

# 基于改进 YOLO v8n 的田间棉花蚜害精确检测与严重度分级

康桓瑜<sup>1</sup> 郑招辉<sup>1</sup> 温浩军<sup>1,2</sup> 黄伟荣<sup>3</sup>

(1. 石河子大学机械电气工程学院, 石河子 832003; 2. 农业农村部西北农业装备重点实验室, 石河子 832003; 3. 新疆农业大学机电工程学院, 乌鲁木齐 830052)

**摘要:** 对于田间环境中棉花受蚜害叶片目标尺度较小、重叠度高及背景复杂等问题, 传统检测方法往往难以兼顾精度与实时性, 导致在实际应用中效果有限。为此, 提出了一种改进的轻量化检测模型。该模型在 YOLO v8n 的基础上, 添加了自适应下采样模块 (Adaptive downsampling module, ADown) 以强化局部特征提取, 引入空间增强注意力机制 (Spatially enhanced attention module, SEAM) 实现多尺度信息交互, 并构建了密集小目标感知的 Focal - EIoU 损失函数, 有效提升了模型对小目标和复杂背景的适应性。在自建数据集上的试验结果表明, 改进的模型在参数量显著减少的同时, 检测精度得到明显提升。平均精度均值达到 96.2%; 此外, 消融试验进一步证明了每个模块在提升棉花蚜害叶片严重度检测模型整体性能的有效性。综合结果表明, 所改进的模型在保证轻量化的同时兼顾检测精度与模型部署效率, 为农业害虫智能监测提供了一种可行的解决方案。

**关键词:** 棉花蚜害; 检测模型; YOLO v8n; 轻量化; 注意力机制; 损失函数

中图分类号: TP242

文献标识码: A

文章编号: 1000-1298(2026)07-0089-08

OSID:



## Accurate Detection and Severity Grading of Cotton Aphid Infestation in Field Based on Improved YOLO v8n

KANG Huanyu<sup>1</sup> ZHENG Zhaohui<sup>1</sup> WEN Haojun<sup>1,2</sup> HUANG Weirong<sup>3</sup>

(1. College of Mechanical and Electrical Engineering, Shihezi University, Shihezi 832003, China

2. Key Laboratory of Northwest Agricultural Equipment, Ministry of Agriculture and Rural Affairs, Shihezi 832003, China

3. Mechanical and Electronical Engineering Institute, Xinjiang Agricultural University, Urumqi 830052, China)

**Abstract:** In order to address the problems of small target scale, high overlap, and complex background of cotton leaves affected by aphids in field environments, traditional detection methods often struggle to balance accuracy and real-time performance, resulting in limited effectiveness in practical applications. Therefore, an improved lightweight detection model was proposed. On the basis of YOLO v8n, an adaptive downsampling module (ADown) was added to enhance local feature extraction, a spatially enhanced attention module (SEAM) was introduced to achieve multi-scale information exchange, and a Focal - EIoU loss function was constructed for dense small object perception, effectively improving the model's adaptability to small objects and complex backgrounds. The experimental results on the self built dataset showed that the improved model achieved significant improvement in detection accuracy while significantly reducing the number of parameters. The average accuracy reached 96.2%. In addition, the ablation study further demonstrated the effectiveness of each module in enhancing the overall performance of the cotton aphid infestation severity detection model. The comprehensive results indicated that the improved model balanced detection accuracy and model deployment efficiency while ensuring lightweight, providing a feasible solution for intelligent monitoring of agricultural pests.

**Key words:** cotton aphid infestation; detection model; YOLO v8n; lightweight; attention mechanism; loss function

收稿日期: 2026-01-07 修回日期: 2026-01-13

基金项目: 财政部和农业农村部: 国家棉花产业技术体系建设项目 (CARS-15-26)

作者简介: 康桓瑜 (1998-), 女, 博士生, 主要从事智能农业装备研究, E-mail: kanghuanyu2022@163.com

通信作者: 温浩军 (1971-), 男, 研究员, 博士生导师, 主要从事农业机械化研究, E-mail: 547273950@qq.com

## 0 引言

棉花作为全球最重要的经济作物之一,在纺织工业和国家经济发展中发挥着重要作用<sup>[1-3]</sup>。然而,棉花在整个生长周期中极易受到多种病虫害的侵袭,其中棉蚜是最具破坏性的害虫之一。棉蚜通过刺吸叶片汁液,不仅直接导致棉株营养不良、叶片卷曲皱缩,影响光合作用,其排泄的蜜露还会诱发煤污病<sup>[4-5]</sup>,进一步阻碍植株生长,最终造成棉花产量与品质的严重下降。棉蚜的暴发还会破坏棉田生态平衡,因其作为初级消费者数量的激增,可能影响更高营养级的生物种群动态,并成为病毒的传播媒介,引发次生灾害。

传统的蚜虫防治主要依赖于化学防治,即大面积、周期性的化学农药喷洒,这种模式不仅导致了农药的过度使用,增加了生产成本和农民的健康风险,更引发了严重的环境污染(土壤、水体污染)、农药残留超标及蚜虫抗药性增强等一系列严峻的生态问题<sup>[6-7]</sup>,威胁食品安全与生物多样性。因此,实现棉田蚜情的精准、快速识别与监测,是推动棉花生产绿色、智能、可持续发展的关键前提,对于保障国家棉花产业安全、促进农业现代化具有现实意义。

