doi:10.6041/j.issn.1000-1298.2024.02.026

基于轻量化高效层聚合网络的黄花成熟度检测方法

吴利刚[1]　陈　乐[2]　周　倩[3]　史建华[1]　马宇波[4]

(1.山西大同大学机电工程学院,大同 037003;2.山西大同大学煤炭工程学院,大同 037003;
3.山西大同大学商学院,大同 037003;4.山西大同大学物理与电子科学学院,大同 037003)

摘要:针对黄花传统人工识别效率低,辨识标准不统一的问题,提出基于轻量化和高效层聚合过渡网络的黄花成熟度识别方法 LSEB YOLO v7。首先,引入轻量化卷积对高效层聚合网络和过渡模块进行轻量化处理,减少模型计算量。其次,在特征提取与特征融合网络之间增加通道注意力机制,提升模型检测性能。最后,在特征融合网络中,优化通道信息融合方式,使用双向特征金字塔网络替换 Concatenate,增加信息融合通道,持续提升模型性能。实验结果表明:与原始模型相比,在黄花成熟度检测中,改进后的 LSEB YOLO v7 模型参数量和浮点运算量分别减少约 2.0×10^6 和 7.7×10^9。训练时长由 8.025 h 降低至 7.746 h,模型体积压缩约 4 MB。同时,训练精确率和召回率分别提升约 0.64 个百分点和 0.14 个百分点,mAP@0.5 和 mAP@0.5:0.95 分别提升约 1.84 个百分点和 1.02 个百分点。此外,调和均值性能保持不变,均为 84.00%。LSEB YOLO v7 算法可均衡模型复杂性与性能,为黄花成熟度检测和智能化采摘设备提供技术支持。

关键词:黄花;成熟度;深度学习;注意力机制;信息融合机制;轻量化

中图分类号:TP399　　**文献标识码**:A　　**文章编号**:1000-1298(2024)02-0268-10　　**OSID**:

Maturity Detection Method for *Hemerocallis citrina baroni* Based on Lightweight and Efficient Layer Aggregation Network

WU Ligang[1]　CHEN Le[2]　ZHOU Qian[3]　SHI Jianhua[1]　MA Yubo[4]

(1. *College of Mechanical and Electrical Engineering*, *Shanxi Datong University*, *Datong* 037003, *China*
2. *College of Coal Engineering*, *Shanxi Datong University*, *Datong* 037003, *China*
3. *College of Business*, *Shanxi Datong University*, *Datong* 037003, *China*
4. *College of Physics and Electronic Science*, *Shanxi Datong University*, *Datong* 037003, *China*)

Abstract: To address the problems of low efficiency of traditional manual identification and inconsistent identification standards, a ripening identification method for *Hemerocallis citrina baroni* based on lightweight and efficient layer aggregation network LSEB YOLO v7 was proposed. Firstly, lightweight convolution was introduced to lighten the efficient layer aggregation network and transition module to reduce the model computation. Secondly, the channel attention mechanism was added between the feature extraction and feature fusion networks to improve the model detection performance. Finally, in the feature fusion network, the channel information fusion method was optimized, and the bi-directional feature pyramid network was used to replace concatenate to increase the information fusion channels and continuously improve the model performance. The experimental results showed that compared with the original algorithm, in the *Hemerocallis citrina baroni* maturity detection, the number of parameters and floating-point operations of the improved LSEB YOLO v7 algorithm were reduced by about 2.0×10^6 and 7.7×10^9, respectively, and the training time was reduced from 8.025 h to 7.746 h, and the model volume was compressed by about 4 MB. Meanwhile, the training precision and recall were improved by about 0.64 percentage and 0.14 percentage, respectively. The mAP@0.5 and mAP@0.5:0.95 were improved by about 1.84 percentages and 1.02 percentages, respectively. In addition, the harmonized

收稿日期:2023-10-10　修回日期:2023-11-21

基金项目:国家自然科学基金项目(12375050)、山西省教育科学“十四五”规划课题项目(GH-220178)、山西省基础研究计划项目(202303021211330)、山西省研究生实践创新项目(2023SJ290)、山西大同大学基础科研基金项目(2022K1)、山西大同大学研究生科研创新项目(2023CX07)和山西大同市科技计划项目(2023015)

作者简介:吴利刚(1986—),男,副教授,博士,主要从事深度学习和目标检测等研究,E-mail:ligangwu@yeah.net

mean remained unchanged at 84.00%. It was evident that the proposed LSEB YOLO v7 algorithm solved the problem of the paradox between model complexity and performance, and provided technical support for intelligent ripening and harvesting inspection equipment for *Hemerocallis citrina baroni*.

Key words: *Hemerocallis citrina baroni*; maturity; deep learning; attention mechanism; information fusion mechanism; lightweight

0　引言

黄花作为经济作物,在食药方面作用广泛,而不同生长阶段的黄花用途不同,经济效益也各不相同[1],但黄花生长速度快,采摘周期短,及时采摘已成熟的黄花,避免花蕾绽放对增加经济收入有积极作用。

现阶段黄花的识别与采摘主要依赖人工完成,识别标准对人工经验的依赖性较大,存在主观性强、可靠性弱的问题[2]。随着劳动力成本的逐年升高,建立统一、智能化的黄花识别标准是扩大黄花产业的关键。

目前,利用计算机视觉和深度学习技术辅助建设智慧农业效果显著,在果蔬生长监测[3]、长势分析[4]、病虫害检测[5]等方面应用广泛。KURYATI 等[6]通过深度学习技术对油棕榈树分类,并实现对其计数。NAN 等[7]对多类别番茄果实进行检测,提出一种多尺度特征融合和特征增强的 WGB-YOLO 算法,多类别平均精度达到 86.0%,但是实时性较差。在 YOLO 算法的基础上,ZHANG 等[8]提出一种旋转检测器,能够针对小麦病害实现任意方向的检测。所提算法检测精确度提升约 10.7%,显著改善模型性能。

此外,在模型优化与改进过程中,轻量化网络和注意力机制也是常用方法。LI 等[9]在 YOLO v4 算法中引入 Ghost Net 轻量化网络,并应用深度可分离卷积替代标准卷积,降低模型的计算量。同时引入(Convolutional block attention module, CBAM)提升检测性能,改进后的算法减少了计算量,提高了检测精确度,实现了对茶叶新芽的检测。WU 等[10]为解决在复杂背景中无花果果实与背景差异小、检测难度大的问题,基于 YOLO v4 算法实现在密集枝叶中对无花果果实成熟度的检测。但是,YOLO v4 算法稳定性较差,模型结构单一,改进与优化局限性较大[11]。

