

宋现雪, 郑崇珂, 邢凡彬, 等. 基于改进 YOLO11n 的大田稻穗检测与计数[J]. 江苏农业学报, 2026, 42(7): 1408-1418.

doi: 10.3969/j.issn.1000-4440.2026.07.012

基于改进 YOLO11n 的大田稻穗检测与计数

宋现雪^{1,2}, 郑崇珂³, 邢凡彬^{1,2}, 王鑫怡^{1,2}, 谢先芝³, 郑纪业^{1,2}, 郑世玲¹, 张霞¹

(1.聊城大学物理科学与信息工程学院, 山东 聊城 252000; 2.山东省农业科学院农业信息与经济研究所, 山东 济南 250100;

3.山东省农业科学院湿地农业与生态研究所, 山东 济南 250100)

摘要: 水稻稻穗的检测与计数对产量估算和品种选育具有重要意义。大田环境下植株密集、稻穗尺寸小, 且常因与叶片交错重叠遮挡严重, 因此在复杂场景中实现稻穗的高精度识别与自动计数面临挑战。为此, 本研究提出一种融合轻量化检测头与高效注意力机制的检测模型 WEL-YOLO, 对原模型 YOLO11n 进行网络结构优化、损失函数改进和模型轻量化。首先, 为提高模型对稻穗的特征提取能力, 在主干部分 C3k2 模块中引入高效多尺度注意力(EMA)机制。其次, 更换损失函数为智能交并比-归一化高斯瓦瑟斯坦距离(WIoU-NWD), 提高定位精度的同时, 解决小目标漏检、误检问题。最后, 引入轻量级可伸缩共享卷积检测头(LSCD), 在保证模型精度的同时进一步降低模型复杂度。在本研究所采用的数据集上进行验证, 结果表明 WEL-YOLO 模型的精确率、召回率、平均检测精度分别为 87.1%、81.6%、90.0%; 与基准模型相比, 精确率和平均检测精度分别提升 1.6 个百分点和 0.9 个百分点; 模型参数量、计算复杂度和模型权重分别降低 6.2%、11.1%、7.3%; 均方根误差、平均绝对误差、计数准确率分别为 5.59、4.15、80.17%。结果表明, WEL-YOLO 模型在提升稻穗检测性能的同时显著降低资源消耗, 为水稻稻穗计数的轻量化提供了参考。

关键字: 稻穗计数; 轻量化目标检测; 注意力机制; YOLO

中图分类号: S126 **文献标识码:** A **文章编号:** 1000-4440(2026)07-1408-11

Field rice panicle detection and counting based on improved YOLO11n

SONG Xianxue^{1,2}, ZHENG Chongke³, XING Fanbin^{1,2}, WANG Xinyi^{1,2}, XIE Xianzhi³, ZHENG Jiye^{1,2}, ZHENG Shiling¹, ZHANG Xia¹

(1.School of Physical Science and Information Engineering, Liaocheng University, Liaocheng 252000, China; 2.Institute of Agricultural Information and Economics, Shandong Academy of Agricultural Sciences, Jinan 250100, China; 3.Institute of Wetland Agriculture and Ecology, Shandong Academy of Agricultural Sciences, Jinan 250100, China)

Abstract: The detection and counting of rice panicles are crucial for yield estimation and variety breeding. In field conditions, dense plant growth, small panicle sizes, and severe overlapping with leaves create challenges for high-precision recognition and automatic counting in complex scenarios. To address this, this study proposed a detection model WEL-YOLO, integrating a lightweight detection head and an efficient attention mechanism. The model optimized the network architecture, improved the loss function, and reduced computational complexity compared to the original YOLO11n. First, the C3k2 module in the main trunk introduced an EMA (Efficient multi-scale attention) mechanism to enhance panicle feature extraction. Second, the loss function was replaced with WIoU-NWD (Wise intersection over union-normalized Gaussian Wasserstein distance), which improved localization accuracy while ad-

收稿日期: 2025-10-27

基金项目: 国家重点研发计划项目(2024YFF1000401)

作者简介: 宋现雪(2002-), 男, 山东菏泽人, 硕士研究生, 主要研究方向为智慧农业。(E-mail) 15264027846@163.com

通讯作者: 谢先芝, (E-mail) xzhxie2010@163.com; 郑纪业, (E-mail) jiyezheng@163.com; 郑世玲, (E-mail) zhengshiling@lcu.edu.cn

dition, improved the loss function, and reduced computational complexity compared to the original YOLO11n. First, the C3k2 module in the main trunk introduced an EMA (Efficient multi-scale attention) mechanism to enhance panicle feature extraction. Second, the loss function was replaced with WIoU-NWD (Wise intersection over union-normalized Gaussian Wasserstein distance), which improved localization accuracy while ad-

addressing the missed detection and false detection of small objects. Finally, the introduced lightweight scalable shared convolutional detection head (LSCD) further reduced model complexity without compromising accuracy. In the dataset analyzed, the WEL-YOLO model achieved 87.1% accuracy, 81.6% recall, and 90.0% average detection precision, representing 1.6 and 0.9 percentage points improvement in accuracy and average detection precision over the baseline model, respectively. The model demonstrated 6.2% reduction in parameter quantity, 11.1% decrease in computational complexity, and 7.3% reduction in weight values. Its performance metrics included 5.59 root mean square error, 4.15 mean absolute error, and 80.17% count accuracy. These results demonstrate that WEL-YOLO enhances rice panicle detection performance while significantly reducing resource consumption, providing valuable insights for lightweight and practical applications in rice panicle counting.

