

基于改进 YOLO v8n 的非结构环境下杭白菊检测方法

喻陈楠^{1,2} 伍永红¹ 周杰¹ 姚坤¹ 郇晓龙^{1,2} 陈建能^{1,2}

(1. 浙江理工大学机械工程学院, 杭州 310018; 2. 全省农业智能感知与机器人重点实验室, 杭州 310018)

摘要: 在非结构环境下, 由于杭白菊的簇状生长特性导致相互遮挡严重, 使得杭白菊检测算法的检测精度较低。针对该问题, 提出一种改进 YOLO v8n 的杭白菊检测模型 Hwc - YOLO v8n (Hangzhou white chrysanthemum - YOLO v8n)。首先, 提出通过增加标签的方式, 将实际需求的双类别标签改变为三类别, 提升模型对杭白菊各个花期的关键性特征的精细化检测能力; 其次, 在主干网络中设计一种动态特征提取模块 (C2f - Dynamic), 以加强模型对被遮挡目标特征缺失情况的动态适应, 并在检测头部分增加 160 像素 × 160 像素的检测头, 使得模型具备针对小目标检测的能力; 最后, 采用角度惩罚度量的损失 (SIoU) 优化边界框损失函数, 提升了模型检测精度和泛化能力。模块位置试验和热力图试验表明, C2f - Dynamic 模块能动态适应遮挡目标的特征变化。改进后的 Hwc - YOLO v8n 模型对遮挡杭白菊识别的平均精度均值提升了 1.7 个百分点, 召回率均值提高了 0.88 个百分点。模型消融和对比试验结果表明, 改进后的 Hwc - YOLO v8n 模型相比于 DETR、SSD、YOLO v5、YOLO v6 和 YOLO v7, 对杭白菊的检测效果更好。平均精度均值相较于 DETR、SSD、YOLO v5、YOLO v6 和 YOLO v7 分别提升了 5.7、12.6、0.7、0.75、11.25 个百分点, 召回率均值相较于 YOLO v5 和 YOLO v7 提升了 2.15、1.4 个百分点, 可为后续杭白菊智能化采收作业提供技术支持。

关键词: 杭白菊; 图像识别; 目标检测; YOLO v8; 遮挡检测

中图分类号: TP391.4 文献标识码: A 文章编号: 1000-1298(2025)05-0405-10

OSID:



Improved YOLO v8n for Detection of Hangzhou White Chrysanthemum in Unstructured Environments

YU Chennan^{1,2} WU Yonghong¹ ZHOU Jie¹ YAO Kun¹ HUAN Xiaolong^{1,2} CHEN Jianneng^{1,2}

(1. School of Mechanical Engineering, Zhejiang Sci-Tech University, Hangzhou 310018, China

2. Zhejiang Key Laboratory of Intelligent Sensing and Robotics for Agriculture, Hangzhou 310018, China)

Abstract: In unstructured environments, the cluster growth characteristics of Hangzhou white chrysanthemum lead to severe mutual occlusion, reducing detection accuracy for chrysanthemum detection algorithms. To address this issue, an improved YOLO v8n detection model for Hangzhou white chrysanthemum, called Hangzhou white chrysanthemum - YOLO v8n (Hwc - YOLO v8n), was proposed. Firstly, the model's ability was enhanced to finely detect critical, similar features of the chrysanthemum by increasing the label categories from two to three. Secondly, a dynamic feature extraction module (C2f - Dynamic) was designed in the backbone network to strengthen the model's adaptive response to missing features in occluded targets. Additionally, a 160 pixel × 160 pixel detection head was added to the detection head section, allowing the model to detect small targets more effectively. Finally, the angle penalty metric loss (SIoU) was adopted to optimize the bounding box loss function, improving both detection accuracy and generalization capability. Experimental results from module placement and heatmap analysis demonstrated that the C2f - Dynamic module can dynamically adapt to feature changes in occluded targets. The improved Hwc - YOLO v8n model achieved a 1.7 percentage points increase in mean average precision and a 0.88 percentage points increase in mean recall rate for

收稿日期: 2024 - 11 - 08 修回日期: 2025 - 01 - 06

基金项目: 国家自然科学基金项目 (32301715、U23A20175)、全省农业智能感知与机器人重点实验室开放课题基金项目 (2025QSZD2505) 和浙江理工大学校内科研启动基金项目 (23242167 - Y)

作者简介: 喻陈楠 (1995—), 男, 讲师, 博士, 主要从事农业机械装备与技术、机构运动综合理论等研究, E-mail: yu.cn@zstu.edu.cn

通信作者: 陈建能 (1972—), 男, 教授, 博士, 主要从事智能农机装备、农业机器人、机构分析与综合等研究, E-mail: jiannengchen@zstu.edu.cn

the occluded Hangzhou white chrysanthemum. Ablation and comparison experiments showed that the improved Hwc-YOLO v8n outperformed DETR, SSD, YOLO v5, YOLO v6, and YOLO v7 in detection of the chrysanthemum. Specifically, compared with DETR, SSD, YOLO v5, YOLO v6, and YOLO v7, the mAP was improved by 5.7, 12.6, 0.7, 0.75, and 11.25 percentage points, respectively. The mR was increased by 2.15 percentage points and 1.4 percentage points compared with that of YOLO v5 and YOLO v7, respectively. The research result can provide a technical foundation for future intelligent harvesting of Hangzhou white chrysanthemum.

Key words: Hangzhou white chrysanthemum; image recognition; object detection; YOLO v8; occlusion detection

0 引言

杭白菊是浙江省著名传统中药之一,也是卫生部首批批准的药食同源的道地药材之一^[1]。桐乡是杭白菊原产地,有300多年栽培历史,全域2022年杭白菊种植面积达3133 hm²,占全国白菊花类总面积的60%^[2]。

杭白菊有胎菊和朵菊两个采收期,其中胎菊的经济价值更高,需求量更大,但是采收期只有5 d。杭白菊现有的主流采摘方式是人工肉眼观察花朵的开放程度并手动完成胎菊和朵菊的选择性采摘,随着经济的发展,人工成本日渐增加,这种成本高且效率低的采收方式严重制约了杭白菊产业的发展。为了提升杭白菊采摘效率,降低企业的用工成本,部分学者开始研究杭白菊采收机^[3-4]。现有的杭白菊采收机均不能实现针对胎菊和朵菊的选择性采收,并且采收到的杭白菊含杂率高,需要二次分选,费时费力。因此,研究准确高效的杭白菊检测方法,对实现杭白菊选择性机械化采收代替传统人工采收具有重要意义。

