

基于稻穗检测与机器学习的水稻始穗期预测

刘庆^{1,2} 顾清² 朱怡航² 娄卫东² 黄福灯³ 朱英⁴ 张小斌^{2,*}

(¹浙江农林大学 数学与计算机科学学院, 杭州 311300; ²浙江省农业科学院 数字农业研究所, 杭州 310021; ³浙江省农业科学院 作物与核利用研究所, 杭州 310021; ⁴浙江省农业科学院 病毒学与生物技术研究所, 杭州 310021; *通信作者, email: zhangxb@zaas.ac.cn)

Prediction of Rice Heading Date Based on Panicle Detection and Machine Learning

LIU Qing^{1,2}, GU Qing², ZHU Yihang², LOU Weidong², HUANG Fudeng³, ZHU Ying⁴, ZHANG Xiaobin^{2,*}

(¹School of Mathematics and Computer Science, Zhejiang A&F University, Hangzhou 311300, China; ²Institute of Digital Agriculture, Zhejiang Academy of Agricultural Sciences, Hangzhou 310021, China; ³Institute of Crop and Nuclear Utilization, Zhejiang Academy of Agricultural Sciences, Hangzhou 310021, China; ⁴Institute of Virology and Biotechnology, Zhejiang Academy of Agricultural Sciences, Hangzhou 310021, China; *Corresponding author, email: zhangxb@zaas.ac.cn)

Abstract: 【Objective】 To address the problems of high labor intensity and low efficiency in manual measurements of heading date in rice breeding, this study proposes an intelligent prediction method that integrates UAV imagery, the YOLOv10b object detection algorithm, and a random forest regression model to achieve automated and efficient prediction of heading date in rice breeding plots. 【Methods】 Using rice breeding plots as the research subject, UAV imagery was acquired at 15 observation time points from booting to maturity. Based on the YOLOv10b algorithm, a rice panicle detection model was trained to recognize and count panicles in plot images. Subsequently, the numbers of panicles at each observation time point were used as input variables, and the number of days from transplanting to heading was used as the prediction variable to construct and compare multiple heading date prediction models. Based on this, feature importance analysis and dimensionality reduction were performed to develop a simplified model. 【Results】 Experimental results showed that the YOLOv10b model achieved a precision of 91.7%, a recall of 92.1%, and an F_1 score of 0.919 in the panicle detection task. In the heading date prediction task, the random forest model constructed using the sequential features of panicle counts from all 15 observation time points achieved an R^2 of 0.84, an RMSE of 1.57 days, and an MAE of 1.12 days. Furthermore, after feature dimensionality reduction based on feature importance analysis, a simplified model constructed using 9 observation time points achieved an R^2 of 0.83, an RMSE of 1.65 days, and an MAE of 1.16 days. This approach effectively reduced feature dimensionality while maintaining prediction accuracy, thereby improving the model's efficiency and practicality. 【Conclusion】 The proposed method can effectively reduce the workload of manual measurements, improve the efficiency of heading date monitoring, and realize automated prediction of heading date in breeding plots. It provides a feasible data foundation and technical pathway for intelligent breeding and precision agricultural management.

Key words: random forest; rice heading date; intelligent breeding; object detection

摘 要: 【目的】针对当前水稻育种过程中人工测量始穗期存在劳动强度大、效率低等问题,本研究提出一种融合无人机图像、YOLOv10b 目标检测算法与随机森林回归模型的智能预测方法,实现水稻育种小区始穗期的自动化高效预测。【方法】以水稻育种小区为研究对象,利用无人机在水稻孕穗至成熟阶段获取 15 个观测期的小区图像,基于 YOLOv10b 算法训练稻穗检测模型,实现小区图像中稻穗的识别与计数。随后以小区各观测期的稻穗数量为输入变量,始穗期距移栽天数为预测变量,构建多种始穗期预测模型并进行对比分析。在此基础上开展特征重要性分析,进行特征降维,构建精简模型。【结果】YOLOv10b 模型在稻穗检测任务中精确率为 91.7%,召回率为 92.1%, F_1 值为 0.919。在始穗期预测任务中,基于全部 15 个观测期穗数时序特征所构建的随机森林模型取得了 R^2 为 0.84, RMSE 为 1.57 d, MAE 为 1.12 d 的预测表现;进一步通过特征重要性降维至 9 个观测期所构建的精简模型,取得了 R^2 为 0.83, RMSE 为 1.65 d, MAE 为 1.16 d 的预测表现,在保证预测精度的同时,显著降低了特

