王帅,王利众,朱丽平,等.基于改进YOLOv5s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.
Wang S, Wang L Z, Zhu L P, et al.Research on apple disease detection technology based on improved YOLOv5s[J].Journal of Shanxi Agricultural University(Natural Science Edition), 2024,44(4):118-129.
doi: 10.13842/j.cnki.issn1671-8151.202401036

基于改进YOLOv5s的苹果病害检测技术研究

王帅,王利众*,朱丽平,孙媛

(中央民族大学 信息工程学院,北京 100081)

摘　要:[目的]面对大规模的苹果园种植和管理,传统的果园巡检容易出现误检、少检的现象,并且传统的苹果病害检测模型参数量庞大难以实现移动端的轻量化部署,因此,设计一个高效并且轻量的苹果病害检测模型可以实现对苹果病害的有效预防与精准管理,从而改善苹果品质与增加果园经济收入。[方法]针对以上需要,提出了一种基于YOLOv5s的改进算法。以常见的炭疽病和褐斑病为主要研究对象,采集苹果表皮病害图像构建果园苹果病害数据集,通过Labelimg工具对图像进行标注与分类;引入GhostNet轻量化模块对主干特征提取网络进行替换,使用更小的参数量来捕获更多的特征信息,达到模型轻量化的效果,便于后期移动端的部署;引入SimAM无参注意力机制加强模型对通道和空间信息的同时关注,在不添加任何参数量的基础上对重要的病害特征赋予更高的优先级,提高模型的准确性;引入SIoU边界框回归损失函数来优化预测框对于目标病害的准确定位,通过重新定义角度惩罚度量帮助预测框快速定位到准确的轴,同时借助遗传算法优化θ的取值,实现提升模型训练和推理能力的效果。[结果]改进后的模型参数量和浮点运算数(FLOPs)比原始模型减少了30.2%和33.8%,在达到轻量化的基础上,mAP@0.5达到93.7%,mAP@0.5:0.95达到63.3%,分别优于YOLOv5s原始算法1.6%和0.7%。[结论]改进后的模型在实现轻量化的同时也达到了较好的检测性能,不仅实现了苹果病害的高效识别,也为其他农作物的病害检测提供了技术支持与参考依据。

关键词:苹果病害; 目标检测; 模型轻量化; 注意力机制; 智慧农业
中图分类号:TP391.41;S436.611　　**文献标识码**:A　　**文章编号**:1671-8151(2024)04-0118-12

近年来,计算机视觉和深度学习在智慧农业领域飞速发展,苹果病害检测作为这一领域的热点话题之一,得到了广泛关注。早期的目标检测主要依赖于手工设计的特征。随着机器学习的发展,支持向量机(Support Vector Machine,SVM)等[1]算法通过学习目标与非目标的边界来进行分类。在深度学习领域,随着深度卷积神经网络的成功应用,目标检测算法也取得了显著进展。两阶段检测器拥有较高准确性,但参数量较大,模型相对复杂,不便于轻量化的移动端部署,代表算法有Fast r-cnn[2]。单阶段检测器拥有较少参数量,模型结构相对简单,便于在资源受限环境中部署,但准确性较低,代表算法有YOLO[3-5]和SSD[6-7]。

国内外许多学者对病害检测进行了一系列研究,Chakraborty等[8]提出了一种结合机器学习与图像处理的苹果叶片病害识别系统,通过采用多类支持向量机的方法,准确率达到了96%。杨英茹等[9]提出结合支持向量机的方法,实现对复杂环境的叶片病害识别。薛勇等[10]提出结合GoogLeNet深度神经网络的技术,解决了对苹果识别精度低的问题,但是具有训练时间过长和设备要求过高等问题。邱光应等[11]提出采用决策树支持向量机的技术,实现了对苹果表面缺陷的判断,节省了运算耗时,对苹果表面缺陷的识别正确率也达到了98.2%。熊梦园等[12]提出采用ResNet50+CBAM注意力机制的方法,实现了对

收稿日期:2024-01-16　　**修回日期**:2024-04-08
基金项目:国家自然科学基金(61972436);中央民族大学研究生精品示范课程(GRSCP202316)
作者简介:王帅(ORCID:0009-0000-5865-235X),硕士研究生,研究方向:深度学习
*通信作者:王利众(ORCID:0009-0009-6857-8785),副教授,硕士生导师,E-mail:wlz4646@muc.edu.cn

玉米叶片的病害识别,平均识别精度达到97.5%。

目前,科研工作者通过机器学习的方法对病害进行研究,虽在一定程度上提高了精确性,但面临着大规模的图像数据带来的计算复杂度挑战。虽然,深度学习也在病害检测领域取得了新进展,但是当前的苹果病害检测面临着参数量庞大、计算复杂度高且准确率低下的问题。

所以,本研究针对传统的果园苹果病害模型参数量大、识别效果差等问题,采用参数量小、检测精度高的YOLOv5s作为试验的基线模型,在苹果病害数据集上对模型的参数和结构进行多次对比试验与调优。改进的模型在实现轻量化和多尺度融合的基础上,提高了对复杂苹果病害的处理能力,旨在为果园苹果病害检测模型的轻量化与高效性提供理论依据。

1　材料和方法

1.1　试验数据集的构建

试验用到的苹果病害数据集由各开源数据集平台搜集到的苹果病害图像构建而成,以果园苹果病害中常见的炭疽病和褐斑病为主要研究对象,对每一张苹果病害图像均使用轻量的开源软件Labelimg进行人工标注。模型在训练时按7:3的比例划分数据集,其中训练集为3986张,验证集为1699张。为避免模型训练过程中发生过拟合现象,在数据集中加入枝叶遮挡的苹果图片,从多角度、多时间段对苹果病害图像进行标注和筛选,提高数据集的多样性。

1.2　YOLOv5s模型架构

YOLOv5由4个不同的版本组成:YOLOv5s、YOLOv5m、YOLOv5l、YOLOv5x,它们的网络深度与宽度逐个递增,这意味着YOLOv5s模型拥有更少的参数量,便于后期嵌入式设备的部署,并且在检测速度方面优于其它版本,由此选用YOLOv5s作为试验基准模型。

