

基于 YOLO 11n - ACE 的轻量化荔枝病虫害检测方法

谢家兴^{1,2} 陈梓灏¹ 陈绍楠¹ 吴家涛¹ 曹 钺¹ 胡 琳¹
高 鹏¹ 王卫星³ 李 君⁴

(1. 华南农业大学电子工程学院(人工智能学院), 广州 510642; 2. 广东省农情信息监测工程技术研究中心, 广州 510642;
3. 华南农业大学珠江学院, 广州 510900; 4. 华南农业大学工程学院, 广州 510642)

摘要: 针对自然环境下荔枝病虫害目标具有多尺度以及背景复杂等问题,本研究提出一种基于 YOLO 11n - ACE 的轻量化荔枝病虫害检测方法。该方法基于 YOLO 11n 算法,采用 C3k2 - AC 模块替换原来的 C3k2 模块提取荔枝病虫害图像特征,降低了模型参数量和计算存储负载;在此基础上进一步将检测头替换为轻量化检测头 Detect - Efficient,在特征提取和参数量上优化,使得模型在面对复杂环境时,能够准确定位和识别荔枝病虫害,在减小参数量的同时提高检测精度;最后,针对荔枝病虫害目标密集和尺度不一的问题,采用 MPDIoU 作为损失函数,最小点距离的引入使得损失函数能够更准确地评估预测框的质量,提高模型的检测性能。试验结果表明,改进后的 YOLO 11n - ACE 在试验数据集上的精确率和召回率达到 88.27% 和 76.44%,对比原始模型分别提高了 2.54、0.97 个百分点,mAP 达到 83.03%,在提高检测精度的同时参数量减小为 2.186×10^6 ,浮点运算量降低 1.3×10^9 。与主流的目标检测模型相比,改进后的模型减少了漏检、误检,精确率、检测精度和参数量均处于优势,为现代果园环境下的移动设备的荔枝病虫害检测提供了技术参考。

关键词: 荔枝; 病虫害识别; C3k2 - AC; YOLO 11n; 轻量化模型

中图分类号: TP391.41; S225 文献标识码: A 文章编号: 1000-1298(2026)21-0347-10 OSID: 

Litchi Disease and Pest Detection Method Based on Lightweight YOLO 11n - ACE

Xie Jiaxing^{1,2} Chen Zihao¹ Chen Shaonan¹ Wu Jiatao¹ Cao Yue¹ Hu Lin¹ Gao Peng¹
Wang Weixing³ Li Jun⁴

(1. College of Electronic Engineering (College of Artificial Intelligence), South China Agricultural University, Guangzhou 510642, China
2. Engineering Research Center for Monitoring Agricultural Information of Guangdong Province, Guangzhou 510642, China
3. Zhujiang College, South China Agricultural University, Guangzhou 510900, China
4. College of Engineering, South China Agricultural University, Guangzhou 510642, China)

Abstract: With the popularization of smart agriculture, in response to the problems of multi-scale and complex background of pest and disease targets of litchi in natural environments, a lightweight detection method for litchi pests and diseases was proposed based on YOLO 11n - ACE. This method was based on the YOLO 11n algorithm and used the C3k2 - AC module to replace the original C3k2 module to extract the features of litchi pest and disease images, reducing the number of model parameters and computational storage load. On this basis, the detection head was further replaced with the lightweight Detect-Efficient head to optimize feature extraction and parameter quantity, enabling the model to accurately locate and identify litchi pests and diseases in complex environments, improving detection accuracy while reducing the number of parameters. Finally, to address the issues of dense and diverse scales of litchi pest and disease targets, the MPDIoU was adopted as the loss function. The introduction of

收稿日期: 2025 - 07 - 10 修回日期: 2025 - 09 - 08

基金项目: 农业装备技术全国重点实验室(华南农业大学)开放基金项目(SKLAET - 202410)、财政部和农业农村部:国家现代农业产业技术体系项目(CARS - 32 - 09)、广东省现代农业产业技术体系创新团队项目(2024CXTD19 - 11)、“百千万工程”开展新一轮农村科技特派员重点派驻任务项目(KTP20240199)和大学生创新创业训练计划项目(202510564040、S202410564127)

作者简介: 谢家兴(1979—),男,副教授,博士,主要从事农情信息获取与智慧农业研究,E-mail: xjx1998@scau.edu.cn

通信作者: 李君(1978—),男,教授,博士,主要从事农业电气化与自动化研究,E-mail: autojunli@scau.edu.cn

the minimum point distance enabled the loss function to more accurately evaluate the quality of prediction boxes and improve the detection performance of the model. Experimental results showed that the improved YOLO 11n – ACE achieved a precision and recall rate of 88.27% and 76.44% on the experimental dataset, respectively, which were 2.54 and 0.97 percentage points higher than that of the original model. The mAP reached 83.03%, and the number of parameters was reduced to 2.186×10^6 while the floating-point operations were reduced by 1.3×10^9 . Compared with mainstream object detection models, the improved model reduced missed detections and false detections, and had advantages in precision, detection accuracy, and parameter quantity, providing a technical reference for litchi pest and disease detection on mobile devices in modern orchard environments.

