

基于YOLOV11-SMALL的轻量化脐橙病虫害检测研究

李奕飞, 王谢堂*, 刘嘉虎

赣州职业技术学院电气工程学院, 江西 赣州

收稿日期: 2025年9月22日; 录用日期: 2025年10月27日; 发布日期: 2025年11月6日

摘要

本文围绕脐橙果园病虫害智能识别的实际需求, 开展基于深度学习的目标检测算法优化研究。通过构建包含复杂背景的脐橙病虫害图像数据集, 提出一种轻量化改进模型YOLOv11-SMALL。该模型在YOLOv11n的基础上引入ADown下采样模块以降低参数与计算量, 嵌入HGNetV2主干网络增强多尺度特征提取能力, 并利用ASFF自适应空间特征融合机制提升小目标与复杂背景下的检测性能。实验表明, 改进模型在准确率、mAP@0.5和mAP@0.5:0.95分别达到0.975、0.971和0.912, 参数量仅1728K, 模型大小3.6M, 在嵌入式芯片上推理速度达25.1 FPS, 综合性能优于YOLO系列多个版本及Faster R-CNN、RT-DETR等对比模型。本研究为轻量化病虫害检测算法在边缘设备中的实际应用提供了有效解决方案。

关键词

脐橙, 病虫害检测, 轻量化, YOLOV11, Adown, HGNetV2, ASFF

Research on Lightweight Detection of Pests and Diseases of Navel Oranges Based on YOLOV11-SMALL

Yifei Li, Xietang Wang*, Jiahu Liu

School of Electrical Engineering, Ganzhou Polytechnic, Ganzhou Jiangxi

Received: September 22, 2025; accepted: October 27, 2025; published: November 6, 2025

*通讯作者。

文章引用: 李奕飞, 王谢堂, 刘嘉虎. 基于 YOLOV11-SMALL 的轻量化脐橙病虫害检测研究[J]. 传感器技术与应用, 2025, 13(6): 848-860. DOI: 10.12677/jsta.2025.136083

Abstract

This paper addresses the need for intelligent identification of pests and diseases in navel orange orchards by conducting research on the optimization of a deep learning-based object detection algorithm. A lightweight improved model named YOLOv11-SMALL is proposed, utilizing a constructed image dataset of navel orange pests and diseases under complex backgrounds. Based on YOLOv11n, the model incorporates the A Down downsampling module to reduce parameters and computational cost, embeds the HGNetV2 backbone network to enhance multi-scale feature extraction, and employs the ASFF (Adaptively Spatial Feature Fusion) mechanism to improve detection performance for small targets and in complex environments. Experimental results show that the improved model achieves an accuracy of 0.975, mAP@0.5 of 0.971, and mAP@0.5:0.95 of 0.912, with only 1.728K parameters and a model size of 3.6M. It achieves an inference speed of 25.1 FPS on an embedded chip, outperforming multiple versions of the YOLO series as well as comparative models such as Faster R-CNN and RT-DETR in overall performance. This study provides an effective solution for the practical application of lightweight pest and disease detection algorithms on edge devices.

Keywords

Orange, Detection of Pests and Diseases, Light Weight, YOLOV11, Adown, HGNetV2, ASFF

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

江西省赣州市是我国最适宜脐橙种植的地区之一，赣南脐橙远近驰名、享誉中外[1]。赣州地处亚热带湿润季风气候，非常适合种植脐橙，但此气候也容易导致脐橙果树的病虫害高发，一旦产生病虫害的问题，将会对脐橙产量及品质造成深远影响，严重还将对当地脐橙产业发展产生阻碍，仅 2013 年安远县因黄龙病导致的经济损失达到了 12 亿[2]-[4]。庆幸的是，大多数柑橘类病虫害都是可防可控的，通过系统、科学地防治手段可有效的控制病虫害，提高脐橙产量与品质[5]。

随着我国农业现代化进程不断加速，采用机器人视觉的果园病虫害防治技术近年来取得了长足进步。中国农业大学研究生李健平所开发的果树喷雾系统，基于图像识别方法，提取出树冠形态结构与枝叶空间分布特征，传输至终端喷雾机构以引导精准施药[6]。新疆农业大学的齐亚聪研发了一套基于机器视觉的变量喷洒调控系统，通过对视觉信息的处理提取作物与杂草的特征，从而实现精准变量喷洒控制[7]。山东农业大学研究生慕君林开发了一种基于计算机图像处理技术的作物病虫害检测方法，借助图像分析手段评估作物受病虫害影响的程度及其生长状态，进而科学判定农药施用量[8]。可见在病虫害防治阶段，病虫害检测算法的准确度直接影响了智能农机的可靠性，一个能搭载在移动设备上的可以进行实时检测的病虫害识别算法对于智能农机来说至关重要。