YOLOv5s是一种单阶段的目标检测模型,包含Input、Backbone、Neck和Head这4个部分。

第一部分是Input,模型在Input端采用Mosaic数据增强、自适应锚框计算和自适应图片缩放[13]等方式来处理输入大小为640×640的图像。

第二部分是Bockbone,模型主要包括CBS模块、C3模块和SPPF模块。CBS封装了二维卷积、BN层和SiLU激活函数,改进版的激活函数有助于网络更快收敛。C3模块封装了3个Conv模块,扩大后的网络深度和感受野有助于特征提取。SPPF模块选用多个小尺寸的池化核级联代替空间金字塔池化SPP模块中的单个大尺寸池化核,丰富了特征图的表达能力。

第三部分是Neck,模型采用了PANet结构,由特征图金字塔网络(Feature Pyramid Networks,FPN)[14]和路径聚合网络(Path Aggregation Network,PAN)[15]构成。特征图金字塔网络通过自顶向下进行上采样,将图像强语义信息传递给浅层;路径聚合网络通过自底向上进行下采样,将图像强定位信息传达给深层。多尺度特征金字塔提升了对多目标尺寸的感知能力,加强了模型的鲁棒性和准确性。

第四部分是Head,针对多尺度的特征图采用1×1卷积进行通道数调整适应多任务检测,通道数与种类个数相关,每个特征层上的每个特征点分别设有3个先验框。对输出的候选框通过非极大值抑制算法来筛选具有位置、类别与置信度等信息的最优锚框,加快对物体的位置和种类检测。

1.3　改进YOLOv5s模型

1.3.1　引用GhostNet网络

Ghost模块是GhostNet网络中的核心组件,其生成特征图的过程主要包括2步。首先输入的特征图通过主要卷积层生成1组特征图,再将生成的特征图通过1组轻量级Ghost卷积层产生额外的特征图,最后将2组生成的特征图进行拼接。Ghost模块如图1所示[16]。

如果输入特征图的尺寸为$H_{in}\times w_{in}\times C_{in}$,输出特征图的尺寸是$H_{out}\times W_{out}\times(n\times C_{out})$,常规卷积核大小是$k\times k$,线性变换卷积核大小是

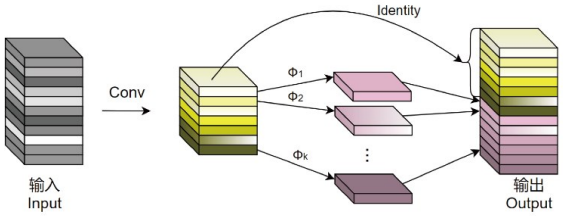

Conv表示卷积操作;Φ表示廉价卷积操作

Conv: convolution operation; Φ: inexpensive convolution operation

图1　Ghost模块示意图

Fig.1　Schematic diagram of the ghost module

$d \times d$。

常规卷积层的参数量为：

$$G_1 = k \times k \times C_{in} \times (n \times C_{out}) \tag{1}$$

如果Ghost模块第一步卷积生成C_{out}个特征图，则需要进行(n-1)次轻量级卷积生成$(n-1) \times C_{out}$个特征图。

Ghost轻量级卷积层的参数量为：

$$G_2 = k \times k \times C_{in} \times C_{out} + d \times d \times (n-1) \times C_{out} \tag{2}$$

当$k \times k$与$d \times d$相似，$n \ll C_{in}$时，传统卷积层的参数量与Ghost轻量级卷积层的参数量之比：

$$\frac{G_1}{G_2} = \frac{k \times k \times C_{in} \times (n \times C_{out})}{k \times k \times C_{in} \times C_{out} + d \times d \times (n-1) \times C_{out}} \approx n \tag{3}$$

1.3.2 添加SimAM注意力模块

本文在模型中嵌入轻量级SimAM注意力机制，减少枝叶阴影、光照变暗等复杂环境对苹果病害检测的影响。与通道注意力和空间注意力对通道或空间位置区别对待不同，SimAM注意力机制生成的三维权重拥有更强大的辨别线索能力。3D权重如图2所示[17]。

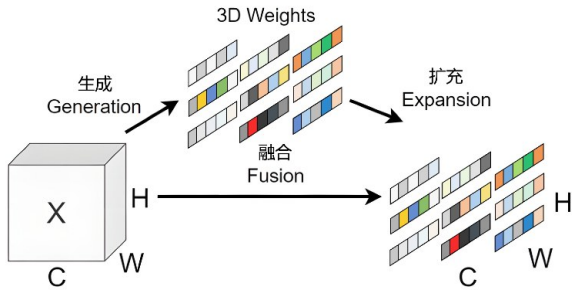

图2 SimAM注意力模块的3D权重示意图

Fig.2 3D weight diagram of the SimAM attention module

SimAM注意力机制的成功实现需要估算每个神经元的重要性。活跃的神经元要被赋予更高的优先级和重要性。通过测量一个目标神经元与其它神经元之间的线性可分离性来找到活跃的神经元。能量函数为：

$$e_t(w_t, b_t, y, x_i) = (y_t - \bar{t})^2 + \frac{1}{M-1}\sum_{i=1}^{M-1}(y_0 - \overline{x_i})^2 \tag{4}$$

通过二值标签与加入正则化的策略简化能量函数，能量函数变化为：

$$e_t(w_t, b_t, y, x_i) = (1-\bar{t})^2 + \frac{1}{M-1}\sum_{i=1}^{M-1}\left(-1 - \overline{x_i}\right)^2 + \lambda w_t^2 \tag{5}$$

其中设u_t是除t以外所有神经元计算所得到的平均值，σ^2是除t以外所有神经元计算所得到的方差。所以，最小能量公式为：

$$e_t^* = \frac{4(\bar{\sigma}^2 + \lambda)}{(t-\bar{u})^2 + 2(\bar{\sigma}^2 + \lambda)} \tag{6}$$

上述等式表明能量值越低，目标神经元t与周围相邻神经元的区分度越高，神经元之间越具有线性可分性，也就是神经元的重要程度越高。为避免干扰每个神经元的重要性，通过单调函数Sigmoid进行特征增强处理。表达式为：

$$\tilde{X} = \mathrm{sigmoid}\left(\frac{1}{E}\right) \odot X \tag{7}$$

对于病害检测而言，通道与空间位置都十分重要，为了便于模型轻量化的部署，引入SimAM无参注意力机制，通过能量函数提高对重要神经元的识别能力并有效抑制无关神经元的干扰，在不增加模型复杂度的基础上，提升了网络的特征提取能力和模型的病害检测能力。