收稿日期: 2025-11-06; 修改稿收到日期: 2026-01-08。

基金项目: 浙江省“三农九方”科技协作计划项目(2025SNJF012); 浙江省农业科学院重大科技任务攻关项目(ZDZX202500)。

征维度,提升了模型的效率与实用性。【结论】该研究提出的方法可有效减少人工测量的工作量,提升水稻始穗期监测效率,实现育种小区始穗期的自动化预测,为智能育种与精准农业管理提供可行的数据支撑与技术路径。

关键词: 随机森林; 水稻始穗期; 智能化育种; 目标检测

水稻(*Oryza sativa* L.)作为全球最主要的粮食作物之一,在保障粮食安全、支撑农业发展和改善民生方面意义重大。随着我国农业现代化,水稻育种水平持续提升,对优质、高产、稳产品种的需求持续增长。始穗期是水稻生长的关键生育周期之一,直接影响产量与品质,在品种选育与栽培中占据着核心地位。准确把握水稻始穗期,可指导品种筛选、优化育种策略并提升育种效率。传统的始穗期调查依赖人工实地观测,通常依据稻田中抽穗株数达总穗数 10% 的日期进行判定,存在观测周期长、劳动强度大、效率低等缺点,难以满足现代化育种对高效、精准监测的需求,从而催生了对自动化、数字化监测的需求^[1,2]。

水稻始穗期预测经历了从经验模型到遥感建模,再到智能算法融合的演进过程。早期研究多采用积温模型、光温响应模型和作物生长模拟器,在特定条件下表现出较高精度^[3-5]。部分研究进一步引入基因型特征或通过贝叶斯推断估算遗传参数,与作物模型集成以提升新品种适应性^[6-7]。然而,此类模型依赖完整气象数据和结构化输入,难以适应复杂育种环境^[8]。为此,研究逐步引入遥感与图像数据,构建基于生育动态的预测框架。研究人员利用无人机影像生成数字表面模型,提取冠层高度并通过 Logistic 或 Fourier 拟合估算关键物候期^[9-11]。莫佳才等^[12-14]基于多光谱植被指数动态变化,利用峰值或最大曲率点结合高斯或双逻辑斯建模,实现始穗期估测, RMSE 普遍小于 5 d。在更大尺度上,遥感方法被用于区域级监测。Zhang 等^[4]利用 SPOT-VGTNDVI 数据估算全国四大稻区抽穗期, RMSE 为 8.76 d, 76% 的结果在 ± 10 d 内,验证了其在区域尺度的可行性。此外, Zhang 等^[8]构建作物模型与机器学习的混合框架,将模拟结果与 XGBoost 算法融合,实现跨区域、跨年度预测。He 等^[15]基于多时相 RADARSAT-2 反散射系数构建决策树,实现四个生育阶段识别,总体精度达 86.2%。

随着深度学习的发展,稻穗识别与物候期监测精度显著提升。基于 YOLO、Faster R-CNN 等网络的检测方法在穗体密集、相互遮挡、小目标及光照变化等条件下表现出较强鲁棒性^[16-18]。改进模型如 RiceYOLO、YOLO-BoT 通过引入注意力机制和 Transformer 结构,有效增强特征提取并提高多生育

期检测精度^[17,19]。Zhang 等^[20]实现了抽穗开花、乳熟和成熟三阶段的自动识别,与人工观测差异不超过 2 d。Cai 等^[21]基于 MobileNetv3-YOLOv8 结合坐标注意力机制,实现了五个关键生育期的高效识别。还有研究利用地面或塔式图像,采用 ResNet、Inception 等分类模型对始穗前后图像进行二分类,并结合 Grad-CAM 可视化,估算始穗期误差小于 1 d^[18,22]。

尽管已有研究取得进展,但水稻始穗期的高精度自动化预测仍面临三个主要挑战: 1) 针对始穗期这一关键临界点的研究不足; 2) 多数方法依赖单时相图像,未能充分利用多时序图像中稻穗的动态变化信息; 3) 田间环境复杂、穗体密集和光照变化,导致模型的泛化性与稳定性受限^[10,12]。

为此,本研究提出一种融合无人机遥感、YOLOv10b 目标检测与随机森林回归的水稻始穗期智能预测方法。以水稻育种小区为研究对象,利用无人机采集其孕穗至成熟阶段的时序图像,基于 YOLOv10b 模型实现稻穗的自动识别与计数; 将小区穗数动态序列作为特征,以移栽期距始穗期天数为预测目标,构建多种始穗期预测模型并进行对比择优,为实现水稻始穗期准确预估提供了完整的技术路径,对提升育种效率与推动精准农业实践具有积极意义。