Key words: litchi; identification of pests and diseases; C3k2 – AC; YOLO 11n; lightweight model

0 引言

荔枝作为广东地区盛产的一种富含矿物质和维生素的水果,在国内乃至国际的鲜果市场上具有明显的竞争优势。随着经济的快速发展,荔枝凭借营养价值高、味甜鲜美等特质,其需求量急速提高,栽培的品种和种植面积也在不断扩大。但荔枝果树生长于气候湿热、阳光充沛的华南地区,病虫害的种类繁杂,危害周期长,难以防治,严重影响了荔枝的产量和品质^[1,2]。

当前,我国大多数荔枝果园的管理方式为传统人工操作,这种管理模式在病虫害预测与防治方面存在诸多不足:病虫害的种类和严重程度需要专业的病虫害专家通过实地观察或者经验判断,这种人工识别的方法存在局限性,不仅耗费人力,且难以在大规模果园中迅速推广;传统的病虫害防治方法需要人力喷洒农药,这种方式劳动强度大、效率低;另外还存在农药使用不科学的问题,导致农药滥用现象较为普遍,农药的过量使用不仅使生产成本增加,还可能对环境造成污染,同时对荔枝果实的品质和安全性产生负面影响^[3-4]。传统管理模式缺乏对病虫害的精准预测和系统性防治策略,在荔枝病虫害高发期,如果缺乏有效的监测和预警手段,果农就只能在发生病虫害后才采取措施,防治效果较差。因此,及时准确地识别荔枝病虫害能够提高病虫害防治效率,有利于促进荔枝的正常生长,得到高产量和高质量的荔枝^[5-6]。

随着近几年人工智能的迅猛发展,国内外研究人员融合机器视觉与深度学习技术,对农作物病虫害进行了深入研究^[7-16]。尽管这些研究在病虫害智能检测方面取得了较好的效果,但在实际应用中仍面临诸多困难,例如:研究对象不够广泛,部分模型仅针对虫害或病害进行检测;模型检测精度低,容易导致病虫害的漏检或误判;模型参数量大,不利于在边缘设备部署。

针对以上问题,本文以自然环境下的荔枝果树

为目标,采集 8 种荔枝病虫害图像,构建数据集,以 YOLO 11n 模型为基准,改进 C3k2 模块,替换轻量化检测头 Detect – Efficient,采用 MPDIoU 损失函数,提出一种 YOLO 11n – ACE 的轻量化荔枝病虫害检测方法,旨在提高模型的检测性能,同时降低部署成本,实现荔枝病虫害的实时监测。

1 数据集建立

1.1 图像数据采集

本研究主要在华南农业大学热带亚热带特色果树资源圃中的荔枝标准果园和广东省农业技术推广总站 2 个不同的试验果园进行了荔枝数据采集。采集设备使用 vivo、一加、小米等 5 部智能手机,采集不同角度,包含近景和远景的图像。气象条件包含晴天、阴天和雨后。图像分辨率包括 3 024 像素 × 4 032 像素、3 000 像素 × 4 000 像素、4 032 像素 × 3 016 像素和 3 016 像素 × 3 016 像素等,病虫害种类包括椿象、尺蠖、蒂蛀虫、叶瘿蚊、毛毡病、炭疽病、藻斑病和煤烟病,共 8 种^[17],保证了病虫害图像的样本多样性,还原了实际场景下的检测。在 2 个试验果园共采集荔枝图像 5 105 幅,8 种荔枝病虫害示例图像见图 1。

1.2 数据集制作

本研究使用 LabelImg 对采集到的数据进行手动标注,标注格式为 YOLO 格式。共对 5 105 幅荔枝果树原始图像进行了 16 335 个目标的标注,并对数据集按比例 8:1:1 进行划分,且在训练中使用在线数据增强功能,通过随机变换生成不同视角、尺寸、光照条件和背景的新样本,提高了模型对不同尺寸样本的适应性,并且缓解了远近景数据不均衡的问题,数据集标签分布如图 2 所示。

由图 2c 可知,边界框的位置相对均匀分布,意味着检测到的物体在图像中处于各个不同位置;图 2d 表明图像宽度和高度之间呈正相关,说明部分物体的形状比例较为一致。



图 1 8 种荔枝病虫害图像示例

Fig. 1 Eight kinds of pests and diseases of litchi




图 2 数据集标签分布图

Fig. 2 Dataset label distributions

2 模型改进

2.1 YOLO 11n 目标检测算法

YOLO 系列目标检测模型是主流的一阶段目标检测模型,对比不同版本的 YOLO 模型,YOLO 11 引入新的架构设计,在保持检测精度的同时减少参数量^[18],因此围绕当前较新的 YOLO 11n 模型进行改进研究,目的是在不失检测速度和模型轻量化的情况下提高对荔枝病虫害的检测精度。YOLO 11 的结构如图 3 所示,主干网络继承 CSPNet (Cross stage partial network) 的结构^[19],引入 C3k2 模块作为基础构建单元,该模块配合残差连接结构来使用 2 个卷积核为 3×3 的深度可分离卷积 DWConv (Depthwise convolution),形成具有深度特征复用能力的复合卷积块,并在最后一层的 SPPF (Spatial pyramid pooling fast) 模块之后添加 C2PSA 模块,增强模型处理空间信息的能力,该模块将金字塔池化思想与通道注意力机制相结合,同时保持高速推理能力^[20],颈部网




