doi:10.6041/j.issn.1000-1298.2026.03.012

融合改进 YOLO v8s－obb 与 NPRP－A 的无人机遥感水稻估产方法

李继宇[1]　李明霞[1]　李惠芬[2,3]　高　荣[1]　卢广栋[1]　刘婉卿[2,3]　梁蕴婷[1]　巫　瀚[4]

（1.华南农业大学工程学院，广州 510642；2.广东省农业科学院水稻研究所，广州 510640；
3.广东省水稻科学技术重点实验室，广州 510640；4.潮安区凤凰镇人民政府，潮州 515656）

摘要：针对现有水稻估产方法忽略同种作物个体差异性及种植密度与单穗质量耦合影响，导致估产精度受限的核心问题，提出了一种融合改进 YOLO v8s－obb 模型与 NPRP－A 的水稻估产方法。通过优化 YOLO v8s－obb 结构，引入 C2f_DCNv4 模块、GSConv、EPSANet 和 DAT 注意力机制，提升模型对稻穗的多尺度精准检测能力。为提升估产结果的可信度，在水稻成熟期实地收割样本小区作物，采集实测产量数据作为模型验证参考，并引入高斯核密度估计与 NPRP－A 单穗质量建模方法，建立密度调控与单穗质量之间的非线性映射关系，实现估产精度提升。实验结果显示，在 3 个 1 m^2 估产小区中，本方法预测误差均低于 5.3%，最小误差为 2.2%，优于传统方法，展示出良好的实际应用前景。该研究为水稻高效、精准估产提供了可靠技术方案，也为智慧农业中的作物表型识别与产量分析提供了思路。

关键词：稻穗检测；作物估产；单穗质量模型；YOLO v8s－obb；NPRP－A；无人机遥感

中图分类号：S2　　**文献标识码**：A　　**文章编号**：1000-1298(2026)03-0119-10　　**OSID**：

UAV-based Rice Yield Estimation Method Integrating Improved YOLO v8s－obb and NPRP－A

LI Jiyu[1]　LI Mingxia[1]　LI Huifen[2,3]　GAO Rong[1]　LU Guangdong[1]　LIU Wanqing[2,3]　LIANG Yunting[1]　WU Han[4]

(1. *College of Engineering*, *South China Agricultural University*, *Guangzhou* 510642, *China*
2. *Rice Research Institute*, *Guangdong Academy of Agricultural Sciences*, *Guangzhou* 510640, *China*
3. *Guangdong Key Laboratory of New Technology in Rice Breeding*, *Guangzhou* 510640, *China*
4. *People's Government of Fenghuang Town*, *Chao'an District*, *Chaozhou* 515656, *China*)

Abstract: Aiming to address the core limitations of existing rice yield estimation methods, particularly the neglect of intra-species variability and the coupled influence of planting density and single-panicle weight, which compromise accuracy, a novel approach was proposed integrating an improved YOLO v8s－obb model with the NPRP－A method. The YOLO v8s－obb architecture was enhanced by incorporating the C2f_DCNv4 module, GSConv, EPSANet, and DAT attention mechanism to strengthen multi-scale detection of rice panicles. To ensure estimation reliability, ground-truth yield data were collected through field harvesting of sample plots at maturity. Gaussian kernel density estimation and the NPRP－A-based single-panicle weight modeling were further introduced to establish a nonlinear mapping between planting density and panicle weight, capturing their interactive effects. Experimental validation was conducted across three 1 m^2 plots. Results showed prediction errors consistently below 5.3%, with the lowest error at 2.2%, significantly outperforming traditional methods. This demonstrated the method's high accuracy and robustness in real-world conditions. The proposed framework not only delivered a reliable technical solution for precise and efficient rice yield estimation but also advanced crop phenotyping and yield analysis in smart agriculture. By explicitly accounting for individual plant variation and density-yield interactions, the approach bridged a critical gap in current remote sensing-based estimation practices. Its design supported scalable deployment and offered practical value for precision farming applications,

收稿日期：2025－10－23　修回日期：2025－11－21

基金项目：广东省自然科学基金面上项目(2023A1515011932)和湛江市烟草专卖局(公司)科技项目(湛烟科项申 202401)

作者简介：李继宇(1979—)，男，教授，博士，主要从事无人机机体架构、旋翼气流等研究，E-mail：lijiyu@scau.edu.cn

通信作者：李惠芬(1978—)，女，农艺师，主要从事水稻高产栽培及品种保护研究，E-mail：lihuifen@gdaas.cn

highlighting strong potential for broader adoption in agricultural monitoring systems.

Key words: rice panicle detection; crop yield estimation; single-panicle mass model; YOLO v8s - obb; NPRP - A; UAV remote sensing

0 引言

水稻作为全球粮食安全的关键作物,其产量稳定对保障粮食供应至关重要。近年来,随着智慧农业的发展,依托遥感与人工智能的作物估产方法快速发展,为传统农业管理提供了数字化、精准化的解决方案。尤其是无人机遥感平台因其高分辨率、操作灵活、成本较低,被广泛用于水稻等作物的生长监测与产量预测中[1]。

随着科技不断进步,作物估产方法也在持续改进。20 世纪 70 年代以来,卫星遥感技术开始应用于作物估产。ISLAM 等[2]通过整合遥感和气象数据,运用机器学习技术,构建快速估算水稻产量的模型,但是在不同区域中该模型的估产精度差异大。MA 等[3]利用哨兵 2 号遥感数据反演叶面积指数(LAI),并将其同化到 SAFY 作物生长模型中实现了对小麦生长的监测和产量的估算,但在实际验证不同年份产量估算中表现欠佳。尽管卫星遥感估产具有覆盖范围广的优势,但其空间分辨率低、重访周期长等局限性导致其在小面积、复杂地形区域的估产精度难以满足实际需求[4-5]。

进入 21 世纪,无人机搭载多光谱、高光谱等相机为农作物估产提供了新的解决方案[6-11]。而利用无人机搭载 RGB 相机对作物进行估产,具有成本较低、数据处理难度较小的优势[12-15]。上述研究表明深度学习技术可实现无人机 RGB 图像中稻穗的高效检测,但现有研究多聚焦作物数量统计,对同种作物个体差异性关注不足,且未充分考虑种植密度与单穗质量的耦合影响对估产结果的作用。已有研究表明[16],水稻产量与种植密度之间存在明显的非线性关系,呈现先上升后下降的变化趋势。在实际的水稻估产工作中,种植密度随机分布的稻田普遍存在,这就要求在估产模型中同步解决“高精度稻穗检测”与“耦合影响量化”两大关键问题,以提高估产结果的准确性和可靠性。

