

李亚,蒋晨,王海瑞,等.基于EDW-YOLOv8的棉花叶片病害检测[J].华中农业大学学报,2025,44(5):189-197.
DOI:10.13300/j.cnki.hnlkxb.2025.05.019

基于EDW-YOLOv8的棉花叶片病害检测

李亚¹,蒋晨¹,王海瑞¹,朱贵富²,胡灿¹

1. 昆明理工大学信息工程与自动化学院,昆明 650504;
2. 昆明理工大学信息化建设管理中心/昆明理工大学-曙光信息产业股份有限公司 AI联合研究中心,昆明 650504

摘要 为解决复杂自然环境背景下棉花叶片病害检测准确率低的问题,提出一种基于改进YOLOv8n的棉花叶片病害检测模型。首先在YOLOv8n的骨干网络处加入EMA注意力机制,同时在骨干网络中的C2f模块中加入可变形卷积Deformable ConvNets v2模块,扩大感受野以加强特征提取能力。在此基础上,将损失函数CIoU替换为具有动态聚焦机制的边界框回归损失WIoU,以加快模型收敛速度,进一步提升模型性能。试验结果显示,改进后的EDW-YOLOv8模型准确率、召回率和平均精度相较于YOLOv8n分别提升了4.3、7.5和4.6个百分点。结果表明,研究所提出的模型具有良好的泛化性,可以准确高效地检测出图像中棉花叶片病害目标。

关键词 棉花叶片病害; YOLOv8; 注意力机制; 可变形卷积; 损失函数

中图分类号 TP391.4; S24 **文献标识码** A **文章编号** 1000-2421(2025)05-0189-09

棉花作为重要的经济作物之一,在全球范围内广泛种植。然而,在棉花的生长过程中常会遭受到各种病害的侵袭,这不仅严重影响了棉花的产量和品质,还增加了生产成本和农药使用量,对环境造成负面影响。早期的棉花病害检测主要是依靠有经验的棉花病害专家通过对比棉花叶片的感官认识来判定,而单纯依靠人工判定病害的方式耗时费力,很难确保检验结果的一致性^[1],并且存在识别效率低,易产生判断失误等问题。随着科技的不断发展,各类技术手段层出不穷,为农作物病害检测开辟了更多新的途径和方法。

近年来,深度学习技术发展迅速,其模型具有强大的特征提取能力,能够自动学习和提取数据中的高级抽象特征,无需手动设计特征工程,适用于处理复杂的农业数据。同时,深度学习模型具有较强的泛化能力,能够适应不同类型的农业数据,对于复杂多变的农业场景具有较好的适应性。当前基于深度学习技术在农业领域的应用主要体现在植物识别与检测^[2]、病虫害诊断与识别^[3]、遥感区域分类与监测^[4]、果实在体检测与产品分级^[5]、动物识别与姿态检测^[6]5个方向。随着目标检测算法的不断迭代更

新,越来越多的国内外学者将深度学习技术应用到病虫害检测与识别的应用中。他们通过改进和优化YOLO系列模型结构,融合不同的骨干网络(如ConvNeXtV2^[7]、MobileNetv3^[8]、Swin Transformer^[9]等),有效提升了模型检测的精度和速度。在复杂的自然环境背景下,这些改进的模型在多种农作物的病虫害识别中表现出优异的性能,为农业病虫害监测与防治提供了有力的技术支持,例如,YOLO系列的目标检测模型在荔枝^[10]、番茄^[11]、黄瓜^[12]等作物的病虫害检测识别中取得了重大的应用。但却很少有学者将该类模型应用到棉花叶片病害检测的场景中。因此,本研究以棉花叶片病害为研究对象,利用YOLOv8n模型,通过在模型中添加注意力机制和可变形卷积模块,有效克服图像中环境背景带来的干扰,更加聚焦目标特征,从而实现对目标病害的准确高效检测。

1 材料与方法

1.1 数据集

本研究从加利福尼亚大学欧文分校维护的机器学习存储库中选取Cotton-Plant-Disease数据集,如

收稿日期: 2024-05-21

基金项目: 国家自然科学基金项目(61863016)

李亚, E-mail: 59515091@qq.com

通信作者: 朱贵富, E-mail: zhuguifu@kust.edu.cn

图1所示。该数据集中共包含6种棉花叶片病害,分别是轮纹斑病(alternaria leaf spot)、曲叶病(curl leaves)、红叶斑病(red spot)、细菌性枯萎病(bacterial blight)、枯萎病(foliar disease)和白斑病(herbicide)。数据集考虑到了自然环境背景的复杂性和病害之间的异质性,在图像拍摄中选择了不同的拍摄角度,光线和拍摄距离等因素,增强目标数据的多样性。该数据集中共包含5 000张图片。



图1 棉花病害图像

Fig.1 Images of cotton pests and diseases

使用LabelImg软件对上述5 000张棉花叶片病害图像进行目标标注。在标注过程中,详细记录了6类不同病害的类别和其具体位置信息。标注完成后,将所有信息保存为txt格式文件。随后,将数据集按照4:1的比例划分为训练集和测试集,其中训练集包含4 000张图像,测试集包含1 000张图像。最终,成功构建了一个可用于模型训练和验证的完整数据集。