在非结构环境下,杭白菊的簇状生长特性导致其相互遮挡严重,在杭白菊的检测中,不仅要考虑枝叶对杭白菊的遮挡,还要考虑花朵重叠导致的分割问题。针对杭白菊的检测,文献[5]提出了一种基于S分量的快速模糊C均值聚类(FCM)算法,用于从不相关背景中提取杭白菊目标图像。文献[6]引入模式识别方法,通过杭白菊的纹理特征,用最小二乘支持向量机(LS-SVM)算法对杭白菊图像进行分割处理。文献[7]利用圆形度提取胎菊,对不同遮挡粘连类型的胎菊图像进行分割重建。以上方法均具有局限性,一方面是面对枝叶遮挡、花朵严重重叠的情况,对杭白菊的识别能力不足,另一方面是在不同生长期场景中,对因遮挡产生的重叠部分分割效果欠佳。因此,本文的研究重点是解决被遮挡杭白菊的检测效果不佳的问题。

近年来,深度学习技术在遮挡目标检测领域得到了广泛应用^[8-10]。综上所述,深度学习方法相对

于传统机器学习具有准确性高、适应性强、速度快等优点,已成为农作物检测的趋势。然而,不同于其他草莓、番茄等果蔬类作物目标在温室大棚的静态、稳态下的大目标、稀分布的生长特性,杭白菊生长在非结构化的田间环境中,且同一花序杭白菊的生长分布呈簇状,不同花序间距离较近,花朵之间存在相互遮挡,对模型的检测效果要求更高。为了解决上述问题,针对智能化采收中对检测的实际需求,本文提出一种基于YOLO v8n的非结构环境下的杭白菊检测方法。通过增设菊米类别标签、在主干网络的特征提取部分设计动态提取模块、增加160像素×160像素的检测头,以及优化损失函数的方法,改善模型对被遮挡杭白菊的检测能力,实现自然环境下杭白菊的准确检测,以期为后续实现杭白菊智能化选择性采收提供技术支持。

1 杭白菊数据集建立

1.1 数据采集

根据田间杭白菊的采收标准,在浙江省嘉兴市桐乡市菊花育种基地采集样本。考虑样本的泛化性,本次采集在实际田间作业环境中,以不同高度、角度对存在强光、弱光、顺光、逆光等复杂场景下杭白菊进行拍摄。采集时间为2023年10月。相机型号为iPhone11,分辨率为1920像素×1080像素,采集场景如图1所示。



图1 采集场景

Fig.1 Collected scenery

1.2 数据集构建

剔除数据集内杭白菊过度模糊、相似度高的图像,共采集有效图像500幅用于训练和测试,采用百度BML在线标注平台将标注好的图像数据集导出

为 xml 格式。针对图像中存在遮挡的杭白菊, 标记被遮挡杭白菊的最大轮廓掩码区域, 得到掩码区域的最小外接矩形, 保证矩形标注框内包含全部杭白菊, 500 幅图像共计标注 12 853 个胎菊和朵菊目标。取数据集的 80%, 共 400 幅作为训练集, 取 50 幅作为验证集, 其余为测试集, 并保证各划分数据集间严格独立。

1.3 检测标签增加

杭白菊由于花期时间较短, 极易出现接近开放的菊米与胎菊成熟度特征相近的情况, 如图 2 所示。自然生长的杭白菊, 呈现出簇状分布、花序间距小的特点, 花朵与花朵、花朵与枝叶相互遮挡, 容易造成判断性特征缺失, 同时菊米与胎菊的形状、颜色特征相似, 导致模型难以准确识别杭白菊生长交替时期的胎菊。



图 2 不同成熟度杭白菊图像对比

Fig. 2 Comparison of Hangzhou white chrysanthemum images at varying maturity levels

然而, 在以往的杭白菊研究中^[5-7], 由于无需采集菊米, 并没有注意到这种相似的特征可能会影响模型对胎菊细节信息的判断。因此, 本文提出从成熟度检测的角度, 标注未开放的菊花为“菊米”, 如图 3 所示。通过引入更多的检测标签, 训练模型学习如何区分不同成熟度的花朵, 提高模型对花朵关键性特征的精细检测能力, 使得模型对于杭白菊特征的变化和噪声干扰具有更好的鲁棒性, 从而提高模型检测胎菊的准确性。

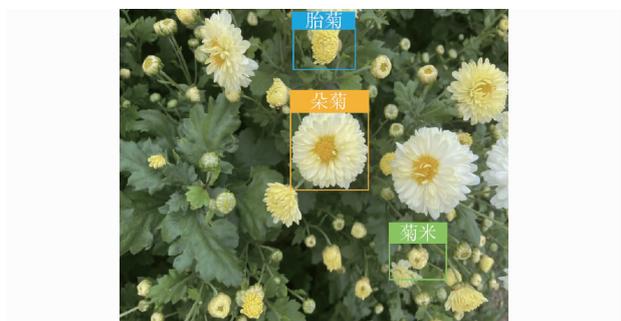


图 3 检测标签示意图

Fig. 3 Diagram of three category detection labels

2 非结构环境下遮挡杭白菊目标检测方法

YOLO v8n 的模型主要由主干网络 (Backbone)、颈部 (Neck)、检测头 (Head) 3 部分组成。其中的主干网络负责提取输入图像的底层特

征, 如边缘、纹理和颜色; 颈部网络负责将 Backbone 提取的多尺度特征进行进一步融合和增强, 为目标检测提供更加丰富的特征信息; 检测头网络根据融合后的特征, 生成最终的检测结果, 包括目标类别、位置框 (Bounding Box) 和置信度。为提升田间采收杭白菊的检测精度, 提高模型对自然环境下被遮挡杭白菊的检测效果, 本文提出一种改进的 YOLO v8n 杭白菊检测模型 Hwc - YOLO v8n。具体的模型改进方案如下: 首先, 增加菊米标签, 实际需求的双类别标签改为三类别标签。其次, 在主干网络中设计一种动态特征提取模块, 在检测头部分增加 160 像素 × 160 像素的检测头。最后, 采用 SIoU 优化边界框损失函数。Hwc - YOLO v8n 模型结构如图 4 所示。

