

DOI: 10.13733/j.jcam.issn.2095-5553.2025.11.019

徐悦, 赵辉, 岳有军. 基于改进YOLOv8n的农作物虫害检测与识别[J]. 中国农机化学报, 2025, 46(11): 144-151, 160

Xu Yue, Zhao Hui, Yue Youjun. Detection and identification of crop pests based on improved YOLOv8n [J]. Journal of Chinese Agricultural Mechanization, 2025, 46(11): 144-151, 160

基于改进 YOLOv8n 的农作物虫害检测与识别*

徐悦^{1, 2}, 赵辉^{1, 2}, 岳有军^{1, 2}

(1. 天津理工大学电气工程与自动化学院, 天津市, 300384;

2. 天津市复杂系统控制理论及应用重点实验室, 天津市, 300384)

摘要:针对农田中基于机器视觉的虫害检测效率低且容易出现误检、漏检、精度较低的问题,为提高对小且密集、特征接近的常见虫害的检测性能,提出一种基于改进YOLOv8的虫害识别深度学习算法YOLOv8-ECSI。首先将EfficientNet替换原有的骨干网络,在保证检测精度不受到大幅影响的前提下实现模型轻量化;其次将原始的上采样模块替换为CARAFE上采样模块,减少细节信息的损失;然后在小目标检测层加入空间通道重组卷积(SCConv),增强特征表达能力;最后将原有损失函数更换为Inner-CIoU损失函数,提高对小目标的检测能力。通过大型公开数据集IP102和网络查询建立数据集。试验表明,改进后的模型平均精度均值达到94.6%,同时参数量减少33.6%,计算量减少23.5%,比YOLOv5、YOLOv7、SSD等模型检测效果更优、速度更快。

关键词:农作物虫害;深度学习;轻量化模型;小目标检测;空间通道重组

中图分类号:S43; TP391.4 **文献标识码:**A **文章编号:**2095-5553(2025)11-0144-09

Detection and identification of crop pests based on improved YOLOv8n

Xu Yue^{1, 2}, Zhao Hui^{1, 2}, Yue Youjun^{1, 2}

(1. School of Electrical Engineering and Automation, Tianjin University of Technology, Tianjin, 300384, China;

2. Tianjin Key Laboratory of Complex System Control Theory and Application, Tianjin, 300384, China)

Abstract: To address the issues of low efficiency, easy false detection, missed detection and limited accuracy in pest detection based on machine vision in agricultural fields, a deep learning algorithm for pest recognition named YOLOv8-ECSI, based on an improved YOLOv8, was proposed to enhance detection performance for small, dense and similar-featured common pests. Firstly, EfficientNet was used to replace the original backbone network, achieving model lightweighting without significantly affecting detection accuracy. Secondly, the original upsampling module was replaced with a CARAFE upsampling module to reduce the loss of detail information. Additionally, the small object detection layer incorporated spatial-channel reorganization convolution (SCConv) to enhance feature representation capabilities. The original loss function was replaced with the Inner-CIoU loss function to improve small object detection capabilities. A dataset was established by using the large public dataset IP102 and web queries. Experiments demonstrated that the improved model achieved an average precision of 94.6%, with a reduction of 33.6% in the number of parameters and a reduction of 23.5% in computational load. Compared with models such as YOLOv5, YOLOv7, and SSD, the improved model exhibited superior detection performance and faster speed.

Keywords: crop pests; deep learning; lightweight model; small target detection; spatial channel recombination

0 引言

我国人口数量居世界第一,粮食需求大,但人均耕

地面积远低于世界平均水平,受水土流失、转换建设用地等因素影响,我国耕地总面积呈下降趋势^[1]。因此,农作物的健康生长成为保证质量及产量的重要因素。

收稿日期:2024年4月24日 修回日期:2024年6月3日

*基金项目:天津市科技支撑计划项目(19YFZCSN00360)

第一作者:徐悦,男,1999年生,河北承德人,硕士;研究方向为人工智能。E-mail: 156324751@qq.com

通讯作者:赵辉,男,1963年生,天津人,博士,教授;研究方向为农业信息化与精准农业智能监控理论与技术。E-mail: zhaohui3379@126.com

农作物虫害种类多、传播快、危害大,极易造成大范围传播,降低产量及品质,甚至导致绝产^[2]。据农作物病虫测报网系统监测数据,专家预计 2024 年主要作物重大虫害发生面积达 15 541 万公顷次,潜在粮食损失超过 1.5×10^8 t^[3]。农药的使用在一定程度上降低病虫害危害,但虫害易复发,给农作物食用带来一定的安全隐患^[4]。目前,人们对农作物虫害防治的整体水平较低,防治不及时、方法不正确导致每年大量减产^[5]。人工识别监测作物虫害容易出现漏检、错检、检测不及时等情况^[6],随着计算机视觉技术的发展,图像识别的应用使传统农业朝着智慧化发展,农作物虫害目标检测可为提高农作物收成提供智能化解决方案,提高识别效率及准确率,为农业发展提供新方向^[7]。因此,迫切需要一种能够在农田环境下准确、快速识别害虫的方法,对智能化农业发展具有重要意义。