类似地,VINCE 等[12]对咖啡豆的生长状况进行监测,实现咖啡豆缺陷的自动检测,并且基于图像处理技术提升检测效率,此外通过混淆矩阵评估模型性能,最终检测准确率为 95.11%,所提算法实现咖啡豆全自动识别与检测,能够降低劳动力成本。此外,为解决农作物大规模种植过程中病害预警问题,NOVELERO 等[13]将深度学习框架用于植物叶病的早期检测与分类中,减少了劳动力的需求,降低了农作物种植成本,但是所提算法模型结构复杂,参数量和计算量较大。PAWAN 等[14]基于 YOLO v5 算法实现对杂草和农作物的区分与监测,实时监测农作物的生长情况,根据杂草长势与生长规律提出有效管理杂草方法。

同样地,借助计算机视觉和无人机技术,MITALI 等[15]改进 YOLO v5 算法,解决高空椰子的识别问题,所提算法能够对椰子生长状况进行实时监测,降低高空作业的危险性,同时实现对椰子产量的估计。ZHOU 等[16]分析草莓种植过程中的虫害问题,针对蜘蛛螨虫和捕食螨虫对草莓生长造成的不良影响,所提 YOLO v4 算法经过图像预处理实现不同光照强度下的虫害监测,降低虫害监测影响,提高监测效率[17]。基于 YOLO v4 算法,WU 等[18]引入剪枝算法,实现了对 3 种苹果的检测,所提算法简化了模型结构,提升了工厂生产线的分类效率和准确性,弥补了人工分类的不足。

随着深度学习进一步发展和计算机计算能力的不断增强,网络模型逐步发展得愈加庞大,网络结构和深度愈加复杂。因此,为解决特征提取冗余、模型结构复杂、检测精确度和召回率较低问题,本文提出 LSEB (Lightweight-squeeze and excitation-bi directional feature pyramid network) YOLO v7 黄花成熟检测方法。在高效层聚合网络和过渡模块中引入轻量化卷积,降低特征提取过程中的冗余性,减少计算量和参数量,压缩模型体积。在特征提取网络和特征融合网络之间增加挤压-激励(Squeeze and excitation, SE)通道注意力机制,充分利用通道之间的相互依赖性,实现自适应的通道校准,提升模型性能。优化信息融合方式,使用加权双向特征金字塔网络实现跨通道信息融合,减少边缘节点数,增加跨节点的信息通道,持续提升模型性能。

1　黄花轻量化检测方法

1.1　轻量化网络

在深度学习模型中,使用高容量的神经网络能够提高模型的精度,但这往往导致模型复杂,难以在

资源受限的设备上运行。因此,轻量化网络的设计目标是保持较高的准确率,同时尽可能减小模型计算量和压缩模型体积。

与传统卷积相比,轻量化 Ghost 卷积[19]应用特征堆叠策略,将线性变换以后的轻量化特征图和传统卷积产生的固有特征图进行融合,实现新的特征输出。应用轻量化 Ghost 卷积降低特征提取的冗余性,避免相邻特征的重复输出。

轻量化 Ghost 卷积如图 1 所示。首先输入图像经过传统卷积产生 n 个特征图。其次,n 个特征图经过线性变换产生 $n(m-1)$ 个 Ghost 特征图,而经过传统卷积则产生 n 个新特征图。最后,$n(m-1)$ 个 Ghost 特征图与 n 个新特征图进行堆叠,共产生 $n+n(m-1)$ 个特征图。

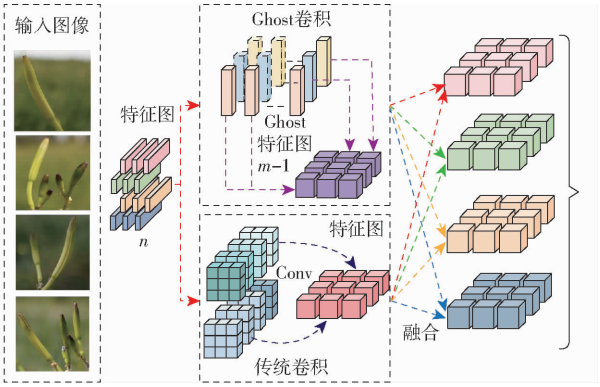


图 1 轻量化 Ghost 卷积

Fig. 1 Lightweight Ghost convolution

假设,c 为输入通道数,nm 是输出通道数,$k\times k$ 是自定义卷积核大小,hw 和 $h'w'$ 分别为输入与输出图像的高、宽。因此传统卷积的计算量为 $C_T=ckknmh'w'$,而 Ghost 卷积计算量为 $C_G=ckknh'w'+nkk(m-1)h'w'$,并且满足 $c\gg m$。因此 $C_G/C_T\approx 1/m$,所以Ghost 卷积计算量约为传统卷积的 $1/m$。可见,引入轻量化卷积能够降低模型计算量。

1.2 高效层聚合过渡网络

在特征提取网络中,高效层聚合网络模块与过渡模块交替使用,逐步提取深层次的特征信息,但是多分支堆叠策略也存在不足。

如图 2 所示,轻量化后的 ELAN(Efficient layer aggregation network)模块将 2 个传统卷积替换为 Ghost 卷积,由 2 个 Ghost 卷积和 5 个传统卷积构成,共 2 条分支路径。因此,在轻量化操作之前,ELAN 模块计算量为

