生物技术通报
· 研究报告 · BIOTECHNOLOGY BULLETIN 2026, 42(10):282-292

基于改进YOLOv8的绿豆叶片主要病害检测研究

王超[1,2] 杨钰超[1] 郭思宇[1] 贾瑶镟[1] 陈艳霞[1] 赵钰[1,2] 乔星星[1,2]
肖璐洁[1,2] 冯美臣[1,2] 杨武德[1,2*]
（1.山西农业大学农学院,太谷 030801；2.山西农业大学省级智慧农业学院,太谷 030801）

摘 要：【目的】为解决自然环境中绿豆叶片病害检测场景复杂、检测精度不足、小目标检测能力较弱等问题，提出一种YOLOv8-EMA-CARAFE-Layer的深度学习算法。【方法】在主干网络中引入了高效多尺度注意力机制（efficient multi-scale attention, EMA），提升模型对病害特征的提取与筛选能力；在颈部网络中采用CARAFE（Content-Aware ReAssembly of FEatures）上采样模块，通过动态生成上采样核增强全局信息聚合能力，从而提高特征重建精度；在Neck和Head网络中添加一个小目标检测层，提升对细小病害目标的检测性能。【结果】改进后的模型在mAP@50、精确度和召回率等关键指标上分别达到了91.0%、86.9%、83.4%，且与主流目标检测模型YOLOv3、YOLOv5、YOLOv6和YOLOv11相比，平均精度mAP@50分别提升了6.8%、0.3%、13.5%和1.6%，在包含复杂田间背景的混合数据集上，表现出较强的绿豆叶片病害检测性能；此外，模型通过轻量化设计保持了较低的参数量，仅为5.95 Mb。【结论】YOLOv8-EMA-CARAFE-Layer模型能够满足无人机、智能农机等移动终端的部署需求，在现有的田间混合数据集上，对提高绿豆叶片主要病害的快速、高效、精准检测水平具有实际应用借鉴价值。

关键词： 图像识别；深度学习；YOLOv8；绿豆叶片病害；高效多尺度注意力机制
DOI: 10.13560/j.cnki.biotech.bull.1985.2025-1295

Research on Detection of Major Diseases in Mung Bean Leaves Based on an Improved YOLOv8

WANG Chao[1,2] YANG Yu-chao[1] GUO Si-yu[1] JIA Yao-xuan[1] CHEN Yan-xia[1] ZHAO Yu[1,2] QIAO Xing-xing[1,2]
XIAO Lu-jie[1,2] FENG Mei-chen[1,2] YANG Wu-de[1,2*]
（1. *College of Agriculture, Shanxi Agricultural University, Taigu* 030801; 2. *Provincial-Level College of Smart Agriculture, Shanxi Agricultural University, Taigu* 030801）

Abstract: 【Objective】To address issues such as complex detection scenarios, insufficient detection accuracy, and weak small-target detection capability for mung bean leaf diseases in natural environments, this study proposes a deep learning algorithm named YOLOv8-EMA-CARAFE-Layer. 【Method】The EMA (efficient multi-scale attention) mechanism was introduced into the backbone network to enhance the model's ability to extract and screen disease features. The CARAFE (Content-Aware ReAssembly of FEatures) upsampling module was adopted in the neck network, which enhanced global information aggregation capability by dynamically generating upsampling kernels, thereby improving feature reconstruction accuracy. A small-target detection layer was added to the neck and head networks to improve the detection effectiveness for minute disease targets. 【Result】The improved model achieved a mAP@50 of 91.0%, a precision of 86.9%, and a recall of 83.4%. Compared with mainstream object detection models YOLOv3, YOLOv5, YOLOv6, and YOLOv11, the mAP@50 improved by 6.8%, 0.3%, 13.5%, and 1.6% respectively, demonstrating superior performance in mung bean leaf disease detection. Furthermore, through lightweight design, the model maintained a low parameter count of only 5.95 MB. 【Conclusion】YOLOv8-EMA-CARAFE-Layer model enables deployment on mobile terminals such as drones and smart agricultural machinery, offering practical application value for enhancing the rapid,

收稿日期：2025-11-27
基金项目：国家重点研发项目子课题（2021YFD1600603-03, 2021YFD1600603-02）
*通信作者：杨武德 sxauywd@126.com

efficient, and accurate detection of major diseases in mung bean leaves.

Keywords: image recognition; deep learning; YOLOv8; mung bean leaf diseases; efficient multi-scale attention mechanism

绿豆作为我国重要的粮食与经济作物，其种植历史悠久且营养丰富，市场需求持续增长[1-2]。然而，绿豆生产常受细菌性疫病、叶斑病等威胁[3]。依赖人工经验进行病害判断、识别和鉴定病害的手段，存在效率低、成本高、对专业知识依赖强及易漏检误检等局限[4]。故研发高效精准的绿豆叶片病害自动检测技术，对提升检测效率、保障绿豆安全生产具有重要的现实需求和实践意义。

基于机器视觉与传统机器学习的方法虽部分提升了检测效率，但存在特征提取复杂、鲁棒性差等局限[5-8]。深度学习技术凭借其自动特征学习和高效检测的优势，已成为植物病害检测的主流方法[9]。其中，YOLO系列因检测速度快、精度高、计算资源需求低，在病害检测中应用最为广泛[10-11]。改进的YOLOv3、YOLOv5等模型在多种作物病害检测中表现出色，但普遍面临复杂环境下小目标检测精度不足、模型泛化能力弱或计算成本高等问题[12-15]。而YOLOv8作为YOLO系列的迭代版本，不仅具备了前代系列模型检测速度快、精度高的优势，也通过优化网络结构进一步平衡了检测性能与模型复杂度，其轻量化版本YOLOv8n更具备参数量小、推理效率高的特点，有效克服了模型规模过大，导致资源适配性差或泛化能力不足的问题[16-17]。当前在复杂田间环境下进行绿豆叶片病害检测的方法，仍面临三方面严峻挑战：（1）病害特征易受叶脉、光影等背景干扰；（2）病斑边界细节模糊，传统上采样难以精准重建；（3）小尺度病斑密集分布，易造成尺度不一致的信息丢失和漏检。此外，模型在轻量化设计与边缘设备部署效率方面亦有待优化，制约了其实际应用[18-19]。

