

王 博,胡蓉华. 基于轻量化神经网络的桃树叶片病害检测方法[J]. 江苏农业科学,2025,53(5):138-146.

doi:10.15889/j.issn.1002-1302.2025.05.017

基于轻量化神经网络的桃树叶片病害检测方法

王 博,胡蓉华

(长江大学计算机科学学院,湖北荆州 434023)

摘要:针对当前桃树叶片病害检测存在精度低、漏检和误检的问题,以及将网络部署到移动端后由于参数量和计算量过大而导致检测速度慢的问题,提出以 YOLO v5 网络为基础的一系列改进方法。首先,使用 EIoU 边界框回归损失函数加快预测框收敛过程,使得模型训练和推理过程更加高效;然后,引入 SimAM 注意力机制,在不增加额外的参数量和计算量的基础上提升网络检测精度;最后,引入 GhostNet 网络,该网络的核心 Ghost 模块将原始卷积层分成 2 个部分,然后使用较少的卷积核生成内在特征映射,继而通过廉价的线性运算生成 Ghost 特征图,这一设计在保证整体网络精度的情况下,明显降低网络的参数量、计算量和权重大小。结果表明,改进后的 YOLO v5s 网络的所有评价指标远优于 YOLO v3、YOLO v4、YOLOX、CenterNet 等网络,相较于基准 YOLO v5s,平均检测精度提升了 3.6 百分点,达到了 94.8%,参数量下降了 47.6%,GFLOPs 减少了 49.4%,权重压缩了 45.5%,检测速度达到 96 帧/s。综上,改进后的 YOLO v5s 网络检测精度更高,且整体的参数量、计算量以及模型权重更小,更适应移动端和物联网设备的实时检测需求。

关键词:轻量化检测模型;桃树叶病害检测;Ghost;SimAM 注意力机制;轻量化神经网络;YOLO v5

中图分类号:S126;TP391.41 **文献标志码:**A **文章编号:**1002-1302(2025)05-0138-09

根据联合国商品贸易统计数据库 (UN Comtrade) 数据,对 2011—2020 年的主要国家和地

区鲜食桃进出口情况进行分析,发现我国生产了全球 50% 以上的桃,产量排名世界第一^[1]。然而桃树在生长过程中,容易受到天气、环境和微生物等的影响而遭受各种病害,严重影响桃树生长和桃子产量。桃树病害特点主要发生在叶片,种类多、相似度高。识别其病害需要大量的农业知识和经验,或者由专业的植保技术人员来判断。如果由桃农凭肉眼来判断其病害类型,耗时长且正确率低。

收稿日期:2024-01-14

基金项目:国家自然科学基金(编号:62006028);湖北省自然科学基金(编号:2023AFB909)。

作者简介:王 博(1996—),男,四川南充人,硕士,主要从事深度学习与区块链研究。E-mail:2021710548@yangtzeu.edu.cn。

通信作者:胡蓉华,博士,讲师,主要从事信息安全与深度学习研究。E-mail:hrh2016@yangtzeu.edu.cn。

[20] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [C]//IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016:770-778.

[21] Liu Z, Lin Y T, Cao Y, et al. Swin transformer: hierarchical vision transformer using shifted windows [C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV), 2021:10012-10022.

[22] Jing L L, Tian Y L. Self-supervised visual feature learning with deep neural networks: a survey [J]. IEEE transactions on pattern analysis and machine intelligence, 2020, 43(11):4037-4058.

[23] 张宸嘉,朱 磊,俞 璐. 卷积神经网络中的注意力机制综述 [J]. 计算机工程与应用, 2021, 57(20):64-72.

[24] Guo W J, Feng Q, Li X Z, et al. Grape leaf disease detection based on attention mechanisms [J]. International Journal of Agricultural and Biological Engineering, 2022, 15(5):205-212.

[25] Wang Y Y, Tao J, Gao H T. Corn disease recognition based on

attention mechanism network [J]. Axioms, 2022, 11(9):480.

[26] Zhang M, Su H H, Wen J H. Classification of flower image based on attention mechanism and multi-loss attention network [J]. Computer Communications, 2021, 179(1):307-317.

[27] Qian Z Z, Mu J, Tian F, et al. Facial expression recognition based on strong attention mechanism and residual network [J]. Multimedia Tools and Applications, 2022, 81(30):44109-44121.

[28] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module [C]//Ferrari V, Hebert M, Sminchisescu C. Proceeding of the European Conference on Computer Vision (ECCV), 2018:3-19.

[29] Xu B, Wang N Y, Chen T Q, et al. Empirical evaluation of rectified activations in convolutional network [J]. ArXiv, 2015, 27:1-5.

[30] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection [C]//Proceedings of the 2017 IEEE International Conference on Computer Vision. 2017:2999-3007.

在桃树叶片病害检测上,使用光谱^[2]和成像技术设备^[3]来检测已经有成熟的应用,但由于设备的购买成本、使用门槛和维护成本过高,对于中小型农场的农户来说,并不是最优选择。

近年来,随着深度学习的发展,凭借其学习能力强、使用范围广、适配性好、性能上限高、可移植性好等优点^[4],已经在植物病害检测中使用广泛^[5-6]。其检测方法包括基于二阶段检测和一阶段检测 2 种。其中,二阶段方法是将检测任务拆成先定位后识别的任务,先用特征提取器生成一系列包含待检物体的预选框,然后使用筛选规则对预选框进行筛选,再在预选框上面进行检测,代表算法有 Faster-RCNN^[7]、Mask R-CNN 等。而一阶段方法会直接在网络中提取特征来预测物体分类和位置,代表算法有 YOLO 系列、CenterNet^[8]等。总的来说,二阶段检测在准确率上表现更好,而一阶段检测在速度上更快。

