

唐秀英, 孙中清, 杨琳琳, 等. 基于改进 YOLO v8n 轻量化的番茄叶霉病发病程度分级检测[J]. 江苏农业学报, 2025, 41(10):1985-1996.  
doi:10.3969/j.issn.1000-4440.2025.10.012

# 基于改进 YOLO v8n 轻量化的番茄叶霉病发病程度分级检测

唐秀英, 孙中清, 杨琳琳, 余静, 刘正林, 王佩, 施杰  
(云南农业大学机电工程学院, 云南 昆明 650201)

**摘要:** 为进一步提高番茄叶霉病发病程度分级识别的精度和效率,降低检测模型的复杂度和权重,便于部署在移动端,本研究对 YOLO v8n 模型进行了改进,提出了一种轻量化病害发病程度分级检测方法。引入 MobileNetV4 中的 UIB 模块,替换 YOLO v8n 模型中的 C2f 卷积层,降低模型的计算量和参数量,满足移动端轻量化部署要求;在主干网络的最高维度后引入级联群体注意力机制模块(CGA),同时引入位置偏置,最后将模型的检测头由解耦检测头替换为双重注意力增强的目标检测头,实现对叶霉病症状特征的精确定位。研究表明,级联群体注意力机制模块(CGA)对模型性能的提升效果最为明显。相比 YOLO v8n 模型,YOLO v8n-UC-DAE 模型的  $P$ 、 $R$ 、 $mAP_{50}$  和  $mAP_{50-95}$  分别提高了 2.0 个百分点、7.7 个百分点、3.8 个百分点和 2.9 个百分点;同时,计算量和权重分别降低了 43.33% 和 32.86%。相较于其他主流模型,本研究构建的 YOLO v8n-UC-DAE 模型能够满足番茄叶霉病发病程度分级检测的需求,并解决了移动端部署的问题。

**关键词:** YOLO v8n 模型; 番茄叶霉病; 发病程度分级

**中图分类号:** S126;TP391.4 **文献标识码:** A **文章编号:** 1000-4440(2025)10-1985-12

## Grading detection for tomato leaf mold severity based on improved lightweight YOLO v8n

TANG Xiuying, SUN Zhongqing, YANG Linlin, YU Jing, LIU Zhenglin, WANG Pei, SHI Jie  
(Faculty of Mechanical & Electrical Engineering, Yunnan Agricultural University, Kunming 650201, China)

**Abstract:** To further improve the accuracy and efficiency of tomato leaf mold severity grading recognition, reduce the complexity and weight of the detection model, and facilitate deployment on mobile devices, this study improved the YOLO v8n model and proposed a lightweight disease severity grading detection method. The UIB module from MobileNetV4 was introduced to replace the C2f convolutional layer in the YOLO v8n model, reducing computational load and the number of parameters to meet the requirements for lightweight deployment on mobile devices. The cascaded group attention (CGA) module was incorporated into the highest-dimensional layer of the backbone network, along with the introduction of positional bias. Additionally, the original decoupled detection head was replaced with a dual attention-enhanced detection head. These modifications enabled the model to achieve precise localization of leaf mold symptoms. The results demonstrated that

收稿日期:2024-12-23

基金项目:云南省重大科技专项(202302AE090020);云南省农业基础研究联合专项(202401BD070001-069);云南省作物生产与智慧农业重点实验室开放课题

作者简介:唐秀英(1981-),女,四川南充人,硕士,副教授,主要从事智能农业装备、植物保护喷雾减药增效研究。(E-mail) xitb05@126.com

通讯作者:施杰,(E-mail) km\_shijie@126.com

the cascaded group attention (CGA) module yielded the most significant improvement in model performance. Compared to the YOLO v8n model, the YOLO v8n-UC-DAE model achieved increases of 2.0 percentage points in  $P$ , 7.7 percentage points in  $R$ , 3.8 percentage points in  $mAP_{50}$ , and 2.9 percentage points in  $mAP_{50-95}$ . Meanwhile, the computational load and the number of parameters were reduced by 43.33% and 32.86%, respectively. Compared

with other mainstream models, the YOLO v8n-UC-DAE model developed in this study is capable of meeting the requirements for grading the severity of tomato leaf mold and has effectively addressed the challenges associated with mobile deployment.

**Key words:** YOLO v8n model; tomato leaf mold; severity grading

番茄叶霉病是一种真菌病害,其病原菌是黄枝孢菌(*Cladosporium fulvum*)<sup>[1]</sup>,这种病害在潮湿、温暖的环境中容易发生,会严重影响番茄产量和品质。随着设施农业的发展,尤其是在温室或密植条件下叶霉病的发生更为普遍。该病在一般年份可能导致番茄减产10%~25%,病害暴发年份产量损失可达50%以上,甚至造成绝收<sup>[2]</sup>。传统的人工识别通过观察番茄叶片的表面特征来判断病害的种类及其严重程度。由于番茄病害类型繁多,传统人工识别效率低下,且容易出现误判。随着计算机视觉技术的迅速发展,利用计算机自动检测植物病害已成为一种趋势。

在番茄病害研究领域,传统机器学习方法曾经展现出广阔的应用前景。然而,现实中植物病害形状、位置多变,图像背景复杂,依靠人工设计特征的传统方法难以准确识别规模庞大的病害图像<sup>[3]</sup>。尤其当发病程度相似时,传统模型的识别效果欠佳,并且其鲁棒性较弱,难以适应不同环境与条件下的应用要求。近年来,随着智慧农业的发展,基于深度学习算法进行番茄病害识别的研究日益深入。如王少波<sup>[4]</sup>通过YOLO v5s进行训练识别番茄叶片病害发生程度,结果表明,YOLO v5s对单一病害的平均识别精度在80%左右。Zhang等<sup>[5]</sup>提出了一种基于ResNet-50的番茄叶片病害检测模型,通过引入目标定位、破坏重组和注意力区域划分模块,为植物病害识别提供了新的方法。胡玲艳等<sup>[6]</sup>提出了一种基于SqueezeNet模型的轻量级网络自适应特征提取方法——GKFENet,通过全局和关键特征提取模块实现了对番茄病害的精准识别。郭小清等<sup>[7]</sup>设计了基于AlexNet的多感受野识别模型,对番茄叶部病害及每种病害发病期进行识别。储鑫等<sup>[8]</sup>提出一种改进的YOLO v4算法应用于8种番茄病害识别,均取得了良好的效果。李仁杰等<sup>[9]</sup>通过改进YOLO v5模型用于实时检测自然环境下番茄叶片病害,改进后的YOLO v5平均识别精度有所提升。周巧黎等<sup>[10]</sup>提出了一种基于改进MobileNetV3的

番茄叶片病害识别方法,通过迁移学习和模型改进实现了较高识别准确率,且具有良好的鲁棒性。众多学者通过算法进行番茄病害分类研究,但针对病害发生程度分级的视觉检测方面的研究仍然较少,大多采用高光谱图像技术<sup>[11-14]</sup>对番茄病害进行检测。高光谱图像技术虽然拥有较高的准确率,但因仪器精密、传感器昂贵、效率较低等问题,在复杂的农业生产场景中无法推广应用。

