文章编号:1671-4598(2025)06-0185-08 DOI:10.16526/j.cnki.11-4762/tp.2025.06.023 中图分类号:TP391.41 文献标识码:A

基于改进轻量化 YOLOv5s 的万寿菊识别方法

李 欣,徐 博,张 雷,于 浩,贾英新,刘子剑

(河北省机电一体化中试基地有限公司,石家庄 050081)

摘要:针对传统识别网络结构冗余且普适性低,导致推理过程复杂、效能低下,难以满足密集生长的万寿菊检测需求的问题,提出了一种改进的轻量化 YOLOv5s 万寿菊识别方法,并通过适宜的数据集增强技术为识别方法提供可靠的数据支撑;该方法采用 ShuffleNet V2 替代 CSPDarknet53 作为主干网络,并引入 SimAM 注意力机制,以减小网络规模并提升密集目标检测效能;颈部网络采用 Slim-neck 结构,结合 GSConv 和 VoV-GSCSP 模块提升密集目标的特征提取效率;训练过程中,使用 WIoU 误差函数并通过 Soft-NMS 动态调整边界框,以增强网络的泛化能力;算例分析及产地实测结果表明,所改进的轻量化 YOLOv5s 网络的平均精度均值较现有常用模型提高了 3%,参数量减少了 6.44 MB,每秒浮点运算次数减少了 14.70 G,模型体积减少了 12.24 MB,每秒帧数增加了 47.19 帧,且网络鲁棒性强,极大地降低了其应用与推广成本。

关键词:万寿菊识别;轻量化模型;改进YOLOv5s模型;ShuffleNet V2;注意力机制

Marigold Recognition Method Based on Improved Lightweight YOLOv5s

LI Xin, XU Bo, ZHANG Lei, YU Hao, JIA Yingxin, LIU Zijian

(Hebei Mechatronics Intermediate Pilot Production Base Co., Ltd., Shijiazhuang 050081, China)

Abstract: Traditional recognition network structure has the features of redundant and low universality, which leads to complex reasoning process and low efficiency, and it is difficult to meet the needs of dense growth marigold detection. To this issue, an improved lightweight YOLOv5s marigold recognition method is proposed, and an appropriate data set enhancement technology provides reliable data support for the recognition method. This method replaces CSPDarknet53 with ShuffleNet V2 as the backbone network, and introduces SimAM attention mechanism to reduce the network size and improve the detection efficiency of dense targets. The neck network adopts the Slim-neck structure, and combines the GSConv and VoV-GSC-SP modules to improve the feature extraction efficiency of dense targets. During the training process, using the WIoU error function and dynamically adjusting the bounding box through Soft-NMS to enhance the generalization ability of the network. Through example analysis and field measurement, the results show that the average accuracy of the improved lightweight YOLOv5s network is 3% higher than that of existing commonly used models, the parameter amount is reduced by 6. 44 MB, the number of floating-point operations per second by 14. 70 G, the model volume by 12. 24 MB, and the number of frames per second is increased by 47. 19 frames. The network has strong robustness, which greatly reduces its application and promotion costs.

Keywords: marigold detection; lightweight model; improved YOLOv5s model; ShuffleNet V2; attention mechanism

0 引言

万寿菊是一种兼具观赏、经济与药用价值的作物, 在我国多个省份均实现了大规模种植,其花朵富含天然 叶黄素成分,在食品、医药等领域具有举足轻重的地 位^{□□}。然而,万寿菊花朵的尺寸差异大、分布紧凑,且 易受叶片的遮挡,加之其采收设备受研制与推广成本的 约束,造成硬件资源受限,上述因素均明显削弱了目标

- 作者简介:李 欣(1990-),男,大学本科,工程师。
- 通讯作者:贾英新(1978-),女,大学本科,高级工程师。
- **引用格式:**李 欣,徐 博,张 雷,等. 基于改进轻量化 YOLOv5s 的万寿菊识别方法[J]. 计算机测量与控制,2025,33(6):185-192,199.

