

基于改进 YOLO v8n 的轻量化烟苗移栽质量检测方法

王 峰¹ 李言赐¹ 李堃臻¹ 杨云福² 李 玮¹ 金 浩³
(1. 西南林业大学机械与交通学院, 昆明 650224; 2. 云南省农业机械研究所有限公司, 昆明 650000;
3. 云南省烟草公司曲靖市公司, 曲靖 655000)

摘要: 为提高烟苗移栽机移栽过程烟苗移栽质量识别精度和检测速度,解决设备计算资源有限的问题,本文提出一种改进 YOLO v8n 的轻量化识别模型,实现烟苗移栽质量检测。在骨干网络(Backbone)中引入基于动态卷积 C2f_Ghost(CSP Bottleneck with 2 convolutions_ghost)模块替换 C2f(CSP Bottleneck with 2 convolutions)模块,保持精度的同时减小模型内存占用量和参数量,使模型更好地部署在移动设备上。引入 ODConv(Omni-dimensional dynamic convolution)替换传统卷积堆叠结构,以新的卷积层替换传统的卷积层,减少因传统卷积层堆叠导致的梯度消失、模型退化,增强了烟苗与地面的判别能力。添加 EMA(Efficient multi-scale attention)注意力机制,通过动态特征加权、长程依赖建模与轻量化计算的核心优势,解决烟苗移栽质量检测田间背景干扰强、关键特征尺度差异大、实时检测需求高的问题,提升网络对多尺度目标检测的适应性和准确度。试验结果表明,在自制数据集上改进 YOLO v8n 模型相比 YOLO v8n 基线网络模型,精确率、召回率、mAP_{0.5}、mAP_{0.5-0.95}、检测速度分别提高 11.3%、17.4%、11.4%、11.8%、4.62%,并且模型内存占用量、参数量和浮点运算量分别下降 17.1%、18.3%、31.7%。研究结果为农业作物表型检测模型轻量化设计提供了可行思路,尤其对烟苗移栽质量量化指标的精准提取具有实践价值,推进现代烟草农业数字化管控的落地应用。

关键词: 轻量化; YOLO v8n; 注意力机制; 目标检测; 烟苗

中图分类号: S223.2; TP391.41 文献标识码: A 文章编号: 1000-1298(2026)14-0287-11 OSID: 

Lightweight Tobacco Seedling Transplanting Quality Detection Method
Based on Improved YOLO v8n

Wang Feng¹ Li Yanci¹ Li Kunzhen¹ Yang Yunfu² Li Wei¹ Jin Hao³
(1. School of Machinery and Transportation, Southwest Forestry University, Kunming 650224, China
2. Yunnan Agricultural Machinery Research Institute Co., Ltd., Kunming 650000, China
3. Yunnan Tobacco Company Qujing City Company, Qujing 655000, China)

Abstract: Aiming to improve the accuracy and speed of evaluating tobacco seedling transplanting quality while addressing the limited computational resources of agricultural equipment, an improved, lightweight YOLO v8n model was proposed. Firstly, the conventional C2f module in the backbone network was replaced with a C2f_Ghost module. This modification significantly reduced memory footprint and parameter count without compromising accuracy, thereby facilitating deployment on mobile and edge devices. Next, omni-dimensional dynamic convolution (ODConv) was introduced to replace traditional convolutional stacks. This mitigated vanishing gradients and model degradation while enhancing the network's ability to distinguish seedlings from complex soil backgrounds. Furthermore, an efficient multi-scale attention (EMA) mechanism was integrated. Leveraging dynamic feature weighting, long-range dependence modeling, and lightweight computation, EMA effectively overcame challenges such as strong field background interference, significant scale variations of key features, and stringent real-time detection requirements. Experimental results on a custom dataset demonstrated that, compared with the baseline YOLO v8n, the proposed model improved precision, recall, mAP_{0.5}, mAP_{0.5-0.95}, and detection speed by 11.3%, 17.4%, 11.4%, 11.8%, and 4.62%, respectively. Concurrently, memory usage, parameter count, and floating-point operations (FLOPs) were decreased by 17.1%, 18.3%, and

31.7% , respectively. This research can provide a highly viable strategy for designing lightweight models in crop phenotypic detection , particularly for the precise quantitative assessment of transplanting quality , thereby advancing the digital management of modern tobacco agriculture.

Key words: lightweight; YOLO v8n; attention mechanism; target detection; tobacco seedling

0 引言

烟草作为重要的农业经济作物,在多个研究领域备受瞩目。烟苗移栽质量检测,不仅是动态监测烟草生长进程、量化评估田间群体结构的基础手段,更是实现大规模生产的基本要求。烟苗移栽质量与最终产量、品质均一性呈现显著正相关关系,通过精准检测与及时补救措施,可有效缩小田间生长差异,避免因部分烟苗长势滞后或早衰导致减产损失,保障烟草种植的经济效益稳定性^[1-2]。

当前,烟苗移栽质量检测主要依靠人工,效率低,易受主观判断和疲劳作业影响无法满足现代烟草种植与科研需求^[3]。随着科技的发展,目标检测算法在精准农业领域实现重大突破,尤其是 YOLO 系列算法^[4]凭借端到端检测架构、超高实时性、强鲁棒性及多目标同步识别能力,成为烟苗移栽质量智能化检测的优选技术方案。同时,算法跨硬件部署的灵活性与版本迭代的适配性,为不同算力条件下技术落地提供了可能,显著降低了智慧农业场景中移栽质量检测的技术门槛与应用成本。例如,肖恒树等^[5]提出了一种轻量级 GEW - YOLO v8 烟苗植株检测方法,与基准 YOLO v8n 相比浮点运算量减小 24.7% ,模型内存占用量减少 26.7% ,引入 WIoU 损失函数加快了模型的收敛并提高准确性,相较原模型 mAP_{0.5} 提高 0.8 个百分点。耿利川等^[6]提出改进 YOLO v7 的轻量化模型(YOLO v7 - Sim),针对无人机遥感影像烟株尺寸小问题,引入小目标检测增强算法,平均精度均值 mAP 提升至 94.5%。吴雪梅等^[7]优化 Faster R - CNN 网络,采用 ResNet50 提取高分辨率特征,实现成熟烟叶分级,准确率显著提高。Pan 等^[8]提出基于改进 YOLO v8n 模型,通过 ShufleNetV2 替代骨干网络、Ghost 模块替换颈部 C2f 层,并嵌入 SE 模块,在保证精确率 91.4% 的同时,降低了模型规模与检测延迟。针对作物幼苗检测难题,马宏兴等^[9]针对 YOLO v5s 参数量大、复杂背景下荒漠草原植物难识别的问题,提出轻量化 YOLO v5s 模型,采用深度可分离卷积实现轻量化压缩,精确率达 95.7% ,且泛化能力优良。Kong 等^[10]结合 YOLO v5 与 Transformer 机制构建幼苗检测网络,使 mAP 提升 1.0 个百分点。Lin 等^[11]利用多光谱传感器获取烟

