

# 基于改进 YOLO v11 的番茄表面缺陷检测方法

朱婷婷<sup>1</sup> 滕广<sup>1</sup> 张亚军<sup>1</sup> 倪超<sup>1</sup> 何惠彬<sup>2</sup>

(1. 南京林业大学机械电子工程学院, 南京 210037; 2. 福建省机械科学研究院, 福州 350005)

**摘要:** 传统的番茄缺陷检测主要依赖于人工分拣, 存在效率低、漏检率高等问题。为此, 提出了一种改进的 YOLO v11 番茄缺陷检测方法 TDD-YOLO (Tomato defect detection YOLO), 实现对番茄表面白斑、增生、凹陷、裂口、变质 5 种缺陷的自动检测。首先, 融合小波深度可分离卷积模块构建新的 HE-Head 层, 在保持模型轻量化的同时提升模型对小目标的检测能力(如白斑); 其次, 使用 WC3k2 模块替换原有 C3k2 模块, 扩大模型在特征提取阶段的感受野, 同时使用动态上采样方法取代原有的上采样, 实现对模型推理效率的提升和轻量化; 最后, 使用自适应阈值焦点损失函数加强对样本的关注度, 提高识别精度。设计实验验证所提方法性能, 实验结果表明本文所提的 TDD-YOLO 模型番茄表面缺陷整体识别精度为 89.0%、召回率为 84.9%、F1 分数为 86.9%、平均精度均值为 88.0%, 识别效果明显优于现有的 YOLO 系列模型以及 Faster R-CNN 和 EfficientDet 模型。此外, TDD-YOLO 模型检测速度为 142.89 f/s, 满足实时检测速度要求, 为番茄检测规范化和工业化提供重要技术支撑。

**关键词:** 番茄; 缺陷检测; YOLO v11; 小波深度可分离卷积; 深度学习

中图分类号: TP391

文献标识码: A

文章编号: 1000-1298(2025)06-0546-08

OSID:



## Improved YOLO v11 Method for Surface Defect Detection of Tomato

ZHU Tingting<sup>1</sup> TENG Guang<sup>1</sup> ZHANG Yajun<sup>1</sup> NI Chao<sup>1</sup> HE Huibin<sup>2</sup>

(1. College of Mechanical and Electronic Engineering, Nanjing Forestry University, Nanjing 210037, China

2. Fujian Academy of Mechanical Sciences, Fuzhou 350005, China)

**Abstract:** Tomatoes are a globally important economic crop with a wide planting area. In order to ensure tomato food safety and improve the economic benefits of tomatoes, accurate surface defect detection and quality grading of tomatoes are necessary. However, traditional tomato defect detection mainly relies on manual sorting during harvesting, which results in low efficiency and high missed detection rate. What's more, new defects generated during procurement and transportation (such as dents, cracks, etc.) would be ignored. Therefore, an improved YOLO v11 method (Tomato defect detection YOLO, TDD-YOLO) was proposed for surface defect detection of tomatoes automatically, including white spot, hyperplasia, depression, crack, and deterioration. Firstly, a HE-Head layer of the YOLO 11 was constructed by fusing the wavelet depth separable convolution module to detect small targets, such as white spot, while maintaining its lightweight design. Secondly, the WC3k2 module was used to replace the original C3k2 module of YOLOv 11 to expand the receptive field of the model in the feature extraction stage, and a lightweight dynamic upsampling method was used to replace the original upsampling. These two improvements of YOLO v11 were to reduce the number of parameters and improve the real-time performance. Finally, an adaptive threshold focus loss function was used to improve the model's attention to various classification label samples in response to the diversity and complexity of tomato surface defect types and distributions. Several experiments were carried out to evaluate the performance of the proposed method. The experimental results showed that the proposed TDD-YOLO method effectively improved the detection accuracy while keeping the model parameters basically unchanged. The overall recognition precision was 89.0% and the recall rate was 84.9%, which was increased by 2.9 percentage points and 5.6 percentage points comparing with that of YOLO v11, respectively. In comparative experiments, the proposed model had better detection performance than all published YOLO

收稿日期: 2025-01-08 修回日期: 2025-02-17

基金项目: 福建省技术创新重点攻关及产业化项目(2023G015)

作者简介: 朱婷婷(1989—), 女, 副教授, 博士, 主要从事无损检测与农林信息化研究, E-mail: tingtingzhu@njfu.edu.cn

通信作者: 倪超(1979—), 男, 教授, 博士, 主要从事无损检测与农林信息化研究, E-mail: chaoni@njfu.edu.cn

series models, Faster R-CNN and EfficientDet on detecting tomato surface defects. The proposed method achieved a detection speed of 142.89 f/s, meeting the real-time detection speed requirements of industrial production applications. This work can provide important technical support for standardized and industrialized tomato detection and inspection.