$$C_1=C_{T7}(C_{T1}+C_{T1}C_{T2}C_{T3}+C_{T1}C_{T2}C_{T3}C_{T4}C_{T5}+C_{T1}C_{T2}C_{T3}C_{T4}C_{T5}C_{T6}) \tag{1}$$

引入轻量化操作以后,ELAN 模块计算量为

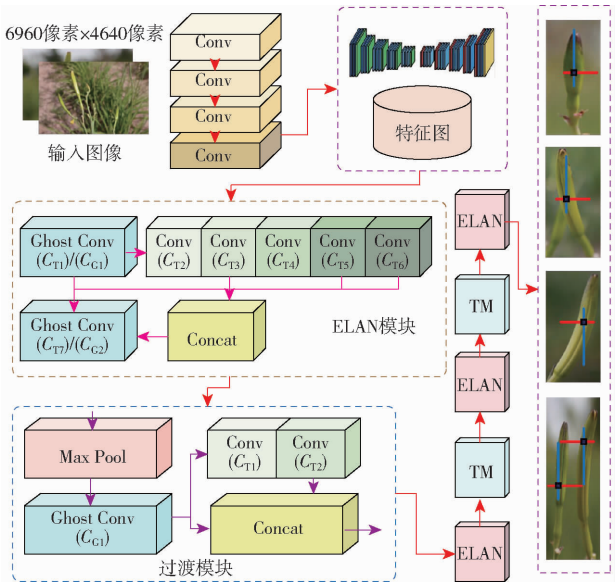


图 2 高效层聚合网络

Fig. 2 Efficient layer aggregation network

$$C_2=C_{G2}(C_{G1}+C_{G1}C_{T1}C_{T2}+C_{G1}C_{T1}C_{T2}C_{T3}C_{T4}+C_{G1}C_{T1}C_{T2}C_{T3}C_{T4}C_{T5}) \tag{2}$$

式中 C_1——轻量化前的 ELAN 模块的计算量

C_2——轻量化后的 ELAN 模块的计算量

C_{Ti}——第 i 个传统卷积,$i=1,2,3,4,5,6,7$

C_{Gi}——第 i 个 Ghost 卷积,$i=1,2$

由于 Ghost 卷积与传统卷积相比,计算量更低,因此,在 ELAN 模块中应用 Ghost 卷积替换传统卷积,能够降低 ELAN 模块的计算量。

同样,在过渡模块中,将 Ghost 卷积应用在最大池化操作以后,能够对池化以后的特征进行筛选,并进一步降低冗余特征数量,实现轻量化特征提取。

1.3 通道注意力机制

SE 注意力机制[20]解决通道间相互依赖的问题,从通道域的角度赋予图像不同位置不同的权重,从而得到更重要的特征信息。

在黄花成熟度检测中,SE 通道注意力机制被增加在特征提取与特征融合网络之间,实现特征提取与特征融合的过渡。

如图 3 所示,特征提取网络中输出的特征信息共经过 2 个阶段:Squeeze 和 Excitation。首先,在 Squeeze 阶段经过 $F_{sq}(\cdot)$ 降低维度,压缩特征信息减少通道数。随后,经过 Excitation 阶段进行 $F_{ex}(\cdot,w)$ 升高维度,还原通道数,保持 Squeeze 和 Excitation 前后通道数不变,完成信息输出。最后将输出信息与输入特征进行融合,完成特征权重的自适应调整。

引入通道注意力机制以后,输出特征信息经过进一步筛选与比较,保留价值性更高的特征,剔除边缘信息,实现特征的倾向性提取。在黄花成熟度检

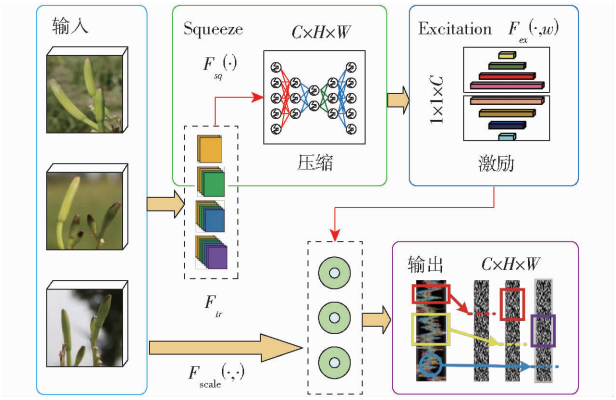


图 3　SE 注意力机制

Fig. 3　Squeeze-and-excitation attention mechanism

测中，引入注意力机制以后能够提升模型检测精确度，降低漏检率和误检率。

1.4　通道信息融合机制

加权双向特征金字塔网络 Bi FPN（Bi-directional feature pyramid network）[21] 在特征金字塔网络的基础上进行改进与优化，不仅能够同时统一缩放所有的骨干网络，而且能够进行高效的双向跨尺度连接，完成加权特征融合。

Bi FPN 首先通过简单的残差操作，增强模型的特征表达能力。其次，根据每个节点的贡献与特征融合能力，删除两端的边缘节点，减少计算量。最后，在不同尺度中增加对应的权重，调节每个尺度的贡献值，提升检测性能，实现特征倾向性提取与特征金字塔网络的融合。

如图 4 所示，以第 6 级输入节点为例，过渡特征权重和输出特征权重分别为

$$P_6^{\mathrm{td}} = \mathrm{Conv}\left(\frac{\omega_1 I_6 + \omega_2 R(I_7)}{\omega_1 + \omega_2 + \varepsilon}\right) \tag{3}$$

$$O_6 = \mathrm{Conv}\left(\frac{\omega_1' I_6 + \omega_2' I_6 + \omega_3' R(I_5)}{\omega_1' + \omega_2' + \omega_3' + \varepsilon}\right) \tag{4}$$

式中　P_6^{td}——第 6 级中间特征

O_6——第 6 级输出

Conv——卷积操作

I_i——第 i 级输入，$i=3,4,5,6,7$

R——上采样或下采样操作

ε——非零极小值

ω_i、ω_i'——输入特征对应的学习权重，$i=1,2,3$

由式(4)可知，第 6 个输出节点融合旁路信息和输入特征，获取不同节点的权重信息与特征信息，实现特征权重的融合。

在黄花成熟度检测中，引入 Bi FPN 能够学习黄花不同特征的重要性，应用 Bi FPN 替换 Concatenate 能够提升模型的训练与检测精确度，满足黄花的检测需求。

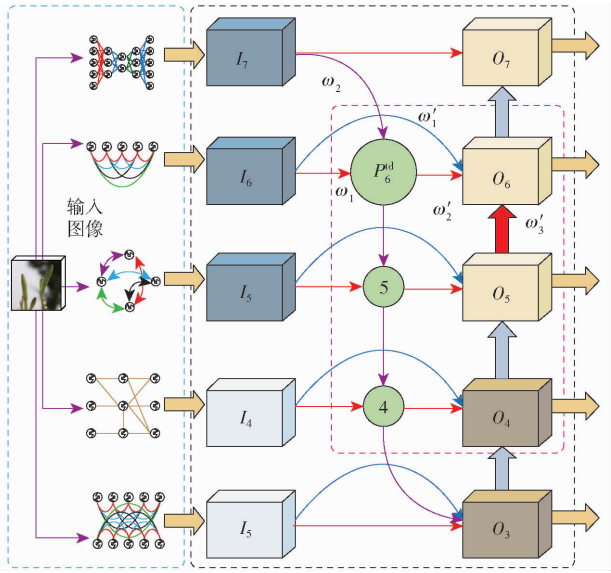


图 4　Bi FPN 信息融合机制

Fig. 4　Bi FPN information fusion mechanism

1.5　LSEB YOLO v7 模型结构

改进后的 LSEB YOLO v7 模型结构如图 5 所示，主要由卷积、Ghost 卷积、不同尺度的最大池化、上采样、高效层聚合网络模块、过渡模块以及 Concatenate 和 Bi FPN 组成。模型结构共分为 4 部分：输入与特征提取网络、SE 注意力机制、空间金字塔池化-跨阶段局部通道（Spatial pyramid pooling - cross-stage partial channels，SPP - CSPC）模块、特征融合网络与输出模块[22]。

