

储鑫, 李祥, 罗斌, 等. 基于改进 YOLOv4 算法的番茄叶部病害识别方法[J]. 江苏农业学报, 2023, 39(5): 1199-1208.
doi: 10.3969/j.issn.1000-4440.2023.05.012

基于改进 YOLOv4 算法的番茄叶部病害识别方法

储鑫^{1,2,3}, 李祥¹, 罗斌^{2,3}, 王晓冬^{2,3}, 黄硕^{2,3}

(1. 东华理工大学信息工程学院, 江西南昌 330013; 2. 国家农业信息化工程技术研究中心, 北京 100097; 3. 北京市农林科学院智能装备技术研究中心, 北京 100097)

摘要: 为快速准确识别自然环境下的番茄叶片病害, 提出一种基于改进 YOLOv4 算法的轻量化番茄叶部病害识别方法。该方法根据番茄病害特征采用 K 均值聚类算法调整先验框的维度, 并使用宽度因子为 0.25 的 MobileNetv1 代替 YOLOv4 原有的主干网络 CSPDarknet53 进行特征提取, 并在特征融合网络 PANet 中引入深度可分离卷积代替原有的 3×3 标准卷积, 同时, 在主干网络的 2 个输出特征层和空间金字塔池化输出层分别嵌入卷积块注意力模块(CBAM), 提高模型识别精度。试验结果表明, 改进后的模型对 8 类番茄叶片整体检测精准性(mAP)为 98.76%, 参数量为 12.64 M, 传输帧数为 1 s 101.76 帧, 相较于原 YOLOv4 模型, 模型参数量减少 80%, 每秒传输帧数比原始 YOLOv4 模型提高了 130%。

关键词: YOLOv4; MobileNet; 轻量化; 注意力机制; 病害

中图分类号: S436.412 **文献标识码:** A **文章编号:** 1000-4440(2023)05-1199-10

Identification method of tomato leaf diseases based on improved YOLOv4 algorithm

CHU Xin^{1,2,3}, LI Xiang¹, LUO Bin^{2,3}, WANG Xiao-dong^{2,3}, HUANG Shuo^{2,3}

(1. College of Information Engineering, East China University of Technology, Nanchang 330013, China; 2. National Engineering Technology Research Center for Agricultural Informatization, Beijing 100097, China; 3. Research Center of Intelligent Equipment Technology, Beijing Academy of Agriculture and Forestry, Beijing 100097, China)

Abstract: In order to identify tomato leaf diseases in natural environment quickly and accurately, a lightweight tomato leaf disease identification method based on improved YOLOv4 algorithm was proposed. The method used K -means clustering algorithm to adjust the dimensions of the prior box according to the characteristics of tomato disease, and used MobileNetv1 with a width factor of 0.25 instead of the original backbone network CSPDarknet53 of YOLOv4 for feature extraction, and introduced deep separable convolution in place of the original 3×3 standard convolution in the feature fusion network PANet. At the same time, the convolutional block attention module (CBAM) was embedded in the two output feature layers and the spatial pyramid pooling output layer of the backbone network to improve the model recognition accuracy. The results showed that, the overall detection accuracy (mAP) of the improved model for

eight types of tomato leaves was 98.76%, the parameter quantity was 12.64 M, and the transmission frame number was 101.76 f/s, which was 80% lower than that of the original YOLOv4 model, and the number of transmitted frames per second was 130% higher than that of the original YOLOv4 model.

Key words: YOLOv4; MobileNet; light weight; attentional mechanism; diseases

收稿日期: 2022-08-31

基金项目: 江苏省科技计划重点及面上项目(BE2021379); 江西省核
地学数据科学与系统工程技术研究中心开放基金项目
(JETRCNGDSS201801)

作者简介: 储鑫(1998-), 女, 安徽安庆人, 硕士研究生, 研究方向
为计算机视觉。(E-mail) 416940305@qq.com。罗斌为共
同第一作者

通讯作者: 李祥, (Tel) 0791-83897395; (E-mail) tom_lx@126.com

番茄是重要的经济作物之一,其营养价值和经济价值非常高。随着番茄植株的生长,大多数番茄叶部病害的发生也呈上升趋势^[1]。因此,及时防治番茄叶部病害是提高番茄质量和产量的关键举措,而精准识别番茄叶部病害种类是番茄病虫害精准防控的前提。现阶段,中国大部分地区主要还是依赖人工排查番茄叶部病害,这不仅耗时耗力,而且仅仅通过肉眼分辨叶部病害种类,难免产生错误,从而不利于病害的及时防治^[2]。对此,需要研究高效率、低成本的病害图像智能识别算法,为番茄叶部病害精准识别提供技术支撑。

