doi:10.6041/j.issn.1000-1298.2025.10.066

基于改进 YOLO v7 - tiny 的农药残留消解过程多品种果蔬精准识别方法

丁志康[1,2]　兰玉彬[1,2]　韩　鑫[1,2]　赵　硕[1,2]　白京波[3]　王　娟[1,2]

(1.山东理工大学农业工程与食品科学学院,淄博 255000;2.山东理工大学生态无人农场研究院,淄博 255000;
3.山东思远农业开发有限公司,淄博 255400)

摘要:利用具有强氧化性、无毒无污染的臭氧水,借助工厂化、无人化处理设备和工艺,根据果蔬种类和农药残留状况,喷淋不同浓度的臭氧水,是实现果蔬农药残留自动化、智能化、绿色、高效消解处理的有效手段。而快速、精准识别果蔬种类是指导工厂化、无人化处理设备针对性喷淋所需浓度臭氧水的前提。本文提出一种基于改进 YOLO v7 - tiny 的农残消解过程中多品种果蔬精准识别方法。首先,在 Head 部分引入渐近特征金字塔网络 AFPN(Asymptotic feature pyramid network)来替换原有 YOLO v7 - tiny 的金字塔网络,在实现网络结构轻量化的同时进一步提高模型准确率;其次,在 Backbone 部分加入多尺度注意力模块 EMA(Efficient multi-scale attention)来提高模型对果蔬图像中有效特征信息的提取能力;最后,将原有 YOLO v7 - tiny 网络的损失函数替换为 Wise - IoU(Wise intersection over union)以提高模型的泛化能力。试验结果表明,改进后 YOLO v7 - tiny 模型(YOLO v7 - AEW)的参数量、浮点数计算量和模型存储占用量分别达到 4.5×10^{6}、1.28×10^{10} 和 8.9 MB,较原模型分别减少 25.0%、3.0% 和 27.6%;准确率与平均精度均值达到 97.9% 和 96.8%,较原模型分别提高 2.3、1.3 个百分点;改进后模型与 Faster R - CNN、SSD、YOLO v5s、YOLO v8 算法对比,平均识别精度均值分别提高 37.1、38.0、32.5、7.1 个百分点。搭建基于改进 YOLO v7 - tiny 的农残消解装置并进行检测试验,改进后模型的检出率和漏检率分别为 97% 和 3%,检测效果优于其他网络模型,证明改进后模型具有较高的实际应用价值。本研究可为基于臭氧水的工厂化、无人化果蔬农药残留消解一体机研制提供深度学习识别方法参考。

关键词:农药残留消解;臭氧水;果蔬识别;YOLO v7 - tiny

中图分类号:S24　　**文献标识码**:A　　**文章编号**:1000-1298(2025)10-0725-11　　**OSID**:

Precise Multi-variety Fruit and Vegetable Identification Method in Process of Pesticide Residues Degradation Based on Improved YOLO v7 - tiny

DING Zhikang[1,2]　LAN Yubin[1,2]　HAN Xin[1,2]　ZHAO Shuo[1,2]　BAI Jingbo[3]　WANG Juan[1,2]

(1. *School of Agricultural Engineering and Food Science*, *Shandong University of Technology*, *Zibo* 255000, *China*
2. *Research Institute of Ecological Unmanned Farm*, *Shandong University of Technology*, *Zibo* 255000, *China*
3. *Shandong Siyuan Agricultural Development Co.*, *Ltd.*, *Zibo* 255400, *China*)

Abstract: Utilizing ozone water with strong oxidation property, which is healthy and pollution-free, spraying ozone water in accordance with different types of fruits and vegetables and diverse pesticide residues is an effective approach to achieve automatic, intelligent, green, and efficient digestion treatment of fruit and vegetable residues. The rapid and precise identification of fruit and vegetable types is the prerequisite for guiding the concentration of ozone water required for targeted spraying of factory and unmanned treatment equipment. A method based on the improved YOLO v7 - tiny was proposed to accurately identify multiple varieties of fruits and vegetables during the process of agricultural residues digestion. Firstly, the asymptotic feature pyramid network (AFPN) was introduced in the Head part to substitute the original YOLO v7 - tiny pyramid network. Secondly, the efficient multi-scale attention

收稿日期:2024 - 07 - 16　修回日期:2024 - 08 - 27

基金项目:山东省蔬菜产业技术体系项目(SDAIT - 05)、山东省自然科学基金项目(ZR2023QC213)、山东省农业重大技术协同推广计划项目(SDNYXTTG - 2023 - 20)和山东省标准创新型企业计划项目(鲁市监标函[2023]246 号)

作者简介:丁志康(1999—),男,硕士生,主要从事计算机视觉与图像处理研究,E-mail:19862512796@163.com

通信作者:王娟(1979—),女,教授,主要从事农产品质量安全技术与装备研究,E-mail:wangjuan7912@163.com

module (EMA) was added to the backbone to enhance the model's capability of extracting effective feature information from fruit and vegetable images. Finally, the loss function of the original YOLO v7 - tiny network was replaced by Wise - IoU. The experimental results indicated that the parameter number, computational capacity, and model size of the improved YOLO v7 - tiny model reached 4.5×10^6, 1.28×10^{10}, and 8.9 MB respectively, which were decreased by 25.0%, 3.0%, and 27.6% compared with that of the original model. The average accuracy and average precision were 97.9% and 96.8%, which were 2.3 percentage points and 1.3 percentage points higher than those of the original model respectively. Compared with Faster - RCNN, SSD, YOLO v5s, and YOLO v8 algorithms, the average recognition accuracy of the improved model was increased by 37.1 percentage points, 38.0 percentage points, 32.5 percentage points, and 7.1 percentage points respectively. An agricultural residue digestion device based on the improved YOLO v7 - tiny was constructed and the detection test was conducted. The detection rate and missing rate of the improved model were 97% and 3% respectively, and the detection effect was superior to other network models, which proved that the improved model had high practical application value. The research result would provide a reference for the deep learning identification method for the development of an integrated machine for industrial and unmanned fruit and vegetable residues digestion based on ozone water.

Key words: pesticide residues degradation; ozone water; fruit and vegetable recognition; YOLO v7 - tiny

0 引言

果蔬在我国居民的膳食结构中占比超 40%,且根据近年农药的使用状况来看,果蔬中的农药残留(简称农残)检出率一直居高不下[1]。果蔬表皮所含的营养价值极高,对于一些以保留果皮食用为主的人群而言,如何在保存果蔬表面完整条件下实现果蔬表面的农残消解是当前所面临的重要问题[2-4]。

目前,果蔬加工企业大多采用传统的喷淋清洗,不仅耗水量大,且单次清洗的果蔬种类单一,无法对果蔬表面的农残达到良好的消解效果[5-6]。通过借助强氧化性、无毒无污染的臭氧水来替代传统的清洁剂,不仅可以对果蔬表面农残实现消解效果,对于果蔬储藏和保鲜也有一定帮助[7-8]。目前,臭氧水作为一种广谱、高效的清洁剂已在国外得到广泛利用,利用臭氧解毒技术在美国、日本、新加坡等地普及率已在 80% 以上,而在我国普及率不足 1%[9-10]。文献[11-13]研究表明,臭氧水在去除果蔬表面农药残留方面具有良好效果,臭氧水消解农残的效率受到果蔬种类和果蔬形态的综合影响,因此利用臭氧水消解果蔬表面农残需要根据果蔬种类进行调整,以便在消解农药残留和保证果蔬品质之间取得良好的平衡[14-16]。

