

doi:10.6041/j.issn.1000-1298.2023.05.023

# 基于改进 YOLO v4 的荔枝病虫害检测模型

王卫星<sup>1</sup> 刘泽乾<sup>1</sup> 高鹏<sup>1</sup> 廖飞<sup>1</sup> 李强<sup>2</sup> 谢家兴<sup>1,3</sup>(1. 华南农业大学电子工程学院(人工智能学院), 广州 510642; 2. 广东省农业技术推广中心, 广州 510520;  
3. 广东省智慧果园科技创新中心, 广州 510642)

**摘要:** 为实时准确地检测到自然环境下背景复杂的荔枝病虫害, 本研究构建荔枝病虫害图像数据集并提出荔枝病虫害检测模型以提供诊断防治。以 YOLO v4 为基础, 使用更轻、更快的轻量化网络 GhostNet 作为主干网络提取特征, 并结合 GhostNet 中的核心设计引入更低成本的卷积 Ghost Module 代替颈部结构中的传统卷积, 得到轻量化后的 YOLO v4-G 模型。在此基础上使用新特征融合方法和注意力机制 CBAM 对 YOLO v4-G 进行改进, 在不失检测速度和模型轻量化程度的情况下提高检测精度, 提出 YOLO v4-GCF 荔枝病虫害检测模型。构建的数据集包含荔枝病虫害图像 3725 幅, 其中病害种类包括煤烟病、炭疽病和藻斑病 3 种, 虫害种类包括毛毡病和叶瘿蚊 2 种。试验结果表明, 基于 YOLO v4-GCF 的荔枝病虫害检测模型, 对于 5 种病虫害目标在训练集、验证集和测试集上的平均精度分别为 95.31%、90.42% 和 89.76%, 单幅图像检测用时 0.167 s, 模型内存占用量为 39.574 MB, 相比改进前的 YOLO v4 模型缩小 84%, 检测速度提升 38%, 在测试集中检测平均精度提升 4.13 个百分点, 同时平均精度比常用模型 YOLO v4-tiny、EfficientDet-d2 和 Faster R-CNN 分别高 17.67、12.78、25.94 个百分点。所提出的 YOLO v4-GCF 荔枝病虫害检测模型能够有效抑制复杂背景的干扰, 准确且快速检测图像中荔枝病虫害目标, 可为自然环境下复杂、非结构背景的农作物病虫害实时检测研究提供参考。

**关键词:** 荔枝; 病虫害检测; 目标检测; YOLO v4; 轻量化中图分类号: TP391.4; S436.629 文献标识码: A 文章编号: 1000-1298(2023)05-0227-09 OSID: 

## Detection of Litchi Diseases and Insect Pests Based on Improved YOLO v4 Model

WANG Weixing<sup>1</sup> LIU Zeqian<sup>1</sup> GAO Peng<sup>1</sup> LIAO Fei<sup>1</sup> LI Qiang<sup>2</sup> XIE Jiaxing<sup>1,3</sup>(1. College of Electronic Engineering (College of Artificial Intelligence), South China Agricultural University, Guangzhou 510642, China  
2. Guangdong Agricultural Technology Extension Center, Guangzhou 510520, China  
3. Guangdong Modern Agricultural Science and Technology Innovation Center for Intelligent Orchard, Guangzhou 510642, China)

**Abstract:** In order to accurately detect litchi diseases and insect pests with complex background in natural environment in real time, the data set of litchi diseases and insect pests was constructed and the detection model of litchi diseases and insect pests was proposed for diagnosis and control. Based on YOLO v4, GhostNet, the lighter and faster lightweight network, was used as the backbone network to extract features. According to the core design of GhostNet, Ghost Module, a lower cost convolution, was used to replace the traditional convolution in the neck structure. Based on the lightweight YOLO v4-G model, the feature fusion method and attention mechanism called CBAM were used to improve the YOLO v4-G. The detection accuracy was improved without losing the detection speed and the lightweight degree of the model. Finally, the YOLO v4-GCF detection model of litchi diseases and insect pests was proposed. The dataset contained 3725 images of litchi diseases and insect pests. Litchi diseases included sooty mold, anthracnose and algal spot. Litchi insect pests included leaf mite and *Dasineura* sp. The

收稿日期: 2022-09-14 修回日期: 2022-10-18

基金项目: 华南农业大学新农村发展研究院农业科技合作共建项目(2021XNYNYKJHZGJ032)、省级乡村振兴战略专项省级组织实施项目(粤财农(2021)37号)、广东省现代农业产业技术体系创新团队建设专项资金项目(2022KJ108)、广东省乡村振兴战略专项(农业科技能力提升)(TS-1-4)和财政部农业农村部:国家现代农业产业技术体系项目(CARS-32-14)

作者简介: 王卫星(1963—), 男, 教授, 博士生导师, 主要从事农业物联网和电子信息技术研究, E-mail: weixing@scau.edu.cn

通信作者: 谢家兴(1979—), 男, 讲师, 博士, 主要从事农业物联网和电子信息技术研究, E-mail: xjx1998@scau.edu.cn

experimental results showed that the average accuracy of five kinds of diseases and insect pests targets detected by YOLO v4 – GCF detection model in train set, validation set and test set was 95.31%, 90.42% and 89.76%, respectively. The detection time of a single image was 0.1671 s, and the size of the model was 39.574 MB. Compared with the YOLO v4, the model size was reduced by 84%, the detection speed was increased by 38% and the average accuracy in the test set was improved by 4.13 percentage points. At the same time, the average accuracy was 17.67, 12.78 and 25.94 percentage points higher than those of YOLO v4 – tiny, EfficientDet – d2 and Faster R – CNN, respectively. The proposed YOLO v4 – GCF detection model of litchi diseases and insect pests can effectively inhibit the interference of complex background, and accurately and quickly detect targets of litchi diseases and insect pests in the images, which can provide reference for crop diseases and insect pests detection research with complex and unstructured background in natural environment.

