

改进 YOLO11n-WCL 的轻量化番茄叶病害检测算法^{*}郭智超^{1,2} 马双宝^{1,2}

(1. 武汉纺织大学机械工程与自动化学院 武汉 430200; 2. 湖北省数字化纺织装备重点实验室 武汉 430200)

摘 要: 针对现有番茄叶片病害检测算法存在的检测精度低、计算量大及部署困难等问题,提出了一种基于 YOLO11n 模型的轻量化改进算法 YOLO11-WCL。所提算法在主干网络中引入 Wavelet Pool 替代下采样阶段,以降低网络复杂度;在 Neck 层引入轻量化 CA-HSFPN 以解决多尺度检测问题;同时采用 LADH 检测头提升模型推理速度。基于实验数据集,进行了轻量化网络对比、不同检测算法对比及消融实验。结果表明,YOLO11-WCL 模型参数量和计算复杂度仅为原 YOLO11n 模型的 50.1% 和 60.3%,分别对应 1.29 MB 和 3.8 GFLOPs,同时 mAP 可达 98.5%。实验验证了所提算法在保证模型紧凑性的同时显著提升了番茄叶片病害检测精度,适合在无人机等移动终端部署,具有广泛的应用前景和市场潜力。

关键词: 番茄叶病害;YOLO11n;Wavelet Pool;高效解耦合;轻量化;目标检测

中图分类号: TP391.4; TN911.7 **文献标识码:** A **国家标准学科分类代码:** 520.60

Research on improved lightweight tomato leaf disease
detection algorithm based on YOLO11n-WCLGuo Zhichao^{1,2} Ma Shungbao^{1,2}

(1. College of Mechanical Engineering and Automation, Wuhan Tertile University, Wuhan 430200, China;

2. Key Laboratory of Digitized Textile Equipment of Hubei Province, Wuhan 430200, China)

Abstract: To address the issues of low detection accuracy, high computational cost and deployment difficulties in existing tomato leaf disease detection algorithms, this paper proposes a lightweight improved algorithm, YOLO11-WCL, based on the YOLO11n model. The algorithm introduces lightweight anti-aliasing wavelet pooling in the backbone network to replace traditional downsampling operations, effectively reducing network complexity. In the Neck part, a lightweight CA-HSFPN module is incorporated to enhance multi-scale feature fusion, while the LADH detection head is adopted to improve inference speed. Based on the experimental dataset, comparative analyses of lightweight networks, different detection algorithms, and ablation experiments were conducted. The experimental results show that the YOLO11-WCL model achieves only 50.1% and 60.3% of the parameters and computational complexity of the original YOLO11n model, corresponding to 1.29 MB and 3.8 GFLOPs, respectively, while reaching an mAP of 98.5%. These findings demonstrate that the proposed algorithm significantly improves the detection accuracy of tomato leaf diseases while maintaining model compactness, achieving high detection efficiency and good generalization performance. It is suitable for deployment on UAVs and other mobile devices, with broad application prospects and practical market potential.

Keywords: tomato leaf disease;YOLO11n;Wavelet Pool;efficient decoupling;lightweight;object detection

0 引 言

农业病虫害是全球农业产量损失的主要因素之一^[1]。据统计,欧洲因病虫害造成的农业经济损失约占产值的 28.2%,北美为 31.2%,而亚洲和非洲的损失率更是 50%

以上^[2]。番茄作为重要的经济作物,其叶部病害(包括叶霉病、黄化卷叶病毒病、早疫病以及晚疫病等)对产量和品质均构成严重威胁。因此,及时防治番茄叶部病害是提高番茄质量和产量的关键举措,而精准识别番茄叶部病害种类是番茄病虫害精准防控的前提。

传统的番茄叶片病害检测通常依赖经验丰富的专业人员通过人工观察进行判别^[3]。虽然这种方法具有一定的可靠性,但存在检测效率低、人力成本高等问题,且容易受到外界环境因素的干扰。为满足农业病害精准防治的需求,深度学习算法检测越来越普及,通过自动化识别技术辅助实现番茄病害的快速诊断与科学防治。

近年来,随着计算机视觉与深度学习技术的快速发展及其在学术界的持续关注,叶片病害智能检测技术在现代番茄生产体系中的融合应用已成为设施农业智能化转型的重要表征。深度学习技术凭借其卓越的自主特征学习机制,显著增强了深度神经网络在复杂农业场景下的检测能力,现已成为作物病害识别领域的研究前沿与创新方向,其衍生出的田间监测系统、移动端诊断平台等创新应用正推动着植保技术范式的革新。目前,基于深度学习的神经网络通常被分为两类:分别为以R-CNN(region-based convolutional neural network)、Fast-R-CNN、Mask R-CNN^[4-6]为代表的两阶段算法和以YOLO(you only look once)^[7]系列和SSD(single shot multibox detector)^[8]以及基于Transformer的目标检测算法DETR(detection transformer)^[9]等为代表的一阶段算法。