收稿日期:2024-11-26; 修回日期:2025-01-02。

基金项目:河北省科技计划项目(17391601D);河北省科学院高层次人才培养与资助项目(2024G13);石家庄市中试熟化平台项目(234790134A)。

检测网络的效能,挑战了依赖视觉技术的采收设备的高效运行,严重时甚至会诱发安全事故^[2]。因此,精准高效的万寿菊检测技术对于保障采收设备的安全稳定运行、提升农业自动化水平及经济效益具有重要的现实 意义。

在复杂的农业环境中,万寿菊及其他作物的传统采 收方式高度依赖于人工,作业艰苦且难以保证采收的时 效性^[3]。近年来,使用采收设备并集成视觉算法实现自 动化、智能化的作物采收成为解决此类问题的关键^[4]。 YOLO^[5]是一种高效的目标检测算法,在众多领域中被 得以广泛应用。然而,作为一种通用的视觉检测模型, YOLO并未针对特定的使用场景进行网络结构的优化 设计,特别是在小目标检测和复杂环境适用性等方面表 现欠佳^[6],使得其泛化性能受到较大限制。

为解决 YOLO 面临的上述问题,许多专家纷纷将 目光投入到对其改进之中,其中 YOLOv5s 因网络规模 小、推理速度快,尤其在资源受限的农业环境中备受青 ·睐^[7]。文献 [8] 通过对 YOLOv5s 模型增添 ESPA 模 块,最终检测的 mAP 值达到了 99.6%,精准地完成了 油菜关键生长阶段的健康监测任务,表明适宜的模块改 进可有效提升 YOLOv5s 模型的效果,但该模块计算较为 复杂。文献[9]将4种注意力机制(SE, CA, CBAM, SimAM)进行对比,并将效果最优的 SE 模块引入 YOLOv5s模型,最终模型在黄瓜花萌芽、开花和凋谢 3个阶段表现优异,说明了引入注意力机制的必要性, 但没有实现模型的轻量化。文献 [10] 通过将 CBAM 模块引入 YOLOv5 模型,并添加小目标检测层和 Kmeans++算法进行锚定聚类,结果表明,改进后的方 法较原有方法能够更有效地完成菠萝花检测任务。文献 「11]提出了一种适用于火龙果图像自主检测的实时多 任务卷积神经网络——SegYOLOv5,改进的算法具有 较高的鲁棒性和通用性,但算力需求较高。上述研究均 揭示了视觉技术在农业领域的巨大潜力,但均未结合具 体应用场景,考虑后续采收设备的成本约束,并有针对 性地进行模型轻量化改进,难以形成系统性的作物采收 方案。

综上所述,我国万寿菊产业规模庞大,但其复杂的 生长特性及采收设备的成本约束明显削弱了检测模型的 效能。此外,目前学界针对万寿菊检测的研究尚显不 足,而针对其他作物的类似研究常关注于提升模型的检 测精度,较少考虑模型的轻量化改进,且实验平台通常 相对理想,缺乏必要的产地实测。因此,本文提出一种 基于改进轻量化 YOLOv5s的万寿菊识别方法。首先, 为增强模型泛化性能,采集数据集后,选用适宜的方法 对其构建及增强。其次,使用 ShuffleNet V2 网络对 YOLOV5s 模型进行轻量化改进,降低算力开销,以提 升密集目标检测效能。在此基础上,引入 SimAM 简化 注意力机制,并在颈部网络采用 Slim-neck 结构,包括 Group Shuffle Convolution (GSConv)和 VoV-GSCSP 两 个先进模块,使得模型在进一步地得以轻量化的同时, 增强其图像特征提取能力,以平衡识别精度。算例分析 与产地实测结果表明,相较于传统检测模型,使用本文 所提模型的采收设备具有更优的作业效果和稳定性,且 保障提升了万寿菊花朵的检测精度,极大降低了其应用 与推广成本。

1 图像增强与数据集的构建

为给后续检测模型提供可靠的数据支撑,本研究团 队在石家庄市某万寿菊种植基地进行了图像数据采集工 作,该数据集涵盖了晴天与阴天两种不同天气条件下的 样本,概览如图1所示。