**Key words:** litchi; detection of diseases and insect pests; object detection; YOLO v4; lightweight

## 0 引言

荔枝属无患子科荔枝属植物,富含矿物质和维生素,味道鲜美,且荔枝果皮和种子具有潜在的药用价值,在国际鲜果市场发挥着明显竞争优势<sup>[1–4]</sup>。随经济的快速发展,荔枝的需求量急速增加,其栽培品种和种植面积不断扩大<sup>[2,4]</sup>。由于荔枝果树栽培于高湿、高温、多向阳的华南地区,且不同品类的混合种植和栽培面积扩大,为虫害和病菌的附着提供了绝佳场所,因此荔枝病虫害也日益严重。荔枝病虫害种类繁多,危害周期长、防治困难,成为影响荔枝产量和品质的重要制约因素<sup>[5–6]</sup>。因此,利用高效准确的检测技术对荔枝病虫害进行防治,是提高荔枝产量和品质的关键问题之一。

人工智能等现代信息技术是发展农业现代化的必经之路,大力推进其在农业中的应用有利于智慧农业的发展<sup>[7]</sup>。目前计算机视觉是智慧农业发展的重要组成部分,能够对病虫害进行高效且精确的诊断防控<sup>[8–9]</sup>。ZHANG 等<sup>[10]</sup>提出了 DCPSNET (Dense channel and position self – attention fusion network) 模型,结合动力机制融合注意力方法,对 6 类脐橙病虫害的识别准确率高达 96.90%。李书琴等<sup>[11]</sup>提出了一种基于轻量级残差网络,在 Plant Village 数据集上识别错误率为 0.32%,并在自建苹果叶片病害数据集上获得了 1.52% 的低识别错误率。刘晓锋等<sup>[12]</sup>提出了一种基于空间残差收缩网络的农作物病虫害识别模型,对 Plant Village 数据库中 4 个农作物病虫害的分类精度达到 99.41%。以上研究开展了计算机视觉技术对于农作物病虫害的分类识别研究,证明了基于深度学习的计算机视觉技术在农作物病虫害上的诊断防控是切实可行的,为深度学习广泛应用于病虫害的检测技术提供了参考。

自然环境下的识别任务中,荔枝病虫害图像背景往往是复杂的、非结构的,并且图像中有时还存在

多种病虫害目标。深度学习的高速发展,使得其能对病虫害图像中的病斑目标检测定位,且具有准确、实时、无损等特点<sup>[13–15]</sup>。YUE 等<sup>[16]</sup>提出了 MSR – RCNN (Multi – scale super – resolution feature enhancement module) 多类作物害虫检测模型,在大规模灯诱害虫数据集(含 26 类共 18 585 幅图像)取得准确率达 67.4% 的最佳性能。李子茂等<sup>[17]</sup>提出了 TSDDP (Two stage detection of diseases and pests) 月季病虫害检测模型,最终检测准确率达 82.26%。李就好等<sup>[18]</sup>提出了基于改进 Faster R – CNN 的田间苦瓜叶部病害检测模型,对 4 类苦瓜叶部病害和健康叶片的检测准确率达到 86.93%。LI 等<sup>[19]</sup>集成了沙钟特征提取模块、深沙钟特征提取模块和空间金字塔池化模块 3 种新模块,提出了 YOLO – JD (YOLO for jute diseases) 网络模型,用于黄麻病虫害图像的检测,平均准确率达 96.63%。LYU 等<sup>[20]</sup>提出了改进 SSD 模型,采用自顶向下的特征融合策略,对粮食害虫小目标的平均准确率达 96.89%。以上研究针对不同病虫害的特点,分析各病虫害的尺度差异以及各自自然环境下的复杂背景,结合需求提出了不同的深度学习检测模型。但在自然环境下对农作物病虫害进行实时地检测仍然存在局限,如 MSR – RCNN 害虫检测模型的数据集为灯诱害虫图像,还需进一步探究自然环境下,背景复杂的病虫害检测效果,以及 YOLO – JD 的沙钟特征提取模块计算成本较大,实时性还需进一步提高。

为了使用兼具速度和精度的检测算法模型,研究者通常使用一阶段的目标检测方法,YOLO 系列在该领域中通常有优异的表现<sup>[21]</sup>。而目前对于复杂、非结构背景下的荔枝病虫害检测研究较少,且荔枝病虫害目标的尺度差异大,本文以 YOLO v4<sup>[22]</sup> 算法为基础,使用轻量化网络 GhostNet<sup>[23]</sup> 作为主干网络,并改进模型的颈部结构以使网络不失精度的同时更轻量化,最终提出轻量级的荔枝病虫害检测模型,以期为林间荔枝病虫害的快速诊断提供精确信息。

# 1 材料与方法

## 1.1 荔枝病虫害图像数据集

### 1.1.1 图像采集

荔枝病虫害图像采集地点为广东省农业技术推广总站,设备为小米 6、realme x、魅族 16th、iphone 7plus、iphone 12 等 5 种智能手机,时间为 2021 年 7 月 11 日至 11 月 19 日,时段为 08:30—11:30 和 14:30—17:30。为采集自然环境下不同尺度和光照



图 1 荔枝病虫害图像

Fig. 1 Images of litchi diseases and insect pests

### 1.1.2 数据集构建

对上述 3 725 幅荔枝病虫害图像进行目标标注,标注工具为 LabelImg。荔枝病虫害图像数据的训练集、验证集和测试集按照比例 8:1:1 划分,数据集具体构建方式见表 1。

表 1 荔枝病虫害数据集

Tab. 1 Dataset of litchi diseases and pests

病虫害类别	训练集	验证集	测试集	合计
毛毡病	630	79	79	788
煤烟病	577	72	72	721
炭疽病	567	71	71	709
叶瘿蚊	636	80	80	796
藻斑病	569	71	71	711
合计	2 979	373	373	3 725