基于上述水稻估产过程中存在的问题,本文提出一种基于改进 YOLO v8s - obb 的多尺度特征融合与密度调控单穗质量模型的稻穗检测与估产方法。该方法首先针对稻穗识别特性改进 YOLO v8s - obb 目标检测模型,将主干部分的 C2f 模块替换为在复杂场景下识别精度更高的 C2f_DCNv4 模块[17],同时在颈部结构中采用 GSConv 模块替代传统的 Conv 模块[18];此外,引入 EPSANet 和 DAT 注意力机制[19-20],进一步增强模型的多尺度特征抓取能力,以满足复杂田间环境下稻穗的精准识别与定位需求。此外,针对密度导致的稻穗个体质量差异问题,采用高斯核密度估计方法解算水稻株穗数,并结合密度调控机制建立水稻单穗质量模型,揭示密度与单穗质量之间的非线性关系,以进一步实现更为精准的水稻估产。

1 材料与方法

1.1 研究区域概况与实验设计

研究区域位于广东省农业科学院白云实验基地(23°39′N,113°42′E),地处珠江三角洲平原,属于典型的南亚热带季风气候区。研究区水稻种植采用双季稻种植模式,包括早熟稻和晚熟稻两季,早熟稻种植期为 3—7 月,晚熟稻种植期为 8—11 月。

以研究区内的水稻田为实验对象,针对水稻齐穗期的稻穗特征进行检测与产量估算。研究区域水稻种植严格按照行距 0.25 m、株距 0.2 m 的种植标准,以期达到最佳的种植效果。水稻齐穗期用高分辨率 RGB 相机采集冠层图像,成熟后人工测定单株穗数与穗质量,用于建模与验证。

1.2 无人机影像采集与预处理

1.2.1 无人机影像采集

采用 DJI Mavic 2、DJI Mini 4k、M300 RTK 等型号无人机,在不同天气条件下对研究区水稻田开展图像采集工作。不同水稻品种在穗部空间分布、穗部弯曲度形态特征上存在分异,这种分异性直接导致穗头在成像过程中呈现差异化视觉特征(纹理复杂度、轮廓清晰度、遮挡率等),进而影响识别模型的泛化能力。因此,在研究区域选取香禾优 9518(图 1b)、香禾优 908(图 1c)、珍野优粤芽丝苗(图 1d) 3 种不同品种水稻作为研究对象,提升数据集的多样性,进而提高目标检测模型的泛化能力。在飞行参数设置上,根据以往的实验经验,将飞行高度设为 2 ~ 5 m,速度控制在 0.5 ~ 1 m/s,采用 60% 旁向、70% 航向重叠率,结合手动与航线飞行,兼顾地形适应性与采集系统性。采集结束后,剔除质量欠佳的图像,最终有效采集结果如表 1 所示。此外,另设 3 个不同品种估产小区以验证方法准确性,如图 2 所示,每个小区的面积为 1 m^2(1 m × 1 m),小区内水稻种植数量为横向 4 株、纵向 5 株。

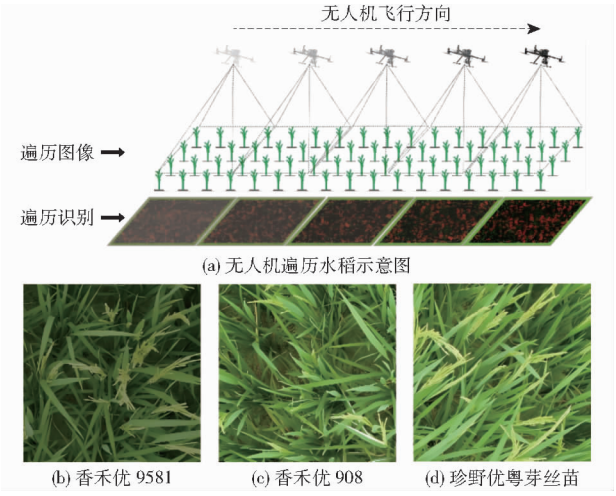

(a) 无人机遍历水稻示意图

(b) 香禾优 9581　(c) 香禾优 908　(d) 珍野优粤芽丝苗

图 1　实验示意及稻穗图像

Fig. 1　Experimental schematic and rice panicle images

1.2.2　样本预处理

先运用 roLabelImg 旋转框标注工具，对采集到的原始图像进行人工标注。每个稻穗以旋转矩形框标注，标注信息涵盖矩形框中心点坐标（x，y）、宽度 w、高度 h 及旋转角度 θ（如图 3 所示）。θ 代表矩形框相对水平轴的倾斜角度，取值范围为 0 ~ π，确保标注框贴合稻穗实际轮廓。为提升模型鲁棒性、降低过拟合风险、丰富数据多样性，借助 OpenCV 实施 4 种常见图像数据增强技术，对稻穗位置、亮度进行调整，并模拟无人机运动拍摄产生的运动模糊（如图 3 所示）。最终得到增强前的有效稻穗图像共 1 200 幅，按照比例 8∶1∶1 划分为训练集、验证集和测试集。随后，对每个子集分别进行增强，扩充至总计 6 000 幅图像，用于模型训练与性能评估，确保数据划分的独立性与实验的客观性。

表 1　无人机图像采集结果

Tab. 1　Results of UAV image acquisition

采集日期	水稻品种	水稻生长时期	图像尺寸/（像素 × 像素）	无人机型号	图像数量
2024－06－04	香禾优 9518	齐穗期	5 742 × 3 648	DJI Mavic 2	400
2024－06－07	香禾优 908	齐穗期	3 840 × 2 160	M300 RTK、DJI Mini 4k	400
2024－06－12	珍野优粤芽丝苗	齐穗期	3 840 × 2 160	DJI Mini 4k	400

