

杨如强, 赵霞, 张鑫. 基于改进 YOLOv11 模型的柑橘叶片病害检测[J]. 江苏农业学报, 2026, 42(1): 99-109.
doi: 10.3969/j.issn.1000-4440.2026.01.011

基于改进 YOLOv11 模型的柑橘叶片病害检测

杨如强, 赵霞, 张鑫

(甘肃农业大学信息科学技术学院, 甘肃 兰州 730070)

摘要: 为提高果园场景下柑橘叶片病害的检测精度, 本研究以 YOLOv11 模型为基准模型, 引入 GhostHGNetV2 网络替换原有的主干网络, 利用 C3k2_MSEIS 模块 (C3k2_MutilScaleEdgeInformationSelect) 和 ADown 模块替换原有模型颈部网络的 C3k2 模块和 Conv 模块, 并利用 MultiSEAMHead 替换原有检测头, 以增强模型对小目标的检测能力, 实现多尺度特征融合与融合路径优化, 提出一种改进的 YOLOv11 模型——YOLOv11-Citrus, 最后利用柑橘园获取的 4 种常见叶片病害影像对模型的检测性能进行分析。结果表明, 改进后的模型 YOLOv11-Citrus 对柑橘叶片病害的检测精确率、召回率和平均精度均值 mAP_{50} 分别比基准模型提高 3.4 个百分点、1.1 个百分点和 2.6 个百分点。与 RE-DETR、YOLOv5、YOLOv8、YOLOv10n 等主流模型相比, YOLOv11-Citrus 模型对柑橘叶片病害的识别具有更高的检测精确率和平均精度均值 mAP_{50} 。本研究结果为柑橘叶片病害的精准识别和有效防治提供了技术支持。

关键词: 柑橘; 病害检测; YOLOv11 模型; 特征融合

中图分类号: S127 **文献标识码:** A **文章编号:** 1000-4440(2026)01-0099-11

An improved YOLOv11 model for citrus leaf disease detection

YANG Ruqiang, ZHAO Xia, ZHANG Xin

(College of Information Science and Technology, Gansu Agricultural University, Lanzhou 730070, China)

Abstract: To improve the detection accuracy of citrus leaf diseases in orchard scenes, this study used the YOLOv11 model as the baseline model. The original backbone network was replaced with the GhostHGNetV2 network. The C3k2 and Conv modules in the original model's neck network were replaced with the C3k2_MSEIS module (C3k2_MutilScaleEdgeInformationSelect) and the ADown module, respectively. Furthermore, the original detection head was substituted with the MultiSEAMHead to enhance the model's ability to detect small targets, achieving multi-scale feature fusion and fusion path optimization. An improved YOLOv11 model (YOLOv11-Citrus) was proposed. Finally, the detection performance of the model was analyzed using images of four common leaf diseases collected from citrus orchards. The results showed that the improved YOLOv11-Citrus model achieved increases of 3.4 percentage points in detection accuracy, 1.1 percentage points in recall rate, and 2.6 percentage points in mean average precision (mAP_{50}) compared with the baseline model. Compared with mainstream models such as RE-DETR, YOLOv5, YOLOv8, and YOLOv10n, the YOLOv11-Citrus model demonstrated higher detection accuracy and mean average precision (mAP_{50}) in detecting citrus leaf diseases. The results of this study provide technical support for the accurate identification and effective control of citrus leaf diseases.

Key words: citrus; disease detection; YOLOv11 model; feature fusion

收稿日期: 2025-04-16

基金项目: 甘肃省自然科学基金项目 (24JRRA656)

作者简介: 杨如强 (2001-), 男, 甘肃宕昌人, 硕士研究生, 研究方向为智慧农业和目标检测。(E-mail) 2818300843@qq.com

通讯作者: 赵霞, (E-mail) 58892778@qq.com

柑橘 (*Citrus reticulata* Blanco), 涵盖橘、柑、橙、金柑、柚、枳等多种水果, 不仅风味独特, 还具

有较高的营养价值与药用价值。中国作为柑橘的重要原产地之一,拥有丰富的柑橘资源和繁多的优良品种^[1]。据世界柑橘组织统计,中国柑橘产量约占全球柑橘总产量的28%,种植面积和总产量均居世界首位。2023年,中国柑橘总产量约为 6.433×10^7 t,产值超过 1.986×10^{11} 元。然而,柑橘病害的发生严重影响其产量和质量,每年因病害造成的直接经济损失高达数百亿元,给种植者带来巨大的经济损失。柑橘病害多由叶片开始,随后逐渐蔓延至整个树体,因此及时准确地识别柑橘叶片病害类型对于病害的早期防治至关重要。

随着计算机视觉和深度学习技术的快速发展,自动化病害识别技术逐渐成为研究热点^[2]。与专家判断相比,病害的自动化检测更有利于病害的早期识别与防治,从而保障柑橘的安全生产,减少种植者的经济损失^[3]。目前,深度学习方法由于具有多层次结构提取目标特征及自动特征学习的能力,已成为目标检测领域的主流检测方法。在众多深度学习目标检测模型中,单阶段目标检测模型如YOLO (You only look once)系列^[4],以其高效且准确的检测能力,展现出巨大潜力^[5]。YOLO系列模型能直接在输入图像上进行目标检测,省略了候选区域生成阶段,从而显著提升了检测速度,因此,YOLO系列模型在众多农作物的病害检测中得到了广泛应用。

近年来,基于深度学习模型的作物病害检测得到较多研究,为作物病害的高精度检测提供了可能。Liu等^[6]在YOLOv3模型中引入图像金字塔技术,优化特征层,解决了传统方法中手动设计特征提取器且特征表达不准确的问题,提高模型对番茄病虫害识别和定位的精度。周俊昌等^[7]利用ShuffleNetv2重构YOLOv5骨干网络,并引入CARAFE上采样模块和FasterNet模块,添加GAM注意力机制,构建了YOLOv5-SCFG轻量模型。与原始模型相比,优化模型的大小和浮点计算量分别减少57%和61%,而平均精度均值(mAP)仅降低0.2%。曾晏林等^[8]在YOLOv5模型中,融入自注意力机制和Transformer模块,显著提升了模型对苹果叶片病害的识别能力。郭嘉璇等^[9]在YOLOv5模型中融入全局响应归一化(GRN)注意力机制,并引入形状交并比(SIoU)损失函数,构建