## 1.2 YOLO v4 概述

YOLO 系列算法作为主流的一阶段目标检测模型,其兼具速度和精度的特点,使得研究者们能够对其加以调整并部署于工程当中。YOLO v4 的主干网络 Backbone 使用了 CSPDarknet53<sup>[24]</sup> (Cross stage partial DarkNet) 进行特征提取,以最后 3 个特征图作为颈部结构 Neck 中特征融合网络 FPN<sup>[25]</sup> (Feature pyramid networks) 和 PANet<sup>[26]</sup> (Path aggregation network) 的输入,经过 FPN 和 PANet 进行特征增强后的 3 个特征图将经过检测头,得到每个特征图的分类和定位信息,并利用其先验框解码进行非极大值抑制,最后获得检测结果。YOLO v4 模型结构如图 2 所示。

## 1.3 荔枝病虫害检测模型构建

以 YOLO v4 为基础,针对自然环境下复杂、非

强度下的图像,拍摄时设备与病斑叶片距离为 0.2~0.5 m,并在晴天、阴天和雨后 3 种不同天气采集图像,且包含背阳、向阳等角度,以还原实际场景下的检测。试验数据集均为自然环境下非结构背景的荔枝病虫害图像,如图 1 所示,病害包括煤烟病、炭疽病和藻斑病,虫害包括毛毡病和叶瘿蚊,共 5 种病虫害,分辨率包括 4 032 像素 × 3 016 像素和 3 016 像素 × 3 016 像素等。最终采集到荔枝病虫害图像 3 725 幅。

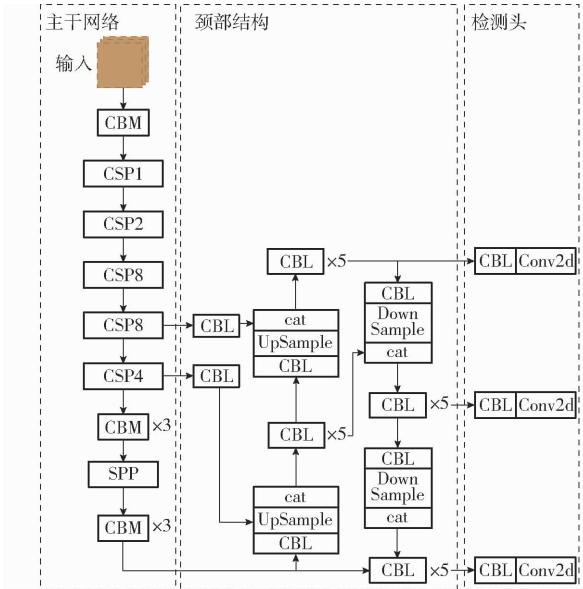


图 2 YOLO v4 模型结构图

Fig. 2 Model structure diagram of YOLO v4

结构背景的多尺度荔枝病虫害目标,设计高效的荔枝病虫害检测模型,使用轻量化识别网络 GhostNet 作为主干网络提取特征,使用 SPPF 替换 SPPP 以加快检测速度,并结合 GhostNet 中的核心思想和方法以更低成本的卷积代替传统卷积,降低模型计算成本,再对颈部结构使用新的特征融合方法和注意力机制 CBAM (Convolutional block attention module),提高模型的检测准确率。利用上述方法的检测模型构建框架如图 3 所示。

### 1.3.1 GhostNet

GhostNet 为轻量级的识别网络,拥有优秀的特征提取效果<sup>[23]</sup>,可作为检测模型的主干网络,其核

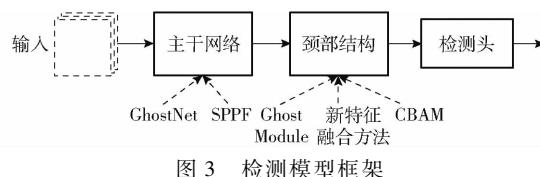


Fig. 3 Framework for detection models

心 Ghost Module 有着对卷积操作进行轻量化的效果。本研究将以 GhostNet 为主干网络，并使用 Ghost Module 对颈部结构做进一步优化。

优秀的深度卷积网络充分收敛后，其信息丰富且冗余的特征图是成功的关键，这些冗余特征应该被提倡产生而不是避免其产生，且以更高效的方式实现，即使用 Ghost Module 实现<sup>[23]</sup>。相比于普通的卷积，Ghost Module 拥有更少的参数和计算量。Ghost Module 将卷积分为 2 步，第 1 步对输入使用  $1 \times 1$ 、个数为输出通道数  $1/2$  的卷积核进行卷积操作，获得特征图。第 2 步对上述特征图进行逐层卷积，相当于对上述特征图进行简单的线性操作以获得冗余特征，最后将冗余特征图与第 1 步的特征图进行通道上的堆叠，作为 Ghost Module 的输出。Ghost Module 的结构如图 4 所示。

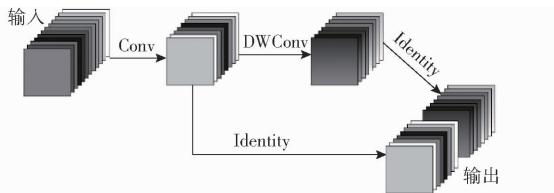


Fig. 4 Structure of Ghost Module

在一般卷积神经网络模型中，传统卷积在无偏置下的参数量  $N_{\text{para}}$  可表示为

$$N_{\text{para}} = C_{\text{In}} k^2 C_{\text{Out}} \quad (1)$$

式中  $C_{\text{In}}$ ——输入通道数

$C_{\text{Out}}$ ——输出通道数

$k$ ——卷积核尺寸

由式(1)可知，Ghost Module 所需参数量  $N_g$  可表示为

$$N_g = C_{\text{In}} \frac{C_{\text{Out}}}{2} + 9 \frac{C_{\text{Out}}}{2} \quad (2)$$

若使用 Ghost Module 代替传统的卷积，则参数量的压缩率可表示为

$$r = \frac{C_{\text{In}} k^2 C_{\text{Out}}}{C_{\text{In}} \frac{C_{\text{Out}}}{2} + 9 \frac{C_{\text{Out}}}{2}} = \frac{2k^2 C_{\text{In}}}{C_{\text{In}} + 9} \approx 2k^2 \quad (3)$$