Key words: rice panicle counting; lightweight object detection; attention mechanism; YOLO

2024 年中国水稻产量约 2.075×10^8 t, 约占全年粮食总产量的 28.75%。水稻是主要的粮食作物之一, 科学准确地预估水稻的产量对于国家粮食管理策略、农业生产规划的制定以及应对潜在的粮食危机有着至关重要的作用^[1-2]。水稻穗数是估产的一项重要指标, 准确获取田间单位面积的水稻穗数是水稻正确估产的重要前提和基础^[3-5]。然而, 靠传统的人工统计单位面积穗数费时费力, 且极易受主观因素干扰而导致重穗、漏穗, 进而影响统计结果的准确性。因此, 建立快速统计水稻单位面积穗数的方法对于节省劳动力、提高估产精度与效率具有重要意义。

随着计算机视觉的快速发展, 深度学习技术已逐步应用于农业对象计数研究^[6-9]。鲍文霞等^[10]提出基于 TPH-YOLO 的麦穗计数方法, 通过引入坐标注意力机制、Transformer 预测头及迁移学习策略, 有效提升了无人机图像中高密度麦穗检测精度, 平均精确率达 88.8%。王宏乐等^[11]通过对比 YOLOv5 与 YOLOv7 模型, 验证了 YOLOv7 在细小密集目标检测任务中的优越性。在梗稻检测中, 该模型交并比 (IoU) 阈值为 0.25 时的平均精度 ($mAP_{0.25}$) 达 93.01%。然而模型交并比阈值较低, 可能导致定位精度不足, 甚至出现同一稻穗被多次重复检测的问题。Ramachandran 等^[12]提出基于边界敏感知识蒸馏 (BSKD) 的方法, 通过教师模型 (ResNet50+边界机制) 与轻量学生模型 (ResNet18) 的特征蒸馏, 结合模仿掩码聚焦前景, 显著提升无人机图像中边缘小稻穗的检测性能, 平均精度 (mAP) 达 76.3%, 优于教师模型, 兼顾到精度与效率。张远琴等^[13]改进了 Faster R-CNN, 将稻穗检测平均精度均值提升至 80.3%, 有效改善了小目标与多尺度检测问题, 但模型结构复杂, 限制了其在边缘设备上的部署应用。

蔡竹轩等^[14]通过在 YOLOv5l 中引入高效通道注意力机制 (ECA) 并前置于空间金字塔池化 (SPP) 模块, 有效增强了小目标稻穗的特征表达。基于深度学习的农业对象计数已取得一定成效, 并逐渐成为主流^[15-19]。然而, 水稻稻穗因具有形态微小、姿态各异且分布密集的特性, 植株间重叠交叉现象显著; 同时, 稻穗与背景在颜色、纹理上高度相似, 导致计数时误检、漏检问题依然存在^[20-21]。本研究拟通过改进 YOLO11n 网络模型中的 C3k2 模块, 增强对小目标的特征提取能力; 优化损失函数, 提升边界框的定位精度, 有效减少误检、漏检; 同时改进检测头结构, 实现模型轻量化, 便于在无人机等边缘设备上高效部署, 实现基于稻穗精准计数的水稻无损估产。

1 材料与方法

1.1 数据集构建

本研究采用飞桨 AI Studio 平台上公开的水稻穗数据集, 由 green_zone 发布 (访问链接: <https://aistudio.baidu.com/datasetdetail/200299/2>)。该数据集涵盖水稻抽穗期、扬花期和乳熟期 3 个关键生育阶段, 图像采集于真实田间环境, 包含多种拍摄角度, 能够有效反映实际稻穗计数场景的复杂性。其中水稻生育时期样本如图 1 所示。

经严格数据清洗 (剔除模糊、曝光异常、有效目标过少或标注不完整的样本) 后, 最终保留 1 000 张高质量图像。所有图像原始分辨率为 $1\,066 \times 800$, 输入模型前统一缩放至 640×640 。数据集背景以密集水稻叶片为主, 部分图像含浅水层, 叶面反光与水珠常见, 稻穗普遍受相邻叶片及其他稻穗遮挡。

1.2 特征标注与处理

在实际大田稻穗计数场景中, 常面临光照变化、噪声干扰和目标遮挡等问题, 为提升检测模型的泛化

能力,本研究对原始数据集进行数据增强,包括添加高斯噪声和随机调整亮度,并在训练过程中引入 Mix-up(混合系数设为 0.2)和 Mosaic(启用概率设为 1.0)

数据增强策略。所有稻穗均使用 Labelimg 软件进行实例级边界框标注,共标记稻穗 30 608 个。将增强后的图像数据按 8 : 2 随机划分为训练集和验证集。




图 1 水稻生育时期样本示例

Fig.1 Sample of rice growth period

2 稻穗检测与计数方法

2.1 YOLO11 模型

YOLO11^[22]是 Ultralytics 团队在 YOLOv8 基础上进行重要设计更新后的模型,其核心创新在于引入可灵活选择结构的 C3k2 模块替换 YOLOv8 中的 C2f 模块,并添加集成注意力机制的 C2PSA 模块,显著增强了模型在复杂场景下的特征提取与小物体检测能力。同时,它通过采用深度可分离卷积和无非极大值抑制(NMS)端到端训练等策略,大幅降低了计算开销和延迟。根据不同场景需求,YOLO11 提供 YOLO11n、YOLO11s、YOLO11m、YOLO11l、YOLO11x 5 个版本,其中最轻量的 YOLO11n 版本平衡了精度与速度,适合部署在计算资源受限的边缘设备上,实现高效实时的目标检测。综合考量模型的精度与速度,以及模型部署成本等因素,本研究选用 YOLO11n 作为基准模型。

