

基于改进 YOLO v7 的花生表面缺陷智能检测方法

田博轩

(山西农业大学, 山西 晋中 030031)

摘要: [目的] 针对花生表面瑕疵多态性强、传统视觉检测方法精度不足的问题, 提出一种基于改进 YOLO v7 的智能缺陷检测方法。[方法] 通过融合跨通道注意力机制强化局部特征响应, 构建双向特征金字塔增强多尺度缺陷融合, 并引入角度约束损失函数优化不规则目标定位, 结合工业级样本库与数据增强策略优化模型。[结果] 改进模型在测试集上的精确率为 0.917、召回率为 0.903、 $P_i@0.5$ 为 0.948、 $P_i@[0.5:0.95]$ 为 0.705, 推理速度为 74.166 帧/s, 性能显著优于其他模型。消融试验表明, 多尺度注意力融合模块对细粒度特征识别贡献度最高。[结论] 该方法兼顾检测精度与实时性, 有效解决了表面纹理复杂、缺陷尺度差异大等难题, 实现了花生表面缺陷的智能检测。

关键词: 智能质检; 目标检测; YOLO v7; 花生; 缺陷识别

Intelligent defect detection on peanut surfaces based on improved YOLO v7

TIAN Boxuan

(Shanxi Agricultural University, Jinzhong, Shanxi 030031, China)

Abstract: [Objective] To propose an intelligent defect detection method based on an improved YOLO v7 model for the challenges of strong polymorphism in peanut surface defects and insufficient accuracy of traditional visual inspection methods. [Methods] A cross-channel attention mechanism is integrated to enhance local feature response. Then, a bidirectional feature pyramid is constructed to improve multi-scale defect fusion. Additionally, an angle constraint loss function is introduced to optimize irregular object localization. Furthermore, the model is optimized using an industrial-grade sample library combined with data augmentation strategies. [Results] The improved model achieves a precision of 0.917, a recall of 0.903, $P_i@0.5$ of 0.948, and $P_i@[0.5:0.95]$ of 0.705 on the test set, with an inference speed of 74.166 frames per second, significantly outperforming other models. Ablation experiments indicate that the MSAM module contributes most to fine-grained feature recognition. [Conclusion] The proposed method balances detection accuracy and real-time performance, effectively overcoming challenges such as complex surface textures and significant defect scale variation. The proposed method provides an efficient solution for intelligent defect inspection on peanut surfaces.

Keywords: intelligent quality inspection; object detection; YOLO v7; peanut; defect recognition

农业智能化进程的加速推进, 促使花生等农产品的品质检测逐步向自动化方向升级。作为重要的油料作物, 花生表面缺陷呈现多类型、多形态的特征, 这对检测系统的识别精度与稳定性提出了更高要求。尽管 YOLO v7 作为主流检测模型在实时性和准确性方面表现突出, 但在处理花生表面复杂缺陷时仍面临特征提取不充分和识别精度不足等挑战^[1-2]。

农产品表面缺陷检测领域的研究近年来取得显著突破, 图像分析与深度学习技术的融合成为推动检测精度

提升的关键驱动力。在传统方法层面, 研究者通过颜色、形态学及纹理特征分析构建检测框架, 如采用阈值分割技术定位苹果腐烂区域^[3], 或基于小波变换提取柑橘表面黑斑特征^[4]。但此类方法受光照条件和背景噪声影响显著, 在缺陷尺度多变、形态不规则的工业场景中泛化能力受限。随着目标检测算法的演进, 以 YOLO 系列、Faster R-CNN 及 RetinaNet 为代表的深度学习架构逐步渗透至该领域^[5-6]。其中, 基于 YOLO v4 的番茄病斑检测系统实现了超高的识别准确率^[7-8], 而引入特征金字塔的

通信作者: 田博轩 (2003—), 男, 山西农业大学在读本科生。E-mail: 13111064042@163.com

收稿日期: 2025-04-15 改回日期: 2025-11-21

引用格式: 田博轩. 基于改进 YOLO v7 的花生表面缺陷智能检测方法[J]. 食品与机械, 2026, 42(3): 105-110.

Citation: TIAN Boxuan. Intelligent defect detection on peanut surfaces based on improved YOLO v7[J]. Food & Machinery, 2026, 42(3): 105-110.

