

基于 GDDL-YOLOv8n 的番茄叶病害轻量化检测算法^{*}胡艳茹^{1,2} 刘德全¹

(1. 宁夏师范大学物理与电子信息工程学院 固原 756000; 2. 宁夏师范大学 固体微结构与功能实验室 固原 756000)

摘要: 针对自然环境中番茄叶病害检测识别精度低、效果差的问题,提出了一种基于优化 YOLOv8 的番茄叶病害检测模型——GDDL-YOLOv8n。该模型通过采用 GhostHGNetV2 改进原有的主干网络,C2f-DWR-DRB 改进颈部网络特征融合,并创新性地引入 LSCG 检测头,成功实现了模型的轻量化与高精度的检测效果。实验结果表明,GDDL-YOLOv8n 模型在参数数量上下降了 49.13%,计算量减少了 37.04%,模型内存占用量降低了 46.67%,同时保持了高精度的检测性能,mAP@0.5 达到了 98.4%,mAP@0.5-0.95 达到了 92.3%。此外本研究还开发了一个基于 PyQt5 的用户友好界面系统,支持图片、视频检测以及摄像头实时跟踪识别功能,农业智能化管理和番茄叶部病害识别技术得到了显著增强,模型更为轻量化极大地促进了这些技术在实际生产中的应用。

关键词: 病害;轻量化;检测;精度;GUI

中图分类号: TP391.41;TN911.73 **文献标识码:** A **国家标准学科分类代码:** 520.40

Lightweight detection algorithm for tomato leaf diseases
based on GDDL-YOLOv8nHu Yanru^{1,2} Liu Dequan¹(1. School of Physics and Electronic Information Engineering, Ningxia Normal University, Guyuan 756000, China;
2. Laboratory of Solid State Microstructure and Function, Ningxia Normal University, Guyuan 756000, China)

Abstract: In order to solve the problems of low accuracy and poor effect of tomato leaf disease detection in natural environment, a tomato leaf disease detection model based on optimized YOLOv8 was proposed, namely GDDL-YOLOv8n. In this model, the original backbone network is improved by using GhostHGNetV2, C2f-DWR-DRB is used to improve the neck network feature fusion, and the Lightweight Shared-Convolutional detection head (LSCG) is innovatively introduced. The lightweight and high-precision detection effect of the model has been successfully realized. Experimental results show that the GDDL-YOLOv8n model decreases by 49.13% in the number of parameters, 37.04% in the amount of computation, and 46.67% in the memory occupation of the model, while maintaining the high-precision detection performance, with the mAP@0.5 reaching 98.4% and the mAP@0.5-0.95 reaching 92.3%. In addition, a user-friendly interface system based on PyQt5 was developed, which supports image and video detection and camera real-time tracking and recognition functions, and the intelligent management of agriculture and the identification technology of tomato leaf disease have been significantly enhanced, and the model is lighter, which greatly promotes the application of these technologies in actual production.

Keywords: disease;lightweighting;detect;precision;GUI

0 引言

宁夏自治区的冷凉蔬菜产业,作为“六新六特六优”产业体系中的关键一环,专注于利用气候冷凉的地区优势在夏季进行蔬菜种植,而番茄则在这一产业中占据了举足轻重的地位。番茄不仅营养丰富,经济价值也相当高,深受消

费者喜爱。然而,随着番茄植株的生长,叶部病害的发生率也逐渐上升,这对番茄的产量和质量构成了严重威胁。因此,及时且精准地识别番茄叶部病害种类,并采取有效的防治措施,成为了提高番茄产量的关键。传统的病害诊断依赖于人工排查,这种方法耗时耗力且准确率难以保证。这可能导致在病害初期未能被及时发现,因此错过最佳防治

时机,给农户带来经济损失。研发高精度且轻量化的识别算法,以适应实际应用需求已成为迫切任务。

在自然环境中检测番茄叶片病害面临多重挑战,包括复杂多变的背景、不稳定的光照条件,以及病害病斑特征的相似性和无规律形态。这些难题使得现有检测识别方法效率低下,模型庞大复杂,难以实际应用。本研究以深度学习和计算机视觉技术为核心,分析了现有模型的局限性,并提出了针对性的改进措施。研究设想是通过先进的 YOLOv8 深度学习模型,并对其网络结构进行了一系列改进。本文采用 GhostHGNetV2 提升主干网络特征提取性能,旨在提升模型精度同时减少参数和计算量。同时利用 C2f-DWR-DRB 优化 Neck 网络,增强模型对番茄叶片微小病害特征的捕捉融合能力提升检测性能。此外本文创新性地引入了 LSCG Head,既保持了检测精度,又减轻了模型的负担。这些改进使得本文模型大幅减少了参数数量和计算需求,模型体积因此缩小,便于实际应用和部署,同时保持了高精度的检测性能。本研究通过实地采集数据和图像预处理构建数据集,随后对模型进行了配置和训练,并设定了评价指标以评估性能。为宁夏冷凉蔬菜产业的可持续发展提供技术保障,推动农业智能化管理,并通过轻量化模型促进技术在实际生产中的应用,具有重要的经济和社会价值。

1 研究现状

近年来随着计算机视觉和深度学习技术不断地发展,其在农业方面的应用也越来越广泛深入,很多学者专门针对农作物叶片病害进行检测研究。张一帆等^[1]改进了 YOLO v7 算法,通过集成 CBAM 和 AFPN,并使用 XIOU 损失函数,将果蔬叶片病害检测精度提升至 96.4%,同时模型大小减至 22.4 MB。李大华等^[2]提出了基于改进 SSD 的轻量化检测方法,利用 MobileNetV2 减小模型规模,RFb 扩大特征感受野,CA 机制强化特征信息,提高了检测精度和速度。陶兆胜等^[3]则对 YOLOv5s 进行了改进,引入 DCAM、Swin Transformer 和 BiFPN,提高了番茄叶片病害的检测和分类精度。梁冬悦^[4]构建了草莓叶片病害检测模型,使用 ConSinGAN 平衡数据集,并提出 YOLOv7_FSU 模型提升检测精度。赵艳芹等^[5]改进的 YOLOv5 模型使用 GhostCANet 和多层递归金字塔网络,提高了番茄病害检测精度。许悦等^[6]提出的 BKW-YOLOv8s 算法通过改进主干网络和引入 BAM,优化了损失函数,提高了番茄叶病害检测的准确率等。储鑫等^[7]提出的轻量化 YOLOv4 改进算法通过调整先验框、替换主干网络、引入深度可分离卷积和 CBAM 模块,提高了番茄叶片病害识别的精度和速度。赵嘉威等^[8]提出的 MC-YOLOv4 算法通过替换主干网络、引入深度可分离卷积和 CBAM 模块,以及优化锚框,提高了苹果叶片病害检测的精度和速度。曾亮等^[9]针对马铃薯叶片病害检测,提出的 YOLOv8n-