目前,国内外研究人员在农作物虫害识别方面已经做了大量研究,机器学习和深度学习的方法已经被广泛应用^[8, 9]。Kasinathan 等^[10]对多种集成分类器和基分类器进行多数投票,提高了识别准确度,此方法抗差能力更强,但复杂性较高。Li 等^[11]提出了一种利用光谱残差定位目标提出特征,采用支持向量机分类器进行分类识别的小昆虫自动检测方法,准确率可达到 93.9%,此方法设备要求低,但不适合多分类,且速度慢。传统机器学习需要手动提取图像特征,人工特征提取复杂,同时识别精确率较低、速度较慢,很难满足实际工作需求^[12, 13]。

深度学习可以通过模型训练的方式获取复杂环境下的图像特征,且识别精度和速度远优于传统机器学习,因此逐渐应用于农业领域^[14, 15]。YOLO 系列^[16-18]为当前应用较广的目标检测网络,具有检测速度快、精确率高、泛化能力强等优点。周桂红等^[19]将 YOLOv4 中部分卷积替换为深度可分离卷积,同时在主干网络中加入了 scSE 注意力机制,增强了模型对小目标的识别能力,改进后平均精度均值 mAP 达 95.06%,但特征表示能力较弱,难以获得空间上的细节特征。Xu 等^[20]采用 ShuffleNet—V2 替换 YOLOv5 的骨干网络,并利用 9 张图拼接的马赛克增强,降低了网络的参数量,提高了模型的识别速度,但是下采样时特征容易丢失,导致识别精度较低。张国忠等^[21]提出一种基于改进 DenseNet 的模型,提升了渐层网络的特征表达能力,对荷叶病虫害的识别准确率达 91.34%,但参数量大、内存消耗高,难以满足实际应用。Zhang 等^[22]提出了一种新的优化器 Adan 应用于 YOLOv7 模型,保证原有识别精度的同时加快了训练速度。张林鎔等^[23]提出一种基于 YOLOv7 改进模型,针对分辨率低的小目标识别问题进行改进,改

进后模型 mAP 比原模型提高 6.1%。Luo 等^[24]提出一种基于改进 YOLOv8 的模型,主干部分引用了 SimAM 和 BRA 注意力机制,针对柑橘病虫害识别 mAP 达 92.5%,但未考虑整体信息,检测复杂任务时对全局信息理解不足。

综上,尽管深度学习弥补了传统机器学习投入多、效率低的缺陷,但应用于农作物病虫害检测领域仍有 3 点不足:(1)面对虫害目标较小、密集、遮挡等情况易出现漏检现象;(2)识别环境复杂情况下易出现错检,准确率较低;(3)模型检测速度难以满足实际需求。

针对上述问题,本文在当前 YOLO 系列中最先进的 YOLOv8 模型基础上进行改进,用 EfficientNet^[25]替换原模型骨干网络,YOLOv8 的上采样层更换为轻量级上采样算子 CARAFE^[26],在 Neck 部分的小目标层中加入空间通道重组卷积 SCConv^[27],Inner—CIoU Loss^[28]代替原始的 CIoU Loss,提出针对复杂背景下虫害识别模型 YOLOv8—ECSI,提高在复杂田间背景下检测效果的同时实现轻量化,以便部署于实际应用。

1 材料与方法

1.1 试验数据集

试验样本数据集共包含两部分:采用公开害虫数据集 IP102 和网络搜索部分清晰且环境复杂的虫害图片,包括稻纵卷叶螟幼虫 (rice leaf roller)、三化螟 (yellow rice borer)、稻飞虱 (rice planthopper)、稻水象甲 (rice water weevil)、蛴螬 (grub)、蝼蛄 (mole cricket)、金针虫幼虫 (wireworm)、红蜘蛛 (red spider)、蝗虫 (locust)、豆芫菁 (epicauta gorhami) 10 种农田常见虫害图像,为满足实际需求,多方位、多背景、多时段挑选共计 4 795 幅图片作为试验数据集。数据集部分虫害图像如图 1 所示。




图 1 不同环境的各类虫害图像

Fig. 1 Images of various insect pests in different environments

使用 LabelImg 对数据集图像进行人工标注,将标签格式保存为 PASCAL VOC 格式,并按照 8.1:0.9:1 随机划分创建训练集、验证集、测试集,得到训练集图像 3 883 幅,验证集图像 432 幅,测试集图像 480 幅。数

据集各类虫害标签数量信息如表 1 所示。

表 1 数据集标签信息
Tab. 1 Data set label information 幅

待测目标	总标签数	训练集标签数	验证集标签数	测试集标签数
稻纵卷叶螟幼虫	623	523	48	52
三化螟	221	187	17	17
稻飞虱	759	615	61	83
稻水象甲	491	399	37	55
蛴螬	955	788	91	76
蝼蛄	650	525	60	65
金针虫幼虫	916	716	104	96
红蜘蛛	522	435	32	55
蝗虫	1 028	833	102	93
豆芫菁	711	578	73	60
总和	6 876	5 599	625	652

1.2 YOLOv8 模型

YOLOv8 是一种基于深度学习的目标检测模型，是 YOLO 系列模型目前最新版本，可用于目标检测、实例分割等任务^[29]。与 YOLOv5 相比，使用参考 C3 模块残差结构和 ELAN 后设计出梯度流更丰富的 C2f 模块，并替代 C3 模块^[30]；头部网络(Head)换成解耦头(Decoupled—Head)结构，其结构如图 2 所示。YOLOv8 的解耦头包含 2 条并行分支，一条用于提取位置特征，另一条用来提取类别特征，分别用一层 $1 \times$