草图像,对比不同波段组合的检测效果,验证了 YOLO v8n 的有效性,准确率大于 90%。Ma 等^[12]提出 YOLO v8n - ShuffleNetv2 - Ghost - SE 检测模型,对苹果进行实时检测,通过 ShuffleNetv2 替换 YOLO v8n 骨干网络、在原 C2f 模块中加入 Ghost 模块,并引入挤压激励(SE)模块增强特征表达,平均精度达 91.4% ,在维持检测精度的前提下,实现了模型轻量化与检测速度提升的平衡;陈海涛等^[13]针对罂粟检测精度低问题,在 YOLO v8n 引入 iRMB 注意增强对罂粟小目标检测能力,并引入 CARAFE 上采样算子提升罂粟的识别率,罂粟果实 mAP 提升 1.0 个百分点,罂粟花 mAP 提高 6.1 个百分点。刘双喜等^[14]针对水稻种植作业中秧苗与稻种的识别难题,基于 YOLO v8s,通过引入 GhostNet 模块、CPCA 注意力模块及替换 EIou 损失函数进行改进,提出轻量化检测方法,验证了模型有效性,平均精度均值达 92.41%。李尚平等^[15]针对宿根蔗补种机田间作业中宿根蔗苗难以精准检测定位的问题,提出双目相机结合改进 YOLO v5s 的识别定位方法,通过调整检测层适配小目标识别、引入 SimAM 注意力机制强化特征提取、替换 SlimNeck 与 Ghost 卷积实现模型轻量化优化,在自制宿根蔗苗数据集上平均精度均值达 97.1%。Chen 等^[16]基于 ResNet - 18 改进 ECA 模块,结合双池化与通道剪枝构建 CACPNET,在花生叶片病害数据集准确率 97.7% ,参数量较 ResNet - 18 减少 57.97%。Martins 等^[17]提出量化 CNN 模型 RiceLeafClassifier - v1.0,针对 5 类水稻叶片病害,融合田间采集与公开数据集训练,量化后模型内存占用量从 78.03 MB 缩减至 6.51 MB。Dong 等^[18]提出融合 ECA 注意力机制与知识蒸馏的 ECA - KDNet 模型,基于 EfficientNetb0 改进苹果叶片病害诊断,在 AppleLeaf 9 数据集上准确率达 98.28% ,参数量仅 3.38×10^6 。

尽管上述研究在各自领域取得了显著进展,但在烟苗移栽质量检测中未对烟苗移栽的田间特殊场景进行针对性优化,仍存在许多问题和挑战。现有轻量化卷积虽能显著精简模型计算量以适配田间实时检测需求,却因弱化通道间信息交互,无法精准捕捉烟苗叶片边缘的细微几何特征,形成特征提取完整性与计算量轻量化之间的核心矛盾;移栽机作业过程机械抖动易引发烟苗形态形变与拍摄角度的不

可预测变化,传统静态卷积核缺乏动态适配能力,面对此类多姿态烟苗目标时检测鲁棒性与适应性显著受限;田间复杂背景中,土壤颗粒、杂草等易干扰模型特征聚焦,引发注意力漂移问题,致使烟苗关键特征被背景噪声淹没,进一步降低移栽质量检测的可靠性与精准性。为解决上述问题,本文构建包含正常移栽株、倒伏缺陷株、多株成穴缺陷、浅栽缺陷株 4 种常见烟苗状态数据集,并提出基于改进 YOLO v8n 的轻量化烟苗移栽质量检测方法,通过引入 C2f_Ghost、ODConv 及 EMA 注意力 3 大核心模块,构建协同互补的检测模型。其中,C2f_Ghost 模块用于缩减模型体积、降低计算参数量,为模型高效推理奠定速度基础;针对 Ghost 卷积可能带来的高频信息丢失,引入 ODConv 借助卷积核多维度动态适配机制,强化空间几何特征提取能力,保障模型在低参数量下对移栽烟苗状态的识别稳健性;最后,利用 EMA 机制在骨干网络中进行全局上下文建模,抑制田间杂草背景的干扰,助力模型在大视野下精准定位烟苗小目标,以提升检测精度。

1 数据采集与预处理

1.1 数据采集

试验地点为云南曲靖马龙的烟草种植试验烟田,气候湿润,降水充足,适合烟草植株生长要求,为烟叶发育成熟提供了天然优势。种植方法主要采用“烤烟膜下小苗移栽”的农艺规范^[19],打塘后进行移栽,塘与塘间距 30 ~ 45 cm,每个塘只栽 1 棵,移栽时要求气温 13℃ 以上,光照良好。当地不仅积累了数十年的标准化种植经验,更拥有集中的大规模烟田,为开展大范围数据采集工作奠定了优质的试验条件。研究对象包括移栽后常见的 4 种烟苗状态:正常移栽株、倒伏缺陷株、多株成穴缺陷、浅栽缺陷株,如图 1 所示。图像采集设备是 STEREO LABS 公司的 ZED 双目相机,拍摄选择晴天,光照为 2 000 ~ 30 000 lx,拍摄时相机固定在移栽机的尾部垂直地面,离地面高约为 60 cm,共获得 1 361 幅烟苗图像。采用人工筛选的方式对图像数据进行处理:剔除因移栽机停止前进产生的重复、调整方向期间未完整包含烟苗植株图像,最终得到 1 002 幅图像。

1.2 数据处理

为增强模型对烟苗移栽现场复杂非结构化环境的鲁棒性,缓解训练过程过拟合问题,提升模型泛化能力,对原始 1 002 幅烟苗移栽图像开展基于物理场景的增强处理,将数据集规模扩充至 3 006 幅。增强策略并非简单的图像变换,而是依据移栽现场的真实环境进行参数设计。旨在模拟光照变化、机




