

基于改进 YOLOv8 的轻量化荷叶病虫害检测模型

刘 忠, 卢安舸*, 崔 浩, 刘 俊, 马秋成

(湘潭大学机械工程与力学学院, 湘潭 411105)

摘 要: 腐败病、叶斑病、病毒病、斜纹夜蛾等荷叶病虫害严重影响莲子的产量与品质。开展疫病叶片检测是防治荷叶病虫害的重要措施。该研究以提高对荷叶病虫害的检测精度、减少模型的计算规模、提升可部署性为目标, 提出了一种基于改进 YOLOv8 的轻量化荷叶病虫害检测模型, 同时, 建立了一种考虑不同环境条件的荷叶病虫害数据集。首先, 将 YOLOv8 颈部网络中的卷积模块 (Conv) 替换为 GSConv, 将 C2f 模块替换为 VoV-GSCSP, 形成了 Slim-neck 架构, 使模型在保持较高识别准确性的基础上降低计算复杂度。同时, 使用融合了 EMA 高效多尺度注意力机制的 C2f_EMA 模块替换主干网络中的 C2f 模块, 提升模型对复杂环境中荷叶病虫害的特征提取能力。试验结果表明, 建立的改进 YOLOv8 荷叶病虫害检测模型能够对荷叶病虫害进行有效检测, 实现的平均精度均值 (mean average precision, mAP) 为 89.3%, 较基线模型提高了 1.6 个百分点; 模型的参数量较基线模型降低了 0.2 M, 模型大小仅为 5.6 MB。与其他主流检测模型相比, 改进 YOLOv8 模型在检测精度、参数量和模型大小等方面表现出显著优势。将模型部署至 Jetson Xavier NX 和树莓派 4B 边缘计算设备上, 模型实现的检测帧率分别为 27 和 0.7 帧/s, 展现了良好的移动端部署前景。所提模型实现了对荷叶病虫害的精准识别, 可为荷叶病虫害自动防治提供支撑。

关键词: 荷叶; 病虫害检测; 深度学习; YOLOv8; 轻量化; 注意力机制

doi: 10.11975/j.issn.1002-6819.202404155

中图分类号: S24

文献标志码: A

文章编号: 1002-6819(2024)-19-0168-09

刘忠, 卢安舸, 崔浩, 等. 基于改进 YOLOv8 的轻量化荷叶病虫害检测模型[J]. 农业工程学报, 2024, 40(19): 168-176.

doi: 10.11975/j.issn.1002-6819.202404155 <http://www.tcsae.org>

LIU Zhong, LU Ange, CUI Hao, et al. Lightweight model for detecting lotus leaf diseases and pests using improved YOLOv8[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2024, 40(19): 168-176. (in Chinese with English abstract) doi: 10.11975/j.issn.1002-6819.202404155 <http://www.tcsae.org>

0 引 言

莲是一种水生植物, 在中国已有 3 000 余年的种植历史。莲子富含淀粉、蛋白质、矿物质、生物活性化合物等成分^[1], 有极高的营养与药用价值, 海内外市场需求较大。在莲子种植过程中, 荷叶容易出现严重的病虫害, 例如腐败病^[2]、叶斑病^[3]、病毒病^[4]、斜纹夜蛾^[5]等, 对莲子产量与品质造成严重影响, 甚至导致莲子绝收^[6]。实施荷叶病虫害防治是解决这一问题的有效方法, 而对疫病叶片进行检测则是实现疫情评估和精准防治的前提条件。目前, 对于荷叶病虫害的检测主要通过人工经验判别, 而该方式存在主观性强、效率低的问题, 若缺乏专业知识, 极易造成漏检或误检。因此, 研究适应莲田实际环境的荷叶病虫害自动检测方法对于提高莲子种植质量、降低经济损失、促进莲子产业发展具有重要意义。

传统的植物病虫害自动检测方法, 主要结合机器视觉、图像处理、人工特征工程、机器学习分类算法实现。

SAHU 等^[7]基于随机森林 (random forest, RF) 和多类支持向量机 (multiclass support vector machine, MCSVM) 建立了一种植物叶片病害检测模型 HRF-MCSVM, 模型准确率达 98.9%。黄林生等^[8]基于 Sentinel-2 影像和 BP 神经网络, 构建了一种小麦条锈病严重度监测模型, 该监测模型的总体精度为 83.3%。虽然传统方法可实现对植物病虫害的自动检测, 但其所需的人工特征提取耗时费力; 另外, 采集的病虫害图像往往随环境状态改变而变化, 在这种情况下, 传统方法的检测精度和鲁棒性有限。

近年来, 具有自动特征提取能力的深度学习目标检测算法在植物病虫害自动检测领域获得应用。相关的算法主要包括二阶段的 Faster R-CNN 系列和一阶段的 YOLO (you only look once) 系列^[9]。KAUR 等^[10]基于 Mask R-CNN 算法构建了一种番茄叶片病害自主分割与检测模型, 该模型通过添加 Light-Head R-CNN, 改变 RPN (region proposal network) 中锚点的比例以提升检测精度, 模型平均精度均值 (mean average precision, mAP) 为 88.2%。毛锐等^[11]基于 Faster R-CNN 构建了一种小麦条锈病和黄矮病识别模型, 其中深度残差网络主干特征网络通过卷积核拆解及下采样延迟策略进行了优化; ROI (region of interest) 则通过 ROI Align 进行改进以提升精度, 最终 mAP 为 91.06%。ZHANG 等^[12]提出了一种基于多特征融合的大豆叶片病害模型 MF³R-CNN, 该模型以跳跃

收稿日期: 2024-04-23 修订日期: 2024-08-16

基金项目: 国家自然科学基金项目 (52205285; 52175255); 湖南省自然科学基金项目 (2023JJ40629)

作者简介: 刘忠, 研究方向为计算机视觉、深度学习、人工智能在农业工程中的应用。Email: 202105500914@smail.xtu.edu.cn

※通信作者: 卢安舸, 博士, 副教授, 研究方向为视觉检测与智能农业装备。Email: ange.lu@xtu.edu.cn

方式连接特征提取网络中的不同层实现多特征混合，模型 mAP 为 83.34%。二阶段目标检测算法虽可实现高检测精度，但因检测过程分为两个阶段，使得其处理速度较慢^[13]，难以满足农业智能装备的轻便部署要求。

