doi:10.6041/j.issn.1000-1298.2026.18.006

基于改进 YOLO v8n 的玉米病害检测系统

魏继勇[1]　赵鑫宇[1]　张鹏磊[1]　杨　玮[1]　塔　娜[2]　孙　红[1]

(1.中国农业大学智慧农业系统集成研究教育部重点实验室,北京 100083;
2.内蒙古农业大学能源与交通工程学院,呼和浩特 010018)

摘要:针对 YOLO v8n 目标检测模型在光照变化显著和背景杂乱条件下识别玉米病害时存在高漏检率和鲁棒性差的问题,本文提出基于改进 YOLO v8n 的新型玉米病害识别模型 DSEMA-YOLO。在 YOLO v8n 基础上,通过在 C2f 模块瓶颈前集成 EMA 全局注意力机制,构建了新型 C2f-attention 模块,有效减少复杂背景对病害图像识别的干扰,同时完整捕捉上下文信息。通过添加 DSConv 模块对颈部网络结构进行重构,采用自适应卷积核形状调整机制,能更精准捕捉图像中玉米病害目标特征,缓解光照变化和背景杂乱的影响。最后,通过引入尺度 160 像素×160 像素的特征融合层优化颈部网络结构,提升小目标边界框检测精度,增强浅层与深层信息融合,从而提高识别准确率。头部网络中新增微目标检测模块,并与尺度 160 像素×160 像素特征融合层相连。田间环境采集的玉米病害数据集试验结果表明,改进模型 mAP@0.5 为 92.2%,较 YOLO v8n 模型提升 7.7 个百分点。在保持检测速度和较低计算开销的同时有效提升了玉米病害识别精度。

关键词:玉米;病害识别;目标检测;YOLO v8n 模型

中图分类号:S126　　**文献标识码**:A　　**文章编号**:1000-1298(2026)18-0062-08　　**OSID**:

Maize Disease Detection System Based on Improved YOLO v8n

Wei Jiyong[1]　Zhao Xinyu[1]　Zhang Penglei[1]　Yang Wei[1]　Ta Na[2]　Sun Hong[1]

(1. *Key Laboratory of Smart Agriculture Systems*, *Ministry of Education*, *China Agricultural University*, *Beijing* 100083, *China*
2. *College of Energy and Traffic Engineering*, *Inner Mongolia Agricultural University*, *Hohhot* 010018, *China*)

Abstract: Aiming to address the high missed detection rate and poor robustness of the YOLO v8n target detection model when identifying maize diseases under significant lighting changes and background disorder, a novel maize disease identification model was proposed based on improved YOLO v8n, DSEMA-YOLO. Based on YOLO v8n, by integrating the EMA global attention mechanism before the C2f module bottleneck, a C2f-attention module was constructed, effectively reducing interference from complex backgrounds on defective image recognition while fully capturing contextual information. By adding the DSConv module to reconstruct the neck network structure and adopting an adaptive convolutional kernel shape adjustment mechanism, it can more accurately capture target features of corn diseases in the image, mitigating the effects of lighting changes and background clutter. Finally, by introducing a 160 pixel×160 pixel scale feature fusion layer to optimize the neck network structure, the detection accuracy of small object bounding boxes was improved, and the fusion of shallow and deep information was strengthened, thereby improving recognition accuracy. A micro-object detection module was added to the head network, connected to the 160 pixel×160 pixel scale feature fusion layer. In the experiment, the improved model mAP@0.5 of the maize disease dataset collected in the field environment was 92.2%, an improvement of 7.7 percentage points over that of the YOLO v8n model. While maintaining detection speed and low computational overhead, it effectively improved the accuracy of maize disease identification.

Key words: maize; disease detection; object detection; YOLO v8n model

收稿日期:2026-03-11　修回日期:2026-03-25

基金项目:内蒙古中央引导地方科技发展资金项目(2024ZY0145)

作者简介:魏继勇(2000—),男,硕士生,主要从事农业信息化技术研究,E-mail:3419169554@qq.com

通信作者:孙红(1980—),女,教授,博士生导师,主要从事农业信息化技术研究,E-mail:sunhong@cau.edu.cn

0　引言

玉米是我国三大粮食作物之一，其产量和质量受多种病害影响[1]。在实际生产环境中，玉米病害通常表现为形态多样、尺度变化大，这给人工识别和传统图像处理方法带来了较大挑战。尤其是灰斑病、小斑病等病害，其病斑面积较小且分布分散，这进一步增加了检测难度。实现对玉米病害的快速、准确识别，对指导田间病害精准防治具有重要意义[2]。基于深度学习的目标检测方法大致可分为 2 类：一类是以 Faster R－CNN[3] 为代表的两阶段目标检测，另一类是以 SSD[4] 和 YOLO[5-6] 系列为代表的单阶段目标检测。在众多模型中，YOLO 系列因其结构简洁、推理速度快以及实时性高，被广泛应用于作物病害检测识别，并在多种农作物病害检测任务中都取得了较好效果。相关研究表明，通过对 YOLO 模型进行针对性改进，可以进一步提升其在复杂农业环境下的检测能力[7-8]。文献[9]在 YOLO v5 中融合自注意力机制与卷积注意模块，对茶树病虫害检测精度达 82.6%。文献[10]优化 YOLO v5 结构用于农田害虫识别，使检测平均精度提升至 80.91%。文献[11]通过构建冬小麦不同生育期数据集，并提出一种基于改进 YOLO v8s 的小麦赤霉病识别方法，对赤霉病高精度检测准确率达 98.3%。

