平检验(图 4a)。灌浆期纹理特征从相关系数的绝对值 $|r|$ 来看,Red_Mean、Blue_Mean、Red-1_Mean、Green_Mean 与单产的相关系数分别为 0.543、0.537、0.549、0.438,均通过了 0.01 显著性水平检验(图 4b)。

## 2.2 模型构建

### 2.2.1 基于植被指数的单产估测模型

从上述分析中,分别从两生育期中选取与单产相关性最高的植被指数(抽穗期:NormB、TCARI、RDVI、TVI、BNDVI、GLI;灌浆期:GR、NCPI、LCI、MSR、WDRVI、RVI)作为自变量,其单产作为因变量,采用 RF、SVM、XGBoost 分别构建两期数据的估产模型。结果表明,灌浆期整体建模效果优于抽穗期,3 种建模方法中 RF 和 SVM 建模效果相差不大(图 5)。在抽穗期,建模效果最好的是 SVM,训练集 $R^2$ = 0.598,RMSE 为 633.765 kg/hm$^2$,NRMSE 为 12.571%,RE 为 5.443%;测试集 $R^2$ = 0.521,RMSE 为 625.32 kg/hm$^2$,NRMSE 为 20.451%,RE 为 6.975%。在灌浆期,RF 建模效果表现最优,训练集 $R^2$ = 0.654,RMSE 为 585.315 kg/hm$^2$,NRMSE 为 12.432%,RE 为 5.086%;测试集 $R^2$ = 0.614,RMSE

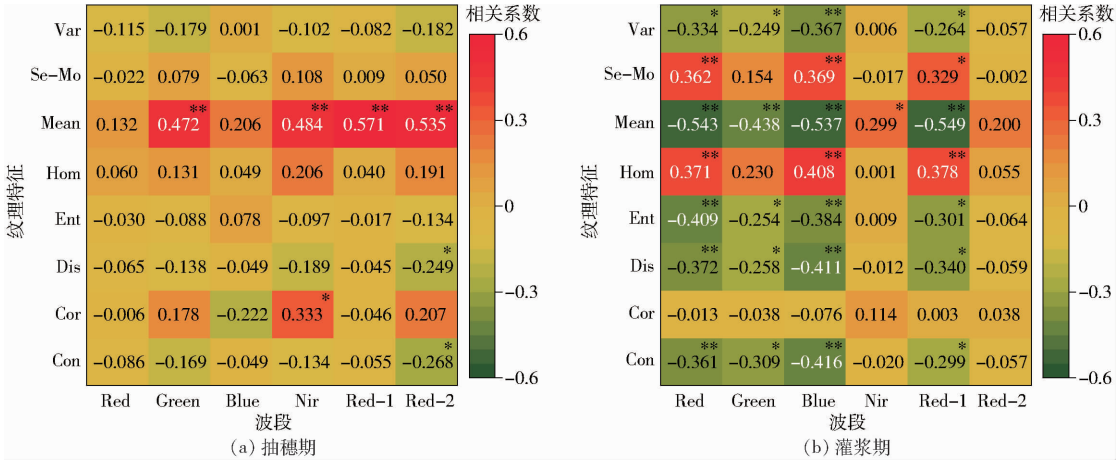


图 4 各生育期纹理特征与单产相关性分析结果($n$ = 35)

Fig. 4 Correlation analysis results between texture characteristics at different growth stages and yield ($n$ = 35)

为 495.465 kg/hm$^2$，NRMSE 为 16.665%，RE 为 4.813%。

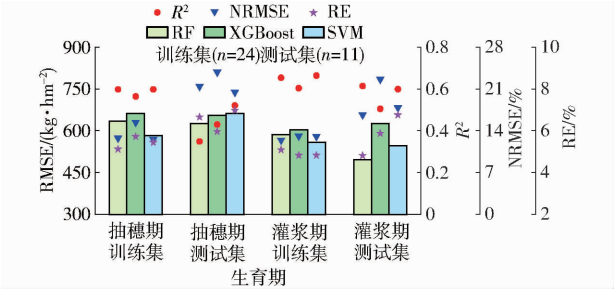


图 5　单变量单产估测结果分析

Fig. 5　Analysis of single-variable yield estimation results

### 2.2.2　基于植被指数和纹理特征的单产估测模型

在两期数据中（抽穗期：Red－1_Mean 和 Red－2_Mean；灌浆期：Red_Mean 和 Red－1_Mean）纹理特征均与单产在 0.01 水平上显著相关，因此采用植被指数与纹理特征组合数据进行建模，组合方式为各个生育期相关性最高的 4 个植被指数（抽穗期：NormB、TCARI、RDVI、TVI；灌浆期：GR、NCPI、LCI、MSR）、2 个纹理特征。