针对上述问题,本研究基于YOLO v8n模型结合通用反转瓶颈<sup>[15]</sup>和级联群体注意力<sup>[16]</sup>,引入新的特征提取网络并更换检测头为双重注意力增强检测头,提出改进模型YOLO v8n-UC-DAE,实现了对番茄叶霉病发生程度的快速、准确分级识别,在保证高效检测的同时,降低了模型的参数量和计算量,便于模型在轻量化设备上部署。本研究旨在建立一种对番茄叶霉病发病程度准确实时的分级检测模型,帮助种植户及时采取防治措施,避免番茄叶霉病大面积暴发。

## 1 材料与方法

### 1.1 番茄叶霉病发病程度分级图像数据集构建

番茄的叶片、果实和茎部均可发生番茄叶霉病,导致植株迅速干枯死亡,番茄叶霉病具有来势猛、传播快等特点,在温暖湿润环境中如不能及时采取防治措施,短短7d就能蔓延至整个种植区,严重影响植株生长,造成绝产。在发病早期,番茄叶片正面出现淡黄色、形状不规则的褪绿斑点,叶片背面形成灰褐色至黑色霉层。随着病情发展,病斑逐渐扩大,叶片变黄并开始卷曲,最终导致叶片枯萎死亡。图1展示了番茄健康叶片和叶霉病发病各个阶段的叶片,微症期叶片有少量褪绿色病斑;发病初期叶片有稀疏的灰黄色病斑;发病中期叶片灰黄色病斑逐渐加深为灰黄色霉病斑;发病后期叶片霉层呈现黑褐色绒状,伴随叶片严重卷曲;发病晚期叶片残缺不全,植株黄化干枯。

根据国家标准NY/T 1858.2-2010<sup>[17]</sup>要求以及相关叶霉病发病情况<sup>[18]</sup>将其发病程度分为6个等

级,具体分级标准如表 1 所示。

本研究使用的图像来源于 PlantVillage 官网中的番茄健康叶片和叶霉病叶片数据集。经过整理和筛选,共获得 400 幅番茄健康叶片和 1 200 幅番茄不同等级叶霉病叶片。为了提高模型的鲁棒性和泛化

能力,对病害叶片进行了一系列剪裁翻转、亮度调整、增加噪声与高斯模糊等数据增强操作,将数据集扩充至 3 000 幅。图像数据集被随机分为训练集、测试集和验证集 3 组,训练集、测试集和验证集的占比按照 8 : 1 : 1 进行随机分配(表 1)。




图 1 番茄健康叶片和叶霉病发病各个阶段叶片的症状

Fig.1 Symptoms on tomato leaves across healthy and various leaf mold infection stages

表 1 番茄叶霉病发病程度的分级与样本数

Table 1 Disease severity grading and sample size for tomato leaf mold

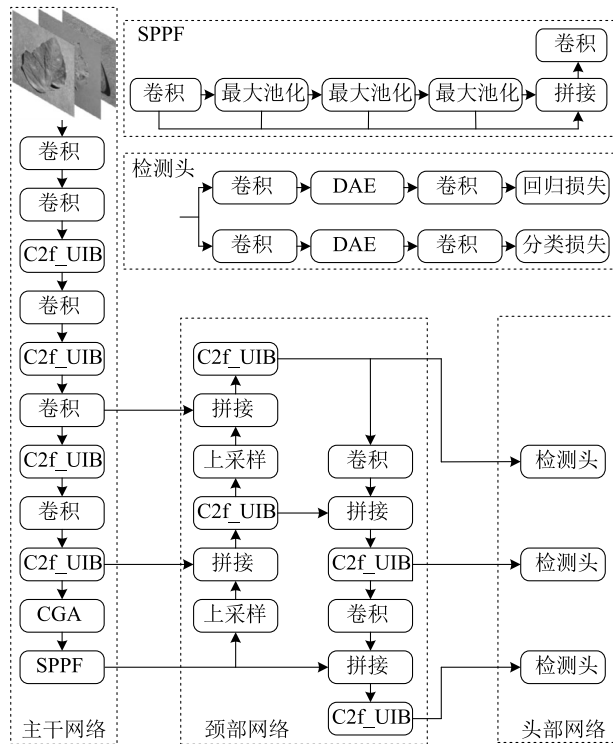
发病程度等级 (级)	特征	训练集叶片数 (张)	测试集叶片数 (张)	验证集叶片数 (张)	总计 (张)
0	无症状	492	60	62	614
1	叶片上出现褪绿色至黄色病斑	192	30	28	250
3	叶片上病斑产生一层稀疏的灰黄色霉	492	54	56	602
5	叶片上病斑产生明显的灰黄褐色霉	390	56	56	502
7	叶片上病斑产生灰褐色或黑褐色霉层,叶片发生卷曲	284	30	32	346
9	叶片上病斑呈黑褐色,并且叶片黄化干枯	550	70	66	686

## 1.2 轻量化番茄叶霉病发病程度分级检测模型

YOLO v8 系列模型在 COCO128 数据集上展现了显著的检测精度和速度提升,因此本研究将该系列模型作为视觉检测框架的基础进行性能改进,以适应番茄叶霉病发病程度分级检测。YOLO v8 网络由 4 部分组成,分别为输入端、骨干网络、颈部网络和头部网络<sup>[19]</sup>。YOLO v8 的主干结构与 YOLO v5 相似,将 C3 模块替换为 C2f 模块;主干结构末端使用空间金字塔池化(SPPF)模块,通过 3 个最大池化(Maxpool)层串联拼接,颈部网络使用 PAN-FPN 特征融合,结合 2 个上采样和多个 C2f 模块<sup>[20]</sup>。本研究改进后的 YOLO v8n 网络结构如图 2 所示,通过引入 MobileNetV4 的 UIB 模块到 C2f 模块中,在主干网络最高维特征后添加级联群体注意力机制模块(CGA),并将 HyCTAS 模型中自注意力机制检测头 Self-Attention 与原检测头结合,明显减少了模型的参数量和数据量,有效提升模型的检测能力和运行速度。

### 1.2.1 C2f\_UIB 模块的获取 YOLO v8 采用的 C2f

模块含有较多的瓶颈(Bottleneck)结构,在提取较多特征的同时导致了通道信息的过度冗余<sup>[19]</sup>。为了改进这一问题,并提高番茄叶霉病发病程度分级检测精度,本研究将 MobileNetV4 中的通用反转瓶颈(UIB)模块<sup>[15]</sup>引入 C2f 模块中(图 3)。在 C2f\_UIB 结构中,先通过 1 个 1×1 卷积(Cv1)对输入特征进行初步映射和通道调整,在 Cv1 之后对特征进行分割(Split)再执行 UIB 模块,实现多分支并行的特征提取:将输入特征拆分成多个子空间,每个分支能够更有针对性地执行“扩展-深度卷积-压缩”的过程,在不同细节上捕捉病害信息,最终在拼接(Concat)阶段融合分支输出,既综合多种特征,增强病害检测的鲁棒性,又避免单一路径通道过度冗余的问题,提升模型的特征表达能力与计算效率。与使用单一的 UIB 模块相比,C2f\_UIB 模块进一步强化了多尺度特征提取能力,并提升了对番茄叶霉病病灶细节的捕捉精度。而在每个 UIB 模块中,通过“扩展-深度卷积-压缩”的结构,在保持特征表达能力的同时减