快速、精准识别果蔬种类是指导工厂化、无人化处理设备针对性喷淋臭氧水的重要前提,近年来,深度学习方法克服了传统机器学习方法的限制,在果蔬识别领域中得到广泛应用[17-21]。

基于上述研究,精准快速识别果蔬种类是利用臭氧水进行果蔬农残消解的重要先决条件,借助 YOLO v7 - tiny 模型在识别精度和检测速度的优势,本文提出一种基于改进 YOLO v7 - tiny 轻量化的果蔬识别模型,通过引入渐进特征金字塔网络 AFPN 来替换 YOLO v7 - tiny 中原有的路径聚合网络,不仅降低模型的复杂度,而且有助于减小不同层次特征之间的语义差距,使得模型能更好地适应不同层次的语义信息,提高特征融合效果。同时引入 EMA 注意力机制加强模型对不同果蔬关键特征信息提取,解决果蔬识别准确率低的问题。将损失函数替换为 Wise - IoU 损失函数,提高模型的泛化能力与整体性能。将改进后的模型与 Faster R - CNN、SSD、YOLO v5s、YOLO v8、YOLO v7 - tiny 网络模型对比,评估模型的性能和效果,以期为基于臭氧水的工厂化、无人化果蔬农残消解提供技术支持。

1 材料与方法

1.1 图像采集与增强

为探究臭氧水对不同种类、不同形态果蔬种类的农残消解效果,考虑到现实生活中果蔬农残超标现象中容易多发的果蔬种类,分别选取水果类中的苹果,花菜类中的花菜,果菜类中的番茄,叶菜类中的芹菜作为研究对象,利用手持相机在不同环境、不同光照条件下进行多角度、多距离拍摄,获得 4 种果蔬共 9 460 幅图像。通过对网络上公开数据集进行部分爬取,获得公开图像 2 640 幅。为避免网络在训练过程中出现过拟合现象,对上述图像采用 MixUp 和 Mosaic 方法进行数据增强,MixUp 增强方法是将 2 幅不同图像进行线性插值组合在一起,从

而随机生成一个新的目标样本；Mosaic 增强方法是采用随机替换的方法，将目标数据集中的 4 幅图像进行随机缩放、随机拼接、随机排布的方法，以上两种数据增强方法获得图像 5 500 幅，对现存数据集进行筛选，剔除其中亮度过高，图像过于模糊等低质量图像，共获 17 380 图像，其中包含苹果数据集 3 120 幅，花菜数据集 3 510 幅，番茄数据集 3 050 幅，芹菜数据集 3 150 幅，同时存在 2 种及以上果蔬种类 4 550 幅，数据增强前后图像示例如图 1 所示。

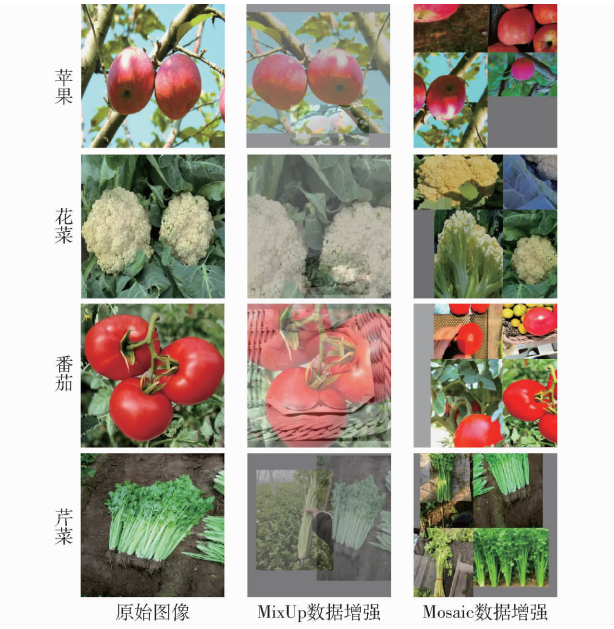


图 1　数据增强前后图像示例

Fig. 1　Photos before and after data enhancement

1.2　数据集构建

采用开源标注软件 LabelImg 对数据集图像进行人工标注，标签分别为 apple（苹果）、cauliflower（花菜）、tomato（番茄）、celery（芹菜）。标注后数据集格式保存为具有位置信息与标签信息的 txt 格式，完成数据集构建。共获取数据集图像 17 380 幅，标签数量 118 850 个，满足神经网络对数据集的大数据要求。按照比例 8∶1∶1 随机划分训练集、验证集、测试集，其中训练集 13 904 幅，验证集 1 738 幅，测试集 1 738 幅。

2　模型改进与训练

2.1　YOLO v7－tiny 算法

YOLO v7－tiny 是在 YOLO v7 版本上改进所得的轻量级版本，其架构由 4 个主要部分组成：输入、特征提取网络、特征融合网络和输出[22－23]。YOLO v7－tiny 模型与原始 YOLO v7 相比，在检测速度与轻量化方面具有显著优势，但 YOLO v7－tiny 网络在参数量、计算量与模型储存占用方面仍有冗余，由于嵌入式设备性能有限，因此对网络模型提出了更高的要求，在保证模型检测精度的前提下，尽可能减少模型的参数量和计算复杂度，实现轻量级高性能识别与处理。

2.2　改进 YOLO v7－tiny 算法

为使模型更好地提取目标特征信息，简化网络模型整体结构，降低计算量，本文对原始 YOLO v7－tiny 做出以下优化，改进后整体网络模型结构图如图 2（图中，CBL 为 Conv（卷积）＋BN（批量归一化）＋LeakyReLU（激活函数）；Contact 为特征连接模块；Maxpool 为最大池化；SPPCSPC 为空间金字塔池化结构；EMA 表示 EMA 注意力；BasicBlock 为残差基

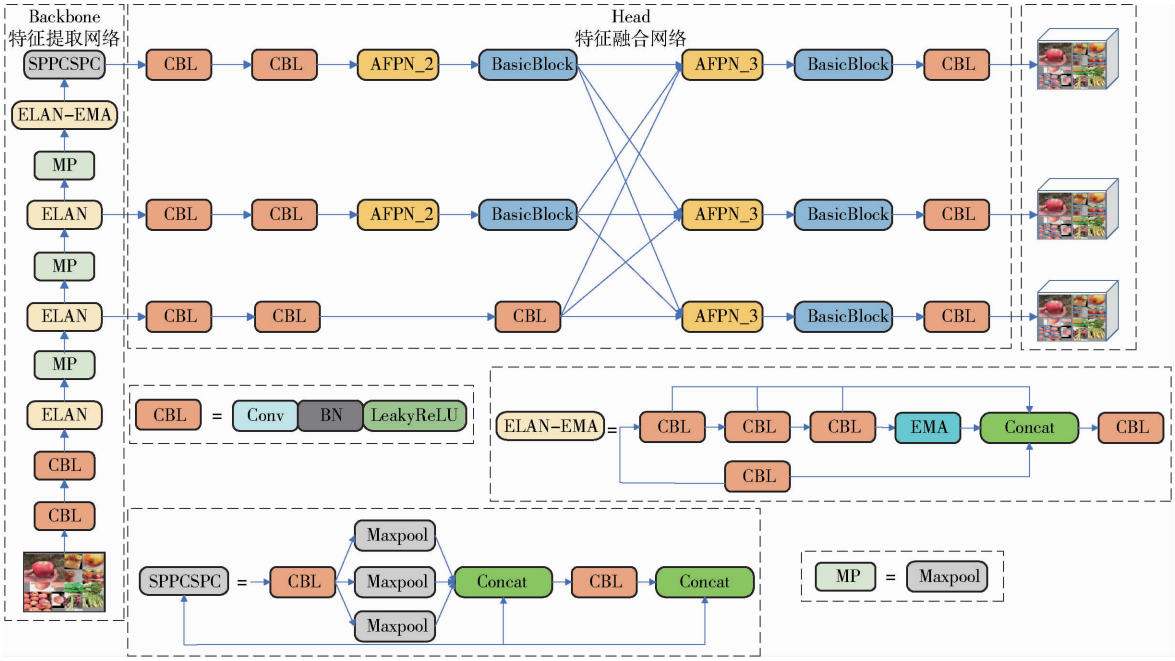


图 2　改进后 YOLO v7－tiny 模型结构图

Fig. 2　Structure diagram of improved YOLO v7－tiny model

础块)所示,改进方法为:

(1)将原始 YOLO v7 - tiny 中的 Head 部分替换为渐近特征金字塔网络 AFPN 结构,不仅减少了不同分层中出现的信息丢失问题,还可以突出果蔬数据集中关键特征信息,轻量化模型同时提高网络模型的准确性与全面性。

(2)在原有高效聚合网络 ELAN 的基础上,通过添加 EMA 注意力机制,不仅保留原有模型的网络架构,还借助 EMA 注意力机制对于关键信息的提取作用,减少网络深度,提高模型精确度。

(3)通过引入 Wise - IoU 损失函数来替代原模型中的 CIoU 损失函数,设计了一种合理的梯度增益分配,减少了极端样本中出现的大梯度或有害梯度,Wise - IoU 损失方法计算更多地关注普通质量的样本,进而提高改进模型的泛化能力和整体性能。

2.2.1 AFPN 特征金字塔

在原始的 YOLO v7 - tiny 网络中,采用多尺度特征提取策略特征金字塔网络(Feature pyramid network,FPN)结构,这种原始策略存在特征信息丢失或退化等相关问题,导致在传播和交互过程中信息可能会丢失或降级,进而导致从原始视图中提取详细特征的效果不佳。为解决此问题,本文引入了渐近特征金字塔网络(AFPN)结构。AFPN 通过融合 2 个相邻的低级特征并逐步将高级特征合并到融合过程中,特征提取过程中首先融合 2 个不同分辨率的低级特征,在特征提取后期阶段,将高级特征纳入融合过程中,最终融合出主干的顶层特征。低级特征与来自高级特征的语义信息和详细信息融合在一起,不仅可以避免多级传输中的信息丢失或退化,还可避免融合过程中非相邻级别之间的巨大语义差距,AFPN 网络结构如图 3 所示。

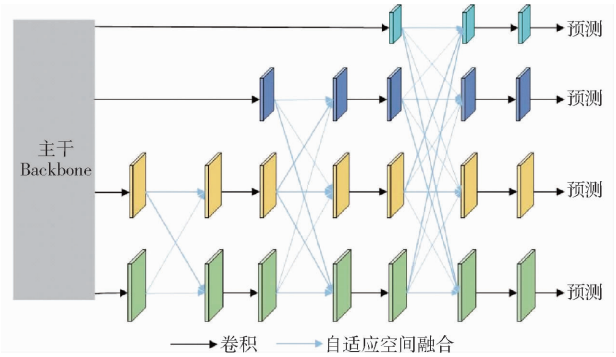


图 3 渐近特征金字塔网络(AFPN)架构图

Fig. 3 Architecture of proposed asymptotic feature pyramid network (AFPN)

在 AFPN 网络结构中,为了进一步提高不同特征融合的有效性,增强关键级的重要性。通过引入自适应空间特征融合(Adaptively spatial feature fusion,ASFF)为不同层的特征分配不同的空间权重,与多层次特征融合方法不同的是,其核心思想是自适应地学习各尺度特征,映射融合的空间权重,通过学习权重参数的方式将不同层的特征融合到一起,使网络自动学习过滤掉其他层的无用信息,从而高效地融合特征,自适应空间融合流程架构如图 4 所示。设 $\boldsymbol{x}_{ij}^{n\to l}$ 表示层次 n 到层次 l 位置的特征向量,所得特征向量表示为 $\boldsymbol{y}_{ij}^{l}$,则计算公式为

$$\boldsymbol{y}_{ij}^{l}=\alpha_{ij}^{l}\boldsymbol{x}_{ij}^{1\to l}+\beta_{ij}^{l}\boldsymbol{x}_{ij}^{2\to l}+\gamma_{ij}^{l}\boldsymbol{x}_{ij}^{3\to l} \tag{1}$$

通过多层次特征的自适应空间融合与特征向量的线性组合而得到 $\boldsymbol{x}_{ij}^{1\to l}$ 的线性组合,如 $\boldsymbol{x}_{ij}^{2\to l}$、$\boldsymbol{x}_{ij}^{3\to l}$,其中 α_{ij}^{l}、β_{ij}^{l}、γ_{ij}^{l} 表示 3 个类的特征空间权重,$\alpha_{ij}^{l}+\beta_{ij}^{l}+\gamma_{ij}^{l}=1$。

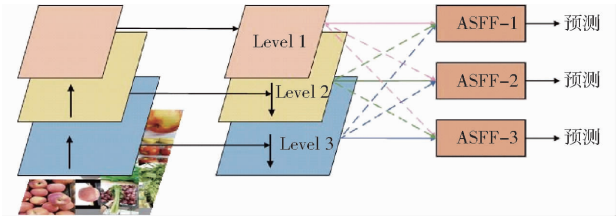


图 4 自适应空间融合流程架构图

Fig. 4 Architecture of proposed adaptive spatial fusion operation

2.2.2 EMA 注意力机制

在消解果蔬农残的识别系统中,原始的 YOLO v7 - tiny 在识别过程中会出现漏检与误检。在自然条件下,由于光照、遮挡等复杂因素导致图像中的无用信息对特征信息的提取造成了干扰,进而影响识别准确度。传统的注意力机制为了提高对特征信息的表征能力,采用通过堆积卷积层数的方法实现,然而大量的卷积层数通常会使模型消耗大量的计算资源,提高了模型的复杂度与计算量,在实际应用中受移动设备运算能力限制,无法得到真正的发挥。

通过引用多尺度注意力模块 EMA 注意力机制,以保留每个通道上的信息和降低计数开销为目标,将部分通道重塑为批量维度并将维度分组为多个子特征,使空间语义特征在每个特征组中均匀分布,EMA 注意力机制的结构如图 5 所示。通过添加 EMA 注意力模块对 ELAN 模块进行改进,将 EMA 插入 ELAN 模块多分支残差主干中,构建 ELAN - EMA 模块,并替换 Backbone 网络中 ELAN 模块,增强 Backbone 对从数据集中所获取的特征图内果蔬信息的特征表达,更高效地关注与复杂背景重合的果蔬信息,提升了区分数据集内特征信息与其他无关信息的能力,减少冗余信息干扰,提升模型检测性能。

