

夏顺兴,倪 铭,罗友璐,等. 基于改进 YOLOv8n 的草莓叶片病害检测方法[J]. 江苏农业学报,2025,41(4):664-675.

doi:10.3969/j.issn.1000-4440.2025.04.005

## 基于改进 YOLOv8n 的草莓叶片病害检测方法

夏顺兴, 倪 铭, 罗友璐, 贺英豪, 赵涛涛

(四川农业大学信息工程学院,四川 雅安 625014)

**摘要:** 为提高目标检测模型在果园环境中对草莓叶片病害的检测能力,本研究以 YOLOv8n 模型为基准模型,引入动态卷积(Dynamic convolution)模块替换骨干网络的第3个卷积层和颈部网络的部分 C2f 模块,引入 GSConv 和 Slim-neck 模块替换颈部网络的卷积层和部分 C2f 模块,并引入内容感知特征重组上采样(CARAFE)算子替换上采样中的最近邻插值法,提出了一种改进的 YOLOv8n 模型——YOLOv8n-DGC,以期在保持模型轻量化的同时提高模型对草莓叶片病害的检测精度。结果表明,改进后的模型 YOLOv8n-DGC 对草莓叶片病害检测的交并比(*IoU*)阈值为 0.50 时的平均精度均值( $mAP_{50}$ )、*IoU* 阈值范围为 0.50~0.95 的平均精度均值( $mAP_{50:95}$ )、精确率和召回率分别比基准模型提高 2.5 个百分点、1.5 个百分点、1.6 个百分点和 1.6 个百分点,模型大小和参数量分别增加 3.2% 和 3.3%,而浮点运算量减少 8.6%。与 Faster R-CNN、SSD、YOLOv5s、YOLOv7-tiny 等模型相比,YOLOv8n-DGC 模型能更好地实现检测精度与效率的平衡,更适合布置到轻量化的检测设备或终端中。

**关键词:** 草莓; 叶片病害; 目标检测; YOLOv8n; 动态卷积; GSConv; CARAFE

**中图分类号:** TP391.4 **文献标识码:** A **文章编号:** 1000-4440(2025)04-0664-12

## Strawberry leaf disease detection method based on improved YOLOv8n

XIA Shunxing, NI Ming, LUO Youlu, HE Yinghao, ZHAO Taotao

(College of Information Engineering, Sichuan Agricultural University, Ya'an 625014, China)

**Abstract:** In order to improve the detection ability of target detection models for strawberry leaf diseases in orchard environment, this study used the YOLOv8n model as the baseline model, introduced the dynamic convolution module to replace the third convolution layer of the backbone network and part of the C2f module of the neck network, introduced the GSConv and Slim-neck module to replace the convolution layer and part of the C2f module of the neck network, and introduced the content-aware reassembly of features (CARAFE) operator to replace the nearest neighbor interpolation method in upsampling. An improved YOLOv8n model named YOLOv8n-DGC was proposed to improve the detection accuracy of strawberry leaf diseases while maintaining the lightweight of the model. The results showed that the mean average precision when the intersection over union (*IoU*) threshold was 0.50 ( $mAP_{50}$ ), the mean average precision when the *IoU* was between 0.50 and 0.95 ( $mAP_{50:95}$ ), precision and recall rate of the improved model YOLOv8n-DGC for strawberry leaf disease detection were 2.5 percentage points, 1.5 percentage points, 1.6 percentage points and 1.6 percentage points higher than those of the baseline model, respectively. The model size and parameter quantity increased by 3.2% and 3.3%, respectively, while the number of floating point of operations decreased by 8.6%. Compared with models such as Faster R-CNN, SSD, YOLOv5s, and YOLOv7-tiny, the YOLOv8n-DGC model better achieved a balance between detection accuracy and efficiency, and was more suitable for placement in lightweight detection equipment or terminals.

收稿日期:2024-10-11

基金项目:四川省自然科学基金面上项目(2022NSFC0172)

作者简介:夏顺兴(2001-),男,四川眉山人,硕士研究生,主要从事深度学习和目标检测研究。(E-mail)xsxaca@163.com

通讯作者:倪 铭,(E-mail)nm@sicau.edu.cn

ciency, and was more suitable for placement in lightweight detection equipment or terminals.

**Key words:** strawberry; leaf diseases; object detection; YOLOv8n; dynamic convolution; GSConv; CARAFE

草莓属蔷薇科浆果类多年生草本植物,素有“水果皇后”的美称。草莓果实颜色艳丽,芳香多汁,且富含糖类、氨基酸、维生素以及钙、磷、铁等多种营养物质<sup>[1-2]</sup>,具有抗氧化、抗癌、抗炎等功能<sup>[3-4]</sup>。近年来,中国草莓种植面积均较大,产量也较高<sup>[5]</sup>。草莓栽培过程中,病害是导致草莓产量减少、品质下降的重要原因之一,及时并准确识别病害类型对草莓安全生产、果农效益提高具有重要意义。

近年来,随着计算机技术和人工智能的发展,特别是深度学习技术的应用,作物病害检测技术得到了显著的提升。深度学习是一种基于人工神经网络的机器学习方法,具有强大的特征提取和模式识别能力<sup>[6]</sup>。通过对大量数据的学习,深度学习模型能够自动提取图像中的复杂特征,实现高效、准确的病害检测。目前目标检测领域的深度学习方法主要分为两类:一类是以 R-CNN<sup>[7]</sup>、Fast R-CNN<sup>[8]</sup>、Faster R-CNN<sup>[9]</sup> 为代表的两阶段检测算法,该类算法分两步完成,首先生成候选目标区域,然后对候选目标区域进行分类和定位;另一类是以 YOLO 系列算法<sup>[10-13]</sup>、SSD 算法<sup>[14]</sup> 为代表的单阶段检测算法,该类算法同时进行边界框位置判断和类别分类。相比较而言,单阶段分类算法简化了处理流程,因而具有更快的检测速度。

由于 YOLO 算法在特征提取、识别实时性、泛化性等方面的优势,目前, YOLO 算法在作物病虫害识别及果实目标检测等领域得到了广泛应用。杨宇游等<sup>[15]</sup> 在 YOLOv5 模型的主干网络中引入 BoTNet 模块,并用 GIoU-NMS 算法替换原来的非极大值抑制(NMS)算法,对 YOLOv5 模型进行优化,改进后的模型对草莓病害的识别精确率和平均精度均值分别比原模型提升 2.1 个百分点和 1.2 个百分点。Li 等<sup>[16]</sup> 利用深度卷积和 CSPNet 结构,将 YOLOv4 模型优化为 DAC-YOLOv4 模型,并用其进行草莓叶片白粉病的检测,既提高了检测效果,又实现了模型的轻量化。公徐路等<sup>[17]</sup> 对 YOLOv5 模型进行一系列的优化,发现改进后的模型对苹果叶片小目标病害检测的平均精度均值和准确率分别比原模型提高 0.8 个百分点和 3.0 个百分点,而参数量和浮点计算量分别减少 6.17 MB 和 13.8 G。时雷等<sup>[18]</sup> 利用全维动态卷积(ODConv)替换 YOLOv8 主干网络中的标准卷积(Conv),利用 Efficient RepGFPN 特征融合网络改进原来的 Neck 网络,并采用 EIoU 损失函数替换 CIoU 损失函数,提高了 YOLOv8s 模型对小