YOLO 系列是近年来出现的代表性一阶段深度学习目标检测算法，具有检测速度快的特点。胡根生等^[14]基于 YOLOv5 模型，将骨干网络中的 3×3 卷积核替换为卷积核组，添加了注意力模块，并将交叉熵损失函数替换为 Focal Loss 损失函数，构建了一种茶尺蠖检测模型，模型 mAP 为 92.89%。姚凌云等^[15]基于 YOLOv5su 构建了一种桃树缩叶病识别模型，其在骨干网络中添加了 DA (deformable attention) 自注意力模块，在 SPPF 模块中引入 LSKA (large separable kernel attention) 模块，并使用轻量化下采样结构替换卷积模块，模型 mAP 为 80.4%。刘诗怡等^[16]提出了一种改进 YOLOv7 模型检测黄瓜叶片病虫害，模型采用了可变形卷积 DCNv2，添加了 SENet 注意力机制模块，采用 K-means++ 算法对锚框参数进行了优化，并将原始 CIoU 损失函数替换为 Focal-ElIoU，模型实现的 mAP 为 94.25%。兰玉彬等^[17]基于 YOLOv5s 模型，引入 CA 注意力机制，构建了一种生姜叶片病虫害检测模型，该模型 mAP 为 83.8%。上述报道通过对基线模型进行改进，提升了对于特定病虫害目标的检测精度。但引入精度改进措施后通常使得模型结构趋于复杂，模型参数量增大，不利于模型的移动端部署。因此，研究如何在提升模型检测性能的基础上实现模型的轻量化具有重要意义。

荷叶病虫害种类多、外观及尺度差异大，相关特征与周围环境相似，检测难度大。本文基于 YOLOv8 目标检测算法构建了一种轻量化荷叶病虫害专用检测模型。在模型颈部网络实现了轻量化设计，并将主干网络中的 C2f 模块替换为融合了注意力机制的 C2f 模块，以提升模型的检测精度、降低计算复杂度、增强可部署性。同时，还研究了模型在 Jetson Xavier NX、树莓派 4B 等边缘计算设备中的部署性能。以期为荷叶病虫害高效智能检测及病虫害智能防治作业装备研发提供技术支撑。

1 材料与方法

1.1 荷叶病虫害图像采集

本研究选取较为常见的腐败病、叶斑病、病毒病、斜纹夜蛾 4 种类型的荷叶病虫害作为研究对象。有关各类病虫害所对应的外观特征描述如表 1 所列。通过开展荷叶病虫害图像实地采集作业，建立了荷叶病虫害检测专用图像数据集。图像采集时间为 2023 年、2024 年的 7—8 月。采集地点位于湖南省湘潭市雨湖区及湘潭县花石镇的多个莲子种植基地。采用的图像采集设备为智能手机，包括 IQOO neo5、iPhone SE2、Vivo X23、HUAWEI Nova7 等型号，所采用的拍摄分辨率包括 4 000×3 000、3 024×4 032、5 632×4 224 (像素) 等。考虑到莲田为露天开放环境，荷叶常处于不同光照及气象条件下，因此采集过程考虑了早上、中午和下午等不同

时段，此外还涵盖了晴天、阴天和雨后等多种天气条件。拍摄过程中采用了不同的拍摄角度和距离。经过清点、裁剪等处理最终获得 4 类荷叶病虫害图片共计 2 600 张。上述采集安排和图片准备方案考虑了样本特征的多样性和丰富性，同时保证了不同类型样本的数量均匀性。采集的荷叶图像样例如图 1 所示。

表 1 本文研究的荷叶病虫害及其主要特征
Table 1 Diseases and pests of lotus leaves and their main characteristics studied by this study

编号 No.	类别 Type	主要特征 Main characteristics
1	腐败病	患病叶片初期呈淡绿色，随后从叶缘开始颜色变淡、干枯，进而全叶卷曲干枯、叶柄顶端呈弯曲状，后期呈枯黄似火烧状 ^[2]
2	叶斑病	叶片染病初期产生褐色斑点，形成圆形病斑，后扩散成红褐色或暗褐色病斑，后期病斑变褐干枯 ^[3]
3	病毒病	患病叶片局部变黄或叶片畸形，叶面包卷、皱缩，叶脉凸起 ^[4]
4	斜纹夜蛾	被害叶片出现缺刻或呈现纱窗状，后期仅剩一层表皮和叶脉 ^[5]

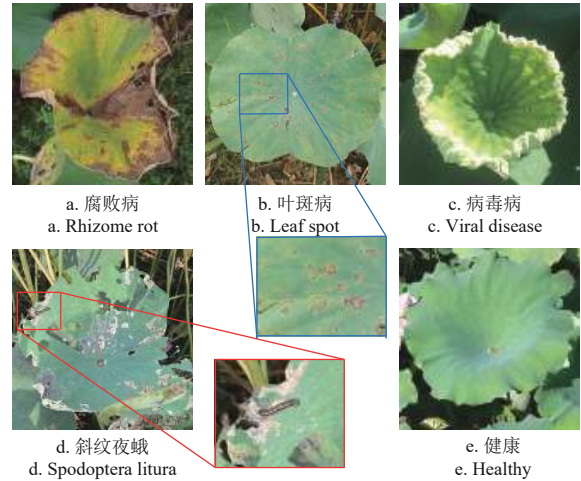


图 1 采集的荷叶图像样例

Fig.1 Example of the collected lotus leaf images

1.2 数据集建立

从荷叶病虫害图片中抽取 2 200 张用于模型训练。为了提高模型的泛化能力和鲁棒性，通过数据增强将图片扩充为 4 400 张。增强方式包括左右翻转、上下翻转、随机平移、随机亮度调整、随机对比度调整等。进一步地，将扩充后的图片按照 8: 2 划分为训练集和验证集。另一方面，将抽取后剩余的 400 张图片作为独立测试集，用于评估模型检测性能，其中 4 类病虫害的图片各 100 张。

采用 LabelImg 软件对数据集图片中的疫病荷叶进行画框标注，其中，腐败病的标签名为“Rhizome rot”，病毒病的标签名为“Viral disease”，叶斑病的标签名为“Leaf spot”，斜纹夜蛾的标签名为“Spodoptera litura”。标注文件保存格式为*.txt，文件中包含病虫害类型及标注框在图片中的位置信息。其中，部分图片中同时存在多个病虫害荷叶对应的多个标注。最终建立的数据集中 4 类荷叶病虫害标注的具体数量如表 2 所示。

表2 数据集中各类荷叶病虫害标注数量

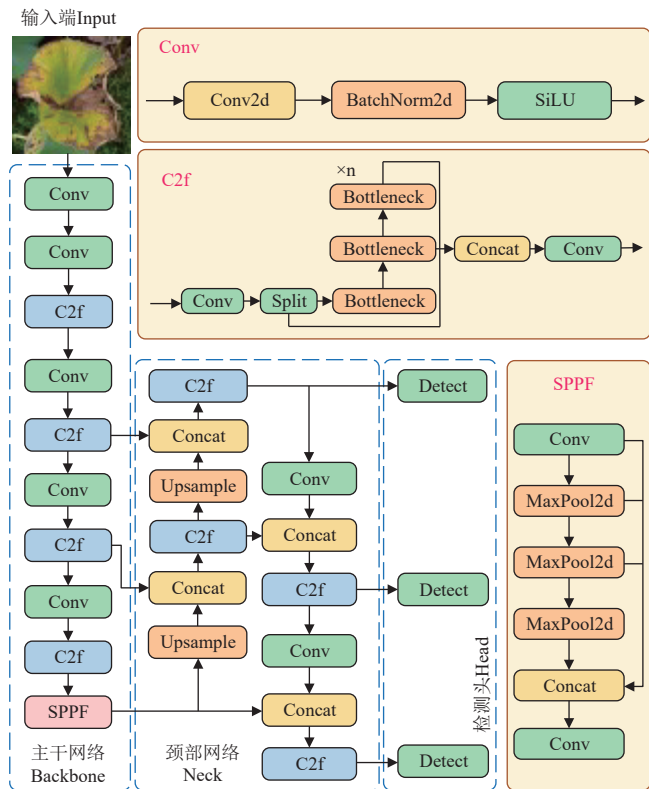
Table 2 The number of annotations for various lotus leaf diseases and pests in the dataset