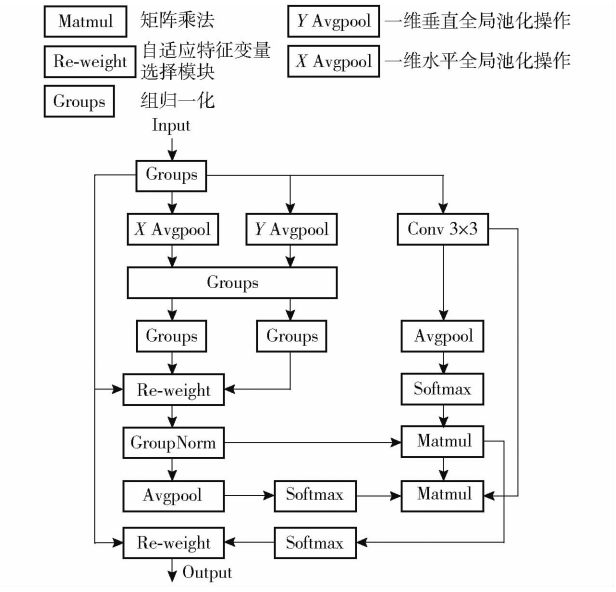


图 5　EMA Attention 结构图

Fig. 5　Efficient multi-scale attention structure diagram

2.2.3　Wise – IoU 损失函数

目标检测作为计算机视觉的核心问题，其检测性能依赖于损失函数的设计。边界框损失函数作为目标检测损失函数的重要组成部分，其良好的定义为目标检测模型带来显著的性能提升[24-25]。本文通过引入基于动态非单调聚焦机制的边界框损失 Wise – IoU 来替代 YOLO v7 – tiny 模型中原有的 CIoU 损失函数，Wise – IoU 可以聚焦果蔬数据集中普通质量的锚框，并提高检测器的整体性能，在降低高质量锚框竞争力的同时，也减小了低质量示例产生的有害梯度，充分挖掘非单调聚焦机制的潜能。Wise – IoU 能够更加准确衡量目标检测结果的质量，并对预测框进行优化，提高模型的性能和准确性，Wise – IoU 损失函数计算公式各项参数如图 6 所示，其中 W_t、H_t 表示目标框与预测框之间重叠区域宽、高；(x,y) 表示预测框的中心坐标；(x_{gt},y_{gt}) 表示目标框的中心坐标；S 表示目标框和预测框并集的面积，$S = wh + W_{gt}H_{gt} - W_tH_t$；$w$、$h$ 表示预测框宽、高；W_{gt}、H_{gt} 表示目标框宽、高；W_g、H_g 表示最小边框宽、高。

IoU 损失用于度量目标检测任务中预测框与真实框的重善程度，其定义为

$$\begin{cases} L_{IoU} = 1 - IoU = 1 - \dfrac{W_tH_t}{S_u} \\ S_u = wh + W_gH_g - W_tH_t \end{cases} \tag{2}$$

距离损失函数 R_{WIoU} 定义为

$$R_{WIoU} = \exp\left(\frac{(x-x_{gt})^2 + (y-y_{gt})^2}{(W_g^2 + H_g^2)^*}\right) \tag{3}$$

聚焦收敛效率 r 定义为

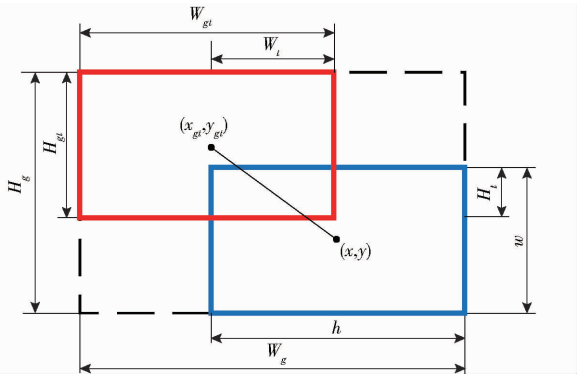


图 6　Wise – IoU 计算参数示意图

Fig. 6　Wise – IoU calculation formula diagram

$$r = \frac{\beta}{\delta\alpha^{\beta-\delta}} \tag{4}$$

其中
$$\beta = \frac{L_{IoU}^*}{\overline{L}_{IoU}} \in [0, +\infty) \tag{5}$$

式中　$\overline{L}_{IoU}$——当前模型实际的 IoU 损失平均值

L_{IoU}^*——最优的 IoU 损失值

δ——收敛难度系数

α——收敛敏感性基数

β——离群度

锚框的离群度 β 由 L_{IoU}^* 与 $\overline{L}_{IoU}$ 比值表述，离群度小意味着锚盒质量高，将较小的梯度增益分配给具有较大离群度的锚框将有效地防止较大的有害梯度[26]。$\beta = \delta$ 时，δ 使 $r = 1$，锚框的离群度满足 $\beta = C$（C 为常值）时，其梯度增益最大。由于 L_{IoU} 是动态的，锚框的质量划分标准也是动态的，这使得 Wise – IoU（v3）可以在每个时刻做出最符合当前情况的梯度增益分配策略。为了防止低质量的锚框在训练早期被落下，初始化 $L_{IoU} = 1$，使 L_{IoU} 的锚框获得最高的梯度增益，在训练的中后期，Wise – IoU（v3）会给低质量的锚框分配较小的梯度增益，以减少有害的梯度，同时，针对普通质量的锚框，提高模型的定位性能。

综上所述，Wise – IoU 损失函数 L_{WIouv3} 定义为

$$L_{WIouv3} = rR_{WIoU}L_{IoU} \tag{6}$$

2.3　模型训练与评价指标

2.3.1　试验平台

试验在 Windows 10 操作系统下进行，以 GPU 为基础对网络进行训练和测试，处理器型号为 Intel（R）Xeon（R）W – 2275 CPU @ 3.30 GHz，显卡为 NVIDIA GeForce RTX 3090 24 GB。软件运行环境选用 Pytorch 1.13.1、Torchvision 0.14.1，采用 Pycharm 专业版进行编译，编程语言为 Python 3.8，以下所有对比模型均在相同环境下运行。

2.3.2　参数设置

为了得到更好训练结果，对网络训练的超参数进行设置，目标检测输入图像尺寸为 640 像素 ×

640 像素,采用 SGD 优化器,SGD 动量设为 0.937,训练批次设置为 16,训练迭代次数为 200 轮,前 3 轮采用热身训练策略,热身训练动量为 0.8,初始学习率为 0.01,终止学习率 0.1,权重衰减系数为 0.000 5,其余超参数均为默认。

2.3.3 评价指标

为了更好评价改进模型的综合性能,采用准确率(Precision,P)、召回率(Recall,R)、平均精度均值(Mean average precision,mAP)来衡量模型识别检测的准确度;选取帧速率(Frames per secomd,FPS)作为模型识别速度的评价指标;选取参数量(Params)、浮点数计算量(FLOPs)、模型存储占用量作为轻量化评价指标。

3 结果与分析

3.1 AFPN 模块对比试验

为了解决原始金字塔网络中各个层次在传输中信息丢失的问题,进一步提高模型的识别精度,在更改特征通道数量后将特征输入到 AFPN 网络中。通过使用 2×2 卷积进行 2 倍下采样,使用 4×4 卷积进行 4 倍下采样,使用 8×8 卷积进行 8 倍下采样,将同样的方法应用于上采样当中。特征融合的初始阶段从主干网络的每个级别中提取最后一层特征,最终形成一组不同尺度的特征,将其标识为 C2、C3、C4 和 C5。低层特征 C2 和 C3 输入到特征金字塔网络中进行特征融合,将 C4 和之前添加的 C2、C3 一起做特征融合,最后添加 C5 和之前添加的层继续做特征融合,产生一组多尺度特征 P2、P3、P4、P5。

为了探究多尺度特征在识别过程中的有效性与可靠性,分别针对不同多尺度特征 P3、P4、P5 与 P2、P3、P4、P5 进行试验并与原始 YOLO v7 - tiny 相对比,试验结果如表 1 和图 7 所示,试验结果表明,针对不同的多尺度特征,P3、P4、P5 多尺度特征拥有较小的参数量与浮点数计算量,P2、P3、P4、P5 多尺度特征在检测精度方面具有较好的效果,其中准确率和平均精度均值较原模型分别提高 1.4、0.4 个百分点,模型参数量、浮点数计算量与模型存储占用量只有原模型的 75.0%、96.9% 和 72.4%。