麦小穗赤霉病识别的准确率和效率。针对无人机采集的茶叶枯病图像中病斑差异大、病斑和背景相似性高等问题,胡根生等<sup>[19]</sup> 在 YOLOv5s 模型的基础上,使用轻量型的 M-Backbone 作为骨干网络设计了一个轻量型网络 LiTLBNet,其对茶叶枯病病斑的检测精度与原模型接近,但模型大小仅为原 YOLOv5s 模型的 13.9%。罗友璐等<sup>[20]</sup> 以 YOLOv8 模型为基准,利用空间深度转换卷积替换原有的卷积模块,引入多尺度空洞注意力机制,同时参考重参数化卷积神经网络架构对检测头进行了改进,提出了一种苹果叶片病害检测的改进算法,改进后 YOLOv8n 模型对苹果叶片病害检测的平均精度均值( $mAP_{50}$ )和准确率分别比原模型提高 2.7 个百分点和 0.9 个百分点。贺英豪等<sup>[21]</sup> 以 YOLOv5 模型为基准,利用 Focus-Maxpool 模块替换主干网络中的下采样卷积,利用 focal loss 和交叉熵函数的加权损失作为模型的分类损失,提高了模型对高遮挡果园环境背景下李果实的识别精度。

针对草莓叶片病害检测算法研究较少的现状,本研究以性能稳定、识别精确度和效率高的 YOLOv8n 模型为基准,结合草莓叶片病害特征,进一步优化相关模块,以提高模型对草莓叶片病害检测精度,降低模型运算量,实现快速、准确的草莓叶片病害检测,为果农的精准管理提供依据。

## 1 材料与方 法

### 1.1 数据集的构建

本研究以草莓生产中常见的 3 种叶片病害叶焦病、叶斑病和白粉病为检测目标(图 1)。数据集来源为四川雅安草莓采摘园实地拍摄图片、Kaggle 平台公开数据集 Strawberry disease data(<http://www.kaggle.com>)和百度图片,共 892 张。为增强研究结果的可信度,数据集 Strawberry disease data 及百度图片均选择自然果园环境下的草莓植株。为了防止数据集过少导致的训练结果过拟合,保持不同类型病斑(标签)数量相对均衡,将筛选得到的图片进行添加随机噪声、亮度调节、旋转、裁剪、平移、镜像等数据增强处理,最终得到 1 371 张图片,按照 8:2 的比例划分为训练集(1 097 张)和验证集(274 张),叶焦病、叶斑病和白粉病标签数量分别为 1 907 个、3 290 个和 1 762 个。

### 1.2 YOLOv8n 检测模型及其改进

YOLOv8n 模型具有参数量少、检测速度快、综合性能良好等特点,因此,本研究选择 YOLOv8n 作为草莓叶片病害检测的基准模型。但考虑到草莓叶片病害病斑较小、不同病害病斑尺寸差异大等特征,研究中对 YOLOv8n 模型进行了适当改进。主要改进体现在以下几个方面:一是将 YOLOv8n 模型主干网络(Backbone)和颈部网络(Neck)的部分标准卷积替换为动态卷积,提高模型的特征提取能力;二是引入轻量化卷积 GSCov 及 Slim-neck 设计范式重新设计 Neck 网络,在实现模型轻量化的同时,提升模型推理速度和特征融合能力;三是将最近邻插值上

采样算子替换为 CARAFE 算子,减少草莓病害小目标导致的特征图语义信息丢失,提高模型的检测精度。YOLOv8n 原模型和改进后的模型 YOLOv8n-DGC 的结构如图 2 所示。


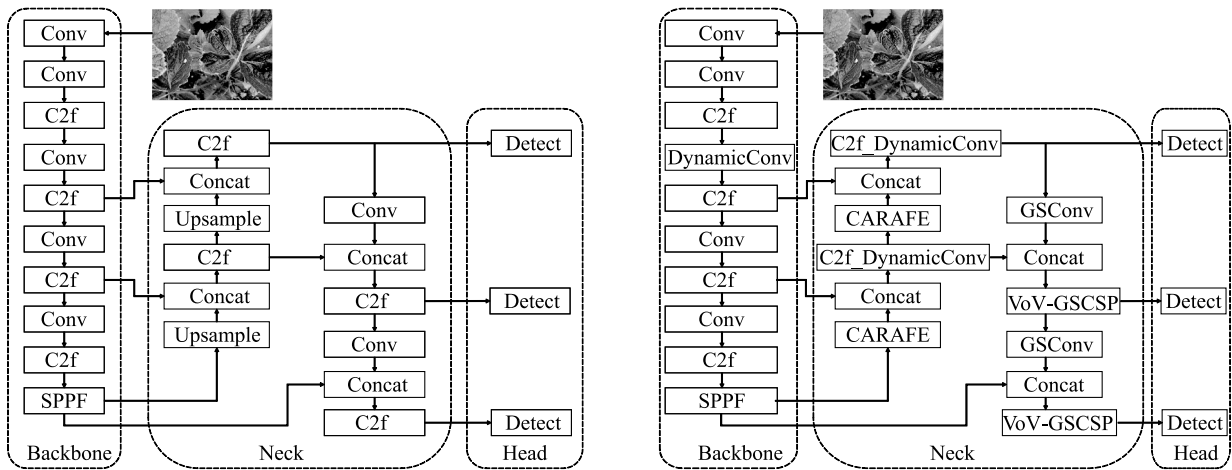


图 1 数据集图例  
Fig.1 Dataset image illustration



Backbone: 主干网络; Neck: 颈部网络; Head: 头部网络; Conv: 卷积; C2f: 特征融合模块; DynamicConv: 动态卷积; SPPF: 快速空间金字塔池化; C2f\_DynamicConv: 引入动态卷积的特征融合模块; Concat: 连接操作; Upsample: 最近邻上采样; CARAFE: 内容感知特征重组上采样算子; GSCov: GSCov 卷积; VoV-GSCSP: 跨阶段部分网络结构; Detect: 检测头。

图 2 YOLOv8n 原模型(左)和改进后的模型 YOLOv8n-DGC(右)结构  
Fig.2 YOLOv8n (left) and improved YOLOv8n-DGC (right) structure diagram

1.2.1 动态卷积(Dynamic convolution)模块 在深度学习领域,标准卷积层是卷积神经网络(Convolutional neural network, CNN)的基本构建块之一。标准卷积层通过固定的卷积核权重对输入特征图进行卷积运算,以提取特征。标准卷积层的操作是静态的,即对于所有输入数据,卷积核权重保持不变(图 3a)。尽管标准卷积层在许多任务中表现出色,但在处理具有显著变化特征的输入时,其静态特性可能会限制模型的性能。因此针对草莓叶片病害染病程度差异较大、特征不明显、背景复杂等问题,本研究引入了动态卷积<sup>[22]</sup>。动态卷积能根据输入特征动态调整权重。这种动态特性使卷积层能够更好地