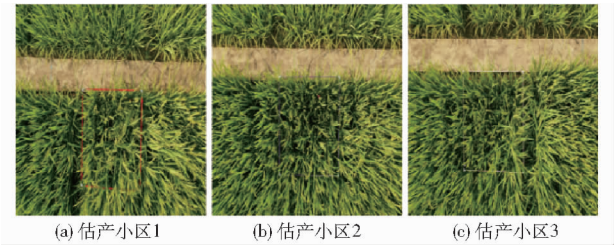
(a) 估产小区1　(b) 估产小区2　(c) 估产小区3

图 2　估产小区例图

Fig. 2　Display diagrams of yield estimation plots

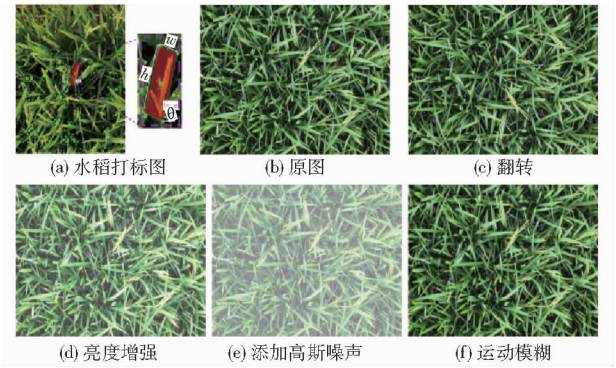
(a) 水稻打标图　(b) 原图　(c) 翻转

(d) 亮度增强　(e) 添加高斯噪声　(f) 运动模糊

图 3　数据预处理

Fig. 3　Data preprocessing

1.3　基于 YOLO v8s－obb 稻穗目标检测改进模型

稻穗检测属于小目标检测领域，针对其特性，本研究从多尺度特征融合、增大感受野、引入注意力机制 3 方面优化模型架构[21－25]。通过整合多尺度特征以优化大小目标感知，扩大图像信息范围以强化复杂结构目标识别定位，自适应分配注意力聚焦关键信息、提升处理效率，进而提高稻穗检测的精度与鲁棒性。

YOLO 系列作为目标检测领域的典型模型，架构由骨干网络（Backbone）、颈部结构（Neck）和头部预测层（Head）组成。针对稻穗检测难题，本研究基于 YOLO v8s－obb 模型进行改进（见图 4），在骨干网络以 C2f_DCNv4 模块替换 C2f 模块，利用可变形卷积的动态感受野，提升复杂田间背景下稻穗识别精度；将 Neck 中的 Conv 模块换为 GSConv 模块，强化多尺度特征融合，提升模型对稻穗上下文信息的感知，抑制背景干扰；在 SPFF 池化模块后引入 EPSANet 注意力机制，助力模型聚焦不同尺度关键特征，捕捉稻穗细节，实现性能提升与高计算效率的平衡；在检测头前引入 DAT 注意力机制，作为 C2f 与 Detect 之间的桥梁，优化特征传递，增强密集目标的定位能力，捕捉长距离依赖并自适应加权，减少稻穗密集场景下的定位偏差。

1.3.1　C2f_DCNv4 模块

在 YOLO v8s－obb 骨干网络的 C2f 模块中引入 DCNv4（Deformable convolution v4）可变形卷积[26]，有效提升了水稻目标检测的精度与鲁棒性。DCNv4 通过动态学习卷积核采样位置的偏移量，使模型能够自适应稻穗的细长、不规则形态及其密集分布特性，有效解决了传统卷积在捕捉小目标和复杂几何

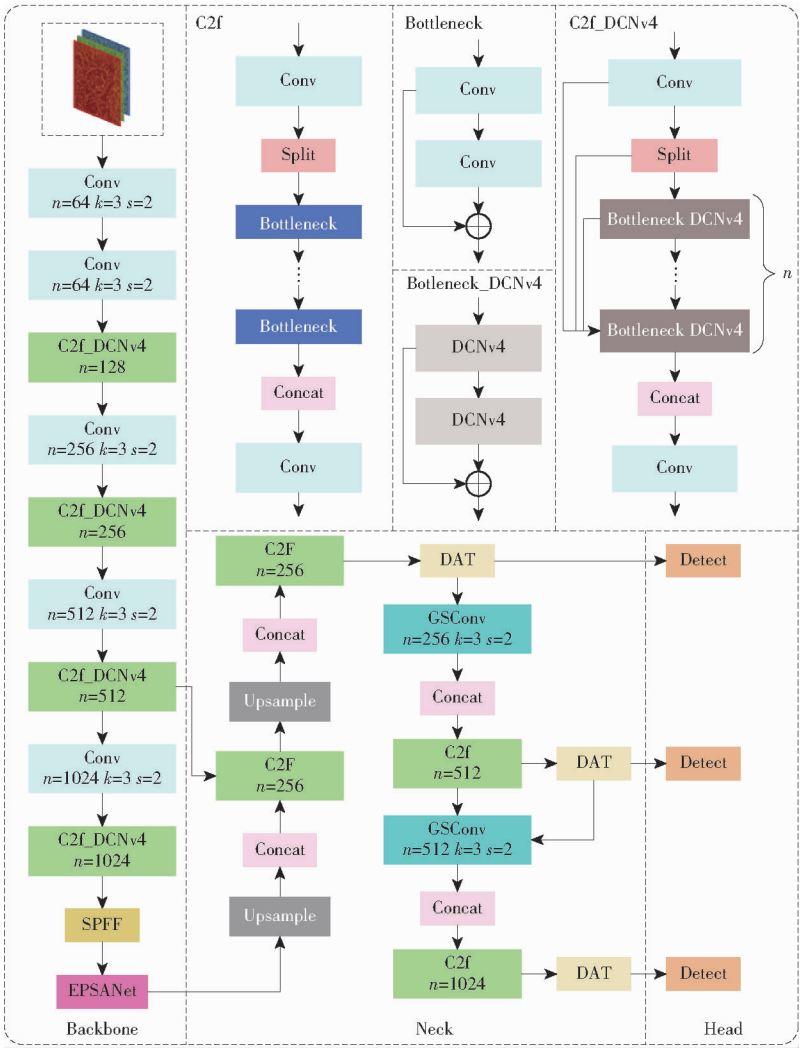

图 4 基于 YOLO v8s－obb 稻穗目标检测改进模型

Fig. 4 Improved model for rice panicle target detection based on YOLO v8s－obb

特征时的局限性。具体实现上，DCNv4 替换了 C2f 模块的传统卷积，形成全新的 C2f_DCNv4 模块，进一步增强模型的特征提取能力。这一改进有效提升了模型在复杂田间环境中的稻穗检测性能，其结构如图 4 所示。

1.3.2 GSConv 卷积替换

Neck 中以 GSConv 替换 Conv 模块，通过 Shuffle 操作融合 SC 的密集通道信息与 DSC 的稀疏特征，增强稻穗特征通道交互并保留通道隐藏连接，提升特征表达丰富性。该设计使特征图质量接近标准卷积，有效提升稻穗检测精准度。

1.3.3 注意力机制 EPSANet

YOLO v8s－obb 的 Backbone 部分在 SPFF 模块后引入了 EPSANet 注意力机制，以提升水稻目标检测的性能。EPSANet 通过金字塔分割将输入特征图分解为多尺度子特征图，并结合多尺度注意力机制动态计算各区域的权重，从而增强模型对稻穗关键特征的捕捉能力。这种机制在针对稻穗的小目标、密集分布和复杂背景场景中，能够有效提取局部细节和全局上下文信息，同时抑制背景干扰。通过在 SPFF 模块后引入 EPSANet，模型有效提升了多尺度特征的表达能力，增强了检测精度和鲁棒性。