1 材料与方法

1.1 试验材料

本研究中的水稻育种试验区位于浙江省嘉兴市浙江省农业科学院杨渡基地。试验区包含 651 个籼粳杂交稻组合小区,每个小区对应一个品种,小区面积约 8 m²(长约 4 m,宽约 2 m),小区间隔约 1 m,以减少边界效应干扰。试验水稻于 2024 年 7 月 1 日移栽,10 月上旬收割。每个小区栽植 8 行,每行 24 株,共 192 株,保证种植密度一致。整个试验周期内,田间管理严格执行统一方案,包括定期灌溉和规范施肥。

1.2 数据采集

图像采集设备为大疆 Mavic 3E 无人机,配备 4/3 CMOS 相机,有效像素 2000 万。采集参数设置: 光圈值 f/2.8,曝光时间 1/500 s,ISO 100,焦距 12 mm,分辨率 5280×3956。无人机高度距水稻冠层约

表 1 数据采集日期及相关信息

Table 1. Data collection dates and the corresponding information

序号 No.	观测期编号 Period No.	采集日期 Collection date	距移栽天数 Days after transplanting (DAT)	与前一期间隔 Interval from previous period (d)
1	T1	2024-08-26	56	0
2	T2	2024-08-28	58	2
3	T3	2024-08-30	60	2
4	T4	2024-09-02	63	3
5	T5	2024-09-04	65	2
6	T6	2024-09-06	67	2
7	T7	2024-09-09	70	3
8	T8	2024-09-10	71	1
9	T9	2024-09-12	73	2
10	T10	2024-09-14	75	2
11	T11	2024-09-18	79	4
12	T12	2024-09-20	81	2
13	T13	2024-09-23	84	3
14	T14	2024-09-26	87	3
15	T15	2024-09-29	90	3

4.5 m, 采用航点航线模式对各试验小区逐一自动采集图像。采集时间为 2024 年 8 月 26 日至 9 月 29 日, 选择在上 午 8:00–12:00 晴朗无云的天气下共采集 15 期数据(表 1)。小区的总穗数在抽穗结束后由人工抽样统计确定, 始穗期由人工地面调查判定, 当小区内抽穗数达到其总穗数的 10%时, 将该日期记为始穗期。

1.3 数据集构建

本研究基于无人机获取的原始小区图像, 构建了两个不同应用目标的图像数据集: 一是稻穗检测图像数据集, 用于训练稻穗检测模型, 实现小区稻穗的自动识别与计数; 二是小区多期时序图像数据集, 用于提取小区稻穗数量的动态变化特征, 支撑始穗期预测建模工作。

在稻穗检测数据集构建中, 为保证样本的多样性与代表性, 从原始小区图像中随机选取图像样本, 并裁剪为 640×640 图像块, 利用 LabelImg 软件对图像块进行稻穗标注。标注采用矩形边界框实现, 遵循以下准则: 边界框应完整框选稻穗主轴及其可见穗粒, 避免包含过多茎秆或叶片背景; 对部分遮挡的稻穗, 依据可见部分进行合理估计标注。最终形成 1,000 张样本图像数据集, 并按 6:2:2 比例将其划分为训练集、验证集和测试集。其中, 训练集共标注 31330 穗; 验证集共标注 10501 穗; 测试集共标注 10491 穗。同时, 为增强模型鲁棒性与泛化能力, 对训练集进行了翻转、亮度与对比度调整、噪声干扰等数据增强操作, 以提升模型在不同环境下的适应性。

为消除原始小区图像中的相邻小区边缘、田埂等非目标区域的干扰, 在构建小区多期时序图像数据集时, 首先筛除始穗期数据早于采集时间等情形的小区, 而后使用 LabelMe 软件对剩余 541 个小区在 15 个观测期图像上逐一标注小区边界, 批量裁剪、旋转矫正和边缘填充后, 获得小区多期时序图像数据集。

1.4 稻穗检测算法

本研究选用 YOLOv10^[23]、YOLOv8 及 YOLOv5 三种目标检测算法进行对比实验。三种目标检测算法均提供了多种规格(n、s、m 等), 各规格在网络结构深度与宽度上存在差异, 参数量与计算复杂度逐级递增, 适用于从资源受限的边缘设备到高性能计算平台的多种应用场景, 以适应不同部署环境与效率要求。

1.5 实验环境及训练策略

本研究中的所有实验均在 Windows 10 操作系统中完成, 软件环境包括 PyTorch 2.1.1、CUDA 12.4, 编程语言为 Python 3.12.4, 集成开发环境为 PyCharm。硬件环境包括 Intel(R) Core(TM) i7-14700KF 3.40 GHz CPU, NVIDIA GeForce RTX 4060 Ti 16GB GPU、32GB 内存, 以及两块 1TB 固态硬盘。