王金星等针对果园环境下识别苹果园害虫易受背景干扰、重要特征表达能力不强的问题,使用改进的 Mask R-CNN 网络实现了棉铃虫、黏虫和桃蛀螟害虫的识别,其模型平均识别精度为 96.52%,达到了精准且有效的识别效果^[9]。杨红云等使用卷积神经网络模型,结合批量归一化和 AlexNet 网络对水稻病害进行识别分析,在背景简单数据集下,实现了多种水稻病害的自动识别,达到了 99.1% 的高准确率^[10]。贾璐等构建了一个由农民在实际农业生产中拍摄自然复杂环境下的葡萄病害数据集,并基于注意力机制和特征融合提出了一个新的网络模型 MANet,模型的参数数量和浮点运算量较小,并且对葡萄叶片病害具有更高的识别准确率,平均识别准确率为 87.93%^[11]。Qi 等使用一种改进的 SE-YOLO v5 网络模型,与 SE 模块相结合,通过重组其主干结构,可以有效地提取检测目标的关键特征,在由手机收集的温室中,番茄病害图像数据集中实现了 94.10% 的平均识别准确率^[12]。在轻量化上,曹跃腾等提出一种基于改进 ResNet 模型的轻量化植物叶片病虫害识别算法 Simplify-ResNet,该模型在人工采集图像和 PlantVillage 数据集上的识别准确率为 92.45%,识别时间为 48 ms,内存大小为 36.14 MB,有效地降低了模型大小和权重^[13]。

以上的模型网络通常为提升模型检测精度,在改进方法上都使用了增加参数数量和计算量的策略,

虽然达到了提升精度的效果,但大模型并不适合移动端部署。在轻量化模型中,为追求轻量化,模型的参数量和计算量会变少,但是会损失过多的精度。针对此类问题,本研究提出了一种改进 YOLO v5s 的轻量化桃树叶片病害检测方法。首先,使用目标定位性能更好的 EIoU 边框损失函数代替默认的 CIoU 损失函数;其次,使用 SimAM 注意力机制提高网络整体的检测精度;最后,在主干网络部分采用了轻量级 GhostNet 模块,使模型的参数量和计算量大幅下降,更适配移动端和物联网设备。

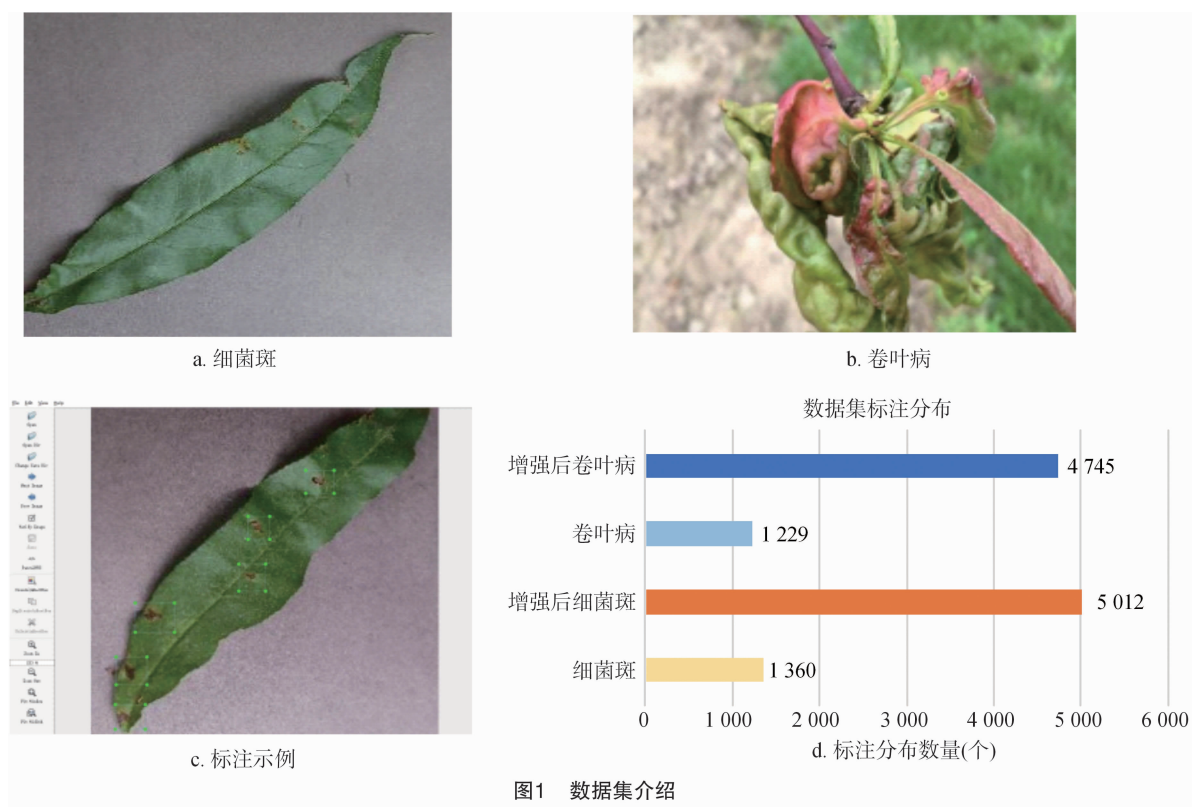
1 材料与方法

1.1 数据集与处理

本试验所用的数据集是自建数据集,一部分来自开源数据集 PlantVillage 的桃树叶病害细菌斑病(bacterial spot),其余部分是由爬虫程序获取、Google Dataset 中筛选而得来。因网上爬取的病害图片大小和格式不一致,需要对其进行裁剪编辑,编辑后的图片格式为 jpg,大小为 640 像素×640 像素。整个数据集有 1 392 张图片、2 589 个标注,其中包含 2 种病害,分别是细菌斑和卷叶病(leaf curl)。为防止模型因为数据集过少造成网络过拟合,使用水平翻转、垂直翻转、等比例缩放、随机亮度、随机平移进行随机组合和数据增强生成图片与标注,数据集的总量达到了 2 784 张图片,标注数量 9 759 个。使用 labeling 作为标注软件,对数据采用最大外接矩形框标注,将显著特征都包括进去,标注格式为 voc 格式。数据集实例、标注示例,标注分布如图 1 所示。试验过程中将数据集按照 8:1:1 的比例随机划分训练集、验证集和测试集。