1 卷积将检测与分类分开完成，减少计算复杂度，提高检测准确性及收敛速度；从有锚节点(Anchor—Base)替换为无锚节点(Anchor—Free)的检测方式^[31]，不依赖于预定的锚框，直接检测目标的中心点和边界信息，提高了检测速度，对小目标检测更加友好。总体而言，YOLOv8 与之前的 YOLO 系列模型相比，具有更强的检测性能。




图 2 Decoupled—Head 的结构图

Fig. 2 Decoupled—Head structure diagram

1.3 数据增强

数据训练时，网络通过随机色调增强、饱和度增强、亮度增强和 Mosaic 等变换生成多样化的训练样本，从而增加数据的多样性，提高模型的泛化能力。

2 改进 YOLOv8 目标检测模型

2.1 YOLOv8—ECSI 模型构建

针对虫害检测环境复杂，目标较小，易出现密集、遮挡等现象，提出一种新的网络模型 YOLOv8—ECSI，其结构如图 3 所示。

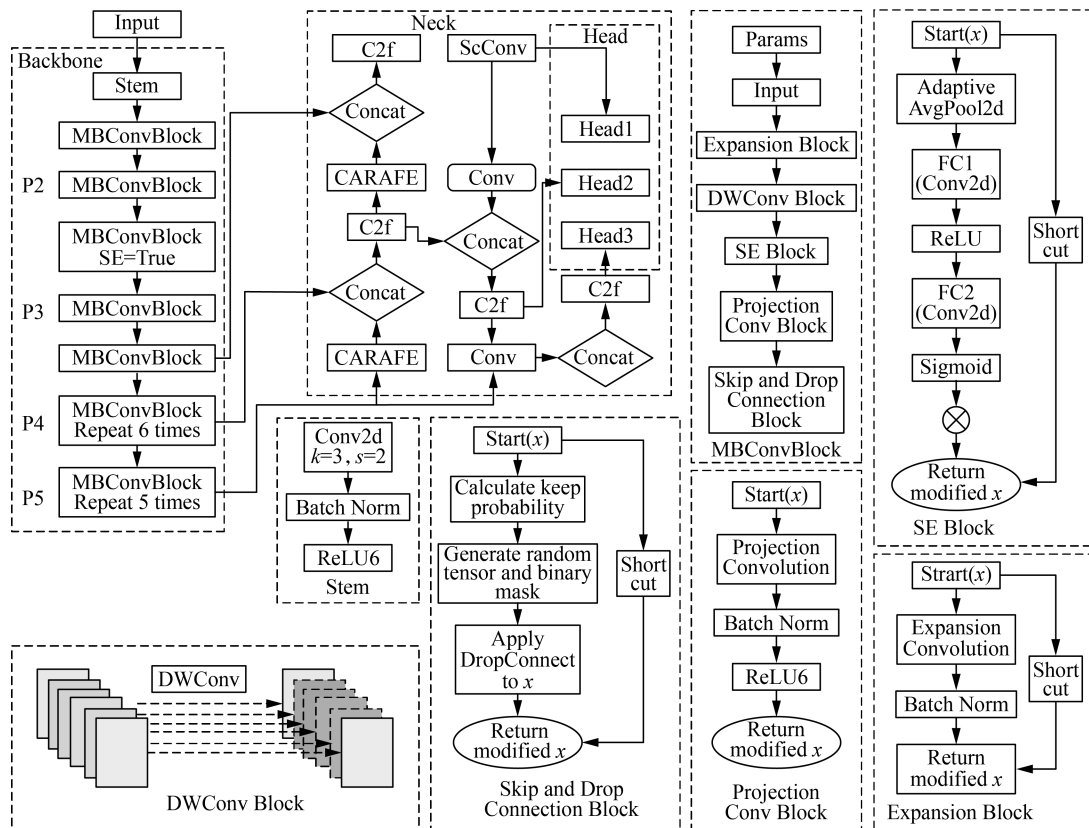


图 3 YOLOv8—ECSI 结构

Fig. 3 YOLOv8—ECSI structure

首先,将 EfficientNet 替换原模型骨干网络,在保证精度的同时降低模型参数量,节省计算资源;其次,将 YOLOv8 的上采样层更换为轻量级上采样算子 CARAFE,更好地保留细节信息;同时,在 Neck 部分的小目标层中加入空间通道重组卷积 SCCConv,增强特征表达能力;最后,将 Inner-CIoU Loss 代替原始的 CIoU Loss,实现更精准的定位。

2.2 EfficientNet 轻量化特征提取网络

虫害检测实际应用中,对模型大小及识别速度要求较高,因此本文用更轻量级的 EfficientNet 网络代替 YOLOv8 原骨干网络,对模型进行轻量化操作。EfficientNet 是一种高效的卷积神经网络,网络结构如图 4 所示。EfficientNet 网络由 3 个部分组成,第 1 部分为 Stem 模块,由卷积、标准化、激活函数组成,完成低级特征提取工作;第 2 部分由 16 个 MBConv(移动翻转瓶颈卷积)模块构成,进一步完成高效特征提取;第 3 部分为分类头,完成目标分类任务,本文只取前两部分替代 YOLOv8 骨干网络。




图 4 EfficientNet 结构

Fig. 4 EfficientNet structure

为满足轻量化需求,选择计算量最少的 EfficientNet-B0 网络,其采用复合缩放方法,通过符合系数调整网络深度、宽度和图像大小,计算如式(1)~式(4)所示。

$$d = \alpha^\varphi \tag{1}$$

$$\omega = \beta^\varphi \tag{2}$$

$$r = \gamma^\varphi \tag{3}$$

$$\begin{cases} \alpha \cdot \beta^2 \cdot \gamma^2 \approx 2 \\ \alpha \geq 1, \beta \geq 1, \gamma \geq 1 \end{cases} \tag{4}$$