了YOLOv5-GRNS模型。与原始模型相比,改进模型具有更少的参数量和更低的浮点计算量,且对密集害虫目标具有更高的识别精度和更快的识别速率。郭文娟等^[10]分别在YOLOX-S和YOLOv7模型中引入SE、CBAM和ECA注意力模块,比较了不同模型和注意力机制对棉花病害的检测能力和注意力机制对棉花病害的检测能力,结果表明,YOLOX-S模型和CBAM注意力模块的组合对棉花病害的检测速度更快、检测精度更高。施国英等^[11]在YOLOv8s模型的基础上,利用RCS-OSA模块替换原模型颈部网络的C2f模块,用融合DCNv3的DyHead检测头替换原始检测头,并采用LAMP算法进行剪枝,构建了YOLOv8s-RDL模型,该模型在杭白菊菊米和胎菊的花期分类中平均精度分别达96.3%和97.7%,较YOLOv8s模型分别提升3.8个百分点和1.5个百分点,为杭白菊的自动化采摘提供了依据。曾亮等^[12]通过优化YOLOv8模型的颈部网络、检测头和损失函数,提高了模型对复杂背景环境下马铃薯叶片病害检测精度,减少了模型浮点计算量和参数量。党珊珊等^[13]在YOLOv10n模型的骨干网络中引入CBAM注意力机制,增强了模型对玉米叶片病害重要特征的关心程度,使得模型在不增加参数量和计算复杂度的情况下,模型对玉米叶片病害检测的精确度、召回率、平均精度均值分别增加2.2个百分点、1.2个百分点、1.7个百分点。靳学萌等^[14]以YOLOv10模型为基准模型,利用AKVanillaNet骨干网络和DysnakeConv模块优化特征提取,并采用PIoU损失函数改进模型识别性能,构建改进的YOLOv10-AD模型。与基准模型相比,改进模型对干制黄花菜等级划分的平均精度均值提升5.7%,每1s帧数增加25.8%。Chen等^[15]基于DenseNet模型^[16],利用深度可分离卷积代替传统卷积层,并嵌入注意力模块,增强学习通道间关系和提升空间点的重要性,采用迁移学习训练,设计了玉米病害识别模型Mobile-DANet,提高了模型对玉米病害的识别精度,并有效减少了模型推理时间。Nie等^[17]基于Faster-RCNN模型^[18]和多任务学习检测网络,引入注意力机制提取特征,开发了草莓黄萎病检测模型(SVWDN),应用效果表明,SVWDN模型对草莓幼叶和叶柄黄萎病的检测准确率达99.95%。蒋龙泉等^[19]采用基于特征包的多特征融合方法对植物叶片图像的

颜色、纹理和方向梯度等特征进行融合,形成特征向量,并利用支持向量机(SVM)分类器^[20]进行训练分类,结果显示,利用融合特征对植物病虫害的识别比单特征具有更高的准确率。

虽然深度学习模型在作物病害检测领域已取得一定进展,但将其直接应用于柑橘叶片病害目标检测仍然面临一些问题。受柑橘病害区域尺寸较小、柑橘园背景复杂以及叶片之间的相互遮挡等因素影响,模型对小目标检测效果欠佳,容易造成误判^[21-22]。黑斑病、黑点病、溃疡病、黄龙病是柑橘生长过程中的常见病害,对柑橘产量和品质有重要影响,对其准确识别对柑橘安全生产具有重要作用。针对生产中基于机器学习的柑橘叶片病害检测方法尚比较缺乏的现状,本研究以 YOLOv11 模型为基准模型,提出了一种改进的柑橘叶片病害检测方法,旨在提高复杂环境下柑橘叶片病害的检测精度,为柑橘病害的早期预警和精准防治提供技术支持。



图1 数据集示例照片

Fig.1 Example images from the dataset

1.2 柑橘叶片病害检测模型

1.2.1 YOLOv11 模型及其改进

YOLOv11 模型是 Ultralytics 团队于 2024 年 9 月推出的一种先进目标检测模型,其结构由骨干网络、颈部网络和检测头 3 部分组成^[24]。YOLOv11 模型结构如图 2 所示。YOLOv11 模型通过优化的 CSPDarknet53 骨干网络、高效的 C3k2 模块、空间金字塔池化快速模块(SPPF)、改进的 C2PSA 注意力机制等设计,在常规目标检测、目标姿态估计和定向目标检测等复杂任务中均展现出高效的检测性能。

本研究在 YOLOv11 模型的基础上,通过一系列改进措施,构建了 YOLOv11-Citrus 模型。改进主要体现在以下几个方面:引入 GhostHGNetV2

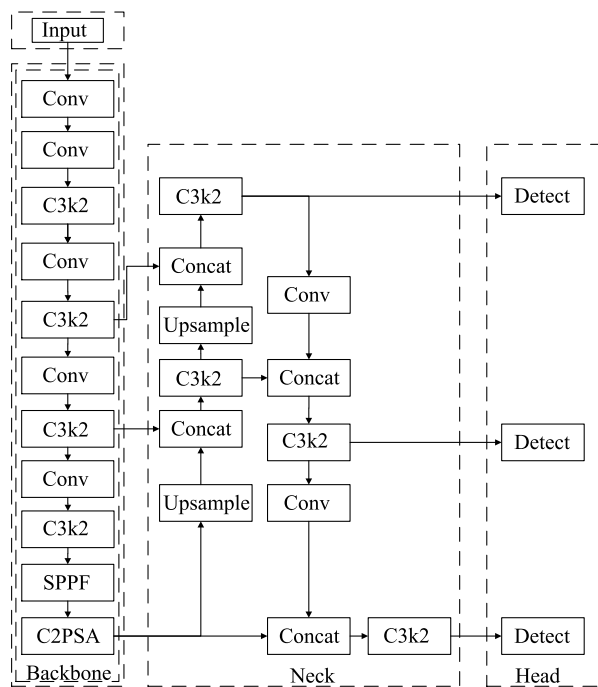
1 材料与方法

1.1 数据集构建

本研究使用智能手机 iPhone 13 Pro Max 在甘肃省陇南市文县柑橘果园拍摄 4 种常见病害(黑斑病、黑点病、溃疡病、黄龙病)叶片及健康叶片,共采集得到 4 191 幅图像。去除质量不佳的图像后,为了确保数据样本的独立性并提升检测模型的泛化能力,随机选择部分原始图像通过镜像旋转、裁剪、模糊等方法进行增强处理^[23],以提高数据集的多样性和平衡不同样本数量,最终获得 5 588 幅有效图像。不同病害叶片示例如图 1 所示。

