

# 基于改进 YOLO v8m 的柑橘花期与花量识别方法

潘鹤立<sup>1</sup> 肖松<sup>1</sup> 杨晓霞<sup>1</sup> 胡子钰<sup>1</sup> 陈思虞<sup>1</sup> 林洁雯<sup>2</sup> 王会全<sup>3</sup> 兰连清<sup>4</sup>

(1. 福建农林大学园艺学院, 福州 350002; 2. 北京市农林科学院智能装备技术研究中心, 北京 100097;  
3. 福建农业职业技术学院园艺园林学院, 福州 350303; 4. 马普科技(福州)有限公司, 福州 350002)

**摘要:** 为实现山地果园柑橘花期准确检测, 提出了一种基于 YOLO v8m 改进的柑橘花期检测方法 (YOLO v8m - CFDNet)。在 YOLO v8m 框架上, 引入花瓣感知卷积 (PAC) 优化 C2f 模块以增强细粒度特征提取; 结合 MS - CAM 与 SAM 提升多尺度注意力表达; 采用 DySample 动态上采样缓解边缘模糊; 设计光照自适应加权交叉熵以增强逆光场景鲁棒性; 并利用 Linear Soft - NMS 优化后处理, 减少密集目标漏检。在福建永春芦柑和福州福橘数据集上进行训练与验证, 采用消融实验、对比实验及泛化实验综合评估模型性能。消融实验表明, 各模块均能独立提升性能, 最终模型 mAP@0.5 达 83.07%, 较基准提升 8.55 个百分点; 对比实验中, YOLO v8m - CFDNet 在 SSD、YOLO v5m、YOLO v6、YOLO v9e、YOLO v10m 等模型中性能最优, 检测速度达 91.94 f/s, 参数量仅  $2.839 \times 10^7$ ; 泛化实验显示, 在福州福橘数据集上 mAP@0.5 提升 6.64 个百分点, 逆光条件下召回率提升 7.2 个百分点。混淆矩阵分析表明, 开放期识别准确率最高 (86.91%)。本文所提出的 YOLO v8m - CFDNet 在检测精度、实时性与计算复杂度之间实现了良好平衡, 具备跨品种与复杂光照条件下的鲁棒性与泛化能力, 为柑橘花期自动化监测与智能农业管理提供了有效技术支撑。

**关键词:** 柑橘; 花朵识别与计数; YOLO v8m; 密集分布

中图分类号: S24 文献标识码: A 文章编号: 1000-1298(2026)05-0186-11

OSID:



## Dense Distribution Citrus Flowering Detection Method Based on YOLO v8m

PAN Heli<sup>1</sup> XIAO Song<sup>1</sup> YANG Xiaoxia<sup>1</sup> HU Ziyu<sup>1</sup> CHEN Siyu<sup>1</sup> LIN Jiwen<sup>2</sup> WANG Huiquan<sup>3</sup> LAN Lianqing<sup>4</sup>

(1. College of Horticulture, Fujian Agriculture and Forestry University, Fuzhou 350002, China

2. Intelligent Equipment Technology Research Centre, Beijing Academy of Agriculture and Forestry Sciences, Beijing 100097, China

3. College of Horticulture and Landscape Architecture, Fujian Vocational and Technical College of Agriculture, Fuzhou 350303, China

4. Maptech (Fuzhou) Co., Ltd., Fuzhou 350002, China)

**Abstract:** Aiming to achieve accurate detection of citrus flowering stages in mountainous orchards, an improved citrus flower detection method was proposed based on YOLO v8m, named YOLO v8m - CFDNet. Within the YOLO v8m framework, a petal-aware convolution (PAC) module was introduced to optimize the C2f structure, thereby enhancing fine-grained feature extraction. The integration of MS - CAM and SAM modules strengthened multi-scale and spatial attention representation, while the DySample dynamic up-sampling method alleviated edge blurring. In addition, an illumination-adaptive weighted cross-entropy loss was designed to improve robustness under backlight conditions, and Linear Soft - NMS was adopted in post-processing to reduce missed detections of densely distributed targets. The model was trained and validated on Yongchun tangerine and Fuzhou mandarin datasets, with ablation, comparative, and generalization experiments conducted for comprehensive performance evaluation. The ablation results demonstrated that each module independently contributed to performance improvement, with the final model achieving 83.07% mAP@0.5, representing an 8.55 percentage points increase over the baseline. In comparative experiments, YOLO v8m - CFDNet outperformed SSD, YOLO v5m, YOLO v6, YOLO v9e, and YOLO v10m, achieving a detection speed of 91.94 f/s with only 28.39 million parameters. Generalization experiments further showed a 6.64 percentage points increase in mAP@0.5 and a 7.2

percentage points improvement in recall under backlight conditions on the Fuzhou mandarin dataset. Confusion matrix analysis indicated the highest recognition accuracy (86.91%) during the full-bloom stage. Overall, the proposed YOLO v8m - CFNet achieved a favorable balance among detection accuracy, real-time performance, and computational efficiency. It demonstrated strong robustness and generalization capability across citrus varieties and illumination conditions, providing an effective technical foundation for automated citrus flowering monitoring and intelligent orchard management.

**Key words:** citrus; flower recognition and counting; YOLO v8m; dense distribution

## 0 引言

柑橘(*Citrus reticulata* Blanco)作为我国南方重要经济作物,在农业生产体系中具有关键地位<sup>[1]</sup>。花期信息是表征柑橘生长状态的重要指标,准确识别花量与开花阶段,不仅有助于提升产量预测准确性,还可为疏花疏果、养分调控等精细化管理提供重要依据<sup>[2]</sup>。传统人工普查方式耗时低效,在大面积果园中难以满足精细化农业需求<sup>[3]</sup>;而传统图像处理方法对复杂光照、遮挡和多尺度目标的适应性不足,难以实现高精度识别<sup>[4]</sup>。

近年来,深度学习技术推动了花朵检测研究的快速发展,YOLO系列等轻量化检测模型已在苹果、猕猴桃、甘蔗等作物中取得良好应用表现,证明其在果园场景中的可行性<sup>[5-7]</sup>。然而,现有研究多聚焦于花朵稀疏分布或结构清晰的作物场景,对柑橘花期中普遍存在的“密集簇生、相互遮挡及形态相似”问题缺乏针对性研究。通过实验统计,当花朵密度超过约25朵/m<sup>2</sup>或遮挡率高于30%时,现有模型(如YOLO v5s、YOLO v8n等)在柑橘花期检测中的mAP@0.5普遍下降10%以上,漏检率超过15%,难以有效应对密集场景下的多目标识别挑战<sup>[3]</sup>。此外,现有模型在逆光或不均匀光照条件下的特征表达能力明显不足,导致特征边缘模糊、识别精度波动较大,暴露出当前算法在多尺度融合与光照鲁棒性方面的缺点。

针对柑橘花朵密集分布与复杂光照条件下的检测瓶颈,本文提出一种多模块协同优化的轻量化检测框架——YOLO v8m - CFNet。通过优化YOLO v8m特征提取网络、引入注意力机制及改进损失函数等措施,适应柑橘花朵检测的复杂场景需求<sup>[8]</sup>,以期对柑橘花期自动识别与智能监测提供解决方案。