稻穗检测模型训练过程中, 设置训练批处理大小为 16, 迭代次数为 300, 输入图像尺寸固定为 640×640 像素, 采用单卡 GPU 并启用自动混合精度(AMP)以提升训练效率。初始学习率设为 0.01, 动量为 0.937, 权重衰减系数为 0.0005; 预热阶段持续

3 个 epoch，早停耐心值设为 100。除与模型规格相关的参数调整外，其余参数均使用默认配置。在测试集上进行模型性能评估时，设置置信度阈值为 0.6，非极大值抑制(NMS)的 IoU 阈值为 0.5。

1.6 始穗期预测建模

在始穗期预测建模过程中，本研究采用了随机森林(Random Forest, RF)、梯度提升回归树(Gradient Boosting Regression Tree, GBRT)、极端梯度提升(Extreme Gradient Boosting, XGBoost)、支持向量回归(Support Vector Regression, SVR)、岭回归(Ridge Regression, RR)和线性回归(Linear Regression, LR)六种回归算法进行模型构建与对比分析。模型输入变量为各小区在 15 个观测期图像中提取的穗数时序特征，输出变量为对应小区自移栽起至始穗期的天数。为确保训练过程规范性与测试集评估独立性，本研究以小区为划分单位，按 8:2 的比例随机划分为训练集和测试集，分别用于模型训练与测试，对不同模型性能进行对比并确定最优模型。同时，在训练过程中采用 5 折交叉验证策略，以增强模型稳健性与泛化能力。

使用随机森林模型建模时超参数设置如下：树的数量($n_{estimators}$: 300–600)、最大深度(max_depth : 20–30)、最小分裂样本数($min_samples_split$: 2–8)、最小叶节点样本数($min_samples_leaf$: 1–3)。为评估最优模型的预测稳定性与统计可靠性，进一步进行 30 次重复测试，记录其性能指标(R^2 、RMSE、MAE)的均值与标准差。

1.7 评价指标

1.7.1 稻穗检测评价指标

为评估稻穗检测模型的性能，本研究选取了准确率(Precision, P)、召回率(Recall, R)、 F_1 值(F_1 -score)、平均精度均值(mAP50)与帧率(FPS)五项指

标^[24–26]，从检测精度与实际应用角度对检测模型进行综合评价。

1.7.2 始穗期预测评价指标

为评估模型在水稻始穗期预测中的性能，本研究选取了决定系数(Coefficient of Determination, R^2)、均方根误差(Root Mean Square Error, RMSE)以及平均绝对误差(Mean Absolute Error, MAE)三项常用指标^[27–29]，综合评价模型的拟合能力与预测精度。

2 结果与分析

2.1 稻穗检测模型精度

为评估 YOLOv10、YOLOv8 与 YOLOv5 算法在稻穗检测任务中的性能差异，本研究在相同参数设置下对三种算法的不同规格模型进行训练，最终在测试集上进行性能评估，结果如表 2 所示。

考虑到稻穗检测常受光照变化、植株遮挡以及轻量化和边缘化部署等因素影响，模型需兼顾精度、速度与部署适配性。综合对比各型号模型性能，YOLOv10b 在保持较高检测精度的同时，具有适中的模型规格与计算复杂度，既能满足检测精度的需求，又能兼顾边缘设备资源约束和批量检测任务中的处理效率。因此，本研究选取 YOLOv10b 作为后续稻穗检测任务的主模型。

为进一步验证 YOLOv10b 模型在真实稻田场景下的适用性，图 1 给出了其在测试图像上的检测结果对比。从图中可见，YOLOv10b 能够在稻穗密集分布、局部叶片遮挡及光照条件复杂等情况下，稳定实现稻穗的准确识别，检测框与人工标注具有较高的一致性，具备良好的检测精度和鲁棒性，能够有效完成复杂农业图像中的稻穗识别任务。

表 2 不同 YOLO 模型在稻穗检测任务中的性能对比

Table 2. Performance comparison of different YOLO models in rice panicle detection tasks

模型 Model	精确率 Precision(%)	召回率 Recall(%)	F_1 值 F_1 -Score	平均精度均值 mAP50	帧率 FPS
YOLOv10n	90.9	89.2	0.900	95.3	227
YOLOv10s	90.2	90.0	0.901	95.5	188
YOLOv10m	91.7	91.2	0.914	96.2	121
YOLOv10b	91.7	92.1	0.919	96.2	117
YOLOv8n	97.2	79.2	0.873	88.5	238
YOLOv8s	95.6	86.4	0.908	92.0	172
YOLOv8m	97.1	83.4	0.897	90.5	111
YOLOv5n	93.6	89.2	0.913	95.2	212
YOLOv5s	93.8	91.0	0.924	95.2	147
YOLOv5m	94.2	90.5	0.923	95.4	86

mAP50, Mean average precision at IoU=0.5; FPS, Frames per second.