使用 LabelImg 软件对数据集图像进行人工标注,将标注的标签分为黑斑病、黑点病、溃疡病、黄龙病和健康叶片 5 类,并将标注结果保存为 txt 格式。随后,将数据集按照 8 : 1 : 1 的比例随机划分为训练集、测试集和验证集,分别包含 4 470 幅、559 幅、559 幅图像。

网络替换原模型的主干网络,提高模型对小目标的特征提取能力和不同尺度数据融合能力,提升模型的检测精度和检测效率;采用 C3k2_MSEIS 模块替换原模型颈部网络中的 C3k2 模块,通过边缘增强与多尺度特征融合机制,提升特征提取的鲁棒性和准确性,强化模型对复杂背景下小目标的检测性能;引入 ADown 模块替换原模型颈部网络中的 Conv(常规卷积)模块,通过全局池化与卷积并行的下采样结构,实现更高效的特征信息保留,从而优化特征融合路径;将原有检测头替换为 MultiSEAMHead 检测头,通过特征交互增强检测能力。改进后的 YOLOv11-Citrus 模型结构如图 3 所示。



Input: 输入; Backbone: 主干网络; Neck: 颈部网络; Head: 头部网络; Conv: 卷积; C3k2: 特征提取模块; SPPF: 快速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; Detect: 检测头。

图 2 YOLOv11 模型结构图

Fig.2 Structure diagram of YOLOv11 model

1.2.2 GhostHGNetV2 网络 将 YOLOv11 主干网络替换为 GhostHGNetV2, 该网络是 HGNetV2 主干网络和 Ghost 卷积技术融合的改进版本, 其通过多尺度特征的融合与优化, 显著增强了模型对小目标的检测能力^[25]。GhostHGNetV2 网络的结构如图 4 所示。输入柑橘叶片病害图像后, 通过 HGStem 模块先进行卷积操作初步提取初始特征, 同步采用最大池化操作对卷积后的特征下采样, 捕捉柑橘叶片病害在不同尺度上的特征^[26], 然后对最大池化后的特征与之前经卷积得到的特征进行拼接, 实现多支路特征的融合, 让特征信息更丰富^[27]。再通过特定规格的卷积层处理, 进一步整合并优化特征维度。HGStem 模块结构如图 4 所示。Ghost_HGBlock 作为 GhostHGNetV2 主干网络的核心特征提取单元, 采用双路径并行架构处理输入特征。一条路径通过多个 3×3 Ghost 卷积层提取特征, 该卷积层先生成少量基础特征图, 再借助轻量线性变换生成额外的 Ghost 特征图, 在减少计算成本的同时提升提取特征多样性; 另一条路径则通过恒等映射直接传递原始输入信息, 避免基础特征流失。两路特征经拼接融

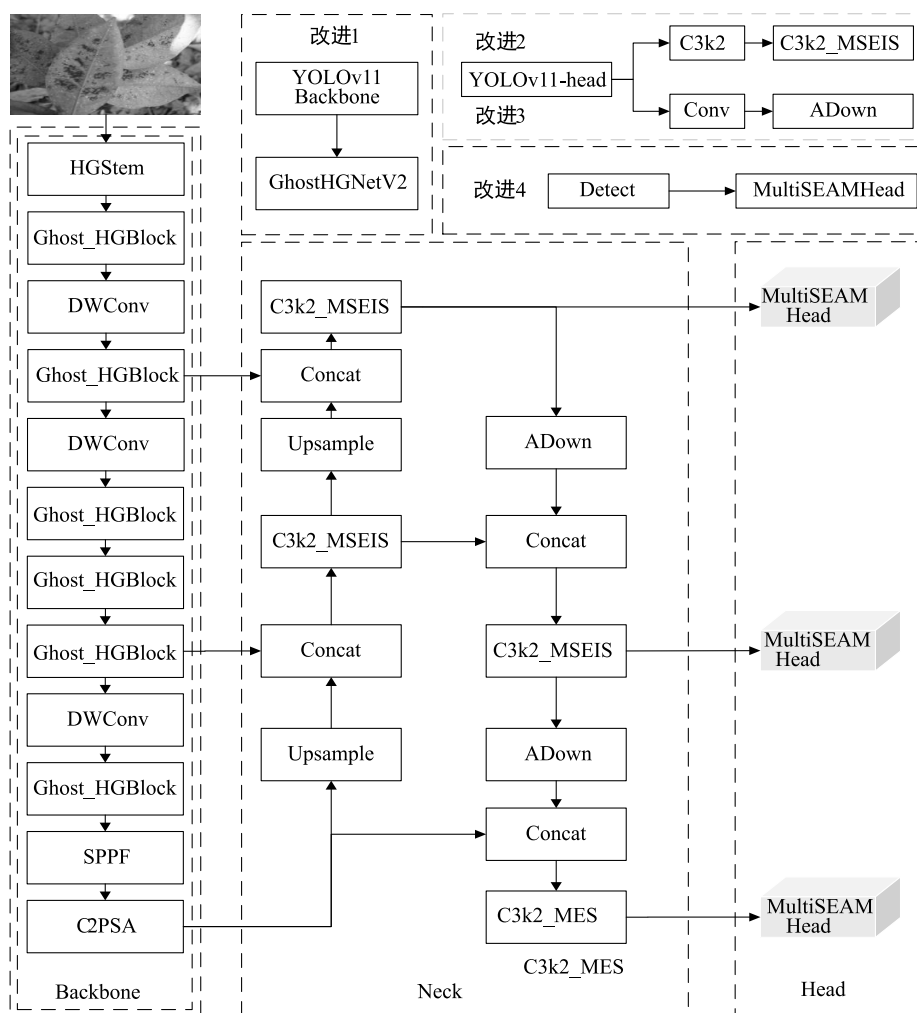
合后, 通过卷积完成通道维度的适配与优化, 在保持高效计算特性的同时具备更强的表征能力。

GhostHGNetV2 网络将原有的标准卷积替换为深度可分离卷积(DWConv)^[28]。DWConv 包括深度卷积和逐点卷积两个步骤: 深度卷积对每个输入通道独立进行卷积, 提取空间特征并避免通道间冗余计算, 增强对病害细节的提取能力, 而逐点卷积则跨通道融合病害特征, 提升对复合病害的判别能力。这种深度卷积和逐点卷积相分离的方式, 避免了通道间冗余计算, 从而显著降低了模型复杂度, 将参数量从传统卷积的 $D^2 \times k \times M \times N$ 减少为 $D^2 \times k \times M + M \times N$ 。结合 Ghost_HGBlock 模块的高效特征生成能力, 利用 DWConv 替代标准卷积不但能提高计算效率, 还能增强模型对不规则目标或变形目标的检测能力^[29]。DWConv 模块结构图如图 5 所示。