Potato 算法通过改进特征融合和检测头,提高了精确度、召回率和 mAP。戴林华等^[10]针对水稻病害检测,改进的 YOLOv8n 算法通过引入 ADown 模块、SE 注意力机制和共享参数检测头,以及 WIoU 损失函数,提升了检测性能和速度。李康顺等^[11]提出的基于 CBAM 和 YOLOX-Nano 的农作物病害检测模型,通过引入 Focal Loss 和 CenterIOU Loss,实现了高精准度和快速检测。刘莎^[12]优化 YOLOX-Nano 模型,提出轻量型苹果叶片病害检测方法,提高了检测精度和速度,并开发了检测软件。杨巧梅等^[13]提出的 YOLO-MobileNet-CBAM 算法通过集成 MobileNetV3 和 CBAM 注意力机制,提高了农作物微小病虫害的检测精度,并实现了模型轻量化和高检测准确率。盛帅等^[14]提出的 Dynamic-YOLOX 模型通过增强特征提取和自适应性,引入 Varifocal Loss 提升小目标检测精度,优于主流模型。

上述研究在农作物叶片病害检测的精度与效率方面均取得了一定进步,为智慧农业的快速发展提供了重要助力,但仍面临一些亟待解决的难题。一方面,由于大多数模型参数量大、计算复杂度高,导致它们在资源受限的环境中难以有效运行。因此,开发轻量级模型以降低推理时间、加快识别速度成为当务之急。另一方面,当前模型的识别精度仍需进一步提升,以更好地适应实际应用中更为严格的要求,推动模型性能达到新的高度。针对这些挑战,本研究推出了针对番茄叶病害识别的 GDDL 模型,该模型在 YOLOv8 的基础上进行了深度优化和改进,旨在全面提升检测性能。

2 方法和材料

2.1 算法改进

在本次番茄叶片病害识别任务中,对 Ultralytics 公司以高精度高效率著称的 YOLOv8 算法进行优化。具体来说,采用 GhostHGNetV2 作为主干网络,以提升特征提取的效能;在颈部网络中,引入了 C2f-DWR-DRB 模块,以增强多尺度特征的捕捉与融合能力;同时,本文还设计了一种新型的 LSCG 检测头,以优化检测流程并降低计算成本。改进后的网络整体架构如图 1 所示。这些改进既保持了模型的高准确度,还极其有效地实现了模型的轻量化目标。

1) C2f-DWR-DRB 模块

如图 2(a)所示 C2f 采用 Bottleneck 设计,通过串联模块和特征融合提升网络效率和表达能力,但计算复杂度较高。为改进它进行了两步优化,首先利用 DWR(dilation-wise residual)改进 C2f,再利用 UniRepLKNet 的 DRB(dilatedreparamblock)改进 DWR 模块,最终形成 C2f_DWR_DRB。本文还创新性地将其加在了颈部网络,通过特征融合与增强,提高模型对复杂视觉特征的提取能力,显著提高对番茄叶细微病害特征的检测精度。