图 1 稻穗检测结果对比

Fig. 1. Comparison of rice panicle detection results

2.2 小区稻穗识别结果分析

为获取小区稻穗数量的时序变化数据,本研究基于 YOLOv10b 稻穗检测模型,提取各小区在各观测期上的稻穗数量,构建覆盖孕穗至成熟阶段的多期时序穗数数据。图 2-A 展示了所有小区总体稻穗数量的时间序列变化趋势。

从图 2-A 可见, T1 观测期大多数小区的穗数接近于零,表明此阶段水稻多数处于孕穗末期尚未抽穗,田间仅有极少数可识别的稻穗。T2 观测期起,部分小区开始出现少量稻穗;至 T4 观测期,穗数显著增加。推进至 T6 至 T9 观测期,穗数趋于平稳并达到峰值,绝大部分小区已完成抽穗。T11 观测期及以后,部分小区穗数略有下降,可能与稻穗成熟、植株姿态变化导致的穗下垂或遮挡,进而影响模型的准确识别有关。总体来看,不同小区在穗数形成过程中的启动时间、增长速率及峰值到达时间等方面的差异明显,反映出不同育种材料的物候期

差异。

除穗数的时序特征外,还统计了各小区移栽期至始穗期的天数分布范围(图 2-B),结果显示,小区的始穗期天数分布在 56~73 d,平均天数为 63.35 d,分布相对集中且近似正态。其中大多数小区的始穗期集中在移栽后 59~69 d。

2.3 基于稻穗检测结果的始穗期预测

2.3.1 多模型性能对比分析

本研究训练了 6 种始穗期预测模型,图 3 展示了各模型预测值与真实值之间的拟合情况。其中,随机森林模型 R^2 达到 0.84, RMSE 为 1.57 d, MAE 为 1.12 d, 整体表现最优。梯度提升回归树、极端梯度提升和支持向量回归三者与随机森林模型表现较为接近,表明它们在捕捉非线性特征方面同样具有良好的表现。线性回归与岭回归两种线性模型表现相对较差, R^2 均为 0.75。同时,为评估随机森林模型的统计稳定性,本研究进行了 30 次重复稳




图 2 不同观测期稻穗数量变化及小区始穗期分布

Fig. 2. Variation in the number of rice panicles and distribution of the initial heading stage among plots across different observation periods




图3 不同回归模型在水稻始穗期预测中的拟合效果对比

Fig. 3. Comparison of fitting performance of different regression models in rice heading date prediction

定性验证, 其预测性能: $R^2 = 0.829 \pm 0.041$, $RMSE = 1.561 \pm 0.200$ d, $MAE = 1.072 \pm 0.090$ d, 表明模型的预测性能具有较高的统计稳定性。

2.3.2 误差分布及分析

为深入评估随机森林模型作为最优模型的预测稳定性与局限性, 进一步分析了其在测试集中各小区的始穗期预测误差分布(图 4)。结果显示, 约 82% 的小区预测误差在 2 d 范围内, 表明模型对多数样本具有良好预测能力, 仅存在少数小区预测误差大于 3 d。

通过对误差值最大的前 10% 小区的图像与穗数时序特征分析, 发现预测误差主要来自多个因素的叠加影响: 穗体密集粘连导致稻穗检测模型在检测时出现漏检或合并识别, 降低穗数统计准确性; 强光照条件下图像过曝或阴影区域对比度下降, 干扰模型对穗边界的判别; 小区内植株抽穗进程不一致, 早抽穗的植株穗体因成熟弯垂而在后续图像中漏检, 晚抽穗的植株穗体尚未完全可见, 导致穗数时序曲线未能完整刻画抽穗进程。

2.3.3 特征重要性

为明确不同观测期的穗数特征在始穗期预测中的相对作用, 本研究基于随机森林模型计算了各




图4 基于随机森林的始穗期预测误差区间分布

Fig. 4. Error interval distribution of heading date prediction using random forest