2.2 WEL-YOLO 模型整体架构

针对实际稻田中存在严重遮挡、稻穗目标较小、与背景高度相似,以及边缘部署等问题,本研究对 YOLO11n 进行了 3 个方面的改进,提出了 WEL-YOLO 模型,在保证轻量化的同时提升模型的精度。首先在 C3k2 模块嵌入高效多尺度注意力(EMA)机制,以增强模型对于被遮挡的小目标的特征提取能力。使用轻量级可伸缩共享卷积检测头(LSCD)替换 YOLO11n 原检测头,在保证模型精度的同时减少模型大小以及参数计算量,以便于边缘部署。将原


损失函数修改为智能交并比-归一化高斯瓦瑟斯坦距离(WIoU-NWD),有效提升边界框的定位精度,显著减少漏检,同时通过自适应加权机制抑制样本的异常梯度,降低误检率,增强模型对小目标和密集场景的鲁棒性。WEL-YOLO 模型网络结构如图 2 所示。

2.2.1 C3k2-EMA 模块 C3k2 模块源于 YOLO11 的核心设计,是对网络结构进行轻量化改进的成果。然而,在大田稻穗计数任务中,C3k2 模块的表现存在局限。该场景下稻穗目标细小密集,常伴有遮挡与重叠,且受光照变换和复杂背景干扰。虽然 C3k2 模块在特征提取方面有一定优势,但在处理这种复杂场景时,捕获长距离依赖关系和跨尺度上下文信息的能力不足,导致模型对微小稻穗的特征感受不够敏感,容易出现误检与漏检情况,进而影响最终的计数精度。

针对上述问题,本研究采用 C3k2-EMA 模块,它是一种在保留 C3k2 轻量化特性和高效推理优势的基础上,融合高效多尺度注意力机制的改进结构。该模块通过“效率+增强”的协同设计理念,实现轻量化与表征能力的有机结合。C3k2-EMA 以 C3k2 为骨干结构,在其特征变换路径中嵌入 EMA 模块^[23],从而显著增强网络对多尺度特征的感知与融合能力。EMA 机制采用分组卷积与多分支并行结构,利用不同尺度的卷积核同时捕捉局部细节与全局上下文信息。同时通过跨纬度动态权重分配机制,实现通道与空间维度上的联合注意力校准,使网

络能够自适应地聚焦于关键区域,尤其有利于从复杂背景中凸显微小而模糊的稻穗特征。EMA 中较小的卷积核分支擅长提取细粒度局部特征,适用于识别孤立或边缘清晰的小尺度稻穗;而较大的感受野分支则有助于理解重叠区域的整体结构,辅助区

分粘连目标。最终,通过高效的跨分支信息交互与加权融合策略,模型能够在不显著增加计算开销的前提下,大幅度提升对密集小目标检测的鲁棒性。EMA 结构如图 3 所示。




CBS:基础卷积单元;C3k2-EMA:特征提取模块;SPPF:空间金字塔池化模块;C2PSA:通道注意力模块;Upsample:上采样;Concat:拼接模块;C3k2:特征提取模块;Split:分割模块;C3:特征提取模块;Conv:卷积;BatchNorm2d:层归一化;ReLU:激活函数; N :模块数。

图2 WEL-YOLO 网络结构

Fig.2 WEL-YOLO network structure

2.2.2 检测头 轻量级可伸缩共享卷积检测头(LSCD)是一种基于共享卷积与自适应特征缩放的轻量化检测头^[24],旨在降低模型的参数量和计算成本,同时维持原有的检测精度。通过共享卷积减少冗余


计算,并引入自适应特征缩放机制以动态调整多尺度特征的贡献,该设计有效优化了传统检测头的结构,在保障检测性能的同时,显著提升检测效率,更好地平衡了模型轻量化与检测精度之间的关系。



Groups: 分割模块; X AvgPool: X 方向平均池化; Y AvgPool: Y 方向平均池化; Concat+Conv(1×1): 卷积拼接模块; Sigmoid: 激活函数; Re-weight: 重加权; GroupNorm: 分组归一化; Conv(3×3): 标准卷积; Avg Pool: 平均池化; Softmax: 归一化; Matmul: 矩阵乘法; ⊕: 逐元素加法。

图3 EMA 结构

Fig.3 EMA structure



P3、P4、P5: 特征金字塔的第 3、第 4、第 5 层级输出; Conv_GN: 卷积+分组归一化模块; DEConv_GN: 可变形卷积+分组归一化模块; Conv_Reg: 回归卷积; Conv_Cls: 分类卷积; Scale: 尺度缩放因子。


图4 轻量级可伸缩共享卷积检测头 (LSCD) 结构

Fig.4 Lightweight scalable shared convolutional detection (LSCD) structure diagram

