

# 改进 YOLOv3 算法检测三七叶片病害

文 斌<sup>1</sup>, 曹仁轩<sup>1</sup>, 杨启良<sup>2</sup>, 张 健<sup>2</sup>, 朱 晗<sup>1</sup>, 李知聪<sup>1</sup>

(1. 三峡大学电气与新能源学院, 宜昌 443000; 2. 昆明理工大学现代农业工程学院, 昆明 650500)

**摘 要:** 为了解决三七叶片密集病害和小区域病害检测不准确的问题, 该研究提出了一种改进的 YOLOv3 (You Only Look Once v3) 目标检测算法 (AD-YOLOv3) 对三七叶片各种病害进行检测。AD-YOLOv3 使用注意力特征金字塔 (Attention Feature Pyramid, AFP) 替代 YOLOv3 中的原始特征金字塔, 解决了特征融合过程中的干扰问题, 提升了病害检测精度。使用双瓶颈层 (Dual Bottleneck, DB) 筛选注意力特征金字塔提取到的特征, 增强特征的特异性, 提升了算法的鲁棒性。AD-YOLOv3 与 YOLOv3 相比在各项性能指标上均有提升, 精确率提升 2.83 个百分点,  $F1$  精度提升 1.68 个百分点, 平均精度均值 (Mean Average Precision, mAP) 提升 1.47 个百分点, 针对小区域病害和密集病害的检测能力明显增强。此外, AD-YOLOv3 在雾, 雨, 暗光等复杂环境下的抗干扰能力明显提升, 该研究为三七叶片的病害检测提供了一种更优的智能检测方法。

**关键词:** 算法; 病害检测; YOLOv3; 特征金字塔; 双瓶颈层; 注意力机制; 三七

doi: 10.11975/j.issn.1002-6819.2022.03.019

中图分类号: TP391.4

文献标志码: A

文章编号: 1002-6819(2022)-03-0164-09

文斌, 曹仁轩, 杨启良, 等. 改进 YOLOv3 算法检测三七叶片病害[J]. 农业工程学报, 2022, 38(3): 164-172.

doi: 10.11975/j.issn.1002-6819.2022.03.019 <http://www.tcsae.org>

Wen Bin, Cao Renxuan, Yang Qiliang, et al. Detecting leaf disease for *Panax notoginseng* using an improved YOLOv3 algorithm[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2022, 38(3): 164-172. (in Chinese with English abstract) doi: 10.11975/j.issn.1002-6819.2022.03.019 <http://www.tcsae.org>

## 0 引 言

三七是中国的名贵中草药, 具有止血, 散瘀, 止痛等功效<sup>[1]</sup>。近年来, 市场对三七的需求量已经超过了 9 000 t, 为了满足市场的需求, 三七的人工培育面积不断扩大<sup>[2]</sup>, 但其作为一种典型的阴生植物, 人工培育需要在遮荫环境下进行, 而这种独特的培养环境容易诱发多种病害问题<sup>[3]</sup>, 如何准确识别其各种病害已成为一个亟待解决的问题。

传统三七叶片病害的检测方法主要包括人工识别和生物试剂检测等。王志敏等<sup>[4]</sup>提出使用人工检疫法来识别三七的若干种病害。杨涛等<sup>[5]</sup>提出使用人工抗病性鉴定识别三七的病害。李欣<sup>[6]</sup>采用基因生物学方法对三七的多种病害进行检测。传统病害检测方法实时性不高, 由于病害种类的多样性, 识别的准确性也难以保证。随着病害检测技术的发展, 传统图像处理方法被用于农作物的病害检测, 这些方法基于阈值分割<sup>[7-9,10-11]</sup>, 颜色空间转换<sup>[10,12]</sup>等技术, 识别精度高于人工识别方法, 但算法的构建比较复杂, 检测速度较慢。

近年来, 深度学习技术快速发展, 基于深度学习的目标检测算法不需要人为设计复杂的特征, 它能自动提取图像中的各种抽象特征, 并根据提取结果进行目标的

分类和定位, 大幅提高了目标检测效率<sup>[13-16]</sup>。研究者们引入了多种基于深度学习的目标检测算法用于农作物病害检测。Patarapuwadol 等<sup>[17]</sup>使用 YOLOv3 算法进行水稻病害的检测, 并将算法部署到了服务器端。黄丽明等<sup>[18]</sup>将改进后的 YOLOv4 算法用于松材线虫病的检测, 检测的平均精度达到了 80.85%。Tassis 等<sup>[19]</sup>将多种卷积神经网络进行集成用于咖啡作物的病虫害检测, 该网络不仅能够达到很好的检测效果, 而且适合于客户端部署。李就好等<sup>[20]</sup>将改进后的 Faster-RCNN 算法用于苦瓜叶片的病害检测, 平均检测精度达到了 86.39%。Sun 等<sup>[21]</sup>改进了 SSD 算法, 提出了 MEAN-SSD 算法并将其用于苹果叶片病害的检测, 平均检测精度达到了 83.12%。基于深度学习的目标检测算法, 具有检测速度快、检测精度高的特点, 这为农作物的病害检测问题提供了新的方法<sup>[22]</sup>。

在三七叶片的病害检测中, 使用计算机视觉技术进行识别的案例极少。罗匡男等<sup>[23]</sup>使用传统图像算法结合机器学习算法对三七叶片典型病害进行检测, 平均准确率均达到 80%以上。但该方法需要人工选取阈值以提取叶片病害的边缘信息, 阈值选取的好坏会对检测结果产生很大影响, 且该方法仅针对三七叶片的两种病害, 其余种类的病害检测并未涉及, 算法缺少普适性。曹春号<sup>[24]</sup>使用 Faster-RCNN 算法配合手机 App 实现了三七叶片病害的在线检测。该方法克服了人为设计特征量的缺点, 并且能检测多种病害, 提高了三七叶片病害检测的实时性和准确性。但 Faster-RCNN 的模型结构十分庞大, 算法的检测速度较慢, 不适合在移动设备中部署。熊凯<sup>[25]</sup>使用不同版本的 YOLOv5 算法进行三七叶片病害的检

收稿日期: 2021-08-18 修订日期: 2021-11-27

基金项目: 国家自然科学基金项目 (61876097)

作者简介: 文斌, 讲师, 主要研究方向为数字视频信号处理。

Email: wenbin\_08@126.com

测, 检测的平均精度最高达到了 89.22%。YOLOv5 是 YOLO 系列算法截至目前的最新版, 检测速度和精度都能达到较高标准, 但算法实现比较复杂。

为了获得兼具速度和精度且易于实现的病害检测方法, 研究者通常会选择 YOLOv3 算法。但在三七叶片的病害检测中存在病害区域密集和病害区域小的问题, YOLOv3 算法对于密集目标和小目标的检测能力有限, 当病害区域过小或过于密集时, 容易出现漏检现象, 为了解决这些问题, 本文改进了 YOLOv3 算法, 引入注意力特征金字塔解决 YOLOv3 特征金字塔特征融合时的噪声干扰问题。引入双瓶颈层对注意力特征金字塔的输出特征再次筛选, 获取核心特征, 舍弃无效特征, 提高模型的鲁棒性, 综合两种改进方法提出了 AD-YOLOv3 算法用于三七叶片病害的检测。