图 1 万寿菊数据集概览

为增强模型的泛化性能,本小节后续将计及万寿菊 植株的生长特性以及真实的采收作业环境,选用适宜的 方法对图像进行增强处理。

考虑到万寿菊花朵易被叶片遮挡,采用改进的 Cutout算法^[12]对图像进行增强,该算法可通过随机屏 蔽输入图像的部分区域,模拟叶片遮挡效果,以增强检 测网络的鲁棒性和泛化性能。在处理包含尺寸不一万寿 菊花朵的数据集时,传统 Cutout 算法因随机屏蔽区域 过大,易导致小尺寸的花朵目标丢失,为解决此问题, 采用改进的 Cutout 算法先对数据集中花朵位置进行标 记,并确定其区域大小。随后,以花朵区域四分之一为 最大遮罩基准,进行随机遮罩处理。

此外,考虑到农业环境复杂多变,如存在尘土、水 雾等不确定性等因素影响,为尽可能地还原真实作业时 的识别场景,本文还使用了 ColorJitter 颜色增强技术、 增加噪声和随机滤波处理的方法对数据集进行图像增 强,随机滤波处理包括高斯滤波、中值滤波以及均值滤 波。最终,数据集的增强效果概览如图 2 所示。

数据集完成图像增强后,将其按照8:2的比例随 机划分为训练集和验证集,分别包含1216张和304张 图像样本,并经由人工对万寿菊花朵进行了细致与精准 的标注,最终完成了数据集的构建。



(a) 原图 (b) 改进的Cutout (c) 颜色增强 (d) 噪声 (e) 随机滤波
 图 2 万寿菊数据集增强效果概览

2 基于改进轻量化 YOLOv5s 的万寿菊识 别方法设计

本节将在已获得的数据基础上,结合万寿菊 植株生长及采收作业场景特点,针对 YOLOv5s 网络存在的缺陷进行适宜性的优化改进,以节 能增效,同时保证检测精度。

2.1 轻量化 YOLOv5s 网络改进设计

YOLO 在通用设计框架下设计使用,未针 对特定应用场景进行优化,导致结构存在一定 的冗余,影响了其效率。此外,在特征提取层 面,较少考虑提取图像的深度特征,易造成小 目标及遮挡目标漏检问题。因此,对其有针对 性地适宜改进是保证万寿菊检测效果的关键。

为了满足高效、精准且低成本的万寿菊检 / S 测需求,对 YOLOv5s 网络进行优化改进。首 _ Bag 先,用 ShuffleNet V2 网络^[13]改换优化了原有的 CSPDarknet53 主干网络,以减少计算量和模型 参数。在最后一层,引入 SimAM 自相似注意力机制模 块^[14],以强化关键图像信息并抑制无关信息,进一步 提升主干网络的特征提取能力。在模型的颈部网络部 分,采用轻量化的 GSConv 和 VOV-GSCSP 模块^[15] 替换 优化了原有的 Conv 和 C3 模块,既发掘了图像的深度 特征,又降低了模型的计算量,并通过知识蒸馏的方法 对模型进行了最终的优化,改进后的轻量化 YOLOv5s 结构如图 3 所示。

2.1.1 基于 ShuffleNet V2 的主干网络改进

CSPDarkNet53 为 YOLOv5s 的默认主干网络,使 用了多层卷积神经网络,包括标准卷积层、批量归一 化,以及采用了 CSPNets 架构和残差连接等,造成了 其体积较大,对计算资源的要求较高。

为了解决这些问题,轻量级网络备受学者青睐,如GhostNet^[16]、MobileNet^[17]和ShuffleNet^[18],上述网络均有效地平衡了速度和准确性,且在相同的复杂度下,经领域内验证^[19],ShuffleNet V2的准确率要高于 MobileNet V2 和 GhostNet。因此,本文选取ShuffleNet V2 作为 YOLOv5s 的骨干网络^[20]。

如图 4 所示, ShuffleNet V2 网络的结构分为 Unit1 和 Unit2, Unit1 将特征图像分割为两个通道,其中左 侧通道保持不变,右侧通道在前端和后端进行 1×1 标 准卷积、中间进行 3×3 深度卷积后与左侧通道合并。 然后,将合并后的特征图进行通道重排处理,使得输入 和输出通道的数量相等,Unit1 只提取特征,不改变输 入特征图的大小和通道数。Unit2 剪除了通道分割操 作,使左右两通道均采用降采样操作,将输入特征图的 高度和宽度减半,通道数扩大为原来的 4 倍,在增加了