LSCD 的轻量化得益于其采用的共享卷积架构。如图 4 所示, LSCD 首先使用 1×1 的 Conv_GN 对 P3、P4、P5 的输出特征图进行卷积与组归一化 (GN) 操作, 将特征图的通道数压缩便于处理前混合特征, 同时保留特征图的空间维度结构。GN 归一化表达如公式 (1) 所示。再将处理过的 3 组数据传入 2 个 3×3 的串联 DEConv_GN 共享卷积层, 相较于 Conv 卷积层, DEConv 通过引入中心差分卷积层 (CDC)、角度差分卷积层 (ADC)、水平差分卷积层 (HDC) 和垂直差分卷积层 (VDC) 增强对边缘、轮廓等高频细节信息的感知。它并行结合 4 个差分卷积层与 1 个普通卷积层提取特征并逐元素相加, 兼顾低频内容与高频细节。为避免参数量增加, DEConv 采用重参数化技术: 训练时并行学习多个卷积核, 推理时将其权重融合为单一等效 3×3 卷积核, 在保证精度的同时提升计算效率。DEConv 网络结构如图 5 所示。经 DEConv_GN 融合后的特征数据分别输入到 Conv_Reg 预测框回归分支和 Conv_Cls 目标分类分支。最后, Scale 层通过一个可学习的缩放因子对 Conv_Reg 层的输出进行逐元素缩放, 动态调整特征大小, 从而稳定预测框回归, 提升训练过程中的定位精度。

$$GN(x) = \frac{x - \mu}{\sqrt{\sigma^2 + \epsilon}} \quad (1)$$

其中, x 是输入特征, μ 是每个组的组内均值, σ^2 是每个组的组内方差, ϵ 是趋近于 0 的常数, 用于保证分母不为 0。



VC: 普通卷积; CDC: 中心差分卷积; ADC: 角度差分卷积; VDC: 垂直差分卷积; HDC: 水平差分卷积。

图5 多尺度特征经细节增强卷积 (DEConv) 结构

Fig.5 Detail-enhanced convolution (DEConv) structure diagram

LSCD 在特征融合部分采用参数共享机制,显著降低计算量与参数规模,多尺度特征经细节增强卷积 (DEConv) 融合,强化边缘、纹理等高频信息表达,提升特征判别力。该设计在保障检测精度的同时增强模型效率,兼顾性能与轻量化,更利于在边缘设备等资源受限场景中部署。

2.2.3 损失函数优化 YOLO11n 使用完整交并比损失 (CIoU) 作为预测框回归损失函数,CIoU 在距离交并比损失 (DIoU) 的基础上引入长宽比惩罚项,综合重叠面积、中心距离和尺度因素,增强对目标框尺寸的约束,使回归更稳定、收敛更可靠,避免了 IoU 和泛化交并比损失 (GIoU) 的训练发散问题。CIoU 损失函数表达式如下:

$$CIoU = IoU - \frac{\rho^2(b, b_{gt})}{c^2} \alpha v \quad (2)$$

$$IoU = \frac{|b \cap b_{gt}|}{|b \cup b_{gt}|} \quad (3)$$

$$\rho^2(b, b_{gt}) = (x_{pred} - x_{gt})^2 + (y_{pred} - y_{gt})^2 \quad (4)$$

$$c = \sqrt{(x_{max} - x_{min})^2 + (y_{max} - y_{min})^2} \quad (5)$$

$$v = \frac{4}{\pi^2} \left[\arctan\left(\frac{w_{gt}}{h_{gt}}\right) - \arctan\left(\frac{w_{pred}}{h_{pred}}\right) \right]^2 \quad (6)$$

$$\alpha = \frac{v}{1 - IoU + v} \quad (7)$$

在上述方程中, IoU 为预测框与真实框的交并比, $\rho(b, b_{gt})$ 为预测框中心点 b 与真实框中心点 b_{gt}

欧氏距离, α 为权衡参数, (x_{pred}, y_{pred}) 是预测框中心点, (x_{gt}, y_{gt}) 是真实框中心点, (x_{min}, y_{min}) 和 (x_{max}, y_{max}) 分别是包围预测框和真实框的最小矩形的左下角和右上角的坐标, w_{pred} 和 h_{pred} 分别是预测框的宽度和高度, w_{gt} 和 h_{gt} 分别是真实框的宽度和高度, v 是长宽比一致性惩罚项, 常数 c 是预测框与真实框的最小外接矩形的对角线的长度。

然而, CIoU 损失函数主要集中在边界框的中心和重叠区域, 小目标的几个像素偏差会对 IoU 和长宽比项造成巨大影响, 产生大梯度, 不利于训练, 且 CIoU 无法区分样本质量, 低质量的异常样本会产生巨大且有害的梯度。因此, 难以实现对稻穗目标的有效检测。针对上述问题, 本研究采用了 Wise-IoU (WIoU) 与归一化 Wasserstein 距离 (NWD) 结合的方法。

WIoU 引入基于“离群度”的注意力机制, 动态降低低质量样本的损失权重, 让模型聚焦于高质量样本, 减少了异常值带来的梯度爆炸风险^[25]。本研究采用 WIoUv3, 计算方法如公式 (8) 所示。

$$L_{WIoUv3} = \gamma L_{WIoUv1} \quad (8)$$

$$\gamma = \frac{\beta}{\delta \alpha^{\beta-\delta}} \quad (9)$$

式中, γ 为基于 β, δ, α 调整的损失函数系数, δ, α 为控制离群度 β 和梯度增益 (r) 映射的超参数。

L_{WIoUv1} 为加权损失函数的第一版, 计算公式为

$$L_{WIoUv1} = R_{WIoU} L_{IoU} \quad (10)$$

$$R_{WIoU} = \exp\left(\frac{(x_{pred} - x_{gt})^2 + (y_{pred} - y_{gt})^2}{(W_1^2 + H_1^2)^*}\right) \quad (11)$$

$$L_{IoU} = 1 - IoU \quad (12)$$

式中, R_{WIoU} 为基于中心点距离的加权因子, L_{IoU} 为 IoU 损失函数, W_1 和 H_1 分别为预测框与真实框最小外接矩形的宽度和高度。