类别 Type	训练集 Training dataset	验证集 Validation dataset	测试集 Test dataset	合计 Total
腐败病	926	221	111	1 258
病毒病	926	248	103	1 277
叶斑病	880	220	121	1 221
斜纹夜蛾	1 052	261	119	1 432
合计	3 784	950	454	5 188

2 模型与训练

2.1 YOLOv8 深度学习模型网络结构

YOLOv8 是 Ultralytics 公司于 2023 年发布的深度学习目标检测算法, 其汲取了 YOLOv5、YOLOv7 等先前版本的优点, 具有优异的性能^[18]。YOLOv8 的模型网络结构如图 2 所示, 主要由输入端 (Input)、主干网络 (Backbone)、颈部网络 (Neck) 和检测头 (Head) 4 部分组成。



注: Conv 为卷积模块, Concat 为特征连接模块, Upsample 为上采样模块, Detect 为检测头, BatchNorm2d 为批归一化层, SiLU 为激活函数, MaxPool2d 为最大池化, Bottleneck 是包含残差连接的卷积模块, Split 作用为特征分层。

Note: Conv is the convolution module, Concat is the feature connection module, Upsample is the upsampling module, Detect is the detection head, BatchNorm2d is the batch normalization layer, SiLU is the activation function, MaxPool2d is the maximum pooling, Bottleneck is the convolution module containing residual connections, and Split is the feature layering.

图2 YOLOv8 模型网络结构

Fig.2 YOLOv8 model network structure

其中, Input 对输入至网络的图像进行预处理, 通过自适应缩放提升图像处理效率^[19]。Backbone 由 Conv、C2f 和 SPPF 模块组成, 用于对输入的图像进行特征信息提取, 其中 C2f 包括了 2 个 Conv 和 n 个 Bottleneck, 用

于提取更丰富的梯度信息^[20]; SPPF 包括了连续 3 次最大池化操作, 用于捕捉不同尺度下的物体信息, 以提高目标检测的准确性^[21]。Neck 部分由 PAN (path aggregation network, 路径聚合网络) 和 FPN (feature pyramid network, 特征金字塔网络) 结构组合而成, 用于将来自不同层、不同尺度的特征图进行融合, 保障了模型在多尺度场景下的特征提取能力。Head 采用解耦头结构和无锚框 (anchor-free) 策略, 共采用 3 个解耦头在不同尺度上完成图像检测与分类任务, 最终输出目标类别及检测框位置信息。

2.2 改进 YOLOv8 模型网络结构

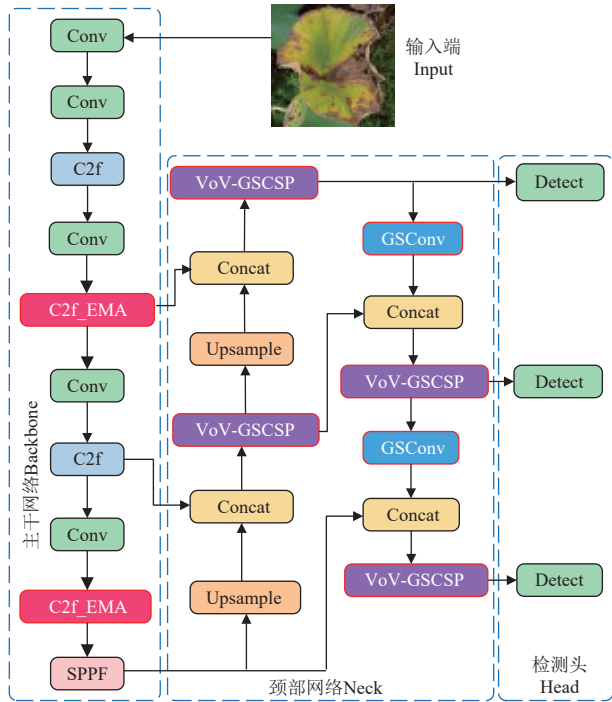
与果蔬类农产品识别研究中的目标相比, 荷叶病虫害目标具有特殊性: 1) 荷叶生长于泥地、池沼非结构环境, 其上病虫害特征 (如颜色、形状等) 与周围环境中的特征相近, 且尺度分布范围宽; 2) 荷叶具有一定面积, 个体之间往往存在互相遮挡, 且生长环境光照情况多变, 检测难度大。另一方面, 荷叶病虫害智能防治工作需在野外实地进行, 检测模型通常需部署在移动设备 (如边缘计算设备) 上, 这类设备算力有限, 对模型的大小、计算规模有更严格的要求, 因此研究实现模型的进一步轻量化具有必要性。

针对上述问题, 本研究以 YOLOv8 (nano) 为基线模型进行下列改进, 构建了一种轻量化荷叶病虫害专用检测模型: 1) 对模型的 Neck 部分进行轻量化设计, 保证荷叶病虫害检测精度的同时, 降低模型的计算规模; 2) 添加高效多尺度注意力机制, 以进一步提升模型对荷叶病虫害有效特征的聚焦能力, 降低图像中干扰因素的影响, 使模型更适合非结构化环境中的荷叶病虫害自动检测作业。改进 YOLOv8 模型网络结构如图 3 所示。

2.2.1 Slim-neck 模块

在自然环境中对荷叶病虫害进行检测对模型的精度和速度性能有很高的要求, 直接关系到模型的工作能力和可部署性。通常模型参数量越大, 其模型的大小也越大, 模型在实际移动设备中的部署难度和成本也随之增加。因此, 为了在保持检测精度的同时有效降低模型的复杂度, 在改进 YOLOv8 模型中构建了由 GSConv 和 VoV-GSCSP 模块组成^[22]的轻量级网络结构 Slim-neck。

在 Slim-neck 中, 首先使用了轻量级混合卷积 GSConv (group-shuffle convolution) 替换原 YOLOv8 颈部网络中的全部 Conv 模块^[23]。GSConv 结构如图 4 所示, 其是由标准卷积 (standard convolution, SC)、深度可分离卷积 (depthwise separable convolution, DSC) 和混洗 (shuffle) 操作组成。采用 GSConv 模块的 Slim-neck 能最大限度地发挥 DSC 的优势, 消除 DSC 存在的因通道信息分隔而造成特征提取能力降低等负面影响^[24]。GSConv 首先对特征图进行 SC 操作, 再进行 DSC 操作, 然后拼接两者形成的特征图, 最终通过 shuffle 操作实现通道重新组合。该方法充分利用了两种卷积的优点, 可在有效降低计算规模的同时保持模型的检测性能^[25-26]。



注：VoV-GSCSP 为一次性聚合的跨级部分网络模块，C2f_EMA 为融合了 EMA 注意力机制的 C2f 模块，GSConv 为轻量级混合卷积。
 Note: VoV-GSCSP is a cross-level partial module variety of view group shuffle cross stage partial network, C2f_EMA is a C2f module that integrates EMA attention mechanism, and GSConv is a lightweight hybrid convolution.