由图 5 可知，LSEB YOLO v7 模型采用多分支堆叠策略，各个模块中分支众多，红色的主干路径贯穿整个模型，实现从图像输入到特征提取，特征融合到预测输出的全过程。最终，在输出预测端，经过传统卷积产生 3 个不同尺度的输出，分别对应不同尺寸的检测图像，实现针对性的目标检测。在实现模型轻量化的同时，提升检测精确度和召回率，更加精准高效地完成黄花成熟度检测[23]。

本文所提 LSEB YOLO v7 模型引入轻量化卷积降低模型计算量和参数量，增加通道注意力与融合机制提升模型精确度和召回率，实现对成熟黄花的高精度、高效率检测。与图 5 模型结构相对应，LSEB YOLO v7 模型训练与验证过程为：

参数：迭代次数，小批次训练，学习率，权重衰减

数据预处理：图像分类，裁剪，数据增强

输入：训练集与验证集，标签集

加载：特征提取网络，ELAN，SE，SPP - CSPC，特征融合网络，多尺度输出预测。

验证：算法环境

200 次迭代训练，第 i 次迭代训练（$i \leqslant 200$）：

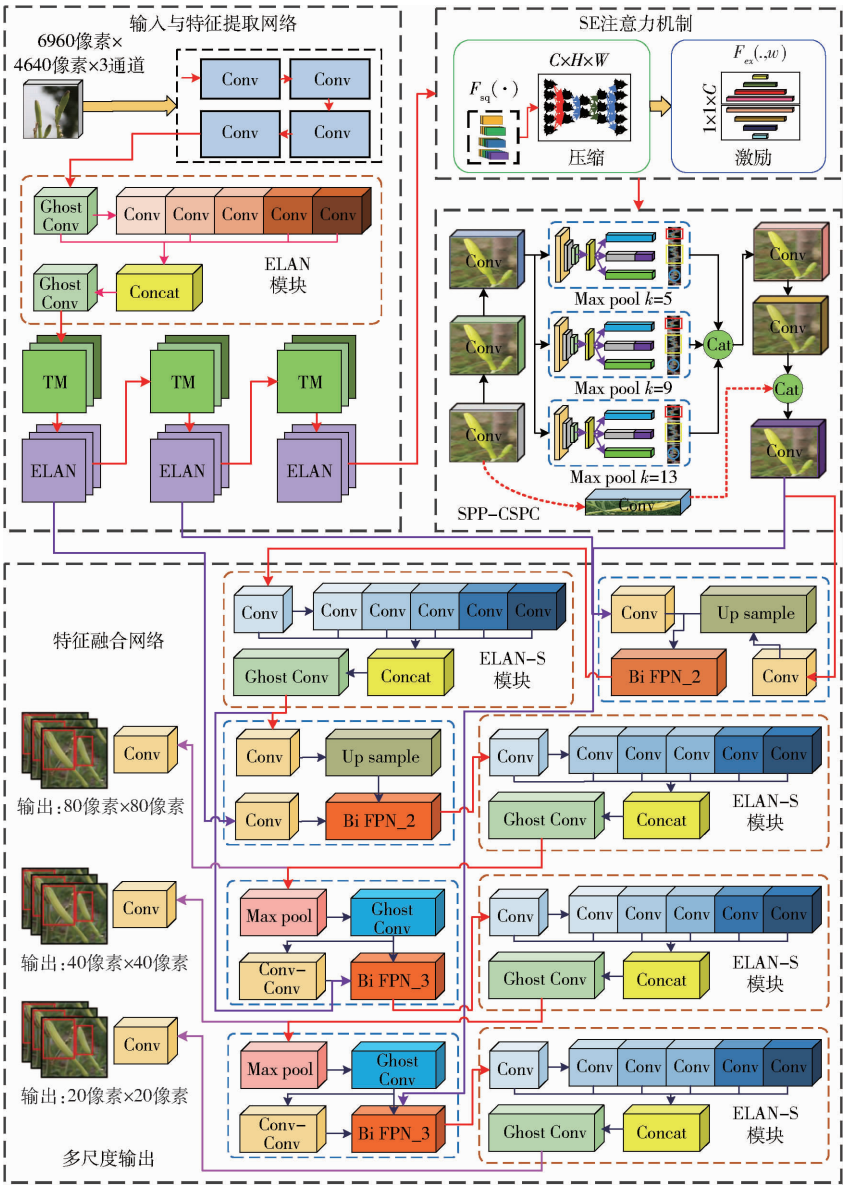


图 5 LSEB YOLO v7 模型结构

Fig. 5 LSEB YOLO v7 model structure

训练网络:

a:特征提取:Conv × 4, ELAN 模型, TM 模型。

b:特征融合:

SE, SPP - CSPC, Ghost 卷积, 上采样, Bi FPN_2, Bi FPN_3。

c:定位误差, 分类误差,置信度误差,总误差 $\sum loss$。

验证网络:

a:模型测试效果 $\overline{\omega}_i$。

b:计算 P,R,mAP@0.5,F_1。

c:调整学习率,更新训练策略。

保存第 i 次的训练结果:权重 π_i,模型 $\overline{\omega}_i$。

更新:$\pi_{i+1} \leftarrow \pi_i$,$\overline{\omega}_{i+1} \leftarrow \overline{\omega}_i$。

保存训练模型:ω'

输出预测:识别、定位、分类

绘制:结果曲线,保存最优模型 ω',输出。

结束训练

由训练与验证过程可知,完成训练的 LSEB YOLO v7 模型可实现对黄花成熟度的识别与定位,并且能够根据训练过程绘制多种精度和实时检测性能的评估曲线,得到评估与训练结果,从而不断优化训练模型。

2 实验数据集与平台

2.1 数据集采集与制作

实验使用 Conon EOS 90D 型相机,在黄花之乡山西省大同市云州区现场拍摄。共获得 800 幅图像,图像尺寸为 6 960 像素 ×4 640 像素。训练集和验证集分别为 597 幅和 148 幅,测试集为 25 幅。由

于黄花成熟花蕾采摘时间有限，故在一天中的最佳采摘时间（清晨或傍晚）进行图像采集。图像包括不同角度、天气下的单个黄花，以及有遮挡、复杂情况多个黄花，丰富数据多样性。

如图 6 所示，在对数据集的处理过程中，将黄花图像通过 LabelImg 插件手动标注出目标的边界真实框，形成可用于训练的 YOLO 格式，同时用数据标注工具包对黄花图像进行标注制作为未成熟（immature）与成熟（mature）2 个类别，标注信息保存为 txt 格式。



