

DOI: 10.13733/j.jcam.issn.2095-5553.2026.02.014

卢彦梅, 陈明东, 史宇亮, 等. 基于改进 YOLOv8n 的黄瓜叶片病害识别[J]. 中国农机化学报, 2026, 47(2): 94-100, 107

Lu Yanmei, Chen Mingdong, Shi Yuliang, et al. Cucumber leaf disease recognition based on improved YOLOv8n [J]. Journal of Chinese Agricultural Mechanization, 2026, 47(2): 94-100, 107

基于改进 YOLOv8n 的黄瓜叶片病害识别*

卢彦梅, 陈明东, 史宇亮, 王家胜, 刘晓童, 胡鹏翔

(青岛农业大学机电工程学院, 青岛市, 266109)

摘要:为快速准确地检测出复杂自然环境下的黄瓜叶片病害目标,针对不同天气、角度、方向以及距离等因素造成黄瓜叶片图像识别准确率低的问题,构建黄瓜叶片数据集图像 6 620 幅,种类包括霜霉病、白粉病、晚疫病及正常叶片,并基于 YOLOv8n 模型提出 AKGAM—YOLOv8 模型。在 Bottleneck 网络层中引入可变核卷积 AKConv,降低模型参数与计算开销,使原模型更加轻量化。在此基础上,使用特征融合网络 BiFPN 与注意力机制 GAM,在不降低检测速度的同时提高模型对细小特征的提取能力。更改原模型损失函数为 WIoU 损失函数,梯度下降速度和收敛后损失值比原模型有优势。试验结果表明,改进后模型的黄瓜叶片病害识别精确率为 97.21%,模型权重为 13.22 MB,与原模型相比,模型权重缩小为基线网络的 56.42%,精确率提升 1.71%,平均精度均值提升 3.04%,满足黄瓜叶片病害实时检测的要求,并可为复杂自然环境下的农作物病害识别检测提供理论依据。

关键词:黄瓜叶片病害;目标检测;YOLOv8n;轻量化;AKConv 卷积;注意力机制

中图分类号:S126; S436.412 **文献标识码:**A **文章编号:**2095-5553 (2026) 02-0094-08

Cucumber leaf disease recognition based on improved YOLOv8n

Lu Yanmei, Chen Mingdong, Shi Yuliang, Wang Jiasheng, Liu Xiaotong, Hu Pengxiang

(College of Mechanical and Electrical Engineering, Qingdao Agricultural University, Qingdao, 266109, China)

Abstract: In order to detect cucumber disease targets in complex natural environment quickly and accurately, aiming at the problem of low accuracy of cucumber leaf image recognition caused by different weather, angle, direction and distance, this study constructed 6 620 images of cucumber leaf data sets, including downy mildew, powdery mildew, late blight and normal leaves, and proposed AKGAM—YOLOv8 model based on YOLOv8n model. Firstly, the variable kernel convolution AKConv is introduced into the Bottleneck network layer to reduce the model parameters and computational overhead, making the original model more lightweight. On this basis, the feature fusion network BiFPN and the attention mechanism GAM are used to improve the model's ability to extract small features without reducing the detection speed. By changing the loss function of the original model to the WIoU loss function, the gradient descent speed and the loss value after convergence are superior to the original model. The experimental results show that the accuracy rate of cucumber disease recognition of the improved model is 97.21%, and the model weight is 13.22 MB. Compared with the original model, the model weight is reduced to 56.42% of the baseline network, the accuracy rate is increased by 1.71%, and the average accuracy is increased by 3.04%. It meets the requirements of real-time detection of cucumber diseases, and provides a theoretical basis for crop disease recognition and detection in complex natural environments.

Keywords: cucumber leaf disease; target detection; YOLOv8n; lightweight; AKConv convolution; attention mechanism

0 引言

黄瓜,作为一种全球广泛种植的蔬菜作物,其在农

业生产中具有重要地位^[1, 2]。然而,黄瓜在生长过程中常受到各种病害的侵扰,其中黄瓜叶片病害尤为常见且难以识别。这些病害严重影响了黄瓜的产量和品

收稿日期:2024 年 5 月 18 日 修回日期:2024 年 8 月 16 日

* 基金项目:山东省农业重大应用技术创新项目(662/2318120)

第一作者:卢彦梅,女,1998 年生,山东日照人,硕士研究生;研究方向为农业工程与信息技术。E-mail: luyanmei12345@163.com

通讯作者:陈明东,男,1978 年生,吉林扶余人,博士,副教授,硕士;研究方向为智能农业装备设计。E-mail: mingdong3202@163.com

质,给农业生产带来了巨大的经济损失。因此,对黄瓜叶片病害的准确识别与防治已成为农业科研领域的热点问题。随着现代图像识别技术的发展,传统农业病害类型辨别及自动诊断已向智能化方向发展^[3-5]。由于黄瓜叶片病害种类较多,病情容易在短时间内迅速扩散且难以管理,及时识别和检测黄瓜叶片病害成为农业生产管理中一项重要的任务。