如图 2(b)DWR 扩张残差模块的原理是通过将多尺度

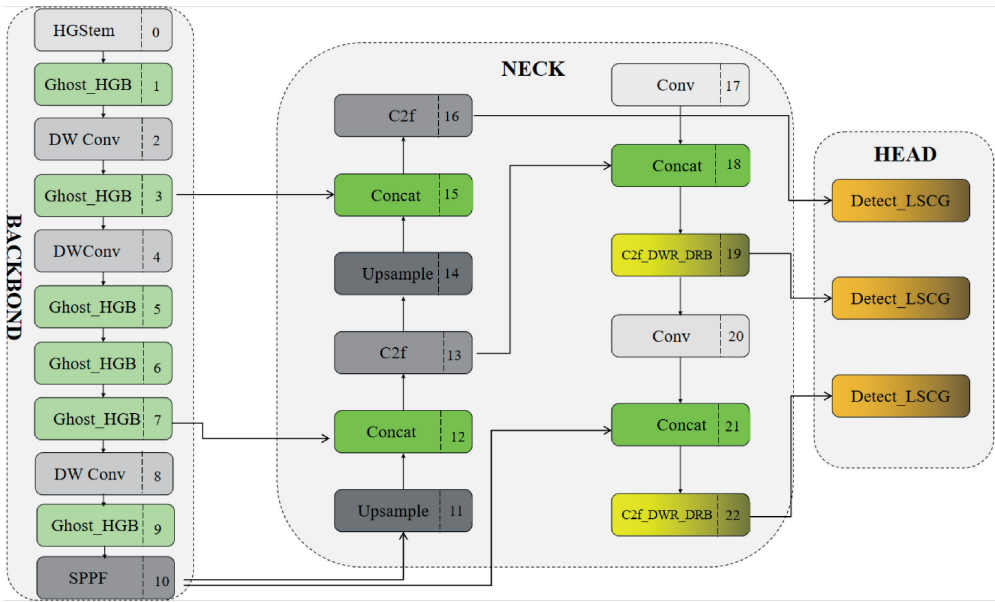


图 1 GDDL-YOLOv8 模型结构
Fig. 1 GDDL-YOLOv8 model structure

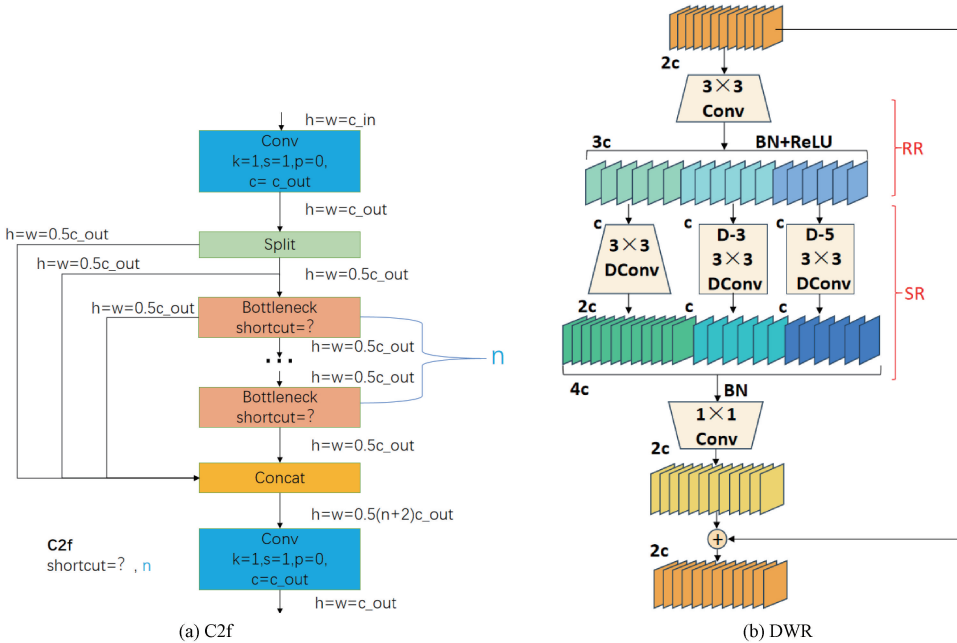


图 2 模块结构图
Fig. 2 Module structure diagram

特征提取过程分解为区域残差化(region residualization)和语义残差化(semantic residualization)两步,利用深度分离扩张卷积在第一步中提取简洁的区域特征,并在第二步中基于这些特征执行语义形态学过滤,同时精细设计扩张率和接收场大小,以高效捕获多尺度上下文信息,从而提高实时语义分割的性能^[15]。通过引入 DWR 模块,C2f 网络能够更准确地提取番茄叶片上的病害特征,并有效区分不同种类的病害。

DRB 是在 C2f-DWR 模块的基础上,本文进行的二次创新,通过引入了专为强化非大核卷积层设计的 DRB。该模块源自 UniRepLKNet 模型,由一层非扩张的小核卷积与多层扩张的小核卷积组成,其核心亮点在于能够重新参数化大卷积核层,从而在无需增加额外计算成本的情况下,显著提升模型性能^[16]。基于这一显著优势,将 C2f-DWR 模块进行了部分革新,创造性地推出了 C2f-DWR-DRB(C2f-dilationwiseresidual-dilatedreparamblock),结构

如图 3 所示。这一创新举措不仅保留了 C2f-DWR 在区域残差化与语义残差化方面的卓越特性,还通过 DRB 的融入,极大地增强了模型在复杂多变的多尺度特征识别与分析方面的能力。




图 3 C2f_DWR_DRB 结构

Fig. 3 Structure of C2f_DWR_DRB

2) GhostHNetV2

GhostNet 是一种专为移动设备设计的轻量级卷积神经网络,其核心是创新的 Ghost 模块,它通过减少参数数量生成更多特征图。Ghost 模块将输出通道分为两部分,一部分采用常规卷积严格控制输出特征图数量,另一部分则通过简单的线性变换(如 depth-wise 后接点积)生成额外特征图,然后拼接得到完整输出,计算公式如下。GhostNet Block 通常由两个这样的 Ghost 模块堆叠而成,类似于 MobileNetV2 的 Inverted bottleneck 设计,第 1 个模块增加输出通道数,第 2 个模块减小回原值以匹配 shortcut path,从而显著降低参数数量和计算量^[17]。

$$Y' = X * F_{1 \times 1} \quad (1)$$

$$Y = \text{Concat}([Y', Y' * F_{dp}]) \quad (2)$$

尽管 Ghost 模块能够有效降低计算量,但由于其卷积操作主要聚焦于局部信息的建模,因此在特征表征能力上存在一定的局限性。在 GhostNet 中特征被分为两部分进行处理:一部分通过成本较低的 3×3 Depth-wise 卷积来

捕获空间信息,而另一部分则仅仅通过 1×1 Point-wise 卷积生成,这部分特征在生成过程中缺乏与其他像素的有效信息交流。为了弥补这一缺陷 GhostNetV2 应运而生,它在第一代的基础上提出了 DFC Attention 机制,即将式(3)分解为水平式(4)和垂直方向式(5)的特征聚集,以此简化全连接注意力机制。这种拆分让每个图像块(patch)的注意力值直接依赖于其相邻块,但这种依赖是递归的,即相邻块的注意力值又依赖于它们的相邻块,从而在两个方向上传播。尽管目的是简化计算,但这种机制实际上仍保持了全局信息的捕捉,因为它通过递归依赖关系间接考虑了所有图像块。DFC attention 与 Ghost 模块协同工作,旨在捕捉输入特征的长距离空间依赖。输入特征被分为两路:Ghost 分支生成输出特征,DFC 分支计算注意力矩阵。DFC attention 借鉴 Self-attention 的线性变换思路,使用卷积转换输入以适应 DFC 分支,最终输出是将两个分支的结果进行点乘,再用 Sigmoid 归一化到 0~1 之间^[18]。

$$a_{hw} = \sum_{h', w'} F_{hw, h', w'} \odot z_{h', w'} \quad (3)$$

$$a'_{hw} = \sum_{h'=1}^H F_{h, h', w}^H \odot z_{h', w}, h = 1, 2, \dots, H, w = 1, 2, \dots, W \quad (4)$$

$$a_{hw} = \sum_{w'=1}^W F_{w, hw'}^W \odot a'_{hw'}, h = 1, 2, \dots, H, w = 1, 2, \dots, W \quad (5)$$

$$O = \text{Sigmoid}(A) \odot v(X) \quad (6)$$

如图 4(a)、(b)所示的 GhostNet 的两个版本中,均采用了两个 Ghost 模块,其特征维度设计为先递增后递减。相较于 V1 版本, V2 版本在结构上进行了优化,将 DFC 注意力分支与第 1 个 Ghost 模块设置为并行处理,以此增强并扩展特征表示。随后,这些经过增强的特征被送入第