尽管现有研究在作物病害识别方面已取得一定进展，但在实际玉米田间环境中仍存在不少问题。首先，玉米叶片上的病斑通常尺寸较小且形态不规则，在特征提取过程中易被忽略或表达不足[12]。其次，田间环境复杂多变，如光照条件变化及叶片之间的相互遮挡等，都会引入干扰信息，从而影响模型对病斑区域的准确识别[13]。另外，部分检测方法依赖结构较为复杂的模型，计算开销较大，在实际农业应用中的部署存在一定难度[14]。

因此，在控制模型规模与计算成本的同时，提高在复杂环境下对小尺度病斑的检测能力，仍是当前需重点关注的问题[15]。针对上述问题，本文以 YOLO v8n 为基础模型，提出一种面向复杂环境下玉米病害识别的 DSEMA－YOLO 检测模型。在骨干网络中引入 EMA 注意力机制，以提升模型对病斑关键区域的关注能力；在颈部网络中融合 DSConv 动态卷积，从而增强对不同尺度及不规则形态特征的表征效果。在此基础上，通过增加小目标检测分支并对多尺度特征融合方式进行优化，以进一步改善模型对细小病斑的识别能力。

1　数据集

1.1　数据采集

以玉米病害图像为研究对象，选取锈病、灰斑病、条纹病、大斑病和小斑病 5 类常见病害作为检测目标，部分样例如图 1 所示。

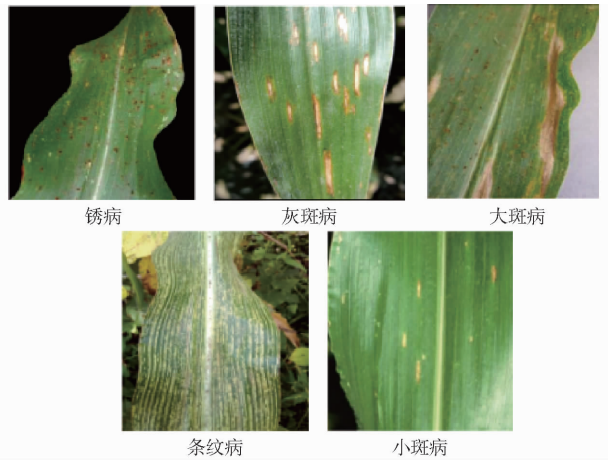

图 1　常见玉米病害样本

Fig. 1　Common maize disease samples

数据集质量对模型效果具有重要作用，为贴近实际应用场景，构建了包含上述 5 类病害的自建数据集。数据来源包括实地采集和公开数据 2 部分。其中，实地数据采集于河南省新乡市中国农业科学院大田实验基地，在玉米生长季（6—9 月）分时段进行获取。采集设备为智能手机，图像分辨率均为 1 920 像素 ×1 080 像素及以上，以保证数据清晰度和可靠性。采集过程尽量覆盖不同环境条件，包括晴天、阴天等天气，同时考虑叶片遮挡、背景杂乱及拍摄角度变化等实际田间情况，提高数据多样性和模型泛化能力。

共获取图像 6 205 幅：实地采集图像 1 436 幅、公开数据集图像 4 769 幅，构建了多场景、多尺度玉米病害数据集，如表 1 所示。

表 1　数据集划分结果

Tab. 1　Dataset segmentation results　　幅

类别	条纹病	锈病	灰斑病	大斑病	小斑病	总计
训练集	854	1 081	1 001	977	1 068	4 981
验证集	214	254	250	248	258	1 224
总计	1 068	1 335	1 251	1 225	1 326	6 205

1.2　数据集制作

为提高数据集可用性，采集过程中从不同角度获取玉米病害图像，同时在模型训练前对数据进行预处理与标注。将所有图像分辨率调整为 640 像素 ×640 像素；使用 LabelImg 工具对病害区域进行人工标注，按照 VOC 格式绘制矩形框，并生成对应

的 XML 标注文件。然后将 XML 文件转换为图像对应的 TXT 格式,满足 YOLO 模型训练输入要求。最后,按照比例 8∶2 将数据集划分为训练集和验证集[15]。

考虑到田间环境复杂且样本规模有限,直接训练易出现过拟合问题,因此对数据集进行了 3 倍增强处理。针对光照变化,通过亮度增强与色彩调整扩展样本分布;针对拍摄过程可能出现的成像不清问题,引入高斯模糊以模拟不同程度的模糊情况,从而提升模型在复杂场景下的鲁棒性。

2 YOLO v8n 模型改进

2.1 YOLO v8n 模型结构

YOLO v8 是目标检测领域中应用最为广泛的算法之一,在兼顾检测速度的同时,对检测精度和目标检测能力均有提升。YOLO 网络结构由骨干网络(Backbone)、颈部网络(Neck)和检测头(Head)3 部分组成[16]。其中,骨干网络用于提取图像基础特征;颈部网络负责对不同层级特征进行融合和增强,以提升多尺度信息表达能力[17-18];检测头则用于对目标边界框的回归及类别预测。通过上述结构协同作用,提高模型整体检测效果[19]。

YOLO v8 针对不同应用需求提供了 n、s、m、l、x 5 种版本[20]。YOLO v8n 参数量小、推理速度快,更适用于本文的需求与场景[21]。因此,选用 YOLO v8n 作为基线模型开展研究。