## 1 三七叶片病害检测算法

### 1.1 YOLOv3 算法

YOLO 系列算法通过卷积神经网络对图像进行特征提取, 对提取结果进行一系列后处理, 最后根据处理结果进行目标检测。相比于其他目标检测算法, YOLO 算法的特点是兼具精度和速度, 这使得工程部署成为可能<sup>[26]</sup>。YOLOv3 作为 YOLO 系列的第三个版本, 其使用了新型特征提取网络 Darknet53, 增强了主干网络的特征提取能力。此外还引入了多尺度检测, 提高目标检测的精度和

效率。YOLOv3 进行目标检测时会把图像分成  $M \times M$  个网格, 每个网格配备三种大小不同的边框作为初始检测框, 每个检测框有  $N+5$  个参数,  $N$  代表该检测任务中目标的类别总数, 5 个参数分别表征检测框中心的横纵坐标, 框的宽度和高度, 以及框中含有目标的置信度, 通过反复调整检测框与实际目标的位置来匹配目标, 最后通过非极大值抑制 (Non-Maximum Suppression, NMS) 算法进行检测框的最后确定<sup>[27]</sup>。

### 1.2 改进的 YOLOv3 算法: AD-YOLOv3

本研究使用注意力特征金字塔 (Attention Feature Pyramid, AFP) 替代了原始特征金字塔结构, 并且引入了双瓶颈层 (Dual-Bottleneck, DB) 对提取的特征进行后处理, 改进后的算法称为 AD-YOLOv3, 其结构如图 1 所示。

AD-YOLOv3 使用 Darknet53 作为特征提取网络对输入图像进行特征提取, 与 YOLOv3 算法不同的是, AD-YOLOv3 在特征提取完毕后使用注意力特征金字塔对提取到的特征进行聚合与筛选, 然后使用双瓶颈层对特征进行增强, 最后通过后续卷积层进行处理得到 3 种不同尺寸 ( $20 \times 20 \times 33$ 、 $40 \times 40 \times 33$ 、 $80 \times 80 \times 33$ ) 的特征图进行检测, 特征图尺寸的前两个维度代表其宽度和高度, 最后一个维度代表检测数据, 由于需检测的病害一共有 6 种, 特征图的每个网格有 3 种检测框, 由前一节公式可得各尺寸特征图上均预测 33 个数据。

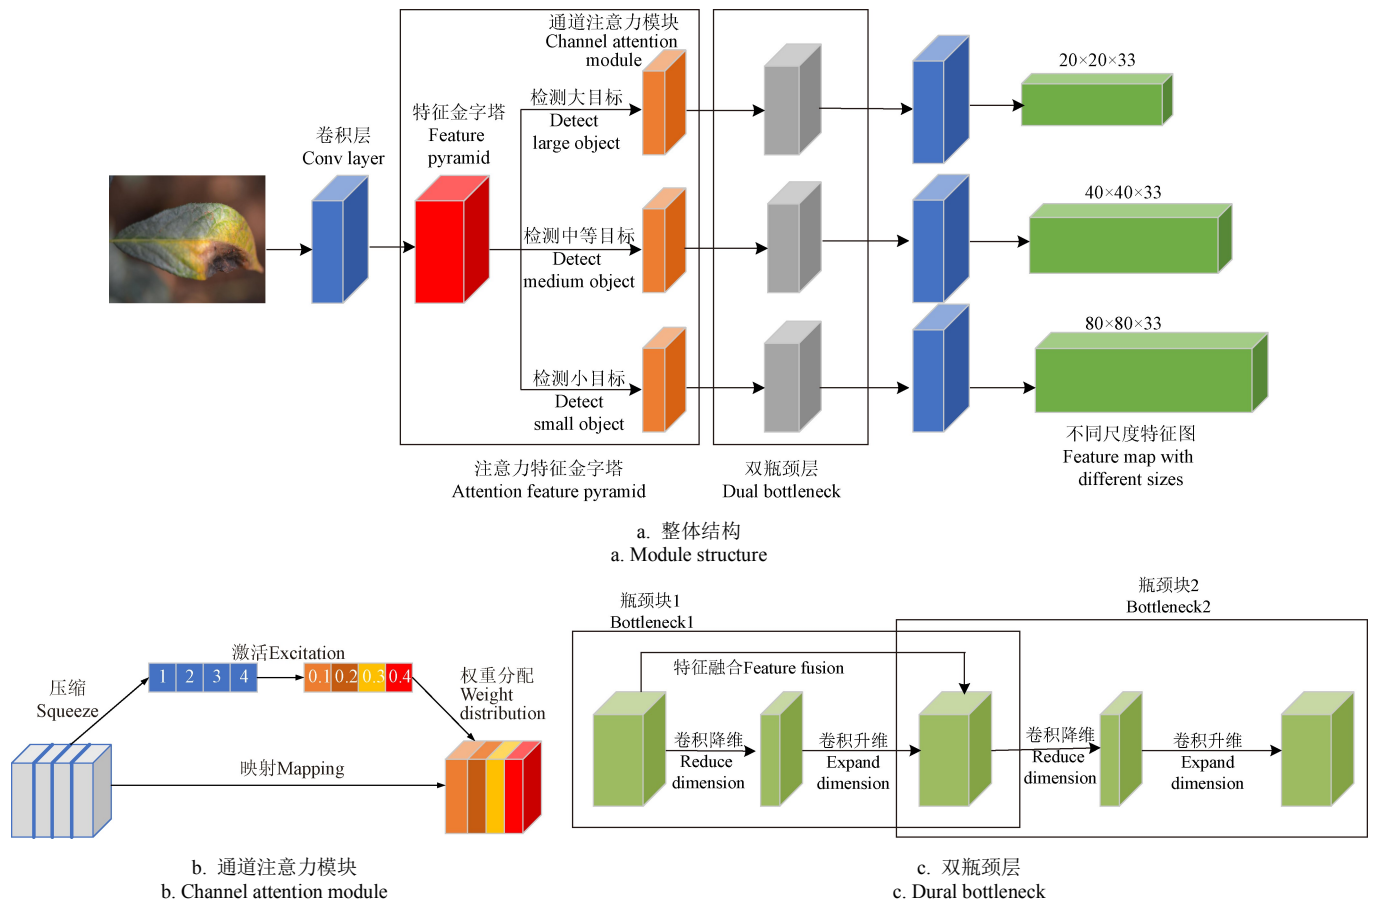


图 1 AD-YOLOv3 与改进模块结构

Fig.1 AD-YOLOv3 and improved module structure

### 1.2.1 注意力特征金字塔 (AFP)

特征金字塔作为一种融合信息的结构,其工作流程为:从原始图像开始进行特征提取,直至最深层特征图。使用最深层特征图作为第一个预测特征层,同时对其进行上采样,使其尺寸扩大为原来的两倍,然后与浅层特征图进行融合得到新特征图进行预测<sup>[28]</sup>。