表 1 AFPN 对比试验

Tab.1 AFPN comparison test

模型	准确率/%	平均精度均值/%	参数量	浮点数计算量	模型存储占用量/MB
YOLO v7 - tiny	95.6	95.5	6.0×10^6	1.32×10^{10}	12.3
YOLO v7 - tiny - AFPN2345	96.4	94.1	4.7×10^6	1.79×10^{10}	10.1
YOLO v7 - tiny - AFPN345	97.0	95.9	4.5×10^6	1.28×10^{10}	8.9

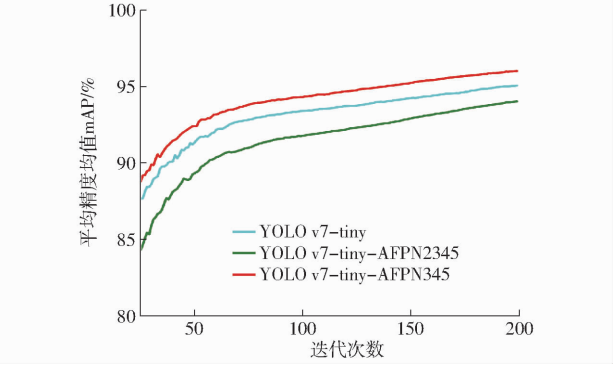


图 7 AFPN 对比试验曲线

Fig.7 Curves of AFPN comparison test

3.2 不同注意力机制检测性能对比

为了得到更好更精准的检测模型,提高模型提取目标特征信息的能力,本文通过在 YOLO v7 - tiny 模型的 Backbone 主干 ELAN 模块中添加 EMA 注意力机制,通过与不同种类的注意力机制相对比来验证改进模块的有效性。通过与通道注意力机制 SE、ECA,混合注意力机制 CBAM,无参注意力机制 SimAM 和全局注意力机制 GAM 相对比,所有改进试验添加注意力位置与数量相同,试验结果如表 2 所示,由表 2 可知,EMA 注意力机制在不增加计算量与模型大小的前提下,对于模型准确率提升最大,效果最好,较原始模型准确率和平均精度均值均提高 0.4 个百分点。

3.3 不同损失函数性能对比

为了更好地提高模型的鲁棒性,通过优化损失函数,调整模型的参数,使模型能够更好地逼近真实结果。通过引入 Wise - IoU 损失函数来替换原 YOLO v7 - tiny 模型中 CIoU。Wise - IoU(v3)使用动态非单调评估锚盒质量的机制,使模型更加关注锚定普通质量的框,并提高了模型定位对象的能力。为了验证模型的有效性,通过与原始的 CIoU 损失函数和常用的 Focal - IoU、Wise - IoU(v1)、Wise - IoU(v2)损失函数做对比,试验效果如图 8 和表 3 所示。试验表明,Wise - IoU(v3)损失函数不仅可以加快模型的收敛效果,对于模型的准确性也有所提升,同时损失值也是上述函数中最小的,准确率和平均精度均值较 YOLO v7 - tiny 中原有的 CIoU 函数提升 1.1、0.6 个百分点,准确率较 Focal - IoU、Wise - IoU(v1)、Wise - IoU(v2)提升 2.0、1.3、1.6 个百分点。

表 2　不同注意力机制对比

Tab. 2　Comparison of different attention mechanisms

模型	准确率/%	平均精度均值/%	参数量	浮点数计算量	模型存储占用量/MB	帧速率/(f·s^{-1})
YOLO v7 - tiny	95.6	95.5	6.0×10^{6}	1.32×10^{10}	12.3	95.3
YOLO v7 - tiny - CBAM	95.7	95.9	6.0×10^{6}	1.32×10^{10}	12.3	89.8
YOLO v7 - tiny - SimAM	94.2	96.0	6.0×10^{6}	1.32×10^{10}	12.3	89.7
YOLO v7 - tiny - GAM	95.9	96.1	8.2×10^{6}	1.85×10^{10}	16.7	85.6
YOLO v7 - tiny - ECA	95.4	95.9	6.0×10^{6}	1.32×10^{10}	12.3	89.4
YOLO v7 - tiny - SE	95.2	95.9	6.0×10^{6}	1.32×10^{10}	12.3	87.7
YOLO v7 - tiny - EMA	96.0	95.9	6.0×10^{6}	1.33×10^{10}	12.3	92.9

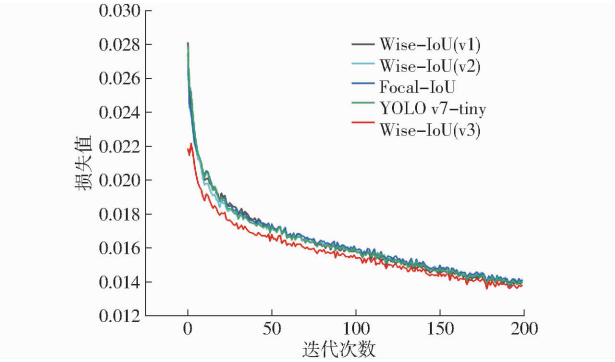


图 8　不同损失函数对比

Fig. 8　Comparison of different loss functions

表 3　不同损失函数性能对比

Tab. 3　Comparison of different loss functions

模型	准确率/%	平均精度均值/%	帧速率/(f·s^{-1})
YOLO v7 - tiny - CIoU	95.6	95.5	95.3
YOLO v7 - tiny - Focal - IoU	94.7	95.9	95.8
YOLO v7 - tiny - Wise - IoU(v1)	95.4	96.0	94.8
YOLO v7 - tiny - Wise - IoU(v2)	95.1	95.9	95.6
YOLO v7 - tiny - Wise - IoU(v3)	96.7	96.1	95.7

3.4　不同模型性能对比

为了验证改进后的模型性能，将改进后的模型与目前主流的检测模型 Faster R - CNN、SSD、YOLO v5s、YOLO v8、YOLO v7 - tiny 相比较，在相同数据集与相同环境下训练相同轮次，试验结果如表 4 所示，改进后的模型准确率、召回率、平均精度均值均大于其他模型，其中平均精度均值较 Faster R - CNN、SSD、YOLO v5s、YOLO v8、YOLO v7 - tiny 分别高出 37.1、38.0、32.5、7.1、1.3 个百分点，其中模型存储占用量只有以上模型的 13.0%、15.5%、45.6%、65.0%、72.3%，参数量也是以上模型中最小的。虽然改进后的模型在检测速度上略有下降，但在精度与轻量化方面均优于以上常用网络模型，证明本研究模型在识别果蔬方面具有较好的效果。

表 4　不同模型对比

Tab. 4　Comparison of different models

模型	准确率/%	召回率/%	平均精度均值/%	参数量	浮点数计算量	模型存储占用量/MB	帧速率/(f·s^{-1})
Faster R - CNN	56.4	57	59.7	5.55×10^{7}	3.42×10^{10}	68.3	22.8
SSD	58.9	59	58.8	3.05×10^{7}	5.04×10^{10}	57.6	33.7
YOLO v5s	82.7	85	84.3	1.58×10^{7}	1.89×10^{10}	19.5	55.8
YOLO v8	88.6	87	89.7	7.1×10^{6}	1.60×10^{10}	13.7	54.8
YOLO v7 - tiny	95.6	98	95.5	6.1×10^{6}	1.32×10^{10}	12.3	95.3
YOLO v7 - AEW(本文模型)	97.9	99	96.8	4.5×10^{6}	1.28×10^{10}	8.9	75.5