1.3.4 注意力机制 DAT

在检测头之前引入引入可变性注意力机制——DAT 注意力机制，以提升水稻目标检测的性能。DAT 通过动态学习偏移量，调整注意力区域，使其适应稻穗特性。这种机制在捕捉小目标和复杂几何特征时表现良好，同时通过多尺度注意力增强局部细节和全局上下文信息的表达能力。在检测头之前引入 DAT，能够优化特征图，使模型更聚焦于稻穗的关键区域，抑制背景干扰，从而有效提升检测精度和鲁棒性。

1.4 建立 NPRP－A 水稻株单穗质量模型

在水稻生产中，由于资源竞争和株间影响，单株水稻的株单穗质量与株穗数通常呈负相关。此外，每株水稻的株单穗质量还与比邻和对角线水稻株的总穗数呈负相关。因此，利用 1.3 节获取的稻穗识别旋转框中心点坐标，构建了 NPRP－A 水稻株单穗

质量模型，用于估计大田二维图像范围内每株水稻的株单穗质量。

1.4.1　人工采集水稻株穗数和株单穗质量

为建立有效的 NPRP－A 水稻株单穗质量模型，首先在各估产小区（图 2）中按株采集穗头数量和 3 个稻穗干质量（水稻完全脱水后的质量）。然后，将 1 号估产小区 20 株水稻的平均穗质量与穗数进行对齐，并使用 Min－Max 归一化映射至[0，1]区间。最后，按比例 7∶2∶1 将 20 株水稻划分为训练集（14 株）、验证集（4 株）和测试集（2 株），并保存对应数据。

1.4.2　NPRP－A 水稻株单穗质量模型

如图 5 所示，本文所建立的 NPRP－A 水稻株单穗质量模型包含 NP－TNPA－TNPD 解算模块和 NAR 神经网络模型，其中 NP－TNPA－TNPD 解算模块使用高斯核密度估计法对 1.3 节得到的稻穗旋转框中心点坐标（即稻穗的初始位置）进行迭代优化，并解算出每株水稻的水稻株穗数 N_P、相邻水稻株穗数 T_{NPA} 和对角水稻株穗数 T_{NPD}。迭代优化公式为

$$[X_{PRP_{in}}\ Y_{PRP_{in}}] = \frac{\sum_{k=1}^{N'}[X_{PRP_{io}}^{(k)}\ Y_{PRP_{io}}^{(k)}]\exp\left(-\frac{\|[X_{PRP_{io}}^{(k)}\ Y_{PRP_{io}}^{(k)}]^{\mathrm{T}}-[X_{PRP_{io}}\ Y_{PRP_{io}}]^{\mathrm{T}}\|^2}{2\sigma^2}\right)}{\sum_{k=1}^{N'}\exp\left(-\frac{\|[X_{PRP_{io}}^{(k)}\ Y_{PRP_{io}}^{(k)}]^{\mathrm{T}}-[X_{PRP_{io}}\ Y_{PRP_{io}}]^{\mathrm{T}}\|^2}{2\sigma^2}\right)} \tag{1}$$

式中　$(X_{PRP_{in}}, Y_{PRP_{in}})$——第 i 个穗头坐标优化值

$X_{PRP_{io}}$——第 i 个穗头初始位置 X 坐标

$Y_{PRP_{io}}$——第 i 个穗头初始位置 Y 坐标

$\exp(\ )$——高斯核函数

σ——核函数带宽参数

N'——相邻穗头数量

在迭代中，使用均方误差（MSE）衡量当前模型输出的穗头位置与实际密度场之间的误差，利用梯度下降法来更新穗头位置，满足阈值，迭代停止。

而 NAR 神经网络模型则通过改进的粒子群算法（PSO）自动优化径向基函数（RBF）神经网络参数，实现水稻株穗数、比邻水稻株总穗数、对角线水稻株总穗数与株单穗质量之间的非线性映射，从而提升水稻估产的准确性。NAR 神经网络模型的数学表达式为

$$\hat{y} = \Psi\left(\sum_{j=1}^{n} w_j \Phi_j([N_P \quad T_{NPA} \quad T_{NPD}]^{\mathrm{T}})\right) + \epsilon \tag{2}$$

其中　$$\Phi_j(X) = \exp\left(-\frac{1}{2}\sum_{k=1}^{3}\frac{(X_k - c_{jk})^2}{\sigma_{jk}^2}\right) \tag{3}$$

式中　$\hat{y}$——水稻株单穗质量

$\Psi(\ )$——输出激活函数

N_P——模型输入的单株稻穗数

T_{NPA}——相邻水稻株穗数

T_{NPD}——对角水稻株穗数

ϵ——系统误差项

Φ_j——可调协方差高斯核函数

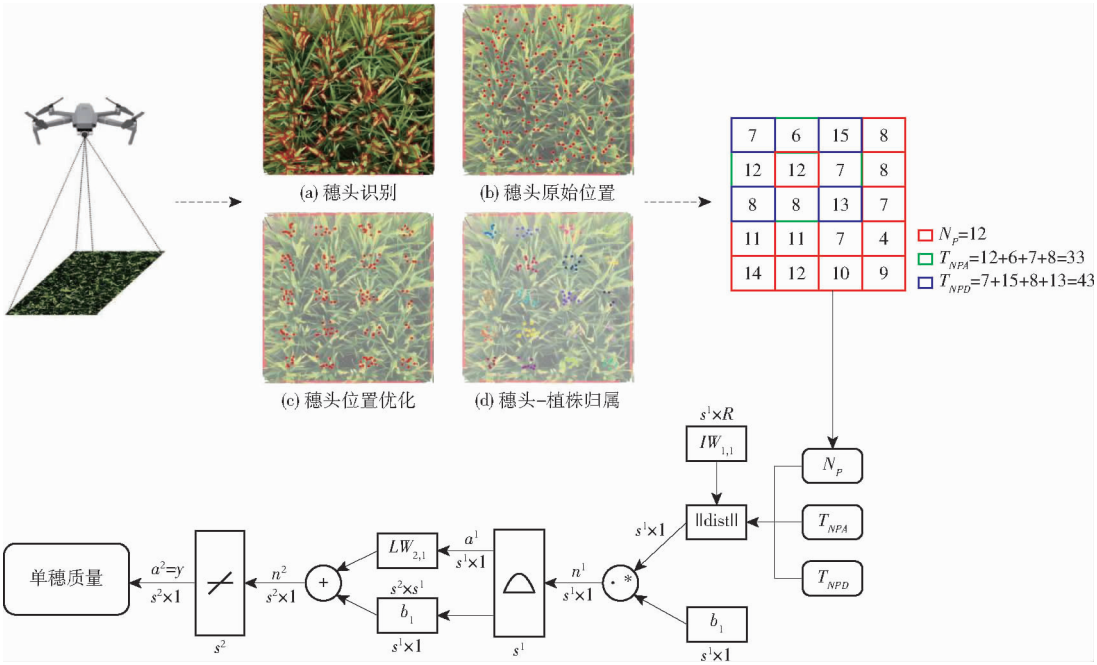

图 5　单穗质量建模图

Fig. 5　Single panicle mass modeling diagram

w_j——连接权重

c_{jk}——第 j 个高斯核函数在第 k 个输入特征维度上的中心坐标

σ_{jk}——协方差参数

式(2)和式(3)中,c_{jk}、σ_{jk}^2、w_j通过改进型 PSO 优化器实时调整,所述改进型 PSO 优化器包含 3 层解算,其中,粒子编码、动态调节和速度更新公式分别为