2.2 轻量化改进模型 DSEMA-YOLO

2.2.1 网络整体框架

针对光照变化显著及背景复杂条件下玉米病害识别易出现漏检、鲁棒性不足的问题,以 YOLO v8n 为基础进行结构优化,构建了 DSEMA-YOLO 检测模型,整体结构如图 2 所示。

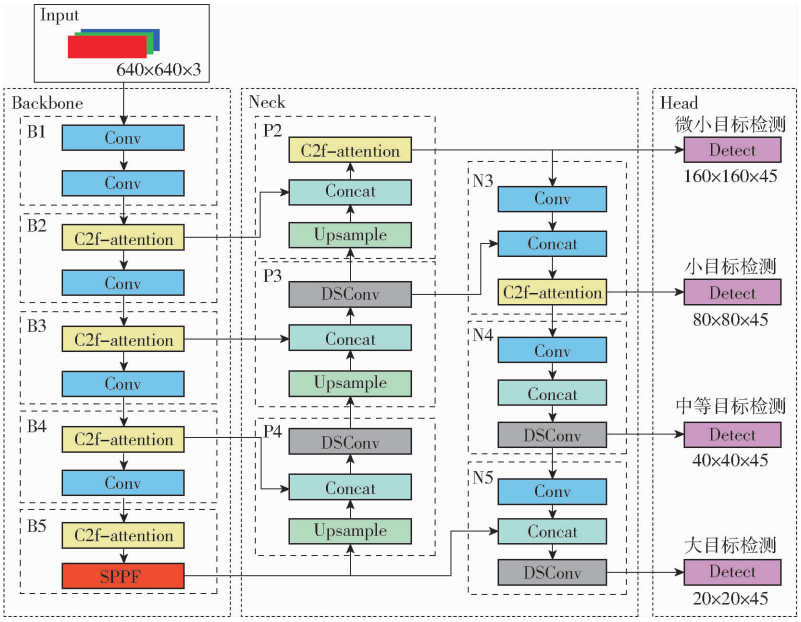

图 2 DSEMA-YOLO 模型网络结构

Fig. 2 DSEMA-YOLO model network structure

在骨干网络(Backbone)部分,引入 EMA(Efficient multi-scale attention)机制的 C2f-attention 结构替换原来的 C2f 模块。该模块能够在多尺度特征空间内对通道与空间信息进行自适应加权,使网络更聚焦于病斑区域,增强对关键病害特征的提前能力。

在颈部网络(Neck)部分,对原有特征融合结构进行了改进。在特征金字塔基础上增加 P2 与 N3 层,以补充浅层细节信息,减轻深层网络中微小特征的衰减问题。同时,在新增层中引入 C2f-attention 模块,以提升对小尺度病斑的感知能力。此外,将 DSConv 动态卷积模块应用于 P3、P4、N4 和 N5 等特征融合层,用以替代原有 C2f 结构。该模块可根据输入特征动态调整卷积参数,从而更好适应病斑在尺度、形态及遮挡等方面的变化,提高模型对病斑的表达能力。

在检测头(Head)部分,引入小目标检测分支,并与 P2 和 N3 特征层进行连接,构建多尺度检测结构。该设计能够在预测阶段充分利用浅层与中层特征信息,从而提升模型对微小目标病害的检测能力。

综合来看,DSEMA-YOLO 通过对 Backbone、Neck 和 Head 的协同优化,在增强小目标特征表达的同时有效提高了模型在田间复杂环境下的鲁棒性,有效改善了玉米病害检测性能。

2.2.2 EMA-attention 模块

在实际田间环境中,玉米病害图像往往伴随背景复杂的问题,易对特征提取过程产生干扰,进而影

响病害信息有效表达。

针对上述情况，引入 EMA－attention 模块提高对特征的提取能力。模块在控制计算开销的前提下，在多尺度空间角度对特征进行建模，通过自适应权重分配机制强化病害特征相关的信息的同时抑制无关背景。具体而言，首先将输入特征划分为多个尺度分支，在不同分支中提取空间与通道信息，以捕获病斑在多个尺度下的特征表现[22]；随后，通过轻量化权重计算方式对各尺度特征进行融合，使模型更加集中于关键区域。

在结构设计上，EMA 引入类似 CA 模块的共享 1×1 卷积分支（记为 1×1 分支），并在其并行位置设置 3×3 卷积分支，用于进一步整合多尺度空间结构信息。通过双分支协同作用，增强了特征表达能力如图 3 所示。图中，h 表示特征图高度，w 表示特征图宽度，c 表示特征图通道数，g 表示通道分组数；X 表示分组后单组特征图；“//”表示整除运算，$c//g$ 表示每组特征通道数。