1.2 YOLO v5s 模型

YOLO 系列网络的基本思想是将输入的特征图经过增强后,将特征图划分为 $S \times S$ 的格子(grid cells),每个格子负责对落入其中的目标进行检测,一次性预测所有含目标的边界框、定位置信度以及所有类别概率向量。相较于二阶段的目标检测方法,在保证精确度的情况下更加简捷快速。YOLO v5 目前是 YOLO 系列第 5 个更新版本,且是使用较为广泛的一个网络,根据不同使用场景及需求有 YOLO v5m、YOLO v5l、YOLO v5s 等版本。本研究选择了网络宽度小、深度低、体积小及实时性较好的 YOLO v5s 版本。YOLO v5s 网络结构大致可分为 4 个部分,包括输入端(Input)、网络主干(Backbone)、颈部



网络 (Neck)、检测头 (Head)。其中输入端负责 Mosaic 数据增强,自适应锚框计算,自适应图片缩放等数据预处理功能。Backbone 主要负责图像卷积后的特征提取、转换等工作。Neck 主要负责将上采样以及多尺度特征融合后的图像特征传入 Head,用来完成图像预测。具体的整体结构及其子结构如图 2 所示。

1.3 YOLO v5s 的改进

1.3.1 EIou 边框损失函数 边界框回归是决定目标定位性能的关键步骤,也是在目标检测领域中衡量网络性能的重要参考之一。其主要的思想就是计算预测框与真实框的交并比值 (IoU),IoU 值越大说明检测效果越好。然而,IoU 仅考虑预测框与真实框的重叠面积,没有考虑两者的位置与尺度信息,导致网络检测效果较差。并且无法处理特殊情况——当 2 个框不相交时,IoU 的值为 0,loss 也为 0,使得梯度无法回传,网络无法训练。为此引入了 EIou^[14] 替换 YOLO v5s 使用的 CIou^[15],它不仅考虑了边界框回归的重叠面积、中心点距离、纵横比,还将纵横比拆开分别计算,一定程度上解决了此前的 CIou 的缺点。CIou 与 EIou 的具体计算公式见公式(1)和公式(2)。

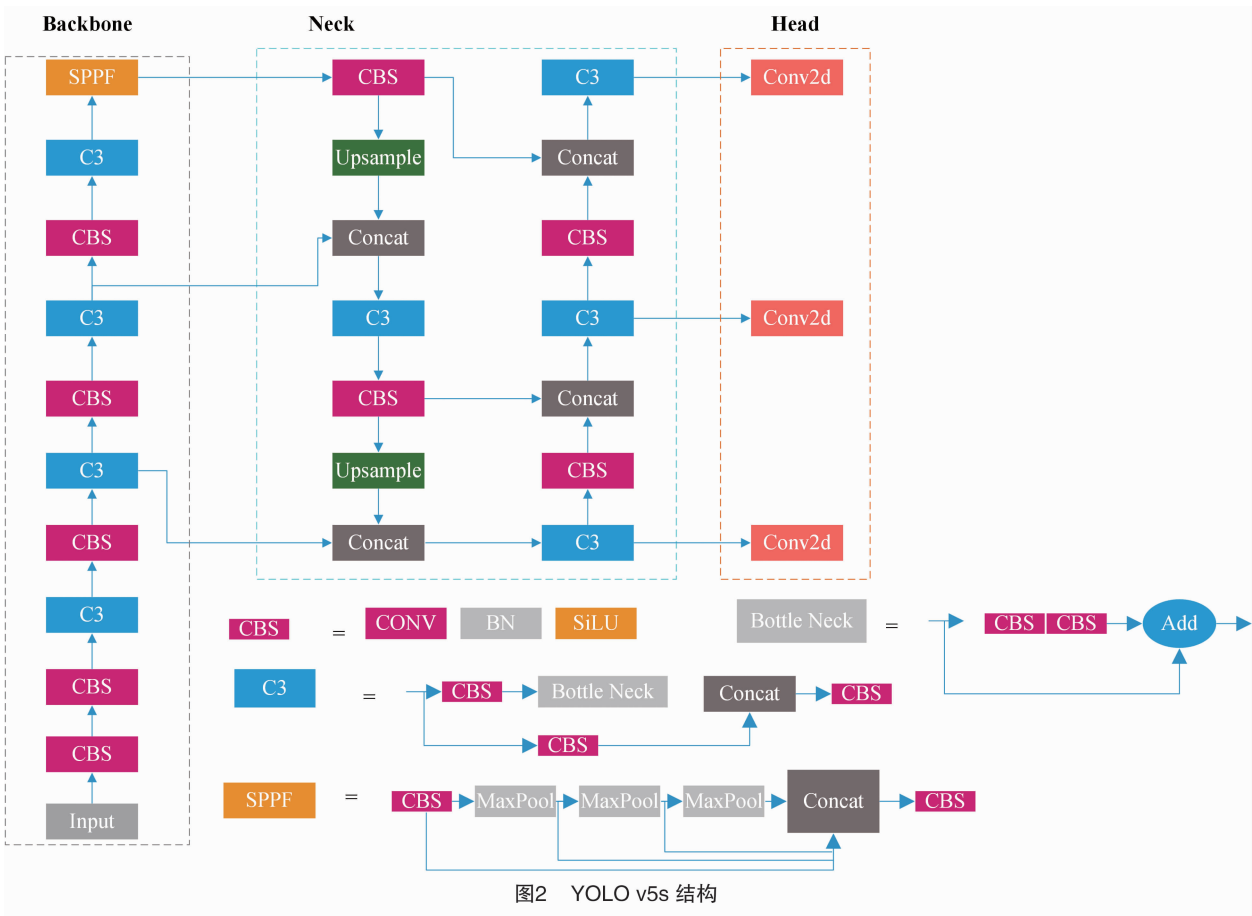
$$L_{\text{CIoU}} = 1 - \text{IoU} + \frac{\rho^2(b, b^{\text{gt}})}{c^2} + \alpha v; \quad (1)$$