在卷积神经网络模型中，深层的特征图往往具有很高的通道数，因此在网络模型深层可以认为式(3)中  $C_{\text{In}} + 9 \approx C_{\text{In}}$ ，则压缩率可简单表示为  $r \approx 2k^2$ 。

因此本文以 GhostNet 作为改进 YOLO v4 的主

干网络，以更轻、更快的方式提取更优的特征信息。并使用 Ghost Module 改进模型的颈部结构，进一步轻量化模型，加快模型对荔枝病虫害的检测速度。

### 1.3.2 SPPF

SPPF 模块 (Spatial pyramid pooling-fast) 为 SPP 模块 (Spatial pyramid pooling) 的优化，与 SPP 模块等效但比 SPP 模块更快，可以提取不同尺度的敏感信息，优化多尺度目标的检测效果。

SPP 模块<sup>[27]</sup> 在 YOLO v4 中能一定程度上解决目标多尺度的问题。如图 5a 所示为 SPP 模块的结构图，图中将不同尺度的最大池化分支并行，并 Concat 堆叠通道。SPPF 模块与 SPP 模块等效但更加高效。如图 5b 所示，SPPF 将 3 个同样尺度的最大池化串联，将每一个最大池化的输出进行通道堆叠，2 个  $5 \times 5$  的最大池化串联等效于 1 个  $9 \times 9$  的最大池化，3 个  $5 \times 5$  的最大池化串联等效于 1 个  $13 \times 13$  的最大池化。显然池化尺度越大需要更多的计算成本，将池化进行串联能充分利用每个池化的输出。因此使用 SPPF 模块替换 SPP 模块以提高模型检测速度。

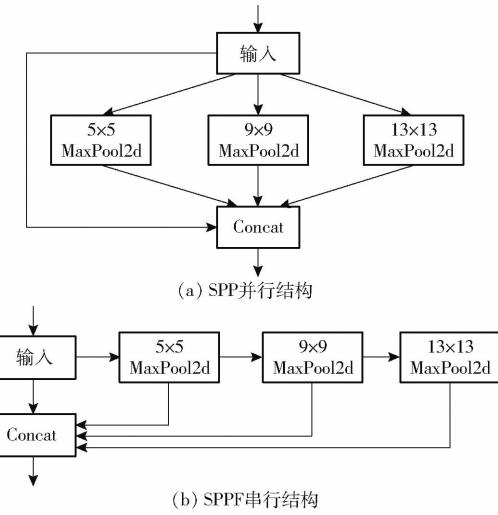


Fig. 5 Structures of SPP and SPPF

### 1.3.3 注意力机制

CBAM (Convolutional block attention module) 利用特征中通道与空间信息的注意力机制，能够使模型关注重要特征，优化模型的检测效果。

CBAM<sup>[28]</sup> 为一种轻量卷积注意力模块，通过注意力机制模仿人类的视觉系统，能够增强网络模型的表征能力，使模型能够更加关注重要特征，抑制复杂背景中不必要的特征。CBAM 利用特征间的通道关系和空间关系先后获得通道注意图和空间注意图，并且将 2 个注意图作用于 CBAM 的输入上，实现特征在通道和空间上的增强，如图 6 所示。

CBAM 极少的参数量和计算成本,使其能够成为即插即用的模块集成到网络模型当中,因此添加该注意力机制,增强模型对复杂背景下荔枝病虫害的检测效果。

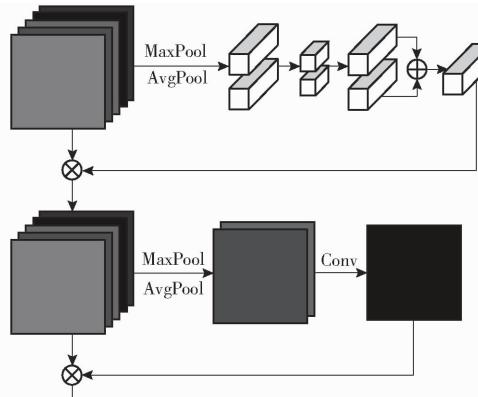


图 6 CBAM 结构图

Fig. 6 Structures of CBAM

### 1.3.4 改进 YOLO v4 的荔枝病虫害检测模型

在自然环境下的荔枝病虫害检测任务中,存在叶片反光等非结构且复杂背景的影响。因此,为实现实时高效且精准的荔枝病虫害检测,以 YOLO v4 为基础模型,使用 GhostNet 作为主干网络,并引入 GhostNet 中低计算成本的 Ghost Module 卷积,以此对 YOLO v4 的颈部结构进行设计,以进一步轻量化模型。同时,将空间金字塔模块 SPP 替换为 SPPF,进一步提高模型的检测速度。此外使用新特征融合方法(Fusion of multi features),将主干网络最后 4 层的输出分别上下采样至与倒数第 3 层输出特征一致的尺寸,并堆叠通道作为颈部结构的输入之一,再添加一支下采样支路堆叠到 FPN 中向上路径的倒数第 2 层中,添加主干网络倒数第 4 层的特征是为了利用其高细粒度和细节信息,提高模型对荔枝病虫害中小目标的检测精度。在颈部结构中,添加了注意力机制 CBAM 进一步提高模型对荔枝病虫害多尺度目标的检测精度。最终,改进的 YOLO v4-GCF 模型结构如图 7 所示。

图 7 中,G-M 表示 Ghost Module 卷积操作,在 ConvSet3 和 ConvSet5 中对卷积核尺寸为  $3 \times 3$  的卷积进行了替换,且 Ghost Module 中前后 2 个卷积,以及 ConvSet3 和 ConvSet5 中每个卷积之后均使用批量归一化和 ReLU6 激活函数。