1.2.3 C3k2_MSEIS 模块 C3k2 模块是 YOLOv11 模型中用于特征提取的关键组件, 该模块在传统 C3 模块的基础上进行了改进。C3k2 模块通过引入可变卷积核和通道分离策略, 增强了特征提取的多尺度适应性。这种设计在保持较高计算效率的同时, 显著提升了特征提取精度和模型的适应性。然而, 尽管 C3k2 模块在特征提取方面表现出色, 但在柑橘病害叶片检测过程中, 由于叶片轮廓相似性较大, 该模块对边缘信息的捕捉能力不足, 难以有效区分目标细节。因此, 为了更好地提升模型性能, 本研究引入 C3k2_MSEIS 模块替换 C3k2, 从而增强边缘信息和融合多尺度信息, 以提升特征提取能力。

C3k2_MSEIS 模块利用自适应平均池化(AdaptiveAvgPool2d)提取多尺度特征, 并通过边缘增强(EdgeEnhancer)模块增强边缘信息。EdgeEnhancer 模块通过平均池化操作提取低频信息, 从原始特征图像中减去低频信息可以突出高频信息, 从而增强边缘信息。EdgeEnhancer 模块提取的增强边缘信息与自适应平均池化提取的多尺度特征以及原始的局部特征图拼接后, 输入到双域选择机制(DualDomainSelectionMechanism)模块中。双域选择机制模块基于注意力机制, 学习不同特征的重要性, 并选择最有用的信息输出, 最终通过卷积操作生成增强后的特征图, 提升模型检测性能。

1.2.4 下采样模块(ADown) ADown 是 YOLOv9 中采用的一种下采样卷积模块, 其主要优势在于能有效缓解深层网络中的梯度消失问题。鉴于柑橘病



GhostHGNetV2: 主干网络;HGStem: 初始特征提取模块; Ghost_HGBlock: 高效特征提取模块; DWConv: 深度可分离卷积模块; SPPF: 快速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_MSEIS: 特征提取模块; ADown: 下采样; MultiSEAM Head: 检测头。

图3 YOLOv11-Citrus 模型结构图
 Fig.3 Structure diagram of YOLOv11-Citrus model

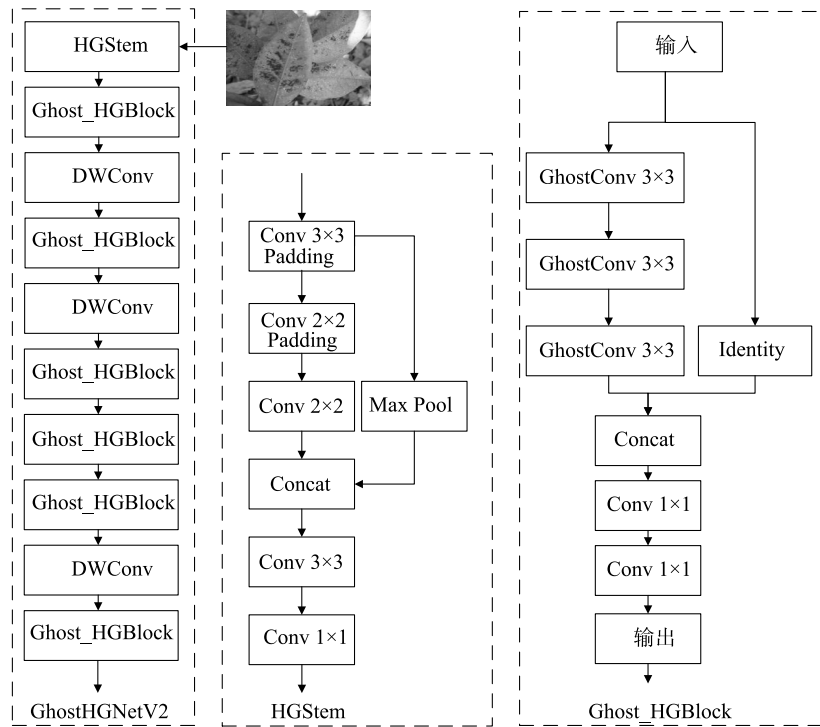
害叶片常呈现密集分布且纹理特征相似,为增强模型对细微特征的捕捉能力,本研究引入 ADown 模块^[30]替换 YOLO11 模型颈部网络中的 Conv 模块,从而在不增加卷积深度的情况下有效扩大感受野。

ADown 模块的结构如图 6 所示。其操作流程如下:首先,对输入特征图像进行全局平均池化,提取特征图像全局信息,降低空间分辨率并减少参数量,从而防止模型过拟合^[31]。接着,将特征图像沿通道方向分割为两部分,分别进行全局最大池化处理和3×3 卷积处理。全局最大池化在将特征图像的宽高减半的同时保留显著特征,3×3 卷积处理则能提取原始特征并调整通道数,同时实现空间下采样。

最后,将两部分输出在通道方向上进行融合,从而得到更全面的特征信息。这种设计在保留原始特征的基础上,增强了对重要特征的提取能力,提升了特征表达的丰富性^[32]。

1.2.5 MultiSEAMHead 检测头 在柑橘叶片病害检测中,早期病斑等小目标的精确检测是主要难点。为此,本研究引入 MultiSEAM 注意力机制对原检测头进行改进,旨在提升模型整体准确性及其多尺度识别能力,使其在目标遮挡、尺度多变及背景干扰等复杂场景下仍能保持较高的检测精度。

MultiSEAMHead 通过一种多层次特征增强机制提升检测性能^[33]。该机制利用多分支结构(基于多



GhostHGNetV2: 主干网络; HGStem: 初始特征提取模块; Ghost_HGBlock: 高效特征提取模块; DWConv: 深度可分离卷积模块; Conv: 卷积; Padding: 填充; MaxPool: 最大池化; GhostConv: Ghost 卷积; Identity: 恒等映射。

