

王斌兵,张亚利,郑光,等.EMD-YOLO:基于YOLOv8n改进的轻量化作物叶部病害检测算法[J].华中农业大学学报,2025,44(4):181-191.
DOI:10.13300/j.cnki.hnlkxb.2025.04.018

EMD-YOLO:基于YOLOv8n改进的轻量化作物叶部病害检测算法

王斌兵,张亚利,郑光,时雷,尹飞

河南农业大学信息与管理科学学院,郑州 450046

摘要 为准确、快速地识别作物叶部病害,降低手工诊断成本,减少叶部病害对作物生长过程与产量的危害,提出一种基于YOLOv8n新型轻量级作物叶部病害检测算法EMD-YOLO。该算法结合多尺度空洞注意力MSDA、EffectiveSE注意力机制、DySample上采样以及Wise-IoU损失函数。其中,多尺度空洞注意力MSDA结合多尺度空间卷积与注意力机制,提高多尺度特征提取效率;EffectiveSE强化特征选择,提升模型表示性能;DySample上采样保留重要特征,提高特征图分辨率和检测性能;Wise-IoU损失函数优化交并比(IoU)计算方式,提升模型定位精度。结果显示,EMD-YOLO的精确度、mAP@0.5、模型权重分别为96.3%、92.8%、4.85 MB,较基线模型YOLOv8n的精确度和平均精度均值分别提高3.0和3.6个百分点,权重降低1.4 MB。结果表明,EMD-YOLO的泛化性良好,适用于移动端农作物叶部病害检测设备。

关键词 深度学习;作物叶部病害;YOLOv8;EffectiveSE注意力机制;多尺度空洞注意力MSDA;轻量化算法

中图分类号 S432;TP391.41

文献标识码 A

文章编号 1000-2421(2025)04-0181-11

农业是社会发展与国家经济的基石,它不仅为数十亿人口提供粮食安全与营养保障,还通过相关产业对农村经济、生态环境和社会秩序产生重要影响。在农业生产中,作物的健康生长无疑是重中之重。但传统的人工病害检测方法不仅耗费时间和精力,且检测效率不高,常常需要植保专家辅助识别,难以应对大规模农田种植时出现的繁重作物病害监测任务。随着计算机技术的快速发展,以机器视觉和深度学习为基础的目标检测算法广泛运用于作物病虫害诊断^[1]。在现代农业生产中,作物生产管理和作物叶片病害的检测逐渐向智能化方向转变^[2-3]。

根据检测阶段的不同,目标检测模型主要分为单阶段和二阶段模型2类。二阶段检测算法通常需要生成候选框,R-CNN^[4]、Fast R-CNN^[5]和Faster R-CNN^[6]都是二阶段检测算法,该类算法精确度高,但参数量大、检测速度低。例如,姜晟等^[7]提出一种改进的Faster RCNN算法来识别茶叶叶部病害,以ResNet50为骨干网络,融入特征金字塔网络(feature

pyramid network, FPN)增加了模型在茶园复杂背景下对茶叶叶部病害特征的提取能力,改善小目标漏检问题和病斑的多尺度问题;采用Rank&Sort(RS)损失函数,缓解样本分布不均给模型带来的性能影响,改进后的模型平均精度达87.95%,但在一些颜色特征相近的病斑上识别效果较差,同时模型权重过大,实现实时检测有较大难度。

单阶段目标检测算法精确度高、学习时间快、参数量较少,且无需生成候选框,能够将边界问题转化为回归问题,先从模型中提取病害特征,再根据提取的特征预测病变位置和类别。单阶段目标检测算法是当今热门的目标检测算法,主要以SSD^[8]和YOLO^[9]为代表。Omer等^[10]提出了一个基于YOLOv5l的黄瓜叶病害检测模型,实现80.1%的平均精度和73.9%的召回率,模型权重仅为13.6 MB,但模型性能在复杂环境下效果不佳,特别是在叶片重合时,模型训练易过拟合。龙阳等^[11]改进了YOLOv5s模型,用于苹果叶部病害检测,与基线模型相比,平均精度

收稿日期:2024-11-28

基金项目:河南省科技攻关项目(242102521027);河南省科技研发计划联合基金项目(222301420113)

王斌兵,E-mail:wangbinbing@stu.henau.edu.cn

通信作者:尹飞,E-mail:yin.fei@henau.edu.cn

均值提升了12.7个百分点,但参数量增加了 34.6×10^6 ,计算量增加了 10.8×10^9 ,模型参数量大,难以部署到移动设备上。刘春菊等^[12]提出了一种基于YOLOv5网络改进的烟草病害识别模型,改进后的YOLOv5-ME-LT相较原模型的召回率和mAP@0.5分别高出14.8、13.0个百分点,但精度下降了1.1个百分点。张一帆等^[13]提出了改进的YOLOv7果蔬叶片病害检测算法,改进后的模型相较于基线模型的精准度、召回率、平均精度分别提高了1.0、0.8、1.3个百分点。但改进后的模型权重仍有49 MB,模型权重相对较大。庞超等^[14]提出一种改进YOLOv8n模型的水稻病害识别方法,改进后获得的BGW-YOLOv8n在水稻病害识别任务中的mAP较YOLOv8n提升了3.6个百分点。Zhang等^[15]提出了DCF-Yolov8算法,使用DenseBlock对YOLOv8网络中的C2f模型进行改进,以实现更好的特征提取。与基线模型YOLOv8相比,该模型的mAP@0.5提高了2.0个百分点,准确率提高了1.3个百分点,召回率提高了3.7个百分点,但检测速度低于YOLOv8n。

尽管现有研究已经在作物叶部病害检测方面取得了较为理想的效果,但大多数工作为实验室条件下的单一作物的病害识别,对于复杂的田间环境和多目标的应用场景试验较少。同时,多数试验缺少对泛用性的验证,这使得改进后的模型具有一定的局限性。此外,现有模型大多体积庞大、参数量较多,且检测过程存在较高的延迟。为解决这些问题,

本研究以精度较高、参数量和模型权重较小的YOLOv8n为基线模型,针对作物叶部病害检测进行优化,以期构建一种轻量化、低延迟、高精度且具备一定泛化能力的作物叶部病害检测模型。

1 材料与方法

1.1 数据来源

本试验的数据集采集自河南省平舆县农田,采集工作于2023年6月至2023年8月期间进行,采集时间为08:00—16:00,采集设备为松典DC202L和iPhone12mini。图像分辨率为4 000像素×3 000像素和2 340像素×1 080像素,以jpg格式保存。数据集图像包含多种光照和背景条件下的农作物叶片,以确保数据集的多样性。经植物病理专家鉴定,共获得数据集2 000张样本图像,包括花生焦斑病、花生早斑病、花生网斑病、玉米锈病、玉米大斑病以及健康叶片6种类型。因自建数据集中病害种类数量较少,故选择Kaggle开源数据库^[16-17]中作物病害叶片样本集进行补充,该数据集涵盖了玉米锈病、玉米大斑病、番茄早疫病、番茄晚疫病和番茄霉霜病5种病害类型。开源数据集共包括2 000张病害图片和300张健康图片。自建数据集与开源数据集共组成4 300张样本图像数据集。