图 3 YOLO 11 结构图

Fig. 3 Structure diagram of YOLO 11

络部分延续 YOLO v8 模型使用 PAN (Path aggregation network) 结构,该结构通过自上而下和自下而上的双向特征金字塔将深层语义信息与浅层细节特征进行多级融合,在特征融合路径中使用 C3k2 模块全面替换原始 C3 模块,检测头部分采用分类头与回归头解耦的设计范式,其中回归头使用标准卷积,分类头使用深度可分离卷积^[21],其中,卷积模块中使用 SiLU 作为激活函数^[22]。

2.2 YOLO 11n 算法改进

2.2.1 C3k2-AC 模块

原始 YOLO 11 在检测荔枝病虫害多尺度目标的场景时,可能会面临一些困难,主要体现在针对小目标的检测精度不足以及模型的计算资源消耗较大这 2 个问题上。原模型的设计更侧重于兼顾多种检测任务,但在处理不同类别、不同尺度的目标时,可能无法充分聚焦于这些目标的特征。为了解决这些问题,将主干网络中的 C3k2 模块进行改进。

C3k2-AC 是在 C3k2 的基础上,通过结合 CAS-ViT^[23] 中的 AdditiveBlock 和 TransNeXt^[24] 中的 Convolutional Gated Linear Unit (CGLU) 对 C3k2 模块进行改进。

C3k-AC 将 C3k 中的 Bottleneck 模块替换成 AdditiveBlock 模块,并且用 CGLU 替换了 AdditiveBlock 模块中的多层感知机。C3k2-AC 根

据参数控制使用多个 C3k-AC 或 Bottleneck 结构进行深度特征提取,当 C3k 的参数设置为 False 时,C3k2-AC 与 C3k2 的结构相同,当参数设置为 True 时,C3k2-AC 中的 C3k 使用 C3k-AC 替换。C3k2-AC 中的 Bottleneck 模块是一种经典的残差结构,主要用于减少计算量的同时保持特征提取能力。然而,AdditiveBlock 模块在设计上更加灵活,它通过引入加法操作来融合特征,能够更有效地保留输入特征的细节信息。而在替换 Bottleneck 的 AdditiveBlock 模块中,进一步用 CGLU 替换了原有的多层感知机 (MLP)。多层感知机是一种常见的神经网络结构,用于学习复杂的非线性映射,但是与 MLP 相比,CGLU 通过引入通道门控机制,能够更有效地控制特征的流动和融合,CGLU 通过一个门控函数对输入特征进行加权,动态地调整特征的重要性,这不仅提高了特征提取的灵活性,还减少了模型的参数量和计算复杂度,改进后的 C3k2-AC 结构如图 4 所示。




图 4 C3k2-AC 结构

Fig.4 C3k2-AC structure

2.2.2 检测头改进

本研究相比 YOLO 11n,改进了一个更为轻量化的检测头 Detect-Efficient,该检测头结构参照 YOLO v8 结构,为减少检测头参数量,并保证病虫害检测的准确性,将 YOLO 11n 的检测头结构的 CBS 模块替换成分组卷积^[25]。

分组卷积 (Group convolution) 是深度学习一种高效的卷积操作,它通过将输入通道分成多个组,并在每个组内独立进行卷积操作,从而减少计算量和参数数量,同时保持特征的多样性,这种技术在许多现代卷积神经网络如 ShuffleNet 中被广泛应用^[26]。图 5 展示了分组卷积操作,其中 W 、 H 、 C 分别为输入特征图的宽、高和通道数, w 、 h 为卷积核的宽和高。输入特征图在通道维度上被均分为两组 (每组 $C/2$ 个通道),两组分别进行卷积运算后,在通道维度上拼接所有组的输出特征图,得到宽为 W' 、高为 H' 、通道数为 C' 的合并结果。

Detect-Efficient 的结构如图 6 所示,其中




图 5 分组卷积操作

Fig.5 Group convolution operation

GCBS 模块与 CBS 模块的区别是卷积操作从普通卷积替换成分组卷积,卷积核大小保持不变,为 3,分组数量设为 16,即每个组内卷积核数量为 $1/16$,使用分组卷积能减少计算量和参数量,通过分组能在保持特征多样性的同时减少计算量与参数量,分组卷积允许每个组独立学习不同的特征,从而增加了模型的特征提取能力。这种设计使得检测头更加高效,能够在不显著降低性能的情况下加速模型的推理速度。




图 6 Detect-Efficient 结构

Fig.6 Detect-Efficient structure

2.2.3 MPDIoU

YOLO 11n 的损失函数用于反向传播优化目标检测性能,它结合了多种损失项,提高检测的效率和准确性,其中包括分类损失和定位损失。分类损失衡量模型识别荔枝病虫害类别的预测准确性,定位损失优化边界框的预测精度,来更加准确地框出病虫害目标。