C2f\_UIB;改进的反转瓶颈模块;CGA;级联群体注意力机制; SPPF;空间金字塔池化模块;DAE;双重注意力增强检测头。

图2 本研究改进后的YOLO v8n-UC-DAE网络结构图

Fig.2 Structure of the improved YOLO v8n-UC-DAE network in this study

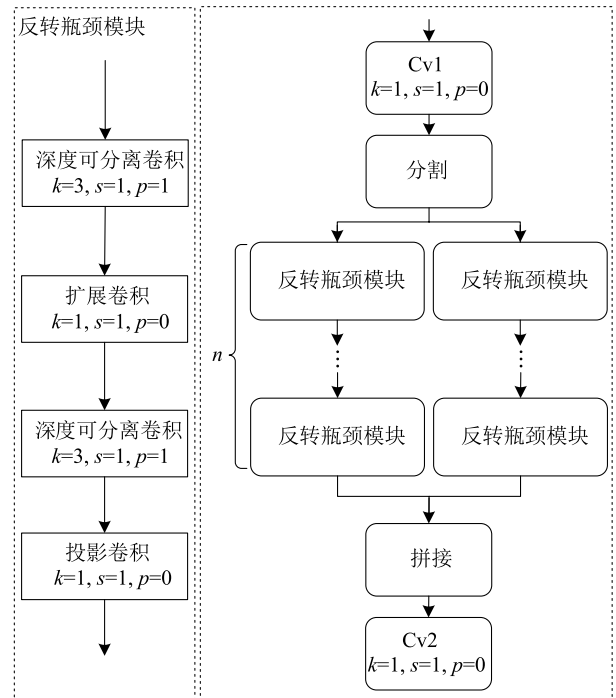
少计算复杂度和参数量。对输入的番茄叶霉病图像特征开始深度可分离卷积进行空间特征提取,精准捕捉病害区域的局部特征,通过扩展卷积将特征维度扩展,以便处理更复杂的病害特征,接着进行中间深度可分离卷积在更高维度的特征空间中深入挖掘病害症状的细节,最后通过投影卷积将特征压缩回目标通道数,以保持高效的计算性能,有效提升番茄叶霉病发病程度分级检测效果。

1.2.2 级联群体注意力机制模块(CGA) 级联群体注意力机制通过逐层处理输入序列,旨在捕捉不同层次的语义结构,主要包括群体注意力机制与级联处理过程两个核心部分。该注意力公式如下所示<sup>[16]</sup>:

$$\tilde{X}_{ij} = \text{Attn}(X_{ij}W_{ij}^Q, X_{ij}W_{ij}^K, X_{ij}W_{ij}^V) \quad (1)$$

$$\tilde{X}_{i+1} = \text{Concat}[\tilde{X}_{ij}]_{j=1,h} X_{ij}W_i^P \quad (2)$$

公式(1)中 $\tilde{X}_{ij}$ 是通过注意力机制 Attn 计算得到的结果。第  $j$  个头计算  $X_{ij}$  的自注意力,  $X_{ij}$  表示输入特征  $X_i$  的第  $j$  个切分,即  $X_i = [X_{i1}, X_{i2}, \dots, X_{ih}]$ , 并且  $1 \leq j \leq h$ 。  $h$  是头的总数,  $W_{ij}^Q$ 、 $W_{ij}^K$  和  $W_{ij}^V$  是将输



Cv1 和 Cv2 均为  $1 \times 1$  卷积层,用于调整输入输出特征通道并实现特征映射衔接。 $k$ :卷积核, $s$ :步长, $p$ :填充。