图 3 改进的轻量化 YOLOv5s 结构图



图 4 ShuffleNet-V2 Unit 的结构

网络宽度的同时,不影响运行速度,最后通过通道重排 方式实现不同组之间的特征融合。

ShuffleNet V2 通过通道重排方法解决了分组卷积 中各组之间特征融合不足的问题。如图 5 (a) 所示, 传统分组卷积将输入特征图划分为多个独立组,尽管降 低了计算复杂度,但缺乏组间信息交互,限制了模型的 表达能力。通道重排通过重新排列通道,如图 5 (b) 和 (c) 所示,实现跨组信息融合。将每个组的特征通 道按顺序提取并重新组合,形成新的组,使每个组包含 来自不同原始组的特征通道。



图 5 ShuffleNet-V2 通道重排示意图

综上可知, ShuffleNet V2 网络通过通道重排加强 了特征融合效果,提升了推理效率,并且更加轻量化, 对检测精度的影响较小,尤其适用于作业背景复杂、资 源受限的万寿菊检测场景。

2.1.2 骨干网络添加 SimAM 注意力机制

前文已提到,文献[9]验证了添加注意力机制在 检测任务中的有效性,为深入提取在复杂农业下万寿菊 特征信息,添加 SimAM 注意力机制。SimAM (Simplified Attention Mechanism)是一种简化的注意力机制, 图 6 为其工作示意图。与传统的注意力机制相比,SimAM 不依赖于复杂的矩阵运算,而是通过计算每个特 征通道的重要性来重新加权输入特征,从而增强网络的 特征提取能力,其计算公式如式(1)所示:

$$w_i = \frac{1}{k} \sum_{j \in N_i} s(f_i, f_j) \tag{1}$$

式中, *w_i* 是第*i* 个像素的注意力权重, *k* 是归一化常数, *N_i* 是第*i* 个像素的相邻像素集合, *s* (*f_i*, *f_j*) 是 第*i* 个像素和第*j* 个像素之间的相似性。

 $s(f_i, f_j)$ 是 SimAM 基于欧氏距离来计算像素之间的相似性,其计算如式(2)所示:

$$s(f_i, f_j) = - \| f_i - f_j \|_2^2$$
(2)

2.1.3 基于 Slim-Neck 的颈部网络改进

为了平衡检测精度和速度,在颈部网络引入 Slimneck。Slim-neck 主要是通过引入新的卷积模块和结构 来减少计算复杂性,同时保持或提高模型的准确性和效 率。其核心模块包括 GSConv 和 VoV-GSCSP。



图 6 SimAM 工作示意图

GSConv模块具有明显的速度优势。在卷积神经网络的骨干网络中,输入图像通常经历空间信息向通道信息的逐步转换。每次特征图的空间压缩和通道扩张都会导致语义信息的部分丢失,通道密集型的卷积计算(SC)最大限度地保留了每个通道之间的隐含连接,而通道稀疏的卷积(DSC)则完全切断了这些连接。GSConv则可以尽可能地保持这些连接,并具有更低的时间复杂性,其整体结构如图7所示。



图 7 GSConv 整体结构图

GSConv模块主要分为以下5个过程:

1)卷积层(Conv):输入特征图首先通过一个卷 积层,该层的输出通道数为 C₂/2。

2) 深度可分离卷积层 (DWConv): 该层对输入特 征图的每个通道独立进行卷积。

3) 拼接层 (Concat): 将 Conv 层和 DWConv 层的 输出进行拼接。

4)随机排列层 (Shuffle):拼接后的特征图经过一个 shuffle操作,以重新排列特征通道,提高特征间的 信息流动。

5)输出层:最终输出的特征图有 C₂ 个通道。

GSConv 通过该设计在保持足够的特征信息的同时 减少计算复杂度,提高了计算效率。

VoV-GSCSP 是 Slim-neck 架构中的另一个关键模块,可进一步提升网络的性能和效率,其整体结构如图 8 所示。VoV-GSCSP 利用一次性聚合方法设计的跨阶段部分网络模块,在不同阶段的特征图之间进行有效的信息融合。其主要分为以下 3 个过程:

1)特征图处理过程通过 GS Bottleneck 和多个卷积 操作有效地处理和组合来自不同层级的特征。GS Bot-



图 8 VoV-GSCSP 模块结构图

tleneck 结构如图 9 所示。



图 9 GS bottleneck 模块结构图

2)特征图融合通过上采样(Upsample)和拼接 (Concat)操作将不同尺度的特征图结合。

3)信息聚合使用 VoV-GSCSP 模块进一步提取和 融合特征,以准备最终的检测头进行目标检测。

VoV-GSCSP模块的不同设计方案通过特征图的有效融合,显著提升了特征利用效率和网络性能。通过GSConv和VoV-GSCSP模块的结合,较多地保留了重要的特征信息,Slim-neck可适用于万寿菊采收等计算资源受限且目标密集的应用场景中。

2.2 基于 Soft-NMS 与 WIoU 损失函数的泛化性能 2.2.1 使用 Soft-NMS 函数确定目标边界

万寿菊作为生长密集型作物,易导致检测边界框出 现重叠问题。传统 NMS 算法仅依据 *IoU* 值进行抑制, 在选取置信度最高的边界框时,可能过度抑制与之重叠 的框,从而错误排除期望目标。

为克服传统 NMS 的局限性,改进的网络使用 Soft-NMS 算法^[20] 替代传统的 NMS 算法。Soft-NMS 通过引 入置信度衰减因子,能够动态调整边界框的置信度,缓 解重叠框被过度抑制的问题。该因子依据 *IoU* 值调整 置信度,可降低期望目标被错误抑制的风险。Soft-NMS计算方法如式(3)所示:

$$s_{i} = \begin{cases} s_{i}, & IoU(M,b_{i}) < N_{i} \\ s_{i} [1 - IoU(M,b_{i})], IoU(M,b_{i}) \ge N_{i} \end{cases}$$
(3)

由式(3)可知,Soft-NMS综合考虑置信度与重叠度,确保了高置信度框的优先保留,以进一步地提升生长密集的万寿菊的检测可靠性。

2.2.2 基于 WIoU 损失函数训练网络

万寿菊花朵极易受到叶片遮挡,传统 IoU 函数对 此现象敏感性欠佳。加权交并比(WIoU, weighted intersection over union)针对 IoU进行了改进,特别是在 IoU基础上引入了中心距离、重叠面积均匀分布和框形 状一致性等权重因子,使得评价更为灵活和精确。 WIoU首先通过考虑预测框和真实框中心点距离,解决 了空间偏差问题。其次重叠面积均匀分布权重确保重叠 面积在两者间均匀分布,鼓励模型更好地拟合目标形 状。此外,形状一致性权重提高了对目标物体形状的敏 感度。其公式如式(4)(5)所示:

$$L_{\rm WIoU} = R_{\rm WIoU} L_{IoU} \tag{4}$$

$$R_{\rm WloU} = \exp\left(\frac{(x - x_{gl})^2 + (y - y_{gl})^2}{(W_g^2 + H_g^2)^*}\right) \tag{5}$$

式中, W_s , H_s 是最小的封闭框的大小。其结构如图 10 所示。



图 10 加权交并比示意图

得到 WIoU 损失值函数后,将其作为改进轻量化 YOLOv5s 网络训练的优化目标,整个训练过程通过公 式(4)(5)量化表达,具体实现中结合深度学习框架 进行损失计算和网络参数更新,以缓解传统 IoU 对目 标遮挡和框体偏移的敏感性不足问题。

3v 算例分析与产地实测

为了全面验证所提改进模型的有效性和优越性,本 节分别开展了消融实验、与现有先进模型的对比实验, 并在石家庄市某万寿菊基地结合团队自研的采收机进行 了产地实测。

3.1 实验平台及评价指标简述

在本算例中,模型训练环境配置如下:操作系统为Windows 11,硬件方面配备了Intel(R)Core(TM)i9-14900HX处理器、64 GB内存,以及拥有16 GB显存的NVIDIA GeForce RTX 4090 Laptop GPU。模型基于PyTorch深度学习框架,在CUDA 11.8.89下以GPU模式进行训练,具体的训练参数如表1所示。