**Key words:** tomato; defect detection; YOLO v11; wavelet depth separable convolution; deep learning

## 0 引言

番茄是一种全球性的重要农作物,对其进行无损化检测与分级,是提高其经济效益的重要途径。对于番茄表面缺陷现有检测方法主要为人工视觉分拣和传统阈值分割<sup>[1-2]</sup>等。然而,传统的检测方法受限于人工检测成本较高、检测精度较低、检测缺陷类别较少等问题,难以实现工业化的流水线高效快速检测,无法满足番茄产业化需求。

近年来,随着计算机技术的发展,深度学习技术在果蔬检测领域取得了显著进展<sup>[3]</sup>,如番茄叶片病害预测<sup>[4]</sup>、火龙果品质检测<sup>[5]</sup>、番茄果实成熟度<sup>[6-7]</sup>等。

目前基于机器视觉和深度学习的方法在番茄检测方面主要是针对番茄个数的检测研究<sup>[8-12]</sup>,而番茄表面缺陷无损检测方面研究较少,且已有研究存在检测缺陷种类少和检测精度低的问题。因此,本文提出一种基于 YOLO v11 算法的改进型表面缺陷检测方法 TDD-YOLO (Tomato defect detection YOLO),对番茄表面白斑、增生、凹陷、裂口、变质 5 种常见缺陷进行识别,并通过对比实验和生产实验来分析和验证所提方法的性能,以期能为番茄工业化检测分级提供技术支撑。

## 1 实验数据获取

### 1.1 数据采集

研究团队自主设计并构建了果蔬光学多机位采集系统,于 2024 年 4—6 月在福建省福建科盛智能包装机械有限公司厂房自动采集番茄图像数据。采集系统配置海康威视的 MV-CS050-10GC 型彩色相机(500 万像素网口面阵)和海康威视的 MVL-KF1228M-12MPE 型镜头(12 mm),采集获得的番茄图像分辨率为 916 像素×641 像素。最终收集有效番茄图像 5 000 幅。

### 1.2 数据集构建

根据生产和销售需求,请经验丰富的工人对采集的番茄图像进行表面缺陷认定,主要分为白斑(white spot)、增生(scar)、凹陷(dent,不破皮)、裂口(gap)和变质(spoilage)5 类缺陷。为了提高番茄表面缺陷检测的准确率,除了上述 5 类缺陷外,还标注

了整果(whole)、叶子(leaf)、果蒂(stem)和果萼(calyx)4 类安全标签。采用 Labelme 工具进行番茄图像样本数据标注,典型样本类别如图 1 所示。