特征金字塔的优势是将浅层特征与深层特征进行融合,从而丰富预测特征层上的语义信息,增强算法对小目标和密集目标的检测能力。特征金字塔结构的问题在于深浅层特征图进行特征融合时,特征图本身的噪声特征也会被融合,进而干扰预测特征层上的预测效果。为了解决噪声对于融合特征的干扰问题,本文采用注意力特征金字塔替代原始特征金字塔,将原始特征金字塔的输出分别送入 3 个通道注意力模块,其结构如图 1a 所示。

注意力特征金字塔由特征金字塔与通道注意力模块 (Channel Attention Module, CAM) 组合而成。其核心的通道注意力模块能够对特征金字塔融合得到的不同特征图按通道权重进行重新划分,强化有效特征的同时抑制噪声,从而对特征金字塔的输出进行优化,其结构如图 1b 所示。

通道注意力模块包含两个分支,分别为掩码分支和映射分支,掩码分支对输入特征图的每个通道进行压缩和激活操作。本研究使用全局平均池化进行压缩,即对每个通道求平均值,用平均值表示通道的特征。相比于传统的全局最大池化方式压缩,全局平均池化能够较好地保存特征信息,减少信息的丢失,拥有更好的压缩效果。

特征图经过压缩后需要进行激活,即对各通道平均值进行非线性处理,增强特征的表达能力,同时将输出值限制在 0~1 内以表示各通道的权重。权重值与映射分支的初始特征图各通道相乘,即可得到按权重重新排列的特征图。通道注意力模块捕获通道之间的相关性,聚焦重要特征的同时抑制干扰特征,提高检测效果<sup>[29]</sup>。

注意力特征金字塔通过特征金字塔与通道注意力模块的组合,既能融合特征又能优化特征表达,能够提升模型的整体检测效果。

### 1.2.2 双瓶颈层 (DB)

YOLOv3 算法中,对于特征金字塔提取到的特征只是通过简单的无残差瓶颈块进行处理。这种处理过于简单,特征金字塔提取到的特征中的冗余部分会对最终检测结果产生不良影响,所以特征金字塔的后处理模块需要对特征进行进一步筛选,丢弃无关信息,只保留最有效信息,以达到最优的检测效果。因此提出双瓶颈层对注意力特征金字塔提取到的特征进行后处理,其结构如图 1c 所示。

双瓶颈层中前一个瓶颈块带有特征融合的残差结构,先用 1×1 尺寸卷积核对特征图进行卷积以降低维度减少计算量,然后使用 3×3 尺寸的卷积核提取特征并进行升维,最后使用残差结构的跳连接与原特征图进行特征融合,残差结构在深层神经网络中可以有效应对梯度消失问题,并且可以加快训练过程的收敛<sup>[30]</sup>。第二个瓶颈块不带残差结构,同样先对输入的高维特征进行降维

以减少模块参数量,然后再进行特征提取并升维,此时特征信息已足够丰富,后一个瓶颈块不再进行残差连接,减少计算资源的消耗。双瓶颈层中的两次降维卷积会造成特征的丢失,但其后的升维卷积可以通过有损特征进行整体特征重构,增强特征表达的鲁棒性。重构特征与原始特征相比,削弱了原始特征中的无关信息,并对有效特征进行了增强,因此双瓶颈层结构能够学习到数据中更重要的特征。

通过两种瓶颈块的组合,扩展了后处理卷积层的深度,使得网络的学习能力进一步增强。注意力特征金字塔提取到的特征经过双瓶颈层的反复升降维处理,得到最简洁有效的特征表达形式,增强了特征的特异性,从而达到更好的检测效果。

## 2 数据准备与模型训练

### 2.1 数据集制作

本次试验数据集三七叶片病害图像采集地点为云南省红河州泸西县午街铺镇昆明理工大学三七控水减排提质增效关键技术与示范基地 (24°25′~24°36′N, 103°42′~105°35′E, 海拔 1 796 m), 采集方式为基地摄像头拍摄,采集到明暗程度、叶片大小、病害种类各不相同的三七叶片图片共 1 886 张,全部裁剪到 640×640 像素大小,使用 LabelImg 工具对图片进行标注,最后按约 8:1:1 的比例将所有图片划分为训练集,验证集和测试集,其中训练集 1 500 张,验证集 186 张,测试集 200 张。数据集中包含的各类病害图片数量如表 1 所示。

表 1 各类病害图像数量表  
Table 1 Number of images of various diseases

病害类型 Disease type	图片数量 Number of images	训练集 Train set	验证集 Validation set	测试集 Test set
疫病 Plague	856	799	37	20
黄锈病 Rust disease	309	260	24	25
炭疽病 Anthrax	367	307	50	10
白粉病 Powderry mildew	571	401	36	134
圆斑病 Round spot	332	211	81	40
病毒病 Virosis	486	318	68	100

数据集中叶片病害一共有 6 类,分别为疫病、黄锈病、炭疽病、白粉病、圆斑病、病毒病。在试验中为了方便,将 6 种病害标记为类别 1~6,病害典型样本如图 3 所示。

### 2.2 试验环境及参数

本文全部试验由单计算机完成,计算机硬件配置为 Intel Core i5-3470 CPU@3.2GHz, GeForce RTX 2060Super GPU, 16G 运行内存,操作系统为 64 位 Windows 10, Pytorch 深度学习框架, Python3.7 编程语言, CUDA11.0 GPU 加速库。

训练过程中的批量尺寸 (Batchsize) 设置为 8, 初始学习率设置为 0.01, 动量设置为 0.937, 总训练轮数 (Epoch) 设置为 500, 使用 SGD 优化器进行优化, 保存精度最高的一次和最后一次的模型参数。训练过程使用 Warm up 方法加快模型收敛速度。