表1 实验参数设置

参数	数值
epochs	300
batch-size	32
learning rate	0.01
Mosaic	1.0
Weight-decay	0.000 5
Img size	640×640

本算例以领域内通用的 PRAUC、Precision、Recall、AP、mAP、Parameters、Model Size、FPS、 FLOPs、Parameters 作为模型评价指标,其中 Precision、Recall、mAP、FLOPs、Parameters 的公式如下 所示:

$$PRAUC = \int_{0}^{1} PRcurve \tag{6}$$

$$Precision = \frac{TP}{TP + FP} \times 100\%$$
(7)

$$Recall = \frac{TP}{TP + FN} \times 100\%$$
(8)

$$AP = \frac{1}{N} \sum_{i=0}^{N} (r_{i+1} - r_i) P(r_{i+1})$$
(9)

$$mAP = \frac{1}{C} \sum_{k=i}^{N} P(k) \triangle R(k) \times 100\%$$
(10)

$$FLOPs = 2 \times K^2 \times C_{in} \times C_{out} \times H_{out} \times H_{out} \quad (11)$$

$$Parameters = C_0 \times (C_i \times K_w \times K_h + 1) \quad (12)$$

PRAUC 即 PR 曲线的面积越大,模型的综合性能越好。mAP 是目标检测中检测精度的度量,mAP 越高,其检测效果越好。FLOPs (G) 是衡量模型计算复杂度的指标,表示模型在进行一次前向传播时所需执行的浮点运算次数,单位为十亿次运算,该指标越低则表明模型的计算复杂度越低。Parameters 用于衡量模型复

杂度,通常表示模型中可学习参数的总数。

3.2 消融实验

为了验证所提模型各模块的有效性,将改进后 YOLOv5s模型的主干网络,注意力机制以及Slim-neck 结构和损失函数进行消融实验对比,实验结果如表 2 所示。

观察表 2,通过逐步引入不同的模块和技术,改进 后的 YOLOv5s 网络在性能上有了显著的提升。首先, 以 ShuffleNet V2 为主干网络的模型虽然导致了平均检 测精度有略微的下降,但显著降低了参数量、计算量和 模型体积,其中参数量减少至 0.84 M,计算量降至 1.83 G,模型体积缩小至 2.00 MB,使模型在计算资源 的消耗显著减小。其次,在引入 SimAM 模块后,模型 的精度提高了 0.9%,在使用 GSconv+VoV-GSCSP 构 成的 Slim-neck 模块后,平均检测精度提高至 93.60%, 参数量减少了 0.31 MB,模型体积减小了 0.62 MB,计 算量减少至 1.10 G,进一步优化了性能。

3.3 改进模型与现有先进模型对比

为了验证所提改进模型的优越性,本小节选择领域 内常用的轻量化模型 YOLOv3-tiny、YOLOv4-tiny、 YOLOv7-tiny,以及 SSD 和 Faster R-CNN 模型与其进 行对比。为了保证实验的客观性,所有模型均选用相同 的训练集和验证集,并且训练参数的选择均依据表 1 的 设置。

使用各模型将测试集图像数据检测推理完成后,各 模型的评价指标结果如表 3 所示。观察表 3 可见,本文 所提模型在各项性能指标上均表现出色。在平均精度方 面,本文所提出的模型达到了 90.50%,相较于 YOLOv5s 算法,提升了 2.55%。在参数量方面,本文所 提出的模型仅为 0.58 MB,远低于其他网络的参数量。 同时,模型的计算量仅为 1.10 G,相较于 YOLOv3-tiny、 YOLOv4-tiny等模型,模型计算量显著减少。模型体积 为 1.47 MB,显著小于其他模型,进一步体现了其在存 储需求上的优势。此外,检测速度达到了 267.43 帧每 秒,展示了更优的实时处理能力。上述结果表明,所提 模型在保持高精度的同时,具备了最小的参数量、计算 量和模型体积,并且具有优异的检测速度。