YOLO 11n 损失计算中的分类分支使用二元交叉熵损失函数 BCE Loss (Binary cross entropy loss),回归分支使用 DFL (Distribution focal loss) 和 CIoU Loss^[27]。

本研究为了进一步提高边界框的定位精度,使用对多类别目标检测的检测框具有较好效果的 MPDIoU Loss 替换 CIoU Loss 进行训练,MPDIoU 示意图如图 7 所示^[28]。

MPDIoU 是一种基于最小点距离的新型边界框相似度比较度量标准,直接最小化预测边界框与实际标注边界框之间的左上角和右下角点距离。MPDIoU 包含现有损失函数中的相关因素,即重叠或非重叠区域、中心点距离、宽高偏差,计算过程也




图 7 MPDIoU 示意图
Fig. 7 Schematic of MPDIoU

被简化,计算公式为

$$MPDIoU = IoU - \frac{d_1^2}{w^2 + h^2} - \frac{d_2^2}{w^2 + h^2} \tag{1}$$

式中 IoU ——预测边界框与实际标注边界框交集面积与并集面积之比

d_1 ——预测边界框与标注边界框之间的左上角点的欧氏距离

d_2 ——预测边界框与标注边界框之间的右下角点的欧氏距离

MPDIoU Loss 通过最小点距离的方式简化了计算过程,提高了计算效率,且能够适应重叠或非重叠的边界框回归场景,尤其在预测框与真实框具有相同纵横比但宽度和高度完全不同时,优化效果显著,最终 MPDIoU Loss 的公式为

$$L_{MPDIoU} = 1 - MPDIoU \tag{2}$$

基于上述改进策略后最终的 YOLO 11 荔枝病虫害检测模型的结构如图 8 所示,图中红色虚线框部分为模型改进部分。




图 8 改进 YOLO 11 模型图
Fig. 8 Model diagram of improved YOLO 11

3 试验环境与结果分析

3.1 试验环境

模型的训练平台配置包括一台装备有主频

2.60 GHz 的 Intel(R) Xeon(R) Gold 6240 CPU、6 × 32 GB DDR4 内存,以及配备两块显存 24 GB 的 NVIDIA GeForce RTX 3090 显卡的台式计算机,操作系统为 Ubuntu 22.04.3 LTS。在软件环境方面,选用了 Python 3.8.19 版本、PyTorch 2.3.1 版本以及 CUDA 12.2 版本。为了确保试验中模型对比的准确性和数据的可靠性,所有选用的模型均在该服务器下完成训练和运行。

3.2 评价指标

为对比本研究提出的模型与其他模型的性能,主要选用目标检测领域常用的精确率、召回率和平均精度均值(mean Average Precision, mAP)作为性能评估指标。

为全面评估模型的综合性能,在考虑检测精度的基础上,引入模型参数量(Parameters)、浮点运算量(Giga floating point operations per second, GFLOPS)作为衡量模型规模与计算复杂性的指标,确保所比较的模型级别为轻量。此外,通过测量检测帧率(Frames per second, FPS)来测评模型的运行效率,量化分析模型的多维度性能。

3.3 试验结果分析

3.3.1 不同模型试验结果对比

通过对 YOLO 11n 模型进行各个方面的优化改进最终得到 YOLO 11n-ACE 模型,为了验证 YOLO 11n-ACE 模型的改进效果,在相同试验环境下,对主流的目标检测模型进行性能对比,具体的对比结果如表 1 所示。

由表 1 可知,SSD 和 Faster R-CNN 在该数据集下表现较差,精度低的同时参数量大;YOLO v5n 在各基准模型中识别的帧率最高,参数量最小,即在有限的硬件资源条件下,该模型的推理速度较快,但是由于其对荔枝病虫害检测的精度较低,无法满足荔枝病虫害检测对高精度的要求;而 RT-DETR-R18 和 YOLO v8n 精度高,但其参数量和浮点运算量比 YOLO 11n 大,在考虑轻量化的前提下,选择 YOLO 11n 作为改进的基准模型。

YOLO 11n-ACE 精确率、召回率和 mAP 分别达到 88.27%、76.44%、83.03%,较基准模型 YOLO 11n 分别提升了 2.54、0.97、0.97 个百分点;参数量和浮点运算量分别减少 15% 和 20.6%。RT-DETR-R18 在参数量是 YOLO 11n-ACE 模型的 9.1 倍,浮点运算量 11.4 倍的情况下,其精确率、召回率和 mAP 等指标并没有明显的领先。相比之下,YOLO 11n-ACE 模型在保证准确的同时,也具备满足实际应用需求的推理速度,还通过改进网络结构与损失,进一步降低了模型的内存占用量和计算复杂度。