当前的病虫害检测模型普遍存在计算量大、模型复杂等问题，导致模型在边缘设备的实时性较差，进而影响智能农机运行效率。龚圣斌等改进了二阶段检测算法 Faster-RCNN，使用 Inception-V2 特征提取网络进行轻量化改进，使网络计算量降低了 51.8% [9]。云南农业大学的杨宏宇等提出一种基于 EBS-YOLOV7 的轻量化检测模型，该模型采用 EfficientNet 轻量化网络、嵌入 BiFormer 注意力机制等方法，降低模型 28.2%

的计算量[10]。黑龙江大学的王庆浩等提出一种基于 SMC-YOLO 的模型,该模型于 YOLOV8 改进而来,将多维特征增强模块(MDFEM)和跨尺度特征级非局部模块(CSFLNLM)进行结合,从而得到一种专用于玉米害虫的轻量化检测模型[11]。而来自长江大学的贾瀛睿等改进了 C2f 中的 Bottleneck,采用 FasterBlock 来减少参数数量和计算量,从而得到 YOLOV8-tea 茶叶病虫害轻量化检测模型[12]。

尽管已有多种轻量化技术可用于目标检测模型优化,但不同模块在特征提取、计算效率和多尺度感知等方面各有侧重。本研究基于脐橙病虫害图像在真实果园环境中的复杂性与检测挑战,选择采用 ADown、HGNetV2 和 ASFF 模块,构建了一种专用轻量化检测模型。ADown 模块结合平均池化与卷积操作,在降低计算复杂度的同时有效保留病斑的整体分布特征,适用于复杂背景下的病害识别;HGNetV2 作为主干网络,通过多分支架构与特征复用机制增强多尺度病斑特征的提取能力,适应不同尺度病害目标的检测需求;ASFF 模块借助自适应加权策略实现多层次特征融合,提升远视角下小尺寸目标的检测性能并减少漏检。三者协同工作,在实现模型轻量化的同时,完成了从特征提取、多尺度融合到小目标增强的闭环优化,从而形成了面向脐橙病虫害图像的专用检测解决方案。

本文以 YOLOV11 作为基准模型,提出 YOLOV11-SMALL 算法,以解决脐橙病虫害检测的检测速度与精度问题。主要贡献有:(1) 本文采用实景拍摄加数据增强的形式,构建了包含复杂背景环境的脐橙病虫害数据集,提高算法在现实环境的泛用性。(2) 采用平均池化下采样(average pooling down sampling, ADown)模块改进 conv 模块,通过平均池化和卷积操作,提高算法的检测速度。接着,使用 HGNetV2 模块改进原始 YOLOV11 主干网络,减少特征计算冗余,降低参数数量。(3) 使用自适应空间特征融合模块(daptively spatial feature fusion, ASFF)改进 Head 部分,提高模型在远景拍摄时的小目标检测能力,提高检测准确度,以平衡算法轻量化后带来的精度下降。

2. 材料与方法

2.1. 脐橙病虫害数据集搭建

2.1.1. 图像采集

本文病虫害图像大部分使用实景拍摄采集的方式,采集地位于江西赣州章贡区水西脐橙果园,因发病的不确定性以及由于防治技术提升,例如黄龙病等少部分病虫害样本较难采集,故该类病虫害图像进行了网络爬虫的手段进行收集。共收集到 6 类脐橙病虫害图像,如图 1 所示,包括裂果病、黄龙病、溃疡病、红蜘蛛病、炭疽病、锈壁虱,共采集图像 1307 张。

对采集到的数据集进行分析可知,裂果病的纵向裂纹呈细长线性分布,易与果面纹理混淆;黄龙病引起的黄化区域色彩与正常叶片相近,且形态不规则,对颜色特征的分辨能力提出较高要求;溃疡病的病斑具有明显黄褐色调和晕圈结构,但尺度变化大,需模型具备多尺度感知能力;红蜘蛛害表现为密集点状斑,特征微小且容易在降采样中丢失;炭疽病的病斑呈现深色凹陷及中央点状特征,需联合纹理与形态信息进行辨识;锈壁虱造成的银灰色斑块具有独特的光泽特征,需模型对表面反射特性敏感。