表 2 模型消融实验评价指标结果

序号	ShuffleNet V2	SimAM	Slim-neck	Soft-NMS	WIoU	$mAP/\frac{0}{0}$	Parameters	FLOPs/G	Size/MB	PR 面积
1						87.50	7 012 822	15.80	13.71	0.75
2	\checkmark					87.20	842 358	1.80	2.00	0.74
3	\checkmark	\checkmark				88.10	887 926	1.90	2.09	0.78
4	\checkmark	\checkmark	\checkmark			89.70	580 966	1.10	1.47	0.81
5	\checkmark	\checkmark	\checkmark	\checkmark		89.90	580 966	1.10	1.47	0.83
6	\checkmark	\checkmark	\checkmark	\checkmark	\checkmark	90.50	580 966	1.10	1.47	0.87

衣5 侠空刈比								
Model	$mAP/\frac{9}{0}$	Parame ters/M	FLOPs/G	size/MB	FPS			
Faster R-CNN	77.50	137.00	194.30	108.00	34.62			
SSD	80.30	23.70	115.70	91.60	83.71			
YOLOv3-tiny	87.70	8.60	12.80	17.44	307.54			
YOLOv4-tiny	85.40	6.12	15.90	23.57	293.42			
YOLOv5s	87.50	7.01	15.80	13.71	220.24			
YOLOv7-tiny	90.10	6.02	13.20	12.29	207.83			
Ours	90.50	0.58	1.10	1.47	267.43			

表 3 模型对比

图 11~13 分别为本文所用算法在改进前、改进中 及改进后 3 个阶段的检测效果。其中,图(a)表示改 进前的检测结果,图(b)表示改进中的检测结果,图 (c)表示改进后的检测结果。图 11 展示了重叠目标检 测效果,结果表明,改进后的模型由于采用了 Soft-NMS 算法,相较于改进前,改进模型能够有效识别重 叠的万寿菊目标。图 12 展示了遮挡目标检测效果,结 果表明,改进后的检测效果能够完整识别遮挡目标。图 13 展示了综合检测效果,结果表明,改进后的模型在 多目标、重叠目标及遮挡目标检测方面表现优异,表明 改进后的模型具有更好的鲁棒性和泛化能力。



(a) YOLOv5s
 (b) YOLOv5s-ShuffleNet V2
 (c)本文所提模型
 图 11 重叠目标检测对比



(a) YOLOv5s (b) YOLOv5s-ShuffleNet V2 (c)本文所提图 12 遮挡目标检测对比

3.4 产地实测

为验证所提模型在实际采收场景的优越性和有效 性,本研究团队将优化后的检测模型部署于自主研制的 万寿菊采收机中。该设备集成了视觉识别、多点位通信 及多机械爪控制等复杂程序,因设备需长时间带电作 业,同时为节约研制推广成本,所搭配的计算资源有



图 13 综合检测对比

限, 仅配备一台 mini 主机, CPU 型号为 i5-13420H, 无显卡, 但算力需求较高。

图 14(a)为智能万寿菊采收机结构图,其配备三 路视觉采集系统:一路负责路径导航,另两路专注于万 寿菊识别,实现万寿菊采收任务。



(b)

(c)

图 14 万寿菊智能采收机结构及其实景作业图

图 14(b)为采收机运行及其采收实拍。产地实测 表明,所提模型能精确识别万寿菊花朵位置,进而驱动 一对机械爪执行采收任务,具体作业流程如图 15 所示。

在同一天1个小时内、同亩地块下,将检测模型部 署于智能采收机中进行采收作业。每次测试随机抽取 30个1m²的地块,使用各模型完成采收,并记录每平 方米的平均采收时间以及采收准确率。平均采收时间的 计算方法为:将采收完成时间除以随机抽样地块的总 数;采收准确率的计算方法则为:抓中花朵的次数除以 落爪的总次数。实测结果显示如表4所示,相较于改进 前,设备整体运转效率和采收准确率有了较大提升。