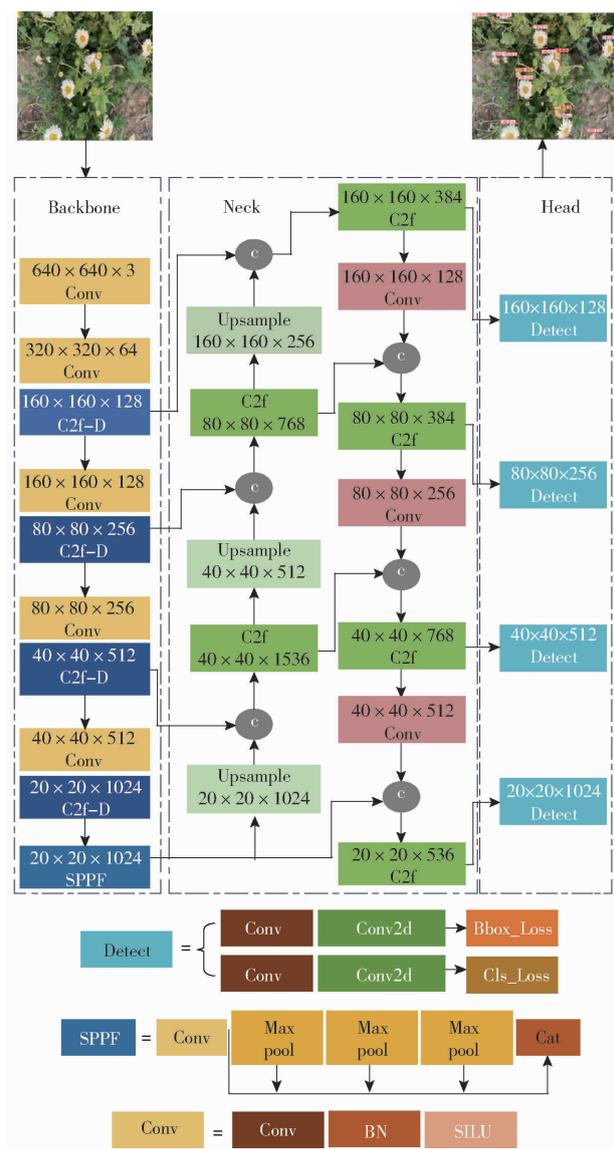


图 4 改进 YOLO v8n 检测模型

Fig. 4 Improved YOLO v8n detection model

2.1 遮挡目标特征动态提取模块设计

在检测的特征提取过程中, 胎菊和菊米之间具有相似颜色、纹理或形状, 同时, 遮挡问题致使部分

胎菊和菊米的差异特征出现缺失,并且缺失情况各异。这些因素的共同作用,使得模型容易忽略胎菊和菊米之间的关键细节信息,进而引发特征混淆,导致检测效果大幅度降低。因此,在面临遮挡情况时,加强模型对胎菊和菊米差异特征的动态选择能力,可以减少特征混淆,提高模型对遮挡杭白菊的检测能力。

YOLO v8 的特征提取 C2f 模块^[11]通过卷积特征转换、分支处理和特征融合,显著增强了网络对复杂数据的抽象表达能力和非线性建模能力。但其采用的是固定形状卷积核,只能捕捉固定的局部感受野,面对胎菊与菊米之间的特征混淆和遮挡问题,难以动态适应。固定形状卷积核公式为

$$y(p) = \sum_{k=1}^K w_k \mathbf{x}(p + p_k) \quad (1)$$

式中 $y(p)$ ——输出特征图在位置 p 处的值

\mathbf{x} ——输入特征图

w_k ——卷积核第 k 个权重

p ——当前像素位置

p_k ——卷积核第 k 个位置相对于 p 的偏移量

K ——卷积核的采样位置个数

本文设计了一种名为 C2f-Dynamic 的动态特征提取模块,如图 5 所示,用于优化特征提取。该模块结合可变形卷积的思想,旨在缓解遮挡目标检测中的特征缺失问题,提高检测精度和鲁棒性。

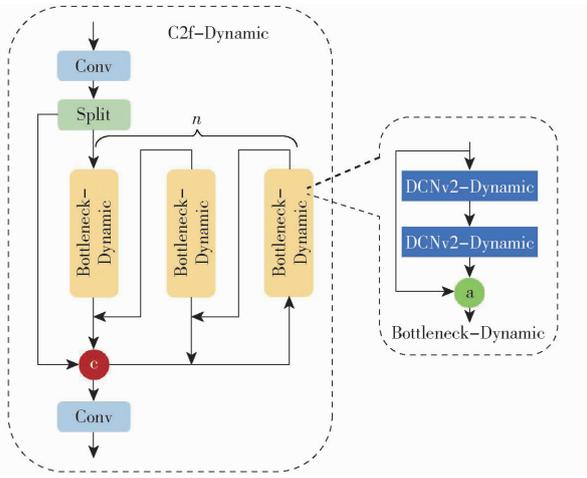


图 5 C2f-Dynamic 动态特征提取模块

Fig. 5 C2f-Dynamic dynamic feature extraction module

具体而言,在 C2f 模块中,本文将原 Bottleneck 的卷积替换为 DCNv2 可变形卷积^[12]。在每个采样点加入权重项进行惩罚,并调整偏移量的方向向量 \mathbf{x} 和 \mathbf{y} 的值,改变卷积核样本的空间分布和相对影响能力。优化后的固定形状卷积核公式为

$$y(p) = \sum_{k=1}^K w_k \mathbf{x}(p + p_k + \Delta p_k) \Delta m_k \quad (2)$$

式中 Δp_k ——动态学习的偏移,表示对 p_k 的微调

Δm_k ——动态学习的权重系数,用于控制每个位置的贡献度

然而,DCNv2 中的偏移量计算时,采用普通卷积的方式对处理遮挡目标的位置信息时存在固有的局限性。对此,文献[13]提出一种遮挡注意力机制,通过两层全连接网络,将每个通道的信息进行融合,弥补在遮挡场景下的损失。同时,将值范围从 $[0, 1]$ 扩展到 $[1, e]$,使结果对位置误差的容忍度更高。可见,注意力机制对捕捉遮挡特征信息有着积极作用。为了解决这一问题,本文采用 SimAM 注意力机制 (Simple, parameter-free attention module, SimAM)^[14],其结构如图 6 所示。现有注意力往往借助额外的子网络,通过学习特征图不同位置之间的相似度来生成注意力权重。而 SimAM 从神经科学理论出发,构建一种能量函数进行重要性的挖掘,无需额外参数为特征图推导出 3D 注意力权重,避免了额外参数对模型的负担。