捕捉不同输入的特征。

卷积权重张量(Convolutional weight tensor)是卷积神经网络中用于执行卷积操作的参数集合,其定义了如何通过滑动窗口的方式在输入特征图上进行局部加权求和,以生成输出特征图。动态卷积由多专家机制(Mixture of experts, MoE)实现(图 3b)。每个专家都有一个独立的卷积权重张量,即独立的卷积运算。多专家机制能增强模型的特征提取能力,其定义为:

$$W' = \sum_{i=1}^M \alpha_i W_i \tag{1}$$

$$Y = X \times W'$$

式中,  $W'$  表示通过动态卷积机制生成的卷积权重张量;  $X$  表示输入特征图;  $Y$  表示输出特征图;  $W_i$  表示第  $i$  个卷积权重张量;  $\alpha_i$  代表对应的动态系数, 即专家的权重;  $M$  为专家数量;  $\times$  表示卷积运算, 即得到卷积权重张量与动态系数乘积之和后再与输入特征进行卷积<sup>[23]</sup>。



Expert: 专家; Mixed Expert: 混合专家; MoE: 多专家机制;  $\alpha_1 \sim \alpha_M$ : 动态系数;  $M$ : 专家数量。

图3 多专家机制

Fig.3 Mixture of experts

对于每个输入特征, 路由网络 (Routing network) 会计算出一组路由权重 (Routing weights), 即动态系数 ( $\alpha_i$ ), 这组系数与专家数量相同, 每个系数对应一个专家。然后, 这些动态系数被用来对专家的卷积权重张量进行加权, 从而生成一个最终的、与输入相关的卷积层。动态系数的生成过程如式 (2) 所示。对于输入的特征图  $X$ , 使用全局平均池化将信息融合成向量, 然后使用具有 softmax 激活函数的多层感知器 (MLP) 模块动态生成动态系数:

$$\alpha = \text{softmax} \{ \text{MLP} [ \text{Pool} (X) ] \} \quad (2)$$

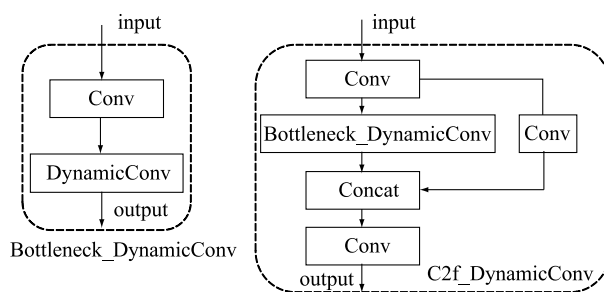
通过将动态卷积替换掉原 Backbone 网络中的标准卷积操作, 加强模型对不同检测目标的特征提取能力。

在动态卷积的基础上, 进一步设计了 Bottleneck\_DynamicConv 和 C2f\_DynamicConv 结构, 如图 4 所示。Neck 网络中部分 C2f 替换为 C2f\_DynamicConv, 进一步提升模型检测性能。

### 1.2.2 基于轻量级卷积 GSConv 的 Neck 网络改进

为了平衡模型的计算复杂度, 引入基于深度可分离卷积 (Depthwise separable convolution, DSConv)<sup>[24]</sup> 改进的 GSConv 结构及 Slim-neck 范式<sup>[25]</sup>, 其中 Slim-neck 设计范式的核心思想是利用模块化、可组合的结构, 灵活地设计和替换 Neck 网络中的不同部分, 从而在成本和性能之间找到最佳平衡。

深度可分离卷积可以减少参数数量和浮点运算, 然而, 深度可分离卷积的通道信息是彼此分离的, 特征图的空间压缩和通道拓展将造成语义特征的丢

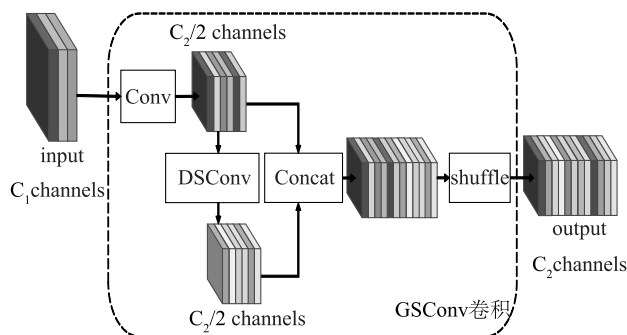


input: 输入; output: 输出; Conv: 卷积; DynamicConv: 动态卷积; Bottleneck\_DynamicConv: 引入动态卷积的瓶颈模块; Concat: 连接操作; C2f\_DynamicConv: 引入动态卷积的特征融合模块。

图4 Bottleneck\_DynamicConv 和 C2f\_DynamicConv 结构

Fig.4 Bottleneck\_DynamicConv and C2f\_DynamicConv structure diagram

失, 尤其是在检测目标较小、模糊不清的情况下, 以致模型特征提取能力大幅度下降, 这将对目标检测的精度造成影响<sup>[26]</sup>。为更好地平衡计算复杂度和通道传输信息保留, 研究中引入 GSConv 结构, 如图 5 所示。GSConv 将标准卷积和深度可分离卷积生成的信息进行 Shuffle<sup>[27]</sup> 操作, 彼此充分混合和渗透, 在不同的通道上均匀地交换局部特征信息。通过这个方法, 既能减少模型参数和浮点运算量, 又能有效利用标准卷积的通道密集优势, 尽可能地保留小检测目标的语义信息。



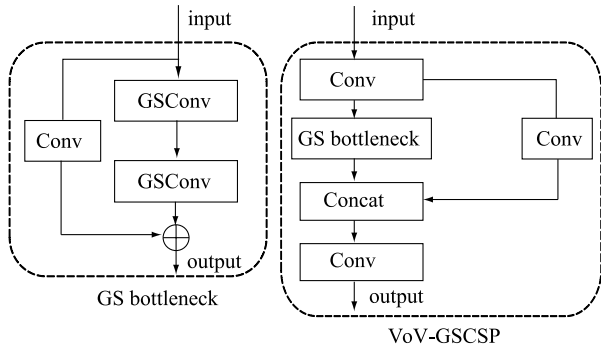
input: 输入; output: 输出;  $C_1$  channels:  $C_1$  通道数;  $C_2$  channels:  $C_2$  通道数;  $C_2/2$  channels:  $C_2/2$  通道数; Conv: 卷积; DSConv: 深度可分离卷积; Concat: 连接操作; shuffle: 混合; GSConv: GSConv 卷积。

图5 GSConv 结构

Fig.5 GSConv structure diagram

基于 GSConv, 引入 GS bottleneck 和 VoV-GSCSP 模块, 并根据 Slim-neck 范式, 灵活使用 GSConv 和 VoV-GSCSP 替换原 Neck 网络中的 Conv 和 C2f 结构, 以达到最优性能。GS bottleneck 和 VoV-GSCSP