图 15 智能万寿菊采收机作业流程图

表 4 产地实测模型效果对比

Model	平均采收时间/(s/m ²)	采收准确率/%		
Faster R-CNN	65.1	72.3		
SSD	58.7	74.4		
YOLOv3-tiny	40.6	76.2		
YOLOv4-tiny	42.5	81.9		
YOLOv5s	48.5	87.4		
YOLOv7-tiny	47.2	92.9		
Ours	35.8	95.1		

4 结束语

本文针对传统目标检测网络在万寿菊产地采收任务 中存在的结构冗余、效能低下、普适性低及部署推广应 用受限等问题,提出了一种基于轻量化改进的 YOLOv5s万寿菊检测方法。该方法通过优化网络结构, 显著降低了模型体积,减少了参数量和计算量,同时保 持了较高的检测精度。实验和产地实测结果表明,所提 模型在复杂作业环境中能够更精确地捕捉关键图像特 征,有效提升了万寿菊的识别效率,改进后的模型在参 数量和计算量上分别减少了 91.7%和 93.1%,体积缩 减至原始的 10.7%,但平均检测精度仍保持在 90.5% 的较高水平。此外,轻量化模型的部署使得其在采收设 备上更加经济可行,具有较强的工程实用价值。

参考文献:

[1] 冯丹琦, 王向红, 吴 迪, 等. 基于 RAW264.7 细胞模型 的槲皮万寿菊素与叶黄素协同改善急性肺损伤的作用机制

[J]. 食品科学, 2024, 45 (17): 96-104.

- [2] 杜小强,李党伟,贺磊盈,等. 基于电子果实技术的机械 振动采收过程果实运动分析 [J]. 农业工程学报,2017, 33 (17):58-64.
- [3] 赵 博,柳苏纯,张巍朋,等. 面向樱桃番茄采摘识别的 轻量化 Transformer 架构优化研究 [J]. 农业机械学报, 2024,55 (10):62-71.
- [4] 刘继展,江应星.农业采摘机器人产业化进程分析与多臂
 高速化技术走向[J].农业机械学报,2024,55 (10):1-17.
- [5] HSU W Y, LIN W Y. Ratio-and-scale-aware YOLO for pedestrian detection [J]. IEEE Transactions on Image Processing, 2020, 30: 934 - 947.
- [6] 徐彦威,李 军, 董元方,等. YOLO 系列目标检测算法 综述 [J]. 计算机科学与探索, 2024, 18 (9): 2221 -2238.
- [7] WANG D, HE D. Channel pruned YOLO V5s-based deep learning approach for rapid and accurate apple fruitlet detection before fruit thinning [J]. Biosystems Engineering, 2021, 210: 271 - 281.
- [8] ZHANG P, LI D. EPSA-YOLO-V5s: A novel method for detecting the survival rate of rapeseed in a plant factory based on multiple guarantee mechanisms [J]. Computers and Electronics in Agriculture, 2022, 193: 106714.
- [9] XU X, WANG H, MIAO M, et al. Cucumber flower detection based on YOLOv5s-SE7 within greenhouse environments [J]. IEEE Access, 2023, 11: 64358 - 64369.
- [10] SU J, YU G. Pineapple flower detection algorithm based on improved YOLOv5 [C] //2023 2nd International Conference on Robotics, Artificial Intelligence and Intelligent Control (RAIIC). IEEE, 2023: 221 – 225.
- [11] 孔凡国,李志豪,仇展明,等. 基于改进 YOLOv5-s 的火 龙果多任务识别与定位 [J]. 电子测量技术,2023,46 (18):155-162.
- [12] DEVRIES T. Improved regularization of convolutional neural networks with cutout [J]. Arxiv Preprint Arxiv: 1708.04552, 2017.
- [13] MA N, ZHANG X, ZHENG H T, et al. Shufflenet v2: practical guidelines for efficient CNN architecture design [C] //Proceedings of the European Conference on Computer Vision (ECCV), 2018: 116 – 131.
- [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, PMLR, 2021: 11863 - 11874.
- [15] LI H, LI J, WEI H, et al. Slim-neck by GSConv: a lightweight-design for real-time detector architectures
 [J]. Journal of Real-Time Image Processing, 2024, 21 (3): 62.