2.1.2. 图像增强

为了提高算法泛用性,以适应复杂情况下的检测工作,本文对采集到的数据集采用运动模糊、随机亮度以及随机对比度三种方式对图像进行数据增强[13]。同时因为病虫害发病频率不同,导致病虫害数据集类别数量出现差异。这种情况下容易导致类别不平衡,从而影响整个模型的性能[14]。因此为了报账数据集分布的均匀性,本文对采集到的数据集进行筛选分类,通过筛选处理后的数据集再进行数据增强,得到每种分类各 300 张训练图片。为了提高算法的检测准确度,减少误报,本文还在数据集中加入了 300 张健康植株,加入后的数据集图片一共 2100 张,如表 1 所示。




Figure 1. Images of diseases and pests of navel oranges (a) Huanglong disease (b) Red spider disease (c) Ulcer disease (d) Rust mite disease (e) Anthrax disease (f) Split fruit disease
图 1. 脐橙病虫害图像(a) 黄龙病(b) 红蜘蛛病(c) 溃疡病(d) 锈壁虱(e) 炭疽病(f)裂果病

Table 1. Distribution of images in the dataset
表 1. 数据集图像分布

序号	病虫害标注名	病虫害类别	原始数据	数据集图片
1	裂果病	病害	347	300
2	黄龙病	病害	278	300
3	溃疡病	病害	284	300
4	红蜘蛛病	虫害	89	300
5	炭疽病	病害	109	300
6	锈壁虱	虫害	263	300
7	健康果实		100	300

2.2. YOLOV11-SMALL 模型

2.2.1. YOLOV11 模型

YOLO (You Only Look Once)作为一种典型的单阶段目标检测算法，通过将检测任务构建为端到端的回归问题，能够在单次前向传播中同时完成目标定位与分类。该算法充分利用图像全局上下文信息，显著降低背景误检率，在多个版本迭代中不断优化，逐渐在速度与精度之间实现高效平衡，已成为当前计算机视觉领域广泛应用的主流检测框架之一。

YOLOV11 作为 YOLO 系列官方最新版本，在前代 YOLOV10 的基础上进一步优化模型结构，推理速度提升约 2%，并显著增强在边缘计算设备上的部署能力。凭借其出色的综合性能与良好的工程适应性，本研究选择 YOLOV11 作为基础模型，并针对具体任务进行算法改进。

YOLO 的整体结构包括 Input、Backbone、Neck、Head 和 Output 五个核心部分，YOLOV11 的具体网络架构如图 2 所示。




Figure 2. Architecture diagram of YOLOV11 network
图 2. YOLOV11 网络架构图

2.2.2. YOLOV11-SMALL 模型改进分析

为了提高检测算法的运行效率并降低其计算成本，同时保持良好的识别精度，本文针对脐橙病虫害的图像特点提出了一种改进算法 YOLOV11-SMALL，其整体网络结构如图 3 所示。




Figure 3. Architecture diagram of YOLOV11-SMALL network
图 3. YOLOV11-SMALL 网络架构图

本研究在模型构建过程中，聚焦于脐橙病虫害图像在自然环境下所呈现的噪声复杂、目标尺度差异大和微小病斑易遗漏等核心问题，有机融合了 ADown、HGNetV2 与 ASFF 三个模块，形成了一条覆盖特征预处理、多尺度提取与自适应融合的完整技术路径。该设计的学理依据，源于对脐橙病害视觉特性的深入观察：病斑多处于复杂背景中，尺度分布广泛、形态不规则，且易受成像条件干扰。ADown 模块重点处理图像底层噪声并保留结构信息，HGNetV2 提升对多尺度病征的判别能力，ASFF 则强化跨尺度特征融合与微小目标感知。三者层层递进、功能互补，共同提升了模型在真实果园环境中的鲁棒性和识别准确度。

