

孙长兰,林海峰.一种基于集成学习的苹果叶片病害检测方法[J].江苏农业科学,2022,50(20):41-47.
doi:10.15889/j.issn.1002-1302.2022.20.006

一种基于集成学习的苹果叶片病害检测方法

孙长兰,林海峰

(南京林业大学信息科学技术学院,江苏南京 210037)

摘要:由于苹果树叶片病害图像背景复杂、病斑形态多样,苹果树叶片病害的检测一直是一项具有挑战性的任务。传统的苹果树叶片病害检测方法严重依赖于果农经验和特定领域的专家,步骤复杂且低效,并很容易导致病害的误判和漏判。为解决该问题,基于深度学习技术对苹果树叶片病害特征进行自适应学习和提取,提出一种基于集成学习的苹果树叶片病害检测方法。该算法基于不同的模型,在处理不同的数据集上呈现出各自的特性,充分利用了模型间的优势互补,使用非极大值抑制算法将 YOLOv5 和 EfficientDet 模型进行集成,进一步提高模型特征提取能力并且增强了模型的检测能力。结果表明,该方法在不增加延迟的情况下,能有效提高 3 种苹果树叶片病害的检测效果,平均精度可达 73.4%,相比于单个 YOLOv5 和 EfficientDet 模型分别提高了 3.0%、4.8%。集成后的算法具有更好的特征提取能力,可以提取到更多的病害特征信息,并且较好地平衡了模型的识别精度与模型复杂度,可为田间环境下苹果树叶片病害识别提供参考。

关键词:苹果树;叶片病害;特征提取;集成学习;病害识别;机器学习

中图分类号:TP391.41 **文献标志码:**A **文章编号:**1002-1302(2022)20-0041-07

苹果是人们喜爱的水果之一,在其种植到成熟的过程中,因为各种病虫害的危害导致其产量急剧下降,带来巨大的经济损失。及时检测出苹果叶部病害对果农们非常重要。以往人们对农作物病害识别靠的是该领域的专家对叶片进行细致观察得出结论^[1]。然而这种方法过多地依赖个人经验,如果产生了大面积的病虫害,这种方法显然效率太低,而且还会由于人力资源的不足导致误判和漏判。因此,解决农作物病虫害检测问题显得尤为重

要。近年来,随着计算机技术的发展,越来越多的研究人员尝试将深度学习应用在农作物病虫害的识别领域中^[2]。

近年来,周敏敏提出基于迁移学习的苹果叶面病害 Android 检测系统,采用 Faster R-CNN 算法和 VGG-16 对苹果树病害图像进行特征提取并将训练结果应用到 Android 系统^[3]。最终在 5 种苹果病害检测中,实现其平均精度(mAP)为 76.55%。但该方法所采集的数据集没有针对不同的发病期进行细致划分。Jiang 等提出一种基于改进卷积神经网络的苹果树叶片病害检测方法,使用一种新的模型 INAR-SSD,把该模型用于 5 种常见的苹果树叶片病害,实现了 78.80% mAP 的检测性能,检测速度高达 23.13 FPS^[4]。但该方法仅适用于背景简单的叶片图像,在实际背景复杂的苹果树叶片病害检测中存在一定的局限性。邸洁等采用目标检测 Tiny-YOLO 算法对 3 种常见的苹果叶片进行识别

收稿日期:2021-10-19

基金项目:江苏省现代农机装备与技术示范推广项目(编号:NJ2021-19);江苏省重点研发计划(编号:BE2021716);江苏省农业科技自主创新资金[编号:CX(20)3038]。

作者简介:孙长兰(1996—),女,安徽六安人,硕士研究生,主要从事农林业病虫害的研究。E-mail:sunchanglan@njfu.edu.cn。

通信作者:林海峰,博士,副教授,主要从事农业物联网和农林人工智能系统研究。E-mail:haifeng.lin@njfu.edu.cn。

recognition[J]. Proceedings of the IEEE,1998,86(11):2278-2324.