目前,国内外针对农作物病害检测算法的研究已取得一定进展。刘诗怡等^[6]提出一种DCNSE—YOLOv7深度学习算法来实现黄瓜叶片病虫害检测与识别,更改主干特征提取网络中的最后一个特征层卷积为DCNv2,并在模型中引入SENet注意力机制、K—means++聚类算法以及Focal—EIoU损失函数,但该模型计算量较大,对硬件设备要求较高。Zhang等^[7]为丰富番茄叶片病害特征提出引入渐进非局部均值算法的多通道自动定向递归注意网络,可降低特征识别难度,但信道数的选取使识别精度有所下降。兰玉彬等^[8]使用GhostNet网络中的Ghost模块和Ghost BottleNeck结构改进到YOLOv5s模型中,并添加CA注意力机制模块,该模型在一定程度上减少了病虫害图像小目标丢失的可能,并增强了特征提取能力,但模型占用内存大且推理速度较低。王卫星等^[9]为实现荔枝病虫害检测提出YOLOv4—GCF模型,该模型引入轻量化网络GhostNe及低成本的卷积Ghost Module,模型识别精度较高但运算成本较大。李大湘等^[10]为提高苹果叶部病虫害识别精度设计了一种细粒度知识蒸馏模型,可使用少量参数并缩短模型推理时间,但计算过程较为复杂。李好等^[11]使用公开数据集PlantVillage为数据集来源,在ShuffleNetV2单元的基础上,加入ECA注意力机制与H—Swish激活函数,较大地提高了病虫害识别平均精确率,可达99.24%。蒋丰千等^[12]基于神经网络系统对生姜炭疽病、姜瘟病、根结线虫病和白星病识别诊断,并引入新的Swish激活函数、BN层以及Gabor滤波器,但该模型需大量数据集运算来提高其识别精度。田凯等^[13]通过建立Fisher判别函数对病虫害叶片上病斑的颜色、形状以及纹理特征进行识别,该模型的分割及判定方法较为传统,叶片病虫害识别精确率较低。

尽管针对农作物病害检测方法的研究已取得较大进展,但对于复杂背景下的细小特征检测仍存在不足。本文以黄瓜叶片病害为例,基于YOLOv8n模型提出一种改进的黄瓜叶片病害识别检测算法,在Battleneck部分使用AKConv变核卷积,轻量化模型的同时,可根据数据集和检测目标灵活调整卷积核的大小和形状,引入GAM注意力机制,增强模型对于黄瓜叶片病害的提取能力,利用特征融合网络BiFPN进

一步提升整体模型的泛化能力和鲁棒性。最后将Wise—IoU损失函数替代原损失函数,以提高黄瓜叶片病害识别的精确性及有效性,并与YOLOv8n、VGG16和Faster R—CNN等主流模型进行对比,检测改进模型的性能与效果。

1 材料与方法

1.1 数据集介绍

黄瓜叶片病害类型主要为霜霉病^[14]、白粉病^[15]和晚疫病^[16]等。霜霉病病害特征主要为叶上起初出现褪绿斑,逐渐呈不规则黄色斑,潮湿时子叶背面产黄瓜霜霉病生灰黑色霉层。白粉病病害特征主要为叶片正面、背面产生白色近圆形的小粉斑,逐渐扩大后成边缘不明显的连片白粉斑,严重时整个叶片布满一层白粉。晚疫病病害特征主要为由叶片边缘开始,向里产生圆形或不规则的水渍状病斑,严重者茎端部位和各侧芽呈暗绿色水渍状软腐,叶片枯死。叶片病害图像如图1所示。




图1 病害图片

Fig. 1 Picture of the disease

黄瓜叶片病害数据图像在2023年6—8月于青岛农业大学温室采集,拍摄时间为8:00—18:00,图像采集设备为Xiaomi K40智能手机和佳能G7Xmark II型相机。在自然环境下采集不同状况时的病害图像,其中包括不同天气、角度、方向以及距离,获得526幅病害图像。同时,利用网上公开数据集进行数据增加,得到662幅原始数据集。为减少神经网络对于病害图像检测的过拟合,提高模型的泛化性和鲁棒性,采用翻转、镜像、亮度调节、高斯噪声以及模糊处理等方法扩充数据集,并手工筛选,删除模糊不清、过度重复以及噪声过大的数据集,共获得6 620幅图像制作数据集。

1.2 数据预处理

利用LabelImg软件^[17]中的VOC格式对样本图像进行标注,使用最大矩形框将叶片病害区域框出,以霜霉病、白粉病、晚疫病、正常叶片4种标签对数据集进行人工标注,并按照8:2:1的比例将数据集划分为训练集、验证集和测试集,完成黄瓜叶片病害数据集的构建。

经过这些增强措施后,数据集的总量增加至 6 620 幅图像,如表 1 所示。所有这些预处理步骤均通过 LabelImg 数据服务完成。

表 1 黄瓜叶片病害数据集的详细信息

Tab. 1 Detailed information on cucumber disease dataset 幅

标签	数据增强		数据划分		
	原始	扩充	训练	测试	验证
正常	200	1 719	1 251	312	156
霜霉病	160	1 599	1 163	291	145
白粉病	187	1 567	1 140	285	142
晚疫病	172	1 735	1 263	315	157
总计	719	6 620	4 817	1 203	600