$$\boldsymbol{P}_i = [\boldsymbol{c}_1^{\mathrm{T}} \quad \cdots \quad \boldsymbol{c}_8^{\mathrm{T}} \quad \sigma_{11} \quad \cdots \quad \sigma_{83} \quad w_1 \quad \cdots \quad w_8]^{\mathrm{T}} \in \mathbf{R}^{56} \tag{4}$$

式中 $\boldsymbol{c}_j^{\mathrm{T}}$——中心点向量

$$\begin{cases} \Omega(t) = 0.9\,\mathrm{e}^{-0.002t} \\ c_1(t) = 2.5 - 1.5(t/T)^{0.5} \\ c_2(t) = 1.5 + 2(t/T)^{0.3} \end{cases} \tag{5}$$

式中 Ω——衰减因子

c_1——认知因子 c_2——社会因子

t——当前迭代次数

T——最大迭代次数

$$v_i^{t+1} = \Omega(t)v_i^t + c_1(t)r_1(pbest_i^t - x_i^t) + c_2(t)r_2(gbest_i^t - x_i^t) \tag{6}$$

式中 $pbest$、$gbest$——$\{\boldsymbol{c}_j, \sigma_{jk}^2, w_j\}$参数的局部最优解

r_1、r_2——随机选取的种群个体

v_i^t——第 i 个粒子在第 t 次迭代时的速度

1.5 总产量计算

为实现水稻的精准估产,将 1.4 节得到的水稻株穗数输入所建立的 NPRP-A 水稻株单穗质量模型中,得到水稻田间二维图像中每株水稻的株穗数和株单穗质量,并累加解算估产区域的水稻总产量。其计算公式为

$$M_{total} = K\sum_{i=1}^{N}\rho_i m_i \tag{7}$$

式中 M_{total}——估产区域的水稻总产量

N——估产区域内水稻株数

ρ_i——第 i 株水稻的水稻株穗数

m_i——第 i 株水稻的株单穗质量

K——环境修正参数,其值由灌浆期日均温度、夜间湿度、极端高温天数等加权决定

2 结果与分析

2.1 稻穗目标检测结果与分析

2.1.1 模型训练和测试平台

水稻检测模型在以下环境训练、验证和检测:Intel Xeon Gold 6226R CPU (2.5 GHz), 192 GB RAM, NVIDIA RTX 4060 GPU (24 GB 显存容量), CUDA 11.8, PyTorch 2.4.1 (Python 3.8)。使用 OpenCV 4.6.0.66 和 PyCharm 作为开发环境,模型训练共 200 个迭代周期。

2.1.2 评价指标

采用精确度、召回率以及 IoU 阈值为 0.50 时的平均精度(Average precision at IoU threshold 0.50, AP50)作为模型的评价指标。这些指标的数值越大,表明模型的检测性能越优。

2.1.3 消融实验

为评估模型性能提升,以 YOLO v8s 为基线,设计消融实验,逐步添加 C2f_DCNv4、GSConv、EPSANet 和 DAT 模块。实验首先验证 DCNv4 对小目标稻穗特征提取的贡献;然后,在 DCNv4 基础上,分别引入 GSConv 增强跨尺度特征融合,EPSANet 优化关键区域注意力,DAT 提升密集场景空间特征表达。最后,集成所有模块评估综合性能。采用精确度、召回率和 AP50 在标准稻穗数据集上进行定量评估(表 2)。

表 2 消融实验结果

Tab. 2 Ablation experiments %

序号	YOLO v8s-obb	C2f_DCNv4	GSConv	EPSANet	DAT	精确度	召回率	AP50
1	√					88.5	86.4	89.7
2	√	√				90.6	86.5	91.7
3	√	√	√			92.3	91.4	95.4
4	√	√	√	√		93.6	92.0	96.0
5	√	√	√	√	√	95.1	93.4	96.7

注:"√"表示该模型所包含的改进策略。

消融实验结果(表 2)表明,渐进式模块融合能有效提升模型性能。YOLO v8s-obb 基线模型已具备基础检测能力(AP50 为 89.7%)。引入 C2f_DCNv4 后,模型 AP50 提升至 91.7%。随后加入 GSConv 模块,性能得到增强,AP50 大幅提升至 95.4%,同时召回率提升了 4.9 个百分点。接着集成 EPSANet 模块,AP50 进一步提升至 96.0%。最终,在集成 DAT 模块后,模型达到最佳性能,AP50 达 96.7%,相较于基线模型累计提升了 7 个百分点,同时精确率和召回率也分别提升了 6.6、7.0 个

百分点。这些结果证明，各模块通过优化特征提取、增强信息融合及其他机制，协同作用有效提升了模型的整体检测精度。

2.1.4　主流稻穗检测模型的比较

为评估稻穗目标检测的准确性，将本研究所述检测模型（后称为“改进 YOLO v8s－obb”）与主流模型（YOLO v8s－obb、YOLO v9s）及实验室前期模型 YOLO v5－pro[14] 的识别效果进行理论数据对比，对比实验保持环境一致（相同数据集、分辨率、训练轮数和评估指标精确度、召回率、AP50），结果如表 3 所示。

实验结果表明，改进 YOLO v8s－obb 在精确度、召回率和 AP50 指标上均达到最优（分别为 95.1%、93.4% 和 96.7%），展现出高精度和稳定性。如图 6 所示，在复杂环境（光照变化、叶片遮挡、穗头交错、图像模糊）下的对比结果表明，改进 YOLO v8s－obb 在各种情况下均优于其他模型。具体而言，在弱光照下，改进 YOLO v8s－obb 和 YOLO v5－pro 精度较高，而 YOLO v8s－obb 和 YOLO v9s 出现漏检或误检；在强光照下，YOLO v9s 和 YOLO v5－pro 出现漏检；在叶片遮挡和穗头交错情况下，改进 YOLO v8s－obb 表现稳定，其他模型则出现性能下降；此外，改