在两阶段检测算法方面,樊湘鹏等^[10]通过改进Faster R-CNN并引入混合代价函数,使玉米病害识别精度超过97%,但模型计算量大、推理速度较慢,难以适应实时田间检测需求。Sanida等^[11]基于VGG-Net(visual geometry group network)与Inception模块提出了一种两阶段迁移学习方法,并通过改进交叉熵损失函数与迁移学习策略,有效提升了番茄病害识别的准确。Nawaz等^[12]将Faster R-CNN与ResNet-34结合,用作特征提取骨干网络,实现了番茄叶片多病害的同时定位与分类,其在公共数据集上的实验结果表明,该方法的mAP达到89.7%,但小病斑检测能力有限,且对光照变化和叶片遮挡的鲁棒性不足。Liu等^[13]则提出了多尺度约束可变形卷积网络(multi-scale convolution and dilated convolution network, MCDC-Net),能够在多尺度和几何变换条件下提取判别性特征,显著提升了苹果叶片病害检测精度,检测性能达到66.8%。但模型对复杂背景下的小病斑仍存在漏检问题。

在此基础上,Paul等^[14]构建了一种结合VGG-16与迁移学习的卷积神经网络,用于11种番茄病害的分类。尽管该方法提高了分类精度,但模型体量大、推理速度慢,对移动端和田间部署不友好。Yao等^[15]提出了一种两阶段框架,利用YOLOv8实现叶片精准定位,并结合改进的U-Net进行病斑分割,其叶片识别精度达到95.3%。但推理耗时显著,难以满足实时检测要求。此外,Li^[16]基于K-means聚类优化Faster R-CNN,以提升玫瑰病虫害的检测能力。但在病害症状重叠、病斑极小的情况下识别准确性仍不足。吕继东等^[17]在Mask R-CNN检测与分割框架的基础上,引入膨胀卷积优化方法,并结合候选框与像素级分

割策略,使模型的F1指标提升了2.17%、1.87%和4.93%。但模型结构复杂,对光照变化和叶片遮挡敏感,推理速度较慢。

相比于两阶段的算法,单阶段检测算法由于省略了候选区域生成过程,显著提升了推理速度,具备实时检测能力。凭借端到端的网络架构设计,该类方法在多尺度目标检测任务中表现出良好的适应性,因而在作物病害检测研究中受到广泛关注。Zhai等^[18]针对SSD模型层间特征互补不足以及小目标检测性能较差的问题,提出了一种改进的SSD算法,通过引入DenseNet架构与特征融合机制,使其在VOC 2007数据集上的平均准确率均值(mean average precision, mAP)提升了3.1%。但对于极小病斑与强光照条件仍存在漏检问题,且模型轻量化不足。张福豹等^[19]提出了一种将弱光增强与YOLOv3相结合的目标检测方法,利用RRDNet对低照度图像进行自适应增强以恢复暗部细节,并通过增加特征金字塔网络(feature pyramid network, FPN)输出层、重新聚类先验框及引入广义交并比(generalized intersection over union, GIoU)损失函数提升小目标检测精度。实验结果表明,该方法在弱光环境下能够有效改善检测性能,降低漏检率与误检率,但在复杂场景下的泛化能力及轻量化部署方面仍有进一步提升空间。

在此基础上,张泽辰等^[20]提出了一种基于小目标感知增强的风机叶片缺陷检测方法,通过在YOLOv8框架中引入动态通道空间卷积模块与多尺度Transformer结构,增强小尺度缺陷的特征表征能力,并结合自适应分布交并比损失提升定位精度。实验结果表明,该方法在自建海上风机叶片数据集上较YOLOv8与RT-DETR取得了更高的检测精度。王海瑞等^[21]针对葡萄叶片细小病害及相似症状识别率低的问题,改进RT-DETR网络,引入坐标注意力增强特征提取、高低频注意力提升对微小病害的检测,并优化跨层特征融合。实验表明,改进模型在精度、召回率和mAP上均优于原模型及其他主流方法,能有效识别相似和微小病害。但DETR类模型在轻量化和实时推理方面仍存在性能瓶颈。

考虑到上述国内外学者对作物叶片病害检测识别的研究中存在的一些问题,例如,精确度低、检测速度慢、模型参数大等,在自然环境中,番茄叶病检测面临光照条件变化、病害症状重叠、病灶面积小、叶片间遮挡等诸多挑战。本文提出了一种高效、准确的轻量化YOLO11n番茄叶片病害检测算法YOLOv11n-WCL。本文模型的创新之处如下:1)在主干网络层引入Wavelet pool替换原有的YOLO11n主干网络中的卷积部分,强化病斑区域的细节表征;2)为了解决斑点大小多样、形状复杂等问题,在Neck层引入轻量级的坐标注意力高层语义特征金字塔网络(coordinate attention-hierarchical spatial feature pyramid network, CA-HSFPN)用于更好解决番茄叶病害检测中的多尺度问题;3)最后,采用轻量化的非对称解耦检测头

(local attention dynamic head, LADH)检测头降低模型的训练难度,同时提高推理速度。在番茄叶片病害检测数据集上的实验结果表明:本文算法能同时平衡检测精度与速度,解决模型复杂程度高的问题,便于部署在算力资源有限的设备中。

1 番茄叶病害检测 YOLO11n-WCL 模型

本文在 YOLO11n 模型的基础上进行了轻量化改进,

提出番茄叶病害检测 YOLO11n-WCL 模型以进一步提升番茄叶病害检测的精度与实时性能。改进后的 YOLO11n-WCL 模型如图 1 所示。首先,在主干网络中引入 Wavelet Pool 结构以替代部分卷积层,强化病斑区域的细节表征。其次,通过 CA-HSFPN 模块以增强多尺度特征的表达能力,改善复杂病斑特征的检测效果。最后,在检测头部分采用高效轻量的 LADH 检测头,以降低模型训练难度并提升推理速度,实现检测精度与计算效率的平衡。