图 3 改进后的 YOLOv8 模型网络结构

Fig.3 Network structure of the improved YOLOv8 model




图 4 GSConv 模块结构

Fig.4 GSConv module structure

相应地，在 GSConv 的基础上，引入了 VoV-GSCSP (variety of view group shuffle cross stage partial network, 一次性聚合的跨级部分网络模块) 模块以进一步减少计算成本、平衡检测精度，其结构如图 5 所示。

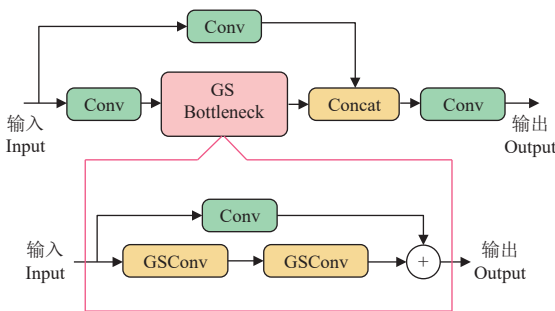


图 5 VoV-GSCSP 模块结构

Fig.5 VoV-GSCSP module structure

VoV-GSCSP 模块的特征信息提取过程分为两条路径：路径一为输入特征图经过普通卷积计算实现特征提取；

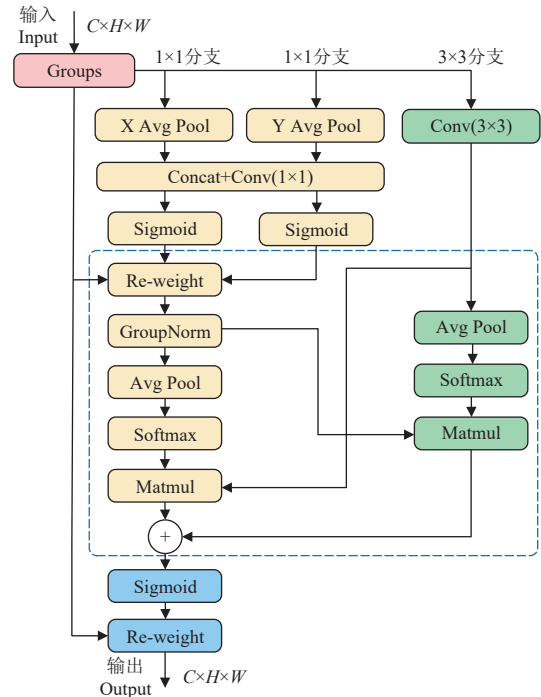
路径二为输入特征图先经普通卷积处理，随后再由基于 GSConv 设计的 GSBottleneck 结构实现特征提取，最后将两部分特征图拼接起来进行输出。

VoV-GSCSP 模块充分利用了 GSConv 和 GSBottleneck 的优势，提高了模型的特征提取能力，减少了模型参数量，在保证模型精度的基础上，进一步改善了模型的轻量化性能^[27]。本研究中使用 VoV-GSCSP 模块替换了原 YOLOv8 模型中 Neck 部分的所有 C2f 模块。

2.2.2 EMA 高效多尺度注意力机制

在荷叶病虫害检测过程中，由于荷叶间部分遮挡、环境光照变化的原因，容易形成漏检；此外，不同类型的病虫害特征之间、病虫害与周围物体之间存在一定特征相似性，易造成误检。这些均与模型对有效荷叶病虫害特征信息提取能力有限或对所提取特征信息的筛选能力不足有关。为提升模型对荷叶病虫害图像的检测能力，本研究在 YOLOv8 的主干网络中添加了 EMA (efficient multi-scale attention) 注意力机制。EMA 注意力机制是 OUYANG 等^[28]于 2023 年提出的一种基于跨空间学习的高效多尺度注意力机制，其通过将部分通道重塑为批量维度并对通道维度分组，而无需降维操作，可防止通道特征信息丢失并降低计算开销，具有精度高、参数量少的特点^[29]。

EMA 注意力机制模块网络结构如图 6 所示。其工作流程如下：首先，对于任意的输入 $X \in R^{C \times H \times W}$ ，EMA 在通道维度上将其切分为 G 个子特征，即 $X = [X_0, X_1, \dots, X_{G-1}]$ ， $X \in R^{C/G \times H \times W}$ ，以获取不同语义。接着，EMA 采用 3 条路线分别提取分组特征图的注意力权重描述符。



注： H 和 W 分别表示图像的高度和宽度； C 为通道数。

Note: H and W represent the height and width of the image, respectively; C is the number of channels.

图 6 EMA 注意力机制模块网络结构

Fig.6 Network structure of the EMA (efficient multi-scale attention) mechanism module

其中前两条路线为使用了含有 1×1 卷积操作的 1×1 分支, 第 3 条路线则为使用了 3×3 卷积操作的 3×3 分支。在 1×1 分支中, 采用两个不同方向的一维全局平均池化操作对通道进行编码, 以实现跨通道信息交互。而在 3×3 分支中则省去了一维全局平均池化操作和 GroupNorm (group normalization, 组归一化), 目的是为了实现在多尺度特征表示。然后, 使用二维全局平均池化操作分别对 1×1 分支和 3×3 分支的输出进行全局空间信息编码。二维全局平均池化操作公式为

$$Z_C = \frac{1}{H \times W} \sum_j \sum_i X_C(i, j) \quad (1)$$

式中 Z_C 表示池化后得到的第 C 个通道的输出值, H 和 W 分别为输入特征的空间维度, C 为通道数, $X_C(i, j)$ 表示宽度为 i 、高度为 j 的第 C 个通道的输入。

各组内的输出特征图由两个生成的空间注意力权重相聚合获得。最后, 使用 Sigmoid 激活函数捕捉像素级的成对关系, 获取全局上下文信息。

本研究将 EMA 注意力机制融入 C2f 的 Bottleneck 中, 形成 C2f_EMA 模块, 其结构图 7 所示。其通过优化 Bottleneck 结构提升 C2f 模块捕捉多尺度特征信息的能力。整体上, 根据前期经验, 将 YOLOv8 主干网络中第 2 个和第 4 个 C2f 模块替换为 C2f_EMA 模块。融合 EMA 注意力机制后, 模型可利用 1×1 卷积和 3×3 卷积在中间特征图上联系更多的上下文信息, 进一步对疫病荷叶的特征信息进行提取和筛选, 这种不同空间维方向的跨空间信息聚合方法使得模型能够有效地应对荷叶病虫害漏检与误检问题。