1.3.3 更换SIoU损失函数

SIoU损失函数，主要由角度、距离、形状和IoU这4个成本函数组成。

1)角度成本

损失函数中角度成本如图3所示[18]。

式中B^{GT}表示真实框，B表示预测框，C_W，C_h表示为：

$$\begin{cases} C_W = \max\left(b_{cx}^{gt}, b_{cx}\right) - min\left(b_{cx}^{gt}, b_{cx}\right) \\ C_h = \max\left(b_{cy}^{gt}, b_{cy}\right) - min\left(b_{cy}^{gt}, b_{cy}\right) \end{cases} \tag{8}$$

设$x = \frac{C_h}{\sigma} = \sin(\alpha)$，则角度成本函数可以表示为：

$$\Lambda = 1 - 2 * \sin^2(\arcsin(x) - \frac{\Pi}{4}) \tag{9}$$

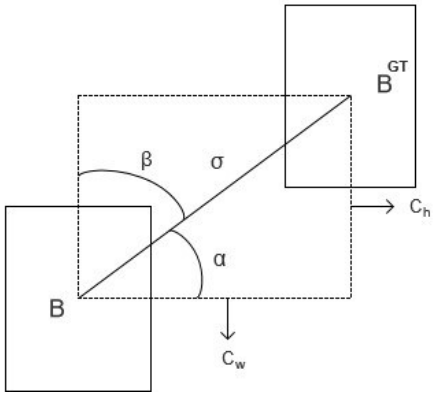

图3　角度成本对损失函数的示意图

Fig.3　Schematic diagram of the angle cost on the loss function

2)距离成本

损失函数中距离成本如图4所示[18]。

距离成本函数表示为:

$$\Delta=\sum_{t=x,y}(1-e^{-\gamma\rho_t}) \tag{10}$$

式中$\gamma=2-\Lambda$,ρ_x和ρ_y表示为:

$$\begin{cases}\rho_x=\left(\dfrac{b_{cx}^{gt}-b_{cx}}{C_w}\right)^2\\ \rho_y=\left(\dfrac{b_{cy}^{gt}-b_{cy}}{C_h}\right)^2\end{cases} \tag{11}$$

3)形状成本

形状成本函数表示为:

$$\Omega=\sum_{t=w,h}(1-e^{-\omega_t})^{\theta} \tag{12}$$

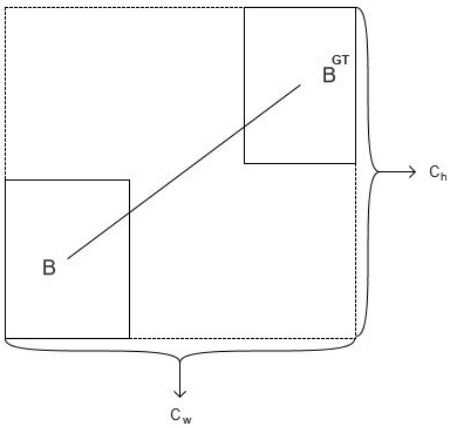

图4　计算真实框与预测框之间距离的示意图

Fig.4　Schematic diagram of calculating the distance between the ground truth bounding box and the predicted box

公式中的θ的取值十分关键,如果值设定为1,会立刻优化形状。

4)SIoU损失函数

SIoU损失函数表示为:

$$L_{box}=1-IoU+\frac{\Delta+\Omega}{2} \tag{13}$$

损失函数对于苹果病害检测模型的收敛和预测性能有着重要的作用。目前,有多种损失函数考虑了框与框之间的中心距离、重叠区域和长宽比。虽然这些损失函数在指导模型训练的过程中起到了积极作用,但并未考虑到框与框之间方向不匹配的情况,这会影响预测框的有效回归,导致模型收敛变慢,预测效果变差。引入SIoU损失函数可以有效帮助预测框快速定位到准确的轴,提升模型收敛速度和推理能力,使模型更加准确识别和定位病害。

1.3.4　改进后的模型

面对传统的苹果病害检测的问题,基于注意力机制的轻量化单阶段目标检测器为苹果病害检测提供了智能化技术。针对果园的实际需求,引入Ghost结构减小模型的参数量和计算复杂度,便于模型在移动端部署,提高模型的便捷性;使用SimAM无参注意力机制降低病害漏检率,实现对苹果病害的准确定位;采用SIoU损失函数减少收敛时间,提高训练和推理性能,高效且准确的适应苹果病害检测任务,减少苹果果园经济损失,推进智能农业可持续发展。改进后的模型如图5所示。

1.4　试验环境

本文选择的试验硬件配置如表1所示,试验软件配置如表2所示。

1.5　试验评价指标

本试验采用精确度(Precision,P)、平均精度(average precision,AP)、平均精度均值(mean Average Precision,mAP)、模型参数量(Parameters)、浮点运算次数(Floating Point Operations,FLOPs)来研究模型的效果。

精确度是指所有预测为正样本的结果中,被预测正确的比例,表示为:

$$P=\frac{TP}{(TP+FP)} \tag{14}$$

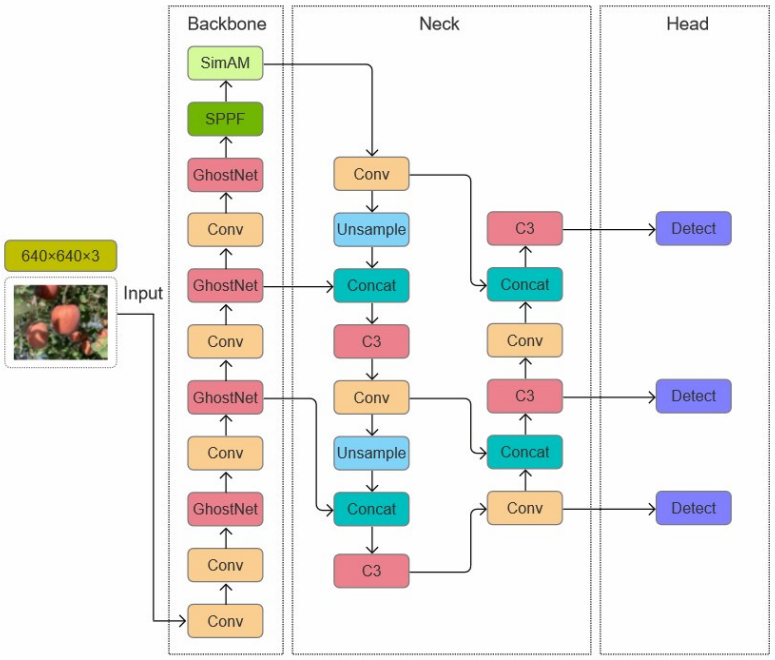

图5 改进YOLOv5s模型结构示意图

Fig.5 Schematic diagram of the improved YOLOv5s model structure

表1 试验硬件配置

Table 1 Experimental hardware configuration

硬件配置 Hardware configuration	版本参数 Version parameters
操作系统	ubuntu20.04
内存	40GB
GPU	NVIDIA GERORCE RTX 3080
CPU	Intel(R) Xeon(R) Platinum 8255C CPU @ 2.50GHz