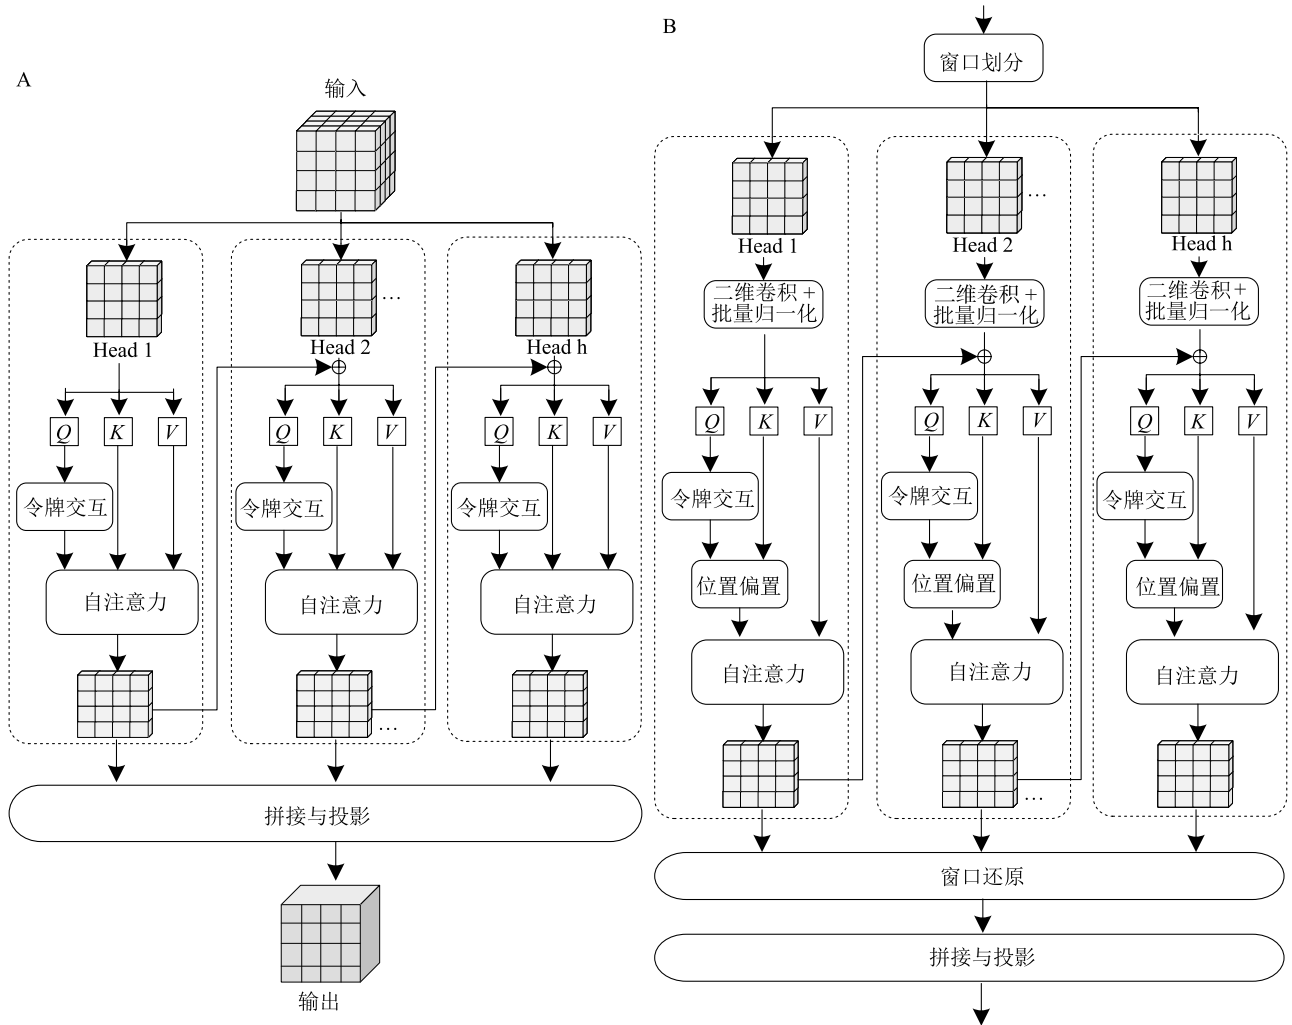
图3 本研究改进后的C2f\_UIB结构图

Fig.3 Structure of the improved C2f\_UIB in this study

入特征映射到不同子空间的投影层,注意力机制的作用是根据  $Q$  (查询向量)、 $K$  (键向量) 和  $V$  (值向量) 之间的关系,计算出对不同输入部分的关注程度,从而得到加权后的输出  $\tilde{X}_{ij}$ 。公式(2)中  $\tilde{X}_{i+1}$  是由一系列  $\tilde{X}_{ij}$  ( $1 \leq j \leq h$ ) 经过拼接(Concat 操作)后,再与  $X_{ij}W_i^P$  进行某种运算得到的。 $W_i^P$  是一个线性层,用于将拼接后的输出特征投影至与输入一致的维度。

原始 CGA 结构如图 4A 所示,本研究改进 CGA 结构分别添加卷积层、局部窗口划分、位置偏置和窗口逆变换,增加提取番茄叶霉病症状局部特征的能力,并且降低计算复杂度。改进后的 CGA 结构如图 4B 所示。

传统的全局注意力机制需要计算每个最小单元(Token)与序列中其他所有Token的相似度,其计算复杂度为  $O(n^2 \cdot d)$  (其中  $n$  为序列长度,  $d$  为每个Token的特征维度)。窗口划分技术将输入划分为多个局部窗口,并在每个窗口内计算自注意力,不仅保留局部特征提取能力,还减少了计算量。假设窗口大小为  $w \times w$ ,总的窗口数量为  $\frac{H}{w} \times \frac{W}{w}$ ,其中  $H$  和  $W$



A:原始 CGA 结构;B:改进 CGA 结构。Q:查询向量;K:键向量;V:值向量。

图 4 本研究对 CGA 结构进行改进

Fig.4 Structural improvements to the cascaded group attention (CGA) module proposed in this study

分别为输入特征图的高和宽。每个窗口的自注意力计算复杂度则为  $O(w2 \cdot d)$ , 整个特征图的计算复杂度降低程度如公式(3)所示。

$$O\left(\frac{H \cdot W}{w2} \cdot w2 \cdot d\right) = O(H \cdot W \cdot d) \quad (3)$$

在图像任务中,空间位置信息十分重要,直接影响叶霉病发病程度的分级效果。改进后的 CGA 结构引入了位置偏置,使得模型在计算自注意力时能够考虑相对位置的信息。即在自注意力机制引入相对位置编码,如公式(4)所示。

$$A_{ij} = \frac{Q_i \cdot K_j^T}{\sqrt{d_k}} + B_{ij} \quad (4)$$

式中,  $A_{ij}$  是注意力得分矩阵中的元素,  $Q_i$  表示第  $i$  个查询向量,  $K_j$  表示第  $j$  个键向量,  $K_j^T$  为其转置,  $d_k$

通常指键向量  $K_j$  的维度,  $\sqrt{d_k}$  用于对  $Q_i \cdot K_j^T$  的结果进行缩放,  $B_{ij}$  是位置偏置项。  $B_{ij}$  通过预设的编码矩阵表示,能够在计算注意力权重时赋予不同空间位置不同的权重,有助于模型在空间上捕捉到叶霉病变区域的位置特征。

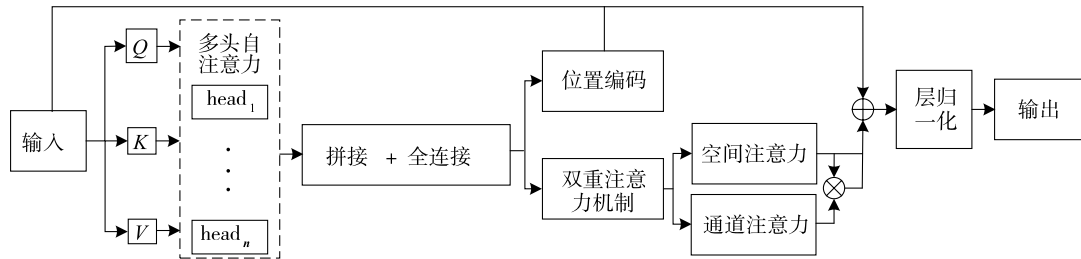
为了进一步提升效率,在每个 Head 前增加卷积操作使模型在输入自注意力层之前能够更好地进行叶霉病变区域的识别。

### 1.2.3 双重注意力增强的目标检测头 (DAEDH)

本研究设计了一种双重注意力增强目标检测头,命名为 DAEDH (Dual-attention enhanced detection head)。DAEDH 结合了多头自注意力机制 (MH-SA)<sup>[21]</sup> 和双重注意力机制<sup>[22]</sup>,通过空间注意力 (SA) 与通道注意力 (CA)<sup>[23]</sup> 模块的相互作用,帮助

模型聚焦于番茄叶霉病症状最为明显的区域。空间注意力模块能够增强病斑区域的特征提取,而通道注意力模块则突出病害症状相关的通道特征,从而提高模型对复杂背景下微小病害症状的识别能力。


DAEDH 显著提升了模型对番茄叶霉病发病程度分级检测的准确性和鲁棒性,DAEDH 结构如图 5 所示,CA 结构如图 6 所示,SA 结构如图 7 所示。



Q、K、V 见图 4 注。

图 5 本研究设计的双重注意力增强目标检测头结构图


Fig.5 Structure of the dual attention-enhanced detection head designed in this study