式中: φ ——复合系数;

d, ω, r ——深度、宽度、分辨率的缩放系数;

α, β, γ ——通过网络搜索确定的常数。

相比于原骨干网络, EfficientNet-B0 网络采用更

深的网络结构,获得更多的细节信息,具备更强的特征提取能力。同时,大幅降低网络的参数量,节约计算资源,进一步提高模型实际运用的效率。

2.3 轻量级 CARAFE 上采样算子

YOLOv8 中采用最近邻插值法的 Upsample 上采样,通过邻近像素点确认上采样核,只考虑局部信息,而忽略了细节信息,丢失部分重要特征。同时无法根据输入特征图进行调整,存在模糊和失真的情况。针对上述问题,选择 CARAFE 上采样算子对其替换。首先将特征图分为低分辨率和高分辨率特征图,低分辨率特征图通过卷积操作得到粗糙的高分辨率特征图并与之前的高分辨率特征图融合,使用自适应卷积核实现内容感知处理。CARAFE 模块如图 5 所示,包含上采样核预测和特征重组两部分。输入特征图尺寸为 $W \times H \times C$,上采样比例为整数 σ 。用 1×1 的卷积将通道压缩为 C_m ,减小计算量。其次进行内容编码,预测得到 $\sigma H \times \sigma W \times k_{up}^2$ 的上采样核,对其进行归一化,其中 k_{up} 表示上采样核大小。特征重组将输出特征图的每个位置映射到输入特征图,取出中心区域 $N(X_1, k_{up})$ 和预测的该点上采样核点积。最后得到输出特征图 X' 。相比于原始 UpSample 上采样, CARAFE 能够更好地保留细节信息,提供更高的上采样质量。




图 5 CARAFE 模块

Fig. 5 CARAFE module

注: W_1' 表示权重核, X_1 表示中心的局部特征区域。

2.4 空间通道重组卷积 SCCConv

为增强模型对密集小目标虫害的检测能力,在颈部的小目标检测层加入空间通道重组卷积 SCCConv。SCCConv 模块由空间重构单元(SRU)和通道重构单元(CRU)组成,结构如图 6 所示。




图 6 SCCConv 模块

Fig. 6 SCCConv module

SRU 通过分离—重构的方式减少空间冗余, CRU 使用分割—转换—融合的方式减少通道冗余,二

者结合提高效率。SRU 中的分离操作是将特征图按照信息丰富和信息稀疏分开,重构操作是将信息丰富的特征图与信息稀疏的特征图按照交叉重构运算的方式相结合,从而减少空间冗余,节省空间,计算过程如式(5)所示。

$$\begin{cases} X_1^w = W_1 \odot X \\ X_2^w = W_2 \odot X \\ X_{11}^w \oplus X_{22}^w = X^{w1} \\ X_{21}^w \oplus X_{12}^w = X^{w2} \\ X^{w1} \cup X^{w2} = X^w \end{cases} \quad (5)$$

式中: \cup ——拼接;

X ——输入特征;

X_{11}^w, X_{12}^w —— X_1^w 拆分后的子特征;

X_{21}^w, X_{22}^w —— X_2^w 拆分后的子特征;

W_1, W_2 ——信息丰富和信息稀疏的特征权重;

X_1^w, X_2^w ——信息丰富和信息稀疏的特征;

X^{w1}, X^{w2} ——交叉重建后的特征;

X^w ——空间细节特征。

CRU 中分割操作将空间细化特征分为通道数为 αC 和 $(1-\alpha)C$ 的两部分,并利用 1×1 卷积核压缩,提高效率。转换操作时,将特征分为上部 X_{up} 和下部 X_{low} ,其中上部采用逐分组卷积(GWC)和逐点卷积(PWC)后相加得到特征图 Y_1 ,下部采用逐点卷积后与原输入并集得到特征图 Y_2 。最后使用 SKNet(选择性核网络)方法将 Y_1 和 Y_2 自适应融合为特征 Y 。最终二者结合,实现空间、通道重组,在模型参数量和计算量少量增加的前提下增强模型对小目标虫害的检测性能。

2.5 Inner-CIoU Loss 损失函数

IoU 损失函数在目标检测中用来优化模型,对模型进行性能评估。YOLOv8 中默认的依旧为常用的 Ciou Loss,计算如式(6)所示。

$$L_{Ciou} = 1 - IoU + \frac{\rho^2(b, b^{gt})}{C^2} + \alpha v \quad (6)$$

式中: L_{Ciou} ——CIoU 损失值;

IoU ——交并比;

ρ ——两点间的欧氏距离;

b, b^{gt} ——预测框和目标框;

C ——最小闭包区域对角线长度;

α ——权重函数;

v ——纵横比度量函数。

CIoU Loss 考虑了目标框的中心的距离、宽高比及目标框的重叠面积,对目标定位更为准确。但 Ciou Loss 计算过程相对复杂,当目标框较小或重叠度较高的时候可能出现数值不稳定的情况。而在虫害检测的实际场景中,目标的尺度可能会发生很大变化,小目标和重叠目标