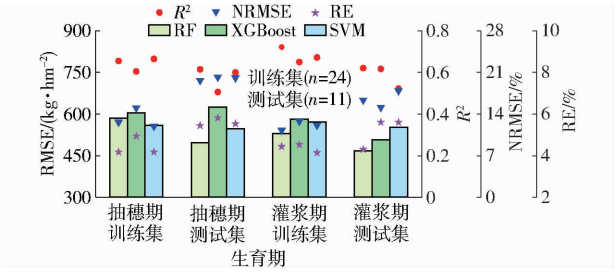


图 6　双变量单产估测结果分析

Fig. 6　Analysis of dual-variable yield estimation results

如图 6 所示，融合纹理特征后，在抽穗期，RF 和 SVM 建模效果相差不大，总体上 RF 精度更高，训练集 $R^2$ = 0.654，RMSE 为 585.315 kg/hm$^2$，NRMSE 为 12.622%，RE 为 4.172%；测试集 $R^2$ = 0.614，RMSE 为 495.465 kg/hm$^2$，NRMSE 为 19.636%，RE 为 5.442%。在灌浆期，RF 建模效果最好，训练集 $R^2$ = 0.721，RMSE 为 529.56 kg/hm$^2$，NRMSE 为 11.251%，RE 为 4.432%；测试集 $R^2$ = 0.620，RMSE 为 466.11 kg/hm$^2$，NRMSE 为 16.323%，RE 为 4.293%。

### 2.2.3　基于植被指数、纹理特征和 LAI 的单产估测模型

基于上述组合，加入 LAI，组合方式为各个生育期相关性最高的 3 个植被指数（抽穗期：NormB、TCARI、RDVI；灌浆期：GR、NCPI、LCI）、2 个纹理特征（抽穗期：Red－1_Mean 和 Red－2_Mean；灌浆期：Red_Mean 和 Red－1_Mean）、1 个 LAI。如图 7～9 所示，融合纹理特征后，建模效果表现最突出的是 RF 方法，明显优于 XGBoost 和 SVM。在抽穗期，训练集 $R^2$ = 0.729，RMSE 为 524.475 kg/hm$^2$，NRMSE 为 11.181%，RE 为 3.481%；测试集 $R^2$ = 0.696，RMSE 为 439.245 kg/hm$^2$，NRMSE 为 10.123%，RE 为 4.085%。在灌浆期，训练集 $R^2$ = 0.779，RMSE 为 479.265 kg/hm$^2$，NRMSE 为 9.736%，RE 为 3.205%；测试集 $R^2$ = 0.715，RMSE 为 389.49 kg/hm$^2$，NRMSE 为 9.254%，RE 为 3.465%。

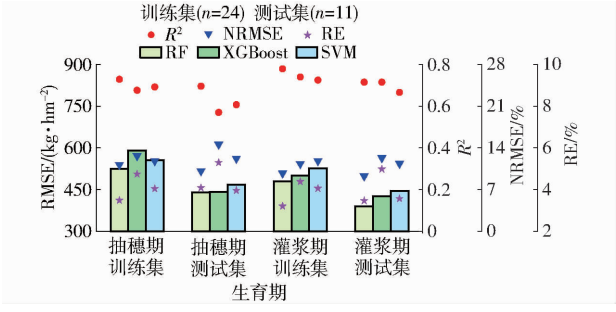


图 7　三变量单产估测结果分析

Fig. 7　Analysis of yield prediction results for three variables

## 2.3　结果对比分析及消融实验

### 2.3.1　模型实验结果对比分析

通过对比 2.2 节中 3 种不同模型组合的结果发现，在不同组合下，RF 方法训练模型精度呈现最优，除了抽穗期，RF 方法建模效果低于 SVM，其余时期均为 RF 效果最好。总体上在不同生育期模型精度最高和最低的是 RF 和 XGBoost。为了直观显示 3 种组合的精度对比，将抽穗期和灌浆期随机森林的模型结果进行对比分析，如表 3 所示，表中①、②、③分别表示植被指数、融合植被指数＋纹理特征、融合植被指数＋纹理特征＋叶面积指数 3 种组合。

由表 3 可知，融合植被指数、纹理特征和叶面积指数模型相较于植被指数与植被指数和纹理特征，$R^2$ 大幅度提升。在抽穗期，训练集的 $R^2$ 相较于单一植被指数与融合纹理特征分别提高 17.970% 和 10.288%，RMSE 降低了 20.838% 和 11.600%，NRMSE 降低了 14.229% 和 12.888%，RE 降低了 47.113% 和 19.822%；在灌浆期，训练集的 $R^2$ 相较于前 2 种组合分别提高 16.046% 和 7.445%，RMSE 降低了 22.128% 和 10.494%，NRMSE 降低了 27.691% 和 15.561%，RE 降低了 58.690% 和 38.284%。显然，融合 3 种特征变量模型比前 2 种模型在冬小麦估产方面具有更好的优势。

### 2.3.2　消融实验

进一步体现各特征变量融合建模对提升模型精度的必要性，分别在模型训练过程中逐一剔除特征变量。由于植被指数、纹理特征和叶面积指数融合建模，分别剔除 1 个特征变量，其余 2 个特征变量作