具体而言，ADown 模块作为下采样组件，将平均池化与卷积操作相结合，在降低计算复杂度的同时有效抑制图像高频噪声——比如果面反光与尘土干扰，同时保持了病斑区域的结构完整性，典型如溃疡病的晕圈特征与炭疽病的深色病斑区域，从而为后续网络层提供噪声更低、结构保持更优的特征输入。HGNetV2 作为主干网络，依托其多分支拓扑和 Ghost 卷积机制，在压缩参数量的同时增强了对多尺度病斑特征的判别能力，尤其适用于同时存在宏观病斑与微观病征的复杂检测场景。ASFF 模块通过空间自适应的权重调控，实现多层次特征的动态融合，显著增强模型对微小目标及模糊病变区域的识别敏感性。三者以串联-互补结构协同作用，构建出一条贯穿噪声抑制、多尺度特征增强与小目标检测的递进式优化路径，系统应对真实果园环境中的光照波动、尺度差异与小目标漏检等核心问题，推动模型从通用目标检测框架向专业化脐橙病虫害识别解决方案的实质性跨越。

2.2.3. 平均池化下采样 ADown 模块

在 YOLOv11 的目标检测架构中，下采样操作通常借助步长为 2 的 3×3 卷积完成。尽管该方法广泛使用，却会明显增加模型的参数量与计算负担。针对脐橙病虫害图像中病斑形态多样、背景复杂多变，以及模型常需部署于计算资源有限设备的实际应用场景，本研究引入了一种基于平均池化的下采样模块 (average pooling down sampling, ADown)，其结构如图 4 所示，以替代原卷积操作。该模块能够在保持模型识别性能的前提下，显著减少参数数量并提高计算效率，更加适应果园实时病害检测的需求。




Figure 4. ADown Module
图 4. ADown 模块

ADown 模块的结构整合了平均池化、最大池化与卷积操作，其处理过程主要包括：首先通过平均池化对输入特征进行平滑，抑制图像中如叶片反光、尘土干扰等的高频噪声与无关变异，同时保留整体结构特征，有助于提取如溃疡病病斑的晕圈、炭疽病病斑的黑色区域等具有连续分布特性的病害信息；随后将特征图沿通道拆分为两支，分别进行处理：一支经最大池化提取如红蜘蛛危害形成的点状斑或果实表面的微裂纹等显著的局部特征，再通过 1×1 卷积进行特征融合；另一支通过步长为 2 的 3×3 卷积实现尺度缩减；最终将两路特征拼接以恢复通道维度。

在计算效率方面，ADown 模块的核心参数量和计算量集中于其内部的 3×3 与 1×1 卷积层。因输入通道数在执行卷积之前已被均匀划分，其总参数量与计算复杂度大幅低于传统卷积下采样。ADown 及普通 3×3 下采样卷积的参数量计算可表示为：

$$P_a = \frac{5}{2}C^2 \quad (1)$$

$$P_c = 9C^2 \quad (2)$$

其中, P_a 为 ADown 的参数量, P_c 为普通 3×3 下采样卷积的参数量, C 为特征图的通道数。

由式(1)和(2)可知, 传统方法的参数和计算量约为 ADown 的 3.6 倍。该结构在提升模型对脐橙常见病虫害的检测敏感性的同时, 显著降低了计算负担, 有利于在实际生产环境中实现高效、精准的危害识别。

2.2.4. GHGNetV2 网络

本文采用的 YOLOv11 基准模型其主干网络大量使用标准卷积操作, 导致参数规模与计算复杂度较高, 严重制约了在移动端的实际部署效率。为实现高效而轻量的病害识别, 本研究对主干网络进行重构, 引入 Ghost 卷积与 HGNetV2 相结合的模块, 以显著减少参数量并提升运行速度, 同时保持对多种脐橙病虫害特征的判别能力。

HGNetV2 最初由 Zhao 等[15]提出, 作为一种面向实时端到端检测任务(DETR)的高效网络结构, 该模型在 COCO2017 数据集上不仅速度和精度表现优异, 还避免了后处理带来的额外开销。与同规模 YOLOv11 相比, HGNetV2 在帧率提升 60%、参数量降低 25.6%的同时, 检测精度仍提高了 0.1%。其核心思想是通过层次化与多尺度特征提取机制, 增强模型对不同抽象级别特征的捕捉能力, 尤其适用于复杂背景下的脐橙病虫害图像, 如识别溃疡病的黄褐色晕圈、炭疽病的黑色病斑、红蜘蛛造成的点状褪色等具有差异显著的病害模式。