表 1 YOLO 11n-ACE 与其他模型的对比结果

Tab. 1 Comparison results of YOLO 11n-ACE with other models

模型	精确率/%	召回率/%	mAP/%	参数量	帧率/(f·s ⁻¹)	浮点运算量
SSD	46.28	20.73	33.25	2.68 × 10 ⁷	46.3	3.25 × 10 ¹⁰
Faster R-CNN	65.48	29.84	44.76	4.26 × 10 ⁷	23.6	9.56 × 10 ¹⁰
RT-DETR-R18	86.76	77.55	82.91	1.99 × 10 ⁷	31.2	5.7 × 10 ¹⁰
YOLO v5n	84.93	74.07	79.96	2.18 × 10 ⁶	201.1	5.8 × 10 ⁹
YOLO v6n	86.94	75.83	81.70	4.16 × 10 ⁶	140.5	1.13 × 10 ¹⁰
YOLO v8n	88.15	76.14	82.49	3.01 × 10 ⁶	168.4	8.1 × 10 ⁹
YOLO v10n	86.83	75.05	81.16	2.26 × 10 ⁶	164.1	6.5 × 10 ⁹
YOLO 11n	85.73	75.47	82.06	2.58 × 10 ⁶	160.2	6.3 × 10 ⁹
YOLO 11n-ACE	88.27	76.44	83.03	2.19 × 10 ⁶	160.0	5.0 × 10 ⁹

这些改进使得 YOLO 11n-ACE 更适合在资源受限的板端中进行实时病虫害检测,为荔枝病虫害的智能化监测提供新的技术手段。

图 9 所示的雷达图进一步直观展示了不同 YOLO 模型的性能效果。图中各模型在 4 项指标(精确率、召回率、mAP、帧率)采用归一化处理,参




图 9 不同版本 YOLO 模型的性能可视化雷达图

Fig. 9 Radar chart of performance visualization for different versions of YOLO

数量和浮点运算量指标采用反向归一化处理,模型越轻量得分越高,所有指标归一化至 80% ~ 100% 范围,突出高性能模型间的细微差异。可以观察到, YOLO 11n-ACE 模型多项指标均接近雷达图边缘,整体呈现出均衡且优越的表现。

3.3.2 结果可视化

为了更加直观体现上述不同版本的 YOLO 模型对荔枝病虫害的检测效果,分别从荔枝病虫害数据集中选取病虫害图像进行检测,图像在荔枝果园自然环境下拍摄,背景复杂且非结构化。

图 10 所示为不同 YOLO 模型识别叶瘿蚊这一虫害的效果,红色方框为重要关注部分。与 YOLO 11n-ACE 算法相比,其他算法容易出现预测框重叠、漏检、误检的问题。再次表明在相同的检测条件下,其他 YOLO 系列算法相较于 YOLO 11n-ACE 算法可能更容易受到背景干扰和目标遮挡的影响, YOLO 11n-ACE 算法在处理部分遮挡或背景噪声较多的情况时表现出更强的鲁棒性,能够更好地处理复杂场景。

图 11 为 YOLO 11n 与 YOLO 11n-ACE 对其余 7




图 10 不同 YOLO 模型识别叶瘿蚊效果图

Fig. 10 Effect diagrams of different YOLO models in identifying leaf goiter mosquitoes



图 11 YOLO 11n 和 YOLO 11n - ACE 识别病虫害的效果图

Fig. 11 Effect diagrams of YOLO 11n and YOLO 11n - ACE in identifying plant diseases and pests

种不同荔枝病虫害进行识别的效果图。由于光线条件不佳以及树枝和叶片的轻微遮挡,荔枝病虫害目标较难通过肉眼直接发现。从椿象图中可以看出, YOLO 11n - ACE 算法在识别荔枝椿象时,能够更准确地定位目标,并在图像上清晰地标注出椿象的位置。这种精确的定位能力对于实际的病虫害监测和管理有重要意义,因为它可以帮助农户或农业技术人员快速识别和定位病虫害,及时采取相应的防治措施。相比之下, YOLO 11n 算法也能检测出荔枝椿象,但其出现漏检情况,且大多数置信度分数比 YOLO 11n - ACE 低,说明在相同的检测条件下, YOLO 11n

算法可能更容易受到背景干扰和目标遮挡的影响,导致检测效果不如 YOLO 11n - ACE 算法好。

3.3.3 不同改进模块的消融试验

通过对各模块的系统性对比分析,本研究使用性能最优的模块,进行组合优化构建出 YOLO 11n - ACE 模型。随后,进一步对比不同模块组合方案在荔枝病虫害数据集上的检测效果,以评估各组合方案的病虫害识别准确性。为了验证对 YOLO 11n - ACE 模型改进方法的有效性,针对上述最优模块进行消融试验,比较其模块叠加对模型精度的影响,消融试验效果如表 2 所示。

表 2 消融试验结果

Tab.2 Ablation test results

模型	C3k2 - AdditiveBlock	C3k2 - AdditiveBlock - CGLU	Detect - Efficient	MPDIoU	精确率/ %	召回率/ %	mAP/ %	参数量	帧率/ (f·s ⁻¹)	浮点运 算量
YOLO 11n					85.73	75.47	82.06	2.583 × 10 ⁶	160.2	6.3 × 10 ⁹
模型 1	✓				85.37	77.15	82.49	2.626 × 10 ⁶	156.7	6.7 × 10 ⁹
模型 2		✓			88.57	73.96	82.15	2.454 × 10 ⁶	168.1	6.2 × 10 ⁹
模型 3			✓		87.07	73.87	81.48	2.315 × 10 ⁶	195.6	5.1 × 10 ⁹
模型 4		✓	✓		87.97	74.28	82.25	2.186 × 10 ⁶	139.1	5.0 × 10 ⁹
YOLO 11n - ACE		✓	✓	✓	88.27	76.44	83.03	2.186 × 10 ⁶	160.0	5.0 × 10 ⁹