S: 逐元素相加。

图 6 通道注意力模块结构

Fig.6 Channel attention module structure



S: 逐元素相加。

图 7 空间注意力模块结构

Fig.7 Spatial attention module structure

在 DAEDH 中,首先 MHA 模块通过动态加权捕捉输入特征的全局关联性。输入特征经线性变换生成查询(Q)、键(K)和价值(V)矩阵。通过计算查

询向量(Q)和键向量(K)的点积,生成注意力权重矩阵A,并对V加权求和。其表达式为:

$$MHA(X) = \text{Concat}(head_1, head_2, \dots, head_n) W_o \quad (5)$$

$$head_i = \text{softmax}\left(\frac{Q_i K_i^T}{\sqrt{d_k}}\right) V_i \quad (6)$$

公式(5)中,MHA(X)表示多头自注意力对输入X的计算结果,Concat表示拼接操作,将多个注意力头的计算结果按特定方式连接,n表示注意力头的数量,W<sub>o</sub>为输出变换矩阵;公式(6)中head<sub>i</sub>表示第i个注意力头的输出结果,d<sub>k</sub>为缩放维度。

随后,通过双重注意力机制进一步优化特征表示。空间注意力(SA)模块通过逐像素加权提取关键区域特征,通道注意力(CA)模块通过全局加权优

化通道信息。其表达式为:

$$Z' = \sigma(W_2 \cdot \delta(W_1 \cdot Pool(V))) \odot V \quad (7)$$

公式(7)中, $Pool(V)$ 表示操作类型,全局平均池化用于通道注意力,卷积操作用于空间注意力; $W_1$ 和 $W_2$ 是全连接层的权重矩阵; $\delta$ 表示 ReLU 激活函数, $\sigma$ 是 Sigmoid 激活函数; $V$ 是输入特征矩阵。

空间注意力和通道注意力的结果通过逐元素相乘进行融合。生成双重增强的特征表示:

$$Z'' = A_s \odot A_c \odot V \quad (8)$$

公式(8)中, $Z''$ 表示融合后的特征; $A_s$ 表示空间注意力权重矩阵; $A_c$ 表示通道注意力权重矩阵; $V$ 表示输入特征矩阵,包含目标区域的原始特征表示; $\odot$ 表示逐元素乘法操作。

融合后的特征通过残差连接与输入特征相加,并进行层归一化处理,确保模型的稳定性和快速收敛。

### 1.3 试验环境的搭建和评价指标

本试验是基于系统版本为 Windows11 的计算机进行搭建,CPU 为 Intel(R) Core(TM) i9-13900HX@ 2.20 GHz,GPU 为 NVIDIA GeForce RTX 4060,显存为 24 G,深度学习框架为 Pytorch-2.5.0,编程语言为 Python-3.9.20,编译环境为 PyCharm,运行环境为 CUDA 12.7。试验过程中的模型均在该环境下进行训练。

训练过程中均采用相同的参数,具体参数如表 2 所示。

表 2 番茄叶霉病发病程度分级训练参数

Table 2 Training parameters for tomato leaf mold severity grading

参数	数值
训练总轮数	500
批量大小	16
图像尺寸	640×640
优化器	SGD
动量	0.937
初始学习率	0.01
权重衰减	0.000 5

考虑到番茄叶霉病发病程度分级的准确性和实时性,本研究选取精确度( $P$ )、召回率( $R$ )、平均精度均值( $mAP$ )、模型参数量( $Params$ )、模型计算量( $GFLOPs$ )以及 1 s 检测帧数( $FPS$ )作为模型性能的评价指标,相关计算公式如下:

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \times 100\% \quad (9)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \times 100\% \quad (10)$$

$$AP = \int_0^1 P(R) dR \quad (11)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n P_{AP_i} \quad (12)$$

在本研究中, $N_{TP}$ 表示模型正确检测叶霉病发病等级样本数; $N_{FP}$ 表示模型错误检测叶霉病发病等级样本数; $N_{FN}$ 表示模型未能检测到叶霉病发病等级的样本数; $AP$ 是  $P$ - $R$  曲线的积分,表示平均精确率; $mAP$ 表示模型在不同叶霉病发病程度分级检测上的平均检测精度;发病等级个数  $n$  为 6。

## 2 结果与分析

### 2.1 消融试验

消融试验可以有效证明不同模块的改进与结合对番茄叶霉病发病程度分级产生的影响。因此,本研究以 YOLO v8n 模型为基线模型,分析 UIB、CGA 以及 DAEDH 的有效性。具体消融试验结果如表 3 所示。

根据表 3 可知,与模型 1(基线模型 YOLO v8n)相比,模型 2 将 UIB 模块引入 C2f 模块中,精确度虽有所降低,但召回率、 $mAP_{50}$  和  $mAP_{50-95}$  分别提高了 7.6 个百分点、2.6 个百分点和 3.2 个百分点,模型计算量减少了 32.22%,权重减少了 32.86%,FPS 增加了 7.3 帧,1 s。这是由于 UIB 模块将部分标准卷积替换为更高效的深度可分离卷积和瓶颈结构,并且通过扩展通道和压缩通道的方式减少了实际参与计算的特征通道数。然而,消融试验结果表明,尽管轻量化改进大幅度减少了模型的参数量和计算量,但是也导致了部分特征表达能力下降,检测精确度下降。与模型 1 相比,模型 3 在主干网络输出的最后一层特征图后引入 CGA 注意力模块,增强了网络的全局上下文感知能力,精确率和召回率都有所提高,模型的计算量和权重都有所减少。模型 4 是将原检测头更换为改进后的自注意力检测头,加强了网络对细节信息的关注,与模型 1 相比,模型 4 的精确率、召回率、 $mAP_{50}$  和  $mAP_{50-95}$  均得到提升,计算量和权重下降,FPS 明显下降,这是由于自注意力机制计算复杂度较高,它需要对特征图中的每一对元素进行交互计算,增加了模型参数量。与模型 1 相比,模型 5 引入 UIB 模块和 CGA 注意力模块,降低了模型计算量和模型权重的同时,精确率和  $mAP_{50-95}$

均有所提升,但召回率和  $mAP_{50}$  都略微下降。模型 6 引入 UIB 模块和 DAEDH 检测头,优化了模型对叶霉病症状特征提取能力,增强了模型对发病程度分级细微特征区域的关注度,同时降低了模型在卷积操作中的运算量,与模型 1 相比,模型 6 大幅度减少了计算量和权重。模型 7 引入 CGA 注意力模块和 DAEDH 检测头,与模型 6 相比,模型 7 在计算量和权重略微增加的基础上,模型  $mAP_{50}$  有所上升。在