当前主流轻量化网络如 MobileNet 和 ShuffleNet 虽采用深度可分离卷积与通道混洗等机制减少计算开销, 但特征图中仍存在大量冗余。为此, 本研究进一步引入 Ghost 卷积[16], 通过将常规卷积分解为少量卷积操作与廉价线性变换两步, 显著降低参数量和内存占用。具体而言, 首先通过普通卷积生成部分特征图, 再利用轻量级线性操作合成剩余特征, 最后进行拼接以保持输出通道完整性, Ghost 卷积网络如图 5 所示。将 Ghost 卷积机制嵌入 HGNetV2 中, 可构建更为高效的 GHGNetV2 主干网络, 如图 6 所示, 在进一步提升模型轻量化水平的同时, 维持对早期黄化、微形裂纹等细微病害特征的敏感度, 从而适应果园环境中复杂多变的成像条件与病害形态。




Figure 5. Ghost module
图 5. Ghost 模块




Figure 6. GHGNetV2 network
图 6. GHGNetV2 网络

2.2.5. 自适应空间特征融合 ASFF 模块

在脐橙果园的实际场景中, 图像背景往往包含复杂植被、光照变化及枝叶重叠等干扰因素, 引入大量噪声, 对病虫害的精准检测构成挑战。尽管 YOLO 系列模型中原有的结构具备多尺度特征融合能力, 但在高度复杂的果园环境中, 其对不同尺度病害特征的融合仍不够充分, 尤其是对于尺度差异显著的病害目标(如果实溃疡病的大斑块与红蜘蛛危害的细微点状斑)难以同时保持高敏感性。为此, 本文引入自适应空间特征融合(daptively spatial feature fusion, ASFF)模块, 如图 7 所示, 嵌入至检测头结构中, 使模型能够自主学习并加权融合来自不同尺度的特征信息, 显著提升多尺度特征表示的一致性与鲁棒性。




Figure 7. ASFF module
图 7. ASFF 模块

ASFF 模块对颈部网络输出的 level1、level2 和 level3 三级特征图进行自适应权重标定, 以抑制冲突信息、强化互补特征。以 ASFF-1 为例, 其输出为三级特征图调整至同一尺度后按空间权重加权融合的结果, 该过程可表示为:

$$\text{ASFF} = \alpha^1 \cdot x^{1 \rightarrow 1} + \beta^1 \cdot x^{2 \rightarrow 1} + \gamma^1 \cdot x^{3 \rightarrow 1} \quad (3)$$

其中, x^1 、 x^2 、 x^3 分别代表三层输入特征, $x^{2 \rightarrow 1}$ 和 $x^{3 \rightarrow 1}$ 表示将 level2 和 level3 特征上采样至与 level1 相同尺寸, 再分别与可学习的空间权重 α^1 、 β^1 、 γ^1 相乘后叠加, 生成融合后的新特征图。权重 α^1 、 β^1 、 γ^1 通过网络自适应学习得到, 在不同空间位置上独立计算, 能够有效突出不同层级中对当前任务贡献最大的特征响应。该机制使模型在面对尺度多变、形态各异的脐橙病虫害(如炭疽病的黑斑、黄龙病的黄化叶片、锈壁虱的银灰色斑点)时, 仍能保持稳定的检测能力, 尤其有助于提升小目标和模糊病斑的识别率, 从而在真实果园环境中实现更精准的病虫害识别。

2.2.6. 模型训练与评价指标

本文模型训练所采用的实验平台参数如表 2 所示, 训练实验选择了最优的训练参数, 训练参数设置如表 3 所示。

Table 2. Parameters of the experimental platform
表 2. 实验平台参数表

Items	Types
Operating system	Windows 11 64
CPU	AMD Ryzen 7 7700 8-Core Processor
GPU	NVIDIA GeForce RTX 3060 Ti 8G
Internal memory	DDR5 32 GB

续表

Language	Python 3.9
Accelerating environment	CUDA 11.8
Framework	Torch 1.12.1 +cu113

Table 3. Training parameter settings table
表 3. 训练参数设置表

Parameter	Value
Epoch	300
Batch size	24
Image size	640 * 640
Optimizer	SGD
Momentum	0.937
Learning Rate	0.01
Works	8

