

唐希延, 郭文芳, 杨晶晶, 等. 基于 YOLO v8n 改进的轻量化樱桃叶片病害检测模型[J]. 江苏农业学报, 2026, 42(7): 1419-1428.
doi: 10.3969/j.issn.1000-4440.2026.07.013

基于 YOLO v8n 改进的轻量化樱桃叶片病害检测模型

唐希延, 郭文芳, 杨晶晶, 赵宇轩, 冯贵良

(河北北方学院信息科学与工程学院, 河北 张家口 075000)

摘要: 针对目前已有模型在樱桃病害检测中存在的识别精度低、计算复杂度高及移动端难部署等问题, 本研究基于 YOLO v8n 模型提出一种轻量化樱桃叶片病害检测模型 YOLO v8n-BFGC。首先, 将 YOLO v8n 模型颈部网络中通道拼接(Concat)结构替换为双向特征金字塔网络(BiFPN)结构, 增强多尺度特征融合能力, 提升检测精度; 其次, 在骨干网络引入幽灵卷积(GhostConv)模块替换传统卷积模块, 并采用 C3Ghost 模块, 在保持精度的同时显著降低参数量和计算量。最后, 在主干网络末端嵌入卷积块注意力(CBAM)模块, 强化对关键特征的提取能力。试验结果表明, 改进模型 YOLO v8n-BFGC 精确率(P)、召回率(R)和平均精度均值(mAP_{50})分别达到 93.1%、89.7% 和 93.8%, 相较于原始模型 YOLO v8n, 参数量减少 63.3%、计算量降低 49.4%。与 YOLO 主流模型相比, 改进模型在精度与轻量化方面均具有优越性。该研究结果可为大棚环境下樱桃叶片病害的高效智能识别提供技术支撑。

关键词: 樱桃; 病害检测; YOLO v8n 模型; 轻量化模型

中图分类号: TP391.4

文献标识码: A

文章编号: 1000-4440(2026)07-1419-10

A lightweight cherry leaf disease detection model improved based on YOLO v8n

TANG Xiyan, GUO Wenfang, YANG Jingjing, ZHAO Yuxuan, FENG Guiliang

(College of Information Science and Engineering, Hebei North University, Zhangjiakou 075000, China)

Abstract: In response to the problems of low recognition accuracy, high computational complexity, and difficult deployment on mobile terminals that existed in current models for cherry disease detection, this study proposed a lightweight cherry leaf disease detection model named YOLOv8n-BFGC based on YOLO v8n. Firstly, the Concat structure in the neck network of YOLO v8n model was replaced with a bidirectional feature pyramid network (BiFPN) structure to enhance the multi-scale feature fusion ability and improve the detection accuracy. Secondly, GhostConv module was introduced in the main network to replace the traditional convolution module, and the C3Ghost module was adopted, significantly reducing the parameter quantity and computational cost without sacrificing accuracy. Finally, the CBAM module was embedded at the end of the main network to strengthen the extraction ability of key features. Experimental results showed that the YOLO v8n-BFGC model achieved a precision (P) of 93.1%, a recall rate (R) of 89.7%, and a mean average precision (mAP_{50}) of 93.8%. Compared with the original YOLO v8n model, the parameter quantity was reduced by 63.3%, and the computational cost was decreased by 49.4%. Compared with mainstream YOLO models, the improved model showed superiority in both

accuracy and lightwightness. The results of this study can provide effective technical support for the efficient and intelligent identification of cherry leaf diseases in greenhouse environments.

Key words: cherry; disease detection; YOLO v8n model; lightweight model

收稿日期: 2025-09-02

基金项目: 河北省高等学校科学研究项目(QN2024146)

作者简介: 唐希延(1999-), 女, 河南鹤壁人, 硕士研究生, 主要从事农业工程与信息技术研究。(E-mail) 1657517446@qq.com

通讯作者: 冯贵良, (E-mail) 6838710@qq.com

樱桃作为高附加值经济作物,深受消费者喜爱,其产业发展对助力农民增收,提升农业经济效益发挥着重要作用^[1]。近年来,中国樱桃种植面积不断扩大,产业规模持续增长 24 年^[2-3],目前,烟台大樱桃的种植面积已扩展至 $2.33 \times 10^4 \text{ hm}^2$,年产量超过 $2.5 \times 10^5 \text{ t}$,产值达到 6×10^9 元^[4]。

近年来,随着栽培面积扩大,樱桃病虫害不断加重。据调查,危害中国樱桃的病虫害以褐斑病、二色切叶象甲等为主,严重威胁产业健康发展^[5]。其中,危害叶片的病害包括白粉病、褐斑病、黑斑病和炭疽病,这些病害严重影响樱桃果实产量与品质。因此,快速准确识别樱桃病害,并采取有效的防治措施,对于维护樱桃产业的稳定发展至关重要。