1.3 YOLOv8 算法简介

YOLOv8 主要特点是可拓展,开源库不仅能用于 YOLO 系列模型,也能够支持非 YOLO 模型以及分类分割姿态估计等各类任务。YOLOv8 算法主要包括

4 个部分,即输入端、骨干网络、颈部网络及头部网络^[18]。骨干网络中的第一层卷积由原本的 6×6 卷积改为 3×3 ,并参考 YOLOv7 ELAN 将 C3 模块改为 C2f 模块,并相应调整模块深度^[19]。颈部网络采用路径聚合网络结构以提升网络对不同缩放尺度对象的特征融合能力^[20]。优化部分较多的为头部网络,由原先的耦合头改为解耦头结构,不再有之前的 Objectness 分支,而是直接解耦成分类任务和回归任务。同时也将 Anchor-Based 改为 Anchor-Free4,分类损失函数为 BCE Loss,回归损失函数为 DFL Loss+CIoU Loss,采用 Task-Aligned Assigner 样本分配策略^[21]。

1.4 黄瓜病虫害识别算法及改进

针对目前黄瓜叶片病害检测存在算法参数量大、识别准确率低以及运行速度慢等缺点,对原 YOLOv8n 模型进行更改,改进后 AKGAM—YOLOv8 模型的体系结构如图 2 所示。

