

基于改进YOLOv8n的海棠叶片病害检测方法

郭秀梅,杨存志,王 硕,丛晓燕*,孙 波*

山东农业大学信息科学与工程学院,山东 泰安 271018

摘要: 本文针对观赏植物病虫害识别的难点问题,以北方常见的观赏植物海棠树为例,提出了一种基于改进的YOLOv8n(MCSW-YOLOv8)海棠叶片常见病害的检测方法。该方法以自然环境下的海棠叶片为研究对象,对采集的样本进行增强处理。对模型进行以下优化:将原模型的主干网络替换为MobileNetV4,采用Wise-IoU(WIoU)V3作为边界框回归的损失函数,将SPP与ELAN结合起来,提高了模型对不同尺度物体的识别能力。最后添加CA注意力机制分解水平或垂直方向的池化,保留位置信息,提升目标检测中的边界框定位精准度。实验结果表明:本文提出的MCSW-YOLOv8目标检测算法在数据集上的查准率提高了7.32%,mAP@0.5提高了7.03%,mAP@0.5:0.95提高了3.53%,取得了较为理想的检测结果。总的来说,MCSW-YOLOv8模型适用于常见海棠叶病害的小目标检测。

关键词: 深度学习; YOLOv8n; 目标检测; 海棠叶片病害

中图法分类号: TP391.41

文献标识码: A

文章编号: 1000-2324(2026)02-0295-11

Detection Algorithm for Crabapple Leaf Diseases Based on Improved YOLOv8n

GUO Xiu-mei, YANG Cun-zhi, WANG Shuo, CONG Xiao-yan*, SUN Bo*

College of Information Science and Engineering/Shandong Agricultural University, Tai'an 271018, China

Abstract: Aiming at the difficulties in the identification of ornamental plant pests and diseases, taking crabapple trees as example, which are common ornamental species in northern China, this paper proposes a detection method for common leaf diseases based on the improved YOLOv8n (MCSW-YOLOv8). This method targets crabapple leaves in natural environments, and enhances the collected samples. The following optimizations are applied to the model: Replace the backbone network of the original model with MobileNetV4, adopt Wise-IoU (WIoU) V3 as the loss function for bounding box regression, and integrate SPP and ELAN to enhance the model's capability to recognize objects of varying scales. Finally, incorporate CA attention mechanism to decompose horizontal and vertical pooling, retain position information, and improve the accuracy of boundary frame positioning in target detection. The results show that the MCSW-YOLOv8 object detection algorithm proposed in this paper improves the precision by 7.32%, mAP@0.5 by 7.03%, and mAP@0.5:0.95 by 3.53% on the dataset, achieving satisfactory detection performance.

Keywords: Deep learning; YOLOv8n; object detection; crabapple leaf diseases

海棠,蔷薇科苹果属植物,海棠花自古以来深受人们喜爱。由于在生长过程中,受到气候条件、土壤状况以及栽培管理不当等因素的影响,海棠容易受到多种病菌和害虫的侵害。常见的病虫害有曲叶病、网蝽、炭疽病、锈病、蚜虫、红蜘蛛等。这些病菌和害虫会通过吸食植株汁液、啃食叶片等方式对海棠造成危害,进而导致植株生长不良,严重时甚至可能死亡,严重影响观赏效果,也给种植户带来巨大的经济损失。因此,及早发现并采取有效的防治措施是保护海棠健康的关键。

目前海棠病虫害的识别主要依赖人工观

察^[1],但这种方法存在效率低、准确性不足以及成本高等问题。为克服人工检测的局限性,发展自动化检测技术已成为迫切需求^[2]。然而,针对海棠病虫害的自动化检测研究仍较为有限。由于海棠属于苹果属,其病虫害特征与苹果病虫害高度相似,因此可以借鉴苹果病虫害的自动化检测方法,为海棠病虫害的智能化识别提供参考和解决方案。早期的苹果叶病害识别主要依赖手工特征提取(如颜色、纹理、形状)结合机器学习分类器(如SVM、随机森林)进行识别。如Zhang等^[3]提出结合遗传算法和基于相关性的特征选择方法进行苹果叶病识别。Satanat等^[4]提出基于目