观测期穗数特征的重要性分数, 并与各观测期对应的移栽期天数(DAT)进行关联, 如图 5 所示。

其中, T5 观测期的穗数特征重要性最高, 贡献率为 23.74%, T4(17.76%)、T6(13.46%)、T3(11.04%)、T7(7.86%)和 T2(5.59%)观测期依次排在其后。这 6 个观测期对应的 DAT 集中在 58~70 d, 与各小区始穗期的主要分布区间(图 2-B)基本一致。其余观测




图 5 不同观测期穗数特征对始穗期预测的重要性
Fig. 5. Importance of panicle number features at different observation periods for predicting heading date

期的穗数特征重要性均低于 5%，对始穗期预测的作用较弱。

2.3.4 降维优化

考虑到在实际应用中使用全部 15 个观测期的穗数特征作为模型输入，可能造成特征冗余并增加数据采集与处理成本，在确保预测精度的前提下，尝试通过特征降维对模型进行优化。基于随机森林算法的特征重要性评估，对所有观测期的穗数特征按重要性进行降序排列，依次选取 Top-K(K=1~14) 个特征构成不同的子特征组合，逐一对每个组合训练随机森林模型并进行性能评估，结果如下表 3 所示。

随着特征数量的减少，模型性能呈现出由稳定到下降的变化趋势。当特征数量精简至 Top-9 个时，模型的 R^2 始终稳定在 0.83 左右，RMSE 仅出现小幅增大，被剔除的 6 个观测期绝大部分小区已完成抽穗，穗数趋于稳定，对预测贡献较弱。综合性能与计算效率，采用 Top-9 子特征组合的预测精度与全特征模型基本一致，在维持高精度的同时将特征维度降低约 40%，显著提升了模型的实用性与部署效率。此外，当特征数量精简至 Top-4 个时，模型虽出现一定的精度下降，但仍然保持较高的预测能力，其特征维度仅占原始模型 27%，在数据采集与处理成本方面具有显著优势。结合图 2 和图 5 可见，Top-4 所对应的四个观测期正处于穗数快速上升阶段，也是多数小区始穗期集中开始的时段，其动态

信息对始穗期预测具有关键指示作用。

3 讨论

本研究通过无人机遥感图像检测稻穗数量并构建时序特征，实现了始穗期的高效预测，减少了对高密度光谱数据的依赖，适合小地块与高通量表型试验场景^[10-11]。

在建模环节中，始穗期对不同观测期穗数特征表现出明显的敏感性差异。特征重要性分析结果显示，T5 观测期穗数特征对预测贡献最大，表明该时段是抽穗的关键节点，具有突出的时序辨识价值。同时，部分关键观测期在预测中贡献显著，表明稻穗时序特征在模型中具有明确的生物学意义，这一结果与作物模型融合机器学习预测方法的研究结论一致^[7,8]。模型通过特征降维，在保持高精度预测的同时显著降低了特征维度，减少了无人机采样次数，验证了特征压缩在提高计算效率与部署可行性方面的潜力。对比各始穗期预测模型，非线性模型在始穗期预测中具有显著优势，尤其是随机森林模型，表现出高精度的预测能力，展现出了较强的泛化能力和鲁棒性，能够适应复杂农业场景下的多样化时序特征。

本研究方法在应用过程中仍受多方面因素影响。田间环境复杂、植株分布密集和光照条件波动等因素，可能导致图像质量下降，从而影响模型的准确性；中午强光易导致过曝与阴影，干扰稻穗特征提取并削弱模型训练的稳定性，这一现象在既往研究中也有所报道^[9,12]。在实际数据采集过程中一般选择清晨、傍晚或阴天等光照均匀时段，小雨天可选择大疆 4D 等适用机型，以减少天气因素对方法应用的干扰。

在应用价值明确的基础上，未来研究可在三方面进一步优化：一是扩大训练样本，增强模型对穗型变化与复杂光照条件的适应能力；二是结合半监督学习和主动学习策略缓解高质量人工标注依赖^[30]；三是融合多源表型信息，结合作物模型和集成学习策略^[1,6]，以提升复杂环境下的稳健性和跨区域泛化能力。

表 3 不同 Top-K 个子特征在随机森林模型中的性能对比

Top-K	1	2	3	4	5	6	7	8	9	10	11	12	13	14
R^2	0.749	0.802	0.808	0.811	0.817	0.816	0.817	0.811	0.829	0.834	0.832	0.832	0.837	0.835
RMSE	1.998	1.775	1.749	1.735	1.707	1.709	1.707	1.735	1.649	1.627	1.636	1.638	1.610	1.622
MAE	1.556	1.225	1.200	1.222	1.227	1.208	1.199	1.210	1.164	1.166	1.171	1.174	1.161	1.172