图 7 融合 EMA 注意力机制的 C2f 结构

Fig.7 C2f structure integrating EMA attention mechanism

2.3 模型训练与评价指标

2.3.1 模型训练平台与参数设置

本研究的模型训练与测试平台硬件配置为: 第 13 代 Intel Core i7-13700H CPU, NVIDIA GeForce RTX 4090 GPU, 24 GB 显存。软件配置包括 Windows 11 操作系统, PyTorch 2.0.1 深度学习框架, 11.8 版本 CUDA, Python 3.8 编程语言, Pycharm 集成开发环境。训练时, 输入模型的图像尺寸设置为 640 像素 \times 640 像素, 训练批次大小 (batch size) 为 16, 训练轮数 (epochs) 为 100 轮, 初始学习率 (learning rate) 为 0.01, 其余参数采用默认值。

测试模型实际部署性能的边缘计算设备包括一台 Jetson Xavier NX (生产厂家: 英伟达, 美国) 和一台树莓派 4B 开发板。Jetson Xavier NX 配置有 6 核 NVIDIA Arm 64 位 CPU, 48 核 NVIDIA Volta™ 架构 GPU, 运行

内存为 8GB。软件运行环境包括 Ubuntu 18.04 操作系统, PyTorch 1.8 深度学习框架, Python 3.6.9 编程语言。树莓派 4B 开发板配置有 4 核 64 位 CPU, 运行内存为 4G。运行环境包括 Raspberry Pi OS 操作系统, PyTorch 1.8.1 深度学习框架, Python 3.9 编程语言。

2.3.2 评价指标

本研究采用精确率 (precision, P)、召回率 (recall, R)、平均精度均值 (mean average precision, mAP@0.5) 评价模型检测精度, 其中 mAP 的阈值设置为 0.5。选取参数量 (parameters) 评价模型计算规模。选取模型权重大小作为可部署性评价指标。选取帧速率 (frame per second, FPS) 评价模型检测实时性^[16]。

3 结果与分析

3.1 不同注意力机制检测性能对比

为研究引入 EMA 注意力机制的合理性, 选取了其他代表性的注意力机制: CBAM (convolutional block attention module)^[30]、SE (squeeze-and-excitation)^[31] 和 SEAM (separated and enhancement attention module)^[32] 进行试验对比。试验过程中各注意力机制模块被设置在 YOLOv8 网络结构中的同一位置, 并在测试集上进行测试。表 3 列出了对比试验结果。

表 3 采用不同注意力机制的模型测试结果

Table 3 Test results of the models with different attention mechanisms

模型 Models	$P/\%$	$R/\%$	mAP/%	模型大小 Model size/MB
YOLOv8	88.6	80.7	87.7	6.0
C2f_EMA-YOLOv8	90.6	80.9	87.9	6.0
CBAM-YOLOv8	85.7	77.8	86.0	6.0
SE-YOLOv8	91.0	79.8	87.5	6.0
SEAM-YOLOv8	90.8	77.3	87.5	6.1

注: P 为精确率, R 为召回率, mAP 为平均精度均值。下同。

Note: P is precision, R is recall, and mAP is mean average precision. Same below.

由表 3 可知, 当引入 EMA 注意力机制后, 模型的 mAP 较基线提升了 0.2 个百分点。而引入 CBAM、SE 和 SEAM 注意力机制后, 模型的 mAP 则较基线均出现不同程度的下降, 分别下降了 1.7、0.2 和 0.2 个百分点。与 EMA 相比, CBAM 注意力机制虽然考虑了通道注意力和空间注意力, 但是其只关注了局部信息而没有建立长距离的依赖关系, 在协调病虫害特征局部与叶片整体时受到限制, 从而影响了复杂环境中的疫病叶片检测。SE 注意力仅关注通道注意力, 一定程度上限制了对病虫害特征的定位和提取能力。SEAM 注意力则在复杂场景和极端遮挡条件下可能无法稳定提取有效的目标。此外, 由结果可知, 向模型中添加注意力机制没有导致模型大小发生大的改变。综上所述, 在引入 EMA 注意力机制后, 在不增大模型大小的同时能够提升特征提取能力。结果表明了本研究通过引入 EMA 注意力机制提升模型对于病虫害检测精度的手段是有效的。

3.2 消融试验

为研究引入 Slim-neck 模块和 EMA 注意力机制对所建立的病虫害检测模型性能的影响, 开展了消融试验。测试集结果如表 4 所示。

表 4 消融试验结果

Table 4 Results of the ablation test

模型 Models	P/%	R/%	mAP/%	mAP ₅₀₋₉₅ /%	参数量 Parameters/M
YOLOv8	88.6	80.7	87.7	75.3	3.0
YOLOv8+Slim-neck	89.5	81.4	88.8	75.0	2.8
YOLOv8+C2f_EMA	90.6	80.9	87.9	75.6	3.0
YOLOv8+Slim-neck +C2f_EMA	92.4	81.8	89.3	75.3	2.8

分析表 4 结果可知，添加 Slim-neck 模块后，模型的精确率增加了 0.9 个百分点，召回率增加了 0.7 个百分点，mAP 增加了 1.1 个百分点，参数量减少了 0.2 M。这是由于模型通过优化特征图的连接方式和减少冗余计算降低了模型的计算复杂度，同时 VoV-GSCSP 模块能够更有效地提取特征来保持检测精度。引入 EMA 注意力机制后，模型的精确率增加了 2 个百分点，召回率和 mAP 分别提升了 0.2 个百分点。这是因为此时模型能够融合来自不同尺度的特征，将更多的注意力放在复杂背景中的病虫害荷叶目标上。对 YOLOv8 模型同时添加 Slim-neck 模块和 EMA 注意力机制后，模型的精确率、召回率和 mAP 分别增加了 3.8、1.1 和 1.6 个百分点，参数量减少了 0.2 M，改进 YOLOv8 模型的目标检测能力均明显优于上述其他模型，漏检和误检情况降低，且参数量较基线模型明显减少。所采用的改进措施有效提高了模型的检测性能，减小了模型的规模，充分发挥了各自应起到的作用。

3.3 主流模型性能对比

为研究改进 YOLOv8 模型与其他模型对于荷叶病虫害检测性能的差异，本节选取了几个主流目标检测模型：Faster R-CNN、SSD、YOLOv3、YOLOv4、YOLOv5、YOLOv7、YOLOv8 和 YOLOv9 开展了性能对比试验。试验结果如表 5 所示。

