

基于改进 YOLO11s 的番茄叶片病害轻量化检测方法

李宏达^{1a}, 刘昕宇^{1a}, 姚东艳^{1b}, 王超明²

(1. 沈阳理工大学 a. 自动化与电气工程学院, b. 经济管理学院, 沈阳 110159; 2. 沈阳东科拉科技有限公司, 沈阳 110004)

摘要: 针对现有番茄叶片病害检测中存在的背景复杂、模型参数量大以及小目标病害检测精度不足等问题, 提出一种基于改进 YOLO11s 的番茄叶片病害轻量化检测方法。在主干网络中使用 GSConv 模块替换部分标准卷积模块, 在保持检测精度的同时显著减少模型参数量; 在特征提取层中引入 C3k2_PConv2 模块, 通过部分通道卷积运算有效减少冗余计算和内存访问量; 在主干网络末端, 将 SENetV2 模块与 C2PSA 模块融合, 形成 C2PSA_SENetV2 模块, 增强通道间信息交互和全局特征表达能力; 引入 UIoU 损失函数, 通过动态权重分配策略改善边界框回归精度。与原始 YOLO11s 模型相比, 改进后的模型检测平均精度均值 (mAP@0.5) 提升了 0.6%, 同时实现了显著轻量化, 模型参数量减少了 19.2%, 计算量降低了 16.9%, 模型权重大小减少了 19.1%。本文提出的方法在保持检测精度的同时实现了显著的轻量化效果, 可为番茄叶片病害实时智能检测提供技术支撑。

关键词: 番茄叶片病害; YOLO11s; 目标检测; 轻量化

中图分类号: TP391.4 文献标志码: A DOI:10.3969/j.issn.1003-1251.2026.04.007

Lightweight Detection Method for Tomato Leaf Diseases Based on Improved YOLO11s

LI Hongda¹, LIU Xinyu¹, YAO Dongyan¹, WANG Chaoming²

(1. Shenyang Ligong University, Shenyang 110159, China; 2. Shenyang Dongkela Technology Co., Ltd., Shenyang 110004, China)

Abstract: A lightweight detection method for tomato leaf diseases based on improved YOLO11s is proposed to address the challenges of complex backgrounds, large model parameters, and insufficient detection accuracy for small-target diseases in existing tomato leaf disease detection systems. GSConv modules are employed to replace certain standard convolution modules in the backbone network. It significantly reduces the number of model parameters while maintaining detection accuracy. The C3k2_PConv2 module is introduced in the feature extraction layers to minimize redundant computations and memory access through partial channel convolution operations. At the end of the backbone network, the SENetV2 module is integrated with the C2PSA module to form the C2PSA_SENetV2 module, enhancing inter-channel information interaction and global feature representation capabilities. The UIoU loss function is incorporated to optimize bounding box regression accuracy through a dynamic weight allocation strategy. Compared to the original YOLO11s model, the improved model demonstrates a 0.6% improvement in mean average precision (mAP@0.5) while simultaneously achieving significant lightweight performance with decreases of 19.2% in model parameters, 16.9% in computational complexity, and 19.1% in model weight size, respectively. The proposed method achieves substantial lightweight performance while maintaining detection accuracy, be-

ing able to provide technical support for real-time intelligent detection of tomato leaf diseases.

Key words: tomato leaf diseases; YOLO11s; object detection; lightweight

番茄是一种重要的经济作物,具有广泛的市场需求。番茄在生长过程中极易受到复杂多样的病害侵袭,严重威胁其产量和品质^[1]。传统的病害检测主要依赖专家肉眼观察和经验判断,耗时费力且准确性受限,难以满足现代农业大规模、实时化、精准化检测需求。

随着人工智能技术的快速发展,基于卷积神经网络(CNN)^[2]的目标检测技术为植物病害识别提供了新的解决方案。当前目标检测算法主要分为两类:一类是两阶段检测算法,如 R-CNN^[3]、Faster R-CNN^[4];另一类是单阶段检测算法,如 YOLO^[5]系列、SSD^[6]等。其中 YOLO 系列算法能够实现端到端的实时检测,可良好平衡检测精度和检测速度,在目标检测领域得到广泛应用。

赵子艺等^[7]在 YOLOv8 的颈部网络中采用 FasterC2f 模块替代原 C2f 模块,提高了模型检测的平均精度均值,但模型轻量化程度提升较小。黄志龙^[8]通过引入可变形卷积(DCNv2)和自注意力检测头(DyHead)改进了 YOLOv5s,有效提升了检测精度,但模型参数量也相应增加。赵艳芹等^[9]对 YOLOv5 进行改进,采用 GhostCANet 作为主干网络,提高了模型的检测精度,同时实现了模型的轻量化。吴六爱等^[10]对 YOLOv10n 进行改进,提出了一种 YOLOv10n-YS 模型,检测精度达到 92.1%,但计算量未得到改善。吴世琛等^[11]在 YOLO11n 的颈部网络采用 Slim-neck 架构,降低了计算复杂度。黄铭杰等^[12]在 YOLO11 的 C3k2 模块中应用了 CMUNeXt 模块,提高了模型对小目标的感知能力。

尽管基于 YOLO 系列的目标检测算法取得了一定进展,但应用于番茄叶片病害检测时仍普遍存在模型参数量较大、小目标病害检测能力不足、复杂背景下检测精度不高等问题。为此,本文提出一种基于改进 YOLO11s 的番茄叶片病害轻量化检测方法。具体改进内容如下:

1) 在主干网络中引入轻量化的 GSConv^[13] 模块替换第 1、3、5、7 层的下采样标准卷积(Conv)模块,采用混合深度可分离卷积与标准卷积的策略减少参数量;

2) 在特征提取层中引入 C3k2_PConv2 模块,仅对部分通道进行卷积运算,在保持空间特征提

取能力的同时有效减少冗余计算和内存访问量;

3) 在主干网络末端将 SENetV2^[14] 模块融合至跨阶段局部空间注意力(C2PSA)模块,形成新的 C2PSA_SENetV2 模块,增强通道间信息交互和全局特征表达能力,提升目标检测的准确性;

4) 引入 UIoU (unified-IoU)^[15] 损失函数,通过动态权重分配策略改善边界框回归精度,提升对边缘小目标叶片的检测精度。

1 YOLO11 网络结构

YOLO11 的网络结构如图 1 所示。YOLO11 延续了由骨干网络(Backbone)、颈部网络(Neck)和检测头(Head)组成的三段式结构设计,其核心创新在于引入 C3k2 模块替代原 C2f 模块,通过优化卷积结构提升特征提取效率。此外,在快速空间金字塔池化模块(SPPF)基础上,新增 C2PSA 模块,使模型更有效地捕获多层次上下文信息。图中:Concat 表示张量拼接模块;Upsample 表示上采样模块;Detect 表示检测头模块。

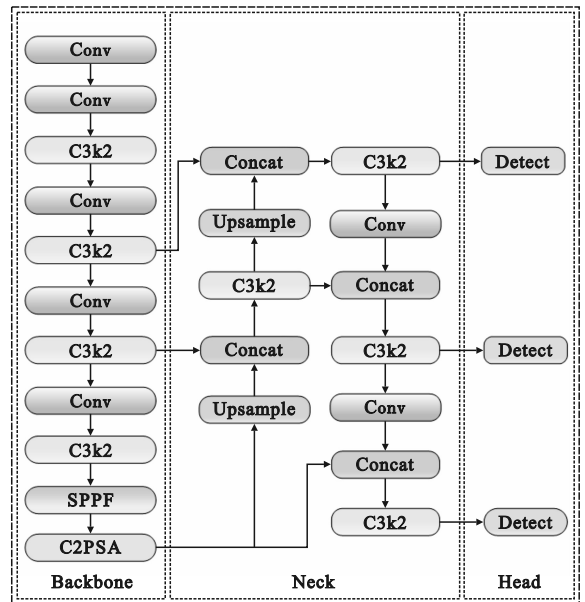


图 1 YOLO11 网络结构

Fig. 1 YOLO11 network structure

YOLO11s 针对 YOLO11 在计算资源受限环境中的应用进行了优化设计,具有快速推理能力,且模型体积较小。因此,本文选择 YOLO11s 作为研究基础框架。

2 改进的 YOLO11s 模型

2.1 改进的 YOLO11s 模型网络结构

番茄在生长过程中易感染早疫病、晚疫病、叶霉病等多种病害,这些病害在叶片上往往表现为微小斑点或轻微颜色变化,番茄叶片病害检测属于典型的小目标检测问题。

现有番茄叶片病害检测中存在病害目标尺寸小、特征不显著、复杂背景干扰以及同一监控画面中病害多尺度分布等问题。为此,本文对 YOLO11s 进行改进:首先,在主干网络中使用 GSConv 模块替换第 1、3、5、7 层的下采样 Conv 模块,通过混合深度可分离卷积和标准卷积的策略,在保持检测精度的同时显著减少模型参数量,提升模型在农业现场部署的可行性;其次,在特征提取层中引入 C3k2_PConv2 模块,该模块融合了 C3k2 的多尺度特征提取能力与部分卷积 (PConv)^[16] 技术,通过仅对部分通道进行卷积运算,在保持空间特征提取能力的同时有效减少冗余计算和内存访问量,进而实现模型的轻量化;另外,将 SENetV2 模块融合至 C2PSA 模块中,形成新的 C2PSA_SENetV2 模块,通过引入多分支聚合密集层增强通道间信息交互和全局特征表达能力,从而提升模型在复杂叶片背景下对关键病害特征的关注度;最后,引入 UIoU 损失函数,通过动态权重分配策略改善边界框回归精度,提升对边缘小目标叶片的检测精度。改进的 YOLO11s 网络结构如图 2 所示。

2.2 GSConv 轻量化卷积模块

针对番茄叶片病害检测在资源受限环境下的实时性需求,传统轻量化网络常采用深度可分离卷积 (DSCConv) 来减少参数量和计算复杂度。然而,DSConv 在大幅降低计算成本的同时往往伴随

着特征表达能力的减弱和跨通道信息交互的不足,导致模型在复杂农业场景下的检测精度显著下降。为解决该问题,本文引入 GSConv 轻量化卷积模块,通过创新的混合卷积策略和通道重组机制,在保持轻量化优势的同时有效弥补传统 DSConv 的不足。