图 4 GhostHGNetV2 网络结构图

Fig.4 Structure diagram of GhostHGNetV2 network

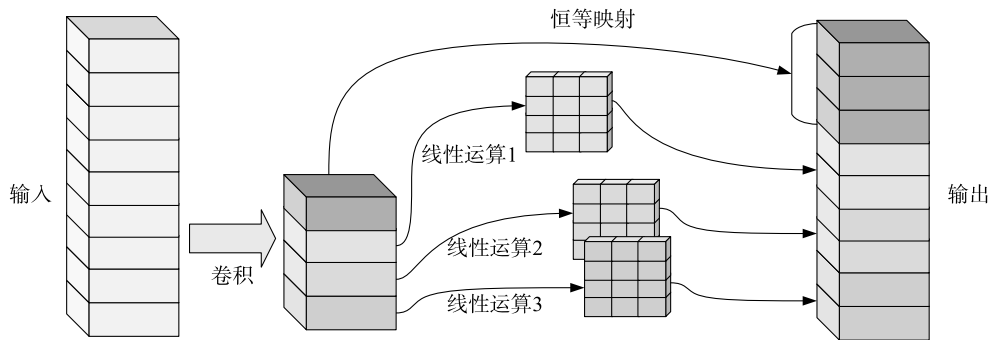


图 5 深度可分离卷积 (DWConv) 模块结构图

Fig.5 Structure diagram of depthwise separable convolution (DWConv) module

个 CSMM 子模块) 提取并融合多尺度上下文特征, 以捕捉不同尺度下的病害信息, 进而借助全局平均池化获取通道维度的全局统计量, 通过全连接层与激活函数生成通道注意力权重, 以精准建立通道间的依赖关系。最后将所得权重与原始特征图相乘实现关键特征的重新校准, 从而提升模型在复杂农业场景中的应用能力。

1.3 模型对柑橘叶片病害的识别性能比较

为评估各改进模块对柑橘叶片病害识别效果,

首先进行了模型改进方案的消融试验, 试验方案如表 1。然后, 将改进后的模型 YOLOv11-Citrus 与其他主流目标检测模型 RE-DETR、YOLOv5、YOLOv8、YOLOv10n 进行柑橘叶片病害检测性能比较。最后, 比较了 YOLOv11 和 YOLOv11-Citrus 模型在柑橘叶片病害检测混淆矩阵和热力图方面的差异, 以验证改进后的模型在柑橘叶片病害检测中的优势。

1.4 试验环境

为保证试验结果的一致性, 本研究统一在 Au-

toDL 平台上进行模型的训练和验证。模型的开发环境为 Pycharm, 操作系统为 Linux Ubuntu20.04.5, 显卡为 NVIDIA GeForce RTX 4090, 显存为 24 GB, 所用语言为 Python 3.10, 深度学习框架版本为 Pytorch 2.5.1, 统一计算设备架构 (CUDA) 版本为 11.8, Visual Studio Code (可视化代码编辑器) 版本为 1.95.2。模型训练参数设置如下: 图像输入尺寸 640 像素×640 像素, 批次 64, 多线程 16, 初始学习率 0.01, 优化器选择随机梯度下降 (SGD), 迭代次数 300 次。

表 1 消融试验方案设计

Table 1 Design of ablation experiment plan

方案	YOLOv11 模型	GhostHGNetV2 网络	C3k2_MSEIS 模块	下采样模块 (ADown)	MultiSEAMHead 检测头
1	√	0	0	0	0
2	√	√	0	0	0
3	√	0	√	0	0
4	√	0	0	√	0
5	√	0	0	0	√
6	√	√	√	0	0
7	√	√	√	√	0
8	√	√	√	0	√
9	√	0	√	√	√
10	√	√	√	√	√

√表示采用;0表示不采用。

1.5 评价指标


选取精确率 (P)、召回率 (R)、平均精度均值 (mAP) 作为评估模型性能的指标, 其计算公式如下:

$$P = \frac{TP}{TP+FP} \quad (1)$$

$$R = \frac{TP}{TP+FN} \quad (2)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n AP \quad (3)$$

式中, TP 为正确识别为正类的正样本数量, FP 为错误识别为正类的负样本数量, FN 为错误识别为负类的正样本数量, n 为病害类别数量, AP 为平均精度, 衡量的是模型在单个类别上的检测性能, 定义为 Precision-Recall 曲线下的面积, mAP 表示对所有类别的 AP 取平均值, 用于综合评估模型在所有类别上的整体性能。



GloAvgPool: 全局平均池化; Channel(2,1): 按照通道维度分割特征图, 将特征图切分为两部分; GloMaxPool: 全局最大池化; Conv: 卷积; Concat: 拼接。

图 6 ADown 模块结构图

Fig.6 Structure diagram of ADown module

2 结果与分析

2.1 消融试验结果

不同改进方案对模型性能的消融试验结果如表 2 所示。从表中可以看出, 基于 YOLOv11 原始模型 (方案 1) 对柑橘叶片病害进行检测, 平均精度均值 mAP_{50} 、平均精度均值 $mAP_{50:95}$ 、精确率、召回率分别为 90.6%、66.1%、84.6% 和 88.0%, 当利用 GhostHGNetV2 网络替换 YOLOv11 模型原有的主干网络后 (方案 2), 模型对柑橘叶片病害检测的精确率、召回率、平均精度均值 mAP_{50} 和平均精度均值 $mAP_{50:95}$ 分别比原始模型提高 0.6 个百分点、0.4 个百分点、1.8 个百分点和 0.8 个百分点, 这说明 GhostHGNetV2 模块能增强特征提取能力, 可提高柑橘叶片病害的综合检测精度。当利用 GhostHGNetV2 网络替换 YOLOv11 模型原有的主干网络及 C3k2_MSEIS 模块替换原始模型颈部网络中的 C3k2 模块 (方案