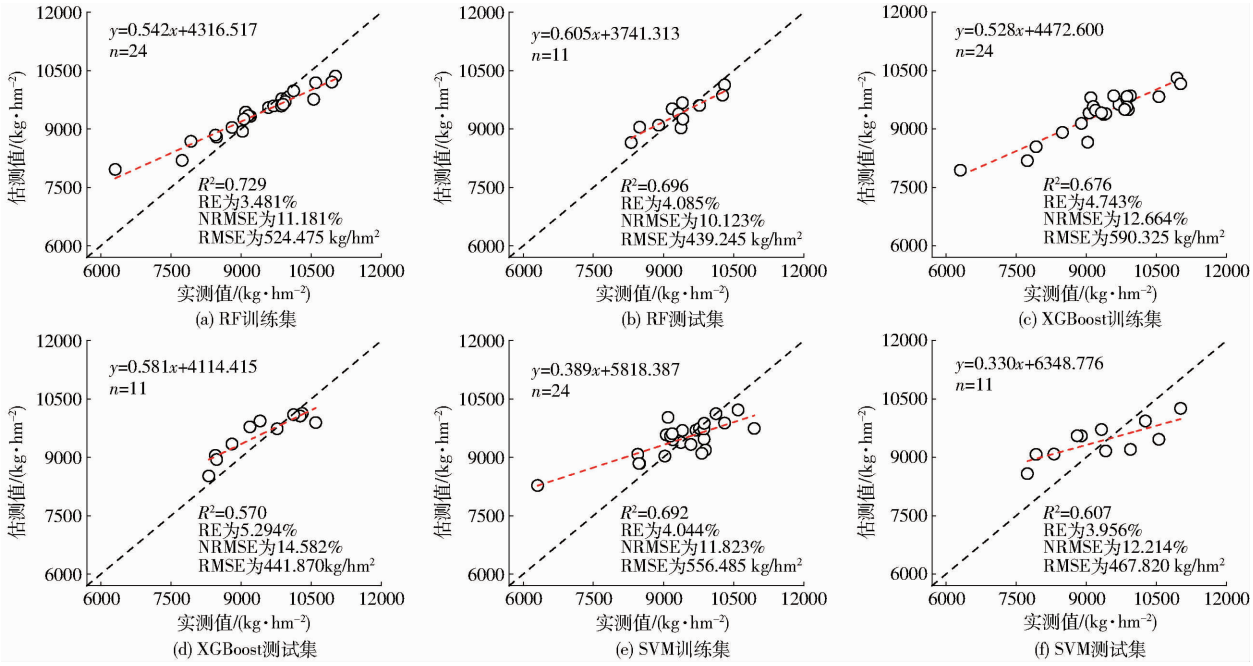


图 8 抽穗期基于植被指数、纹理特征和叶面积指数的单产实测值与估测值

Fig. 8 Actual and estimated yields based on vegetation indices, texture features and leaf area index during heading stage

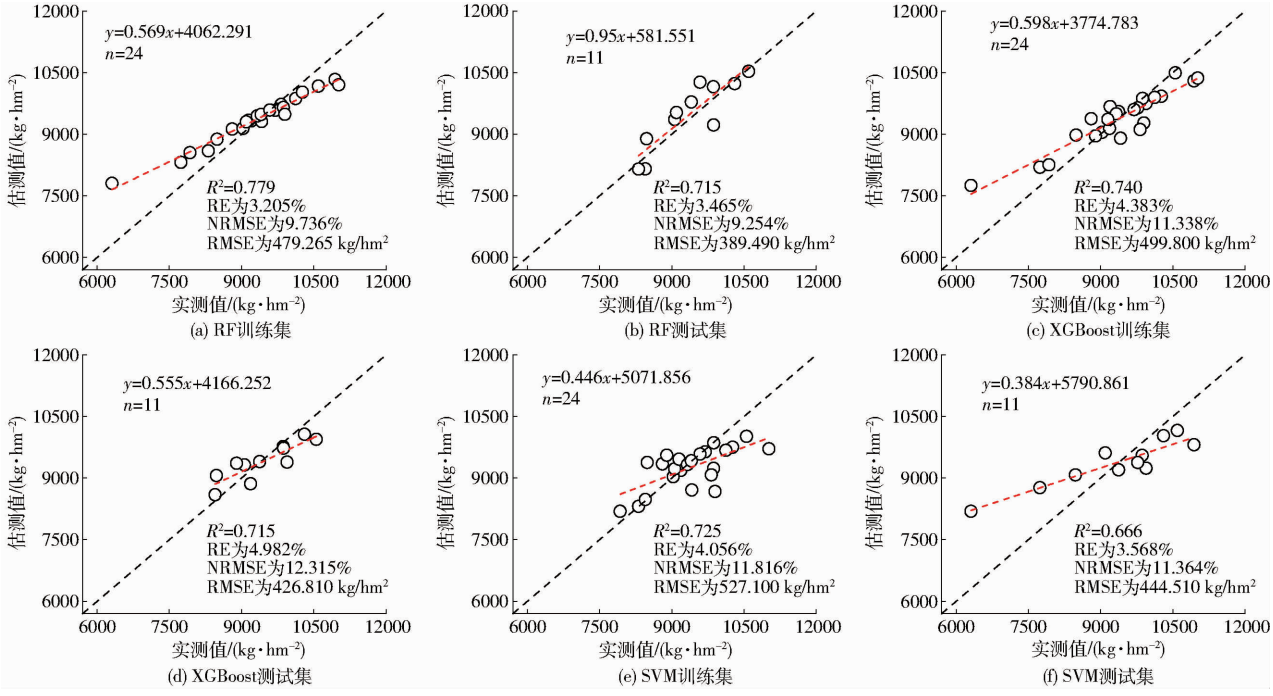


图 9 灌浆期基于植被指数、纹理特征和叶面积指数的单产实测值与估测值

Fig. 9 Actual and estimated yields based onvegetation indices, texture characteristics and leaf area index during filling period