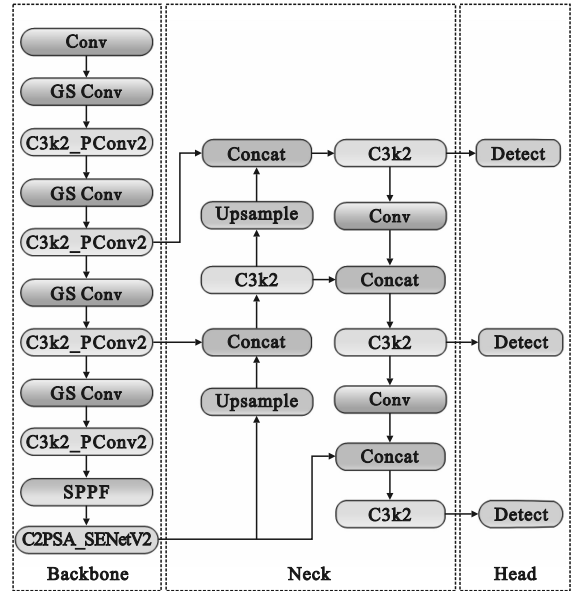


图 2 改进的 YOLO11s 网络结构

Fig. 2 Improved YOLO11s network structure

GSConv 模块结构如图 3 所示。对于输入通道数为 C_1 的特征图,GSConv 采用双分支处理架构实现高效特征提取:上分支采用标准卷积操作,得到通道数为 $C_2/2$ 的特征图,保持了丰富的跨通道信息交互能力;下分支则将标准卷积得到的特征图进一步进行深度卷积 (DWConv) 操作,同样得到通道数为 $C_2/2$ 的特征图,实现了参数量和计算量的显著降低。两个分支输出的特征图通过 Concat 操作进行拼接,随后采用通道重排 (Shuffle) 操作对拼接后的特征图通道进行重新排列组合,使得来自不同分支的特征信息能够充分混合交互,最终

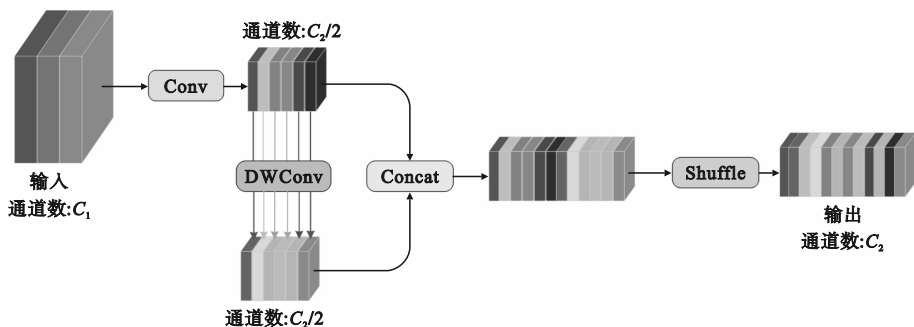


图 3 GSConv 模块结构

Fig. 3 GSConv module structure

得到具有 C_2 个通道的融合特征图。上述设计兼顾了标准卷积的特征表达丰富性和深度可分离卷积的计算高效性。

标准卷积和 GSConv 的时间复杂度分别表示为

$$T_{\text{Conv}} = O(W \times H \times K_1 \times K_2 \times C_1 \times C_2) \quad (1)$$

$$T_{\text{GSConv}} = O\left(W \times H \times K_1 \times K_2 \times \frac{C_2}{2} \times (C_1 + 1)\right) \quad (2)$$

式中: T_{Conv} 和 T_{GSConv} 分别表示标准卷积和 GSConv 的时间复杂度; W 和 H 分别为输出特征图的宽度和高度; $K_1 \times K_2$ 表示卷积核的大小; C_1 为输入特征图的通道数; C_2 为输出特征图的通道数。相较于标准卷积, GSConv 通过将输出特征图通道数减半的方式降低了时间复杂度, 同时使得参数量显著减少, 从而达到模型轻量化的效果。

2.3 C3k2 模块的改进

针对番茄叶片病害检测中存在的特征提取效率不高、计算资源消耗大且推理速度受限的问题, 本文引入基于 PConv 技术的 C3k2_PConv2 模块。该模块通过减少冗余计算和内存访问量更有效地提取空间特征, 可在保持检测精度的同时显著提升推理速度。传统深度可分离卷积虽能减少参数量, 但频繁的内存访问影响实际推理速度。PConv 的核心思想是利用特征图通道间的冗余性和相关性, 仅对输入特征图的部分通道进行标准卷积操作提取特征信息, 可显著降低计算复杂度。PConv 模块结构如图 4 所示。




图 4 PConv 模块结构

Fig. 4 PConv module structure

PConv 的浮点运算量 (FLOPs) 计算公式为

$$F_{\text{PConv}} = h \times w \times k^2 \times c_p^2 \quad (3)$$

式中: F_{PConv} 表示 PConv 的浮点运算量; h 和 w 分别为特征图的高度和宽度; c_p 为参与卷积的通道数; k 为卷积核大小。PConv 仅对 c_p 个通道进行卷积操作, 当通道比例 $r = c_p / c = 1/4$ 时, 由式 (3) 可知, PConv 的浮点运算量仅为标准卷积的 1/16。

内存访问量 M 的计算公式为

$$M = h \times w \times 2c_p \times k^2 \times c_p^2 \approx h \times w \times 2c_p \quad (4)$$