图 1 改进 YOLO11 模型

Fig. 1 Improved YOLO11 model

1.1 Wavelet Pool 模块

番茄叶病害形状多样且大小不一,加之病斑颜色与叶片背景高度相近,给语义特征提取带来挑战。为解决上述问题,本研究引入改进的 Wavelet Pool 模块,利用多尺度频域分解与融合,强化病斑区域的细节表征,有效提升对遮挡、光照变化等复杂场景下的检测鲁棒性。该模块基于二维离散小波变换实现特征的二级分解,并在保留第 2 级高、低频子带的同时丢弃第 1 级子带,以达到降维、去冗余和噪声抑制的目的。其过程如下:式(1)表示对输入特征在第 j 层进行低频分解,式(2)表示对输入特征第 j 层进行高频分解。

$$W_{\varphi}[j+1, k] = h_{\varphi}[-n] * W_{\varphi}[j, n] \mid_{n=2k, k \leq 0} \quad (1)$$

$$W_{\psi}[j+1, k] = h_{\psi}[-n] * W_{\psi}[j, n] \mid_{n=2k, k \leq 0} \quad (2)$$

其中,近似函数 φ 与细节函数 ψ 分别生成近似系数 W_{φ} 和细节函数 W_{ψ} 。 $h_{\varphi}[-n]$ 和 $h_{\psi}[-n]$ 表示时域翻转尺度向量和时域翻转小波向量。其中 $[-n]$ 表示矢量中的样本, j 表示分解的尺度级别。经两次行列方向的小波变换后可获得 LH、HL、HH 等多方向细节子带以及 LL 近似子带。

与传统的 Max Pooling 容易造成纹理弱化和特征平滑不同, Wavelet Pool 能够在保留高频边缘与纹理信息的同时抑制冗余背景,从而缓解“过度平滑”带来的细小病斑丢

失问题。为进一步验证改进的小波池化结构在细节保持方面的有效性,本研究对 3 种典型池化算子(Max Pool、Avg Pool、Wavelet Pool)生成的梯度响应进行了可视化分析,并绘制其梯度幅值分布直方图,如图 2 所示。结果表明:最大池化在局部区域形成尖锐的响应峰值,但对纹理边界的连续性破坏较为明显;平均池化产生的梯度幅值整体偏低,分布集中于低频段,呈现显著的“过度平滑”现象。而 Wavelet Pool 在梯度图中保持了更完整的边缘结构,其直方图在中高幅值区间呈现更宽的范围,说明其能够在保留高频纹理与边缘信息的同时有效抑制冗余背景噪声。上述可视化结果从梯度层面直观证明了小波池化在抑制特征过度平滑、增强细小病斑辨识能力方面的优势。本文仅保留二级小波子带并通过逆离散小波变换实现二倍下采样,使网络在保持结构紧凑的同时增强频域表达能力。

$$W_{\varphi}[j, k] = h_{\varphi}[-n] \times W_{\varphi}[j+1, n] + h_{\psi}[-n] * W_{\psi}[j+1, n] \mid_{n=\frac{k}{2}, k \leq 0} \quad (3)$$

图 3 展示了小波池化的前向传播算法流程。所提出的小波池化算法通过逆向执行其前向传播过程实现反向传播。具体步骤如下:首先对需反向传播的图像特征执行一阶小波分解,然后对细节系数子带(LH、HL、HH)进行二倍上采样,生成新的一级分解,原分解层级随之升级为二级分解。最后,基于新的二阶小波分解,通过逆离散小波变换重构图像特征,供后续反向传播使用。




图 2 不同的池化算子梯度响应图及梯度幅值分布直方图

Fig. 2 Gradient response maps of different pooling operators and the corresponding gradient magnitude distribution histograms




图 3 小波池化传播算法

Fig. 3 Wavelet pooling propagation algorithm

1.2 CA-HSFPN 模块

CA-HSFPN 模型结构如图 4 所示。特征选择模块通过通道注意力和维度匹配模块对多尺度特征图进行筛选。通道注意力利用全局平均池化和最大池化结合权重计算,高效提取各个通道的关键信息。最大池化旨在从通道中提取最相关的信息,而平均池化则均匀捕捉特征图中的所有数据以最小化损失。两者的结合优化了信息的提取和损失。最后通过 Sigmoid 激活函数确定各通道的权重值,并将权重与调整尺寸后的特征图融合,生成精细化特征图。

特征融合模块采用选择性特征融合机制,将筛选后的低层特征与高层特征进行有机结合。具体表现为高层特征经双线性插值与转置卷积,缩放后与低层特征融合,提高模型对细微特征的捕捉与表达能力。

在番茄叶病害识别任务中,准确确定病斑的位置和形态至关重要。针对实际应用中存在的尺度差异、光照变化

和叶片遮挡等挑战,本研究采用 CA 坐标注意力机制替代原有高级筛选特征融合金字塔 HSFPN 中的通道注意力模块。通过将坐标信息引入特征图,该改进方案能对病斑区域进行精确的权重调整,从而更有效地捕捉病害部位及其边缘轮廓特征。改进后的模型可自适应响应不同拍摄角度和环境变化,有效整合病斑区域与周边叶片信息,显著增强特征金字塔在特征选择和特征融合方面的能力。