收稿日期: 2025-06-27

修回日期: 2026-03-06

第1作者简介: 郭秀梅(1979-),女,博士,副教授,研究方向:模式识别在农业中的应用。E-mail:xium@163.com

*通讯作者: Author for correspondence. E-mail:sdaucxxyy@163.com;sunb@sdau.edu.cn

标检测和边界框多数投票策略的病害识别分类方法。早期基于传统的检测方法过多依赖先验知识,识别精度不高。随着深度学习研究的深入,越来越多的研究者将深度学习模型引入到苹果病虫害识别中。Yu等^[5]提出基于感兴趣区域(ROI)感知的深度CNN方法,先定位叶片区域再进行病害识别,提高计算效率和准确率。Zhou等^[6]将改进的深度残差网络(ResNet)用于苹果叶病识别,通过调整网络结构或训练方法提升标准ResNet的性能。Ni^[7]将较新的CNN架构或训练策略,引用到苹果叶病识别。针对小样本和背景复杂的情况,Gao等^[8]提出BAM-Net网络,专注于复杂背景下的苹果叶病识别,利用注意力机制或背景分割技术以提高在真实果园环境中的识别性能。Li等^[9]针对小样本和不平衡数据集问题,通过数据增强或迁移学习策略,开发轻量级卷积网络解决方案。Pu等^[10]提出了一种实体识别方法,融合动态词典与卷积块注意力模块(CBAM)。新增并行空间注意力模块,作用于编码输出特征,通过空间注意力网络提升模型对上下文信息的提取能力。以上算法虽然可以识别出苹果也病虫害,但是识别整张图片,还不能精准定位病斑区域,对于一张叶片有多种病害也失去有效性。针对这些问题,研究者们提出了基于YOLO(You Only Look Once, YOLO)模型的病虫害识别算法。Lv等^[11]结合Transformer和注意力机制(CBAM)改进YOLOv5,提高复杂背景下的识别率,mAP达96.2%,较原YOLOv5提升4.1%,参数量仅增加1.3 M。Sun等^[12]提出了一种改进的YOLOv5s果实病害识别模型。该模型结合在线图像增强和迁移学习,加速了收敛过程。其体积(2.06 MB)仅为原YOLOv5s模型的1/6,识别速度(0.065秒/张)是原模型的2.5倍,且mAP@0.5达到0.916,较原始模型提升了8.5%。Feng等^[13]改进YOLOv7,引入深度可分离卷积(DSC)减少计算量,改进PANet结构,增强多尺度特征交互,采用EIoU损失提升边界框回归精度,mAP@0.5为94.8%,较原YOLOv7提升2.3%。Zhang等^[14]在YOLOv8基础上进行了改进,引入了多层次多尺度特征融合机制。改进后的算法mAP@0.5显著提升至88.74%,较传统YOLOv8方法提高了8.53%,而计算开销并未显著增长。Zeng等^[15]提出轻量级YOLOv8-GSSW,用GhostNet替换主干

网络,减少冗余特征计算,结合GSConv深度可分离卷积进一步压缩参数量,利用动态加权损失(GSSW)调整难易样本权重,在自建数据集上,mAP@0.5:0.95达89.4%,接近原模型(90.1%),速度提升1.8倍。

鉴于YOLO系列模型在病虫害检测领域已展现出显著优势,而YOLOv8凭借其高精度、高效率及出色的开发者友好性,在实时检测与快速部署场景中表现尤为突出。针对海棠叶片病害检测这一具体应用场景,本文提出了一种改进的YOLOv8n(MCSW-YOLOv8)检测海棠叶片常见病害的方法。该方法将YOLOv8n原主干网络替换为准确率更高、小目标识别能力更强、更为轻便的MobileNetV4。针对特征可能在信息融合过程中会被稀释的问题,采用SPEELAN结构,来提高小目标识别能力。引入CA(Coordinate Attention)注意力机制并将损失函数优化为WIoU(Wise-Intersection over Union),模型识别能力大幅度提升。全文结构安排如下:第一部分介绍本文使用的数据集及预处理;第二部分详述改进算法设计;第三部分展示实验结果与分析;第四部分总结全文并展望未来研究方向。该模型具体研究流程如图1。

1 材料与方法

1.1 数据集

试验所用海棠叶片图像采自北方某八棱海棠苗圃。为了更好地模拟在真实世界部署时将面临的设备多样性挑战,本文采用iPhone14 Pro及佳能EOS R6两种设备采集海棠病害图像。采集了该苗圃发病率最高的曲叶病、白粉病、炭疽病三种病害样本和正常样本数据共计296张,其中,曲叶病、白粉病、炭疽病、正常图像各有52、129、53、62张。防止因背景与病害相似从而导致过拟合现象,本实验采用多维数据增强策略优化样本多样性,具体实施空间变换与噪声注入方法:(1)旋转变换与水平翻转操作,构建不同观测视角对识别系统的影响机制;(2)高斯噪声注入技术,模拟海棠树在自然环境中的背景干扰要素;(3)动态亮度调整模块,模拟从现实世界中晨曦到黄昏不同光照场景对叶片纹理特征的成像差异。最后将处理后满足自然环境真实分布的2 084张样