由式 (4) 可知, 当通道比例为 1/4 时, PConv 的内存访问量减少至标准卷积的 1/4。PConv 显

著降低了模型的计算复杂度和内存访问开销。

基于 PConv 技术构建的 CSPPC_Bottleneck 模块采用双重 PConv 串联结构, 去除传统残差连接, 通过连续两次部分卷积操作增强特征提取能力; C3kPConv 模块则将传统 Bottleneck 模块替换为 CSPPC_Bottleneck 模块, 实现轻量化的特征提取; C3k2_PConv2 模块进一步集成 C3kPConv 模块作为其核心处理单元, 形成完整的轻量化特征提取方案。本文在特征提取层中引入 C3k2_PConv2 模块既保证了特征表达的丰富性, 又通过 PConv 技术显著降低了计算开销。C3k2_PConv2 模块、C3kPConv 模块和 CSPPC_Bottleneck 模块结构如图 5 所示。

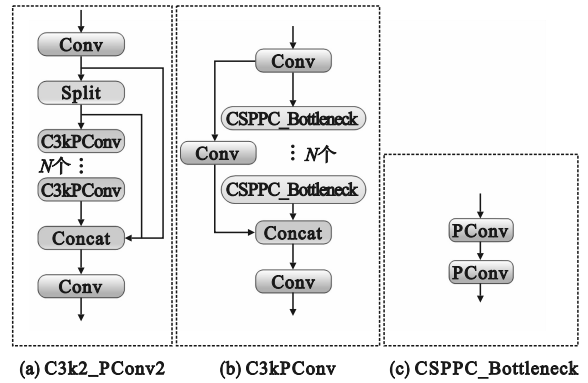


图 5 C3k2_PConv2 模块、C3kPConv 模块和 CSPPC_Bottleneck 模块结构

Fig. 5 The structures of C3k2_PConv2 module, C3kPConv module, and CSPPC_Bottleneck module

2.4 C2PSA 模块的改进

为满足复杂农业场景下番茄叶片病害检测的实时性要求, 本文对 YOLO11s 中 C2PSA 模块进行轻量化改进。原始 C2PSA 模块虽然能够有效关注图像中的关键区域, 但其计算复杂度较高, 在处理高分辨率农业图像时存在推理速度瓶颈。

为了在保持检测性能的同时进一步降低计算复杂度, 本文引入 SENetV2 网络架构。SENetV2 是一种高效的图像分类网络, 其核心部分是 SaE (squeeze aggregated excitation) 模块。SaE 模块将 SE 模块与密集层相结合; SE 模块对通道特征进行重新校准, 使模型能够更好地捕捉关键特征, 通过全局信息动态调整通道特征的重要性, 从而提高模型的特征表达能力; 密集层可进一步优化特征表示, 有助于增强通道特征的全局表示能力, 从而提高模型的性能。

SaE 模块的结构如图 6 所示, 将输入特征经过标准卷积处理后, 利用全局平均池化操作挤压

(Squeeze)特征,挤压后的输出特征送至多分支全连接(FC)层,然后进行激励(Excitation)操作,进一步经通道级别的缩放(Scale)并与卷积特征相加后,再经后续卷积层形成最终输出。

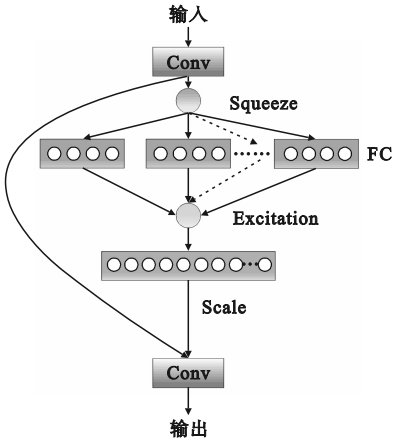


图6 SaE模块结构

Fig.6 SaE module structure

本文设计的C2PSA_SENetV2模块通过引入基于SaE的多分支通道注意力机制,能够显著降低计算复杂度,并更好地适应番茄叶片病害的多尺度特征,通过通道重校准有效抑制复杂农业背景的干扰,提升对关键病害特征的关注度,为农业现场的实时智能检测提供高效的技术支撑。

2.5 UIoU 损失函数

针对番茄叶片病害检测中边界框回归精度不足、小目标病害定位不准确的问题,本文引入UIoU损失函数。UIoU通过动态权重分配策略将模型注意力从低质量预测框转移到高质量预测框,以增强模型检测性能。

UIoU损失函数设计为可与任意IoU变体结合的通用框架,在本文番茄叶片病害检测任务中,将UIoU与CIoU(complete IoU)相结合,该设计使得模型既能利用UIoU的动态权重分配优势,又能够保持CIoU在边界框回归方面的几何特性优化能力。

CIoU以IoU为基础,引入惩罚项,计算表达式为

$$L_{\text{CIoU}} = 1 - L_{\text{IoU}} + \frac{\rho^2}{d^2} + \alpha v \quad (5)$$

其中

$$\alpha = \frac{v}{(1 - L_{\text{IoU}}) + v} \quad (6)$$

$$v = \frac{4}{\pi^2} \left[\arctan\left(\frac{m^{\text{gt}}}{n^{\text{gt}}}\right) - \arctan\left(\frac{m}{n}\right) \right]^2 \quad (7)$$