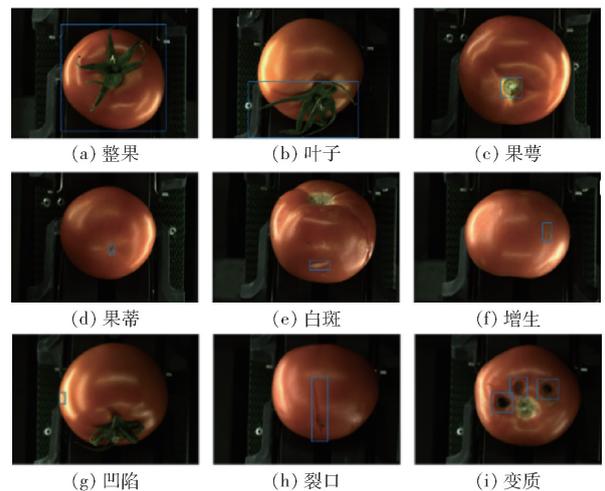


图 1 典型样本示例

Fig. 1 Representative samples

将标签标注框进行比例可视化得到图 2。可见整体标签标注框以中心向周围分散,四周分布较为均匀,且小目标标注相对较多。

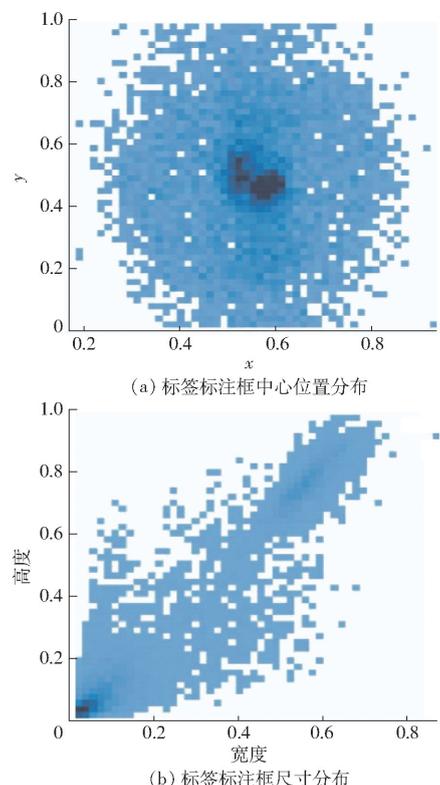


图 2 标签标注框位置与尺寸分布图

Fig. 2 Size distributions of label annotation box



在不同频率分量上应用小核卷积进行指定特征提取,低频分量获取全局信息,高频分量关注局部细节<sup>[15]</sup>。卷积后的子带特征进行逆向小波变换,还原至原始空间进行多频率特征融合。第*i*级小波卷积的表达式为

$$X_{\text{out}}^{(i)} = \text{Conv}(W_{\text{base}}, X^{(i-1)}) + \text{IWT}(\text{Conv}(W^{(i)}, \text{WT}(X_{\text{LL}}^{(i-1)}))) \quad (1)$$

式中  $X^{(i-1)}$ ——第*i*-1级特征图

$\text{WT}()$ ——二维 Haar 小波变换

$\text{IWT}()$ ——逆小波变换

$W^{(i)}$ ——第*i*级小波频域卷积的子带权重

$W_{\text{base}}$ ——基础卷积权重

$X_{\text{LL}}^{(0)}$ ——输入特征图

所提出的 TDD-YOLO 模型运用小波卷积构建了 WC3k2 模块,替换了原 Backbone 中的 C3k2 模块,结构如图 4 所示。WC3k2 模块使用 WTConv 替换了普通 Bottleneck 中的 Conv,组成新的 WBottleneck。新的 WC3k2 模块在特征提取过程中利用小波变换的分解能力,有效扩大了模型感受野,高效提升模型对图像低频全局信息的提取能力。与此同时,小波卷积对高频细节信息的保留也帮助模型提高对边缘信息和细节特征的关注。

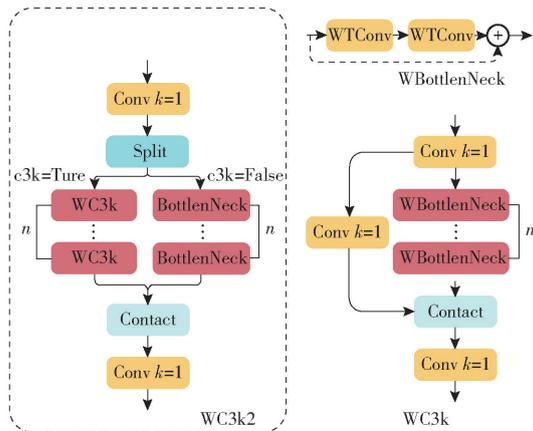


图 4 WC3k2 结构图

Fig. 4 Structure of WC3k2

## 2.2 基于小波卷积的高效检测头

为了进一步提高对小目标(面积占比小)的检测精度,在 Head 层中,基于小波卷积构建了小波深度可分离卷积模块 WDWConv,替换原 Head 层中深度可分离卷积模块,组成新的检测头 HED(High-efficiency detect),扩大了模型 Head 层的感受野,其结构如图 3 所示。

此外,在 HED 中将  $20 \times 20$  的检测头换成  $160 \times 160$  大小的新检测头,进一步增强对细小特征的提取,形成新的 HE-Head 层,其结构如图 3 所示。同时,Neck 层中的  $20 \times 20$  检测头对应特征传递融合

模块也进行调整。

## 2.3 基于点采样的动态上采样

由于 TDD-YOLO 中 HE-Head 采用了  $160 \times 160$  高分辨率检测头使模型参数量上升和计算资源增加,为了平衡模型复杂度,引入了一种基于点采样的轻量级高效动态上采样方法<sup>[16]</sup>(DU<sub>p</sub>)替换模型原有上采样方法,减少模型参数量、计算所需资源、推理延迟。