1.2 棉花叶片病害检测方法

1) YOLOv8网络模型。YOLOv8网络模型是Ultralytics公司于2023年发布的一款全新开源模型,能够同时完成图像分类、目标检测以及实例分割等多种任务。YOLOv8不仅保留了之前模型的优势,还在功能和性能上做出了显著的提升和创新。

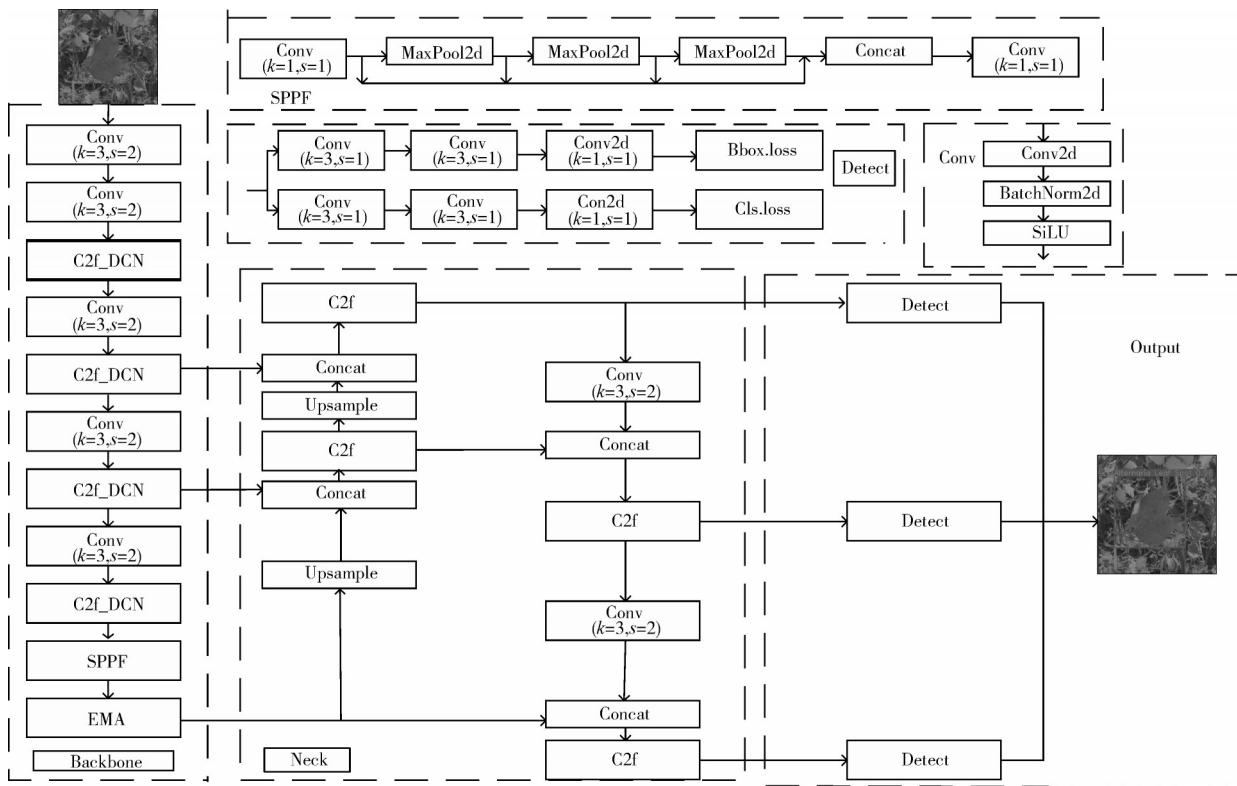
YOLOv8网络结构包括3个部分:主干网络(Backbone)、颈部网络(Neck)和头部网络(Head)。在骨干网络和颈部网络设计中,借鉴了YOLOv7中ELAN结构的理念,将YOLOv5中的C3模块升级为包含更多梯度信息的C2f模块,针对不同尺度模型调整了不同的通道数,进一步优化性能。Neck部分引入PAN结构,通过聚合不同层级的特征图,整合多尺

度信息,从而优化检测性能。在Head部分,与YOLOv5相比换成了解耦头结构(DeCouple-head),将特征提取和目标检测分开,从而提高模型性能和效率。这种结构有助于更好地捕获目标特征,提高了模型检测的准确性和速度。YOLOv8n网络是YOLOv8中参数量和计算量最小的网络,考虑到计算机硬件资源的限制,本研究提出的模型将在YOLOv8n的基础上进行改进。

2) 网络模型的改进。本研究改进后的EDW-YOLOv8模型结构如图2所示,在骨干网络SPPF下加入跨空间学习的高效多尺度注意力模块(EMA);在骨干网络C2f模块中加入可变形卷积网络(Deformable ConvNets v2);替换损失函数CIoU为WIoU(具有动态聚焦机制的边界盒回归损失),有效地提高模型检测精度,减少漏检和错检。

3) EMA注意力机制。在棉花叶片病害检测识别的场景中,光照变化的问题可能会导致图片亮度不均匀,影响目标和周围背景的对比度,从而影响网络识别。此外,各类病害在形态、边缘轮廓、颜色和大小等方面也存在差异。这些差异增加了模型学习和识别的复杂性,导致网络在训练时难以全面地捕捉所有特征,从而降低了检测的准确性。同时,周围背景环境中引入了大量的噪声和干扰,使得目标难以从背景中被准确分离出来。注意力机制的核心思想是通过突出重要特征、抑制无关信息,帮助模型聚焦图像关键区域。在病害检测中,引入注意力机制可以帮助模型更好地区分病害目标和背景元素,提高检测的准确性。