Faster R-CNN 变体在苹果表面损伤分类任务中也取得了显著成效。然而,现有研究对花生这类表面褶皱密集、缺陷边界模糊的作物关注度不足:多数方法直接套用通用网络结构^[9-10],未针对微小缺陷和局部形变区域进行模型优化,导致实际检测中出现漏检与误判。现有文献^[11-12]普遍聚焦于精度指标优化,而对模型实时性、鲁棒性及部署可行性考虑不足,难以同时满足工业应用中高效与高精度的双重要求。

针对现有方法在微小缺陷识别、多尺度特征融合与边界框回归方面的不足,研究拟提出一种基于改进 YOLO v7 框架的花生表面缺陷检测方法,重点提升模型对微小缺陷、边缘模糊目标及多类别缺陷的辨识能力。通过引入多尺度注意力机制增强特征选择性,优化特征金字塔融合路径改善多尺度信息传递,并设计具有角度感知能力的损失函数,系统性地提升模型对复杂缺陷的表征能力,以期农产品质量检测提供兼具高效性与鲁棒性的智能解决方案。

1 研究设计

1.1 数据来源与预处理

试验数据来源于中国某花生加工龙头企业,通过产线部署的图像采集系统实时获取,全面覆盖分选环节中出现的裂纹、霉变、虫蛀、污渍等典型花生表面缺陷。图像采集采用 1 920 像素×1 080 像素的工业级相机,确保缺陷微观特征的完整捕捉,满足改进 YOLO v7 模型对高分辨率输入的需求。标注工作使用 LabelImg 工具进行人工标注,严格记录缺陷类别与其在图像中的边界框信息。针对数据分布不均衡问题,研究采用随机水平翻转、亮度调整、高斯模糊、图像旋转及椒盐噪声增强等处理方法。最终构建的数据集包含 2 987 张训练图像、517 张验证图像与 496 张测试图像,全面覆盖不同缺陷形态与复杂背景组合。

图像预处理阶段采用双阶段标准化流程:先将原始图像双线性插值缩放至 640 像素×640 像素,满足 YOLO v7 网络输入规格;随后执行线性归一化操作,将像素值映射至[0,1]区间以优化模型训练效率。针对工业现场光照不均问题,应用自适应直方图均衡化(CLAHE)对图像进行对比度增强,通过抑制背景干扰突出缺陷区域纹理特征。

1.2 改进 YOLO v7 模型构建

为提升 YOLO v7 在花生表面缺陷检测中的精度与鲁棒性,从特征提取、特征融合与目标框定位 3 个方面进行系统性优化,通过引入多尺度注意力融合模块(MSAM)、构建改进的 FPN+BiFPN 路径结构,并结合方向敏感的 SiouU 边界框回归损失函数,构建了一种适用于复杂表面缺陷识别任务的改进检测模型。

1.2.1 MSAM 将 MSAM 模块嵌入 YOLO v7 主干网络各尺度特征图的输出端,融合 SE 通道注意力与 CBAM 空间注意力机制,并在不同尺度间引入跨尺度并联融合,以增强模型的细粒度特征表达能力。

输入特征图 $F \in \mathbf{R}^{C \times H \times W}$ 首先通过通道注意力增强。使用全局平均池化与最大池化分别生成两个通道描述子:

$$p_{a,c} = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W F_{c,i,j}, \quad (1)$$

$$p_{m,c} = \max_{i,j} F_{c,i,j}, \quad (2)$$

式中:

$F_{c,i,j}$ ——输入特征图中第 c 个通道在位置 (i,j) 的特征值;

H ——特征图高度,像素;

W ——特征图宽度,像素;

$p_{a,c}$ ——第 c 个通道的平均池化结果;

$p_{m,c}$ ——第 c 个通道的最大池化结果。

将二者输入共享的 MLP 后,经 Sigmoid 激活获得通道权重向量 $w_c \in \mathbf{R}^{C \times 1 \times 1}$,用于通道重标定:

$$F' = w_c \odot F, \quad (3)$$

式中:

F ——输入特征图;

F' ——通道重标定后的输出特征图;

w_c ——通道权重向量(用于对各通道特征进行加权)。

然后,将 F' 输入空间注意力模块,先进行通道维平均池化与最大池化:

$$f_a = \frac{1}{C} \sum_{c=1}^C F'_c, \quad (4)$$

$$f_m = \max_{c=1,\dots,C} F'_c, \quad (5)$$

式中:

F'_c ——通道重标定后的第 c 个通道特征图;