式中: L_{CIoU} 和 L_{IoU} 分别表示CIoU损失和IoU损

失; ρ 是预测框和真实框中心点之间的欧氏距离; d 是包含预测框和真实框最小闭包区域的对角线长度; α 是用于表示权重的参数; v 是用于评价长宽比一致性的参数; n^{gt} 和 m^{gt} 分别为真实框的长和宽; n 和 m 分别为预测框的长和宽。

UIoU损失函数的核心创新在于焦点框(Focus Box)机制,该机制通过动态缩放边界框实现自适应权重分配,缩放系数决定训练过程中注意力的动态调整模式。本文采用线性衰减策略,缩放系数计算表达式为

$$r_{\text{linear}} = -0.005 \times N_{\text{epoch}} + 2 \quad (8)$$

式中: r_{linear} 为缩放系数; N_{epoch} 为当前训练轮数。通过该策略,本文中缩放系数从训练初期的2.0线性衰减至300轮后的0.5。 r_{linear} 随着训练周期进行变化:训练初期, $r_{\text{linear}} > 1$,边界框扩大,模型将注意力集中于低质量预测框,加速收敛;训练过程中, r_{linear} 逐渐减小,当 $r_{\text{linear}} < 1$ 时,边界框收缩,模型将注意力逐渐转向高质量预测框,提升定位精度。

UIoU与CIoU的结合既保持了CIoU在边界框几何约束方面的优势,又可通过焦点框机制增强对小目标番茄叶片病害以及边缘区域的检测能力,显著提升番茄叶片病害检测的精度和稳定性。

3 实验结果与分析

3.1 实验环境和超参数设置

实验的操作系统为Ubuntu20.04,深度学习框架为PyTorch2.0.0,编程语言为Python3.8.10、CUDA(版本为11.8);显卡型号为NVIDIA GeForce RTX 4060Ti,16 G显存,运行内存为32 GB,CPU型号为Intel(R) Xeon(R) CPU E5-2683 v4。初始学习率设为0.01,学习率动量设置为0.937,采用随机梯度下降优化器(SGD),图像输入尺寸设定为640×640像素,使用数据增强等技术提高模型性能,训练轮次(epoch)设为300,批次大小(batch)设为32。

3.2 数据集及评价指标

本研究采用的番茄叶片病害数据集来源于两个公开数据库:一是Plant-Village数据集^[17]中的番茄叶片病害图片;二是Roboflow平台公开的番茄叶片病害数据集^[18]。对图像数据进行预处理:通过水平翻转或垂直翻转以及±15°旋转变换,模拟不同拍摄角度;对病害特征明显的区域进行裁剪和放大处理,去除叶片边缘、土壤背景等无关信息区域;添加高斯噪声模拟真实拍摄环境中的噪

声干扰。经过数据增强后的数据集包含健康叶片、早疫病、晚疫病、叶霉病、花叶病、斑枯病、黄叶卷曲病、潜叶虫和叶螨等 9 种常见的番茄叶片病害图片,总计 6 446 张图像,采用 Labelimg 标注工具对经过预处理的番茄叶片病害图像逐一进行人工标注。番茄叶片病害数据集分布情况如表 1 所示。

表 1 番茄叶片病害数据集分布

Table 1 Distribution of tomato leaf disease dataset

病害种类	图片数量	标注框数
健康	873	1 147
早疫病	847	1 428
晚疫病	829	1 373
叶霉病	746	1 429
花叶病	692	1 381
斑枯病	718	1 306
黄叶卷曲病	637	1 219
潜叶虫	531	1 042
叶螨	573	1 197

为保持实验数据的随机性,将数据集按 8:1:1 的比例划分为训练集、验证集和测试集。所有图像统一调整分辨率为 640×640 像素,以满足 YOLO 目标检测模型的输入要求。各种番茄叶片病害图例如图 7 所示。

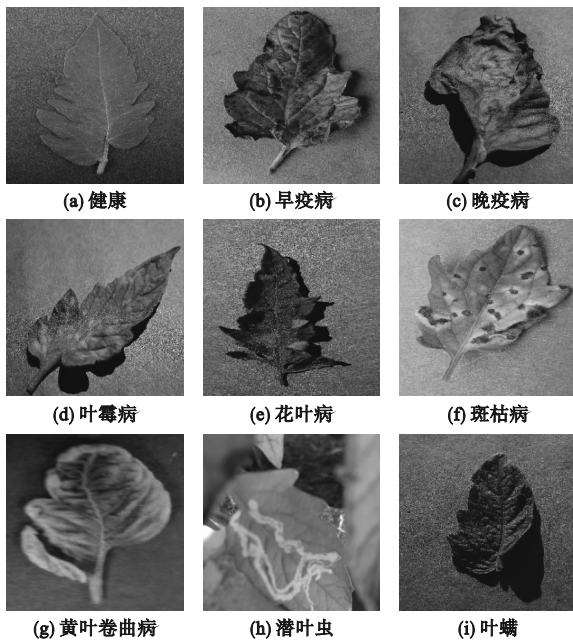


图 7 番茄叶片病害数据集图例

Fig. 7 Legends of tomato leaf disease dataset

本文选择平均精度均值 (mAP@0.5)、模型参数量 (Params)、模型计算量 (GFLOPs)、模型权重大小 (Weights) 及帧率 (FPS) 作为评价指标,全面评估模型在检测精度和轻量化方面的性能。