的情况较多,因此 Ciou Loss 的局限性较大,同时常规的 IoU Loss 收敛缓慢、泛化能力弱。

为解决以上不足,引入基于辅助边框的 Inner-CIoU 损失函数,通过不同尺度的辅助边框计算 IoU Loss。同时引入比例因子 $ratio$,针对不同的数据集控制辅助边界框的大小,从而更好地捕捉信息,计算损失,加速回归,增强泛化能力。Inner-CIoU 损失函数 $L_{Inner-CIoU}$ 的计算如式(7)~式(14)所示。

$$b_l^{gt} = x_c^{gt} - \frac{w^{gt} \times ratio}{2}, b_r^{gt} = x_c^{gt} + \frac{w^{gt} \times ratio}{2} \quad (7)$$

$$b_t^{gt} = y_c^{gt} - \frac{h^{gt} \times ratio}{2}, b_b^{gt} = y_c^{gt} + \frac{h^{gt} \times ratio}{2} \quad (8)$$

$$b_l = x^c - \frac{w^{gt} \times ratio}{2}, b_r = x^c + \frac{w \times ratio}{2} \quad (9)$$

$$b_t = y^c - \frac{h \times ratio}{2}, b_b = y^c + \frac{h \times ratio}{2} \quad (10)$$

$$inner = [\min(b_r^{gt}, b_r) - \max(b_l^{gt}, b_l)] \times [\min(b_b^{gt}, b_b) - \max(b_t^{gt}, b_t)] \quad (11)$$

$$union = (w^{gt} \times h^{gt}) \times (ratio)^2 + (w \times h) \times (ratio)^2 - inner \quad (12)$$

$$IoU^{inner} = \frac{inner}{union} \quad (13)$$

$$L_{Inner-CIoU} = L_{Ciou} + IoU - IoU^{inner} \quad (14)$$

式中: (x_c^{gt}, y_c^{gt}) ——目标框中心点;

(x^c, y^c) ——锚框中心点;

w^{gt}, h^{gt} ——目标框的宽度和高度;

b_l, b_r, b_t, b_b ——预测框左、右、上、下边界坐标;

$b_l^{gt}, b_r^{gt}, b_t^{gt}, b_b^{gt}$ ——真实框左、右、上、下边界坐标;

w, h ——预测框的宽度和高度;

$ratio$ ——可调节比例因子;

$inner$ ——边界框的交集区域;

$union$ ——边界框的交集区域。

Inner-CIoU Loss 能够使模型更准确地捕捉细节信息,精准定位,从而在小目标检测中提高准确度,满足虫害识别的实际需求。

3 结果与分析

3.1 试验平台与参数设置

试验在基于 Ubuntu 18.04, Python 3.8 与 PyTorch 1.12.1 搭建的深度学习环境中完成,编程平台为 pycharm,在 GTX1080Ti 的服务器上进行试验,同时使用 CUDA v10.2 对运算进行加速。模型训练过程中数据集图片大小调整为 640 像素 \times 640 像素,初始

学习率为 0.01, 训练批量(*batch size*)设置为 16, 训练总轮次(*epoch*)设置为 300, 优化器选择 SGD, 动量参数(*momentum*)为 0.937。

3.2 主要评价指标

对于目标检测模型的评价指标, 通常用精确率 P 、召回率 R 、平均精度均值 mAP 来评价模型的性能。评价指标计算如式(15)~式(17)所示。

$$P = \frac{TP}{TP + FP} \quad (15)$$

$$R = \frac{TP}{TP + FN} \quad (16)$$

$$mAP = \frac{1}{N} \int_0^1 P(R) dR \quad (17)$$

式中: TP ——检测出正确的正样本数;

FP ——检测出错误的正样本的数;

FN ——检测出错误的负样本的数;

N ——类别总数。

在判断模型是否实现轻量化的问题中, 模型的参数量 $Params$ 和计算量 $FLOPs$ 可作为主要判断标准。其中参数量为训练过程中的参数总量, 可判断模型的复杂度; 计算量为模型的浮点运算次数, 可判断模型的计算资源消耗。

3.3 对比试验

3.3.1 主流模型对比

YOLOv8—ECSI 模型基于 YOLOv8n 改进得到, 为验证改进后模型能够在保证检测能力的同时实现轻量化, 将 YOLOv8—ECSI 模型与主流模型 SSD、Faster R—CNN、YOLOv5s、YOLOv7 和 YOLOv8n 进行对比试验, 结果如表 2 所示。

表 2 不同模型实现对比结果

Tab. 2 Comparison results of different model

模型	mAP /%	参数量 /M	计算量 /G	模型体积 /MB
SSD	92.3	26.29	62.75	95.2
Faster R—CNN	89.72	28.48	941.17	108.5
YOLOv5s	92.2	7.04	15.8	14.4
YOLOv7	93.2	36.53	103.3	74.9
YOLOv8n	94.8	3.01	8.1	6.3
YOLOv8—ECSI	94.6	2	6.2	4.3

由表 2 可知, 改进 YOLOv8—ECSI 模型相比其他网络模型平均精度均值、参数量、浮点运算量和模型体积都有较大优势。YOLOv8—ECSI 模型训练的平均精度均值较 SSD、Faster R—CNN、YOLOv5s 和 YOLOv7 分别提高 2.3%、4.88%、2.4% 和 1.4%, 相比于 YOLOv8n 在平均精度均值仅降低 0.2% 的情况下, 参数量、计算量和训练模型体积分别减少 33.6%、23.5% 和 31.7%,