由表 5 可知，与其他模型相比，改进 YOLOv8 模型的精确率、mAP 结果均更高，参数量和模型大小均更小。与 Faster R-CNN、SSD、YOLOv3、YOLOv4、YOLOv5、YOLOv7 和 YOLOv9 模型相比，mAP 分别提高了 3.8、10.3、13.5、30.7、5.3、6.3 和 4.9 个百分点；参数量分别减少了 38.5、21.0、58.7、61.1、4.2、33.7 和 6.8M；

模型大小分别减少了 102.4、86.5、229.4、238.4、8.0、65.7 和 13.7 MB。从表征模型综合性能的雷达图结果（图 8）可以看出，改进 YOLOv8 模型的图形区域最为饱满，表明其各方面的性能都较其他模型更接近理想状态。

表 5 主流目标检测模型在测试集上的检测性能对比

Table 5 Detection performance comparison between different mainstream object detection models on the test dataset

模型 Models	P/%	R/%	mAP/%	参数量 Parameters/M	模型大小 Model size/MB
Faster R-CNN	64.3	85.1	85.5	41.3	108.0
SSD	88.5	80.1	79.0	23.8	92.1
YOLOv3	82.7	66.4	75.8	61.5	235.0
YOLOv4	80.9	40.5	58.6	63.9	244.0
YOLOv5	86.9	76.5	84.0	7.0	13.6
YOLOv7	81.1	80.5	83.0	36.5	71.3
YOLOv8	88.6	80.7	87.7	3.0	6.0
YOLOv9	84.2	79.8	84.4	9.6	19.3
改进 YOLOv8	92.4	81.8	89.3	2.8	5.6


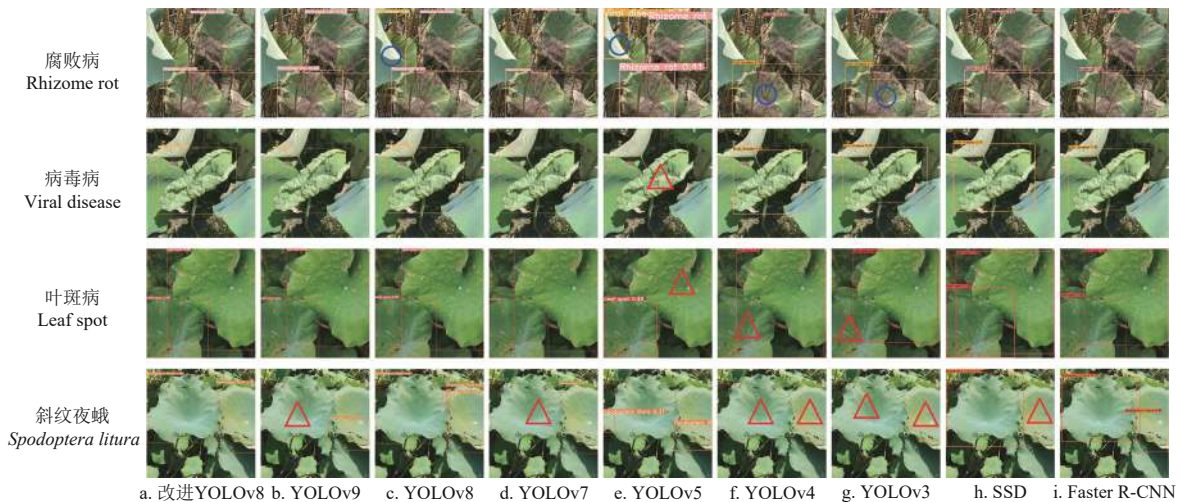


图 8 主流模型综合性能对比雷达图

Fig.8 Radar chart of the comprehensive performance comparison of the mainstream models

为验证各模型的实际检测效果，选择了多幅单独拍摄的莲田中荷叶病虫害场景图片进行检测，可视化结果如图 9 所示，由图可知，在腐败病检测方面，YOLOv8 和 YOLOv5 模型错误地将正常被风吹动的荷叶检测成了病毒病叶，YOLOv4 和 YOLOv3 则将腐败病错误地检测成了病毒病。



注：图中三角形表示漏检，圆圈表示误检。下同。
Note: The triangles in the figure indicate missed detections, and the circles indicate false detections. Same below.

图 9 不同模型的荷叶病虫害检测可视化结果对比

Fig.9 Comparison of visualization results of the lotus leaf diseases and pests detected by using different models

在病毒病的检测中, YOLOv5 未检出目标。在叶斑病检测方面, YOLOv5、YOLOv4 和 YOLOv3 存在漏检。此外, 在斜纹夜蛾的检测方面, YOLOv9、YOLOv7 和 SSD 均出现漏检, YOLOv4 和 YOLOv3 则完全未检出斜纹夜蛾。这是由于斜纹夜蛾染病叶片上形成纱窗状或缺刻特征, 这些特征易与背景中的环境特征混淆, 增大了检测难度。造成上述漏检和误检现象的原因是各模型对复杂背景环境中病虫害目标的特征信息提取能力及抵抗图像中干扰因素作用方面存在不足, 也进一步说明了添加注意力机制的重要性。

综上所述, 在荷叶病虫害图片的检测和识别任务中, 相较于其他 8 种模型, 改进 YOLOv8 模型在实现良好荷叶病虫害检测精度的同时还具有较好的轻量化效果。此外, 该模型展现了更强的实地病虫害检测能力。

3.4 边缘计算设备部署试验分析

为验证所建立的改进 YOLOv8 模型在田间移动端的实际部署性能, 将该模型、基线模型以及实地部署报道较多的 YOLOv5 模型部署在边缘计算设备 Jetson Xavier NX 和树莓派 4B 上, 并开展了测试试验。模型检测帧率结果如表 6 所示。

表 6 模型在边缘计算设备上实现的检测帧率

Table 6 Detection frame rate of the model implemented on the edge computing devices (帧·s⁻¹)

设备 Device	YOLOv5	YOLOv8	改进 YOLOv8 Improved YOLOv8
Jetson Xavier NX	18.1	23.9	27.0
树莓派 4B	0.4	0.7	0.7

改进 YOLOv8 模型在 Jetson Xavier NX 和树莓派 4B 上实现的检测帧率分别为 27.0 和 0.7 帧/s。YOLOv8 模型在 Jetson Xavier NX 和树莓派 4B 上实现的检测帧率分别为 23.9 和 0.7 帧/s。YOLOv5 模型在 Jetson Xavier NX 和树莓派 4B 上实现的检测帧率分别为 18.1 和 0.4 帧/s。相较于 YOLOv5 模型, 改进 YOLOv8 模型在 Jetson Xavier NX 和树莓派 4B 上帧率分别提升了 8.9 和 0.3 帧/s。模型在不同边缘设备中运行的可视化结果如图 10 所示。