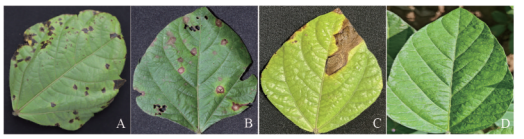
针对上述问题，本研究以轻量化的YOLOv8n为基线，创新性地设计EMA-CARAFE-小目标检测层的特定组合。该组合的选择是针对绿豆叶片病害图像的具体特点进行考量：EMA高效多尺度注意力机制能够通过跨维度交互和低参数开销有效抑制背景噪声并捕捉多尺度病斑特征；CARAFE内容感知上采样模块动态生成核，适合重建低对比度、模糊边界的病斑细节；专用小目标检测层则通过高分辨率特征重采样，直接弥补小尺度病斑的信息丢失。这种互补协同的组合设计旨在在复杂田间背景的混合数据集上，实现绿豆叶片病害的高精度、轻量化检测。

1　材料与方法

1.1　材料

1.1.1　绿豆叶片病害图像采集　针对绿豆叶片公开病害数据集的匮乏，本研究于2024年7-9月，在山西省多个产区（附图1）采集了4 078张细菌性疫病（1 386张）、叶斑病（1 123张）、轮纹病（594张）及健康叶片（975张）的图像。图像采用智能手机（手机像素6 240×4 160）和佳能Mark III数码相机拍摄，为增强数据集的环境代表性，采集过程涵盖了多种实际田间条件，包括不同光照强度、天气状况、拍摄角度与距离以及背景杂乱程度。对数据集中的模糊、重复及不符合标注要求的图像进行剔除，并通过旋转、翻转、亮度调整等数据增强技术扩充样本。此外，本研究基于YOLOv8框架进行训练，该框架默认启用了针对目标检测任务的数据增强技术，包括Mosaic、MixUp、CopyPaste和HSV随机调整等。这些高级增强在YOLO系列中广泛应用，能显著提升模型对田间变异的鲁棒性。其中，Mosaic和CopyPaste有助于更好地捕捉细小密集病斑的空间关系和纹理细节；MixUp虽可能在混合时轻微模糊部分边界，但整体提高了模型对病斑与背景区分的泛化能力，未导致显著细节丢失，增强了数据针对性，缓解了田间复杂背景和病斑变异的挑战。针对数据集存在的类别不平衡问题，本研究在数据增强阶段特别对轮纹病加强了旋转、翻转和亮度调整等操作，以增加其样本多样性和数量占比，从而缓解类别不平衡对模型训练的影响。此外，YOLOv8训练过程默认采用自动类平衡策略，进一步减轻不平衡带来的偏差。此外，所有图像经预处理归一化至640×640分辨率，以保障后续模型训练稳定性与检测效果[20]，最终形成含3 927张图像的高质量混合数据集，各类病害图像表现及特征描述如图1和表1所示。

1.1.2　数据标注及预处理　采用LabelImg标注工具



A:细菌性疫病;B:叶斑病;C:轮纹病;D:健康

A: Bacterial blight; B: Leaf spot; C: Ring spot; D: Healthy

图1 绿豆病害图

Fig. 1 Images of mung bean leaves

对病斑区域定位并绘制边界框，生成xml格式文件，标签分别设为“health”（健康）、“ring spot”（轮纹病）、“leaf spot”（叶斑病）、“bacterial blight”（细菌性疫病）。标注完成后，将xml格式文件转换为YOLO训练所需的txt格式，按7∶2∶1比例随机划分数据集为训练集、测试集与验证集[21]。

1.2 方法

1.2.1 YOLOv8深度学习模型网络结构 YOLOv8是一种高效且稳健的目标检测算法[22]，其网络结构主要包含输入端（Input）、主干网络（Backbone）、颈部网络（Neck）和检测头（Head）4部分。输入端负责图像的预处理与自适应缩放。主干网络通过CBS结构、C2f及SPPF模块提取深层特征。颈部网络结合了PAN（路径聚合网络）与FPN（特征金字塔网络），以增强多尺度特征融合能力。检测头则采用解耦头与无锚框（anchor-free）策略，在不同尺度上并行预测目标类别与位置。其整体网络结构如图2所示。

表1 绿豆叶片病害种类及特征

Table 1 Types and characteristics of mung bean leaf diseases

病害名称 Disease types	病害特征 Disease characters
细菌性疫病 Bacterial blight	初期叶片表面出现小的水浸斑，变成淡黄色到棕褐色；后期病斑在叶片上扩展，病斑呈黑色
轮纹病 Ring spot	初期叶片产生小的、褐色圆形病斑；后期发展成大的具有同心环的圆形或不规则的深褐斑
叶斑病 Leaf spot	初期叶片上出现小型不规则或圆形褐色斑点，边缘清晰；后期病斑扩展，形成大的不规则坏死区域
健康 Health	叶片呈深绿色，叶形卵状，叶脉清晰可见，质地柔软薄嫩，表面光滑