随着深度学习的不断发展和其在农业方面越来越多的应用^[3],有学者针对作物叶片病害检测识别进行了深入研究。刘文波等^[4]将改进后的 SOLOv2 算法应用于番茄叶部病害检测,平均精度达 42.3%,与其他文献的模型相比,精度不太理想。文斌等^[5]在 YOLOv3 的基础上采用注意力特征金字塔和双瓶颈层构建新的网络,实现三七叶片病害的识别,但检测速度仅为 23 fps。Hu 等^[6]提出将多卷积神经网络集成用于茶树叶部病害的识别,结果显示,该算法可以有效区分病叶与健康叶,但检测类别较少。Qi 等^[7]在 YOLOv5 模型中增加了 1 个挤压-激发(SE)模块,构建新的模型,实现对番茄病害的识别,平均检测精度为 91.07%,但模型参数量较大,高达 42.796 M。刘延鑫等^[8]构建 5 种烟草叶部病害数据集,选用 YOLOv3 模型对烟草叶部病害进行识别检测,采用 K-means++ 聚类方法对锚框(Anchor box)的宽和高进行计算,提高了模型检测精度,得到整体检测精准性(*mAP*)为 0.77,算法结果优于 SSD(单步多框目标检测)算法检测的 *mAP* 值(0.69),但模型单样本耗时比 SSD 算法多 2 s。王超学等^[9]分别以一张葡萄叶片和一串葡萄果实为单位做标注,将 YOLOv3 算法中的主干网络 DarkNet-53 替换为 EfficientNet-B3 作为模型的主干特征提取网络,对 12 种葡萄病害、健康葡萄叶片和健康葡萄果实进行识别,识别精度为 98.60%,B3 网络结构模型与其他以 EfficientNet 作为主干特征提取网络的模型训练时间和模型体积相近,且相对于 YOLOv3 网络模型,参数量缩减 50%,模型体积缩减 2/3 的同时,模型平均识别精度提升 3%,最终参数量仍然较大,约为 29 M。周维等^[10]利用 GhostNet 网络代替

YOLOv4 中主干网络 CSPDarkNet-53,并以深度可分离卷积代替普通卷积的方式改进路径聚合网络(PANet),对网上获取的 6 种水稻病虫害数据集进行检测识别,识别准确率为 79.36%。王权顺等^[11]利用 PlantVillage 中苹果叶部黑星病图片与网上另外 3 种苹果叶部病害图片构建数据集,通过将 YOLOv4 中主干网络 CSPdarknet53 替换为 DenseNet121 网络,在保证特征提取能力的同时减少计算量,针对 YOLOv4 的预设锚框不适合应用于病斑检测的情况,采用二分 *K* 均值聚类算法得到一组新的锚框优化算法,相较于原 YOLOv4 算法 *mAP* 值提高 0.89%,模型权重大小为 62.71 MB,相较于其他文献报道,该算法识别病害种类较少,仅有 4 种。

考虑到上述国内外学者对作物叶片病害检测识别的研究中存在的一些问题,例如,精确度低、检测速度慢、模型参数大等,本研究针对番茄叶片多类病害病斑差别较小、病斑形状复杂且无规律、检测识别方法的检测速率低和模型参数大等问题,提出一种改进的 YOLOv4 轻量化番茄叶部病害识别方法,使用 *K* 均值聚类算法得到 9 个新的先验框,同时利用迁移学习,将预训练 YOLOv4 算法得到的最优参数与在 COCO 数据集训练得到的 MobileNetv1 权重进行融合,并对主干网络、路径聚合网络进行改进,达到降低模型参数和减小计算量的目的。在主干网络的 2 个输出特征层和空间金字塔池化输出层分别嵌入坐标注意力机制 CBAM(卷积块注意力模块),以此避免改进网络后减少模型参数带来的精度损失。