## 1 材料与方法

### 1.1 图像采集与数据获取

本研究中的芦柑相关图像数据集采自福建省泉州市永春县猛虎柑橘产业基地,果园采用东西排列的栽培模式,全园实施统一的病虫害防治和修剪管

理。图像采集阶段涵盖芦柑花期的花苞期、开放期和凋落期,拍摄时间为每天的08:00—10:00、11:00—12:00、15:00—17:00,连续随机拍摄实验区内的芦柑花;在果园中随机选取90棵树,每个时期实地拍摄图像共400幅,拍摄实验数据为芦柑花的正面、侧面、遮挡等图像,以覆盖不同果树不同方位所包含的不同图像信息,增加数据集的丰富性;拍摄时距离芦柑果树1.5 m、离地高1 m,以仰拍45°以及俯拍45°的姿态进行;所使用的拍摄设备为DJI Mavic 3E型无人机,搭配4/3英寸CMOS 2000万像素哈苏镜头,图像分辨率为5 280像素×3 956像素。通过控制上述条件,本研究构建了一个信息丰富、代表性强的芦柑花图像数据集。

### 1.2 数据集密集性统计

本研究中“密集分布柑橘花期”特指单幅图像满足以下任一条件:花密度40朵/m<sup>2</sup>以上(永春基地开放期实地调研下限);遮挡率30%以上(采用检测框重叠近似遮挡,通过IoU大于等于0.3判定)。为验证数据集对“密集分布场景”的覆盖性,对5 908幅有效芦柑花图像的关键指标进行统计,结果显示:开放期图像的平均花密度为42.6朵/m<sup>2</sup>、遮挡率为41.8%,均显著高于花苞期与凋落期,整体数据集58.5%的图像为密集场景,其中23.7%的图像为“花密度40朵/m<sup>2</sup>以上,遮挡率30%以上”。数据统计采用Python OpenCV + LabelImg标注信息自动计算。

### 1.3 数据集制作

本研究从原始图像中筛选出包含目标的608幅图像,其中花苞期198幅、开放期232幅、凋落期178幅。为适应YOLO v8m网络模型的输入要求,将采集图像随机裁剪至1 280像素×1 280像素,不足部分则进行像素填充,填充颜色为RGB(128, 128, 128)。裁剪后,去除不包含芦柑花目标的子图像,整理得到5 908幅有效芦柑花图像,按比例7:2:1划分为训练集、测试集和验证集;接下来使用LabelImg工具对芦柑花图像进行标注,具体操作为:将每幅图像中存在的花朵区域根据所属形态标记相应的标签,示例如图1所示,其中绿色、红色和黄色分别表示花苞期、开放期和凋落期的标签。标注过程在熟

悉芦柑栽培管理的专家指导下完成,确保不同形态花朵区域识别的准确性,经统计花苞期标签占比 27.4%,开放期占比 35.8%,凋落期占比 36.8%。



图1 图像标注过程

Fig. 1 Image labeling process

## 2 密集分布柑橘花期检测方法

本文选用 YOLO v8m 作为基准模型,其在轻量化设计下兼顾检测速度与精度,满足花期识别的实时性与准确性需求。YOLO 算法以单一神经网络实现多目标检测,具备高效与实时的识别能力,为农作物的识别及表型分析提供技术基础<sup>[9]</sup>。YOLO v8m 的主干网络 (Backbone) 由卷积模块 (ConvModule)、跨阶段连接层 (CSPLayer\_2Conv) 及多尺度池化模块 (SPPF) 组成,用于多层次特征提取;Neck 部分采用 FPN + PAN 双路径结构实现多尺度特征融合,检测头 (Detect) 通过解耦分类与回归任务实现高效预测<sup>[10-11]</sup>。

然而,原始 YOLO v8m 在密集花朵检测中仍存在漏检与误检问题<sup>[12]</sup>。为此,本研究以芦柑花期检测为核心任务,提出改进模型 YOLO v8m - CFDNet,从多维度优化模型性能:采用花瓣感知卷积 PAC (Petal-aware convolution) 重构 C2f 模块,在保持轻量化特性的同时增强细粒度特征提取能力;引入 MS-CAM 与 SAM 模块,融合多尺度通道与空间特征信息,提高模型在重叠、遮挡场景下的目标判别精度<sup>[13-14]</sup>;采用 DySample 动态上采样替代传统插值方法,使采样策略可根据花朵边界自适应调整,改善边缘模糊问题<sup>[15]</sup>;引入光照权重对分类损失进行光照自适应加权,增强模型在逆光场景下的适配性;在后处理阶段采用 Linear Soft-NMS 算法,优化候选框筛选策略,降低密集目标的误删率。基于上述策略构建的 YOLO v8m - CFDNet 模型整体结构如图 2 所示,图中 MaxPool 为最大池化;Bbox. Loss 为边界框损失;Cls. Loss 为分类损失;BatchNorm2d 为二维批量归一化层;SiLU 为激活函数层。

### 2.1 改进 C2f

柑橘花瓣呈放射状对称结构(5片花瓣辐射分布,具细微锯齿纹理),其纹理由基部平滑向边缘逐渐密集,具有较强的局部缺失耐受性,即使局部遮挡仍可依靠中心放射结构识别<sup>[16]</sup>。基于此,本文提出 PAC 模块,通过 3 类卷积核实现花瓣生物学特征与卷积算子结构的对应映射:

(1)放射状卷积核:构建 5~6 路对称分支以模拟花瓣生长方向,提取径向纹理梯度。

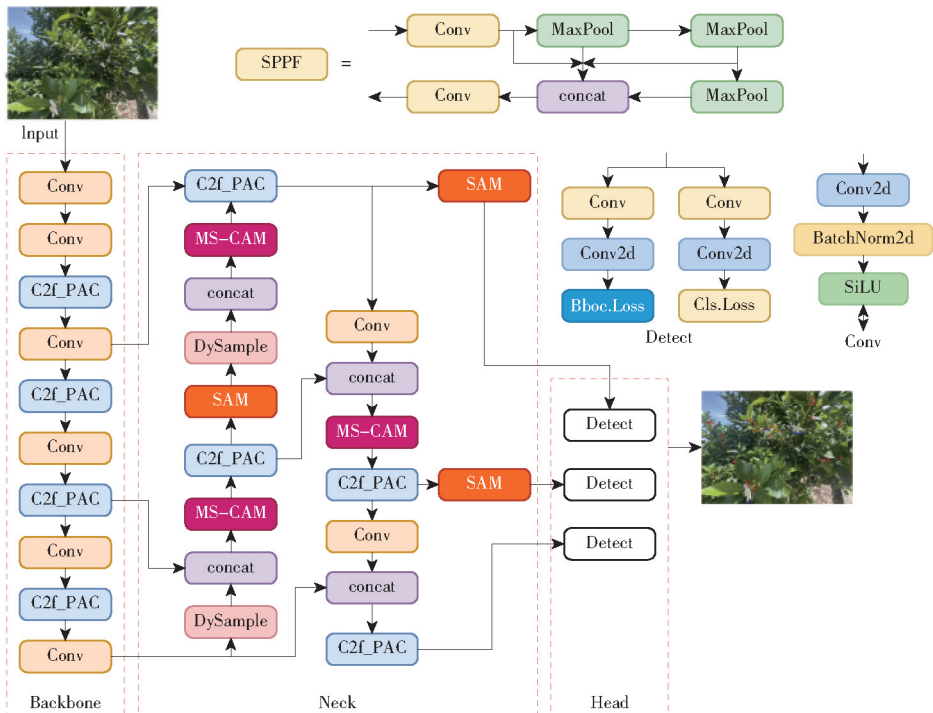


图2 YOLO v8m - CFDNet 网络结构图

Fig. 2 Network structure diagram of YOLO v8m - CFDNet

(2)方向感知卷积核:设定 $0^\circ$ 、 $45^\circ$ 、 $90^\circ$ 、 $135^\circ$ 权重卷积,捕捉锯齿状边缘的方向变化,减弱边缘模糊造成的特征丢失。

(3)全局特征卷积核:采用 $3 \times 3$ 大感受野卷积融合整体形态信息,弥补花瓣缺失区域的特征表达。

模块中引入ECA注意力机制,突出颜色与高频纹理等关键通道,抑制枝叶与阴影干扰,使特征聚焦于花瓣显著区域。PAC替代YOLO v8m中的BottleNeck模块形成C2f\_PAC结构。C2f\_PAC结构如图3所示,图中Split为特征分割单元;BottleNeck

为特征提取单元。多尺度PAC单元能在花密度 $35$ 朵/ $m^2$ 以上的场景中缓解特征混淆,显著提升检测精度。

### 2.2 尺度序列特征提取

YOLO v8m的特征融合依托FPN (Feature pyramid network)与PAN(Path aggregation network)结构实现,但在跨层特征交互中仍存在信息利用不足的问题,难以充分挖掘金字塔层间的相关性。面对密集重叠的小尺度花朵,网络易忽略大尺度层级中的细节特征,导致形态与分布表征不足。为此,本文引入MS-CAM (Multi-scale channel attention module)以增强通道与尺度特征建模能力<sup>[17]</sup>,结合SAM(Spatial attention module)<sup>[18]</sup>,协同提升特征融合与空间信息利用效果。其结构如图4所示。

在MS-CAM模块中,来自骨干网络的多层特征图经 $1 \times 1$ 、 $3 \times 3$ 、 $5 \times 5$ 不同尺度池化操作,分别捕获单花细节、小簇结构及整体花量信息。池化结果沿通道维度拼接后经 $1 \times 1$ 卷积融合压缩,并通过Sigmoid激活函数<sup>[19]</sup>生成动态通道权重,强化花朵特征、抑制背景噪声。权重图与原始特征逐通道相乘,经批量归一化与非线性激活进一步优化分布。

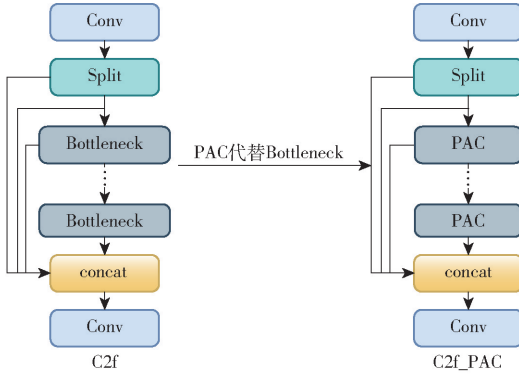


图3 主干网络C2f的改进

Fig. 3 Improvement of backbone network C2f

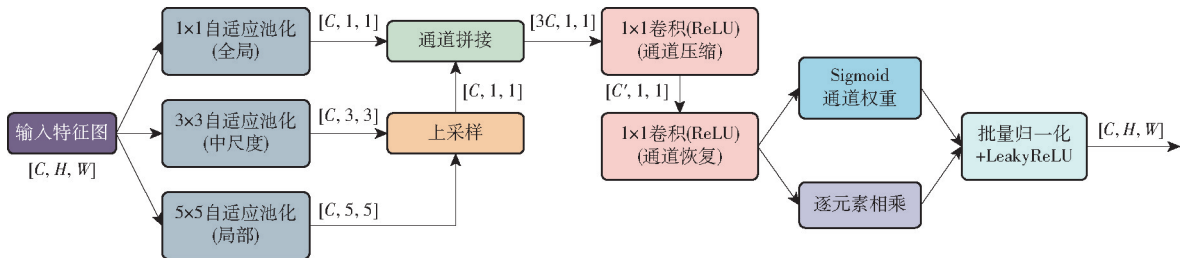


图4 MS-CAM尺度特征融合过程

Fig. 4 Scale feature fusion process of MS-CAM

该结构在保持轻量化的同时,有效提升了模型对多尺度与高密度花朵的表征能力。结合SAM模块后,模型在通道与空间两维度实现特征互补,显著增强了柑橘花量识别的鲁棒性与稳定性。

为应对复杂场景下目标特征易受背景干扰的问题,本文构建MS-CAM与SAM的双重注意力机制以协同强化特征表达,SAM结构如图5所示。其中,MS-CAM作为多尺度通道注意力模块,针对不同尺度特征图(小/中/大)自适应学习通道权重,抑制杂草、阴影等背景通道,突出花瓣颜色与花蕊纹理等显著特征,实现通道层级的特征筛选。经MS-CAM优化后的特征输入至SAM模块,后者在空间维度进一步聚焦目标区域。SAM通过对特征图执行最大池化与平均池化,提取显著响应与全局分布信息,再经 $1 \times 1$ 卷积融合并由Sigmoid激活生成归一化空间权重图,从而强化目标区域特征、削弱背景

干扰。双模块协同作用使模型在通道与空间维度实现互补优化,显著提升特征判别力及在复杂光照与遮挡条件下的鲁棒性。




图5 SAM结构示意图

Fig. 5 Schematic of SAM structure

MS-CAM针对不同尺度的花朵特征,分别学习独立通道权重——既能过滤杂草纹理、枝叶阴影等背景主导的干扰通道,又能保留花苞局部纹理、花瓣颜色等与花朵强相关的有效通道,从特征源头减少无关信息干扰;在此基础上,SAM进一步解决“有效

通道内仍混有背景”的问题(例如粉色花瓣通道中可能存在的粉色杂草、光斑反光),通过空间权重分配强化花苞轮廓、花蕊细节等关键空间位置的特征,同时弱化通道内的枝叶、杂草区域。

### 2.3 DySample 上采样器

上采样操作增强模型对多尺度目标的识别能力、促进特征层间信息融合,并保持空间位置信息精度,是连接高低层特征、提升检测性能的重要环节<sup>[20]</sup>。然而,传统最近邻插值采用固定网格采样,难以适应目标形态多样性,常造成柑橘花瓣边缘阶梯状模糊。由于花朵在不同发育阶段呈现圆形、放射状或卷曲状特征,固定采样策略难以准确捕获其结构差异。