为全面评估本文所提出模型在病虫害识别任务中的综合性能，兼顾其识别精度、模型复杂度及推理效率，本文选取了多类定量评价指标。在识别准确性方面，采用精确率(Precision)、召回率(Recall)和平均精度均值(mAP)作为主要评价依据[15]。其中，Precision 衡量的是模型预测为正样本中实际为正样本的比例，Recall 则反映模型从所有真实正样本中成功识别出的比例，两者分别由公式(4)和(5)定义。AP 用于评估模型在单一类别上在不同置信度阈值下的综合性能，而 mAP 作为多个类别 AP 的平均值，用于评判模型在多个病虫害类别上的整体识别能力，其计算方式如公式(6)和(7)所示。

$$P = \frac{TP}{TP + FP} \quad (4)$$

$$R = \frac{TP}{TP + FN} \quad (5)$$

$$AP = \int_0^1 P(R) dR \quad (6)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i \quad (7)$$

在模型轻量化与效率层面，本文选用参数量(Params)、模型大小(Size)、浮点运算次数(FLOPs)和每秒帧率(FPS)作为核心指标[16]。Params 指模型中所有可训练参数的总数，可用于衡量模型的规模与存储占用；Size 表示模型权重文件的实际存储大小，直接反映模型所占内存空间；FLOPs 用于评估模型进行一次前向传播所需的浮点运算次数，体现其计算复杂度[17]。此外，FPS 用于度量模型在嵌入式平台 Rockchip RK3588 上的实际推理速度，即每秒能够处理的图像数量，其计算方式如公式(8)所示。

$$FPS = \frac{1}{\text{Processing time per frame}} \quad (8)$$

3. 实验结果

3.1. YOLOV11-CUS 模型训练结果

为验证本文提出的改进模型 YOLOV11-SMALL 的有效性与实际性能，在相同训练集上对其与原始

YOLOV11n 进行了对比训练。经过 300 轮训练后, YOLOV11-SMALL 在测试集上准确率达到 0.975, $mAP@0.5$ 和 $mAP@0.5:0.95$ 分别达到 0.971 和 0.912, 均优于 YOLOV11n 的 0.968、0.962 和 0.910。从训练过程中精度变化曲线如图 8 可见, YOLOV11-SMALL 在整个训练过程中始终保持更高的平均精度值, 且两者在约 250 轮次后均趋于收敛, 表明模型已稳定。在测试集的测试结果如图 9 所示。




Figure 8. Curve of accuracy changes during training

图 8. 训练过程中精度变化曲线




Figure 9. Test results of the test set

图 9. 测试集测试结果

3.2. 消融实验结果

为了系统评估各改进模块对模型性能的影响，本文在 YOLOV11n 的基础上依次引入 ADown、HGNetV2 和 ASFF 模块进行消融实验，所有实验均保持相同的训练集与超参数设置，结果如表 4 所示。

Table 4. Abandonment experiment of lightweight improvement algorithm
表 4. 轻量化改进算法消融实验

算法	params(K)	GFLOPs	size(M)	FPS	map50	precision
YOLOV11n	2582	6.3	5.2	20.8	0.962	0.968
+ADown	2093	5.6	3.9	22.7	0.949	0.926
+HGNetV2	1802	5.3	3.7	24.9	0.932	0.921
+ASFF	3962	8.6	6.3	18.9	0.979	0.982
YOLOV11-SMALL	1728	5	3.6	25.1	0.971	0.975

从轻量化效果来看，ADown 模块的引入使参数量(Params)降低至 2093K，GFLOPs 减少至 5.6，模型大小(Size)压缩至 3.9M，同时 FPS 提升至 22.7，表明其通过平均池化与卷积组合有效降低了计算冗余；进一步引入 HGNetV2 后，参数量进一步降至 1802K，GFLOPs 为 5.3，模型大小为 3.7M，FPS 提高至 24.9，说明其多分支结构与特征复用机制在进一步提升轻量化水平的同时维持了较高的推理速度。然而，单独使用 ASFF 模块虽显著提升了检测精度(mAP50 增至 0.979，Precision 达 0.982)，但参数量和计算开销大幅增加(Params 3962K，GFLOPs 8.6)，FPS 降至 18.9，反映出其在增强多尺度特征融合能力的同时也带来了较高的计算负担。

最终，将三项改进结合的 YOLOV11-SMALL 在保持较高精度的同时(mAP50 0.971，Precision 0.975)，实现了最优的轻量化性能：参数量仅 1728K，GFLOPs 为 5，模型大小 3.6M，FPS 达 25.1。结果表明，ADown 与 HGNetV2 有效压缩了模型复杂度并提升推理速度，而 ASFF 模块通过自适应空间特征融合显著增强了模型对多尺度病虫害特征的感知能力，三者结合在精度与效率之间取得了良好平衡，适用于实际果园环境中对实时性与准确性均具要求的脐橙病虫害检测任务。