表2 试验软件配置

Table 2 Experimental software configuration

软件配置 Software configuration	版本参数 Version parameters
Python	3.8.5
Pytorch	1.12.0
CUDA	11.3
CuDNN	8.3

AP是指P-R曲线(Precision-Recall Curve,P-R)下面积的积分,表示为:

$$AP=\int_0^1 PRdR \tag{15}$$

mAP@0.5是指预测框与真实框的交叠比(Intersection over Union,IoU)阈值等于0.5时,对所有类别的AP@0.5进行平均,表示为:

$$mAP@0.5=\frac{\sum_{i=1}^{n}AP_i}{n} \tag{16}$$

式中TP为正确识别的正样本数量,FP为错误识别的负样本数量,FN为未能识别的正样本数量,n表示数据的类别数量,AP_i表示第i类检测平均精度,mAP表示所有类别AP_i均值。

1.6 试验参数设置

试验使用随机梯度下降(Stochastic Gradient Descent,SGD)优化器训练网络,寻找最优权重。在训练之前修改apple.yaml数据集配置文件,目标种类参数(number of classes,nc)定义为3,种类分别命名为Anthracnose(炭疽病)、Marssoninan blotch(褐斑病)、Apple(苹果)。本文试验所用参数如表3所示。

试验前期加入预热训练,在预热训练结束以后,模型会在训练过程采用余弦退火策略调整学习率,加快苹果病害检测模型的收敛并提高模型在苹果病害数据集上的准确性。

表3　试验参数设置

Table 3　Experimental parameter settings

试验参数 Experimental parameters	参数值 Parameter values
迭代次数	300
批量大小	16
初始学习率	0.01
权重衰减	0.000 5
动量参数	0.937

2　结果与分析

2.1　模型轻量化对比试验

为了验证苹果病害模型更换轻量化主干网络的效果,设计模型的轻量化对比试验,通过MobileNetV3[19]、C3Faster、Ghost更换YOLOv5s模型的主干特征提取网络。以YOLOv5s为基线模型,标注为YOLOv5s-MobileNetV3、YOLOv5s-C3Faster、YOLOv5s-GhostNet。更换轻量化网络后的模型性能对比试验如表4所示,更换轻量化模型后在苹果病害数据集上的预测结果如图6所示。

通过表4模型轻量化的对比试验可以看出,更换了轻量化模块的苹果病害检测模型在参数量与计算复杂度方面均实现了不同程度的缩减。其中YOLOv5s-MobileNetV3的参数量与计算复杂度缩减程度最大,部分参数量的丢失导致了YOLOv5s-MobileNetV3模型对于苹果病害的检测准确度下降了1.3%;YOLOv5s-C3Faster的参数量和FLOPs相较于原YOLOv5s模型也得到了较大程度的降低,但是YOLOv5s-C3Faster的mAP值相较于YOLOv5s-GhostNet降低较多;替换了Ghost模块的YOLOv5s-GhostNet不仅在mAP值方面高于YOLOv5s-MobileNetV3与YOLOv5s-C3Faster,而且其模型参数量与计算复杂度相较于基线模型分别减少了30.2%和33.8%,整体检测效果最优。因此,通过模型轻量化的对比试验可以发现,采用Ghost模块更换基线模型的主干特征提取网络可以在降低模型复杂性的基础上,保持较好的病害检测效果。

通过设计苹果病害的轻量化对比试验,可以更好地可视化苹果病害模型更换轻量化主干网络的效果。从模型轻量化的预测结果对比图可以看出,在同时检测出病害的前提下,第1张苹果病害的检测效果表明,YOLOv5s-GhostNet对于炭疽病苹果病害的检测准确度高于YOLOv5s-MobileNetV3与YOLOv5s-C3Faster;第2张苹果病害的检测效果表明,YOLOv5s-GhostNet对于炭疽病苹果病害的检测效果与YOLOv5s-C3Faster一致,两者均高于YOLOv5s-MobileNetV3;第3张苹果病害的检测效果表明,YOLOv5s-GhostNet对于褐斑病苹果病害的检测准确度高于YOLOv5s-MobileNetV3与YOLOv5s-C3Faster。

通过对上述试验的结果分析,充分表明替换Ghost模块后,YOLOv5s-GhostNet可以在苹果病害数据集上学习到更多稀疏的表示,这使得改进后的模型在病害检测方面可以取得较好的识别效果,替换Ghost模块有助于降低模型计算的复杂度,使模型适用于有限的移动资源,从而满足果园苹果病害的轻量化检测需求。

2.2　注意力机制对比试验

为提升改进后的轻量化模型对于苹果病害的特征提取能力与检测识别能力,探究不同注意力对轻量化模型的病害检测效果,将适用于苹果病害检测的注意力机制SE[20]、ECA[21]、CBAM[22]、CA[23]、SimAM添加到轻量化模型主干网络中,设计轻量化模型添加注意力机制对比试验,添加注意力机制的轻量化模型性能对比试验如表5所示。

表4　模型轻量化性能比较

Table 4　Comparison of model lightweight performance

模型 Model	AP@0.5/% 炭疽病 Anthracnose	AP@0.5/% 褐斑病 Marssoninan blotch	AP@0.5/% 苹果 Apple	mAP@0.5/%	mAP@0.5:0.95/%	参数量 Parameters	复杂度/G FLOPs
YOLOv5s(Baseline)	95.6	84.8	96.1	92.1	62.6	7027720	16.0
YOLOv5s(MobileNetV3)	95.8	83.0	94.7	91.2	61.3	3733096	6.5
YOLOv5s(C3Faster)	96.0	81.4	96.7	91.4	61.6	5797192	12.8
YOLOv5s(GhostNet)	95.6	84.5	95.3	91.8	62.1	4902256	10.6



(a)为输入的苹果病害图像;(b)为YOLOv5s的识别结果;(c)为YOLOv5s更换了MobileNetV3的识别结果;(d)为YOLOv5s更换了C3Faster的识别结果;(e)为YOLOv5s更换了GhostNet的识别结果