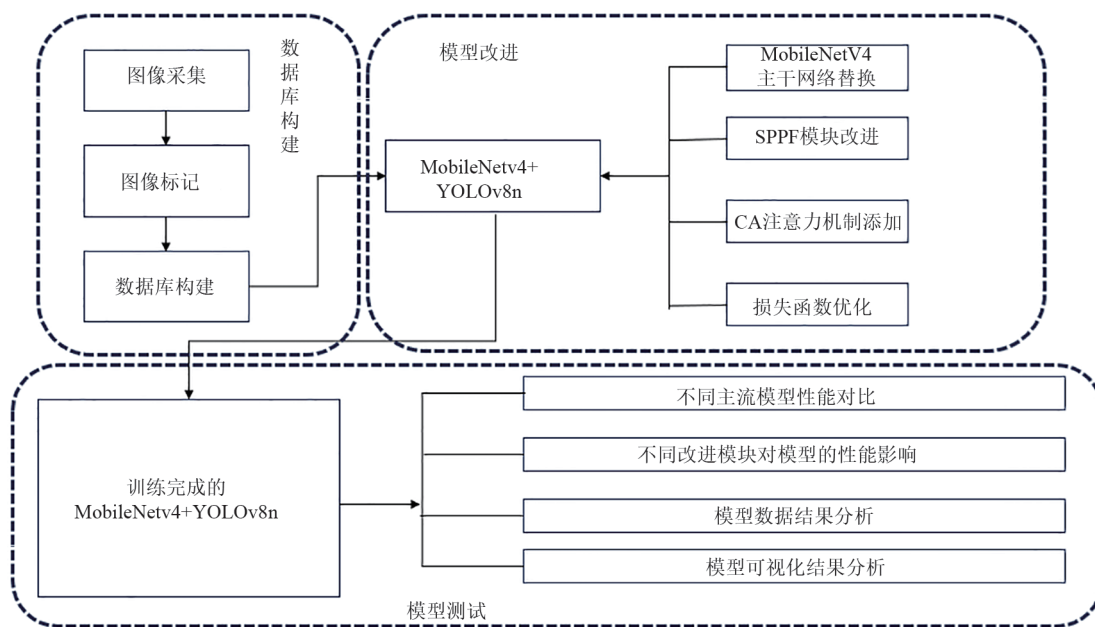


图 1 海棠叶片病虫害检测模型流程图

Fig. 1 Flow chart of pest and disease detection model for begonia leaves

本集进行按 8:1:1 比例划分,形成包含 1 666 张样本的训练集用于模型参数优化,209 张验证集实施超参数调优,以及 209 张测试集完成性能验证

的三位一体评估体系,确保模型鲁棒性与泛化能力的有效验证。图 2 为不同背景下的四种样本。图 3 为不同背景下检测效果对比。



图 2 不同背景下的四种样本

Fig. 2 Four samples in different backgrounds

1.2 YOLOv8n 模型

YOLOv8n^[16]延续了 YOLO 系列的单阶段检测框架,采用主干网络(Backbone)+ 颈部网络(Neck)+ 检测头(Head)的三段式结构,并针对速度和精度进行了多项优化:其主干网络基于改进的 CSPDarknet,通过 C2f 模块(跨阶段部分融合的梯度流优化)替代了 YOLOv5 的 C3 模块,增强了特征提取能力;颈部网络沿用 PAN-FPN 结构(双向特征金字塔),结合上采样和跳跃连接融合多尺度特征;检测头采用解耦式设计(分类与回

归分支分离),并引入动态标签分配策略(如 Task-Aligned Assigner)提升训练效率。YOLOv8n 的整体结构如图 4 所示。

在执行小目标检测任务方面,由于 YOLOv8n 下采样次数多,导致特征图分辨率低,检测效果不佳。在模型复杂度方面,和轻量级模型相比,参数量大,计算资源消耗多。这对移动端或边缘设备要求较高,检测任务可能注重部署时的硬件限制,从而需要模型压缩或蒸馏。在多尺度检测方面,YOLOv8n 可能在高分辨率和大范围尺度

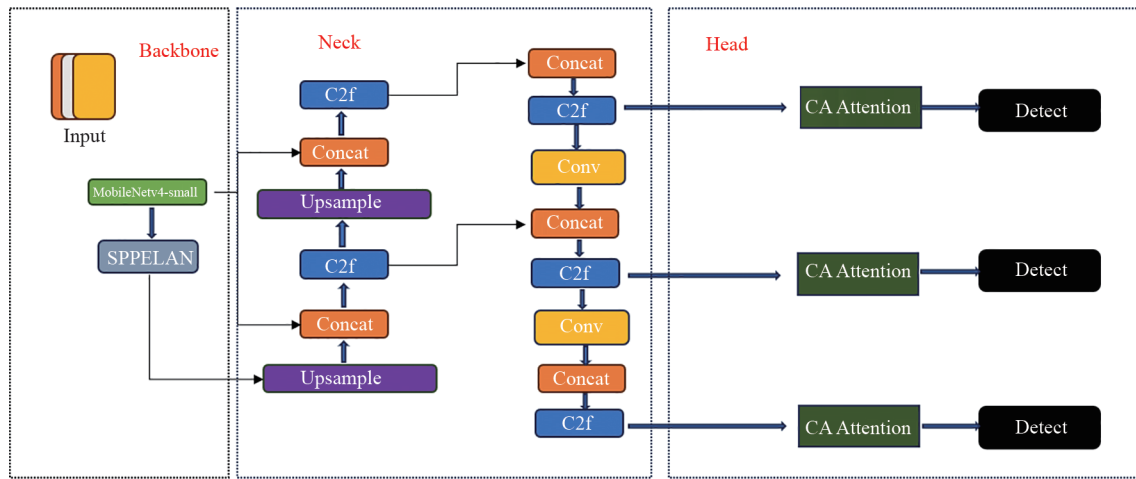


图 5 MCSW-YOLOv8 构架图

Fig. 5 Architectural diagram of MCSW-YOLOv8

模块创新设计^[17],实现了模型的低计算量与参数量。本架构创新性地逆向瓶颈模块(UIB)中集成双路径可配置深度可分离卷积核,形成动态特征表征能力与计算效能兼备的优化方案。具体而言,该模块采用分阶段特征处理策略:第一个深度卷积位于扩展层之前,负责对输入特征进行初步处理,从而更好地提取低层次特征;第二个后置深度可分离卷积核则嵌入在通道扩展与降维投影层之间,显著提升对复杂语义特征的建模能力。MobileNetV4作为主干