为此,本文引入 DySample 动态上采样方法<sup>[21]</sup>,可根据输入特征自适应调整采样点位置,实现对不同花期形态的灵活建模。其核心采样点生成器的结构如图6所示。图中  $G$  表示原始采样网格; $O$  表示偏移量; $S$  表示采样集; $\sigma$  表示 Sigmoid 函数; $2gs^2$  表示特征图通过线性层后的通道数。通过偏移量  $O$  动态确定采样位置,在花瓣边缘区域增加采样密度,并以邻域加权融合平滑边缘过渡、降低模糊失真。DySample 根据目标形态自适应调整采样策略:通过  $1 \times 1$  卷积压缩通道维度后,利用  $3 \times 3$  卷积捕捉花瓣轮廓的径向对称性与边缘完整性,生成 2 个关键特征指标(对称度、边缘完整度)。当对称度高且边缘完整时,判定为开放期,采样核向边缘区域偏移以增加边缘采样密度;当对称度低且边缘紧凑时,判定为花苞期,采样核聚焦中心区域;当边缘完整度低且对称度中等时,判定为凋落期,采样核仅对未残缺的局部区域密集采样。该方法较双线性插值仅增加约  $8.0 \times 10^4$  个参数,对计算量影响极小。

静态采样中特征图  $x$  首先通过 1 个输入和输出通道分别为  $C$  和  $2gs^2$  的线性层,接着乘以大小为 0.25 的静态范围因子,然后进行像素重组得到大小为  $(2g) \times (sH) \times (sW)$  的偏移量  $O$ 。最后,采样集  $S$  为偏移量  $O$  和原始采样网格  $G$  的总和,过程为

$$S = G + O \quad (1)$$

$$\text{其中 } O = 0.25 \text{Linear}(x) \quad (2)$$

式中 Linear 表示线性层。

动态范围因子方法则使用两个线性层,一个线性层执行标准线性操作,另一个线性层后使用  $0.5 \text{Sigmoid}$  函数,将二者结果相乘来调整偏移,过程为

$$O = 0.5 \text{Sigmoid}(\text{Linear1}(x)) \text{Linear2}(x) \quad (3)$$

### 2.4 改进损失函数

逆光/低对比度条件下,花瓣与背景(如阴影下

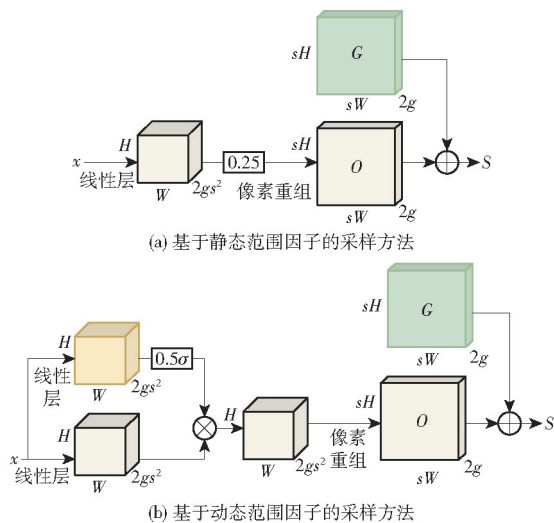


图6 采样点生成器

Fig. 6 Sampling point generator

的枝叶、强光反射区域)的视觉差异被削弱,导致模型对花朵类别的分类置信度降低,易出现“将花苞误判为阴影”“将凋落期花朵误判为枯叶”等问题。传统交叉熵损失对所有样本赋予相同权重,逆光/低对比度样本因特征不显著,在训练中易被正常光样本的梯度覆盖,模型难以针对性优化。

据此引入光照因子,对逆光/低对比度样本赋予更高损失权重,强制模型聚焦这类难样本的分类误差,为明确逆光场景的亮度量化标准,从永春芦柑与福州福橘数据集中筛选典型逆光图像(共 326 幅,涵盖晨夕逆光、树荫逆光等场景),计算每幅图像的亮度均值  $B$ 。统计发现,这些逆光图像的亮度均值集中分布于 35 ~ 55 之间,其中亮度均值等于或接近 50 的图像占比达 68.7%,基于此实测分布特征,确定  $B = 50$  作为逆光与正常光场景的区分界线。对 326 幅逆光图像测试不同权重性能:权重 1.0 时逆光优化不足,权重 3.0 时虽逆光召回率略高,但正常光样本因过度加权出现过拟合;仅权重 2.0 能兼顾显著的逆光优化效果与正常光性能稳定,故确定逆光场景( $B < 50$ )权重为 2.0,正常光场景( $B \geq 50$ )权重为 1.0。

定义光照权重  $w_i$ ,通过灰度转化计算单幅图像的亮度均值,对逆光样本赋予 2.0 倍权重,强制模型对这类难样本的分类误差更敏感。将光照权重  $w_i$  作为系数,与原损失中“第  $i$  个锚框的分类损失项”相乘,实现对难样本的加权,公式为

$$L_{\text{cls}}^{\text{light\_mid}} = - \sum_{i=1}^N \left( w_i \sum_{c=1}^{C'} y_{i,c} \lg(P_{i,c}) \right) \quad (4)$$

式中  $y_{i,c}$ ——真实类别标签

$C'$ ——类别总数

$N$ ——参与计算的锚框总数

$p_{i,c}$ ——模型的预测概率

整合优化过程,最终得到针对逆光场景的光照自适应加权交叉熵损失 $L_{cls}^{origin}$ 公式

$$L_{cls}^{origin} = - \sum_{i=1}^N w_i \sum_{c=1}^{C'} y_{i,c} \lg(p_{i,c}) \quad (5)$$

当锚框属于逆光样本时, $w_i = 2.0$ ,其分类损失被放大2倍,模型训练时会优先优化这类样本的分类误差。

## 2.5 Linear Soft - NMS

传统NMS通过删除高重叠度候选框实现冗余抑制,但在柑橘花朵密集分布场景下,检测框间的IoU<sup>[22]</sup>普遍偏高,易将真实花朵对应的候选框误删,造成检测遗漏<sup>[23]</sup>。为解决该问题,本文引入Linear Soft - NMS<sup>[24]</sup>算法对检测结果进行后处理。该算法通过置信度线性衰减机制替代传统的硬性删除操作,从而在保持检测准确率的同时减少漏检。其主要流程如下:首先,将所有候选框按置信度得分由高到低排序,选取得分最高的预测框作为基准框;随后计算其余候选框与基准框的IoU值,对于重叠度超过设定阈值的候选框,依据线性函数衰减其置信度得分。衰减后的候选框若仍高于置信度阈值,则予以保留,其置信度调整过程可表示为

$$s_i = s_i(1 - \text{IoU}(M, b_i)) \quad (6)$$

式中  $s_i$ ——候选框的初始置信度得分

IoU——当前候选框与基准框的交并比

$M$ ——置信度最高的当前基准框

$b_i$ ——待调整置信度的候选框

通过这种基于重叠度的线性衰减机制,候选框置信度可根据其与基准框的重叠程度实现动态适配调整,能更精准地保留密集分布花朵场景中的真实目标候选框,有效提升密集花朵检测的准确性,在遮挡率40%以上的密集场景中,漏检率较传统NMS有所降低。

