

基于改进 YOLOv8n 算法的水稻虫害检测

王金聪 于志超 杨海峰 汤普然 张志伟

(东北林业大学计算机与控制工程学院 哈尔滨 150006)

摘要: 水稻是我国主要的粮食作物之一,水稻的虫害胁迫制约着水稻产业的健康持续发展。因此,快速、准确地识别出水稻虫害类型具有十分重要的意义。针对水稻虫害检测精度低、易发生漏检和误检等问题,提出了改进 YOLO 第 8 版 (YOLOv8n) 水稻虫害识别检测方法。首先,融合了双向特征金字塔 (BiFPN) 结构,用于有效特征层的整合。并在主干网络与颈部网络之间引入基于挤压-激励 (SE) 的注意力机制模块,提高网络的特征融合能力;引入 Wise-IoUv2 损失函数代替 IoU 损失函数,从而降低原有 IoU 损失函数存在的回归精度问题;进一步提升网络的检测性能。在水稻虫害数据集上进行大量实验,结果表明,所提出的改进模型在平均精度均值 (mAP)、精确率 (Precision) 和召回率 (Recall) 方面均优于当前主流算法。具体而言,该方法在 mAP 上达到了 89.2%,Precision 为 92.5%,Recall 为 83.3%。相比之下,YOLOv5 的 mAP 为 84.1%、YOLOv8 为 85.2%、YOLOv9 为 86.4%、YOLOv10 为 85.1%,Faster R-CNN 仅为 59.75%。在 Precision 方面,该模型也优于 YOLOv5 (88.4%)、YOLOv8 (89.6%) 等,且 Recall 高于所有其他模型,显示出更强的目标检测能力和稳定性,mAP 较原始 YOLOv8n 提升了 4%。改进 YOLOv8n 算法能够满足水稻叶片虫害识别及对检测精度的需求,同时提高了对小目标和密集目标的检测能力,从而减少了漏检和误检的情况。改进 YOLOv8n 算法与目前主流算法相比在精度上具有一定优势,水稻害虫检测提供了一种更优的方法,对于防治水稻害虫有重要意义。

关键词: 水稻;害虫识别;目标检测;YOLOv8n;注意力机制;损失函数

中图分类号: TN911.73;TP391.41 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Rice pest detection based on improved YOLOv8n algorithm

Wang Jincong Yu Zhichao Yang Haifeng Tang Puran Zhang Zhiwei

(College of Computer and Control Engineering, Northeast Forestry University, Harbin 150006, China)

Abstract: Rice is one of the main grain crops in China and the pest stress on rice restricts the healthy and sustainable development of the rice industry. Therefore, it is of great significance to quickly and accurately identify the types of rice pest infestations. An improved YOLO version 8 nano (YOLOv8n) rice pest identification and detection method was proposed to address the issues of low accuracy, easy missed and false detections in rice pest detection. Firstly, the BiFPN pyramid structure is integrated for the integration of effective feature layers. And introduce an attention mechanism module based on squeeze and excitation (SE) between the backbone network and the neck network to improve the network's feature fusion ability; introducing the Wise-IoUv2 loss function instead of the IoU loss function to reduce the regression accuracy issue of the original IoU loss function; further enhance the detection performance of the network. Extensive experiments were conducted on the rice pest dataset, and the results showed that the improved model proposed in this paper outperforms current mainstream algorithms in terms of mAP, Precision and Recall. Specifically, this method achieved 89.2% mAP, 92.5% Precision and 83.3% Recall. In contrast, the mAP of YOLOv5 is 84.1%, YOLOv8 is 85.2%, YOLOv9 is 86.4%, YOLOv10 is 85.1% and Faster R-CNN is only 59.75%. In terms of precision, our model outperforms YOLOv5 (88.4%), YOLOv8 (89.6%) and has a higher recall than all other models, demonstrating stronger object detection ability and stability. mAP has increased by 4% compared to the original YOLOv8n. Improving the YOLOv8n algorithm can meet the requirements of rice leaf pest identification and detection accuracy, while improving the detection ability of small and dense targets, thereby reducing missed and false detections. The improved YOLOv8n algorithm has certain advantages in accuracy compared to current mainstream algorithms and provides a better method for rice pest detection, which is of great significance for the prevention and control of rice pests.