(a) 原图　　(b) 标注后图像

图 6　原图与标注后图像示例

Fig. 6　Schematics of original image and annotated images

2.2　实验平台与参数

实验基于 Python 3.8.5 和 CUDA 11.3 环境完成。硬件设备的参数为 NVidia GeForce RTX 3080 10 GB、DDR4 3 600 MHz，Intel Core i9 − 10900k @ 3.7 GHz。此外，LSEB YOLO v7 和 YOLO v7 算法使用相同的参数设置：学习率为 0.01，余弦退火超参数为 0.1，权重衰减系数为 0.000 5，动量梯度下降中动量参数为 0.937。训练过程迭代次数为 200，batch size 为 10。

3　结果分析

3.1　消融实验

在机器学习中，特别是复杂的深度神经网络背景下，消融实验能够有效验证各个模块的必要性，即通过增加或者删减不同的模块来改进与优化神经网络，从而提升模型性能。

如表 1 所示，在黄花成熟度检测中，以 YOLO v7 模型为基础，模型 1 和模型 2 分别在特征提取网络和特征融合网络中引入轻量化 Ghost 卷积，减少参数量和浮点运算量。基于此，模型 3 在特征提取网络与特征融合网络之间增加 SE 通道注意力机制，对特征提取以后的信息进一步筛选，保留价值性更高的特征，剔除无效信息。最后，LSEB YOLO v7 模型在模型 3 的基础上，应用 Bi FPN 替换 Concatenate，实现跨通道的信息融合。

表 1　消融实验结果

Tab. 1　Ablation experiment

模块	YOLO v7	模型 1	模型 2	模型 3	LSEB YOLO v7
Ghost（特征提取网络）	√				
Ghost（特征融合网络）	√	√			
SE	√	√	√	√	
Bi FPN	√	√	√	√	√

注：“√”表示模型加入该模块。

3.1.1　轻量化分析

模型轻量化可能会对模型性能产生一定的影响，但相对于资源消耗和延迟要求较高的场景，模型轻量化具有更多的优势。模型轻量化能够节省存储空间，提高推理速度，降低硬件需求，减少资源受限的影响。

如表 2 所示，以 YOLO v7 模型为参照，模型 2 在模型 1 的基础上进一步实现轻量化。由于模型 2 中引入 Ghost 卷积，增加线性变换，因此网络层数由 415 层增加至 500 层，GPU 的使用从 7.24 GB 提升至 7.35 GB。但是，模型 2 实现轻量化，因此，模型参数量从 3.72×10^7 降低至 3.46×10^7，降低约 6.99%。同样地，模型体积和浮点运算量受到模型结构的影响，分别降低约 6.82% 和 7.73%。

表 2　模型轻量化分析

Tab. 2　Model lightweight analysis

参数	YOLO v7	模型 1	模型 2	模型 3	LSEB YOLO v7
网络层数	415	470	500	506	506
参数量	3.72×10^7	3.55×10^7	3.46×10^7	3.52×10^7	3.52×10^7
浮点运算量	1.05×10^{11}	9.84×10^{10}	9.67×10^{10}	9.71×10^{10}	9.71×10^{10}
训练时长/h	8.025	7.616	7.724	7.719	7.691
模型体积/MB	74.8	71.4	69.7	70.8	70.8
GPU 占用量/GB	7.24	7.33	7.35	7.39	7.21

为弥补轻量化导致的模型性能降低，在模型 3 和 LSEB YOLO v7 模型中依次增加通道注意力机制和通道信息融合机制，实现模型性能的有效提升。但是，改进后的 LSEB YOLO v7 模型轻量化优势更

加明显。

与原始算法相比,LSEB YOLO v7 模型的参数量和浮点运算量分别降低约 5.46% 和 7.35%,模型训练时间由 8.025 h 降低至 7.691 h,减少约 0.334 h。此外,模型体积由 74.8 MB 降低至 70.8 MB,压缩约 4 MB。模型训练过程中,YOLO v7 算法占用的 GPU 为 7.24 GB,而 LSEB YOLO v7 算法占用的 GPU 为 7.21 GB,减少约 0.03 GB。

改进后的 LSEB YOLO v7 黄花成熟度检测算法模型结构更加轻量,降低了对计算机硬件和计算能力的需求。

3.1.2 精确度

不同的模型评估指标能够多角度评估模型性能。通过使用多个评估指标,可以更加全面地理解模型在不同任务和场景中的表现,从而更好地评估不同模型的性能。

精确率(Precision,P)和召回率(Recall,R)主要用于评估模型在二分类问题中的性能。mAP@0.5 表示在 IoU 阈值为 0.5 时的平均精度均值,而 mAP@0.5:0.95 则考虑从 0.5 到 0.95 之间,10 个连续 IoU 阈值下的性能表现,因此更能全面的评估模型性能。调和均值综合考虑模型的精确率和召回率,是对精确率和召回率的调和平均,用于衡量模型综合性能。

由表 3 可知,模型 1 和模型 2 分别在特征提取和特征融合网络中引入轻量化 Ghost 卷积,对比可知,在特征融合网络进行轻量化操作对模型性能的影响较大,模型 2 的多项性能降幅明显。

表 3 不同模型精度对比

Tab.3 Precision of different models %

参数	YOLO v7	模型 1	模型 2	模型 3	LSEB YOLO v7
精确率	73.00	73.38	67.72	71.56	73.64
召回率	77.08	77.01	73.83	76.44	77.22
mAP@0.5	78.40	80.05	74.07	77.73	80.24
mAP@0.5:0.95	62.87	63.76	56.92	61.07	63.89
调和均值	84.00	84.00	84.00	84.00	84.00

模型 3 和 LSEB YOLO v7 模型依次增加通道注意力机制和通道信息融合机制,实现模型性能的逐步提升。LSEB YOLO v7 模型的精确率性能均超越原始模型,与原始模型相比,模型精确率由 73.00% 提升至 73.64%,提升约 0.64 个百分点。召回率由 77.08% 提升至 77.22%,提升约 0.14 个百分点。

相比之下,较 YOLO v7 模型,mAP@0.5 和 mAP@0.5:0.95 提升幅度更为明显,分别提升约 1.84 个百分点和 1.02 个百分点。而调和均值性能保持不变,仍然与原始模型相同,为 84.00%。

综上所述,改进后的 LSEB YOLO v7 模型在轻量化方面具有明显优势,减少了模型计算量,压缩了模型体积,简化了模型结构。同时,检测精准率、召回率、平均精度均值、调和均值等性能都有不同程度的提高,此外,检测效率也满足实时性要求。