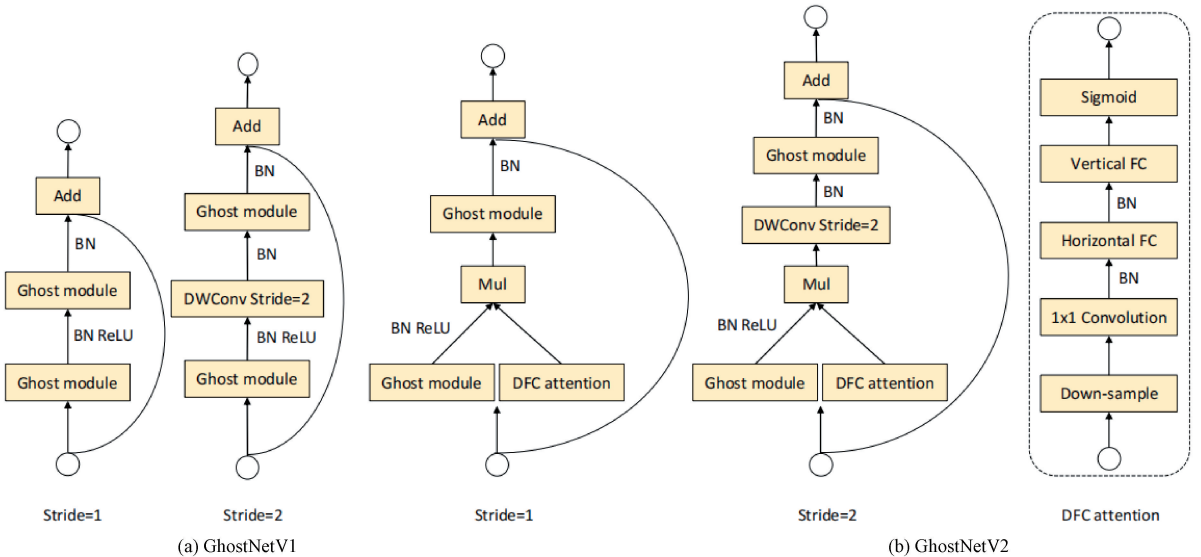


图 4 GhostNet 结构

Fig. 4 GhostNet structure

2 个 Ghost 模块,以生成最终的输出特征^[17]。此设计策略旨在同时实现两个目标:一是捕捉不同空间位置像素间的长距离依赖性,从而增强 Ghost 模块的性能;二是通过这一结构改进,提升轻量化卷积神经网络的计算效率。针对番茄叶片病害病斑差异小且形状复杂识别,采用 GhostNetV2 优化模型可最大限度提升识别精度。

GhostHGNetV2 是利用 GhostNetV2 改进 HGBlock 网络主干, HGNet 是一种结合了 ResNeSt 和 Hourglass 网络结构特点的目标检测神经网络模型。它的设计灵感来源于人类对目标的快速检测与定位能力,通过多个由 ResNeSt 模块和 Hourglass 模块构成的重复结构堆叠,逐步提取图像特征,以提高目标检测的精度^[18]。HGNet 在目标检测任务中表现出色,具有高准确率和鲁棒性,能够同时检测出多个目标,并给出它们的位置和类别信息,这为一张番茄叶病害图片上多个病害识别定位提供了有效保障。

3) LSCG Head

检测头负责从特征图中精准定位并分类目标,传统的目标检测算法通常采用多个独立的检测头来处理不同尺度的特征输入,这往往会导致模型参数和计算复杂度较高。本研究创新性地提出了 LSCG (lightweight shared-

convolutional), G 代表该模块采用的组归一化 (group normalization) 技术,它采用 Conv_GN 结构,以组归一化 (GN) 替代批归一化 (BN),旨在提升模型的定位与分类精度。

如图 5 所示,与 YOLO 系列中各特征层级独立使用检测头的做法不同, LSCG 通过共享卷积层并保留独立的 BN 层,有效减少了模型参数,同时性能略有提升。具体来说, 3×3 的 Conv_GN 以及 Conv_Reg (回归卷积) 和 Conv_Cls (分类卷积) 都通过共享卷积层,大幅减少了参数数量,使得模型更加轻便,特别适用于资源受限的设备。此外针对本任务中病害大小尺度不一致问题,引入了 Scale 层进行特征缩放,融合公式如下所示,使得动态特征融合不同尺度的特征,提高了检测精度。其中, x 为输入特征, x_i 为不同尺度特征的第 1 个通道, w_i 为第 i 个通道的动态权重系数,可以自适应地调整不同尺度特征的融合权重,检测头输出为:

$$DFL(x) = \sum w_i x_i \quad (7)$$

$$y = [bbox, cls] \quad (8)$$

其中, $bbox = [cx, cy, w, h, reg_{max}]$, $cls = [c_1, c_2, \dots, c_n]$ 。

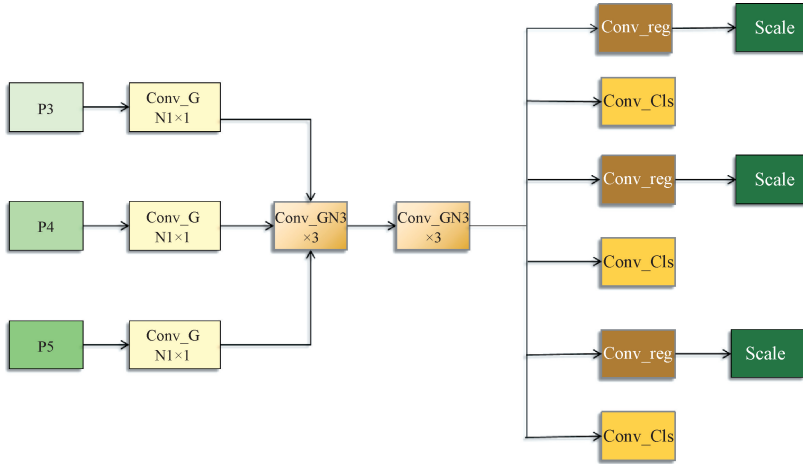


图 5 LSCG 结构

Fig. 5 LSCG structure

2.2 图像采集与预处理

本实验所用数据集来源于两部分:一是 roboflow 上公开的数据集,包含 4 128 张高质量图像;二是实地去宁夏固原市原州区彭堡镇惠德村冷凉蔬菜基地拍摄 1 000 余张番茄叶图像,两部分经过筛选去除部分质量不佳的图像后,共收集到 5 000 张,通过图像增强技术扩增数据集,如图 6 所示采用像素变换(椒盐噪声,饱和度调整)和几何变换(水平翻转、随机裁剪)共计 4 种形式,将数据集扩增到 20 000 张。

如图 7 所示使用 Labelimg 进行图像标注,导入图像文件夹,用最小外接矩形圈注目标对象‘Early Blight’, ‘Healthy’, ‘Late Blight’, ‘Leaf Miner’, ‘Leaf Mold’, ‘Mosaic Virus’, ‘Septoria’, ‘Spider Mites’, ‘Yellow

Leaf Curl Virus’ 9 种常见病害类型。标签打完后生成包含类别索引和坐标信息的 .txt 文件,以满足 YOLO 模型训练的数据格式要求。

为了保持数据集的多样性和平衡,将图片和标签随机分成三部分:训练集 80%,验证集 10%,测试集 10%。其中,训练集主要用于模型的训练和学习;验证集则用于调整模型参数,以防止过拟合现象的发生;而测试集则专门用于评估模型的最终性能。这种划分策略确保了模型在各个阶段都能得到充分的学习和评估,并通过随机分配减少了数据偏差,提高了模型的泛化能力^[19]。

2.3 模型配置及训练

本次实验在 Intel i5-12500 CPU 和 NVIDIA RTX



图 6 图像增强

Fig. 6 Image enhancement




图 7 Labeling 制作数据集

Fig. 7 Labeling creates a dataset

3090 GPU 的台式机上运行,系统为 Windows 11,使用 Python 3.8.20 和 PyTorch 2.4.1+CUDA11.8。设定 150 个训练周期,批处理 4 张图,4 个 worker 并行加载数据,学习率 0.01,采用 SGD 优化器。所有图像统一为 640×640 像素。

2.4 评价指标

本研究中,采用以下关键指标全面评估模型性能:

(1)准确度方面,通过准确率(P)、召回率(R)及平均精度(mAP)衡量;(2)轻量化程度以参数数量(Param)和计算复杂度(GFLOPs)为评估标准;(3)实时性能则通过 FPS(每秒帧数)来评价^[19]。

1)准确度

精确率 P 反映了模型在识别正样本时的准确性,即模型预测为正样本的实例中真正为正样本的比例。而召回率 R 则评估了模型捕捉所有正样本的能力,即所有真正的正样本中被模型正确预测为正样本的比例。IoU 阈值为 0.5 时的平均精度(mAP@0.5)和 IoU 阈值从 0.5 到 0.95 时的平均精度(mAP@0.5-0.95),mAP@0.5 和 mAP@0.5-0.95 数值越高代表检测越准确,具体计算公式如下:

$$P = \frac{TP}{TP + FP} \quad (9)$$

$$R = \frac{TP}{TP + FN} \quad (10)$$

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

$$mAP@50 = \frac{1}{n} \sum_{i=1}^n P_i = \frac{1}{n} P_1 + \frac{1}{n} P_2 + \dots + \frac{1}{n} P_n \quad (12)$$

$$mAP@50 = \frac{1}{C} \sum_{k=1}^C mAP@50_k \quad (13)$$

$$mAP@50 \sim 95 = \frac{1}{10} mAP@50 + \frac{1}{10} mAP@55 + \dots + \frac{1}{10} mAP@95 \quad (14)$$

其中,TP 为正确识别的正样本数;FP 为误识的负样本数;FN 为漏识的正样本数;AP 为单类别平均精度,反映识别效果;n 为总类别数。

2)轻量化

在模型复杂度方面,参数量(Params)指的是模型训练过程中涉及的参数总数,涵盖了模型中所有的权重和偏置参数,它是衡量模型空间复杂度和规模的关键指标。计算量(GFLOPs)表示模型完成一次前向传播所需的浮点运算次数,通常用来评估模型在计算资源消耗方面的表现,单位是每秒十亿次浮点运算。一般来说,参数数量和浮点运算次数较低的模型更倾向于轻量化。

$$Params = \sum_{i=1}^L (W_i \times H_i \times C_i) \quad (15)$$

$$GFLOPs = \sum_{i=1}^L (W_i \times H_i \times C_{in,i} \times C_{out,i} \times K_i \times K_i) / 100\,000\,000 \quad (16)$$

其中,L 是模型层数, W_i 、 H_i 、 C_{in} 及 C_{out} 分别为第 i 层的输入宽度、高度、输入通道数和输出通道数, K_i 是第 i 层卷积核的大小(假设卷积核是正方形的)。

3)实时性

为了评估模型在实际应用中的表现,特别是在实时处理场景下,关注 FPS 指标,因为高 FPS 意味着更快的处理速度和更好的实时性。

$$FPS = \frac{1\,000}{T_{pre} + T_i + T_N} \quad (17)$$

其中, T_{pre} 为图像预处理时间(pre-process); T_i 为推

理时间(inference),是预处理后图像从输入模型到模型输出结果的时间; T_N 为后处理时间(NMS per image),是模型输出结果等操作的时间。

2.5 对比验证

本文对比了包括 YOLO 系列(v5、v8、v10、v11)、SSD 和 RetinaNet 在内的几种主流目标检测算法。对比结果主要从准确率(mAP@0.5/%、mAP@0.5-0.95/%)、参数量、模型大小、计算量(FLOPS/G)和处理速度(FPS/Hz)5个维度进行。如表1所示,YOLOv8n 和 RetinaNet 在

mAP@0.5/%上表现最好,均为98.4%。但从参数量、模型大小、计算量和实时性来看,SSD 和 RetinaNet 相对较差。与 YOLO 系列其他算法相比,YOLOv8n 在精度和实时性上都有优势。综合来看,在保证检测精度的同时,YOLOv8n 在综合性能上表现最佳,因此被选为优化的基准模型。GDDL-YOLOv8n 在保持相同检测精度几近平的情况下,参数和计算量是所有模型中最小,模型尺寸也最轻。它每秒能处理143.7张图片,远超实时场景的60帧需求,显示出其在轻量化和实时性方面的优势。