网络(Backbone),凭借其硬件优化的通用反向残差块(UIR)和轻量级层级设计,在保持高检测精度的同时显著降低计算负载(FLOPs仅数百M级),支持多尺度特征高效提取;通过动态通道调整和硬件感知NAS优化,适配移动端CPU/GPU的算力特性,实现边缘设备上的高精度目标检测,兼顾低能耗与强泛化能力。因此,本文将YOLOv8n原有的主干网络替换为MobileNetV4。图6为MobileNetV4 UIB结构图。




图 6 MobileNetV4 UIB 结构图

Fig. 6 Structure diagram of MobileNetV4 UIB

1.3.2 SPPELAN 模块 SPPF (Spatial Pyramid Pooling Fast)是一种在深度学习和计算机视觉领域常用的技术,尤其适用于目标检测任务^[18]。由于小目标的尺寸较小,SPPF 大核卷积可能无法提供足够的空间分辨率来有效捕获小目标的特征,这些特征在信息融合过程中可能会被稀释,进而影响检测精度。为了解决这一问题,本文使用了 SPPELAN^[19] (Spatial Pyramid Pooling with Efficient Layer Aggregation Network)。该网络架

构融合了空间金字塔池化模块(SPP)与高效层级聚合网络(ELAN)的注意力导向机制,通过多尺度特征融合机制显著提升了小尺度目标的检测定位精度。具体而言,SPPELAN 复合模块(图7所示结构示意图)实现了双重优化:其空间金字塔池化组件通过多层级感受野的并行计算,增强了对微小目标纹理细节的捕获能力;而ELAN的跨通道注意力权重分配机制,则有效聚焦于关键特征区域。

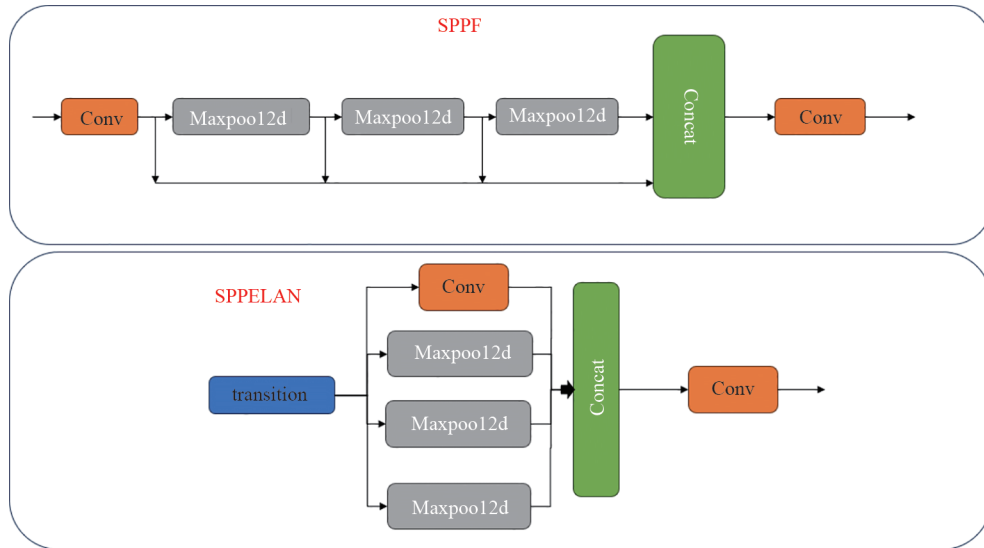


图7 SPPF 和 SPPELAN 模块示意图

Fig. 7 Schematic diagram of SPPF and SPPELAN modules

1.3.3 CA 注意力机制 为了进一步提升模型的精度、小目标检测能力,本文将在模型 head 部分中添加 CA^[20] (Coordinate Attention) 注意力机制。CA 注意力机制将输入特征图分别沿水平方向和垂直方向进行全局平均池化(GAP),得到两个独立的 1D 特征向量(高度和宽度方向),显式编码空间坐标信息。将水平池化与垂直池化的特征拼接,通过 1×1 卷积压缩通道

维度,使用非线性激活(如 Sigmoid)生成中间特征。接着将中间特征沿空间维度拆分为水平注意力权重和垂直注意力权重。然后将水平注意力权重与垂直注意力权重逐元素相乘到原始特征图的对应该坐标位置,增强关键区域的响应。最终输出特征既包含通道间依赖关系,兼具低计算量与高效性。图8为CA注意力机制实现过程图。