(a): represents the input image of apple diseases; (b): the recognition results of YOLOv5s; (c): the recognition results of YOLOv5s after replacing it with MobileNetV3; (d): the recognition results of YOLOv5s after replacing it with C3Faster; (e): the recognition results of YOLOv5s after replacing it with GhostNet

图6 轻量化模型预测结果对比示意图

Fig.6 Schematic diagram comparing prediction results of the lightweight models

表5 轻量化模型添加注意力机制的性能比较

Table 5 Performance comparison of lightweight models with added attention mechanism

编号 Number	模型 Model	AP@0.5/%			mAP@0.5/%	mAP@0.5:0.95/%	参数量 Parameters	复杂度/G FLOPs
		炭疽病 Anthracnose	褐斑病 Marssoninan blotch	苹果 Apple				
1	YOLOv5s(GhostNet)	95.6	84.5	95.3	91.8	62.1	4 902 256	10.6
2	YOLOv5s(GhostNet+SE)	96.0	81.4	96.7	91.4	61.6	4 935 024	10.6
3	YOLOv5s(GhostNet+ECA)	96.6	84.5	96.9	92.7	63.6	4 902 259	10.6
4	YOLOv5s(GhostNet+CBAM)	96.5	85.1	96.9	92.8	62.8	4 935 122	10.6
5	YOLOv5s(GhostNet+CA)	96.1	85.3	97.1	92.8	63.0	4 937 936	10.7
6	YOLOv5s(GhostNet+SimAM)	95.8	86.7	96.8	93.1	63.0	4 902 256	10.6

注:编号1为YOLOv5s更换GhostNet的模型;编号2~编号6为分别添加SE、ECA、CBAM、CA、SimAM注意力机制的模型

Note: Model numbered 1 refers to the model where GhostNet is substituted in place of the original model in YOLOv5s. Models numbered 2 to 6 respectively incorporate SE, ECA, CBAM, CA, and SimAM attention mechanisms

通过表5的对比试验可知,添加ECA、CBAM、CA、SimAM注意力机制的轻量化模型对于苹果病害检测的准确性得到了提升,这表明注意力机制的添加提升了轻量化模型的特征提取能

力和苹果病害识别能力,改善了轻量化模型对苹果病害的检测性能。其中,添加SimAM注意力机制的YOLOv5s-GhostNet比YOLOv5s-GhostNet的检测精度提升了1.3%,而且SimAM注意力机制在苹果病害数据集上表现效果最优。这表明添加SimAM注意力机制可以在未引入任何参数量的基础上,实现对重要病害的有效识别,这不仅有助于苹果病害检测模型的轻量部署,而且显著提升了苹果病害检测模型的性能。

2.3　优化损失函数对比试验

为了提升模型的推理能力与检测性能,探究不同损失函数对轻量化模型的病害检测效果,设计了轻量化模型采用不同损失函数的对比试验,采用不同损失函数的轻量化模型性能对比试验如表6所示。

通过表6的对比试验可知,在苹果病害数据集上,更换了SIoU函数的轻量化模型在检测精度达到了93.7%,分别高于基线模型1.6%、改进后采用CIoU函数的模型0.6%、改进后采用WIoU[24]函数的模型1.4%,这表明改进后的轻量化模型采用SIoU损失函数可以提升模型对于苹果病害的定位与识别能力。

表6　轻量化模型更换损失函数的性能比较

Table 6　Performance comparison of lightweight models with different loss functions replacement

编号 Number	模型 Model	AP@0.5/%			mAP@0.5/%	mAP@0.5:0.95/%	参数量 Parameters	复杂度/G FLOPs
		炭疽病 Anthracnose	褐斑病 Marssonina blotch	苹果 Apple				
1	YOLOv5s (Baseline)	95.6	84.8	96.1	92.1	62.6	7027720	16.0
2	YOLOv5s (GhostNet+SimAM+CIoU)	95.8	86.7	96.8	93.1	63.0	4902256	10.6
3	YOLOv5s (GhostNet+SimAM+WIoU)	97.0	83.3	96.6	92.3	62.1	4902256	10.6
4	YOLOv5s (GhostNet+SimAM+SIoU)	96.6	86.4	97.3	93.7	63.3	4902256	10.6

注:编号1为YOLOv5s基线模型;编号2~编号4为分别添加CIoU、WIoU、SIoU损失函数的模型

Note: Model numbered 1 refers to the YOLOv5s baseline model; Models numbered 2 to 4 represented models incorporating with CIoU, WIoU, and SIoU loss functions, respectively

2.4　消融试验

为了验证改进后的模型在果园苹果病害检测中的识别效果,对各改进的模块进行消融研究。第一步是将Ghost模块引入主干和颈部网络,实现模型轻量化的效果;第二步是嵌入SimAM注意力模块,将其与SE、ECA、CBAM、CA进行对比;第三步是替换损失函数为SIoU,将其与CIoU、WIoU进行对比。检测效果如表7所示,改进前后的迭代对比效果如图7~图9所示。

通过表7的消融试验与图7~图9的效果对比可知,整体检测性能与收敛速度方面均得到了正向提升,改进后的YOLOv5s模型(编号9)在参数量与计算复杂度大幅下降30.2%和33.8%的基础上,检测性能的指标得到明显的提高,相较于基线模型(编号1)mAP@0.5值提升了1.6%,mAP@0.5:0.95值提升了0.7%。在针对各个改进的试验中,基线模型(编号1)虽然比更换Ghost模块的模型(编号2)在准确度方面高一点,但是编号1模型的复杂度远远高于编号2;编号2~编号6为各注意力之间的对比,添加了SimAM注意力过后的轻量化模型各指标均得到提升,说明SimAM注意力可以加强模型对于病害特征与重要位置的感知能力,其产生的三维权重对目标线索拥有较强大的辨别能力;编号7~编号9为各损失函数之间的对比,SIoU重新定义了角度惩罚度量,可以有效帮助预测框准确定位,使其整体表现效果最优。

综上,改进后的苹果病害检测模型在保证了苹果病害检测准确性的基础上,实现了苹果病害检测模型的轻量化部署要求,适用于将改进后的苹果病害检测模型部署于计算资源受限的设备。