注:“✓”表示添加该模块。

表 2 中模型 1 将 C3k2 模块替换为 C3k2 - AdditiveBlock 模块,模型 2 将 C3k2 模块替换为 C3k2 - AdditiveBlock - CGLU 模块,模型 3 是在原始模型上引入轻量化检测头 Detect - Efficient,模型 4 是在模型 2 基础上引入轻量化检测头 Detect - Efficient,最后的 YOLO 11n - ACE 模型是在模型 4 的基础上使用 MPDIoU 损失函数替换原损失函数中的 CIoU 损失函数训练。由表 2 试验结果可知,使用添加 AdditiveBlock 的 C3k2 模块的平均精度有所提升,但模型的参数量和浮点数运算量同时也有所增加,且模型检测的帧率低于原始模型,意味着检测速度有所下降。而采用 CGLU 改进的 AdditiveBlock 的 C3k2 模块参数量和浮点数运算有所减少,更适用于嵌入式 AI 板端的部署条件,且帧率比原来的 C3k2 模块高。当对原始 YOLO 11n 模型同时实施 3 种改进策略:替换 C3k2 模块为 C3k2 - AC 模块、改进检测头为更具轻量化检测头 Detect - Efficient、更换损失函数中边界框损失函数为 MPDIoU,此时的 YOLO 11n - ACE 模型综合性能最优。最终的 YOLO 11n - ACE 模型相比原始 YOLO 11n 模型的精确率、召回率以及 mAP 均实现显著的提升,分别达到 88.27%、76.44%、83.03%,比原始的 YOLO 11n 模型的 3 项指标分别高出 2.54、0.97、0.97 个百分点,参数量也从 2.583 × 10⁶下降到 2.186 × 10⁶,减少了

3.97 × 10⁵,浮点运算量从 6.3 × 10⁹下降到 5.0 × 10⁹,减少了 1.3 × 10⁹。这表明所提出的 3 种改进策略在提升 YOLO 11n 模型性能方面的有效性。

4 结论

(1)为了提高荔枝病虫害的检测精度,降低模型计算资源需求,解决荔枝因生长环境和病害种类复杂造成的漏检和误检等问题,本文在 YOLO 11n 的基础上,提出一种基于 YOLO 11n - ACE 的轻量化荔枝病虫害检测方法。使用 C3k2 - AC 模块替换原来的 C3k2 模块,增强模型对荔枝的特征提取能力,提高对小目标的检测精度。考虑到荔枝病虫害检测的情况,更改损失函数为 MPDIoU,进一步提高多类别目标检测框的定位精度。最后,为实现模型的可迁移化,满足荔枝病虫害嵌入式设备的实时检测需求,把部分必要卷积替换成分组卷积,设计轻量化检测头 Detect - Efficient。改进后的 YOLO 11n - ACE 模型对比原模型的精确率和召回率,提高了 2.54、0.97 个百分点,参数量和浮点运算量减少 15.3% 和 20.6%。

(2)本文提出的 YOLO 11n - ACE 模型在自建的荔枝病虫害数据集上取得了较好的检测效果,但仍存在不足之处。受限于数据采集条件,数据集在样本规模、病虫害种类及环境复杂性等方面尚显不足。

参 考 文 献

[1] 杨佐兵, 魏玉晗, 魏丹. 广东省荔枝古树资源分布及影响要素研究[J]. 林业调查规划, 2025, 50(1): 122-127.
Yang Zuobing, Wei Yuhuan, Wei Dan. Resources distribution and influencing factors of litchi chinensis ancient tree in Guangdong Province[J]. Forest Inventory and Planning, 2025, 50(1): 122-127. (in Chinese)

[2] 吴盛豪. 海南荔枝主要病虫害的防治[J]. 特种经济动植物, 2021, 24(9): 60-61.
Wu Shenghao. Control of major pests and diseases of litchi in Hainan[J]. Special Economic Animal and Plant, 2021, 24(9): 60-61. (in Chinese)

[3] Li H, Huang D, Ma Q, et al. Factors influencing the technology adoption behaviours of litchi farmers in China[J]. Sustainability, 2020, 12(1): 271.