长期以来,传统作物病害诊断多以人工经验为主,普遍存在诊断效率低、主观偏差大、时效性滞后等问题^[6]。在目标检测方面,传统方法同样存在明显缺陷:一是基于滑动窗口的检测策略计算量大、复杂度高、运算负担重;二是模型鲁棒性较差^[7]。随着农业信息化的快速推进,机器学习算法逐步应用于农业病害识别领域。然而,在樱桃叶片病害检测中,传统机器学习方法仍存在显著局限,其高度依赖人工设计与手动提取图像特征,不仅需要较强的专业知识,还需进行繁琐的特征筛选工作,限制了检测精度与泛化能力^[8]。

随着深度学习的快速发展,目标检测算法已经从基于手动特征的传统算法转向基于深度学习的目标检测算法^[9]。目标检测算法在发展过程中,可以分为以 R-CNN 为代表的基于候选框的算法和以 YOLO 为代表的基于回归的算法两类,前者算法在精度上高于后者,后者在推理时间上的表现优于前者^[10]。

Dönmez 等^[11]采用卷积神经网络(CNN)来确定樱桃树病害特征,在樱桃叶片病害检测中的准确率高达 88.1%。尽管两阶段检测器在精度上表现出色,但其复杂的流程和较长的推理时间限制了实时应用^[12],而以 YOLO 为代表的一阶段算法是基于回归分析的算法,通过在特征图上直接预测目标的类别和边界框位置,实现了高效的实时检测^[13]。视网膜网络(RetinaNet)通过引入焦点损失(Focal loss)解决了类别不平衡问题,进一步提高了检测精度^[14]。至此,快速的检测性能使一阶段目标检测算法获得了研究者的广泛关注。

董元和等^[15]提出了一种集成注意力机制和加权双向特征金字塔网络(BiFPN)的模型,显著提高了对葡萄叶片病害特征的识别精度,同时降低了模型参数。赵鑫等^[16]基于 YOLO v5 模型引入幽灵(Ghost)模块和 Ghost BottleNeck 结构,有效提高了对苹果叶片病害的检测精度,同时降低了模型参数。王帅等^[17]通过引入幻影网络(GhostNet)轻量化模块和无参数注意力机制在实现轻量化的同时达到了较好的检测效果。一阶段目标检测模型通过深度融合轻量化网络结构、特征融合机制及注意力模块,在农作物病虫害实时识别领域取得了持续突破。

Bui 等^[18]将 Ghost 模型与 3 种先进的注意力机制集成,实现模型在作物病害检测上参数显著降低。Feng 等^[19]在原有模型架构中融入 BiFPN 网络,同时引入卷积块注意力模块(CBAM)作为注意力机制,实现了模型检测精度和速度的提升。Wang 等^[20]通过使用幽灵卷积(GhostConv)层取代了一些标准卷积,同时加入 CBAM,实现了模型对水稻病虫害的高精度实时监测和参数量的减少。

上述研究在作物病虫害智能检测方面均取得了较好效果,然而,樱桃叶片病害检测仍受限于早期病斑的细微特征、田间复杂背景干扰及边缘设备算力的约束。同时针对樱桃叶片病害检测的研究仍存在小尺度病斑漏检率高、复杂背景干扰强、模型计算负担重、移动端适配性差等问题。为应对上述问题,本研究选取 YOLO v8n 模型作为基础检测框架,进行轻量化与特征增强的协同优化,推出改进后的轻量化目标检测模型——YOLO v8n-BFGC。

1 材料与方法

1.1 数据获取

本研究构建的樱桃叶片病害数据集共涵盖 5 个类别,分别是健康叶片、白粉病叶片、褐斑病叶片、黑斑病叶片、炭疽病叶片(图 1)。于 2025 年 5-7 月在河北省张家口市蔚县暖泉镇樱桃基地进行实地采集,使用尼康 Zfc 相机在大棚内针对树冠不同部位(新梢、老枝、向阳面、背阴面)的叶片进行多角度拍摄,采集时段覆盖早晨、中午和傍晚,并包含强光直射、弱光散射、树阴背光不同的光照环境,经过图像去噪等预处理获得 889 张高分辨率 JPG 格式图像,并从公开数据集随机挑选 204 张白粉病图像作为补充数据集。




图1 樱桃健康叶片及4种主要病害叶片的形态特征

Fig.1 Morphological characteristics of healthy cherry leaves and leaves with four major diseases

1.2 数据集处理

本试验使用 LabelImg 工具对原始数据集进行人工标注,以最小外接矩形框选叶片病斑区域,标注结果保存为 YOLO 格式。在划分数据集前,为提升模型的泛化能力,并降低其在特定数据上过拟合的风险,通过随机对比度调整、添加椒盐噪声等增强方

式对原始数据进行数据增强处理,最终扩充至6 559张图像,增强后的图像如图2所示。为确保试验数据的随机性,数据集按7:2:1的比例划分为训练集、验证集和测试集,对应样本量分别为4 591张、1 312张和 656 张。