Keywords: rice; pest identification; object detection; YOLOv8n; attention mechanism; loss function

0 引言

在中国的农业发展政策目标中,维护粮食安全一直是

尤为重要的一项^[1]。水稻是我国重要的粮食作物。黑龙江省作为中国重要的粮食生产基地,以种植水稻、玉米和大豆等作物为主。其水稻种植面积和产量均位居全国前列,是

国家重要的商品粮基地,在中国粮食生产中的重要地位不可忽视。由于许多种植者对水稻植株病害的认知程度不足,难以准确识别病害类型,人工肉眼识别通常会出现高概率的误判。有时,农民还会寻求专家帮助,但这种方式耗时费力且效率低下^[2]。因此,寻找更为高效、自动化的病虫害检测方法成为亟待解决的问题。随着互联网的不断发展,利用计算机视觉技术进行有害生物识别逐渐得到广泛研究^[3]。过去,病虫害识别技术经历了从人工特征提取到机器学习,再到深度学习的逐步演化。早期的病虫害识别方法主要依赖于传统的图像处理和模式识别技术,如支持向量机(support vector machine, SVM)和决策树等,这些方法在特定环境下能够取得较好的效果,但由于其对手工特征提取和领域知识的强烈依赖,难以在复杂和多变的农业环境中稳定发挥作用。基于机器视觉的农作物病虫害识别系统的开发,极大地推动我国农业智能化、自动化的发展^[4]。此外,传统方法对于大规模数据的处理能力有限,且在实时性和精度方面难以满足实际需求。随着计算机视觉和深度学习技术的不断进步,尤其是卷积神经网络(convolutional neural networks, CNN)的广泛应用,病虫害识别的技术水平有了显著提高。CNN通过自动学习图像的深层次特征,能够大幅度提高识别精度并减少人为干预。然而,尽管CNN在精度上取得了突破,其计算量较大,模型复杂度高,导致其在嵌入式设备和实时监测中的应用受到一定的限制。因此,如何在保证准确率的同时,提升模型的计算效率,成为了研究的一个重要方向。

在这一背景下,YOLO(you only look once)系列目标检测算法应运而生,迅速成为目标检测领域的主流技术之一。与传统目标检测方法相比,YOLO通过一阶段的回归框架实现图像中的物体检测,具有速度快、精度高的特点,能够在保证实时性的同时提供较高的检测精度。这种特点使得YOLO在农业病虫害监测中表现突出,尤其是在需要实时识别和定位目标的应用场景中,具有明显的优势。在CNN成为主流之前,害虫识别与分类的研究工作主要集中于模式识别和传统机器学习方法^[5]。传统的目标检测流程通常包含3个核心步骤:首先进行区域选择,随后提取特征,最后训练分类器。该方法的整体性能高度依赖于特征提取的效果,若所提取的特征区分度不足,则难以获得理想的识别结果。因此,早期许多学者在害虫识别领域的探索,均是建立在上述传统目标检测算法的基础之上。在深度学习方面,国外研究者们则更加注重于卷积网络的轻量化发展以及与嵌入式设备的交互性。Krizhevsky等推出AlexNet(AlexNet convolutional neural network)之后,深度学习技术已经快速发展并广泛应用于各个领域。郭阳等在YOLOv3的模型中引入了Darknet-53(Darknet-53 convolutional neural network)网络和多尺度融合,实现对水稻害虫的准确识别,精度可达91.93%。范金豪等^[6]替换YOLOv4主干为轻量型特征提取网络,并利用ECA重