在蚜害监测的早期阶段,主要依赖于农业技术人员或植保专家的田间实地勘查<sup>[8-9]</sup>。这种方法主要依靠人眼的观察和经验进行判断,其过程耗时费力,且覆盖范围有限,难以实现对大田区域的快速、全面普查。此外,人工识别结果的准确性和一致性极易受到调查者主观状态、专业知识水平以及田间复杂环境(如光照变化、观察角度)的影响,导致识别效率低下且误差较大。虽然后续出现了一些基于诱集器、色板等物理工具的辅助监测手段<sup>[10-12]</sup>,但它们大多只能提供害虫的种群密度估计,无法实现对单株或单叶级别蚜虫危害的精准定位与程度评估。传统方法的这些固有缺陷,使其无法满足现代农业对病虫害实时、高精度预警与防控的迫切需求。

随着传感器与信息技术的发展,早期的自动化监测技术开始涌现,例如基于光谱反射特性的遥感监测和基于传统图像处理技术的识别方法。这类技术在一定程度上减少了对人力的依赖,能够获取更大范围的作物生长态势信息。然而,基于遥感的监测空间分辨率往往不足,难以识别单株病虫害;而基于颜色、纹理等设计特征的图像识别方法,在应对田间复杂的背景、多变的光照条件以及病虫害症状的多样性时,特征表达能力有限,鲁棒性和泛化能力较差,难以满足高精度、实时在线监测的需求。

随着计算机视觉与深度学习技术的迅猛发展,

基于图像的农作物病虫害自动识别技术应运而生,为解决上述难题开辟了新的路径。以 YOLO 系列为代表的单阶段目标检测算法,已成为当前农业病虫害智能检测领域的主流架构之一,其持续演进显著推动了该研究方向的技术前沿。如祝诗平等<sup>[13]</sup>针对自然环境下识别车前草病虫害检测效率低等问题,提出一种基于 YOLO v8n - Plantago 的车前草病虫害检测方法。朱惠斌等<sup>[14]</sup>结合图像处理和机器视觉技术,对玉米田间病虫害自动、快速和准确识别。文献<sup>[15]</sup>尝试融合深度或多光谱等多模态数据,以提供超越 RGB 色彩的空间与光谱信息,从而抵抗光照干扰。然而,这类前沿模型的优化多侧重于通用架构的增强,对农业场景中特有的、密集遮挡问题的针对性不足。此外,结构复杂性的增加可能损害其部署实时性,而多模态方案则依赖于昂贵的专用传感器,抬高了大规模应用的门槛。

尽管现有深度学习模型在实验室环境或受控条件下表现优异,但当其直接应用于真实、复杂的田间场景进行棉蚜识别时,仍面临诸多严峻挑战与固有弊端,如复杂背景干扰、叶片相互遮挡等导致了在许多理想数据集上训练出的模型,在实际部署时性能显著下降。

针对上述瓶颈问题,本文以 YOLO v8n 作为模型的基础来进行改进与优化,通过在主干及颈部添加 ADown 以强化局部特征提取,引入 SEAM 实现多尺度信息交互,构建密集小目标感知的 Focal - EIou 损失函数,来提升模型对小目标和复杂背景的适应性。以期为复杂场景下农业病虫害的高效智能检测技术研发,以及病虫害智能防治作业装备的创新设计提供技术支撑。

## 1 材料与方 法

### 1.1 图像采集装置

图像采集设备为 DJi Mavic3 型无人机(图 1),详细参数见表 1。为确保所收集样本的多样性,共收集了 1 050 幅图像,涵盖了多种因素,如不同的光照水平、不同的照明角度以及不同的天气条件等。格式为 jpg。

### 1.2 棉花蚜害严重等级划分

参照 GB/T 22101.1—2008《棉花抗虫性评价技



图 1 DJi Mavic3 型无人机

Fig. 1 DJi Mavic3 drone

表1 无人机参数

Tab.1 Drone parameters

参数	数值
轴距/mm	380.1
无人机起飞质量/g	1 050
最大飞行海拔高度/m	6 000
最大水平飞行速度/(m·s <sup>-1</sup> )	15
续航时间/min	43
图像分辨率/(像素×像素)	3 840×2 160

术规范》<sup>[16]</sup>中的级别划分标准,将棉花受蚜害侵蚀叶片划分为5个等级,具体分类标准如表2所示。

表2 棉花蚜害的分级标准

Tab.2 Grading standards for cotton aphid infestation

蚜害级别	为害描述	卷曲比例/%
Normal	无蚜虫,叶片平展	0
Mild	有蚜虫,叶片无受害	0~20
Moderate	有蚜虫,受害最重的叶片皱缩或微卷,近半圆	20~50
Emphasis	有蚜虫,受害最重的叶片卷曲达半圆或半圆以上,呈弧形	50~75
Heavy	有蚜虫,受害最重的叶片完全卷曲,呈球形	75~100

### 1.3 数据集构建

棉花蚜害叶片图像数据于2024年7—8月在新疆农业科学院玛纳斯试验站采集,采集时间段为14:00—17:00,通过筛选后共计1 050幅图像。为了避免因图像数量有限而导致的过拟合现象,通过对图像进行亮度调整、镜像、旋转、平移和锐化等操作,对图像进行了增强和扩展<sup>[17-18]</sup>。在进行数据增强后,部分图像因变换导致目标丢失,经过筛选、增强后的数据集中剩余2 909幅图像,如表3所示。

