

基于改进 YOLO v7 的苹果叶片病害检测方法

袁杰 谢霖伟 郭旭 梁荣光 张迎港 马浩田

(新疆大学电气工程学院, 乌鲁木齐 830017)

摘要: 针对苹果叶片疾病形态多样、分布密集, 导致检测精度不高的问题, 提出了一种改进的 YOLO v7 模型。首先, 用双向特征金字塔网络 (BiFPN) 替代 YOLO v7 中原有的特征融合方法, 以提高模型对苹果叶片上不同尺度病害的检测能力。其次, 在 YOLO v7 的 ELAN 和 E-ELAN 模块之后, 增加高效通道注意力机制 (ECA), 以增强模型对苹果叶片病害特征的提取能力, 并提高检测精度。最后, 将 YOLO v7 的损失函数改为 SIOU 损失函数, 以加快模型的收敛速度。实验结果表明: 改进 YOLO v7 模型精确率为 89.4%, 召回率为 81.5%, mAP@0.5 为 90.5%, mAP@0.95 为 62.1%, 与原始 YOLO v7 模型相比, 分别提高 4.9、5.2、3.5、4.6 个百分点。改进 YOLO v7 模型与 Faster R-CNN、SSD、YOLO v3、YOLO v5s、YOLO v7 模型相比, mAP@0.5 分别提升 40.9、20.3、4.0、2.3、3.5 个百分点, 单幅图像检测时间为 12 ms。

关键词: 苹果叶片; 病害检测; YOLO v7; 多尺度融合; 注意力机制

中图分类号: TP391; S24

文献标识码: A

文章编号: 1000-1298(2024)11-0068-07

OSID:



Apple Leaf Disease Detection Method Based on Improved YOLO v7

YUAN Jie XIE Linwei GUO Xu LIANG Rongguang ZHANG Yinggang MA Haotian

(School of Electrical Engineering, Xinjiang University, Urumqi 830017, China)

Abstract: Apples have become one of the most popular fruits in the world, and the annual production of apples in China has continued to increase. However, there are certain diseases in the growth process of apple trees, which will affect the quality and yield of apples, resulting in economic losses of fruit farmers. Therefore, in view of the problem that apple leaf diseases have diverse forms and dense distribution, resulting in low detection accuracy, an improved YOLO v7 model was proposed to accurately detect apple leaf diseases. Firstly, bidirectional feature pyramid network (BiFPN) was used to replace the original feature fusion method in YOLO v7 to improve the model's detection ability of different scale diseases on apple leaves. Secondly, after the ELAN and E-ELAN modules of YOLO v7, an efficient channel attention mechanism (ECA) was added to enhance the ability of the model to extract features of apple leaves disease and improve detection accuracy. Finally, the loss function of YOLO v7 was changed to the SIOU loss function to accelerate the convergence speed of the model. Experimental results showed that the improved YOLO v7 model had a precision of 89.4%, a recall rate of 81.5%, a mean average precision (mAP@0.5) of 90.5%, and a mean average precision (mAP@0.95) of 62.1%. Compared with the original YOLO v7 model, they were increased by 4.9, 5.2, 3.5, and 4.6 percentage points, respectively. Compared with the Faster R-CNN, SSD, YOLO v3, YOLO v5s, and YOLO v7 models, the mAP@0.5 of improved YOLO v7 model was increased by 40.9, 20.3, 4.0, 2.3 and 3.5 percentage points, respectively, and the single image detection speed reached 12 ms. The research can provide a feasible technical means for accurately detecting apple leaf diseases.