[14]赵彩敏,刘国红.基于改进的 LeNet-5 卷积神经网络的人脸表情识别[J].许昌学院学报,2021,40(2):113-116.

[15]张赛,王应彪,杨谭,等.基于改进 LeNet-5 模型的木材表面典型缺陷识别方法研究[J].木材科学与技术,2021,35(6):31-37.

[16]吴淑琦.基于卷积神经网络的玉米病害识别[J].现代信息科技,2021,5(9):6-9.

[17]罗华美.基于最大池化层参数的优化模型在引力波天文学中的应用[J].重庆工商大学学报(自然科学版),2020,37(1):59-64.

[18]吴雪琦.基于卷积神经网络的葡萄病毒病的图像识别[J].现代信息科技,2021,5(10):30-33.

检测,平均精度可达 83.54%,但该方法仅把 5 种病害进行了简单的分类,并没有检测出病害发生的具体位置^[5]。李鑫然等采用改进的 Faster R-CNN 网络,通过特征金字塔网络,将具有语义信息的深度特征和具有细节信息的浅层特征进行融合,对 5 种苹果树叶片病害检测,平均精度可达 82.28%,但该方法同样会把背景信息误判为需要提取的特征信息^[6]。

以上所提的方法大多是采用单个的目标检测网络检测苹果树叶片病害产生的位置,很少有将 2 个模型同时使用来降低误判或者漏判的可能性^[7]。因此,本研究提出一种基于集成学习的苹果树叶片病害检测新方法。首先,由于苹果树叶片病害背景较为复杂且病害点复杂多样,使用单一的模型检测病害并不能取得很好的效果^[8-11]。经验表明,每个模型都具有从不同的模型提取不同特征的优势。因此,选择 2 个不同的模型(YOLOv5^[12] 和 EfficientDet^[13])进行融合、利用各自模型的优势可以显著提高模型的鲁棒性、提高检测性能。在实际

试验中,单独使用 YOLOv5 和 EfficientDet 目标检测器,以并行的方式检测苹果叶片病害,最后使用非极大值抑制算法去除模型检测中产生的冗余框。

1 材料与方法

本研究提出一种高效的集成策略(YEUnion),集成 2 个单独的模型实现模型间的优势互补,经过 2 个模型并行处理并采取非极大值抑制算法去除冗余框,最后完成目标识别。试验于 2021 年 6 月 12 日定植至 2021 年 9 月 24 日,在南京林业大学软件工程实验室进行。

1.1 数据集

本研究所使用的试验数据集均来自公开数据集 PlantVillage^[14],PlantVillage 数据集包含多种植物叶片图像和相应的标签。本研究所使用的苹果病害叶片类型分别是黑星病、黑腐病、雪松锈病,具体见图 1。其中,叶片黑星病的图片共有 630 张,叶片黑腐病的图片共有 621 张,叶片雪松锈病共有 275 张,总共 1 526 张。



图1 3种苹果树叶片病害展示

将所有数据集按照 9 : 1 划分为训练集和测试集。为了得到更好的检测效果,须要对叶片图像进行预处理,由于图片的尺寸不一,产生很多冗余信息。通过编写 python 脚本把叶片图像尺寸统一调整到 224 × 224 × 3 像素。

1.2 图像标注

数据集的标注同样也是深度学习中非常重要的一个环节,所标注的图片质量直接决定了模型训练效果和目标检测准确率^[15]。就普通对象而言,标注框需要紧贴目标对象边缘,且误差必须小于 2 个像素点(图 2-a)。但是,苹果树叶片病害是一个极特殊的对象,它没有清晰的轮廓,纹理特征较为复杂。这种“不确定性”给数据标注带来了极大的困难,目前病害识别领域尚未有一种公认的危害标注