表 3　主流水稻稻穗检测模型的比较

Tab. 3　Comparison of mainstream rice panicle detection models　%

模型	精确度	召回率	AP50
YOLO v5－pro	94.0	92.5	96.4
YOLO v8s－obb	88.5	86.4	89.7
YOLO v9s	87.1	84.6	89.6
改进 YOLO v8s－obb	95.1	93.4	96.7

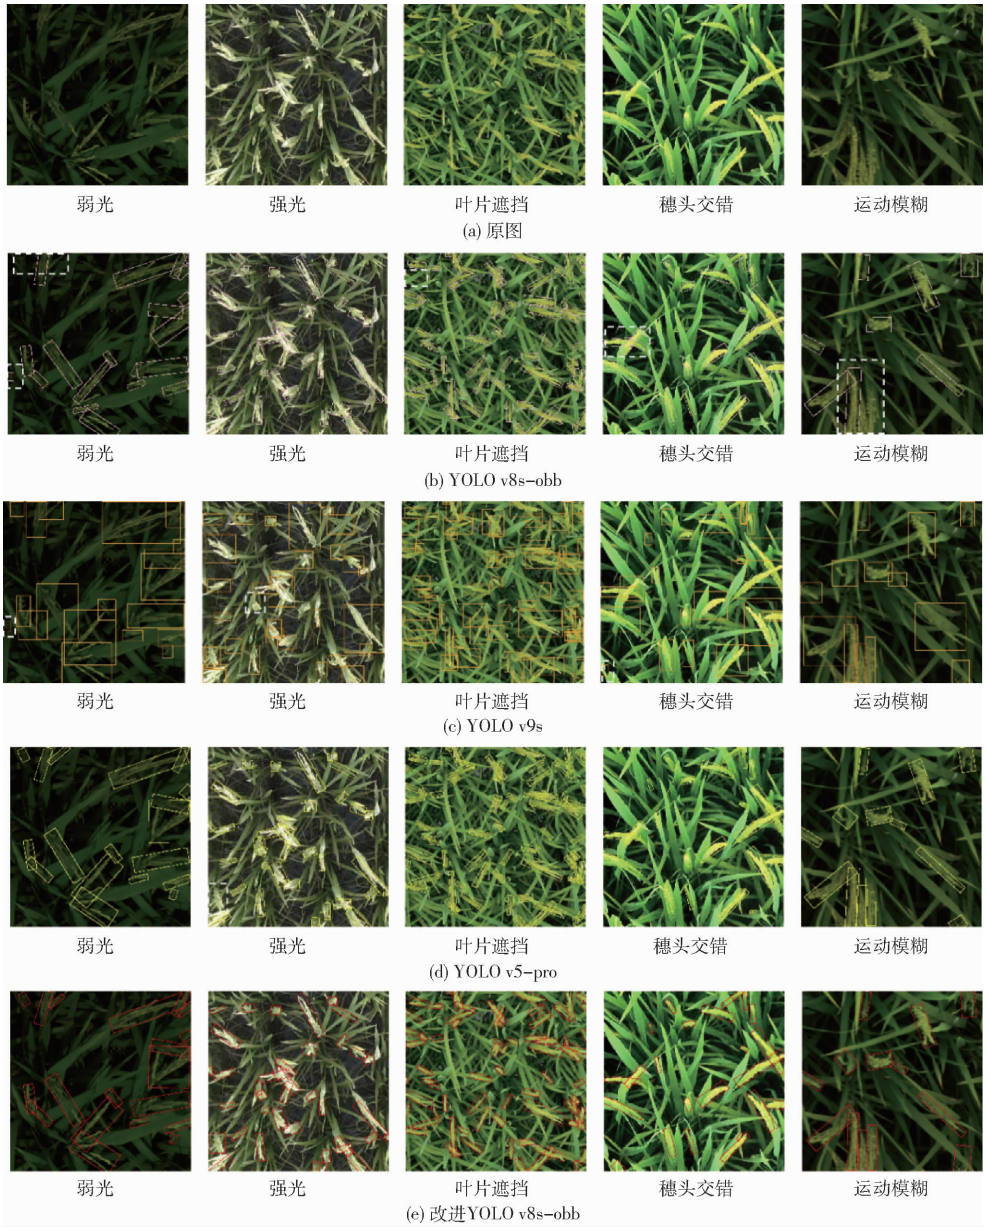

图 6　主流稻穗检测模型识别效果比较

Fig. 6　Comparison of recognition performance among mainstream rice panicle detection models

进 YOLO v8s－obb 对图像模糊具有一定的鲁棒性。综上，改进 YOLO v8s－obb 在复杂环境下能有效识别稻穗。

2.2 NPRP－A 水稻株单穗质量模型解算结果验证与分析

本研究提出的水稻株穗数解算方法，结合了目标检测模型识别框信息解算、基于密度场分析的迭代算法优化以及水稻株穗数解算，从多个环节逐步提高了稻穗位置定位和水稻株穗数解算的准确性。

为验证本文所提出的水稻株穗数解算方法的准确性，将 2.2.1 节所示 3 个估产小区的水稻株穗数解算结果与人工田间采集水稻株穗数进行对比分析，对比结果如图 7 所示。

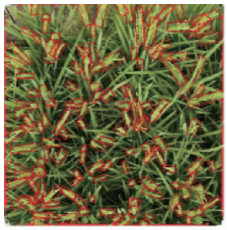

7	12	8	6
3	6	11	8
4	11	10	10
4	10	12	10
6	9	8	9

6	12	7	6
5	6	11	7
2	12	12	11
5	10	13	11
5	7	6	9

1	0	1	0
−2	0	0	1
2	−1	−2	−1
−1	0	−1	−1
1	2	2	0

图像检测效果　水稻植株的穗数计算结果　水稻植株穗数的人工采集结果　水稻植株穗数的对比误差

(a) 估产小区1

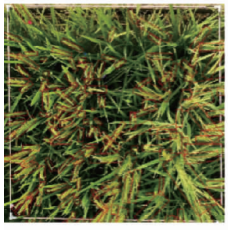

4	7	6	5
6	7	10	9
8	9	11	9
8	7	12	11
5	5	10	8

6	7	7	4
6	7	9	10
9	7	11	8
7	9	11	9
5	6	11	8

−2	0	−1	1
0	0	1	−1
−1	0	0	1
1	−2	1	2
0	−1	−1	0

图像检测效果　水稻植株的穗数计算结果　水稻植株穗数的人工采集结果　水稻植株穗数的对比误差

(b) 估产小区2

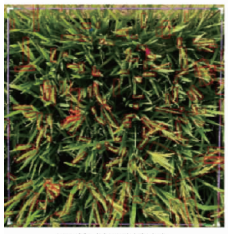

4	3	4	5
6	10	10	5
9	12	11	8
3	7	8	7
4	7	9	7

5	3	4	4
7	10	9	5
8	13	13	8
3	9	10	8
3	6	8	7

−1	0	0	1
2	0	1	0
1	−1	−2	0
0	−2	−2	−1
0	1	1	0

图像检测效果　水稻植株的穗数计算结果　水稻植株穗数的人工采集结果　水稻植株穗数的对比误差

(c) 估产小区3

图 7　水稻株穗数解算与人工田间采集结果对比图

Fig. 7　Comparison charts of rice panicle number calculation results and manual field collection results