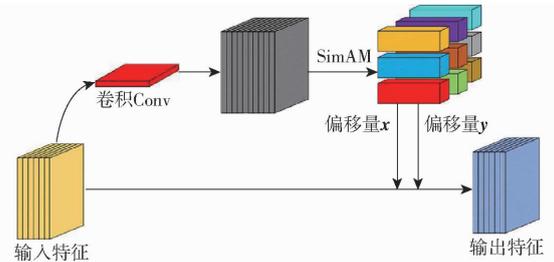


图 6 DCNv2-Dynamic 原理图

Fig. 6 DCNv2-Dynamic schematic

本文认为相较其他注意力机制如 CBAM^[15]、CA^[16]、SE^[17] 等,依赖于全局平均池化或全连接层来进行加权计算,更多地考虑了全局信息。然而,在处理遮挡目标时,由于遮挡会导致部分目标信息的缺失,全局信息的可靠性可能会受到严重影响。因此,这些机制在遮挡场景下可能无法提供足够的局部细节和准确性。而 SimAM 注意力机制,通过能量函数来计算注意力权重,关注于局部信息的处理。SimAM 通过均值将特征的值中心化;计算中心化特征的局部方差;通过考虑每个特征点的能量值在特征图中的位置以及该位置周围的局部统计信息来建立能量函数,计算每个特征点的重要性。这种方式更加侧重局部信息的处理。由于遮挡目标存在局部信息的缺失,突出局部判断特征与目标之间的关系对捕捉到杭白菊未被遮挡部分的特征更为重要。能量计算公式为

$$e_t = \frac{4(\sigma_t^2 + \lambda)}{(t - u)^2 + 2\sigma_t^2 + 2\lambda} \quad (3)$$

式中 t ——目标神经元

u ——除 t 外所有神经元平均值

σ_t^2 ——除 t 外所有神经元方差

λ ——超参数

特征缩放公式为

$$X = \text{sigmoid} \left(\frac{1}{E} \right) x \quad (4)$$

式中 E ——所有通道和空间维度中的能量函数的总和

通过对 DCNv2 模块增加相关性的关注,使得偏移量的方向向量 x 和 y 的值更加聚焦杭白菊遮挡下剩余的显式特征。这使得模块相较于原来更能够动态适应遮挡目标的特征缺失情况,同时消除胎菊与菊米之间特征混淆问题所造成的关联影响。

2.2 针对小目标的检测头设计

YOLO v8 共有 3 个检测头,各个检测头所对应的检测特征图尺寸为 80 像素 \times 80 像素、40 像素 \times 40 像素、20 像素 \times 20 像素,分别用于检测 8 \times 8、16 \times 16、32 \times 32 以上的目标。面对菊园复杂环境,胎菊尺寸小,导致胎菊在图像中所占像素比较小,原模型对特征的过分提取会导致遮挡杭白菊的细节信息受到损失,容易出现漏检的问题^[18]。因此,在杭白菊的检测中,检测头应该具备针对小目标的检测能力,以提升对遮挡和重叠目标的检测准确性。

本文为解决这一问题,在 YOLO v8 现有 3 个检测头的基础上,增加一个 160 像素 \times 160 像素的检测头,用于检测 4 \times 4 以上的目标。160 像素 \times 160 像素的检测头具有更高的分辨率和更大尺度的特征图,增加 160 像素 \times 160 像素的检测头可以捕捉到更多小目标的细节信息,提升模型对小目标的感知能力,使得模型在菊园复杂背景和菊花被遮挡情况下,依然能够有效区分目标和噪声;同时,对细节信息的保留可以确保细小或部分遮挡的目标也能被准确感知到。

2.3 边界框损失函数优化

IoU 用于评估模型在预测目标位置和大小方面的准确性。高 IoU 值通常意味着模型能够精确地定位目标边界框。模型中原有的 CIoU (Complete IoU)^[19]考虑边界框的中心点距离和长宽比的差异,通过引入修正因子,使得损失对于不同形状的目标框更具鲁棒性,通常适合于对目标边界精确度要求较高的场景。但在菊园环境下,胎菊和朵菊的形状和大小变化较大,高度存在差异以及它们与枝叶的交错遮挡,可能会造成过度惩罚。因此,本文根据杭白菊的实际特点,引入一种考虑边界框向量角度的 SIoU 损失函数^[20-21]。相对于传统的 IoU,SIoU 通过综合优化边界框的位置、方向和形状,不仅解决了传

统 IoU 在零交集时梯度消失的问题,还大幅提升了对旋转目标和复杂场景的适应能力。SIoU 的引入考虑了边界框预测与真实框之间的平滑过渡,更好地适应了变化多样的目标形状和遮挡情况,从而提高了模型的鲁棒性,SIoU 的各个参数如图 7 所示。SIoU 损失包含角度损失、距离损失、形状损失和交并比损失 4 部分。

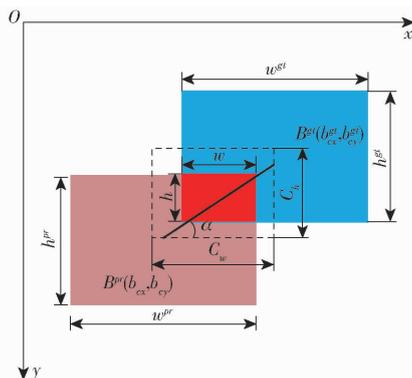


图 7 SIoU 计算参数示意图

Fig. 7 Schematic of SIoU calculation parameters

角度损失 Λ 描述了预测框与真实框中心点连线与 x 、 y 轴之间的最小角度,公式为

$$\Lambda = 1 - 2 \sin^2 \left(\arcsin(x) - \frac{\pi}{4} \right) \quad (5)$$

其中

$$x = \frac{\max(b_{cx}^g, b_{cy}) - \min(b_{cx}^g, b_{cy})}{\sqrt{(b_{cx}^g - b_{cx})^2 + (b_{cy}^g - b_{cy})^2}} \quad (6)$$

式中 (b_{cx}, b_{cy}) ——预测框的中心点坐标

(b_{cx}^g, b_{cy}^g) ——真实框的中心点坐标

距离损失 Δ 描述了预测框与真实框中心点之间的距离,惩罚代价与角度损失呈正相关,公式为

$$\Delta = 2 - e^{-\lambda \left(\frac{b_{cx}^g - b_{cx}}{C_w} \right)^2} - e^{-\lambda \left(\frac{b_{cy}^g - b_{cy}}{C_h} \right)^2} \quad (7)$$

$$\lambda = 2 - \Lambda \quad (8)$$

式中 C_w ——预测框横纵坐标之差

C_h ——真实框横纵坐标之差

形状损失 Ω 描述了两框之间的长宽比,通过对长、宽收敛来达到整体收敛的效果,公式为

$$\Omega = 1 - e^{-\frac{|w - h^g|}{\max(w, w^g)}} + \left(1 - e^{-\frac{|h - h^g|}{\max(h, h^g)}} \right)^4 \quad (9)$$