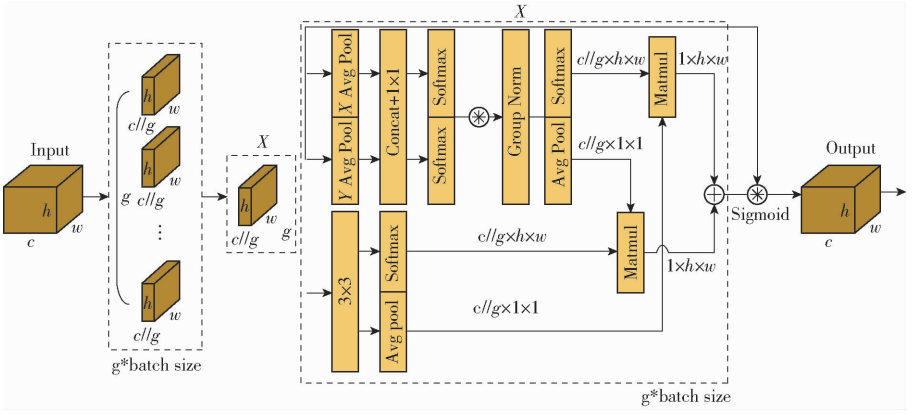

图 3　EMA－attention 模块

Fig. 3　EMA－attention module

EMA－attention 在结构设计上减少了对全局信息的大规模计算，在控制参数量和计算开销方面更具优势，适合嵌入检测网络。在玉米病害识别任务中，能够提升模型对病斑区域、边界模糊以及光照不均区域的响应能力，从而增强在复杂背景条件下的稳定性[22-23]。

2.2.3　DCv2 与 DSConv 模块设计

在真实玉米地病害识别中，常面临病害种类多、形态变化大等问题[24]。传统卷积核通常采用固定尺寸和规则采样方式，对不同尺度及不规则形状目标的表达能力受限，削弱了模型对形态变化大的目标检测能力[25]。为解决这个问题，引入动态卷积（Dynamic convolution，DyConv），并在此基础上构建 DCv2 模块，增强网络对复杂病害形态的特征表达能力。

在 DyConv 中，卷积核中每个采样点位置由可学习偏移量动态确定，使卷积采样不再受限于固定的规则网格分布，从而能够自适应不同形状特征的玉米病害目标。具体而言，DyConv 通过对输入特征图进行预测采样点偏移量，并结合偏移后的位置完成对特征采样与卷积运算。

输出特征图 Y 可表示为

$$Y(p_0) = \sum_{p_n \in R} w(p_n) x(p_0 + p_n + \Delta p_n) \quad (1)$$

其中 $R = [(-1,-1),(-1,0),\cdots,(0,1),(1,1)]$

式中　p_0——输入特征图像素位置

R——其他像素点与中心像素点的相对位置

p_n——R 中对于 p_0 的相对位置

Δp_n——偏移量

x——输入特征图

w——应采样位置的卷积权重

通过引入偏移量 Δp_n，让卷积核的采样位置由规则网格变为不规则分布，采样区域可进一步表示为

$$R = (\Delta p_n \mid n = 1,2,\cdots,n) \quad (2)$$

该方式使卷积核能够更好地贴合玉米病害目标的边缘和不规则形态。

为进一步增强采样点对关键病害区域的响应能力，在 DyConv 基础上引入调制系数 Δm_k，形成 DCv2 卷积。调制系数用于动态调整各采样点贡献权重，从而抑制背景干扰信息，对无关采样点的响应可学习设置为 0。

对任意位置 p，输出特征图 $Y(p)$ 可表示为

$$Y(p) = \sum_{k=1}^{K} w_k x(p + p_k + \Delta p_k) \Delta m_k \quad (3)$$

式中　K——卷积核采样点数量

w_k——第 k 个采样点权重

p_k——初始位置

Δp_k——可学习偏移量

DCv2 模块先对输入的特征图预处理，生成偏移

量与调制系数;随后,对规则采样点进行多方向偏移形成不规则采样;然后将采样特征与卷积核权重进行逐元素相乘并求和,得到输出特征图。动态特征提取过程如图 4 所示。

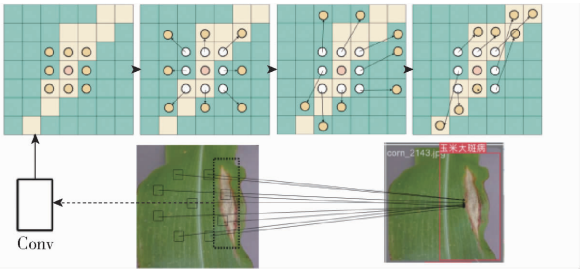

图 4 DCv2 动态提取过程

Fig. 4 Dynamic feature extraction process of DCv2

YOLO v8n 的 C2f 模块通过多级 Bottleneck 结构逐层提取特征,从而实现多尺度特征表达。但在骨干网络中采用的普通卷积在感受野和形态建模方面存在一定局限[26]。

针对上述问题,以 DCv2 为基础,在 C2f 结构引入 DSConv 模块。将 C2f 模块模块在保持 C2f 多分支与特征复用优势的同时,增强网络对多尺度、不规则病害目标的表达能力。整体结构如图 5 所示。

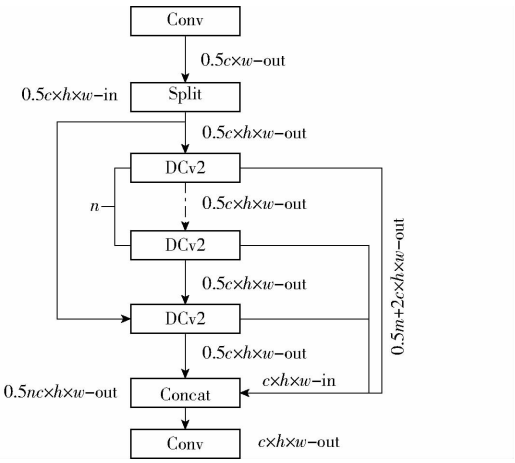

图 5 DSConv 结构图

Fig. 5 DSConv architecture diagram

2.2.4 微小目标检测检测优化

在检测头(Head)部分,新增 160 像素 × 160 像素的微小目标检测头。对 Neck 网络特征融合后,将不同尺度特征被分别输入到对应的检测层中。使模型能够完成对微小、小、中等、大 4 类目标的检测。通过对高分辨率特征的使用,将微小病斑信息保留,从而提升微小目标病害检测能力。在参数量仅小幅增加情况下,实现了检测精度有效提升。