同时采用 NWD^[26] 弥补 WIoU 在小目标上的短板。首先将边界框建模为二维高斯分布:

$$\mu = \begin{bmatrix} c_{xA} \\ c_{yA} \end{bmatrix}, \sigma = \begin{bmatrix} \frac{w_A^2}{4} & 0 \\ 0 & \frac{h_A^2}{4} \end{bmatrix} \quad (13)$$

其中, $N(\mu, \sigma)$ 为边界框高斯分布, (c_{xA}, c_{yA}) 为边界框 A 的中心坐标, w_A, h_A 分别为边界框 A 的宽度和高度。

然后使用 NWD 来度量派生高斯分布的相似度:

$$W_2^2(N_A, N_B) = \left\| \left[\begin{array}{cc} c_{xA} & c_{yA} \\ \frac{w_A}{2} & \frac{h_A}{2} \end{array} \right]^T, \left[\begin{array}{cc} c_{xB} & c_{yB} \\ \frac{w_B}{2} & \frac{h_B}{2} \end{array} \right]^T \right\|_2^2 \quad (14)$$

$$NWD(N_A, N_B) = \exp\left(-\frac{\sqrt{W_2^2(N_A, N_B)}}{C}\right) \quad (15)$$

$$L_{NWD} = 1 - NWD(N_A, N_B) \quad (16)$$

同理, (c_{xB}, c_{yB}) 为边界框 B 的中心坐标, w_B, h_B 分别为边界框 B 的宽度和高度, $W_2^2(N_A, N_B)$ 为高斯分布 N_A 和 N_B 之间的 Wasserstein 距离, $NWD(N_A, N_B)$ 为边界框之间的相似性度量。 L_{NWD} 是基于 NWD 构造的边界框回归损失函数。

NWD 的主要优点为即使没有重叠或重叠微小也可度量分布的相似度, 进而显著提升模型在小目标检测场景下的性能。但 NWD 对不同尺度的物体不敏感, 故与 $WIoU$ 形成互补。

$WIoU$ - NWD 损失函数的计算方法如公式 (17) 所示。

$$L_{WIoU-NWD} = \alpha L_{WIoU} + (1-\alpha) L_{NWD} \quad (17)$$

经试验验证, 式中, α 为常数 0.4、0.5、0.6、0.7、0.8 时, 对应的精确率 (P) 分别为 86.0%、86.1%、86.2%、85.7%、85.8%, 故 α 取值为 0.6。

3 试验配置及评价指标

3.1 试验环境与参数

本研究的硬件配置为: Intel Core i9-14900K 3.20 GHz、NVIDIA GeForce RTX 5060 Ti、16 G 显存。软件配置: Windows 11、64 位操作系统、python3.10、Pytorch 2.8.0、CUDA12.9。参数信息见表 1。

表 1 试验参数

Table 1 Experimental parameters

参数	数值
图像尺度	640×640
批数量	16
迭代次数(次)	200
学习率	0.01

3.2 评价指标

为全面评估本研究在密集小目标检测场景下的性能, 本研究采用了一套多维度的评价体系。首先, 在检测精度方面, 采用精确率 (P)、召回率 (R)、平均精度 (mAP)、综合指标值 ($F1-score$); 在计数精度

方面, 以均方根误差 ($RMSE$)、平均绝对误差 (MAE) 和计数准确率 (相对误差 $\pm 20\%$) 为核心指标, 同时分析了模型内存占用量 ($Model\ size$)、参数量 ($Params$) 及计算量 ($FLOPs$)。公式如下:

$$P = \frac{TP}{TP+FP} \quad (18)$$

$$R = \frac{TP}{TP+FN} \quad (19)$$

$$P_{AP} = \int_0^1 P(R) dr \quad (20)$$

$$P_{mAP} = \frac{1}{n} \sum_{i=1}^n P_{AP} \quad (21)$$

$$F1-score = \frac{2P * R}{(P+R)} \quad (22)$$

式中, TP 表示正确预测的阳性样本的数量, FP 表示被错误预测为阳性的阴性样本数量, FN 表示模型未能检测到的真实阳性样本数量, P_{AP} 为模型平均精度, P_{mAP} 为模型平均精度均值。

4 结果与分析

4.1 损失函数对比试验

为验证 YOLO11n 引入损失函数 $WIoU$ - NWD 在稻穗检测与计数任务中的合理性与有效性, 同时分析不同损失函数对基准模型性能造成的影响, 本研究使用不同损失函数替换 YOLO11n 的损失函数并进行对比试验, 结果如表 2 所示。其中 $CIoU$ 为基准模型损失函数。由表 2 可知, 相较于 $CIoU$ 损失函数, 在基准模型中引入 $DIoU$ 、 $EIoU$ 、 $SIoU$ 、 $WIoU$ 后模型性能均可获得一定程度的提升, 其中引入 $WIoU$ - NWD 损失函数时精确率提升 0.7 个百分点, 召回率提升 2.1 个百分点, $F1-score$ 提升 1.44, 平均精度提升 1.6 个百分点, 模型表现出更好的优化能力。试验结果表明, 采用 $WIoU$ - NWD 替代 $CIoU$ 损失函数能有效提高预测框与真实框的匹配度, 进而减少漏检、误检现象。

