DOI: 10.3969/j.issn.2097-583X.2026.04.013　　文章编号：2097-583X(2026)04-0615-07

基于YOLOv11的轻量化黄瓜病害检测模型

彭世博[1]，姜懿芮[2]，陈　晓[3]，闫文凯[1]，贾芝琪[1]，周海霞[4]，杨路明[1*]

(1. 河南农业大学 园艺学院，河南 郑州 450002；
2. 河南工业大学 人工智能与大数据学院，河南 郑州 450002；
3. 河南省政务大数据中心，河南 郑州 450002；
4. 郑州市农业科技研究院，河南 郑州 450000)

摘　要：针对黄瓜病害检测模型计算量大、难以在资源受限场景部署的问题，提出轻量化模型WDL-YOLOv11。该模型以YOLOv11n为基础，引入WaveletPool模块以降低计算量并保留细粒度特征，引入DySample上采样增强小目标表征，构建Detect_LSCD检测头，实现参数共享与多尺度特征校准。在包含5类黄瓜病害及健康叶片的5191张图像上进行相关实验。结果表明：WDL-YOLOv11的mAP@0.5达88.2%，参数量仅有4.1 MB，计算量为4.6 GFLOPs；相比YOLOv11n，参数量和计算量分别减少21.2%和28.1%，精度仅下降0.5个百分点。该模型在参数量和计算量上均优于Rtdetr-l及YOLO系列轻量模型，且检测精度居前，并展现出良好的架构泛化性与病斑聚焦能力。

关键词：黄瓜病害；目标检测；YOLOv11；轻量化模型
中图分类号：TP391.4　　**文献标志码：**A　　**开放科学(资源服务)标识码(OSID)：**

Lightweight cucumber disease detection model based on YOLOv11

Peng Shibo[1], Jiang Yirui[2], Chen Xiao[3], Yan Wenkai[1], Jia Zhiqi[1], Zhou Haixia[4], Yang Luming[1*]

(1. School of Horticulture, Henan Agricultural University, Zhengzhou 450002, China;
2. School of Artificial Intelligence and Big Data, Henan University of Technology, Zhengzhou 450002, China;
3. Henan Provincial Government Affairs Big Data Center, Zhengzhou 450002, China;
4. Zhengzhou Academy of Agricultural Sciences, Zhengzhou 450000, China)

Abstract: To address the issues of high computational cost and limited deployability in resource-constrained scenarios for cucumber disease detection, a lightweight model, WDL-YOLOv11, was proposed. Based on YOLOv11n, a WaveletPool module was introduced to reduce computational cost while preserving fine-grained features, a DySample upsampling operation was introduced to enhance the representation of small objects, and a Detect_LSCD detection head was constructed to achieve parameter sharing and multi-scale feature calibration. Experiments were conducted on 5191 images containing five types of cucumber diseases and healthy leaves. The results showed that WDL-YOLOv11 attained an mAP@0.5 of 88.2%, with only 4.1 MB parameters and 4.6 GFLOPs of computational cost. In comparison with YOLOv11n, the number of parameters and the computational cost were reduced by 21.2% and 28.1%, respectively, while the accuracy was decreased by only 0.5 percentage points. The model was superior to Rtdetr-l and YOLO series lightweight models in terms of both parameter count and computational cost, and ranked among the top in detection accuracy, and exhibited good architectural generalization and disease spot focusing capability.

Key words: cucumber diseases; object detection; YOLOv11; lightweight model

收稿日期：2026-05-12；**修回日期：**2026-05-20；*.**通信联系人，**E-mail：lumingyang@henau.edu.cn
基金项目：河南省重大科技专项项目(241100110200)；国家自然科学基金项目(31501784)
作者简介：彭世博(2002－)，男，河南许昌人，硕士研究生，主要从事作物表型组学方向的研究；杨路明(1981－)，男，河南郑州人，教授，博士，博士生导师，主要从事瓜类作物基因组与分子育种、瓜类重要性状形成的遗传基础与分子机理的研究。
引用格式：彭世博，姜懿芮，陈晓，等. 基于YOLOv11的轻量化黄瓜病害检测模型[J]. 信阳师范大学学报(自然科学版)，2026，39(4)：615-621.
Peng Shibo, Jiang Yirui, Chen Xiao, et al. Lightweight cucumber disease detection model based on YOLOv11[J]. Journal of Xinyang Normal University (Natural Science Edition), 2026, 39(4):615-621.