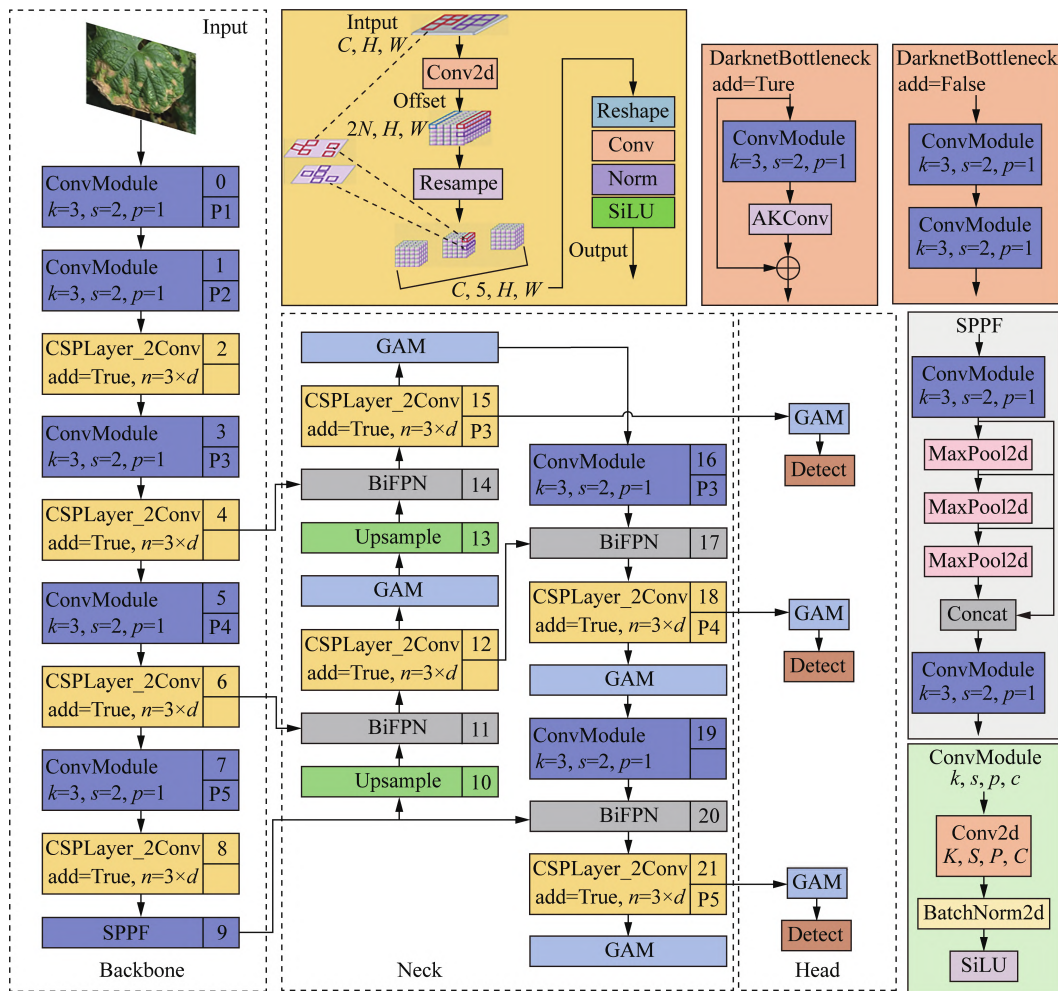


图 2 AKGAM—YOLOv8 模型的体系结构

Fig. 2 Architecture of the AKGAM—YOLOv8 model

1) 引入 AKConv 轻量级架构。AKConv 通过其创新的可变核卷积设计,为卷积神经网络带来显著的性能提升。其能够根据不同的数据集和目标灵活调整

卷积核的大小和形状,从而实现更高效的特征提取。

2) 引入 BiFPN 特征融合网络。提高多尺度特征提取能力,旨在优化特征层次结构,更好地捕获不同尺度

的目标信息。其设计核心在于通过双向的方式,充分融合高层和低层特征,提高检测模型对目标的感知度。

3) 添加 GAM 注意力机制^[22]。GAM 注意力机制可减少信息损失,同时放大大局交互表示来提高深度神经网络的性能,更好地提取样本中的关键信息。

4) 将损失函数 CIoU 替换成 Wise-IoU^[23]。动态非单调聚焦机制使用“离群度”替代 IoU 对锚框进行质量评估,并提供了明智的梯度增益分配策略。该策略在降低高质量锚框竞争力的同时,也减小了低质量示例产生的有害梯度。这使得 WIoU 可以聚焦于普通质量的锚框,并提高检测器的整体性能。

1.5 引入 AKConv 轻量级架构

对黄瓜叶片病害进行识别检测时,黄瓜叶片病害种类较多,形状大小不同,在自然复杂环境中会呈现不同视角、光照和大小病斑形态的变化,因此模型在提取病害图像特征时存在几何变换的局限性。为提高模型对形状特征识别能力,在 YOLOv8 网络模型的 Bottleneck 层添加 AKConv 可变核卷积,如图 3 所示,其可根据实际需求调整其大小和形状,从而更有效地适应不同目标的变化,对不同卷积核的大小,利用初始采样坐标增强处理图像目标的灵活性,还能够通过线性增减卷积参数的数量,轻量化的同时较好地提高模型性能。




图 3 AKConv 轻量级架构

Fig. 3 AKConv lightweight architecture

可变形卷积通过学习偏移量改变卷积计算位置,从而改变卷积核的形状,但其窗口大小固定为 K ,随 K 值增加相应参数会迅速增加,并且卷积核参数无法改变。AKConv 可变核卷积改变 $K \times K$ 参数的限制,可以有任意参数。为适应不规则卷积核的采样网络,AKConv 可变核卷积采用任意大小卷积的算法生成初始采样坐标,并解决不规则采样坐标与相应卷积大小的匹配问题。同时,利用卷积运算得到相应核的偏移量,修改后的坐标由偏移和原始坐标求和得到,并使用差值和重采样获取相应位置的特征。

1.6 引入 BiFPN 特征融合网络

多尺度特征表示是目标检测的重点方向,主要难点是如何有效地表示和处理多尺度特征。FPN 提出一种自上而下的途径来组合多尺度特征。PANet 在 FPN 之

上添加一个额外的自下而上的路径聚合网络;NAS-FPN 利用神经架构搜索来自动设计特征网络拓扑。虽然实现更好的性能,但 NAS-FPN 在搜索过程中需要数千 GPU 小时,且生成的特征网络不规则。因此,引入 BiFPN 特征融合网络,BiFPN 具备高效的双向跨尺度连接和加权特征融合能力,不仅能够不同层级间实现更全面的信息流通与融合,还能根据不同特征的重要性自适应地调整融合策略,从而优化多尺度特征的融合效果,并提升特征表示的精确度。网络结构如图 4 所示。




图 4 特征融合网络结构

Fig. 4 Feature fusion network structure

在特征融合过程中,不同输入特征的不同分辨率会导致输出特征的贡献不等,自然条件下采集的黄瓜叶片病害检测目标较多,BiFPN 采用快速归一化融合模块平衡不同特征权重,可提取黄瓜叶片病害目标的深层信息,提高识别精确率。输出特征图 O 的计算如式(1)所示。

$$O = \sum_i \frac{\omega_i}{\epsilon + \sum_j \omega_j} \cdot I_i \quad (1)$$

式中: ϵ ——很小的常数;

I_i ——第 i 级输入特征;

ω_j ——对应于每个输入的可学习权重。

为确保 ω_i 始终非负,在其后应用 ReLU 激活函数。为维护数值的稳定性,通过归一化使权重的值在 0~1 逐渐减小。以特征层 P4 为例,中间特征 P_4^{id} 描述如式(2)所示,而输出特征 P_4^{out} 描述如式(3)所示。

$$P_4^{id} = \text{Conv} \left[\frac{\omega_1 \cdot P_4^{in} + \omega_2 \cdot \text{Resize}(P_5^{in})}{\omega_1 + \omega_2 + \epsilon} \right] \quad (2)$$

$$P_4^{out} = \text{Conv} \left[\frac{\omega_1' \cdot P_4^{in} + \omega_2' \cdot P_4^{id} + \omega_3' \cdot \text{Resize}(P_3^{out})}{\omega_1' + \omega_2' + \omega_3' + \epsilon} \right] \quad (3)$$