## 1.4 模型训练与评价指标

### 1.4.1 模型训练环境与参数设置

本文试验所使用的硬件设备配置包括 Inter(R) Xeon(R) Gold 6240 CPU@ 2.59 GHz 处理器,192 GB 运行内存,NVIDIA GeForce GTX 3090Ti \* 2 显卡,24 GB 显存。软件环境为 Windows 10 操作系统,

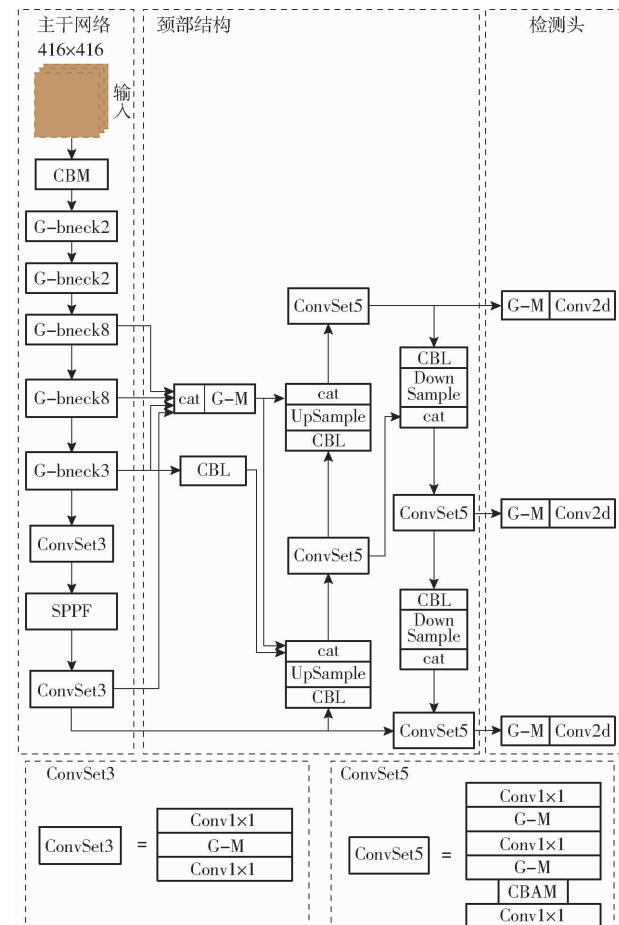


图 7 YOLO v4 - GCF 检测模型和 ConvSet 模块结构图

Fig. 7 Structures of YOLO v4 - GCF detection model and ConvSet module

Pycharm 2021.3.3, Python 3.8.10, CUDA 11.1, CuDNN 8.0.5, 深度学习框架为 Pytorch 1.8.0。

为加速模型训练时的收敛速度,采取迁移学习的方式使用 GhostNet 主干网络的预训练权重对改进 YOLO v4 的模型进行构建。所有输入图像分辨率将被统一缩放至 416 像素  $\times$  416 像素,并以 0.5 的概率使用 Mosaic 数据增强,为保证图像不失真,在后 30% 训练次数中不使用数据增强。训练过程中,初始学习率设置为 0.0001, 使用 Adam 优化器调整学习率,迭代次数为 200, 前 50 次冻结主干网络并将批量大小设置为 64, 后 150 次解冻主干网络并将批量大小设置为 32。对完成训练的模型在测试集进行性能测试时,交并比(IoU)阈值设置为 0.5, 预测结果采用非极大值抑制(Non-maximum suppression, NMS), NMS 的 IoU 阈值同样设置为 0.5。

### 1.4.2 评价指标

以单幅图像检测用时(Detection time per image)作为模型检测速度的评价指标,以平均精度(Average precision, AP)作为模型检测各类别荔枝

病虫害精度的评价指标。其中精度与模型检测时的准确率 (Precision) 和召回率 (Recall) 有关,由某个类别在给定 IoU 阈值下的准确率和召回率所绘制的曲线面积表示。

## 2 结果分析

### 2.1 Ghost Module 使用情况对比

为验证利用 GhostNet 主干网络进行特征提取的有效性,并结合 GhostNet 中以更低计算成本的卷积操作获得特征的方法,利用 Ghost Module 对 YOLO v4 的颈部结构中部分传统卷积进行替换,使模型整体进一步轻量化,加快模型的检测速度。本研究对模型检测的用时验证除了图像在模型中的推理过程用时,还包括图像的预处理以及后处理,以还原真实情况下单幅图像从初始状态下到获得检测结果的实际用时。并在测试集上验证各模型对荔枝病虫害的检测平均精度。以 GhostNet 作为主干网络以及 Ghost Module 使用情况对比结果如表 2 所示。其中 YOLO v4 - G1 为仅使用 GhostNet 主干网络,颈部结构不变的模型;YOLO v4 - G2 为使用 GhostNet 主干网络后,利用 Ghost Module 替换所有  $3 \times 3$  和部分  $1 \times 1$  传统卷积的模型(具体替换情况见图 7);YOLO v4 - G3 为使用 GhostNet 主干网络后,利用 Ghost Module 替换所有传统卷积的模型。

表 2 Ghost Module 使用情况对比结果

Tab. 2 Comparison results of Ghost Module usage

网络模型	平均精度/%		单幅图像 检测用时/s	模型内存占 用量/MB
	训练集	验证集		
YOLO v4	85.63	0.2693	250.349	
YOLO v4 - G1	89.26	0.2010	153.933	
YOLO v4 - G2	88.70	0.1601	36.586	
YOLO v4 - G3	87.58	0.1560	31.788	

由表 2 可知,相比原始 YOLO v4,以 GhostNet 作为主干网络的 YOLO v4 - G1 不仅模型内存占用量缩小约 100 MB,检测速度提升约 25.4%,并且检测平均精度提升 3.63 个百分点。利用 Ghost Module 将颈部结构中的传统卷积进行替换的 YOLO v4 - G2 和 YOLO v4 - G3 分别将模型内存占用量缩小为 36.586 MB 和 31.788 MB,检测速度也进一步提升约 20.4% 和 22.4%。虽然 YOLO v4 - G3 相对更轻更快,但检测平均精度与 YOLO v4 - G1 相比降低 1.68 个百分点,检测精度降幅过大。而 YOLO v4 - G2 的检测精度下降 0.56 个百分点,仍兼具轻和快的优点,更适合用于实时地对荔枝病虫害进行检测。因此本文以 YOLO v4 - G2 (以下简称 YOLO v4 - G) 作为荔枝病虫害检测所需模型,并作进一步改进。