[4] 王伟莉, 曾智良, 龚文婷. 基于深度学习技术的农作物病虫害检测识别系统的研究[J]. 农业灾害研究, 2024, 14(4): 52-54.
Wang Weili, Zeng Zhiliang, Gong Wenting. Research on a crop disease and pest detection and recognition system based on deep learning technology[J]. Agricultural Disaster Research, 2024, 14(4): 52-54. (in Chinese)

[5] 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(7): 1-18.
Zhai Zhaoyu, Cao Yifei, Xu Huanliang, et al. Review of key techniques for crop disease and pest detection[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(7): 1-18. (in Chinese)

[6] 张国忠, 吕紫薇, 刘浩蓬, 等. 基于改进 DenseNet 和迁移学习的荷叶病虫害识别模型[J]. 农业工程学报, 2023, 39(8): 188-196.
Zhang Guozhong, Lv Ziwei, Liu Haopeng, et al. Model for identifying lotus leaf pests and diseases using improved DenseNet and transfer learning[J]. Transactions of the CSAE, 2023, 39(8): 188-196. (in Chinese)

[7] 刘拥民, 胡魁, 聂佳伟, 等. 基于 MSDB-ResNet 的水稻病虫害识别[J]. 华南农业大学学报, 2023, 44(6): 978-985.
Liu Yongmin, Hu Kui, Nie Jiawei, et al. Rice disease and pest identification based on MSDB-ResNet[J]. Journal of South China Agricultural University, 2023, 44(6): 978-985. (in Chinese)

[8] 彭红星, 何慧君, 高宗梅, 等. 基于改进 ShuffleNetV2 模型的荔枝病虫害识别方法[J]. 农业机械学报, 2022, 53(12): 290-300.
Peng Hongxing, He Huijun, Gao Zongmei, et al. Litchi diseases and insect pests identification method improved ShuffleNetV2[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(12): 290-300. (in Chinese)

[9] 王卫星, 刘泽乾, 高鹏, 等. 基于改进 YOLO v4 的荔枝病虫害检测模型[J]. 农业机械学报, 2023, 54(5): 227-235.
Wang Weixing, Liu Zeqian, Gao Peng, et al. Detection of litchi diseases and insect pests based on improved YOLO v4 model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(5): 227-235. (in Chinese)

[10] Wang L, Shi W, Tang Y, et al. Transfer learning-based lightweight SSD model for detection of pests in citrus[J]. Agronomy, 2023, 13(7): 1710.

[11] Zhang Y, Wa S Y, Zhang L X, et al. Automatic plant disease detection based on tranvolution detection network with GAN modules using leaf images[J]. Frontiers in Plant Science, 2022, 13: 875693.

[12] Kumar R D, Md. Akkas A, Kumar A S, et al. Deep multibranch fusion residual network and IoT-based pest detection system using sound analytics in large agricultural field[J]. Multimedia Tools and Applications, 2023, 83(13): 40215-40252.

[13] 谢家兴, 廖飞, 王卫星, 等. 基于改进 Faster R-CNN 的荔枝病虫害检测[J]. 华中农业大学学报, 2025, 44(1): 62-73.
Xie Jiaxing, Liao Fei, Wang Weixing, et al. Detection diseases and insect pests in litchi based on improved Faster R-CNN[J]. Journal of Huazhong Agricultural University, 2025, 44(1): 62-73. (in Chinese)

[14] 周平, 殷勇, 杨岚, 等. 基于改进 YOLOv7 的荔枝叶片病害监测模型[J]. 农业工程, 2025, 15(4): 21-27.
Zhou Ping, Yin Yong, Yang Lan, et al. Litchi leaf disease monitoring model based on improved YOLOv7[J]. Agricultural Engineering, 2025, 15(4): 21-27. (in Chinese)

[15] 朱军, 陈钢, 蒋丽花, 等. 轻量化改进 YOLOv8n 的荔枝病虫害检测方法[J]. 农业工程学报, 2025, 41(13): 207-215.
Zhu Jun, Chen Gang, Jiang Lihua, et al. Detecting litchi pests and disease using lightweight improved YOLOv8n[J]. Transactions of the CSAE, 2025, 41(13): 207-215. (in Chinese)

[16] 黎祖胜, 唐吉深, 匡迎春. 基于改进 YOLOv10n 的轻量化荔枝虫害小目标检测模型[J]. 智慧农业(中英文), 2025, 7(2): 146-159.
Li Zusheng, Tang Jishen, Kuang Yingchun. A lightweight model for detecting small targets of litchi pests based on improved YOLOv10n[J]. Smart Agriculture, 2025, 7(2): 146-159. (in Chinese)

[17] 李婷, 李靖, 赵霞, 等. 我国荔枝主要病虫害及农药登记情况简析[J]. 农药科学与管理, 2022, 43(12): 7-12.
Li Ting, Li Jing, Zhao Xia, et al. Analysis of the main pests occurred and pesticides registered on litchi in China[J]. Pesticide Science and Management, 2022, 43(12): 7-12. (in Chinese)

[18] 朱婷婷, 滕广, 张亚军, 等. 基于改进 YOLO v11 的番茄表面缺陷检测方法[J]. 农业机械学报, 2025, 56(6): 546-553.
Zhu Tingting, Teng Guang, Zhang Yajun, et al. Improved YOLO v11 method for surface defect detection of tomato[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(6): 546-553. (in Chinese)

[19] Hu X, Dai N, Hu X, et al. YOLOvT: CSPNet-based attention for a lightweight textile defect detection model[J]. Textile

Research Journal, 2024, 94(9 – 10) : 1021 – 1039.

[20] Lee S Y, Patil P M, Kim G J, et al. Hyperparameter optimization for tomato leaf disease recognition based on YOLOv11m [J]. Plants, 2025, 14(5) : 653.