与通道注意力机制及其他复杂注意力机制相比,坐标注意力采用轻量化设计,便于集成到现有网络框架中。这种设计大幅度降低了模型复杂度和计算负担,使其更适用于田间番茄叶病害检测的实际应用场合,有利于在农业现场环境的部署与应用。坐标注意力模块结构如图 5 所示。其核心流程包括两个关键步骤:首先沿单一空间维度(宽度或高度)聚合特征,随后沿正交进行特征再聚合。具体而言,坐标注意力模块通过水平与垂直方向的池化核尺寸分别为 $(H, 1)$ 与 $(1, W)$ 对特征图进行编码。第 c 通道在




图 4 CA-HSFPN 模块结构

Fig. 4 CA-HSFPN model framework




图 5 CA 注意力机制结构

Fig. 5 Structure of the CA attention mechanism

宽度 h 处的输出如式(4)所示。

$$\mathbf{Z}_c^h(h) = \frac{1}{W} \sum_{0 \leq i \leq w} \mathbf{X}_c(h, i) \quad (4)$$

同理,第 c 通道在高度 w 处的垂直方向输出如式(5)所示。

$$\mathbf{Z}_c^w(h) = \frac{1}{W} \sum_{0 \leq i \leq w} \mathbf{X}_c(j, w) \quad (5)$$

其中, $\mathbf{X}_c(h, i)$ 和 $\mathbf{X}_c(j, w)$ 分别表示沿水平方向和垂直方向聚合的特征图。然后通过 1×1 卷积实现变换操作,如式(6)所示。

$$\mathbf{f} = \sigma(F_1[\mathbf{z}^h, \mathbf{z}^w]) \quad (6)$$

其中, $\mathbf{f}$ 代表中间特征图, F_1 代表卷积操作, $[\mathbf{z}^h, \mathbf{z}^w]$ 表示水平与垂直特征图的拼接, σ 为激活函数。

$$\mathbf{g}^h = \sigma(F_h(\mathbf{f}^h)) \quad (7)$$

$$\mathbf{g}^w = \sigma(F_w(\mathbf{f}^w)) \quad (8)$$

其中, $\mathbf{f}^h$ 和 $\mathbf{f}^w$ 分别通过拆分中间特征图 $\mathbf{f}$ 获得, F_h 和 F_w 为方向特异化卷积操作,最终生成水平注意力机制权重 $\mathbf{g}^h$ 和垂直注意力机制 $\mathbf{g}^w$,并保证水平注意力机制权重和垂直注意力机制拥有相同的通道数可直接与原始特征图进行逐元素相乘。

这种双路径注意力机制,模型能有效捕获叶片图像中

的空间信息,重点关注病害区域的形态特征。最终输出特征公式如式(9)所示。

$$\mathbf{y}_c(i, j) = \mathbf{x}_c(i, j) \times \mathbf{g}_c^h(i) \times \mathbf{g}_c^w(j) \quad (9)$$

该机制使网络能自适应增强病斑区域的特征响应,同时抑制健康叶片区域的干扰信息,显著提升复杂田间环境下病害识别的鲁棒性。

1.3 LADH 检测头

YOLO11 原始的检测头采用解耦结构,分类和回归采用相同的卷积层结构,但是不同任务的侧重点有所差异,会造成检测的冲突和冗余计算,导致精度不高和计算量偏大等问题。为了解决上述问题,本文引入了 LADH 结构,如图 6 所示。

受到非对称解耦头的启发,本文提出了轻量化非对称检测头。该结构通过多级通道压缩将网络按任务类型分为 3 条通道:分别为分类分支(classification, Cls)、回归分支(regression, Reg)、质量评估分支(intersection over union, IoU),并在每个分支中用 3×3 深度可分离卷积(depthwise convolution, DW Conv)替代常规 3×3 卷积,同时为 IoU 分支增设 3 层降通道卷积以扩展感受野并增加其学习能力。深度可分离卷积首先对每个输入通道独立进行深度卷积,保留通道数不变、参数量极少,然后通过




图 6 LADH 结构

Fig. 6 LADH structure

1×1 逐点卷积(pointwise convolution,PW Conv)跨通道融

合特征并调整通道数,从而显著降低参数量和计算量、加速推理并保持跨通道信息融合能力。将 YOLO11n 中的解耦头替换为 LADH-Head 后,模型参数显著减少、推理速度提升、检测精度得到进一步改善,从而有效化解了分类与回归任务之间的冲突。

2 实验数据与方法

2.1 实验环境及数据

在番茄叶病分类研究中,构建一个全面且均衡的图像数据集是实现可靠性能的基础。本研究所使用的数据集主要基于宾夕法尼亚州立大学发布的 PlantVillage 数据集,并结合其他公开的在线资源进行扩充。最终共收集了 2 227 张番茄叶片图像,涵盖 8 类常见病害,包括:早疫病、晚疫病、潜叶虫、叶霉病、花叶病毒、叶斑病、叶螨病以及黄化曲叶病毒。图 7 展示了各类病害的典型图像示例。



图 7 常见的番茄叶片病害

Fig. 7 Common tomato leaf diseases

由于番茄叶片病害在视觉症状上往往具有高度相似性,本研究采用多种数据增强技术以提升模型的泛化能力与鲁棒性。具体方法包括水平翻转、旋转、亮度调整以及高斯模糊。通过这些处理,原始数据集的规模扩展至原来的 3 倍,共获得 6 681 张增强图像。将数据集按照 8:2 的比例划分为训练集和验证集,为了确保训练集与验证集在整体分布及类别比例上的代表性,本研究采用了随机划分策略。为简化表述,本文对各类别样本数量采用了缩写方式。各类比图片数量如图 8 所示。