EMA注意力机制是在2023年提出的一种跨空间学习的高效多尺度注意力模型。该模型将部分通道维度重新整形为批量维度,避免通过通用卷积进行某种形式的降维。同时,它将通道维度分组为多个子特征,确保空间语义特征在每个子特征组中均匀分布。同时,EMA注意力机制利用3条并行路线提取分组特征图的注意力权重。其中,2条并行路线位于 1×1 的卷积分支中,1条路线位于 3×3 的卷积分支中,这样的设计能够增强模型对不同尺度信息的感知能力。通过同时关注局部细节和全局上下文信息,提高模型特征表征的多样性和丰富性,有助于提升模型的性能和泛化能力^[13]。EMA注意力机制相较于其他注意力机制在参数和准确率方面都有较大的优势,所以本研究选取EMA注意力机制进行改进。EMA结构如图3所示。



SPPF为空间金字塔池化模块;C2f_DCN为加入可变形卷积模块的C2f模块;Upsample为上采样模块;Detect为检测头;Maxpool2d为最大池化;Concat为特征连接模块;Bbox.Loss为边界框损失;Cls.Loss为分类损失;Output为输出端。SPPF is space pyramid pool module; C2f_DCN is a C2f module with a deformable convolutional module. Upsample indicates the upsampling module. Detect indicates the detection header. Maxpool2d is the max pool. Concat is the feature connection module. Bbox.Loss indicates the boundary frame loss. Cls.Loss is classified loss. Output is the output terminal.

图2 EDW-YOLOv8模型结构图
Fig.2 EDW-YOLOv8 model structure

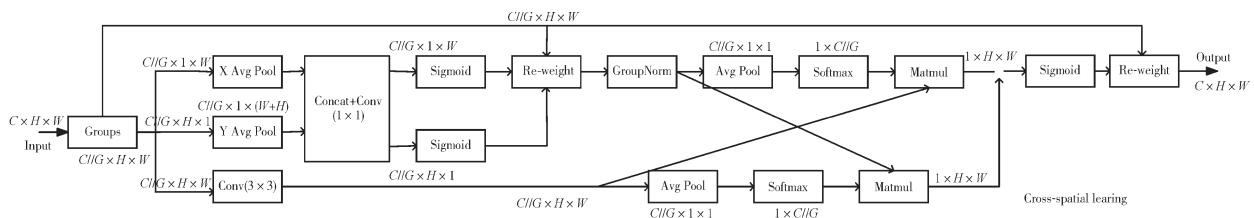


图3 EMA结构图
Fig.3 Structure of EMA

4)C2f_DCN模块。在YOLOv8的C2f模块中存在的Bottleneck模块是一组关键组件,由若干卷积层组成,通过卷积操作来实现特征提取和特征融合。但是面对棉花叶片病害的高度异质性、形状尺寸差异较大的情况下,传统的卷积层无法很好地适应这些差异,导致无法很好地提取特征,造成检测效果不理想。因此,为了更好地提取特征,提高对棉花病害的检测识别效果,在模型骨干网络中的C2f模块中引入可变形卷积(Deformable ConvNets v2)模块,扩大感受野,更好地适应不同尺寸的变换,捕获目标特

征。可变形卷积结构和C2f_DCN v2结构如图4和图5所示。

Deformable ConvNets v2是相较于初代的DCN模块提出的一种改进的可变形卷积,相较于一代DCN,在DCN v2中堆叠了更多可变形卷积层,同时引入的可变形卷积机制具备双重调节能力,不仅能自适应学习输入特征的采样位置偏移,还能动态调整不同空间位置输入特征的权重。在极端情况下,模块可以通过将其特征幅度设置为零来决定是否感知来自特定位置的信号^[14]。可调节的变形卷积定义

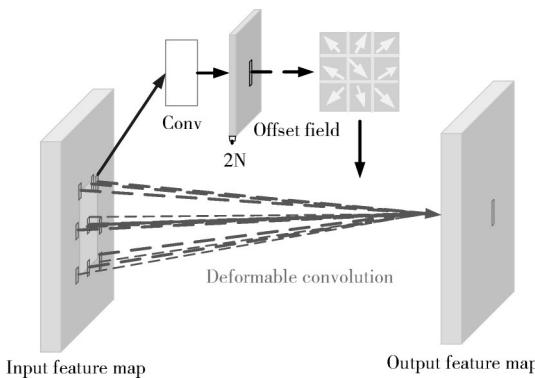


图4 可变形卷积结构

Fig.4 Deformable convolution structure

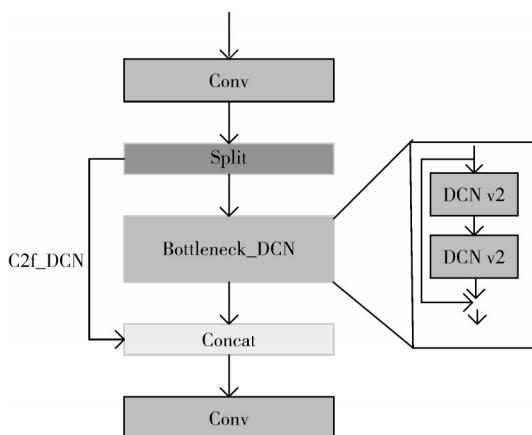


图5 DCN v2结构

Fig.5 DCN v2 architecture

如式(1)所示。

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

式(1)中: w_k, p_k 分别表示第 k 个位置的权重和预先设定好的偏移; $x(p), y(p)$ 分别表示输入特征图 x 和输出特征图 y 中位置 p 的特征; $\Delta p_k, \Delta m_k$ 表示第 k 个位置上的可学习的偏移和调节参数, $\Delta m_k \in [0, 1]$, Δp_k 为任意值。