动态上采样方法借助点采样方法将上采样问题重构为点采样问题,进而避免传统动态卷积的高计算资源需求。基于内容感知的采样点实现轻量化、高效率的特征重采样操作。动态上采样方法的初始化采样位置采用双线性初始化,实现采样点初始分布更均匀;加入偏移范围约束避免采样点重叠或者过于分散;采取分组措施,将输入特征按照通道进行分组,每组特征共享采样点,因此能够实现减少计算量的同时提高采样灵活性<sup>[17]</sup>。

基于点采样的动态上采样,核心机制为学习动态偏移量动态调整采样点的分布位置,实现内容感知的高效特征上采样。对于输入特征图  $X \in \mathbf{R}^{B \times C \times H \times W}$ ( $B$  为批量大小、 $C$  为通道数、 $H$  为输入特征图高度、 $W$  为输入特征图宽度)的动态上采样输出特征图  $X'$  为

$$X' = \bigcup_{g=1}^G X'_g \quad (2)$$

$$\text{其中 } X'_g = f_{\text{resample}}(X_g, S_g) \quad (g \in [1, G]) \quad (3)$$

式中  $X'_g$ ——第*g*组上采样特征图

$f_{\text{resample}}$ ——内容感知的重采样函数

$X_g$ ——第*g*组输入特征图

$G$ ——分组数

$S_g$ ——第*g*组采样点位置

采样点位置  $S$  的计算公式为

$$S = G + \alpha \sigma(O') \quad (4)$$

$$\text{其中 } O' = f_{\text{reshape}}(O) \in \mathbf{R}^{B \times 2 \times sH \times sW} \quad (5)$$

$$O = f_{\text{offset}}(X) \in \mathbf{R}^{B \times 2Gs^2 \times H \times W} \quad (6)$$

式中  $\alpha$ ——偏移范围控制因子

$\sigma()$ ——Sigmoid 函数,限制偏移量范围为  $[0, 1]$

$O'$ ——每个采样点偏移量

$O$ ——动态偏移量

$f_{\text{reshape}}()$ ——尺寸调整函数

$f_{\text{offset}}()$ ——偏移量计算函数

$s$ ——上采样比例

基于点采样的动态上采样有效降低了计算复杂度和内存需求,使得模型能够在保持轻量化的同时具备灵活性和高效性<sup>[18]</sup>。

## 2.4 自适应焦点损失函数

由于番茄的果蒂和增生、凹陷与裂口特征相似,导致存在误识别。因此,引入基于焦点损失的自适应阈值焦点损失函数(Adaptive threshold focus loss function, ATFL)<sup>[19]</sup>替换原有损失函数,提高模型对难分类标签样本的关注。ATFL使用动态调节损失权重,降低模型对易分类标签样本的关注,提升对难区分的标签样本关注;同时使用滑动平均动态调整超参数以减少超参数调试的时间成本,有助于提升模型检测精确度。ATFL数学表达式为

$$L_{\text{ATFL}} = \begin{cases} -(\lambda - p_t)^{-\ln p_t} \ln p_t & (p_t \leq 0.5) \\ -(1 - p_t)^{-\ln \hat{p}_t} \ln \hat{p}_t & (p_t > 0.5) \end{cases} \quad (7)$$

$$\text{其中} \quad p_t = lp + (1 - l)p \quad (8)$$

$$\hat{p}_t = 0.05\bar{p}_t^{\text{old}} + 0.95p_t \quad (9)$$

式中  $\lambda$ ——对难分类样本的全局权重调整超参数  
 $p$ ——预测概率  $l$ ——真实标签

$p_t$ ——预测概率匹配项,用来统一处理正负样本的预测概率

$\hat{p}_t$ ——滑动平均预测概率,实现动态调节易分类样本权重

$\bar{p}_t^{\text{old}}$ ——之前批次预测概率均值

自适应焦点损失通过上述设置,可以有效实现对目标样本难分类的重点关注,提高模型对难区分缺陷标签的识别率,有效提高模型的整体检测性能和泛化能力。

## 3 实验

### 3.1 实验环境与参数设置

番茄表面缺陷检测模型训练和测试所用计算机的CPU型号为Intel(R)Core(TM)i5-12600KF(3.70 GHz),32 GB运行内存,GPU型号为NVIDIA GeForce RTX4060 Ti,操作系统为Windows 11专业版。软件环境为Python 3.10.13、Pytorch 2.2.1和CUDA 12.6.65。

训练时将原采集番茄彩色图像尺寸916像素×641像素调整为640像素×640像素,迭代次数(Epochs)设置为600,批处理大小(Batch size)设置为8,初始学习率设为0.01,权重衰减(Weight decay)设为0.0005。为了加速训练速度,优化器选择随机梯度下降(SGD)。