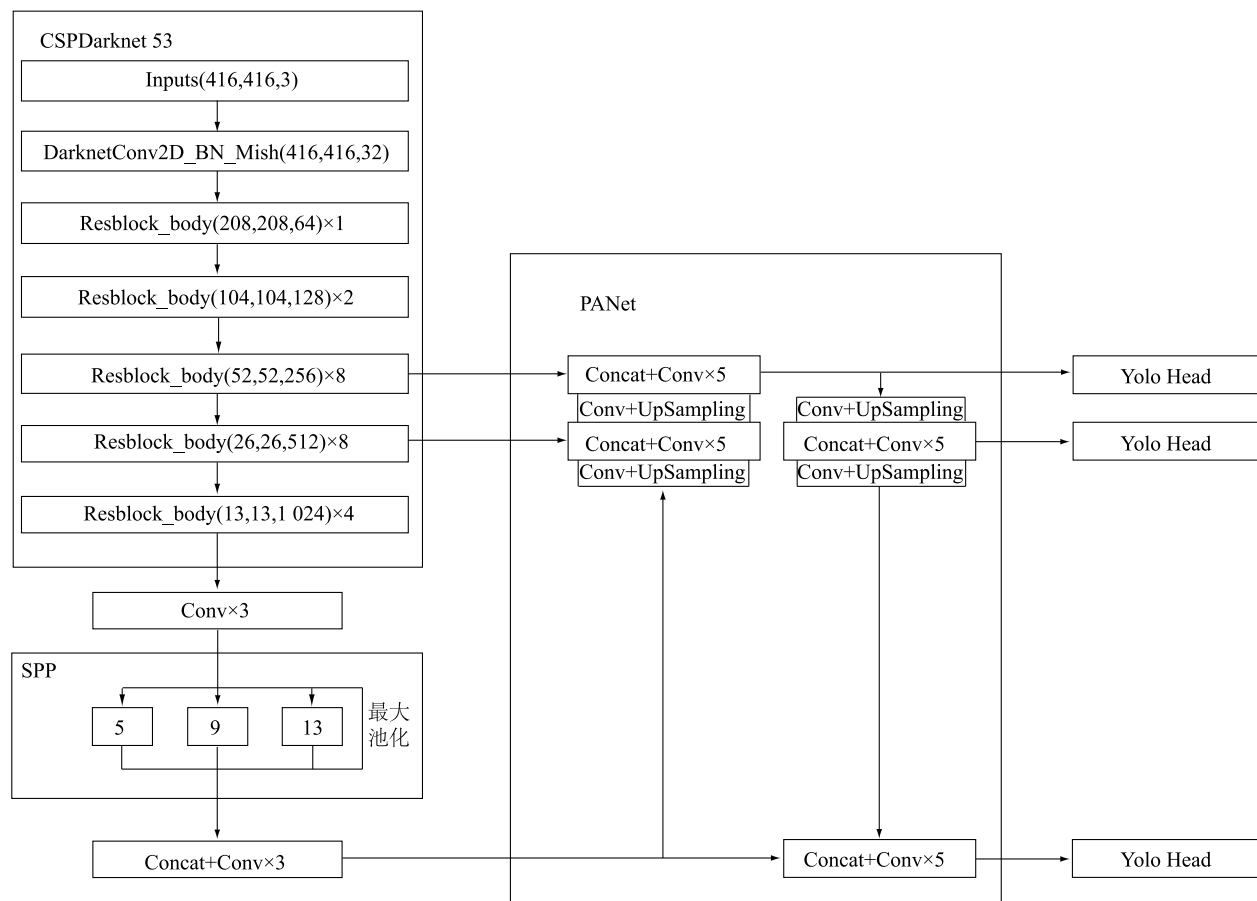
1 YOLOv4 模型改进

1.1 YOLOv4 模型

YOLOv4^[12-13]作为 YOLO 系列第 4 代单阶段目标检测算法,相较于 YOLOv3 算法,其在检测精度与检测速度方面均有较大的提升。YOLOv4 模型主要包括 4 个方面:输入端、主干网络(Backbone)、颈部网络(Neck)以及头部网络(Head)。YOLOv4 在输入端采用 Mosaic 数据增强^[14],丰富了数据的多样性,提高了模型的泛化能力。主干网络在 DarkNet53 的基础上融合了跨阶段局部网络的思想,形成特征提取效果更强的 CSPDarkNet53 结构。CSPDarkNet53 主干网络主要由 5 层残差网络 Resblock_Body 组成,同时通过下

采样输出 3 个有效特征层,以此保证提取更完备的图像语义信息。颈部网络主要由空间金字塔池化(Space pyramid pool, SPP)^[15]和 PANet^[16]组成,空间金字塔池化通过 5 个大小为 5×5 、 9×9 和 13×13 的最大池化层来融合尺度大小不同的特征图,起到增加感受野的作用。路径聚合网络可以提高信息流在网络

中的传递效率^[17],其对特征图进行上采样与下采样,借此融合网络提取到的特征信息。最后 YOLOv4 生成 3 个检测头用于检测目标^[18]。YOLOv4 网络结构如图 1 所示。为提高模型检测效率,降低模型参数量,本研究提出一种改进的 YOLOv4 算法的番茄叶部病害识别方法。



Inputs:输入图像;SPP:空间金字塔池化;CSPDarknet53:YOLOv4 主干网络;Resblock _Body:残差网络;PANet:路径聚合网络;Yolo Head:头部网络。


图 1 YOLOv4 网络结构

Fig.1 YOLOv4 network structure diagram

1.2 改进 YOLOv4 模型

1.2.1 运用迁移学习 在原先的 YOLOv4 模型中,输入图片尺寸大小为 416×416 ,冻结层与非冻结层批次大小(Batch size)均为 16,模型检测番茄叶片的 mAP 为 98.16%。由于本研究采用的番茄叶部病害数据集尺寸大小为 256×256 ,因此,在模型输入端将尺寸改为 256×256 ,并将冻结层与非冻结层 batch size 均改为 8,最终得到模型检测番茄叶片的

mAP 为 98.58%。因此,在下文其他模型训练时均采用上述参数进行训练。由于 COCO 数据集包含的数据特征丰富,因此,本研究用到的所有模型的训练权重均为对应模型在 COCO 数据集训练所得,利用这些训练权重有利于得到更高精度的结果。由此可见,运用迁移学习有利于检测精度的提升,迁移学习改进后参数量由 64.36 M 降低为 63.79 M,图 2 为参数改进前后 mAP 的对比。



左图为修改参数前,右图为修改参数后。 mAP :整体检测精准性。

图2 修改参数前后 mAP 对比

Fig.2 Comparison of overall detection accuracy (mAP) before and after the parameter was modified

1.2.2 使用 MobileNetv1 为主干网络 MobileNetv1 是 2017 年由谷歌公司提出的一种轻量化深层神经网络,与传统的卷积神经网络模型相比,该模型需要的计算工作量相对较少^[19],主要是用于嵌入各类硬件和软件设备,其最大优势是提出了深度可分离卷积 (Depthwise separable convolution),并且 MobileNetv1 采用 ReLU6 代替 ReLU 作为激活函数。图 3 为普通卷积和深度可分离卷积结构的对比。采用多个 ReLU6 激活函数,可以在减少计算量的同时避免带来精度损失。

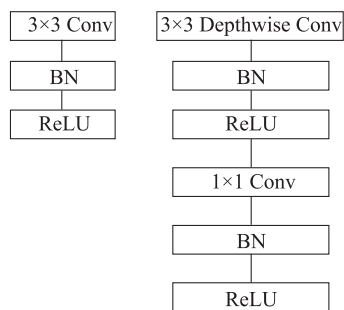


图3 普通卷积(左)和深度可分离卷积结构(右)对比

Fig.3 Ordinary convolution (left) and depth separable convolution structure (right)