调节可变形RoIPooling的设计是类似的,输出特征计算如式(2)所示。

$$y(k) = \sum_{j=1}^{n_k} x(p_{kj} + \Delta p_k) \Delta m_k / n_k \quad (2)$$

式(2)中: p_{kj} 表示第 k 个采样区域中的第 j 个小格; n_k 表示采样区域内小格数量。

5) WIoU 损失函数。YOLOv8 网络所采用 CIoU^[15]损失作为边框回归的损失函数,CIoU 损失虽然考虑了重叠面积、中线点距离、长宽比等因素,但是当预测框与真实框的高宽比呈线性关系时,CIoU 的惩罚项会出现趋近于 0 的情况,对回归损失产生不利影响。

因此,本研究采用具有动态聚焦机制的边界盒回归损失(WIoU)来替换 CIoU 损失。由于训练数据不可避免地包含低质量的样本和几何因素,从而降低模型的泛化性能^[16]。为此,设计了基于距离度量的注意力模块,得到了具有 2 层注意力机制的 WIoU v1,计算如式(3)所示。

$$L_{\text{WIoU}} = R_{\text{WIoU}} L_{\text{IoU}} \quad (R_{\text{WIoU}} \in [1, e], L_{\text{IoU}} \in [0, 1]) \quad (3)$$

$$R_{\text{WIoU}} = \exp\left(\frac{(x - x_{\text{gt}})^2 + (y - y_{\text{gt}})^2}{(W_g^2 + H_g^2)^*}\right) \quad (4)$$

式(3)、(4)中: R_{WIoU} 为用于放大普通质量锚盒的 L_{IoU} , W_g, H_g 为最小封闭盒的宽度和高度。

使用 β 构造一个非单调聚焦系数,并应用于 WIoU v1 得到具有动态非单调 FM 的 WIoU v3,计算如式(5)所示, β 计算如式(6)所示。

$$L_{\text{WIoU}} = r L_{\text{WIoU v1}}, r = \frac{\beta}{\delta \alpha^{\beta - 2}} \quad (5)$$

$$\beta = \frac{L_{\text{IoU}}^*}{\overline{L}_{\text{IoU}}} \in [0, +\infty] \quad (6)$$

式(5)、(6)中: $\overline{L}_{\text{IoU}}$ 表示动态滑动平均值。 α, δ 表示超参数; r 表示梯度增益。

WIoU v3 使用动态非单调评估锚盒质量的机制,使模型更加关注锚定普通质量的框,提高了模型定位对象的能力,从而提高检测性能,故而采用 WIoU v3 来替换原本的边框回归损失。

1.3 训练环境、参数及评价指标

本研究模型训练和测试均在同一环境下运行,试验训练和测试硬件配置,采用 GPU 为 RTX3090, CPU 为 Intel(R) Xeon(R) Platinum 8350C, 显存 24 GB, 软件环境为 Windows10, 64 位, python3.8 版本, pytorch1.9.0 框架, Cuda11.1 版本。训练参数设置如下: 初始学习率为 0.01, 迭代周期为 100, 训练批次数为 64。实验结果采用准确率 P(precision, %)、召回率 R(recall, %) 和平均精确度 AP(average precision, %) 来衡量, 以 mAP 表示数据集中所有类别 AP 的均值。

2 模型训练与结果分析

2.1 与其他注意力机制的对比

本研究以 YOLOv8n 网络为基础网络, 在骨干网络处添加 EMA 注意力机制, 在保持其他参数, 网络结构一致的情况下, 对比添加 SE 注意力机制^[17], ECA 注意力机制^[18], CBAM 注意力机制^[19], 结果如表 1 所示。

表1 不同注意力机制的对比
Table 1 Comparison of different attention mechanisms

注意力机制 Attention mechanism	准确率 Precision	召回率 Recall	平均精确度 (mAP) Average precise	%
YOLOv8n+SE	94.6	87.6	94.3	
YOLOv8n+ECA	91.2	87.5	94.0	
YOLOv8n+CBAM	91.8	86.4	93.2	
YOLOv8n+EMA	94.1	87.9	94.7	
YOLOv8n	92.7	86.1	93.3	

由表1可知,添加SE注意力机制,相较于YOLOv8n网络,准确率、召回率、平均精确度分别提升1.9、1.5和1.0个百分点,但是与添加EMA注意力机制相比,召回率与平均精确度分别低0.3、0.4个百分点,准确率只高0.5个百分点;添加ECA注意力机制,相较于YOLOv8n网络,召回率、平均精确度分别提升1.4、0.7个百分点,准确率降低1.5个百分点,与添加EMA注意力机制相比,准确率、召回率、平均精确度分别降低2.9、0.4和0.7个百分点;添加CBAM注意力机制,相较于YOLOv8n网络,召回率提升0.3个百分点,准确率、平均精确度分别降低0.9、0.1个百分点,与添加EMA注意力机制相比,准确率、召回率、平均精确度分别降低2.3、1.5和1.5个百分点;由此可见,本研究选取添加EMA注意力机制,使网络可以更好地区分病害目标,提高网络检测的准确性。