图 1 移栽烟苗状态

Fig. 1 State of transplanted tobacco seedlings

械抖动、传感器噪声及拍摄角度偏移等非结构化因素,如表 1 所示。

表 1 数据增强策略

Tab. 1 Data enhancement strategy

方法	参数设置	物理环境映射
随机亮度	Factor $\in [0.7, 1.3]$	日照强度变化
高斯噪声	$\mu = 0, \sigma^2 \in [0.005, 0.01]$	传感器热噪声与弱光噪点
运动模糊	Kernel size $\in \{3, 5\}$	移栽机作业时的机械抖动
随机旋转	Angle $\in [-15^\circ, 15^\circ]$	摄像头安装误差或机身倾斜

为验证增强数据未破坏烟苗的语义特征分布,进行分布一致性分析。选取 1 002 幅原始图像与 3 006 幅增强图像。利用训练好的 YOLO v8n 骨干网络提取高斯特征向量,并通过 t-SNE 将特征降至二维空间进行可视化,如图 2 所示。




图 2 数据增强一致性检测

Fig. 2 Data enhancement consistency detection

由图 2 可知,增强样本蓝色与原始样本红色在特征空间中高度重叠,未出现明显的离群点或独立簇结构,表明增强操作仅引入合理扰动而未改变语义本质。数据增强策略有效扩展了样本多样性,同

时避免了过度增强导致的负迁移风险。在 Make Sense 官网进行烟苗的标注,生成 xml 文件的压缩包,文件包含图像名称、大小和烟苗位置信息,烟苗状态与标签对应关系如表 2 所示,然后进行数据集划分,训练集占 70%,验证集占 20%,测试集占 10%。

表 2 烟苗状态及数量

Tab.2 Name and quantity of tobacco seedling status

烟苗状态	标签名	图像数量
正常移栽株	Properly Transplanted Seedling	742
倒伏缺陷株	Lodging Defect Seedling	760
多株成穴缺陷	Multiple - Seedling Defect	748
浅栽缺陷株	Shallow - Planting Defect Seedling	756

1.3 YOLO v8 算法

在 YOLO 系列算法中 YOLO v8 在目标检测与图像分割领域应用广泛,相较于其他识别算法,具有对各类移动设备更优的适配兼容性^[20]。YOLO v8 基于网络架构的深度与宽度差异,衍生出 n、s、m、l、x 5 个不同规格的模型。YOLO v8 模型网络结构由骨干网络(Backbone)、特征融合网络(Neck)、检测部分(Head)、损失函数 4 个部分组成。骨干网络包含 CSP、C2f、SPPF 等模块,CSP 采用残差连接和特征融合策略,减少计算量的同时保持精度;C2f 通过引入跨层分支连接机制,有效拓展梯度流,强化残差特征的学习进而构建出具备更强特征表达能力的神经网络模块;SPPF(空间金字塔池化模块)采用多尺度最大池化并行处理特征图,实现跨尺度特征聚合,提升多尺度特征提取效率。Neck 部分沿用 PANet(路径聚合网络)架构,负责特征融合与增强,强化不同层次特征的交互传递,这种融合方式不仅有效增强了模型对不同尺度目标的感知能力,更通过强化多尺度特征的交互关联。检测部分采用 3 分支结构并行处理不同尺度的目标检测任务^[21],各检测分支均采用解耦头架构,将目标分类与定位任务分离,通过独立的分类头与检测头实现更精准的预测,同时,采用 Anchor-free 检测策略,简化模型结构的同时提升对多样化目标形态的适应性,有效降低计算复杂度并增强检测泛化能力^[22]。损失函数分为分类损失其使用 BCE with logits loss(二分类交叉熵)和回归损失 CIoU Loss(Complete intersection over union),同时优化重叠率、中心点距离和宽高比^[23]。考虑到本研究对模型轻量化部署的需求,为降低计算资源消耗并提升推理速度,最终选定模型参数量少、结构最为精简的 YOLO v8n 作为基础模型。

2 改进 YOLO v8n 模型

C2f_Ghost 模块可在减小模型内存占用量和参

数量的同时尽可能保持精度,因此选择 C2f_Ghost 模块替换 YOLO v8n 中 C2f;引入 ODConv 代替原来的卷积 Conv,解决传统卷积层堆叠导致的梯度消失、模型退化、致使烟苗精度下降、计算速度慢的问题;将 EMA 注意力机制引入特征提取网路中增强模型对关键特征的捕捉能力,提高小目标识别能力,从而提高整体精度。改进 YOLO v8n 的轻量化检测模型结构如图 3 所示。

2.1 C2f_Ghost

针对移栽机作业场景下烟苗检测对模型轻量化与实时性的需求,传统卷积中,提升性能常依赖增设或堆叠卷积层,但会增加模型的参数量和浮点运算量并降低检测速度,然而模型参数量越大对设备要求越高,而移动端设备的计算算力有限,模型参数量和计算量越大移动端运行速度越慢,卡死的几率越高,故引入 C2f_Ghost 代替 C2f 模块降低模型的参数量,提高烟苗移栽质量的识别速度。

GhostConv 具备即插即用的特性^[24],通道拆分比例 n 是影响模型效率与性能的关键参数,决定了输入通道在标准卷积与轻量操作之间的分配比例,从而直接影响特征表达能力与计算复杂度。从性能角度看,较小 n 意味着更多通道经过标准卷积,特征表达能力更强,精度更高,但计算量增加;较大 n 则进一步降低计算成本,但可能导致特征表达不足,精度下降。现有研究 GhostNet 通常采用经验值 n 为 2,即将输入通道平均拆分为 2 部分,一部分通过标准卷积生成固有特征,另一部分通过线性变换生成冗余特征,显著降低了计算成本。如图 4 所示,利用 1×1 卷积对通道信息进行聚合,再通过分组卷积生成新的特征图,将传统卷积分解为 2 个步骤的策略,有效减轻网络计算负担。综上,GhostConv 在显著降低模型计算量和参数量的同时保持了功能。图 4 中 ϕ_1 至 ϕ_s 均为线性运算。

固有及 Ghost 特征图计算式为

$$Y' = Xw'$$
 (1)

$$y_{i,j} = \phi_j(Y'_i) \quad (i = 1, 2, \cdots, m; j = 1, 2, \cdots, s)$$
 (2)

- 式中 X ——输入特征图
 w' ——标准卷积核
 Y' ——固有特征图
 $y_{i,j}$ ——Ghost 特征图
 ϕ_j ——第 j 个线性操作
 m ——固有特征图数量
 s ——每个固有特征图生成 Ghost 特征数量