0　引言

黄瓜(*Cucumis sativus* L.)是全球广泛栽培的葫芦科蔬菜作物,以其生长周期短、产量高、营养丰富的特点,成为设施农业中的核心经济作物之一,其产量与品质直接关系到农业生产效益和市场供应的稳定性[1]。设施栽培通过人工调控温湿度、光照等环境条件,实现了黄瓜周年生产,但高密度种植与密闭环境也为病害的滋生与传播提供了有利条件,极易诱发霜霉病、白粉病、蚜虫、枯萎病等多种病虫害[2-3]。据统计,病害每年可导致黄瓜大幅度减产,严重地块甚至绝收,不仅造成巨大的经济损失,还可能因农药滥用引发食品安全与环境污染问题,对设施农业的可持续发展构成严峻威胁[4]。

传统的黄瓜病害检测主要依赖人工巡检与经验判断,存在效率低、主观性强、漏检率高等问题,难以适应大规模设施栽培的实时监测需求[5]。分子生物学检测技术虽能实现精准识别,但存在操作复杂、成本高昂、耗时较长等问题,无法满足田间快速检测的实际需求[6]。

近年来,基于深度学习的目标检测技术为病害智能识别开辟了新的路径,其中 YOLO 系列、Faster R-CNN 等模型凭借高效的检测性能,已在黄瓜病害识别中得到广泛应用[7]。在现有研究的基础上,针对黄瓜病害检测的轻量化模型设计已形成多种基于 YOLO 系列的改进方案。例如,Wang 等[8]基于 YOLOv10 设计了轻量化模型,通过架构优化减少了计算冗余,为移动端部署奠定了高效基础;Song 等[9]将卷积注意力模块(CBAM)集成到 YOLOv10 中,有效增强了模型对关键特征的感知能力,提升了对小目标或细微缺陷的检测精度。在具体应用方面,Omer 等[10]采用一种改进的轻量级 YOLOv5 模型专门用于黄瓜叶部病害与害虫的检测,通过结构优化在保持精度的同时实现了模型压缩。此外,Liu 等[11]提出的 YOLO-Cucumber 模型,以 YOLOv11n 为基础融入可变形卷积和通道剪枝等技术,在复杂农田环境下实现了高精度与高速检测,为嵌入式部署提供了解决方案。

然而,当前病害检测的相关研究仍存在明显局限性:多数研究聚焦于检测精度的提升,存在“重精度、轻部署”的倾向,模型设计过程中未能充分考虑农业边缘设备的资源约束[12]。现有主流目标检测模型(包括部分轻量化版本)尽管在实验室环境下表现优异,但普遍存在计算复杂度高、参数量偏大的问题,导致其在 Jetson Nano、树莓派等资源受限的边缘设备上推理延迟较高,难以实现实时巡检[13-15]。例如,孙寿松等[16]在番茄叶片病虫害检测中,提出的 RHEO-YOLO 模型虽经轻量化改进,但在 Jetson Nano 上的推理速度仅为 8.3 帧/s,仅能勉强满足最低实时性要求,凸显了边缘算力与模型复杂度之间的尖锐矛盾。兰玉彬等[17]在生姜叶片病虫害识别中,即便使用性能更强的 Jetson Orin NX 平台并对 YOLOv5s 模型进行 TensorRT 和 INT8 量化加速,其 74.3 帧/s 的实时检测性能也高度依赖于专用优化技术,而非模型本身的轻量性。马超伟等[18]针对小麦病害的移动端部署,通过将骨干网络替换为 PP-LCNet 等轻量化设计来减少参数量,反映出为适配无人机等移动平台,必须在精度与模型大小之间做出权衡。此外,李龙海等[19]为实现玉米病害在 Jetson Nano 上的实时检测,采用剪枝与知识蒸馏等复杂后处理技术,将模型大小从 6.35 MB 压缩至 4.40 MB,进一步印证了将实验室高精度模型适配至低资源边缘设备所需付出的额外工程代价。