表3 数据构成

Tab.3 Data composition

蚜害级别	数据集图像数	
	数据增广前	数据增广后
Normal	175	584
Mild	239	632
Moderate	196	579
Emphasis	213	601
Heavy	227	513
总计	1 050	2 909

根据表2中的分类标准,使用LabelImg对图像进行标注,健康棉叶标注为Normal,轻度感染棉叶为Mild,中度感染为Moderate,偏重感染为Emphasis,重度感染为Heavy。图像标注完成后,会生成相应的XML文件,其中包含边界框的位置信息和类别详情。将数据集按比例8:1:1分为训练集、

测试集和验证集,用于模型的训练和测试工作。

### 1.4 试验环境配置

为确保试验顺利进行,对试验环境和试验参数采用统一的配置,CPU为Intel i9-12900K,GPU为NVIDIA GeForce RTX 3090Ti,操作系统采用Windows 10,深度学习框架采用PyTorch 1.12,编程语言采用Python 3.8,集成开发环境采用PyCharm 2020.1.3。

在模型训练阶段,输入图像尺寸640×640,设定初始学习率为0.01、训练轮次为200轮、批次大小为8、动量因子为0.937。

### 1.5 试验评价指标

本研究构建了一个多维评价体系,旨在评估轻量化处理对模型性能的影响。选取的评估指标包括:精确率、召回率、平均精度均值(mAP, Mean average precision)、模型参数量、模型浮点运算量以及模型内存占用量。

## 2 模型改进

### 2.1 YOLO v8 模型

YOLO v8<sup>[19]</sup>是一种高效深度学习模型,主要用于目标检测领域,其继承了YOLO系列算法的传统模式,能实现高精度且快速的目标检测。YOLO v8的主干网络采用了YOLO v5<sup>[20]</sup>中的CSP(Cross stage partial)结构,但其模块设计进行了优化。其主要改进在于,YOLO v8用C2f模块替换了YOLO v5中的原始C3模块,从而降低了模型的内存消耗并提高了计算效率。同时,YOLO v8引入CIoU损失函数,有效提高目标框回归准确性。此外,YOLO v8还优化数据增强和训练策略,使模型在不同规模和背景下的性能更加稳定。

针对不同体量任务,YOLO v8设计了5种不同尺寸的模型,基于轻量化设计要求,本文选择最小尺寸的YOLO v8n作为基线模型。将Backbone和Neck中部分C2f模块替换为ADown,保留原始特征提取能力的同时简化模型;在颈部引入SEAM,并替换原有损失函数为Focal-EIoU,提高在复杂场景下识别性能。改进的YOLO v8n模型结构如图2所示。

### 2.2 自适应下采样模块

自适应下采样模块是一种智能的特征图下采样方法,相比传统的池化或步长卷积,能够更好地保留重要特征信息<sup>[21]</sup>,其结构如图3所示。在棉花蚜害叶片检测任务中,在Backbone部分将ADown模块替换传统下采样层,其通过可学习的参数自适应地融合局部特征,能够在进行特征图尺寸缩减时,有选

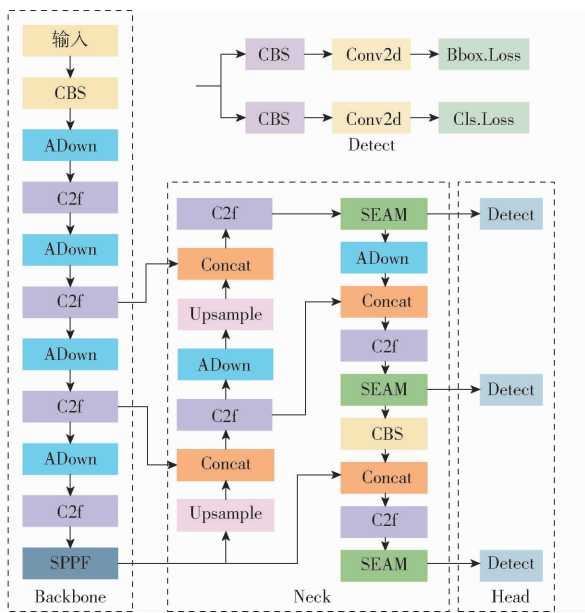


图2 改进 YOLO v8n 网络结构图

Fig.2 Improved YOLO v8n network structure diagram

择性地保留与蚜害相关的微小纹理特征(如叶片失绿斑点)和边缘信息,避免传统池化或步长卷积可能造成的细小蚜虫特征或早期点状病灶的特征平滑与丢失问题<sup>[22-23]</sup>。在 Neck 部分,ADown 模块与上采样操作交替使用,形成了一种非对称的、信息保留更充分的多尺度特征融合路径,可以有效处理棉花叶片图像中受害叶片目标尺度变化大的问题,它保证了网络在聚合高层语义信息以检测大范围受害区域的同时,下采样路径仍能为低层特征图提供足够精细的空间细节,从而维持了对小型单叶及轻微受害叶片的检测灵敏度<sup>[24-25]</sup>。