表7 消融试验

Table 7 Ablation experiment

编号 Number	模型 Model	主干 Backbone	注意力 Attention	损失函数 Loss function	mAP@0.5/%	mAP@0.5:0.95/%	参数量 Parameters	复杂度/G FLOPs
1	YOLOv5s	—	—	CIoU	92.1	62.6	7 027 720	16.0
2	YOLOv5s	GhostNet	—	CIoU	91.8	62.1	4 902 256	10.6
3	YOLOv5s	GhostNet	SE	CIoU	91.4	61.6	4 935 024	10.6
4	YOLOv5s	GhostNet	ECA	CIoU	92.7	63.6	4 902 259	10.6
5	YOLOv5s	GhostNet	CBAM	CIoU	92.8	62.8	4 935 122	10.6
6	YOLOv5s	GhostNet	CA	CIoU	92.8	63.0	4 937 936	10.7
7	YOLOv5s	GhostNet	SimAM	CIoU	93.1	63.0	4 902 256	10.6
8	YOLOv5s	GhostNet	SimAM	WIoU	92.3	62.1	4 902 256	10.6
9	YOLOv5s	GhostNet	SimAM	SIoU	93.7	63.3	4 902 256	10.6

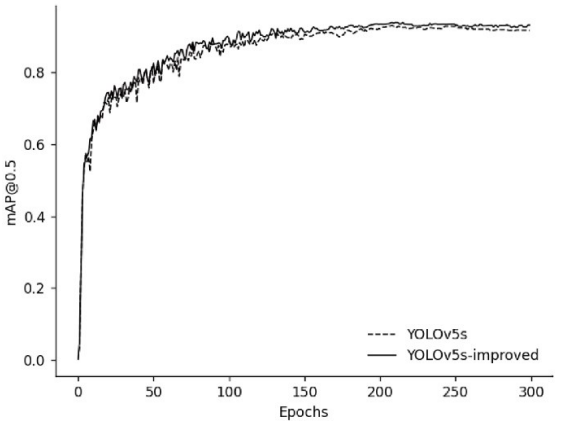

YOLOv5s-improved 为本文改进的 YOLOv5s-GhostNet-SimAM-SIoU模型,下同

YOLOv5s-improved refers to the improved YOLOv5s-GhostNet-SimAM-SIoU model in this paper. The same below

图7 mAP@0.5改进前后对比示意图

Fig.7 Schematic diagram comparing mAP@0.5 before and after improvement

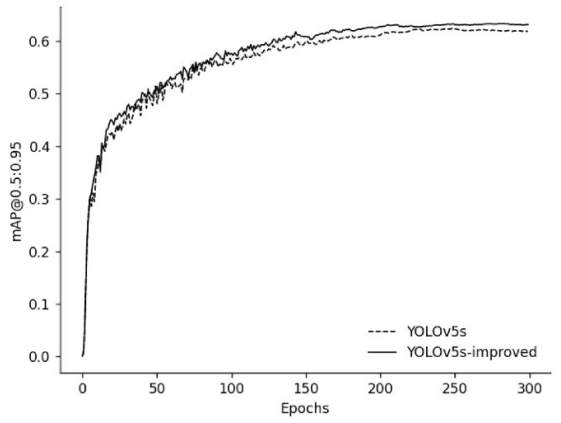

图8 mAP@0.5:0.95改进前后对比示意图

Fig.8 Schematic diagram comparing mAP@0.5:0.95 before and after improvement

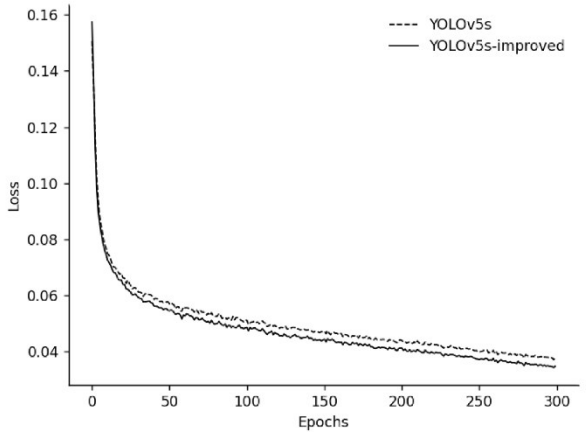

图9 损失函数改进前后对比示意图

Fig.9 Schematic diagram comparing the loss function before and after improvement

2.5 对比试验

为验证改进模型的优越性,将改进的模型与SSD[25]、Faster RCNN[26]、YOLOv3-EfficientNet、YOLOv4-tiny、YOLOv5s、YOLOX[27]、YOLOv7-tiny检测模型在同一数据集上进行对比试验,对比试验的迭代次数与试验环境均相同。

试验结果如表8所示。通过对比试验可以看出,改进的模型在参数量最低的基础上,mAP值分别提升了10.5%、8.0%、7.0%、7.7%、1.6%、2.2%、5.1%。改进的模型在苹果病害检测轻量化与准确精度方面有更大的优势。

3 讨论

在大规模种植的果园中准确地检测并识别苹果病害,有利于尽早采取必要措施防止苹果病害的蔓延,减少苹果损失。目前,针对苹果病害已经

表8　对比试验结果

Table 8　Comparative experimental results

模型 Model	计算复杂度/G FLOPs	参数量/M Parameters	平均精度均值/% mAP
SSD	62.8	26.3	83.2
Faster RCNN	370.2	137.1	85.7
YOLOv3－EfficientNet	4.0	7.2	86.7
YOLOv4－tiny	7.0	6.1	86.0
YOLOv5s	16.0	7.0	92.1
YOLOX	156.0	54.2	91.5
YOLOv7－tiny	13.9	6.2	88.6
YOLOv5s－improved	10.6	4.9	93.7

提出了很多基于深度学习的检测模型。赵嘉威等[28]通过更换轻量级网络MobileNetV3与添加注意力CBAM对YOLOv4优化,实现了苹果叶片病害的高效检测。王权顺等[29]引入DenseNet121特征提取网络,以数据扩增的方式提升模型的鲁棒性。以上方法虽然对于苹果病害防治有重要意义,但是,大多数苹果病害的研究都是在实验室环境进行,容易忽略复杂的自然条件。果园种植条件下往往会有低光照、枝叶遮挡、光斑干扰等情况,这些自然环境往往会影响苹果病害的有效识别。所以,为进一步直观地显示改进YOLOv5s模型对于苹果病害识别的鲁棒性,本文以实际果园场景下的苹果病害进行讨论研究。