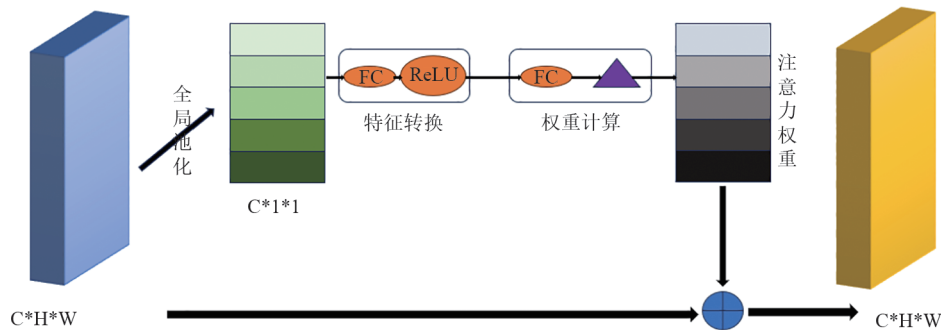


图8 CA注意力机制实现过程图

Fig. 8 Realization process diagram of CA

1.3.4 损失函数优化 在目标检测和回归任务中,模型所使用的损失函数将会影响模型的整体性能和收敛速度。通过对多种损失函数的综合对比(如图9),本文将采用 Wise-IoU^[21] (Wise-Intersection over Union)v3 作为该模型的边界框损失函数。Wise-IoU(WIoU)通过引入动态自适应聚焦机制,采用“离群度”指标取代传统IoU对预测框进行质量度量,并设计了一套智能梯度调控方案。该机制通过双路径优化策略:一方面弱化高精度预测框在训练中的主导性,另一方面抑制低质量样本反向传播时的负面梯度干扰,从而引导模型将学习重点集中在中等质量样本上,显著增强检测模型的泛化能力。技术迭代方面,WIoUv1 首创了注意力驱动边界框回归损失函数,而 WIoUv3 在该框架基础上进一步深化,通过建立可学习的梯度增益(聚焦系数)计算体系,实现了动态聚焦机制的精细化升级。

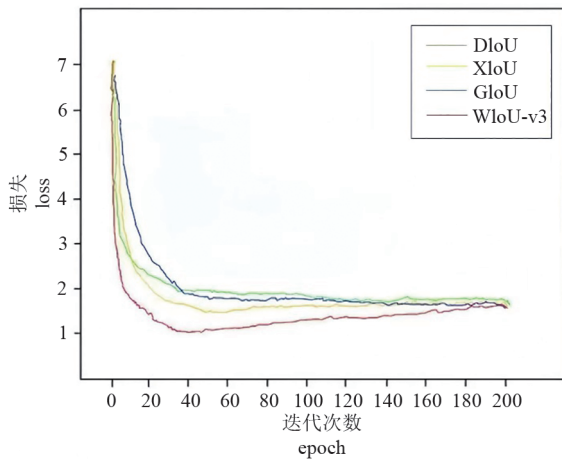


图9 不同损失函数对比图

Fig. 9 Comparison chart of different loss functions

动态非单调FM: 锚框的离群度用 L_{IoU} 与 $\overline{L_{IoU}}$ 的比值表示如公式(1):

$$\beta = \frac{L_{IoU}^*}{L_{IoU}} \in [0, +\infty) \quad (1)$$

该机制基于预测框的统计特性实施动态梯度调制策略,具体而言:当检测到低离群度(表征预测框与真值框具有良好匹配度)时,通过自适应调节机制降低其反向传播强度,促使边界框回归优化过程更聚焦于中等质量样本。同步构建的防御性学习框架中,针对高离群度样本(质量较差的预测框)实施梯度衰减策略,这种双重调控机制既避免了高质量样本在训练中的过度主

导,又能有效抑制低质量样本对参数更新的干扰,从而降低模型因噪声样本导致的过拟合风险,提升模型对典型样本的学习专注度。使用 β 构造一个非单调聚焦系数并将其应用于 WIoUv1 如公式(2)所示:

$$L_{WIoUv3} = rL_{WIoUv1}, r = \frac{\beta}{\delta\alpha^{\beta-\delta}} \quad (2)$$

离群度 β 和梯度增益 r 的映射,由超参数 α 、 δ 控制。不同的超参数可能适用于不同的模型和数据集,需要自行调整 `_scaled_loss` 的缺省值以找到最优解。

2 结果与分析

2.1 评价指标

在评估 YOLO 系列目标检测算法效能时,通常采用四大核心指标衡量模型性能:查准率(Precision, P)如公式(3)、查全率(Recall, R)如公式(4)、平均查准率(Average Precision, AP)如公式(5)及综合平均查准率(mean Average Precision, mAP)如公式(6)。针对模型轻量化与性能的平衡优化,评价指标包括参数规模(Params)和十亿浮点运算量(GFLOPs)。理想轻量化方案需在维持较高检测精度的前提下,有效压缩模型参数体量并降低运算复杂度。

$$P = \frac{TP}{TP + FP} \quad (3)$$

$$R = \frac{TP}{TP + FN} \quad (4)$$

$$AP = \int_0^1 PRdr \quad (5)$$

$$mAP = \frac{1}{N} \sum_{i=0}^n AP_i \quad (6)$$

本研究构建三维度评估体系,选定 mAP@0.5、mAP@0.5:0.95 及 GFLOPs 作为核心量化指标。

2.2 实验环境与配置

本实验平台为 Windows10 64 位操作系统,实验基于 PyCharm Community Edition 2020.1.3 x64,平台 GPU 主机搭载了 NVIDIA GeForce RTX 1080Ti 8G 显存显卡,所使用的开发语言为 Python3.9, CUDA 版本为 11.1。