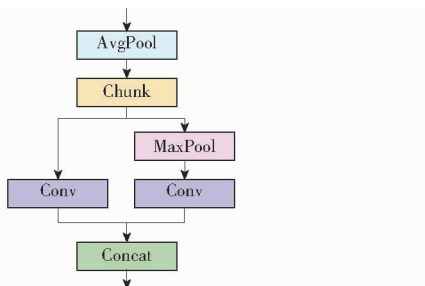


图3 ADown 结构图

Fig.3 ADown structure diagram

### 2.3 空间增强注意力模块

空间增强注意力模块是一种用于增强卷积神经网络空间感知能力的注意力机制<sup>[26]</sup>。它通过建模空间维度上的依赖关系,使网络能够更好地关注重要的空间区域,其结构如图4所示。棉花叶片受害后,蚜虫及其引发的病灶(如卷曲、黄化)在空间分布上具有不规则、局部集中的特点,且常与健康的叶脉、叶肉组织及复杂的田间背景(如土壤、杂草)混杂。SEAM 部署于 YOLO v8 架构的检测头前关键位

置,使网络在最终决策前,能够依据特征图自身的空间上下文,主动增强疑似病灶区域(高响应区域)的权重,并抑制背景及健康组织区域的干扰。这种机制直接提升了模型对“受害区域”与“非受害区域”的空间判别能力,而非均匀地处理整个叶片。

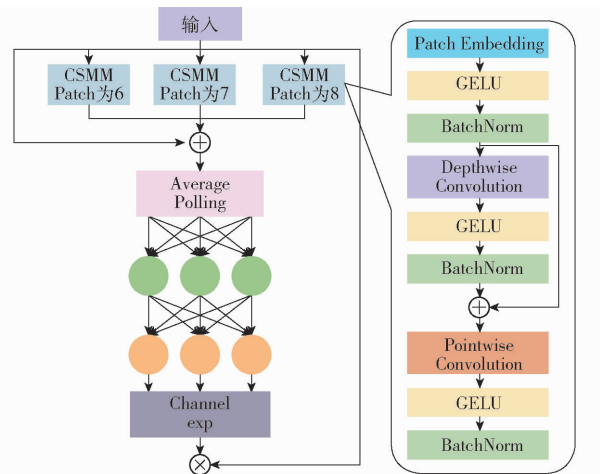


图4 SEAM 结构图

Fig.4 SEAM structure diagram

SEAM 模块的多尺度空间上下文捕获机制特别适合处理棉花蚜害叶片分布的不规则性和尺度多样性<sup>[27-28]</sup>。与 ADown 的协同作用进一步增强了模型的多尺度特征表示能力,在保持特征图空间分辨率的同时提升了对于细微病害特征的保留程度。这种空间注意力机制的引入使得改进后的模型在复杂农业场景下具备更强的鲁棒性,能够有效应对光照变化、叶片遮挡、姿态多样等实际挑战,为棉花蚜害的精准识别和严重程度评估提供了可靠的技术保障。

### 2.4 Focal - EIoU

Focal - EIoU 损失函数是一种先进的边界框回归损失函数,它结合了 EIoU (Efficient IoU) 和 Focal Loss 的优势,专门针对目标检测中的边界框回归问题进行了优化<sup>[29]</sup>。该损失函数在传统 IoU 基础上引入了中心点距离、宽高比的一致性度量,同时融入了 Focal 机制来解决难易样本不平衡问题。具体而言,Focal - EIoU 通过 3 个分量来优化边界框回归:重叠面积损失、中心点距离损失和宽高差异损失,并利用 Focal 因子动态调整不同难度样本的权重,使模型在训练过程中更加关注那些难以定位的边界框样本。

由于受蚜害叶片目标小、分布密集,传统损失函数在处理这类复杂场景时容易出现定位不准、收敛缓慢的问题,将 YOLO v8n 中的 CIoU 损失函数替换为 Focal - EIoU 能够更准确地度量小尺寸叶片边界框的回归质量,特别是在处理密集棉叶群体时,能够有效区分相邻个体边界,避免检测框的重叠和漏检。

其引入的 Focal 机制使得模型在训练过程中自动聚焦于那些难以定位的样本,如部分遮挡、姿态异常的个体,而不是被大量简单样本主导训练过程,这显著提升了模型对复杂场景下棉花蚜害叶片识别的鲁棒性。同时,Focal - EIou 的收敛速度更快且更稳定,在棉花叶片图像背景复杂、目标尺度变化大的情况下,能够帮助模型更快地学习到准确的定位特征,减少训练过程中的振荡现象,最终实现更高的检测精度和更好的泛化能力。

### 3 结果与分析

#### 3.1 不同注意力机制对比试验

为了进行对比测试,在 YOLO v8n 模型中增加了其他 3 种具有代表性的注意力机制,以验证注意力机制应用于模型本身的有效性。包括卷积注意力机制 (Convolutional block attention module, CBAM)<sup>[30]</sup>、高效通道注意力机制 (Efficient channel attention, ECA)<sup>[31]</sup> 和感受野注意力机制 (Receptive-field attention, RFA)<sup>[32]</sup>。对比结果如表 4 所示。

由表 4 可知 SEAM 表现最为突出,其精确率达到 85.6%,召回率为 89.8%,mAP 达到 86.5%,相比基准模型分别提升了 2.1、1.6、1.7 个百分点。