表 2 损失函数对比试验

Table 2 Comparison of loss function experiments

损失函数	精确率 (%)	召回率 (%)	$F1-score$	平均精度 (%)
$CIoU$	85.5	80.8	83.08	89.1
$DIoU$	85.6	81.2	83.34	89.5
$EIoU$	85.5	81.5	83.45	89.4
$SIoU$	85.0	81.6	83.26	89.2
$WIoU$	86.3	82.4	84.30	90.4
$WIoU$ - NWD	86.2	82.9	84.52	90.7

$F1-score$: 综合指标值。

4.2 消融试验

为评估 C3k2-EMA、LSCD 与 WIoU-NWD 损失函数对 YOLO11n 模型的改进效果,本研究从检测精度、计数精度与轻量化性能 3 个方面对 WEL-YOLO 进行综合试验验证。检测精度以精确率(P)、召回率(R)、 $F1$ -score 和平均检测精度(mAP)衡量;计数精度采用均方根误差($RMSE$)、平均绝对误差(MAE)以及计数准确率(相对误差 $\pm 20\%$)评价;轻量化效果则以参数量、计算量($FLOPs$)和模型大小作为指标。在相同试验设置下,基于原数据集开展消融试验,结果如表 3 所示。

由表 3 可知,C3k2-EMA、LSCD 与 WIoU-NWD 3 个模块均在不同方面提升了模型的综合性能。其中,WIoU-NWD 对检测精度的提升最为显著,单独使用即可将精确率提升至 86.2%, mAP 达到 90.7%,同时其 $F1$ -score 提高至 84.52。在计数任务上,该模块亦表现出色, $RMSE$ 降至 5.11, MAE 降至 3.83,计数准确率达到 80.67%,有效缓解了密集场景下漏检与误检问题。LSCD 在保持较高检测精度的同时,显著降低了模型复杂度与资源消耗,将参数

量和计算量分别压缩至 2.42 M 和 5.6 G,为边缘部署奠定了轻量化基础。C3k2-EMA 与 WIoU-NWD 的结合表现出强大的协同效应,精确率进一步提升至 87.3%,召回率达 82.5%,其 $F1$ -score (84.83) 与计数准确率(84.00%)均为所有组合中的最优值,展现出优异的特征提取与目标判别能力。最终,融合全部 3 个模块的 WEL-YOLO 在检测精度、计数精度与轻量化性能之间取得了良好的平衡。相较于基准模型,其精确率、召回率、平均检测精度分别提升 1.6 个百分点、0.8 个百分点、0.9 个百分点,模型参数量、计算复杂度和模型权重分别降低 6.2%、11.1%、7.3%; $F1$ -score 提升至 84.26。在计数方面, $RMSE$ (5.59)与 MAE (4.15)较基准模型均有改善,计数准确率达到 80.17%。同时,模型在轻量化方面成效显著,模型大小压缩至 5.1 MB,计算量降低约 11.1%。该结果验证了各模块在提升模型综合性能与降低资源消耗方面的有效性,表明 WEL-YOLO 在精度与效率之间实现了协同优化,具备较好的边缘部署能力。

表 3 消融试验结果

Table 3 Results of ablation experiments

YOLO11n	C3k2-EMA	LSCD	WIoU-NWD	精确率 (%)	召回率 (%)	$F1$ -score	平均检测精度 (%)	$RMSE$	MAE	计数准确率 (%)	参数量 (M)	$FLOPs$ (G)	模型大小 (MB)
✓	-	-	-	85.5	80.8	83.08	89.1	5.60	4.18	79.83	2.58	6.3	5.5
✓	✓	-	-	85.6	81.8	83.65	89.5	5.72	4.36	76.83	2.58	6.4	5.5
✓	-	✓	-	84.6	79.2	81.81	87.8	6.15	4.54	74.67	2.42	5.6	5.1
✓	-	-	✓	86.2	82.9	84.52	90.7	5.11	3.83	80.67	2.58	6.3	5.5
✓	✓	✓	-	84.5	80.2	82.29	88.2	5.61	4.02	80.50	2.42	5.6	5.1
✓	✓	-	✓	87.3	82.5	84.83	90.8	5.00	3.75	84.00	2.58	6.4	5.5
✓	-	✓	✓	85.7	81.3	83.44	89.4	5.90	4.24	78.00	2.42	5.6	5.1
✓	✓	✓	✓	87.1	81.6	84.26	90.0	5.59	4.15	80.17	2.42	5.6	5.1

$F1$ -score:综合指标值; $RMSE$:均方根误差; MAE :平均绝对误差; $FLOPs$:计算量。

为更加直观地展示 WEL-YOLO 模型在复杂场景下的检测性能,尤其是对严重遮挡、目标微小等困难案例检测的改进效果,本研究选取了 3 种典型生育时期的水稻图像进行可视化分析。如图 6 所示,通过对比原图、基准模型(YOLO11n)预测结果与 WEL-YOLO 预测结果可以看出,WEL-YOLO 能够有效缓解重复检测问题,并在遮挡与微小稻穗的识别中表现出更强的鲁棒性。图 6 为基线模型 YO-


LO11n 与改进模型 WEL-YOLO 的效果对比图。

4.3 不同模型对比试验

为验证 WEL-YOLO 模型对水稻稻穗的识别与计数能力,本研究选择主流轻量化目标检测网络 YOLOv5n、YOLOv8n、YOLOv10n、YOLO11n 进行对比试验。训练过程中,所有网络均使用原数据集对模型性能进行综合评估。模型对比结果如表 4 所示。由表 4 可知,对于本研究所采用的稻穗数据集,