式中: $\omega_1', \omega_2', \omega_3'$ ——学习权重。

将 YOLOv8 原特征融合网络替换为 BiFPN,不仅能够根据不同尺度的特征分配权重,还可以跨尺度地抑制权重或增强特征表达,从而进一步强化特征融合,提升目标检测的性能。

1.7 GAM 注意力机制

为提高目标检测的准确性,各种注意力机制也在不断优化更新,GAM 全局注意力机制是基于 CBAM

卷积块注意力模块提出的新模块。GAM 和 CBAM 注意力机制同样使用了通道注意力机制和空间注意力机制。但是不同的是对通道注意力和空间注意力的处理。对于输入特征图,首先进行维度转换,经过维度转换的特征图输入到 MLP,再转换为原来的维度,进行 Sigmoid 处理输出,如图 5 所示。




图 5 通道注意力模块

Fig. 5 Channel attention module

对于 SAM, GAM 主要使用了卷积处理,类似 SE 注意力机制,先将通道数量减少,再将通道数量增加。首先通过卷积核为 7 的卷积缩减通道数量,减少计算量,再经过一个卷积核为 7 的卷积操作,增加通道数量,保持通道数量的一致。最后经过 Sigmoid 输出,如图 6 所示。为减少信息分散和放大全局维度的交互特征,增强模型性能和病害特征表达能力,在 YOLOv8n 模型中引入 GAM 全局注意力机制,更好地提取图像中的重要信息,实现复杂自然背景条件下黄瓜叶片病害的精准识别。




图 6 空间注意力模块

Fig. 6 Spatial attention submodule.

1.8 WIoU 损失函数

在黄瓜叶片病害检测识别中,细小特征的识别较为关键。YOLOv8 原网络模型中的预测边框坐标损失函数采用 CIoU Loss,其在 DIoU 损失的基础上引入预测边界框与真实边界框的长宽比,使损失函数更加关注边界框的形状,但 CIoU 损失为单调聚焦机制,对复杂样本的检测精度较低。CIoU 损失函数 L_{CIoU} 计算如式(4)~式(7)所示。

$$L_{CIoU} = L_{IoU} + \frac{(x - x_{gt})^2 + (y - y_{gt})^2}{W_g^2 + H_g^2} + \alpha v \quad (4)$$

$$\alpha = \frac{v}{L_{IoU} + v} \quad (5)$$

$$v = \frac{4}{\pi^2} (\arctan \frac{w}{h} - \arctan \frac{w_{gt}}{h_{gt}})^2 \quad (6)$$

$$L_{IoU} = \frac{W_i H_i}{w h + w_{gt} h_{gt} - W_i H_i} \quad (7)$$

式中: $w, h, (x, y)$ ——预测框的宽、高和中心坐标;

$w_{gt}, h_{gt}, (x_{gt}, y_{gt})$ ——真实框的宽、高和中心坐标;

W_i, H_i ——交集宽、高;

α ——权重函数,用于平衡参数;

v ——纵横比度量函数,用于衡量高宽比一致性。

选用动态非单调聚焦机制 WIoU 替换原损失函数,其损失函数 L_{WIoU} 如式(8)所示。

$$L_{WIoU} = r R_{WIoU} L_{IoU} \quad R_{WIoU} \in [1, e], L_{IoU} \in [0, 1] \quad (8)$$

式中: R_{WIoU} ——距离聚焦机制,用于放大普通适量锚框的 L_{IoU} ;

r ——非单调聚焦系数,用于聚焦普通质量的锚框。

R_{WIoU} 定义如式(9)所示, r 定义如式(10)所示。

$$R_{WIoU} = \exp \left[\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)^*} \right] \quad (9)$$

$$r = \frac{\beta}{\delta a^{\beta - \delta}} \quad (10)$$

式中: β ——离群度,表示动态滑动平均值;

W_g, H_g ——最小边框宽、高;

a, δ ——超参数。

WIoU 损失函数在降低高质量锚框的竞争性的同时,还能够降低质量示例产生的有害梯度,提升病害检测神经网络的泛化性与整体性能。因此,选用 WIoU 损失函数代替原损失函数。

2 结果与分析

2.1 训练环境与方法

使用 Windows 10 操作系统, GPU 为 NVIDIA RTX2080 Ti, 显存为 64 GB, 主机内存为 1 TB, 编程语言为 Python 3.9.17, 使用 CUDA v11.3 对 GPU 进行加速, 基于深度学习框架 Pytorch 1.11.0 进行训练。Torchvision 版本为 0.12.0。

训练参数设置: 图像输入尺寸为 640 像素 \times 640 像素, 批次 $Batch_size$ 为 16, 多线程设置为 2, 初始学习率为 0.01, 每次训练迭代 ($epoch$) 500 次。每完成 10 次迭代, 保存一次权重参数, 共得到 50 个权重参数。由于试验修改了原算法的主干特征提取网络, 因此在首次训练时无预训练权重, 先进行 200 次的迭代训练, 再利用训练好的权重重新进行 500 次的迭代训练。