C ——通道数;

f_a ——通道平均池化结果;

f_m ——通道最大池化结果。

拼接后送入 7×7 卷积与 Sigmoid 激活,生成空间注意力图 $M_s \in \mathbf{R}^{1 \times H \times W}$:

$$a_s = \sigma(f^{7 \times 7}([f_a; f_m])), \quad (6)$$

$$F'' = a_s \odot F', \quad (7)$$

式中:

a_s ——空间注意力图;

$f^{7 \times 7}(\cdot)$ —— 7×7 卷积操作;

$\sigma(\cdot)$ ——Sigmoid 激活函数;

F'' ——经空间注意力重标定后的输出特征图。

最终,将多个尺度下的 F'' 进行拼接后,统一通道维度并输出增强特征图:

$$F_M = \text{Conv}_{1 \times 1}(\text{Concat}(F''_1, F''_2, F''_3)), \quad (8)$$

式中:

F''_1, F''_2, F''_3 ——不同尺度下经空间注意力模块处理后的特征图;

$\text{Concat}(\cdot)$ ——特征拼接操作;

$\text{Conv}_{1 \times 1}(\cdot)$ —— 1×1 卷积操作(用于通道融合);

F_M ——MSAM 输出的特征图。

通过在局部注意力增强的同时引入尺度间语义补充, MSAM 提升了模型对微小缺陷区域的显著性建模能力。

1.2.2 改进特征融合路径: FPN+BiFPN 结构 FPN+BiFPN 结构在 YOLO v7 原始特征金字塔基础上, 引入双向路径与融合权重学习机制, 重构多尺度信息传递流程, 提升浅层边缘特征与高层语义特征的集成效率。

对于同一尺度输出节点, 其融合方式:

$$\hat{P}_i = \frac{\sum_{j \in \Omega_i} w_j \cdot P_j}{\sum_{j \in \Omega_i} w_j + \epsilon}, \quad (9)$$

式中:

$\hat{P}_i$ ——第 i 层节点的所有输入特征图集合;

Ω_i ——第 i 层节点的所有输入特征图索引集合;

P_j ——输入特征;

w_j ——可学习权重;

ϵ ——常数稳定项。

权重 w_j 经过 ReLU 激活函数处理后, 保证其值 ≥ 0 (即保持非负性)。

在网络构建中, BiFPN 模块采用三类连接:

- (1) 自顶向下路径: 从高层语义图向下采样接入。
- (2) 自底向上路径: 将低层结构信息向上传递。
- (3) 横向路径: 连接相邻尺度以维持连续性。

为减少计算负担, BiFPN 内部所有卷积操作均替换为深度可分离卷积, 并仅对 C3~C5 进行融合。该结构通过节点级加权特征融合实现信息自适应整合, 使模型在保持检测速度的同时, 获得更优的尺度泛化能力与特征分离度。

1.2.3 自定义角度敏感型 SIOU 损失函数 SIOU 损失函数在边界框回归过程中引入形状偏差、距离误差与方向差异的综合衡量项, 较传统 CIoU 更适用于非矩形与旋转目标检测。其损失函数:

$$L_{\text{SIOU}} = 1 - I_{\text{ou}} + \alpha \cdot \Delta_d + \beta \cdot \Delta_s + \gamma \cdot \Delta_\theta, \quad (10)$$

式中:

I_{ou} ——预测框与真实框的交并比;

α, β, γ ——3 个偏差项的权重系数;

Δ_d ——距离偏差项;

Δ_s ——形状偏差项;

Δ_θ ——角度偏差项, rad。

3 个偏差项分别定义为:

距离误差项:

$$\Delta_d = \frac{\|c_p - c_g\|_2^2}{d^2}, \quad (11)$$

式中:

Δ_d ——距离偏差度量项;

c_p ——预测框中心坐标, 像素;

c_g ——真实框中心坐标, 像素;

d ——预测框与真实框外接矩形的对角线长度, 像素。

形状偏差项:

$$\Delta_s = \left(1 - \frac{w_p}{w_g}\right)^2 + \left(1 - \frac{h_p}{h_g}\right)^2, \quad (12)$$

式中:

Δ_s ——形状偏差项;

w_p ——预测框的宽度, 像素;

w_g ——真实框的宽度, 像素;

h_p ——预测框的高度, 像素;

h_g ——真实框的高度, 像素。

方向角误差项:

$$\Delta_\theta = 1 - \cos(\theta_p - \theta_g), \quad (13)$$

式中:

Δ_θ ——方向角误差项;

θ_p ——预测框主轴方向角, rad;

θ_g ——真实框主轴方向角, rad。

权重超参数经试验调优设为: $\alpha=0.3, \beta=0.4, \gamma=0.3$ 。

该损失函数能够在训练过程中有效引导网络优化具有角度偏移和形态畸变的目标预测框, 使检测模型更具几何适应能力。

1.3 评价指标

为全面评估改进 YOLO v7 模型在花生表面缺陷检测任务中的性能, 从检测准确性、缺陷识别完整性、综合判别能力以及运行实时性 4 个方面对模型进行了系统分析与比较, 力求在保证识别精度的同时兼顾模型的实际部署效率和工业适用性。

1.3.1 精确率 (precision) 精确率衡量的是模型预测为缺陷的样本中实际为缺陷的比例, 计算式为:

$$P = \frac{c_p}{c_p + c_f}, \quad (14)$$

式中:

P ——精确率;

c_p ——正确识别为缺陷的样本数量;

c_f ——被错误识别为缺陷的正常样本数量。

1.3.2 召回率 (recall) 召回率表示模型对实际缺陷样本的识别能力, 计算式为:

$$R = \frac{c_p}{c_p + c_m}, \quad (15)$$

式中:

R ——召回率;

c_m ——模型未能识别出的真实缺陷样本数量。

1.3.3 平均精度均值 (mAP) mAP 是衡量目标检测模型综合性能的核心指标, 计算过程中首先在不同 IoU (intersection over union) 阈值下计算各类别的平均精度 (AP), 再取所有类别的平均值。具体而言, AP 可定义为精确率—召回率 (precision-recall) 曲线下的面积, 其数学表达为:

$$P_a = \int_0^1 p(r) dr, \quad (16)$$

式中:

$p(r)$ ——精确率关于召回率的函数;

r ——召回率;

P_a ——单一类别的平均精度。

所有类别的 AP 取平均即可得到 mAP:

$$P_t = \frac{1}{N} \sum_{i=1}^N P_{a,i} \quad (17)$$

式中:

$P_{a,i}$ ——第 i 类目标的平均精度;

N ——总类别数;

P_t ——所有类别平均精度的均值。

采用两种常用的 P_t 评估指标:① 在交并比(I_{ou})阈值为 0.5 时计算得到的平均精度($P_t@0.5$);② 在 I_{ou} 阈值从 0.5 到 0.95(步长为 0.05)的 10 个不同阈值下分别计算得到的平均精度均值($P_t@[0.5:0.95]$)。结合这两种评估指标,可以从整体准确性与局部精确性两方面全面评估目标检测模型的综合性能。

1.3.4 帧率(FPS) FPS 用于评估模型的推理速度,即每秒可处理图像的帧数。由于花生表面缺陷检测常应用于自动化分选流水线上,检测速度直接影响生产效率,因此 FPS 是衡量模型实时性能的关键指标。

2 研究结果与分析

2.1 改进 YOLO v7 性能分析

2.1.1 收敛分析 试验硬件配置为 NVIDIA GeForce RTX 3090 GPU (24 GB 显存)、Intel i9-12900K CPU 及 32 GB DDR4 内存,运行于 Ubuntu 20.04 LTS 操作系统,软件环境基于 PyTorch 1.12.0 框架, CUDA 11.6 与 cuDNN 8.4.0 加速库,编程语言为 Python 3.8。改进 YOLO v7 模型在训练集(2 987 张图像)和验证集(517 张图像)上进行评估。由图 1 可知,改进模型在前 30 轮呈现更快的损失下降趋势,表明其能更高效地捕捉样本特征,完成初步的目标识别能力构建。

原始 YOLO v7 模型的训练收敛速率相对滞后,前 50 轮内损失值持续处于高波动状态。改进模型的损失曲线在第 80 轮进入平稳收敛阶段,至第 180 轮后基本稳定,整体波动幅度显著低于原始模型。试验对比表明,原始模型在相同训练轮次下仍存在周期性波动现象,说明其在特征表达能力与参数更新策略上的局限性。改进模型通过引入多尺度注意力机制与优化特征融合路径,在训练末期达到更低的稳定损失值,验证了结构改进对边界定位精度的提升效果。相较之下,原始模型受限于单一特征提取模式,难以突破最终收敛精度的瓶颈。