表 4 不同通道注意力机制在 YOLO v8n 中性能  
Tab. 4 Performance of different channel attention mechanisms in YOLO v8n

模型	精确率/ %	召回 率/%	mAP/ %	内存占用 量/MB
YOLO v8n	83.5	88.2	84.8	6.2
YOLO v8n + CBAM	84.2	88.8	85.5	6.8
YOLO v8n + ECA	83.8	88.5	85.1	6.4
YOLO v8n + RFA	84.5	89.0	85.8	7.0
YOLO v8n + SEAM	85.6	89.8	86.5	7.2

SEAM 模块独特的多尺度空间增强机制,能够有效聚焦棉花叶片上蚜虫病害的细微特征,在复杂背景下准确区分受害区域与健康组织。在其他注意力机制的对比中,RFA 凭借其递归结构在召回率和 mAP 较高,而 CBAM 则通过通道与空间注意力的串联组合在精确率方面具有一定优势。ECA 性能提升相对有限但计算代价最小,内存占用量仅增加 0.2 MB。而 SEAM 在获得最佳检测性能的同时,内存占用增加幅度为 1.0 MB,处于合理范围,保持了模型的实用性和部署可行性。

#### 3.2 消融试验

为了验证改进的模型对棉花受蚜害叶片检测的有效性,开展了消融试验,试验结果如表 5 所示。

表 5 消融试验结果

Tab. 5 Ablation test results

ADown	SEAM	Focal - EIou	精确率/%	召回率/%	mAP/%	参数量	浮点运算量	内存占用量/MB
×	×	×	83.5	88.2	84.8	$3.01 \times 10^6$	$8.20 \times 10^9$	6.2
√	×	×	85.2	89.6	95.5	$3.28 \times 10^6$	$8.86 \times 10^9$	6.7
×	√	×	85.6	89.8	95.9	$3.42 \times 10^6$	$9.05 \times 10^9$	7.0
×	×	√	84.8	89.3	95.7	$3.01 \times 10^6$	$8.20 \times 10^9$	6.2
√	√	×	86.3	90.1	96.0	$3.56 \times 10^6$	$9.33 \times 10^9$	7.3
√	×	√	86.0	90.0	95.8	$3.28 \times 10^6$	$8.86 \times 10^9$	6.7
×	√	√	86.1	90.2	96.1	$3.42 \times 10^6$	$9.05 \times 10^9$	7.0
√	√	√	86.8	90.5	96.2	$3.45 \times 10^6$	$9.15 \times 10^9$	7.1

注: × 表示不引入此模块;√表示引入此模块。

由表 5 可知单独引入 ADown 模块使 mAP 提升至 95.5%,精确率和召回率分别达到 85.2% 和 89.6%,证明其自适应特征保留机制能有效维持受害叶片目标的细节信息;单独集成 SEAM 模块获得 95.9% 的 mAP,其空间注意力机制显著增强了对蚜虫分布区域的定位能力;而单独采用 Focal - EIou 在保持模型复杂度不变的前提下仍将 mAP 提升至 95.7%,显示出其在难易样本平衡和边界框回归优化方面的独特优势。

ADown + SEAM 组合的 mAP 为 96.0%,性能优于任一单一模块,且精确率与召回率均有进一步提升。这表明 ADown 提供的多尺度细节保留与

SEAM 实现的空间选择性增强形成了有效互补:前者为注意力机制提供了更完整、信息损失更少的特征图,后者则在前者基础上实现了对关键区域的精准提取,两者协同显著提升了特征表示的品质。

ADown + Focal - EIou 与 SEAM + Focal - EIou 组合的 mAP 分别达到 95.8% 和 96.1%。对比发现,SEAM 与 Focal - EIou 的组合效果更优。这可能是因为 SEAM 在特征层面增强了对目标区域的响应,而 Focal - EIou 在损失函数层面进一步强化了对已被注意但定位困难样本的优化,两者从特征强调与梯度优化的两个不同维度形成了合力。

完整改进后的模型 mAP 达到 96.2%,精确率

和召回率分别提升至 86.8% 和 90.5%。这说明各模块间的协同增强效应: ADown 模块通过改进下采样过程保留更多特征细节, 为后续处理提供丰富的信息基础; SEAM 模块在此基础上强化空间特征选择, 提升对关键区域的关注度; Focal - EIoU 则从损失函数层面优化训练过程, 进一步提高定位精度。改进后模型的参数量 ( $3.45 \times 10^6$ ) 和浮点运算量 ( $9.15 \times 10^9$ ) 仅较基准模型适度增加, 保持了模型的

实用性和部署可行性。

### 3.3 不同检测模型对比试验

为验证改进后 YOLO v8n 模型在检测精度和实时性上的综合性能, 选取 YOLO v8n、YOLO v7 - Tiny<sup>[33]</sup>、YOLO v6n<sup>[34]</sup>、YOLO v5n、Faster R - CNN<sup>[35]</sup> 和 SSD<sup>[36]</sup> 共 6 种主流模型进行试验对比分析, 所有模型均在相同环境下测试, 试验结果如表 6 所示。