2.2 损失函数消融

YOLOv8采用CIoU损失函数作为边框回归损失,但CIoU损失函数复杂度较高,需要更长时间训练才能收敛。因此,本研究采用WIoU损失函数来替代原本的CIoU损失函数。通过试验对比YOLOv8n网络采用WIoU、DIoU^[20]和GIoU^[21]损失函数的收敛情况,结果如图6所示。由图6可知,采用GIoU时收敛速度最慢,收敛后损失较高,采用DIoU和CIoU时收敛速度略快于GIoU,收敛后损失略小于GIoU,采用WIoU时收敛速度最快,收敛后损失最低,在前20轮迭代中,模型梯度快速下降,并且损失远小于其他3种函数。

2.3 可变形卷积消融

本研究在YOLOv8n骨干网络处C2f模块中加入了可变形卷积DCN v2,扩大感受野,加强网络特征提取能力。本研究在加入EMA注意力机制和替换WIoU损失函数的基础上(EWD-YOLOv8n),分别在骨干网络C2f模块、颈部网络C2f模块和全部网络

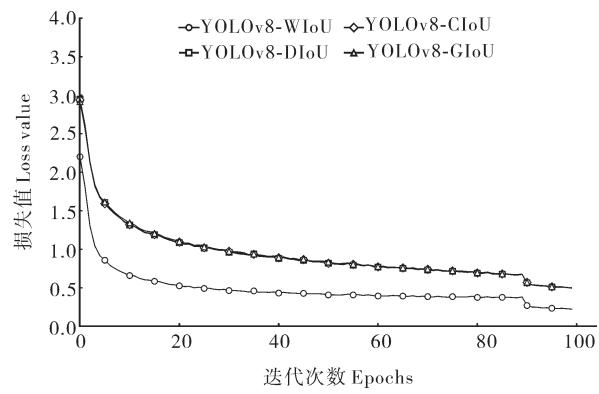


图6 4种损失函数对比

Fig.6 Comparison of four loss functions

C2f模块上加入DCN v2可变形卷积,结果如表2所示。由表2可知,将DCN v2模块与骨干网络模块中的C2f模块相结合,准确率、召回率和平均精确度比将DCN v2模块加入到颈部网络和全部网络的C2f模块中分别高0.6、1.3、2.0、1.4个百分点和0.7、0.6个百分点,使得网络提取特征能力更强,检测效果更好。因此,本研究选择将DCN v2模块加入到骨干网络中的C2f模块中。

2.4 消融实验

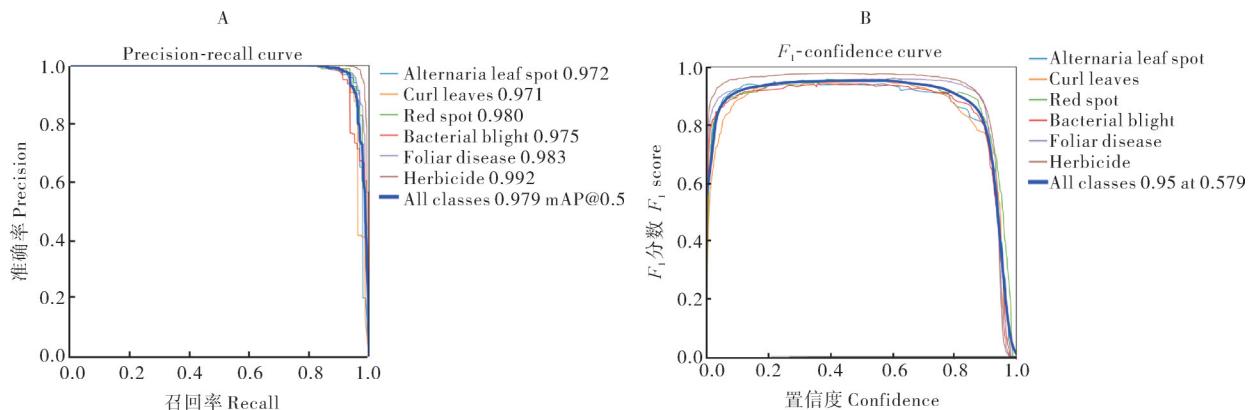
为了验证本研究所提出的算法改进的有效性,设计了消融实验,结果如表3所示,在添加EMA注意力机制后,网络的特征提取能力得到增强,可以更好地提取目标特征,使得网络的准确率、召回率和平均精确度均有所提升;在实验3中,单独替换WIoU损失函数后,虽然准确率略微下降,但是召回率和平均精度都有所提升,这表明WIoU有助于提高模型拟合能力;实验4加入DCN v2卷积后,扩大了模型的感受野,加强了特征提取能力,使网络的准确率、召回率和平均精度相较于原来分别提升了2.7、6.1和3.4个百分点;实验6中,改进后的模型EWD-YOLOv8网络相比于原网络准确率、召回率和平均精确度分别

表3 消融实验

Table 3 Ablation experiments

实验编号 Test number	EMA	WIoU v2	DCN v2	准确率 Precision	召回率 Recall	平均精确度 Average precise
1	×	×	×	92.7	86.1	93.3
2	✓	×	×	94.1	87.9	94.7
3	×	✓	×	91.3	90.2	95.1
4	×	×	✓	95.4	92.2	96.7
5	✓	✓	×	95.6	89.7	96.0
6	✓	✓	✓	97.0	93.6	97.9

注:✓表示使用该算法,×表示不使用该算法。Note: ✓ indicates that the algorithm is used, × indicates that the algorithm is not used.