### 3.2 评价指标

对于番茄缺陷检测模型实验,采用精确率、召回率、平均精度均值、F1分数、帧率、模型参数量6个指标进行模型评价<sup>[20-21]</sup>。

## 4 实验结果与分析

### 4.1 消融实验

设计了一组消融实验来分析所提出的基于YOLO v11的改进模型对番茄表面缺陷识别的效果,具体实验结果如表1所示。其中,由于WC3k2模块和HE都是基于小波卷积构建,所以将两者基于小波卷积的改进记为WTC+。WTC+的引入能够有效降低模型参数量,同时小幅度提升召回率,但其对精确度和平均精度均值有着一定削弱。新构建的HE-Head实现了模型召回率和平均精度均值的有效提升,与此同时模型的参数量增加较多。动态上采样的引入则给模型带来了轻量化的同时对模型性能略有削弱;ATFL的引入实现模型的整体性能有一定提升,但其也对模型参数量带来了一定程度的负面效果。HE-Head和ATFL的改进,显著提高了YOLO v11模型在番茄表面缺陷识别的精度和召回率,但增加了模型参数和复杂度。WTC+和Dup有效地降低了模型参数,但缺陷检测性能也略有降低。综合考虑模型参数量和模型性能,最终所提出的TDD-YOLO模型在少量增加模型参数的情况下,尽可能提高模型性能,相比基础模型YOLO v11而言,番茄表面缺陷识别精确度从86.1%提升至89.0%、召回率从79.3%提升至84.9%、F1分数从82.6%提升至86.9%、平均精度均值从83.2%提升至88.0%,而模型参数量基本没有变化,其帧率达到142.89 f/s(表2),仅比YOLO v11低约2 f/s;相比精度最高的YOLO-HE-Head-ATFL组合模型,TDD-YOLO识别精确度仅低0.9个百分点,而召回率提高0.7个百分点,两者的综合指标F1分数相近,且平均精度均值提高1.7个百分点,模型参数量降低 $4 \times 10^6$ 。综上,所改进的YOLO-TDD在提升

表1 消融实验性能对比

Tab.1 Ablation experimental results of YOLO v11 with different improvement modules

WTC+	HE-Head	Dup	ATFL	精确度/%	召回率/%	F1分数/%	平均精度均值/%	模型参数量
				86.1	79.3	82.6	83.2	$9.30 \times 10^6$
√				85.2	79.9	82.5	81.9	$7.50 \times 10^6$
	√			86.1	83.0	84.5	85.9	$1.26 \times 10^7$
		√		84.5	79.1	81.7	81.5	$7.60 \times 10^6$
			√	86.6	79.8	83.1	83.0	$9.60 \times 10^6$
	√		√	89.9	84.2	87.0	86.3	$1.33 \times 10^7$
	√	√	√	89.7	80.7	85.0	86.2	$1.19 \times 10^7$
√	√	√	√	89.0	84.9	86.9	88.0	$9.30 \times 10^6$

注:“√”表示含有该模块。

表 2 各模型对番茄表面缺陷检测性能对比

Tab.2 Comparison results of different models for detecting tomato surface defects

模型	精确度/%	召回率/%	平均精度均值/%	F1 分数/%	帧率/(f·s <sup>-1</sup> )
Faster R - CNN	79.5	72.0	75.0	75.6	43.01
EfficientDet	82.1	74.5	76.6	78.1	52.21
YOLO v5	84.1	75.1	77.2	79.3	79.37
YOLO v5u	81.5	76.1	78.1	78.7	103.90
YOLO v7	82.5	76.4	78.3	79.3	129.25
YOLO v8	81.5	75.9	78.4	78.6	122.22
YOLO v9	80.4	76.4	78.2	78.3	112.77
YOLO v10	82.5	74.5	77.3	78.3	127.27
YOLO v11	86.1	79.3	83.2	82.6	144.83
TDD - YOLO	89.0	84.9	88.0	86.9	142.89

识别精度和准确率的同时保障了模型运行速度。

### 4.2 对比实验

在同样的硬件设备条件下使用同一组数据集进行测试,选取了 Faster R - CNN<sup>[22]</sup>、EfficientDet<sup>[23]</sup>和 YOLO v5<sup>[24]</sup>、YOLO v5u、YOLO v7<sup>[25]</sup>、YOLO v8<sup>[25]</sup>、YOLO v9、YOLO v10、YOLO v11,与本文提出的 TDD - YOLO 模型进行对比实验,进一步验证本文模型对番茄表面缺陷识别效果。训练模型的迭代次数统一为 600,测试结果如表 2 所示。可见所提出的 TDD - YOLO 各项指标明显优于其他模型,相比 Faster R - CNN 识别精确率提高 9.5 个百分点、召回率提高 12.9 个百分点。YOLO v11 的帧率最高为 144.83 f/s,比 TDD - YOLO 略高,两者实时性较好,而 Faster R - CNN、EfficientDet 和 YOLO v5 的帧率较低,实时性效果偏差。此外,图 5 给出了一组测试结果,可见 Faster R - CNN、EfficientDet 和 YOLO v5 存在漏检现象。