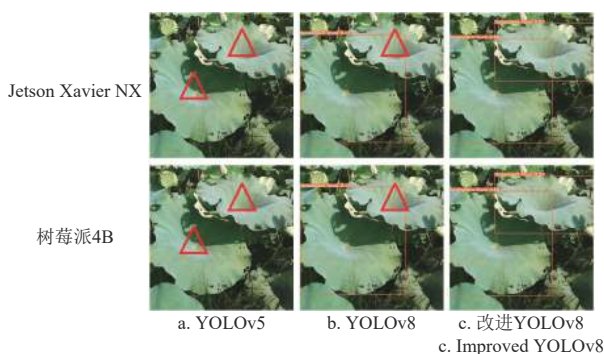


图 10 模型在不同边缘计算设备中部署的检测效果

Fig.10 Detection effect of the model deployed in different edge computing devices

由图 10 可以看出, 改进 YOLOv8 在移动端部署检测效果最好。在实际部署性能方面, 改进 YOLOv8 模型

较经典的 YOLOv5 模型的表现更为突出, 实现了更高的检测速度。此外, 部署在 Jetson Xavier NX 和树莓派 4B 边缘设备的检测结果没有显著差异。上述结果表明改进 YOLOv8 模型具有良好的移动端部署前景, 可为荷叶病虫害高效智能检测及病虫害智能防治作业装备研发提供技术支撑。

4 结论

本研究提出了一种基于改进 YOLOv8 的轻量化荷叶病虫害检测模型, 建立了一种考虑不同环境条件的荷叶病虫害数据集, 为实现荷叶病虫害智能检测和装备实地部署提供一种新的手段。主要结论如下:

1) 在建立的改进 YOLOv8 模型中引入了轻量级卷积 GSCov 和 VoV-GSCSP 模块, 形成 Slim-neck 轻量化架构。此外, 在模型中引入了 EMA 注意力机制, 形成 C2f_EMA 模块替换模型 Backbone 中的 C2f 模块。这使得模型在保持较高准确性的同时降低了计算复杂度, 增强了模型对空间多尺度荷叶病虫害特征的提取和融合能力。模型的精确率、召回率和 mAP 指标分别为 92.4%、81.8% 和 89.3%, 能够对荷叶病虫害进行准确、有效识别。

2) 改进 YOLOv8 模型与目前主流的 Faster R-CNN、SSD、YOLOv3、YOLOv4、YOLOv5、YOLOv7、YOLOv8 和 YOLOv9 等模型相比, 实现的 mAP 更高、参数量更少、模型大小更小。其在实现良好荷叶病虫害检测精度的同时还具有较好的轻量化效果, 在复杂背景中的荷叶病虫害检测任务中更具优势。

3) 改进 YOLOv8 模型在边缘计算设备 Jetson Xavier NX 和树莓派 4B 上完成了部署与测试, 检测帧率分别达到 27.0 和 0.7 帧/s, 且部署性能优于主流 YOLOv5 模型和 YOLOv8 基线模型, 可有效满足病虫害智能防治装备轻便部署要求。

本研究提出的改进 YOLOv8 模型实现了对荷叶病虫害的精准识别, 具有良好的移动端部署前景, 可为荷叶病虫害自动防治作业和病虫害智能防治作业装备研发提供技术支撑。

[参考文献]

- [1] BANGAR S P, DUNNO K, KUMAR M, et al. A comprehensive review on lotus seeds (*Nelumbo nucifera* Gaertn.): Nutritional composition, health-related bioactive properties, and industrial applications[J]. *Journal of Functional Foods*, 2022, 89: 104937.
- [2] 邓旭, 谭济才, 黄佑新. 湘潭莲藕病虫害初步调查[J]. *安徽农业科学*, 2007, 35(3): 768-769.
- [3] 邹华娇. 4 种农药对莲藕叶斑病的控制效果比较[J]. *中国植保导刊*, 2014, 34(4): 64-66.
- [4] 刘娟, 吴伟文, 贺振, 等. 莲藕常见病虫害的发生与防治研究进展[J]. *江苏农业科学*, 2017, 45(16): 24-28.
- [5] 魏林, 梁志怀. 莲藕病虫害草害识别与综合防治[M]. 北京: 中国农业科学技术出版社, 2013.
- [6] 滕辉, 杨继硕, 李思雨, 等. 莲藕腐败病导致藕节组织结构

- 变异的显微观察研究[J]. 植物病理学报, 2024, 54(1): 82-91. TENG Hui, YANG Jishuo, LI Siyu, et al. Histopathological assessment on the lotus rhizome tissue infected by *Fusarium* spp. causing lotus rhizome rot[J]. *Acta Phytopathologica Sinica*, 2024, 54(1): 82-91. (in Chinese with English abstract)
- [7] SAHU S K, PANDEY M. An optimal hybrid multiclass SVM for plant leaf disease detection using spatial Fuzzy C-Means model[J]. *Expert Systems with Applications*, 2023, 214: 118989.
- [8] 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 Linsheng, JIANG Jing, HUANG Wenjiang, et al. Wheat yellow rust monitoring method based on Sentinel-2 image and BPNN model[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2019, 35(17): 178-185. (in Chinese with English abstract)
- [9] 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 Kai, ZHANG Pengchao, WANG Lei, et al. Recognizing citrus in complex environment using improved YOLOv8n[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2024, 40(8): 152-158. (in Chinese with English abstract)
- [10] KAUR P, HARNAL S, GAUTAM V, et al. An approach for characterization of infected area in tomato leaf disease based on deep learning and object detection technique[J]. *Engineering Applications of Artificial Intelligence*, 2022, 115: 105210.
- [11] 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 Rui, ZHANG Yuchen, WANG Zexi, et al. Recognizing stripe rust and yellow dwarf of wheat using improved Faster-RCNN[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2022, 38(17): 176-185. (in Chinese with English abstract)
- [12] ZHANG K, WU Q, CHEN Y. Detecting soybean leaf disease from synthetic image using multi-feature fusion faster R-CNN[J]. *Computers and Electronics in Agriculture*, 2021, 183: 106064.
- [13] 杨锋, 丁之桐, 邢蒙蒙, 等. 深度学习的目标检测算法改进综述[J]. 计算机工程与应用, 2023, 59(11): 1-15. YANG Feng, DING Zhitong, XING Mengmeng, et al. Review of object detection algorithm improvement in deep learning[J]. *Computer Engineering and Applications*, 2023, 59(11): 1-15. (in Chinese with English abstract)
- [14] 胡根生, 吴继甜, 鲍文霞, 等. 基于改进 YOLOv5 网络的复杂背景图像中茶尺蠖检测[J]. 农业工程学报, 2021, 37(21): 191-198. HU Gensheng, WU Jitian, BAO Wenxia, et al. Detection of *Ectopis oblique* in complex background images using improved YOLOv5[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2021, 37(21): 191-198. (in Chinese with English abstract)
- [15] 姚凌云, 周俊峰, 李丽. 改进 YOLOv5su 模型检测桃树缩叶病[J]. 农业工程学报, 2024, 40(14): 109-117. YAO Lingyun, ZHOU Junfeng, LI Li. Improved YOLOv5su model for detecting peach leaf curl disease[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2024, 40(14): 109-117. (in Chinese with English abstract)
- [16] 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 Shiyi, HU Bin, ZHAO Chun. Detection and identification of cucumber leaf diseases based improved YOLOv7[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2023, 39(15): 163-171. (in Chinese with English abstract)
- [17] 兰玉彬, 孙斌书, 张乐春, 等. 基于改进 YOLOv5s 的自然场景下生姜叶片病虫害识别[J]. 农业工程学报, 2024, 40(1): 210-216. LAN Yubin, SUN Binshu, ZHANG Lechun, et al. Identifying diseases and pests in ginger leaf under natural scenes using improved YOLOv5s[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2024, 40(1): 210-216. (in Chinese with English abstract)
- [18] 马超伟, 张浩, 马新明, 等. 基于改进 YOLOv8 的轻量化小麦病害检测方法[J]. 农业工程学报, 2024, 40(5): 187-195. MA Chaowei, ZHANG Hao, MA Xinming, et al. Method for the lightweight detection of wheat disease using improved YOLOv8[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2024, 40(5): 187-195. (in Chinese with English abstract)
- [19] LIU L, LI P, WANG D, et al. A wind turbine damage detection algorithm designed based on YOLOv8[J]. *Applied Soft Computing*, 2024, 154: 111364.
- [20] ZHANG Y, ZHANG H, HUANG Q, et al. DsP-YOLO: An anchor-free network with DsPAN for small object detection of multiscale defects[J]. *Expert Systems with Applications*, 2024, 241: 122669.
- [21] SOLIMANI F, CARDELLICCHIO A, DIMAURO G, et al. Optimizing tomato plant phenotyping detection: Boosting YOLOv8 architecture to tackle data complexity[J]. *Computers and Electronics in Agriculture*, 2024, 218: 108728.
- [22] LI H, LI J, WEI H, et al. Slim-neck by GSConv: A better design paradigm of detector architectures for autonomous vehicles[J/OL]. (2022-08-17)[2024-08-20]. <https://export.arxiv.org/abs/2206.02424v2>
- [23] LU M, SHENG W, ZOU Y, et al. WSS-YOLO: An improved industrial defect detection network for steel surface defects[J]. *Measurement*, 2024, 236: 115060.
- [24] 王法安, 何忠平, 张兆国, 等. 面向复杂田间收获作业的轻量化三七目标检测方法[J]. 农业工程学报, 2024, 40(8): 133-143. WANG Fa'an, HE Zhongping, ZHANG Zhaoguo, et al. Lightweight object detection method for Panax Notoginseng in complex field harvesting[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2024, 40(8): 133-143. (in Chinese with English abstract)
- [25] WU T, ZHANG Q, WU J, et al. An improved YOLOv5s model for effectively predict sugarcane seed replenishment positions verified by a field re-seeding robot[J]. *Computers and*