3.5　消融试验性能对比

为验证改进模型各个部分的有效性，在同一环境下进行消融试验，试验结果如表 5 所示。试验结果表明，3 个改进措施对于模型精度均有提高，原模型识别果蔬的精确率为 95.6%，平均精度均值为 95.5%。通过在模型添加 AFPN 网络后，准确率与平均精度值较原模型分别上涨 1.4、0.4 个百分点，模型参数量与浮点数计算量较原模型减少 26.2% 与 3.1%，模型存储占用量较原模型减少 27.6%。试验表明 AFPN 网络结构对于模型精度与模型轻量化均有改进，原因在于 AFPN 网络结构引入渐进连接与特征融合 2 种改进措施，避免了特征信息的损失与冗余，能够更好地平衡低层与高层特征的贡献，进而提高了模型的检测能力；通过添加 EMA 通道注意力机制，精确率和平均精度较原模型均提高 0.4 个百分点，参数量与浮点数计算量等无明显提升，表明 EMA 注意力机制提取特征信息具有较好效果；通过在网络模型引入 Wise - IoU(v3) 来

表 5 消融试验结果

Tab. 5 Ablation experiment results

AFPN	EMA Attention	Wise－IoU(v3)	准确率/%	平均精度均值/%	参数量	浮点数计算量	模型存储占用量/MB
－	－	－	95.6	95.5	6.0×10^6	1.32×10^{10}	12.3
√	－	－	97.0	95.9	4.5×10^6	1.28×10^{10}	8.9
－	√	－	96.0	95.9	6.0×10^6	1.32×10^{10}	12.3
－	－	√	96.7	96.1	6.0×10^6	1.32×10^{10}	12.3
√	√	－	97.4	96.8	4.5×10^6	1.28×10^{10}	8.9
－	√	√	97.6	96.3	6.0×10^6	1.32×10^{10}	12.3
√	－	√	97.6	96.5	4.5×10^6	1.28×10^{10}	8.9
√	√	√	97.9	96.8	4.5×10^6	1.28×10^{10}	8.9

注：√表示使用该算法；－表示不使用该算法。

替换 YOLO v7－tiny 中原有的 CIoU，加快了模型的收敛速度，同时降低了模型训练时的损失值，准确率与平均精度均值较原模型分别提升 1.1、0.6 个百分点，参数量、浮点数计算量、模型存储占用量无较大改变。在添加 3 种改进后，准确率与平均精度均值分别达到 97.9% 和 96.8%，较原模型增加 2.3、1.3 个百分点，参数量、浮点数计算量和模型存储占用量分别为 4.5×10^6、1.28×10^{10} 和 8.9 MB，较原模型分别减少 25.0%、3.0% 和 27.6%，在准确率提高的同时减少了模型参数量与浮点数计算量，同时模型存储占用量也有明显降低，证明以上改进措施能够有效提高模型的识别精度与模型轻量化。

4 模型部署与热力图可视化

4.1 模型部署与加速

为了验证改进后模型边缘设备部署情况，受嵌入式设备算力限制，导致模型的识别速度低下，为了进一步提升推理速度，采用 TensorRT 推理库进行优化加速并部署到 Jetson Orin NX 开发板上，TensorRT 利用深度学习模型中的并行计算、内存优化和精度调整等技术，对模型进行优化和推理加速。通过将改进后的 YOLO v7－tiny 模型转换为 TensorRT 可执行文件，可以充分利用 GPU 的计算能力，实现更快的推理速度。试验结果显示，未使用 TensorRT 加速前识别速度为 15.5 f/s，使用 TensorRT 加速后识别速度可达 56.7 f/s，满足实时监测的要求。

4.2 果蔬检测试验

为了验证改进后模型的可靠性与实用性，搭建基于改进 YOLO v7－tiny 模型的农残消解装置，实物装置如图 9 所示，其工作过程为：待清洗果蔬经传送带运送至高清工业摄像头的工作范围，工业摄像头将检测到的信号传输给计算机，计算机通过串口通信将指令发送给单片机，单片机根据接收到的信号控制继电器进而控制电磁阀工作，电磁阀控制高压扇形喷头喷淋不同浓度的臭氧水来实现不同果蔬的农残消解。

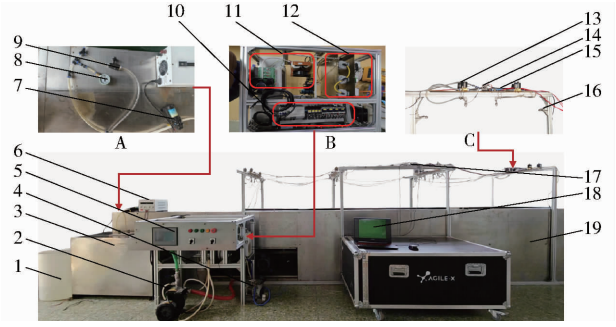


图 9 基于改进 YOLO v7－tiny 模型的果蔬农残消解装置

Fig. 9 Fruit and vegetable pesticide degradation device based on improved YOLO v7－tiny model

1. 清水箱 2. 气液混合泵 3. 臭氧水箱 4. 空气压缩机 5. 臭氧控制面板 6. 直流电源 7. 水泵 8. 压力表 9. 溢流阀 10. 电气控制系统 11. 臭氧发生装置 12. 制氧机 13. 电磁阀 14. 高清摄像头 15. 继电器 16. 扇形喷嘴 17. 单片机 18. 显示屏 19. 传送装置

选取尺寸不同的 4 种果蔬各 25 个进行检测试验，传送带速度为 0.2 m/s，试验结果如表 6 所示，试验结果表明，当前主流模型对于果蔬的检出率均在 70% 以上，其中 Faster R－CNN、SSD、YOLO v5s、YOLO v8、YOLO v7－tiny 的检出率分别为 61.0%、65.0%、85.0%、89.0%、93.0%，原因在于受传送带速度、光照强度和模型检测精度影响，主流模型对于

表 6 农残消解装置果蔬检测结果

Tab. 6 Detection results of fruit and vegetable in agricultural residue digestion device

模型	果蔬总数	检出数	漏检数	检出率/%	漏检率/%	错检数
Faster R－CNN	100	71	29	61.0	39.0	0
SSD	100	75	25	65.0	35.0	0
YOLO v5s	100	85	15	85.0	15.0	0
YOLO v8	100	89	11	89.0	11.0	0
YOLO v7－tiny	100	93	7	93.0	7.0	0
YOLO v7－AEW（本文模型）	100	97	3	97.0	3.0	0

实际应用中的果蔬检测模型准确性和实用性还有待提高；改进后 YOLO v7 – tiny 模型的检出率达到 97.0%，漏检率仅为 3.0%，改进后模型的误检率较改进前降低了 4 个百分点，表明改进后 YOLO v7 – tiny 模型在检测性能上有明显提升。考虑到在果蔬农残消解的实际应用中对检测精度的要求，以避免造成资源浪费，达到果蔬表面农残的充分消解，改进后模型在同等情况下检测更准确，更符合实际需要。

4.3　模型特征热力图可视化

为了更直观地显示改进模型以及改进后各个模块对于识别能力的提升，采用 Grad – CAM（Gradient-weighted class activation mapping）绘制热力图，热力图中的不同颜色表示图像在果蔬检测任务中每个位置的重要性，颜色越深，正响应性越高，模型越关注它，修改前后模型热力图变化如图 10 所示。由图 10 可知，改进后的模型对于果蔬的重要特征区域更加关注，有助于模型对不同果蔬的检测。