式中 w, h ——交集的长、宽

w^g, h^g ——预测框的长、宽

最后,SIoU 定义为

$$L_{SIoU} = 1 - IoU + \frac{\Delta + \Omega}{2} \quad (10)$$

3 试验与讨论

3.1 试验环境与方法

本研究相关试验在 Ubuntu 18.04 操作系统进行,其 GPU 为 12 GB 显存的 GeForce RTX 3080 Ti,

CUDA 版本为 11.6, 所有程序都是用 Python 编写的。本文以官方的 YOLO v8 代码库为基础, 不采用预训练权重, 基于上述条件实现了第 2 节内容所描述的修改。使用 ADAM 优化器执行训练, 将初始学习率设置为 8×10^{-4} 。运行 300 个批次, 批次大小为 8。

3.2 试验指标

训练时采用 16 个样本作为一个处理单元, 初始学习率设置为 0.001, 根据初始设置逐渐衰减。动量衰减、重量衰减等参数参照 YOLO v8 中的初始参数, 验证该模型对杭白菊检测的效果。

为了准确地评价模型对各个标签的检测性能, 本文基于测试集数据, 采用平均精度 (AP)、召回率 R、平均精度均值 (mAP)、召回率均值 (mR)、F1 值和模型内存占用量来评估模型的精准度和模型的复杂度; 由于菊米不属于采摘对象, 因此在试验中只记录实际需要的胎菊与朵菊试验。

3.3 改进 YOLO v8 模型对比试验

3.3.1 检测标签对比试验

采用三类别检测标签替换原有两类别检测标签。为了探究三类别标签的有效性, 开展对比试验, 结果如表 1 所示。

表 1 标签对比试验结果
Tab.1 Label comparison test %

标签种类	平均精度		召回率		F1 值
	胎菊	朵菊	胎菊	朵菊	
双标签	82.2	95.4	71.9	93.6	85.58
三标签	81.8	95.0	76.4	91.8	86.20

从表 1 试验结果可知, 添加菊米标签后, 模型对胎菊的平均检测精度降低了 0.4 个百分点, 对胎菊的召回率显著提升了 4.5 个百分点, F1 值提升了 0.62 个百分点; 对朵菊的平均精度和召回率降低了 0.4 个百分点和 1.8 个百分点, 但召回率和准确率间达到了最佳平衡点。菊米虽然不是采摘目标, 但是由于菊米和胎菊的形状、颜色、尺寸相似, 采用双类别标签, 模型无法精准地区分菊米和胎菊, 容易出现误判的情况。添加菊米标签后, 模型能够学习菊米这一特定对象的特征, 以及菊米和胎菊在细节上的差异。该方法提高了模型对杭白菊关键性特征的精细化检测能力, 抑制菊米与胎菊的相似外形特征所造成的影响。在不增加模型内存占用量的情况下, 使原模型对胎菊的漏检问题有较大改善, 后续均对三标签模型进行试验分析。

3.3.2 遮挡目标特征动态提取模块试验分析

对主干网络中的特征提取模块进行改进, 设计一种遮挡目标特征动态提取模块 C2f-Dynamic, 以

加强模型对被遮挡胎菊和菊米的差异性细节特征的动态选择能力, 改善特征混淆问题, 提高对被遮挡杭白菊的检测能力, 以下称为 C2f-D 模块。

首先对模块的插入位置进行试验。增加过多模块会增加模型的计算量和大小, 因此仅讨论 1 个、2 个模块和 4 个模块的插入, 旨在探究最优的模块插入位置, 减少模块计算量负担, 位置如图 8 所示, 图中蓝色圆圈是 C2f-D 取代 C2f 的位置。

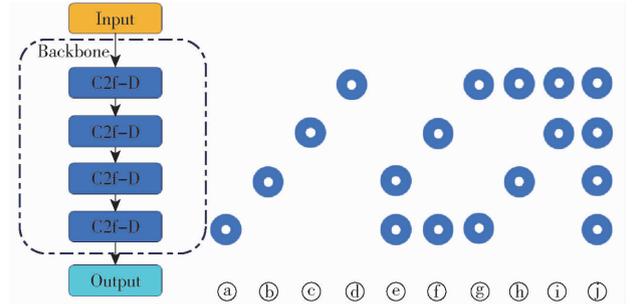


图 8 模块插入位置

Fig.8 Module insertion position

由表 2 试验结果可知, 对 C2f-Dynamic 在单个模块插入的 (a)~(d) 中, 第 1、第 2、第 3、第 4 个位置模块的插入对胎菊的平均精度分别提高了 0.4、0.2、1、1 个百分点; 第 2、第 3、第 4 个位置模块的插入对朵菊的平均精度分别提高了 0.2、0.1、0.2 个百分点; 说明了模型对杭白菊遮挡的判断特征提取主要聚焦于浅层信息。然而, 随着插入位置深入, 朵菊的召回率均有所提升, 胎菊的召回率却降低, 尤其位于第 3、第 4 个位置分别降低了 0.7、1.5 个百分点, 表明越深的特征提取模块伴随着细节特征的损失, 对胎菊这类小目标提取的遮挡信息越少。

表 2 模块位置对比试验结果

Tab.2 Module position comparison test %

模块位置	平均精度		召回率	
	胎菊	朵菊	胎菊	朵菊
(a)	82.20	95.00	73.20	93.50
(b)	82.00	95.20	79.40	94.20
(c)	82.80	95.10	75.70	92.70
(d)	82.80	95.20	74.90	93.50
(e)	83.33	95.20	75.70	90.40
(f)	82.70	95.10	74.20	93.30
(g)	82.10	95.00	76.10	91.00
(h)	83.30	96.30	78.00	91.20
(i)	80.30	94.80	72.80	90.40
(j)	82.40	95.20	76.60	94.20

试验结果表明 (e)、(i)、(j) 精度较 (f)、(g)、(h) 总体降低, (i)、(j) 与效果最好的 (h) 相比, 胎菊的平均精度最多降低了 3 个百分点, 召回率降低了 5.2 个百分点。这表明了过多的连续改进特征提取可能会扰乱特征信息的分布, 导致模型的精度降低, 间隔