$$L_{\text{EIou}} = L_{\text{IoU}} + L_{\text{dis}} + L_{\text{asp}} = 1 - \text{IoU} + \frac{\rho^2(b, b^{\text{gt}})}{c^2} + \frac{\rho^2(w, w^{\text{gt}})}{C_w^2} + \frac{\rho^2(h, h^{\text{gt}})}{C_h^2}。 \quad (2)$$

式中: α 表示权重函数; v 表示用来度量纵横比的相似性;公式(2)中边框损失函数包含 3 个部分,分别为重叠损失 (L_{IoU})、中心距离损失 (L_{dis})、宽高损失 (L_{asp}); $b^{\text{gt}}, w^{\text{gt}}, h^{\text{gt}}$ 和 b, w, h 分别是真实框和预测框的中心点坐标、边宽、边长; c, C_w, C_h 分别表示真实框和预测框最小外接矩形的对角线、边宽、边长。

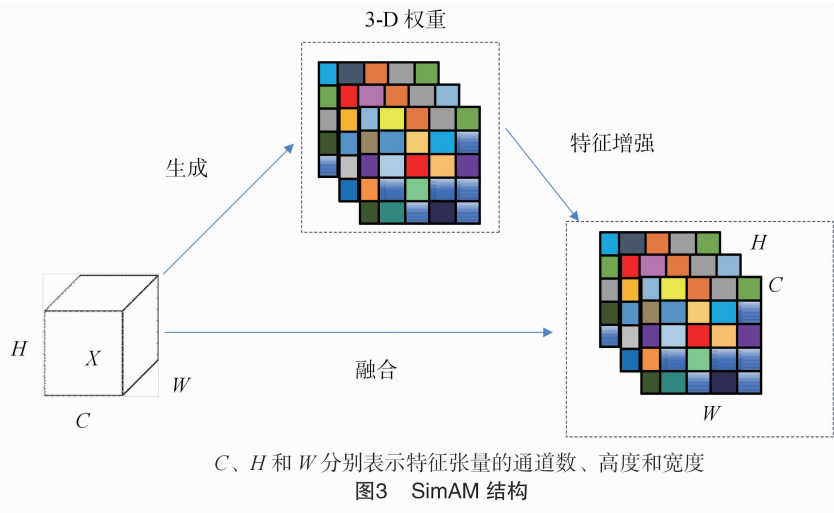
公式(1)中反映的纵横比的差异,而不是宽、高分别与其置信度的真实差异,所以有时会阻碍模型有效优化相似性。而 EIou 在 CIou 的惩罚项基础上将纵横比的影响因子拆开分别计算目标框和锚框的长和宽,有效提高了收敛速度和定位精度。

1.3.2 SimAM 注意力机制 人类的注意力是最重要的选择机制之一,通过优先考虑与任务相关的特征,同时减弱不相关的信息,在有限的资源条件下,达到利用效率最大化。根据上述理念,注意力机制在目标视觉中已经应用广泛^[16]。



SimAM 注意力机制是一种通过 Energy 函数计算权重,提高了计算速度并且不产生额外参数的 3D 注意力模块^[17]。相较于通道注意力,空间注意力具有更轻量 and 实现简单的优势。具体来说是在网

络中神经元最简单的实现方法,就是测量一个目标神经元和其他神经元之间的线性可分性。其原理如图 3 所示,Energy 函数见公式(3)。



$$\tilde{X} = \text{sigmoid}\left(\frac{1}{E}\right) \odot X. \quad (3)$$

式中: \tilde{X} 表示输出后结果特征, E 表示每个通道的能量函数; \odot 为点积运算, X 为输入特征集;sigmoid 函

数限制整个公式的值在合理区间。其中最小能量函数表达式见公式(4)。

$$e_i^* = \frac{4(\hat{\sigma}^2 + \lambda)}{(t - \hat{\mu})^2 + 2\hat{\sigma}^2 + 2\lambda}. \quad (4)$$

式中: t 表示神经元, 且 $t \in \mathbf{X}$; λ 为正则化系数, 且值为 0.000 1 时取得较好的性能, 能量函数越小表示神经元与周围神经元越不同, 即表示在视觉处理过程中更重要。 x_i 是输入特征集 \mathbf{X} 的单个通道中的其他神经元, i 是空间维度上的索引, M 是该通道上的神经元数量。 μ 是平均前的某个通道的值, $\hat{\mu}$ 和 $\hat{\sigma}^2$ 是除 t 以外的所有神经元的平均值和方差, 具体见公式(5)。

$$\begin{cases} \hat{\mu} = \frac{1}{M} \sum_{i=1}^M x_i \\ \hat{\sigma}^2 = \frac{1}{M} \sum_{i=1}^M (x_i - \hat{\mu})^2 \end{cases} \quad (5)$$