C2f_Ghost 模块在不额外增加网络参数的情况下,一方面缩小了模型内存占用量,缩短了冗余特征图的推理耗时;另一方面,在实现网络轻量化的同




图 3 改进 YOLO v8n 的轻量化检测模型结构

Fig. 3 Improved lightweight detection model structure of YOLO v8n




图 4 Ghost 模块网络结构

Fig. 4 Ghost module network structure

时,提升了网络的检测精度。

Bottleneck_Ghost 模块^[25]由 2 个 Ghost 模块堆叠组成,C2f_Ghost 模块完全采用 Bottleneck_Ghost 模块对 C2f 的 Bottleneck 网络结构进行替换,如图 5 所示。C2f_Ghost 模块能在不额外增加网络参数的前提下有效压缩模型体积,同时降低冗余特征图的推理耗时,达到网络轻量化设计目标。虽然 Ghost 模块有效降低了模型体积,但削弱了对烟苗边缘细节的提取能力。为此,将该模块作为基础特征提取器,并将细节恢复的任务通过 ODConv 模块实现。

2.2 ODConv

为弥补 C2f_Ghost 模块细节提取短板,充分利用轻量化带来的算力冗余,并解决移栽机在正常作业时会产生震动、颠簸和移栽机车身有时会遮挡阳光的问题,采用常规卷积实施降维操作^[26]。但常规卷积存在明显局限性,因缺乏对特征信息重要性的判别能力,无法依据特征关键程度进行差异化处理,为了解决移栽机作业过程摄像头抖动和光照不均带




图 5 C2f_Ghost 模块结构

Fig. 5 C2f_Ghost module structure

来的特征模糊问题,引入 ODConv 替换骨干网络中标准 Conv 卷积。ODConv 提供全维度动态特性,针对烟苗形态的多样性,ODConv 能根据输入的特征图动态调整卷积核权重,显著增强模型对不同烟苗姿态、不同大小烟苗的鲁棒性。为了平衡推理速度与精度,仅将骨干网络中第 8 层 Conv 卷积替换成 ODConv,采用通道剪枝输出通道数减半,以新的卷积层替换传统的卷积层,可显著减少因传统卷积层堆叠导致的梯度消失、模型退化,增强烟苗与地面的判别能力,提高灵活适应不同输入特征的能力,从而提高模型精度和灵活性。ODConv 结构如图 6 所示。

ODConv 输出特征图 Y 数学表达式为

$$Y = (\alpha_{w1} W_1 + \alpha_{w2} W_2 + \cdots + \alpha_{wn} W_n) * X \quad (3)$$

式中 W_i ——第 i 个静态卷积核(共 n 个核)

α_{wi} ——第 i 个卷积核相关的标量注意力权重

$*$ ——卷积操作




图6 全维动态卷积

Fig.6 Full-dimensional dynamic convolution

ODConv 通过空间、输入通道、输出通道和卷积核 4 个维度的动态加权实现特征增强,使模型能够更好适应烟苗移栽场景的复杂性如图 7 所示。在空间维度,模型可根据烟苗在图像中实际分布自适应调整感受野更准确地提取叶片边缘与弯折等细粒度结构;在输入通道维度,动态通道权重强化烟苗主体的颜色与纹理特征,同时抑制土壤、杂草等背景干扰;在输出通道维度,模型对于烟苗姿态、叶片展开和直立性相关的特征进行重点强化;在卷积核维度,动态核权重使模型能在多尺度、多姿态烟苗之间灵活切换特征提取策略。依托上述 4 维动态机制,ODConv 显著提升模型在光照变化、机械抖动和复杂背景下的特征表达能力,从而增强烟苗移栽质量检测的稳定性与准确性。

传统动态卷积(如 CondConv^[27] 或 DyConv^[28]) 公式为

$$Q = \left(\sum_{i=1}^n \alpha_i W_i \right) * k \tag{4}$$

式中 Q ——输出特征图

k ——输入特征图

α_i ——基础卷积核数量

ODConv 扩展上述框架,引入 4 个维度的互补注意力,计算式为

$$Q = \left(\sum_{i=1}^n \alpha_{W_i} \alpha_{f_i} \alpha_{C_i} \alpha_{s_i} \odot W_i \right) * k \tag{5}$$

式中 α_{W_i} ——卷积核维度注意力

α_{f_i} ——输出通道维度注意力

α_{C_i} ——输入通道维度注意力

α_{s_i} ——空间维度注意力

$\odot$ ——核空间多维度乘法运算

ODConv 在特征降维环节中,通过增强特征金字塔对输入数据空间与通道相关性的解析能力,显著提升了特征的判别能力,减少信息损失,提高网络模型的精确度。

2.3 EMA 注意力机制

在经过 Ghost 轻量化和 ODConv 动态提取后,特征图中仍可能混杂着类似烟苗颜色的杂草噪声。




图7 4个维度的加权过程

Fig.7 Weighting process of four dimensions

EMA 模块被部署在骨干网络的关键节点,通过跨空间维度交互,将网络注意力重新聚焦到烟苗核心区域,确保最终输出的纯净度。EMA 注意力机制采用分组结构设计,实现跨空间维度的信息融合,如图 8 所示。

通过 2 条并行路径对分组特征图进行注意力权重提取,分别采用 1×1 卷积分支与 3×3 卷积分支^[29],优势在于保持通道维度不变的同时,显著增强特征聚合能力,兼具计算复杂度低和识别精度高的特点。在 1×1 分支中,引入 CA 模块^[30]并结合二维平均池化,将输出张量拆分为 2 条并行的一维特征向量。利用 Sigmoid 函数生成二维注意力分布,并通过逐元素乘法融合组内的 2 幅通道注意力图。

二维平均池化计算式为

$$z_c = \frac{1}{HW} \sum_j \sum_i x_c(i,j) \tag{6}$$

式中 z_c ——第 c 个通道全局平均池化输出特征

H ——特征图高度

W ——特征图宽度

x_c ——第 c 通道输入特征

(i,j) ——像素坐标

在 EMA 结构中,通过堆叠 1 个 3×3 卷积核以提取多尺度特征,从而增强特征空间的表达能力;与




图 8 EMA 模块结构

Fig. 8 EMA module structure

此同时,采用二维全局平均池化对该路径的整体空间信息进行编码。借助 2 条并行分支,EMA 一方面对通道间的依赖关系进行建模并动态分配权重,另一方面在通道维度中保留细粒度空间信息,然后输出更具判别性的特征。