A. 每类病害的PR曲线 The PR curve for each type of disease; B. 每类病害的 F_1 分数曲线 The F_1 score curve of each type of disease.

图7 模型识别效果

Fig.7 Model recognition effect

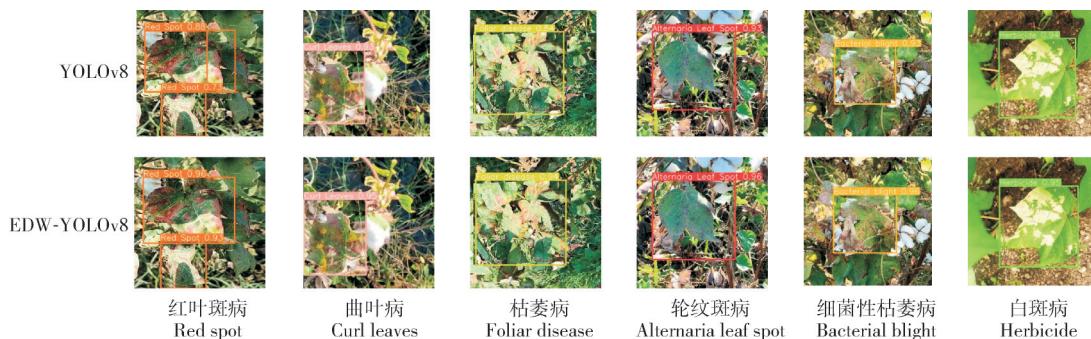


图8 改进前后结果可视化对比

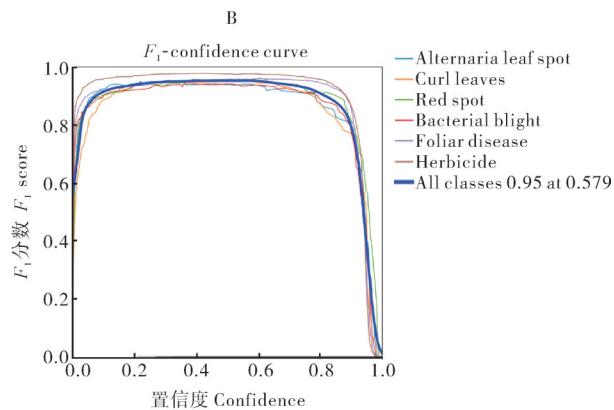
Fig.8 Visual comparison of results before and after improvement

2.5 不同网络模型性能对比试验

为了验证本研究提出的网络模型的有效性,选取YOLOv7^[22]、YOLOv5^[23]、YOLOv7-tiny、YOLOv8n、RT-DETR^[24]、CenterNet^[25]和EDW-YOLOv8共7种网络模型,在相同的训练环境下,用同一数据集训练,进行对比试验,对比结果如表4所示。

由表4可知,改进后的YOLOv8n模型EDW-

提升4.3、7.5和4.6个百分点。这些结果都进一步验证了本研究提出算法改进的有效性。改进后模型对每类病害检测的PR曲线和 F_1 分数曲线如图7所示。图8展示了改进前后模型对6种病害检测的可视化效果对比。如图8所示,在对枯萎病的检测中提升效果最好;在对红叶斑病的检测中,上面的棉花叶片在光照的影响下,对下面的棉花叶片进行了一个阴影遮挡,改进后的模型可以很好地关注到被遮挡后的病害,检测效果相较于原本模型有了较大的提升;对其他4种病害的检测中,本研究的模型都很好地克服了环境背景所带来的影响,使检测结果均有所提升。



YOLOv8在准确率、召回率和平均精确度上都大于其他模型,在平均精确度上分别比YOLOv5、YOLOv7、YOLOv7-tiny和YOLOv8n大于10.5、5.3、3.1和4.6个百分点,在准确率上,相较于检测效果最差的YOLOv5提升9.6个百分点,相比于YOLOv7、YOLOv7-tiny和YOLOv8n分别提升6.8、4.4和4.3个百分点。与非YOLO系列模型的RT-DETR和CenterNet 2个模型相比,改进后的EDW-YOLOv8在各项

衡量指标上也都优于这2个模型。

表4 不同网络模型性能对比试验

Table 4 Comparative tests %

模型名称 Model name	准确率 Precision	召回率 Recall	平均精确度 Average precision
YOLOv5	87.4	78.0	87.4
YOLOv7	90.2	86.5	92.6
YOLOv7-tiny	92.6	88.6	94.8
YOLOv8n	92.7	86.1	93.3
CenterNet	95.3	84.9	92.3
RT-DETR	94.4	87.1	93.5
EDW-YOLOv8	97.0	93.6	97.9