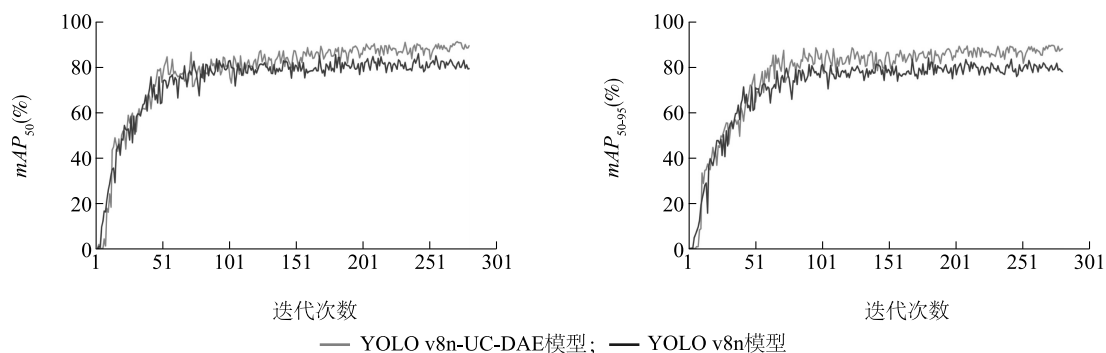
模型 8 中,将 3 种改进模型全部融入,最终将改进后模型与原始模型(模型 1)相比,精确率、召回率、 $mAP_{50}$  和  $mAP_{50-95}$  分别提升了 2.0 个百分点、7.7 个百分点、3.8 个百分点和 2.9 个百分点(图 8),模型计算量和权重分别减少 43.33% 和 32.86%,整体网络检测速度达 105.8 帧,1s,性能显著优于原始模型 YOLO v8n,满足了农业生产中的实时性和轻量化要求。

表 3 消融试验结果

Table 3 Results of ablation test

模型	模块			$P$ (%)	$R$ (%)	$mAP_{50}$ (%)	$mAP_{50-95}$ (%)	$GFLOPs$ (GB)	权重 (MB)	$FPS$ (帧,1 s)
	UIB	CGA	DAEDH							
模型 1	○	○	○	79.9	83.4	87.5	84.8	9.0	7.0	94.5
模型 2	※	○	○	77.1	91.0	90.1	88.0	6.1	4.7	101.8
模型 3	○	※	○	81.9	84.0	91.0	89.0	8.2	6.5	100.7
模型 4	○	○	※	80.3	89.4	89.3	87.7	7.0	6.1	42.8
模型 5	※	※	○	80.3	83.2	87.1	85.1	6.2	4.9	102.6
模型 6	※	○	※	82.2	89.2	90.3	88.4	5.1	4.5	103.2
模型 7	○	※	※	78.5	88.8	90.6	87.6	7.1	6.3	89.4
模型 8	※	※	※	81.9	91.1	91.3	87.7	5.1	4.7	105.8

UIB:反转瓶颈模块,CGA:级联群体注意力发病等级机制模块,DAEDH:基于双重注意力增强的检测头, $P$ :精确度, $R$ :召回率, $GFLOPs$ :模型计算量, $FPS$ :1 s 检测帧数, $mAP_{50}$ 表示在交并比阈值固定为 0.50 时,对番茄叶霉病发病等级各分级类别分别计算的平均精确率( $AP$ )的平均值。 $mAP_{50-95}$ 表示在交并比阈值从 0.50 到 0.95 的多组阈值下分别计算  $mAP$  后的平均值。※表示使用该模块;○表示不使用该模块。



$mAP_{50}$ 、 $mAP_{50-95}$ 见表 4 注。

图 8 YOLO v8n 改进前后  $mAP_{50}$  与  $mAP_{50-95}$  对比结果Fig.8 Comparison results of  $mAP_{50}$  and  $mAP_{50-95}$  before and after YOLO v8n improvements

Grad-CAM 通过计算类别得分相对于卷积层特征图的梯度生成热力图,显示出网络在作出预测时关注的图像区域<sup>[24]</sup>。本研究采用该可视化技术对 YOLO v8n 模型改进前后病害部位关注能力进行研究与分析,从图像可视化的角度评估 YOLO v8n-UC-DAE 模型(图 9)。从图 9 可见,随着病害逐级加重,YOLO v8n 模型改进前后都能够对病害部位进行比较精准的定位,改进后的模型在关注病害严重程度

区域时更加集中和突出。对于轻微病害(如 1 级、3 级),改进前的模型热力图显示关注区域较为分散,容易受到背景干扰,而改进后的模型则能够更精准地聚焦于病变的核心区域。随着病害程度的加深(如 5 级、7 级、9 级),改进前的模型对病变区域的关注强度不足,对部分区域甚至无法正确识别,而改进后的模型则展现出更强的关注能力,较为明显地提高了对病变区域的关注度。此外,热力图的边界

清晰度和高亮区域的集中性也表明,改进后的模型具有更好的特征提取能力和判别力。综上所述,改进后的 YOLO v8n-UC-DAE 模型在番茄叶片病害识

别中表现出更优的性能,能够有效排除无关信息的干扰,集中关注病斑区域,验证了 YOLO v8n-UC-DAE 模型对番茄叶霉病发病程度分级的有效检测。

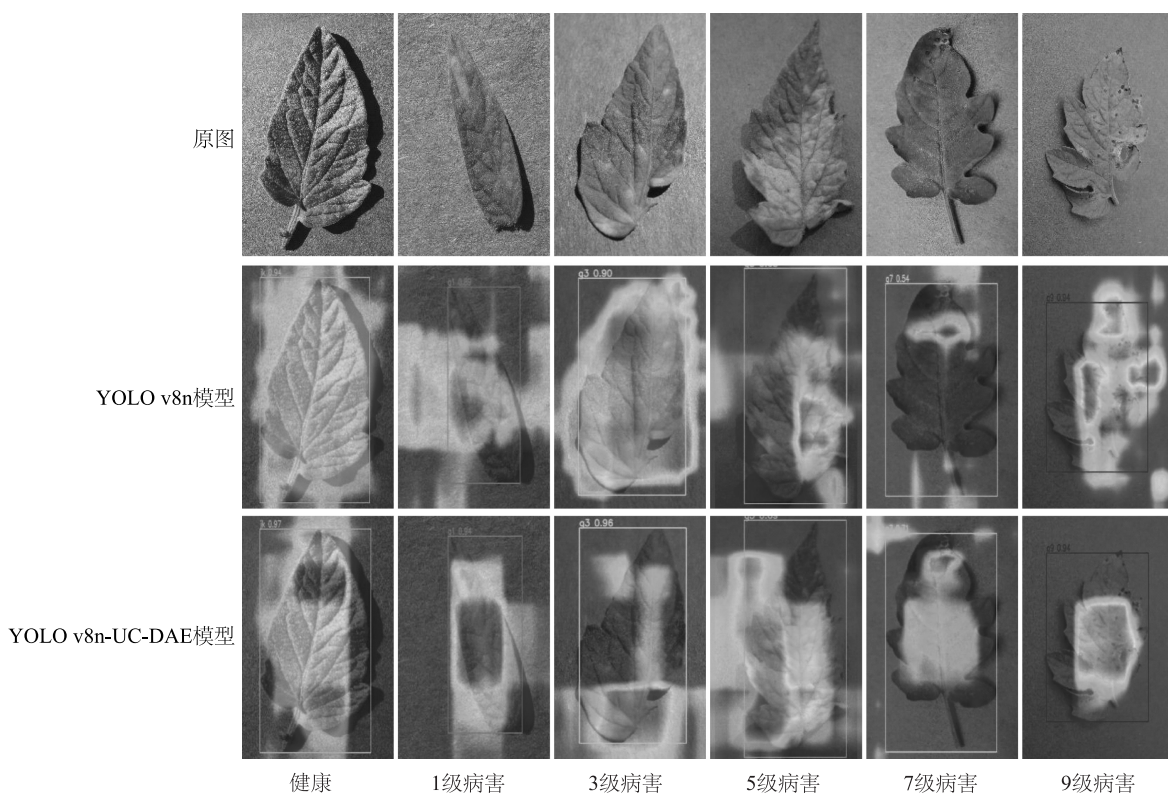


图9 YOLO v8n 模型改进前后病害部位关注能力热力图

Fig.9 Heatmaps of model attention to disease areas before and after YOLO v8n model improvements