图2 樱桃叶片病害图像数据增强效果

Fig.2 Data augmentation effects of cherry leaf disease images

1.3 YOLO v8n-BFGC 轻量化模型

本研究以 YOLO v8n 检测网络模型为基础,提出 YOLOv8n-BFGC 改进模型,改进后的模型结构如图3所示,首先颈部网络重构:引入 BiFPN 结构替代原有的 Concat 操作,并增加高分辨率 P2 特征层,以优化多尺度特征融合;其次轻量化卷积替换:在主干和颈部网络中,利用 GhostConv 模块和 C3Ghost 模块分别替代标准卷积与 C2f 模块,降低模型计算冗余;再次注意力机制嵌入:在骨干网络末端引入 CBAM 模块,以增强对病害关键特征的关注度。改进后的模型在提升检测性能的同时,实现了模型轻量化,从而有效解决了检测模型在移动端部署难的实际应用难题。

1.3.1 加权双向特征金字塔网络 YOLO v8 原始颈部网络主要依赖 Concat 操作进行特征拼接。这种静态的无差别融合机制忽略了不同尺度特征对病害检测贡献度的差异,无法自适应强化关键特征;同时,Concat 操作导致的通道数单纯叠加显著增加了

模型的计算量与内存占用,制约了检测模型在移动端部署的效率。为解决这些问题,本研究引入加权双向特征金字塔网络(BiFPN),它是一种改进的特征金字塔网络,BiFPN 在融合不同尺度的输入特征时不是简单拼接,而是为每个输入特征引入一个快速归一化的可学习权重。该权重在训练中通过反向传播自动优化,使网络能够动态地评估并强调贡献更大的特征,抑制次要或噪声特征,实现自适应、有区分地融合。另外 BiFPN 对原始路径聚合网络(PANet)结构进行了简化,剔除了只有单一输入的边,并在同一层内添加了额外的跳跃连接,将原始特征与融合后的特征相连。这种双向且高效的连接方式在保证信息充分流动的同时,避免了 Concat 带来的通道数直接翻倍,有效控制模型复杂度和计算量。考虑到在复杂的叶片背景下,大多数病斑目标较小,很难被检测到,因此本研究在原始 BiFPN 结构的基础上引入 P2 特征层。P2 特征层能够有效捕捉叶片表面尺寸小于 20 像素的微小病斑细节,解决了传统

方法因特征图分辨率不足而造成的小目标漏检问题。同时,通过额外卷积层对特征图尺寸进行规整,并在同层级原始输入节点与输出节点之间构建跳跃连接,采用加权特征融合策略实现多尺度信息整合。

该改进结构有利于梯度在深层网络中更高效传播,在几乎不增加计算量的前提下,显著提升了模型对微小病斑的检测性能,改进后的 BiFPN 网络结构如图 4 所示。





图 3 YOLO v8n 改进模型图

Fig.3 Schematic diagram of the improved YOLO v8n model



P1~P5:特征层;U:上采样操作;B:双向特征金字塔网络加权特征融合。

图 4 金字塔 (BiFPN) 网络结构图

Fig.4 Structure of the bidirectional feature pyramid network (BiFPN)

1.3.2 引入特征融合(Ghost Conv)模块 传统卷积神经网络的缺陷在于其特征生成机制的低效性。为获得全面特征表达,其依赖的独立卷积核会输出大量相似性高的特征图,这不仅显著增加了参数量,也引入了不必要的计算消耗。为解决此问题,本研究在 YOLO v8 架构中嵌入了 Ghost 模块。Ghost 卷积是 GhostNet 中高效卷积方法,其模块原理如图 5 所示:首先通过 Convert(基础卷积)生成特征图子集,随后基于这些特征图,利用低成本线性操作 $\Phi i (i=1, 2, \dots, n)$ 生成额外的“Ghost 特征图”,最后将基础特征图与 Ghost 特征图和 Identity(恒等映射)支路的特征进行融合,完成特征扩充。该方法通过将单步卷积

拆分为“基础卷积生成核心特征+廉价线性操作生成冗余特征”两个阶段,大幅降低了参数量与计算量。本研究将传统卷积层替换为 GhostConv 模块,并采用 C3Ghost 模块,该模块融合了 C3 模块^[21]的跨阶段局部网络(CSP)结构优势与 GhostNet^[22]的轻量级卷积思想,在显著降低计算负载与参数量的同时,谨慎保留了对目标检测任务至关重要的关键区特征。C3 Ghost模块的原理如图 6 所示:首先通过标准卷积生成一组内在特征图。随后,这些特征图经过计算开销较低的线性变换生成更广泛的特征图阵列。这些特征图有效封装了冗余信息,且处理开销极低,显著降低了生成特征通道数量所需的计算开销^[23]。