3.3. 算法对比实验

为评估本文改进算法模型 YOLOV11-CUS 的综合性能，在统一实验环境与数据集下，将其与当前广泛使用的目标检测算法进行了对比，包括 YOLOv3 至 YOLOv11 系列的轻量化版本、Faster R-CNN、Mask R-CNN 和 RT-DETR-X 等，结果如表 5 所示。实验表明，Faster R-CNN、Mask R-CNN 和 RT-DETR-X 等二阶段系列算法在模型大小、计算复杂度、参数量及检测精度等方面均表现不佳。在 Rockchip RK3588 嵌入式平台中，由于这些模型计算需求过高，无法正常运行，因此未能获得 FPS 数据。同样，YOLOv3-tiny 和 YOLOv8S 也因计算资源占用过大无法在该芯片部署。在 YOLO 系列中，YOLOv11n 凭借其结构上的优化，在检测精度上有显著提升，同时参数量和计算量均低于早期版本，使其能够在资源受限设备中稳定高效运行，因而本文选择其作为基础模型。YOLOV11-SMALL 在 YOLOv11n 的基础上进一步提高了检测精度，并降低了模型复杂度和计算开销，表现出更优的综合性能与应用潜力。

4. 结论

本文围绕脐橙果园病虫害精准检测与喷施的实际需求，开展基于改进 YOLOv11-SMALL 的轻量化识别算法与系统研究。通过构建真实场景下的脐橙病虫害图像数据集，结合多项结构优化策略，提出

Table 5. Algorithm comparison experiment
表 5. 算法对比实验

算法	参数量(K)	GFLOPs	size(M)	FPS	map50	precision
YOLOV3-tiny	12134	18.9	28.4	/	0.887	0.877
YOLOV5s	9116	16	15.2	3.2	0.924	0.928
YOLOV6n	4234	11.8	9.1	9.8	0.889	0.882
YOLOV8s	11132	28.8	21.5	/	0.931	0.919
YOLOV10n	2707	8.4	5.8	14.7	0.933	0.919
YOLOV11n (base)	2582	6.3	5.2	20.8	0.943	0.923
Faster R-CNN	41201	203.7	129.1	/	0.868	0.872
Mask R-CNN	44217	190	370.2	/	0.879	0.881
RT-DETR-X	65472	222.5	129.1	/	0.881	0.862
YOLOV11-CUS (ours)	1728	5	3.6	25.1	0.967	0.947

YOLOv11-SMALL 模型，在保持较高精度的同时显著降低计算开销。实验表明，该模型在准确率、mAP@0.5、mAP@0.5:0.95 等关键指标上均优于原 YOLOv11n 及其他对比模型，同时参数量、模型大小和推理延迟均显著减小，证明了其在实际边缘设备中具备良好的部署可行性。

本研究的创新点主要包括：通过引入 ADown 下采样模块有效降低了模型的参数量与计算冗余；将 HGNetV2 作为主干网络嵌入模型，增强了对多尺度病斑特征的提取能力；采用自适应空间特征融合机制 (ASFF)，提升了算法在复杂背景和小目标场景下的检测鲁棒性。消融实验结果表明，各模块不仅单独发挥作用，联合使用时进一步提高了模型的轻量化水平和识别精度。

尽管当前系统在轻量化与识别准确率之间实现了较好平衡，但在极端光照、严重遮挡等复杂场景下的性能仍存在一定局限。后续研究将重点探索更高效的注意力机制，并结合跨季节数据增强策略，以提升模型在不同物候条件和成像环境中的泛化能力[18]。同时，将进一步开展基于多模态传感信息融合的决策方法研究，以促进农业病虫害智能防控系统向更可靠、实用方向发展[19]。

基金项目

赣州职业技术学院青年课题(X-2024-KXJS-16); 江西省教育厅科学技术研究项目(GJJ2410305); 赣州职业技术学院青年课题(X-2024-KXJS-01); 赣州职业技术学院青年课题(X-2024-KXJS-21)。

参考文献

[1] 郭慧, 钟八莲, 卢占军. 基于产业集群理论的脐橙产业可持续发展研究——以赣南脐橙为例[J]. 价格月刊, 2015(2): 75-79.