此后,将数据集随机划分为训练集、验证集和测试集,比例为7:1:2,分别为3 010、430、860张,部分叶部病害样本如图1所示。

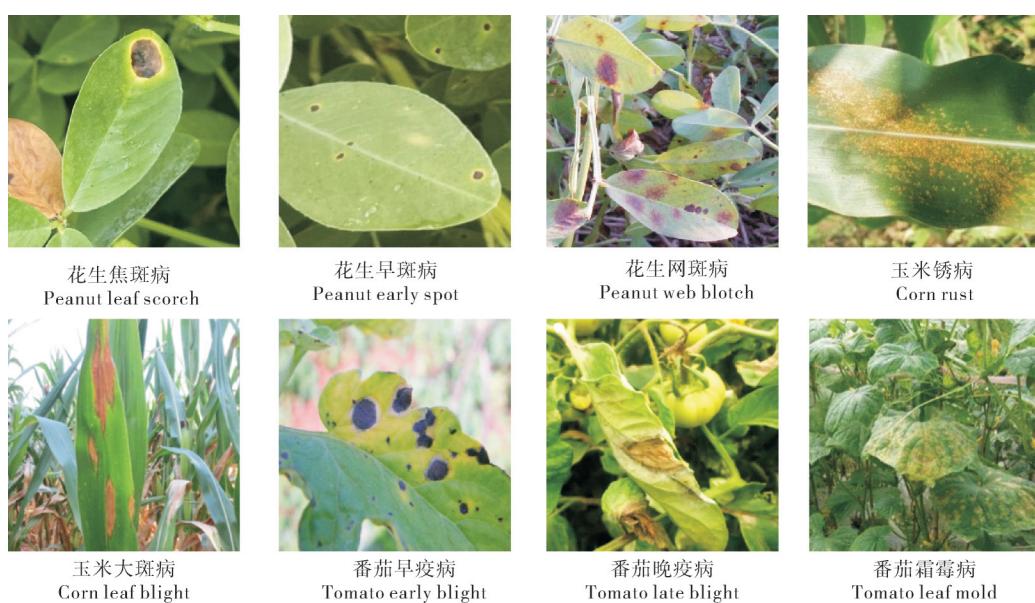


图1 作物叶部病害图像样本

Fig. 1 Image samples of crop leaf disease

1.2 数据增强

数据集样本标注使用 Labelimg 标注软件, 标注结果保存为 YOLO 格式的 txt 文件。对 4 300 张样本数据标注后, 将训练集图像设置为 640 像素 \times 640 像素。为防止样本不均衡和数据集过少导致过拟合与泛化性能差的问题, 对训练集图像进行数据增强。由于数据集图像的拍摄时间涵盖各个时间段, 且图像噪声水平较低, 使用颜色抖动和噪声注入等方法对模型性能的提升有限, 且会增加训练复杂性。因此, 数据增强方式选择镜像与缩放, 增强后的训练集作为模型训练数据。增强前后数据集标注的分布如表 1 所示。

表 1 增强前后数据集标注分布

Table 1 Label distribution of the dataset

病害类型 Disease type	图像数量 Number of images	标注数量 Number of annotations	增强后的图 像数量 Number of images after enhancement	增强后的标注数量 Number of annotations after enhancement
花生焦斑病 Peanut leaf scorch	394	2 010	788	4 020
花生早斑病 Peanut early spot	376	2 842	752	5 684
花生网斑病 Peanut web blotch	372	2 103	744	4 206
玉米锈病 Corn rust	348	1 846	696	3 692
玉米大斑病 Corn leaf blight	383	2 229	766	4 458
番茄早疫病 Tomato early blight	378	2 883	756	5 766
番茄晚疫病 Tomato late blight	392	2 975	784	5 950
番茄霜霉病 Tomato leaf mold	367	2 854	734	5 708
全部 Total	3 010	19 742	6 020	39 484

1.3 YOLOv8 网络

YOLOv8^[18]在检测精度和速度方面明显优于之前的 YOLO 系列网络^[19], 共包含 5 种模型, 分别为 YOLOv8n、YOLOv8s、YOLOv8l、YOLOv8m 和 YOLOv8x^[20]。根据实际需求可以选择不同的 YOLOv8

模型。随着深度的增加, 这些模型的检测精度逐渐提升^[21], 但参数量和检测速度随着精度的提高而降低^[22], YOLOv8n 是 YOLOv8 中最轻量的模型^[23-24]。因此, 本研究选择使用 YOLOv8n 版本进行改进, 以构建一种轻量化、低延迟、高精度且具备一定泛化能力的作物叶部病害检测模型。

1.4 环境配置与参数设置

本研究所有试验均在内存为 32G 的 64 位 Windows11、NVIDIA RTX3060 12GB GPU 下进行, 使用的 Python 版本为 3.8.18, CUDA 版本为 11.8, PyTorch 版本为 2.1.2, Torchvision 版本为 0.16.2。模型训练参数设置如表 2 所示。

表 2 模型训练参数设置

Table 2 Setting of training parameter

参数 Parameter	数值 Value	参数 Parameter	数值 Value
Epochs	300	Optimizer	SGD
Patience	30	Close_mosaic	10
Batch	16	Warmup_momentum	0.8
Workers	8	Weight_decay	0.0005
Lrf	0.05	Patience	50
ImgSz	640	Momentum	0.937

1.5 评价指标

本研究使用的病害识别模型评价指标包括召回率(recall, R)、精确度(precision, P)、 F_1 分数、平均精度均值(mean average precision, mAP, 公式中记作 P_{mA})、浮点运算次数(floating-point operations per second, FLOPs, 公式中记作 F)、参数量(parameters, 公式中记作 P_m)、帧率(frames per second, FPS, 公式中记作 F_{PS}) 等, 部分指标公式如下所示。

$$P = \frac{T_p}{T_p + F_p} \quad (1)$$

$$R = \frac{T_p}{T_p + F_N} \quad (2)$$

$$F_1 = \frac{2 \times P \times R}{P + R} \quad (3)$$

$$P_{mA} = \frac{\sum_{i=1}^n P_{Ai}}{n} \quad (4)$$

$$F = K^2 \times C_{in} \times C_{out} \times H_{out} \times W_{out} \quad (5)$$

$$P_m = K^2 \times C_{in} \times C_{out} + B \quad (6)$$

$$F_{PS} = \frac{1}{T_i} \quad (7)$$

式(1)~(7)中, T_p 为真实正样本, F_p 为虚假正样本, F_N 为虚假负样本, P_A 为平均精度, K 是卷积核的大小, C_{in} 是输入通道数, C_{out} 是输出通道数, H_{out} 是输出特征图的高度, W_{out} 是输出特征图的宽度, B 是偏