图5 卷积模块示意图

Fig.5 Schematic diagram of convolution module




图6 C3 幽灵模块 (C3 Ghost) 示意图

Fig.6 Schematic diagram of the C3 Ghost module


1.3.3 引入注意力机制(CBAM)模块 樱桃叶片病害图像往往存在背景复杂、枝叶交错、病斑与健康组织边

界模糊等特点,极大制约了叶片病害检测的准确性。为应对这些难题,本研究提出在骨干网络中嵌入了通道与空间注意力机制(CBAM)模块。CBAM 是一种简洁高效的、用于卷积神经网络的注意力机制^[24],旨在增强模型对重要特征的提取能力,由通道注意力模块和空间注意力模块组成。如图 7 所示,CBAM 模块融合了空间注意力与通道注意力机制^[25],通道注意力能强化病变色差特征,空间注意力能聚焦病斑区域,使模型能够有效剔除不相关的干扰因素,进而提升网络对樱桃叶片病害特征的识别与提取能力。

1.4 试验环境

试验平台部署在基于 x64 架构的 Windows 11 专业版操作系统。处理器采用第 13 代 Intel® Core™ i7-13620H,图形处理器(GPU)为 NVIDIA GeForce RTX™ 4050 Laptop GPU,系统配置 16 GB DDR5-4800 MHz 双通道随机存取存储器(RAM)和 1TB NVMe PCIe 4.0 固态硬盘(SSD)。

本试验依托 Python 3.12.4 编程语言环境,调用



CAM:通道注意力模块;SAM:空间注意力模块。

图 7 通道与空间注意力机制 (CBAM) 模块图

Fig.7 Schematic diagram of channel and spatial attention mechanism (CBAM) module

PyTorch 2.6.0 深度学习框架。试验参数设置为:训练轮次 300 次,每次训练的批处理大小为 32,为满足模型对输入数据格式的要求,并保持数据的一致性,将输入叶片图像的尺寸统一为 640 像素×640 像素,优化器选择 SGD。鉴于设备显存容量有限,为提升训练效率、降低显存需求,本试验引入了早停策略。

1.5 评价指标

为评估樱桃叶片病害检测模型的性能,本研究从模型复杂度和性能表现两个方面进行评估。在性能评估方面,选取精确率(P)、召回率(R)以及平均精度均值(mAP_{50})作为核心评估指标。其中,精确率表征模型判定为正例的样本中实际为正例的比例;召回率反映被正确检出的正例样本占有所有真实正例样本的比例;平均精度均值通过整合多置信度阈值下的 P - R 曲线,综合评价模型的综合检测性能。此外,还引入了浮点计算量($GFLOPs$)与模型大小作为衡量模型复杂度与模型推理速度的指标,以下为其中 3 个关键指标的计算公式。

$$P = \frac{TP}{TP+FP} \times 100\% \quad (1)$$

$$R = \frac{TP}{TP+FN} \times 100\% \quad (2)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n \int_0^1 P(R) dR \quad (3)$$

式中: TP 表示模型正确预测为正例样品的数量; FP 表示模型错误预测为正例的数量; FN 表示模型未能检测到的真正正例样品的数量; n 为类别总数。 AP 就是通过计算 P - R 曲线与坐标轴围成的面积得到的,它是一个综合了精确率和召回率的单一指标, mAP 是所有类别 AP 的平均值; dR 代表召回率的微小增量。

2 结果与分析

2.1 不同注意力机制对比试验结果

为验证改进策略的有效性,本研究针对引入不

同的注意力机制开展对比试验(表 1),结合平均精度均值(mAP)、 F_1 分数、浮点运算量($GFLOPs$)及参数量($Params$)等指标进行综合评估。展示了 YOLO v8n 模型集成不同注意力模块的性能对比,包括全局注意力机制(GAM)^[26]、无参数注意力机制($SimAM$)^[27]、卷积与注意力融合($CAFM$)模块^[28]以及本研究采用的 CBAM 模块的对比结果。从表 1 可知,当不同注意力模块嵌入相同网络位置时,CBAM 模块在综合性能方面展现出显著优势。

表 1 不同注意力机制下 YOLO v8n 模型检测性能对比结果

Table 1 Performance comparison of YOLO v8n with different attention mechanisms

模型+注意力机制	mAP_{50} (%)	mAP_{50-95} (%)	F_1	$GFLOPs$ (G)	$Params$ (M)
YOLO v8n	92.3	77.9	92.0	8.1	3.0
YOLO v8n+GAM	93.3	78.3	92.1	9.4	4.6
YOLO v8n+SimAM	92.6	79.0	91.4	8.1	3.0
YOLO v8n+CAFM	92.8	77.2	91.2	8.4	3.3
YOLO v8n+CBAM	93.3	76.3	92.0	8.1	3.0

mAP_{50} :交并比阈值为 0.50 时的平均精度均值; mAP_{50-95} :交并比阈值从 0.50 到 0.95 的平均精度均值; F_1 :模型精确率和召回率的调和平均值; $GFLOPs$:浮点计算量; $Params$:参数量。 GAM :全局注意力机制; $SimAM$:无参数注意力机制; $CAFM$:卷积与注意力融合模块; $CBAM$:卷积块注意力模块。