## 3 结果与分析

### 3.1 模型训练与评价指标

#### 3.1.1 训练平台及训练参数

本实验平台采用DELL Precision T7960工作站Ubuntu 20.04.3 LTS作为操作系统,CPU和GPU分别为Intel(R) Xeon(R) Gold 5318 Y CPU @ 2.10 GHz和NVIDIA RTX4090(24 GB) × 2,使用Python 3.12.6编程语言、Cuda 12.6运算架构和Pytorch 2.5.1深度学习框架训练模型。实验模型训练参数设置如下:迭代次数为300,学习率设为0.01,动量因子为0.937,批量大小为16,IoU阈值为0.5。模型训练过程中,加入图像平移与缩放、图像色彩增

强、mosaic数据增强、随机擦除等多种数据增强方法,增强数据多样性,以此提升模型的鲁棒性。

#### 3.1.2 模型评价指标

本文在试验过程中采用精确率(Precision,  $P$ )、召回率(Recall,  $R$ )、平均精度均值(Mean average precision, mAP@0.5)、参数量(Parameters)、浮点运算量(Floating point of operations, FLOPs)和检测速度对模型进行全面、有效的评价。

#### 3.1.3 模型训练

对模型进行训练,训练过程中损失值变化曲线如图7所示。由图可知,随着训练轮数的不断增加,总损失值及各分项损失值均逐渐减小,且训练集与验证集损失曲线趋势一致,未出现过拟合、欠拟合现象。在训练230个轮次后,验证集上损失值趋于收敛,模型训练表现良好,可正常进行结果分析。




图7 YOLO v8m - CFDNet 损失函数变化曲线

Fig. 7 Loss function variation curves of YOLO v8m - CFDNet

### 3.2 消融实验

为了验证模型各模块对最终性能的贡献,本文设计并进行消融实验。以YOLO v8m为基准,通过逐步添加或改进模型中的关键模块,分析它们对各个性能指标的影响,从而评估模型的有效性。实验结果如表1所示。

在单模块实验中,Linear Soft - NMS后处理使精确率、召回率和mAP@0.5分别提升0.84、0.45、0.59个百分点,验证其在密集花朵检测中的有效

表1 消融实验结果

Tab.1 Ablation experiments results

Linear Soft - NMS	C2f - PAC	MS - CAM + SAM	DySample	光照加权 损失函数	P/%	R/%	mAP@0.5/ %	浮点运算量	参数量
-	-	-	-	-	78.21	72.43	74.52	$2.591 \times 10^{10}$	$2.603 \times 10^7$
√	-	-	-	-	79.05	72.88	75.11	$2.591 \times 10^{10}$	$2.603 \times 10^7$
-	√	-	-	-	79.66	73.91	76.24	$2.518 \times 10^{10}$	$2.536 \times 10^7$
-	-	√	-	-	80.14	75.17	77.09	$2.683 \times 10^{10}$	$2.705 \times 10^7$
-	-	-	√	-	79.88	74.82	76.79	$2.631 \times 10^{10}$	$2.618 \times 10^7$
√	√	√	-	-	80.50	75.10	77.32	$2.636 \times 10^{10}$	$2.642 \times 10^7$
√	√	-	√	-	80.22	75.62	77.25	$2.690 \times 10^{10}$	$2.707 \times 10^7$
-	√	√	√	-	80.01	74.92	77.21	$2.629 \times 10^{10}$	$2.617 \times 10^7$
-	-	-	-	√	78.43	72.88	74.98	$2.591 \times 10^{10}$	$2.603 \times 10^7$
√	√	√	√	-	82.88	78.34	82.34	$2.764 \times 10^{10}$	$2.839 \times 10^7$
√	√	√	√	√	82.91	78.36	83.07	$2.764 \times 10^{10}$	$2.839 \times 10^7$

注：“-”表示不采用该模块；“√”表示采用该模块。

性。PAC 模块将 mAP@0.5 从 74.52% 提升至 76.24%，增强了花瓣细粒度特征提取；MS - CAM + SAM 模块使召回率提升至 75.17%，改善了复杂背景下的目标判别；DySample 模块将 mAP@0.5 提升至 76.79%，优化了边缘模糊区域检测；光照自适应加权交叉熵使损失函数在基线模型上提升 0.46 个百分点，mAP@0.5 在 CFDNet 上进一步提升 0.73 个百分点，增强了逆光场景的检测鲁棒性。

在多模块组合实验中，多模块叠加后模型精度提升幅度趋于平缓，这一现象主要由特征增强的冗余效应引起。PAC 模块侧重于局部纹理与边缘特征提取，而 MS - CAM + SAM 模块强化了全局尺度与空间注意力特征，两者在特征层面存在部分重叠。当多个模块同时启用时，网络的特征增强效果趋于饱和，导致整体性能提升幅度相对减缓。该结果符合深度检测模型中“注意力模块叠加增益递减”的规律，表明各模块已在不同层级充分提取特征信息，

模型整体处于较优平衡状态。性能持续提升，最终 YOLO v8m - CFDNet 模型的 mAP@0.5 达到 83.07%，较基准模型提升 8.55 个百分点；召回率 78.36%，精确率 82.91%，在浮点运算量仅增加约 6.7% 的情况下实现了性能与效率的最优平衡。总体而言，各模块在局部特征提取、目标定位、边缘建模及光照适应性方面形成互补，协同优化显著优于单一模块，验证了结构设计的合理性与必要性。

### 3.3 对比实验

为了进一步验证 YOLO v8m - CFDNet 模型在芦柑花期检测任务中的性能，选取经典目标检测模型 SSD、YOLO v5m<sup>[25]</sup>、YOLO v6<sup>[26]</sup>，以及先进目标检测模型 YOLO v8m<sup>[27]</sup>、YOLO v9e<sup>[28]</sup>、YOLO v10m<sup>[29]</sup> 进行对比，为确保公平性，所有模型均在统一输入分辨率 1280 像素 × 1280 像素和数据集采用相同的训练方式进行训练和测试，结果如表 2 所示。

表2 对比实验结果

Tab.2 Comparative experiments results

模型	P/%	R/%	mAP@0.5/%	浮点运算量	参数量	检测速度/(f·s <sup>-1</sup> )
SSD	68.47	64.23	70.35	$3.147 \times 10^{10}$	$2.406 \times 10^7$	139.82
YOLO v5m	76.13	71.84	76.52	$4.903 \times 10^{10}$	$2.092 \times 10^7$	110.29
YOLO v6	74.82	70.51	75.19	$4.421 \times 10^{10}$	$1.854 \times 10^7$	119.64
YOLO v8m	78.21	72.43	74.52	$2.591 \times 10^{10}$	$2.603 \times 10^7$	105.32
YOLO v9e	77.34	71.92	76.18	$1.061 \times 10^{11}$	$5.771 \times 10^7$	85.43
YOLO v10m	76.52	71.12	75.06	$2.514 \times 10^{10}$	$5.473 \times 10^7$	89.76
YOLO v8m - CFDNet	82.91	78.36	83.07	$2.764 \times 10^{10}$	$2.839 \times 10^7$	91.94