Key words: apple leaf; disease detection; YOLO v7; multi-scale fusion; attention mechanism

0 引言

苹果树生长过程中会出现一定的疾病, 会影响

苹果的质量与产量, 从而导致果农经济损失。据统计, 苹果树的多数疾病出现在苹果树叶部。因此, 为了保证苹果种植业的发展, 准确地检测出苹果树叶

部病害具有重要的意义。

传统的果树病害检测技术是通过果农和专家根据经验目测识别,这种方法存在效率低而且主观性强的问题。随着计算机视觉技术的发展,图像检测技术已经应用到农业中^[1-2]。传统机器视觉在农作物叶片病害检测中主要是通过单一叶片病害的纹理、颜色、形状等特征对叶片病害检测,其算法流程为:首先在输入的图像中找出感兴趣区域,然后对该区域进行特征提取,得到图像的特征向量,最后通过区域分类和边界回归来预测感兴趣区域中的物体类别,并输出检测结果。常用方法有支持向量机^[3]、K 均值聚类^[4]、贝叶斯分类器^[5]等,虽具有简单的特征提取步骤,但是此类方法存在复杂背景下检测精度较低、计算量大等缺点,因此降低了叶片病害检测的效率。

近几年,随着农业智能技术的不断发展和进步,基于深度学习的目标检测技术在农业领域中得到了广泛应用^[6-7],与传统的机器视觉技术相比,具有更快的检测速度和更高的精度。

基于深度学习的农作物目标检测分为两类模型:第 1 类是两阶段目标检测模型,主要以 R-CNN^[8-9]、Faster R-CNN^[10]为代表。这类两阶段检测算法可以较准确地检测出农作物叶子病害^[11-13],但其网络模型大,检测速度偏慢,实际应用效果欠佳。第 2 类是单阶段目标检测模型,主要以 SSD^[14]、YOLO^[15]为代表。尽管单阶段检测算法发展已经较为成熟,检测速度快、实时性好,但是对小目标检测效果不太理想^[16-23]。苹果叶片病害具有形态多样、分布密集以及小目标病害较多等特征,会导致检测效果不佳。因此,设计一种高精度的苹果叶片病害检测模型至关重要。

本文提出一种基于改进 YOLO v7 模型的苹果叶片病害检测方法。YOLO v7 是一种快速而准确的目标检测模型,具有良好的实时性能和较低的计算复杂度,适用于大规模图像数据的处理和分析^[24]。YOLO v7 在苹果树叶部病害检测中应用较少,且由于其样本数据类别分布不平衡,小目标病害较多,导致检测效果不佳。因此,以苹果树叶部病害为研究目标,首先,通过采集大量的苹果叶片图像,建立一个包含多个苹果叶片病害类别的数据集;然后,利用改进的 YOLO v7 模型进行训练;最后,通过 4 组对比实验,以验证本文模型检测性能。

1 实验数据集与检测方法

1.1 实验数据

以甘肃省平凉市庄浪县苹果园种植的苹果树叶

为研究对象。在 2023 年 7—9 月,使用华为 nova7 5G 智能手机采集 4 种果园常见的叶片病害,即结痂病、蛙眼病、锈病、白粉病进行实验。采集的 4 种病害图像共 5 000 幅,经过筛选,最终保留 4 499 幅图像进行实验。按照 7:2:1 的比例划分为训练集、验证集和测试集,其中,训练集图像 3 272 幅、验证集图像 818 幅、测试集图像 409 幅,图 1 为 4 种叶片病害的样本数据示例。然后通过 LabelImg 对数据集手动标注,总共标注的结痂病、蛙眼病、锈病、白粉病标签数量分别为 2 185、6 836、5 124、2 685。




图 1 苹果叶片病害的样本数据示例

Fig.1 Sample data of apple leaf diseases

1.2 YOLO v7 模型

YOLO v7 是一种目标检测模型。YOLO (You only look once) 的思想是将目标检测任务转化为回归问题,通过单次前向传播,即可同时预测图像中多个目标的位置和类别^[25]。YOLO v7 网络结构主要由输入端 (Input)、主干网络 (Backbone)、检测网络 (Head) 3 部分组成。YOLO v7 还采用了更复杂的训练策略,包括数据增强、批次正则化等,以进一步提升模型性能。相较于其他目标检测算法,YOLO v7 具有速度快、准确率高的特点,能够在实时场景下实现实时目标检测,并且可以处理大量目标。然而,YOLO v7 也存在对密集目标、小目标检测效果差等缺点。