2.2 不同模型对比试验结果

为验证本研究提出的轻量化模型在检测性能与工程部署方面的优势,在自建樱桃叶片病害数据集上,将 YOLO v8n-BFGC 模型与当前主流目标检测经典模型进行对比试验,对比模型包括 YOLO v5n、YOLO v8n、YOLO v8s、YOLO v10n、YOLO v11n 及 YOLO v12n。为确保试验结果的可靠性与可比性,所有模型均采用完全一致的训练与测试参数。基于 mAP_{50} 、 mAP_{50-95} 、 $GFLOPs$ 、 $Params$ 及模型大小 5 项评估指标。

试验结果如表 2 所示,本研究提出的 YOLO v8n-BFGC 模型在检测精度方面表现出显著优势,其中 mAP_{50} 达到 93.8%,相较于 YOLO v11n 和 YOLO v12n 分别提升了 1.4 个和 3.4 个百分点。同时参数量较其他模型大幅下降。这表明,在解决农业场景下的小目标检测难题时,YOLO v8n-BFGC 模型引入的 BiFPN 高效特征融合结构与 CBAM 注意力聚焦机制,效果优于单纯堆叠网络。

在模型效率维度,本研究通过引入 Ghost 模块对骨干网络进行深度的线性重构,YOLO v8n-BFGC

模型的参数量被显著降低至 1.1 M,浮点运算量仅为 4.1 G。与当前主流的轻量化模型 YOLO v11n 相比,本模型的参数量和计算量分别进一步缩减了 56.0%和 34.9%,且模型大小仅为 3.1 MB。这说明,相较于主流模型,本研究提出的模型在维持检测精度的同时,可显著降低模型复杂度与计算量,不仅减少了硬件资源需求,还提升了推理速率,在资源受限场景的轻量化部署中展现出显著竞争优势。

表 2 YOLO v8n-BFGC 模型与主流目标检测模型的性能与轻量化对比结果

Table 2 Performance and lightweight comparison between YOLO v8n-BFGC and mainstream object detection models

模型	mAP_{50} (%)	mAP_{50-95} (%)	$GFLOPs$ (G)	$Params$ (M)	模型大小 (MB)
YOLO v5n	92.3	75.7	7.1	2.5	5.0
YOLO v8n	92.3	77.9	8.1	3.0	5.9
YOLO v8s	91.9	79.6	28.4	11.2	21.5
YOLO v10n	92.1	77.0	6.5	2.2	4.5
YOLO v11n	92.4	78.2	6.3	2.5	5.2
YOLO v12n	90.4	72.5	6.3	2.5	5.3
YOLO v8n-BFGC	93.8	78.0	4.1	1.1	3.1

mAP_{50} 、 mAP_{50-95} 、 $GFLOPs$ 、 $Params$ 见表 1 注。

2.3 轻量化模块对比试验结果

本研究在基础模型 YOLO v8n 上引入 BiFPN 结

构对颈部网络进行了优化,使改进后的模型具备一定的轻量化特性,但在进行卷积运算时仍存在特征冗余现象,且现有的参数量与计算复杂度在嵌入式设备上仍有优化空间。为了进一步提升其在移动端的部署效率,本研究采用 GhostConv (G1) 和 C3Ghost (G2) 模块分别替代原网络中的标准卷积与 C2f 模块。为验证轻量化改进策略的有效性,在同一樱桃叶片病害数据集上进行消融试验,结合平均精度均值、 F_1 分值、浮点运算量及参数量等指标进行综合评估,结果如表 3 所示。模型 YOLO v8n-G1 通过引入 GhostConv 模块成功将模型参数量降低了 0.6 M,但由于单纯替换卷积层会丢失部分细粒度特征导致 mAP_{50} 轻微下降 0.3 个百分点;模型 YOLO v8n-G2 通过引入 C3Ghost,在保持原有精度的基础上显著降低了计算量,表明 C3Ghost 在特征聚合方面具备高效性。YOLO v8n-G1-G2 集成了两种 Ghost 模块,与原始模型相比,其参数量和模型大小分别减少了 43.3% 和 39.0%, $GFLOPs$ 降低了 38.3%,同时 mAP_{50} 提升至 92.9%,推理速度 1 s 提升至 72.4 帧。综上,YOLO v8n-G1-G2 模型在实现显著轻量化的同时,有效提升了樱桃叶片病害检测的精度与速度,为后续检测模型部署在算力受限的农业移动设备上奠定了坚实基础。

表 3 轻量化模块对比结果

Table 3 Comparison results of lightweight modules

模型	P (%)	R (%)	mAP_{50} (%)	$GFLOPs$ (G)	$Params$ (M)	F_1	FPS (帧, 1 s)	模型大小 (MB)
YOLO v8n	93.5	90.7	92.3	8.1	3.0	92.0	68.9	5.9
YOLO v8n-G1	90.4	90.6	92.0	7.8	2.4	90.4	65.7	5.7
YOLO v8n-G2	91.2	90.5	92.3	5.1	2.2	90.7	70.4	4.7
YOLO v8n-G1-G2	90.9	91.3	92.9	5.0	1.7	91.1	72.4	3.6