为了使模型参数量更小,检测速度更快,MobileNetv1 在输入通道上引入可以使每一层网络均匀细化的宽度因子 (a),其取值为 0.25、0.50、0.75、1.00。当 a 取 1.00 时,代表原始的网络,只有当 $a <$

1.00 时,才有细化网络层的功能。本研究选取 a 为 0.25 的 MobileNetv1 网络作为主干网络对 YOLOv4 模型进一步压缩,在只给精度仅带来 0.01% 的损失的同时减少了 23.23 M 参数量,因此,选取 a 为 0.25 的 MobileNetv1 网络代替 YOLOv4 的主干网络 CSPDarkNet-53,大大地减少了模型参数量且几乎不带来识别精度的损失。

1.2.3 改进 PANet 深度可分离卷积的核心思想是将普通卷积运算分为逐深度卷积 (Depthwise convolution) 与逐点 1×1 卷积 (Pointwise convolution) 2 步进行^[20]。逐深度卷积不同于普通卷积的是 1 个通道由 1 个卷积核负责,每个通道独立进行空间卷积运算。不同深度卷积的输出由逐点 1×1 卷积重新组合输出,从而得到新的特征图。图 4A 为普通卷积运算,图 4B 为逐深度卷积运算,图 4C 为逐点卷积运算。

由图 4A 可知,普通卷积计算量为:

$$H \times W \times M \times N \times D_k \times D_k \quad (1)$$

由图 4B 可知,逐深度卷积计算量为:


$$H \times W \times M \times D_k \times D_k \quad (2)$$

由图 4C 可知,逐点卷积计算量为:

$$H \times W \times M \times N \quad (3)$$

式中, W 、 H 表示输入特征图, M 表示输入通道, N 表示输出通道, D_k 表示卷积核。

因此,采用深度可分离卷积代替普通卷积后的计算量与普通卷积计算量之比如公式(4)所示,PA-Net 采用深度可分离卷积代替 3×3 普通卷积可以大



A:普通卷积;B:逐深度卷积;C:逐点卷积。 M 表示输入通道, N 表示输出通道, D_k 表示卷积核。

图4 深度可分离卷积


Fig.4 Depth separable convolution

幅度降低计算量,有利于模型的压缩。

$$\frac{H \times W \times M \times D_k \times D_k + H \times W \times M \times N}{H \times W \times M \times N \times D_k \times D_k} = \frac{1}{N} + \frac{1}{D_k^2} \quad (4)$$

1.2.4 改进 Anchor box YOLOv4 是一种根据锚框对目标物体进行预测回归的算法,其原先 Anchor box 是根据 COCO 数据集训练得到的固定数值。而本研究的对象是 COCO 数据集中鲜少出现的番茄叶片病害,并且数据集中番茄叶片病害种类繁多,导致数据集标注边界框尺寸相差甚远。为了使 Anchor box 更接近数据集标注尺寸,本研究采用 K 均值聚类算法对本研究数据集的 Anchor box 进行聚类分析,得到合适的锚框尺寸。 K 均值聚类算法具有计算复杂度低、收敛速度快和可解释性强等特点。根据 K 均值聚类算法随机初始化得到 9 个中心点,计算每个坐标到中心点的欧式距离,将每个样本分配给离它最近的中心点,不断重复此步骤直到 9 个中心点不再移动,从而得到 9 个新的 Anchor box,分别为 (132, 198)、(162, 222)、(182, 200)、(186, 234)、(203, 224)、(226, 212)、(209, 240)、(223, 237)、(237, 242),将新的 Anchor box 运用到算法中,并采用 mAP 值和 $GFLOPs$ 值(每秒浮点运算次数)作为优化前后的评价指标。最终结果表明,优化后的 mAP 值增长了 0.02%, $GFLOPs$ 值也比优化前高出 1.36 G。图 5 是 K 均值聚类分布。

1.2.5 添加 CBAM 注意力机制 CBAM 模块是一种在通道和空间 2 个维度上对特征图像进行权重分配,从而提取到更有用的特征信息的模块。特



×:质心;圆点:数据集标注框样本。

图5 先验框 K 均值聚类分布

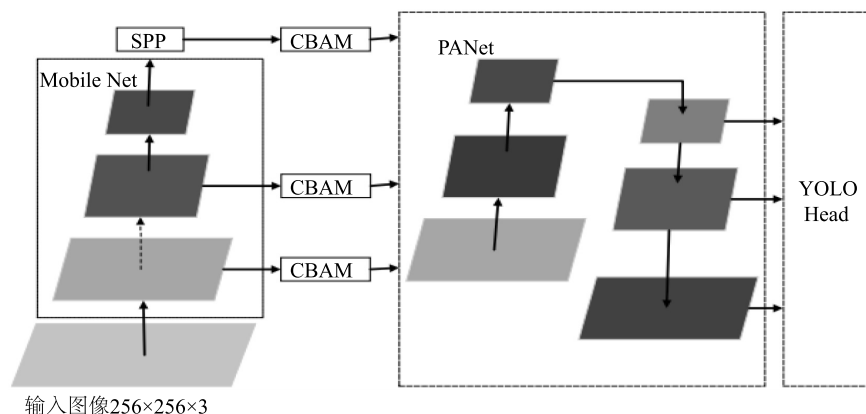
Fig.5 Cluster distribution of prior box K -means