针对上述挑战,本研究的核心目标并非片面追求检测精度的极致提升,而是在保证较高识别精度的前提下,通过结构化改进实现模型的显著轻量化,以适配资源受限的应用场景。基于该目标,以 YOLOv11n 为基础模型,提出一种面向黄瓜病害检测的轻量化模型。通过引入高效特征提取模块,增强小目标识别能力,采用轻量化特征融合模块降低计算复杂度,设计参数共享检测头实现多尺度特征自适应校准,在显著降低模型计算量与参数量的同时,维持优异的检测性能。

1　图像数据

所用图像数据源自 Cucumber Disease Recognition Dataset、WMC-Leafset 等公开数据集,通过多源整合以覆盖更丰富的病害类型,增强模型的鲁棒性。为扩充数据规模与样本多样性,采用随机旋转、亮度调整、翻转、裁剪、缩放等多种数据增强方法。最终构建的数据集涵盖 5 类病害(炭疽病、细菌性枯萎病、霜霉病、蔓枯病、白粉病)及健康叶片,共计 5191 张图像,按 8∶1∶1 的比例划分

为训练集、验证集和测试集。各类样本分布见表1。

表1　病害图像数据分布

Tab. 1　Distribution of the disease image dataset

病害类别	训练集/张	验证集/张	测试集/张	合计/张
健康叶	640	80	80	800
炭疽病	640	80	80	800
细菌性枯萎病	640	80	80	800
霜霉病	640	80	80	800
蔓枯病	640	80	80	800
白粉病	953	119	119	1191
合计	4153	519	519	5191

2　模型与训练

2.1　基于改进YOLOv11的病害检测模型构建

YOLOv11是一种先进的实时目标检测算法,其架构主要由主干网络(Backbone)、多尺度特征融合颈部(Neck)、检测预测层(Head)共3部分组成。该算法的核心创新在于引入了更高效的跨阶段局部网络设计,并采用改进的BiFPN结构实现更优的特征金字塔融合,同时集成了最新优化器与数据增强技术,从而显著提升了训练效率[20]。此外,YOLOv11模型融合了多尺度特征增强模块与硬件感知的重参数化结构[21]。鉴于YOLOv11n在参数量与推理速度之间取得了良好的平衡,本研究选择该版本作为基础模型。

尽管YOLOv11在通用目标检测任务中表现优异,但其在边缘设备上的实际部署仍存在局限性[22]。首先,YOLOv11模型的轻量化程度尚不足以满足严格资源约束下的实时性要求,在计算能力有限的设备上推理延迟较高,难以实现实时巡检。其次,在模型轻量化的过程中,小尺寸病斑的漏检率可能升高,从而导致精度与效率失衡[23]。因此,该模型在农业应用场景中仍有待改进。

为提升病害的检测精度并进一步推进模型轻量化,在YOLOv11n的基础上提出一种新型检测模型WDL-YOLOv11(如图1所示)。具体的改进措施包括:1)采用WaveletPool模块替换原有的Conv模块,以降低计算量并保持模型精度;2)引入DySample模块替代Upsample模块,增强对小目标特征的表征能力;3)使用Detect_LSCD检测头替换原检测头,以显著压缩计算量并提升其在定位与分类任务中的性能。

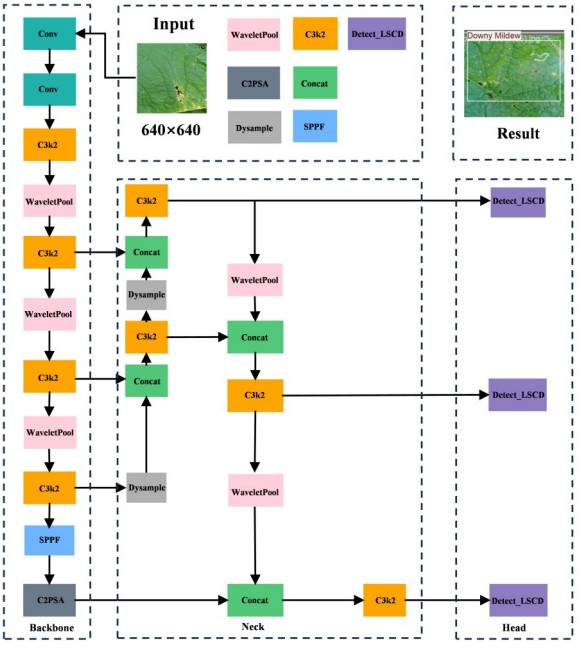


图1　本文提出的WDL-YOLOv11网络结构图

Fig. 1　Architecture of the proposed WDL-YOLOv11 network

2.1.1　WaveletPool模块

WaveletPool是一种基于Haar小波多分辨率分析的下采样模块(如图2所示)。通过固定的低频/高频滤波器组,以分组卷积的形式将输入特征分解为多方向细节子带,在降采样的同时完整保留多频率信息,将传统池化的“信息丢弃”转变为“多频分解”,实现降采样与特征增强的一体化。该结构仅依赖标准卷积运算,无需额外复杂组件。其计算过程可描述如下:

首先,构建2×2的固定Haar小波滤波器组,分解为LL(低频-低频)、LH(低频-高频)、HL(高频-低频)、HH(高频-高频)等4类滤波器核,如式(1)所示:

$$W_{\text{wavelet}}=\{W_{\text{LL}},W_{\text{LH}},W_{\text{HL}},W_{\text{HH}}\}。\tag{1}$$

随后,通过分组卷积(groups=C)将上述滤波器组并行作用于输入特征图的每个通道,并完成步长为2的下采样,如式(2)所示:

$$F_{\text{sub}}=\text{Conv}(x,W_{\text{wavelet}},\text{stride}=2,\text{groups}=C),\tag{2}$$

式中:x为输入特征图,C为输入通道数,Conv表示卷积操作。最终输出为4个子带特征的通道维度拼接,通道数扩展为输入的4倍,如式(3)所示:

$$\text{WaveletPool}(x)=\text{Concat}(F_{\text{LL}},F_{\text{LH}},F_{\text{HL}},F_{\text{HH}}),\tag{3}$$

式中:Concat表示通道维度的拼接操作,F_{LL}、F_{LH}、F_{HL}、F_{HH}分别为4类小波滤波器输出的子带特征。

该结构通过固定小波滤波器与分组卷积的结

合,在不增加可学习参数、不提升计算复杂度的前提下,最大限度地保留了病害目标的边缘、纹理等高频特征,特别适用于农业场景中尺度小、形态多变的病虫害目标检测任务,有效缓解了传统池化导致的小目标信息丢失问题。

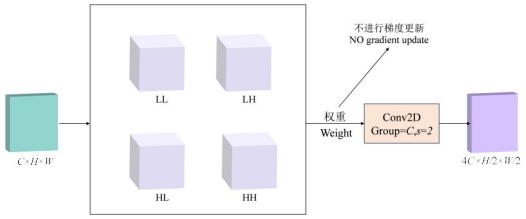


图 2　WaveletPool 模块结构图

Fig. 2　Structure diagram of the WaveletPool module

2.1.2　DySample 模块

DySample 是一种轻量级动态上采样模块,通过 1×1 卷积预测像素级采样偏移,以自适应重采样替代固定的插值上采样。将其嵌入 YOLOv11 的颈部上采样路径,能够有效增强小目标的边缘与细节保留能力,缓解黄瓜病害检测中纹理模糊导致的信息丢失,在提升精度的同时保持高推理效率。其结构如图 3 所示。

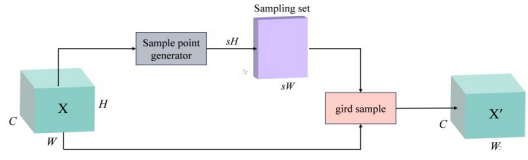


图 3　DySample 模块结构图

Fig. 3　Structure diagram of the DySample module

2.1.3　Detect_LSCD 检测头

Detect_LSCD 是一种轻量化检测头,通过分组共享卷积、Conv_GN 模块与可学习尺度缩放,实现参数共享与多尺度特征校准,从而大幅降低参数量。在 YOLOv11n 上,该检测头提升了小尺度病斑的检测灵敏度与定位精度,实现了更高的精度-效率平衡。其结构如图 4 所示。