表 6 不同目标监测模型性能对比

Tab.6 Comparison of performance of different target monitoring models

模型	精确率/%	召回率/%	mAP/%	参数量	浮点运算量	内存占用量/MB
YOLO v8n	83.5	88.2	84.8	$3.01 \times 10^6$	$8.20 \times 10^9$	6.2
YOLO v7 - Tiny	82.0	87.0	83.5	$6.01 \times 10^6$	$1.32 \times 10^{10}$	10.5
YOLO v6n	82.5	87.5	83.8	$2.80 \times 10^6$	$7.50 \times 10^9$	5.8
YOLO v5n	81.5	86.5	82.5	$1.90 \times 10^6$	$4.50 \times 10^9$	4.5
Faster R - CNN	85.0	85.0	85.0	$4.10 \times 10^7$	$1.00 \times 10^{11}$	50.0
SSD	80.0	82.0	80.0	$2.60 \times 10^7$	$6.20 \times 10^{10}$	30.0
本文	86.8	90.5	96.2	$3.45 \times 10^6$	$9.15 \times 10^9$	7.1

由表 6 可知改进模型在关键检测指标上均表现出最优性能, 其中精确率为 86.8%, 召回率为 90.5%, mAP 为 96.2%, 显著优于其他对比模型。改进后模型参数量为  $3.45 \times 10^6$ , 浮点运算量为  $9.15 \times 10^9$ , 内存占用量为 7.1 MB, 相较于 YOLO v7 - Tiny 和 Faster R - CNN 等模型具有明显的效率优势。与其他轻量级模型相比, YOLO v5n 虽然具有最低的参数量和计算成本, 但其检测精度显著低于本研究提出的方法。尽管 Faster R - CNN 在精确率方面表现尚可, 但其召回率相对较低, 且模型复杂度显著高于单阶段检测器。这说明将 ADown 和 SEAM 集成到 YOLO v8n 基础架构中的有效性, 以及 Focal - EIoU 损失函数的优化策略使模型能够更好地适应棉花蚜害叶片检测的特殊需求。

### 3.4 模型训练测试

对改进后的 YOLO v8n 在测试集上进行测试。棉花蚜害叶片不同严重程度检测结果见表 7。

表 7 不同蚜害程度结果对比

Tab.7 Comparison of results on different degrees of aphid infestation %

蚜害级别	精确率	召回率	mAP
Normal	88.0	91.2	97.3
Mild	90.3	93.0	97.7
Moderate	86.3	89.7	95.5
Emphasis	83.8	88.7	94.8
Heavy	85.6	89.9	95.7
整体	86.8	90.5	96.2

尽管改进后的模型在棉花蚜害叶片检测任务中取得了整体优异的性能 (mAP 达到 96.2%), 但从表 7 可以看出, 模型对不同蚜害程度的叶片检测性能存在差异。具体而言, Emphasis 和 Heavy 叶片的精确率与召回率相对略低。由于 Emphasis 和 Heavy 级别的叶片其受害特征更为密集和严重, 常表现为叶片大面积卷曲、黄化、皱缩, 甚至出现煤污病等次生症状。严重卷曲的叶片使得目标本身的边界变得难以界定, 与背景或其他叶片粘连, 导致边界框定位难度增加, 影响了定位精度, 部分表现为精确率的下降。密集的蚜虫群落、分泌物以及严重的病斑相互重叠, 使得单个受害特征的可辨别性降低。模型可能将一个大面积的连续受害区域识别为多个小目标, 或将重叠的目标漏检, 这直接导致了召回率的轻微损失。

为了测试改进后的 YOLO v8n 模型在 5 种病害程度叶片数据集的真实识别性能, 将数据集中的测试集输入到模型中进行验证。如图 5 所示, 该模型能够准确检测出每幅图像中的受害叶片图像, 并有效区分不同的严重程度。

## 4 结论

(1) 通过系统地集成 ADown、SEAM 和 Focal - EIoU 损失函数, 构建了适用于复杂田间场景的棉花蚜害叶片检测模型。消融试验结果表明, 改进后的模型在保持轻量化特性的同时, 检测性能得到显著提升, mAP 达到 96.2%, 精确率和召回率分别提升




图 5 YOLO v8n 改进后图像检测结果

Fig. 5 Image detection results before and after YOLO v8n improvement

至 86.8% 和 90.5%。各改进模块展现出明显的协同增强效应: ADown 模块通过自适应特征保留机制有效维持了蚜害叶片的细节信息, SEAM 模块通过空间注意力机制强化了对病灶区域的定位能力, 而 Focal - EIoU 则通过优化边界框回归过程提升了小目标的检测精度。

(2) 改进模型在保持轻量化优势的同时, 实现了精度与效率的最佳平衡。相较于 YOLO v7 - Tiny、YOLO v5n 等轻量化模型, 本研究的模型在参数量为  $3.45 \times 10^6$ 、浮点运算量为  $9.15 \times 10^9$  的适中复杂度下, 获得了显著的性能优势。同时, 与 Faster R - CNN 等两阶段检测器相比, 在保持较高检测精度的基础上大幅降低了计算资源消耗。模型对不同严重程度蚜害叶片均表现出良好的适应性, 特别是在早期危害识别方面表现优异, 对 1 级受害叶片的检测 mAP 达到 97.7%。