4 结论

本研究提出了一种融合无人机遥感、YOLOv10b 目标检测与随机森林算法的水稻始穗期智能预测方法。在该方法中, YOLOv10b 稻穗检测模型实现了稻穗的高精度识别(精确率 91.7%, 召回率 92.1%), 为物候监测提供了可靠数据源。基于多期稻穗数量时序特征所构建的随机森林模型, 表现出最优的预测性能($R^2=0.84$, RMSE=1.57 d, MAE=1.12 d)。特征重要性分析表明, 不同观测期对预测的贡献存在显著差异, 通过降维优化, 仅需 9 个关键观测期的穗数特征可在保证预测精度的同时将特征维度降低 40%, 显著提升了模型的实用性与部署效率。本研究为水稻育种物候监测提供了有效的技术路径, 对推动智能育种发展具有积极意义。

参考文献:

- [1] 魏逸飞. 基于优化加权集成模型的水稻生长阶段监测研究[D]. 武汉: 华中农业大学, 2023.
Wei Y F. Research on monitoring rice growth stage based on optimized weighted integrated model [D]. Wuhan: Huazhong Agricultural University, 2023. (in Chinese with English abstract)
- [2] Bai X, Cao Z, Zhao L, Zhang J, Lv C, Li C, Xie J. Rice heading stage automatic observation by multi-classifier cascade based rice spike detection method[J]. *Agricultural and Forest Meteorology*, 2018, 259: 260-270.
- [3] Hyun S, Kim K S. Estimation of heading date for rice cultivars using ORYZA (v3)[J]. *Korean Journal of Agricultural and Forest Meteorology*, 2017, 19(4): 246-253.
- [4] Zhang Z, Song X, Chen Y, Wang P, Wei X, Tao F. Dynamic variability of the heading-flowering stages of single rice in China based on field observations and NDVI estimations[J]. *International Journal of Biometeorology*, 2015, 59(5): 643-655.
- [5] Chen Y C, Lin W S, Chen R K, Chao Y Y, Chin S W, Chen F C, Lee C Y. Establishment of a prediction model for the miRNA-based heading date characteristics of rice in the booting stage[J]. *Genetics and Molecular Research*, 2015, 14(2): 4381-4390.
- [6] Kawakita S, Yamasaki M, Teratani R, Yabe S, Kajiya-Kanegae H, Yoshida H, Fushimi E, Nakagawa H. Dual ensemble approach to predict rice heading date by integrating multiple rice phenology models and machine learning-based genetic parameter regression models[J]. *Agricultural and Forest Meteorology*, 2024, 344: 109821.
- [7] Chen T S, Aoike T, Yamasaki M, Kajiya-Kanegae H, Iwata H. Predicting rice heading date using an integrated approach combining a machine learning method and a crop growth model[J]. *Frontiers in Genetics*, 2020, 11: 599510.
- [8] Zhang J, Lin X, Jiang C, Hu X, Liu B, Liu L, Xiao L, Zhu Y, Cao W, Tang L. Predicting rice phenology across China by integrating crop phenology model and machine learning[J]. *Science of the Total Environment*, 2024, 951: 175585.
- [9] Hong W, Li Z, Feng X, Qin J, Wang A, Jin S, Wang D, Chen S. Estimating key phenological dates of multiple rice accessions using unmanned aerial vehicle-based plant height dynamics for breeding[J]. *Rice Science*, 2024, 31(5): 617-628.
- [10] Taniguchi S, Sakamoto T, Imase R, Nonoue Y, Tsunematsu H, Goto A, Matsushita K, Ohmori S, Maeda H, Takeuchi Y, Ishii T, Yonemaru J I, Ogawa D. Prediction of heading date, culm length, and biomass from canopy-height-related parameters derived from time-series UAV observations of rice[J]. *Frontiers in Plant Science*, 2022, 13: 998803.
- [11] Lyu M, Lu X, Shen Y, Tan Y, Wan L, Shu Q, He Y, He Y, Cen H. UAV time-series imagery with novel machine learning to estimate heading dates of rice accessions for breeding[J]. *Agricultural and Forest Meteorology*, 2023, 341: 109646.
- [12] 莫佳才, 彭漪, 刘小娟, 王靖. 基于无人机遥感影像的多品种水稻抽穗时间估算[J]. *河南农业科学*, 2022, 51(1): 154-161.
Mo J C, Peng Y, Liu X J, Wang J. Estimation of heading time for rice of different cultivars based on UAV remote sensing images[J]. *Journal of Henan Agricultural Sciences*, 2022, 51(1): 154-161. (in Chinese with English abstract)
- [13] Ma Y, Jiang Q, Wu X, Zhu R, Gong Y, Peng Y, Duan B, Fang S. Monitoring hybrid rice phenology at initial heading stage based on low-altitude remote sensing data[J]. *Remote Sensing*, 2021, 13(1): 86.
- [14] 马驿. 基于无人机影像的水稻长势监测和产量估计[D]. 武汉: 武汉大学, 2021.
Ma Y. Monitoring rice growth parameters and estimating yield based on UAV images[D]. Wuhan: Wuhan University, 2021. (in Chinese with English abstract)
- [15] He Z, Li S, Wang Y, Dai L, Lin S. Monitoring rice phenology based on backscattering characteristics of multi-temporal RADARSAT-2 datasets[J]. *Remote Sensing*, 2018, 10(2): 340.
- [16] 吴水秀. 基于深度学习的稻穗检测及水稻多生育期识别研究[D]. 福州: 福建农林大学, 2024.
Wu S X. Deep learning-based rice spike detection and rice multi-growth stage recognition research[D]. Fuzhou: Fujian Agriculture and Forestry University, 2024. (in Chinese with English abstract)