图4 GhostNet 过程示意

由图 4 可知, ϕ 代表线性计算, 规定 h 和 w 分别为输入特征图的高和宽, 输入特征通道为 c , 输出特征图的通道数为 n 。给定输入 $h \times w \times c$ 经过 $k \times k$ 卷积核, 线性运算核为 $d \times d$, 运算次数为 s 且远远小于 c 。使用 Ghost module 模块升级普通卷积的理论加速比为公式(6)。

$$r_s = \frac{n \cdot h' \cdot w' \cdot c \cdot k \cdot k}{\frac{n}{s} \cdot h' \cdot w' \cdot c \cdot k \cdot k + (s-1) \cdot \frac{n}{s} \cdot h' \cdot w' \cdot d \cdot d} \approx \frac{s \cdot c}{s+c-1} \approx s_0 \quad (6)$$

式中: h' 和 w' 分别表示输出特征图的高和宽。当 d 与 k 相似时, 可简化为公式(7)。

$$r_s = \frac{n \cdot c \cdot k \cdot k}{\frac{n}{s} \cdot c \cdot k \cdot k + (s-1) \cdot \frac{n}{s} \cdot d \cdot d} \approx \frac{s \cdot c}{s+c-1} \approx s_0 \quad (7)$$

由公式(6)、公式(7)可知, 与卷积计算相比, 通过线性运算提取与计算特征, 计算量更小。在本网络中, 除去保留必要的卷积核外, 全部使用线性运算代替卷积核运算。这样能大幅减少生成特征图的计算特征的时间, 从而实现网络的轻量化。

利用 GhostNet module 的优势设计了小型神经网络 G-bneck (Ghost-bottleneck), 根据步长的不

在本研究中, SimAM 注意力机制凭借着其实现简单, 添加后在 YOLO v5s 网络中不会产生额外计算量, 为提升整体网络精度提供了理论支撑。

1.3.3 GhostNet 目前, 深度卷积神经网络通常由大量卷积组成, 在计算和生成特征时会产生大量冗余, 这会导致巨大的计算成本^[18], GhostNet 的出现降低了深度神经网络的计算成本^[19]。其原理是通过 Ghost 模块将生成特征图分为 2 步, 首先使用普通卷积生成一些内在特征图, 然后利用廉价的线性运算生成另一部分特征图, 最终通过拼接操作将这 2 个部分的特征进行融合, 过程如图 4 所示^[19]。

同分为 2 种, 步长 (Stride) 为 1 时充当了一个扩展层, 增加了通道的数量。步长为 2 时减少通道数量, 以匹配快捷路径。相同的是 2 个 Ghost modules 模块的输入和输出之间都使用了快捷的连接方式。具体设计如图 5 所示^[19]。

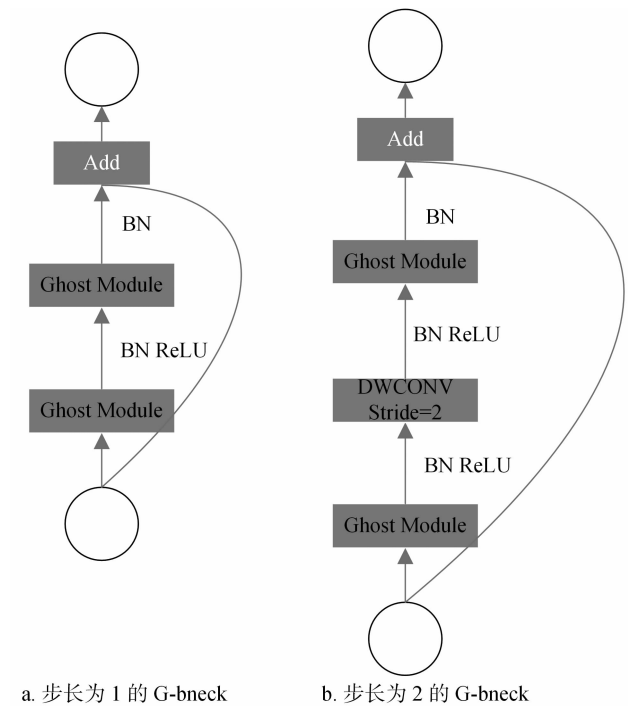


图5 G-bneck 结构图

最终改进后的 YOLO v5s 的结构如图 6 所示,其中子结构在图 2 中已解释,此处省略。

由图 6 可知,改进后的 YOLO v5s 使用

GhostConv 和 C3Ghost 替换了原有的 C3 和 Conv 结构,减少了计算量和参数量,并在颈部网络和预测头之间添加了 SimAM 注意力机制,提升了精确度。