### 2.2 消融试验

为验证所提出改进模型的有效性,在相同平台和参数设置的情况下,分别在训练集、验证集和测试集上进行消融试验,验证各改进模型的检测精度。本研究对 YOLO v4 - G 的改进模型包括添加注意力机制 CBAM 的 YOLO v4 - GC (YOLO v4 - G with CBAM)、使用新特征融合方法的 YOLO v4 - GF (YOLO v4 - G with fusion of multi features),以及同时添加注意力机制和使用新特征融合方法的 YOLO v4 - GCF (YOLO v4 - G with CBAM and fusion of multi features)。消融试验对比结果如表 3 所示。

表 3 消融试验对比结果

Tab. 3 Comparison results of ablation experiments

网络模型	平均精度/%			单幅图 像检测 用时/s	模型内 存占用 量/MB
	训练集	验证集	测试集		
YOLO v4	88.90	87.90	85.63	0.2693	250.349
YOLO v4 - G	94.16	89.26	88.70	0.1601	36.586
YOLO v4 - GC	94.81	90.18	88.60	0.1640	37.393
YOLO v4 - GF	94.81	90.15	89.39	0.1623	38.694
YOLO v4 - GCF	95.31	90.42	89.76	0.1671	39.574

由表 3 可知,与 YOLO v4 - G 相比,YOLO v4 - GC 尽管在测试集中的平均精度没有优异表现,但在保证检测速度和模型内存占用量不作牺牲的情况下,对训练集和验证集的平均精度分别提升 0.65、0.92 个百分点;YOLO v4 - GF 同样在保证一定程度下的检测速度和模型内存占用量,在训练集、验证集和测试集上检测平均精度均获得提升,分别为 0.65、0.89、0.69 个百分点;而 YOLO v4 - GCF 在模型检测速度和模型内存占用量方面仅做微小损失,在训练集、验证集和测试集上对荔枝病虫害的检测平均精度分别提升 1.15、1.16、1.06 个百分点。相比于 YOLO v4 网络模型,最终改进模型 YOLO v4 - GCF 不仅在测试集上的平均精度提升 4.13 个百分点,且检测速度提升约 38% 和模型内存占用量缩小约 84%。

为更直观比较各改进方法对荔枝病虫害的检测效果,在测试集中取不同模型对荔枝病虫害的检测图像进行对比。图 8 为各模型对每类荔枝病虫害的检测效果,图 9 为 YOLO v4、YOLO v4 - G 和 YOLO v4 - GCF 在不同实际场景下对荔枝病虫害的检测效果。

由图 8 可知,YOLO v4 在每类荔枝病虫害中均存在漏检的情况。对于毛毡病,因叶片反光的影响,YOLO v4 - G 和 YOLO v4 - GF 会对毛毡病斑漏检,而 YOLO v4 - GC 和 YOLO v4 - GCF 能更准确检测



图 8 不同模型对每类荔枝病虫害的检测效果

Fig. 8 Detection effect of different models on each kind of litchi diseases and insect pests

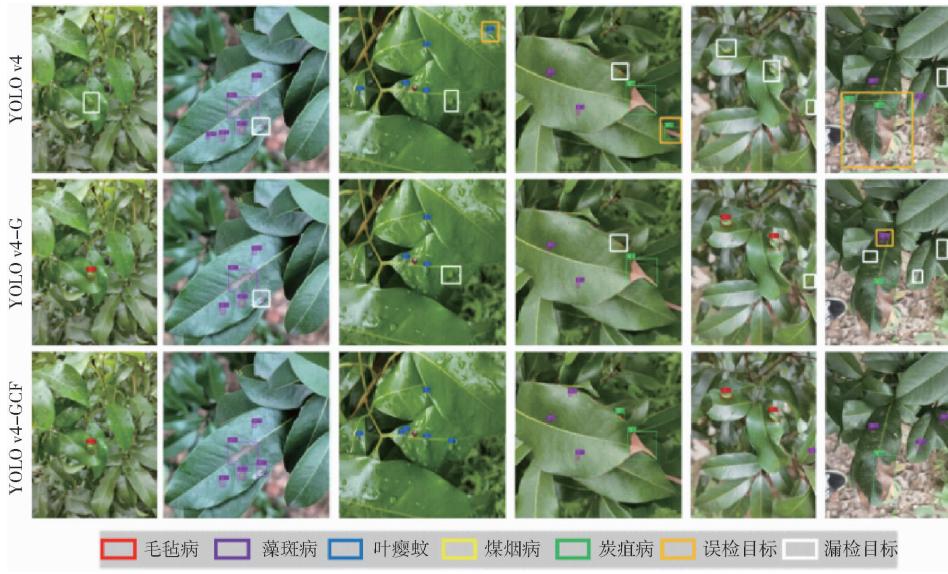


图 9 不同实际场景下不同模型的检测效果

Fig. 9 Detection effect of different models in different actual scenes

出其病斑,证实注意力机制 CBAM 对毛毡病特征检测的有效性。对于藻斑病,YOLO v4-G 存在漏检, YOLO v4-GC 和 YOLO v4-GF 对叶尖的藻斑病斑误检为常表现于叶尖的炭疽病,而 YOLO v4-GCF 能够准确检测出叶尖的藻斑病斑。对于叶瘿蚊和煤烟病,YOLO v4-GC 和 YOLO v4-GF 也出现类似漏检情况,而 YOLO v4-GCF 能够准确检测出叶瘿蚊早期病斑和煤烟病斑。对于炭疽病,YOLO v4-G 存在漏检, YOLO v4-GC、YOLO v4-GF 和 YOLO

v4-GCF 能够准确检测炭疽病斑。以上不同模型对每类荔枝病虫害的检测效果对比均说明新特征融合方法和注意力机制 CBAM 共同作用下的有效性。

由图 9 可知,前 3 列展示了雨后场景下不同模型对毛毡病、藻斑病和叶瘿蚊的检测效果,因叶片上的水易反光,且水珠与叶瘿蚊病斑相似,易对模型的检测造成影响而发生漏检、误检的现象。而 YOLO v4-GCF 能够相对更好地抑制叶片上水的影响,对