3.2 对比实验

3.2.1 YOLO v7 与 YOLO 系列模型对比

为验证 YOLO v7 模型在黄花数据集的检测性能,分别使用 YOLO v5、YOLO v7 和 YOLO v8 3 种不同模型进行黄花成熟度检测,实验结果如表 4 所示。

表 4 不同模型对比实验

Tab.4 Comparative experiment of different algorithms

参数	YOLO v5	YOLO v7	YOLO v8	LSEB YOLO v7
浮点运算量	1.08×10^{11}	1.05×10^{11}	1.65×10^{11}	1.97×10^{11}
参数量	4.61×10^{7}	3.72×10^{7}	4.36×10^{7}	3.52×10^{7}
模型体积/MB	92.7	74.8	87.7	70.8
mAP@0.5/%	89.035	78.399	82.735	80.241
召回率/%	77.17	77.08	65.73	77.22

由表 4 可知,YOLO v5 和 YOLO v8 模型的浮点运算量远大于 YOLO v7 模型,分别为 1.08×10^{11} 和 1.65×10^{11}。同时,这 2 种模型的参数量较大,分别比 YOLO v7 模型多约 8.9×10^{6} 和 6.4×10^{6}。此外,YOLO v5 的精度更高,但参数数量也最多,这可能导致黄花成熟度检测需要性能更优的计算设备。

因此,在 YOLO v7 模型的基础上,改进后的 LSEB YOLO v7 模型参数量和浮点运算量更少,模型体积更小,适合未来智能收花设备的需要。此外,其召回率超过 YOLO v5 和 YOLO v8 模型,达到 77.22%。

3.2.2 LSEB YOLO v7 与 YOLO v7 模型对比

在黄花成熟度检测中,模型改进前后的 mAP@0.5 和 mAP@0.5:0.95 曲线如图 7 所示。由图 7 可知,改进后的 LSEB YOLO v7 模型平均精度均值曲

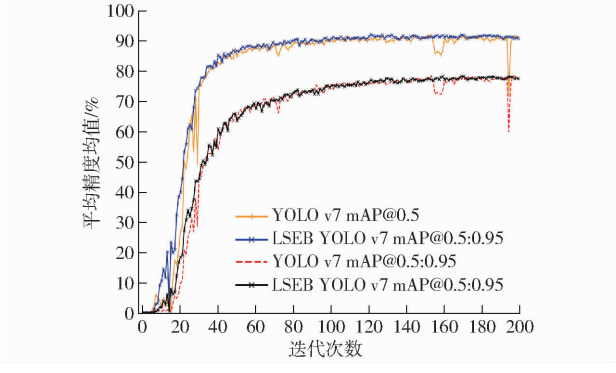


图 7 平均精度均值曲线

Fig.7 Average precision curves

线更加理想，mAP@0.5 和 mAP@0.5:0.95 均略高于原始算法。

在模型训练前期，改进后的 LSEB YOLO v7 算法平均精度均值提升速度更快、效率更高，明显优于原始模型。在模型训练过程中，LSEB YOLO v7 算法波动性更小，mAP@0.5 和 mAP@0.5:0.95 曲线都不存在急剧下降的情况，因此稳定性更强。

R－P 曲线可以直观地展示出分类模型在不同阈值下的性能表现，此外通过计算 R－P 曲线线下面积可以得到模型的平均精度（Average precision，AP）。

YOLO v7 与 LSEB YOLO v7 的 R－P 曲线如图 8 所示。由图 8 可知，LSEB YOLO v7 模型的线下面积明显大于 YOLO v7 模型，因此平均精度更高。

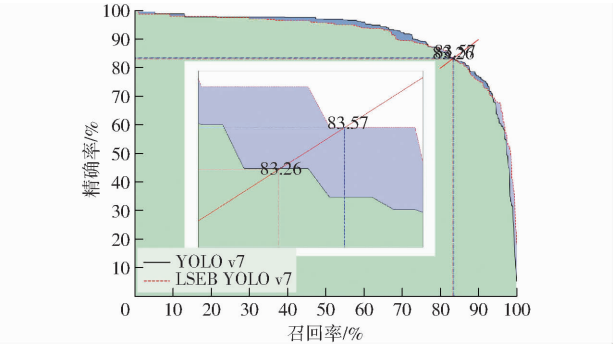


图 8　R－P 曲线

Fig. 8　R－P curve

在 R－P 曲线中，连接点（0，0）和点（1，1）绘制 R－P 曲线的平衡线，分别与 YOLO v7 和 LSEB YOLO v7 模型的 R－P 曲线产生 2 个交点：（83.26%，83.26%）和（83.57%，83.57%）。由此可知，在黄花成熟度检测中，LSEB YOLO v7 模型能够兼顾精确率和召回率，其平衡性能更加理想。

可见，在黄花成熟度检测中，对比原始 YOLO v7 算法，本文所提 LSEB YOLO v7 模型不仅实现了模型轻量化，而且提升了多项检测精确度，能够兼顾精确率和召回率，具有更好的模型平衡性，满足黄花成熟度检测的要求。

3.3　实时性能

模型的实时检测性能能够反映算法的运算能力，算法科学合理、结构简单可行则模型的实时检测速度较快，反之亦然。一般通过每秒实时处理帧数（Frames per second，FPS）衡量模型实时性能。FPS 越大，模型的实时性能越好。通常情况下，实时监测性能要求 FPS 大于 30 f/s。

在 YOLO v7 和 LSEB YOLO v7 模型中，训练所得的检测模型中增加非极大值抑制（NMS）策略，因此检测效率更高，检测过程更加稳定。

本次实验对 25 幅不同场景的黄花图像进行检测，YOLO v7 模型的总用时为 230 ms，其中执行 NMS 推理策略的用时为 20 ms，检测用时为 210 ms，因此 YOLO v7 模型的 FPS 为 108.70 f/s。而 LSEB YOLO v7 模型的总用时为 280.7 ms，其中执行 NMS 推理策略的用时为 30 ms，检测用时为 250.7 ms，因此 FPS 为 99.72 f/s。

在黄花成熟度检测中，YOLO v7 和 LSEB YOLO v7 模型的 FPS 分别为 108.70 f/s 和 99.72 f/s，远大于 30 f/s 的检测要求，因此均能够满足实时性能的检测需要。

3.4　检测结果对比

在黄花成熟度检测过程中，YOLO v5、GGSC YOLO v5[24]、YOLO v7、GCB YOLO v7[25] 和 LSEB YOLO v7 模型使用相同的阈值参数，其中能够影响检测结果的 IoU 阈值和置信度阈值分别为 0.25 和 0.25。检测结果如图 9 所示。