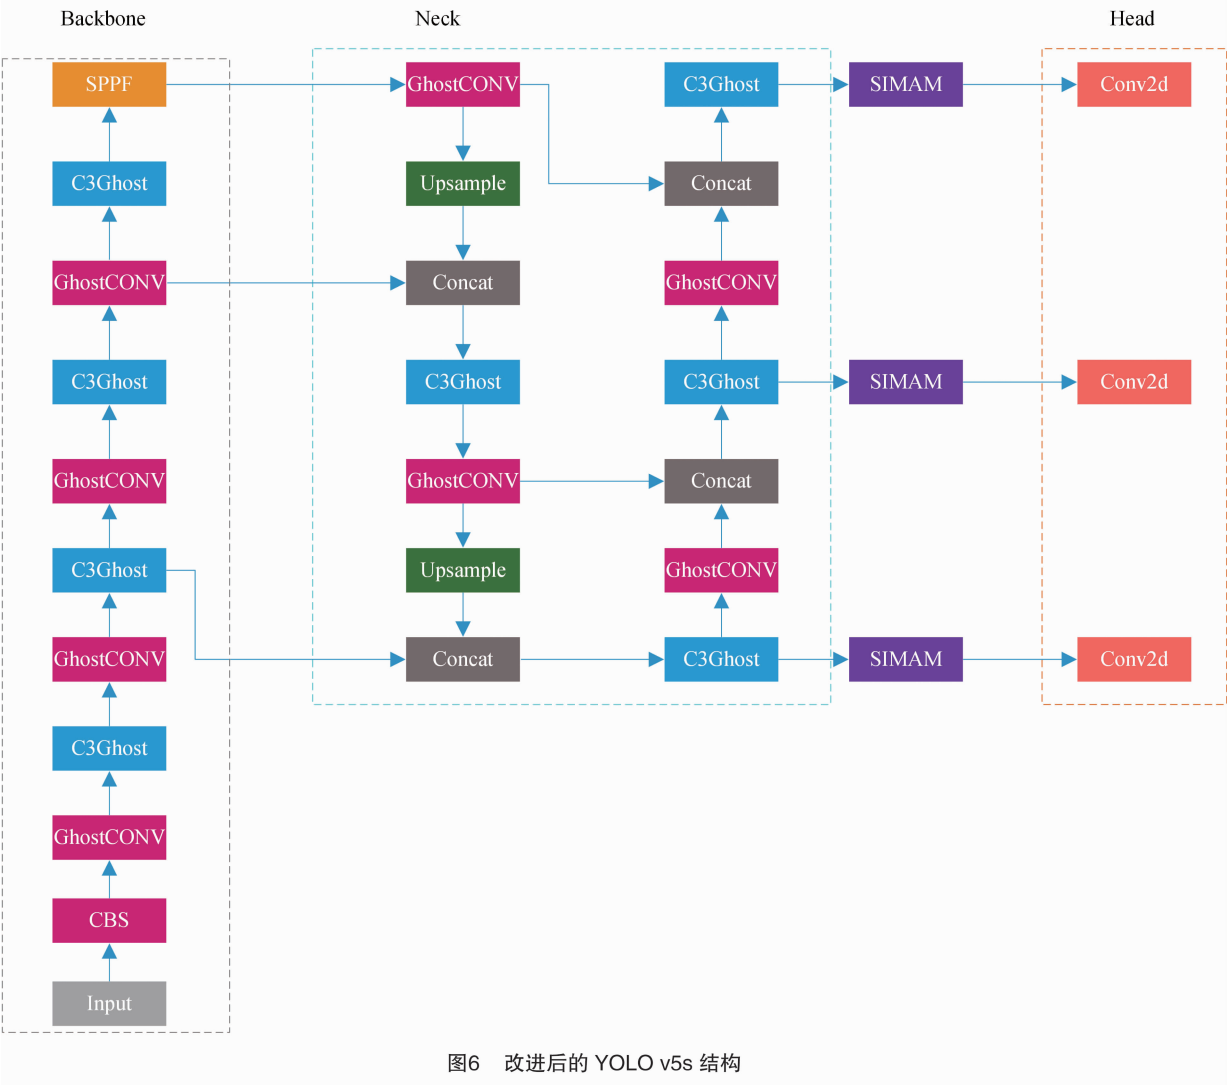


图6 改进后的 YOLO v5s 结构

1.4 试验环境与评价标准

本试验所使用的硬件配置为 Intel® Xeon® Platinum 8255C 处理器、40 GB 内存, GeForce RTX 2080 Ti(11GB)显卡。软件配置为 Ubuntu 20.04 操

作系统、Python 3.8、Pytorch 11.7, Cuda 11.0。试验时间为 2023 年 2—6 月,试验地点为长江大学计算机科学学院,关键参数如表 1 所示。

表 1 试验关键参数设置

参数名称	初始值	参数名称	初始值
图像大小	640 像素 × 640 像素	IoU 训练时的阈值	0.5
初始学习率	0.01	迭代轮次(次)	300
优化函数	SGD	Batch - size	32
学习率动量	0.937	工作线程	8
权重衰减系数	0.000 5	Mosaic 概率	1.0

为验证所提出网络的检测性能和速度,探究各个改进方法的有效性,通过对比基准 YOLO v5s 和

改进方法的检测图像差异来评估模型性能。采用目标检测领域常见的精准率(Precision, P)、召回率

($Recall, R$)、平均精度均值@0.5 ($mAP@0.5$)、参数量、每秒钟检测图像的帧数 (FPS) 和代表网络计算代价——10 亿次浮点运算量 (GFLOPs) 作为评价指标。具体计算如公式(8)至公式(11)所示。

$$P = \frac{TP}{TP + FP} \times 100\% ; \quad (8)$$

$$R = \frac{TP}{TP + FN} \times 100\% ; \quad (9)$$

$$P_{ap} = \int_0^1 P(R) dR ; \quad (10)$$

$$P_{map} = \frac{\sum P_{ap}}{n} 。 \quad (11)$$

2 结果与分析

2.1 对比试验

设置基准 YOLO v5s 为默认参数,对改进后的 YOLO v5s 与基准 YOLO v5s 进行训练总损失与平均精度值对比,试验对比结果如图 7、图 8 所示。

训练过程中损失值的迭代过程越趋近于 0 表示模型训练的训练效果越好。从图 7-a 不难看出,改进后的 YOLO v5s 网络相较于基准 YOLO v5s 训练效果更好,最小值达到了 0.051 5。




图7 损失值与 mAP 值对比




图8 混淆矩阵对比

在图 7-b 中,轻量化改进后 YOLO v5s 在 300 轮迭代中,在 130 轮之后 $mAP@0.5$ 开始超过基准 YOLO v5s,在精度上也证明了改进措施的优越性。

为更好地分析改进后网络的分类性能,使用混淆矩阵进行分析,试验结果如图 8 所示。

从图 8-a 可以看出,基准 YOLO v5s 细菌斑病和卷叶病预测类别概率为 87% 和 92%;预测为背景的概率分别为 13%、8%。从图 8-b 可以看出,改进后的网络细菌斑病和卷叶病预测类别概率分别