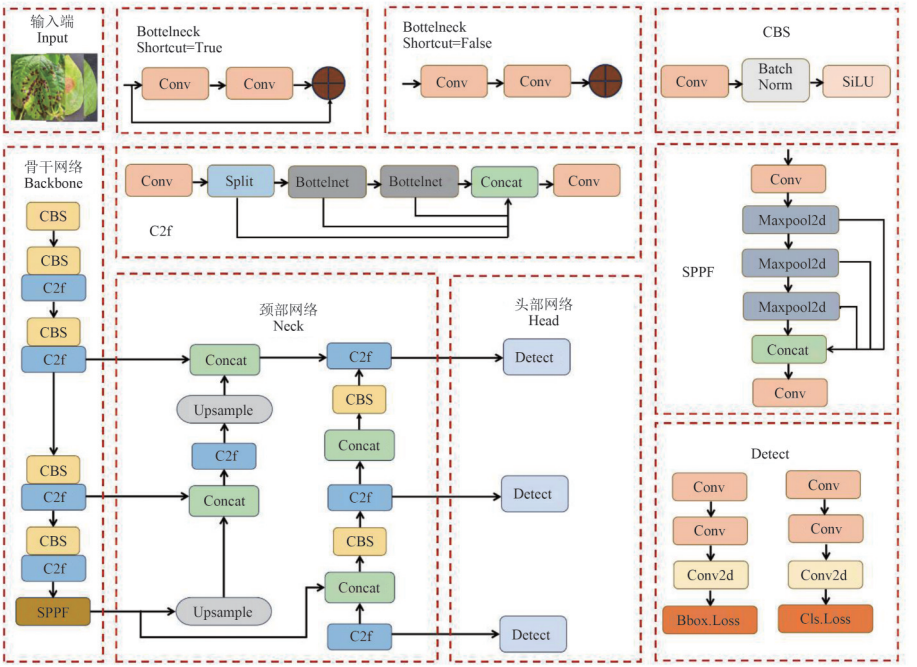


图2 YOLOv8模型网络结构

Fig. 2 YOLOv8 model network architecture

1.2.2　改进YOLOv8模型网络结构　YOLOv8n作为YOLOv8系列轻量化版本，检测速度快、精度较高且参数量小，适配移动设备部署[23]。但在复杂场景下小目标检测精度、特征融合能力及收敛速度仍有不足。故本研究以轻量化的YOLOv8n为基线，提出了YOLOv8-EMA-CARAFE-Layer改进模型。其主要改进包括三方面：（1）在骨干网络中引入EMA高效多尺度注意力机制，以强化病害特征的提取与筛选能力；（2）在颈部网络中使用CARAFE上采样模块替换原结构，增强特征重建中的细节保留；（3）在Neck与Head之间增加一个小目标检测层，以缓解尺度不一致造成的信息丢失，从而提升小病害目标的识别性能。改进后的模型结构如图3所示。

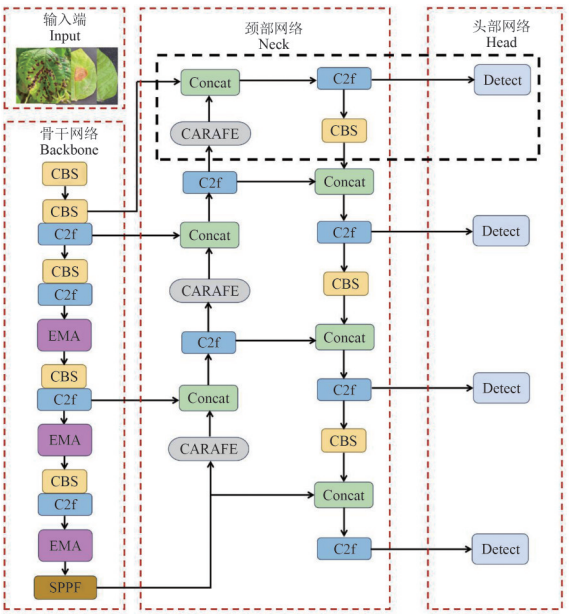


图3　YOLOv8-EMA-CARAFE-Layer网络结构

Fig. 3　YOLOv8-EMA-CARAFE-Layer network architecture

（1）EMA高效多尺度注意力机制。绿豆叶片病害特征复杂、病斑形态差异大，且叶脉、光影等背景易致漏检误检，故在YOLOv8n主干网络引入EMA机制[24-25]。EMA的设计核心包括特征分组、并行子网和跨空间学习3部分。首先特征分组将输入特征图通道维度划分为多子特征组，通过独立注意力权重捕捉不同语义信息，且通过通道–批处理维度重塑避免信息丢失。其次，分组后特征被送入3条路径，2条1×1分支通过全局平均池化与共享权值1×1卷积学习跨通道交互，1条3×3分支通过局部卷积扩大感受野，提升多尺度特征表达。在跨空间学习阶段，EMA将1×1和3×3分支的输出特征融合，经二维全局平均池化编码空间信息，通过Softmax生成空间注意力图，最终以Sigmoid生成像素级权重，突出病害区域、压制背景噪声。图4所示为EMA注意力机制模块网络结构。

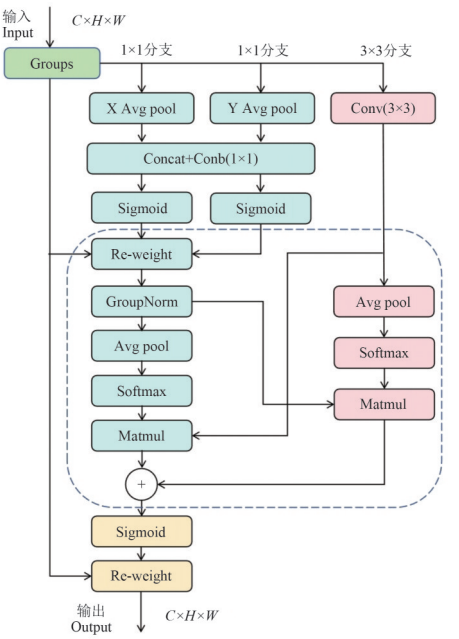


图4　EMA注意力机制模块网络结构

Fig. 4　EMA attention mechanism module network architecture

（2）CARAFE上采样。传统上采样仅依赖局部像素加权，无法捕捉病斑与背景的全局关联，导致绿豆小叶斑病特征重建不完整。故本研究在Neck网络采用CARAFE模块，通过动态生成上采样核实现全局信息聚合，图5为CARAFE的整体框架。

该模块的结构由内核预测模块（kernel prediction module）和特征感知重组模块（feature perception recombination moudle）两部分组成，通过高效的上采样操作，能够充分保留图像中的细节信息，从而提升模型对病害特征的识别能力。在内核预测模块中，输入特征图（H×W×C）经通道压缩降维至Cm，再通过kup×kup卷积内容编码生成σ2×kup2尺寸重组核，随后展开空间维度并重组为σH×σW上采