2.2.5 损失函数优化

在 YOLO v8n 中,CIoU 损失函数难以刻画实际形状差异,同时在目标尺度变化较大时易出现不稳定情况,此外,CIoU 未考虑预测框与真实框之间的方向关系,对于形态不规则目标,回归过程存在收敛速度较慢的问题。

因此,采用 SIoU 损失函数对原有回归损失进行解决。SIoU 引入预测框与真实框之间的角度信息,并结合位置信息对惩罚项进行设计,提高边界框回归精度与收敛效率。SIoU 损失函数可表示为

$$L_{SIoU} = 1 - I_{oU} + \frac{\Delta + \Omega}{2} \tag{4}$$

其中 $$I_{oU} = \frac{|B \cap B^{gt}|}{|B \cup B^{gt}|}$$

式中 I_{oU}——预测框 B 与真实框 B^{gt} 之间交并比

Δ——距离损失,计算预测框和真实框中心距离

Ω——形状损失,衡量预测框中心与真实框中心偏差

3 结果与分析

3.1 试验设置

3.1.1 训练环境与参数设置

试验环境配置:操作系统为 Windows 11,处理器为 Intel ® Core i9 - 13900HX,显卡(GPU)为 GeForce RTX 4060,编程语言为 Python 3.8,深度学习框架为 PyTorch 1.13。

在训练过程中,输入图像统一调整为 640 像素 × 640 像素,采用 SGD 优化器进行参数更新,动量设为 0.937,初始学习率为 0.01,训练轮数为 200,并在 GPU 环境下完成模型训练。

3.1.2 评价指标

选择平均精度均值(mAP)、浮点运算量及模型参数量作为评价指标,对模型在玉米病害检测模型进行性能评估[27]。

3.2 消融试验

为验证各改进模块有效性,以 YOLO v8n 为基线模型,分别引入 EMA 注意力机制、DSConv 动态卷积以及小目标检测头构建不同组合模型,并进行消融试验,结果如表 2 所示。

表 2 消融试验结果

Tab. 2 Ablation experiment results

EMA	DSConv	小目标检测头	参数量	浮点运算量	mAP@0.5/%
×	×	×	3.1×10^6	8.70×10^9	84.5
√	×	×	3.1×10^6	8.72×10^9	86.5
√	√	×	4.4×10^6	8.60×10^9	87.7
√	×	√	4.4×10^6	1.43×10^9	89.9
×	√	√	3.2×10^6	1.16×10^{10}	91.8
√	√	√	4.5×10^6	1.16×10^{10}	92.2

注:√表示使用该模块,×表示不使用该模块。

由表 2 可知，各模块均对模型性能产生了不同程度影响，但其作用机制存在差异。引入 EMA 模块后，mAP@0.5 提升至 86.5%。通过增强空间与通道特征之间的关联性，使模型在复杂背景中更易聚焦于病斑区域，从而提升对显著病害特征的识别能力。在此基础上加入 DSConv 后，模型性能提升至 87.7%。得益于其动态卷积特性，网络能够根据输入特征自适应调整参数，从而增强对不同尺度及不规则形态病斑的表达能力，对小目标和形态变化大的目标更为明显。

当引入小目标检测头后，模型性能提升更加显著。其中，DSConv 结合小目标检测头的模型 mAP@0.5 达到 91.8%，表明高分辨率特征的引入能够有效弥补浅层信息不足的问题，增强浅层与深层信息融合，显著增强对病斑的检测能力。

综合 3 种改进策略，DSEMA－YOLO 取得最佳性能，mAP@0.5 达到 92.2%。表明多模块协同优化在提升检测精度方面具有明显优势。

总体而言，所提模型在保证计算复杂度基本可控的前提下，实现了检测性能的显著提升。相比 YOLO v8n 模型，mAP@0.5 提高 7.7 个百分点，表明该方法在复杂环境下具有更好的适应能力，如图 6 所示。

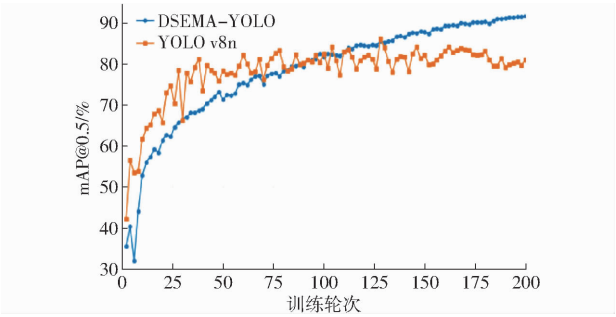

图 6　改进前后模型性能变化曲线

Fig. 6　Performance change curves of before and after improvement

3.3　不同模型性能测试

如表 3 所示，各模型在玉米病害识别任务中的表现存在明显差异，且不同类别之间的检测效果并不均衡。具体类别来看，YOLO v5n 对条纹病（94.3%）和大斑病（88.2%）等病斑面积大、特征清晰的目标具有很好的识别能力，但在灰斑病（74.8%）和小斑病（71.3%）等小尺度、纹理复杂病害上的表现相对较弱，其对细粒度特征的刻画能力相对有限。