3 试验与结果分析

3.1 试验环境及参数设置

完成模型的训练与测试硬件条件:处理器采用 CPU 为 13 代 Intel Core i9-13900K,内存 128 GB,显卡为 NVIDIA GeForce RTX4090(显存 24 GB);软件环境基于 Windows 10 专业版 64 位系统,搭配 CUDA 11.8、Python 3.8.20 及 PyTorch 2.4.1。训练参数设置:批次大小设为 32,初始学习率取 0.01,为避免数据过拟合训练迭代次数设为 200,其余参数采用默认值。

3.2 评估指标

为全面衡量改进模型性能,从识别性能、计算性能及模型参数量维度,选取评估模型识别性能指标分别为精确率(P)、召回率(R)、 $mAP_{0.5}$ 与 $mAP_{0.5-0.95}$ 。计算性能的评价维度包括参数量、浮点运算量、推理时间,以及作为轻量化依据的模型内存占用量。其中参数量体现模型在训练中包含参数规模,数值越大说明模型空间越复杂与存储需求越高;浮点运算量衡量计算复杂度与执行效率,运算量增加会带来更高的算力和时间消耗;推理时间表示

模型从输入数据处理到输出结果的延迟;模型内存占用量反映在终端设备中内存占用情况,是衡量模型轻量化水平的关键指标。

3.3 ODConv 卷积试验

为了验证 ODConv 模块通道剪枝比例合理性,分别设置不同剪枝策略进行试验,包括无剪枝、剪枝 0.75、剪枝 0.5 以及剪枝 0.25,试验结果如表 3 所示。由表 3 可知,剪枝比例对检测精度与模型复杂度之间存在显著的权衡关系:无剪枝模型在精度上表现最佳,但计算量较大;剪枝 0.25 与剪枝 0.75 虽然有效减小了模型规模,但在烟苗移栽质量检测中精度下降明显,难以满足实际应用需求;相比之下,剪枝 0.5 在保持较高 mAP 的同时显著降低了参数量和模型内存占用量,在精度与效率之间取得了较优平衡。因此,在烟苗移栽质量检测场景下,剪枝 0.5 的策略能够兼顾检测准确性与实时性,更适合部署于资源受限的农业机器人平台。

表 3 ODConv 模块不同通道剪枝比例试验结果

Tab.3 Test results of different channel pruning

ratio of ODConv module						
剪枝比例	精确率/%	$mAP_{0.5}/\%$	$mAP_{0.5-0.95}/\%$	参数量	模型内存占用量/MB	
1.00	88.5	89.5	65.5	3.90×10^6	7.66	
0.75	84.1	85.2	63.3	3.59×10^6	7.06	
0.50	88.2	90.3	66.4	3.27×10^6	6.46	
0.25	77.4	79.7	65.7	2.97×10^6	5.87	

3.4 不同模型性能试验

为了验证改进 YOLO v8n 模型对烟苗移栽质量检测的优越性,将其与当前主流的目标检测算法进行对比测试,对比模型涵盖轻量级网络如 NanoDet、EfficientDet-D0, YOLO 系列的经典版本 YOLO v5s、YOLO v6、YOLO v7-tiny 以及最新的 YOLO 迭代版本 YOLO v9s~YOLO 12n。为保障试验结果的公平性与可比性,所有模型均在完全一致的试验条件下完成训练与测试,试验环境配置保持统一,数据集采用本文构建的烟苗移栽数据集,输入图像尺寸均调整为 640 像素 $\times$ 640 像素且未实施多尺度训练;超参数设置均选用 SGD 优化器,初始学习率设为 0.01、动量为 0.937、训练轮次统一设定为 200;数据增强策略层面,所有模型均保持完全相同,以此消除数据预处理环节的差异对试验结果造成的影响。评价指标主要包括精确率、召回率、 $mAP_{0.5}$ 、 $mAP_{0.5-0.95}$ 、参数量、浮点运算量、模型内存占用量,全面评估改进方法的有效性,试验结果如表 4 所示。由表 4 可知,改进 YOLO v8n 模型在各项关键性能指标上均展现出显著优势,成功实现检测精度与模

型轻量化的最优平衡,相较于原 YOLO v8n 基准网络,改进模型的检测精度实现质的飞跃,精确率从 83.4% 提升至 92.8%,召回率由 75.2% 提升至 88.3%,平均精度均值 $mAP_{0.5}$ 高达 95.4%。结果表明,引入 EMA 注意力机制与 ODConv 模块可有效解决烟苗漏检及背景误检问题;在精度显著提升的同时,改进模型参数量仅为 2.46×10^6 ,浮点运算量降至 5.60×10^9 ,模型内存占用量减小至 4.96 MB,说明 C2f_Ghost 模块的轻量化重构不仅抵消了新增模块的计算量,还使模型较原版更轻量化。进一步对比 YOLO - NAS、YOLO v9s、YOLO v10n、YOLO 11n 及 YOLO 12n 等主流新型模型可见,尽管这些模型在通用数据集上表现优异,但在本研究特定的烟苗移栽数据集上, $mAP_{0.5}$ 分别为 74.8%、82.6%、82.4%、79.1% 和 82.5%,均显著低于改进模型,充分说明盲目追求最新网络架构并非适用于所有场景,针对特定农业场景设计的特征提取与融合机制

更能精准捕捉烟苗的细微特征。即便与参数量高达 6.82×10^7 的大型网络 YOLO v8x 相比,改进模型的 $mAP_{0.5}$ 仍高 5.7 个百分点,且参数量仅为 YOLO v8x 的 1/27 左右,浮点运算量仅为其 1/46,进一步验证了改进算法并非依赖参数堆叠提升性能,而是通过构建更高效的特征表达机制实现了“小而精”的性能优势。从综合性能来看,NanoDet 虽具备最低计算量但 $mAP_{0.5}$ 仅为 63.9%,难以满足移栽作业的高精度需求;与主流轻量级模型 YOLO v7 - tiny 相比,改进模型的模型内存占用量、参数量和浮点运算量分别降低 59.7%、59.1% 和 57.6%;改进模型在维持极低计算量,性能优于 YOLO v5s、YOLO v8n 等多数主流轻量化模。综上,改进 YOLO v8n 模型兼具最高检测精度、精简参数规模与优异推理效率,能够有效适配移栽机作业的复杂环境及硬件资源约束,是当前最适用于烟苗移栽实时检测任务的模型。