的结构如图 6 所示。



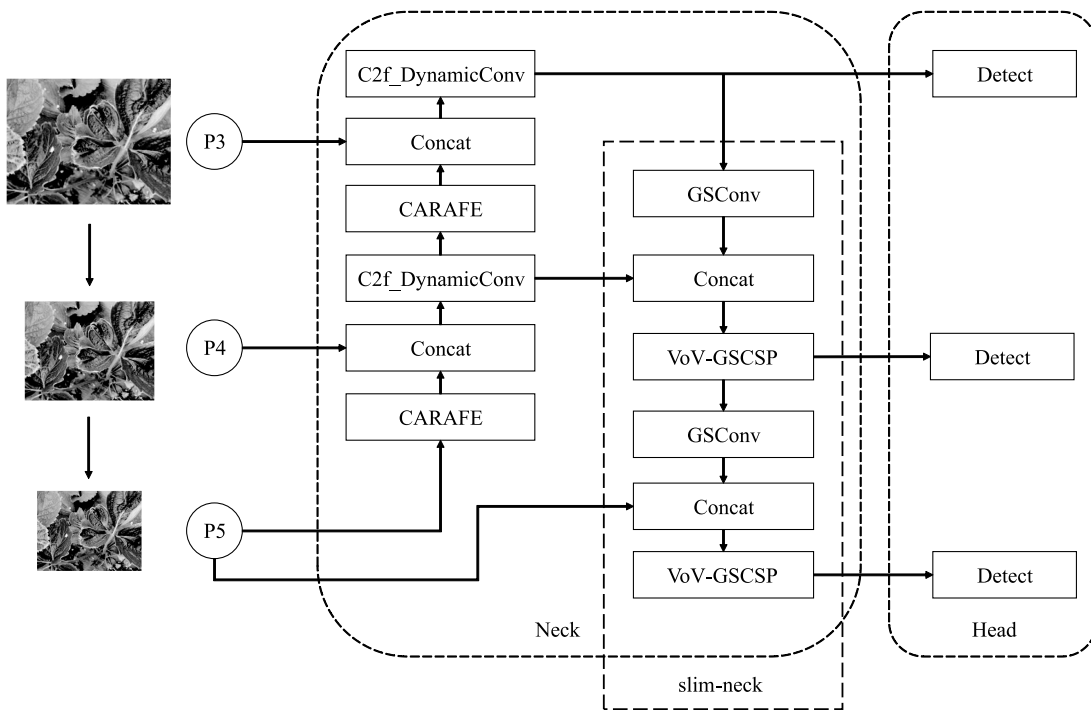
input; 输入; output; 输出; Conv; 卷积; GSConv; GSConv 卷积; Concat; 连接操作; GS bottleneck; GS 瓶颈网络; VoV-GSCSP; 跨阶段部分网络结构。

图 6 GS bottleneck 和 VoV-GSCSP 结构

Fig.6 GS bottleneck and VoV-GSCSP structure diagram

由于大量使用 GSConv 会显著增加网络层数, 导致推理时间显著增加, 因此根据 Slim-neck 设计思路, 选择只在 Neck 部分使用 GSConv 和 VoV-GSCSP 替换原有的 Conv 和部分 C2f 模块, 如图 7 所示。

1.2.3 CARAFE 上采样算子 YOLOv8n 模型默认使用最近邻插值法实现特征上采样操作, 这种方法实现简单, 计算速度快, 但由于插值结果缺乏连续性, 可能会造成图像灰度上的不连续, 在灰度变化大的地方可能会出现明显的锯齿状, 尤其是像草莓白粉病这类边缘不明显的病害, 插值后的图像会使得原本模糊的边缘仍然难以区分, 严重影响病害特征信息的提取。因此, 引入内容感知特征重组上采样算子 (CARAFE) [28] 代替原有的最近邻插值上采样算子。



P3; P3 输出层; P4; P4 输出层; P5; P5 输出层; Neck; 颈部网络; Head; 头部网络; C2f\_DynamicConv; 引入动态卷积的特征融合模块; Concat; 连接操作; CARAFE; 内容感知特征重组上采样算子; GSConv; GSConv 卷积; VoV-GSCSP; 跨阶段部分网络结构; Detect; 检测头; slim-neck; slim-neck 模块。

图 7 YOLOv8n-DGC 中的 Slim-neck 结构

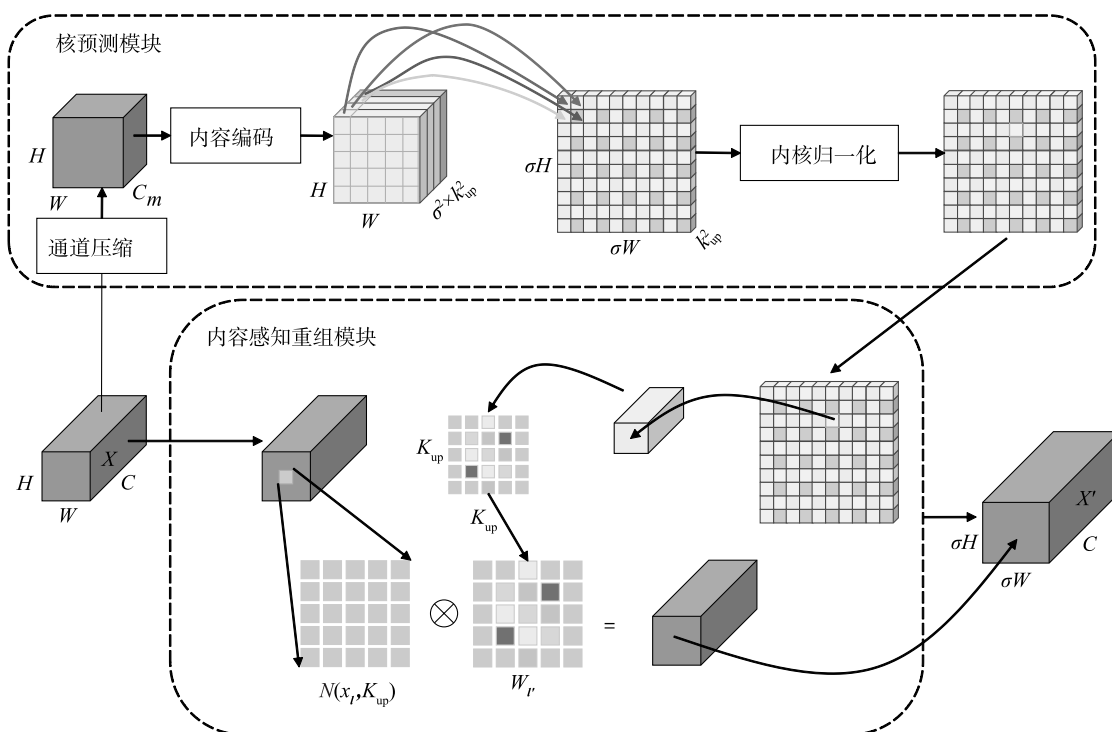
Fig.7 Slim-neck structure in YOLOv8n-DGC

CARAFE 上采样算子实现过程如图 8 所示: 假设给定一个尺寸为  $C \times H \times W$  的特征图  $X$ , CARAFE 将  $X$  进行通道压缩, 得到尺寸为  $C \times \sigma H \times \sigma W$  ( $\sigma$  为上采样倍率) 新的特征图  $X'$ , 通过核预测模块, 为  $X'$  的每个目标位置生成一个重组卷积核, 然后利用这个卷积核对