规则。Lee 等针对该问题做了深入的研究,并提出了 3 种不同病害标注策略^[16]。本研究以苹果树叶片黑腐病为例展示病害的 3 种标注策略,具体见图 3。

本研究使用 YOLOv5 模型和 EfficientDet 模型同时训练苹果树叶片数据集。首先需要完成数据集的标注任务。本研究使用 labelImg 软件对图像采用混合标注法(对病害区域分块标注)进行手工标注,具体操作方法是:对图片中的病害点进行标注并附上自定义的标签。程序会自动生成一个 xml 文件,一个 xml 文件主要由图片名称、图像尺寸、标注矩形框坐标、目标物类别等组成。

下面以苹果叶片黑腐病为例展示数据的标注和标注后的结果。图中绿色的框表示标注的病害

位置。标注后生成的 xml 文件如图 2-b 所示。

1.3 YOLOv5

YOLO 的全称为 you only look once, 由 Redmon 等提出, 是一种单阶段目标检测算法^[17]。YOLOv5 在 YOLOv4 算法的基础上做了进一步的改进, 检测性能得到进一步的提升。持续的改进使得这个目标检测模型在 2 个官方数据集 (Microsoft COCO^[18]、Pascal VOC^[19]) 取得很好的检测效果。它因具有体积小、速度快、高精度等优点而被当今学术研究者广泛使用。YOLOv5 的具体结构见图 4。本研究采用 YOLOv5 作为第 1 个目标检测模型有 3 个原因。首先, YOLOv5 将跨阶段部分网络 (CSPNet^[20]) 并入了 Darknet, 创建了 CSPDarknet 作为其主干网络。CSPNet 解决了大规模主干网中梯度信息重复的问

题, 将梯度变化集成到特征图中, 从而减少了模型的参数和浮点运算, 不仅保证了推理的速度和准确性, 还减小了模型的体积。在苹果叶片病虫害检测任务中, 检测速度和精度是必不可少的, 紧凑的模型尺寸也决定了其在资源贫乏的边缘设备上的推断效率。其次, YOLOv5 应用路径聚合网络 (PANet^[21]) 作为其特征融合网络 (Neck), 以促进信息流。PANet 采用了一种新的特征金字塔网络 (FPN) 结构, 增强了自底向上的路径, 提高了底层特征的传播。最后, YOLOv5 的输入端采用了 Mosaic 数据增强方式、可丰富检测的数据集来增强识别能力。YOLOv5 包含多种常用的网络模型权重文件, 如 YOLOv5s、YOLOv5m 等。本研究采用的是 YOLOv5s, 它有体积小、权重低、运算速度快等优势。