由表 2 可知，YOLO v8m - CFDNet 模型的精确率、召回率和平均精度均值分别为 82.91%、78.36% 和 83.07%，在所有对比模型中均为最高。与 SSD、YOLO v5m、YOLO v6、YOLO v9e 和 YOLO

v10m 相比，YOLO v8m - CFDNet 的平均精度均值分别提高了 12.72、6.55、7.88、6.89、8.01 个百分点。此外，YOLO v8m - CFDNet 的浮点运算量和参数量分别为  $2.764 \times 10^{10}$  和  $2.839 \times 10^7$ ，相较 YOLO v9e

和YOLO v10m,参数量分别降低了50.8%和48.1%。在检测速度方面,YOLO v8m - CFDNet达到91.94 f/s,相较YOLO v9e和YOLO v10m分别提升了7.6%和2.4%。相较YOLO v8m,YOLO v8m - CFDNet参数增加9.1%,检测速度下降至91.94 f/s,主要由于DySample及多注意力模块的卷积操作增加了计算量,但相对带来8.55个百分点的mAP@0.5提升,实现了精度与速度的合理平衡。综合来看,YOLO v8m - CFDNet在保证较低计算复杂度和适中参数量的同时,实现了精度与实时性的显著提升,较好地平衡了检测性能、复杂度与部署效率,能够满足柑橘花期检测在实际应用中的高精度与高效率需求。

为了验证YOLO v8m - CFDNet模型在其他品种柑橘花期检测任务上的性能,从采集的福州福橘的原始图像中筛选出300幅,制作福州福橘品种柑橘花期图像数据集进行泛化实验,所有对比模型采用表1的相同超参数与数据增强,结果如表3所示。

表3 泛化实验结果

Tab.3 Generalization experiments results %

模型	P	R	mAP@0.5	小目标	逆光场景
				平均精度	召回率
YOLO v8m	76.12	70.84	71.18	58.40	67.10
YOLO v9e	77.56	72.33	74.26	61.20	69.00
YOLO v10m	75.44	71.08	73.15	60.10	68.20
YOLO v8m - CFDNet	81.03	75.26	77.82	66.85	74.30

由表3可知,4种模型在福州福橘数据集上的表现存在明显差异。YOLO v8m - CFDNet模型在精确率、召回率和平均精度均值上分别达到81.03%、75.26%和77.82%,在4种模型中均为最高。与YOLO v8m相比,精确率、召回率和平均精度均值分别提高了4.91、4.42、6.64个百分点;与YOLO v9e和YOLO v10m相比,平均精度均值分别提升了3.56、4.67个百分点。在小目标检测方面,YOLO v8m - CFDNet的小目标平均精度达到66.85%,相比YOLO v8m(58.40%)提升了8.45个百分点,也高于YOLO v9e(61.20%)和YOLO v10m(60.10%)。这说明改进结构中的C2f - PAC与DySample模块有效增强了模型对小尺度柑橘花的特征表达与定位能力。在逆光场景召回率方面,YOLO v8m - CFDNet达到74.30%,较YOLO v8m提升7.20个百分点,也分别高于YOLO v9e(69.00%)与YOLO v10m(68.20%)。这得益于光照自适应加权损失函数对低照度与背光区域的特征权重动态调整能力,使模型在逆光条件下保持了更稳定的检测

性能。

综合来看,YOLO v8m - CFDNet在精度、小目标检测能力和逆光鲁棒性方面均优于其他对比模型,表明所提出方法在存在显著域偏移的福州福橘数据集上具有较强的泛化能力,为跨品种花期智能检测提供了有效的技术支撑,但由于福州福橘数据集规模较小(仅300幅图像),且拍摄季节和光照条件相对单一,模型的泛化能力尚未在更大规模、多拍摄设备条件下得到充分验证。而且凋落期花朵目标尺寸偏小、颜色与背景相近,其在小样本泛化测试中的检测精度依然较低,在复杂背景下仍存在漏检与误检现象。其次,本研究的泛化实验仅在单一站点和单一品种上进行,尚未涵盖不同区域、品种及采集时间。但模型针对逆光等复杂光照场景的损失函数优化具有普适性原理,从理论层面为其在更广泛柑橘品种及场景下的泛化能力提供了机制保障。后续研究需在多区域、多年份柑橘花期数据集上进一步验证,更全面地评估模型在复杂实际场景中的泛化性能。

### 3.4 密集分布花朵检测效果分析

为了更加直观地验证改进效果,本文对密集分布芦柑花朵的检测效果进行分析,图8展示了YOLO v8m和YOLO v8m - CFDNet在不同场景下的检测框和预测结果,黄圈内是漏检或误检的花朵。

由图8可知,在花苞遮挡花朵方面,对于被1个花苞期花朵遮挡住的开放期花朵,YOLO v8m出现漏检花苞期的现象,而YOLO v8m - CFDNet正确检测;在花朵相互遮挡方面,YOLO v8m - CFDNet相比YOLO v8m多检测出1个开放期花朵;在树叶遮挡花朵方面,对于被树叶遮挡的开花期花朵,YOLO v8m有4朵被树叶遮挡的开放期花朵未能正确检测出,而YOLO v8m - CFDNet均能正确检测;逆光场景下,多处低对比度花朵在YOLO v8m - CFDNet下呈现更好检测效果。因此,YOLO v8m - CFDNet在多种密集分布场景下相较于YOLO v8m减少了误检和漏检的情况,表现出更加全面的检测性能。

### 3.5 不同花期检测效果分析

处于不同花期的芦柑花会受到颜色、形态等因素特征相似的影响,出现误检现象。本文对不同花期花朵的检测效果进行分析,图9展示了YOLO v8m和YOLO v8m - CFDNet对不同花期花朵的检测框和预测结果。由图9可知,在混淆开放期和花苞方面,部分花朵受开放角度影响,难以完整呈现花瓣开放幅度,导致YOLO v8m将1朵开放期花朵误检为花苞期,而YOLO v8m - CFDNet能正确检测。在混淆凋落期和开花期方面,YOLO v8m将1朵开放

花朵误检为两个凋落期,而 YOLO v8m - CFDNet 正确检测。在混淆光影和花苞期方面, YOLO v8m 将拍照时的 5 个光影误检为花苞期花朵,而 YOLO v8m - CFDNet 只将其中一个光影检测为花苞期花朵, YOLO v8m - CFDNet 展现出更强的花期判别能力。




图 8 改进前后密集分布花朵检测效果

Fig. 8 Detection performance for densely distributed flowers before and after improvement