其中,BS 表示细菌斑点;EB 表示早疫病;LB 表示晚疫病;SLS 表示斑枯病;H 表示健康;LM 表示叶霉病;SM




图 8 各类病害的样本数量

Fig. 8 Number of samples for each type of disease

表示蜘蛛螨;TYLCV 表示黄化卷叶病毒;TMV 表示花叶病毒。

2.2 实验环境与配置参数

本实验在配备 NVIDIA GeForce RTX4060 的 64 位 Windows11 平台完成,采用 Python3. 11. 5,在基于深度学习框架 Pytorch2. 1. 1 的环境下进行 YOLO11n 模型改进,通过 CUDNN11. 8 和 CUDA11. 8 对 GPU 进行加速,提高网络训练速度。训练参数设置如表 1 所示。

表 1 参数设置

Table 1 Parameter settings

参数	设置	参数	设置
optimizer	SGD	weight_decay	0. 000 5
epochs	200	close_mosaic	50
Wokers	1	batch	32
lr	0. 01	momentum	0. 9
imgsz	640		

本文采用的性能评价指标包括精确度 (precision, P)、召回率(recall, R)、每秒帧数 (frames per second, FPS) 和 mAP 等。其中,mAP 分为 mAP@50 和 mAP@50-95,分别对应 IoU 阈值为 0. 5 以及 0. 5~0. 95 范围内的平均精度,用于衡量预测框与真实框的重叠程度,后者相较前者更全面且更严格。

$$P = \frac{TP}{TP + FP}$$
(10)

$$R = \frac{TP}{TP + FN}$$
(11)

$$AP = \int_0^1 PRdR$$
(12)

$$mAP = \frac{\sum_{i=1}^n AP_i}{n}$$
(13)

在具体定义上,TP(true positive)表示正确预测为正类的样本数,FP(false positive)表示错误预测为正类的样本数,P 值越高说明模型对正类的判定越准确;FN(false negative)为被错误预测为负类的样本数,R 值越高表明模型对正类样本的检出能力越强。AP 表示单类别的平均精度,mAP 为所有类别的平均值,其数值越高代表预测框与真实框的重合度越大,检测结果越精确。除精度指标外,本文还引入轻量化评估指标,包括权重文件大小 (Weight)、模型参数量 (Params) 以及浮点运算次数 (floating point operations, FLOPs),分别反映模型的存储开销、规模大小和计算复杂度。这些指标受硬件条件影响,能够从侧面体现模型的轻量化程度与实际部署价值。

2.3 混淆矩阵

利用混淆矩阵对 YOLOv11n-WCL 模型进行评估,如图 9 所示。结果显示模型在番茄叶片病害分类中表现出

高准确率:健康叶片与叶螨分别达到 99. 0%,晚疫病与红蜘蛛为 98. 0%,番茄花叶病毒为 97. 0%,白粉病与早疫病为 93. 0%,褐斑病与叶斑病分别为 97. 0%和 96. 0%,仅存在少量误分类。总体而言,该模型具有较强的分类能力和稳健性,适用于智能农业监测系统的实际应用。




图 9 YOLOv11-WCL 混淆矩阵
Fig. 9 Confusion matrix of YOLOv11-WCL

2.4 模型评价指标

图 10 展示了 YOLO11-WCL 模型的训练与验证曲线,表明其具有良好的收敛性与泛化能力。上排曲线中,train/box_loss、train/cls_loss 与 train/df1_loss 持续下降,说明模型拟合性能不断提升。同时 precision(B)、recall(B)、mAP50(B)与 mAP50-95(B)稳步上升并在后期趋于稳定,反映出检测性能逐渐增强并收敛。下排为验证结果,其中 val/box_los 与 val/cls_loss 在早期快速下降后趋于平稳,val/df1_loss 整体呈下降趋势,伴随轻微波动。值得注意的是,验证集 mAP50(B)与 mAP50-95(B)持续提升,进一步验证了模型在未见数据上的强泛化能力。总体而言,YOLO11-WCL 在训练与验证过程中均表现出稳定的学习行为与可靠的检测精度,为实际部署提供了坚实基础。

图 11 展示了 YOLO11-WCL 可视化热图,对比了模型增强前后的注意力分布情况,为模型关注区域提供直观呈现。热度较高的区域表明模型在分类过程中认为关键部位。原始 YOLOv11n 模型的注意力较为分散,可能影响番茄叶片病斑的精确定位;而增强后的 YOLOv11n-WCL 模型在病变区域表现出更加集中和清晰的激活,从而提升了对多种番茄叶片病害的检测能力。

3 实验结果分析

3.1 轻量化网络对比试验

为验证本研究 YOLO11n 网络相较于其他轻量化检测网络更能平衡番茄病害检测精度与速度的优势,本研究选




图 10 YOLO11-WCL 损失函数

Fig. 10 Loss function of YOLOv11-WCL




图 11 可视化热力图

Fig. 11 Heatmap visualization

取分组卷积(grouped convolution, GConv)^[22]、Faster net^[23]、MobileNetv4^[24]网络在同一番茄叶病害数据集中,在相同环境中进行训练测试,实验结果如表 2 所示。GConv 与 YOLO11-WCL 模型在计算复杂度 GFLOPs 及参数规模 Params 方面均表现出较低水平。相较而言,YOLOv11-WCL 模型在参数压缩率上优于 GConv,整体模型规模减少约 30.6%,展现出显著的轻量化优势,更契合移动终端与边缘计算等存储与内存受限环境的部署需求。