WEL-YOLO 模型的精确率为 87.1%,与 YOLOv5n、YOLOv8n、YOLOv10n、YOLO11n 相比,分别提高 3.8 个百分点、2.2 个百分点、2.2 个百分点、1.6 个百分

点。在轻量化方面,改进后模型的参数量、计算量、模型大小均有不同幅度的下降。



粗黑框为误检漏检部分。

图 6 模型可视化对比图

Fig.6 Comparison of model visualization

表 4 不同模型对比试验

Table 4 Comparison of different models

模型	精确率 (%)	召回率 (%)	<i>F1-score</i>	平均检测精度 (%)	参数量 (M)	<i>FLOPs</i> (G)	模型大小 (MB)
YOLOv5n	83.3	78.6	80.88	87.0	2.50	7.1	5.3
YOLOv8n	84.9	80.6	82.69	88.6	3.01	8.1	6.3
YOLOv10n	84.9	79.6	82.16	88.6	2.69	8.2	5.8
YOLO11n	85.5	80.8	83.08	89.1	2.58	6.3	5.5
WEL-YOLO	87.1	81.6	84.26	90.0	2.42	5.6	5.1

F1-score:综合指标值;*FLOPs*:计算量。

4.4 显著性检验

为验证改进模型 WEL-YOLO 对于精确率提升的有效性,本研究使用 5 个不同的随机种子 (42、123、456、789、101) 重复试验。改进模型的精确率为 $86.58\% \pm 0.43\%$, 优于基准模型 ($85.34\% \pm 0.32\%$)。配对 *t* 检验结果表明,改进模型精确率均值提升显著 [$t(4) = 8.857, P = 0.0004$, 单侧], 效应量Cohen's *d* 值为 3.961, 表明改进具有实际意义。

4.5 可视化界面

为便于结果展示与交互操作,本研究基于 PyQt5 设计并开发了模型可视化应用界面。该界面支持图像和视频的实时加载、稻穗检测与计数结果的显示、检测框与置信度的可视化标注,用户可通过简洁的操作界面便捷地调用训练好的 WEL-YOLO 模型进行推理,显著提升了模型在实际应用场景中的可用性与交互体验。可视化界面如图 7 所示。

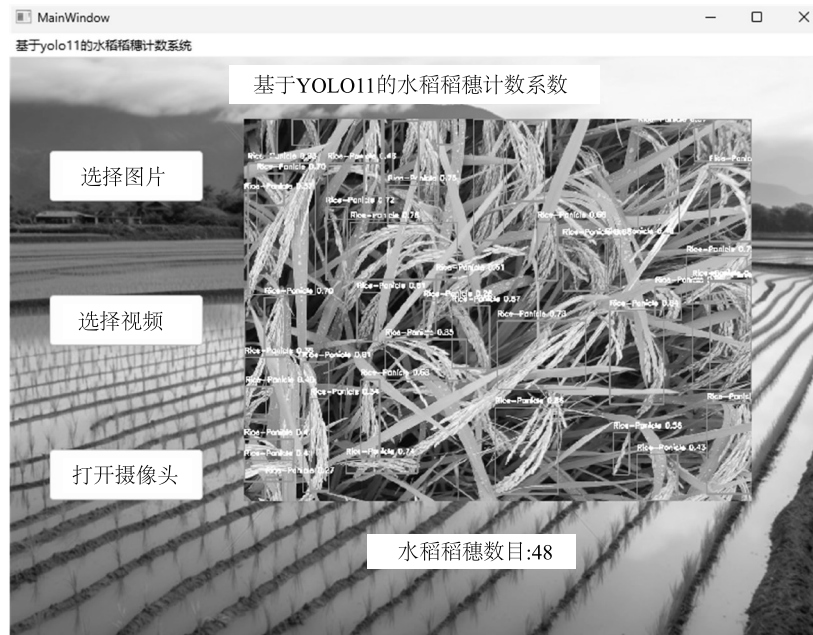


图7 可视化界面

Fig.7 Visualization interface

5 结论

本研究为提高水稻稻穗的检测精度,解决稻穗计数过程中因稻穗大小及生长环境造成的误检、漏检以及模型计算开销大等问题,提出一种融合轻量化检测头与高效注意力机制的 WEL-YOLO 检测模型,主要研究结论如下:

1) 在 YOLO11n 主干网络的 C3k2 模块中引入 EMA 多尺度注意力机制,构建 C3k2-EMA 模块,显著提升模型对多尺度特征的提取能力;使用共享卷积检测头 LSCD 替换基准检测头,在保证模型检测精度的同时有效降低模型的复杂度;将基准模型的损失函数 CIoU 替换为 WIoU-NWD,提升模型的定位精度,有效减少漏检与误检问题。与基准模型相比,精确率、召回率、平均检测精度分别提升了 1.6 个百分点、0.8 个百分点、0.9 个百分点,模型参数量、计算复杂度、模型权重分别降低 6.2%、11.1%、7.3%。

2) WEL-YOLO 在精度与轻量化方面均优于当前主流模型,相比 YOLOv5n、YOLOv8n、YOLOv10n、YOLO11n 精确率分别提升 3.8 个百分点、2.2 个百分点、2.2 个百分点、1.6 个百分点。模型大小分别降低 0.2 MB、1.2 MB、0.7 MB、0.4 MB。结果表明, WEL-YOLO 在水稻稻穗计数任务中更具优势。