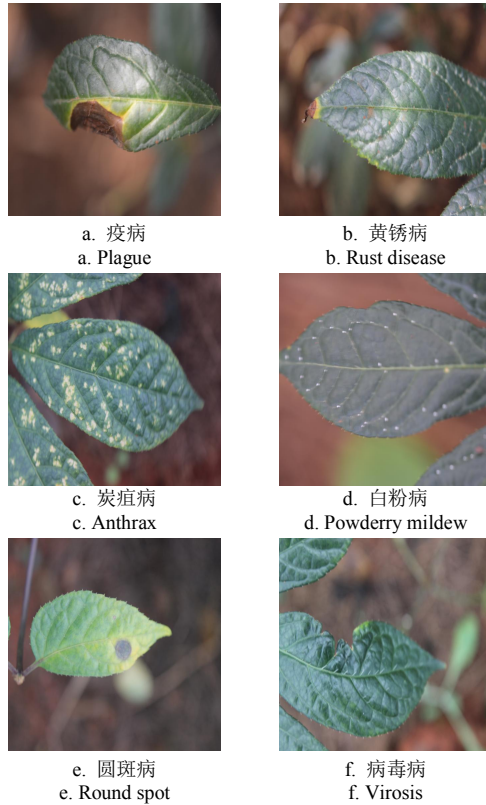


图 3 三七叶片病害图  
Fig.3 Leaf disease of Panax notoginseng

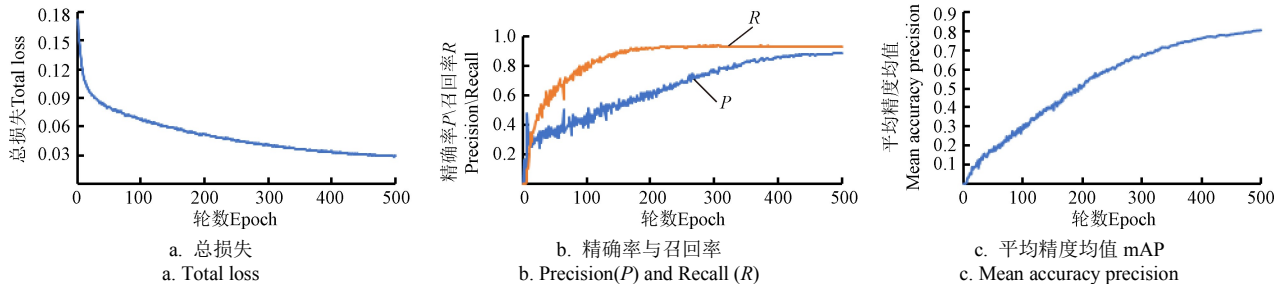


图 4 训练过程参数指标  
Fig.4 Parameters of training process

如图 4a 所示, 训练过程前 50 轮损失值下降速度最快, 50 轮之后损失下降速度逐渐变慢, 在训练轮数达到 500 次时, 损失曲线趋近于平缓, 表明模型精度已经达到了稳定值, 模型训练过程完毕。如图 4b、4c 所示, 随着训练轮数的增加, 总损失下降的同时, 准确率和召回率均不断上升, 训练至 500 轮时, 准确率和召回率分别达到 89.1% 和 93.6%, 同时 mAP 曲线也随训练轮数的增加而逐渐升高, 最终各类型病害检测的平均准确率能达到 80.6%, 训练过程中各曲线走势能够反映出训练的有效性。

### 3.2 综合检测性能对比

对 AD-YOLOv3 进行消融试验, 各性能指标如表 2 所示。由消融试验结果可得, 使用注意力特征金字塔改进后的模型在精确率上提升 1.35 个百分点,  $F1$  精度提升 0.87 个百分点, mAP 提升 0.31 个百分点。注意力特征金字塔对融合特征图按权重进行通道的重新排列, 使算法聚焦重要特征通道, 提升了检测精度。使用双瓶颈层改

### 2.3 评价指标

本研究使用精确率  $P$ , 召回率  $R$ , 整体精度  $F1$  以及类别平均精度 mAP 指标对试验结果进行评估。精确率表征算法检测到的所有目标的准确率, 召回率表征算法检测目标的全面性,  $F1$  精度表征算法在准确率和召回率上的综合性能, mAP 表征算法在不同类别上的平均检测精度。计算公式如下:

$$P = \frac{TP}{TP+FP} \times 100\% \quad (3)$$

$$R = \frac{TP}{TP+FN} \times 100\% \quad (4)$$

$$F1 = 2 \div \left( \frac{1}{P} + \frac{1}{R} \right) \quad (5)$$

$$mAP = \frac{\int_0^1 P(r) dr}{N} \quad (6)$$

式中  $TP$  为算法检测正确的目标数量;  $FP$  为算法检测错误的目标数量;  $FN$  为算法漏检的目标数量;  $N$  为检测的类别总数;  $P(r)$  为以召回率  $r$  为自变量, 精确率  $P$  为因变量的函数。

## 3 试验与结果分析

### 3.1 AD-YOLOv3 模型参数调试

使用 AD-YOLOv3 算法在数据集上进行训练和测试。训练过程的总损失下降过程如图 4 所示。

进后的模型在精确率和  $F1$  精度上提升不大, 但 mAP 提升了 0.81 个百分点。双瓶颈层主要用于对特征进行再次筛选, 筛选前需保证特征足够精简。没有注意力特征金字塔的情况下, 进入双瓶颈层的特征包含了较多噪声, 筛选后的特征中也包含较多无用信息, 所以单独使用双瓶颈层对精度的提升并不明显。综合使用双瓶颈层与注意力特征金字塔后的模型在精确率提升了 2.83 个百分点,  $F1$  精度提升了 1.68 个百分点, mAP 提升了 1.47 个百分点。所有性能指标提升比较明显, 得益于注意力特征金字塔和双瓶颈层的联合使用。因此, 注意力特征金字塔可以提升算法的性能指标, 双瓶颈层能够起到特征修正作用, 两者配合使用能够实现较好的性能提升, 综合使用两种方法得到的 AD-YOLOv3 可以达到较好检测效果。

AD-YOLOv3 与其他算法模型的检测性能对比如表 3 所示, 试验对比了一阶目标检测算法中的 YOLOv3 模型和使用了跨阶段局部网络 (Cross Stage Partial Network,



CSPNet) 作为主干提取网络<sup>[31]</sup>的 CSPYOLOv3 模型, 此外还对比了二阶目标检测模型中检测效果较好的 Mask R-CNN<sup>[32]</sup>。

表 2 消融试验性能指标对比

网络设置 Network setting	注意力特征 金字塔 AFP	双瓶颈层 Dual bottleneck	准确率 Precision	召回率 Recall	F1 精度 F1 accuracy	mAP
-	-	-	86.26	93.18	89.59	79.08
√	-	-	87.61	93.51	90.46	79.39
-	√	√	86.51	93.42	89.84	79.89
√	√	√	89.09	93.56	91.27	80.55