[21] Nagpal J, Goel L. ResdenseNet: a lightweight dense ResNet enhanced with depthwise separable convolutions and its applications for early plant disease classification[J]. Neural Computing and Applications, 2025, 37(8) : 1 – 22.

[22] 刘玉洁, 金钧. 基于改进的 YOLOv5s 绝缘子故障识别方法[J]. 机械与电子, 2024, 42(12) : 31 – 36.
Liu Yujie, Jin Jun. Insulator fault identification method of overhead contact system based on improved YOLOv5s [J]. Machinery & Electronics, 2024, 42(12) : 31 – 36. (in Chinese)

[23] Zhang T, Li L, Zhou Y, et al. CAS – ViT: convolutional additive self-attention vision transformers for efficient mobile applications[J]. IEEE Transactions on Image Processing, 2026, 35: 1899 – 1909.

[24] 段淳耀, 赵霞, 程鸿. 基于改进 YOLOv8 的百合地杂草分类识别[J]. 软件工程, 2025, 28(2) : 46 – 51.
Duan Chunyao, Zhao Xia, Cheng Hong. Weed classification and recognition of lily fields based on improved YOLOv8 [J]. Software Engineering, 2025, 28(2) : 46 – 51. (in Chinese)

[25] Liu Z, Zhuo L, Dong C, et al. YOLO – TBD: tea bud detection with triple-branch attention mechanism and self-correction group convolution[J]. Industrial Crops & Products, 2025, 226: 120607.

[26] Sulaiman B Z. RP squeeze U – SegNet model for lesion segmentation and optimization enabled ShuffleNet based multi-level severity diabetic retinopathy classification[J]. Network (Bristol, England), 2024, 36(4) : 31 – 34.

[27] Xun J L, Cheng F, Li Y Q, et al. Detection of farmland obstacles based on an improved YOLOv5s algorithm by using CIoU and anchor box scale clustering[J]. Sensors, 2022, 22(5) : 1790.

[28] Xia Y, Wang Z, Cao Z, et al. Recognition model for tea grading and counting based on the improved YOLOv8n [J]. Agronomy, 2024, 14(6) : 1251.

(上接第 279 页)

[13] 李志杰, 兰媛, 黄家海, 等. 基于 CBLRE 模型的轴向柱塞泵空化状态检测研究[J]. 机电工程, 2022, 39(5) : 634 – 640.
Li Zhijie, Lan Yuan, Huang Jiahai, et al. Research on cavitation state detection of axial piston pump based on CBLRE model [J]. Mechanical and Electrical Engineering, 2022, 39(5) : 634 – 640. (in Chinese)

[14] Konatham S R, Maram R, Cortés L R, et al. Real-time gap-free dynamic waveform spectral analysis with nanosecond resolutions through analog signal processing[J]. Nature Communications, 2020, 11(1) : 3309.

[15] Ye W, Yi Y, Luo X. Numerical modeling of unsteady cavitating flow over a hydrofoil with consideration of surface curvature [J]. Ocean Engineering, 2020, 205: 107305.

[16] Daubechies I. The wavelet transform, time-frequency localization and signal analysis[J]. IEEE Transactions on Information Theory, 1990, 36(5) : 961 – 1005.

[17] Feng K, Ji J C, Ni Q, et al. A review of vibration based gear wear monitoring and prediction techniques[J]. Mechanical Systems and Signal Processing, 2023, 182: 109605.

[18] Feng K, Ji J C, Zhang Y, et al. Digital twin-driven intelligent assessment of gear surface degradation[J]. Mechanical Systems and Signal Processing, 2023, 186: 109896.

[19] Ni Q, Ji J C, Halkon B, et al. Physics-informed residual network (PIResNet) for rolling element bearing fault diagnostics [J]. Mechanical Systems and Signal Processing, 2023, 200: 110544.

[20] Ni Q, Ji J C, Feng K, et al. Data-driven bearing health management using a novel multi-scale fused feature and gated recurrent unit[J]. Reliability Engineering & System Safety, 2024, 242: 109753.

[21] Gao B, Guo P, Zhang N, et al. Experimental investigation on cavitating flow induced vibration characteristics of a low specific speed centrifugal pump[J]. Shock and Vibration, 2017, 2017: 6568930.

[22] Elsas J H, Moriconi L. Vortex identification from local properties of the vorticity field[J]. Physics of Fluids, 2017, 29(1) : 1 – 22.

[23] Tiwari R, Bordoloi D J, Dewangan A. Blockage and cavitation detection in centrifugal pumps from dynamic pressure signal using deep learning algorithm[J]. Measurement, 2021, 173: 108676.

[24] Sha Y, Faber J, Gou S, et al. A multi-task learning for cavitation detection and cavitation intensity recognition of valve acoustic signals[J]. Engineering Applications of Artificial Intelligence, 2022, 113: 105499.

[25] 吴侃. 离心泵空化状态识别方法研究与实现[D]. 镇江: 江苏大学, 2019.
Wu Kan. Research and implementation of cavitation state recognition method for centrifugal pump [D]. Zhenjiang: Jiangsu University, 2019. (in Chinese)