对比结果表明，3 个估产小区的株穗数解算误差均小于 2 个，说明本方法能准确提取各株水稻的稻穗数量。为进一步验证该方法的有效性，对模型解算的株穗数和人工采集的株穗数进行了双样本 F 检验方差分析，结果显示，模型计算的单株稻穗数平均值为 7.72，标准差为 2.57；人工采集的单株稻穗数平均值为 7.72，标准差为 2.69。双样本 F 检验方差分析中，F 值为 1.524 9，P 值为 0.721 0（>0.05）。这表明两者在统计学上无显著差异。综上所述，本研究提出的株穗数解算方法能够准确提取各株水稻上的稻穗个数。

为评估本文所建立的 NPRP－A 水稻株单穗质量模型性能，将 2.2.1 节所示估产小区 2 和估产小区 3 的水稻株穗数解算结果输入 NPRP－A 水稻株单穗质量模型中，得到两个估产小区各 20 株水稻的株单穗质量的对比，如图 8 所示。对比结果显示，40 株水稻的株单穗质量模型解算结果误差平均值为 0.567 g，最大误差为 1.493 g。为进一步验证，对模型解算结果和人工采集结果进行了正态性检验、方差齐性检验和独立样本 t 检验，结果显示，模型计算的单株穗质量平均值为 4.596 g，正态性检验 P 值为 0.796 1；人工采集的单株穗质量平均值为 5.018 g，正态性检验 P 值为 0.416 9。方差齐性检验 P 值为 0.344 4。独立样本 t 检验结果表明，模型解算结果和人工采集结果在统计学意义上无显著差异（$H=0$，$P=0.132\ 6>0.05$）。综上所述，NPRP－A 水稻株单穗质量模型可以有效且准确地解算出水稻株单穗质量。

2.3 水稻估产方法应用结果与分析

为验证本研究提出的水稻估产方法在田间实际应用中的有效性，选取了 3 个水稻估产小区开展产量估算实验。待水稻成熟后，通过人工方式分别测量了各小区的平均穗质量和实际产量。基于实验室前期研究成果[14]，采用 1.3 节所述的改进 YOLO

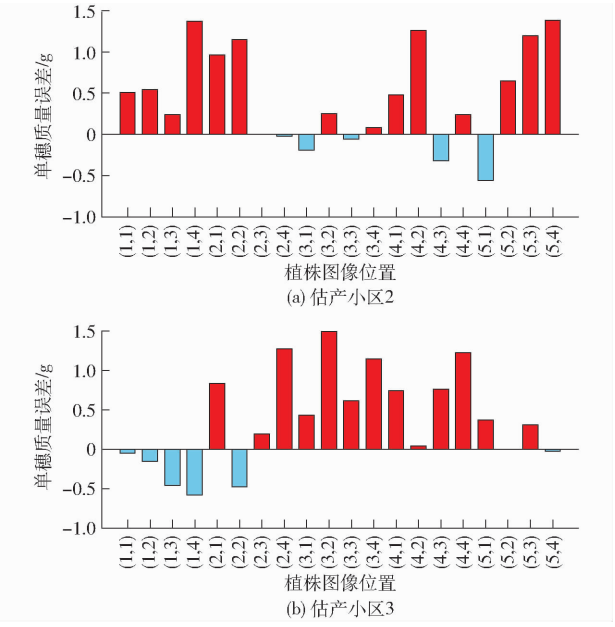

图 8　水稻株穗数解算与人工田间采集结果对比分析

Fig. 8　Comparison analysis chart of rice panicle number calculation results and manual field collection results

v8s－obb 检测模型获取 3 个小区的穗数，并结合平均穗质量得到估产结果 A。同时，运用本文所提出的估产方法对各小区产量进行估算，得到估产结果 B。最终，将估产结果 A、估产结果 B 与实际产量进行详细比较与分析，具体结果如表 4 所示。

表 4 的结果表明，本研究提出的估产方法在 3 个小区上均表现出较好的效果，估算误差均控制在 5.3% 以内，平均误差为 3.3%。其中，香禾优 908 小区的估算误差最小，仅为 2.2%。从估产结果来看，3 个小区的估产结果 B 均高于估产结果 A，说明引入水稻单穗质量参与估产能够有效提升仅依赖穗数估算的精度。由此可见，本研究方法相较于实验室前期采用的估产方法，在估产精度和稳定性方面均有明显提高，展现出应用于实际生产的潜力。

3　结论

（1）针对传统水稻估产效率低、误差大及遥感技术检测小目标的局限性，提出了基于改进 YOLO v8s－obb 目标检测模型和水稻株穗数的估产方法。通过优化模型结构，将主干网络的 C2f 模块替换为动态可变形卷积 C2f_DCNv4，采用轻量化 GSConv 模块优化颈部特征融合，并引入 EPSANet 和 DAT 注意力机制增强多尺度特征捕捉能力，有效提升了稻穗检测精度（AP50 达 96.9%，提升 7 个百分点）。结合密度场迭代优化算法与核密度估计，修正穗头定位偏差，构建水稻密度-单穗质量的二次多项式回归模型，揭示了密度与单穗质量的非线性关系。在 3 个实际田间采样小区中，本方法实现了平均误差 3.3%、最低误差 2.2% 的估产性能。实验结果与人工实收产量高度一致，验证了该方法在小尺度真实产量估算中的有效性。

（2）将旋转目标检测、水稻株穗数与单穗质量差异建模相结合，突破了仅依赖穗数统计的估产局限。无人机平台与改进模型的高效协同，可进一步实现大田环境下稻穗的快速采集与精准分析，为规模化应用奠定基础。

表 4　预估产量与实际产量

Tab. 4　Estimated yield and actual yield

小区编号	品种	长×宽/(m×m)	实际质量/kg	估产结果 A		估产结果 B	
				质量/kg	误差/%	质量/kg	误差/%
1	珍野优粤芽丝苗	1×1	0.790	0.839	6.2	0.832	5.3
2	香禾优 9518	1×1	0.810	0.845	4.3	0.829	2.3
3	香禾优 908	1×1	0.885	0.851	3.8	0.865	2.2

参　考　文　献

[1] DELA TORRE D M G, GAO J, MACINNIS-NG C. Remote sensing-based estimation of rice yields using various models: a critical review[M]//Geo-spatial information science. Taylor and Francis Ltd., 2021: 580－603.