表 4 不同模型性能试验结果
Tab.4 Performance test results of different models

模型	精确率/%	召回率/%	$mAP_{0.5}/\%$	$mAP_{0.5-0.95}/\%$	参数量	浮点运算量	模型内存占用量/MB
EfficientDet - D0	64.6	50.9	64.6	44.3	3.82×10^6	2.36×10^9	15.16
NanoDet	63.9	64.6	63.9	47.2	9.40×10^5	3.40×10^8	3.78
YOLO - NAS	69.2	68.1	74.8	52.5	7.23×10^7	1.71×10^{10}	122.11
YOLO v5s	80.2	73.7	83.9	62.5	2.51×10^6	7.10×10^9	5.02
YOLO v6	75.8	67.4	77.4	57.5	4.23×10^6	1.18×10^{10}	8.27
YOLO v7	80.1	72.0	78.9	56.3	3.72×10^7	1.05×10^{11}	74.80
YOLO v7 - tiny	80.5	73.1	79.1	55.2	6.02×10^6	1.32×10^{10}	12.30
YOLO v8n	83.4	75.2	85.6	61.8	3.01×10^6	8.20×10^9	5.98
YOLO v8x	85.7	85.8	89.7	67.1	6.82×10^7	2.58×10^{11}	390.00
YOLO v9s	80.5	81.4	82.6	62.1	7.16×10^6	2.67×10^{10}	14.50
YOLO v10n	81.9	72.3	82.4	61.6	2.26×10^6	6.50×10^9	5.47
YOLO 11n	85.4	73.5	79.1	60.6	2.58×10^6	6.30×10^9	5.20
YOLO 12n	84.9	74.2	82.5	61.2	2.55×10^6	6.30×10^9	5.25
改进 YOLO v8n	92.8	88.3	95.4	69.1	2.46×10^6	5.60×10^9	4.96

3.5 消融试验

改进 YOLO v8n 模型显著压缩了模型体积,降低了参数量和计算量,同时提高了烟苗移栽状态检测精度并增强了模型鲁棒性,各种模型对烟苗质量检测结果如表 5 所示。依托 YOLO v8n 基准模型,在固定试验环境下,通过增量式引入改进模块并进行消融试验,验证各模块对模型性能提升的作用,依次替换原 C2f 模块、Conv 模块以及添加 EMA 注意力机制。

由表 5 可知,使用 C2f_Ghost 替换原 YOLO v8n 中的 C2f 模块后,模型浮点运算量、模型参数量以及模型内存占用量都明显降低,精确率降低很小,召回率提升 6.91%, $mAP_{0.5}$ 提升 7.35%, $mAP_{0.5-0.95}$ 提升

6.95%;在此基础上,使用 ODConv 替换原 YOLO v8n 网络中 Conv 模块,参数量和模型内存占用量增加很小,但精确率提升 4.92%,召回率提升 4.97%, $mAP_{0.5-0.95}$ 提升 0.3%,浮点运算量下降 3.45%。当 ODConv 与 C2f_Ghost 模块结合使用时,C2f_Ghost 的轻量化特征生成机制能够有效抑制 ODConv 带来的冗余噪声,使特征分布更加稳定,从而在精确率与召回率上均优于原始 YOLO v8n。由此证明 C2f_Ghost 模块和 ODConv 模块替换方案显著提升了模型识别精度。将 EMA 注意力机制嵌入到模型中,改进模型相较于原 YOLO v8n 模型在参数量和计算复杂度不变的情况下,精确率提升 6.17%,召回率提升 4.62%, $mAP_{0.5}$ 提升 4.03%, $mAP_{0.5-0.95}$ 提升

表 5 消融试验结果

Tab.5 Ablation test results

C2f_Ghost	ODConv	EMA	精确率/ %	召回率/ %	mAP _{0.5} / %	mAP _{0.5-0.95} / %	推理时间/ ms	参数量	浮点运算 量	模型内存占 用量/MB
✓	✓	✓	83.4	75.2	85.6	61.8	8.05	3.01 × 10 ⁶	8.2 × 10 ⁹	5.98
			83.3	80.4	91.9	66.1	7.51	2.18 × 10 ⁶	5.8 × 10 ⁹	4.39
✓	✓	✓	88.2	72.0	90.3	66.4	7.68	3.27 × 10 ⁶	7.9 × 10 ⁹	6.46
			88.7	79.5	90.2	65.0	8.58	3.44 × 10 ⁶	6.4 × 10 ⁹	6.82
✓	✓	✓	87.4	84.4	91.7	66.3	7.83	3.07 × 10 ⁶	5.6 × 10 ⁹	6.09
✓	✓	✓	92.8	88.3	95.4	69.1	7.69	2.46 × 10 ⁶	5.6 × 10 ⁹	4.96

注：✓表示模型使用该模块。

4.22%，参数量下降 19.8%，模型内存占用量下降 18.5%。

综上,改进 YOLO v8n 模型相比 YOLO v8n 基线网络模型,精确率、召回率、mAP_{0.5}、mAP_{0.5-0.95} 分别提高 11.3%、17.4%、11.4%、11.8%，并且模型内存占用量、参数量、浮点运算量和推理时间分别下降 17.1%、18.3%、31.7%、4.47%，证明改进算法的有效性。

3.6 算法验证

为了直观地评估价改进 YOLO v8n 模型与 YOLO v8n 模型在烟苗移栽质量检测中对不同烟苗状态的检测表现,选取测试集中包含 4 种标签的样本图像,然后从各烟苗状态中选择 1 幅图像进行检测,结果如图 9 所示,为了避免单一烟苗状态精度的提升从而对整体精度产生误导,表 6 为烟苗各状态检测结果,结果表明每个参数都有提升,从而验证改进模型的有效性。

将改进的模型与 YOLO v8n 模型同步训练 200 轮次后,对应的精确率、召回率、mAP_{0.5} 及 mAP_{0.5-0.95}变化曲线如图 10 所示。从图 10 可知,召回率曲线在 50 轮时振幅较大,这一现象源于网络结构中骨干网络用 ODConv 替换标准卷积增强模型表