- [Electronics in Agriculture](#), 2023, 214: 108280.
- [26] HAN K, WANG Y, TIAN Q, et al. GhostNet: More features from cheap operations[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Seattle: IEEE, 2020: 1577-1586.
- [27] 牛鑫宇, 毛鹏军, 段云涛, 等. 基于 YOLOv5s 室内目标检测轻量化改进算法研究[J]. [计算机工程与应用](#), 2024, 60(3): 109-118.
NIU Xinyu, MAO Pengjun, DUAN Yuntao, et al. Research on lightweight improved algorithm for indoor target detection based on YOLOv5s[J]. [Computer Engineering and Applications](#), 2024, 60(3): 109-118. (in Chinese with English abstract)
- [28] OUYANG D L, HE S, ZHAN G Z, et al. Efficient multi-scale attention module with cross-spatial learning[C]. 2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Rhodes Island, Greece: IEEE, 2023: 1-5.
- [29] CHEN S, LI Y, ZHANG Y, et al. Soft X-ray image recognition and classification of maize seed cracks based on image enhancement and optimized YOLOv8 model[J]. [Computers and Electronics in Agriculture](#), 2024, 216: 108475.
- [30] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision (ECCV), Munich: Springer, 2018: 3-19.
- [31] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Salt Lake City: IEEE, 2018: 7132-7141.
- [32] YU Z, HUANG H, CHEN W, et al. YOLO-FaceV2: A scale and occlusion aware face detector[J]. [Pattern Recognition](#), 2024, 115: 110714.

Lightweight model for detecting lotus leaf diseases and pests using improved YOLOv8

LIU Zhong, LU Ange^{*}, CUI Hao, LIU Jun, MA Qiucheng

(School of Mechanical Engineering and Mechanics, Xiangtan University, Xiangtan 411105, China)

Abstract: Lotus leaf diseases and pests have seriously threatened the yield and quality of lotus seeds, such as rhizome rot, leaf spot, virus disease, and *Spodoptera litura*. The detection of diseased leaves has been the most important measure to prevent and control the lotus leaf diseases and pests. However, manual detection cannot fully meet the large-scale production in recent years, due to the subjective and inefficient experience. It is still lacking in professional knowledge, easily leading to missed or false detection. Therefore, automatic detection can be expected to improve the planting quality in the actual environment of lotus fields. In this study, a lightweight detection model was proposed for the lotus leaf disease and pest using improved YOLOv8. The detection accuracy was improved to reduce the calculation scale for the better deployability of the model. At the same time, a new dataset of lotus leaf disease and pests was established to consider the different environmental conditions. Firstly, the convolution module (Conv) in the YOLOv8 neck network was replaced with GSCov. The C2f module was replaced with the VoV-GSCSP to form a slim-neck architecture, in order to reduce the computational complexity of the model for the high recognition accuracy. The C2f_EMA module was integrated with the EMA efficient multi-scale attention mechanism. The C2f module was then replaced in the backbone network, in order to extract the features of lotus leaf pests and diseases in the complex environments. The experimental results show that the improved YOLOv8 detection model effectively detected the lotus leaf pests and diseases. The mean average precision (mAP) was achieved at 89.3%, which was 1.6 percentages higher than the baseline model; The number of parameters of the model was reduced by 0.2M, compared with the baseline model. The model size was only 5.6 MB. A comparison was performed on several mainstream one-stage target detection models: Faster R-CNN, SSD, YOLOv3, YOLOv4, YOLOv5, YOLOv7, YOLOv8, and YOLOv9. The results show that the improved YOLOv8 model shared significant advantages in the detection accuracy, number of parameters, and model size, compared with the rest mainstream models. Finally, the improved YOLOv8 model was deployed on the Jetson Xavier NX and Raspberry Pi 4B edge computing devices, where the frame rates were 27 and 0.7 frames/s, respectively. Compared with the YOLOv5 model, the frame rates increased by 8.9 and 0.3 frames/s, respectively. In terms of actual deployment performance, the improved YOLOv8 model performed better than the classic YOLOv5 model, indicating a better prospect for the mobile terminal deployment. The accurate identification can provide support to the automatic prevention and control of lotus leaf diseases and pests.

Keywords: lotus leaf; diseases and pests detection; deep learning; YOLOv8; lightweight; attention mechanism