构卷积模块,实现了轻量化与检测精度的统一。Chen等^[7]在Mobile Net-V2网络基础上添加注意力机制,优化损失函数,并对水稻病害进行识别,平均准确率达98.48%。李咏然等^[8]提出了动态多尺度YOLO模型(dynamic multi-scale YOLO model, DMS-YOLO)。该模型通过自适应上下文感知特征金字塔网络、集成可变形卷积(DCNv3)与协同注意力机制的检测头,以及Focaler-IoU损失函数,在RDD2022数据集上实现了87.9%的平均精度均值(mAP) mAP@0.5(较基准提升3%),同时模型轻量。张永宏等^[9]提出了用于PCB精密检测的实时Transformer模型MFSF-DETR。通过引入Faster-CGLU Block、ETB模块及RAWCFF-CFSF融合编码器,该模型在多个数据集上实现了最高98.1%的检测精度,显著提升了PCB缺陷与元件的自动化检测性能。

然而,尽管YOLO系列算法在害虫检测中已经取得了显著的成果,仍存在一些挑战。例如,YOLO在复杂背景中的误检问题仍未完全解决。问题表明,虽然YOLO系列技术已成为害虫检测的主流选择,但仍然有进一步提升的空间。针对这些挑战,本文提出了一种基于YOLOv8的优化方法,旨在解决现有算法在小目标害虫环境中的识别问题。通过对网络结构的改进和训练策略的优化,本研究期望能够提高模型的鲁棒性,从而在农业害虫检测中提供一种更加高效和精准的解决方案。

1 YOLOv8

表1为YOLOv8模型包含的5个不同版本。该系列的创新在于提出了一个全新的骨干网络(Backbone)、一种改进的损失函数以及一个Anchor-Free(无锚框)检测头。在同等实验条件下,YOLOv8在检测速度与精度上均表现优异,性能超越了前代模型YOLOv7^[10]。其骨干网络设计保留了YOLOv5中采用跨阶段局部网络(cross stage partial network, CSPNet)^[11]思想,该结构能有效将梯度变化融入特征图,促进更高效的信息流动与特征复用。具体而言,YOLOv8的主干网络中包含4个关键的C2f层,其中堆叠的C2f模块数量分别为3、6、6、3,这种设计在模型复杂度与特征提取能力之间取得了良好平衡。此外,YOLOv8通过巧妙的结合路径聚合网络(path aggregation network, PAN)^[12]与特征金字塔网络(feature pyramid network, FPN)^[13]两大网络的优势,构建了高效的多尺度特征融合网络。FPN结构实现了自上而下的语义增强,而PAN则在此基础上增加了自下而上的定位信息传递路径,两者协同工作,显著提升了模型对不同尺度害虫目标的检测能力,尤其是对小尺寸目标的识别效果。

水稻虫害在中国粮食生产中的重要地位不可忽视。作为最主要的口粮作物,水稻的稳定产出直接关系国家粮食安全与农民生计,而虫害则是威胁其稳产高产的关键生物灾害。2022年,预测水稻虫害累计发生面积约为12.3亿

表 1 不同版本 YOLOv8 模型的比较

Table 1 Comparison of different versions of YOLOv8 models

模型	参数量/($\times 10^6$)	GFLOPs
YOLOv8n	3.2	8.7
YOLOv8s	11.2	28.6
YOLOv8m	25.9	78.9
YOLOv8l	43.7	165.2
YOLOv8x	68.2	257.8

亩;2023 年,预测累计发生面积约为 11.6 亿亩;2024 年,预测累计发生面积进一步增加,达到约 12.4 亿亩;2025 年预测累计发生面积超过 12.9 亿亩(数据来源于中国农药信息网)。近年来水稻虫呈上升趋势,给水稻产业造成了巨大的损失^[14]。所以科学害虫防治是农作物害虫的鉴定的一个重要基础^[15],水稻虫害发生图如图 1 所示。