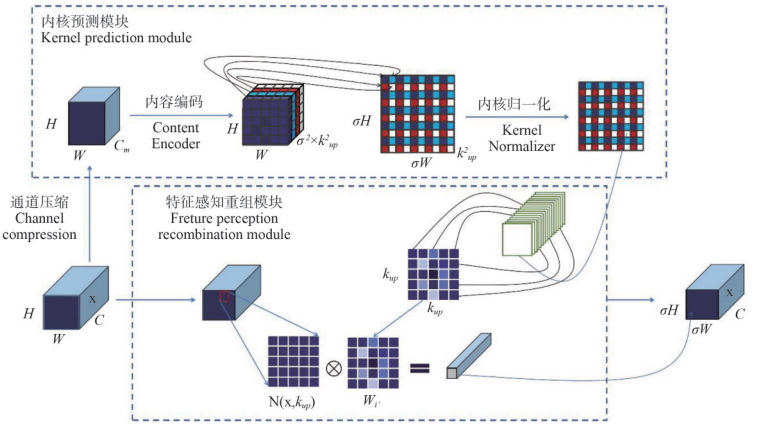


图5 CARAFE的整体框架

Fig. 5 Overall framework of CARAFE

样核，经Softmax归一化确保权重和为1，公式为：

$$C_m = \sigma^2 \times k_{up}^2 \quad (1)$$

其中σ表示上采样倍数，k_{up}为动态上采样核的大小。

特征感知重组模块中对输出特征图每个目标位置，取kup×kup特征区域与动态上采样核做点积，映射生成σH×σW×C最终特征图，通过动态权重聚合上下文信息，平衡特征建模精度与计算效率。

（3）添加小目标检测层。绿豆叶斑病等病害以细小斑点形式存在，现有模型小目标识别能力不足，故新增小目标检测层（图6），该检测层通过特征重采样将低层特征图上采样恢复高分辨率，与高层语义特征融合形成联合特征图，弥补下采样导致的细节丢失，再在融合特征图上引入独立小目标检测头，通过轻量化卷积增强特征表达，提升小目标检测准确率与召回率。

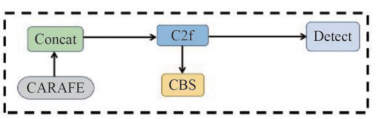


图6 小目标检测层

Fig. 6 Small object detection layer

1.2.3 模型训练与评价指标

（1）试验环境和参数设置。本试验的模型训练与测试均在同一实验环境下进行，处理器采用Intel（R）Core（TM）i7-8750H CPU @ 2.20 GHz，显卡为NVIDIA GeForce RTX 3090，显存容量为32 GB。操作系统为Windows 11，深度学习框架选用PyTorch2.0.1，计算架构基于CUDA 11.7，编程语言为Python3.8.0。训练参数方面，最大迭代轮次设置为300，批量大小为16，初始学习率为0.000 1。

（2）评价指标。评价指标可以全面衡量一个模型在不同任务中的性能表现[26]。本研究选择的评价指标有精确度（precision）、召回率（recall）和平均精度（mean average precision, mAP），这些指标为模型的检测能力提供全面而客观的评估[27]，其公式如下：

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \times 100\% \quad (2)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \times 100\% \quad (3)$$

$$\text{mAP} = \frac{\sum_{i=1}^{c} \text{AP}(c)}{\text{C}} \times 100\% \quad (4)$$

式中，TP（true positive）表示正确识别病害的数量；FP（false positive）表示健康区域被错误识别为病害的数量；FN（false negative）代表判断错误为病害的数量；AP是精确查全率曲线（P-R曲线）下的面积；C为病害的种类。

1.2.4 模块协同机制 本研究所提出的改进方案，遵循从特征提取、特征融合到目标检测的完整流程，是针对绿豆叶片病害图像中背景复杂与小目标密集这两大特点所构建的系统性协同设计。EMA模块置于主干网络早期，通过跨空间学习与像素级注意力权重机制，有效抑制背景噪声干扰，并增强多尺度

病害特征的提取能力，为后续颈部网络提供更为纯净的输入；CARAFE模块接收经EMA增强后的特征，借助动态内容感知核实现全局上下文的自适应聚合，有助于重建小病斑区域的模糊边界与细节信息；而新增的小目标检测层，则充分融合前两个模块协同输出的鲁棒特征，通过高分辨率特征的重采样与融合，直接补偿小尺度病斑在常规检测中的信息损失。整体上，EMA承担前端特征的净化与筛选，CARAFE负责中端细节的重建，小目标检测层则完成后端尺度的补偿，三者沿特征流向逐级递进、功能互补，共同应对复杂背景下小目标病害的检测挑战。

2　结果

2.1　YOLOv8模型改进前后的性能对比试验

为验证改进模型性能，将YOLOv8-EMA-CARAFE-Layer与原始YOLOv8n在相同数据集上训练测试。由表2可知，改进后模型精确度、召回率分别提升1.4%、2.3%，mAP@50、mAP@50-95分别提升4.8%、4.7%，参数量仅增加0.22 MB。表明改进模型在特征提取方面更加高效，能够保留更多的细节信息，从而更准确地识别目标，同时减少漏检目标的数量。

表2　改进前后模型性能对比

Table 2　Model performance comparison before and after improvement

模型	精确度 Precision(%)	召回率 Recall(%)	mAP@50(%)	mAP@50-95(%)	参数量 Params(MB)
YOLOv8n	85.5	81.1	86.2	62.8	5.73
YOLOv8-EMA-CARAFE-Layer	86.9	83.4	91.0	67.5	5.95

附图2直观反映改进后的YOLOv8-EMA-CARAFE-Layer模型与原始YOLOv8n模型在训练过程中的性能差异，改进后的模型在训练过程中损失值下降更快，且整体曲线更加平滑，最终的损失值低于原始YOLOv8n模型，表明改进后的模型在训练过程中收敛性和稳定性得到了优化，表明改进后的模型在绿豆叶片病害检测任务中具有较高的实用性和性能优势。

2.2　引入不同注意力机制性能分析

为评估本文提出的EMA注意力机制的性能表现，将EMA注意力机制模块与卷积注意力模块CBAM（convolutional block attention module）、坐标注意力模块CA（coordinate attention）引入YOLOv8n模型中进行对比分析，结果如表3所示。

表3　添加不同注意力机制的模型对比试验

Table 3　Experimental comparison of models with different attention mechanisms

模型 Model	精确度 Precision(%)	召回率 Recall(%)	mAP@50(%)	mAP@50-95(%)	参数量 Params (MB)
YOLOv8_CBAM	84.5	78.6	86.8	64.3	5.86
YOLOv8_CA	87.4	80.3	86.7	64.0	5.75
YOLOv8_EMA	83.1	81.2	87.4	64.0	5.73