1.3 YOLO v7 模型改进

针对苹果叶片病害形态多样、分布密集,导致检测难度大的问题,对 YOLO v7 模型进行改进,改进后网络结构如图 2 所示。为了有效融合多尺度特征,采用 BiFPN 结构取代 YOLO v7 中原始的特征融合方法,解决苹果叶片病害不同尺度特征的提取能力;在原始网络结构的 ELAN 和 E-ELAN 模块后增加 ECA 注意力机制,增强重要特征的提取,提高检测精度;最后替换原始网络中的损失函数 CIOU 为 SIOU,提高预测框回归速度,加快模型的收敛,从而




图 2 改进 YOLO v7 模型网络结构图

Fig. 2 Improved network structure of YOLO v7

提高检测精度。

1.3.1 双向特征金字塔网络 BiFPN

目前,在 YOLO v7 中使用的 PANet 是一种单向特征融合方法,在苹果叶片病害检测的环境中很难提取显著的病害特征,而且 PANet 结构(图 3a)只是增强了位置信息,当不同分辨率融合输入时,只是简单的相加,且在提取的信息中缺乏原始的特征,容易导致训练学习的偏差。因此,本文采用一种级联的方式将 BiFPN^[26] (Bidirectional feature pyramid network)结构(如图 3b 所示)集成到 YOLO v7 的特征提取网络中,替换原始网络中的特征融合部分。BiFPN 是一种多尺度融合模块,通过引入权重来学习不同分辨率输入特征的重要性,其基于 PANet 结构增加了交叉尺度连接,并简化了输入边和输出边的节点。具体来说,BiFPN 设计了一个从 p7 到 p3 的自上而下的路径,将高层特征的语义信息传递到底层,以及一个从 p3 到 p7 的自下而上的路径,将底层的位置新信息传递到更高的层次。此外,BiFPN 增加了一个从 p4 到 p6 的连接,直接连接同一层的输入和输出节点,跨越中间层,以实现更深层次的特




图 3 PANet 和 BiFPN 结构图

Fig. 3 PANet and BiFPN structure diagram

征融合。

来自不同特征层的分辨率可能会导致对输出的不同贡献。高分辨率的浅层特征图的细节信息较丰富,但语义特征信息较少。BiPFPN 网络在整合苹果叶片病害的局部和全局特征的同时,在苹果叶片病害图像中保留了更浅的语义信息,而不丢失太多更深的位置信息,从而实现了针对不同尺度和遮挡的苹果叶片病害的准确检测。

1.3.2 高效通道注意力机制模块 ECA

在深度卷积神经网络中,注意力机制可以为输入特征的不同部分分配不同的权重,保证了图像信息中重要特征的提取。本文在 YOLO v7 网络的 ELAN 和 ELAN-H 模块之后添加高效通道注意力机制^[27] (Efficient channel attention, ECA),如图 4 所示,ECA 模块遵循 SE 注意力机制的一部分。对 SE 注意力机制的主要改进是自适应地选择一维卷积核,并在局部跨通道交互过程中保持了维数,降低了网络复杂度,提高了模型提取重要特征的性能。在 ECA 中,首先输入原始特征图像,将所有原始图像所有通道做全局平均池化,然后快速使用大小为 Q 的一维卷积的生成通道权重,并计算相应的不同通道的概率,然后与原始图像进行比较,最后与输入特征相乘作为下一层的输入。该方法通过函数自适应确定 Q 值,其值与通道维度 C 成正比,有

$$Q = \Psi(C) = \left\lfloor \frac{\ln C}{\lambda} + \frac{b}{\lambda} \right\rfloor \quad (1)$$