置项, T_1 是模型推理单个样本所需的时间(单位为 s)。

1.6 轻量化作物叶部病害检测模型改进

针对当前主流作物叶部病害检测模型体积庞大且泛用性缺乏验证等问题,本研究在YOLOv8n的基础上提出EMD-YOLO算法。主要在以下3个方面进行优化和改进。首先,为增强模型的特征提取和特征融合能力,引入多尺度空洞注意力机制(multi-scale dilated attention, DSMA)^[25]和EffectiveSE(effective squeeze and extraction)注意力机制^[26]。DSMA注意力机制负责在不同尺度上捕捉目标,EffectiveSE注意力机制负责在通道级别上精细地调整特征的重要性,两者结合能够更全面地提升模型对微小病变的识别能力。为在较大感受野中融合背景

信息,改善模型检测准确性,引入轻量动态上采样 DySample(dynamic sample)网络结构^[27],可在降低模型参数量和计算量的同时,更有效地保留病害特征细节。最后,使用 Wise-IoU (weighted interpolation of sequential evidence for intersection over union, WIoU) 损失函数^[28], Wise-IoU 将叶部病害图像的分类信息整合到 IoU(intersection over union) 计算中,通过结合叶部病害图像的分类信息和边界框回归,来帮助模型更准确地学习病害特征的位置和大小,从而提升网络模型的边界框回归性能,提升检测精度,达到降低计算成本、提高检测性能的目的。

改进后的EMD-YOLO网络模型结构如图2所示,改进部分以阴影加粗方式显示。

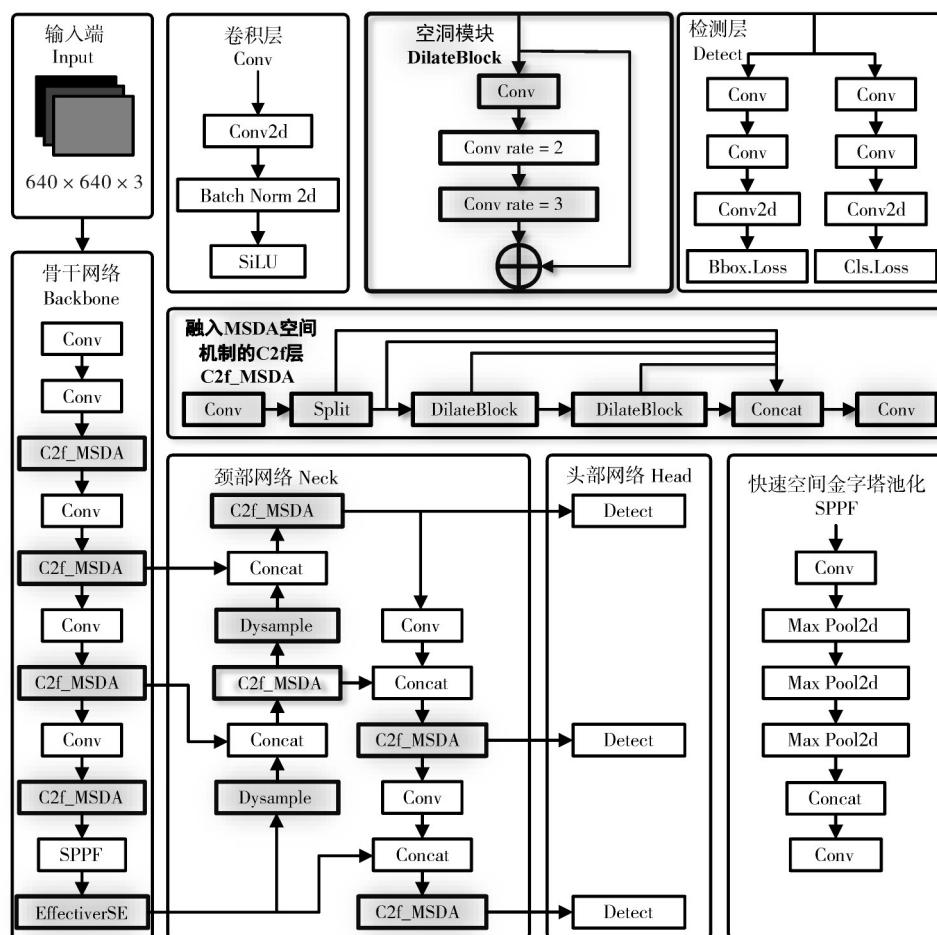


图2 EMD-YOLO模型结构

Fig. 2 Structure diagram of EMD-YOLO model

1.7 多尺度空洞注意力机制

多尺度空洞注意力(multi-scale dilated attention, MSDA)是一种创新神经网络机制,它能够通过结合多尺度和膨胀卷积技术来提升识别作物叶部病害的

性能。MSDA 在捕捉不同尺度的特征信息和长距离依赖关系方面表现优异。

MSDA核心思想是结合膨胀卷积和多尺度注意力机制。膨胀卷积为捕捉更多作物叶部病害图像的

上下文信息,在卷积核中引入了空洞原理,进而扩大感受野。多尺度注意力机制能够同时处理多个尺度的特征,能够确保网络在不同层次上捕捉到丰富的细节和全局信息。

为了更全面地理解和利用输入数据的特征,MS-DA 模块采用多头设计,不同的头部使用不同的扩张率,从而实现多尺度的特征聚合和语义信息捕获。它在特征图通道所划分的多个头部中使用多种空洞率来执行滑动窗口膨胀注意力(sliding window attention, SWDA)^[29]。其公式如下:

$$h_i = \text{SWDA}(Q_i, K_i, V_i, r_i), 1 \leq i \leq n \quad (8)$$

$$X = \text{Linear}(\text{Concat}[h_1, \dots, h_n]) \quad (9)$$

式(8)~(9)中, r_i 为膨胀率, Q_i, K_i 和 V_i 为特征图中获取的切片, 通常为 Query(查询)、Key(键)、Value(值)组成的矩阵, h_i 为滑动窗口膨胀操作后的特征值, X 为 h_i 通过特征聚合后的输出值, SWDA 为滑动膨胀操作, Linear 为特征聚合操作。

其中, 对于每个头部, 都会有一个独立的膨胀率 r_i 。从特征图中获取切片 Q_i, K_i 和 V_i , 执行 SWDA, 得到输出 h_i 。随后将所有头部的输出连接在一起, 通过一个线性层进行特征聚合。

模块在浅层使用所提出的多尺度空洞注意力, 在深层使用原始注意力机制。为了增强局部性和引入位置编码, 采用了CPE, 即深度可分离卷积。公式如下:

$$X = \text{CPE}(\hat{X}) + \hat{X} = \text{DwConc}(\hat{X}) + \hat{X} \quad (10)$$

$$Y = \begin{cases} \text{MSDA}(\text{Norm}(X)) + X, \text{low-level} \\ \text{MHSA}(\text{Norm}(X)) + X, \text{high-level} \end{cases} \quad (11)$$

$$Z = \text{MLP}(\text{NORM}(Y)) + Y \quad (12)$$

式(10)~(12)中, \hat{X} 为输入特征图(通常为前一层的输出或初始输入), \hat{Y} 为注意力加权后的特征图, Y 为残差和, Z 是全连接层堆叠操作后的输出, CPE 为用于引入位置编码或跨阶段特征交互的卷积操作, DwConc 为深度卷积与通道拼接的结合操作, MSDA 和 MHSA 为相应的注意力机制处理, Norm 为可选择的特征归一化操作, MLP 为全连接层堆叠操作, 用于特征非线性变换。