2.2 评价指标

试验结果采用精确率 P 、召回率 R 、平均精度均值 mAP 来衡量模型识别检测的准确度。

$$P = \frac{TP}{TP + FP} \times 100\% \quad (11)$$

$$R = \frac{TP}{TP + FN} \times 100\% \quad (12)$$

$$mAP = \frac{\sum_{i=1}^N \int_0^1 P dR}{N} \times 100\% \quad (13)$$

式中： TP ——正确检测叶片病虫害的样本数；
 FP ——被误测为叶片病虫害的样本数；
 FN ——未被正确检测的叶片病虫害样本数；
 N ——类别数量，本文中研究 3 种黄瓜叶片病虫害与正常叶片，故 $N=4$ 。

2.3 分类结果分析

为使网络检测模型具有更好的识别和检测效果，

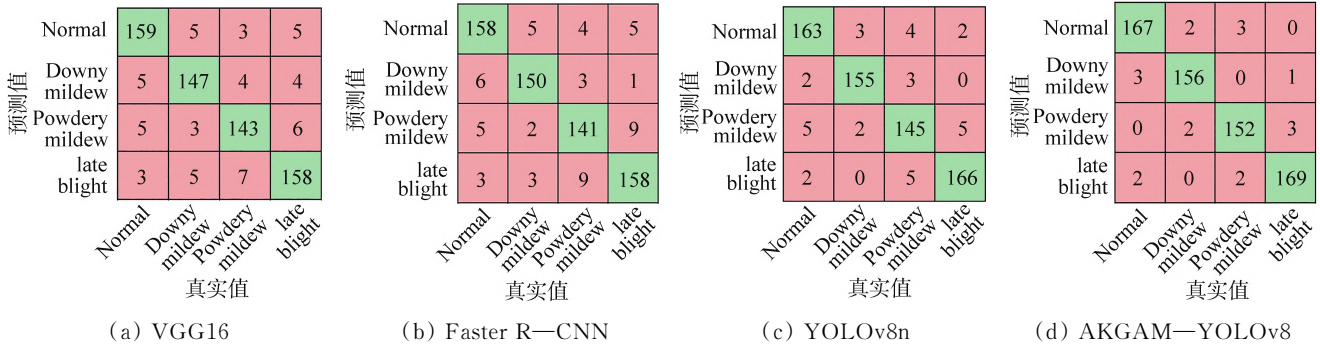


图 7 混淆矩阵

Fig. 7 Confusion matrix

2.4 消融实验

为验证本模型优化策略的可行性，以 YOLOv8n 为基线模型，通过引入 AKConv 轻量化卷积、Wiou 损失函数、GAM 注意力机制以及 BiFPN 特征融合网络不同模块的组合，以评价模型的检测精度、召回率、平均精度均值、权重以及检测时间。

由图 8、图 9 以及表 2 可知，使用 AKConv 轻量化卷积，有效减小计算量和模型权重，提高推理速度，但也可能因为丢失部分通道的特征，召回率和平均精度均值略有下降。采用 BiFPN 特征融合网络，通过增加重复双向跨尺度连接和带权重的特征融合，进一步减小计算量和模型权重，同时提高模型的召回率。GAM 注意力机制在提升模型整体性能与精确度方面表现较好，引入 Wiou 损失函数提供合理的梯度增益分配策略，从而提高模型的检测精确率、召回率和平均精度均值。相比于基线网络，最终模型的权重减小至 13.22 MB，检测时间减小至 37.16 ms，精确率提升

比较 AKGAM—YOLOv8、YOLOv8n、VGG16 和 Faster R—CNN 四种主流模型对黄瓜叶片病害图像的性能。当参数 $Batch_size$ 为 16, $MaxEpochs$ 为 50 时，4 种网络模型的混淆矩阵如图 7 所示。在 4 种主流模型中，AKGAM—YOLOv8 模型对图像识别和检测的效果最好。因此，选择 AKGAM—YOLOv8 模型作为黄瓜叶片病害识别检测模型。

1.71%，召回率提升 2.2%，平均精度均值提升 3.04%。综上，证明了所提改进方法的有效性，为黄瓜叶片病害识别的轻量级模型设计提供有力支持。




图 8 AKGAM—YOLOv8 与 YOLOv8n 的精确率结果对比

Fig. 8 Compare precision result of AKGAM—YOLOv8 and YOLOv8n




图 9 AKGAM—YOLOv8 与 YOLOv8n 的损失结果对比

Fig. 9 Compare loss result of AKGAM—YOLOv8 and YOLOv8n

表 2 消融实验

Tab. 2 Ablation test

序号	基线模型	AKConv	Wiou	GAM	BiFPN	$P/\%$	$R/\%$	$mAP/\%$	权重/MB	检查时间/ms
1	YOLOv8n	—	—	—	—	95.50	85.46	94.11	23.43	56.71
2	YOLOv8n	✓	—	—	—	95.63	84.16	93.25	17.65	51.47
3	YOLOv8n	—	✓	—	—	96.32	86.25	95.55	23.43	56.71
4	YOLOv8n	—	—	✓	—	96.26	85.46	94.06	16.71	47.55
4	YOLOv8n	—	—	—	✓	96.66	85.95	94.17	16.82	47.96
5	YOLOv8n	✓	✓	—	—	97.03	86.56	96.53	14.62	39.21
6	YOLOv8n	✓	✓	✓	—	97.16	87.13	97.09	13.89	37.98
7	YOLOv8n	✓	✓	✓	✓	97.21	87.66	97.15	13.22	37.16