表 2 轻量化对比实验					
Table 2 Lightweight comparison experiment					
模型	GFLOPs/G	模型参数量/M	FPS	R/%	mAP@0.5/%
YOLO11+GConv	7.4	2.64	147.0	70.6	77.0
YOLO11+fasternet	13.1	6.38	188.7	73.4	79.5
YOLO11+mobilenetv4	21.0	5.40	131.5	72.1	77.6
YOLO11n-WCL	3.8	1.29	226.2	68.1	98.5

同时, YOLO11-WCL 在帧率 FPS 上显著优于 GConv,凸显其优越的实时处理性能,尤其适用于视频监控与无人机感知等对高时效性要求较高的场景。更为重要的是,该模型在保持与 Faster-Net 相当检测精度的同时,有效提升了召回率 R,显著降低漏检风险,提升了检测系统的鲁棒性与可靠性。

综上所述,YOLO11-WCL 模型在结构紧凑性、计算效率、实时性与检测性能等方面均具备显著优势,展现出良

好的轻量化部署潜力,能够满足高效能与高实时性并重的实际应用需求。

3.2 算法对比试验

为验证本文算法 YOLO11n 模型作为基准网络模型,

模型体积、GFLOPs、模型参数量、mAP@0.5 为评价指标,为验证本文算法 YOLO11n 模型作为基准网络模选取经典两阶段模型 Faster R-CNN、单阶段 SSD 和 YOLO 在增强后的数据集上与本研究 YOLO11n 实验结果如表 3 所示。

表 3 不同算法对比实验
Table 3 Comparison experiments of algorithms

算法	模型体积	GFLOPs/G	模型参数量/M	FPS	mAP@0.5/%
SSD	98.8	66.36	22.28	184.10	86.4
Faster R-CNN	59.3	134.4	41.76	25.50	88.3
RT-DETR	24.5	100.6	28.46	48.78	97.7
YOLOv5n	4.6	5.8	2.18	238.10	98.3
YOLOv6	8.5	11.5	4.15	227.27	97.9
YOLOv8	5.6	6.8	2.68	250.00	98.2
YOLOv9s	13.3	22.1	6.19	140.85	98.4
YOLOv10	5.8	6.5	2.26	270.27	98.0
YOLO11n	5.5	6.3	2.58	243.90	98.1
YOLO11n-WCL	2.9	3.8	1.29	226.20	98.5

如表 3 所示,不同模型在检测精度、推理速度及资源消耗方面表现存在差异。传统检测器如 Faster R-CNN 能够获得较为理想的精度,但其模型体积庞大、计算复杂度高且推理速度较低,难以满足实时应用需求。同样,SSD 模型也存在模型规模较大且精度相对较低的问题,从而限制了其在番茄叶片病害细粒度识别中的应用效果。相比之下, YOLO 系列模型整体表现更为优越。其中, YOLOv5n、YOLOv8 与 YOLOv10 在保持较高 mAP@0.5 的同时,均实现了极快的推理速度,适用于实时检测任务。其中, YOLOv10 在帧率 FPS 方面表现最佳,凸显其卓越的实时处理能力。

图 12 给出了模型优化前后的性能雷达图。图 12 中较小的封闭区域代表性能提升,可以明显看出优化后的模型在多项评价指标上均实现了显著改进。




图 12 YOLO11n-WCL 模型在改进前后的检测结果对比
Fig. 12 Comparison of detection results of the YOLO11n-WCL model before and after improvement

值得注意的是,本研究提出的 YOLO11n-WCL 模型展现出突出的轻量化特性。与原始 YOLO11n 相比,

YOLO11n-WCL 在模型规模、计算复杂度和参数数量方面均实现了显著下降,同时 mAP@0.5 略有提升,验证了结构优化策略的有效性。该模型在大幅降低资源消耗的同时,保持了较高的检测精度,部署灵活性显著增强,尤其适用于农业病害检测中对嵌入式或边缘计算设备的应用需求。

3.3 消融实验

为验证本文改进的 YOLO11n 算法各项改进模块的有效性,以模型体积 GFLOPs、FPS、模型参数量和 mAP@0.5 作为评价指标,以 YOLO11n 为基础,运用 wavelet pool 替换主干网络中的普通卷积,并在 Neck 层引入轻量级的 CA-HSFPN、改进检测头为 LADH,在番茄叶病害数据集上进行 8 组消融实验,检测结果如表 4 所示,其中“√”表示使用相应的模块。

实验 1 表明仅引入 Wavelet Pool 模块即可在保持 mAP@0.5 达到 98.1% 的情况下,将模型大小减少 14.5%、参数量减少 13.6%,验证了多尺度特征提取的有效性。实验 2 表明引入 CA-HSFPN 模块,该模块通过坐标注意力机制增强特征融合,使模型大小进一步减少 29.1%,mAP@0.5 提升至 98.2%,尽管计算复杂度略有增加,但突出了其在特征表示增强方面的优势。实验 3 显示,仅使用 LADH 模块能够将模型体积使模型大小进一步减少 10.9%,GFLOPs 降至 5.2,参数量降至 2.28 M,推理速度升至 256.4 FPS,表明轻量化检测头在优化模型结构的同时显著提升了推理效率。实验 4 表明,当 CA-HSFPN 与 LADH 同时作用时,模型体积降至 4.7 MB,相比原模型减少 14.5%,GFLOPs 降至 5.2,参数量降至 2.16 M,推理速度升至 228.6 FPS,mAP@0.5 提升至 98.4%,特征融合