1.8 EffectiveSE 注意力机制

在模型改进中, 通过增强模型对叶部病害的特征提取和提高作物叶部病害图像的多尺度信息融合能力能够显著增强模型性能, 其中使用了 EffectiveSE 注意力机制, EffectiveSE 注意力机制是由

SENet^[30]简化并通过聚合策略和优化注意力机制进行改进而来。引入的 EffectiveSE 注意力机制, 具有简单的网络结构和更小的计算量, 能够帮助模型自适应地关注作物叶部病害的重要特征及其权重, 提升模型的识别率。EffectiveSE 注意力机制网络结构如图3所示。

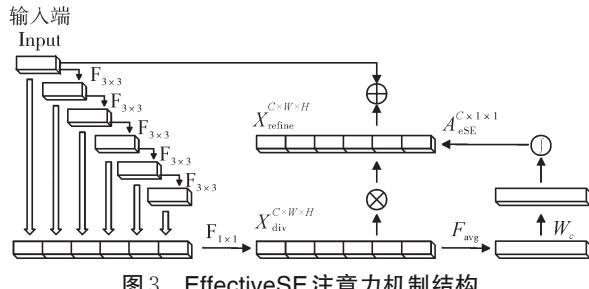


图3 EffectiveSE 注意力机制结构
Fig. 3 Structure diagram of the EffectiveSE attention mechanism

其中, 3×3 卷积提取输入的特征图 $F_{3 \times 3}$ 的特征, 再将提取的特征逐级进行整合, 1×1 卷积将 $F_{1 \times 1}$ 转化为多样化特征图 X_{div} 后进行全局平均池化 F_{avg} 。全连接层 W_c 计算通道的权重 X_{refine} , 然后输出 $A_{\text{eSE}}(X_{\text{div}})$, $A_{\text{eSE}}(X_{\text{div}})$ 的维度为 X_{refine} , 最后将得到注意力权重 $A_{\text{eSE}}(X_{\text{div}})$ 应用于原始多样化特征图 X_{div} 。公式如下, \otimes 表示元素级别的乘法, C, H, W 为通道数。

$$A_{\text{eSE}}(X_{\text{div}}) = \delta(W_c(F_{\text{avg}})(X_{\text{div}})) \quad (13)$$

$$X_{\text{refine}} = A_{\text{eSE}}(X_{\text{div}}) \otimes X_{\text{div}} \quad (14)$$

1.9 DySample 上采样

本研究使用的 DySample 上采样是一种动态上采样方法, 旨在通过自适应地调整上采样过程中的权重和位置, 提高图像目标识别任务中的上采样效果^[31]。该方法通过动态调整采样位置和权重, 与传统固定位置采样方法(如双线性插值或反卷积)相比, 能够更精确地恢复高分辨率特征图。

DySample 上采样绕过了基于内核的动态上采样器(如CARAFE、FADE 和 SAPA)所需的大量资源占用, 而使用PyTorch 中标准内置函数实现, 使其具有更少的参数量而减少 GPU 内存的使用^[32]。

在语义分割、目标检测、实例分割、全视分割和单目深度估计上, DySample 上采样器都显示出优于其他上采样器的性能^[33]。DySample 通过增强特征图的细节和边缘信息, 从而提升模型的整体性能。

1.10 WiseIoU 损失函数

在作物叶部病害中, 多数叶部病害为细微的病

斑,因此小目标病害检测是作物叶部病害检测任务的关键。而YOLOv8采用的CIoU损失函数计算复杂,涉及边界框距离、重叠区域和纵横比等参数,导致目标检测训练中计算成本高。尤其是当训练数据中含有较多低质量样本时,距离和纵横比等几何因素会增加算法误差,从而降低算法的泛化能力,导致训练不稳定^[34]。

因此,本研究引入Wise-IoU(WIoU)函数替代CIoU函数,Wise-IoU函数可以减弱几何因素的影响,提高模型的泛化能力,从而解决CIoU的一些不足之处。同时,Wise-IoU函数结合了注意力机制和梯度增益的思想,能够更好地优化目标检测模型的训练过程。CIoU的计算公式如下:

$$L_{\text{CIoU}} = 1 - \text{IoU} + \frac{\rho^2(b^A, b^B)}{c^2} + \alpha v \quad (15)$$

式(15)中, b^A 和 b^B 分别表示预测框和真实框的中心点, ρ 表示两点之间的欧式距离, c 表示预测框和真实框的最小外接矩形的对角线长度; α 为平衡参数; v 用于计算预测框和目标框高宽比的相合性。

Wise-IoU通过构造梯度增益来附加聚焦机制,以防止距离和纵横比等几何因素对模型产生过度惩罚,其计算公式如下:

$$L_{\text{WIoU}} = rR_{\text{WIoU}}L_{\text{IoU}}, r = \frac{\beta}{\delta\alpha^{\beta-\delta}} \quad (16)$$

$$\beta = \frac{L_{\text{IoU}}^*}{\overline{L}_{\text{IoU}}} \in [0, +\infty) \quad (17)$$

$$R_{\text{WIoU}} = \exp\left(\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 - H_g^2)^*}\right) \quad (18)$$

式(16)~(18)中, $L_{\text{IoU}} \in [0, 1]$ 表示预测框与真实框的重叠程度, R_{WIoU} 为惩罚项,*表示 W_g 和 H_g 从计算图中分离, $\left(\frac{L_{\text{IoU}}^*}{\overline{L}_{\text{IoU}}}\right)^\gamma$ 为梯度增益 r , L_{IoU}^* 为单调聚焦系数, $\overline{L}_{\text{IoU}}$ 表示具有动量 m 的滑动平均值, $\gamma > 0$ 。当 $\beta = \delta$ 时,梯度增益 $r = 1$ 。

在定位框与目标框重合较好时,Wise-IoU可显著减少其对中心点距离的注意。若发现较低的锚框离群度,则说明其质量较高,Wise-IoU分配小的梯度增益。若锚框是高离群度,则说明其质量较低,Wise-IoU分配较小的梯度增益。因此, R_{WIoU} 可以显著增强普通质量锚框的 L_{IoU} ;而 L_{IoU} 可以显著降低高质量锚框的 R_{WIoU} 。因此,Wise-IoU能有效减少低质量样本产生有害梯度的概率,从而提高模型的泛化能力。

2 结果与分析

2.1 数据增强评估

为确定镜像和缩放增强对模型性能的影响,利用4种数据组合(无增强、镜像增强、缩放增强、镜像与缩放组合增强),采用控制变量法使用基线模型YOLOv8n进行分析。由表3可知,镜像增强和缩放增强均能提升模型性能;两者结合使用,性能提升最为显著,精确度和mAP@0.5分别达到93.3%和89.2%(表3),表明数据增强对模型优化的积极影响。