表 1 不同模型性能对比实验

Table 1 Comparison experiments of different models

模型	mAP@0.5/%	mAP@0.5-0.95/%	Params	Size/M	FLOPS/G	FPS/Hz
YOLOv5	98.2	92.1	2 504 699	5	7.10	130.3
YOLOv8n	98.4	93.0	3 007 403	6	8.10	206.3
YOLOv10	98.1	91.8	2 266 923	5.5	6.50	161.0
YOLOv11	98.1	92.7	2 583 907	5.2	6.30	151.1
SSD	98.0	92.2	22 286 903	9.8	62.79	59.0
RetinaNet	98.4	92.9	22 415 620	14.6	34.35	11.0
GDDL-YOLOv8n	98.4	92.8	1 530 000	3.2	5.10	143.7

为了验证不同主干对模型性能的影响,选取几个有代表性的主干网络进行性能对比实验,如表2所示,具体包括 EfficientViT、Timn、Fastermet 和 GhostHGNetV2。Fastermet 和 GhostHGNetv2 在 mAP@0.5/%上并列最

高为98.7%。参数数量方面 GhostHGNetV2 最少够轻量化。计算效率上,GhostHGNetV2 的 FLOPS/G 最低为6.8 G,表明其处理速度最快。综合考虑 GhostHGNetV 脱颖而出成为最佳选择。

表 2 不同主干网络性能对比实验

Table 2 Comparative experiments on the performance of different backbone networks

主干网络	mAP@0.5/%	mAP@0.5-0.95/%	Params	FLOPS/G
EfficientViT	98.6	92.6	4 010 027	9.4
Timn	98.6	93.5	13 327 979	35.1
Fastermet	98.7	93.1	4 173 935	10.7
GhostHGNetV2	98.7	93.3	2 310 463	6.8

C2f 模块对 YOLOv8 模型至关重要,它不仅提高了检测性能和准确率,还通过轻量化设计和优化的梯度流加快了训练速度。C2f 模块的特征融合能力也增强了对不同大小物体的检测效果。如表3所示,本文对比了7种C2f改进模块,包括 C2f-EMBC、C2f-iRMB-DRB 等。实验显示,

C2f-DWR-DRB 在 mAP 上表现最好,mAP@0.5/%和 mAP@0.5-0.95/%分别达到98.4%和92.3%,计算效率也高,FLOPS/G 值为5.7 G,适合需要快速处理的应用场景。虽然 C2f-DWR-DRB 的参数数量不是最少,但其在精度和效率上的综合表现使其成为最佳选择。

表 3 不同 C2f 改进模块性能对比实验

Table 3 Comparative experiment on the performance of different improved C2f modules

C2f 改进模块	mAP@0.5/%	mAP@0.5-0.95/%	Params	FLOPS/G
C2f-EMBC	98.3	92.1	3 351 611	6.9
C2f-iRMB-DRB	97.8	91.4	2 658 843	7.3
C2f-iRMB-Cascaded	97.9	91.7	2 612 915	7.2
C2f-SWC	98.3	92.2	3 178 811	10.8
C2f-RVB-EMA	97.4	91.6	2 288 507	6.4
C2f-Faster-CGLU	97.9	92.1	2 224 295	6.2
C2f-DWR-DRB	98.4	92.3	2 845 227	5.7

为了评估不同检测头改进对模型性能的具体影响,如表 4 所示,对 Aux,EfficientHead,SEAMHead 和 LSCG 四种检测头进行了性能对比实验。实验结果表明,LSCG 在精度、轻量化

和处理速度方面均展现出显著优势。它不仅维持了高水平的检测精度,还具备较少的参数数量和更高的计算效率,这些特点使得 LSCG 在此检测任务中成为理想的选择。

表 4 不同检测头性能对比实验

Table 4 Comparative experiments on the performance of different detection heads

检测头	mAP@0.5/%	mAP@0.5-0.95/%	Params	FLOPS/G
Aux	98.6	93.2	3 007 403	8.1
EfficientHead	98.4	93.4	3 837 227	8.1
SEAMHead	98.6	92.8	2 819 243	7.1
LSCG	98.6	93.3	2 362 908	6.5

2.6 消融实验

为了评估模型改进的有效性,基于 YOLOv8 进行了消融实验,逐步集成了 GhostHGNetV2、C2f-DWR-DRB 和 LSCG 模块。表 5 的数据显示,这些模块的组合显著优化了模型的尺寸、参数数量和计算效率,同时几乎未影响检测精度。特别是模型 8,它融合了 3 个改进模块,尽管精确率

和召回率有轻微的下降,但 mAP@0.5/% 仍稳定在 98.4%。更重要的是模型 8 在轻量化方面取得了极其显著的提升,模型大小 3.2 M 较基准模型减少了 46.67%,参数数量 1 530 000 M 下降了 49.13%,FLOPS/G 为 5.1 降低了 37.04%。这些改进使得模型 8 在保持高检测精度的同时,更适合于对模型大小和运算受限的应用环境。

表 5 消融实验

Table 5 Ablation experiment

模型	GhostHGNetV2	C2f-DWR-DRB	LSCG	P/%	R/%	mAP@0.5/%	Size/M	Params/M	FLOPS/G
1(base)				96.9	95	98.4	6	3 007 403	8.1
2	✓			97.6	94.5	98.7	4.7	2 310 463	6.8
3		✓		97.4	94.4	98.4	5.7	2 845 227	7.8
4			✓	96.5	95.3	98.6	4.7	2 362 908	6.5
5	✓	✓		95.8	95.6	98.4	6.7	2 174 495	4.5
6	✓		✓	96.6	95.4	98.7	3.4	1 665 968	5.3
7		✓	✓	97.7	95.5	98.7	4.5	2 226 940	6.4
8(ours)	✓	✓	✓	96.6	95	98.4	3.2	1 530 000	5.1