2.2　模型训练与评价指标

2.2.1　训练平台

实验基于 PyTorch 深度学习框架,在 Windows 11 操作系统上进行模型训练与测试。实验平台的主要硬件与软件配置如表 2 所示。

2.2.2　训练参数

在模型训练过程中,输入图像的大小均调整为 640×640 像素。具体的超参数设置如表 3 所示。

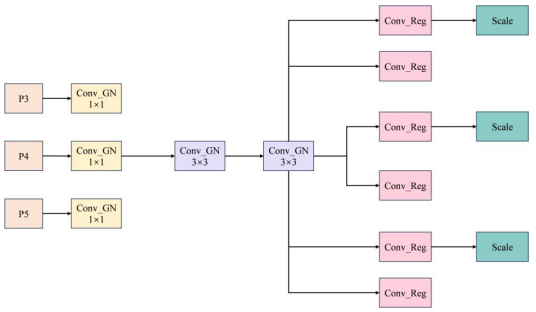


图 4　Detect_LSCD 检测头结构

Fig. 4　Architecture of the Detect_LSCD head

表 2　实验平台配置

Tab. 2　Experimental platform configuration

环境	环境项	规格
硬件	CPU	Intel Xeon Platinum 8352V Processor
	GPU	NVIDIA GeForce RTX 4090
	内存	32 GB
	显存	24 GB
软件	操作系统	Windows 11
	深度学习框架	PyTorch 2.2.2
	CUDA	12.1
	编程语言	Python 3.10.14

表 3　模型训练超参数设置

Tab. 3　Model training hyperparameter settings

超参数	数值	超参数	数值
epochs	200 轮次	optimizer	SGD
patience	100	weight_decay	0.000 5
batch	32	momentum	0.937 0
imgsz	640×640 像素	workers	8
lr	0.01	close_mosaic	0

2.2.3　评价指标

为全面评估模型的检测性能,采用精确度(Precision, P)、召回率(Recall, R)、$F1$ 分数($F1$-score)和交并比阈值为 0.5 时的平均精度(Mean Average Precision at IoU threshold of 0.5, mAP@0.5)作为检测精度的主要评价指标,同时采用参数量和计算量(GFLOPs)来评估模型的复杂度。各指标计算公式如下:

$$P=\frac{\mathrm{TP}}{\mathrm{TP}+\mathrm{FP}}, \tag{4}$$

$$R=\frac{\mathrm{TP}}{\mathrm{TP}+\mathrm{FN}}, \tag{5}$$

$$\mathrm{AP}=\int_0^1 P(R)\mathrm{d}R, \tag{6}$$

$$\mathrm{mAP@0.5}=\sum_{i=1}^{C}\mathrm{AP}_i / C, \tag{7}$$

$$F1\text{-score}=2\times\frac{P\times R}{P+R},\tag{8}$$

式中:TP代表真正例,FP代表假正例,FN代表假负例,AP_i表示第i类的平均精度,PR曲线下的面积对应AP值,i表示类别索引,C是类别总数。

3　结果与分析

3.1　对比试验

为评估WDL-YOLOv11在黄瓜病害检测任务中的性能,将其与Rtdetr-l及YOLO系列轻量模型在相同条件下进行对比,结果如表4所示。WDL-YOLOv11的mAP@0.5达到了88.2%,仅比YOLOv11n低了0.5个百分点,但高于其他轻量级模型;精确度(P)、召回率(R)与$F1$分数分别为87.1%、84.0%与85.5%,保持了良好的检测一致性。同时,该模型的参数量仅为4.1 MB,计算量为4.6 GFLOPs,在所有对比模型中均为最低,较YOLOv11n分别降低21.2%和28.1%。在精度基本持平的前提下,模型规模得到大幅压缩,实现了精度与轻量化的最优平衡,适合田间实时部署。

表4　不同模型在黄瓜病害检测任务上的性能对比

Tab. 4　Performance comparison of different models on the cucumber disease detection task

模型	mAP@0.5/%	P/%	R/%	$F1$/%	参数量/MB	计算量/GFLOPs
Rtdetr-l	83.8	87.6	79.1	83.1	63.2	103.5
YOLOv5n	87.7	86.4	85.0	85.6	5.0	7.1
YOLOv6n	87.0	87.5	80.9	84.0	8.3	11.8
YOLOv8n	88.1	87.0	84.3	85.6	5.4	6.8
YOLOv10n	87.2	88.1	80.8	84.1	5.5	6.5
YOLOv11n	88.7	89.1	84.3	86.6	5.2	6.4
YOLOv12n	87.3	87.9	83.6	85.6	5.3	6.3
WDL-YOLOv11	88.2	87.1	84.0	85.5	4.1	4.6