保证检测效果的同时实现模型轻量化, 证明改进模型在实际应用中的有效性。

3.3.2 采用不同比例因子的损失函数对比

针对不同数据集, 利用不同比例因子改变辅助边框的大小, 以提高模型的检测效果。针对本文数据集采用不同的比例因子对模型进行试验, 结果如表 3 所示。

表 3 采用不同 *ratio* 下的模型对比试验结果

Tab. 3 Results of model comparison tests at different *ratio* %

网络结构	P	R	mAP
YOLOv8(CIoU)	93.1	88.2	94.8
YOLOv8(Inner—CIoU, <i>ratio</i> =1.2)	94.9	89.2	95.3
YOLOv8(Inner—CIoU, <i>ratio</i> =1.1)	95.9	88.9	95.4
YOLOv8(Inner—CIoU, <i>ratio</i> =1)	95.7	90.6	95.2
YOLOv8(Inner—CIoU, <i>ratio</i> =0.9)	89.8	92.5	95.3
YOLOv8(Inner—CIoU, <i>ratio</i> =0.8)	94.7	88.9	95.3

通过设置不同比例因子试验后进行分析, 改变 *ratio* 参数时, 模型的参数量和计算量基本不变, 因此主要以精确率、召回率和平均精度均值作为评价指标。由表 3 可知, 当 *ratio*=1.1 时, 模型在保证召回率优于原模型的同时, 识别目标精确率最高, 平均精度均值指标效果最好, P 达到 95.9%、 mAP 达到 95.4%, 较原模型分别提高 2.8%、0.6%。

综上, 将原模型的损失函数由 CIoU 改为基于辅助边框的 Inner—CIoU, 并将 *ratio* 设置为 1.1 时, 能够有效提高模型的检测性能。

3.3.3 不同轻量化骨干网络性能对比

为验证本文更改骨干网络的有效性, 对比 4 种常用轻量化骨干网络替换 YOLOv8 骨干网络进行试验, 结果如表 4 所示。

表 4 轻量化网络试验结果

Tab. 4 Results of lightweight network experiment

模型	P /%	R /%	mAP /%	参数量/M	计算量/G
YOLOv8n	93.1	88.2	94.8	3.01	8.1
YOLOv8n+EfficientNet	93.5	89.4	93.4	1.91	5.7
YOLOv8n+PP_LCNet	92.3	86	91.1	1.73	5
YOLOv8n+MobileNeXt	91.5	85.9	91.5	2.06	5.9
YOLOv8n+ShuffleNetv2	92.5	85.2	91.4	1.71	5
YOLOv8n+SwinTransformer	95.2	86.7	92.1	3.55	30.6

由表 4 可知, PP_LCNet 网络具有较少的参数量和最低的计算量, 但 P 、 R 和 mAP 分别比 YOLOv8n 降低 0.8%、2.2% 和 3.7%; MobileNeXt 网络的参数量降低约 1/3, 计算量降低约 1/4, 但 P 、 R 和 mAP 分别比

YOLOv8n 下降 1.6%、2.3% 和 3.3%；ShuffleNetv2 虽拥有最低的参数量和计算量,但 P 、 R 和 mAP 分别下降 0.6%、3% 和 3.4%；SwinTransformer 虽然相比于原模型 P 提高 2.1%,但参数量和计算量都有大幅度提高,同时 R 和 mAP 均有降低;然而选用的 EfficientNet,在 mAP 仅降低 1.4% 的情况下, P 和 R 均有升高,且具有较低的计算量和参数量。

综上,将 EfficientNet 替换 YOLOv8n 骨干网络后可以在保证检测效果的同时,大幅减小模型复杂程度,证明改进后模型更利于实际应用。

3.4 消融实验

为验证改进后 YOLOv8—ECSI 模型的识别效果,采用消融实验进行对比,结果如表 5 所示。可以看出,更换 EfficientNet 为骨干网络后模型的检测效

果略有降低,但复杂程度降低,说明该网络具有更高的效率。当 CARAFE 模块替代原模型上采样后,相比于 YOLOv8n+EfficientNet 模型 P 提高 1.6%, mAP 提高 0.5%,说明 CARAFE 算子能够提高上采样质量,减少细节信息丢失。在小目标检测层加入 SCConv 模块后,相比于 YOLOv8n+EfficientNet+CARAFE 模型 P 提高 0.2%, mAP 提高 0.3%,说明该模块的加入增强了模型的特征表达能力,更好地区分不同的特征。更换 Inner—CIoU 损失函数后,相比于 YOLOv8n+EfficientNet+CARAFE+SCConv 模型 P 提高 0.8%, mAP 提高 0.4%,说明利用辅助边框的损失函数可以更好地帮助模型定位检测目标,提高模型的检测性能。通过消融实验进一步验证所提出基于 YOLOv8 改进模型的可行性。

表 5 消融实验结果

Tab. 5 Results of ablation experiment

基线模型	EfficientNet	CARAFE	SCConv	Inner—CIoU	P /%	R /%	mAP /%	参数量/M	计算量/G
YOLOv8n	×	×	×	×	93.1	88.2	94.8	3.01	8.1
	√	×	×	×	93.5	89.4	93.4	1.91	5.7
	×	√	×	×	93.7	88.9	95.3	3.14	8.6
	×	×	√	×	96.7	91.6	95.8	3.02	8.2
	×	×	×	√	95.9	88.9	95.4	3.01	8.1
	√	√	×	×	95.1	88.5	93.9	1.99	6.1
	√	√	√	×	95.3	88.3	94.2	2.0	6.2
	√	√	√	√	96.5	87.4	94.6	2.0	6.2