征图像首先进入通道注意力模块,通过平均池化和最大池化得到各个通道的信息,并将得到的参数通过多层感知进行叠加,再经过激活函数处理,从而得到通道注意力特征图^[21]。空间注意力模块主要关注空间层面上特征图的内在联系,将通道注意力模块的输出作为空间注意力模块的输入,经过卷积和激活操作后获得空间注意力模块的特征图^[22]。

为提取到番茄病害更丰富的有效特征信息,本研究在 YOLOv4 改进后的主干特征提取网络 MobileNetV1 的 2 个输出特征层以及加强特征提取网络 SPP 的输出特征层上添加 CBAM 模块,以 CBAM 模块输出的有效特征图作为 PANet 的输入,传入 PANet 结构中进行卷积和上采样,最终提取到包含更多关键信息的特征图。改进后 YOLOv4 的网络结构如图 6 所示。

2 结果与分析

为验证本研究算法在 multi-class 番茄病害识别与分类方面的性能,首先构建数据集,然后分别对 YOLOv4 不同主干网络和在主干网络输出层加入的不同注意力机制模块进行训练,并选取经典的单阶段目标检测算法与本研究改进的 YOLOv4 算法进行对比。试验的硬件配置为 Intel Core™ i7-10700K 处理器和 NVIDIA GeForce RTX 3060 显卡。操作系统是 Ubuntu 20.04.2 LTS 64 位系统。Python 的版本为 3.8.5,Pytorch 的版本为 1.8.1。在训练过程中,首先对输入的图片进行 Mosaic(马赛克)数据增强,并使用余弦退火算法对学习率进行调整,每轮共设置 300 次迭代,冻结层和非冻结层 batch size 设置为 8。



MobileNet; MobileNet 轻量化网络; SPP; 空间金字塔池化网络; CBAM; 注意力机制; PANet; 路径聚合网络; YOLO Head; 头部网络。

图 6 改进后 YOLOv4 的网络结构

Fig.6 Improved network structure of YOLOv4

2.1 数据集的构建

本研究所用数据集选自 Plant Village 公开数据集中的番茄叶片集,其中包括细菌性斑点病、叶霉病、晚疫病、叶斑病、二斑叶螨病、黄曲叶病、早疫病叶片以及健康叶片,共 8 个类别。由于样本分布不均匀会影响模型训练结果,因此,每个类别的叶片选取相同的数量,均为 1 250 张。数据集中早疫病图片仅有 1 000 张,通过编写程序将其中 250 张图片旋转 270°后与原有图像整合,使其与其他类别图像达到相同数量,最终得到所有数据集 10 000 张,数据集如图 7 所示。使用 Make Sense 工具对上述 10 000 张番茄叶片病害图像进行标注,标注时利用最小外接矩形框标记出叶片位置并选择对应的类别标签。标注完成后,每张图片会产生 1 个对应的包含病害类别标签和矩形框坐标信息的 txt 文件,图 8 为数据集标注示例。通过编写随机抽样的程序,从 10 000 张图片中随机选择 8 001 张作为训练集,随机选择 999 张图片作为验证集,随机选择 1 000 张图片作为测试集。

2.2 评价指标

为了评估算法的性能优劣,本研究以对所有类别的番茄叶片整体检测精准性(mAP)、每秒所执行的浮点运算次数、每秒帧数(FPS)、平均每张图片检测时间以及模型参数量作为评价模型大小、检测速度和精度的指标。 mAP 由所有类别的平均精度(AP)取平均值得到, AP 是精确度(P)和召回率(R)组成的曲线的面积。 P 、 R 的计算方法分别见公式

(5)、公式(6), mAP 的计算公式如公式(7)所示。 $GFLOPs$ 用于衡量模型的计算量,其值越大,表明模型计算速度越高。 FPS 用于衡量模型的实时性能,其值越大,表明模型实时检测的性能越好。

$$P = \frac{TP}{TP + FP} \quad (5)$$

$$R = \frac{TP}{TP + FN} \quad (6)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n AP \quad (7)$$

式中, TP 表示正确检测到的病害类别的数量; FP 表示误检病害类别的数量; FN 表示未检测到的病害类别的数量; n 表示番茄病害样本类别数。

2.3 不同主干网络的性能比较

针对 YOLOv4 参数量多和网络结构复杂等问题,分别选取不同的轻量化主干网络代替原来的 CSPDarknet 网络,对 8 001 张训练集进行训练后,得到相应权重再分别检测验证集和测试集。为验证 MobileNetv1 轻量化网络检测番茄病害的优越性,选取的网络分别是 MobileNetv2、MobileNetv3 以及 CSPDarknet,预测结果如表 1 所示。

由表 1 可以看出,MobileNetv2 和 MobileNetv3 虽然检测时间优于原 YOLOv4 模型,但识别精度(整体检测精准性)却低于原 YOLOv4 模型。MobileNetv1 不仅比其他轻量化网络识别模型的整体检测精准性高,检测速度也具有较大的优势,检测每张图片平均仅需 9 ms,比原 YOLOv4 模型快了 13 ms,满足实时检测的条件。