3.3 消融实验

为验证本文提出的各改进模块的有效性,在 YOLO11s 基础上设计消融实验方案,分别测试 GSConv 模块 (A)、C3k2_PConv2 模块 (B)、C2PSA_SENetV2 模块 (C) 和 UIoU 损失函数 (D) 的贡献,结果如表 2 所示。

由表 2 可以看出:单独引入 GSConv 模块 (实验 2) 时,模型参数量由 9.42×10^6 降至 8.46×10^6 ,减少了 10.2%,浮点运算量降低了 12.7%,权重大小减少了 9.8%,验证了该模块的轻量化效果,但 FPS 由 91 降至 88,轻微下降了 3.3%;单独引入 C3k2_PConv2 模块 (实验 3) 同样实现了参数压缩,参数量减少了 7.3%,计算量降低了 3.8%,模型权重大小降低了 7.1%,同时 FPS 提升至 96,相比基线模型提升了 5.5%;单独引入 C2PSA_SENetV2 模块 (实验 4) 时,在轻微轻量化的情况下,将检测精度提升至 97.2%,FPS 提升到 94,证明了注意力机制的有效性;单独引入 UIoU 损失函数 (实验 5) 时,在不增加任何模型参数的前提下,显著提升了检测精度,mAP@0.5 达到 97.4%,同时 FPS 保持 91 不变,展现出损失函数优化的重要作用。

轻量化模块的协同作用亦表现明显:GSConv 与 C3k2_PConv2 的组合 (实验 6) 实现了参数量减少 17.5%、计算量降低 16.4%、检测精度则提升至 97.1%,FPS 提升至 95;在上述两种模块基础上再引入 C2PSA_SENetV2 模块 (实验 7),检测精度进一步提升至 97.3%,同时 FPS 显著提升至 100,相比基线模型提升了 9.9%;将四个模块完整组合 (实验 8),结果显示,通过 UIoU 损失函数的引入,检测精度增至 97.6%,相比基线模型提升了 0.6%,同时实现参数量减少了 19.2%、计算量降低了 16.9%、权重大小减少了 19.1%,FPS 则保持在 100 不变,充分验证了各改进模块的有效性和协同效应。

3.4 对比实验

为进一步验证本文改进模型的有效性,将改进模型与其他主流目标检测模型进行对比,其中 YOLOv5^[19]、YOLOv8^[20]、YOLOv9^[21]、YOLOv10^[22]、YOLO11^[23] 为通用目标检测模型。所有实验均使用相同的训练集与验证集,实验结果如表 3 所示。

表2 消融实验结果
Table 2 Results of ablation experiment

实验序号	模块				mAP@0.5/%	Params/ 10^6	GFLOPs	Weights/ 10^6	FPS
	A	B	C	D					
1					97.0	9.42	21.3	18.3	91
2	√				96.9	8.46	18.6	16.5	88
3		√			97.1	8.73	20.5	17.0	96
4			√		97.2	9.25	21.2	18.0	94
5				√	97.4	9.42	21.3	18.3	91
6	√	√			97.1	7.77	17.8	15.2	95
7	√	√	√		97.3	7.61	17.7	14.8	100
8	√	√	√	√	97.6	7.61	17.7	14.8	100

表3 不同检测模型性能对比

Table 3 Comparison of performance metrics of different detection models

模型	mAP@0.5/%	Params/ 10^6	GFLOPs	Weights/ 10^6	FPS
YOLOv5	96.6	7.03	15.8	13.8	86
YOLOv8	96.8	9.83	23.4	19.0	94
YOLOv9	96.9	9.60	38.7	19.4	54
YOLOv10	97.2	7.22	21.4	15.8	83
YOLO11s	97.0	9.42	21.3	18.3	91
本文模型	97.6	7.61	17.7	14.8	100

由表3可见,本文改进模型在关键指标上均优于对比模型。YOLOv5作为经典版本,其参数量较小,但检测精度偏低;YOLOv8在精度方面有所提升,但参数量和计算复杂度较高;YOLOv9受网络结构复杂化影响,计算量显著增加;YOLOv10检测精度略有提升,但计算量较大;YOLO11s虽然精度有所改善,但参数量和计算量

仍有优化空间。相比之下,本文改进模型在保持良好轻量化特性的同时,实现了最高的检测精度,在番茄叶片病害检测任务中展现出明显的综合优势。

3.5 实验结果可视化分析

为了更直观地验证本文提出模型的检测效果,分别采用YOLO11s原始模型与本文改进模型对番茄叶片病害进行检测,结果如图8所示。




图8 不同模型检测结果对比

Fig. 8 Comparison of detection results with different models

由图8可见,本文改进模型在番茄叶片病害检测任务中表现出显著的性能提升。在单目标检测场景下,改进模型的检测精度普遍得到提高,置信度相比原始模型有明显提升。在复杂背景下的多目标检测任务中,改进模型展现出了更强的检测能力:原始模型在面对边缘小目标叶片时存在明显的检测盲区,往往无法有效识别图像边缘位置的病害叶片,对残缺叶片的检测精度较低,甚至出现漏检现象;本文改进模型成功检测到边缘小目标,在检测精度上有显著提升,能够在复杂植物群体图像中准确识别出更多的病害区域,对残叶和小目标的检测更加全面和准确。本文改进模型在特征提取能力、对小目标的敏感性以及在复杂场景下的适应性等方面均有显著增强,有效解决了原模型在边缘目标检测方面的不足。