为 90% 和 96%,预测为背景的概率分别为 10%、4%。证明了改进后的网络分类性能更优。

为证明所提出网络在检测精度和轻量化上的优越性,将改进后网络与 YOLO v3^[20]、YOLO v4^[21]、YOLOX^[22]、CenterNet 等热门网络进行对比,试验条件都是默认参数设置,试验结果如表 2 所示。

从表 2 可以看出,所提出改进后的方法在各个指标上都优于对比网络, $mAP@0.5$ 最高值达到了 94.80%,较 YOLO v5s 提升了 3.6 百分点,参数量最

表 2 不同网络试验结果对比

网络名称	参数量 (M)	$mAP@0.5$ (%)	精准率 (%)	召回率 (%)	GFLOPs (G)	FPS (帧/s)	权重 (MB)
CenterNet	32.67	70.95	91.31	25.43	70.22	68	124.0
YOLO v3	61.50	90.40	92.20	86.50	154.60	43	123.4
YOLO v4	24.34	84.10	88.20	78.60	53.00	71	49.0
YOLO v5s	7.02	91.20	95.00	87.40	15.80	84	14.5
YOLOX	54.21	71.10	82.70	60.19	156.01	67	34.3
本研究网络	3.68	94.80	95.40	90.90	8.00	96	7.9

小,仅为 3.68 M,减少了 3.34 M,计算量也减少了 7.8 G,FPS 最高(检测速度最快),权重最小。

2.2 消融试验

为验证本研究所提出各项改进的有效性,设置 YOLO v5s 默认参数,每次只增加一个改进点在自建数据集进行了消融试验,试验结果如表 3 所示。

从表 3 可以看出,引入了 EIoU 边框损失函数

后, $mAP@0.5$ 值提升了 0.8 百分点,而 SimAM 注意力明显提升了平均精度值,达到了 95.3%,并且没有带来额外的参数量、计算量和模型权重。在 YOLO v5s 的主干中引入 Ghost 模块后,网络的权重、参数量和计算量近乎减少了一半,而代价仅仅是损失了 0.5% 的 mAP 。证明了所提出的每个改进都是有效的。

表 3 消融试验结果表

名称	EIoU	SimAM	Ghost	精准率 (%)	召回率 (%)	$mAP@0.5$ (%)	GFLOPs (G)	权重 (MB)	参数量 (M)
Base_net	×	×	×	95.0	87.4	91.2	15.8	14.5	7.02
EIoU	√	×	×	94.2	88.4	92.0	15.8	14.5	7.02
SimAM	√	√	×	94.9	92.6	95.3	15.8	14.5	7.02
Ghost	√	√	√	95.4	90.9	94.8	8.0	7.9	3.68

2.3 检测效果对比

为验证实际检测效果,随机选取了测试集中的 2 张图片,细菌斑、卷叶病各 1 张。使用基准 YOLO v5s 和改进后 YOLO v5s 以及训练后的对比网络进行检测,具体检测效果如图 9 所示。

从图 9 可以看出,除去 YOLO v5s,其他的对比网络都或多或少出现漏检和误检的情况,而改进后的 YOLO v5s 并没有出现漏检和误检的情况。虽然改进后的 YOLO v5s 检测框置信度略低于 YOLO v5s 网络,但是减少近一半的参数量、计算量,在模型权重和更高的检测效率(高 FPS)的优势下,其代价是可以接受的。