表 3 不同模型检测性能对比

模型 Model	病害检测准确率 Disease detection precision/%						检测速度 Frames per second (/帧·s <sup>-1</sup> )	
	疫病 Plague	黄锈 病 Rust disease	炭疽病 Anthrax	白粉病 Powderry mildew	圆斑 病 Round spot	病毒 病 Virosis		
YOLOv3	77.2	76.2	85.1	67.9	85.4	82.7	79.1	24
CSPYOLOv3	72.5	71.6	81.0	64.1	80.1	79	74.7	22
Mask-RCNN	89.5	90.3	75.3	81.8	82.0	85.3	84.0	0.4
AD-YOLOv3	78.0	79.5	86.7	69.0	85.9	84.2	80.6	23

由表 3 可知, AD-YOLOv3 在所有类型病害的检测中准确率均优于 YOLOv3 与 CSPYOLOv3, 在平均精度均值 mAP 上 AD-YOLOv3 低于二阶检测模型 Mask-RCNN, 但在炭疽病和圆斑病检测中精度高于 Mask-RCNN。AD-YOLOv3 在 6 类病害的检测中对白粉病的检测效果较差, 原因是白粉病的多数病害区域过小, 在图片中所占像素点极少, 而 YOLO 系列算法恰好对于小目标的检测能力较弱, 因此算法对白粉病的检测效果不佳, 而二阶检测算法 Mask-RCNN 对小目标的检测能力较强, 在白粉病的检测中精度大幅领先 YOLO 系列算法。AD-YOLOv3 对 6 类病害中圆斑病的检测效果最好, 原因是圆斑病的特征十分明显, 病害区域和叶片正常区域有明显差异且病害区域较大, 因此模型对圆斑病的检测能够达到较好效果。

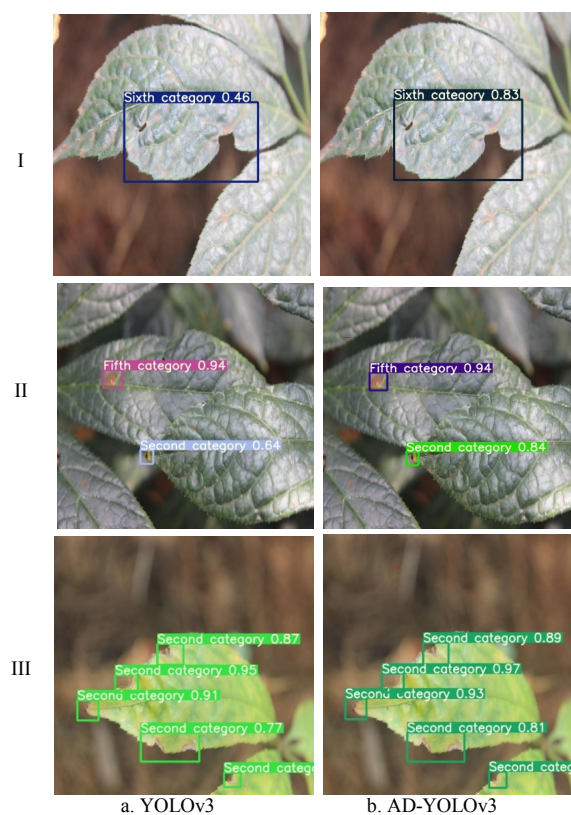
实际病害检测中, 需要考虑到算法的检测速度和模型的复杂度, 二阶检测模型 Mask-RCNN 虽然精度高, 但其构成相对复杂, 检测速度慢, 由表可知 AD-YOLOv3 每秒检测的图片数量几乎是 Mask-RCNN 的 60 倍。而相比于原始 YOLOv3, AD-YOLOv3 在速度几乎没有损失的情况下实现了多方面性能的提升。

### 3.3 置信度对比试验

随机选取含有少量病害、中等数量病害和密集病害且病害类型不同的多张图片对 YOLOv3 和 AD-YOLOv3 进行测试, 典型检测结果如图 5 所示。

两组图片中图 I 病害为病毒病; 图 II 有两种病害, 类别 2 为黄锈病, 类别 5 为圆斑病; 图 III 病害为黄锈病。图 I 中 AD-YOLOv3 模型检测出病毒病的置信度为 83%, 高于 YOLOv3 模型的 46%; 图 II 中, AD-YOLOv3 模型对于黄锈病的检测置信度为 84%, 高于 YOLOv3 模型的 64%。发病区域最多的图 III 中, AD-YOLOv3 模型对于

所有病害区域的置信度均高于 YOLOv3。置信度的提高说明 AD-YOLOv3 获取到了图像中更丰富的语义信息, 而语义信息的丰富得益于算法中深层特征图和浅层特征图的融合, 融合后的特征图能够达到更好的检测效果。



注: Sixth category 为病毒病, Fifth category 为圆斑病, Second category 为黄锈病。下同。  
Note: Sixth category represents Virosis, Fifth category represents Round spot, Second category represents Rust disease. Same below.

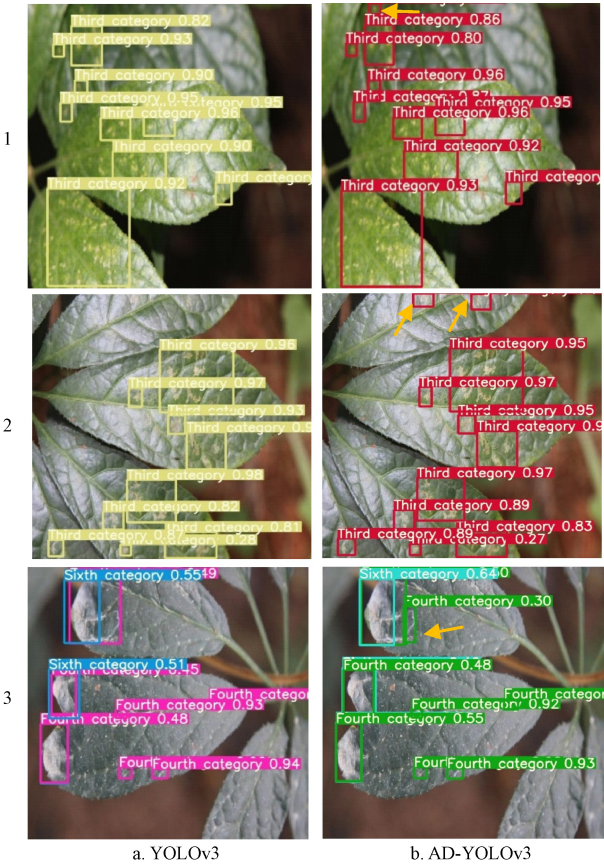
图 5 置信度对比图

Fig.5 Confidence comparison

### 3.4 密集病害检测试验

不同三七叶片的病害情况不同, 有些叶片存在多种病害, 有些叶片存在多个病害区域, 人工检测容易漏检, 而使用计算机检测能够提高检测精度。在测试集中随机选取多张存在易漏检病害区域的图片, 分别使用 YOLOv3 和 AD-YOLOv3 进行检测, 典型检测结果如图 6 所示。