2.5 不同模型黄瓜叶片病虫害检测可视化

为验证改后模型的综合性能,使用训练好的 AKGAM—YOLOv8、YOLOv8n 模型分别对自然场景下的黄瓜叶片病害进行检测,如图 10 所示。可以看出,黄瓜叶片病害面积较大且叶片繁茂,YOLOv8n 模型在多目标场景中易出现误检现象,与 YOLOv8n 模型相比,AKGAM—YOLOv8 模型表现出更高的检测精确度且目标框更贴合实际目标尺寸大小,进行检测时拥有更高的置信度,且目标定位更加准确,模型鲁棒性更强。



图 10 不同模型可视化结果对比

Fig. 10 Comparison of visualization results of different models

3 结论

1) 复杂自然环境下黄瓜叶片病害的快速准确识别对黄瓜叶片病害及时诊断与预防具有重要意义,为准确识别复杂环境下的黄瓜叶片病害,基于 YOLOv8n 模型引入 AKConv 可变核卷积、特征融合网络 BiFPN、注意力机制 GAM 以及损失函数 WIoU,在轻量化的同时可提高模型对细小特征的提取能力,从而提升整体识别准确率。

2) 经测试,黄瓜叶片病害识别精确率为 97.21%,模型权重为 13.22 MB,与原模型相比,改进后模型权重缩小为基线网络的 56.42%,精确率提升 1.71%,平均精度均值提升 3.04%,与 YOLOv8n、VGG16、Faster R—CNN 主流目标检测网络模型相比,也具有一定的优势。采用 AKConv 可变核卷积减小模型参数和计算开销,改进后模型权重较原模型降低 24.67%,并在此基础上使用特征融合网络 BiFPN 与注意力机制 GAM 对模型细小特征提取能力进行优化,更改原模型损失函数为 WIoU 损失函数,精确率提升 0.82%,进一步提升黄瓜叶片病害检测神经网络的泛化性与整体性能。

3) 构建复杂自然环境下黄瓜叶片病害数据集用于各个模型间的性能对比,所提出的 AKGAM—YOLOv8 模型在识别准确率、识别速度以及轻量化方面

具有一定的优势,可满足黄瓜叶片病害识别检测要求,为复杂自然环境下的农作物病害识别检测提供理论依据。

参 考 文 献

- [1] 徐彦刚,贺振,李瑞,等. 黄瓜枯萎病研究进展[J]. 中国瓜菜, 2018, 31(6): 1—6.
- [2] 马燕,李彦军,滕巍,等. 我国黄瓜抗病品种选育技术研究进展[J]. 中国果菜, 2021, 41(3): 68—71, 84.
- [3] Astuti E, Saragih N E, Sribina N, et al. Dempster-shafer method for diagnose diseases on vegetable [C]. 6th International Conference on Cyber and IT Service Management (CITSM). IEEE, 2018: 1—4.
- [4] Barbedo J G A. A review on the main challenges in automatic plant disease identification based on visible range images [J]. Biosystems Engineering, 2016, 144: 52—60.
- [5] 谷永立,宗欣欣. 基于深度学习的目标检测研究综述[J]. 现代信息技术, 2022, 6(11): 76—81.
- [6] 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, 2023, 39(15): 163—171.
- [7] Zhang Y, Huang S, Zhou G, et al. Identification of tomato leaf diseases based on multi-channel automatic orientation recurrent attention network [J]. Computers and Electronics in Agriculture, 2023, 205: 107605.
- [8] 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 undernatural scenes using improved YOLOv5s [J]. Transactions of the Chinese Society of Agricultural Engineering, 2024, 40(1): 210—216.
- [9] 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 Weixing, Liu Zeqian, Gao Peng, et al. Detection of litchi diseases and insect pests based on improved YOLOv4 model [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(5): 227—235.
- [10] 李大湘,滑翠云,刘颖. 面向苹果叶部病害识别的细粒度蒸馏模型[J]. 农业工程学报, 2023, 39(7): 185—194.
Li Daxiang, Hua Cuiyun, Liu Ying. Identifying apple leaf disease using a fine-grained distillation model [J]. Transactions of the Chinese Society of Agricultural Engineering, 2023, 39(7): 185—194.