表 6 改进前后烟苗状态检测结果

Tab.6 Test results of tobacco seedling state before and after improvement

烟苗状态	精确率		召回率		mAP _{0.5}		mAP _{0.5-0.95}	
	前	后	前	后	前	后	前	后
正常移栽株	91.3	87.5	77.8	93.1	91.1	97.1	78.4	79.0
倒伏缺陷株	77.6	87.4	72.6	95.0	85.8	96.0	48.1	55.2
多株成穴缺陷	91.8	98.3	87.3	87.6	88.5	90.2	75.5	79.9
浅栽缺陷株	72.9	98.2	63.1	77.5	77.0	98.3	45.2	62.1




图 10 模型改进前后性能变化曲线

Fig.10 Performance variation curves before and after improvement

征能力,添加 EMA 注意力机制以聚焦关键信息,同时采用 C2f_Ghost 以实现轻量化。ODConv 与 EMA 动态特性会在训练初期增加优化难度,从而导致曲线波动。但当训练至第 100 轮时,精确率与召回率 2 条曲线虽仍呈上升趋势,但上升速度已显著缓慢,开始逐步向平稳态势过渡;当训练进行到第 125 轮时,2 条曲线波动幅度大幅缩小,整体趋于稳定。而 mAP_{0.5} 与 mAP_{0.5-0.95} 曲线,迭代至第 125 轮时,曲线虽存在一定波动,但整体变化趋势已明显放缓。最终模型在检测精度与模型规模之间取得了优于基线模型的综合性能,说明上述结构调整有效且合理。

3.7 真实环境测试

采用 ZED 双目相机获取图像,软件环境为 Linux 系统,搭配 CUDA 11.7、Python 3.8、PyTorch




图 9 改进前后检测结果

Fig.9 Test results before and after improvement

1.13.1;依托 Jetson None B01 加载烟苗检测模型进行推理,烟苗移栽实时检测平台如图 11 所示。在移动端部署改进 YOLO v8n 模型进行检测分析,随机选取 500 幅图像进行检测,结果如表 7 所示。




图 11 烟苗移栽机移栽质量检测平台

Fig. 11 Tobacco seedling transplanter transplanting quality detection platform

表 7 移动端改进前后试验结果

Tab. 7 Test results before and after improvement of mobile terminal

模型	精确率/	mAP _{0.5} /	mAP _{0.5-0.95} /	推理时
	%	%	%	间/ms
YOLO v8n	83.2	84.7	61.1	144.3
改进 YOLO v8n	92.1	91.7	67.2	121.4

由表 7 可知,改进 YOLO v8n 模型在检测精度方面显著优于原始模型,精确率提升 10.69%,mAP_{0.5}提升 8.26%,mAP_{0.5-0.95}提升 9.98%,推理时间(121.4 ms)相比原模型提高 15.9%,结果表明改进 YOLO v8n 模型在 Jetson Nano B01 平台部署具有

可行性与实用性,能够满足烟苗移栽机对实时性与准确性的双重要求。

4 结论

(1)基于 YOLO v8n 模型构建改进模型,为了缩短推理时间、降低内存占用量并减少计算参数量,添加 C2f_Ghost 模块,使模型更好地部署在移动设备上,采用 ODConv 模块使卷积核在多个维度上实时调整,提高模型对烟苗的识别能力。为了提高模型的精度,在大的视野里寻找烟苗引入 EMA 注意力机制,增强模型对关键特征的捕捉能力,提高小目标检测精度,比原 YOLO v8n 模型精确率提升 6.17%,召回率提升 4.62%,mAP_{0.5}提升 4.03%,mAP_{0.5-0.95}提升 4.22%,参数量下降 19.8%,模型内存占用量下降 18.5%。

(2)改进后的轻量化模型在保持高精度的同时,实现了模型复杂度的显著下降。试验结果表明,与主流轻量级模型 YOLO v7-tiny 相比,改进模型的模型内存占用量、参数量和浮点运算量分别降低 59.7%、59.1%和 57.6%。改进轻量化优势使得模型能够以更低的算力运行,显著提升了鲁棒性,更适配计算资源受限的移动端部署场景。

(3)将改进后的模型部署在 Jetson None B01 边缘计算平台上进行验证,单帧图像推理时间为 121.4 ms,可以满足烟苗移栽机自动识别烟苗状态,为保障烟草基础产量和实现烟苗智能化种植提供了技术支持。

参 考 文 献

[1] Pranata S W, Sigit W H. Tomato plant growth monitoring system using computer vision and deep learning[J]. Mathematical Statistician and Engineering Applications, 2022, 71(4): 9408-9417.

[2] 张叶, 郭小宝, 温晓霞. 我国烟草产业发展现状及其未来改革方向[J]. 江西农业, 2016(3): 29.

[3] 薛宇飞, 张军, 张萍, 等. 基于 Sentinel-2 遥感影像的烟草种植信息精准提取[J]. 中国烟草科学, 2022, 43(1): 96-106.

Xue Yufei, Zhang Jun, Zhang Ping, et al. Accurate extraction of tobacco planting information based on Sentinel-2 remote sensing image[J]. China Tobacco Science, 2022, 43(1): 96-106. (in Chinese)

[4] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.

[5] 肖恒树, 李军营, 梁虹, 等. 基于改进 YOLO v8 和无人机遥感影像的大田烟株数量检测[J]. 电子测量技术, 2024, 47(9): 163-171.

Xiao Hengshu, Li Junying, Liang Hong, et al. Detection of field tobacco plant number based on improved YOLO v8 and UAV remote sensing images[J]. Electronic Measurement Technology, 2024, 47(9): 163-171. (in Chinese)

[6] 耿利川, 王忠丰, 秦永志, 等. 基于 YOLO v7-Sim 和无人机遥感影像的烟株数量检测[J]. 中国烟草科学, 2023, 44(4): 94-102.

Geng Lichuan, Wang Zhongfeng, Qin Yongzhi, et al. Detection of tobacco plant number based on YOLO v7-Sim and UAV remote sensing images[J]. China Tobacco Science, 2023, 44(4): 94-102. (in Chinese)

[7] 吴雪梅, 刘红芸, 王芳, 等. 基于改进 Faster R-CNN 网络的烟叶分级[J]. 计算机与数字工程, 2023, 51(6): 1422-1427, 1432.

Wu Xuemei, Liu Hongyun, Wang Fang, et al. Tobacco leaf grading based on improved Faster R-CNN network[J]. Computer and Digital Engineering, 2023, 51(6): 1422-1427, 1432. (in Chinese)

[8] Pan Y, Zhu N, Ding L, et al. Identification and counting of sugarcane seedlings in the field using improved Faster R-CNN[J]. Remote Sensing, 2022, 14(22): 5846.