[2] 詹永斌. 新形势下赣南脐橙产业的发展问题与对策[J]. 现代园艺, 2023, 46(3): 62-64.

[3] 谭巧巧, 黄小兰, 秦泰春, 等. 赣南脐橙产业发展现状及黄龙病防控探讨[J]. 江西科学, 2022, 40(5): 841-847.

[4] 叶翩翩. 农业灾害风险管理的个案研究——以赣南脐橙黄龙病为例[D]: [硕士学位论文]. 南昌: 江西师范大学, 2020.

[5] 李富才, 钟世胜, 张天生, 等. 赣南脐橙的主要病虫害及防治措施[J]. 农业开发与装备, 2020(3): 191-192.

[6] 李龙龙, 何雄奎, 宋坚利, 王潇楠, 贾晓铭, 刘朝辉. 基于变量喷雾的果园自动仿形喷雾机的设计与试验[J]. 农业工程学报, 2017, 33(1): 70-76.

[7] 齐亚聪, 陈毅飞, 杨会民, 喻晨, 王学农. 基于 PLC 的变量喷雾系统的设计与试验[J]. 农机化研究, 2024, 46(11):

- 162-168.
- [8] 慕君林, 马博, 王云飞, 任卓, 刘双喜, 王金星. 基于深度学习的农作物病虫害检测算法综述[J]. 农业机械学报, 2023, 54(S2): 301-313.
 - [9] 龚圣斌, 王少杰, 侯亮, 等. 基于 Faster-RCNN 算法的轻量化改进及其在沙滩废弃物检测中的应用[J]. 厦门大学学报(自然科学版), 2022, 61(2): 253-261.
 - [10] 杨宏宇, 谢小龙, 郭容, 等. 基于 EBS-YOLOv7 的轻量化葡萄病害识别方法[J]. 江苏农业科学, 2025, 53(5): 165-174.
 - [11] Wang, Q., Liu, Y., Zheng, Q., Tao, R. and Liu, Y. (2025) SMC-YOLO: A High-Precision Maize Insect Pest-Detection Method. *Agronomy*, **15**, Article 195. <https://doi.org/10.3390/agronomy15010195>
 - [12] 贾瀛睿, 龙阳, 胡蓉华, 等. 基于 YOLOv8-Tea 的茶叶病害检测方法[J]. 江苏农业科学, 2024, 52(15): 213-221.
 - [13] Wang, C., Han, Q., Li, C., Zou, T. and Zou, X. (2024) Fusion of Fruit Image Processing and Deep Learning: A Study on Identification of Citrus Ripeness Based on R-LBP Algorithm and YOLO-CIT Model. *Frontiers in Plant Science*, **15**, Article 1397816. <https://doi.org/10.3389/fpls.2024.1397816>
 - [14] Zhang, S.W., Shang, Y.J. and Wang, L. (2015) Plant Disease Recognition Based on Plant Leaf Image. *Journal of Animal & Plant Sciences*, **25**, 42-45.
 - [15] 张芳, 李晓辉, 杨洪伟. 复杂背景下植物叶片病害的图像特征提取与识别技术研究[J]. 辽宁大学学报(自然科学版), 2016, 43(4): 311-318.
 - [16] 芦兵, 孙俊, 杨宁, 武小红, 周鑫. 基于荧光透射谱和高光谱图像纹理的茶叶病害预测研究[J]. 光谱学与光谱分析, 2019, 39(8): 2515-2521.
 - [17] 李淼, 王敬贤, 李华龙, 胡泽林, 杨选将, 黄小平, 曾伟辉, 张建, 房思思. 基于 CNN 和迁移学习的农作物病害识别方法研究[J]. 智慧农业, 2019, 1(3): 46-55.
 - [18] 兰玉彬, 朱梓豪, 邓小玲, 练碧桢, 黄敬易, 黄梓效, 胡洁. 基于无人机高光谱遥感的柑橘黄龙病植株的监测与分类[J]. 农业工程学报, 2019, 35(3): 92-100.
 - [19] Li, M., Zhu, X., Ji, J., Jin, X., Li, B., Chen, K., et al. (2025) Visual Perception Enabled Agriculture Intelligence: A Selective Seedling Picking Transplanting Robot. *Computers and Electronics in Agriculture*, **229**, Article ID: 109821. <https://doi.org/10.1016/j.compag.2024.109821>