通过图10可以看出,未改进的YOLOv5s模型在枝叶遮挡与模糊条件下均把苹果误检为炭疽病,在远距离低光照条件下把炭疽病误检为苹果,在阴影遮挡条件下出现漏检苹果的现象,在光斑干扰与低光照的条件下,YOLOv5s基线模型的苹果病害置信度整体低于本研究的改进模型。而本研究的改进模型针对以上6种复杂的果园环境,均已实现准确检测并且拥有较高的置信度。由此,证明了改进的YOLOv5s模型在降低模型复杂度的基础上,实现了检测精度的提升,以更少的参数量达到了更高的识别效果,大大降低了误检、漏检情况的发生。在下一步的试验研究中,本文将扩充对苹果病害种类的研究,实地考察并拍摄其他种类的苹果病害图像,在实现优化模型的基础上,进一步提升模型的多类别检测能力。

4　结论

通过使用GhostNet轻量化网络构建苹果病害检测模型的特征提取网络,实现大幅降低苹果病害检测模型参数量与计算复杂度的效果。轻量化过后的模型在参数量方面由基线模型YOLOv5s的7 027 720下降到了4 902 256,在计算复杂度方

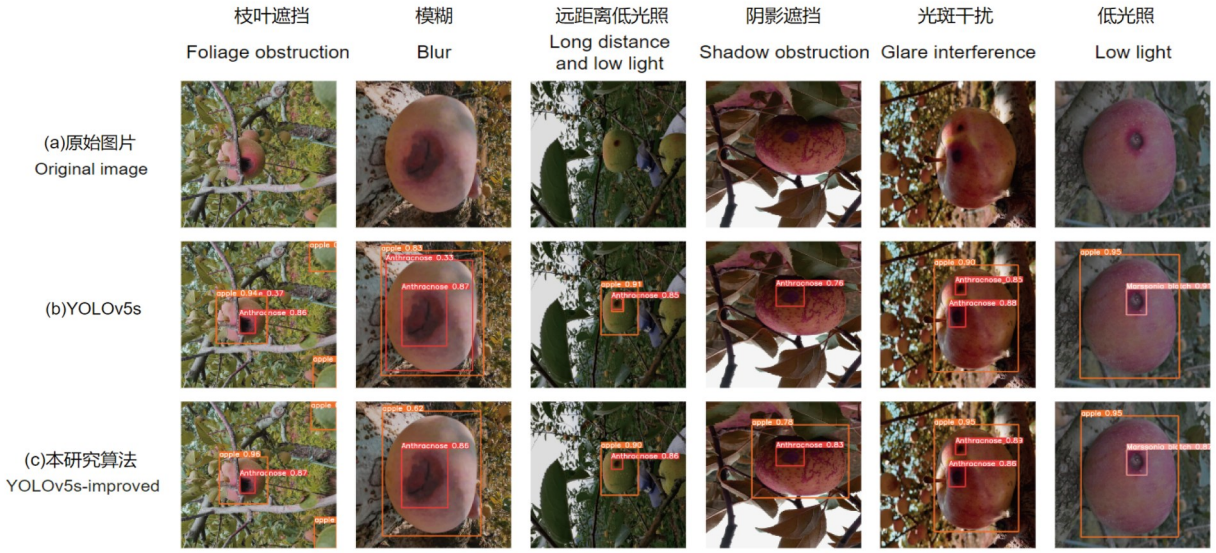

(a)为输入的苹果病害图像;(b)为YOLOv5s的识别结果;(c)为本文改进算法的识别结果

(a): represents the input image of apple disease; (b): shows the recognition results of YOLOv5s; (c): displays the recognition results of the improved algorithm proposed in this paper

图10　自然条件下的苹果病害检测示意图

Fig.10　Schematic diagram of apple disease detection under natural conditions

面由基线模型YOLOv5s的16.0 G下降到10.6 G,分别下降了30.2%和33.8%,与其它主流的检测模型相比,参数量与计算复杂度也较低,满足了果园苹果病害检测的轻量化部署要求。

由于轻量化过后的模型在参数量方面得到削减,易造成对苹果病害检测精度的丢失,为提升轻量化模型的检测性能与推理能力。引入SimAM无参注意力机制,在参数量不变的基础上,提取更丰富的重要信息,提升模型的识别精度;为优化预测框对苹果病害的准确定位,引入SIoU损失函数,便于模型更快收敛,提升模型的推理能力。

试验表明,优化后的模型对果园苹果病害的检测精度得到了提升,其中mAP@0.5达到了93.7%,mAP@0.5:0.95达到了63.3%,分别优于YOLOv5s原始算法1.6%和0.7%。优化的模型满足了模型轻量化与精确度的要求,为苹果果园经济的移动部署提供了新思路。

参 考 文 献

[1]Balasubramaniam V. Artificial Intelligence Algorithm with SVM Classification using Dermascopic Images for Melanoma Diagnosis[J]. Journal of Artificial Intelligence and Capsule Networks,2021,3(1):34-42.

[2]Girshick R. Fast R-CNN[C]. 2015 IEEE International Conference on Computer Vision (ICCV). Santiago: IEEE, 2015:1440-1448.

[3]Redmon J, Farhadi A. YOLOv3: an incremental[EB/OL]. [2024-04-08]. 2018: arXiv: 1804.02767. http://arxiv. org/abs/1804.02767.

[4]Wang C Y, Bochkovskiy A, Liao H Y M. Scaled-YOLOv4: scaling cross stage partial network[C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville:IEEE,2021:13024-13033.

[5]Wang C Y, Bochkovskiy A, Liao H Y M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]. 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Vancouver: IEEE, 2023:7464-7475.

[6]Yang Z T, Sun Y N, Liu S, et al. 3DSSD: point-based 3D single stage object detector[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle:IEEE,2020:11037-11045.

[7]Zheng W, Tang W L, Jiang L, et al. SE-SSD: self-ensembling single-stage object detector from point cloud[C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville:IEEE,2021:14489-14498.

[8]Chakraborty S, Paul S, Rahat-uz-Zaman M. Prediction of apple leaf diseases using multiclass support vector machine[C]. 2021 2nd International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST). Dhaka: IEEE, 2021: 147-151.

[9]杨英茹,吴华瑞,张燕,等. 基于复杂环境的番茄叶部图像病虫害识别[J]. 中国农机化学报,2021,42(9):177-186.
Yang Y R, Wu H R, Zhang Y, et al. Tomato disease recognition using leaf image based on complex environment[J]. Journal of Chinese Agricultural Mechanization, 2021, 42(9): 177-186.