图2 苹果叶片病害标注图像和标注后文件

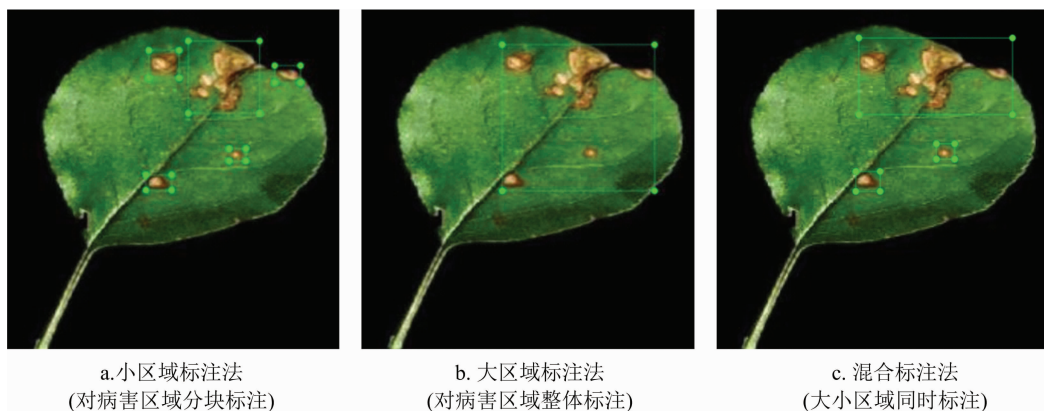


图3 3 种不同病害标注策略

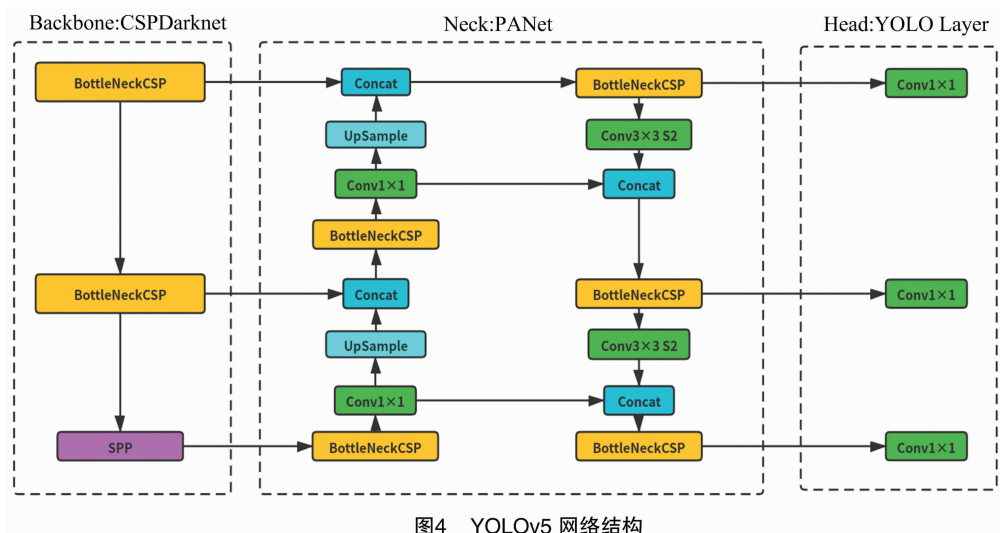


图4 YOLOv5 网络结构

YOLOv5 模型不仅能成功分类病害所属类别,还能准确地定位病害产生的位置,这对果农和专家判断苹果叶片是否有病害起着非常关键的作用。

YOLOv5 网络结构主要包含:主干网络(Backbone) CSPDarknet、特征融合网络(Neck) PANet、前端网络(Head) Yolo 层三大部分。

1.4 EfficientDet

EfficientDet 是 Google 公司开发的一个新的目标检测模型,在广泛的资源限制下,它始终比现有技术实现更高的效率^[22]。与 YOLOv5 类似,EfficientDet 在 Pascal VOC 和 Microsoft COCO 任务中也取得了显著的性能,并广泛应用于现实研究中。

EfficientDet 的网络架构如图 5 所示。本研究选择 EfficientDet 作为第 2 个模型有 3 个原因。首先,EfficientDet 采用最先进的网络 EfficientNet^[23] 作为其主干网络,使得该模型能够充分学习各种苹果叶片病虫害的复杂纹理特征。其次,它采用了一种改

进的 PANet,称为双向特征金字塔网络(Bi-FPN)作为其特征融合网络,以实现简单快速的多尺度特征融合。与 YOLOv5 特征融合网络相比,Bi-FPN 具有参数少、重复次数少的优点。同时,不同的特征融合策略带来了不同的语义信息,从而带来了不同的检测结果。最后,与 EfficientNet 类似,它集成了一种复合缩放方法,可同时对所有主干网络、特征融合网络和类别预测网络的分辨率、深度和宽度进行统一缩放^[24]。在有限的计算资源下,确保了最大的准确性和效率。第 2 个模型 EfficientDet 拥有不同的主干网络、特征融合网络和前端网络,可以学习 YOLOv5 无法学习的信息。

它包括主干网络(Backbone) EfficientNet、特征融合网络(Neck) Bi-FPN、前端网络(Head) 3 个部分。与 YOLOv5 类似,数据首先输入 EfficientNet 网络中进行特征提取,然后送入特征融合网络进行特征融合。最后,再由前端网络输出模型的检测结果。