2.6 模型泛化实验

为了验证本研究提出的改进模型在农作物病虫害检测识别中是否具有良好的泛化性,从公开数据集plantvillage中选取番茄病虫害数据集;从roboflow开源视觉数据平台中选取马铃薯病虫害数据集进行验证。同时,选取公开数据集CCTSDB交通标志数据集,来验证模型在不同场景下的通用性。验证结果如表5所示。

表5 模型泛化实验

Table 5 Model generalization experiment %

模型 Model	数据集 Datasets	准确率 Precision	召回率 Recall	平均精确度 Average precision
YOLOv8	番茄病虫害 Tomato pests and diseases	87.5	82.0	90.1
	马铃薯病虫害 Potato pests and diseases	84.7	83.2	89.9
	CCTSDB交通标志 CCTSDB traffic signs	94.6	90.3	94.9
EDW-YOLOv8	番茄病虫害 Tomato pests and diseases	91.8	82.2	91.7
	马铃薯病虫害 Potato pests and diseases	88.1	88.1	92.7
	CCTSDB交通标志 CCTSDB traffic signs	95.7	92.1	96.4

由表5结果可见,本研究的算法相较于原始YOLOv8算法,在番茄病虫害和马铃薯病虫害数据集上均有较高的识别精确率,表明本研究的算法在农作物病虫害检测识别中具有较好的识别效果,模型具

有一定的泛化性。此外,在面对不同背景的情况下,在CCTSDB数据集上本算法也比原来算法展示出了更好的识别效果,说明模型具有较强的自适应特征能力,可以应用于其他领域,模型具有一定的通用性。

3 讨论

本研究提出的EDW-YOLOv8棉花叶片病害检测模型,通过引入EMA注意力机制、DCN v2模块和WIoU损失函数,在精度、召回率和平均精度上相较原模型分别提升了4.3、7.5和4.6个百分点,且在检测精度和收敛速度上都优于YOLOv5、YOLOv7等模型。

尽管EDW-YOLOv8模型在棉花叶片病害检测任务中表现出色,但仍存在一些值得进一步研究和改进的方面。首先,虽然引入了EMA注意力机制和可变形卷积DCN v2模块以提高检测精度,但这些改进可能会增加模型的计算复杂度,从而影响实时性和部署的便捷性。特别是在资源受限的边缘设备上,这种计算开销可能会限制模型的应用范围。其次,虽然WIoU损失函数在提高平均精度和加快收敛速度方面表现良好,但在不同场景中的优化效果可能有所不同,未来研究可以针对不同应用场景设计自适应的损失函数,以进一步提高模型的鲁棒性和通用性。最后,未来的研究还可以探索如何在多模态数据中应用该模型,例如结合光谱信息或地理信息,提高对复杂场景的检测能力。通过这些研究,模型有望在农业智能化领域发挥更大的作用,进一步推动棉花叶片病害防治的精准化和高效化。

参考文献 References

- [1] 张楠楠,张晓,白铁成,等.基于CBAM-YOLOv7的自然环境下棉叶病虫害识别方法[J].农业机械学报,2023,54(S1):239-244.ZHANG N N, ZHANG X, BAI T C, et al. Cotton leaf pest and disease recognition method in natural environments based on CBAM-YOLOv7 [J]. Transactions of the CSAM, 2023, 54 (S1) : 239-244 (in Chinese with English abstract).
- [2] KAMILARIS A, PRENAFETA-BOLDÚ F X. Deep learning in agriculture:a survey[J].Computers and electronics in agriculture, 2018, 147: 70-90.
- [3] 贾少鹏,高红菊,杭潇.基于深度学习的农作物病虫害图像识别技术研究进展[J].农业机械学报,2019,50(S1):313-317.JIA S P, GAO H J, HANG X. Research progress on crop pest and disease image recognition technology based on deep learn-