输入特征  $X$  进行重组, 从而生成上采样后的特征图。

由于重组过程考虑了更相关的局部信息, 可以更有效地捕捉和整合特征图中的语义信息, 从而提升特征图的语义表达能力。引入 CARAFE 算子, 可以使模型在处理复杂场景草莓叶片病害时, 能够更

准确地捕捉和表达图像中的重要信息,提高模型的精度。



$X$ :输入特征图; $X'$ :重组特征图; $H$ :特征图高; $W$ :特征图宽; $C$ :通道数; $C_m$ :压缩后的通道数; $\sigma$ :上采样倍率; $K_{up}$ :重组核大小; $W_r$ :重组卷积核; $x_l$ :输入特征图位置; $N$ :正方形区域。

图8 内容感知特征重组上采样(CARAFE)算子结构

Fig.8 Content-aware reassembly of features (CARAFE) operator structure diagram

为直观展示 CARAFE 上采样方法相较于传统上采样技术的优势,本研究选取深度神经网络中生成的一张特征图,首先进行4倍的下采样处理,然后再进行2倍最近邻插值上采样与2倍 CARAFE 上采样处理,结果如图9所示。从图中可以看出,最近邻插值上采样结果在目标边缘处出现了较为明显的锯齿状伪影,而 CARAFE 上采样结果在目标边缘部分呈现出更加细腻和自然的过渡,这说明 CARAFE 上采样能较好保留图像细节和边缘信息。

### 1.3 模型检测性能比较

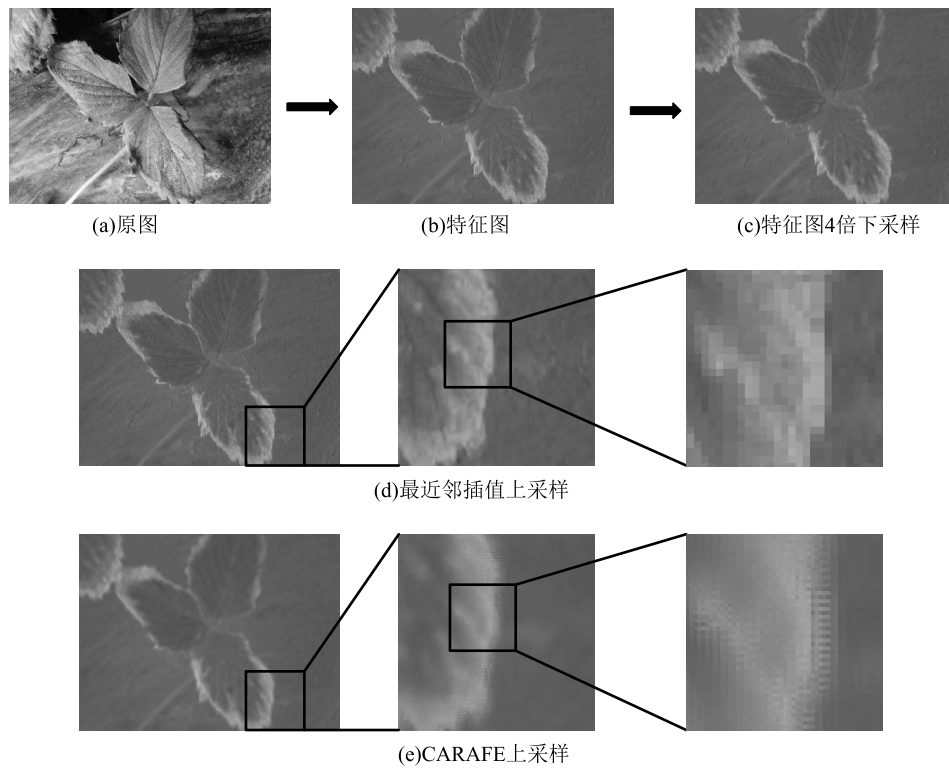
首先比较了 Backbone 网络不同位置 Conv 替换为 DynamicConv、Neck 网络中引入 C2f\_DynamicConv 模块后模型对草莓叶片病害的检测性能;然后分析了 YOLOv8n 原模型和改进模型 YOLOv8n-DGC 对草莓叶片病害检测性能差异,并开展消融试验。消融试验方案如表1所示。最后,进一步比较了目前流行的目标识别模型 Faster R-CNN、SSD、YOLOv5s、

YOLOv7-tiny、YOLOv8s、YOLOv10n 与 YOLOv8n-DGC 对草莓叶片病害的检测性能差异。

### 1.4 模型训练与测试

1.4.1 试验平台及参数设置 本研究所使用的操作系统为 Windows10,中央处理器(CPU)型号为 Intel Core i9-10900K 3.70 GHz, GPU 型号为 NVIDIA Quadro RTX 5000 (16 G 显存)。所用语言为 Python3.9.7,深度学习框架为 Pytorch2.0.1,并行计算平台为 CUDA11.7。试验中,图像分辨率设置为  $640 \times 640$ ,迭代次数 500,批量大小 8,采用随机梯度下降算法(SGD)优化器,动量参数 0.937,权重衰减速率 0.0005。

1.4.2 模型评价指标 选取平均精度均值(Mean average precision,  $mAP$ )、精确率(Precision,  $P$ )、召回率(Recall,  $R$ )、模型大小、参数量、浮点运算次数(Floating point operations,  $FLOPs$ )作为评估模型性能的指标。平均精度均值、精确率和召回率公式如下:



a: 原始图像; b: 深度神经网络生成的特征图; c: 特征图进行 4 倍下采样后得到特征图; d: 利用最近邻插值方法进行 2 倍上采样后的结果; e: 利用 CARAFE 方法进行 2 倍上采样后的结果。

图 9 最近邻插值上采样和内容感知特征重组上采样 (CARAFE) 效果对比

Fig.9 Comparison of effect between nearest neighbor interpolation upsampling and content-aware reassembly of features (CARAFE) upsampling

表 1 消融试验方案

Table 1 Design of ablation test

方案	DynamicConv 模块	GSCConv 模块	CARAFE 模块
0	-	-	-
1	√	-	-
2	-	√	-
3	-	-	√
4	√	√	-
5	√	-	√
6	-	√	√
7	√	√	√

“-”表示在方案中不采用,“√”表示在方案中采用。

$$mAP = \frac{\sum_i AP_i}{n} \times 100\% \quad (3)$$

$$P = \frac{TP}{TP+FP} \times 100\% \quad (4)$$

$$R = \frac{TP}{TP+FN} \times 100\% \quad (5)$$

式中,  $AP_i$  为第  $i$  个类别的平均精度, 即精确率与召回率 ( $PR$ ) 曲线中曲线与坐标轴所围成的图形面积。  $TP$  为正确预测的真阳性样本;  $FP$  为错误预测的假阳性样本;  $FN$  为漏检的假阴性样本;  $n$  为分类类别数。