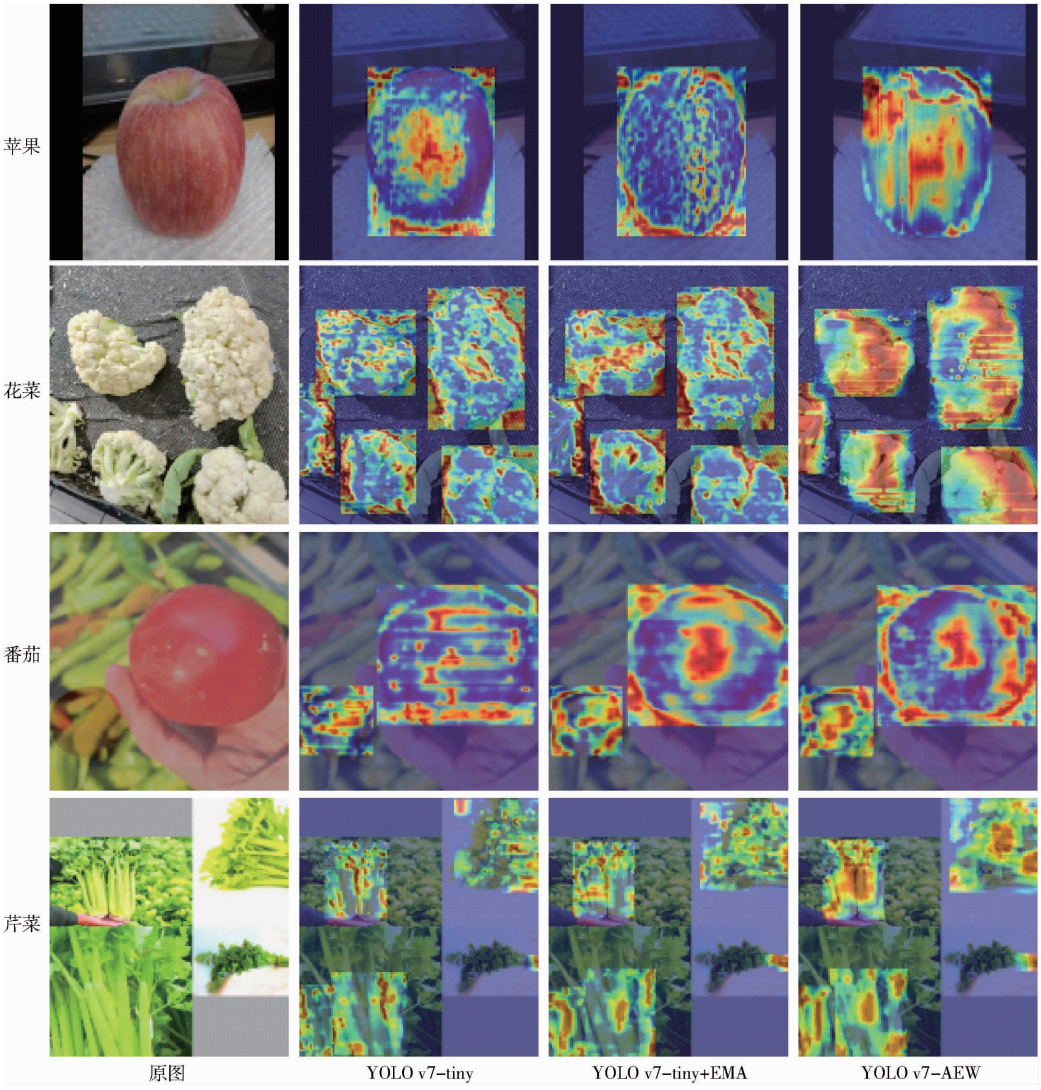


图 10　改进前后热力图

Fig. 10　Heat maps before and after improvement

5　结论

（1）为快速、精准识别果蔬种类，以指导工厂化、无人化臭氧水农残处理设备针对性喷淋所需浓度的臭氧水，提出了一种基于改进 YOLO v7 – tiny 的农残消解过程中多品种果蔬精准识别方法。首先通过在 Head 部分引入渐近特征金字塔网络（AFPN），在实现网络结构轻量化的同时进一步提高模型准确率；其次在 Backbone 部分加入多尺度注意力模块 EMA，以提高模型对果蔬图像中有效特征信息的提取能力；最后，将原有 YOLO v7 – tiny 网络的损失函数替换为 Wise – IoU，以提高模型的泛化能力。该方法为基于臭氧水的工厂化、无人化果蔬农残消解一体机研制提供了深度学习识别方法参考。

（2）改进后识别模型在轻量化与识别精度方面较原始 YOLO v7 – tiny 模型均实现有效提升。试验结果表明，改进后模型的准确率和平均精度均值分别达到 97.9% 和 96.8%，较原模型分别提高 2.3、

1.3 个百分点;改进后模型存储占用量仅为 8.9 MB,较原模型减少 27.6%,同时参数量与浮点数计算量较原模型分别减少 25.0%、3.0%,在轻量化的同时仍保持较高识别精度。改进后识别模型的平均精度均值较 Faster R - CNN、SSD、YOLO v5s、YOLO v8、YOLO v7 - tiny 模型分别高出 37.1、38.0、32.5、7.1、1.3 个百分点,而模型存储占用量只有上述模型的 13.8%、16.3%、15.8%、68.6%、72.3%,说明本文提出的识别模型较目前常用模型具有精度高和轻量化优势。

参 考 文 献

[1] 丁亚会, 陈诚, 乔晓军, 等. 基于物联网的病虫害绿色防控系统研发与应用[J]. 中国农业科技导报, 2024, 26(4): 77 - 86.
DING Yahui, CHEN Cheng, QIAO Xiaojun, et al. Development and application of green pest control system based on IoT technology[J]. Journal of Agricultural Science and Technology, 2024, 26(4): 77 - 86. (in Chinese)

[2] 王珊. 臭氧水处理对小白菜中农药残留马拉硫磷和丁硫克百威的降解和调控机制研究[D]. 沈阳: 沈阳农业大学, 2022.
WANG Shan. Degradation and regulation mechanism of malathion and carbosulfan pesticide residues in pak choi by ozone water treatment[D]. Shenyang: Shenyang Agricultural University, 2022. (in Chinese)

[3] 隋斌, 董姗姗, 孟海波, 等. 农业工程科技创新推进农业绿色发展[J]. 农业工程学报, 2020, 36(2): 1 - 6.
SUI Bin, DONG Shanshan, MENG Haibo, et al Innovation in agricultural engineering and technology to accelerate green development of agriculture[J]. Transactions of the CSAE, 2020, 36(2): 1 - 6. (in Chinese)

[4] 刘媛, 程铭, 王健, 等. 酸性电生功能水联合超声波去除马铃薯净菜中 4 种农药残留效果分析[J]. 食品工业科技, 2022, 43(5): 262 - 269.
LIU Yuan, CHENG Ming, WANG Jian, et al. Effect of acid electrolyzed functional water ultrasonic cleaning on the removal of 4 pesticide residues in fresh-cut potatoes[J]. Science and Technology of Food Industry, 2022, 43(5): 262 - 269. (in Chinese)

[5] 乔雄梧. 食品中农药残留风险评估述评[J]. 农药学学报, 2023, 25(1): 12 - 22.
QIAO Xiongwu. A critical review of dietary risk assessment of pesticide residues in foods[J]. Chinese Journal of Pesticide Science, 2023, 25(1): 12 - 22. (in Chinese)

[6] LAN Y, HUANG Z, DENG X, et al. Comparison of machine learning methods for citrus greening detection on UAV multispectral images[J]. Computers and Electronics in Agriculture, 2020, 171: 105234.