P :精确率; R :召回率; FPS :帧率。 mAP_{50} 、 $GFLOPs$ 、 $Params$ 、 F_1 见表 1 注。

2.4 消融试验结果

为评估各改进模块的有效性,本研究在自建数据集上设计了不同模型的消融试验,对比结果(表 4)显示,模型 A 为 YOLO v8n;模型 B 在 YOLO v8n 架构基础上,将颈部网络的 Concat 结构替换为 BiFPN 结构,在保证运行速度的同时,提升了检测精度, mAP_{50} 达 92.9%,同时参数量显著降低 36.7%。这一结果表明,BiFPN 结构独特的双向跨尺度连接和加权特征融合机制,与原有 Concat 结构相比,不仅能更高效传递深层语义信息,还能通过移除冗余的卷

积拼接层实现模型的轻量化。

模型 C 在模型 A 的基础上,在骨干网络引入 GhostConv 模块替换原始 Conv 模块,并将骨干和颈部网络中的 C2f 结构均替换为 C3Ghost 模块,显著降低了计算量并提升了综合性能,与模型 A 相比,在 mAP_{50} 有所提升的同时, $GFLOPs$ 大幅下降 38.3%。这表明原 YOLO v8n 骨干网络中存在大量可被线性变换替代的冗余特征图, Ghost Conv 模块在不牺牲特征表达能力的前提下,大幅减轻了模型的计算量。

表 4 消融试验对比结果

Table 4 Comparison of ablation experiment results

模型	BiFPN 结构	Ghost Conv 模块	CBAM 模块	P (%)	R (%)	mAP_{50} (%)	$GFLOPs$ (G)	$Params$ (M)	模型大小 (MB)	F_1	FPS (帧, 1 s)
A				93.5	90.7	92.3	8.1	3.0	5.9	92.0	68.9
B	√			94.3	90.7	92.9	7.1	1.9	4.6	92.3	64.9
C		√		90.9	91.3	92.9	5.0	1.7	3.6	91.1	72.4
D			√	93.9	90.4	93.3	8.1	3.0	6.0	92.0	64.1
E	√	√		91.4	91.4	93.5	4.1	1.1	3.0	91.0	78.8
F		√	√	93.1	92.7	93.7	5.0	1.8	3.7	92.8	71.4
G	√		√	93.9	90.8	93.9	7.1	2.0	4.7	92.2	64.5
H	√	√	√	93.1	89.7	93.8	4.1	1.1	3.1	91.4	78.4

A: YOLO v8n 模型; B: 在 YOLO v8n 基础上, 将颈部网络的 Concat 结构替换为 BiFPN 结构; C: 在 YOLO v8n 基础上, 骨干网络引入 GhostConv 模块替换原始 Conv 模块, 并将骨干和颈部网络中的 C2f 结构均替换为 C3Ghost 模块; D: 在 YOLO v8n 基础上, 在骨干网络末端融入 CBAM 注意力机制模块; E: 在 YOLO v8n 基础上, 同时集成模型 B 和模型 C 的改进; F: 在 YOLO v8n 基础上, 同时集成模型 C 和模型 D 的改进; G: 在 YOLO v8n 基础上, 同时集成模型 B 和模型 D 的改进; H: 在 YOLO v8n 基础上, 同时集成模型 B、模型 C、模型 D 的改进。BiFPN 结构: 加权双向特征金字塔网络; Ghost Conv 模块: 幽灵卷积模块; CBAM 模块: 卷积块注意力模块。 mAP_{50} 、 $GFLOPs$ 、 $Params$ 、 F_1 见表 1 注。 P 、 R 、 FPS 见表 3 注。

模型 D 在模型 A 的基础上, 通过在骨干网络末端融合卷积块注意力 (CBAM) 模块, 精确率提升 0.4 个百分点、 mAP_{50} 提高了 1.0 个百分点, 计算量与参数量保持基准水平。这一结果表明, CBAM 模块能聚焦病斑区域, 使模型能够有效剔除不相关的干扰因素, 进而提升模型对叶片病害特征的识别与提取能力。

模型 E 联合引入 BiFPN 结构与 Ghost Conv 模块, 验证检测模型在极低计算负载下的性能表现。相比模型 A, 其参数量与计算量分别锐减 63.3% 和 49.4%, 推理速度则提升至 1 s 78.8 帧。结果表明, BiFPN 结构高效的双向跨尺度连接机制有效补偿了 Ghost Conv 模块在特征稀疏化过程中潜在的信息损失, 二者的结合不仅最大程度减少了网络中的冗余计算, 还优化了特征传递路径, 使 mAP_{50} 稳定在 93.5%。这证明在对骨干网络进行深度压缩时, 优化特征融合路径是维持模型鲁棒性的关键策略。