## 2 结果与分析

### 2.1 模型 Backbone 网络不同位置 Conv 替换为 DynamicConv 对检测性能的影响

基准模型 Backbone 网络不同位置 Conv 替换为 DynamicConv 对草莓叶片病害检测性能的影响如表 2 所示。从表中可以看出, 主干网络 (Backbone) 中第 3 个标准卷积 (Conv) 替换为动态卷积的效果最好,  $mAP_{50}$ 、 $mAP_{50:95}$ 、精确率和召回率分别为 88.2%、58.2%、87.0% 和 83.5%, 且模型大小、参数

量和浮点运算量均最低。其原因可能在于,深度神经网络中,靠近输入层的卷积层主要负责提取图像中的边缘、纹理等低级特征,而靠近输出层的卷积层则更多地学习高级语义特征,负责更为复杂、抽象的图像特征提取,且主要表现为语义信息<sup>[29]</sup>。第3个

卷积层处于 Backbone 的中间部分,既能够捕捉较为细节的局部特征,又能够学习一定的全局特征,将该位置的 Conv 替换为 DynamicConv,能充分发挥动态卷积的自适应调整能力,使得模型在局部特征和全局信息之间取得更好的平衡,从而提升检测性能。

表2 不同位置 Conv 替换为 DynamicConv 对草莓叶片病害检测性能的影响

Table 2 Effect of replacing Conv with DynamicConv at different locations on the performance of strawberry leaf disease detection

替换位置	$mAP_{50}(\%)$	$mAP_{50:95}(\%)$	精确率(%)	召回率(%)	模型大小(MB)	参数量(M)	浮点运算量(G)
1	86.5	57.6	85.9	82.3	6.5	3.1	7.6
2	87.4	57.8	83.9	84.7	6.5	3.1	7.4
3	88.2	58.2	87.0	83.5	6.5	3.1	7.4
4	87.2	58.0	85.2	84.1	7.0	3.3	7.4
5	87.8	58.3	85.5	84.6	8.3	4.0	7.4

替换位置编号分别对应图2中主干网络部分从上向下的标准卷积模块。

## 2.2 C2f\_DynamicConv 在 Neck 中的效果

C2f 是 YOLOv8 中用于提取多层次特征的基础模块。该模块通过分裂特征图和跨层连接,有效地提高了网络的表达能力,促进了梯度信息流动。将 Neck 网络中的部分 C2f 替换为 C2f\_DynamicConv,能在不同的层级和尺度上选择更合适的卷积核,使得特征能够在多个层次上得到优化,增强了多尺度特征的融合能力,这有助于提高模型对不同尺度物

体的检测能力,进一步提升模型的目标检测性能。将 Neck 网络中的部分 C2f 替换为 C2f\_DynamicConv 后,模型对草莓叶片病害的检测性能的影响如表3所示。从表中可以看出,替换后,模型对草莓叶片病害检测的  $mAP_{50}$ 、 $mAP_{50:95}$ 、精确率分别较替换前增加 1.1 个百分点、0.7 个百分点和 2.3 个百分点,模型大小和参数量略有增加,但模型浮点运算量下降 3.9%。

表3 Neck 网络中部分 C2f 模块替换为 C2f\_DynamicConv 模块后模型的检测性能比较

Table 3 Comparison of model detection performance after replacing some of the C2f modules in the Neck network with the C2f\_DynamicConv module

C2f_DynamicConv	$mAP_{50}(\%)$	$mAP_{50:95}(\%)$	精确率(%)	召回率(%)	模型大小(MB)	参数量(M)	浮点运算量(G)
-	87.1	57.5	84.7	85.1	6.3	3.0	7.7
√	88.2	58.2	87.0	83.5	6.5	3.1	7.4

“-”表示仅在 Backbone 加入 DynamicConv,“√”表示在 Backbone 加入 DynamicConv 以及在 Neck 加入 C2f\_DynamicConv。 $mAP_{50}$ 表示交并比(IoU)阈值为 0.50 时的平均精度均值; $mAP_{50:95}$ 表示 IoU 阈值范围为 0.50~0.90 的平均精度均值。

## 2.3 消融试验

引入不同替换模块对模型检测性能影响的消融试验结果如表4所示。从表中可以看出,采用 DynamicConv 替换第3个 Conv 模块和 C2f\_DynamicConv 替换 Neck 部分 C2f 的方案1后,模型对草莓叶片病害检测的  $mAP_{50}$ 、 $mAP_{50:95}$ 、召回率分别比基准模型提高 0.8 个百分点、0.5 个百分点和 1.3 个百分点,模型大小和参数量分别增加 6.3% 和 6.7%,浮点运算量减少 6.2%。单独利用 GSConv 卷积和 Slim-neck 模块的方案2后,模型对草莓叶片病害检

测的  $mAP_{50}$ 、 $mAP_{50:95}$ 、召回率分别比基准模型提高 0.9 个百分点、0.5 个百分点和 1.4 个百分点,模型大小、参数量及浮点运算量分别减少 4.8%、6.7% 和 6.2%,这表明 GSConv 模块对模型精度有一定的促进作用,同时也带来检测效率的提高。单独利用 CARAFE 算子进行上采样的方案3后,模型对草莓叶片病害检测的  $mAP_{50}$ 、 $mAP_{50:95}$ 、召回率分别比基准模型提高 1.1 个百分点、0.8 个百分点和 0.3 个百分点,模型大小、参数量及浮点运算量分别增加 4.8%、3.3% 和 3.7%,说明 CARAFE 算子的使用能

减少草莓叶片病害细小病斑的特征信息丢失,确保特征信息的完整性,更有效地捕捉和整合特征图中的语义信息。同时利用 DynamicConv 模块和 GSConv 模块进行替换的方案 4 后,模型对草莓叶片病害检测的  $mAP_{50}$ 、 $mAP_{50:95}$ 、精确率分别比基准模型提高 0.5 个百分点、0.8 个百分点和 1.1 个百分点,模型大小和参数量无变化,浮点运算量减少 11.1%。同时利用 CARAFE 与 DynamicConv 模块替代后(方案 5),模型对草莓叶片病害检测的  $mAP_{50}$ 、 $mAP_{50:95}$ 、召回率分别比基准模型提高 1.5 个百分点、0.8 个百分点和 1.0 个百分点,模型大小和参数量分别增加 11.1% 和 10.0%,而浮点运算量减少 2.5%。同时利用 CARAFE 与 GSConv 模块替代后(方案 6),模型对草莓叶片病害检测的  $mAP_{50}$ 、

$mAP_{50:95}$ 、召回率分别比基准模型提高 0.2 个百分点、0.1 个百分点和 1.0 个百分点,模型大小、参数量和浮点运算量分别减少增加 1.6%、3.3% 和 2.5%。同时利用 3 个替换模块的方案 7,模型对草莓叶片病害检测的  $mAP_{50}$ 、 $mAP_{50:95}$ 、精确率和召回率分别比基准模型提高 2.5 个百分点、1.5 个百分点、1.6 个百分点和 1.6 个百分点,模型大小和参数量分别增加 3.2% 和 3.3%,而浮点运算量减少 8.6%,效果最好。这说明 DynamicConv 的使用能增强卷积层对局部和全局特征的提取能力,CARAFE 的使用能确保上采样过程中细节特征的完整性,模型在特征提取和融合上表现出更强的适应性和准确性,提高了模型的鲁棒性,特别适合背景干扰较多、形态复杂的叶片病害检测。