其中

$$C = \Phi(Q) = 2^{Q-b} \quad (2)$$

式中 Q ——自适应选择的卷积核大小,为奇数

λ 、 b ——常数,用于调整函数映射关系




图 4 高效通道注意力机制模块

Fig. 4 Efficient channel attention module

其中, $\lambda = 2, b = 1, Q$ 取最接近的奇数。ECA 具有灵活、轻量级的结构, 可以自适应地选择一维卷积核, 避免降维, 直接进行跨通道通信, 增强特征图中有用的语义信息, 减少冗余和无效信息, 提高苹果叶片病害特征的有效提取。

1.3.3 SIOU 损失函数

检测模型损失函数由位置损失、置信度损失、分类损失 3 部分组成。由于苹果树叶病害小目标多且部分类别分布较密集, 因此要考虑边界框回归指标的度量集合。原始 YOLO v7 网络结构中采用 CIOU 损失函数, 其通过对比预测框与真实框的距离、重叠面积、纵横比等位置信息进行损失的计算。采用的 SIOU 损失函数^[28]在 CIOU 的基础上考虑预测框回归真实框时两框中心点之间的向量角度, 重新定义了角度惩罚度量, 可以使预测框以最快的速度移动到最近的坐标轴, 只需要对一个坐标轴进行回归, 有效地减少了损失函数中自由变量的数量, 从而提高苹果叶片病害检测模型准确率。SIOU 损失函数包含: 角度损失、距离损失、形状损失、IOU 损失。

2 实验结果分析

2.1 实验平台

为保证实验结果的统一性, 本文使用相同的实验平台进行模型的训练和验证。实验环境为 Ubuntu 20.04 系统, 显卡采用 NVIDIA GeForce RTX3080, Pycharm 版本为 22.3, Python 版本为 3.8, Pytorch 版本为 1.10.0, CUDA 版本为 11.3。

2.2 实验参数设置

采用 YOLO 格式的数据集对苹果叶片病害检测模型进行训练, 输入图像分辨率为 640 像素 × 640 像素。通过多次实验发现模型在 100 轮以内能达到收敛, 设置模型的参数: 周期为 100, 批量大小为 8; 使用 Adam 优化器, 初始学习率设置为 0.01。

2.3 评价指标

采用精确率 P 、召回率 R 、平均精度均值作为评价指标。

2.4 实验结果

进行了 4 组实验进行性能对比: 不同损失函数模型对比实验; 不同注意力机制模型对比实验; 不同改进方法模型对比实验; 不同检测模型对比实验。实验结果中, mAP@0.5 指 IOU 为 0.5 时平均精度均值, mAP@0.95 指 IOU 从 0.5 到 0.95, 步长 0.05 时的平均精度均值。

2.4.1 不同损失函数模型性能对比

将 CIOU 损失函数、DIOU^[29] 损失函数、MDPIOU^[30] 损失函数与本文中的 SIOU 损失函数进行对比, 结果如表 1 所示。

表 1 不同损失函数模型性能对比

Tab. 1 Performance comparison of models

with different loss functions %

模型	P	R	mAP@0.5	mAP@0.95
YOLO v7_CIOU	84.5	76.3	87.0	57.5
YOLO v7_DIOU	86.3	79.2	88.5	59.2
YOLO v7_MDPIOU	85.5	79.2	87.9	58.1
YOLO v7_SIOU	88.3	81.7	89.5	60.1

由表 1 可以看出, 使用本文中的损失函数 SIOU 与其他损失函数相比, 精确率、召回率、平均精度均最高。YOLO v7_SIOU 损失函数与 YOLO v7_CIOU 损失函数相比, 精确率、召回率、mAP@0.5 和 mAP@0.95 分别提高 3.8、5.4、2.5、2.6 个百分点; 与 YOLO v7_DIOU 损失函数相比, 精确率、召回率、mAP@0.5 和 mAP@0.95 分别提高 2.0、2.5、0.7、0.9 个百分点; 与 YOLO v7_MDPIOU 损失函数相比, 精确率、召回率、mAP@0.5 和 mAP@0.95 分别提高 2.8、2.5、1.6、2.0 个百分点; 因此, SIOU 损失函数在 YOLO v7 模型中具有更好的性能, 能够有效提高检测精度。