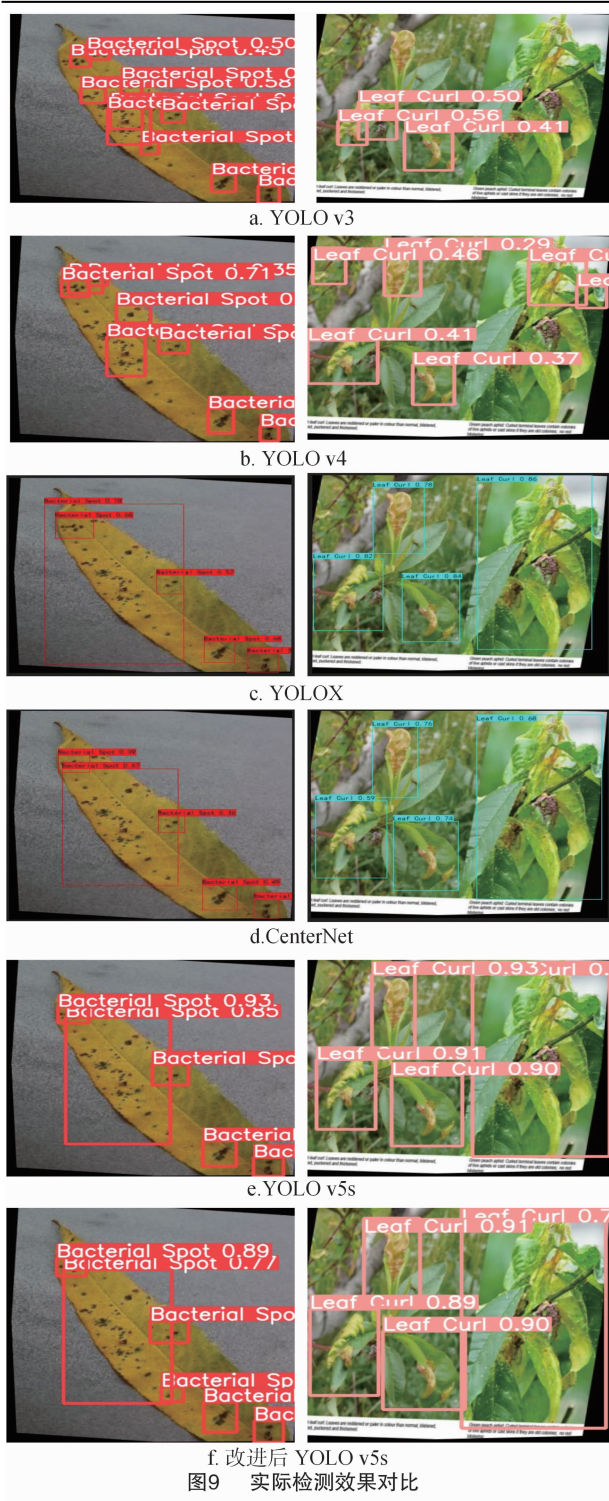
3 结论与讨论

本研究针对桃树叶片病害检测提出了轻量化的 YOLO v5s,首先使用收敛速度更快和定位精度更高的 EIoU 边框损失函数。接下来添加了不额外产生参数和计算量的 SimAM 注意力机制,有效提升了检测精度,最后引入了 Ghost 模块,实现了整体网络的轻量化。试验结果表明,改进后的网络对比其他

网络在检测精度上有着明显的优势,与基准 YOLO v5s 相比,网络的参数量、计算量、权重都有近乎一半的缩减,而 FPS 也是最高的,这有利于部署在移动端或物联网设备,为无人检测果园病害提供了算法支撑。在后续的研究中,为了让所提出方法在真实场景下使用,将在数据集层面收集更多种类、不同环境下的病害图片,扩充数据集覆盖范围;在网络优化方面会尝试模型权重剪枝和稀疏化,从而进一步压缩参数量、计算量、权重,并验证在物联网设备上的实际效果。

参考文献:

[1]徐磊,陈超.中国桃产业经济分析与发展趋势[J].果树学报,2023,40(1):133-143.
[2]Sankaran S,Ehsani R.Visible - near infrared spectroscopy based citrus greening detection: evaluation of spectral feature extraction techniques[J].Crop Protection,2011,30(11):1508-1513.
[3]Moghadam P,Ward D,Goan E,et al.Plant disease detection using hyperspectral imaging[C]//2017 International Conference on Digital Image Computing: Techniques and Applications (DICTA).November 29 - December 1,2017,Sydney,NSW,Australia.IEEE,2017:1-8.



- [4] 邵明月, 张建华, 冯全, 等. 深度学习在植物叶部病害检测与识别的研究进展[J]. 智慧农业(中英文), 2022, 4(1): 29–46.
- [5] Zhang Q, Liu Y Q, Gong C Y, et al. Applications of deep learning for dense scenes analysis in agriculture: a review[J]. Sensors, 2020, 20(5): 1520.

- [6] 赵嘉威, 田光兆, 邱畅, 等. 基于改进 YOLOv4 算法的苹果叶片病害检测方法[J]. 江苏农业科学, 2023, 51(9): 193–199.
- [7] 毛锐, 张宇晨, 王泽玺, 等. 利用改进 Faster-RCNN 识别小麦条锈病和黄矮病[J]. 农业工程学报, 2022, 38(17): 176–185.
- [8] 林相泽, 徐啸, 彭吉祥. 基于图像消冗与 CenterNet 的稻飞虱识别分类方法[J]. 农业机械学报, 2022, 53(9): 270–276, 294.
- [9] 王金星, 马博, 王震, 等. 基于改进 Mask R-CNN 的苹果园害虫识别方法[J]. 农业机械学报, 2023, 54(6): 253–263, 360.
- [10] 杨红云, 万颖, 王映龙, 等. 基于批归一化与 AlexNet 网络的水稻病害识别[J]. 激光与光电子学进展, 2021, 58(6): 0610007.
- [11] 贾璐, 叶中华. 基于注意力机制和特征融合的葡萄病害识别模型[J]. 农业机械学报, 2023, 54(7): 223–233.
- [12] Qi J T, Liu X N, Liu K, et al. An improved YOLO v5 model based on visual attention mechanism; application to recognition of tomato virus disease[J]. Computers and Electronics in Agriculture, 2022, 194: 106780.
- [13] 曹跃腾, 朱学岩, 赵燕东, 等. 基于改进 ResNet 的植物叶片病虫害识别[J]. 中国农机化学报, 2021, 42(12): 175–181.
- [14] Zhang Y F, Ren W Q, Zhang Z, et al. Focal and efficient IOU loss for accurate bounding box regression[J]. Neurocomputing, 2022, 506: 146–157.
- [15] Zheng Z H, Wang P, Ren D W, et al. Enhancing geometric factors in model learning and inference for object detection and instance segmentation[J]. IEEE Transactions on Cybernetics, 2022, 52(8): 8574–8586.
- [16] Guo M H, Xu T X, Liu J J, et al. Attention mechanisms in computer vision: a survey[J]. Computational Visual Media, 2022, 8(3): 331–368.
- [17] Yang L, Zhang R Y, Li L, et al. Simam: a simple, parameter-free attention module for convolutional neural networks[C]//International conference on machine learning. PMLR, 2021: 11863–11874.
- [18] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27–30, 2016, Las Vegas, NV, USA. IEEE, 2016: 770–778.
- [19] Han K, Wang Y H, Tian Q, et al. GhostNet: more features from cheap operations[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13–19, 2020, Seattle, WA, USA. IEEE, 2020: 1577–1586.
- [20] 文斌, 曹仁轩, 杨启良, 等. 改进 YOLO v3 算法检测三七叶片病害[J]. 农业工程学报, 2022, 38(3): 164–172.
- [21] 孙道宗, 刘欢, 刘锦源, 等. 基于改进 YOLO v4 模型的茶叶病害识别[J]. 西北农林科技大学学报(自然科学版), 2023, 51(9): 1–10.
- [22] 马驰, 吴华瑞, 于会山. 基于 YOLOX 的穴盘甘蓝病害检测方法[J]. 江苏农业科学, 2023, 51(8): 193–202.