3.5 检测效果分析

针对农作物虫害检测中常遇到背景相似、光线不足、

小目标和遮挡问题,使用 YOLOv8—ECSI 和 YOLOv8n 等模型进行检测,得到可视化图像如图 7 所示。




图 7 检测可视化结果

Fig. 7 Detection of visual results

由图 7 可知,YOLOv5s 和 YOLOv7 模型的检测精度普遍不高且出现误检情况;Faster R—CNN 模型检测精度较高,但出现大量误检情况;SSD 模型检测精

度较高,但出现大量漏检情况;YOLOv8n 原模型在光线不足和小目标情况下精度低于改进后模型,且在遮挡检测下出现误检现象,因此改进模型效果更好。同

时 YOLOv8—ECSI 的检测速度也有很大优势,在可视化过程中每幅图平均推理时间为 11.7 ms,满足实际应用需求,训练模型体积仅为 4.3 MB,更便于实际应用。

综上,改进后的模型在实现模型轻量化的同时依旧保证了良好的检测性能。

4 结论

1) 首先在 YOLOv8 的基础上将 EfficientNet 替换原骨干网络部分,减少模型参数量和计算量,实现模型的轻量化;其次,CARAFE 模块替换原模型上采样模块,提高对虫害目标细节信息的定位提取能力;同时,小目标检测层加入 SCConv 模块,在空间和通道两方面提取特征,加强模型对虫害的识别能力;最后,引入 Inner—CIoU Loss 替代原损失函数,利用比例因子控制辅助边框大小,易于模型收敛,提高检测准确度。

2) 改进后模型平均精度均值为 94.6%,较原模型仅降低 0.2%,但精确率达到 96.5%,较原模型提高 3.4%,同时参数量减少 33.6%,计算量减少 23.5%,在保证模型检测能力的同时实现模型的轻量化。

参 考 文 献

- [1] 刘沁萍,朱闯,田洪阵,等. 基于 MODIS 数据的中国耕地时空变化及其影响因素[J]. 兰州大学学报(自然科学版), 2022, 58(5): 689—697.
- [2] 张福进,丛星梅,刘真,等. 农业病虫害防治的现状与解决措施[J]. 种子科技, 2024, 42(2): 146—148.
- [3] 刘杰,曾娟,黄冲,等. 2024 年全国农作物重大病虫害发生趋势预报[J]. 中国植保导刊, 2024, 44(1): 37—40.
- [4] Panwar L, Devi S, Singh Y. Insect pest management in vegetable crops through trap cropping [J]. The Indian Journal of Agricultural Sciences, 2021, 91(10): 1433—1437.
- [5] Stefopoulou A, Maselou D A, Papachristos D, et al. Pest control in primary sector: Towards the identification of knowledge gaps [J]. Agronomy, 2021, 11(8): 1596.
- [6] 赵辉,黄鏢,王红君,等. 基于改进 YOLOv7 的农田复杂环境下害虫识别算法研究[J]. 农业机械学报, 2023, 54(10): 246—254.
- Zhao Hui, Huang Biao, Wang Hongjun, et al. Pest identification method in complex farmland environment based on improved YOLOv7 [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(10): 246—254.
- [7] Li M, Cheng S, Cui J, et al. High-performance plant pest and disease detection based on model ensemble with inception module and cluster algorithm [J]. Plants, 2023, 12(1): 200.
- [8] Chithambarathanu M, Jeyakumar M K. Survey on crop pest detection using deep learning and machine learning approaches [J]. Multimedia Tools and Applications, 2023, 82(27): 42277—42310.
- [9] 慕君林,马博,王云飞,等. 基于深度学习的农作物病虫害检测算法综述[J]. 农业机械学报, 2023, 54(S2): 301—313.
- Mu Junlin, Ma Bo, Wang Yunfei, et al. Review of crop disease and pest detection algorithms based on deep learning [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(S2): 301—313.
- [10] Kasinathan T, Uyyala S R. Machine learning ensemble with image processing for pest identification and classification in field crops [J]. Neural Computing and Applications, 2021, 33(13): 7491—7504.
- [11] Li W, Yang Z, Lü J, et al. Detection of small-sized insects in sticky trapping images using spectral residual model and machine learning [J]. Frontiers in Plant Science, 2022, 13: 915543.
- [12] 马佳佳,陈友鹏,王克强,等. 基于优化 SVM 的虫害图像识别研究[J]. 中国粮油学报, 2022, 37(5): 10—15.
- [13] Ahmad Loti N N, Mohd Noor M R, Chang S W. Integrated analysis of machine learning and deep learning in chili pest and disease identification [J]. Journal of the Science of Food and Agriculture, 2021, 101(9): 3582—3594.
- [14] Liu J, Wang X. Plant diseases and pests detection based on deep learning: A review [J]. Plant Methods, 2021, 17: 1—18.
- [15] 蒋心璐,陈天恩,王聪,等. 农业害虫检测的深度学习算法综述[J]. 计算机工程与应用, 2023, 59(6): 30—44.
- [16] Redmon J, Divvala S, Girshick R, et al. You only look once: Unified, real-time object detection [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779—788.
- [17] Wang C Y, Bochkovskiy A, Liao H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464—7475.
- [18] Redmon J, Farhadi A. YOLOv3: An incremental improvement [J]. arXiv preprint arXiv: 1804.02767, 2018.
- [19] 周桂红,马帅,梁芳芳. 基于改进 YOLOv4 模型的全景图像苹果识别[J]. 农业工程学报, 2022, 38(21): 159—168.
- Zhou Guihong, Ma Shuai, Liang Fangfang. Recognition of the apple in panoramic images based on improved YOLOv4 model [J]. Transactions of the Chinese Society of Agricultural Engineering, 2022, 38(21): 159—168.