的改进特征提取模块,更适用于胎菊这类小目标的检测。

在④、⑤和⑥中,⑥总体表现最好,对胎菊和朵菊平均精度提升了 1.5 个百分点和 1.3 个百分点,胎菊召回率提高了 1.6 个百分点。虽然对朵菊的召回率降低了 0.6 个百分点,但朵菊平均精度显著上升,这表明对朵菊这类较大目标而言,深层的语义信息将更好地通过第 4 个 C2f-Dynamic 和 Neck 层得到提取的特征金字塔,使得在后续特征融合中能够充分学习到变形卷积中的突出信息,同时,第 2 个位置的模块可以很好地将胎菊的信息输入到特征金字塔中,两个模块达到了效果的平衡。综上所述,本文采用⑥的方法插入改进的特征提取模块。

其次,为了验证 C2f-D 模块中的 SimAM 注意力机制对遮挡目标关注的有效性和优越性,分别对比 SE、ECA、BAM、CA、CCA 和 CBAM 对模型的性能影响。表 3 表明不同的注意力机制对模型的平均精度、召回率有较大影响。使用 SimAM 注意力机制的平均精度为 83.30% 和 96.30%,召回率(Recall)为 78% 和 91.2%。相较于 SE、ECA、BAM、CA、CCA、CBAM 注意力机制,胎菊的平均精度提升了 1.2、3.2、0.8、1.2、1.5 个百分点,对朵菊的平均精度提升了 1.3、1.4、1.5、0.7、0.8、0.8 个百分点。除 CBAM 外模型对胎菊的召回率提升了 4.6、3、11.1、4.2、1.5 个百分点。虽然 SimAM 相较于 CBAM 对胎菊召回率没有优势,同时,对朵菊的召回率有所下降,但综合考虑其无参的属性和 SimAM 相较于其他注意力机制对遮挡信息的关注,其依然是最优的选择。

表 3 注意力机制对比性能

Tab. 3 Comparison of attention mechanism

模块种类	performance			
	平均精度		召回率	
	胎菊	朵菊	胎菊	朵菊
C2f + DCNV2	82.10	95.20	78.20	92.00
C2f - Dynamic	83.30	96.30	78.00	91.20
+ SE	82.30	95.00	73.40	94.50
+ ECA	81.00	94.90	75.00	93.60
+ BAM	80.10	94.80	66.90	92.80
+ CA	82.50	95.60	80.60	92.50
+ CCA	82.10	95.70	73.80	93.60
+ CBAM	81.70	95.50	76.50	93.20

图 9 为选取测试集中多幅不同图像,分别用原始模型、DCNV2 模块和 C2f-Dynamic 在激活权重下的模型之间关注区域可视化图。输入图中标注了不同类型的菊花,蓝色方框内是朵菊,绿色方框内是胎菊,黄色方框内是菊米。图 9 表明,在原模型中 YOLO v8 明显对朵菊的花瓣部分显示了较高的激活

权重,朵菊较大的面积使得原模型对朵菊有着明显的热点,而忽略了细小目标。而在图 9c 中,可以看到在菊花图像中产生了更为广泛的激活区域,在背景中也有较多的激活点,模型更加关注花朵的周围区域,由于杭白菊生长环境复杂,且具有簇状生长的特点,分布密集的杭白菊使得 DCNV2 在动态变形的过程中,产生了较多的背景噪声,变形的过程使模型偏离了应该关注的区域,最终导致检测效果的降低。图 9d 中,可以发现相较于图 9c,C2f-Dynamic 对背景噪声控制较好,热点权重更加关注被遮挡花朵的花蕊等关键性特征的形状和规则纹理。可见在遮挡目标的检测中,C2f-Dynamic 因为注意力机制中的信息关注分配,很好地抑制了背景噪声,此时的 DCNV2 出现了向遮挡目标的变形转移,克服了原有 DCNV2 面对复杂环境的缺陷。

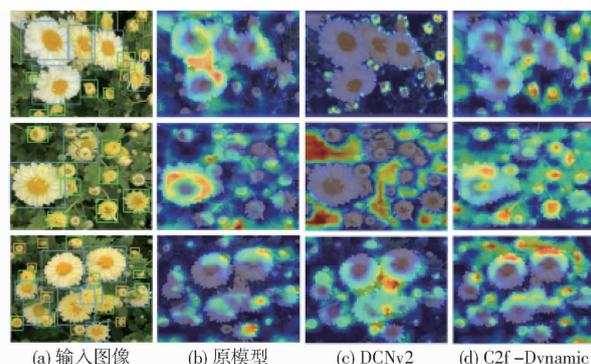


图 9 关键区域权重激活图

Fig. 9 Activation diagrams of key area weights

3.3.3 边界框损失函数优化结果分析

为验证 SIOU 边界框损失函数在杭白菊遮挡检测中的优越性,分别对比了 CIOU、GIOU、EIOU 和 PLOU 损失函数对改进模型性能的影响。如表 4 所示,SIOU 对胎菊的平均精度分别比 CIOU、GIOU、EIOU、PLOU 高 1.2、1、2.1、0.7 个百分点。SIOU 对胎菊的召回率分别比 CIOU、GIOU、EIOU、PLOU 高 1.2、4.2、5.9、3.3 个百分点。尽管 SIOU 对朵菊和平均精度召回率不是完全占优,但综合评价 SIOU 综合占优。

表 4 不同边界框损失函数性能对比

Tab. 4 Performance comparison of different

损失函数	boundary box loss functions			
	平均精度		召回率	
	胎菊	朵菊	胎菊	朵菊
SIOU	83.00	95.70	77.80	93.00
CIOU	81.80	95.00	76.60	91.80
GIOU	82.00	95.80	73.60	94.50
EIOU	80.90	95.70	71.90	92.80
PLIU	82.30	95.50	74.50	92.80

3.4 改进 YOLO v8 模型消融试验分析

为验证本研究改进策略对 YOLO v8n 模型检测

性能的影响,对模型开展了消融试验,试验过程中保持数据集、训练参数的一致性,结果如表 5 所示。

表 5 改进模型消融试验结果

Tab.5 Ablation test results of improved model

试验编号	C2f-Dynamic	p2	SIoU	平均精度/%		平均精度 均值/%	召回率/%		召回率均 值/%	F1 值/ %	浮点运 算数
				胎菊	朵菊		胎菊	朵菊			
1	×	×	×	81.80	95.00	88.40	76.40	91.80	84.10	86.20	8.10×10^9
2	√	×	×	83.30	96.30	89.80	78.00	91.20	84.60	87.12	8.10×10^9
3	√	√	×	83.70	95.60	89.65	78.40	92.80	85.60	87.58	1.21×10^{10}
4	√	√	√	83.90	95.50	89.70	73.80	93.50	83.65	86.57	1.21×10^{10}