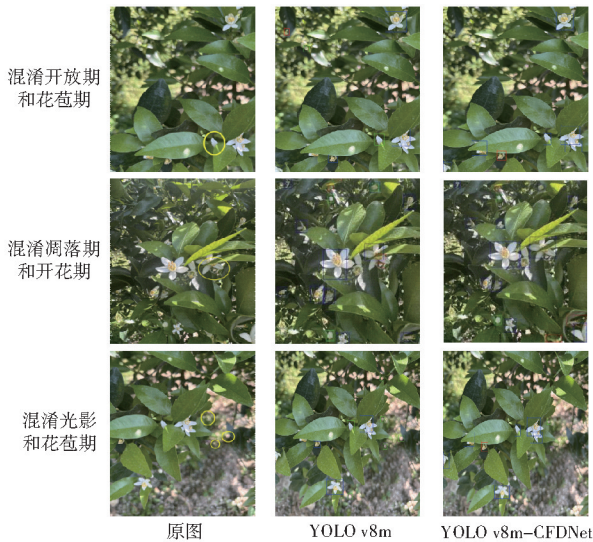


图 9 改进前后不同花期检测效果

Fig. 9 Detection performance for different flowering periods before and after improvement

### 3.6 不同花期误检分析

为了验证花期误检的具体分布,分析花期混淆情况,采用 YOLO v8m - CFDNet 的归一化混淆矩阵

进行评估。如图 10 所示,矩阵中的数值表示属于横坐标对应类别的所有真实样本中,有多少比例被预测为纵坐标对应类别,矩阵从左上到右下的对角线上的数值,为对应类别真实样本中正确预测的比例,即召回率。

YOLO v8m - CFDNet 模型在芦柑花苞期、开放期、凋落期以及背景的检测任务中表现出了较高的准确性。从图 10 中可以看出,开放期的检测准确率最高,达到 86.91%,因为柑橘花在不同花期的形态与纹理特征差异。开放期花朵花瓣完全展开,呈放射状结构,纹理清晰、颜色亮度高且与背景反差明显,易于模型在特征空间形成稳定的类间边界;同时该阶段样本占比较高(35.8%),使模型在训练过程中获得更多代表性特征,以及改进的特征提取与注意力机制对花瓣完全展开、结构清晰的花朵具有较强的识别能力。花苞期的检测准确率为 78.65%,主要的误判来源是与开放期的混淆(12.34%),这是由于在花苞期花朵体积较小、纹理细节尚未显著,强光条件下,花苞期与开放期在纹理和边缘特征上存在相似性,部分样本被错误分类。凋落期的检测准确率最低,仅为 71.33%,主要与背景(10.69%)和花苞期(9.56%)混淆。这一结果是源于凋落期花朵在视觉特征上的弱化:其花瓣颜色逐渐接近枝叶背景,纹理对比度下降,且形态不规则、卷曲严重,导致特征空间聚类分布模糊,模型难以形成稳定的分类边界。此外,凋落花常部分脱落或被遮挡,仅保留残瓣区域,使检测框的目标置信度显著下降。同时该阶段样本占比最高(36.8%)。由此可见,检测偏差主要来自特征可分性弱化。




图 10 不同花期混淆矩阵

Fig. 10 Confusion matrix for different flowering periods

总体来看,改进模型在形态清晰、特征明显的开放期上表现最好;而在视觉特征不明显或低对比度的凋落期识别仍存在一定不足。未来可通过增强低对比度特征的表达能力、针对凋落期类别进行特征

细化与针对性增强训练,以进一步降低混淆率、提升整体检测精度。

## 4 结论

(1)针对自然环境中不同花期的柑橘花朵形态多样、花朵之间存在相互遮挡的问题,本研究基于YOLO v8m模型进行改进,在Backbone与Neck结构上,引入C2f-PAC以增强小目标的边缘特征提取,引入MS-CAM+SAM改善多尺度注意力表达,并通过DySample提升上采样精度;后处理阶段采用Linear Soft-NMS减少重叠目标的误删;训练阶段引入光照自适应加权损失函数,增强模型在逆光与低对比度条件下的鲁棒性。

(2)YOLO v8m-CFDNet模型在永春芦柑数据集上的精确率、召回率与mAP@0.5较YOLO v8m分别提升4.70、5.93、8.55个百分点,检测速度达91.94 f/s,相较YOLO v8m,在保持轻量化的同时显著提升了检测性能。

(3)在福州福橘数据集上的泛化实验结果表明,YOLO v8m-CFDNet相较YOLO v8m、YOLO v9e、YOLO v10m,在mAP@0.5、小目标平均精度与逆光场景召回率上分别提升3.56~6.64、5.65~8.45、5.30~7.20个百分点,在小样本与显著域偏移条件下仍保持较高检测精度与鲁棒性,证明模型在不同品种(芦柑与福橘)数据集上表现出较好的适应性,初步显示了跨品种检测的泛化潜力,但仍需在更大规模多区域数据集上进一步验证。

(4)基于改进模型的混淆矩阵分析显示,开放期花朵检测准确率最高(86.91%),说明模型对主要花期类别具备良好的区分能力;凋落期检测相对较弱(71.33%),易与背景混淆,是后续改进的重点方向。

(5)本研究的检测结果可为果园花量统计与产量预测提供技术支撑。通过统计检测框数量可估算单株花量分布,为后续疏花疏果与精准施肥决策提供依据。

## 参 考 文 献

- [1] 李子茂,李嘉晖,尹帆,等.基于可形变卷积与SimAM注意力的密集柑橘检测算法[J].中国农机化学报,2023,44(2):156-162.  
LI Zimao, LI Jiahui, YIN Fan, et al. Dense citrus detection algorithm based on deformable convolution and SimAM attention [J]. Journal of Chinese Agricultural Mechanization, 2023,44(2):156-162. (in Chinese)
- [2] 任晶秋,万恩晗,单蜜,等.基于改进YOLO v8n网络的番茄成熟度实时检测算法[J].农业机械学报,2025,56(3):374-382.  
REN Jingqiu, WAN Enhuan, SHAN Mi, et al. Real-time detection algorithm for tomato ripeness based on improved YOLO v8n network [J]. Transactions of the Chinese Society for Agricultural Machinery, 2025,56(3):374-382. (in Chinese)
- [3] 邓颖,吴华瑞,朱华吉.基于实例分割的柑橘花朵识别及花量统计[J].农业工程学报,2020,36(7):200-207.  
DENG Ying, WU Huarui, ZHU Huaji. Citrus flower recognition and bloom counting based on instance segmentation [J]. Transactions of the CSAE, 2020,36(7):200-207. (in Chinese)
- [4] 贾惠,伍希志,薛洋,等.基于迁移学习和数据增强的小样本柑橘缺陷检测研究[J].农业与技术,2024,44(2):23-27.
- [5] ZHANG Song, YANG Yehua, TU Lei, et al. Comparison of YOLO-based sorghum spike identification detection models and monitoring at the flowering stage [J]. Plant Methods, 2025,21(1):20.
- [6] 尚钰莹,张倩如,宋怀波.基于YOLOv5s的深度学习在自然场景苹果花朵检测中的应用[J].农业工程学报,2022,38(9):222-229.  
SHANG Yuying, ZHANG Qianru, SONG Huaibo. Application of deep learning based on YOLOv5s in apple flower detection under natural scenes [J]. Transactions of the CSAE, 2022,38(9):222-229. (in Chinese)
- [7] 梁斯佳,李雷,顾月,等.基于改进YOLO v8n的甘蔗叶片病害识别算法[J].农业机械学报,2025,56(10):567-574.  
LIANG Sijia, LI Lei, GU Yue, et al. Disease recognition algorithm for sugarcane leaves based on improved YOLO v8n [J]. Transactions of the Chinese Society for Agricultural Machinery, 2025,56(10):567-574. (in Chinese)
- [8] 刘东旭,刘晓群,刘秉强. SE-YOLO:一种基于YOLOv8改进的密集缺陷检测算法[J].无线互联科技,2024,21(6):107-111,115.  
LIU Dongxu, LIU Xiaoqun, LIU Bingqiang. SE-YOLO:an improved dense defect detection algorithm based on YOLOv8 [J]. Wireless Internet Science and Technology, 2024,21(6):107-111,115. (in Chinese)
- [9] 董甲东,桑飞虎,郭庆虎,等.基于深度学习的目标检测算法轻量化研究综述[J].计算机科学与探索,2025,19(8):2057-2084.  
DONG Jiadong, SANG Feihu, GUO Qinghu, et al. Review of lightweight object detection algorithms based on deep learning [J]. Journal of Frontiers of Computer Science & Technology, 2025,19(8):2057-2084. (in Chinese)
- [10] 吕宗旺,王甜甜,孙福艳,等.基于改进YOLOv8m的小麦仓储粮虫检测方法[J].中国农机化学报,2025,46(3):108-114.  
LÜ Zongwang, WANG Tiantian, SUN Fuyan, et al. Improved YOLOv8m-based grain insect detection method for wheat storage [J]. Journal of Chinese Agricultural Mechanization, 2025,46(3):108-114. (in Chinese)