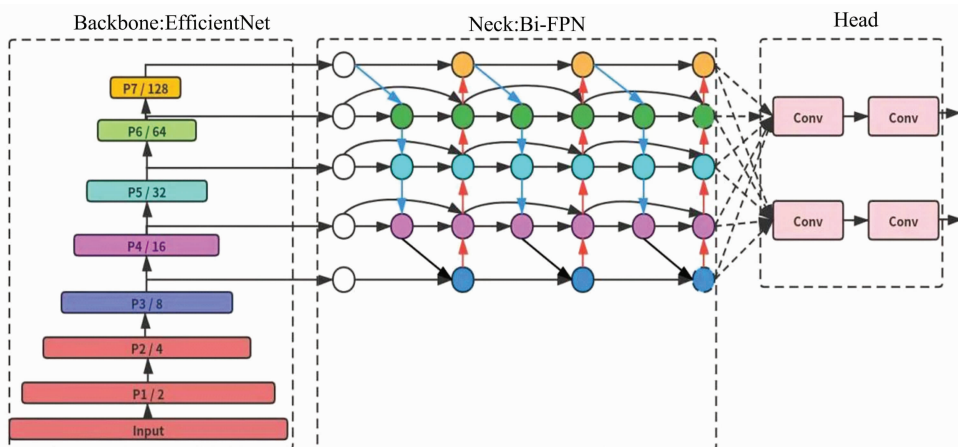


图5 EfficientDet 网络体系结构

1.5 YEUnion 集成模型

在实际的苹果树叶片病害检测问题上,由于叶片病害的纹理是动态变化的。不同发病期、不同地区的气候条件、种植条件等因素都会对病害目标大小、特征颜色、区域分布产生影响,这给苹果树叶片病害的检测带来很大困难。

以 YOLOv5 和 EfficientDet 为例,YOLOv5 擅长大面积病虫害的检测,对小目标的检测困难且会发生漏检问题。与此同时,尽管 EfficientDet 对大面积

叶面病虫害检测敏感度较低,但它比 YOLOv5 更为“仔细”,可以同时识别出叶片中尽可能多的病害。

因此,本研究提出一种高效的集成策略——YEUnion(图6)。集成2个单独的模型,实现模型间的优势互补,以输入苹果树叶片黑星病为例,经过2个模型并行处理、后经过非极大值抑制^[25](non-maximum suppression, NMS)算法去除冗余框,最后完成苹果树叶片病害的检测。

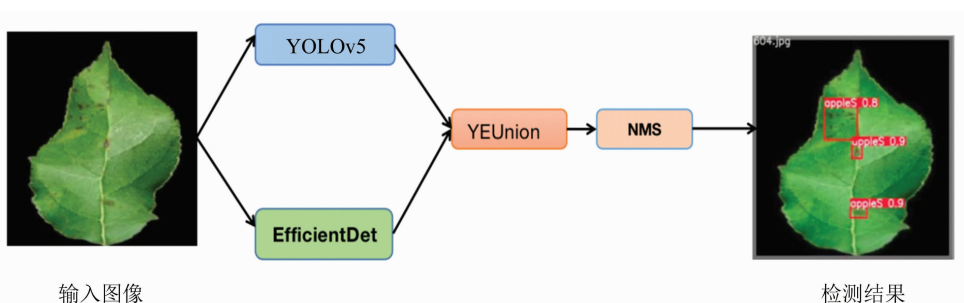


图6 集成模型架构图

具体实现方法是:首先用 YOLOv5 和 EfficientDet 分别对输入图像进行预测,生成各自的预测框,记 YOLOv5 生成的预测框为 $B^x = \{b_1^x, \dots, b_N^x\}$, EfficientDet 生成的预测框为 $B^y = \{b_1^y, \dots, b_N^y\}$,然后将所有预测框汇总,记为 $B = B^x \cup B^y$ 。

以苹果树叶片黑腐病为例,汇总后的预测框大致分为图7中的3种情况:图7-a中,YOLOv5(蓝色标注)和 EfficientDet(黄色标注)检测模型均正确识别出了上下2个病害点;图7-b中,YOLOv5 检测模型识别出了下面的病害点而 EfficientDet 检测模型识别出了上面的病害点;图7-c中,YOLOv5 识别出了上面的病害点而 EfficientDet 识别出了下面的病害点。针对这3种情况,本研究采用非极大