- [17] Bak H J, Sang W G, Chang S, Kwon D, Im W J, Lee J H, Chung N J, Cho J I. Estimation of rice heading date of paddy rice from slanted and top-view images using deep learning classification model[J]. *Korean Journal of Agricultural and Forest Meteorology*, 2023, 25(4): 337-345
- [18] Desai S V, Balasubramanian V N, Fukatsu T, Ninomiya S, Guo W. Automatic estimation of heading date of paddy rice using deep learning[J]. *Plant Methods*, 2019, 15(1): 76.
- [19] Tan S, Lu H, Yu J, Lan M, Hu X, Zheng H, Peng Y, Wang Y, Li Z, Qi L, Ma X. In-field rice panicles detection and growth stages recognition based on RiceRes2Net[J]. *Computers and Electronics in Agriculture*, 2023, 206: 107704.
- [20] Zhang Y, Xiao D, Liu Y, Wu H. An algorithm for automatic identification of multiple developmental stages of rice spikes based on improved Faster R-CNN[J]. *The Crop Journal*, 2022, 10(5): 1323-1333.
- [21] Cai W, Lu K, Fan M, Liu C, Huang W, Chen J, Wu Z, Xu C, Ma X, Tan S. Rice growth-stage recognition based on improved YOLOv8 with UAV imagery[J]. *Agronomy*, 2024, 14(12): 2751.
- [22] Qin J, Hu T, Yuan J, Liu Q, Wang W, Liu J, Guo L, Song G. Deep-learning-based rice phenological stage recognition[J]. *Remote Sensing*, 2023, 15(11): 2891.
- [23] Wang A, Chen H, Liu L. YOLOv10: Real-Time End-to-End Object Detection[A]. arXiv, 2024.
- [24] Howard A G, Zhu M, Chen B, Kalenichenko D, Wang W, Weyand T, Andreetto M, Adam H. MobileNets: Efficient convolutional neural networks for mobile vision applications[J]. *ArXiv Preprint, ArXiv: 1704.04861*, 2017.
- [25] Lin T Y, Maire M, Belongie S, Hays J, Perona P, Ramanan D, Dollár P, Zitnick C L. Microsoft COCO: Common objects in context[C]//Computer Vision – ECCV 2014. Cham: Springer, 2014: 740-755.
- [26] Kamilaris A, Prenafeta-Boldú F X. Deep learning in agriculture: A survey[J]. *Computers and Electronics in Agriculture*, 2018, 147: 70-90.
- [27] Willmott C J, Matsuura K. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance[J]. *Climate Research*, 2005, 30(1): 79-82.
- [28] Botchkarev A. Performance metrics (error measures) in machine learning regression, forecasting and prognostics: Properties and typology[J]. *Interdisciplinary Journal of Information, Knowledge, and Management*, 2018, 14: 45-76.
- [29] Hodson T O. Root-mean-square error (RMSE) or mean absolute error (MAE): When to use them or not[J]. *Geoscientific Model Development*, 2022, 15(14): 5481-5487.
- [30] 张立才, 张欣, 陈孝玉龙, 刘佳明, 文兴甜, 杨胜贤. 改进伪标签半监督方法的石榴生长阶段检测模型[J]. *计算机工程与应用*, 2025, 61(13): 291-299.
- Zhang L C, Zhang X, Chen X, Liu J M, Wen X T, Yang S X. Improved pseudo-labeled semi-supervised method for pomegranate growth stage detection modeling[J]. *Computer Engineering and Applications*, 2025, 61(13): 291-299. (in Chinese with English abstract)