2.3 不同网络模型对比实验

本文与目前几个主流模型 YOLOv6^[22]模型、

YOLOv8n 模型、YOLOv9^[23] 模型、YOLOv10、DETR 模型^[24]、Faster-RCNN^[25] 模型和 SSD^[26] 模型进行对比实验,采用相同的数据集和参数设

置,进行 200 次迭代训练和测试,不同模型的查准率、mAP@0.5、FPS、和 mAP@0.5:0.95 如表 1 所示。

表 1 不同模型之间性能测试对比结果
Table 1 Results of performance test comparison between different models

| 模型 Model | 查准率/% Precision | mAP@0.5/% | mAP@0.5:0.95/% | FPS/(帧·s ⁻¹) |
|-------------|--------------------|-----------|----------------|--------------------------|
| YOLOv6 | 83.8 | 89.7 | 64.2 | 53.84 |
| YOLOv8n | 89.4 | 91.3 | 73.1 | 50.23 |
| YOLOv9 | 81.5 | 87.2 | 69.2 | 49.68 |
| YOLOv10 | 91.3 | 89.9 | 71.4 | 50.48 |
| DETR | 84.8 | 89.4 | 65.8 | 36.74 |
| Faster-RCNN | 81.8 | 84.5 | 63.3 | 44.45 |
| SSD | 82.4 | 86.0 | 64.0 | 47.58 |

通过对各模型性能指标的综合对比, YOLOv8n 展现出显著优势:其查准率(89.4%)领先 YOLOv6 (83.8%)、YOLOv9 (81.5%)、DETR (84.8%)、Faster-RCNN (81.8%)和 SSD (82.4%); mAP@0.5 (91.3%) 接近 DETR (89.4%), 远超 Faster-RCNN (84.5%) 和 SSD (86.0%), mAP@0.5:0.95 (73.1%) 综合表现最优,同时以 50.23 FPS 的推理速度远超 DETR (36.74), 仅次于轻量级 YOLOv6 (53.84)。相较于 YOLOv10, 二者查准率相差不大,但 YOLOv8n 在 mAP@0.5 方面突出。综合而言, YOLOv8n 在小目标与高精度需求场景中表现最优,是兼顾性能与效率的实用选择。

2.4 消融实验

为了科学和客观地评估各改进模块对整体性能的贡献,本部分内容在 YOLOv8n 主框架下进行了消融实验,实验结果如表 2 所示。通过对比消融实验结果可得出:实验 1,基线模型(无改进模块)在查准率(89.43%)、mAP@0.5 (91.37%)

和 mAP@0.5:0.95 (73.15%) 上表现最弱,但其计算成本(FLOPs 8.2 G)和参数量(3.01 M)最低,凸显了性能与效率的原始矛盾;实验 2 将主干网络替换为 MobileNetV4 后,可以看到查准率从 89.43% 提升到 95.18%, mAP@0.5 从 91.37% 提升到 97.34%, mAP@0.5:0.95 从 73.15% 提升到 73.02%。参数量从 3.01 M 增加到 5.70 M, FLOPs 从 8.2 G 增加到 22.6 G。这说明 MobileNetV4 凭借其硬件优化的通用反向残差块(UIB)和轻量级层级设计,提高了该模型的检测精度和多尺度特征高效提取能力。虽然参数量和 FLOPs 有所提升,但是达到了本模型所追求的高精度小目标检测的要求。实验 3 启用 SPPELAN 模块后,查准率微增(从 95.18% 到 95.34%), 虽检测性能下降(mAP@0.5 下降 1.37%、mAP@0.5:0.95 下降 2.84%), 表明其在目标尺度适应性上存在局限,但计算量降低;实验 4 加入 CA 注意力机制后,查准率降低 0.59%, 但 mAP@0.5、mAP@0.5:0.95 两项检测指标均有提升,证明其能增强复杂背景

表 2 消融实验结果
Table 2 Ablation results

| 实验编号 Experiment number | MobileNetV4 | SPPELAN | CA | Wiou | 查准率/% Precision | mAP@0.5/% | mAP@0.5:0.95/% | FLOPs/ GFLOPs | Parameter/M |
|---------------------------|-------------|---------|----|------|--------------------|-----------|----------------|------------------|-------------|
| 1 | | | | | 89.43 | 91.37 | 73.15 | 8.2 | 3.01 |
| 2 | √ | | | | 95.18 | 97.34 | 73.02 | 22.6 | 5.70 |
| 3 | √ | √ | | | 95.34 | 95.97 | 70.18 | 21.4 | 4.23 |
| 4 | √ | | √ | | 94.75 | 96.12 | 72.48 | 22.7 | 5.64 |
| 5 | √ | | | √ | 94.86 | 95.63 | 71.19 | 22.6 | 5.70 |
| 6 | √ | √ | √ | | 95.48 | 97.88 | 75.73 | 21.6 | 4.17 |
| 7 | √ | √ | √ | √ | 96.75 | 98.40 | 76.68 | 21.6 | 4.17 |