相较于YOLOv8_CBAM和YOLOv8_CA模型，YOLOv8_EMA召回率分别提升了2.6%和0.9%，平均精度指标mAP@50分别增加了0.6%和0.7%。在精确度方面，EMA虽然低于CA和CBAM注意力机制，但本研究考虑在绿豆叶片病害检测的农业应用场景中，小目标病斑占比高，漏检会导致病害扩散和产量损失，代价远高于误检，因此优先提升召回率以减少漏检更具实际意义，mAP@50作为综合评价指标EMA最高，EMA参数量最低，仅为5.73 MB，表明EMA可同步提升检测性能和控制模型复杂度，其综合性能更适配绿豆叶片病害检测。

2.3　消融实验

以YOLOv8n为基线，通过消融实验验证各改进模块有效性。由表4可知，单独引入EMA（试验1），mAP@50提升至87.4%、mAP@50-95提升1.2%，但精确度下降2.4%，这与特征调整引发的预测偏差有关。对于叠加CARAFE（试验2），其mAP@50进一步提升至87.9%，但mAP@50-95降至63.8%，参数

量增加0.27 MB，表明CARAFE可增强特征表达但泛化能力待优化。而在完整模型（试验3）中，精确度、召回率、mAP@50、mAP@50-95较基线分别提升1.4%、2.3%、4.8%、4.7%，参数量仅增加0.22 MB，说明小目标检测层可优化模型结构，并可兼顾轻量化与检测性能。

表4 YOLOv8n不同消融方法试验表现

Table 4 Performance of different ablation methods for YOLOv8n

消融试验组 Ablation study group	EMA	CARAFE	Layer	精确度 Precision(%)	召回率 Recall(%)	mAP@50(%)	mAP@50-95(%)	参数量 Params (MB)
0	–	–	–	85.5	81.1	86.2	62.8	5.73
1	√	–	–	83.1	81.2	87.4	64.0	5.73
2	√	√	–	87.2	80.5	87.9	63.8	6.00
3	√	√	√	86.9	83.4	91.0	67.5	5.95

为直观反映不同改进模块组合对模型性能的影响差异，将4类消融实验模型在训练过程中的性能变化进行对比分析。由附图3可知，改进模块越多，mAP@50提升越显著，改进后完整模型损失值始终最低，表明随迭代轮次增加，模型均逐渐收敛，进一步验证了改进方法的有效性。

2.4 与经典模型对比实验

为验证该研究算法相比当前热门目标检测模型的优越性，本文将改进模型与YOLOv3、YOLOv5、YOLOv6、YOLOv8n、YOLOv11系列模型进行对比，结果如表5所示。改进模型mAP@50达到了91.0%，较其他模型分别提升6.8%、0.3%、13.5%、4.8%、1.6%；mAP@50-95较YOLOv3、YOLOv6、YOLOv8n分别提升10.8%、11.2%、4.7%；且改进模型的其他参数整体表现优于其他对比模型，表现为精确度86.9%，召回率83.4%，参数量为5.95 MB。本研究改进后的模型在参数量方面虽略有增加，但仍保持在轻量化水平，具备实际应用于农业场景的良好基础。虽然mAP@50-95仅较YOLOv11提升1.6%，但这并不代表本文方法性能不及参数占优的YOLOv11，反而体现了面向特定病害检测场景的针对性改进在性能均衡与实际应用中的价值。此外，为全面评估模型的轻量化性能，本研究进一步测试了计算量和推理速度。改进模型虽FLOPs和推理延迟略有增加，但FPS仍高达357，远高于实时应用需求，结合低参数量特性，充分满足无人机、智能农机等移动终端的部署要求。综上，该模型在有效控制计算资源需求的同时，在绿豆叶片病害检测任务中实现了更优的综合性能表现。

表5 改进模型与传统目标检测模型的表现

Table 5 Performance comparison between the improved model and classical models

模型 Model	精确度 Precision(%)	召回率 Recall(%)	mAP@50(%)	mAP@50-95(%)	参数量 Params(MB)	FLOPs(G)	推理延迟 Latency(ms)	FPS
Yolov3	82.5	76.8	84.2	56.7	16.55	65.9	15.2	65.8
Yolov5	84.7	85.3	90.7	66.1	13.38	32.5	6.8	147.1
Yolov6	76.2	72.7	77.5	56.3	8.07	18.4	4.9	204.1
Yolov8n	85.5	81.1	86.2	62.8	5.73	8.7	2.1	476.2
Yolov11	88.7	81.5	89.4	65.6	4.93	7.2	1.8	555.6
YOLOv8-EMA-CARAFE-Layer	86.9	83.4	91.0	67.5	5.95	12.4	2.8	357.1

2.5 病害检测效果可视化分析

为进一步验证改进模型YOLOv8-EMA-CARAFE-Layer在绿豆叶片病害实际检测中的效果，本文对比分析了改进模型与YOLOv8模型在检测绿豆各类病害时的精度表现，检测结果如图7所示。由图可看出，相比YOLOv8模型，改进后的模型（YOLOv8-

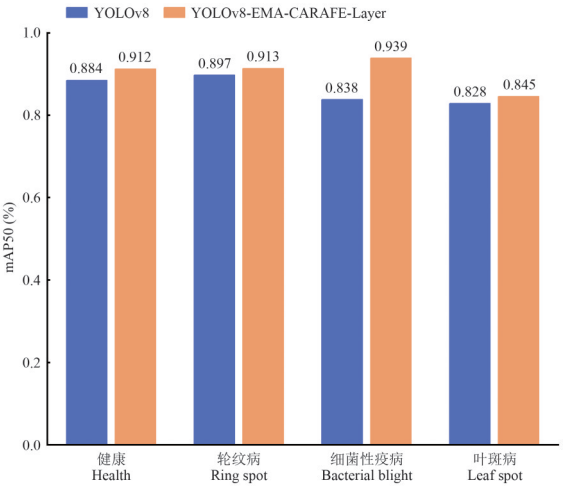


图7　对比分析YOLOv8和改进模型对绿豆各类病害检测精度

Fig. 7　Comparison of mung bean disease detection accuracy between YOLOv8 model and its improved model (YOLOv8-EMA-CARAFE-Layer)