[10]薛勇,王立扬,张瑜,等. 基于GoogLeNet深度迁移学习的苹果缺陷检测方法[J]. 农业机械学报,2020,51(7):30-35.
Xue Y, Wang L Y, Zhang Y, et al. Defect detection method of apples based on GoogLeNet deep transfer learning[J]. Transactions of the Chinese Society for Agricultural Machinery,2020,51(7):30-35.

[11]邱光应,彭桂兰,陶丹,等. 基于决策树支持向量机的苹果表面缺陷识别[J]. 食品与机械,2017,33(9):131-135.
Qiu G Y, Peng G L, Tao D, et al. Detection on surface defect of apples by DT-SVM method[J]. Food & Machinery, 2017, 33(9):131-135.

[12]熊梦园,詹炜,桂连友,等. 基于ResNet模型的玉米叶片病害检测与识别[J]. 江苏农业科学,2023,51(8):164-170.
Xiong M Y, Zhan W, Gui L Y, et al. Detection and identification of corn leaf disease based on ResNet model[J]. Jiangsu Agricultural Sciences,2023,51(8):164-170.

[13]叶树芬,施振华,苏成悦,等. 基于YOLOv5的电力线和杆塔实时检测算法研究[J]. 计算机测量与控制,2022,30(11):77-84.
Ye S F, Shi Z H, Su C Y, et al. Research on real-time detection algorithm of power line and pole tower based on YOLOv5[J]. Computer Measurement & Control, 2022, 30(11):77-84.

[14]Ghiasi G, Lin T Y, Le Q V. NAS-FPN: learning scalable feature pyramid architecture for object detection[C]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach:IEEE,2019:7029-7038.

[15]Zhou L M, Rao X H, Li Y H, et al. A lightweight object detection method in aerial images based on dense feature fusion path aggregation network[J]. ISPRS International Journal of Geo-Information,2022,11(3):189.

[16]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). Seattle: IEEE,2020:1577-1586.

[17]Yang L X, Zhang R Y, Li L D, et al. Simam: A simple, parameter-free attention module for convolutional neural networks[C]. International conference on machine learning. PMLR,2021:11863-11874.

[18]Gevorgyan Z. SIoU loss: more powerful learning for bounding box regression[EB/OL]. [2024-04-08]. 2022: arXiv: 2205.12740. http://arxiv. org/abs/2205.12740.

[19]Howard A, Sandler M, Chen B, et al. Searching for MobileNetV3[C]. 2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul:IEEE,2019:1314-1324.

[20]Hu J,Shen L,Sun G. Squeeze-and-excitation networks[C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City:IEEE,2018:7132-7141.

[21]Wang Q L, Wu B G, Zhu P F, et al. ECA-net: efficient channel attention for deep convolutional neural networks[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle:IEEE,2020:11531-11539.

[22]Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module[C]. Computer Vision - ECCV 2018. Cham:Springer International Publishing,2018:3-19.

[23]Hou Q B, Zhou D Q, Feng J S. Coordinate attention for efficient mobile network design[C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville:IEEE,2021:13708-13717.

[24]Tong Z J,Chen Y H,Xu Z W,et al. Wise-IoU:bounding box regression loss with dynamic focusing mechanism[EB/OL]. [2024-04-08]. 2023: arXiv: 2301.10051. http://arxiv.org/abs/2301.10051.

[25]Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector[C]//Leibe B,Matas J,Sebe N,et al.,eds. Computer Vision - ECCV 2016. Cham: Springer International Publishing,2016:21-37.

[26]Girshick R. Fast R-CNN[C]. 2015 IEEE International Conference on Computer Vision (ICCV). Santiago: IEEE, 2015:1440-1448.

[27]Ge Z, Liu S T, Wang F, et al. YOLOX: exceeding YOLO series in 2021 [EB/OL]. [2024-04-08]. 2021: arXiv: 2107.08430. http://arxiv.org/abs/2107.08430.

[28]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.
Zhao J W, Tian G Z, Qiu C, et al. Detection method of apple leaf diseases based on improved YOLOv4 algorithm[J]. Jiangsu Agricultural Sciences,2023,51(9):193-199.

[29]王权顺,吕蕾,黄德丰,等. 基于改进YOLOv4算法的苹果叶部病害缺陷检测研究[J]. 中国农机化学报,2022,43(11):182-187.
Wang Q S, Lü L, Huang D F, et al. Research of apple leaf disease defect detection based on improved YOLOv4 algorithm[J]. Journal of Chinese Agricultural Mechanization, 2022, 43(11):182-187.

Research on apple disease detection technology based on improved YOLOv5s

Wang Shuai, Wang Lizhong*, Zhu Liping, Sun Yuan

(*College of Information Engineering, Minzu University of China, Beijing 100081, China*)

Abstract: [Objective] In the context of large-scale apple orchard planting and management, traditional orchard inspections are prone to false detections and omissions. Additionally, traditional apple disease detection models have a large number of parameters, making it different to deploy them on mobile devices. Therefore, designing an efficient and lightweight apple disease detection model can enable effective prevention and precise management of apple diseases, thereby improving apple quality and increasing orchard economic income. [Methods] To address these needs, an improved algorithm based on YOLOv5s is proposed. The common diseases anthracnose and brown spot are the primary research subjects. Apple skin disease images were collected to construct an orchard apple disease dataset, and images were annotated and classified using the Labelimg tool. The GhostNet lightweight module was introduced to replace the main feature extraction network, capturing more feature information with fewer parameters to achieve a lightweight model suitable for mobile deployment. The SimAM parameter-free attention mechanism was introduced to strengthen the model's simultaneous focus on channel and spatial information, assigning higher priority to important disease features without adding any parameters, thus improving model accuracy. The SIoU boundary box regression loss function was introduced to optimize the accurate localization of the predicted box to the target diseases, quickly locating the accurate axis by redefining the angle penalty metric and using a genetic algorithm to optimize the value of θ, thereby enhancing model training and inference capabilities. [Results] The improved model's parameters and floating-point operations (FLOPs) were reduced by 30.2% and 33.8%, respectively, compared to the original model. On the basis of achieving lightweight performance, the mAP@0.5 reached 93.7%, and the mAP@0.5:0.95 reached 63.3%, which were 1.6% and 0.7% better than the original YOLOv5s algorithm, respectively. [Conclusion] The improved model achieves good detection performance while maintaining a lightweight design, efficiently identifying apple diseases and providing technical support and reference for the detection of diseases in other crops.

Keywords: Apple diseases, Object detection, Model lightweighting, Attention mechanism, Smart agriculture

(编辑:韩志强)