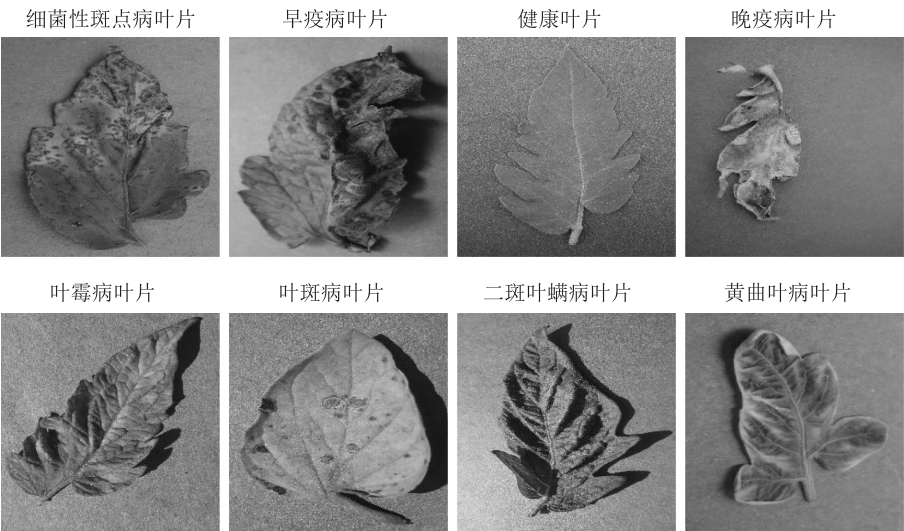


图7 番茄叶片数据集
Fig.7 Dataset of tomato leaves

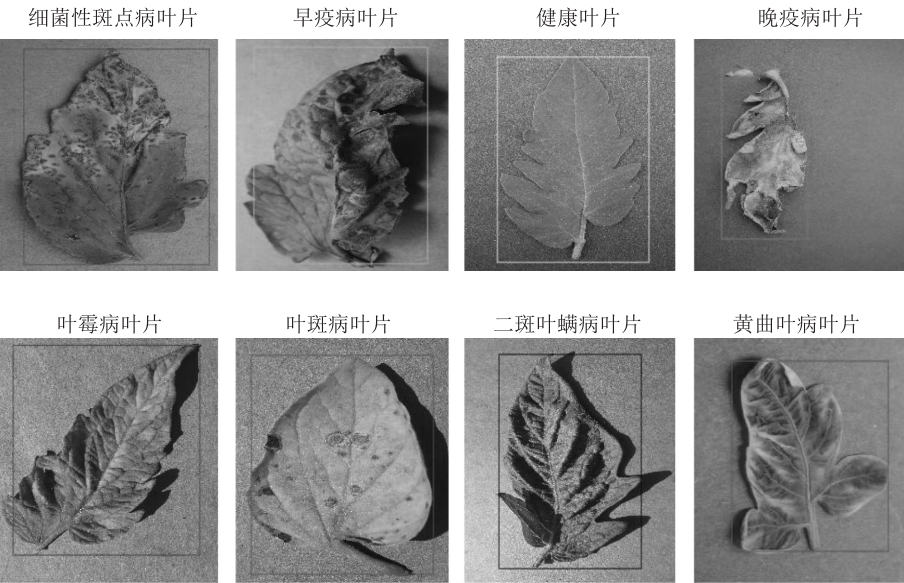


图8 番茄叶片数据集标注示例
Fig.8 Labeling samples of tomato leaf dataset

表 1 不同主干网络的性能比较

Table 1 Performance comparison of different backbone networks

模型	<i>mAP</i> (%)	<i>GFLOPs</i>	<i>FPS</i> (帧, 1 s)	<i>Time</i> (ms)
YOLOv4	98.58	22.65	44.24	22
YOLOv4+MobileNetv3	98.33	2.68	70.47	14
YOLOv4+MobileNetv2	98.40	2.88	81.18	12
YOLOv4+MobileNetv1	98.68	10.01	102.31	9

mAP:模型对 8 类叶片整体检测精准性;*GFLOPs*:每秒所执行的浮点运算次数;*FPS*:每秒传输帧数;*Time*:模型检测时间。

2.4 不同注意力机制的比较

为验证本研究在主干网络 2 个输出层和 SPP 结构的输出层添加 CBAM 模块的有效性,本研究设计了在同等条件下添加不同注意力模块的对比试验,结果如表 2 所示。由表 2 可以看出,在设定参数以及其他改进均相同的情况下,添加 CBAM 模块比添加 CA 模块和 ECA 模块的平均检测精度都具有优势,并且没有带来检测速度方面的损失。原因可能是 CBAM 模块属于轻量级模块,其插入

网络层后并不会给网络带来运行负担,并且相较于 ECA 模块与 CA 模块只关注通道注意力,CBAM 模块可以在关注通道注意力的同时又关注空间注意力,而空间注意力对图像中的有效语义信息更为敏感,因此,添加 CBAM 模块使得空间注意力与通道注意力相辅相成,从而有效地提高网络的特征提取能力。