2.4.2 不同注意力机制模型性能对比

在同样位置添加 CBAM^[31]、CA^[32]、SE^[33]、TA^[34] 注意力机制, 与本文注意力机制进行性能对比, 结果如表 2 所示。

表 2 不同注意力机制模型性能对比

Tab. 2 Performance comparison of different

attention mechanism models %

模型	P	R	mAP@0.5	mAP@0.95
YOLO v7	84.5	76.3	87.0	57.5
YOLO v7_CBAM	80.7	74.9	82.4	52.7
YOLO v7_CA	86.4	78.4	87.8	57.8
YOLO v7_SE	86.8	79.7	88.7	59.1
YOLO v7_TA	86.9	78.9	88.5	59.1
YOLO v7_ECA	88.6	78.2	88.8	59.7

由表 2 可以看出, 对比不同注意力机制, 本文

添加的注意力机制 ECA 模块在精确率和平均精度均值都是最高的,添加的 SE 注意力机制模块的召回率是最高的。YOLO v7_ECA 模型与原始 YOLO v7 模型相比,精确率、召回率、mAP@ 0.5 和 mAP@0.95 分别提高 4.1、1.9、1.8、2.2 个百分点;YOLO v7_ECA 模型与 YOLO v7_CBAM 模型相比,精确率、召回率、mAP@ 0.5 和 mAP@ 0.95 分别提高 7.9、3.3、6.4、7.0 个百分点;YOLO v7_ECA 模型与 YOLO v7_CA 模型相比,精确率、mAP@0.5 和 mAP@ 0.95 分别提高 2.2、1.0、1.9 个百分点;YOLO v7_ECA 模型与 YOLO v7_SE 模型相比,精确率、mAP@ 0.5 和 mAP@ 0.95 分别提高 1.8、0.1、0.6 个百分点;YOLO v7_ECA 模型与 YOLO v7_TA 模型相比,精确率、mAP@ 0.5 和 mAP@ 0.95 分别提高 1.7、0.3、0.6 个百分点。因此,本文添加的 ECA 注意力机制模块具有较好的可行性。

2.4.3 消融实验对比

采用不同改进模型与本文改进的模型进行性能比较,结果如表 3 所示,YOLO v7_B 为 YOLO v7 网络与 BiFPN 模块结合的模型,YOLO v7_S 为 YOLO v7 网络替换损失函数为 SIOU 的模型,YOLO v7_E 为 YOLO v7 网络添加 ECA 注意力机制的模型,YOLO v7_BS 为 YOLO v7 网络与 BiFPN 模块结合并替换损失函数为 SIOU 的模型,YOLO v7_BE 为 YOLO v7 网络与 BiFPN 模块结合并添加 ECA 注意