3.2　消融实验

为评估WaveletPool、Detect_LSCD与DySample模块的独立作用及协同效果,以YOLOv11n为基准模型设计6组消融实验,结果如表5所示。基准模型的mAP@0.5为88.7%,P为89.1%,R为84.3%,$F1$分数为86.6%,参数量为5.2 MB,计算量为6.4 GFLOPs。

表5　WDL-YOLOv11模型的消融实验

Tab. 5　Ablation experiment of the WDL-YOLOv11 model

WP	DL	DS	mAP@0.5/%	P/%	R/%	$F1$/%	参数量/MB	计算量/GFLOPs
×	×	×	88.7	89.1	84.3	86.6	5.2	6.4
√	×	×	88.5	84.9	86.2	85.5	4.4	5.4
×	√	×	88.4	87.7	84.1	85.8	4.9	5.6
×	×	√	88.5	87.3	85.8	86.5	5.3	6.3
√	√	×	88.1	88.4	83.9	86.0	4.1	4.7
√	√	√	88.2	87.1	84.0	85.5	4.1	4.6

注　WP:WaveletPool模块;DL:Detect_LSCD模块;DS:DySample模块。√表示采用该模块,×表示未采用该模块。

单独引入WaveletPool模块后,计算量与参数量分别下降至5.4 GFLOPs和4.4 MB,轻量化效果最为显著;召回率升至86.2%,但精确度小幅降至84.9%,mAP@0.5微降至88.5%。单独引入Detect_LSCD模块后,参数量降至4.9 MB,计算量降至5.6 GFLOPs,各项指标小幅下降,实现了低代价的参数压缩。单独引入DySample模块后,计算量小幅降至6.3 GFLOPs,召回率升至85.8%,$F1$分数达86.5%,整体检测一致性保持良好。组合WaveletPool与Detect_LSCD时,mAP@0.5为88.1%,参数量与计算量进一步压缩至4.1 MB和4.7 GFLOPs,虽出现轻微特征冲突,但复杂度压缩效果显著。3个模块全部引入构成WDL-YOLOv11后,mAP@0.5回升至88.2%,参数量保持在4.1 MB,计算量降至约4.6 GFLOPs,实现了最优的轻量化与性能平衡。综上,WaveletPool是轻量化的核心模块,大幅降低了参数量与计算量;Detect_LSCD辅助压缩参数量且对性能影响较小;DySample维持检测能力,有效缓解多模块组合带来的性能损失。三者协同可在精度基本稳定的前提下最大程度降低模型开销,有力支撑边缘端部署。

3.3　泛化实验

为验证所提改进结构的泛化性,将其分别移植到YOLOv11的n、s、m等3种模型上进行实验。

结果如表6所示。在YOLOv11n上，mAP@0.5仅下降0.5个百分点，参数量和计算量分别降低21.2%和28.1%；在YOLOv11s上，mAP@0.5下降0.4个百分点，但召回率升至86.5%、*F*1分数升至86.8%，参数量和计算量均大幅压缩；在YOLOv11m上，mAP@0.5略有提升，参数量、计算量及各评价指标均获小幅优化。该改进结构在不同规模的YOLOv11架构上普遍降低了模型复杂度，并维持甚至优化了检测性能，展现出良好的架构适应性与泛化能力，可为不同资源约束场景提供灵活的部署方案。

3.4　可视化结果

为进行定性评估，对YOLO系列轻量模型开展检测结果与注意力热力图的可视化对比(图5)。热力图显示，YOLOv11n的注意力分散于叶片边缘区域，易导致病斑定位偏差；而WDL-YOLOv11n的注意力则集中于病斑区域，有效抑制了背景干扰。检测结果表明，在复杂场景下，WDL-YOLOv11n的置信度和边界定位精度与基准模型相当，且优于其他轻量模型。上述结果直观验证了轻量化改进并未损害模型的核心检测性能，进一步证明了本方法的优势。

表6　泛化实验

Tab. 6　Generalization experiment

模型	mAP@0.5 /%	*P* /%	*R* /%	*F*1 /%	参数量 /MB	计算量 /GFLOPs
YOLOv11n	88.7	89.1	84.3	86.6	5.2	6.4
WDL-YOLOv11n	88.2	87.1	84.0	85.5	4.1	4.6
YOLOv11s	88.8	86.5	84.7	85.5	18.3	21.3
WDL-YOLOv11s	88.4	87.1	86.5	86.8	15.6	18.5
YOLOv11m	88.2	87.0	85.4	86.1	38.7	68.4
WDL-YOLOv11m	88.3	87.3	85.6	86.4	31.6	61.9