注: × 表示未包含该模块;√表示包含该模块。

由表 5 测试结果可知,试验 1 为原始 YOLO v8n 模型,在胎菊、朵菊双类别标签的基础上增加了菊米标签,在参数量、计算量和模型内存占用量均不发生变化的情况下,效果均有所提升,证明了通过引入更多的检测标签,可以增强模型对花朵关键性特征的精细检测能力;试验 2 在试验 1 的基础上设计了动态特征提取模块 C2f-D,相比试验 1,模型对胎菊和朵菊的检测效果提升都较为明显,平均精度均值与召回率均值分别提升了 1.4、0.5 个百分点,证明加入 C2f-D 后,模型对目标的细节提取更加关注,进而检出更多目标;试验 3 在试验 2 的基础上增加小目标层后,相较试验 2 对胎菊的平均精度提升了 0.4 个百分点,召回率提升了 0.4 个百分点,此结果表明,小目标层的加入,放大了检测头大小限制导致模型所忽略的变形卷积所改变的细节偏移信息;模型对 C2f-D 提取的特征在浅层目标下关注更加细致;试验 4 利用 SIoU 损失函数优化边界框损失函数,对朵菊的召回率提升了 0.7 个百分点,对胎菊的平均精度也有所提高,相比于试验 3,模型复杂度不变;上述消融试验分析证明了本文对模型的改进对遮挡小目标的检测有着有益效果。通过对比测试集的检测结果与标签,模型对各个遮挡的识别效果如图 10 所示,绿色框表示正确检出的杭白菊,红色框表示漏检的杭白菊,蓝色框表示误检的杭白菊。由图 10 表明,Hwc-YOLO v8n 能够较好地识别被遮挡的杭白菊,而原模型漏检、误检现象较为严重。

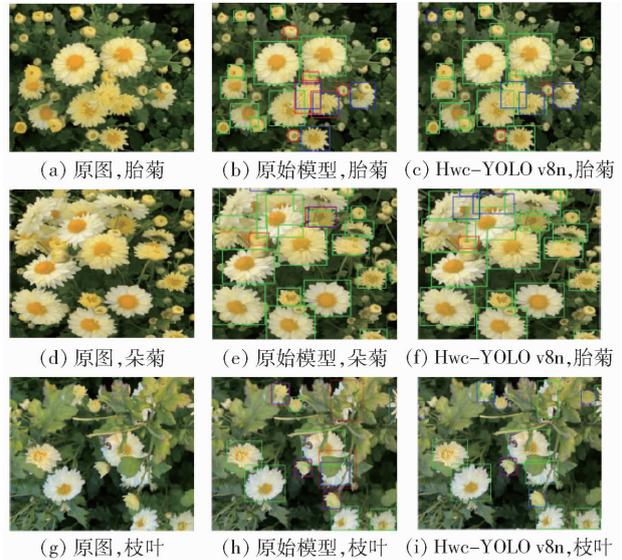


图 10 Hwc-YOLO v8n 模型检测结果

Fig. 10 Detection results of modified Hwc-YOLO v8n model

为深入研究 Hwc-YOLO v8n 相较于原模型在遮挡杭白菊检测方面的实际效果,本文对已有 500 幅数据集进行遮挡的精细化处理,通过对数据集中的遮挡胎菊与遮挡朵菊进行标注,统计数据集中遮挡杭白菊数量,共计 3 931 个遮挡目标,其中遮挡胎菊数量为 941 朵,遮挡朵菊数量为 2 990 朵,得到平均每幅图像遮挡个数约为 7.8 个。在此基础上,进一步将测试集中遮挡标签数量大于 8 的样本定义为高遮挡数据集,共计 14 幅,含有遮挡杭白菊 263 朵。其中胎菊 37 朵,朵菊 226 朵。以此开展遮挡数据集检测效果试验,试验结果见表 6。

表 6 改进模型遮挡试验结果

Tab.6 Evaluation results of different experimental models

模型	平均精度/%		平均精度 均值/%	召回率/%		召回率均 值/%	F1 值/%	检测时间/ s
	胎菊	朵菊		胎菊	朵菊			
YOLO v8	70.30	96.00	83.20	62.40	95.40	78.90	80.99	0.56
Hwc-YOLO v8	74.50	95.20	84.90	63.80	92.10	77.90	81.25	0.80

3.5 改进 YOLO v8n 模型对比试验分析

为对比 Hwc-YOLO v8n 与不同目标检测模型的检测性能,选取 SSD^[20]、DETR^[21]、YOLO 系

列^[22-23]目标检测模型进行对比试验,训练过程中保持训练参数、数据集的一致性。由表 7 试验结果可知,Hwc-YOLO v8 模型平均精度均值为 89.7%、召

表7 不同试验模型评估结果

Tab.7 Occlusion test results of improved model

模型	平均精度/%		平均精度 均值/%	召回率/%		召回率均 值/%	F1 值/%	检测时间/ s	模型内存 占用量/MB
	胎菊	朵菊		胎菊	朵菊				
DETR	76.00	92.00	84.00	75.20	91.00	83.10	83.55	1.25	40
SSD	70.20	84.00	77.10	61.70	80.40	71.05	73.95	1.63	90.6
YOLO v5	82.50	95.50	89.00	68.30	94.70	81.50	85.09	0.52	88.5
YOLO v6	83.80	94.10	88.95	82.90	91.50	87.20	88.07	0.52	70.9
YOLO v7	68.20	88.70	78.45	75.50	89.00	82.25	80.31	1.25	71.3
Hwc - YOLO v8	83.90	95.50	89.70	73.80	93.50	83.65	86.57	0.77	72

回率均值为 83.65%, 相较于 YOLO v5、YOLO v6 和 YOLO v7, 平均精度均值提升了 0.7、0.75、11.25 个百分点, 召回率相较于 YOLO v5、YOLO v7 提升了 2.15、1.4 个百分点。二阶段模型如 SSD 的表现较差, 可能的原因是面对遮挡目标的特征表示不完整会在网络结构、IoU 计算和后处理阶段的不足等多个方面引起模型的不佳表现。DETR 的检测时间相较于 YOLO 系列较长, 原因在于采用了 Transformer 架构, 这种架构在处理序列数据时表现优异, 但其复杂性也带来了一定的计算成本。试验结果表明, 本文设计的模型对杭白菊有更好的检测效果。