2.1.2 与其他模型对比 为系统评估改进 YOLO v7 模型在花生表面缺陷检测任务中的性能提升效果,选取 3 种主流检测模型(YOLO v7、Faster R-CNN 及 EfficientDet-D1)




图 1 收敛分析曲线

Figure 1 Convergence analysis curves

在包含 496 张花生缺陷图像的测试集上进行对比。原始 YOLO v7 作为基线模型,能够直观反映结构优化的有效性;Faster R-CNN 作为二阶段检测器的代表,可提供理论精度上限参考;而 EfficientDet-D1 凭借复合缩放策略,在精度与计算效率间取得平衡,适用于工业部署与边缘设备应用。三者分别从结构精度性、部署适应性和改进前后对比等维度构成了具有代表性的参照系,试验结果见表 1。

表 1 模型对比结果

Table 1 Model comparison results

模型结构	精确率	召回率	$P_t@0.5$	$P_t@[0.5:0.95]$	帧率/s ⁻¹
改进 YOLO v7	0.941	0.928	0.958	0.821	71.248
YOLO v7	0.902	0.881	0.919	0.763	72.005
Faster R-CNN	0.913	0.897	0.932	0.782	19.388
EfficientDet-D1	0.891	0.874	0.909	0.751	46.112

改进 YOLO v7 模型在检测精度指标上全面领先,其精确率(0.941)与召回率(0.928)较原始模型分别提升 0.039 和 0.047,证明其结构改进有效增强了模型特征感知能力。MSAM 通过同步优化通道权重与空间注意力,显著提升模型对微小缺陷及边缘模糊区域的特征捕获能力;改进的 FPN+BiFPN 特征融合路径则强化了跨层级语义交互,使模型能协同利用局部形态特征与全局上下文信息,从而提升检测结果的完整性和定位精度。

精度评估显示,改进模型在 $P_t@0.5$ 和 $P_t@[0.5:0.95]$ 指标分别达到 0.958 与 0.821,相较于对比模型提升显著,验证了其在不同 IoU 阈值下缺陷定位的鲁棒性。通过引入角度敏感型 SIoU 损失函数,模型对旋转类及不规则缺陷目标回归精度显著提高,增强了花生表面复杂缺陷几何形态的适应性。检测效率方面,改进模型实现 71.248 帧/s 的推理速度,与原始 YOLO v7 的 72.005 帧/s 基本持平,远超 Faster R-CNN (19.388 帧/s) 和 EfficientDet-D1 (46.112 帧/s)。该结果表明,模型在保持轻量化计算的同

时实现结构优化,继承了YOLO系列的单阶段检测效率优势。在工业级实时性要求下,改进方案实现了精度与速度的协同提升,满足产线高速质检需求。

2.2 消融试验

为量化评估各改进模块的性能增益,以测试集设计了基于模块去除策略的消融试验。研究通过逐步移除MSAM、改进特征融合结构(BiFPN)以及自定义角度敏感损失函数(SIoU),同时维持其他结构固定,系统分析各模块对检测精度与推理速度的影响差异,试验结果见表2。

表2 消融试验结果

Table 2 Ablation experiment results

模型结构	精确率	召回率	$P_i@0.5$	$P_i@[0.5:0.95]$	帧率/s ⁻¹
最终模型(全部模块)	0.917	0.903	0.948	0.705	74.166
去除MSAM	0.896	0.882	0.925	0.675	75.318
去除BiFPN	0.903	0.890	0.932	0.684	75.745
去除SIoU	0.902	0.888	0.930	0.681	75.998

综合检测性能评估显示,完整改进模型的精确率(0.917)、召回率(0.903)、 $P_i@0.5$ (0.948)及 $P_i@[0.5:0.95]$ (0.705)均达最优水平,说明了多模块协同优化的必要性。试验表明,移除任一模块均会导致精度指标下降,验证了各模块在模型结构中的实际有效性。

MSAM模块移除导致精确率(0.896)、召回率(0.882)、 $P_i@0.5$ (0.925)和 $P_i@[0.5:0.95]$ (0.675)全面下降。该结果表明,MSAM通过通道与空间注意力协同机制,增强模型对细粒度纹理和低对比度缺陷的特征表征能力,成为性能提升的核心模块。在此基础上,BiFPN模块进一步增强了模型的多尺度特征融合能力。BiFPN模块的缺失使 $P_i@0.5$ 与 $P_i@[0.5:0.95]$ 下降至0.932和0.684,该模块通过优化特征金字塔的跨层级交互,提升模型对多尺度缺陷的检测一致性。SIoU损失函数移除导致 $P_i@0.5$ 与 $P_i@[0.5:0.95]$ 降至0.930和0.681。虽然性能下降幅度略小于MSAM与BiFPN,但通过优化预测框形状建模与方向对齐机制,有效降低了复杂背景下的框偏移与重叠误判概率。