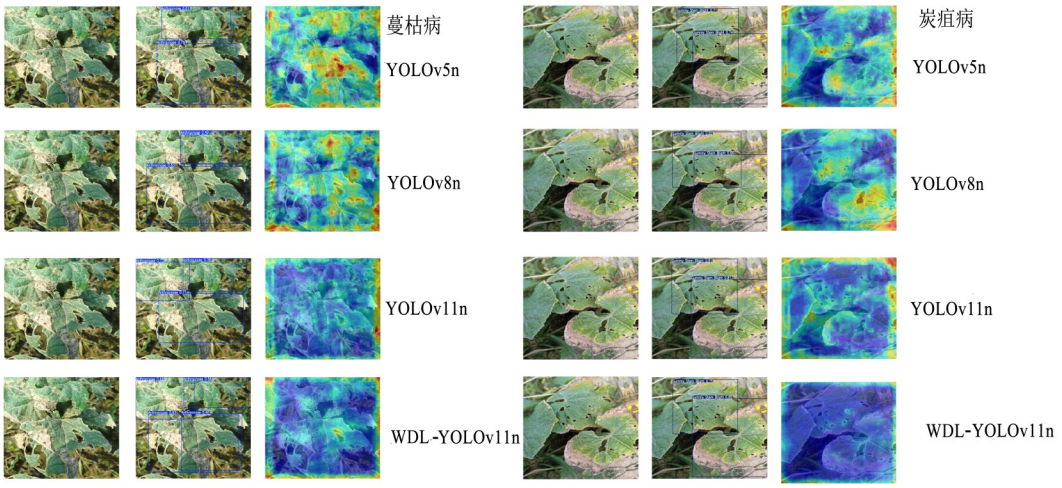


图5　不同模型的检测结果和热力图的可视化对比

Fig. 5　Comparative visualization of detection results and heatmaps from different models

4　结束语

针对现有黄瓜病害检测模型普遍存在重精度、轻部署的问题，以YOLOv11n为基础，通过引入WaveletPool、DySample、Detect_LSCD等3个改进模块，构建了轻量化病害检测模型WDL-YOLOv11，在检测性能与模型轻量化之间实现了有效平衡，为农业边缘计算场景下的病害实时检测提供了技术方案。三者协同作用有效缓解了轻量化改造过程中常见的精度与效率失衡问题。

在包含5类黄瓜病害及健康叶片的5191张图像数据集上，WDL-YOLOv11的mAP@0.5达到88.2%，参数量为4.1 MB，计算量为4.6 GFLOPs。与基准模型相比，参数量减少21.2%，计算量降低28.1%，精度仅下降0.5个百分点。与Rtder-l及其他轻量化YOLO系列模型相比，本模型在参数量与计算量上均为最优，检测精度位居前列。泛化性实验表明，该改进结构在YOLOv11的n、s、m等3种架构中均具备良好的适应性；可视化结果进一步证实模型能够有效聚焦病斑区域、抑制背景干扰。本模型在精度基本稳定的前提下实现了模型轻量化水平的大幅提升，可为黄瓜田间实时精准检测提供高效解决方案。

然而，本研究仍存在以下不足：模型在严重遮挡、运动模糊、极端光照等复杂田间环境下的鲁棒性有待进一步提升；目前仅在实验室数据集上完

成验证,尚未开展大规模田间实测;病害类别仅覆盖5种常见类型,需进一步扩展;模型在边缘设备上的推理速度、功耗等实际部署指标仍需通过硬件实测进行评估。

参考文献:

[1] 秦立峰, 李博棣, 林敬轩, 等. 基于SGD-YOLO模型的黄瓜霜霉病检测[J]. 农业机械学报, 2026, 57(2): 203-214.

[2] 周成松, 吉艳玲, 毛亮, 等. 吐鲁番秋延设施黄瓜病虫害绿色防控技术[J]. 蔬菜, 2020(11): 52-54.