表 3　不同模型性能测试结果

Tab. 3　Performance test results of different models　%

模型	mAP@0.5						mAP@0.5:0.95
	条纹病	锈病	灰斑病	大斑病	小斑病	平均值	
YOLO v5n	94.3	78.7	74.8	88.2	71.3	81.4	63.6
YOLO v8n	94.7	81.2	78.6	89.1	78.9	84.5	65.3
改进 YOLO v5n	94.2	80.8	79.4	87.4	77.9	83.9	66.1
YOLO v8－Extend	94.5	81.1	79.8	88.7	76.3	84.0	67.5
DSEMA－YOLO	97.5	88.5	89.6	93.4	91.6	92.2	69.8

相比之下，YOLO v8n 在各类别上均有一定提升，尤其在灰斑病（78.6%）和小斑病（78.9%）上的改进较为明显，其在多尺度特征融合策略具有一定效果。但还是对小尺度病斑与背景信息区分仍不够充分。

改进 YOLO v5n 在灰斑病和小斑病上分别提升至 79.4% 和 77.9%，但整体性能提升不明显，改进主要体现在局部特征层面；YOLO v8－Extend 虽在高 IoU 阈值下有一定提升（mAP@0.5:0.95 为 67.5%），但在小斑病类别上出现下降。因此，单纯增加网络复杂度难以改善田间复杂背景条件下小目标病害检测问题。

相比上述方法，DSEMA－YOLO 在各类别上均取得较好结果，尤其对微小目标尺度病害的提升最为显著：小斑病由 78.9% 提高到 91.6%，灰斑病由 78.6% 提高到 89.6%。而对于条纹病和大斑病等大目标类别，提升幅度相对有限，模型在此类目标上已具备较好基础性能，而改进方法的优势主要体现在小目标样本上。

性能提升源于多个模块的协同作用：小目标检测头增强了浅层高分辨率特征的利用，使细粒度信息得到保留；DSConv 提升了模型对不同尺度和形态变化的适应能力；EMA 注意力机制在一定程度上削弱背景干扰，使特征表达更集中于病斑区域。

此外，在更高 IoU 阈值下，DSEMA－YOLO 的 mAP@0.5:0.95 达到 69.8%，较 YOLO v8n 提升 4.5 个百分点，表明模型在定位精度方面同样有所改善。总体来看，该方法在田间复杂环境背景下对小目标玉米病害具有更好的表达能力和检测能力。

4 软件系统

4.1 总体架构

农技耘系统采用“前端交互-云端服务-AI 智能引擎”的分布式架构设计,构建了覆盖玉米病害图像采集、智能识别、知识库及决策支持的完整业务流程。通过接口实现数据交互。松耦合的特性有利于提升系统在多用户并发访问场景下的可靠性与扩展性。同时,也为后续功能开发与迭代提供了空间。

4.2 系统实现

结合功能需求与用户习惯,农技耘 App 采用模块化设计方式构建。系统主要包括病害识别模块、病害知识库模块以及 AI 农技助手与问答社区。

4.2.1 病害识别模块

病害识别模块核心功能是对玉米病害进行检测与诊断。用户可通过拍照或上传本地图片提交病害图像,系统将数据上传至云端模型分析,然后返回对应的病害信息与防治建议。

识别结果页面采用卡片式展示直接呈现检测结果及匹配度。同时,系统会自动关联相关病害信息及防治建议,支持用户进一步查看详细信息。此外,还提供病害高发时期及典型症状等其他信息,用来帮助用户进一步诊断病害,如图 7 所示。



(a) 主页面 (b) 识别结果页面

图 7 病害识别页面

Fig. 7 Disease identification page

4.2.2 病害知识库模块

病害知识库模块用于提供病害详细信息。在病害详情页面中,包括症状特征、发生规律以及防治措施,涵盖农业防治、生物防治和化学防治等内容。

用户在完成识别后直接跳转至对应病害的详细页面,实现“识别-认知-防治”一体化,增强系统实用性,如图 8 所示。



(a) 知识库首页 (b) 病害详细页面

图 8 知识库页面

Fig. 8 Knowledge base page

4.2.3 AI 农技助手与问答社区模块

AI 农技助手为用户提供智能问答,用户可以围绕病害识别结果进行深入咨询。也可通过文本或语音方式提出相关问题,如病害成因、防治时机及用药建议等,系统能够给出相应解答,一定程度上弥补用户相关专业知识不足的困境,如图 9 所示。



(a) 农技助手页面 (b) 问答社区页面 (c) 问题详情页面

图 9 农技助手与问答社区模块

Fig. 9 Agricultural technology assistant and Q&A community module

问答社区模块则为用户提供交流与经验分享的平台,用户围绕玉米病虫害问题与田间管理等内容进行讨论。

5 结论

(1)构建了一种融合多尺度注意力机制的轻量化检测模型。针对田间玉米复杂背景下对小目标病害检测能力不足的问题,在骨干网络中引入 EMA 注意力机制,对特征进行自适应加权,增强了对关键病斑区域的检测性能,同时在一定程度上抑制了背景干扰。在此基础上,在颈部网络引入 DSConv 动态卷积并补充 P2 与 N3 特征层,提升模型对微小病斑的识别与表达能力。