值抑制算法,其伪代码见表1。该算法的原理是将一个目标对应的所有预测框按预测分数高低进行排序,然后以分数最高的预测框为基准,分别计算与其他预测框的交并比,最后将交并比超过阈值(默认为0.5)的预测框视为冗余框并将它们移除。因此,图7-a中的冗余预测框将被移除,只保留预测分数最高的框。此外,图7-b和图7-c中分别来自2个模型的预测框也均被保留,实现了个体模型之间的优势互补,进而减少了漏检问题。

2 试验结果与分析

2.1 试验环境及参数设置

本试验于2021年在谷歌云实验室(Google

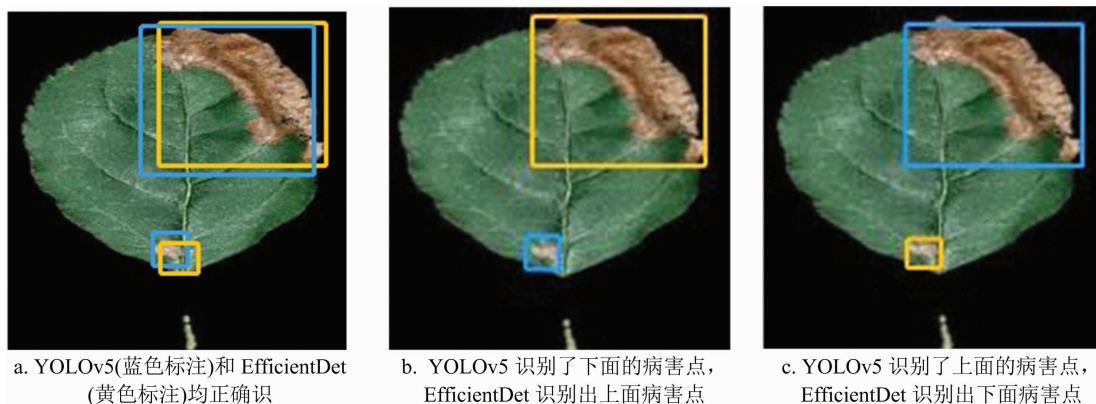


图7 YOLOv5 和 EfficientDet 的预测框发生重叠

表 1 非极大值抑制算法伪代码

Algorithm 1. Non - Maximum Suppression(NMS)

Input: $B = B^x \cup B^y = \{b_1^x \cdots b_N^x, b_1^y \cdots b_N^y\}$, $S = S^x \cup S^y = \{s_1^x \cdots s_N^x, s_1^y \cdots s_N^y\}$, N_t
B : YOLOv5 和 EfficientDet 预测框的集合
S : 对应预测框的预测分数
N_t : NMS 阈值
begin
$D \leftarrow \{\}$
While $B \neq \text{empty}$ do
$m \leftarrow \operatorname{argmax} S$
$M \leftarrow b_m$
$D \leftarrow D \cup M$; $B \leftarrow B - M$
for b_i in B do
if $\operatorname{IOU}(M, b_i) \geq N_t$ then
$B \leftarrow B - b_i$; $S \leftarrow S - s_i$
end
end
end
Return D, S
end

Colaboratory)完成训练和测试过程。

谷歌云实验室的配置可参考表 2。在训练数据之前,将试验数据集按照 9 : 1 划分为训练集和测试集。只有训练集参与实际的模型训练过程,而测试集只用来评估模型的精度。试验中 YOLOv5 模型和 EfficientDet 模型训练的细节见表 3。

表 2 试验环境配置

试验环境	配置参数
编程语言	Python 3.7
深度学习框架	PyTorch 1.9.0
GPU	Tesla T4
GPU 加速包	CUDA:11.2
操作系统	Ubuntu 18.04.5 LTS