在图 9a 中，YOLO v5、GGSC YOLO v5、YOLO v7 和 GCB YOLO v7 模型的检测效果均不理想，分别出现重复检测和漏检的问题，并且定位预测框与人工标注的实际边界存在较大偏差。

在图 9b 中，不同的模型均能够检测出图中未成熟的黄花，但是相比之下，改进后的 LSEB YOLO v7 算法检测置信度均值更高，检测效果更加理想。

在图 9c 中，由于黄花与背景的差异性较小，检测难度较大，因此不同的检测模型暴露出不同的弊端。YOLO v7、LSEB YOLO v7 模型均存在漏检。相比之下，LSEB YOLO v7 模型非极大值抑制效果显著，预测框与人工标注框偏差较小。

在图 9d 中，与 LSEB YOLO v7 模型相比，YOLO v7 未能检测到黄花果实，YOLO v5 的检测效果最理想，检测置信度均值更高。

综上所述，改进以后的 LSEB YOLO v7 模型具有更好的模型定位与识别能力。此外，由于引入非极大值抑制策略，在对黄花密集植株进行成熟度识别时，能够避免重复检测，同时也能够给出更高的置信度。

4　结论

（1）从自然环境中采集不同场景的黄花图像，包括不同角度、天气下的单个黄花和有遮挡、复杂情况的多个黄花，建立具有针对性的黄花数据集。

（2）提出一种基于轻量化高效层聚合过渡网络的黄花成熟度检测模型 LSEB YOLO v7。引入轻量化 Ghost 卷积，降低特征提取过程中的冗余性，进而压缩模型体积。此外，在特征提取网络和

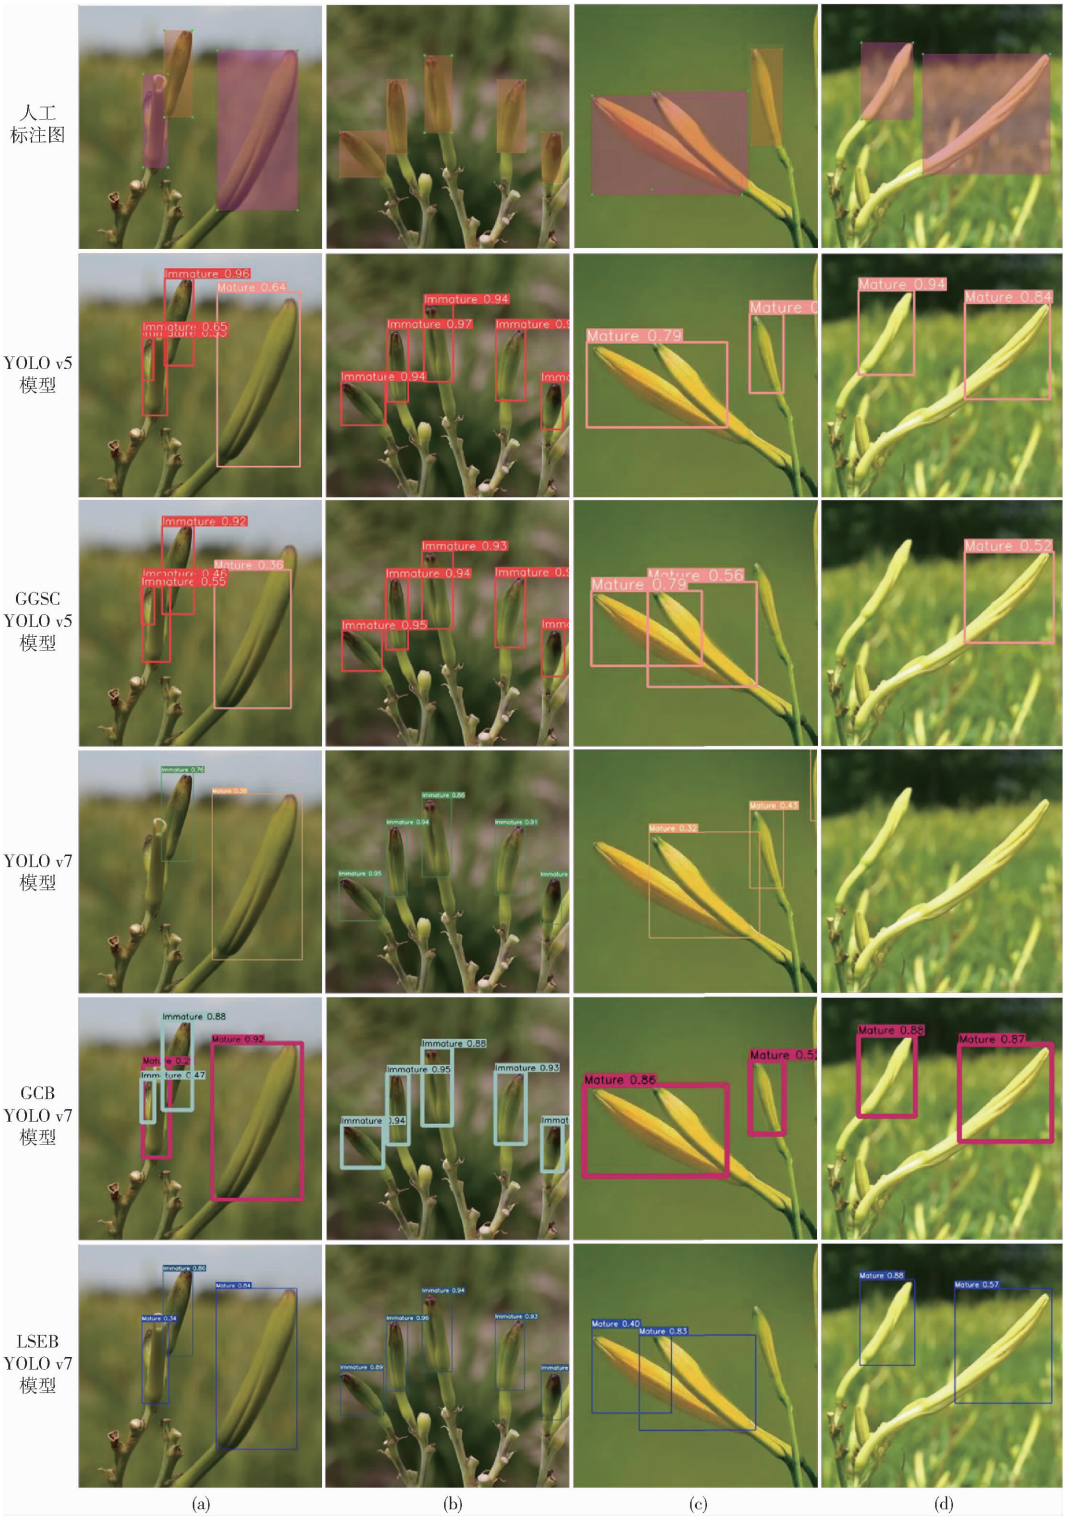


图 9 检测结果对比

Fig. 9 Comparison of detection results

特征融合网络之间增加通道注意力机制,提升模型性能。同时,使用加权双向特征金字塔网络实现跨通道的信息融合,增加跨节点的信息通道,持续提升模型性能。

(3)经过消融实验验证后,在黄花成熟检测中,改进后的 LSEB YOLO v7 模型具有更少的参数量和计算量,能够呈现出高的检测精确率,此外也能够满足实时性能的要求。

参 考 文 献

[1] 霍静琦. 基于机器视觉的黄花菜花蕾目标识别及定位研究[D]. 太谷:山西农业大学,2022.