根据表4可以得出, YOLO v8n 改进后的模型平均检测精度( $mAP$ )更高,尤其是在病害某些发病等级上的平均检测精度比改进前提高了10个百分点以上。病害等级为0级时,两个模型的 $mAP_{50}$ 和 $mAP_{50-95}$ 几乎相同,表明改进前后的差异对该等级影响较小。病害等级为1级时,改进后模型平均检测精度与改进

前相比表现出较明显的提升, $mAP_{50}$ 从92.6%提高到97.0%, $mAP_{50-95}$ 从87.5%提高到92.4%;病害等级为3级时, $mAP_{50}$ 从75.2%提升至86.5%, $mAP_{50-95}$ 从72.8%提升至85.1%。虽然在病害等级为5级和9级时,改进后模型的 $mAP$ 表现有所下降,但降幅相对较小,整体依然维持在较高水平。

表4 YOLO v8n 改进前后模型对番茄叶霉病发病程度分级的  $mAP$  对比

Table 4 Comparison of  $mAP$  for tomato leaf mold severity grading before and after YOLO v8n improvements

病害等级 (级)	$mAP_{50}$ (%)		$mAP_{50-95}$ (%)	
	YOLO v8n 模型	YOLO v8n-UC-DAE 模型	YOLO v8n 模型	YOLO v8n-UC-DAE 模型
0	99.5	99.5	98.4	97.8
1	92.6	97.0	87.5	92.4
3	75.2	86.5	72.8	85.1
5	79.7	77.6	75.1	72.8
7	80.3	88.9	76.3	85.0
9	97.4	98.0	93.3	93.0

$mAP_{50}$ 、 $mAP_{50-95}$ 见表3注。

## 2.2 不同轻量化主干网络改进模型对比

本研究以 C2f-UIB 为主干网络的 YOLO v8n 模型作为基线模型,通过替换主流轻量化特征提取的主干网络,例如 MobileViTv2、ShuffleNetv2、Faster-

NeT、GhostNetv2,在保持其他参数不变的前提下,对比不同主干网络改进模型对目标检测训练效果的影响(表 5、图 10)。

表 5 不同轻量化主干网络改进模型性能对比

Table 5 Performance comparison of improved models with different lightweight backbone networks

主干网络	$P$ (%)	$R$ (%)	$mAP_{50}$ (%)	$mAP_{50-95}$ (%)	$GFLOPs$ (GB)	权重(MB)
MobileViTv2	79.2	85.6	87.4	84.6	11.3	6.9
ShuffleNetv2	74.5	91.3	88.9	86.6	7.4	5.9
FasterNet	77.8	84.1	88.0	84.7	37.0	30.7
GhostNetv2	79.3	86.6	84.2	82.4	8.7	13.3
C2f-UIB	77.1	91.0	90.1	88.0	6.1	4.7

$P$ 、 $R$ 、 $mAP_{50}$ 、 $mAP_{50-95}$ 、 $GFLOPs$  见表 3 注。




图 10 不同主干网络改进模型检测结果对比

Fig.10 Detection performance comparison of improved models with different backbone networks

由表 5 可知,使用改进的 C2f-UIB 主干网络相较于使用 MobileViTv2、ShuffleNetv2、FasterNet、GhostNetv2 轻量化主干网络的模型,召回率、 $mAP_{50}$ 、 $mAP_{50-95}$ 、 $GFLOPs$  以及模型权重都有较大优势。部分轻量化主干网络改进模型的精确度优于改进的 C2f-UIB 主干网络模型,主要原因在于改进的 C2f-UIB 主干网络在特征提取过程中部分特征的表达能力受到抑制,导致精确度下降。因此,在主干网络的最高维度后引入了 CGA 注意力模块,以增强对番茄叶霉病症状特征的提取能力,从而提升模型的整体性能。

## 2.3 YOLO v8n 改进模型 YOLO v8n-UC-DAE 与其他模型对比

本研究将 YOLO v8n 改进模型 YOLO v8n-UC-DAE 与 YOLO v3-tiny、YOLO v5n、YOLO v7、YOLO v7-tiny、YOLO v10n、SSD 以及 Faster R-CNN 等主流目标检测网络模型进行对比,验证 YOLO v8n 改进模型 YOLO v8n-UC-DAE 的有效性(表 6、图 11)。从表 6 可知,9 个模型中 YOLO v8n 改进模型 YOLO v8n-UC-DAE 的精

度、召回率和平均精度最高,分别达到了 81.9%、91.1% 和 91.3%,模型计算量仅为 5.1 GB,模型占用内存大小仅为 4.7 MB。与 YOLOv3-tiny、YOLO v5n、YOLO v7、YOLO v7-tiny、YOLO v10n、YOLO v8n、SSD 以及 Faster R-CNN 模型相比,YOLO v8n-UC-DAE 模型的精确度分别提高 22.6 个百分点、8.3 个百分点、14.6 个百分点、10.6 个百分点、6.7 个百分点、2.0 个百分点、1.6 个百分点和 0.5 个百分点,召回率分别提高 9.5 个百分点、2.2 个百分点、5.8 个百分点、11.6 个百分点、6.3 个百分点、7.7 个百分点、7.9 个百分点和 9.2 个百分点, $mAP_{50}$  分别提高 11.3 个百分点、4.2 个百分点、8.6 个百分点、11.7 个百分点、5.2 个百分点、3.8 个百分点、4.2 个百分点和 2.9 个百分点,同时计算量分别减小 73.0%、33.8%、95.2%、61.4%、37.0%、43.3%、94.8%、96.3%,模型权重大小分别减小 80.7%、20.3%、93.7%、61.8%、25.4%、32.9%、94.8%、95.6%。相较于其他模型,YOLO v8n-UC-DAE 对于番茄叶霉病发病程度的分级检测效果更好。

表 6 不同模型对番茄叶霉病发病程度分级检测结果对比

Table 6 Comparison of detection results of different models for tomato leaf mold severity grading