两种模型对密集病害的检测结果如表 4 所示。YOLOv3 在图 1 和图 2 的大量炭疽病区域检测中存在漏检现象, 在图 3 的白粉病和病毒病混杂的病害区域中存在白粉病区域的漏检现象, 漏检区域在 AD-YOLOv3 检测结果图中已用箭头标出。AD-YOLOv3 检测出了不同种类病害中所有病害区域, 未出现漏检, 检测能力明显增强。在密集病害区域的检测中, 重叠的病害区域容易被忽略, 注意力特征金字塔通过通道注意力模块对融合特征按权重重新进行排列, 高权值特征通道的特征会更加显著, 即使密集区域发生了重叠现象, 该区域特征也会因为其高权重而得到保留, 在一定程度上解决了因重叠造成的密集区域漏检现象。因此, 注意力特征金字塔的引入有助于解决密集区域病害的检测问题。试验表明, AD-YOLOv3 在密集区域病害的检测中表现更好。



注：箭头标注为漏检区域，Third category 为炭疽病，Fourth category 为白粉病。下同。  
Note: Arrows represent missed areas. Third category represents anthrax; Fourth category represents powdery mildew. Same below.

图 6 密集病害检测  
Fig.6 Detection results of dense disease

表 4 密集病害检测结果统计表

Table 4 Detection results of dense disease summary table		病害区域数量 Disease region number		
模型 Model	图编号 Image No.	总数 Total	检出数 Discover	漏检数 Miss
YOLOv3	1	10	9	1
	2	11	9	2
	3	10	9	1
AD-YOLOv3	1	10	10	0
	2	11	11	0
	3	10	10	0

3.5 小区域病害检测试验

YOLO 算法对于小目标的检测能力较弱，三七叶片病害中存在较多发病面积小的病害，主要类型为早期炭疽病以及早期黄锈病以及极小区域的白粉病。为验证 AD-YOLOv3 对小区域病害的检测效果，从测试集小面积病害图片中选取多张含有典型早期黄锈病和早期炭疽病区域的图片进行测试，其典型检测结果如图 7 所示。

如图 7 所示，在不同病害类型的叶片中，原始 YOLOv3 模型对于小区域病害的检测均有漏检现象，漏检区域在 AD-YOLOv3 检测结果图中用箭头标出。图中病害区域小，分辨率低，在固定区域中能反映的信息少，卷积神经网络提取特征过程中经过多次下采样，很多小区域病害的特征信息已经丢失，导致小区域病害的漏检。

AD-YOLOv3 引入注意力特征金字塔对深层特征图进行上采样，通过深层特征信息对图像中的原始语义信息进行重构，最后将两者融合，使病害区域浅层位置信息和深层语义信息都能在融合特征图上进行反映，后续双瓶颈层对融合特征图进一步筛选，得到准确的小区域病害的特征信息，明显改善了小区域病害的检测效果。试验表明，引入了注意力特征金字塔和双瓶颈层结构的 AD-YOLOv3 能更好地检测出容易被忽略的小区域病害，在实际检测中能够达到更好的检测效果。

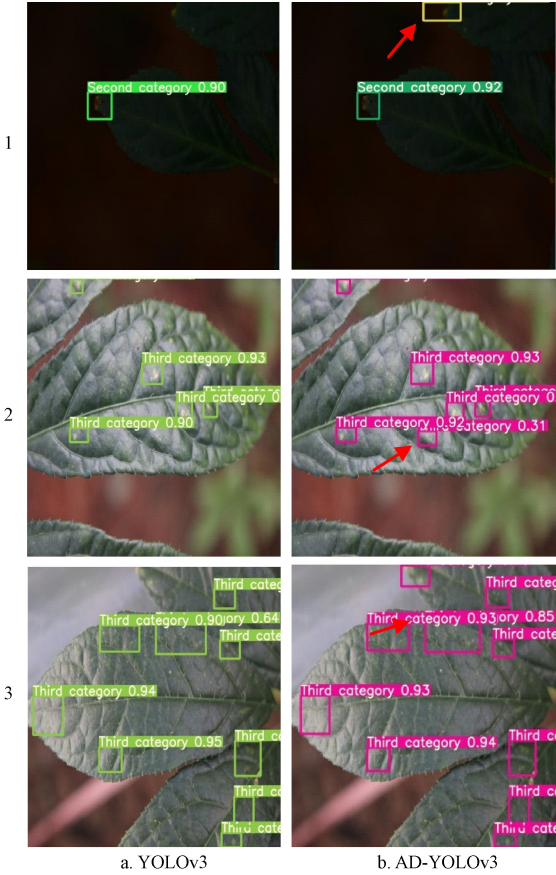


图 7 小区域病害检测  
Fig.7 Detection results of small region


3.6 算法鲁棒性对比试验

算法的鲁棒性是指算法在各种干扰情况下保持正常工作的能力，三七叶片病害的实际检测中存在各种环境干扰问题，例如在拍摄叶片图片时可能存在光线不足，雨雾干扰等问题，这就要求算法有较强的鲁棒性，能够在有干扰的情况下保证检测的准确性。随机选取测试图片并对图片进行雾化、加雨、降低亮度处理，并比较 YOLOv3 和 AD-YOLOv3 在雾，雨，暗光条件下的检测效果，结果如图 8 所示。

处于浓雾环境中的叶片病害类型分别为早期黄锈病和圆斑病。处于雨水环境中叶片病害为圆斑病与早期黄锈病，处于暗光条件下叶片病害类型为早期黄锈病。由 3 种干扰情况下检测结果可看出，在浓雾环境中，两种算法都能够检测出病害区域，但 AD-YOLOv3 检测出的结果置信度明显高于 YOLOv3；在雨水和暗光条件下，YOLOv3 出现了漏检现象，漏检区域在图 8 中用箭头标



出。雾,雨,暗光条件都会给检测带来困难,这是由于干扰因素改变了图像中的原始特征,卷积神经网络提取到的特征中包含了很多干扰信息,病害的表征受到了噪声影响,因此一些病害就可能无法被检出,为了应对这种情况,就需要提升算法的鲁棒性。AD-YOLOv3 使用了注意力特征金字塔对不同尺度的特征图进行特征的一次聚焦,关注重要特征的同时弱化干扰特征。通过特征的初次筛选后,特征又经过双瓶颈层进行二次筛选,两次特征筛选过程使 AD-YOLOv3 有很强的鲁棒性,提升了算法在干扰环境下的检测能力。试验和理论两方面都证明注意力特征金字塔和双瓶颈层结构增强了算法的鲁棒性,AD-YOLOv3 更适合实际环境下的三七叶片病害检测。



注: 箭头标注为漏检区域。  
Note: Arrows represent missed areas.