为了进一步分析各类模型番茄表面缺陷识别性能,图 6 展示了各模型对 5 类缺陷正确识别性能。可见,所提出的 TDD - YOLO 模型对于缺陷识别效果明显优于其他模型,特别是对白斑、增生和裂口;其次是基础模型 YOLO v11 识别效果较好,但与本文模型相比还有明显差距。

### 4.3 生产实验

本文所提的针对番茄表面缺陷的快速准确检测方法旨在解决工业化番茄分级设备上的检测问题,为验证所提方法的有效性,在福建省泉州市福建康顺旺生态农业有限公司家兴农场成功部署在实际生产设备上,并进行了生产实验。智能番茄表面缺陷检测与分析设备如图 7 所示,本次生产实验旨在验证所提方法在实际工业化的番茄分级设备中的检测效率是否满足实际生产需要。



图 5 各模型缺陷识别结果

Fig.5 Results of different models for detecting tomato surface defects

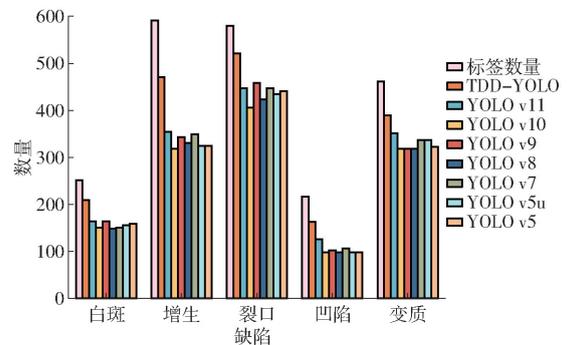


图 6 各模型测试集缺陷准确识别统计图

Fig.6 Statistical chart of identification results of different models for defects in testing set

生产实验使用经过人工检测记录后的番茄样本共计 100 个,其中表面含缺陷的番茄样本个数为 20 个,包含各类缺陷 55 个,正常无缺陷番茄样本 80 个。自动检测实验重复 5 次,实验结果如表 3 所示。经过实际检测,该批样本平均缺陷识别率为 88.0%,含缺陷番茄识别率为 91.0%,误检率为 1.8%,每个番茄平均检测用时为 8.6 ms,满足生产实时检测速度需求。

## 5 结论

(1)研究了工业化番茄在线检测问题,提出一种基于 YOLO v11 的番茄表面缺陷快速检测方法 TDD - YOLO,用以实现快速精准的番茄表面缺陷检测。

(2)基于二维小波变换理论构建小波卷积 WTConv,进而构建新的小波深度可分离卷积模块

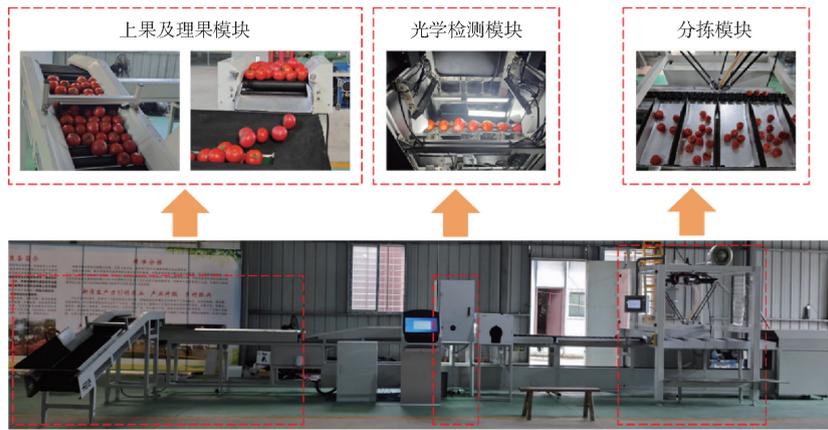


图7 番茄表面缺陷检测与分拣系统装备实物图

Fig.7 Tomato surface defect detection and sorting system

表3 生产实验测试结果

Tab.3 Testing results of production experiment by TDD-YOLO

测试序号	正确识别缺陷数	含缺陷番茄识别数	缺陷识别率/%	误识别缺陷番茄数	误检率/%	平均用时/ms
1	48	18	87.3	2	2.0	7.5
2	49	19	89.1	2	2.0	8.3
3	47	18	85.5	1	1.0	9.1
4	48	17	87.3	1	1.0	9.2
5	50	19	90.9	3	3.0	8.9
平均值	48.4	18.2	88.0	1.8	1.8	8.6