EMA-CARAFE-Layer）对健康叶片、轮纹病、细菌性疫病、叶斑病的mAP@50分别提升2.8%、1.6%、10.1%、1.7%，尤其在细菌性疫病、叶斑病两类病害的检测中，表现优势显著。尽管数据集存在轮纹病样本较少的问题，但改进模型对轮纹病的mAP@50仍提升1.6%，可视化结果也显示其检测框精度更高、背景干扰抵抗更强，表明所采用的数据增强和训练平衡策略有效缓解了不平衡影响，对少数类型的识别效果未受显著负面影响。

进一步对两类模型绿豆各类病害进行可视化分析和验证，结果如图8所示。对于健康叶片，其检测边界更贴合叶片实际形态，有效减少了对背景区域的误判；针对细菌性疫病，该模型能够全面覆盖细小且密集分布的病斑区域，避免了原始模型易出现的漏检问题；在轮纹病检测中，改进模型的检测框选精度更高，可有效抵御背景干扰，精准定位病斑范围；而在叶斑病检测任务中，其能够完整捕捉密集分布的小叶斑目标，解决了原始模型对密集小目标识别不完整的缺陷。针对细菌性疫病，该模型能够全面覆盖细小且密集分布的病斑区域，总体上改善了原始模型的漏检问题，但在图8所示案例中仍出现过检与定位框不准确的情况。细菌性疫病的病斑具有边缘模糊、密集细小的特点，导致模型在特征提取时难以区分病斑与相似背景。EMA模块虽能抑制多数背景噪声，却可能对大范围模糊区域过度关注，影响CARAFE上采样核的稳定重建；同时，小目标检测层在提升召回时对模糊伪目标的抑制仍显不足。该结果表明，模型在极端模糊场景下存在局限，整体改进虽有效，仍需在特征区分与伪目标抑制方面进一步优化。综上所述，改进后的YOLOv8-EMA-CARAFE-Layer模型在多数绿豆叶片病害检测场景中表现优于原始YOLOv8n模型，具备良好的总体应用潜力。同时，上述失败案例分析也为模型在模糊边界条件下的后续优化提供了具体方向。

3　讨论

本研究针对绿豆病害传统检测方法效率低、复杂背景干扰大、小目标病害捕捉能力弱等问题，以

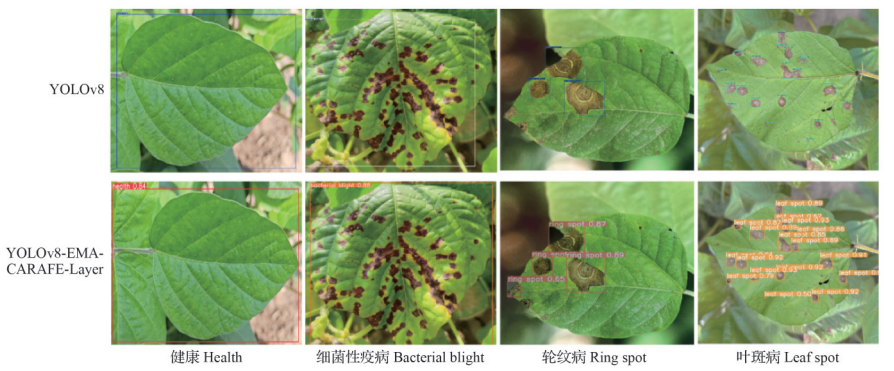


图8　对比分析YOLOv8和改进模型对绿豆各类病害检测可视化表现

Fig. 8　Comparison of visualization performance for mung bean disease detection between YOLOv8 and its improved model (YOLOv8-EMA-CARAFE-Layer)

YOLOv8n为基础架构，通过融入EMA高效多尺度注意力机制、CARAFE采样模块及新增小目标检测层，构建了YOLOv8-EMA-CARAFE-Layer改进模型，实现复杂自然环境下的精准快速检测。本文在针对3 927张图像的测试中，该改进模型精确度达86.9%、召回率83.4%、mAP@50 91.0%、mAP@50-95 67.5%，参数量仅5.95 MB，较基线YOLOv8n模型提升4.8%，且优于YOLOv3、YOLOv5等其他主流模型，这一提升主要源于三大核心模块的协同优化，其中EMA注意力机制通过跨空间学习与多尺度融合筛选关键病害特征，抑制复杂背景噪声，减少无效信息干扰，相较CBAM、CA等传统注意力机制，在低计算开销下显著降低漏检误检，尤其适配细菌性疫病、叶斑病等边缘模糊、受干扰严重的病害，与Deng等[28]验证的EMA复杂场景优势一致。其次，引入CARAFE上采样模块，通过动态生成内容感知上采样核，有效重建叶片病斑的模糊边界细节，相较于传统上采样方法及计算复杂度较高的BiFPN结构更具优势，弥补了传统插值的全局上下文感知不足的问题，Liu等[29]认为这可增强特征重建精度，从而将召回率提升至83.4%。最后，通过新增小目标检测层，结合上采样与特征融合技术，解决下采样语义信息丢失的问题，强化细小病斑感知，这与Liu等[26]提出的特征融合提升多尺度检测性能的研究逻辑相符。此外，相较于Khalid等[13]基于深度卷积神经网络的植物健康检测研究，本模型在轻量化前提下更适配绿豆叶片病害的细小、模糊、密集特点，实现了更高的泛化能力与检测精度。

EMA原为COCO等通用数据集设计，凭借高效多尺度校准与低开销提升检测性能。本研究中，其背景抑制作用在绿豆叶片病害复杂田间场景下更为突出，区别于通用任务的均衡关注。该差异反映了农业图像的独特挑战，使EMA表现出更强的针对性适应。作为高效轻量化模块，EMA为农业病害检测及田间设备部署提供了新的优化方向。