6)后,模型对柑橘叶片病害检测的精确率、召回率、平均精度均值 mAP_{50} 分别比方案 2 提升 0.4 个百分点、1.4 个百分点、0.2 个百分点,而平均精度均值 $mAP_{50:95}$ 下降 1.5 个百分点,这说明 GhostHGNetV2 网络与 C3k2_MSEIS 模块的协同改进,共同提升了模型的特征提取能力。其中,C3k2_MSEIS 模块通过其边缘增强与多尺度特征提取机制,对提升模型的精确率、召回率等指标进一步产生了积极的贡献。在方案 6 的基础上,进一步引入 ADown 模块替换原始模型颈部网络中的 Conv 模块(方案 7)后,模型对柑橘叶片病害检测的精确率、 $mAP_{50:95}$ 分别比方案 6 提升 0.5 个百分点、1.9 个百分点,这说明 ADown 模块能通过全局平均池化和最大池化策略,有效地整合多尺度特征信息,在与主干网络和特征提取模块共同作用下,进一步增强模型对细节特征的捕捉能力,提高模型的检测性能。在方案 7 的基础上,将 MultiSEAMHead 检测头与 Detect 模块融合后(方案 10),模型对柑橘叶片病害检测的精确率、召回率、平均精度均值 mAP_{50} 、平均精度均值 $mAP_{50:95}$ 分别达 88.0%、89.1%、93.2% 和 69.0%,比方案 7 分别提升 1.9 个百分点、0.3 个百分点、1.3 个百分点和 2.9 个百分点。由此可知,改进后的 YOLOv11-Citrus 模型比原始模型 YOLOv11 具有更出色的柑橘叶片病害检测能力,能够更准确地识别柑橘叶片病害类型,有效降低误判率和漏检率,为柑橘的病害防治提供强有力的技术支持。

表 2 消融试验结果

Table 2 Results of ablation experiments

试验方案	平均精度均值 (mAP_{50})(%)	精确率 (%)	召回率 (%)	平均精度均值 ($mAP_{50:95}$)(%)
方案 1	90.6	84.6	88.0	66.1
方案 2	92.4	85.2	88.4	66.9
方案 3	91.2	85.7	84.3	64.8
方案 4	91.9	83.9	88.5	67.0
方案 5	91.5	84.8	89.9	64.9
方案 6	92.6	85.6	89.8	65.4
方案 7	91.9	86.1	88.8	67.3
方案 8	91.3	84.1	88.3	67.1
方案 9	89.7	82.4	87.1	63.1
方案 10	93.2	88.0	89.1	69.0

方案 1~方案 10 见表 1。

2.2 不同模型的检测性能

在相同训练参数下,YOLOv11-Citrus 模型与 RE-DETR、YOLOv5、YOLOv8、YOLOv10n、YOLOv11 等模型对柑橘叶片病害检测性能如图 7 和表 3 所示。从图 7 中可以看出,YOLOv11-Citrus 模型在训练初期就展现出优秀的学习能力,其 mAP_{50} 值迅速上升,迭代 50 次后开始趋于稳定。这种快速提升和稳定的训练过程说明 YOLOv11-Citrus 在目标检测任务中不仅具有更高的准确性,而且展现出良好的泛化能力。

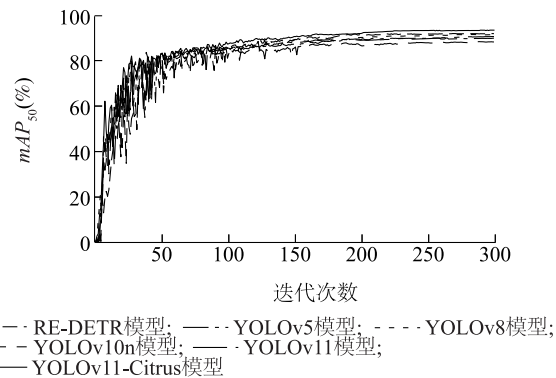


图 7 不同模型对柑橘叶片病害检测平均精度均值 (mAP_{50}) 随迭代次数的变化

Fig.7 Mean average precision (mAP_{50}) of different models for citrus leaf disease detection across training iterations

表 3 不同模型对柑橘叶片病害的检测效果

Table 3 Detection performance of different models on citrus leaf diseases

模型	平均精度均值 (mAP_{50})(%)	精确率 (%)	召回率 (%)	平均精度均值 ($mAP_{50:95}$)(%)
RE-DETR	91.8	87.6	89.1	69.2
YOLOv5	89.6	80.4	89.1	60.7
YOLOv8	91.4	84.7	88.2	64.5
YOLOv10n	88.1	79.9	85.9	59.2
YOLOv11	90.6	84.6	88.0	66.1
YOLOv11-Citrus	93.2	88.0	89.1	69.0

YOLOv11-Citrus 模型对柑橘叶片病害检测的精确率和平均精度均值 mAP_{50} 分别比 RE-DETR 模型提高 0.4 个百分点和 1.4 个百分点,召回率一致, $mAP_{50:95}$ 下降 0.2 个百分点;相较于 YOLOv5 模型,YOLOv11-Citrus 模型的检测精确率、 mAP_{50} 、 $mAP_{50:95}$ 分别提升 7.6 个百分点、3.6 个百分点、8.3 个百分点;与 YOLOv8 模型相比,YOLOv11-Citrus 模型的检测精确率、召回率、 mAP_{50} 、

$mAP_{50:95}$ 分别提升 3.3 个百分点、0.9 个百分点、1.8 个百分点、4.5 个百分点;YOLOv11-Citrus 模型对柑橘叶片病害检测的精确率、召回率、 mAP_{50} 、 $mAP_{50:95}$ 分别比 YOLOv10n 模型提高 8.1 个百分点、3.2 个百分点、5.1 个百分点、9.8 个百分点。上述结果说明,与其他模型相比,本研究改进的 YOLOv11-Citrus 模型具有更好地检测复杂环境中柑橘叶片病害的能力。

2.3 改进模型 YOLOv11-Citrus 对柑橘叶片病害及健康叶片的检测性能

改进模型 YOLOv11-Citrus 对柑橘不同类型病害及健康叶片的检测结果如表 4 所示。从表中可以看出,模型对柑橘叶片黑斑病检测的精确率、召回率和平均精度均值 mAP_{50} 分别为 82.8%、100.0% 和 99.5%,识别精准且误判率低。模型对柑橘叶片黑点病检测的精确率、召回率和平均精度均值 mAP_{50} 分别为 83.6%、88.5%、92.8%,表现均衡。模型对柑橘叶片溃疡病检测的精确率、召回率和平均精度均值 mAP_{50} 分别为 88.4%、81.3%、90.2%,有进一步提升的空间。模型对柑橘叶片黄龙病检测的精确率、召回率和平均精度均值 mAP_{50} 分别为 86.2%、76.0%、84.0%,效果相对较差,说明模型对该病害的识别能力仍需进一步提升。模型对柑橘健康叶片检测的精确率、召回率和平均精度均值 mAP_{50} 分别为 99.2%、99.9%、99.5%,识别极为准确。总体上,改进模型 YOLOv11-Citrus 对柑橘叶片病害检测的准确率、召回率、平均精度均值 mAP_{50} 分别达 88.0%、89.1% 和 93.2%,这说明改进模型在柑橘叶片病害检测中综合性能出色,能有效应用于实际检测,具备