本研究提出的 WEL-YOLO 模型在水稻稻穗公

开数据集上取得了较好的计数效果,但仍存在不足。一方面,受限于数据集的样本质量、生长时期覆盖,模型泛化能力有待提升,后续将继续扩充数据集以增强适应性。另一方面,模型未引入目标追踪算法,无法实现视频序列中的去重计数,后续将融合轻量级追踪方法,提升动态场景下的应用能力。

参考文献:

- [1] 刘泽钰,周云成,梁铨玮,等. 基于可变形卷积的稻粒在穗计数方法[J]. 农业机械学报,2025,56(3):363-373.
- [2] Wang G, Chen Y F, An P, et al. UAV-YOLOv8: a small-object-detection model based on improved YOLOv8 for UAV aerial photography scenarios[J]. Sensors,2023,23(16):7190.
- [3] Qu F H, Li H L, Wang P, et al. Rice spike identification and number prediction in different periods based on UAV imagery and improved YOLOv8[J]. Computers, Materials & Continua,2025,84(2):3911-3925.
- [4] Chen Y, Xin R, Jiang H Y, 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,2023,211:108032.
- [5] 朱家微,江朝晖,洪石兰,等. 基于神经架构搜索的灌浆期水稻稻穗分割及特征分析[J]. 激光与光电子学进展,2022,59(22):182-188.
- [6] 欧阳春凡,高嘉正,陈 桥,等. 大视场下火龙果目标检测与计数方法[J]. 中国农业科技导报(中英文),2025,27(8):100-109.

- [7] Shao H M, Tang R, Lei Y J, et al. Rice ear counting based on image segmentation and establishment of a dataset [J]. *Plants*, 2021, 10(8):1625.
- [8] 赵 静,李京谦,杨 蕾,等. 基于 PConv-CGLU 与重参数检测头的轻量化膜下棉苗实时检测算法[J]. *农业工程学报*, 2025, 41(18):151-162.
- [9] 刘 鑫,马本学,李玉洁,等. 基于改进 YOLOv7-ByteTrack 的干制哈密大枣缺陷检测与计数系统[J]. *农业工程学报*, 2024, 40(3):303-312.
- [10] 鲍文霞,谢文学,胡根生,等. 基于 TPH-YOLO 的无人机图像麦穗计数方法[J]. *农业工程学报*, 2023, 39(1):155-161.
- [11] 王宏乐,叶全洲,王兴林,等. 基于 YOLOv7 的无人机影像稻穗计数方法研究[J]. *广东农业科学*, 2023, 50(7):74-82.
- [12] Ramachandran A, Sendhil Kumar K S. Border sensitive knowledge distillation for rice panicle detection in UAV images[J]. *Computers, Materials & Continua*, 2024, 81(1):827-842.
- [13] 张远琴,肖德琴,陈焕坤,等. 基于改进 Faster R-CNN 的水稻稻穗检测方法[J]. *农业机械学报*, 2021, 52(8):231-240.
- [14] 蔡竹轩,蔡雨霖,曾凡国,等. 基于改进 YOLOv51 的田间水稻稻穗识别[J]. *华南农业大学学报*, 2024, 45(1):108-115.
- [15] 肖仲平,赵倩颖,曾甲元,等. 基于 YOLO-DCL 的复杂环境油茶果遮挡检测与计数研究[J]. *农业机械学报*, 2024, 55(10):318-326, 480.
- [16] 姜海燕,徐 灿,陈 尧,等. 基于田间图像的局部遮挡小尺寸稻穗检测和计数方法[J]. *农业机械学报*, 2020, 51(9):152-162.
- [17] Wei L L, Luo Y S, Xu L Z, et al. Deep convolutional neural network for rice density prescription map at ripening stage using unmanned aerial vehicle-based remotely sensed images[J]. *Remote Sensing*, 2021, 14(1):46.
- [18] 马小林,王梦麟,旷海兰,等. 基于 YOLOv8n 改进的蚕虫检测与计数方法[J]. *农业工程学报*, 2024, 40(15):143-151.
- [19] 翟肇裕,张梓涵,徐焕良,等. YOLO 算法在动植物表型研究中的应用综述[J]. *农业机械学报*, 2024, 55(11):1-20.
- [20] 杨万里,段凌凤,杨万能. 基于深度学习的水稻表型特征提取和穗质量预测研究[J]. *华中农业大学学报*, 2021, 40(1):227-235.
- [21] Madec S, Jin X L, Lu H, et al. Ear density estimation from high resolution RGB imagery using deep learning technique[J]. *Agricultural and Forest Meteorology*, 2019, 264:225-234.
- [22] Khanam R, Hussain M. YOLOv11: an overview of the key architectural enhancements [EB/OL]. arXiv:2410.17725. (2024-10-23) [2025-05-26]. <https://doi.org/10.48550/arXiv.2410.17725>.
- [23] 王如梦,王 赫,武国庆,等. 基于 WTEMA-YOLOv11 的房屋裂缝检测方法[J]. *电子制作*, 2025, 33(15):33-38.
- [24] Zheng Z H, Zhao J G, Fan J J. YOLO-GML: an object edge enhancement detection model for UAV aerial images in complex environments[J]. *PLoS One*, 2025, 20(7):e0328070.
- [25] Hu D A, Yu M, Wu X Y, et al. DGW-YOLOv8: a small insulator target detection algorithm based on deformable attention backbone and WIoU loss function[J]. *IET Image Processing*, 2024, 18(4):1096-1108.
- [26] 严嘉旭,苏天康,宋慧慧. 改进 YOLOv8 的轻量化无人机航拍目标检测[J]. *计算机系统应用*, 2025, 34(9):151-161.

(责任编辑:陈海霞)