在模型运行效率分析中,随着改进模块的逐步叠加,帧率呈小幅下降的趋势。试验数据显示,集成全部优化模块后的帧率为74.166 s⁻¹,略低于移除MSAM、BiFPN和SIoU模块后的数值(帧率分别为75.318, 75.745, 75.998 s⁻¹)。这种参数波动本质上源于模块结构的复杂度增量:MSAM通过双层注意力机制实现了通道特征与空间特征的协同优化,BiFPN借助加权节点与双向传播路径增强了多尺度特征的融合效能,SIoU度量函数则通过几何约束优化改进了检测框的回归精度。尽管上述技术改进带来了额外的计算负载,但系统整体仍维持着工业

级实时检测的精度要求,充分验证了算法优化与计算效率之间的平衡性。

2.3 花生检测结果

图2展示了测试集中496张花生表面缺陷图像的识别结果区域分布特征。试验采用10×10网格划分策略,各单元格作为独立检测单元,基于灰度编码系统实现缺陷类型可视化。检测图谱中,裂纹缺陷、霉变区域、虫蛀部位及污渍样本分别以B、C、D、E类表示,未检出缺陷的正常区域为A类。该标注方式构建了直观的缺陷分布图,有效呈现了不同类别异常在空间维度上的聚集特性。

识别结果显示,模型在多个区域成功输出了明确的缺陷类型,实现了精确的缺陷定位与分类,验证了其对应空间分布差异的适应能力。图中显示出的多样性缺陷分布特征进一步验证了模型的识别广度,能够有效区分形态、材质及纹理各异的缺陷目标,各类缺陷在空间分布上未出现明显偏倚或空白区域,表明模型具有均衡的类型识别能力和全域覆盖特性。部分区域同类缺陷呈现聚集现象,这反映了模型对局部特征模式的敏感响应,该特性有助于识别工业场景中的批次缺陷或局部污染问题。针对裂纹和虫蛀等边界复杂的缺陷,模型仍保持稳定的检测输出,证明其具备良好的几何特征解析能力。




图2 缺陷类型分布图

Figure 2 Defect type distribution

为进一步展示改进YOLOv7模型在花生表面缺陷检测任务中的性能,图3呈现了部分代表性测试样本的检测结果。图中利用矩形边界框标注了裂纹(crack)、霉变(moldy)、虫蛀(hole)及污渍(stain)4种缺陷类型。观测结果表明,该模型在复杂背景干扰及缺陷形态多样性的条件下,仍能实现精确的目标定位与分类。特别是在裂纹细节的捕捉和虫蛀区域的识别方面,模型表现出优异性能。此可视化结果有力地证实了所提方法在实际工业应用场景中的可行性与有效性。



图 3 花生表面缺陷检测效果图

Figure 3 Defect detection results of peanut surfaces

3 结论

为解决花生表面多形态缺陷检测中存在的特征提取不足、边界模糊和尺度不一致等问题,该研究提出了一种基于改进 YOLO v7 模型的智能识别方法。该方法通过多尺度注意力融合模块(MSAM)、改进 FPN+BiFPN 特征融合结构和引入方向敏感的 Siou 损失函数,有效提升了模型对复杂缺陷的识别能力与定位精度。改进 YOLO v7 模型在检测精度、召回率及平均精度均值等核心指标上均优于 YOLO v7、Faster R-CNN 和 EfficientDet 等主流算法,在裂纹与虫蛀等细粒度缺陷的识别方面表现突出;推理速度达 74.166 帧/s,满足工业自动质检对实时性的需求。消融试验进一步验证了各模块对模型性能的正向贡献,其中 MSAM 对微小缺陷特征的增强作用最为显著。该方法兼顾检测精度与计算效率,在农产品智能质检领域具有良好的应用前景。未来研究将聚焦模型在不同作物间的迁移能力以及多模态融合策略的拓展,以进一步提升系统的通用性与鲁棒性。