表 2 不同注意力机制的性能比较

Table 2 Performance comparison of different attention mechanisms

模型	<i>mAP</i> (%)	<i>FPS</i> (帧, 1 s)	<i>Time</i> (ms)
YOLOv4	98.68	102.31	9
YOLOv4+ECA	98.58	102.30	9
YOLOv4+CA	98.64	99.14	10
YOLOv4+CBAM	98.76	101.76	9

mAP、*FPS*、*Time* 见表 1 注。ECA、CA、CBAM 表示不同的注意力机制模块。

表 3 消融试验的性能比较

Table 3 Performance comparison of ablation tests

迁移学习	引入 MobileNetv1	改进 PANet	<i>K</i> 均值	添加 CBAM	模型参数量 (M)	<i>mAP</i> (%)
—	—	—	—	—	64.36	98.16
✓	—	—	—	—	63.79	98.58
✓	✓	—	—	—	40.56	98.57
✓	✓	✓	—	—	12.30	98.68
✓	✓	✓	✓	—	12.30	98.70
✓	✓	✓	✓	✓	12.64	98.76

“—”表示未做改进;“✓”表示已做改进;*mAP*、*Time* 见表 1 注。

2.6 与其他单阶段目标检测算法比较

当前的目标检测算法分为 2 类,一类是以 Faster R-CNN^[23] 为代表的 Two-stage 检测算法,Two-stage 检测算法识别精度较高,但对检测速度有所限制,显然不适用于实时检测场景。另一类是 One-stage 检测算法,这类算法直接使用网络检测目标边界框和类概率分数,检测速度快,识别准确率高,适用于农业病害实时检测场景。因此,本研究选择对以 SSD^[24] 和 YOLO 为代表的 One-stage 目标检测算法与改进的 YOLOv4 轻量化算法进行对比,表 4 为不同单阶段算法对比。由表 4 可以看出,本研究提出的算法平均每张图片检测速度分别比 SSD 和 RetinaNet 算法快 6 ms 和 5 ms, *mAP* 比 SSD 和 Reti-

2.5 消融试验

为验证本研究提出的每个改进对试验结果的积极影响,本研究设计了消融对比试验,试验内容包括运用迁移学习,以 MobileNetv1 为主干网络,改进 PANet,采用 *K* 均值聚类 Anchor box 和添加 CBAM 模块,试验结果如表 3 所示。由表 3 可知,采用参数迁移学习后,番茄病害平均检测精度有所提高,而在采用 MobileNetv1 替换主干网络后,模型参数量减少了 23.23 M,在此基础上,进一步对 PANet 进行改进,使得模型参数量大幅度减少了 28.26 M。由此可以看出,对 YOLOv4 算法主干网络和路径聚合网络的改进,有效地减少了模型参数量。并且在网络中添加 CBAM 模块后,使得 *mAP* 有所提升的同时参数量仅有微小提升。因此,改进后的 YOLOv4 算法在保障精度有所提升的前提下,大大提高了模型检测病害的速度。

naNet 算法高。本研究提出的算法模型参数量更是远远小于 SSD、RetinaNet 以及原 YOLOv4 模型,分别比 SSD、RetinaNet 以及原 YOLOv4 模型小 9.64 M、9.77 M 和 51.33 M。因此,本研究提出的算法在不影响识别精度的前提下大大减少了模型大小,更适合在嵌入式系统上部署。


为验证改进后的 YOLOv4 算法是否可以较好地应用于自然场景,选择现实场景里番茄相对感染较多的 4 种病害,分别是早疫病、晚疫病、细菌性斑点病和黄曲叶病,使用改进后的 YOLOv4 算法对 4 种病害进行检测识别。图 9 为使用改进后的 YOLOv4 算法对病害识别的结果,可以看出该算法可以准确识别自然环境下的番茄叶部病害。

表 4 不同单阶段目标检测算法的性能比较

Table 4 Performance comparison of different single-stage object detection algorithms

模型	<i>mAP</i> (%)	<i>GFLOPs</i>	<i>FPS</i> (帧, 1 s)	参数量 (M)	<i>Model size</i> (MB)	<i>Time</i> (ms)
SSD	98.50	62.79	66.36	22.28	98.8	15
YOLOv4	98.16	22.65	44.24	63.97	256.4	22
RetinaNet	98.48	34.35	67.72	22.41	146.2	14
本研究算法	98.76	3.79	101.76	12.64	53.7	9

Model size:模型权重大小;*mAP*、*GFLOPs*、*FPS*、*Time* 见表 1 注。



A: 早疫病; B: 晚疫病; C: 细菌性斑点病; D: 黄曲叶病。

图 9 自然场景病害识别结果

Fig.9 Disease identification results in natural scenes

3 结 论

针对不同类型番茄叶片病害误检率高、实时检测速度低等问题^[25-26], 本研究提出一种改进的 YOLOv4 轻量化检测算法, 应用于 8 种番茄病害识别, 改进后的模型在平均识别精确度、检测速度以及参数内存大小方面均取得了良好的效果。将 YOLOv4 的主干网络 CSPDarkNet 替换成轻量化的 MobileNetv1 网络, 并采用深度可分离卷积取代 PA-Net 加强特征提取网络中的 3×3 普通卷积, 使得模型的计算量得到进一步压缩。通过有效调整 YOLOv4 原始模型参数, 结合迁移学习策略, 将 MobileNetv1 在 COCO 数据集上训练的权重运用到改进的 YOLOv4 模型, 并在主干网络的 2 个输出特征层和空间金字塔池化输出层分别嵌入坐标注意力机制, 以此避免减小模型参数带来精度损失。应用 *K* 均值聚类算法对 Anchor box 进行重新优化, 得到新的 Anchor box 值, 取代原始 YOLOv4 的盲目搜索方法, 从而提升了模型检测能力。本研究提出的模型传输帧数为 101.76 f/s, 比原始 YOLOv4 模型提高了 130%, 而模型参数量仅为 12.64 M, 比原 YOLOv4 模型参数量减少了 80%, 在 1 000 张测试集图片上整体检测精准性为 98.76%, 比原始 YOLOv4 模型提高了 0.6 个百分点, 平均每张病害图片检测时间为 9 ms。