力机制的模型,YOLO v7_ES 为 YOLO v7 网络添加 ECA 注意力机制并替换损失函数为 SIOU 的模型,YOLO v7_BSE 为本文模型。

从表 3 可以看出,本文模型相比其他模型,精确率和平均精度均值都最高,YOLO v7_S 模型的召回率是最高的,比本文模型高 0.2 个百分点。本文模型与 YOLO v7 模型相比,精确率、召回率、mAP@ 0.5 和 mAP@ 0.95 分别提高 4.9、5.2、3.5、4.6 个百分点;本文模型与 YOLO v7_B 模型相比,精确率、召回率、mAP@ 0.5 和 mAP@ 0.95 分别提高 0.3、3.5、1.7、4.0 个百分点;本文模型与 YOLO v7_S 模型相比,精确率、mAP@ 0.5 和 mAP@ 0.95 分别提高 1.1、1.0、2.0 个百分点;本文模型与 YOLO v7_E 模型相比,精确率、召回率、mAP@ 0.5 和 mAP@ 0.95 分别提高 0.8、3.3、1.7、2.4 个百分点;本文模型与 YOLO v7_BS模型相比,精确率、召回率、mAP@ 0.5 和 mAP@ 0.95 分别提高 0.2、0.3、0.9、0.6 个百分点;本文模型与 YOLO v7_BE 模型相比,精确率、召回率、mAP@ 0.5 和 mAP@ 0.95 分别提高 0.9、2.1、2.7、2.9 个百分点;本文模型与 YOLO v7_B模型相比,精确率、召回率、mAP@ 0.5 和 mAP@ 0.95 分别提高 0.7、2.8、2.1、3.0 个百分点。因此,本文模型具有更好的检测效果。

本文模型与原始 YOLO v7 模型训练 100 个周期,得到精确率、召回率、mAP@ 0.5、损失值变化曲线如图 5 所示。从图 5 可以看出,本文模型与原始 YOLO v7 模型相比,精确率、召回率、mAP@ 0.5 都相对有所提升,损失值也有一定降低。

2.4.4 不同目标检测模型实验对比

本文模型 YOLO v7_BSE 分别与目前主流模型 Faster R – CNN、SSD、YOLO v3、YOLO v5s、YOLO v7 进行对比,结果如表 4 所示。可以看出,本文模型 mAP@0.5 比 Faster R – CNN、SSD、YOLO v3、YOLO v5s、YOLO v7 模型中的 mAP@ 0.5 分别高出 40.9、20.3、4.0、2.3、3.5 个百分点,改进模型单幅图像检测时间为 12 ms,比 Faster – RCNN、YOLO v3、YOLO v7

表 3 不同改进方法模型性能对比

Tab.3 Model performance comparison of different improved methods

模型	P	R	mAP@ 0.5	mAP@ 0.95
YOLO v7	84.5	76.3	87.0	57.5
YOLO v7_B	89.1	78.0	88.8	58.1
YOLO v7_S	88.3	81.7	89.5	60.1
YOLO v7_E	88.6	78.2	88.8	59.7
YOLO v7_BS	89.2	81.2	89.4	61.5
YOLO v7_BE	88.5	79.4	87.8	59.2
YOLO v7_ES	88.7	78.7	88.4	59.1
YOLO v7_BSE	89.4	81.5	90.5	62.1




图 5 精确率、召回率、mAP@0.5、损失值变化曲线
Fig.5 Precision, recall, mAP@ 0.5 and loss change curves

表 4 不同检测模型性能对比

Tab.4 Performance comparison of different detection models

模型	mAP@0.5/%	单幅图像检测时间/ms
Faster R-CNN	40.9	35
SSD	70.2	8
YOLO v3	86.5	20
YOLO v5s	88.2	6
YOLO v7	87.0	15
YOLO v7_BSE	90.5	12

分别减少 23、8、3 ms。

图 6 为本文模型的可视化展示。可以看出结痂病、白粉病、锈病检测精确率基本在 90% 以上,蛙眼病的检测精确率基本在 85% 以上。总体来说,本文模型具有较好的检测性能。

3 结论

(1)对于苹果树叶片疾病形态多样、分布密集,导致检测效果差的问题。在 YOLO v7 模型的基础上将 BiFPN 模块添加到 YOLO v7 中,替换原始网络中的特征融合部分,提高对不同尺度的苹果叶片病害的检测能力;在原始网络结构的 ELAN 和 E-ELAN 模块后加入 ECA 注意力机制,在不增加模型复杂度的情况下,加强苹果苹果叶片重要