**表 3 训练集($n=24$)各生育期模型对比结果分析**

**Tab. 3 Analysis of comparison results of models at different growth stages in training set ($n=24$)**

| 生育期 | 组合 | $R^2$ | RMSE/(kg·hm$^{-2}$) | NRMSE/% | RE/% |
|---|---|---|---|---|---|
| 抽穗期 | ① | 0.598 | 633.765 | 12.772 | 5.121 |
| | ② | 0.654 | 585.315 | 12.622 | 4.171 |
| | ③ | 0.729 | 524.475 | 11.181 | 3.481 |
| 灌浆期 | ① | 0.654 | 585.315 | 12.432 | 5.086 |
| | ② | 0.721 | 529.560 | 11.251 | 4.432 |
| | ③ | 0.779 | 479.265 | 9.736 | 3.205 |

为数据输入,因此本文设置 3 个消融实验来验证其余特征对模型的影响。

如表 4、5 所示,剔除植被指数后,抽穗期在训练集上 $R^2$ 下降 2.244%,RMSE 上升了 1.848%,NRMSE 和 RE 分别上升 4.640% 和 30.878%;灌浆期 $R^2$ 下降了 7.448%,RMSE 上升了 2.234%,NRMSE 和 RE 分别上升 7.768% 和 12.805%。主要是因为植被指数能反映植物生长状况,蕴含了丰富的光谱信息,因此剔除植被指数,能一定程度上降低

模型精度。剔除纹理特征后，抽穗期在训练集上 $R^2$ 下降 2.676%，RMSE 上升了 0.974%，NRMSE 和 RE 分别上升 0.640% 和 22.867%；灌浆期 $R^2$ 下降了 6.712%，RMSE 上升了 5.902%，NRMSE 和 RE 分别上升 10.043% 和 17.046%。这是因为纹理特征能够有效补充光谱信息的不足，通过量化作物冠层结构和生长状态的空间异质性，显著提升单产估测精度。剔除 LAI 后，抽穗期在训练集上 $R^2$ 下降 12.346%，RMSE 上升了 10.376%，NRMSE 和 RE 分别上升 10.092% 和 38.779%；灌浆期 $R^2$ 下降了 17.496%，RMSE 上升了 15.162%，NRMSE 和 RE 分别上升 14.031% 和 18.980%。因 LAI 为单位地面面积上作物叶片的总面积，是衡量作物冠层结构、生长状况和光合作用潜力的重要指标，间接对单产造成影响，因此，剔除 LAI 很大程度上降低了模型精度。

综合以上分析，融合植被指数、叶面积指数和 LAI 3 种特征变量的模型，与前两种模型相比，具有较高的准确性和平稳性，更能适应各种不确定性环境。

**表 4　抽穗期消融实验结果**

**Tab. 4　Results of melting experiment during heading stage**

| 模块 | | | $R^2$ | RMSE/(kg·hm$^{-2}$) | NRMSE/% | RE/% |
|---|---|---|---|---|---|---|
| *V* | *T* | *LAI* | | | | |
| × | √ | √ | 0.713 | 534.165 | 11.725 | 5.036 |
| √ | × | √ | 0.710 | 529.635 | 11.253 | 4.513 |
| √ | √ | × | 0.639 | 585.195 | 12.436 | 5.686 |

注：√表示融合，×表示剔除。下同。

### 2.3.3　基于 SHAP 的可解释性分析

为了进一步挖掘植被指数、纹理特征和 LAI 对冬小麦单产估测的贡献度，使用 SHAP 方法对输入 RF 模型的特征变量进行可解释性分析。

**表 5　灌浆期消融实验结果**

**Tab. 5　Experimental results of melting during filling period**

| 模块 | | | $R^2$ | RMSE/(kg·hm$^{-2}$) | NRMSE/% | RE/% |
|---|---|---|---|---|---|---|
| *V* | *T* | *LAI* | | | | |
| × | √ | √ | 0.725 | 490.215 | 10.556 | 4.225 |
| √ | × | √ | 0.730 | 509.325 | 10.823 | 4.441 |
| √ | √ | × | 0.663 | 564.915 | 11.325 | 4.547 |

SHAP 值有正负之分，每个点对应一个特征变量和一个 SHAP 值。处于左侧的样本对估测值表现负影响，处于右侧的样本对估测值表现正影响，如图 10a 所示，在抽穗期，LAI 和 Red－2_Mean 高值对模型正影响越大，低值对模型负影响越大。NormB 和 Red－1_Mean 取值高低对模型输出正负影响相差不大。如图 10b 所示，在灌浆期，NCPI 其值较低时仅呈正影响，较高时正负影响并存。Red－1_Mean 取值越大，对模型只有负影响，取值越小，对模型既有正影响又有负影响。Red_Mean 取值越低，对模型的正影响越大，取值越高对模型相对集中于负影响。LAI 取值越高对模型正影响越大，负影响相对集中于低值。

特征重要性图中每个特征变量在总样本中的平均绝对值被当作该全局重要性。由图 10c、10d 可知，在抽穗期，LAI、Red－2_Mean、NormB 和 Red－1_Mean 对冬小麦单产估测模型的重要性排前 4 位。特别是 LAI，其 SHAP 绝对平均值达到 21；在灌浆期，NCPI、Red－1_Mean、Red_Mean 和 LAI 对冬小麦单产估测模型的重要性排前 4 位，其 SHAP 绝对平均值大于 8。