表 4 消融实验结果
Table 4 Dissolution experiment results

实验序号	Wavelet pool	CA-HSFPN	LADH	模型体积	GFLOPs/G	模型参数量/M	FPS	mAP@0.5/%
1				5.5	6.3	2.58	243.9	98.1
2	✓			4.7	5.5	2.23	178.6	98.1
3		✓		3.9	5.6	1.81	181.8	98.2
4			✓	4.9	5.2	2.28	256.4	98.4
5	✓	✓		3.2	4.8	1.46	212.8	98.4
6	✓		✓	4.2	4.4	1.93	181.8	98.2
7		✓	✓	4.7	5.2	2.16	228.6	98.4
8	✓	✓	✓	2.9	3.8	1.29	226.2	98.5

与小目标感知能力得到互补增强,验证了两者在结构上的协同效应。

值得注意的是,当模型同时集成 Wavelet Pool、CA-HSFPN 和 LADH 轻量化检测头时,性能提升最为显著。与仅包含 Wavelet Pool 和 CA-HSFPN 的组合相比,增加 LADH 模块后推理速度提升至 226.2 FPS,模型大小减少 47.3%,计算复杂度降低 39.7%,参数量减少 50%,mAP@0.5 达到 98.5%。这表明三者结合具有协同效应,在显著提高检测精度的同时保持了较低的计算开销。与其他

轻量化模块相比,所提出的模块组合在精度与计算效率之间实现了更优平衡。综合实验结果进一步证明,该组合架构非常适用于资源受限的嵌入式设备以及实时农业病害检测场景。

3.4 测量结果可视化

图 13 展示了基础模型 YOLO11n 与所提模型 YOLO11n-WCL 在番茄病害检测任务中的定性对比结果。每行 4 组子图对应不同植株部位与病害类型:叶枯病(LB)、早疫病(ES)、细菌性斑点病(BS)和早疫斑病(SLS)。



图 13 YOLO11n 与 YOLO11n-WCL 对比

Fig. 13 Comparison between YOLO11n and YOLO11n-WCL

从图 13 中可以看出,基准模型 YOLO11n 模型在背景模糊、茎秆遮挡及叶片重叠等复杂条件下,易出现置信度偏低及检测框不稳定的问题。相比之下,YOLO11n-WCL 模型在检测精度与稳定性上均表现更优,具有显著更高的置信度以及更准确的目标边界定位。这一性能提升充分说明了引入多尺度特征优化策略的有效性。改进后的模型能够更好地捕捉病斑细微特征并抑制背景干扰,从而获得更加稳健且可解释的检测结果。可视化结果进一步验证了 YOLO11n-WCL 相较基线模型的显著优势。

4 结 论

番茄叶部病害的准确检测与及时干预对于保障农业可持续生产至关重要,尤其是在光照变化和叶片遮挡等复杂田间环境条件下。尽管无人机图像采集技术已被广泛应用,但叶片重叠、病斑特征模糊以及背景复杂等问题,仍然严重制约了小尺度病害目标的精准检测。

为应对上述挑战,本文提出了一种改进的 YOLO11 模型——YOLOv11-WCL。该模型融合了 3 项关键优化:基

于小波池化的主干网络以增强特征提取能力,轻量化的 CA-HSFPN 结构以提升细粒度特征表征能力,以及高效轻量化的 LADH 解耦头以增强检测鲁棒性。

实验结果表明,YOLO11-WCL 在检测遮挡病斑方面显著优于基线 YOLO11 模型,在提高检测精度的同时有效降低了误检率和漏检率。研究结果凸显了该模型在精准农业中的应用潜力,为基于无人机的自动化番茄病害监测提供了一种有效解决方案。

然而,在极其复杂的场景下检测精度仍有待提升。未来的研究将重点探索多光谱与红外成像的融合,增强模型在多样光照条件下的鲁棒性。此外,YOLO11-WCL 部署在嵌入式平台上实现实时病害检测,有望在保证低延迟与高精度的同时,推动智能农业实践的进一步发展。