图 6 本文模型可视化结果

Fig.6 Visualization results of proposed model

特征提取;引入 SIOU 损失函数替换原始网络中的 CIOU 损失函数,加快模型收敛速度,提高模型检测精度。改进 YOLO v7 模型,可以准确检测苹果叶片病害疾病。

(2)改进 YOLO v7 模型与原始模型相比精确率、召回率、mAP@0.5 和 mAP@0.95 分别提高 4.9、5.2、3.5、4.6 个百分点;改进 YOLO v7 模型与 Faster R-CNN、SSD、YOLO v3、YOLO v5s 模型相比,mAP@0.5 分别提升 40.9、20.3、4.0、2.3 个百分点,单幅图像检测时间为 12 ms。

参 考 文 献

[1] TERENCEV A, DOLZHENKO V, FEDOTOV A, et al. Current state of hyperspectral remote sensing for early plant disease detection: a review[J]. Sensors, 2022, 22(3): 757.

[2] XU W, ZHANG G, DUAN Y. Farmland detection in synthetic aperture radar images with texture signature[J]. Journal of Applied Remote Sensing, 2014, 8(1): 084997.

[3] YANG X, YU Q, HE L, et al. The one-against-all partition based binary tree support vector machine algorithms for multi-class classification[J]. Neurocomputing, 2013, 113: 1-7.

[4] ZHANG D, LI M, XU D, et al. A survey on theory and algorithms for k-means problems[J]. Scientia Sinica Mathematica, 2020, 50(9): 1387-1404.

[5] WANG S, DU R, LIU Y. The learning and optimization of full bayes classifiers with continuous attributes[J]. Chinese Journal of Computers, 2012, 35(10): 2129-2138.

[6] CORCEIRO A, ALIBABAEI K, ASSUNCAO E, et al. Methods for detecting and classifying weeds diseases and fruits using AI to improve the sustainability of agricultural crops: a review[J]. Processes, 2023, 11(4): 1263.

[7] RAJPOOT V, TIWARI A, JALAL A S. Automatic early detection of rice leaf diseases using hybrid deep learning and machine learning methods[J]. Multimedia Tools and Applications, 2023, 82(23): 36091-36117.

[8] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[J]. arXiv Preprint, arXiv: 1311.2524, 2013.

[9] GIRSHICK R. Fast R-CNN[J]. arXiv Preprint, arXiv: 1504.08083, 2015.

[10] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(6): 1137-1149.

[11] GAO W Q, XIAO Z Y, BAO T F. Detection and identification of potato-typical diseases based on multidimensional fusion atrous-CNN and hyperspectral data[J]. Applied Sciences-Basel, 2023, 13(8): 5023.

[12] 薛卫,程润华,康亚龙,等. 基于 GC-Cascade R-CNN 的梨叶病斑计数方法[J]. 农业机械学报,2022,53(5):237-245. XUE Wei, CHENG Runhua, KANG Yalong, et al. Pear leaf disease spot counting method based on GC-Cascade R-CNN [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(5): 237-245. (in Chinese)

[13] ZHAO Shengyi, LIU Jizhan, WU Shuo. Multiple disease detection method for greenhouse-cultivated strawberry based on