(2)通过多个模块协同,显著提升了模型的检

测性能。在检测头部分增加分辨率 160 像素 × 160 像素分支，并结合 SIoU 损失函数优化边界框回归过程，使模型在复杂光照与杂乱背景条件下具有更稳定的定位能力。试验结果表明，改进模型在自建数据集上的 mAP@0.5 提高至 92.2%，同时在保证计算开销可控的前提下，降低了漏检现象，实现了精度与效率之间的平衡。

(3)完成了面向实际应用的系统开发与功能集成。采用前后端分离与云端部署相结合的方式，实现从图像采集、自动识别到知识服务与智能问答的完整流。

参 考 文 献

[1] 代瑞熙，徐伟平. 中国玉米增产潜力预测[J]. 农业展望，2022，18(3)：41－49.
Dai Ruixi, Xu Weiping. Potential forecast of maize yield increase in China[J]. Agricultural Outlook, 2022, 18(3):41－49. (in Chinese)

[2] Gan X, Cao S, Wang J, et al. YOLO v8－DBW: an improved YOLO v8－based algorithm for maize leaf diseases and pests detection[J]. Sensors, 2025, 25(15): 4529.

[3] Ren S, He K, Girshick R, et al. Faster R－CNN: towards real-time object detection with region proposal networks[J]. IEEE Trans. Pattern Anal. Mach. Intell., 2017, 39(6): 1137－1149.

[4] Liu W, Anguelov D, Eehan D, et al. SSD: single shot multibox detector[C]// Computer Vision－ECCV 2016: 14th European Conference, 2016: 21－37.

[5] Yang Z, Feng H, Ruan Y, et al. Tea tree pest detection algorithm based on improved Yolov7－Tiny[J]. Agriculture, 2023, 13(5): 1031.

[6] Shi Q, Li C, Guo B, et al. Manipulator-based autonomous inspections at road checkpoints: application of faster YOLO for detecting large objects[J]. Defence Technology, 2022, 18(6): 937－951.

[7] Xu D, Xiong H, Liao Y, et al. EMA－YOLO: a novel target-detection algorithm for immature yellow peach based on YOLO v8[J]. Sensors, 2024, 24(12): 3783.

[8] Wei S W, Liang L, Wei F F, et al. Dynamic convolution and attention-based steel surface defect detection via LDSE－YOLO[J]. Journal of Testing and Evalution, 2026, 30(4): 1053－1068.

[9] Xue Z, Xu R, Bai D, et al. YOLO－tea: a tea disease detection model improved by YOLO v5[J]. Forests, 2023, 14(2): 415.

[10] 柳春源，陈洪建，曾小辉，等. 基于 YOLO－V5 与 ResNet50 的农田害虫检测[J]. 人工智能与机器人研究，2022，11(3)：236－247.
Liu Chunyuan, Chen Hongjian, Zeng Xiaohui, et al. Detection of farmland pests based on YOLO－V5 and ResNet50[J]. Research on Artificial Intelligence and Robotics, 2022, 11(3): 236－247. (in Chinese)

[11] 时雷，杨程凯，雷镜楷，等. 基于改进 YOLO v8s 的小麦小穗赤霉病检测研究[J]. 农业机械学报，2024，55(7)：280－289.
Shi Lei, Yang Chengkai, Lei Jingkai, et al. Wheat spikelet detection of fusarium head blight based on improved YOLO v8s[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(7): 280－289. (in Chinese)

[12] Li F, Song Q, Zhang Y, et al. GhostNet_Triplet_YOLO v8n: a lightweight YOLO v8n algorithm for maize disease detection[J]. Agriculture, 2024, 14(10): 1823.

[13] Zhang W, Chen S, Li W. An improved lightweight YOLO v5 based on multi-attention for small object detection[J]. J. Eng. Sci., 2023, 45(10): 110－118.

[14] 张立伟，肖国锋，高东浩，等. 基于改进型轻量化的 YOLOv5 玉米病害检测[J]. 计算机科学与应用，2025，15(6)：99－109.
Zhang Liwei, Xiao Guofeng, Gao Donghao, et al. Corn disease detection based on improved lightweight YOLOv5[J]. Computer Science and Application, 2025, 15(6): 99－109. (in Chinese)

[15] 刘梦姝，张春琪，晁金阳，等. 基于 YOLO v8n 改进的小麦病害检测系统[J]. 农业机械学报，2024，55(增刊 1)：280－287，355.
Liu Mengshu, Zhang Chunqi, Chao Jinyang, et al. Improved wheat disease detection system based on YOLO v8n[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(S1): 280－287, 355. (in Chinese)

[16] 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 Sijia, Li Lei, Gu Yue, et al. Sugarcane leaf disease recognition algorithm based on improved YOLO v8n[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(10): 567－574. (in Chinese)

[17] 王春梅，刘欢. YOLO v8－VSC：一种轻量级的带钢表面缺陷检测算法[J]. 计算机科学与探索，2024，3(1)：151－160.
Wang Chunmei, Liu Huan. YOLO v8－VSC: lightweight algorithm for strip surface defect detection[J]. Journal of Frontiers of Computer Science and Technology, 2024, 3(1): 151－160. (in Chinese)

[18] Xu Y, Huang J N, Wang J X, et al. ESA－VLAD: a lightweight network based on second-order attention and NetVLAD for loop closure detection[J]. IEEE Robotics and Automation Letters, 2021, 6(4): 6545－6552.