表 6 展示了 GDDL-YOLOv8n 在多个类别上的优秀性能,其中精确度(P)、召回率(R)、mAP50 和 mAP50-95 均达到了 80%以上,表明模型具有极高检测准确度和极低的误检与漏检率。特别地,在“Spider Mites”类别中,mAP50

值达到了 0.995,显示了极高的分类准确性。总体而言,模型的整体平均精确率(mAP@0.5)为 0.984,这显示了其在检测任务中的卓越表现,具备高精确度和高召回率,是一个高效的分类工具。

表 6 验证测试结果

Table 6 Validation test results

Class	P/%	R/%	mAP50/%	mAP50-95/%
all	96.6	95.4	98.4	92.8
Early Blight	98.1	94.2	98.3	93.7
Healthy	93.7	88.6	94.7	82.4
Late Blight	98.8	97.7	99.4	94.2
Leaf Miner	99.2	95.2	98.7	90.7
Leaf Mold	98.1	94.1	98.4	92.4
MosaicVirus	98.1	95.5	98.9	92.2
Septoria	96.3	100	99.5	96.8
Spider Mites	93.2	99.1	99.5	97.2
Yellow Leaf Curl Virus	94.1	94.3	98.2	90.9

2.7 泛化实验

为了测试模型的泛化能力,使用了 Kaggle 的“leaf_disease_dataset”,包含 2 489 张图片,分为 ‘mildew’, ‘rose_P01’, ‘rose_R02’ 三个类别,原先的研究使用 YOLOv10 模型。如表 7 所示,本文的 GDDL-YOLOv8n 模型在精确率、召回率和 mAP@0.5/% 等关键指标上都略

优于 YOLOv10 和 YOLOv8。此外 GDDL-YOLOv8n 模型参数更少 FLOPS/G 为 5.1 G,使得模型更轻量化。5.1 G 的运算量比 YOLOv10 的 24.5 G 和 YOLOv8 的 8.1 G 更快,显示了更高的处理速度。这些结果表明,GDDL-YOLOv8n 模型不仅在番茄叶病害检测任务上表现出色,而且在其他数据集上也有很好的泛化能力。

表 7 泛化实验

Table 7 Generalisation experiments

模型	P/%	R/%	mAP@0.5/%	Size/M	Params/M	FLOPS/G
原 YOLOv10	72.2	62.6	66.4	12.1	8 037 282	24.5
YOLOv8	68.4	63.3	64.8	6.0	3 006 233	8.1
本文	72.3	62.8	66.4	3.2	1 529 610	5.1

3 系统设计与实现

本系统的前端界面采用 Python 3.9 和 PyQt5 5.15.2 构建,PyQt5 提供了丰富的工具包,简化了桌面应用的开发。Qt Designer 工具通过拖放组件,让界面设计更高效,生成的.ui 文件可转换为 Python 代码便于集成开发,利用 Qt Designer 设计界面并用 pyuic5 转换,以便在 Python 中

实现后端逻辑^[20]。

3.1 图片检测

用户可以通过点击界面上的“图片”图标来上传单张图片,或者点击“文件夹”来批量导入整个文件夹进行检测。如图 8 所示,系统会显示检测时间、识别的目标数量,并详细列出病害类别、置信度和目标位置,为用户提供了全面直观的分析结果。



图 8 图片检测

Fig. 8 Image detection

3.2 视频检测

用户可以通过点击“选择视频”来上传视频文件。视频导入后,系统会自动播放并快速显示每一帧的病害识别结果。如图 9 所示,系统能高效准确地识别视频中的番茄叶病害。当一帧中有多个目标时,用户可以点击“目标选

择”来查看特定目标的详细信息。

3.3 在线摄像头检测

如图 10 所示,用户点击“开启摄像头”后,系统会启动摄像头并捕获视频流,实时显示画面及其检测结果,从而实现动态分析和识别。



图 9 视频检测

Fig. 9 Video detection



图 10 摄像头检测

Fig. 10 Camera detection

4 结 论

本研究提出的 GDDL-YOLOv8n 模型是针对自然环境中番茄叶病害检测识别精度低、效果差的问题,以及现有检测识别方法效率低下、模型庞大复杂难以实际应用挑战。针对这些不足,本文改进策略的动机在于提升模型的轻量化和高精度检测效果,具体通过 3 个主要改进提高

了模型性能;使用了 GhostHGNetV2 作为核心网络;通过 C2f-DWR-DRB 技术优化了特征融合;采用了 LSCG 检测头。实验显示 GDDL-YOLOv8n 模型在检测性能上超越了标准 YOLOv8n 模型,具体表现在高的检测精度($mAP@0.5$ 为 98.4%, $mAP@0.5-0.95$ 为 92.3%),同时极大减少了模型参数(减少 49.13%)、计算需求(降低 37.04%)和内存使用(减少 46.67%)。此外还开发了一个

基于 PyQt5 的用户界面,支持图片和视频检测,以及摄像头实时识别,增强了模型的实用性。GDDL-YOLOv8n 模型在识别番茄叶病害上取得了进展,为智慧农业提供了实用的解决方案,有助于农业的数字化发展,并为相关领域的研究提供了新的思路。

未来的研究可以聚焦于以下几个方向:首先,将模型应用到更多农作物病害检测中,开发更通用的检测方法;其次,探索更好的训练策略和数据增强技术,增强模型在多变环境下的稳定性;最后将系统与物联网和边缘计算结合,以实现智慧农业的广泛应用。