## 参 考 文 献

- [1] 蔡路, 张正贵, 兰雅琦, 等. CCER 机制下中国棉花碳信用潜力及其经济价值[J]. 棉花学报, 2025, 37(2): 79 - 93.  
CAI Lu, ZHANG Zhengui, LAN Yaqi, et al. The carbon credit potential and economic value of China cotton based on CCER mechanism[J]. Cotton Science, 2025, 37(2): 79 - 93. (in Chinese)
- [2] 潘昊, 张若宇, 蔡凤杰, 等. 棉花生产智慧农场标准体系研究[J]. 农业机械学报, 2025, 56(5): 38 - 48.  
PAN Hao, ZHANG Ruoyu, CAI Fengjie, et al. Standard system for smart cotton production farms[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(5): 38 - 48. (in Chinese)
- [3] 火勋国, 杜鸿君, 孙帅, 等. 新气候态下新疆棉花种植气候适宜性区划[J]. 沙漠与绿洲气象, 2025(4): 37 - 45.  
HUO Xunguo, DU Hongjun, SUN Shuai, et al. Climate suitability zoning for cotton cultivation in Xinjiang under the new climate regime[J]. Desert and Oasis Meteorology, 2025(4): 37 - 45. (in Chinese)
- [4] 杨惠敏, 李茂春, 杨景燕, 等. 新疆沙雅县棉田蚜虫发生与气象因子关系分析[J]. 中国棉花, 2025, 52(6): 45 - 48.  
YANG Huimin, LI Maochun, YANG Jingyan, et al. Analysis of the relationship between aphids occurrence and meteorological factors in cotton fields, Shaya County, Xinjiang[J]. China Cotton, 2025, 52(6): 45 - 48. (in Chinese)
- [5] 李庆锁. 棉花主要病虫害识别与综合防控策略研究[J]. 农业开发与装备, 2025(4): 187 - 189.
- [6] 沈丹, 单莹, 刘艳珍, 等. 棉花蚜虫防治药剂筛选[J]. 园艺与种苗, 2024, 44(2): 95 - 96.  
SHEN Dan, SHAN Ying, LIU Yanzhen, et al. Screening of cotton aphid control agents[J]. Horticulture and Seed, 2024, 44(2): 95 - 96. (in Chinese)
- [7] 吕少宏. 基于棉花田间管理与病虫害防治技术分析[J]. 中文科技期刊数据库(全文版)农业科学, 2024(2): 122 - 125.  
LÜ Shan hong. Analysis of cotton field management and pest control technology[J]. Chinese Science and Technology Journal Database Agricultural Science, 2024(2): 122 - 125. (in Chinese)
- [8] 周晓静, 白素芬, 李欣, 等. 蜜露检测法在转基因棉抗蚜性指标中的应用[J]. 河南农业大学学报, 2012, 46(1): 53 - 57.  
ZHOU Xiaojing, BAI Sufen, LI Xin, et al. Application of honeydew colormetry in determining indexes of aphid resistance of transgenic insect resistant cottons[J]. Journal of Henan Agricultural University, 2012, 46(1): 53 - 57. (in Chinese)
- [9] LIU P J, ZHANG T, GAO Y, et al. Volatiles produced by bacteria in the honeydew of cotton aphids mediate prey location by *Hippodamia variegata* (Coleoptera: Coccinellidae)[J]. Biological Control, 2025, 202(3): 105728.
- [10] 汤金仪, 王建强, 莫肖斌. 一种新型害虫测报工具——昆虫自动诱集器[J]. 中国植保导刊, 2001, 21(3): 9 - 10.
- [11] 洪霖, 漆学伟, 程森弟, 等. 两种玉米害虫种群动态监测及不同诱捕器诱集效果评价[J]. 应用昆虫学报, 2025, 62(3): 677 - 688.  
HONG Lin, QI Xuwei, CHENG Sendi, et al. Population dynamics of two maize pests and the performance of two different trap types[J]. Chinese Journal of Applied Entomology, 2025, 62(3): 677 - 688. (in Chinese)
- [12] 宋鹏慧, 于金成, 杨瑞华, 等. 不同粘虫板及食诱剂添加对西花蓟马的诱集效果[J]. 河南农业科学, 2025, 54(5): 95 - 102.  
SONG Penghui, YU Jincheng, YANG Ruihua, et al. Trapping efficacy of different sticky boards and food attractant supplementation on *Frankliniella occidentalis* [J]. Journal of Henan Agricultural Sciences, 2025, 54(5): 95 - 102. (in Chinese)
- [13] 祝诗平, 周杰, 张越, 等. 基于轻量化 YOLO v8n 的自然环境下车前草病虫害检测方法[J]. 农业机械学报, 2026, 57(2): 215 - 224.  
ZHU Shiping, ZHOU Jie, ZHANG Yue, et al. Detection method for pests and diseases of *Plantago asiatica* L. in natural