4 结论与展望

提出了一种基于改进YOLO11s的轻量化番茄叶片病害检测方法。通过GSConv轻量化卷积模块替换标准卷积模块,降低了模型参数量和计算复杂度;引入C3k2_PConv2模块,有效减少了冗余计算和内存访问量;提出了一种C2PSA_SENetV2模块,增强了通道间信息交互和全局特征表达能力;采用UIoU损失函数,通过动态权重分配策略改善了边界框回归精度。实验结果表明,相比原始模型,本文改进模型的检测精度(mAP@0.5)达到97.6%,提升了0.6%,同时模型参数量减少了19.2%、计算量降低了16.9%、模型权重大小减少了19.1%。

本文研究结果有望为智慧农业中病害监测提供技术支撑;改进模型的轻量化特性使其具备在资源受限环境下应用的潜力;高精度的检测性能可望为农户提供及时准确的病害预警;模型对小目标和边缘病害的有效识别能力可使其在病害早期阶段实现精准诊断,为病害防治争取更多时间。但本研究仍存在一定局限性:使用的数据集主要来源于实验室环境以及温室大棚,与真实田间场景存在一定差异;虽然模型在参数量、计算量和帧率上均有改善,但在极端复杂田间场景下的实时性仍需在真实设备上进一步验证。未来将构建真实田间数据集,进一步优化模型的实时检测性能,并在实际农业设备上部署,为番茄病害智能检测提供技术支撑。

参考文献(References):

- [1] 贾京珠,张天柱.日光温室番茄典型病害及防治措施[J].现代园艺,2020(1):173-174.
- [2] Lecun Y, Bengio Y, Hinton G. Deep learning [J]. Nature, 2015, 521(7553):436-444.
- [3] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]//2014 IEEE Conference on Computer Vision and Pattern Recognition. Columbus, OH, USA: IEEE, 2014: 580-587.
- [4] Ren S Q, He K M, 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.
- [5] Terven J, Córdova-Esparza D M, Romero-González J A. A comprehensive review of YOLO architectures in computer vision: from YOLOv1 to YOLOv8 and YOLO-NAS [J]. Machine Learning and Knowledge Extraction, 2023, 5(4):1680-1716.
- [6] Liu W, Anguelov D, Erhan D, et al. SSD: single shot Multi-Box detector [C]//2016 European Conference on Computer Vision. Amsterdam, The Netherlands: Springer, 2016: 21-37.
- [7] 赵子艺,张德育,徐双成.基于改进YOLOv8的铁路异物检测算法[J].沈阳理工大学学报,2025,44(3):32-38,46. Zhao Z Y, Zhang D Y, Xu S C. Algorithm of railway foreign object intrusion detection based on improved YOLOv8 [J]. Journal of Shenyang Ligong University, 2025, 44(3):32-38,46. (in Chinese)
- [8] 黄志龙.基于改进YOLOv5s的番茄叶片病虫害识别方法[J].电大理工,2024(3):1-7,17.
- [9] 赵艳芹,王萌.改进YOLOv5模型的番茄叶部病害检测算法[J].黑龙江科技大学学报,2023,33(1):136-141. Zhao Y Q, Wang M. Detection of tomato leaf diseases based on improved YOLOv5 model [J]. Journal of Heilongjiang University of Science and Technology, 2023, 33(1):136-141. (in Chinese)
- [10] 吴六爱,许雪珂.基于改进YOLOv10n的轻量化番茄叶片病虫害检测方法[J].智慧农业(中英文),2025,7(1):146-155. Wu L A, Xu X K. Lightweight tomato leaf disease and pest detection method based on improved YOLOv10n [J]. Smart Agriculture, 2025, 7(1):146-155. (in Chinese)
- [11] 吴世琛,毛玉明,胡慧中,等.基于改进YOLO11n的葡萄果叶病害检测方法[J].农业工程学报,2025,41(14):140-147. Wu S C, Mao Y M, Hu H Z, et al. Detecting grape leaf diseases using improved YOLO11n [J]. Transactions of the Chinese Society of Agricultural Engineering, 2025, 41(14):140-147. (in Chinese)
- [12] 黄铭杰,蔡伟强,张子健,等.基于改进YOLO11的荔枝果实品种实时精准识别算法[J].农业工程学报,2025,41(11):156-164. Huang M J, Cai W Q, Zhang Z J, et al. Real-time accurate recognition algorithm for litchi fruit varieties based on improved YOLO11 [J]. Transactions of the Chinese Society of Agricultural Engineering, 2025, 41(11):156-164. (in Chinese)
- [13] Li H L, Li J, Wei H B, 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.
- [14] Wang J, Zhao H. Improved YOLOv8 algorithm for water surface object detection [J]. Sensors, 2024, 24(15):5059.