## 2.4　冬小麦单产空间分布图获取

根据 2.2 节得出在 2 个时期，基于组合③的随

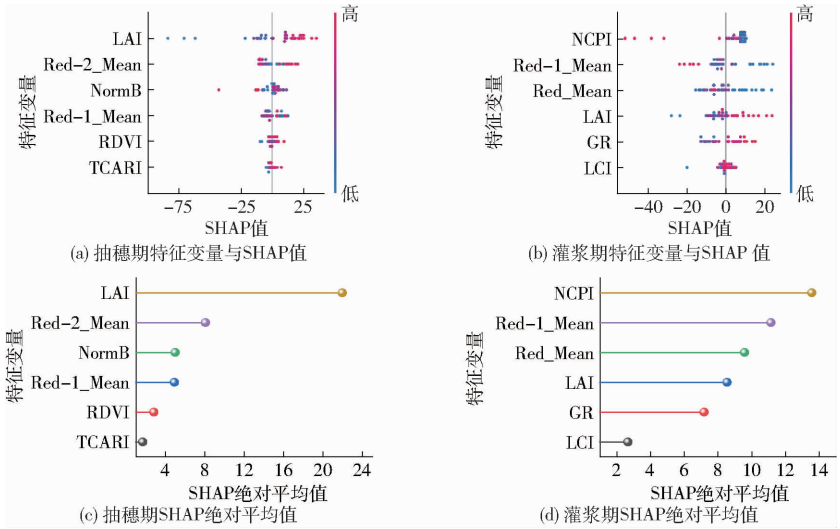


图 10　各生育期特征变量 SHAP 分析（$n$ = 35）

Fig. 10　SHAP analysis of characteristic variables at each growthstage（$n$ = 35）

机森林算法估测模型效果最优。因此,根据最优模型结合实验区域绘制冬小麦单产变化空间分布图,去除道路影响,最终得到 2 个生育期单产空间分布图(图 11),图例中的颜色梯度反映了冬小麦单产从低到高的变化趋势,红色代表单产较低,绿色代表单产较高。

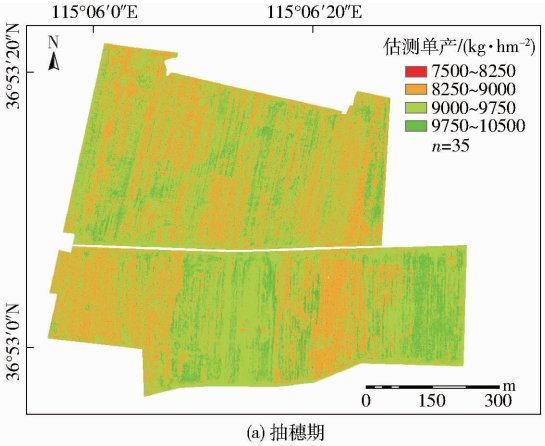


(a) 抽穗期

(b) 灌浆期

图 11 2023—2024 年单产空间分布图

Fig. 11 Spatial distribution map of yields for 2023—2024

在抽穗期(图 11a),冬小麦的单产范围为 8 086.500 ~ 10 251.735 kg/hm$^2$,平均单产为 9 321.9 kg/hm$^2$,大体呈现橘黄色;在灌浆期(图 11b),冬小麦的单产范围为 7 542.825 ~ 10 388.445 kg/hm$^2$,平均单产为 9 229.035 kg/hm$^2$,灌浆期估测的单产与实际平均单产 8 895 kg/hm$^2$更加接近,因此灌浆期单产估测更加准确。

将最优模型和最优特征变量组合运用到 2025 年冬小麦抽穗期和灌浆期进行单产估测,如图 12 所示。在 2024 年得出结论基础上,道路以南、西部区域因地势问题,单产偏低,因此,2025 年对此区域进行精准施策,得到了明显提升。在抽穗期(图 12a),冬小麦单产范围为 8 625.090 ~ 10 257.075 kg/hm$^2$,平均单产为 9 287.655 kg/hm$^2$;在灌浆期(图 12b),冬小麦单产范围为 8 692.545 ~ 10 394.235 kg/hm$^2$,平均单产为 9 224.235 kg/hm$^2$,与真实平均单产 8 940 kg/hm$^2$相比,灌浆期比抽穗期估测更加准确。