- [11] 白凯, 张玉杰, 苏邓文, 等. 基于改进 YOLO v8n 的花生叶片病害检测方法[J]. 农业机械学报, 2025,56(6):518-526.  
BAI Kai, ZHANG Yujie, SU Dengwen, et al. Peanut leaf disease detection method based on improved YOLO v8n[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025,56(6):518-526. (in Chinese)
- [12] 任龙龙, 杜永辉, 李玉强, 等. 基于 CEG-YOLO 的轻量化设施环境樱花检测[J]. 农业机械学报, 2025,56(9):648-656.  
REN Longlong, DU Yonghui, LI Yuqiang, et al. Lightweight cherry blossom detection method in protected environments based on CEG-YOLO[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025,56(9):648-656. (in Chinese)
- [13] HUANG Qian, SUN Huashan, WANG Yiming, et al. Ship detection based on YOLO algorithm for visible images[J]. IET Image Processing, 2024,18(2):481-492.
- [14] KARAMAN A, PACAL I, BASTURK A, et al. Robust real-time polyp detection system design based on YOLO algorithms by optimizing activation functions and hyper-parameters with artificial bee colony (ABC)[J]. Expert Systems with Applications, 2023,221:119741.
- [15] GUI Chong, XU Xubo, TAO Liang, et al. Deep learning-based lightweight road disease detection approach[C]//2025 5th International Conference on Artificial Intelligence and Industrial Technology Applications (AIITA), 2025:1953-1957.
- [16] MARQUES J, AMORIM L, SPÓSITO M, et al. Ultrastructural changes in the epidermis of petals of the sweet orange infected by *Colletotrichum acutatum*[J]. Protoplasma, 2016,253(5):1233-1242.
- [17] KANG M, TING C M, TING F F, et al. ASF-YOLO: a novel YOLO model with attentional scale sequence fusion for cell instance segmentation[J]. Image and Vision Computing, 2024,147:105057.
- [18] 江金辉. 联合 SAM 与 VGG16 的树上柑橘检测方法[J]. 河北农机, 2024(1):19-21.
- [19] 胡朝海, 李自胜, 王露明. Attention-Like YOLO:嵌入类注意力机制的 YOLO 算法[J]. 计算机与数字工程, 2023,51(9):1973-1978.  
HU Chaohai, LI Zisheng, WANG Luming. Attention-Like YOLO: YOLO detection algorithm that embeds attention-like mechanism[J]. Computer and Digital Engineering, 2023,51(9):1973-1978. (in Chinese)
- [20] 范天浩, 顾寄南, 王文波, 等. 基于改进 YOLOv5s 的轻量化金银花识别方法[J]. 农业工程学报, 2023,39(11):192-200.  
FAN Tianhao, GU Ji'nan, WANG Wenbo, et al. Lightweight recognition method of honeysuckle based on improved YOLOv5s [J]. Transactions of the CSAE, 2023,39(11):192-200. (in Chinese)
- [21] LIU Wenze, LU Hao, FU Hongtao, et al. Learning to upsample by learning to sample[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV), 2023:6027-6037.
- [22] 齐向明, 严萍萍, 姜亮. 基于 YOLOv8n 的航拍图像小目标检测算法[J]. 计算机工程与应用, 2024,60(24):200-210.  
QI Xiangming, YAN Pingping, JIANG Liang. Small target detection algorithm for aerial images based on YOLOv8n[J]. Computer Engineering and Applications, 2024,60(24):200-210. (in Chinese)
- [23] 张长伦, 张翠文, 王恒友, 等. 基于注意力机制的 NMS 在目标检测中的研究[J]. 电子测量技术, 2021,44(19):82-88.  
ZHANG Changlun, ZHANG Cuiwen, WANG Hengyou, et al. Research on non-maximum suppression based on attention mechanism in object detection[J]. Electronic Measurement Technology, 2021,44(19):82-88. (in Chinese)
- [24] 赵云龙, 田生祥, 李岩, 等. 基于注意力模型和 Soft-NMS 的输电线路小目标检测方法[J]. 电子科技大学学报, 2023,52(6):906-914.  
ZHAO Yunlong, TIAN Shengxiang, LI Yan, et al. Attention model and Soft-NMS-based transmission line small target detection method[J]. Journal of University of Electronic Science and Technology of China, 2023,52(6):906-914. (in Chinese)
- [25] ZHU N, GE Q, WANG H, et al. Real-time traffic sign detection based on YOLO v5-MGC[J]. Laser & Optoelectronics Progress, 2024,61(12):1228008.
- [26] LI Chuyi, ZHANG Bo, LI Lulu, et al. YOLOV6: a single-stage object detection framework for industrial applications[C]//ICLR 2024 Conference, 2024.
- [27] WANG K, ZHOU C, MA Y, et al. Cotter pin detection of transmission line based on YOLOv8-DEA[J]. Laser & Optoelectronics Progress, 2025,62:364-374.
- [28] WANG C Y, YE H I H, MARK LIAO H Y. YOLOv9: learning what you want to learn using programmable gradient information [C]//European Conference on Computer Vision. Cham: Springer Nature Switzerland, 2024:1-21.
- [29] WANG Ao, CHEN Hui, LIU Lihao, et al. YOLOv10: real-time end-to-end object detection[C]//NeurIPS 2024, 2024.