尽管该改进模型YOLOv8-EMA-CARAFE-Layer在包含田间复杂背景的现有混合数据集上取得了优异性能，但仍存在一定的局限性。第一，模型训练依赖高性能硬件，在资源受限移动设备部署时需进一步优化以降低推理延迟。第二，因EMA模块在简单场景会过度关注全局特征，易导致轻微预测偏差。第三，本研究目前仅涵盖细菌性疫病、叶斑病、轮纹病及健康叶片，虽然样本总量达3 927张并针对主要病害进行了优化，但病害类别有限，可能限制模型对其他病害、不同生育期症状变异及复合感染的泛化能力。第四，本研究所有图像均采集自自然田间环境，未划分简单背景和复杂背景子集进行针对性对比，也未充分覆盖极端光照、严重遮挡、病害严重度差异及极度杂乱背景等困难条件，因此对极端复杂场景的鲁棒性仍需进一步验证。第五，在细菌性疫病等边缘模糊类别中，个别案例仍存在过检与定位偏差，表明模型对极端模糊边界的区分能力有待提升。第六，本研究聚焦于绿豆叶片主要病害的识别与定位，尚未涉及病害严重程度的量化分级，这在实际农业或植物保护场景中往往具有更大的应用价值与实践指导意义。针对上述技术问题，未来研究可结合模型压缩与量化策略，推动模型在无人机、智能农机等移动设备的实时部署，同时，通过优化EMA模块注意力分配机制，平衡全局与局部特征关注程度，提升简单场景检测精确度[30]。此外，还需进一步扩展病害类别库，采集更多类型病害、复合感染样本以及不同生育期下的叶片图像，并构建更具挑战性的多环境测试集以及背景复杂度子集，通过对比实验量化模型在不同背景条件下的鲁棒性，提升数据集的环境多样性和模型在实际田间部署中的泛化能力，并重点开展病害严重程度量化分级研究，为绿豆病害的全面智能监测提供更强的支撑。综上所述，本文开发的YOLOv8-EMA-CARAFE-Layer改进模型可在复杂环境及绿豆叶片病害的高效精准检测条件下保持轻量化的特性，这对于未来应用于生产实践提供了一定的技术支撑。

4 结论

YOLOv8-EMA-CARAFE-Layer模型在保持轻量化的同时，实现了优异的病害检测精度。与原始YOLOv8n模型相比，改进模型的mAP@50和mAP@50-95分别提升至91.0%和67.5%，并在复杂背景与小目标病害检测中表现出更强的鲁棒性。此外，模型参数量仅为5.95 MB，具有良好的轻量化特性，能够满足无人机、智能农机等移动终端的部署需求，为田间绿豆病害的精准智能监测提供了可行的技术支撑。

文章所有附图附表请点击链接查看（https://bio-tech.aiijournal.com/fileup/1002-5464/NEWS/20260506103558_NewsFile_6.pdf）

参考文献

[1] 戴高星. 发展绿豆生产大有可为 [J]. 四川农业科技, 2011(6): 18-19.
Dai GX. Developing mung bean production is promising [J]. Sichuan Agric Sci Technol, 2011(6): 18-19.

[2] Maiti D, Majumdar M. Impact of bioprocessing on phenolic content and antioxidant activity of soy seed to improve hypoglycemic functionality [J]. Asian J Plant Sci Res, 2012, 2(2): 924-931.

[3] 孙瑞卿, 秦曙, 李晋栋, 等. 我国绿豆病虫害化学防治现状及质量安全问题分析 [J]. 农产品质量与安全, 2017(3): 91-94.
Sun RQ, Qin S, Li JD, et al. Current situation of chemical control of mung bean diseases and insect pests in China and analysis of quality and safety problems [J]. Qual Saf Agro Prod, 2017(3): 91-94.

[4] 赵玉梅. 农业信息化在蔬菜病虫害防治技术上的应用分析 [J]. 农业工程技术, 2022, 42(27): 31-32.
Zhao YM. Analysis on the application of agricultural informatization in vegetable pest control technology [J]. Agric Eng Technol, 2022, 42(27): 31-32.

[5] 梁斯佳, 李雷, 顾月, 等. 基于改进YOLO v8n的甘蔗叶片病害识别算法 [J]. 农业机械学报, 2025, 56(10): 567-574.
Liang SJ, Li L, Gu Y, et al. Sugarcane leaf disease recognition algorithm based on improved YOLO v8n [J]. Trans Chin Soc Agric Mach, 2025, 56(10): 567-574.

[6] Kumar Sahu S, Pandey M. An optimal hybrid multiclass SVM for plant leaf disease detection using spatial Fuzzy C-Means model [J]. Expert Syst Appl, 2023, 214: 118989.

[7] 黄林生, 江静, 黄文江, 等. Sentinel-2影像和BP神经网络结合的小麦条锈病监测方法 [J]. 农业工程学报, 2019, 35(17): 178-185.
Huang LS, Jiang J, Huang WJ, et al. Wheat yellow rust monitoring method based on Sentinel-2 image and BPNN model [J]. Trans Chin Soc Agric Eng, 2019, 35(17): 178-185.

[8] 朱锐, 张家瑜, 黄继超, 等. 基于卷积神经网络的农作物叶片病害检测研究进展 [J]. 农业工程学报, 2025, 41(17): 15-28.
Zhu R, Zhang JY, Huang JC, et al. Research progress of crop leaf disease detection based on convolutional neural network [J]. Trans Chin Soc Agric Eng, 2025, 41(17): 15-28.

[9] 徐洪丽, 安凤, 史宇轩. 基于改进YOLO v8的苹果叶片病害检测研究 [J]. 农业机械学报, 2025, 56(10): 530-538.
Xu HL, An F, Shi YX. Apple leaf disease detection method based on improved YOLO v8 [J]. Trans Chin Soc Agric Mach, 2025, 56(10): 530-538.

[10] 苗荣慧, 李志伟, 武锦龙. 基于改进YOLO v7的轻量化樱桃番茄成熟度检测方法 [J]. 农业机械学报, 2023, 54(10): 225-233.
Miao RH, Li ZW, Wu JL. Lightweight maturity detection of cherry tomato based on improved YOLO v7 [J]. Trans Chin Soc Agric Mach, 2023, 54(10): 225-233.

[11] 郑俊键, 兰玉彬, 熊万杰, 等. 基于YOLOv5s改进模型的小白菜虫害识别方法 [J]. 农业工程学报, 2024, 40(13): 124-133.
Zheng JJ, Lan YB, Xiong WJ, et al. Method for identification of Pak choi pests and diseases based on improved YOLOv5s [J]. Trans Chin Soc Agric Eng, 2024, 40(13): 124-133.