- environments based on lightweight YOLO v8n[J]. Transactions of the Chinese Society for Agricultural Machinery, 2026, 57(2):215–224. (in Chinese)
- [14] 朱惠斌,王明鹏,白丽珍,等. 基于视觉识别的玉米病虫害检测与精准变量喷药系统研究[J]. 农业机械学报, 2024, 55(增刊2):210–221.  
ZHU Huibin, WANG Mingpeng, BAI Lizhen, et al. Maize pest and disease detection and precise variable spraying system based on visual recognition[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(Supp. 2):210–221. (in Chinese)
- [15] 王文杰,卢霞,张徐慧,等. 基于叶片反射光谱的稻纵卷叶螟危害等级诊断模型构建[J]. 中国农业大学学报, 2026, 31(3):233–247.  
WANG Wenjie, LU Xia, ZHANG Xuhui, et al. Construction of a diagnostic model for *Cnaphalocrocis medinalis* damage level based on leaf reflectance spectra[J]. Journal of China Agricultural University, 2026, 31(3):233–247. (in Chinese)
- [16] 中华人民共和国国家质量监督检验检疫总局, 中国国家标准化管理委员会. 棉花抗病虫性评价技术规范 第1部分:棉铃虫;GB/T 22101.1—2008[S].
- [17] ORD K. Data adjustments, overfitting and representativeness[J]. International Journal of Forecasting, 2020, 36(1):195–196.
- [18] ZHAO Y, SHI Y, WANG Z. The improved YOLO V5 algorithm and its application in small target detection[C] // Lecture Notes in Computer Science, 2022:679–688.
- [19] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C] // Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016:779–788.
- [20] HORVAT M, JELECEVIC L, GLEDEC G. A comparative study of YOLO v5 models performance for image localization and classification[C] // Central European Conference on Information and Intelligent Systems. Faculty of Organization and Informatics Varazdin, 2022:349–356.
- [21] WANG C Y, YEH I H, LIAO H Y M. YOLO v9: learning what you want to learn using programmable gradient information [EB/OL]. (2024-02-29) [2024-09-20]. <https://arxiv.org/pdf/2402.13616>.
- [22] YU Y, LI D, SONG S, et al. Ginseng – YOLO: integrating local attention, efficient downsampling, and slide loss for robust ginseng grading[J/OL]. Horticulturae, 2025, 11(9). DOI:10.3390/horticulturae11091010.
- [23] 陈婷婷,马海荣,罗治情,等. LDH – YOLOv11n:一种高效的温室辣椒轻量化目标检测模型[J]. 农业工程学报, 2025, 41(24):201–209.  
CHEN Pingting, MA Hairong, LUO Zhiqing, et al. LDH – YOLOv11n: an efficient lightweight object detection model for greenhouse chill peppers[J]. Transactions of the CSAE, 2025, 41(24):201–209. (in Chinese)
- [24] 白凯,张玉杰,苏邓文,等. 基于改进 YOLO v8n 的花生叶片病害检测方法[J]. 农业机械学报, 2025, 56(6):518–526, 564.  
BAI Kai, ZHANG Yujie, SU Dengwen, et al. Peanut leaf disease detection method based on improved YOLO v8n[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(6):518–526, 564. (in Chinese)
- [25] 王洁,徐善永,程军辉,等. 基于改进 YOLO11n 算法的甜菜杂草检测[J/OL]. 重庆工商大学学报(自然科学版), <https://link.cnki.net/urlid/50.1155.n.20250916.0937.002>.
- [26] YU Z, HUANG H, CHEN W, et al. YOLO – FaceV2: a scale and occlusion aware face detector[J]. Pattern Recognition, 2024, 115:110714.
- [27] 胡健威,马慧敏,宁孝梅,等. 基于改进 YOLOv8 的无人机图像玉米幼苗检测[J]. 江苏农业学报, 2025, 41(6):1179–1187.  
HU Jianwei, MA Huimin, NING Xiaomei, et al. Corn seedling detection in unmanned aerial vehicle images based on improved YOLOv8[J]. Jiangsu J. of Agr. Sci., 2025, 41(6):1179–1187. (in Chinese)
- [28] CHEN D, LIU L, ZHAO L, et al. Method for lightweight tomato leaf disease recognition based on improved YOLOv11s[J]. International Journal of Agricultural & Biological Engineering, 2025, 18(5):298–305.
- [29] ZHANG Y F, REN W, ZHANG Z, et al. Focal and efficient IoU loss for bounding accurate box regression[J]. Neurocomputing, 2022, 506:146–157.
- [30] WOO S, PARK J, LEE J Y, et al. Cbam: convolutional block attention module[C] // Proceedings of the European Conference on Computer Vision (ECCV). Munich Springer Nature Switzerland, 2018:3–19.
- [31] WANG, Q, WU B, ZHU P, et al. ECA – Net: efficient channel attention for deep convolutional neural networks[J/OL]. arXiv Preprint, arXiv:1910.03151, 2019.
- [32] ZHANG X, LIU C, YANG D, et al. RFACnv: innovating spatial attention and standard convolutional operation[EB/OL]. (2024-03-28) [2025-05-26]. <https://arxiv.org/pdf/2304.03198>.
- [33] HOWARD A, SANDLER M, CHU G, et al. Searching for MobileNetV3[J/OL]. arXiv Preprint, arXiv:1905.02244, 2019.
- [34] LI C, LI L, JIANG H, et al. YOLO v6: a single-stage object detection framework for industrial applications[J/OL]. arXiv Preprint, arXiv:2209.02976, 2022.
- [35] REN S, HE K, ROSS G, et al. Faster R – CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6):1137–1149.
- [36] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: single shot multibox detector[C] // Computer Vision-ECCV 2016: 14th European Conference. Amsterdam: Springer International Publishing, 2016:21–37.