因此, 改进后的轻量化 YOLOv4 模型实时检测性能更好, 精确度更高并且更适合在硬件上部署。下一步的研究重点是将本研究算法应用到各种复杂的自然场景, 将深度学习应用到更广泛的农业工程中。

参考文献:

- [1] WANG X W, LIU J, ZHU X N. Early real-time detection algorithm of tomato diseases and pests in the natural environment[J]. Plant Methods, 2021, 17(1): 1-17.
- [2] XU C, DING J Q, QIAO Y, et al. Tomato disease and pest diagnosis method based on the Stacking of prescription data[J]. Computers and Electronics in Agriculture, 2022, 197: 106997.
- [3] 吕盛坪, 李灯辉, 洗荣亨. 深度学习在我国农业中的应用研究现状[J]. 计算机工程与应用, 2019, 55(20): 24-33, 51.
- [4] 刘文波, 叶涛, 李 颀. 基于改进 SOLO v2 的番茄叶部病害检测方法[J]. 农业机械学报, 2021, 52(8): 213-220.
- [5] 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.
- [6] HU G S, YANG X W, ZHANG Y, et al. Identification of tea leaf diseases by using an improved deep convolutional neural network[J]. Sustainable Computing: Informatics and Systems, 2019, 24: 100353.
- [7] QI J T, LIU X N, LIU K, et al. An improved YOLOv5 model based on visual attention mechanism: application to recognition of tomato virus disease[J]. Computers and Electronics in Agriculture, 2022, 194: 106780.
- [8] 刘延鑫, 王俊峰, 杜传印, 等. 基于 YOLOv3 的多类烟草叶部病害检测研究[J]. 中国烟草科学, 2022, 43(2): 94-100.
- [9] 王超学, 祁 昕, 马 昱, 等. 基于 YOLOv3 的葡萄病害人工智能识别系统[J]. 植物保护, 2022, 48(6): 278-288.
- [10] 周 维, 牛永真, 王亚伟, 等. 基于改进的 YOLOv4-GhostNet 水稻病虫害识别方法[J]. 江苏农业学报, 2022, 38(3): 685-695.
- [11] 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.
- [12] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]. Las Vegas; IEEE Computer Society, 2016.

- [13] BOCHKOVSKIY A, WANG C Y, LIAO H Y. YOLOv4: optimal speed and accuracy of object detection[J/OL]. arXiv, 2020.
- [14] 胡文骏, 杨莉琼, 肖宇峰, 等. 识别安全帽佩戴的轻量化网络模型[J/OL]. 计算机工程与应用; 1-9. [2023-03-15]. <http://kns.cnki.net/kcms/detail/11.2127.TP.20220524.1106.011.html>.
- [15] 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.
- [16] LIU S, QI L, QIN H F, et al. Path aggregation network for instance segmentation[C]. Salt Lake City, UT, USA: IEEE Press, 2018: 8759-8768.
- [17] 陈道怀, 汪杭军. 基于改进 YOLOv4 的林业害虫检测[J]. 浙江农业学报, 2022, 34(6):1306-1315.
- [18] 裴瑞景, 王 硕, 王华英. 基于改进 YOLOv4 算法的水果识别检测研究[J/OL]. 激光技术; 1-11 [2023-03-15]. <http://kns.cnki.net/kcms/detail/51.1125.TN.20220518.1135.004.html>.
- [19] SRINIVASU P N, SIVASAI J G, IJAZ M F, et al. Classification of skin disease using deep learning neural networks with MobileNet V2 and LSTM[J]. Sensors, 2021, 21(8):2852.
- [20] WANG H T, LU F Y, TONG X, et al. A model for detecting safety hazards in key electrical sites based on hybrid attention mechanisms and lightweight Mobilenet [J]. Energy Reports, 2021, 7(S7):716-724.
- [21] 郝 帅, 张 旭, 马 旭, 等. 基于 CBAM-YOLOv5 的煤矿输送带异物检测[J]. 煤炭学报, 2022, 47(11):4149-4158.
- [22] 姚齐水, 别帅帅, 余江鸿. 一种结合改进 Inception V2 模块和 CBAM 的轴承故障诊断方法[J]. 振动工程学报, 2022, 35(4):949-957.
- [23] REN S Q, HE K M, GIRSHICK R, et al. FasterR-CNN: towards real - time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6):1137-1149.
- [24] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector [M]. Amsterdam, The Netherland: Proceedings of the European Conference on Computer Vision, 2016.
- [25] 胡 政, 张 艳, 尚 静, 等. 高光谱图像在农作物病害检测识别中的研究进展[J]. 江苏农业科学, 2022, 50(8):49-55.
- [26] 牛学德, 高丙朋, 南新元, 等. 基于改进 DenseNet 卷积神经网络的番茄叶片病害检测[J]. 江苏农业学报, 2022, 38(1):129-134.

(责任编辑:陈海霞)