模型	$P$ (%)	$R$ (%)	$mAP_{50}$ (%)	$GFLOPs$ (GB)	权重 (MB)
YOLO v3-tiny	59.3	81.6	80.0	18.9	24.4
YOLO v5n	73.6	88.9	87.1	7.7	5.9
YOLO v7	67.3	85.3	82.7	105.2	74.9
YOLO v7-tiny	71.3	79.5	79.6	13.2	12.3
YOLO v10n	75.2	84.8	86.1	8.1	6.3
YOLO v8n	79.9	83.4	87.5	9.0	7.0
SSD	80.3	83.2	87.1	97.5	90.5
Faster R-CNN	81.4	81.9	88.4	137.0	108.0
YOLO v8n-UC-DAE	81.9	91.1	91.3	5.1	4.7

$P$ 、 $R$ 、 $mAP_{50}$ 、 $mAP_{50-95}$ 、 $GFLOPs$  见表 3 注。




图 11 不同模型检测结果

Fig.11 Detection results of different models

### 3 结论

本研究提出的轻量化番茄叶霉病发病程度分级检测模型 YOLO v8n-UC-DAE,通过在 YOLO v8n 基线模型中引入 MobileNetV4 中的 UIB 模块、级联群体注意力机制模块(CGA)、位置偏置以及双重注意力增强检测头,有效提升了番茄叶霉病发病程度分级检测的精度和效率。消融试验结果表明,每项改进措施对模型性能均有较大提升,尤其是级联群体注意力机制模块 CGA 的引入表现出了明显的优化效果。通过病症部位关注能力热力图直观展示了该模型在番茄叶霉病发病程度分级检测中的优越性。与原始 YOLO v8n 模型相比,改进后的模型在  $P$ 、 $R$ 、 $mAP_{50}$  和  $mAP_{50-95}$  等指标上分别提高了 2.0 个百分点、7.7 个百分点、3.8 个百分点和 2.9 个百分点。同时,模型的计算量和权重分别降低了 43.33% 和 32.86%,为在移动端部署提供了充分的支持。在与其他轻量化主干网络(如 MobileViTv2、ShuffleNetv2、FasterNet、GhostNetv2)改进模型进行对比后,

YOLO v8n-UC-DAE模型的番茄叶霉病发病程度分级检测性能表现优异。此外,与 YOLO 系列、SSD 以及 Faster R-CNN 等主流目标检测模型相比,YOLO v8n-UC-DAE 模型在性能和效率方面均有出色表现。YOLO v8n-UC-DAE 模型不仅在番茄叶霉病发病程度分级检测任务中实现了性能的突破,还为移动端深度学习模型的轻量化应用提供了有效解决方案。

目前该模型仅针对番茄叶霉病的发病程度进行分级检测。考虑到番茄存在多种不同类型病害,未来研究需要涉及多种病害发病程度分级检测。为了提高模型的普适性和实用性,需探索将不同病害的发病程度分级检测融合在一个模型中,从而实现对不同病害的精准化诊断。

#### 参考文献:

- [1] 李江峰. 番茄叶霉病的诊断与综合防治技术[J]. 特种经济动植物, 2023, 26(7): 119-121.
- [2] 张雪辉. 番茄叶霉病的发生与防治[J]. 现代园艺, 2012(13): 68.

- [3] 吴华瑞. 基于深度残差网络的番茄叶片病害识别方法[J]. 智慧农业, 2019, 1(4): 42-49.
- [4] 王少波. 基于光谱信息和图像信息的番茄叶片病害识别[D]. 昆明: 云南师范大学, 2024.
- [5] ZHANG D, HUANG Y, WU C, et al. Detecting tomato disease types and degrees using multi-branch and destruction learning[J]. *Computers and Electronics in Agriculture*, 2023, 213: 108244.
- [6] 胡玲艳, 周 婷, 刘 艳, 等. 基于轻量级网络自适应特征提取的番茄病害识别[J]. 江苏农业学报, 2022, 38(3): 696-705.
- [7] 郭小清, 范涛杰, 舒 欣. 基于改进 Multi-Scale AlexNet 的番茄叶部病害图像识别[J]. 农业工程学报, 2019, 35(13): 162-169.
- [8] 储 鑫, 李 祥, 罗 斌, 等. 基于改进 YOLOv4 算法的番茄叶部病害识别方法[J]. 江苏农业学报, 2023, 39(5): 1199-1208.
- [9] 李仁杰, 宋 涛, 高 婕, 等. 基于改进 YOLOv5 的自然环境下番茄患病叶片检测模型[J]. 江苏农业学报, 2024, 40(6): 1028-1037.
- [10] 周巧黎, 马 丽, 曹丽英, 等. 基于改进轻量级卷积神经网络 MobileNetV3 的番茄叶片病害识别[J]. 智慧农业, 2022, 4(1): 47-56.
- [11] 孟凯鑫. 基于高光谱成像技术的番茄叶斑病与枯萎病早期检测方法研究[D]. 泰安: 山东农业大学, 2024.
- [12] YAN Z, HUA-RUI W, HUA-JI Z. Hyperspectral latent period diagnosis of tomato Gray Mold based on TLBO-ELM model [J]. *Spectroscopy and Spectral Analysis*, 2022, 42(9): 2969-2975.
- [13] 崔江南, 付 芸, 赵 森, 等. 基于高光谱成像的番茄叶霉病的无损检测[J]. 长春理工大学学报(自然科学版), 2022, 45(4): 65-71.
- [14] 周占坤. 基于 THz-NIR 高光谱相融合的番茄病虫害检测研究[D]. 镇江: 江苏大学, 2022.
- [15] QIN D, LEICHNER C, DELAKIS M, et al. MobileNetV4: universal models for the mobile ecosystem[C]. Berlin: Springer, 2024.
- [16] LIU X, PENG H, ZHENG N, et al. EfficientViT: memory efficient vision transformer with cascaded group attention[EB/OL]. [2023-05-12] (2024-10-22). <https://arxiv.org/abs/2305.07027>.
- [17] 中华人民共和国农业农村部. 番茄主要病害抗病性鉴定技术规范: NY/T 1858.2-2010[S]. 北京: 中国标准出版社, 2010.
- [18] 李国花, 王晓敏, 赵宇飞, 等. 180 份番茄种质资源对 3 种主要叶部病害的田间抗病性评价[J]. 新疆农业科学, 2021, 58(4): 741-755.
- [19] XIE S, SUN H. Tea-YOLO v8s: a tea bud detection model based on deep learning and computer vision[J]. *Sensors*, 2023, 23(14): 6576.
- [20] LOU H, DUAN X, GUO J, et al. DC-YOLO v8: small-size object detection algorithm based on camera sensor[J]. *Electronics*, 2023, 12(10): 2323.
- [21] WU C, WU F, GE S, et al. Neural news recommendation with multi-head self-attention[C]. Hong Kong: Association for Computational Linguistics, 2019.
- [22] FU J, LIU J, TIAN H, et al. Dual attention network for scene segmentation[C]. Long Beach: IEEE, 2019.
- [23] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C]. Munich: Springer, 2018.
- [24] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: visual explanations from deep networks via gradient-based localization[J]. *International Journal of Computer Vision*, 2020, 128(2): 336-359.

(责任编辑: 黄克玲)