图 8 算法鲁棒性对比  
Fig.8 Comparison of algorithm robustness

## 4 结 论

本研究使用 YOLOv3 作为基础检测算法,使用注意力特征金字塔替换原算法中的特征金字塔,并在注意力特征金字塔结构后插入了双瓶颈层结构,对改进后的算法使用含有 6 种叶片病害的数据集进行训练,最后比较了改进算法与原算法在小目标病害和密集数量病害以及各种干扰环境下的检测效果,得出如下结论:

1) 相比于原始 YOLOv3 算法,注意力特征金字塔和

双瓶颈层均能提升算法的检测精确率和平均精度均值。注意力特征金字塔的引入对算法的精确率提升明显,双瓶颈层的引入对于算法平均精度均值的提升明显。

2) 改进算法在检测速度不变的情况下对 6 种病害的检测精确率均优于原始算法,注意力特征金字塔与双瓶颈层的引入对检测速度影响很小。

3) 改进算法在小目标病害和密集病害的检测上均优于原始算法并且算法的鲁棒性得到提升。相比于原始算法,改进算法的精确率提升了 2.83 个百分点, F1 精度提升了 1.68 个百分点,平均精度均值提升了 1.47 个百分点,性能指标提升明显。改进算法在雾、雨、暗光等干扰环境下也能达到较好检测效果。

## [参 考 文 献]

- [1] 于慧妍. 三七研究进展[J]. 世界最新医学信息文摘. 2017, 17(39): 21-22.  
Yu Huiyan. Research progress of *Panax notoginseng*[J]. 2017, 17(39): 21-22. (in Chinese with English abstract)
- [2] 李宏伟, 郭富贵, 刘洋, 等. 三七病虫害研究现状与展望[J]. 草业科学, 2019, 36(5): 1415-1427.  
Li Hongwei, Guo Fuyang, Liu Yang, et al. Research status and prospect on diseases and pests of *Panax notoginseng*[J]. Pratacultural Science, 2019, 36(5): 1415-1427. (in Chinese with English abstract)
- [3] 张连娟, 高月, 董林林, 等. 三七主要病害及其防治策略[J]. 世界科学技术-中医药现代化, 2017, 19(10): 1635-1640.  
Zhang Lianjuan, Gao Yue, Dong Linlin, et al. Major diseases of *Panax notoginseng* and their control strategies[J]. World Science and Technology/Modernization of Traditional Chinese Medicine and Materia Medica, 2017, 19(10): 1635-1640. (in Chinese with English abstract)
- [4] 王志敏, 皮自聪, 罗万东, 等. 三七圆斑病和黑斑病及其防治[J]. 农业与技术, 2016, 36(1): 49-51, 53.  
Wang Zhimin, Pi Zicong, Luo Wandong, et al. Round plot disease and black plot disease of *Panax notoginseng* and prevention[J]. Agriculture and Technology, 2016, 36(1): 49-51, 53. (in Chinese with English abstract)
- [5] 杨涛, 陈昱君, 段承俐, 等. 三七黑斑病抗性人工鉴定方法的建立[J]. 云南农业大学学报(自然科学), 2006, 21(5): 549-553, 559.  
Yang Tao, Chen Yujun, Duan Chengli, et al. The methodology for artificial identification of *Panax notoginseng* resistance to black spot disease[J]. Journal of Yunnan Agricultural University (Natural Science), 2006, 21(5): 549-553, 559. (in Chinese with English abstract)
- [6] 李欣. 三七主要病害病原菌的快速检测及叶部病害病原菌的鉴定[D]. 昆明: 昆明理工大学, 2020.  
Li Xin. The Rapid Detection of the Pathogens of the Main Diseases of *Panax notoginseng* and the Identification of the Pathogens of the Leaf Diseases[D]. Kunming: Kunming University of Science and Technology, 2020. (in Chinese with English abstract)
- [7] Wang Y, Dai Y, Xue J, et al. Research of segmentation method on color image of Lingwu long jujubes based on the

- maximum entropy[J]. *Eurasip Journal on Image & Video Processing*, 2017, 17(18): 6029-6036.
- [8] 明浩, 苏喜友. 利用特征分割和病斑增强的杨树叶部病害识别[J]. *浙江农林大学学报*, 2020, 37(6): 1159-1166.  
Ming Hao, Su Xiyu. Image recognition of poplar leaf diseases with feature segmentation and lesion enhancement[J]. *Journal of Zhejiang A&F University*, 2020, 37(6): 1159-1166. (in Chinese with English abstract)
- [9] 王燕妮, 贺莉. 基于多分类 SVM 的石榴叶片病害检测方法[J]. *计算机测量与控制*, 2020, 28(9): 191-195.  
Wang Yanni, He Li. Detection method of pomegranate leaf disease based on multi classification SVM[J]. *Computer Measurement & Control*, 2020, 28(9): 191-195. (in Chinese with English abstract)
- [10] 刘永波, 雷波, 胡亮, 等. 机器视觉在 HSV 颜色空间下稻瘟病病程分级判定研究[J]. *农学学报*, 2020, 10(10): 83-90.  
Liu Yongbo, Lei Bo, Hu Liang, et al. The grading determination of rice blast: HSV color space method based on machine vision[J]. *Journal of Agriculture*, 2020, 10(10): 83-90. (in Chinese with English abstract)
- [11] 陈善雄, 伍胜, 于显平, 等. 基于卷积神经网络结合图像处理技术的荞麦病害识别[J]. *农业工程学报*, 2021, 37(3): 155-163.  
Chen Shanxiong, Wu Sheng, Yu Xianping, et al. Buckwheat disease recognition using convolution neural network combined with image processing[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2021, 37(3): 155-163. (in Chinese with English abstract)
- [12] Bai X, Li X, Fu Z, et al. A fuzzy clustering segmentation method based on neighborhood grayscale information for defining cucumber leaf spot disease images[J]. *Computers and Electronics in Agriculture*, 2017, 136: 157-165.
- [13] 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 with English abstract)
- [14] 吴雪, 宋晓茹, 高嵩, 等. 基于深度学习的目标检测算法综述[J]. *传感器与微系统*, 2021, 40(2): 4-7, 18.  
Wu Xue, Song Xiaoru, Gao Song, et al. Review of target detection algorithms based on deep learning[J]. *Transducer and Microsystem Technologies*, 2021, 40(2): 4-7, 18. (in Chinese with English abstract)
- [15] 员娇娇, 胡永利, 孙艳丰, 等. 基于深度学习的小目标检测方法综述[J]. *北京工业大学学报*, 2021, 47(3): 293-302.  
Yuan Jiaojiao, Hu Yongli, Sun Yanfeng, et al. Survey of small object detection methods based on deep learning[J]. *Journal of Beijing University of Technology*, 2021, 47(3): 293-302. (in Chinese with English abstract)
- [16] Liu Y, Sun P, Wergeles N, et al. A survey and performance evaluation of deep learning methods for small object detection[J]. *Expert Systems With Applications*, 2021, 172(4): 114602.
- [17] Patarapuwadol S. A system for automatic rice disease detection from rice paddy images serviced via a Chatbot[J]. *Computers and Electronics in Agriculture*, 2021, 185: 106156.
- [18] 黄丽明, 王懿祥, 徐琪, 等. 采用 YOLO 算法和无人机影像的松材线虫病异常变色木识别[J]. *农业工程学报*, 2021, 37(14): 197-203.  
Huang Liming, Wang Yixiang, Xu Qi, et al. Recognition of abnormally discolored trees caused by pine wilt disease using YOLO algorithm and UAV images[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2021, 37(14): 197-203. (in Chinese with English abstract)
- [19] Tassis L, Souza J, Krohling R. A deep learning approach combining instance and semantic segmentation to identify diseases and pests of coffee leaves from in-field images[J]. *Computers and Electronics in Agriculture*, 2021, 186(1): 106191.
- [20] 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 Jiuhao, 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 Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2020, 36(12): 179-185. (in Chinese with English abstract)
- [21] Sun H, Xu H, Liu B, et al. MEAN-SSD: A novel real-time detector for apple leaf diseases using improved light-weight convolutional neural networks[J]. *Computers and Electronics in Agriculture*, 2021, 189(1): 106379.
- [22] 周惠汝, 吴波明. 深度学习在作物病害图像识别方面应用的研究进展[J]. *中国农业科技导报*, 2021, 23(5): 61-68.  
Zhou Huiru, Wu Mingbo. Advances in research on deep learning for crop disease image recognition[J]. *Journal of Agricultural Science and Technology*, 2021, 23(5): 61-68. (in Chinese with English abstract)
- [23] 罗匡男, 彭琳, 齐伟恒. 基于机器视觉的三七叶片病斑识别[J]. *江苏农业科学*, 2017, 45(24): 209-212.  
Luo Kuangnan, Peng Lin, Qi Weiheng. Disease spot recognition of *Panax notoginseng* leaf based on machine vision[J]. *Jiangsu Agricultural Sciences*, 2017, 45(24): 209-212. (in Chinese with English abstract)
- [24] 曹春号. 基于卷积神经网络的三七叶片病害手机在线检测与预警装置研制[D]. 昆明: 昆明理工大学, 2020.  
Cao Chunhao. Development of Mobile Phone Online Detection and Early Warning Device Based on Convolutional Neural Network For *Panax notoginseng* Leaf Diseases[D]. Kunming: Kunming University of Science and Technology, 2020. (in Chinese with English abstract)
- [25] 熊凯. 基于机器学习的三七病害高发期的病害预测与识别[D]. 昆明: 昆明理工大学, 2021.  
Xiong Kai. Disease Prediction and Identification of *Panax notoginseng* Disease in High Incidence Period Based on Machine Learning[D]. Kunming: Kunming University of Science and Technology, 2021. (in Chinese with English abstract)
- [26] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-Time object detection[C]//Proceedings of the



- IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2016: 779-788.
- [27] Redmon J, Farhadia A. YOLO v3: An incremental improvement[EB/OL]. 2018,ArXiv:abs/1084.02767.
- [28] Lin T, 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.
- [29] Hu J, Li S, Samuel A, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020,42(8):2011-2023.
- [30] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 770-778.
- [31] Wang C, Liao H, Wu Y, et al. CSPNet: A New Backbone that can Enhance Learning Capability of CNN[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Seattle: IEEE, 2020: 1571-1580.
- [32] He K, Gkioxari G, Dollár P, et al. Mask R-CNN[C]. IEEE International Conference on Computer Vision. Venice: IEEE, 2017: 2980-2988.

## Detecting leaf disease for *Panax notoginseng* using an improved YOLOv3 algorithm

Wen Bin<sup>1</sup>, Cao Renxuan<sup>1</sup>, Yang Qiliang<sup>2</sup>, Zhang Jian<sup>2</sup>, Zhu Han<sup>1</sup>, Li Zhicong<sup>1</sup>

(1. College of Electrical Engineering & New Energy, China Three Gorges University, Yichang 443000, China; 2. Faculty of Modern Agricultural Engineering, Kunming University of Science and Technology, Kunming 650500, China)

**Abstract:** *Panax notoginseng* is one kind of the most precious herbal medicine in China. A variety of leaf diseases easily occur and disperse widely during the planting process at present. However, there is no universal detection of leaf diseases so far, due to the diversity and complexity of the leaf diseases of *Panax notoginseng*. Alternatively, a target detection technology using deep learning has been applied for detection tasks in various fields. This technology can be widely expected to greatly improve the efficiency of detection tasks for smart agriculture. In this study, an improved YOLOv3 (You Only Look Once v3) object detection (AD-YOLOv3) was proposed to locate and identify the complex diseases of *Panax notoginseng* leaves in dense and small areas. The attention feature pyramid in the AD-YOLOv3 was selected to replace the original in YOLOv3. Specifically, the channel attention module was used to compress each channel of the original feature map into a single value, then input into the fully connected layer and activate with the activation function for the weight of each feature channel, and finally the weight to perform the feature channel on the original feature map reorganization. As such, the important features were focused in the channel attention, further to discard the irrelevant for the less redundant interference in the multi-scale feature map during feature fusion. A double bottleneck layer was designed with two stacked blocks, where the first bottleneck block was added with the residual connection, and the second bottleneck block was the traditional structure in the attention feature pyramid. The resulting dual bottleneck block presented a higher performance than the raw. The dual bottleneck layer was further used to filter the features from the attention feature pyramid, indicating the better specificity of features and the robustness of detection. The attention feature pyramid and the double bottleneck layer were integrated to significantly improve the four performance indicators of the detection. Specifically, the AD-YOLOv3 had improved the overall accuracy, *F1* accuracy, and mean average precision by 2.83, 1.68, and 1.47 percentage points, respectively, compared with YOLOv3. At the same time, the AD-YOLOv3 had improved the detection capabilities for each type of disease. The average precision of plague, rust disease, anthrax disease, powdery mildew, round spot disease, virosis, and all kinds of diseases were 78.0%, 79.5%, 86.7%, 69.0%, 85.9%, 84.2%, and 80.6%, respectively. The detection ability was significantly enhanced in the small and dense areas, as well as the anti-interference ability under complicated environments, such as fog, rain, and dark light. Correspondingly, there was a tradeoff between detection speed and accuracy in the AD-YOLOv3 with a simple structure, compared with the second-order object detection of Mask-RCNN. The modified AD-YOLOv3 can also be deployed to the server or client in the cloud detection of diseases in real time. The finding can provide a better intelligent detection for the leaf disease of *Panax notoginseng*.

**Keywords:** algorithm; disease detection; YOLOv3; feature pyramid; dual bottleneck; attention mechanism; *panax notoginseng*