下的目标识别能力且不增加计算负担;实验 5 采用 WIoU 损失函数使 $mAP@0.5$ 、 $mAP@0.5:0.95$ 有所下降,检测指标呈现不稳定波动,但在实验 6 中引入 WIoU 损失函数,模型的各项指标均有明显提升,反映该损失函数需参数调优、组合策略才能充分发挥效果。实验 7 所有模块全部启用,此时查准率、 $mAP@0.5$ 、 $mAP@0.5:0.95$ 分别都达到最高值 96.75%、98.40%、76.68%,较基准模型分别提高了 7.32、7.03、3.53 个百分点。结合均衡的 FLOPs(21.6 G)与参数量(4.17 G),证明各模块通过互补性设计实现了性能与效率的综合突破。

2.5 MCSW-YOLOv8 可视化结果分析

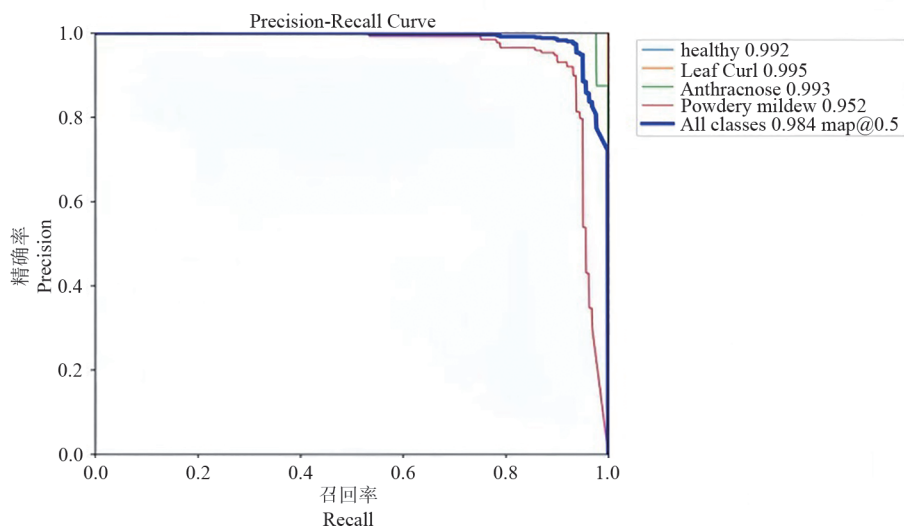
图 10 展示了 MCSW-YOLOv8 模型在数据集的可视化结果。由图 10 可知, YOLOv8n 模型对海棠叶部病害出现了错检现象,红色标框为错检结果,将曲叶病识别为正常叶片和将白粉病识别为炭疽病。在自然环境下白粉病的初期病害特征为细小的白褐色斑点,与炭疽病的病害特征极其相似。曲叶病与正常叶片的区别特征较少, YOLOv8n 模型过小无法区分病害特征。并且模型的分类损失(cls_loss)与定位损失(box_loss)权重对该数据集匹配度不高,进而影响模型对目



(a) 原模型识别效果图
(a) Original model recognition results



(b) MCSW-YOLOv8 识别效果图
(b) MCSW-YOLOv8 identify results



(c) 各类别性能指标
(c) Performance indicators of various categories

图 10 可视化识别效果图

Fig. 10 Visual representation of detection results

标的分类和定位能力。本文提出的 MCSW-YOLOv8 模型很好的识别了正常和炭疽病病斑的细微特征并进行区分,该模型的查准率达到了最高 96.75%, mAP@0.5 为 98.40%, mAP@0.5:0.95 为 76.68%。这表明, MCSW-YOLOv8 能有效提升海棠树叶部病害检测的效率,有利于对海棠树叶部病害的预防与治疗工作的进行。

3 结论

本文所改进的 MCSW-YOLOv8 海棠常见病害检测算法,将主干网络替换为 MobileNetv4,采用 WIoU 作为边界框损失函数,同时考虑了边界框的形状差异,对小目标的识别和检测更加精准;为提升模型的精度和小目标检测能力增加了 CA 注意力机制,同时引入 SPPELAN 实现多尺度特征提取,提高模型检测能力。与原始的 YOLOv8n 模型相比,该算法在保持轻量化特性的同时显著提高了微小目标的识别准确度。当前版本仍面临两项技术挑战:首先,在具有相似纹理或形态特征的目标类别判别上(如病斑特征趋同的作物病害),模型存在分类边界模糊导致的误判现象;其次,即便采用超高分辨率输入数据,对于像素占比极低(通常小于 20×20 像素)的微观目标,仍存在约 3%-4% 的漏检率。后续优化方向将聚焦于构建多层级特征增强网络,通过引入注意力引导的细粒度特征挖掘机制与跨尺度特征融合技术,强化模型对类间差异特征的辨识能力,同时设计针对超小目标的渐进式检测模块,预期可将微尺度目标的召回率继续提升,实现检测性能的全面优化。