WDWConv 和 WC3k2 模块, 替换 Backbone 层中的原有 C3k2 模块, 扩大网络在特征提取阶段的感受野, 有效减少模型参数量。使用轻量高效的动态上采样方法, 同样也降低了模型参数量, 提高了模型运行速度。

(3) 针对番茄表面小缺陷所占像素面积较小的

特点, 构建新的检测头 HE-Head, 扩大网络 Head 层的感受野, 增强对小目标的感知能力。同时, 采用的自适应阈值焦点损失函数 ATFL 降低了易分类标签样本的影响, 提升了网络对难分类标签样本的关注。两者一定程度上提升了模型检测精确率和召回率。

(4) 实验结果表明, 本文所提出的 TDD-YOLO 方法各项性能指标均优于 Faster R-CNN、EfficientDet、YOLO v5、YOLO v5u、YOLO v7、YOLO v8、YOLO v9、YOLO v10、YOLO v11。但由于网络结构的改变, 即使使用多种轻量化方法进行精简, 帧率指标较改进前略有降低。

(5) 实验结果表明, 基于 YOLO v11 改进的 TDD-YOLO 模型在番茄表面缺陷检测中具有较大的应用潜力。能够满足工业化番茄检测分级所面临的高效率、高精度检测要求。本文所提方法在实际设备中已成功验证其检测性能, 在检测精度及模型轻量化方面具有较大潜力。

## 参 考 文 献

- [1] CHEN Chengcheng, WANG Xianchang, HEIDARI A A, et al. Multi-threshold image segmentation of maize diseases based on elite comprehensive particle swarm optimization and Otsu[J]. *Frontiers in Plant Science*, 2021, 12:789911.
- [2] 何婷婷, 姚继超, 张钟莉莉, 等. 基于图像局部方差的亮度矫正下番茄表面缺陷检测方法[J]. *食品与机械*, 2023, 39(9): 128-133, 161.  
HE Tingting, YAO Jichao, ZHANG Zhonglili, et al. Tomato surface defect detection method based on image local variance considering brightness correction[J]. *Food and Machinery*, 2023, 39(9): 128-133, 161. (in Chinese)
- [3] THANGARAJ R, ANANDAMURUGAN S, PANDIYAN P, et al. Artificial intelligence in tomato leaf disease detection: a comprehensive review and discussion[J]. *Journal of Plant Diseases and Protection*, 2022, 129(3): 469-488.
- [4] TRIVEDI NK, GAUTAM V, ANAND A, et al. Early detection and classification of tomato leaf disease using high-performance deep neural network[J]. *Sensors*, 2021, 21(23): 7987.
- [5] 徐婷婷, 宋亮, 卢学鹤, 等. 基于 YOLO v7-RA 的火龙果品质与成熟度双指标检测方法[J]. *农业机械学报*, 2024, 55(7): 405-414.  
XU Tingting, SONG Liang, LU Xuehe, et al. Dual-index detection method of pitaya quality and maturity based on YOLO v7-RA[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(7): 405-414. (in Chinese)
- [6] 龙洁花, 赵春江, 林森, 等. 改进 Mask R-CNN 的温室环境下不同成熟度番茄果实分割方法[J]. *农业工程学报*, 2021, 37(18): 100-108.  
LONG Jiehua, ZHAO Chunjiang, LIN Sen, et al. Segmentation method of the tomato fruits with different maturities under greenhouse environment based on improved Mask R-CNN[J]. *Transactions of the CSAE*, 2021, 37(18): 100-108. (in Chinese)
- [7] YANG Guoliang, WANG Jixiang, NIE Ziling, et al. A lightweight YOLOv8 tomato detection algorithm combining feature