表3 数据增强效果评估

Table 3 Data augmentation evaluation %				
镜像增强 Mirror	缩放增强 Scale	精确度 Precision	召回率 Recall	mAP@0.5
×	×	90.5	82.8	86.3
√	×	92.1	83.1	88.1
×	√	91.7	81.7	87.3
√	√	93.3	82.8	89.2

2.2 模型训练与测试

将基线模型YOLOv8n与改进的EMD-YOLO模型在相同试验设置下、相同植物病害检测任务中进行性能对比。由图4可知,EMD-YOLO模型在4项评价指标上都优于YOLOv8n。由表4可知,EMD-YOLO对花生焦斑病、早斑病和网斑病的mAP@0.5分别为98.9%、92.6%和96.9%,显著优于YOLOv8n的97.7%、88.9%和90.1%。尽管在玉米锈病的检测上,EMD-YOLO的mAP@0.5与基线模型相比无明显差异,但玉米大斑病的检出率有显著提升,mAP@0.5检出率从94.7%提升至98.8%。此外,虽然EMD-YOLO对番茄晚疫病的检测效果略差,但其mAP@0.5仍提升3.6个百分点,对番茄早疫病和霜霉病mAP@0.5的检测效果分别提升至94.5%和86.4%。

总体而言,EMD-YOLO的mAP@0.5达到92.8%,超过了基线模型的89.2%,并且mAP@0.5:0.95也有所提升,从60.1%增加到61.9%,试验结果验证了EMD-YOLO的优越性。

2.3 消融实验

本研究通过消融实验评估MSDA注意力机制、EffectiveSE注意力机制、DySample上采样和Wise-IoU损失函数的协同优化效果。由表5可知,单独使用MSDA模块时,检测精确度提升较大,增加1.3个百分点,检测帧率达到113帧/s,且浮点运算数、参数量

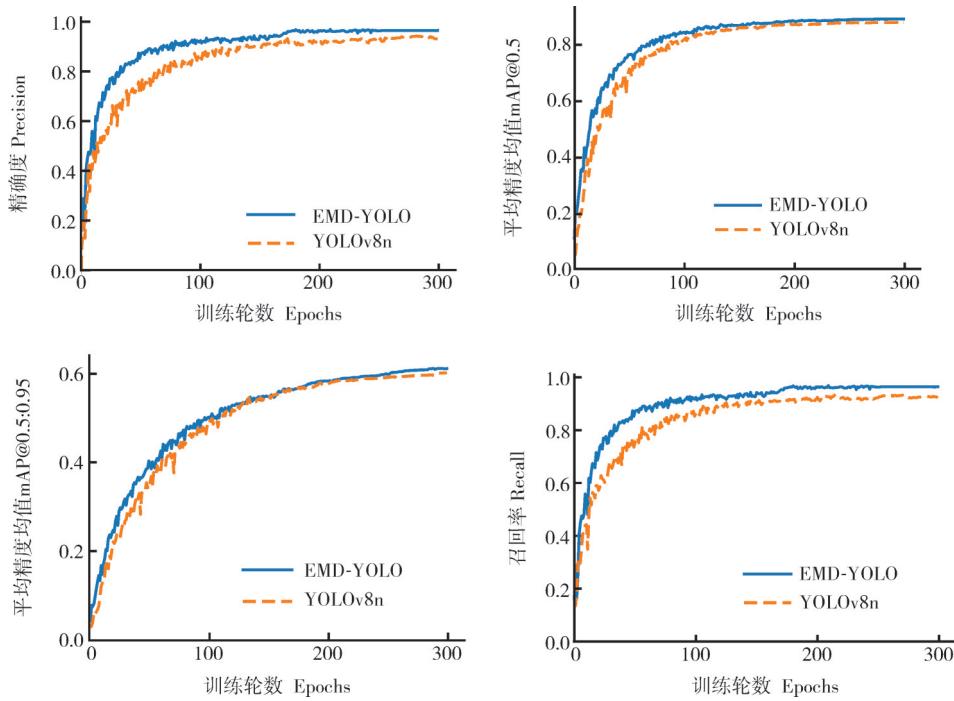


图4 模型评价指标对比

Fig. 4 Comparison of EMD-YOLO and baseline models

表4 EMD-YOLO与基线模型对比

Table 4 Comparison of EMD-YOLO and baseline models

病害 Disease	mAP@0.5 %				mAP@0.5:0.95 YOLOv8n EMD-YOLO
	YOLOv8n	EMD-YOLO	YOLOv8n	EMD-YOLO	
花生焦斑病 Peanut leaf scorch	97.7	98.9	62.4	64.6	
花生早斑病 Peanut early spot	88.9	92.6	43.3	48.8	
花生网斑病 Peanut web blotch	90.1	96.9	47.6	49.7	
玉米锈病 Corn rust	95.2	94.9	75.3	75.4	
玉米大斑病 Corn leaf blight	94.7	98.8	70.6	70.8	
番茄早疫病 Tomato early blight	89.6	94.5	59.5	61.8	
番茄晚疫病 Tomato late blight	75.9	79.5	55.7	55.6	
番茄霜霉病 Tomato leaf mold	81.4	86.4	66.3	68.7	
所有病害 Total	89.2	92.8	60.1	61.9	

和模型权重有一定的降低。单独使用 EffectiveSE 模块时,模型召回率稍降,但 mAP@0.5 提升较大,增加 1.2 百分点。在单独使用 DySample 上采样和 Wise-IoU 损失函数时,模型均表现出一定优势。四者协同作用下,模型较 YOLOv8n 基线网络模型,精确度、召回率和 mAP@0.5 分别提高了 3.0、4.3、3.6 百分点,帧率提高 15 帧/s,且模型的浮点计算数、参数量和模型权重分别下降了 1.4×10^9 、 0.8×10^6 和 1.4 MB。结果表明,改进模块不仅增强了模型的识别能力,还优化了其运行效率与资源占用。

2.4 模型对比试验

为验证 EMD-YOLO 算法的优越性,选取 mAP@0.5、 F_1 分数、浮点计算数(FLOPs)、参数量(parameters)、模型权重(model size)和在 NVIDIA RTX3060 上的检测帧率(FPS)作为评价指标,在相同试验条件下,将 EMD-YOLO 模型与 7 种模型进行对比试验。由表 6 可知,EMD-YOLO 在所有模型中获得最高的 mAP@0.5 和 F_1 分数,较 Faster R-CNN、YOLOv5s、YOLOv5n、YOLOv7、RT-DETR-L、YOLOv8n 和 YOLOv8s 的 mAP@0.5 分别高出 36.6、5.3、7.5、6.0、6.9、3.6、1.5 百分点;较 Faster R-CNN、YOLOv5s、YOLOv5n、YOLOv7、RT-DETR-L、YOLOv8n 和 YOLOv8s 的 F_1 分数分别高出 38.8、9.0、13.4、13.5、12.1、3.5、1.3 百分点。同时在实时性上,EMD-YOLO 仍比 FPS 最高的 YOLOv8n 增加 15 帧/s,比改进前检测效果最好的 YOLOv8s 高出 41 帧/s。以上结果表明,本研究提出的 EMD-YOLO 算法在参数量、模型权重、 F_1 分数、mAP@0.5、检测速度方面均得到提升。