[7] 李晓晗, 吴舸, 张贤钊, 等. 臭氧去除果蔬中农药残留研究进展[J]. 农药学学报, 2023, 25(1): 35 - 50.
LI Xiaohan, WU Ge, ZHANG Xianzhao, et al. Research progress on removal of pesticide residues in fruits and vegetables by ozone[J]. Chinese Journal of Pesticide Science, 2023, 25(1): 35 - 50. (in Chinese)

[8] 陈存坤, 张慧杰, 纪海鹏, 等. 臭氧精准处理提高采后草莓抗氧化酶活性和酚类物质含量[J]. 农业工程学报, 2019, 35(10): 274 - 280.
CHEN Cunkun, ZHANG Huijie, JI Haipeng, et al. Ozone treatment improving antioxidant enzyme activity and phenolic content of postharvest strawberry[J]. Transactions of the CSAE, 2019, 35(10): 274 - 280. (in Chinese)

[9] 乔晓东, 贾海遥, 王晨健, 等. 有机基质臭氧消毒设备设计与试验[J]. 农业机械学报, 2020, 51(7): 138 - 145.
QIAO Xiaodong, JIA Haiyao, WANG Chenjian, et al. Design and experiment of ozone sterilizer device for organic matrix[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(7): 138 - 145. (in Chinese)

[10] 罗自生, 张莉. 臭氧处理对竹笋木质化及相关酶活性的影响[J]. 农业机械学报, 2010, 41(11): 115 - 118.
LUO Zisheng, ZHANG Li. Effects of O_3 on lignification and related enzyme activity in bamboo shoots[J]. Transactions of the Chinese Society for Agricultural Machinery, 2010, 41(11): 115 - 118. (in Chinese)

[11] 伍季, 吕微, 李向力. 蔬菜残留有机磷农药脱除新方法[J]. 食品研究与开发, 2014, 35(3): 72 - 74,90.
WU Ji, LÜ Wei, LI Xiangli. Study on the new methods of degradation of organophosphorus pesticide residues in vegetables[J]. Food Research and Development, 2014, 35(3): 72 - 74,90. (in Chinese)

[12] 王琼, 姜微波, 曹建康, 等. 臭氧溶解特性及对哈密瓜中农药残留降解的研究[J]. 中国农学通报, 2014, 30(25): 207 - 12.
WANG Qiong, JIANG Weibo, CAO Jiankang, et al. Ozone dissolution characteristics and removal effect of pesticide residues in cantaloupes by ozone water[J]. Chinese Agricultural Science Bulletin, 2014, 30(25): 207 - 212. (in Chinese)

[13] 季仁东. 基于光谱分析的典型食品农药残留检测与降解关键技术研究[D]. 南京: 南京航空航天大学, 2015.
JI Rendong. Research on the detection of pesticide residueand degradation key technology of typical food by spectroscopic methods[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2015. (in Chinese)

[14] 申元丽, 马金锋, 赵旭, 等. 臭氧氧化降解除草剂草甘膦的实验研究[J]. 环境科学学报, 2011, 31(8): 1647 - 1652.
SHEN Yuanli, MA Jinfeng, ZHAO Xu, et al. Ozonation of herbicide glyphosate[J]. Acta Scientiae Circumstantiae, 2011, 31(8): 1647 - 1652. (in Chinese)

[15] 孙宇, 刘宝震, 安呈泰, 等. 基于高级氧化技术降解水中 OPPs 的研究进展[J]. 应用化工, 2024, 53(2): 428 - 432,57.
SUN Yu, LIU Baozhen, AN Chengtai, et al. Research progerss on degradation of organophosphorus pesticides in water based on advanced oxidation technology[J]. Applied Chemical Industry, 2024, 53(2): 428 - 432,57. (in Chinese)

[16] 张志远, 罗铭毅, 郭树欣, 等. 基于改进 YOLO v5 的自然环境下樱桃果实识别方法[J]. 农业机械学报, 2022, 53(增

刊 1)：232 - 240.
ZHANG Zhiyuan, LUO Mingyi, GUO Shuxin, et al. Cherry fuirt detection method in natural scene based on improved YOLO v5 [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(Supp. 1): 232 - 240. (in Chinese)
[17] DORJ U O, LEE M, YUN S S. An yield estimation in citrus orchards via fruit detection and counting using image processing [J]. Computers and Electronics in Agriculture, 2017, 140: 103,12.
[18] 罗家梅. 改进 YOLOv5 的水果品质检测与分类方法研究[D]. 赣州：赣南师范大学,2023.
LUO Jiamei. Research on fruit quality detection and classification based on improved YOLOv5[D]. Ganzhou: Gannan Normal University, 2023. (in Chinese)
[19] MUKHRIDDIN M, AZAMJON M, JINSOO C. Improved classification approach for fruits and vegetables freshness based on deep learning[J]. Sensors, 2022, 22(21): 8192.
[20] NAM Y, ZHANG H, ZENG Y, et al. Intelligent detection of multi-class pitaya fruits in target picking row based on WGB - YOLO network[J]. Computers and Electronics in Agriculture, 2023, 208:107780.
[21] 余琼, 张瑞, 李德豪, 等. 基于残差块与注意力机制的果蔬自动识别方法[J]. 农业机械学报, 2023, 54(增刊 2): 214 - 222.
YU Qiong, ZHANG Rui, LI Dehao, et al. Method for fruit and vegetable automatic recognition based on residual block and attention mechanism[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(Supp. 2): 214 - 222. (in Chinese)
[22] 洪孔林, 吴明晖, 高博, 等. 基于改进 YOLOv7 - tiny 的茶叶嫩芽分级识别方法[J]. 茶叶科学, 2024, 44(1): 62 - 74.
HONG Konglin, WU Minghui, GAO Bo, et al. A grading identification method for tea buds based on improved YOLOv7 - tiny [J]. Journal of Tea Science, 2024, 44(1): 62 - 74. (in Chinese)
[23] 徐胜勇,刘政义,黄远,等. 基于 Self - Attention - BiLSTM 网络的西瓜种苗叶片氮磷钾含量高光谱检测方法[J]. 农业机械学报,2024,55(8):243 - 252.
XU Shengyong, LIU Zhengyi, HUANG Yuan, et al. Hyperspectral non-destructive detection of nitrogen, phosphorus and potassium content of watermelon seedling leaves based on Self - Attention - BiLSTM network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(8): 243 - 252. (in Chinese)
[24] 薛珊, 安宏宇, 吕琼莹, 等. 复杂背景下基于 YOLOv7 - tiny 的图像目标检测算法[J]. 红外与激光工程, 2024, 53(1): 269 - 280.
XUE Shan, AN Hongyu, LV Qiongying, et al. Image target detection algorithm based on YOLOv7 - tiny in complex background [J]. Infrared and Laser Engineering, 2024, 53(1): 269 - 280. (in Chinese)
[25] 付裕. 单源摄像头下的行人多目标跟踪研究[D]. 荆州：长江大学,2023.
FU Yu. Research on pedestrian multi-object tracking under single-source camera[D]. Jingzhou: Yangtze University, 2023. (in Chinese)
[26] 郭文昌. 基于 CNN 与 Transformer 融合的目标检测改进方法及其应用研究[D]. 济南：山东大学,2023.
GUO Wenchang. Research on improved object detection method and its applications based on fusion of CNN and Transformer [D]. Ji'nan: Shandong University, 2023. (in Chinese)