(下转第 160 页)

- IEEE Transactions on Robotics, 2020, 37(2): 550—566.
- [12] Santin R, Assis L, Vivas A, et al. Matheuristics for multi-UAV routing and recharge station location for complete area coverage [J]. Sensors, 2021, 21(5): 1705.
- [13] Liu G, Shu C, Liang Z, et al. A modified sparrow search algorithm with application in 3D route planning for UAV [J]. Sensors, 2021, 21(4): 1224.
- [14] Murray C, Karwan M. A branch-and-bound-based solution approach for dynamic rerouting of airborne platforms [J]. Naval Research Logistics (NRL), 2013, 60(2): 141—159.
- [15] Goncharenko V I, Lebedev G N, Mikhailin D A. Online two-dimensional route planning for a group of unmanned aerial vehicles [J]. Journal of Computer and Systems Sciences International, 2019, 58: 147—158.
- [16] 方文婷, 艾时钟, 王晴. 基于混合蚁群算法的冷链物流配送路径优化研究[J]. 管理科学, 2019, 27(11): 107—115.
Fang Wenting, Ai Shizhong, Wang Qing. Research on cold chain logistics distribution path optimization based on hybrid ant colony algorithm [J]. Chinese Journal of Management Science, 2019, 27(11): 107—115.
- [17] 陈高华, 郗传松. 求解多目标车辆路径优化的改进蚁群算法研究[J]. 机械设计与制造, 2023(9): 231—236.
Chen Gaohua, Xi Chuansong. Research on improved ant colony algorithm for multi-objective vehicle path optimization [J]. Machinery Design & Manufacture, 2023(9): 231—236.
- [18] Song S, Yang F, Yu P, et al. Stochastic multi-attribute acceptability analysis with numerous alternatives [J]. European Journal of Operational Research, 2021, 295(2): 621—633.
- [19] Wang Y, Luo Y. Integration of correlations with standard deviations for determining attribute weights in multiple attribute decision making [J]. Mathematical and Computer Modelling, 2010, 51(1—2): 1—12.
- [20] Lahdelma R, Salminen P. SMAA—2: Stochastic multicriteria acceptability analysis for group decision making [J]. Operations Research, 2001, 49(3): 444—454.
- [21] Song S, Xia Q, Yang F, et al. Stochastic decision tree acceptability analysis with uncertain state probability [J]. Journal of the Operational Research Society, 2023, 74(3): 944—955.

(上接第 151 页)

- [20] Xu W, Xu T, Thomasson J A, et al. A lightweight SSV2—YOLO based model for detection of sugarcane aphids in unstructured natural environments [J]. Computers and Electronics in Agriculture, 2023, 211: 107961.
- [21] 张国忠, 吕紫薇, 刘浩蓬, 等. 基于改进DenseNet和迁移学习的荷叶病虫害识别模型[J]. 农业工程学报, 2023, 39(8): 188—196.
Zhang Guozhong, Lü Ziwei, Liu Haopeng, et al. Model for identifying lotus leaf pests and diseases using improved DenseNet and transfer learning [J]. Transactions of the Chinese Society of Agricultural Engineering, 2023, 39(8): 188—196.
- [22] Zhang C, Hu Z, Xu L, et al. A YOLOv7 incorporating the Adan optimizer based corn pests identification method [J]. Frontiers in Plant Science, 2023, 14: 1174556.
- [23] 张林鎔, 巴音塔娜, 曾庆松. 基于StyleGAN2—ADA和改进YOLOv7的葡萄叶片早期病害检测方法[J]. 农业机械学报, 2024, 55(1): 241—252.
Zhang Linxuan, Ba Yintana, Zeng Qingsong. Grape disease detection method based on StyleGAN2—ADA and improved YOLOv7 [J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(1): 241—252.
- [24] Luo D, Xue Y, Deng X, et al. Citrus diseases and pests detection model based on self-attention YOLOV8 [J]. IEEE Access, 2023.
- [25] Tan M, Le Q. EfficientNet: Rethinking model scaling for convolutional neural networks [C]. International Conference on Machine Learning. PMLR, 2019: 6105—6114.
- [26] Wang J, Chen K, Xu R, et al. Carafe: Content-aware reassembly of features [C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 3007—3016.
- [27] Li J, Wen Y, He L. SCConv: Spatial and channel reconstruction convolution for feature redundancy [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 6153—6162.
- [28] Zhang H, Xu C, Zhang S. Inner—IoU: More effective intersection over union loss with auxiliary bounding box [J]. arXiv preprint arXiv: 2311.02877, 2023.
- [29] Hussain M. YOLO—v1 to YOLO—v8, the rise of YOLO and its complementary nature toward digital manufacturing and industrial defect detection [J]. Machines, 2023, 11(7): 677.
- [30] Liu L, Li P, Wang D, et al. A wind turbine damage detection algorithm designed based on YOLOv8 [J]. Applied Soft Computing, 2024: 111364.
- [31] Shen L, Lang B, Song Z. Infrared object detection method based on DBD—YOLOv8 [J]. IEEE Access, 2023, 11: 145853—145868.