实际应用价值。

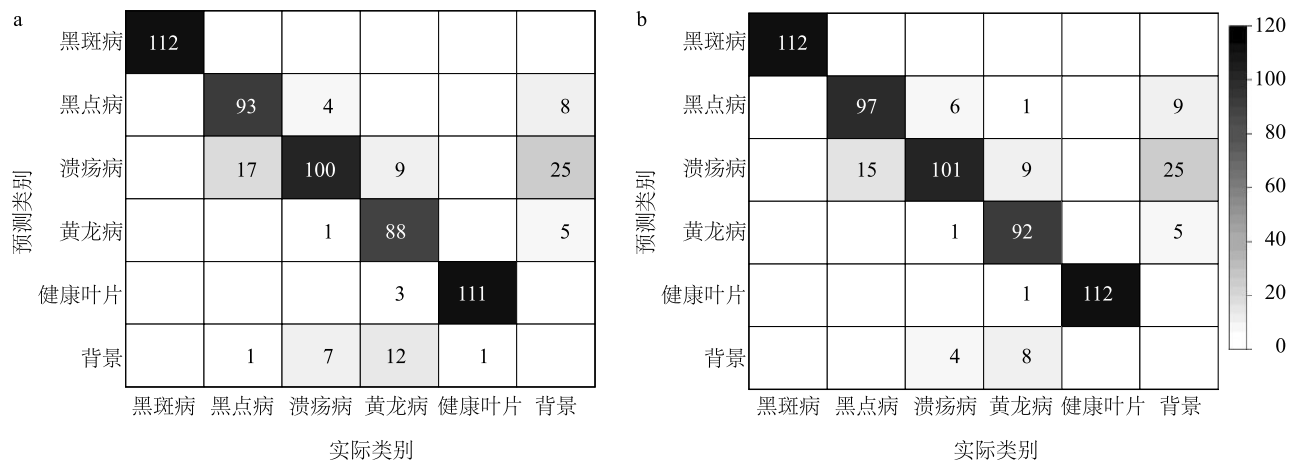
表 4 不同柑橘叶片病害的检测效果

Table 4 Detection performance on various citrus leaf diseases

类别	平均精度均值 (mAP_{50}) (%)	精确率 (%)	召回率 (%)
黑斑病	99.5	82.8	100.0
黑点病	92.8	83.6	88.5
溃疡病	90.2	88.4	81.3
黄龙病	84.0	86.2	76.0
健康叶片	99.5	99.2	99.9

2.4 改进模型 YOLOv11-Citrus 对柑橘叶片病害的识别效果

2.4.1 混淆矩阵分析 混淆矩阵是常用的检测结果分析工具^[34]。YOLOv11 模型和 YOLOv11-Citrus 模型对柑橘叶片病害验证集检测的混淆矩阵如图 8 所示。从图中可以看出,YOLOv11 模型对柑橘叶片黑斑病检测全部准确,对健康叶片的检测存在 1 个误判,而在黑点病、溃疡病和黄龙病的识别上,模型容易将这些病害与其他类别混淆,黑点病、溃疡病和黄龙病的误判样本数量分别为 18 个、12 个和 24 个。而利用 YOLOv11-Citrus 模型进行检测,黑斑病和健康叶片的检测均全部准确,黑点病、溃疡病和黄龙病的误判样本数量有所减少,分别为 15 个、11 个和 19 个。因此,YOLOv11-Citrus 模型在柑橘叶片病害检测中的表现更为出色,不仅提高了检测的准确性,还降低了误判率和漏检率,具有更高的识别能力。



a: YOLOv11 模型的混淆矩阵;b: YOLOv11-Citrus 模型的混淆矩阵。

图 8 YOLOv11 模型和 YOLOv11-Citrus 模型对柑橘叶片病害检测的混淆矩阵

Fig.8 Confusion matrices of YOLOv11 and YOLOv11-Citrus models for citrus leaf disease detection

2.4.2 热力图分析 YOLOv11 模型和 YOLOv11-Citrus 模型对柑橘叶片病害检测的热力图差异如图 9 所示。从图中可以看出,原始模型 YOLOv11 对柑橘叶片病害的识别准确性相对较低,易将部分背景区域和健康区域误标记为病害区域,产生误报,同时存在漏检现象。这种误报、漏检现象不仅会影响病害诊断的准确性,还可能影响病害防治的及时性和有效性。相比之下,改进模型 YOLOv11-Citrus 在病害识别中表现出显著的优越性,模型能更精确地定位病害区域,显著减少错误识别和漏检的情况,且改进模型识别的高亮区域与实际病害位置高度一致,对病害区域的识别更加完整和准确,这不但提高了模型的识别精度,还改善了病害诊断的整体可靠性。




图9 YOLOv11 模型和 YOLOv11-Citrus 模型对不同病害识别的热力图

Fig.9 Heat maps of YOLOv11 and YOLOv11-Citrus models for identifying different citrus leaf diseases

3 结论

本研究在 YOLOv11 模型的基础上,采用 GhostHGNetV2 网络替换原模型的主干网络,C3k2_MSEIS 模块替换原模型颈部网络的 C3k2 模块,引

入 ADown 模块替换原模型颈部网络中的 Conv 模块,并将检测头 Detect 替换为 MultiSEAMHead,构建了 YOLOv11-Citrus 模型。改进后的 YOLOv11-Citrus 模型对柑橘叶片病害检测的准确率、召回率、平均精度均值 mAP_{50} 、平均精度均值 $mAP_{50:95}$ 分别达 88.0%、89.1%、93.2% 和 69.0%,分别比原模型提高提升 3.4 个百分点、1.1 个百分点、2.6 个百分点和 2.9 个百分点,展现出良好的柑橘叶片病害检测能力。消融试验验证了 4 个改进模块的协同作用能够优化 YOLOv11 模型,从而有效降低了病害检测的误判率和漏检率。与 RE-DETR、YOLOv5、YOLOv8、YOLOv10n、YOLOv11 等主流目标检测模型相比, YOLOv11-Citrus 模型对柑橘叶片病害检测的精确率、召回率、平均精度均值 mAP_{50} 、平均精度均值 $mAP_{50:95}$ 等指标总体上均有不同程度的提升。综上, YOLOv11-Citrus 模型可以为柑橘种植者提供更为可靠的病害预警结果,这有利于柑橘叶片病害早期防治,能有效降低因病害导致的经济损失,保障柑橘产业的可持续发展。