2.5 算法验证

为了验证改进的 EMD-YOLO 模型在实际应用中的有效性,选用改进的 EMD-YOLO 模型与基线 YOLOv8n 模型在相同的试验环境下进行对比试验。由图 5 可知,改进的 EMD-YOLO 模型的识别精度得

表5 消融实验

Table 5 Ablation experiment

MSDA 注意力机制	EffectiveSE 注意力机制	DySample 上采样	损失函数 Wise-IoU	精确度/% Precision	召回率/% Recall	mAP @0.5/%	浮点运算数 FLOPs	参数量 Parameters	模型权重/MB Model size	帧率/(帧/s) FPS
×	×	×	×	93.3	82.8	89.2	8.1×10^9	3.2×10^6	6.3	87
√	×	×	×	94.6	83.1	89.3	6.6×10^9	2.2×10^6	4.7	113
×	√	×	×	94.2	81.7	90.4	8.3×10^9	3.3×10^6	6.4	78
×	×	√	×	93.6	83.4	89.3	8.1×10^9	3.2×10^6	6.3	86
×	×	×	√	93.4	82.9	89.5	8.1×10^9	3.2×10^6	6.3	87
√	√	×	×	95.1	83.6	90.7	6.7×10^9	2.3×10^6	4.8	105
×	×	√	√	93.9	83.5	89.7	8.1×10^9	3.2×10^6	6.3	87
√	√	√	×	95.7	84.5	90.9	6.7×10^9	2.3×10^6	4.9	101
√	√	×	√	95.3	83.9	90.6	6.7×10^9	2.3×10^6	4.9	98
√	√	√	√	96.3	87.1	92.8	6.7×10^9	2.4×10^6	4.9	102

表6 EMD-YOLO与7种模型的试验对比

Table 6 Comparison table of EMD-YOLO with various models

模型 Models	mAP@0.5/%	F ₁ 分数/% F ₁ score	浮点运算数 FLOPs	参数量 Parameters	模型权重/MB Model size	帧率/(帧/秒) FPS
Faster R-CNN	56.2	52.8	386.3×10^9	41.4×10^6	97.7	17
YOLOv5s	87.5	82.6	16.0×10^9	8.1×10^6	14.5	69
YOLOv5n	85.3	78.2	7.2×10^9	4.2×10^6	8.6	73
YOLOv7	86.8	78.1	105.2×10^9	36.9×10^6	74.9	65
RT-DETR-L	85.9	79.5	16.8×10^9	5.8×10^6	18.7	24
YOLOv8n	89.2	88.1	8.1×10^9	3.2×10^6	6.3	87
YOLOv8s	91.3	90.3	28.7×10^9	11.1×10^6	22.5	61
EMD-YOLO	92.8	91.6	6.7×10^9	2.4×10^6	4.85	102

到显著提升,能够识别出基线模型未能检测到的特征不明显的目标,结合参数量、模型权重以及检测帧率的优化可看出,EMD-YOLO是一个具有高精度、低时延的轻量化叶部病害检测模型。

2.6 泛化性验证

为评估改进后的EMD-YOLO模型在不同任务中的泛化性,选择了New Plant Diseases Dataset^[35]这一公开数据集进行泛化性验证,通过Labelimg进行标注,该数据集提供了38类作物病害图像。将改进后的EMD-YOLO模型与基线模型YOLOv8n进行统一变量试验。由表7可知,改进后的EMD-YOLO模型在精准度、召回率和mAP@0.5指标上分别提升了6.4、5.6、4.5个百分点,整体性能提升显著。此外,EMD-YOLO模型在保持较高检测精度的同时,检测帧率达到104帧/s,略高于原模型。以上结果表明,EMD-YOLO模型在不同的检测任务中依旧具备良好的鲁棒性和泛化性。

3 讨论

作物叶部病害检测在现代农业生产中具有重要

意义,但同时也极具挑战性,面临作物种类繁多、病斑大小和形态各异,以及田间环境的多样性等诸多不利因素。尽管已有研究在单一作物病害检测方面取得显著进展,但大多数方法难以直接应用于多作物、多病害的复杂场景。本研究提出的EMD-YOLO模型通过引入多尺度空洞注意力机制(MSDA)、EffectiveSE注意力机制、DySample上采样和Wise-IoU损失函数,在多种作物叶部病害检测中显现了高效、轻量化且具有较高精度的检测能力。

将C2f结构替换为C2f_MSDA后,模型mAP@0.5提升至89.3%,权重降低1.6 MB。MSDA与EffectiveSE结合使用时,先通过MSDA扩大感受野,再由EffectiveSE优化细节特征关注,使mAP@0.5进一步提高至90.7%,模型权重保持稳定。DySample上采样和Wise-IoU损失函数具有互补的边界优化与信息增强能力。因此,模型融入4项改进后,模型性能实现了全面的提升,mAP@0.5最终达到92.8%,模型表现出更好的鲁棒性,且模型权重仅为4.9 MB,相较于基线模型降低1.4 MB,实现了轻量化设计,适合在资源受限的移动端进行部署。此外,检测帧率达到