HUO Jingqi. Research on yellow cauliflower bud target recognition and localization based on machine vision[D]. Taigu: Shanxi Agricultural University, 2022. (in Chinese)

[2] 李爽. 基于 Faster R-CNN 的黄花菜主要病害的分类识别[D]. 太谷:山西农业大学,2022.
LI Shuang. Classification and recognition of major diseases of brassicas based on Faster R-CNN[D]. Taigu: Shanxi Agricultural University, 2022. (in Chinese)

[3] NABILA H S, RYUKIN A L, SIWI I. Deep learning models for automatic identification of plant-parasitic nematode[J]. Artificial Intelligence in Agriculture, 2023(7): 1-12.

[4] 王金鹏, 周佳良, 张跃跃, 等. 基于优选 YOLOv7 模型的采摘机器人多姿态火龙果检测系统[J]. 农业工程学报, 2023, 39(8): 276-283.
WANG Jinpeng, ZHOU Jialiang, ZHANG Yueyue, et al. Multi-pose dragon fruit detection system for picking robots based on the optimal YOLOv7 model[J]. Transactions of the CSAE, 2023, 39(8): 276-283. (in Chinese)

[5] 祝志慧,何昱廷,李沃霖,等. 基于改进 YOLOv7 模型的复杂环境下鸭蛋识别定位[J]. 农业工程学报,2023,39(11):274-285.
ZHU Zhihui, HE Yuting, LI Wolin, et al. Improved YOLOv7 model for duck egg recognition and localization in complex environments[J]. Transactions of the CSAE, 2023, 39(11): 274-285. (in Chinese)

[6] KURYATI K, SALLEH O, ANNIE J, et al. Deep learning applications for oil palm tree detection and counting[J]. Smart Agricultural Technology, 2023(5): 100241.

[7] NAN Y L, ZHANG H C, ZENG Y F, 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.

[8] ZHANG D Y, LUO H S, CHENG T, et al. Enhancing wheat fusarium head blight detection using rotation YOLO wheat detection network and simple spatial attention network[J]. Computers and Electronics in Agriculture, 2023, 211: 107968.

[9] LI J, LI J H, ZHAO X, et al. Lightweight detection networks for tea bud on complex agricultural environment via improved YOLO v4[J]. Computers and Electronics in Agriculture, 2023, 211: 107955.

[10] WU Y J, YANG Y, WANG X F. Fig fruit recognition method based on YOLOv4 deep learning[C]//2021 18th International Conference on Electrical Engineering /Electronics, Computer, Telecommunications and Information Technology (ECTI-CON), Chiang Mai, Thailand, 2021: 303-306.

[11] SETON C A, VINASETAN R H, CASTRO G H, et al. Deep learning methods for biotic and abiotic stresses detection and classification in fruits and vegetables: state of the art and perspectives[J]. Artificial Intelligence in Agriculture, 2023(9): 46-60.

[12] VINCE A M, MARC V T. Classification of defects in robusta green coffee beans using YOLO[C]//2022 IEEE International Conference on Artificial Intelligence in Engineering and Technology (IICAIET), 2022: 1-6.

[13] NOVELERO J M, JENNIFER C. On-tree mature coconut fruit detection based on deep learning using UAV images[C]//2022 IEEE International Conference on Cybernetics and Computational Intelligence, 2022: 494-499.

[14] PAWAN K D, REVATHI G P. Detection of weed & crop using YOLO v5 algorithm[C]//2022 IEEE 2nd Mysore Sub Section International Conference (MysuruCon), 2022: 1-5.

[15] MITALI V S, ROHIN D D. High performance deep learning architecture for early detection and classification of plant leaf disease[J]. Journal of Agriculture and Food Research, 2023(14): 100675.

[16] ZHOU C L, LEE W S, LIBURD O E, et al. Detecting two-spotted spider mites and predatory mites in strawberry using deep learning[J]. Smart Agricultural Technology, 2023(4): 100229.

[17] SUDHA C, MOHAN K, ARULAALAN M. Real time riped fruit detection using Faster R-CNN deep neural network models[C]//2022 International Conference on Smart Technologies and Systems for Next Generation Computing (ICSTSN), 2022: 1-4.

[18] WU D, LV S, JIANG M, et al. Using channel pruning-based YOLOv4 deep learning algorithm for the real-time and accurate detection of apple flowers in natural environments[J]. Computers and Electronics in Agriculture,2020,178: 105742.

[19] 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), 2020.

[20] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020,42(8):2011-2023.

[21] 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), 2020.

[22] 周学成,肖明玮,梁英凯,等. 基于改进 DeepLabv3+的火龙果园视觉导航路径识别方法[J]. 农业机械学报,2023,54(9):35-43.
ZHOU Xuecheng, XIAO Mingwei, LIANG Yingkai, et al. Navigation path recognition between dragon orchard using improved DeepLabv3+ network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(9): 35-43. (in Chinese)

[23] 张万枝,曾祥,刘树峰,等. 基于改进 YOLO v5s 的马铃薯种薯芽眼检测方法[J]. 农业机械学报,2023,54(9):260-269.
ZHANG Wanzhi, ZENG Xiang, LIU Shufeng, et al. Detection method of potato seed bud eye based on improved YOLO v5s[J]. Transactions of the Chinese Society for Agricultural Machinery,2023,54(9):260-269. (in Chinese)

[24] ZHANG L, WU L G, LIU Y Q. *Hemerocallis citrina baroni* maturity detection method integrating lightweight neural network and dual attention mechanism[J]. Electronics, 2022, 11(17):2743.

[25] SHENG B, WU L G, ZHANG N. A maturity detection method for *Hemerocallis citrina baroni* based on lightweight and attention mechanism[J]. Applied Sciences,2023,13(21):12043.