[2] ISLAM M D, DI L, QAMER F M, et al. Rapid rice yield estimation using integrated remote sensing and meteorological data and machine learning[J]. Remote Sensing, 2023, 15(9):2374.

[3] MA C, LIU M, DING F, et al. Wheat growth monitoring and yield estimation based on remote sensing data assimilation into the SAFY crop growth model[J]. Scientific Reports, 2022, 12(1):5473.

[4] ZHANG H, ZHANG Y, LIU K, et al. Winter wheat yield prediction using integrated Landsat 8 and Sentinel－2 vegetation index time-series data and machine learning algorithms[J]. Computers and Electronics in Agriculture, 2023, 213:108250.

[5] WANG J, GAO X, HUANG K, et al. A remote sensing-based method for high-resolution crop water footprint quantification in an irrigation district with complex planting structure[J]. Journal of Hydrology, 2023, 617:108250.

[6] PENG X, HAN W, AO J, et al. Assimilation of LAI derived from UAV multispectral data into the safy model to estimate maize

yield[J]. Remote Sensing, 2021, 13(6):1094.
[7] KANG Y, WANG Y, FAN Y, et al. Wheat yield estimation based on unmanned aerial vehicle multispectral images and texture feature indices[J]. Agriculture, 2024, 14(2):167.
[8] CHATTERJEE S, BAATH G S, SAPKOTA B R, et al. Enhancing LAI estimation using multispectral imagery and machine learning: a comparison between reflectance-based and vegetation indices-based approaches[J]. Computers and Electronics in Agriculture, 2025, 230:109790.
[9] LIU Y, FAN K, MENG L, et al. Synergistic use of stay-green traits and UAV multispectral information in improving maize yield estimation with the random forest regression algorithm[J]. Computers and Electronics in Agriculture, 2025, 229:109724.
[10] GUO Y, HAO F, ZHANG X, et al. Improving maize yield estimation by assimilating UAV-based LAI into WOFOST model [J]. Field Crops Research, 2024, 315:109477.
[11] 胡正东,汤秋香,樊世语,等. 无人机冠层 3D 时序动态建模驱动棉花生物量高精度反演研究[J]. 农业机械学报, 2025, 56(5):103 - 110.
HU Zhengdong, TANG Qiuxiang, FAN Shiyu, et al. UAV-driven 3D spatiotemporal canopy modeling enhanced high-accuracy cotton biomass retrieval[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(5):103 - 110. (in Chinese)
[12] REZA M N, NA I S, BAEK S W, et al. Rice yield estimation based on K-means clustering with graph-cut segmentation using low-altitude UAV images[J]. Biosystems Engineering, 2019, 177: 109 - 121.
[13] LI J, MAGAR R T, CHEN D, et al. SoybeanNet: Transformer-based convolutional neural network for soybean pod counting from unmanned aerial vehicle (UAV) images[J]. Computers and Electronics in Agriculture, 2024, 220:108861.
[14] LIANG Y, LI H, WU H, et al. A rotated rice spike detection model and a crop yield estimation application based on UAV images[J]. Computers and Electronics in Agriculture, 2024, 224:109188.
[15] CHEN Y, XIN R, JIANG H, et al. Refined feature fusion for in-field high-density and multi-scale rice panicle counting in UAV images[J]. Computers and Electronics in Agriculture, 2023, 211:109188.
[16] 吴大霞, 陈世勇, 袁先福,等. 水稻减氮密植研究进展与“极限密植”技术[J]. 植物营养与肥料学报, 2024, 30(10): 2000 - 2012.
WU Daxia, CHEN Shiyong, YUAN Xianfu, et al. Research progress on the synergistic effects of nitrogen nutrition and cultivation density of rice and the “extremely dense planting” technology[J]. Journal of Plant Nutrition and Fertilizers, 2024, 30(10): 2000 - 2012. (in Chinese)
[17] XIONG Y, LI Z, CHEN Y, et al. Efficient deformable convNets: rethinking dynamic and sparse operator for vision applications[C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2024: 5652 - 5661.
[18] LI H, LI J, WEI H, et al. Slim-neck by GSConv: a lightweight-design for real-time detector architectures[J]. Journal of Real-Time Image Processing, 2024, 21(3):62.
[19] ZHANG H, ZU K, LU J, et al. EPSANet: an efficient pyramid squeeze attention block on convolutional neural network[C]// Proceedings of the Asian Conference on Computer Vision, 2022:1161 - 1177.
[20] XIA Z, PAN X, SONG S, et al. DAT + +: spatially dynamic vision transformer with deformable attention[J/OL]. 2023. http://arxiv.org/abs/2309.01430.
[21] TIAN Y, WANG S, LI E, et al. MD-YOLO: multi-scale dense YOLO for small target pest detection[J]. Computers and Electronics in Agriculture, 2023, 213:108233.
[22] ZHANG L, YANG K, HAN Y, et al. TSD-DETR: a lightweight real-time detection transformer of traffic sign detection for long-range perception of autonomous driving[J]. Engineering Applications of Artificial Intelligence, 2025, 139:109536.
[23] CHEN D, LIN F, LU C, et al. YOLOv8 - MDN - Tiny: a lightweight model for multi-scale disease detection of postharvest golden passion fruit[J]. Postharvest Biology and Technology, 2025, 219:113281.
[24] 徐洪丽, 安凤, 史宇轩. 基于改进 YOLO v8 的苹果叶片病害检测研究[J]. 农业机械学报, 2025, 56(10): 530 - 538.
XU Hongli, AN Feng, SHI Yuxuan. Apple leaf disease detection method based on improved YOLO v8[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(10):530 - 538. (in Chinese)
[25] 黄华, 张存东, 张晖旺, 等. 基于 YOLO V8_EGW 的马铃薯种薯芽眼检测方法[J]. 农业机械学报, 2025, 56(8): 458 - 466.
HUANG Hua, ZHANG Cundong, ZHANG Huiwang, et al. Detecting method of potato seed bud eye based on YOLO v8_EGW [J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(8):458 - 466. (in Chinese)
[26] CAI F, QU Z, XIA S, et al. A method of object detection with attention mechanism and C2f_DCNv2 for complex traffic scenes [J]. Expert Systems with Applications, 2025, 267:126141.