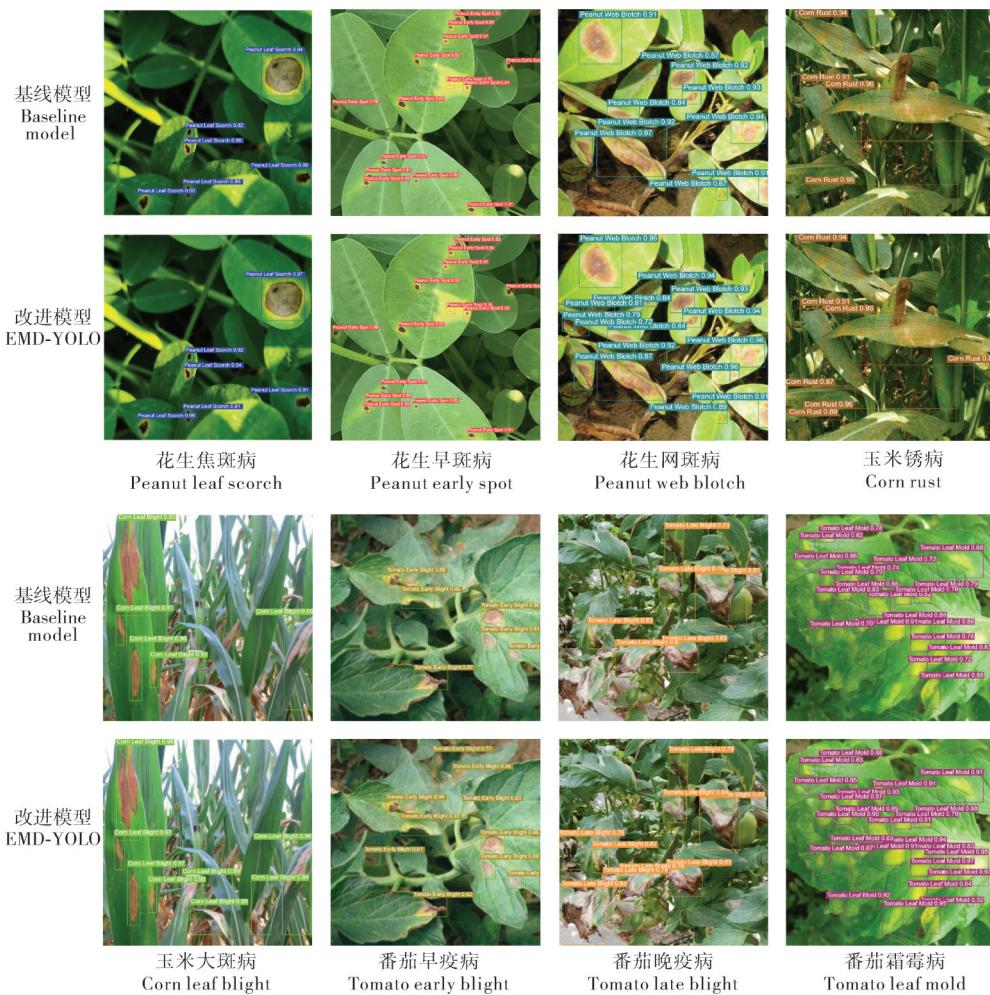


图5 不同模型对作物叶部病害的识别效果

Fig. 5 Recognition effects of different models on crop leaf diseases

表7 泛化实验

Table 7 Generalization experiment

模型 Models	精确度/% Precision	召回率/% Recall	mAP@0.5/%	帧率/(帧/s) FPS
YOLOv8n	87.6	80.3	86.2	83
EMD-YOLO	93.2	85.9	90.7	104

102帧/s,确保了高效实时处理,实现了最佳检测精度和最快检测速度。同时,EMD-YOLO模型展现了较好的泛用性,无论是在花生叶片,还是玉米和番茄叶片上均能保持出色的病害检测效果。

然而,尽管引入了多种优化机制,模型在面对特征高度相似的病害类型时仍可能出现误判,尤其是在小样本情况下。未来的研究将扩展样本库,以涵盖更多作物种类和病害类型,从而进一步增强模型的泛化能力,并优化模型的特征区分能力,探索更高效的特征提取机制,以减少对相似病害的误判。通过这些改进,EMD-YOLO有望在实际农业生产中实

现更广泛的应用,为作物病害的精准防控提供有力支持。

参考文献 References

- [1] ORCHI H, SADIK M, KHALDOUN M, et al. Automation of crop disease detection through conventional machine learning and deep transfer learning approaches [J/OL]. Agriculture, 2023, 13(2):352[2024-11-28].https://doi.org/10.3390/agriculture13020352.
- [2] 郑果,姜玉松.基于多任务学习农作物叶片病害诊断方法[J].中国农业科技导报,2024,26(1):89-98. ZHENG G, JIANG Y S. Diagnosis of crop disease based on multi-task learning[J]. Journal of agricultural science and technology, 2024, 26 (1): 89-98 (in Chinese with English abstract).
- [3] 彭玉寒,李书琴.基于重参数化 MobileNetV2 的农作物叶片病害识别模型[J].农业工程学报,2023,39(17):132-140. PENG Y H, LI S Q. Recognizing crop leaf diseases using reparameterized MobileNetV2 [J]. Transactions of the CSAE, 2023,39(17):132-140 (in Chinese with English abstract).

- [4] ROSSI L, KARIMI A, PRATI A. Self-balanced R-CNN for instance segmentation [J/OL]. Journal of visual communication and image representation, 2022, 87: 103595 [2024-11-28]. <https://doi.org/10.1016/j.jvcir.2022.103595>.
- [5] ULLAH A, XIE H M, FAROOQ M O, et al. Pedestrian detection in infrared images using fast RCNN[C]//2018 Eighth International Conference on Image Processing Theory, Tools and Applications (IPTA). November 7-10, 2018, Xi'an, China. Xi'an: IEEE, 2018: 1-6.
- [6] LIU Y J, ZHOU S J, LIU X Y, et al. Unbiased faster R-CNN for single-source domain generalized object detection [C]// 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). June 16-22, 2024, Seattle, WA, USA. Seattle: IEEE, 2024: 28838-28847.
- [7] 姜晟,曹亚莉,刘梓伊,等.基于改进 Faster RCNN 的茶叶叶部病害识别[J].华中农业大学学报,2024,43(5):41-50.JIANG S, CAO Y P, LIU Z Y, et al. Recognition of tea leaf disease based on improved Faster RCNN [J]. Journal of Huazhong Agricultural University, 2024, 43(5):41-50 (in Chinese with English abstract).
- [8] WANG L H, SHI W P, TANG Y H, et al. Transfer learning-based lightweight SSD model for detection of pests in *Citrus* [J/OL]. Agronomy, 2023, 13(7): 1710 [2024-11-28]. <https://doi.org/10.3390/agronomy13071710>.
- [9] ZHU X H, WANG R R, SHI W, et al. Detection of pine-wilt-disease-affected trees based on improved YOLOv7 [J/OL]. Forests, 2024, 15 (4) : 691 [2024-11-28]. <https://doi.org/10.3390/f15040691>.
- [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] 龙阳,肖小玲.基于多注意力机制的苹果叶部病害检测方法[J].江苏农业科学,2023,51(23):178-186.LONG Y, XIAO X L. Apple leaf disease recognition method based on multi-attention mechanism [J]. Jiangsu agricultural sciences, 2023, 51 (23):178-186 (in Chinese with English abstract).
- [12] 刘春菊,刘延鑫,李斐,等.基于 YOLOv5 的烟草叶部病害智能识别[J].中国烟草科学,2024,45(3):93-101.LIU C J, LIU Y X, LI F, et al. Intelligent recognition of tobacco leaf diseases based on YOLOv5[J]. Chinese tobacco science, 2024, 45 (3):93-101 (in Chinese with English abstract).
- [13] 张一帆,张梅,陈杰.基于改进 YOLOv7 的果蔬叶片病害检测算法[J].兰州工业学院学报,2024,31(4):48-53.ZHANG Y F, ZHANG M, CHEN J. Algorithm for detecting fruit and vegetable leaf diseases based on improved YOLOv7[J]. Journal of Lanzhou Institute of Technology, 2024, 31(4):48-53 (in Chinese with English abstract).
- [14] 庞超,王传安,苏煜,等.基于改进 YOLOv8n 的水稻病害检测方法[J].内蒙古农业大学学报(自然科学版),2024,45(2):62-68.PANG C, WANG C A, SU Y, et al. Rice disease detection method based on improved YOLOv8n[J]. Journal of Inner Mongolia Agricultural University (natural science edition), 2024, 45(2):62-68 (in Chinese with English abstract).
- [15] ZHANG L J, DING G C, LI C R, et al. DCF-YOLOv8: an improved algorithm for aggregating low-level features to detect agricultural pests and diseases [J/OL]. Agronomy, 2023, 13 (8) : 2012 [2024-11-28]. <https://doi.org/10.3390/agronomy13082012>.
- [16] KAGGLE. Tomato [DB/OL]. [2024-11-28]. <https://www.kaggle.com/datasets/noulam/tomato>.
- [17] KAGGLE. Corn or maize leaf disease dataset [DB/OL]. [2024-11-28]. <https://www.kaggle.com/datasets/smaranjitgohose/corn-or-maize-leaf-disease-dataset>.
- [18] 左昊轩,黄祺成,杨佳昊,等.基于双目视觉和改进 YOLOv8 的玉米茎秆宽度原位识别方法[J].智慧农业,2023,5(3):86-95.ZUO H X, HUANG Q C, YANG J H, et al. In situ identification method of maize stalk width based on binocular vision and improved YOLOv8 [J]. Smart agriculture, 2023, 5 (3):86-95 (in Chinese with English abstract).
- [19] YUE X, QI K, NA X Y, et al. Improved YOLOv8-seg network for instance segmentation of healthy and diseased tomato plants in the growth stage [J/OL]. Agriculture, 2023, 13 (8) : 1643 [2024-11-28]. <https://doi.org/10.3390/agriculture13081643>.
- [20] 孙向阳,杨晓霞.GSW-YOLOv7:一种基于改进 YOLOv7 的玉米叶病害检测方法[J].山东农业大学学报(自然科学版),2024, 55 (4) : 566-578.SUN X Y, YANG X X. GSW-YOLOv7: a maize leaf disease detection method based on improved YOLOv7[J]. Journal of Shandong Agricultural University (natural science edition), 2024, 55(4): 566-578 (in Chinese with English abstract).
- [21] LIU S, QIL, QIN H F, 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. Salt Lake City : IEEE, 2018 : 8759-8768.
- [22] WANG X W, LIU J. Vegetable disease detection using an improved YOLOv8 algorithm in the greenhouse plant environment [J/OL]. Scientific reports, 2024, 14: 4261 [2024-11-28]. <https://doi.org/10.1038/s41598-024-54540-9>.
- [23] 岳凯,张鹏超,王磊,等.基于改进 YOLOv8n 的复杂环境下柑橘识别[J].农业工程学报,2024,40(8):152-158.YUE K, ZHANG P C, WANG L, et al. Recognizing citrus in complex environment using improved YOLOv8n [J]. Transactions of the CSAE, 2024, 40(8):152-158 (in Chinese with English abstract).
- [24] 王帅,刘珊珊,李保田,等.基于改进 YOLOv8s 的织物疵点检测[J].棉纺织技术,2025,53(2): 49-55.WANG S, LIU S, LI B T, et al. Fabric defect detection based on improved YOLOv8s[J]. Cotton textile technology, 2025, 53(2) : 49-55 (in Chinese with English abstract).
- [25] JIAO J Y, TANG Y M, LIN K Y, et al. DilateFormer: multi-scale dilated transformer for visual recognition [DB/OL]. arX-