4 结论

(1) 通过增加菊米标签, 模型对胎菊的召回率显著提升了 4.5 个百分点, 提升了对杭白菊关键性

特征的精细化检测能力。

(2) 设计一种动态特征提取模块 C2f - Dynamic 对遮挡目标进行特征的动态适应。改进后的模型在平均精度均值和召回率均值方面较基线模型分别提高了 1.4、0.5 个百分点。通过分析热力图, 发现模块更加关注杭白菊遮挡区域的显著特征部分, 这与人眼对遮挡目标的判断具有较高的一致性。

(3) 在检测头部分增加 160 像素 × 160 像素的检测头, 使得模型具备针对小目标检测的能力, 放大了 C2f - Dynamic 的效果, 增强了模型的鲁棒性。

(4) 采用 SIoU 损失函数优化边界框损失函数, 模型的准确率、F1 值、mAP 分别提升了 1.86、0.20、0.25 个百分点, 有效地提升了模型精度。与 SSD、DETR、YOLO v5、YOLO v6、YOLO v7 模型相比, 改进后模型的检测效果最佳、鲁棒性更强。

参 考 文 献

- [1] 钟爱娇, 姜哲, 李雪征, 等. 杭白菊化学成分和药理活性的研究进展[J]. 现代药物与临床, 2014, 29(7): 824 - 830. ZHONG Aijiao, JIANG Zhe, LI Xuezheng, et al. Research progress on chemical constituents and pharmacological activities of *Chrysanthemi Flos*[J]. *Drugs & Clinic*, 2014, 29(7): 824 - 830. (in Chinese)
- [2] 张雨滴, 肖飞. 浙江桐乡杭白菊飘香海外出口量同比增长 46.37% [N/OL]. 中新网浙江, 2022 - 12 - 16. <https://www.zj.chinanews.com.cn/jzkzj/2022-12-16/detail-ihchvren2492601.shtml>.
- [3] 王荣炎, 于慧爽, 陈安迪, 等. 气动翻转梳齿式菊花采摘装置设计与试验[J]. 农业机械学报, 2022, 53(10): 184 - 193. WANG Rongyan, YU Huishuang, CHEN Andi, et al. Design and test of pneumatic flipping comb-type chrysanthemum picking device[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(10): 184 - 193. (in Chinese)
- [4] 刘子良, 王庆祝, 于慧爽, 等. 梳齿带自走式杭白菊收获机设计与试验[J]. 农业机械学报, 2023, 54(增刊 2): 43 - 51, 100. LIU Ziliang, WANG Qingzhu, YU Huishuang, et al. Design and experiment of self-propelled harvester with comb and conveyer belt for Hangzhou white chrysanthemum[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(Supp. 2): 43 - 51, 100. (in Chinese)
- [5] YANG Q, CHANG C, BAO G, et al. Recognition and localization system of the robot for harvesting Hangzhou white chrysanthemums[J]. *International Journal of Agricultural and Biological Engineering*, 2018, 11(1): 88 - 95.
- [6] YANG Q, LUO S, CHANG C, et al. Segmentation algorithm for Hangzhou white chrysanthemums based on least squares support vector machine[J]. *International Journal of Agricultural and Biological Engineering*, 2019, 12(4): 127 - 134.
- [7] 常春. 自然环境下胎菊识别方法的研究[D]. 杭州: 浙江工业大学, 2019.
- [8] 司永胜, 孔德浩, 王克俭, 等. 基于 CRV - YOLO 的苹果中心花和边花识别方法[J]. 农业机械学报, 2024, 55(2): 278 - 286. SI Yongsheng, KONG Dehao, WANG Kejian, et al. Recognition of apple king flower and side flower based on CRV - YOLO [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 55(2): 279 - 285. (in Chinese)
- [9] QI C, NYALALA I, CHEN K. Detecting the early flowering stage of tea chrysanthemum using the F - YOLO model[J]. *Agronomy*, 2021, 11(5): 834.
- [10] BAI Y, YU J, YANG S, et al. An improved YOLO algorithm for detecting flowers and fruits on strawberry seedlings[J].

Biosystems Engineering, 2024, 237: 1 – 12.

- [11] REJIN V, SAMBATH M. YOLOv8: a novel object detection algorithm with enhanced performance and robustness[C]//2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS), 2024: 1 – 6.
- [12] ZHU X, HU H, LIN S, et al. Deformable convnets v2: more deformable, better results[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 9308 – 9316.
- [13] YU Z, HUANG H, CHEN W, et al. YOLO – FaceV2: a scale and occlusion aware face detector[J]. Pattern Recognition, 2024, 155: 110714.
- [14] YANG L, ZHANG R Y, LI L, et al. SimAM: a simple, parameter-free attention module for convolutional neural networks[C]//International Conference on Machine Learning, 2021.
- [15] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [C] // Proceedings of the European Conference on Computer Vision (ECCV), 2018: 3 – 19.
- [16] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021.
- [17] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 42: 2011 – 2023.
- [18] 王金鹏, 何萌, 甄乾广, 等. 基于 COF – YOLOv5s 的油茶果识别定位 [J]. 农业工程学报, 2024, 40(13): 179 – 188.
WANG Jinpeng, HE Meng, ZHEN Qianguang, et al. *Camellia oleifera* fruit harvesting in complex environment based on COF – YOLOv5s [J]. Transactions of the CSAE, 2024, 40(13): 179 – 188. (in Chinese)
- [19] ZHENG Z, WANG P, REN D, et al. Enhancing geometric factors in model learning and inference for object detection and instance segmentation [J]. IEEE Transactions on Cybernetics, 2022, 52(8): 8574 – 8586.
- [20] WEI L, DRAGOMIR A, DUMITRU E, et al. SSD: single shot MultiBox detector [M]. Springer, Cham, 2016.
- [21] LV W, XU S, ZHAO Y, et al. Detsr beat yolos on real-time object detection [C] // 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2023: 16965 – 16974.
- [22] LI C Y, LI L, JIANG H L, et al. YOLOv6: a single-stage object detection framework for industrial applications [A]. 2022.
- [23] WANG C Y, BOCHKOVSKIY A, LIAO H. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C] // 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2022: 7464 – 7475.