- [15] Zhang L Y, Wu X, Liu Z H, et al. ESD-YOLOv8: an efficient solar cell fault detection model based on YOLOv8 [J]. IEEE Access, 2024, 12: 138801 – 138815.
- [16] Liu Z G, Sun B S, Bi K Y. Optimization of YOLOv7 based on PConv, SE attention and wise-IoU [J]. International Journal of Computational Intelligence and Applications, 2024, 23: 2350033.
- [17] Hughes D P, Salathé M. An open access repository of images on plant health to enable the development of mobile disease diagnostics [PP/OL]. arXiv (2016 – 04 – 12) [2025 – 08 – 15]. <https://doi.org/10.48550/arXiv.1511.08060>.
- [18] Universitas Atma Jaya. Tomato leaf disease dataset [DS/OL]. Roboflow Universe (2023 – 04 – 01) [2025 – 08 – 15]. <https://universe.roboflow.com/universitas-atma-jaya/tomato-leaf-disease-rxcft>.
- [19] Zhu X K, Lyu S C, Wang X, et al. TPH-YOLOv5: improved YOLOv5 based on transformer prediction head for object detection on drone-captured scenarios [C]//2021 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW). Montreal, QC, Canada: IEEE, 2021: 2778 – 2788.
- [20] Hussain M. YOLOv1 to v8: unveiling each variant; a comprehensive review of YOLO [J]. IEEE Access, 2024, 12: 42816 – 42833.
- [21] Murat A A, Kiran M S. A comprehensive review on YOLO versions for object detection [J]. Engineering Science and Technology, an International Journal, 2025, 70: 102161.
- [22] Ali M L, Zhang Z. The YOLO framework: a comprehensive review of evolution, applications, and benchmarks in object detection [J]. Computers, 2024, 13 (12): 336.
- [23] Sapkota R, Flores-Calero M, Qureshi R, et al. YOLO advances to its genesis: a decadal and comprehensive review of the You Only Look Once (YOLO) series [J]. Artificial Intelligence Review, 2025, 58 (9): 274.

(责任编辑:宋颖韬)

(上接第41页)

- [16] Rao D Y, Xu T Y, Wu X J. TGFuse: An infrared and visible image fusion approach based on transformer and generative adversarial network [J]. IEEE Transactions on Image Processing, 2023, PP (99): 1.
- [17] Zhao Z X, Xu S, Zhang C X, et al. DIDFuse: deep image decomposition for infrared and visible image fusion [C]//2020 29th International Joint Conference on Artificial Intelligence (IJCAI). Yokohama, Japan: IJCAI Organization, 2020: 970 –

976.

- [18] Li H, Wu X J. DenseFuse: a fusion approach to infrared and visible images [J]. IEEE Transactions on Image Processing, 2019, 28 (5): 2614 – 2623.
- [19] Li H, Wu X J, Durrani T. NestFuse: an infrared and visible image fusion architecture based on nest connection and spatial/channel attention models [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69 (12): 9645 – 9656.

(责任编辑:和晓军)

(上接第49页)

- [7] Awad N H, Ali M Z, Suganthan P N. Ensemble sinusoidal differential covariance matrix adaptation with Euclidean neighborhood for solving CEC2017 benchmark problems [C]//2017 IEEE Congress on Evolutionary Computation (CEC). Donostia, Spain: IEEE, 2017: 372 – 379.
- [8] Zhang G, Liu H C, Zhang J B, et al. Wind power prediction based on variational mode decomposition multi-frequency combinations [J]. Journal of Modern Power Systems and Clean Energy, 2019, 7 (2): 281 – 288.
- [9] Van Houdt G, Mosquera C, Nápoles G. A review on the long short-term memory model [J]. Artificial Intelligence Review, 2020, 53 (8): 5929 – 5955.
- [10] Zhong C T, Li G, Meng Z, et al. Starfish optimization algorithm (SFOA): a bio-inspired metaheuristic algorithm for global optimization compared with 100 optimizers [J]. Neural Computing and Applications, 2025, 37 (5): 3641 – 3683.
- [11] Oueslati R, Ouertani M W, Amdouni A, et al. MS-FSOA-LightGBM: multi-strategy starfish optimization algorithm with LightGBM for software defect prediction [J]. Procedia Computer Science, 2025, 270: 4054 – 4063.
- [12] Liu S L, Jin Z K, Lin H T, et al. An improve crested porcupine algorithm for UAV delivery path planning in challenging environments [J]. Scientific Reports, 2024, 14: 20445.

- [13] Abdollahpour A, Rouhi A, Pira E. An improved gazelle optimization algorithm using dynamic opposition-based learning and chaotic mapping combination for solving optimization problems [J]. The Journal of Supercomputing, 2024, 80 (9): 12813 – 12843.
- [14] 尚凯凯. 融合扰动策略的自适应哈里斯鹰优化算法 [J]. 计算机与数字工程, 2025, 53 (2): 338 – 346.
- Shang K K. Adaptive Harris Hawks optimization algorithm based on disturbance strategies [J]. Computer and Digital Engineering, 2025, 53 (2): 338 – 346. (in Chinese)
- [15] Mirjalili S, Lewis A. The whale optimization algorithm [J]. Advances in Engineering Software, 2016, 95: 51 – 67.
- [16] Hashim F A, Hussain K, Houssein E H, et al. Archimedes optimization algorithm: a new metaheuristic algorithm for solving optimization problems [J]. Applied Intelligence, 2021, 51 (3): 1531 – 1551.
- [17] Amiri M H, Mehrabi Hashjin N, Montazeri M, et al. Hippopotamus optimization algorithm: a novel nature-inspired optimization algorithm [J]. Scientific Reports, 2024, 14: 5032.
- [18] Guan Y M, Shi Y L, Wang G, et al. Electricity behaviors anomaly detection based on multi-feature fusion and contrastive learning [J]. Information Systems, 2025, 127: 102457.

(责任编辑:和晓军)