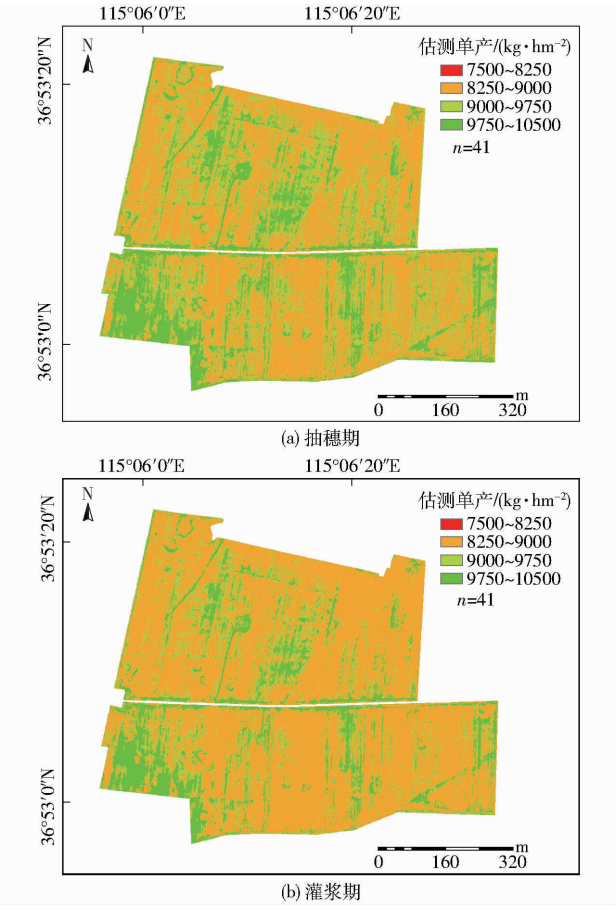


(a) 抽穗期

(b) 灌浆期

图 12 2024—2025 年单产空间分布图

Fig. 12 Spatial distribution map of yields for 2024—2025

## 3 讨论

本文基于冬小麦不同生育期遥感特征差异,从 15 种植被指数中筛选与单产相关性较高的变量,并结合纹理特征,引入 LAI 构建逐步特征融合的单产估测模型。相较于单一特征或双特征融合模型,该方法在建模精度上表现出显著优势。已有研究多侧重于植被指数或纹理特征构建单产估测模型[10],并未充分考虑将相应时期的 LAI 融入估测过程。作为表征作物生长状况和生理状态的重要参数[21,31],LAI 在单产估测中具有关键作用,SHAP 解释结果表明其在抽穗期和灌浆期均具有稳定的重要性。消融实验进一步验证了逐步融合特征对模型精度的显著提升,表明引入 LAI 能够有效弥补单一光谱信息的不足。

在冬小麦抽穗期和灌浆期单产估测中,RF 模型整体精度显著优于 SVM 和 XGBoost,与杨楠等[18]关于 RF 在作物单产估测中比 SVM、BP 神经网络和偏最小二乘算法具有更强非线性建模能力的研究结论一致,表明 RF 更有利于刻画冬小麦单产与遥感特征之间复杂的非线性关系。同时,不同生育期的估

测精度存在明显差异，本文灌浆期的单产估测精度均高于抽穗期，这一结果与已有研究认为灌浆期是冬小麦最终单产形成关键阶段、遥感特征响应关系更为直接的结论相符合，如 Liu 等[32]实验结果表明灌浆期指标与单产相关性高且灌浆后期是估测籽粒单产的最佳单生育期，明显高于抽穗期；王晶晶等[33]在基于单生育期估产模型中，得出灌浆期单产估测模型优于抽穗期。这是由于抽穗期虽穗部已形成，但籽粒尚未灌浆，最终单产受后期环境影响较大；而灌浆期光合作用增强、干物质快速积累，遥感信息与实际单产的相关性更强，从而提升了估测精度。

基于最优模型最优组合下，2023—2024 年度冬小麦抽穗期与灌浆期单产估测精度分别达到：$R^2$ 为 0.729 和 0.779，RMSE 为 524.475 kg/hm$^2$ 和 479.265 kg/hm$^2$，NRMSE 为 11.181% 和 9.736%，RE 为 3.481% 和 3.205%，与已有研究中基于植被指数或传统建模方法获得的单产估测结果相比[10,14,19]，本文模型在不同生育期均综合性表现出较高稳定性和综合估测优势。单产空间分布结果显示，2023—2024 年度冬小麦抽穗期估测单产与实际单产相差 426.9 kg/hm$^2$，灌浆期相差 334.035 kg/hm$^2$；2024 年实验区南部及西部低洼区域单产偏低，主要受积水、根系缺氧及病害影响，2025 年精准管理后，该区域单产显著提升，2024—2025 年度抽穗期和灌浆期估测平均单产与实测值的差异进一步缩小，分别为 347.655 kg/hm$^2$ 和 284.235 kg/hm$^2$。跨年度、不同品种的应用验证结果表明，本文提出的“空-地一体”决策思路在田块尺度冬小麦单产估测中具有较好的现实应用潜力。

实验表明本文所采取的特征变量组合在田块尺度冬小麦单产估测中具有一定适用性，但仍存在一些不足：在现有 3 类特征变量基础上可以考虑增添其他影响因子（降水量、施肥量和气温变化等）；空间异质性导致单产也存在一定的差异，其形成机制涉及地形、气候、土壤和管理措施等多重因素的交互作用。因此需要因地制宜，在地势低洼的区域加强排水与合理施肥，并围绕单产估测关键生育期开展精准监测，以进一步提升模型估测精度与应用效果。

## 4　结论

（1）采用 3 种机器学习方法分别对 3 种组合方式进行建模分析对比，其中基于植被指数 + 纹理特征 + LAI 组合方式的随机森林方法在两生育期建模效果最好。基于最优组合最优模型下，抽穗期 $R^2$ = 0.729，RMSE 为 524.475 kg/hm$^2$，NRMSE 为 11.181%，RE 为 3.481%；灌浆期 $R^2$ = 0.779，RMSE 为 479.265 kg/hm$^2$，NRMSE 为 9.736%，RE 为 3.205%，即在生育期方面，灌浆期冬小麦单产估测效果明显高于抽穗期。