参考文献

- [1] 张海红. 观赏海棠病虫害发生种类及防治技术[J]. 现代农村科技,2024(03):55-56.
- [2] 翟肇裕,曹益飞,徐焕良,等. 农作物病虫害识别关键技术研究综述[J]. 农业机械学报,2021,52(07):1-18.
- [3] Chuanlei Z, Shanwen Z, Jucheng Y, et al. Apple leaf disease identification using genetic algorithm and correlation based feature selection method[J]. International Journal of Agricultural and Biological Engineering,2017,10:74-83.
- [4] Kitsiranuwat S, Kawichai T, Khanarsa P. Identification and classification of diseases based on object detection and majority voting of bounding boxes[J]. Journal of Advances in Information Technology, 2023,14(6):1301-1311.
- [5] Yu H J, Son C H, Lee D H. Apple leaf disease identification through region-of-interest-aware deep convolutional neural network[J]. Journal of Imaging Science and Technology,2020,64(2):10.
- [6] Zhou C, Xing J. Improved deep residual network for apple leaf disease identification[J]. Journal of Information Processing Systems,2021,17(6):12.
- [7] Ni J. Smart agriculture: An intelligent approach for apple leaf disease identification based on convolutional neural network[J]. Journal of Phytopathology, 2024 (4):172.
- [8] Gao Y, Cao Z, Cai W, et al. Apple leaf disease identification in complex background based on BAM-Net[J]. Agronomy,2023.
- [9] Li L, Zhang S, Wang B. Apple leaf disease identification with a small and imbalanced dataset based on lightweight convolutional networks[J]. Sensors (Basel, Switzerland),2021,22(1):2-13.
- [10] 蒲攀,刘勇,张越,等. 融合动态词典特征和 CBAM 的苹果病虫害命名实体识别方法[J]. 农业机械学报,2024,55(12):333-343.
- [11] Lv M, Su W H. YOLOV5-CBAM-C3TR: An optimized model based on transformer module and attention mechanism for apple leaf disease detection[J]. Frontiers in Plant Science,2024,14(1): 1323301.
- [12] 孙丰刚,王云露,兰鹏,等. 基于改进 YOLOv5s 和迁移学习的苹果果实病害识别方法[J]. 农业工程学报,2022,38(11):171-179.
- [13] Feng L, Liu Y, Yang H, et al. Detctin of apple leaf diseases target based on improved YOLOv7[J]. INMATEH-Agricultural Engineering,2024,72(1):280.
- [14] 张书贵,陈书理,赵展. 改进 YOLOv8 的农作物叶片病虫害识别算法[J]. 中国农机化学报,2024,45(07): 255-260.
- [15] Zeng W, Pang J, Ni K, et al. Apple leaf disease detection based on lightweight YOLOv8-GSSW[J]. Applied Engineering in Agriculture, 2024, 40(5): 589-598.
- [16] Terven J, Cordova-Esparza D M, Romero-Gonzalez J A. A comprehensive review of YOLO architectures in computer vision: From YOLOv1 to YOLOv8 and YOLO-NAS[J]. Machine Learning And Knowledge Extraction, 2023, 5(4):1680-1716.
- [17] Qin D, Leichner C, Delakis M, et al. MobileNetV4 --

- universal models for the mobile ecosystem[C].European conference on computer vision. Cham: Springer Nature Switzerland, 2024: 78-96.
- [18] Lu J, Zhu M, Ma X, et al. Steel strip surface defect detection method based on improved YOLOv5s [J]. *Biomimetics*, 2024, 9(1) :28.
- [19] Wang C Y, Bochkovskiy A, Liao H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2023:7464-7475.
- [20] Hou Q, Zhou D, Feng J. Coordinate attention for efficient mobile network design[C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Electr Network: IEEE, 2021: 13713-13722.
- [21] Tong Z J, Chen Y H, Xu Z W, et al. Wise-IoU: Bounding box regression loss with dynamic focusing mechanism[EB/OL].2023-01-24.<https://arxiv.org/abs/2301.10051>.
- [22] Li C Y, Li L L, Jiang H L, et al. YOLOv6: A single-stage object detection framework for industrial applications[J].*ArXiv*,2022(9):2209.02976.
- [23] Wang C Y, Yeh I H, Liao H Y. YOLOv9: Learning what you want to learn using programmable gradient information[EB/OL]. 2024-02-21. <https://arxiv.org/abs/2402.13616v2>.
- [24] Carion N, Massan F, Synnaeve G, et al. End-to-end object detection with transformers[C]. *Proceedings of the 16th European Conference on Computer Vision-ECCV 2020*, Glasgow, UK, 2020: 213-229.
- [25] Ren S, He K, Girshick R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2017, 39(6): 1137-1149.
- [26] Liu W, Anguelov D, Erhan D, et al. Ssd: Single shot multibox detector[C]. *Computer Vision-ECCV: 14th European Conference*, Amsterdam. The Netherlands: Springer International Publishing,2016:21-37.