[12] 祝诗平, 张越, 唐茂杰, 等. 基于改进YOLO v10n的百香果成熟果实检测方法 [J]. 农业机械学报, 2025, 56(10): 549-557, 595.
Zhu SP, Zhang Y, Tang MJ, et al. Ripe fruit detection model of passion fruit based on improved YOLO v10n [J]. Trans Chin Soc Agric Mach, 2025, 56(10): 549-557, 595.

[13] Khalid M, Sarfraz M, Iqbal U, et al. Real-time plant health detection using deep convolutional neural networks [J]. Agriculture, 2023, 13(2): 510.

[14] 公徐路, 张淑娟. 基于改进YOLOv5s的苹果叶片小目标病害轻量化检测方法 [J]. 农业工程学报, 2023, 39(19): 175-184.
Gong XL, Zhang SJ. Lightweight detection of small target diseases in apple leaf using improved YOLOv5s [J]. Trans Chin Soc Agric Eng, 2023, 39(19): 175-184.

[15] 袁杰, 谢霖伟, 郭旭, 等. 基于改进YOLOv7的苹果叶片病害检测方法 [J]. 农业机械学报, 2024, 55(11): 68-74.
Yuan J, Xie LW, Guo X, et al. Apple leaf disease detection method based on improved YOLOv7 [J]. Trans Chin Soc Agric Mach, 2024, 55(11): 68-74.

[16] 毛锐, 张宇晨, 王泽玺, 等. 利用改进Faster-RCNN识别小麦条锈病和黄矮病 [J]. 农业工程学报, 2022, 38(17): 176-185.
Mao R, Zhang YC, Wang ZX, et al. Recognizing stripe rust and yellow dwarf of wheat using improved Faster-RCNN [J]. Trans Chin Soc Agric Eng, 2022, 38(17): 176-185.

[17] 王会征, 孙良晨, 李新龙, 等. 基于改进YOLOv7-tiny的番茄叶片病虫害检测方法 [J]. 农业工程学报, 2024, 40(10): 194-202.
Wang HZ, Sun LC, Li XL, et al. Detecting tomato leaf pests and diseases using improved YOLOv7-tiny [J]. Trans Chin Soc Agric Eng, 2024, 40(10): 194-202.

[18] 甘雨, 郭庆文, 王春桃, 等. 基于改进EfficientNet模型的作物害虫识别 [J]. 农业工程学报, 2022, 38(1): 203-211.
Gan Y, Guo QW, Wang CT, et al. Recognizing crop pests using an improved EfficientNet model [J]. Trans Chin Soc Agric Eng, 2022, 38(1): 203-211.

[19] 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.
Liu SY, Hu B, Zhao C. Detection and identification of cucumber leaf diseases based improved YOLOv7 [J]. Trans Chin Soc Agric Eng, 2023, 39(15): 163-171.

[20] 孙丰刚, 王云露, 兰鹏, 等. 基于改进YOLOv5s和迁移学习的苹果果实病害识别方法 [J]. 农业工程学报, 2022, 38(11): 171-179.
Sun FG, Wang YL, Lan P, et al. Identification of apple fruit diseases using improved YOLOv5s and transfer learning [J]. Trans Chin Soc Agric Eng, 2022, 38(11): 171-179.

[21] Arnal Barbedo JG. Plant disease identification from individual lesions and spots using deep learning [J]. Biosyst Eng, 2019, 180: 96-107.

[22] 罗志聪, 何陈涛, 陈登捷, 等. 基于轻量化YOLOv8s-GD的自然环境下百香果快速检测模型 [J]. 农业机械学报, 2024, 55(8): 291-300.
Luo ZC, He CT, Chen DJ, et al. Passion fruit rapid detection model based on lightweight YOLOv8s-GD [J]. Trans Chin Soc Agric Mach, 2024, 55(8): 291-300.

[23] 李嘉诚, 陈中举, 许浩然. 基于改进YOLOv8n的真实场景下草莓病害检测方法 [J]. 中国农机化学报, 2024, 45(12): 267-274.
Li JC, Chen ZJ, Xu HR. A method for strawberry disease detection in real scenarios based on improved YOLOv8n [J]. J Chin Agric Mech, 2024, 45(12): 267-274.

[24] Zhang YP, Liu J, Li SZ, et al. ESM-YOLOv11: a lightweight deep learning framework for real-time peanut leaf spot disease detection and precision severity quantification in field conditions [J]. Comput Electron Agric, 2025, 238: 110801.

[25] Chen SY, Li YX, Zhang YD, et al. Soft X-ray image recognition and classification of maize seed cracks based on image enhancement and optimized YOLOv8 model [J]. Comput Electron Agric, 2024, 216: 108475.

[26] Liu S, Qi L, Qin HF, et al. Path aggregation network for instance segmentation [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. June 18-23, 2018, Salt Lake City, UT, USA. Piscataway, NJ: IEEE, 2018: 8759-8768.

[27] 于营, 王春平, 付强, 等. 语义分割评价指标和评价方法综述 [J]. 计算机工程与应用, 2023, 59(6): 57-69.
Yu Y, Wang CP, Fu Q, et al. Survey of evaluation metrics and methods for semantic segmentation [J]. Comput Eng Appl, 2023, 59(6): 57-69.

[28] Deng H, Chen YY, Xu YL. ALD-YOLO: a lightweight attention detection model for apple leaf diseases [J]. Front Plant Sci, 2025, 16: 1616224.

[29] Liu F, Wang SD, Pang SC, et al. Detection and recognition of tea buds by integrating deep learning and image-processing algorithm [J]. Food Measure, 2024, 18(4): 2744-2761.

[30] 杨锋, 姚晓通. 基于改进YOLOv8的小麦叶片病虫害检测轻量化模型 [J]. 智慧农业, 2024, 6(1): 147-157.
Yang F, Yao XT. Lightweighted wheat leaf diseases and pests detection model based on improved YOLOv8 [J]. Smart Agric, 2024, 6(1): 147-157.

（责任编辑 张婷婷）