第1列中的毛毡病、第2列中水珠覆盖下的藻斑病和第3列中易与水珠混淆的叶瘿蚊检测精准。图9后3列展示了单幅图像中存在不同荔枝病虫害情况下不同模型的检测效果,第4列中YOLO v4将褐色枝干误检为炭疽病且存在漏检,YOLO v4-G未误检但仍存在漏检,YOLO v4-GCF则能够准确检测出图像中的藻斑病和炭疽病。第5列中不仅叶片反光程度大且存在不易注意到的藻斑病小目标,YOLO v4和YOLO v4-G均出现漏检,YOLO v4-GCF则能够准确检测出图像中的毛毡病和藻斑病。第6列YOLO v4和YOLO v4-G均出现漏检且YOLO v4检测区域过大,将大量非病斑区域作为病斑部分检测为炭疽病,YOLO v4-GCF则能够更准确检测出图像中的炭疽病和藻斑病。

### 2.3 不同模型性能对比

为探究其他不同模型对荔枝病虫害的检测性能,以及验证所提出改进网络模型YOLO v4-GCF在复杂且非结构背景下对荔枝病虫害检测的有效性,在相同条件下使用YOLO v4、YOLO v4-tiny、EfficientDet-d2、Faster R-CNN与所提出的YOLO v4-GCF进行比较。不同模型在测试集的检测平均精度等性能结果如表4所示。

表4 不同模型性能对比

Tab. 4 Performance comparison of different models

网络模型	平均精度/%	单幅图像检测用时/s	模型内存占用量/MB
YOLO v4	85.63	0.2693	250.349
YOLO v4-tiny	72.09	0.1748	23.393
EfficientDet-d2	76.98	0.3758	32.019
Faster R-CNN	63.82	0.6841	110.933
YOLO v4-GCF	89.76	0.1671	39.574

由表4可知,相比于其他模型,提出的YOLO v4-GCF检测平均精度比YOLO v4、YOLO v4-tiny、

EfficientDet-d2和Faster R-CNN分别高4.13%、17.67%、12.78%、25.94个百分点。由于在自然环境获取的荔枝病虫害图像背景复杂,以上常用模型难以提取有效特征,检测的平均精度相比本研究提出的YOLO v4-GCF要低得多。

提出的YOLO v4-GCF荔枝病虫害检测模型相比改进前的YOLO v4,模型内存占用量缩小84%,检测速度提升38%,在测试集中检测平均精度提升4.13个百分点,且相较于其他常用检测模型,YOLO v4-GCF在复杂背景荔枝病虫害拥有更高的检测精度和更快的检测速度,更适用于实际场景下的实时检测任务。

### 3 结论

(1)提出了一种基于改进YOLO v4的荔枝病虫害检测模型YOLO v4-GCF,使用轻量化网络GhostNet作为主干网络提取荔枝病虫害特征,并使用Ghost Module替换YOLO v4颈部结构中的传统卷积,提出更轻更快的检测模型YOLO v4-G。在此基础上使用新特征融合方法和注意力机制CBAM对YOLO v4-G模型进行改进,在不失检测速度的情况下提高荔枝病虫害的检测精度,最终提出YOLO v4-GCF模型。

(2)构建了自然环境下复杂、非结构背景的荔枝病虫害数据集,用于进行模型的对比试验,所提出的YOLO v4-GCF模型在训练集、验证集和测试集的检测平均精度分别为95.31%、90.42%和89.76%,单幅图像检测用时0.1671 s,模型内存占用量为39.574 MB,在检测精度和检测速度上优于常用的检测模型,具有较高应用价值,能够为后续自然环境下复杂、非结构背景的农作物病虫害检测研究提供参考。

### 参 考 文 献

- [1] 熊俊涛,刘柏林,钟灼,等.基于深度语义分割网络的荔枝花叶分割与识别[J].农业机械学报,2021,52(6):252-258.  
XIONG Juntao, LIU Bolin, ZHONG Zhuo, et al. Litchi flower and leaf segmentation and recognition based on deep semantic segmentation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(6): 252 - 258. (in Chinese)
- [2] FENG S, HUANG M, CRANE J H, et al. Characterization of key aroma-active compounds in lychee (*Litchi chinensis* Sonn.) [J]. Journal of Food and Drug Analysis, 2018,26(2):497 - 503.
- [3] 易琼,李国良,黄旭,等.配施中微肥对荔枝产量、品质及养分吸收累积的影响[J].果树学报,2022,39(9):1649-1658.  
YI Qiong, LI Guoliang, HUANG Xu, et al. Lychee yield, quality, and nutrients uptake and accumulation as affected by medium and micro-fertilizers[J]. Journal of Fruit Science, 2022,39(9):1649 - 1658. (in Chinese)
- [4] 陈厚彬,苏钻贤,杨胜男.2022年全国荔枝生产形势分析[J].中国热带农业,2022(3):5-14.  
CHEN Houbin, SU Zuanxian, YANG Shengnan. Analysis on the litchi production situation in 2022 [J]. China Tropical Agriculture, 2022(3): 5 - 14. (in Chinese)
- [5] 王松,谢银燕,张成彬,等.荔枝病虫害及其防治研究进展[J].江苏农业科学,2019,47(17):120-124.  
WANG Song, XIE Yinyan, ZHANG Chengbin, et al. Research progress on prevention and control of litchi chinensis pests and diseases[J]. Jiangsu Agricultural Sciences, 2019, 47(17): 120 - 124. (in Chinese)
- [6] 陈炳旭,董易之,李文景,等.荔枝主要害虫防治技术研究进展与综合治理体系构建[J].广东农业科学,2020,