表 3 模型训练的细节

模型	训练集 数据 (个)	测试集 数据 (个)	优化器	学习率	批处理 尺寸 (个)	迭代 次数 (次)
YOLOv5 - S	1 373	153	SGD ^[26]	1×10^{-2}	12	300
EfficientDet - D0	1 373	153	AdamW ^[27]	1×10^{-4}	12	300

2.2 试验结果

为了验证本试验所提出的模型,采用 mAP@.5、参数量来评价模型的好坏。目标检测中常用的用来评价模型好坏的指标还有 mAP@ [.5:.95]。

mAP@.5 指在交并比(IOU)阈值为 0.5 时的所有类别的平均精度。本研究所使用的精度(AP)指单个类别的平均精度,通常该值越大,表明模型学习的效果越好,反之则越差。mAP 的计算方法:先计算每一类别的 AP,AP 是 P - R 曲线围成的面积,P 和 R 分别指查准率、查全率,然后再计算所有类别的平均值^[28]。模型的参数量直接决定了模型计算的空间复杂度。

查准率 = 成功检测到的病害图片数量 / (成功检测到的病害图片数量 + 检测错误的病害图片数量)。

查全率 = 成功检测到的病害图片数量 / (成功检测到的病害图片数量 + 没有检测到的病害图片数量)。

2.3 结果分析

由表 4 的试验数据可知,从检测精度分析,本研究提出的 YEUnion 模型对 3 种苹果叶片病害的检测精度均有明显提升。在 IOU 阈值为 0.5 的情况下,其 mAP 为 73.4%,和单个模型 YOLOv5 和 EfficientDet 相比分别提高了 3.0%、4.8%。EfficientDet 模型检测结果最低,因为本研究所使用的权重文件是 EfficientDet - D0,该权重文件在 EfficientDet 家族中参数量最小且运算速度较快。因此,综合考虑试验的结果,在检测精度、算法运算的空间复杂度方面,本研究所提出的 YEUnion 模型具有更强的抗干扰能力,能够更好地区分复杂背景和特征点,能更有效地完成 3 种苹果叶片病害的检测工作。

表 4 3 个模型的检测结果

模型	AP(%)			mAP (%)	参数量 (M)
	黑星病	黑腐病	雪松锈病		
YOLOv5 - S	81.2	57.4	72.5	70.4	2.7
EfficientDet - D0	78.6	56.8	70.5	68.6	3.9
YEUnion	84.5	61.2	74.6	73.4	6.6

3 结论

本研究提出了一种基于集成学习的苹果树叶片病害检测模型,解决了实际条件下苹果树叶片病害图像由于背景重复、病斑较小而带来的漏检问题。提出使用 YOLOv5 和 EfficientDet 模型并行执行的新方法。由于 YOLOv5 模型适合大区域型的病害检测,EfficientDet 模型比 YOLOv5 的检测更加“仔细”,二者可以实现优势互补,可有效提高模型的性

能。通过试验证明,本研究提出的模型对 3 种苹果叶片病害检测的平均精度均值可达 73.4%,在实际的苹果叶片病害检测方面更具有实用性。

试验结果表明,集成学习的策略显著改善了果树叶片病害检测任务中普遍存在的漏检问题。与单个的目标检测器相比,本研究的模型在平均准确率、算法空间复杂度之间实现了更好的折中。这些重大改进使该模型能够在实际病虫害检测应用中表现良好,本研究提出的基于集成学习的方法在病害检测任务中取得了不错的效果。

参考文献:

- [1] 乔社茹. 苹果叶部病害的识别与防治[J]. 山西林业科技, 2020, 49(2): 55–57.
- [2] 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.
- [3] 周敏敏. 基于迁移学习的苹果叶面病害 Android 检测系统研究[D]. 杨凌: 西北农林科技大学, 2019.
- [4] Jiang P, Chen Y H, Liu B, et al. Real-time detection of apple leaf diseases using deep learning approach based on improved convolutional neural networks[J]. IEEE Access, 2019, 7: 59069–59080.
- [5] 邸洁, 曲建华. 基于 Tiny-YOLO 的苹果叶部病害检测[J]. 山东师范大学学报(自然科学版), 2020, 35(1): 78–83.
- [6] 李鑫然, 李书琴, 刘斌. 基于改进 Faster R-CNN 的苹果叶片病害检测模型[J]. 计算机工程, 2021, 47(11): 298–304.
- [7] 李鑫然. 基于深度学习的苹果叶片病害检测方法研究[D]. 杨凌: 西北农林科技大学, 2021.
- [8] 鲍文霞, 吴刚, 胡根生, 等. 基于改进卷积神经网络的苹果叶部病害识别[J]. 安徽大学学报(自然科学版), 2021, 45(1): 53–59.
- [9] 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.
- [10] 曹珊珊. 苹果内部缺陷的无损检测研究[D]. 保定: 河北农业大学, 2020.
- [11] Yadav D, Akanksha, Yadav A K. A novel convolutional neural network based model for recognition and classification of apple leaf diseases[J]. Traitement Du Signal, 2020, 37(6): 1093–1101.
- [12] Ultralytics. YOLOv5 [Z/OL]. (2021-09-01) [2021-10-02]. <https://github.com/ultralytics/yolov5>.
- [13] Tan M X, Pang R M, Le Q V. EfficientDet: scalable and efficient object detection[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA, 2020: 10778–10787.
- [14] PlantVillage Dataset[DS/OL]. (2021-08-01) [2021-10-02]. <https://www.kaggle.com/abdallahalidev/plantvillage-dataset>.
- [15] 普措才仁, 秦亚红. 基于深度学习模型的非结构化数据标注方法研究[J]. 西北民族大学学报(自然科学版), 2020, 41(2): 14–19, 44.
- [16] Lee Y, Im D, Shim J. Data labeling research for deep learning based fire detection system[C]//2019 International Conference on Systems of Collaboration Big Data, Internet of Things & Security (SysCoBioTS). 2019, Casablanca, Morocco, 2019: 1–4.
- [17] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA. IEEE, 2016: 779–788.
- [18] Lin T Y, Maire M, Belongie S, et al. Microsoft coco: common objects in context[C]//European Conference on Computer Vision. Springer, Cham, 2014: 740–755.
- [19] Everingham M, Eslami S M A, Gool L, et al. The pascal visual object classes challenge: a retrospective[J]. International Journal of Computer Vision, 2015, 111(1): 98–136.
- [20] Wang C Y, Liao H Y M, Wu Y H, et al. CSPNet: a new backbone that can enhance learning capability of CNN[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Seattle, WA, USA, 2020: 1571–1580.
- [21] Liu S, Qi L, Qin H F, et al. Path aggregation network for instance segmentation[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA, 2018: 8759–8768.
- [22] Tan M X, Pang R M, Le Q V. EfficientDet: scalable and efficient object detection[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA, 2020: 10778–10787.
- [23] Tan M X, Le Q V. Efficientnet: Rethinking model scaling for convolutional neural networks[C]//36th International Conference on Machine Learning. California, 2019: 6105–6114.
- [24] 陈志韬, 殷恺铭, 张洋, 等. 基于 EfficientDet 的安全帽佩戴检测研究[J]. 信息技术与标准化, 2021(增刊1): 19–23, 29.
- [25] Neubeck A, Van Gool L. Efficient non-maximum suppression[C]//18th International Conference on Pattern Recognition (ICPR'06), Hong Kong, 2006: 850–855.
- [26] Bottou L. Large-scale machine learning with stochastic gradient descent[M]//Lechevallier Y, Saporta G. Proceedings of COMPSTAT'2010. New York: Physica-Verlag HD, 2010: 177–186.
- [27] Loshchilov I, Hutter F. Decoupled weight decay regularization[C]//ICLR 2019, 2019.
- [28] 张志达, 黄鹏, 刘洋, 等. 基于 YOLO 算法与深度学习的证件质量检测系统[J]. 单片机与嵌入式系统应用, 2021, 21(7): 67–70.