- ing[J].Transactions of the CSAM,2019,50(S1):313-317(in Chinese with English abstract).
- [4] ZHU X X, TUIA D, MOU L C, et al. Deep learning in remote sensing: a comprehensive review and list of resources [J]. IEEE geoscience and remote sensing magazine, 2017, 5 (4) : 8-36.
- [5] KOIRALA A, WALSH K B, WANG Z L, et al. Deep learning: method overview and review of use for fruit detection and yield estimation [J]. Computers and electronics in agriculture, 2019, 162:219-234.
- [6] NOROUZZADEH M S, NGUYEN A, KOSMALA M, et al. Automatically identifying, counting, and describing wild animals in camera-trap images with deep learning [J]. PNAS, 2018, 115(25):E5716-E5725.
- [7] 郑宇达,陈仁凡,杨长才,等.基于改进YOLOv5s模型的柑橘病虫害识别方法[J].华中农业大学学报,2024,43(2):134-143.ZHENG Y D, CHEN R F, YANG C C, et al. Citrus pest and disease identification method based on an improved YOLOv5s model [J]. Journal of Huazhong Agricultural University, 2024, 43(2):134-143 (in Chinese with English abstract).
- [8] 郑果,姜玉松,沈永林.基于改进YOLOv7的水稻害虫识别方法[J].华中农业大学学报,2023,42(3):143-151.ZHENG G, JIANG Y S, SHEN Y L. Rice pest identification method based on an improved YOLOv7 model[J]. Journal of Huazhong Agricultural University, 2023, 42 (3) : 143-151 (in Chinese with English abstract).
- [9] 王铭慧,张怀清,樊江川,等.基于深度学习网络实现番茄病虫害检测与识别[J].中国农业大学学报,2023,28(11):165-181. WANG M H, ZHANG H Q, FAN J C, et al. Detection and identification of tomato diseases and pests based on deep learning networks [J]. Journal of China Agricultural University, 2023, 28(11):165-181 (in Chinese with English abstract).
- [10] 王卫星,刘泽乾,高鹏,等.基于改进YOLOv4的荔枝病虫害检测模型[J].农业机械学报,2023,54(5):227-235. WANG W X, LIU Z Q, GAO P, et al. Detection of *Litchi* diseases and insect pests based on improved YOLOv4 model[J]. Transactions of the CSAM, 2023, 54 (5) : 227-235 (in Chinese with English abstract).
- [11] RANGARAJAN A K, PURUSHOTHAMAN R, RAMESH A. Tomato crop disease classification using pre-trained deep learning algorithm[J]. Procedia computer science, 2018, 133: 1040-1047.
- [12] 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 S Y, HU B, ZHAO C. Detection and identification of cucumber leaf diseases based improved YOLOv7[J]. Transactions of the CSAE, 2023, 39 (15) : 163-171 (in Chinese with English abstract).
- [13] OUYANG D L, HE S, ZHANG G Z, et al. Efficient multi-scale attention module with cross-spatial learning [C]// ICASSP 2023 - 2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Rhodes Island, Greece:IEEE, 2023:1-5.
- [14] ZHU X Z, HU H, LIN S, et al. Deformable ConvNets V2: more deformable, better results [C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach, CA, USA: IEEE, 2019: 9300-9308.
- [15] ZHENG Z H, WANG P, LIU W, et al. Distance-IoU loss: faster and better learning for bounding box regression [DB/OL]. 2019: 1911.08287. <http://arxiv.org/abs/1911.08287v1>.
- [16] TONG Z J, CHEN Y H, XU Z W, et al. Wise-IoU: bounding box regression loss with dynamic focusing mechanism [DB/OL]. 2023: 2301.10051. <http://arxiv.org/abs/2301.10051v3>.
- [17] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA: IEEE, 2018: 7132-7141.
- [18] WANG Q L, WU B G, ZHU P F, et al. ECA-net: efficient channel attention for deep convolutional neural networks [C]// 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA: IEEE, 2020: 11531-11539.
- [19] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [C]//European Conference on Computer Vision. Cham: Springer, 2018: 3-19.
- [20] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: faster and better learning for bounding box regression [C]//Proceedings of the 34th AAAI Conference on Artificial Intelligence, the 32nd Innovative Applications of Artificial Intelligence Conference, the 10th AAAI Symposium on Educational Advances in Artificial Intelligence, New York, Feb 7-12, 2020. Menlo Park: AAAI, 2020: 12993-13000.
- [21] REZATOFIGHI H, TSOI N, GWAK J, et al. Generalized intersection over union: a metric and a loss for bounding box regression [C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach, CA, USA: IEEE, 2019: 658-666.
- [22] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Vancouver, BC, Canada: IEEE, 2023: 7464-7475.
- [23] 黄彤镔,黄河清,李震,等.基于YOLOv5改进模型的柑橘果实识别方法[J].华中农业大学学报,2022,41(4):170-177. HUANG T B, HUANG H Q, LI Z, et al. Citrus fruit identification method based on an improved YOLOv5 model [J]. Journal of Huazhong Agricultural University, 2022, 41 (4) : 170-177 (in Chinese with English abstract).
- [24] ZHAO Y A, LV W Y, XU S L, et al. DETRs beat YOLOs on

- real-time object detection[DB/OL].2023:2304.08069.http://arxiv.org/abs/2304.08069v3.
- [25] DUAN K W, BAI S, XIE L X, et al. CenterNet: keypoint triplets for object detection[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, Korea (South): IEEE, 2019:6568-6577.

Cotton leaf disease detection based on EDW-YOLOv8

LI Ya¹, JIANG Chen¹, WANG Hairui¹, ZHU Guifu², HU Can¹

1. Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650504, China;

2. Kunming University of Science and Technology, Information Technology Management Center/Kunming University of Science and Technology - Dawn Information Industry Co., Ltd., AI Joint Research Center, Kunming 650504, China

Abstract Accurate detection of cotton leaf diseases in complex natural environments is essential for effectively minimizing the impact of diseases on cotton yield and quality. To address this, this study proposes a cotton leaf disease detection model based on an improved YOLOv8n. First, the EMA attention mechanism is integrated into the backbone network of YOLOv8n. Simultaneously, the deformable convolutional module, Deformable ConvNets v2, is incorporated into the C2f module within the backbone network to expand the sensory field and strengthen feature extraction capabilities. Additionally, the CIoU loss function is replaced with the WIoU bounding box regression loss, which includes a dynamic focusing mechanism to accelerate model convergence and further improve performance. The experimental results showed that the improved EDW-YOLOv8 model achieves increases of 4.3%, 7.5% and 4.6% in accuracy, recall, and average precision, respectively, compared with the original YOLOv8n. These results show that the proposed model, with good generalization ability, can accurately and efficiently detect cotton leaf disease targets in images.

Keywords cotton leaf diseases; YOLOv8; attention mechanism; deformable convolutional module; loss function

(责任编辑:边书京)