- 47(11):103–113.
- CHEN Bingxu, DONG Yizhi, LI Wenjing, et al. Research progress in control technique of main litchi pests and construction of IPM system[J]. Guangdong Agricultural Sciences, 2020, 47(11): 103–113. (in Chinese)
- [7] 兰玉彬, 王天伟, 陈盛德, 等. 农业人工智能技术:现代农业科技的翅膀[J]. 华南农业大学学报, 2020, 41(6):1–13. LAN Yubin, WANG Tianwei, CHEN Shengde, et al. Agricultural artificial intelligence technology: wings of modern agricultural science and technology[J]. Journal of South China Agricultural University, 2020, 41(6): 1–13. (in Chinese)
- [8] 余小东, 杨孟辑, 张海清, 等. 基于迁移学习的农作物病虫害检测方法研究与应用[J]. 农业机械学报, 2020, 51(10): 252–258.
- YU Xiaodong, YANG Mengji, ZHANG Haiqing, et al. Research and application of crop diseases detection method based on transfer learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(10): 252–258. (in Chinese)
- [9] AGARWAL M, GUPTA S K, BISWAS K K. Development of efficient CNN model for tomato crop disease identification[J]. Sustainable Computing: Informatics and Systems, 2020, 28:100407.
- [10] ZHANG Y, LIU Y P, HASSAN A S. Identification of navel orange diseases and pests based on the fusion of DenseNet and self-attention mechanism[J]. Computational Intelligence and Neuroscience, 2021, 2021:5436729.
- [11] 李书琴, 陈聪, 朱彤, 等. 基于轻量级残差网络的植物叶片病害识别[J]. 农业机械学报, 2022, 53(3):243–250. LI Shuqin, CHEN Cong, ZHU Tong, et al. Plant leaf disease identification based on lightweight residual network [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(3): 243–250. (in Chinese)
- [12] 刘晓锋, 高丽梅. 基于改进空间残差收缩网络模型的农作物病虫害识别[J]. 山东农业大学学报(自然科学版), 2022, 53(2):259–264.
- LIU Xiaofeng, GAO Limei. The recognition for crop pests and diseases based on the improved residual shrinkage network[J]. Journal of Shandong Agricultural University (Natural Science Edition), 2022, 53(2): 259–264. (in Chinese)
- [13] 边柯橙, 杨海军, 路永华. 深度学习在农业病虫害检测识别中的应用综述[J]. 软件导刊, 2021, 20(3):26–33. BIAN Kecheng, YANG Haijun, LU Yonghua. Application review of deep learning in detection and identification of agricultural pests and diseases[J]. Software Guide, 2021, 20(3): 26–33. (in Chinese)
- [14] 康飞龙, 李佳, 刘涛, 等. 多类农作物病虫害的图像识别应用技术研究综述[J]. 江苏农业科学, 2020, 48(22):22–27. KANG Feilong, LI Jia, LIU Tao, et al. Application technology of image recognition for various crop diseases and insect pests: a review[J]. Jiangsu Agricultural Sciences, 2020, 48(22): 22–27. (in Chinese)
- [15] 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)
- [16] YUE T, JIE Z, DONG S, et al. MSR – RCNN: a multi-class crop pest detection network based on a multi-scale super-resolution feature enhancement module[J]. Frontiers in Plant Science, 2022, 13:810542.
- [17] 李子茂, 刘恋冬, 夏梦, 等. 基于深度学习的月季多叶片病虫害检测研究[J]. 中国农机化学报, 2021, 42(8):169–176. LI Zimao, LIU Liandong, XIA Meng, et al. Detection of rose diseases and insect pests based on deep learning[J]. Journal of Chinese Agricultural Mechanization, 2021, 42(8): 169–176. (in Chinese)
- [18] 李就好, 林乐坚, 田凯, 等. 改进 Faster R – CNN 的田间苦瓜叶部病害检测[J]. 农业工程学报, 2020, 36(12):179–185. LI Jiuhalo, LIN Lejian, TIAN Kai, et al. Detection of leaf diseases of balsam pear in the field based on improved Faster R – CNN[J]. Transactions of the CSAE, 2020, 36(12): 179–185. (in Chinese)
- [19] LI D, AHMED F, WU N, et al. YOLO – JD: a deep learning network for jute diseases and pests detection from images[J]. Plants, 2022, 11(7):937.
- [20] LYU Z, JIN H, ZHEN T, et al. Small object recognition algorithm of grain pests based on SSD feature fusion[J]. IEEE ACCESS, 2021, 9:43202–43213.
- [21] 陈科圻, 朱志亮, 邓小明, 等. 多尺度目标检测的深度学习研究综述[J]. 软件学报, 2021, 32(4):1201–1227. CHEN Keqi, ZHU Zhiliang, DENG Xiaoming, et al. Deep learning for multi-scale object detection: a survey[J]. Journal of Software, 2021, 32(4): 1201–1227. (in Chinese)
- [22] BOCHKOVSKIY A, WANG C, LIAO H M. YOLO v4: optimal speed and accuracy of object detection[J]. arXiv preprint arXiv:2004.10934, 2020.
- [23] HAN K, WANG Y, TIAN Q, et al. GhostNet: more features from cheap operations[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020:1580–1589.
- [24] WANG C, LIAO H M, WU Y, et al. CSPNet: a new backbone that can enhance learning capability of CNN[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020:390–391.
- [25] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu:IEEE, 2017:2117–2125.
- [26] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018:8759–8768.
- [27] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9):1904–1916.
- [28] WOO S, PARK J, LEE J, et al. CBAM: convolutional block attention module[C]// Proceedings of the European Conference on Computer Vision (ECCV), 2018:3–19.