模型 G 通过组合 BiFPN 结构与 CBAM 模块提高了检测精度, 但由于保留了标准卷积的全部计算量, 其 $GFLOPs$ 高达 7.1 G, 推理速度仅为 1 s 64.5 帧。表明标准卷积虽然保留了丰富的特征细节, 但其带来的计算负担难以满足实时检测需求。模型 G 以牺牲推理速度为代价仅换取了微弱精度优势, 这也从侧面证明了本研究引入 Ghost Conv 模块的必要性。作为本研究提出的最终方案, 模型 H 集成了 BiFPN 结构、Ghost Conv 模块与 CBAM 模块的优势, 实现了模型性能的综合优化。试验结果显示, 模型 H 在保持与模

型 E 相同的低资源消耗的前提下, 凭借 CBAM 模块与 BiFPN 结构的特征增强, 将 mAP_{50} 提升至 93.8%, 仅低于计算量巨大的模型 G 0.1 个百分点, 而推理速度却保持在较高水平。这一结果有力证明了 BiFPN 结构的特征融合、Ghost Conv 模块的冗余重构及 CBAM 模块的注意力聚焦之间形成了良性的互补效应, 实现了在农业移动端资源受限场景下检测精度、推理速度与模型大小的相对平衡。

为直观展示改进模型在樱桃叶片病害检测中的有效性, 本研究选取不同样本图像分别进行原模型和改进模型的热力图对比, 对比结果 (图 8) 显示, 改进模型目标区域的热力图集中在叶片的主体部分, 边缘更清晰且集中, 并且背景的热力响应明显较弱, 减少了对背景的误关注, 验证了改进模块的引入有助于改善模型对叶片病害检测的性能。




图 8 改进模型热力图对比

Fig.8 Heatmap comparison of the improved model

2.5 改进模型有效性验证结果

目标检测置信度是衡量模型预测可靠性的核心

指标,为验证改进模型的有效性,本研究将改进模型 YOLO v8n-BFGC 与原始模型 YOLO v8n 进行性能对比。与原始模型 YOLO v8n (图 9) 相比,改进模型 (图 10) 对检测目标所产生的置信度明显提升。这一现象直观体现了改进模型在特征判别与定位精度

上的提升。模型大小和性能对比试验结果(图 11)显示,与原始模型 YOLO v8n 相比,改进模型 YOLO v8n-BFGC 平均精度均值(mAP_{50})大幅度提升,模型大小显著下降。




图 9 原始模型 YOLO v8n 检测置信度

Fig.9 Detection confidence of the YOLO v8n model





图 10 改进模型 YOLO v8n-BFGC 检测置信度

Fig.10 Detection confidence of the YOLO v8n-BFGC model



BiFPN 结构、GhostConv 模块、CBAM 模块见表 4 注。 mAP_{50} 见表 1 注。

图 11 模型大小和性能对比结果

Fig.11 Comparison of model size and performance

3 结论

本研究基于 YOLO v8n 模型框架提出轻量化樱桃病害检测模型 YOLO v8n-BFGC, 针对传统樱桃病害检测模型在大棚复杂场景下计算效率低、部署困

难等问题开展系统性优化。通过在骨干网络引入 Ghost Conv 模块替代标准卷积操作, 结合 C3Ghost 模块重构特征提取路径, 显著降低模型参数冗余; 在骨干网络末端嵌入卷积块注意力 (CBAM) 模块^[29-31], 通过通道与空间注意力权重分配强化病害区域特征响应, 有效提升复杂背景下病斑识别能力; 将颈部网络原始 Concat 结构替换为 BiFPN 结构, 采用跨尺度加权融合策略优化多尺度特征交互效率。试验结果表明, 在自建樱桃叶片病害数据集上, 与 YOLO v8n 模型相比, YOLO v8n-BFGC 模型 mAP_{50} 提升 1.5 个百分点, 参数量压缩 63.3%, 计算量降低 49.4%。该模型兼具准确率高和效率高的特性, 可满足大棚移动终端实时检测需求。轻量化架构显著降低对 GPU 算力的依赖, 可部署于边缘计算节点, 为果园病害智能监测系统提供核心技术支持, 推动精准植保向低成本、自动化方向发展。但目前本研究建立的数据集病害类型较少, 后续研究将聚焦复杂田间环境下的模型泛化能力和鲁棒性, 重点优化枝叶重度遮挡、强光过曝、雨雾干扰等极端条件下的

叶片病害识别能力,拓展在低质量图像采集场景的应用边界。

参考文献:

- [1] 沈卓群. 樱桃种植机械化发展问题与对策研究[J]. 农业科技与装备, 2025(2): 73-74.
- [2] 马文江, 李殿运. 费县大樱桃产业现状与发展建议[J]. 果农之友, 2024(12): 125-127.
- [3] 何明莉, 张琪静, 艾佳音, 等. 鞍山市甜樱桃产业发展现状、问题及建议[J]. 中国果业信息, 2024, 41(11): 35-38.
- [4] 钟银芹. 破局与重塑: 山东烟台大樱桃物流体系的创新变革[J]. 食品界, 2025(6): 128-130.
- [5] 徐湾湾. 中国樱桃主要病虫害发生与绿色防控技术[J]. 中国果业信息, 2025, 42(6): 70-71, 74.
- [6] 宋长年, 李红月, 董瑞萍, 等. 大樱桃病害防治技术研究进展[J]. 现代农业科技, 2022(15): 115-118, 122.
- [7] 王迪聪, 白晨帅, 邬开俊. 基于深度学习的视频目标检测综述[J]. 计算机科学与探索, 2021, 15(9): 1563-1577.
- [8] Nandhini P, Mahaveerakannan R. An efficient treatment for cherry tree disease using the random forest classifier comparison with the decision tree algorithm[M]//Hung B T, Sekar M, Esi A, et al. Applications of Mathematics in Science and Technology. CRC Press, 2025: 636-640.
- [9] 蒋雪松, 计恺豪, 姜洪喆, 等. 深度学习在林果品质无损检测中的研究进展[J]. 农业工程学报, 2024, 40(17): 1-16.
- [10] 于涵, 刘砚菊, 冯迎宾. 基于YOLO v5s的轻量化车辆目标检测算法[J]. 工业控制计算机, 2025, 38(7): 105-106, 109.
- [11] Dönmez E, Ünal Y, Kayhan H. Bacterial disease detection of cherry plant using deep features[J]. Sakarya University Journal of Computer and Information Sciences, 2024, 7(1): 1-10.
- [12] 王宁, 智敏. 深度学习下的单阶段通用目标检测算法研究综述[J]. 计算机科学与探索, 2025, 19(5): 1115-1140.
- [13] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//IEEE. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016.
- [14] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[C]//IEEE. 2017 IEEE International Conference on Computer Vision (ICCV). Venice, Italy: IEEE, 2017.
- [15] 董元和, 李恩泽, 贾炎, 等. YOLO-EZ: 一种高效且轻量化的葡萄病害检测模型[J]. 湖北师范大学学报(自然科学版), 2024, 44(4): 12-20.
- [16] 赵鑫, 马明涛, 王丽芬, 等. 基于YOLO v5的轻量化苹果叶片病害检测[J]. 自动化应用, 2024, 65(18): 146-148.
- [17] 王帅, 王利众, 朱丽平, 等. 基于改进YOLO v5s的苹果病害检测技术研究[J]. 山西农业大学学报(自然科学版), 2024, 44(4): 118-129.
- [18] Bui T D, Do Le T M. Ghost-attention-YOLO v8: enhancing rice leaf disease detection with lightweight feature extraction and advanced attention mechanisms[J]. AgriEngineering, 2025, 7(4): 93.
- [19] Feng H R, Chen X Q, Duan Z Y. LCDDN-YOLO: lightweight cotton disease detection in natural environment, based on improved YOLO v8[J]. Agriculture, 2025, 15(4): 421.
- [20] Wang J F, Ma S Y, Wang Z T, et al. Improved lightweight YOLO v8 model for rice disease detection in multi-scale scenarios[J]. Agronomy, 2025, 15(2): 445.
- [21] Esmail M A, Wang J L, Wang Y H, et al. Resource-aware strategies for real-time multi-person pose estimation[J]. Image and Vision Computing, 2025, 155: 105441.
- [22] Khanam R, Hussain M. What is YOLO v5: a deep look into the internal features of the popular object detector[EB/OL]. (2024-07-30) [2025-08-20]. <https://arxiv.org/abs/2407.20892>.
- [23] Han K, Wang Y H, Tian Q, et al. GhostNet: more features from cheap operations[C]//IEEE/CVF. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA: IEEE, 2020.
- [24] 甄元元, 刘平, 金雨纯, 等. 基于改进YOLO v8的葡萄叶片病害检测与识别[J]. 农业工程学报, 2025, 41(14): 148-154.
- [25] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//IEEE. 2014 IEEE Conference on Computer Vision and Pattern Recognition. Columbus, OH, USA: IEEE, 2014.
- [26] 梁绍鹏, 李翰山. 基于SGE-YOLO v8的弹丸爆炸火光图像识别算法[J]. 探测与控制学报, 2025, 47(3): 84-91, 102.
- [27] Yang L, Zhang R Y, Li L, et al. SimAM: a simple, parameter-free attention module for convolutional neural networks[C]//PMLR. International Conference on Machine Learning. Sanya: PMLR, 2021.
- [28] Li H, Liu J, Han K, et al. CAFM-enhanced YOLO v8: a two-stage optimization for precise strawberry disease detection in complex field conditions[J]. Applied Sciences, 2025, 15(18): 10025.
- [29] 楚家, 肖敏, 周迅, 等. 基于改进YOLO v8的复杂环境下农田害虫检测算法[J]. 江苏农业科学, 2025, 53(16): 192-204.
- [30] 雷俊杰, 周保平. 基于改进DCGAN的棉叶螨为害图像数据增强方法[J]. 江苏农业学报, 2025, 41(5): 916-926.
- [31] 刘天真, 苑迎春, 滕桂法, 等. 基于改进YOLO v4的自然场景下冬枣果实分类识别[J]. 江苏农业科学, 2024, 52(1): 163-172.

(责任编辑: 黄克玲)