（2）通过消融实验验证了植被指数、纹理特征和 LAI 在冬小麦单产估测中的必要性与贡献度，并进一步引入 SHAP 方法对最优模型进行解释分析发现：在抽穗期，估测重要性前 4 位的特征为 LAI、Red - 2_Mean、NormB 和 Red - 1_Mean；在灌浆期，估测重要性前 4 位的特征为 NCPI、Red - 1_Mean、Red_Mean 和 LAI。从两生育期可以看出，不同特征对单产估测的贡献存在差异，其中 LAI 在 2 个生育期均表现出较为稳定的重要性，表明多特征之间的协同融合能够有效提升冬小麦单产估测效果。

（3）基于最优特征组合方式和最优模型绘制 2023—2024 年度冬小麦单产空间分布图，抽穗期和灌浆期估测平均单产与实际值差异分别为 426.9、334.035 kg/hm$^2$。进一步将该模型应用于 2024—2025 年度不同品种冬小麦影像数据，抽穗期和灌浆期估测平均单产与实际值差异分别为 347.655、284.235 kg/hm$^2$，能够准确估测冬小麦单产，验证了模型良好的泛化能力和估测精度，可为冬小麦精准估产与农业管理提供可靠参考。

## 参　考　文　献


[1] 杨俊，丁峰，陈晨，等. 小麦生物量及产量与无人机图像特征参数的相关性[J]. 农业工程学报，2019，35(23)：104 - 110.
Yang Jun, Ding Feng, Chen Chen, et al. Correlation between wheat biomass and yield and drone image feature parameters[J]. Transactions of the CSAE, 2019, 35(23): 104 - 110. (in Chinese)

[2] Manafifard M, Huang J. A comprehensive review on wheat yield prediction based on remote sensing[J]. Multimedia Tools and Applications, 2025, 84(19): 20843 - 20916.

[3] Maimaitijiang M, Sagan V, Sidike P, et al. Crop monitoring using satellite/UAV data fusion and machine learning[J]. Remote Sensing, 2020, 12(9): 1357.

[4] 王鹏新，田惠仁，张悦，等. 基于深度学习的作物长势监测和产量估测研究进展[J]. 农业机械学报，2022，53(2)：1 - 14.
Wang Pengxin, Tian Huiren, Zhang Yue, et al. Research progress on crop growth monitoring and yield estimation based on deep learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(2): 1 - 14. (in Chinese)

[5] Bharadiya J P, Tzenios N T, Reddy M. Forecasting of crop yield using remote sensing data, agrarian factors and machine

learning approaches[J]. Journal of Engineering Research and Reports, 2023, 24(12): 29 – 44.
[6] Jin X, Kumar L, Li Z, et al. A review of data assimilation of remote sensing and crop models[J]. European Journal of Agronomy, 2018, 92: 141 – 152.
[7] 马战林, 文枫, 周颖杰, 等. 基于作物生长模型与机器学习算法的区域冬小麦估产[J]. 农业机械学报, 2023, 54(6): 136 – 147.
Ma Zhanlin, Wen Feng, Zhou Yingjie, et al. Regional winter wheat yield estimation based on crop growth models and machine learning algorithms[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(6): 136 – 147. (in Chinese)
[8] 李道亮, 赵晔, 杜壮壮. 农业领域多模态融合技术方法与应用研究进展[J]. 农业机械学报, 2025, 56(1): 1 – 15.
Li Daoliang, Zhao Ye, Du Zhuangzhuang. Research progress on multimodal fusion technology methods and applications in the agricultural field[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(1): 1 – 15. (in Chinese)
[9] 解毅, 王鹏新, 王蕾, 等. 基于作物及遥感同化模型的小麦产量估测[J]. 农业工程学报, 2016, 32(20): 179 – 186.
Xie Yi, Wang Pengxin, Wang Lei, et al. Estimation of wheat yield based on crop and remote sensing assimilation models[J]. Transactions of the CSAE, 2016, 32(20): 179 – 186. (in Chinese)
[10] 韦春宇, 杜娅丹, 程智楷, 等. 基于无人机遥感植被指数优选的覆膜冬小麦估产研究[J]. 农业机械学报, 2024, 55(4): 146 – 154, 175.
Wei Chunyu, Du Yadan, Cheng Zhikai, et al. Research on yield estimation of mulched winter wheat based on optimized vegetation indices from UAV remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(4): 146 – 154, 175. (in Chinese)
[11] Raza A, Shahid M A, Zaman M, et al. Improving wheat yield prediction with multi-source remote sensing data and machine learning in arid regions[J]. Remote Sensing, 2025, 17(5): 774.
[12] Cao J, Zhang Z, Luo Y, et al. Wheat yield predictions at a county and field scale with deep learning, machine learning, and google earth engine[J]. European Journal of Agronomy, 2021, 123: 126204.
[13] Khodjaev S, Bobojonov I, Kuhn L, et al. Optimizing machine learning models for wheat yield estimation using a comprehensive UAV dataset[J]. Modeling Earth Systems and Environment, 2025, 11(1): 15.
[14] 樊杰杰, 邱春霞, 樊意广, 等. 基于连续小波变换和机器学习的小麦产量预测[J]. 光谱学与光谱分析, 2024, 44(10): 2890 – 2899.
Fan Jiejie, Qiu Chunxia, Fan Yiguang, et al. Wheat yield prediction based on continuous wavelet transform and machine learning[J]. Spectroscopy and Spectral Analysis, 2024, 44(10): 2890 – 2899. (in Chinese)
[15] 葛焱, 朱志畅, 臧晶荣, 等. 融合无人机多时相参数的冬小麦单产估测方法[J]. 农业机械学报, 2025, 56(1): 344 – 355.
Ge Yan, Zhu Zhichang, Zang Jingrong, et al. Method for estimating winter wheat yield using multi-temporal parameters from unmanned aerial vehicles[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(1): 344 – 355. (in Chinese)
[16] 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. A method for estimating wheat yield based on multi-phase multi-parameter fusion in wheat-corn rotation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(12): 186 – 196. (in Chinese)
[17] 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.
[18] 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. Estimation of wheat leaf area index and yield based on UAV RGB images[J]. Journal of Triticeae Crops, 2023, 43(7): 920 – 932. (in Chinese)
[19] 张悦, 王鹏新, 陈弛, 等. 基于双变量同化和交叉小波变换的冬小麦单产估测[J]. 农业机械学报, 2023, 54(4): 170 – 179.
Zhang Yue, Wang Pengxin, Chen Chi, et al. Estimation of winter wheat yield based on bivariate assimilation and cross-wavelet transform[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(4): 170 – 179. (in Chinese)
[20] Li Q, Jin S, Zang J, et al. Deciphering the contributions of spectral and structural data to wheat yield estimation from proximal sensing[J]. The Crop Journal, 2022, 10(5): 1334 – 1345.
[21] 任建强, 陈仲新, 周清波, 等. 基于叶面积指数反演的区域冬小麦单产遥感估测[J]. 应用生态学报, 2010, 21(11): 2883 – 2888.
Ren Jianqiang, Chen Zhongxin, Zhou Qingbo, et al. Regional yield estimation of winter wheat based on leaf area index derived from remote sensing data[J]. Chinese Journal of Applied Ecology, 2010, 21(11): 2883 – 2888. (in Chinese)
[22] 程智楷, 周智辉, 谷晓博, 等. 基于多模态深度特征模型的冬小麦冠层等效水厚度反演方法[J]. 农业工程学报, 2025, 41(10): 119 – 128.
Cheng Zhikai, Zhou Zhihui, Gu Xiaobo, et al. Inversion of winter wheat canopy equivalent water thickness based on multi-modal depth feature model[J]. Transactions of the CSAE, 2025, 41(10): 119 – 128. (in Chinese)