表 4 消融试验结果

Table 4 Ablation test results

方案	$mAP_{50}$ (%)	$mAP_{50:95}$ (%)	精确率 (%)	召回率 (%)	模型大小 (MB)	参数量 (M)	浮点运算量 (G)
0(基准模型)	85.7	56.7	85.4	81.9	6.3	3.0	8.1
1	86.5	57.2	85.0	83.2	6.7	3.2	7.6
2	86.6	57.2	86.1	83.3	6.0	2.8	7.6
3	86.8	57.5	86.9	82.2	6.6	3.1	8.4
4	86.2	57.5	86.5	81.7	6.3	3.0	7.2
5	87.2	57.5	86.5	82.9	7.0	3.3	7.9
6	85.9	56.8	85.5	82.9	6.2	2.9	7.9
7(优化模型)	88.2	58.2	87.0	83.5	6.5	3.1	7.4

$mAP_{50}$ 、 $mAP_{50:95}$  见表 3 注。

## 2.4 YOLOv8n 模型与改进模型 YOLOv8n-DGC 的检测效果对比

改进模型 YOLOv8n-DGC 和原模型 YOLOv8n 对草莓叶片病害检测效果如图 10 所示。从图中可以看出,改进后的模型能降低草莓叶片病害的漏检率与错检率,且病害识别置信度也有所提高。这说明引入动态卷积能加强模型对复杂背景和病害样本中草莓叶片病害的特征提取和学习能力;引入 GSConv 能降低模型的参数量,提高模型的特征融合能力;利用 CARAFE 算子替换最近邻插值法进行上采样,使得草莓叶片病害的特征信息更易被理解和表达,从而使改进后的模型识别效果优于原模型。图 11 为不同迭代次数下, YOLOv8n-DGC 模型和 YOLOv8n 模型对草莓叶片病害检测的平均精度均值变化特征。从图中可以看出,经

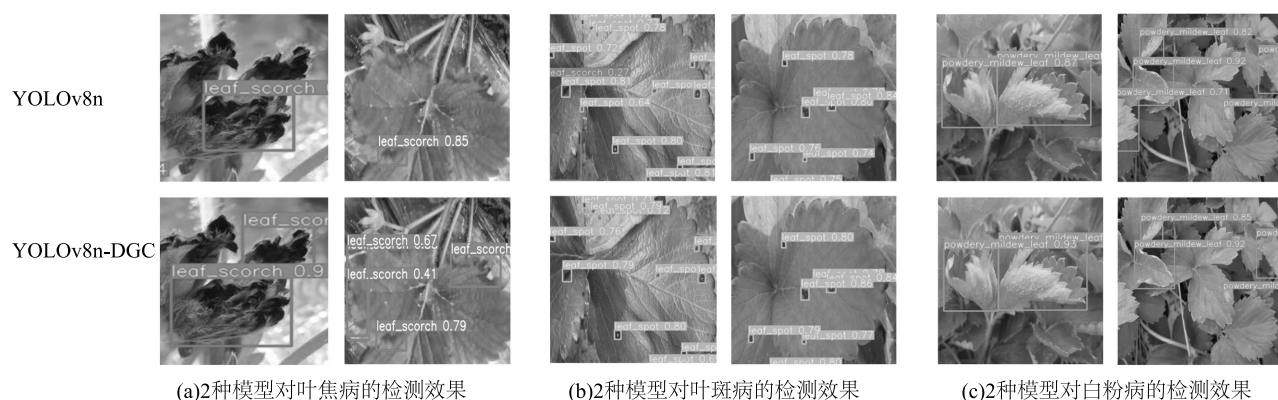
过几十次训练迭代后,2 个模型检测的  $mAP$  开始产生差距;迭代次数达 500 次时,2 个模型都趋于稳定,且差距明显。

## 2.5 改进 YOLOv8n 与其他模型的草莓叶片病害检测性能比较

改进 YOLOv8n 模型(YOLOv8n-DGC)与其他模型 Faster R-CNN、SSD、YOLOv5s、YOLOv7-tiny、YOLOv8s、YOLOv10n 等对草莓叶片病害检测性能的比较结果如表 5 所示。从表中可以看出,Faster R-CNN 和 SSD 模型对草莓叶片病害识别的平均精度均值( $mAP_{50}$ )分别仅为 59.8% 和 58.2%,且参数量和浮点运算量巨大,不能满足草莓叶片病害检测的精度要求。YOLOv5s 模型对的草莓叶片病害识别的平均精度均值( $mAP_{50}$ )较高,达 87.7%,但参数量和浮点运算量同样较大,分别为 YOLOv8n-DGC 模型

的 2.26 倍、2.14 倍。同样, YOLOv7-tiny、YOLOv8s 模型的参数量和浮点运算量分别是 YOLOv8n-DGC 模型的 1.94 倍、3.58 倍和 1.76 倍、3.84 倍, 且检测的平均精度均值 ( $mAP_{50}$ ) 分别比 YOLOv8n-DGC 模型低 4.4 个百分点和 1.3 个百分点。YOLOv10n 模


型的参数量低于 YOLOv8n-DGC 模型, 但其检测的精度均值 ( $mAP_{50}$ ) 亦低 3.5 个百分点。上述结果说明, 改进后的 YOLOv8n-DGC 模型综合性能较优, 即本研究提出的改进算法在草莓叶片病害检测中是有效的。



检测框后的数字为置信度。

图 10 YOLOv8n 和 YOLOv8n-DGC 的改进前后检测效果对比

Fig.10 Comparison of the detection effects of YOLOv8n and YOLOv8n-DGC



$mAP_{50}$ 、 $mAP_{50:95}$  见表 3 注。

图 11 平均精度均值 ( $mAP$ ) 对比图

Fig.11 Comparison diagram of mean average precision ( $mAP$ )

表 5 不同模型对草莓叶片病害检测性能比较

Table 5 Comparison of the performance of different models for strawberry leaf disease detection

模型	$mAP_{50}$ (%)	$mAP_{50:95}$ (%)	精确率 (%)	召回率 (%)	模型大小 (MB)	参数量 (M)	浮点运算量 (G)
Faster R-CNN	59.8	29.9	41.5	72.2	108.2	136.7	369.7
SSD	58.2	32.3	82.6	37.7	91.6	23.8	60.9
YOLOv5s	87.7	58.1	87.9	84.8	14.4	7.0	15.8
YOLOv7-tiny	83.8	52.5	84.6	79.8	12.3	6.0	13.0
YOLOv8s	86.9	59.9	87.7	82.8	22.6	11.1	28.4
YOLOv10n	84.7	54.2	84.6	80.7	5.5	2.7	8.2
YOLOv8n-DGC	88.2	58.2	87.0	83.5	6.5	3.1	7.4