参考文献:

- [1] 帖军,赵捷,郑禄,等.改进 YOLOv5 模型在自然环境下的柑橘识别的应用[J].中国农业科技导报,2024,26(7):111-120.
- [2] 周秀珊,文露婷,介百飞,等.改进 YOLOv11 的水面膨化饲料颗粒图像实时检测算法[J].智慧农业(中英文),2024,6(6):155-167.
- [3] 王会征,孙良晨,李新龙,等.基于改进 YOLOv7-tiny 的番茄叶片病虫害检测方法[J].农业工程学报,2024,40(10):194-202.
- [4] 周维,牛永真,王亚炜,等.基于改进的 YOLOv4-GhostNet 水稻病虫害识别方法[J].江苏农业学报,2022,38(3):685-695.
- [5] 徐彦威,李军,董元方,等. YOLO 系列目标检测算法综述[J].计算机科学与探索,2024,18(9):2221-2238.
- [6] LIU J, WANG X W. Tomato diseases and pests detection based on improved yolo V3 convolutional neural network[J]. Frontiers in Plant Science,2020,11:898.
- [7] 周俊昌,曾维,彭鹏,等.苹果叶片病害检测的轻量化 YOLOv5 研究与实现[J].中国农机化学报,2025,46(4):126-132.
- [8] 曾晏林,贺壹婷,蔺瑶,等.基于 BCE-YOLOv5 的苹果叶部病害检测方法[J].江苏农业科学,2023,51(15):155-163.
- [9] 郭嘉璇,王蓉芳,南江华,等.融入全局相应归一化注意力机制的 YOLOv5 农作物害虫识别模型[J].农业工程学报,2024,40(8):159-170.
- [10] 郭文娟,冯全.基于改进 YOLO 的棉花叶片病害检测[J].干旱地区农业研究,2024,42(6):195-205.

- [11] 施国英,纪嘉鹏,李天华,等. 基于改进 YOLOv8s 的杭白菊检测与花期分类[J]. 农业工程学报,2025,41(7):192-199.
- [12] 曾亮,彭龔. 基于改进 YOLOv8 的马铃薯叶片病害检测算法[J]. 洛阳理工学院学报(自然科学版),2024,34(3):62-69.
- [13] 党珊珊,白明宇,路扬,等. 基于改进 YOLOv10n 的玉米叶片病害检测研究[J]. 内蒙古民族大学学报(自然科学版),2025,40(2):69-76.
- [14] 靳学萌,梁西银,邓鹏飞. 基于改进 YOLOv10 的轻量级黄花菜分级检测模型[J]. 智慧农业(中英文),2024,6(5):108-118.
- [15] CHEN J D, WANG W H, ZHANG D F, et al. Attention embedded lightweight network for maize disease recognition[J]. Plant Pathology,2021,70(3):630-642.
- [16] GONG H, LIU T H, LUO T Y, et al. Based on FCN and DenseNet framework for the research of rice pest identification methods[J]. Agronomy,2023,13(2):410.
- [17] NIE X, WANG L Y, DING H X, et al. Strawberry *Verticillium* wilt detection network based on multi-task learning and attention[J]. IEEE Access,2019,7:170003-170011.
- [18] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2017,39(6):1137-1149.
- [19] 蒋龙泉,鲁帅,冯瑞,等. 基于多特征融合和 SVM 分类器的植物病虫害检测方法[J]. 计算机应用与软件,2014,31(12):186-190.
- [20] CHAUDHARI D J, MALATHI K. Detection and prediction of rice leaf disease using a hybrid CNN-SVM model[J]. Optical Memory and Neural Networks,2023,32(1):39-57.
- [21] 韩宇,齐康康,郑纪业,等. 基于改进 YOLOv11 的轻量化肉牛面部识别方法[J]. 智慧农业(中英文),2025,7(3):173-184.
- [22] 杨森,陈义明. 基于 YOLOv11-PMS 的草莓目标检测方法[J]. 农业与技术,2025,45(16):1-7.
- [23] 刘鹏,张天翼,冉鑫,等. 基于 PBM-YOLOv8 的水稻病虫害检测[J]. 农业工程学报,2024,40(20):147-156.
- [24] 李彬,李生林. 改进 YOLOv11n 的无人机小目标检测算法[J]. 计算机工程与应用,2025,61(7):96-104.
- [25] 朱康凯,侯红玲,杨澳,等. 干涉配合铆接缺陷检测方法研究[J]. 塑性工程学报,2025,32(2):96-104.
- [26] 孙月平,孟祥汶,郭佩璇,等. 基于改进 YOLOv8n 的渔光互补池塘作业船导航中线提取方法[J]. 农业工程学报,2024,40(22):173-182.
- [27] YUE M, ZHANG L Q, HUANG J, et al. Lightweight and efficient tiny-object detection based on improved YOLOv8n for UAV aerial images[J]. Drones,2024,8(7):276.
- [28] 张磊,李熙尉,燕倩如,等. 基于改进 YOLOv5s 的综采工作面人员检测算法[J]. 中国安全科学学报,2023,33(7):82-89.
- [29] LI M, ZHANG J C, LIU H B, et al. A lightweight method for apple-on-tree detection based on improved YOLOv5[J]. Signal, Image and Video Processing,2024,18(10):6713-6727.
- [30] 许英超,刘书玮,王相友,等. 基于改进 YOLOv8n 的轻量化马铃薯表面缺陷在线检测方法[J]. 农业工程学报,2025,41(5):135-144.
- [31] 董一兵,曾辉,侯少杰. LMUAV-YOLOv8:低空无人机视觉目标检测轻量化网络[J]. 计算机工程与应用,2025,61(3):94-110.
- [32] WANG Y, RONG Q J, HU C H. Ripe tomato detection algorithm based on improved YOLOv9[J]. Plants,2024,13(22):3253.
- [33] YAN C M, XU E E. ECM-YOLO:a real-time detection method of steel surface defects based on multiscale convolution[J]. Journal of the Optical Society of America A,2024,41(10):1905-1914.
- [34] 李芳,危疆树,王玉超,等. 基于改进 YOLOv8n 模型的辣椒病害检测方法[J]. 江苏农业学报,2025,41(2):323-334.

(责任编辑:石春林)