参考文献

- [1] 张明华, 黄基萍, 宋巍, 等. 基于 UMS-YOLO v7 的面向样本不均衡的水下生物多尺度目标检测方法[J]. 农业机械学报, 2025, 56(1): 388-396, 409.
ZHANG M H, HUANG J P, SONG W, et al. Multi-scale object detection method for underwater organisms under unbalanced samples based on UMS-YOLO v7[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(1): 388-396, 409.
- [2] 杨哲宇, 于航. 基于改进 YOLO v7 的斜盘表面小面积缺陷检测方法[J]. 南方农机, 2024, 55(24): 129-133.
YANG Z Y, YU H. Small-area defect detection method for swash plate surface based on improved YOLO v7[J]. Southern Agricultural Machinery, 2024, 55(24): 129-133.
- [3] HASAN S, JAHAN S, ISLAM M I. Disease detection of apple leaf with combination of color segmentation and modified DWT

- [J]. Journal of King Saud University-Computer and Information Sciences, 2022, 34(9): 7 212-7 224.
- [4] 李大华, 孔舒, 李栋, 等. 基于改进 SSD 模型的柑橘叶片病害轻量化检测模型[J]. 浙江农业学报, 2024, 36(3): 662-670.
LI D H, KONG S, LI D, et al. Lightweight detection model of citrus leaf disease based on improved SSD[J]. Acta Agriculturae Zhejiangensis, 2024, 36(3): 662-670.
- [5] 鄢紫, 陈良艳, 刘卫华, 等. 基于 YOLO-FFD 的水果品种和新鲜度识别方法[J]. 食品与机械, 2024, 40(1): 115-121.
YAN Z, CHEN L Y, LIU W H, et al. Fruit variety and freshness recognition method based on YOLO-FFD[J]. Food & Machinery, 2024, 40(1): 115-121.
- [6] ZHANG T, WANG Z H, LI F W, et al. Automatic detection of surface defects based on deep random chains[J]. Expert Systems with Applications, 2023, 229: 120472.
- [7] 刘建航, 何鉴恒, 陈海华, 等. 基于改进 YOLO v4 和 ICNet 的番茄串检测模型[J]. 农业机械学报, 2023, 54(10): 216-224, 254.
LIU J H, HE J H, CHEN H H, et al. Development of detection model for tomato clusters based on improved YOLO v4 and ICNet[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(10): 216-224, 254.
- [8] 李天华, 孙萌, 丁小明, 等. 基于 YOLO v4+HSV 的成熟期番茄识别方法[J]. 农业工程学报, 2021, 37(21): 183-190.
LI T H, SUN M, DING X M, et al. Tomato recognition method at the ripening stage based on YOLO v4 and HSV[J]. Transactions of the Chinese Society of Agricultural Engineering, 2021, 37(21): 183-190.
- [9] 皮卫, 屈喜龙, 王绍成, 等. 基于改进 CNN 和数据扩充的苹果表面缺陷检测[J]. 食品与机械, 2023, 39(8): 122-128, 226.
PI W, QU X L, WANG S C, et al. Apple surface defect detection based on improved CNN and data augmentation[J]. Food & Machinery, 2023, 39(8): 122-128, 226.
- [10] 刘亚恒. 基于改进 Faster R-CNN 苹果叶部病害检测方法研究[D]. 汉中: 陕西理工大学, 2022: 7-18.
LIU Y H. Study on apple leaf diseases detection method based on improved Faster R-CNN[D]. Hanzhong: Shaanxi University of Technology, 2022: 7-18.
- [11] 梁源林, 黄爱清, 吴健豪, 等. 基于改进 YOLOv5 的菌菇检测及分类模型研究[J]. 仲恺农业工程学院学报, 2025, 38(1): 20-27.
LIANG Y L, HUANG A Q, WU J H, et al. Research on mushroom detection and classification model based on improved YOLOv5[J]. Journal of Zhongkai University of Agriculture and Engineering, 2025, 38(1): 20-27.
- [12] 张东彦, 高玥, 程涛, 等. 基于 YOLOv8-FECA 的密集场景下小麦赤霉病孢子目标检测[J]. 农业工程学报, 2024, 40(21): 127-136.
ZHANG D Y, GAO Y, CHENG T, et al. Detection of wheat scab spores in dense scene based on YOLOv8-FECA[J]. Transactions of the Chinese Society of Agricultural Engineering, 2024, 40(21): 127-136.