[3] 魏运伟. 设施栽培黄瓜全生育期主要病虫害绿色防控技术[J]. 种子科技, 2017, 35(3): 92-93.

[4] 王哲, 张华, 屠春宝, 等. 设施黄瓜病虫害特点及绿色防控技术[J]. 农业科学, 2023, 13(6): 545-553.

[5] 刘诗怡, 胡滨, 赵春. 基于改进YOLOv7的黄瓜叶片病虫害检测与识别[J]. 农业工程学报, 2023, 39(15): 163-171.

[6] DeShields J B, Bomberger R A, Woodhall J W, et al. On-site molecular detection of soil-borne phytopathogens using a portable real-time PCR system[J]. Journal of Visualized Experiments, 2018(132): 56891.

[7] Menco-Tovar A, Martinez-Santos J C, Puertas E. Detection of diseases in cucumber using deep neural networks[J]. Neural Computing and Applications, 2026, 38(5): 127.

[8] Wang Ao, Chen Hui, Liu Lihao, et al. YOLOv10: real-time end-to-end object detection[C]//Advances in Neural Information Processing Systems 37. December 10-15, 2024. Vancouver, BC, Canada. Neural Information Processing Systems Foundation, Inc. (NeurIPS), 2024: 107984-108011.

[9] Song Yan, Li Danpei, He Pinglai, et al. YOLOv10-CBAM: lightweight metal surface defect detection based on YOLOv10[C]//2025 International Conference on Equipment Intelligent Operation and Maintenance (ICEIOM). August 1-3, 2025, Urumqi, China. Piscataway, NJ: IEEE, 2025: 257-265.

[10] Omer S M, Ghafoor K Z, Askar S K. Lightweight improved YOLOv5 model for cucumber leaf disease and pest detection based on deep learning[J]. Signal, Image and Video Processing, 2024, 18(2): 1329-1342.

[11] Liu Jun, Wang Xuewei, Chen Qian, et al. Deep learning method for cucumber disease detection in complex environments for new agricultural productivity[J]. BMC Plant Biology, 2025, 25(1): 888.

[12] 肖双喜, 姚彤彤, 李灿. 基于改进MobileNetV2的轻量化茶叶病害检测方法[J]. 华南农业大学学报, 2025, 46(6): 801-809.

[13] 罗志聪, 李鹏博, 宋飞宇, 等. 嵌入式设备的轻量化百香果检测模型[J]. 农业机械学报, 2022, 53(11): 262-269, 322.

[14] 黄河清, 胡嘉沛, 李震, 等. 基于边缘计算的柑橘果实识别系统的设计[J]. 湖南农业大学学报(自然科学版), 2021, 47(6): 727-732.

[15] 李玉华, 刘全程, 李天华, 等. 基于Jetson Nano处理器的大蒜鳞芽朝向调整装置设计与试验[J]. 农业工程学报, 2021, 37(7): 35-42.

[16] 孙寿松, 李新凯, 张宏立, 等. 嵌入式平台的番茄叶片病虫害检测模型[J]. 计算机工程与应用, 2025, 61(16): 305-314.

[17] 兰玉彬, 孙斌书, 张乐春, 等. 基于改进YOLOv5s的自然场景下生姜叶片病虫害识别[J]. 农业工程学报, 2024, 40(1): 210-216.

[18] 马超伟, 张浩, 马新明, 等. 基于改进YOLOv8的轻量化小麦病害检测方法[J]. 农业工程学报, 2024, 40(5): 187-195.

[19] 李龙海, 王轶哲, 吴禹竺, 等. 基于剪枝与蒸馏的轻量化玉米病害检测方法[J]. 农业工程学报, 2025, 41(17): 194-202.

[20] 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.

[21] 张志豪, 厉小润, 陈淑涵. 基于改进YOLO11的无人机航拍图像小目标检测算法[J]. 液晶与显示, 2025, 40(6): 915-930.

[22] 王兴伟, 李霞, 朱志航, 等. 基于改进YOLO11n的多种类杂草检测模型[J/OL]. 天津理工大学学报, 2026-05-28. https://link.cnki.net/urlid/12.1374.N.20260303.1018.002.

[23] 张帅, 王波涛. 基于改进YOLO11-seg的轻量化病虫害分割模型[J]. 农业工程学报, 2025, 41(24): 173-181.

责任编辑:陈松楠　张伟博