[9] 马宏兴, 董凯兵, 王英菲, 等. 基于改进 YOLO v5s 的轻量化植物识别模型研究[J]. 农业机械学报, 2023, 54(8): 267-276.

- Ma Hongxing, Dong Kaibing, Wang Yingfei, et al. Research on lightweight plant recognition model based on improved YOLO v5s[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(8): 267–276. (in Chinese)
- [10] Kong S, Li J, Zhai Y, et al. Real-time detection of crops with dense planting using deep learning at seedling stage[J]. Agronomy, 2023, 13(6): 1503.
- [11] Lin H, Chen Z, Qiang Z, et al. Automated counting of tobacco plants using multispectral UAV data[J]. Agronomy, 2023, 13(12): 2861.
- [12] Ma B, Hua Z, Wen Y, et al. Using an improved lightweight YOLO v8 model for real-time detection of multi-stage apple fruit in complex orchard environments[J]. Artificial Intelligence in Agriculture, 2024, 11: 70–82.
- [13] 陈海涛, 王辉, 邓涛, 等. 基于 YOLO v8n 的罂粟识别改进算法研究[J]. 西南大学学报(自然科学版), 2025, 47(6): 201–212. Chen Haitao, Wang Hui, Deng Tao, et al. Research on improved poppy recognition algorithm based on YOLO v8n[J]. Journal of Southwest University (Natural Science Edition), 2025, 47(6): 201–212. (in Chinese)
- [14] 刘双喜, 张玮平, 胡宪亮, 等. 基于改进 YOLO v8s 的水稻种植机械作业质量检测[J]. 农业机械学报, 2024, 55(增刊1): 61–70. Liu Shuangxi, Zhang Weiping, Hu Xianliang, et al. Quality inspection of rice planting machinery operation based on improved YOLO v8s[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(S1): 61–70. (in Chinese)
- [15] 李尚平, 张超, 张彪, 等. 宿根蔗补种机轻量化蔗苗识别与定位技术[J]. 农业机械学报, 2024, 55(12): 44–56. Li Shangping, Zhang Chao, Zhang Biao, et al. Lightweight identification and positioning technology of ratoon sugarcane supplementary inoculation machine[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(12): 44–56. (in Chinese)
- [16] Chen R, Qi H, Liang Y, et al. Identification of plant leaf diseases by deep learning based on channel attention and channel pruning[J]. Frontiers in Plant Science, 2022, 13: 1023515.
- [17] Martins O O, Oosthuizen C C, Desai D A. RiceLeafClassifier-v1.0: a quantized deep learning model for automated rice leaf disease detection and edge deployment[J]. Engineering Reports, 2025, 7(6): e70231.
- [18] Dong Q, Gu R, Chen S, et al. Apple leaf disease diagnosis based on knowledge distillation and attention mechanism[J]. IEEE Access, 2024, 12: 65154–65165.
- [19] DB53/T 657—2014 烤烟小苗膜下移栽技术规程[S].
- [20] Terven J, Córdova-Esparza D M, Romero-González J A. A comprehensive review of yolo architectures in computer vision: from YOLO v1 to YOLO v8 and YOLO–NAS[J]. Machine Learning and Knowledge Extraction, 2023, 5(4): 1680–1716.
- [21] Li R, Li Y, Qin W, et al. Lightweight network for corn leaf disease identification based on improved YOLO v8s[J]. Agriculture, 2024, 14(2): 220.
- [22] 谭厚森, 马文宏, 田原, 等. 基于改进 YOLO v8n 的香梨目标检测方法[J]. 农业工程学报, 2024, 40(11): 178–185. Tan Housen, Ma Wenhong, Tian Yuan, et al. Improved YOLO v8n object detection of fragrant pears[J]. Transactions of the CSAE, 2024, 40(11): 178–185. (in Chinese)
- [23] Wang P, Luo Y, Zhu Z. FDI–YOLO: feature disentanglement and interaction network based on YOLO for SAR object detection[J]. Expert Systems with Applications, 2025, 260: 125442.
- [24] 翟亚红, 王杰, 徐龙艳, 等. 基于改进 YOLO v5n 的舍养绵羊行为识别方法[J]. 农业机械学报, 2024, 55(4): 231–240. Zhai Yahong, Wang Jie, Xu Longyan, et al. Sheep behavior recognition method based on improved YOLO v5n[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(4): 231–240. (in Chinese)
- [25] 赵会鹏, 曹景胜, 潘迪敬, 等. 改进 YOLO v8 算法的交通标志小目标检测[J]. 现代电子技术, 2024, 47(20): 141–147. Zhao Huipeng, Cao Jingsheng, Pan Dijing, et al. Improved YOLO v8 algorithm for traffic sign small target detection[J]. Modern Electronic Technology, 2024, 47(20): 141–147. (in Chinese)
- [26] Li C, Zhou A, Yao A. Omni-dimensional dynamic convolution[C]// International Conference on Learning Representation (ICLR), 2022.
- [27] 牟家宇, 南新元. 基于 YOLO v7–tiny 改进的交通标志小目标实时检测算法[J]. 科学技术与工程, 2024, 24(30): 13072–13079. Mou Jiayu, Nan Xinyuan. Improved real-time detection algorithm for small targets of traffic signs based on YOLO v7–tiny[J]. Science and Technology and Engineering, 2024, 24(30): 13072–13079. (in Chinese)
- [28] Shu T, Shen L, Zhang P. FADConv: a frequency-aware dynamic convolution for farmland non-agriculturalization identification and segmentation[J]. International Journal of Applied Earth Observation and Geoinformation, 2026, 146: 105014.
- [29] 罗斌, 李家超, 周亚男, 等. 基于改进 YOLO v8 的轻量化稻瘟病孢子检测方法[J]. 农业机械学报, 2024, 55(11): 32–38. Luo Bin, Li Jiachao, Zhou Ya'nan, et al. Lightweight rice blast spore detection method based on improved YOLO v8[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 32–38. (in Chinese)
- [30] 奚小波, 丁杰源, 翁小祥, 等. 基于轻量化 YOLO v5s–MCA 的番茄成熟度检测方法[J]. 农业机械学报, 2025, 56(3): 383–391, 436. Xi Xiaobo, Ding Jieyuan, Weng Xiaoxiang, et al. Tomato maturity detection method based on lightweight YOLO v5s–MCA[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(3): 383–391, 436. (in Chinese)