- multiscale feature fusion Faster R-CNN[J]. Computers and Electronics in Agriculture, 2022, 199: 107176.
- [14] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[J]. arXiv Preprint, arXiv:1512.02325, 2015.
- [15] CHITHAMBARATHANU M, JEYAKUMAR M K. Survey on crop pest detection using deep learning and machine learning approaches[J]. Multimedia Tools and Applications, 2023, 82(27): 42277–42310.
- [16] TIAN L, ZHANG H, LIU B, et al. VMF-SSD: anovel V-space based multi-scale feature fusion SSD for apple leaf disease detection[J]. IEEE-ACM Transactions on Computational Biology and Bioinformatics, 2023, 20(3): 2016–2028.
- [17] 张立杰,周舒骅,李娜,等. 基于改进 SSD 卷积神经网络的苹果定位与分级方法[J]. 农业机械学报,2023,54(6):223–232.
ZHANG Lijie, ZHOU Shuhua, LI Na, et al. Apple location and classification based on improved SSD convolutional neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(6): 223–232. (in Chinese)
- [18] 雷建云,叶莎,夏梦,等. 基于改进 YOLO v4 的葡萄叶片病害检测[J]. 中南民族大学学报(自然科学版),2022,41(6): 712–719.
LEI Jianyun, YE Sha, XIA Meng, et al. Detection of grape leaf diseases based on improved YOLO v4[J]. Journal of South-Central Minzu University(Natural Science Edition), 2022, 41(6):712–719. (in Chinese)
- [19] MATHEW M P, MAHESH T Y. Leaf-based disease detection in bell pepper plant using YOLO v5[J]. Signal Image and Video Processing, 2022,16(3): 841–847.
- [20] 孙长兰,林海峰. 一种基于集成学习的苹果叶片病害检测方法[J]. 江苏农业科学,2022,50(20):41–47.
SUN Changlan, LIN Haifeng. An apple tree leaf disease detection method based on ensembl learning[J]. Jiangsu Agricultural Sciences, 2022, 50(20): 41–47. (in Chinese)
- [21] 张领先,景嘉平,李淑菲,等. 基于图像自动标注与改进 YOLO v5 的番茄病害识别系统[J]. 农业机械学报,2023, 54(11):198–207.
ZHANG Lingxian, JING Jiaping, LI Shufei, et al. Tomato disease recognition system based on image automatic labeling and improved YOLO v5[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(11): 198–207. (in Chinese)
- [22] WANG Y, WANG Y, ZHAO J. MGA-YOLO: a lightweight one-stage network for apple leaf disease detection[J]. Frontiers in Plant Science, 2022, 13: 927424.
- [23] 张林鎔,巴音塔娜,曾庆松. 基于 StyleGAN2-ADA 和改进 YOLO v7 的葡萄病害检测方法[J]. 农业机械学报,2024, 55(1): 241–252.
ZHANG Linxuan, BA Yintana, ZENG Qingsong. Grape disease detection algorithm based on StyleGAN2-AND and improved YOLO v7[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(1): 241–252. (in Chinese)
- [24] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLO v7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[J]. arXiv Preprint, arXiv: 2207.02696, 2022.
- [25] SHAO Y, ZHANG D, CHU H, et al. A review of YOLO object detection based on deep learning[J]. Journal of Electronics & Information Technology, 2022, 44(10): 3697–3708.
- [26] TAN M, PANG R, LE Q V. Efficient det: scalable and efficient object detection[J]. arXiv Preprint, arXiv: 1911.09070, 2019.
- [27] WANG Q, WU B, ZHU P, et al. ECA-Net: efficient channel attention for deep convolutional neural networks[J]. arXiv Preprint, arXiv: 1910.03151, 2019.
- [28] GEVORGYAN Z. Siou loss: more powerful learning for bounding box regression[J]. arXiv Preprint, arXiv: 2205.12740, 2022.
- [29] ZHENG Z, WANG P, REN D, et al. Enhancing geometric factors in model learning and inference for object detection and instance segmentation[J]. arXiv Preprint, arXiv: 2005.03572, 2020.
- [30] SILIANG M, YONG X. MPDIoU: a loss for efficient and accurate bounding box regression[J]. arXiv Preprint, arXiv: 2307.07662, 2023.
- [31] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[J]. arXiv Preprint, arXiv: 1807.06521, 2018.
- [32] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design[J]. arXiv Preprint, arXiv: 2103.02907, 2021.
- [33] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks[J]. arXiv Preprint, arXiv: 1709.01507, 2017.
- [34] MA W, CUI Y, SHAO N, et al. TripleNet: triple attention network for multi-turn response selection in retrieval-based chatbots [J]. arXiv Preprint, arXiv: 1909.10666, 2019.