参考文献

- [1] 刘慧,朱晓明,卓富彦,等. 2023 年全国三大粮食作物病虫害防控植保贡献率评价研究报告[J]. 中国植保导刊,2024,44(1):62-66,103.
- LIU H, ZHU X M, ZHUO F Y, et al. Evaluation report on the contribution of plant protection to pest and disease control of the three major grain crops in China in 2023 [J]. China Plant Protection, 2024, 44(1): 62-66,103.
- [2] BARBEDO J G A. Factors influencing the use of deep learning for plant disease recognition[J]. Biosystems Engineering, 2018, 172: 84-91.
- [3] 吴华瑞. 基于深度残差网络的番茄叶片病害识别方法[J]. 智慧农业,2019,1(4):42-49.
- WU H R. Tomato leaf disease recognition method based on deep residual network[J]. Smart Agriculture, 2019, 1(4): 42-49.
- [4] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.
- [5] REN SH 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, 2016, 39(6): 1137-1149.
- [6] HE K M, GIRSHICK G, DOLLÁR P, et al. Mask R-CNN[C]. IEEE International Conference on Computer Vision, 2017: 2961-2969.
- [7] DIWAN T, ANIRUDH G, TEMBHURNE J V. Object detection using YOLO: Challenges, architectural successors, datasets and applications[J]. Multimedia Tools and Applications, 2023, 82: 9243-9275.
- [8] JIA D Y, ZHOU J L, ZHANG C W. Detection of cervical cells based on improved SSD network[J]. Multimedia Tools and Applications, 2022, 81: 13371-13387.
- [9] ZHU X ZH, SU W J, LU L W, et al. Deformable detr: Deformable transformers for end-to-end object detection[J]. ArXiv preprint arXiv:2010.04159, 2020.
- [10] 樊湘鹏,周建平,许燕. 基于改进区域卷积神经网络的田间玉米叶部病害识别[J]. 华南农业大学学报,2020, 41(6):82-91.
- FAN X P, ZHOU J P, XU Y. Field corn leaf disease recognition based on improved region-based convolutional neural network[J]. Journal of South China Agricultural University, 2020, 41(6): 82-91.
- [11] SANIDA T, SIDERIS A, SANIDA M V, et al. Tomato leaf disease identification via two-stage transfer learning approach[J]. Smart Agricultural Technology, 2023, 5: 100275.
- [12] NAWAZ M, NAZIR T, JAVED A, et al. A robust deep learning approach for tomato plant leaf disease localization and classification[J]. Scientific Reports, 2022, 12(1): 18568.
- [13] LIU B, HUANG X L, SUN L M, et al. MCDC Net: Multi-scale constrained deformable convolution network for apple leaf disease detection [J]. Computers and Electronics in Agriculture, 2024, 222: 109028.
- [14] PAUL S G, BISWAS A A, SAHA A, et al. A real-time application-based convolutional neural network approach for tomato leaf disease classification [J]. Array, 2023, 19: 100313.
- [15] YAO C H, YANG Z Q, LI P F, et al. Two-stage detection algorithm for plum leaf disease and severity assessment based on deep learning[J]. Agronomy, 2024, 14(7): 1589.
- [16] LI Z M, LIU L D, XIA M, et al. Detection of rose diseases and insect pests based on deep learning[J]. Journal of Chinese Agricultural Mechanization, 2021, 42: 176.
- [17] 吕继东,王艺洁,夏正旺,等. 基于改进的 Mask R-CNN 自然场景下苹果识别研究[J]. 常州大学学报(自然科学版),2022,34(1):68-77.
- LYU J D, WANG Y J, XIA ZH W, et al. Apple recognition in natural scenes based on improved Mask R-CNN[J]. Journal of Changzhou University(Natural Science Edition), 2022, 34(1): 68-77.
- [18] ZHAI S P, SHANG D R, WANG S H, et al. DF-SSD: An improved SSD object detection algorithm

- based on DenseNet and feature fusion [J]. IEEE Access, 2020, 8: 24344-24357.
- [19] 张福豹,吴婷,赵春峰,等.基于弱光增强与YOLO算法的锯链缺陷检测方法[J].电子测量技术,2024,47(6):100-108.
- ZHANG F B, WU T, ZHAO CH F, et al. Chain defect detection method based on low-light enhancement and YOLO algorithm [J]. Electronic Measurement Technology, 2024, 47(6): 100-108.
- [20] 张泽辰,姚顺春,梁骁俊,等.基于小目标感知增强的风机叶片缺陷智能检测[J].仪器仪表学报,2025,46(9):159-172.
- ZHANG Z CH, YAO SH CH, LIANG X J, et al. Wind turbine blade intelligent defect detection based on small object perception enhancement [J]. Chinese Journal of Scientific Instrument, 2025, 46(9): 159-172.
- [21] 王海瑞,胡灿,朱贵富,等.基于改进RT-DETR的葡萄叶片病害检测[J].湖南农业大学学报(自然科学版),2025,51(4):117-124.
- WANG H R, HU C, ZHU G F, et al. Grape leaf disease detection based on improved RT-DETR [J]. Journal of Hunan Agricultural University (Natural Sciences), 2025, 51(4): 117-124.
- [22] 张建宇,谢娟英. ObjectBoxG: 基于GC3模块的目标检测算法[J]. 智能系统学报, 2024, 19(6): 1385-1394.
- ZHANG J Y, XIE J Y. ObjectBoxG: Target detection algorithm based on GC3 module [J]. Journal of Intelligent Systems, 2024, 19(6): 1385-1394.
- [23] ZHANG Q, ZHANG J N, LI Y, et al. ID-YOLO: A multi-module optimized algorithm for insulator defect detection in power transmission lines [J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 1-11.
- [24] 张宁,周云翀,徐坤财,等.基于MobileNetV4改进的YOLOv8目标检测算法研究[J].集成技术,2026,15(2):91-103.
- ZHANG N, ZHOU Y CH, XU K C, et al. Research on YOLOv8 object detection algorithm improved based on MobileNetV4 [J]. Integrated Technology, 2026, 15(2): 91-103.

作者简介

郭智超,硕士研究生,主要研究方向为目标识别算法。

E-mail:15872759550@163.com

马双宝(通信作者),硕士,教授,主要研究方向为智能检测与控制、机器视觉、电力控制系统设计。

E-mail:2006118@wtu.edu.cn