参考文献

- [1] 张一帆,张梅,陈杰. 基于改进 YOLO v7 的果蔬叶片病害检测算法[J]. 兰州工业学院学报, 2024, 31(4): 48-53.
ZHANG Y F, ZHANG M, CHEN J. An improved YOLOv7-based algorithm for fruit and vegetable leaf disease detection[J]. Journal of Lanzhou Institute of Technology, 2024, 31(4):48-53.
- [2] 李大华,孔舒,李栋,等. 基于改进 SSD 模型的柑橘叶片病害轻量化检测模型[J]. 浙江农业学报, 2024, 36(3):662-670.
LI D H, KONG SH, LI D, et al. A lightweight citrus leaf disease detection model based on improved SSD[J]. Acta Agriculturae Zhejiangensis, 2024, 36(3):662-670.
- [3] 陶兆胜,石鑫宇,王勇,等. 基于改进 YOLOv5s 的番茄叶片病害检测方法[J]. 沈阳农业大学学报, 2023, 54(6):712-721.
TAO ZH SH, SHI X Y, WANG Y, et al. Tomato leaf disease detection method based on improved YOLOv5s [J]. Journal of Shenyang Agricultural University, 2023, 54(6):712-721.
- [4] 梁冬悦. 基于深度学习的草莓叶片病害检测研究[D]. 泰安:山东农业大学, 2024.
LIANG D Y. Research on strawberry leaf disease detection based on deep learning[D]. Taian: Shandong Agricultural University, 2024.
- [5] 赵艳芹,王萌. 改进 YOLOv5 模型的番茄叶部病害检测算法[J]. 黑龙江科技大学学报, 2023, 33(1):136-141.
ZHAO Y Q, WANG M. Tomato leaf disease detection algorithm based on improved YOLOv5 model [J]. Journal of Heilongjiang University of Science and Technology, 2023, 33(1):136-141.
- [6] 许悦,陈琳. 基于改进 YOLO v8 的番茄叶片病害检测算法[J]. 江苏农业科学, 2024, 52(17):192-200.
XU Y, CHEN L. Tomato leaf disease detection algorithm based on improved YOLOv8 [J]. Jiangsu Agricultural Sciences, 2024, 52(17):192-200.
- [7] 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.
- [8] 赵嘉威,田光兆,邱畅,等. 基于改进 YOLOv4 算法的苹果叶片病害检测方法[J]. 江苏农业科学, 2023, 51(9):193-199.
ZHAO J W, TIAN G ZH, QIU CH, et al. Apple leaf disease detection method based on improved YOLOv4 algorithm[J]. Jiangsu Agricultural Sciences, 2023, 51(9):193-199.
- [9] 曾亮,彭龔. 基于改进 YOLOv8 的马铃薯叶片病害检测算法[J]. 洛阳理工学院学报(自然科学版), 2024, 34(3):62-69.
ZENG L, PENG Y. Potato leaf disease detection algorithm based on improved YOLOv8[J]. Journal of Luoyang Institute of Science and Technology(Natural Science Edition), 2024, 34(3):62-69.
- [10] 戴林华,黎远松,石睿. 基于改进 YOLOv8n 算法的水稻叶片病害检测[J]. 湖北民族大学学报(自然科学版), 2024, 42(3):382-388.
DAI L H, LI Y S, SHI R. Rice leaf disease detection based on improved YOLOv8n algorithm[J]. Journal of Hubei University for Nationalities(Natural Science Edition), 2024, 42(3):382-388.
- [11] 李康顺,杨振盛,江梓锋,等. 基于改进 YOLOX-Nano 的农作物叶片病害检测与识别方法[J]. 华南农业大学学报, 2023, 44(4):593-603.
LI K SH, YANG ZH SH, JIANG Z F, et al. Crop leaf disease detection and recognition method based on improved YOLOX-Nano[J]. Journal of South China Agricultural University, 2023, 44(4):593-603.
- [12] 刘莎. 基于轻量型网络的苹果叶片病害检测研究[D]. 杨凌:西北农林科技大学, 2023.
LIU SH. Research on apple leaf disease detection based on lightweight network [D]. Yangling: Northwest A&F University, 2023.
- [13] 杨巧梅,崔婷婷,袁永榜,等. 轻量化 YOLO 模型在农作物微小病虫害检测中的应用研究[J]. 中国农机化学报, 2024, 45(9):265-270.
YANG Q M, CUI T T, YUAN Y B, et al. Research on application of lightweight YOLO model in crop micro pest and disease detection [J]. Journal of Chinese Agricultural Mechanization, 2024, 45(9): 265-270.
- [14] 盛帅,段先华,胡维康,等. Dynamic-YOLOX:复杂

背景下的苹果叶片病害检测模型[J]. 计算机科学与探索, 2024, 18(8):2118-2129.

SHENG SH, DUAN X H, HU W K, et al. Dynamic-YOLOX: Apple leaf disease detection model in complex background [J]. Computer Science and Exploration, 2024, 18(8):2118-2129.

[15] WEI H, LIU X, XU S, et al. DWRSeg: Rethinking efficient acquisition of multi-scale contextual information for real-time semantic segmentation[J]. ArXiv preprint arXiv:2203.00305, 2022.

[16] YOU L, CHEN Y, XIAO C, et al. Multi-object vehicle detection and tracking algorithm based on improved YOLOv8 and ByteTrack[J]. Electronics, 2024, 13(15):3033-3040.

[17] TANG Y, HAN K, GUO J, et al. GhostNetv2: Enhance cheap operation with long-range attention[J]. Advances in Neural Information Processing Systems, 2022, 35:9969-9982.

[18] XIA H, DING Z. Hgnet: Hybrid generative network for zero-shot domain adaptation[C]. Computer Vision-ECCV 2020: 16th European Conference, Cham: Springer, 2020:55-70.

[19] YANG G, WANG J, NIE Z, et al. A lightweight YOLOv8 tomato detection algorithm combining feature enhancement and attention[J]. Agronomy, 2023, 13(7):1824-1831.

[20] MEIER B. Python GUI programming cookbook: Develop functional and responsive user interfaces with tkinter and PyQt5[M]. Birmingham: Packt Publishing Ltd, 2019.

作者简介

胡艳茹, 硕士研究生, 讲师, 主要研究方向为深度学习、智慧农业等。

刘德全(通信作者), 博士, 副教授, 主要研究方向为图像处理。

E-mail:yixing_166@qq.com