- enhancement and attention[J]. *Agronomy*, 2023, 13(7): 1824.
- [8] ZHENG Taixiong, JIANG Mingzhe, LI Yongfu, et al. Research on tomato detection in natural environment based on RC-YOLOv4[J]. *Computers and Electronics in Agriculture*, 2022, 198: 107029.
- [9] 赵承敏, 余宏杰, 孙豪杰. 基于改进 YOLOv8n 的番茄果实检测方法[J/OL]. *安徽科技学院学报*, 1-9[2025-02-17]. <http://kns.cnki.net/kcms/detail/34.1300.N.20241210.0947.004.html>.
- ZHAO Chengmin, YU Hongjie, SUN Haojie. Tomato maturity detection method based on improved YOLOv8n[J/OL]. *Journal of Anhui Science and Technology University*, 1-9[2025-02-17]. <http://kns.cnki.net/kcms/detail/34.1300.N.20241210.0947.004.html>. (in Chinese)
- [10] 毕泽洋, 杨立伟, 吕树盛, 等. 基于 EDH-YOLO 的轻量型温室番茄检测方法[J]. *农业机械学报*, 2024, 55(增刊2): 246-254.
- BI Zeyang, YANG Liwei, LÜ Shusheng, et al. Lightweight greenhouse tomato detection method based on EDH-YOLO[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(Supp. 2): 246-254. (in Chinese)
- [11] WANG Xuewei, LIU Jun, ZHU Xiaoning. Early real-time detection algorithm of tomato diseases and pests in the natural environment[J]. *Plant Methods*, 2021, 17(1): 43.
- [12] YUE Xiang, QI Kai, YANG Fuhao, et al. RSR-YOLO: a real-time method for small target tomato detection based on improved YOLOv8 network[J]. *Discover Applied Sciences*, 2024, 6(5): 268.
- [13] KHANAM R, HUSSAIN M. YOLOv11: an overview of the key architectural enhancements[J]. *arXiv:2410.17725*, 2024.
- [14] FINDER S E, AMOYAL R, TREISTER E, et al. Wavelet convolutions for large receptive fields[C] // 2024 ECCV 18th European Conference on Computer Vision, 2025: 363-380.
- [15] FINDER S E, ZOHAY Y, ASHKENAZI M, et al. Wavelet feature maps compression for image-to-image CNNs[C] // 36th Conference on Neural Information Processing Systems (NeurIPS). *Advances in Neural Information Processing Systems*, 2022.
- [16] LIU Wenze, LU Hao, FU Hongtao, et al. Learning to upsample by learning to sample[C] // 2023 IEEE/CVF International Conference on Computer Vision, 2023: 6004-6014.
- [17] YANG Wenji, QIU Xiaoying. A lightweight and efficient model for grape bunch detection and biophysical anomaly assessment in complex environments based on YOLOv8s[J]. *Frontiers in Plant Science*, 2024, 15: 1395796.
- [18] 吴仪邦, 陈喆, 李喆, 等. 基于改进 YOLOv9 的禁垦陡坡地违规耕种区遥感影像检测方法[J]. *农业工程学报*, 2024, 40(17): 197-204.
- WU Yibang, CHEN Zhe, LI Zhe, et al. Detecting illegal cultivation of step slopes from remote sensing images using improved YOLOv9[J]. *Transactions of the CSAE*, 2024, 40(17): 197-204. (in Chinese)
- [19] YANG Bo, ZHANG Xinyu, ZHANG Jian, et al. EFLNet: enhancing feature learning for infrared small target detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 1-11.
- [20] CUI Wenqi, LI Zhenye, DUANMU Anning, et al. CCG-YOLO v7: a wood defect detection model for small targets using improved YOLOv7[J]. *IEEE Access*, 2024, 12: 10575-10585.
- [21] XUE Sheng, LI Zhenye, WU Rui, et al. Few-shot learning for small impurities in tobacco stems with improved YOLOv7[J]. *IEEE Access*, 2023, 11: 48136-48144.
- [22] CHEN Mengqi, YU Lingjie, ZHI Chao, et al. Improved Faster R-CNN for fabric defect detection based on Gabor filter with genetic algorithm optimization[J]. *Computers in Industry*, 2022, 134: 103551.
- [23] TAN Mingxing, PANG Ruoming, LE Q. EfficientDet: scalable and efficient object detection[C] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 10778-10787.
- [24] ADIBHATLA V A, CHIH H C, HSU C C, et al. Applying deep learning to defect detection in printed circuit boards via a newest model of you-only-look-once[J]. *Mathematical Biosciences and Engineering*, 2021, 18(4): 4411-4428.
- [25] JUNG D, KIM N. Analysis of fire detection performance of deep learning-based YOLO v7 and YOLO v8 models using GAN algorithm[J]. *Journal of Information Technology and Applied Engineering*, 2024, 14(1): 13-21.