[19] Dian S Y, Yin Y J, Wu C, et al. Loop closure detection based on local-global similarity measurement strategies[J]. Journal of Electronic Imaging, 2022, 31(2): 31－42.

(下转第 132 页)

[110] 闫德见. 小麦防病害 AI 来助力[EB/OL]. (2025 - 05 - 19)[2026 - 05 - 15]. https://www.moa.gov.cn/xw/qg/202505/t20250516_6474032.htm.

[111] 朱萌,龚为纲. 数字技术赋能农业社会化服务的技术逻辑与实践困境:基于农技推广大数据的分析[J]. 西北农林科技大学学报(社会科学版), 2024, 24(6): 83 - 95.
Zhu Meng, Gong Weigang. Technical logic and practical challenges of digital technology empowering agricultural socialization services: an analysis based on big data of agricultural extension platform[J]. Journal of Northwest A&F University (Social Science Edition), 2024, 24(6): 83 - 95. (in Chinese)

[112] 邵腾伟,吕秀梅. 基于转变农业发展方式的基层农业技术推广路径选择[J]. 系统工程理论与实践, 2013, 33(4): 942 - 948.
Shao Tengwei, Lü Xiumei. Research on the choices to agricultural technology extension ways based on the changing of agricultural development means[J]. Systems Engineering-Theory & Practice, 2013, 33(4): 942 - 948. (in Chinese)

[113] 姚科艳,陈利根,刘珍珍. 政府购买服务模式如何影响农业技术推广效果:基于农作物秸秆还田技术的实证分析[J]. 农业技术经济, 2023(11): 98 - 109.
Yao Keyan, Chen Ligen, Liu Zhenzhen. How does government purchase model affect the effect of agricultural technology promotion: an empirical analysis based on mechanized straw returning technology for crops[J]. Journal of Agrotechnical Economics, 2023(11): 98 - 109. (in Chinese)

[114] 马红坤,陈雪,毛世平. 如何打通农业新技术推广应用的“最后一公里”:以日本推广智能农机“遥控割草机”为例[J]. 中国软科学, 2025(5): 67 - 78.
Ma Hongkun, Chen Xue, Mao Shiping. How to bridge the “last mile” of promoting and applying new agricultural technologies: a case study of Japan's remote-controlled mower[J]. China Soft Science, 2025(5): 67 - 78. (in Chinese)

[115] 易红梅,何煦,智华勇,等. 涉农数智技术采纳现状与现实挑战:基于两套具有代表性农户调查的研究[J]. 智慧农业(中英文), 2026, 8(3): 51 - 66.
Yi Hongmei, He Xu, Zhi Huayong, et al. Adoption and challenges of digital and intelligent technologies in agriculture: evidence from two representative household survey[J]. Smart Agriculture, 2026, 8(3): 51 - 66. (in Chinese)

(上接第 69 页)

[20] Dong G, Xie W, Huang X, et al. Review of small object detection algorithms based on deep learning[J]. Computer Engineering and Applications, 2023, 59(11): 16 - 27.

[21] Yang G, Wang J, Nie Z, et al. A lightweight YOLO v8 tomato detection algorithm combining feature enhancement and attention [J]. Agronomy, 2023, 13(7): 18 - 24.

[22] 雷帮军,余翱,余快. 基于 YOLO v8s 改进的小目标检测算法[J]. 无线电工程, 2024, 54(4): 857 - 870.
Lei Bangjun, Yu Ao, Yu Kuai. Small object detection algorithm based on improved YOLO v8s[J]. Radio Engineering, 2024, 54(4): 857 - 870. (in Chinese)

[23] 王泽宇,徐慧英,朱信忠,等. 基于 YOLO v8 改进的密集行人检测算法:MER - YOLO[J]. 计算机工程与科学, 2024, 46(6): 1050 - 1062.
Wang Zeyu, Xu Huiying, Zhu Xinzhong, et al. An improved dense pedestrian detection algorithm based on YOLO v8: MER - YOLO[J]. Computer Engineering & Science, 2024, 46(6): 1050 - 1062. (in Chinese)

[24] 周兴华,陈西江,羊海东,等. 动态卷积 YOLO v5 的视频火焰检测算法[J]. 测绘科学, 2023, 48(4): 106 - 118.
Zhou Xinghua, Chen Xijiang, Yang Haidong, et al. Video flame detection algorithm based on dynamic convolution YOLO v5 [J]. Science of Surveying and Mapping, 2023, 48(4): 106 - 118. (in Chinese)

[25] Shi Q, Li C, Guo B, et al. Manipulator-based autonomous inspections at road checkpoints: application of faster YOLO for detecting large objects[J]. Defence Technology, 2022, 18(6): 937 - 951.

[26] 刘清河, 崔光尚, 姜翔瀚,等. 改进 YOLO v8 的复杂交通场景目标检测算法[C]// 第三十一届中国汽车工程学会年会论文集, 2024: 89 - 95.
Liu Qinghe, Cui Guangshang, Jiang Xianghan, et al. Improved YOLO v8 target detection algorithm for complex traffic scenes [C]// Proceedings of the 31st SAECCE2024, 2024: 89 - 95. (in Chinese)

[27] 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)