- iv, 2023: 2302.01791 [2024-11-28]. <https://arxiv.org/abs/2302.01791v1>.
- [26] LEE Y, PARK J. CenterMask: real-time anchor-free instance segmentation [DB/OL]. arXiv, 2019: 1911.06667 [2024-11-28].<https://arxiv.org/abs/1911.06667v6>.
- [27] LIU W Z, LU H, FU H T, et al. Learning to upsample by learning to sample [DB/OL]. arXiv, 2023: 2308.15085 [2024-11-28].<https://arxiv.org/abs/2308.15085v1>.
- [28] TONG Z J, CHEN Y H, XU Z W, et al. Wise-IoU: bounding box regression loss with dynamic focusing mechanism [DB/OL]. arXiv, 2023: 2301.10051 [2024-11-28]. <https://arxiv.org/abs/2301.10051v3>.
- [29] SAITO K, USHIKU Y, HARADA T, et al. Strong-weak distribution alignment for adaptive object detection [DB/OL]. arXiv, 2018: 1812.04798 [2024-11-28].<https://arxiv.org/abs/1812.04798v3>.
- [30] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks [DB/OL]. arXiv, 2017: 1709.01507 [2024-11-28].
- iv, 2023: 2302.01791 [2024-11-28]. <https://arxiv.org/abs/1709.01507v4>.
- [31] WANG J Q, CHEN K, XU R, et al. CARAFE: content-aware ReAssembly of FEatures [DB/OL]. arXiv, 2019: 1905.02188 [2024-11-28].<https://arxiv.org/abs/1905.02188v3>.
- [32] LU H, LIU W Z, FU H T, et al. FADE: fusing the assets of decoder and encoder for task-agnostic upsampling [DB/OL]. arXiv, 2022: 2207.10392 [2024-11-28].<https://arxiv.org/abs/2207.10392v2>.
- [33] LU H, LIU W Z, YE Z X, et al. SAPA: similarity-aware point affiliation for feature upsampling [DB/OL]. arXiv, 2022: 2209.12866 [2024-11-28]. <https://arxiv.org/abs/2209.12866v2>.
- [34] ZHANG Y F, REN W Q, ZHANG Z, et al. Focal and efficient IoU loss for accurate bounding box regression [J]. Neurocomputing, 2022, 506: 146-157.
- [35] KAGGLE. New Plant Diseases Dataset [DB/OL]. [2024-11-28]. <https://www.kaggle.com/datasets/vipoooool/new-plant-diseases-dataset>.

EMD-YOLO: an improved lightweight algorithm for detecting diseases in crop leaf based on YOLOv8n

WANG Binbing, ZHANG Yali, ZHENG Guang, SHI Lei, YIN Fei

College of Information & Management Sciences, Henan Agricultural University, Zhengzhou 450046, China

Abstract A novel lightweight algorithm for detecting diseases in crop leaf based on YOLOv8n, EMD-YOLO was proposed to accurately and rapidly identify diseases, reduce costs of manual diagnosis, and minimize the impact of leaf diseases on the production and quality of crops. The algorithm integrated the multi-scale dilated attention (MSDA), EffectiveSE attention mechanism, DySample upsampling, and Wise-IoU loss function. MSDA was combined with multi-scale spatial convolution and attention mechanisms to increase the efficiency of extracting multi-scale feature, while EffectiveSE strengthened the selection of feature and improved the representation performance of model. DySample upsampling preserved important features to enhance the map resolution of feature and the detection performance. Wise-IoU loss function optimized intersection over union (IoU) computation to improve the localization accuracy of model. The results showed that the accuracy, mAP@0.5, and weight of EMD-YOLO was 96.3%, 92.8%, and 4.85 MB, respectively. The accuracy and mAP@0.5 of YOLOv8n increased by 3.0 and 3.6 percentage points compared with that of the baseline model YOLOv8n, respectively, while the weight decreased by 1.4 MB. It is indicated that EMD-YOLO has good generalization and is suitable for detecting diseases in crop leaf with mobile devices.

Keywords deep learning; diseases in crop leaf; YOLOv8; EffectiveSE attention mechanism; multi-scale dilated attention (MSDA); lightweight algorithm

(责任编辑:葛晓霞)