$mAP_{50}$ 、 $mAP_{50:95}$  见表 3 注。

### 3 结论

本研究以 YOLOv8n 模型为基准模型,利用 DynamicConv 替换原模型 Backbone 网络的第 3 个标准卷积(Conv),利用 C2f\_DynamicConv 模块替换 Neck 网络的部分 C2f 模块,根据 Slim-neck 范式,引入 GSConv 和 VoV-GSCSP 重新设计 Neck 网络,增强 Neck 网络的特征表达能力,并使用 CARAFE 算子替换最近邻插值法进行上采样,扩大上采样过程的感受野,构建了改进的 YOLOv8n 模型——YOLOv8n-DGC,并用于果园环境下草莓叶片病害的检测。改进后的模型 YOLOv8n-DGC 对草莓叶片病害检测的  $mAP_{50}$ 、 $mAP_{50:95}$ 、精确率和召回率分别比基准模型提高 2.5 个百分点、1.5 个百分点、1.6 个百分点和 1.6 个百分点,模型大小和参数量分别增加 3.2% 和 3.3%,而浮点运算量减少 8.6%,效果较好。与 Faster R-CNN、SSD、YOLOv5s、YOLOv7-tiny 等模型相比,YOLOv8n-DGC 模型更好地实现检测精度与效率的平衡,更适合布置到轻量化的检测设备或终端中。目前模型主要用于病害类型的检测,而对病害感染程度的评估能力仍不足,未来的研究中可以通过引入多任务学习或其他相关方法,进一步丰富模型的功能,实现病害类型及感染程度的检测,为果农提供更为准确的病害诊断和管理建议。此外,还可以进一步丰富数据集,提高模型的可信度,为果园的智慧化生产提供精准的决策支持。

#### 参考文献:

- [1] 曹丹,张明,王竞,等. 土壤改良剂对连作草莓生长及品质的影响[J]. 现代农业科技,2024(3):52-55.
- [2] 潘少香,刘雪梅,郑晓冬,等. 基于质构分析的鲜食草莓质地感官品质综合评价[J]. 食品科技,2023,48(8):37-43.
- [3] 唐歆玥,曹叶婷,邓明益,等. 柠檬醛对草莓贮藏期间品质和抗氧化能力的影响[J]. 食品安全质量检测学报,2024,15(2):131-140.
- [4] 杨海艳,王洪玲,钟国跃,等. 草莓属植物资源分布、化学成分、药理活性研究进展[J]. 中成药,2022,44(2):510-518.
- [5] 联合国粮食及农业组织(FAO). 粮农组织统计数据库——粮食和农业数据[DB/OL]. [2024-10-01]. <http://www.fao.org/faostat/zh/#Data/QCL>.
- [6] 刘玉娟,刘颜达,闫振,等. 注意力机制的混合卷积光谱图像分类方法[J]. 光谱学与光谱分析,2024,44(10):2916-2922.
- [7] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]//IEEE. 2014 IEEE Conference on Computer Vision and Pattern Recognition. Columbus, OH, USA: IEEE, 2014: 580-587.
- [8] GIRSHICK R. Fast R-CNN [C]//IEEE. 2015 IEEE International Conference on Computer Vision (ICCV). Santiago, Chile: IEEE, 2015: 1440-1448.
- [9] REN S Q, HE K M, 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.
- [10] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection [C]//IEEE. 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA: IEEE, 2016: 779-788.
- [11] REDMON J, FARHADI A. YOLO9000: better, faster, stronger [C]//IEEE. 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, HI, USA: IEEE, 2017: 6517-6525.
- [12] REDMON J, FARHADI A. YOLOv3: an incremental improvement [EB/OL]. (2018-04-08). <https://arxiv.org/abs/1804.02767v1>.
- [13] BOCHKOVSKIY A, WANG C Y, LIAO H M. YOLOv4: optimal speed and accuracy of object detection [EB/OL]. (2020-04-23). <https://arxiv.org/abs/2004.10934v1>.
- [14] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot MultiBox detector [M]//ECCV. Computer Vision-ECCV 2016. Cham: Springer International Publishing, 2016: 21-37.
- [15] 杨宇游,潘文林. 基于改进 YOLOv5 的草莓病害检测 [J]. 云南民族大学学报(自然科学版), 2024, 33(5): 624-629.
- [16] LI Y, WANG J C, WU H R, et al. Detection of powdery mildew on strawberry leaves based on DAC-YOLOv4 model [J]. Computers and Electronics in Agriculture, 2022, 202: 107418.
- [17] 公徐路,张淑娟. 基于改进 YOLOv5s 的苹果叶片小目标病害轻量化检测方法 [J]. 农业工程学报, 2023, 39(19): 175-184.
- [18] 时雷,杨程凯,雷镜楷,等. 基于改进 YOLOv8s 的小麦小穗赤霉病检测研究 [J]. 农业机械学报, 2024, 55(7): 280-289.
- [19] 胡根生,谢一帆,鲍文霞,等. 基于轻量型网络的无人机遥感图像中茶叶枯病检测方法 [J]. 农业机械学报, 2024, 55(4): 165-175.
- [20] 罗友璐,潘勇浩,夏顺兴,等. 基于改进 YOLOv8 的苹果叶病害轻量化检测算法 [J]. 智慧农业(中英文), 2024, 6(5): 128-138.
- [21] 贺英豪,唐德钊,倪铭,等. 基于改进 YOLOv5 对果园环境中李的识别 [J]. 华中农业大学学报, 2024, 43(5): 31-40.
- [22] HAN K, WANG Y H, GUO J Y, et al. ParameterNet: parameters are all you need for large-scale visual pretraining of mobile networks [C]//IEEE. 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, WA, USA: IEEE, 2024: 15751-15761.
- [23] 涂智荣,凌海英,李帆,等. 基于改进 YOLOv7-Tiny 的轻量化百香果检测方法 [J]. 广西师范大学学报(自然科学版), 2024, 42(5): 79-90.
- [24] CHOLLET F. Xception: deep learning with depthwise separable

- convolutions[C]//IEEE:2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, HI, USA: IEEE, 2017: 1800-1807.
- [25] LI H L, LI J, WEI H B, et al. Slim-neck by GSCov: a light-weight-design for real-time detector architectures[J]. *Journal of Real-Time Image Processing*, 2024, 21(3): 62.
- [26] 张佳承, 韦 锦, 陈义时. 改进 YOLOv8 的实时轻量化鲁棒绿篱检测算法[J/OL]. *计算机工程* [2024-10-01]. <https://doi.org/10.19678/j.issn.1000-3428.0069524>.
- [27] ZHANG X Y, ZHOU X Y, LIN M X, et al. ShuffleNet: an extremely efficient convolutional neural network for mobile devices [C]//IEEE. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA: IEEE, 2018: 6848-6856.
- [28] WANG J Q, CHEN K, XU R, et al. CARAFE: content-aware Re-Assembly of FEatures[C]//IEEE. 2019 IEEE/CVF International Conference on Computer Vision. Seoul, Korea (South): IEEE, 2019: 3007-3016.
- [29] 张 顺, 龚怡宏, 王进军. 深度卷积神经网络的发展及其在计算机视觉领域的应用[J]. *计算机学报*, 2019, 42(3): 453-482.

(责任编辑:石春林)