(下转第 107 页)

- [13] Chen Y, Geng C, Wang Y, et al. Extraction method for centerlines of rice seedlings based on Fast—SCNN semantic segmentation [J]. *Inmateh-Agricultural Engineering*, 2021, 64(2): 335—344.
- [14] 朱伟, 马立新, 张平, 等. 基于 GoogLeNet 和无人机图像的水稻秧苗形态识别[J]. *华南农业大学学报*, 2022, 43(3): 99—106.
Zhu Wei, Ma Lixin, Zhang Ping, et al. Morphological recognition of rice seedlings based on GoogLeNet and UAV image [J]. *Journal of South China Agricultural University*, 2022, 43(3): 99—106.
- [15] 李柯泉, 陈燕, 刘佳晨, 等. 基于深度学习的目标检测算法综述[J]. *计算机工程*, 2022, 48(7): 1—12.
- [16] 胡顺石, 杨斌, 黄英, 等. 不同种植设施背景蔬菜作物无人机高光谱精细分类[J]. *遥感学报*, 2024, 28(1): 280—292.
Hu Shunshi, Yang Bin, Huang Ying, et al. Fine classification of vegetable crops covered with different planting facilities using UAV hyperspectral image [J]. *National Remote Sensing Bulletin*, 2024, 28(1): 280—292.
- [17] GB/T 6243—2017, 水稻插秧机 试验方法[S].
- [18] Ren S, He K, Girshick R, et al. Faster R—CNN: Towards real-time object detection with region proposal networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(6): 1137—1149.
- [19] Girshick R. Fast R—CNN [C]. *Proceedings of 2015 IEEE International Conference on Computer Vision*, 2015: 1440—1448.
- [20] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition [C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016: 770—778.
- [21] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [C]. *International Conference on Learning Representations*, 2014: 1—14.
- [22] Lin T, Dollár P, Girshick R, et al. Feature pyramid networks for object detection [C]. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017: 936—944.
- [23] He K, Gkioxari G, Dollár P, et al. Mask R—CNN [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017: 2980—2988.
- [24] 邵延华, 张铎, 楚红雨, 等. 基于深度学习的YOLO目标检测综述[J]. *电子与信息学报*, 2022, 44(10): 3697—3708.
- [25] Liu W, Dragomir A, Dumitru E, et al. SSD: Single shot multibox detector [C]. *European Conference on Computer Vision*, 2016: 21—37.

(上接第 100 页)

- [11] 李好, 邱卫根, 张立臣. 改进 ShuffleNet V2 的轻量级农作物病害识别方法[J]. *计算机工程与应用*, 2022, 58(12): 260—268.
- [12] 蒋丰千, 李旻, 余大为, 等. 基于 Caffe 的生姜病害识别系统研究与设计[J]. *中国农机化学报*, 2019, 40(1): 126—131.
Jiang Fengqian, Li Yang, Yu Dawei, et al. Design and experiment of tobacco leaf grade recognition system based on Caffe [J]. *Journal of Chinese Agricultural Mechanization*, 2019, 40(1): 126—131.
- [13] 田凯, 张连宽, 熊美东, 等. 基于叶片病斑特征的茄子褐纹病识别方法[J]. *农业工程学报*, 2016, 32(S1): 184—189.
- [14] 李都鸽, 谢忠. 黄瓜霜霉病发生规律及综合防治措施[J]. *西北园艺*, 2024(3): 35—37.
- [15] 刘恩龙, 陈俊. 黄瓜白粉病田间防效试验[J]. *云南农业*, 2024(1): 86—87.
- [16] 董莉, 董文阁, 刘念, 等. 朝阳市温室蔬菜生产主要病害及防治措施[J]. *园艺与种苗*, 2024, 44(3): 30—31, 48.
- [17] 王景鑫, 潘欣. 一种基于 Labelimg 的辅助标注方法[J]. *科技创新与应用*, 2023, 13(29): 145—148.
- [18] Chen J, Xie Y, Qian Z, et al. Power adapter appearance defect detection based on task feature decoupling YOLOv8n [J]. *IEEE Access*, 2024, 12: 60070—60080.
- [19] 王小荣, 许燕, 周建平, 等. 基于改进 YOLOv7 的复杂环境下红花采摘识别[J]. *农业工程学报*, 2023, 39(6): 169—176.
Wang Xiaorong, Xu Yan, Zhou Jianping, et al. Safflower picking recognition in complex environments based on an improved YOLOv7 [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2023, 39(6): 169—176.
- [20] Liu S, Qi L, Qin H, et al. Path aggregation network for instance segmentation [C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Salt Lake City, 2018: 8759—8768.
- [21] Lou H, Duan X, Guo J, et al. DC—YOLOv8: Small-size object detection algorithm based on camera sensor [J]. *Electronics*, 2023, 12(10): 2323.
- [22] Liu Y, Shao Z, Hoffmann N. Global attention mechanism: Retain information to enhance channel-spatial interactions [J]. *arXiv preprint arXiv: 2112.05561*, 2021.
- [23] Tong Z, Chen Y, Xu Z, et al. Wise-IoU: Bounding box regression loss with dynamic focusing mechanism [J]. *arXiv preprint arXiv: 2301.10051*, 2023.