[23] 承达瑜，何伟德，付春晓，等. 融合无人机光谱信息与纹理特征的冬小麦综合长势监测[J]. 农业机械学报，2024，55(9)：249－261.
Cheng Dayu，He Weide，Fu Chunxiao，et al. Integrated monitoring of winter wheat growth using drone spectral information and texture features[J]. Transactions of the Chinese Society for Agricultural Machinery，2024，55(9)：249－261.（in Chinese）

[24] Xue J，Su B. Significant remote sensing vegetation indices：a review of developments and applications[J]. Journal of Sensors，2017，2017(1)：1353691.

[25] Zhang J Y，Qiu X L，Wu Y T，et al. Combining texture，color，and vegetation indices from fixed-wing UAS imagery to estimate wheat growth parameters using multivariate regression methods[J]. Computers and Electronics in Agriculture，2021，185：106138.

[26] 解毅，王佳楠，刘钰. 基于 Sentinel－1/2 数据特征优选的冬小麦种植区识别方法研究[J]. 农业机械学报，2024，55(2)：231－241.
Xie Yi，Wang Jianan，Liu Yu. Research on the identification method of winter wheat planting areas based on the optimal selection of Sentinel－1/2 data characteristics[J]. Transactions of the Chinese Society for Agricultural Machinery，2024，55(2)：231－241.（in Chinese）

[27] Montanaro G，Petrozza A，Rustioni L，et al. Phenotyping key fruit quality traits in olive using RGB images and back propagation neural networks[J]. Plant Phenomics，2023，5：0061.

[28] 邓江，谷海斌，王泽，等. 基于无人机遥感的棉花主要生育时期地上生物量估算及验证[J]. 干旱地区农业研究，2019，37(5)：55－61，69.
Deng Jiang，Gu Haibin，Wang Ze，et al. Estimation and verification of above-ground biomass during the main growth period of cotton based on unmanned aerial vehicle remote sensing[J]. Agricultural Research in the Arid Areas，2019，37(5)：55－61，69.（in Chinese）

[29] 刘丽，匡纲要. 图像纹理特征提取方法综述[J]. 中国图象图形学报，2009，14(4)：622－635.
Liu Li，Kuang Gangyao. Review of image texture feature extraction methods[J]. Journal of Image and Graphics，2009，14(4)：622－635.（in Chinese）

[30] Lundberg S M，Lee S I. A unified approach to interpreting model predictions[C]// Proceedings of the 31st International Conference on Neural Information Processing Systems，2017：4768－4777.

[31] 齐浩，孙海芳，吕亮杰，等. 基于无人机多光谱信息与纹理特征融合的小麦叶面积指数估测[J]. 农业机械学报，2025，56(3)：334－344.
Qi Hao，Sun Haifang，Lü Liangjie，et al. Estimation of wheat leaf area index based on fusion of multispectral information and texture features from unmanned aerial vehicles[J]. Transactions of the Chinese Society for Agricultural Machinery，2025，56(3)：334－344.（in Chinese）

[32] Liu J，Zhu Y，Tao X，et al. Rapid prediction of winter wheat yield and nitrogen use efficiency using consumer-grade unmanned aerial vehicles multispectral imagery[J]. Frontiers in Plant Science，2022，13：1032170.

[33] 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）