图 1 全国水稻虫害发生面积

Fig. 1 National rice pest occurrence area map

2 YOLO8 算法改进

为便于水稻害虫检测模型最终部署在主机电脑上,选用 YOLOv8 系列中体积最小的 YOLOv8n 模型作为基础网络。该模型结构包含 3 部分:骨干特征提取网络(backbone)、颈部网络(neck)和检测头(head)。本研究旨在通过改进 YOLOv8 模型,提升其在水稻害虫检测中的准确率,从而有效解决当前水稻害虫检测面临的技术瓶颈,推动智能农业的发展。在实际田间环境中,一株水稻可能同时感染多种害虫,且部分虫害在形态上高度相似,极易导致检测误判。此外,水稻害虫体积较小,且分布在复杂多变的田间背景中,给传统目标检测算法带来了极大挑战,影响了检测的效率与精度。针对这些问题,基于 YOLOv8 模型的改进不仅聚焦于提升对小目标的识别能力,还注重增强模型在复杂环境下的鲁棒性与区分相似虫害的能力,从而实现更加精准和高效的水稻害虫检测,改进后的网络模型结构如图 2 所示。

YOLOv8 凭借其轻量化设计和高效检测性能,在多种应用场景中表现优异。在通用目标检测任务上取得了显著成果,但在特定领域如水稻虫害检测时,仍面临若干挑战。YOLOv8 虽然轻量快速,但传统的损失函数在处理多类别、小目标检测时,往往难以兼顾不同类别之间的权重分配,容易导致模型偏向检测频率较高的类别,忽视少数类别




图 2 YOLOv8 网络结构

Fig. 2 YOLOv8 network structure

的准确性。引入改进的损失函数,可以更加合理地权衡不同类别的损失,提升整体检测性能,但在精度和召回率的平衡上仍有提升空间,尤其是在多类虫害混杂的情况下表现欠佳。针对上述问题,本研究从模型结构优化、小目标特征增强以及损失函数调整等方面入手,对 YOLOv8 算法进行了针对性改进。引入改进措施,提升模型对水稻虫害的检测能力和鲁棒性,从而实现更加精准和高效的虫害监测。由图 2 可知,YOLOv8 从以下 3 个方面进行了改进。

1)原始 YOLOv8 模型采用路径聚合网络(PANet)进行特征图融合。该结构通过拼接不同通道维度的特征来加强层级间的信息交互,从而整合多尺度特征,以提升模型对多尺度目标的检测能力。然而,不同尺度特征对输出特征图的贡献程度各异,简单的直接相加难以实现最优融合效果。为此,本文引入双向交互特征金字塔网络(BiFPN)结构,通过建立跨尺度双向连接并采用加权特征融合机制,对模型进行了优化与改进。

2)引入了挤压-激励模块(squeeze-and-excitation, SE)注意力机制,通过显式建模通道之间的关系,使得网络能够自动学习到每个通道的重要性,从而能够自动强调重要通道、抑制不重要的通道。SE 模块结构简单,计算开销相对较小,可以轻松集成到各种网络结构中。通过自适应的通道加权机制,SE 机制增强了特征图中对关键信息的关注,提高了网络的性能。

3)通过替换损失函数(wise-IoU v2, WIoU)进行优化, WIoU 引入了加权机制, WIoU 在传统交并比(intersection over union, IoU)损失的基础上,为不同的预测框样本引入了动态的权重分配机制。该权重根据预测框与真实框之间的几何关系(如距离、重叠面积)动态计算,使模型在训练过程中能更聚焦于那些难以回归的“困难样本”,从而优化梯度分配。这一改进有效提升了模型,特别是对小目标或遮

挡目标的边界框回归精度与收敛稳定性。

2.1 SE 注意力机制

引入 SE 注意力机制可提高主干网络的特征提取能力^[16]。因此在主干网络的第 10 层引入 SE 注意力机制,SE 注意力机制通过自适应学习通道权重,并根据不同权重对通道特征图进行加权,从而建模卷积特征通道之间的相互依赖关系,提升网络的特征提取能力。以增强 CNN 的表征能力。SE 块通过堆叠形成挤压-激励网络(squeeze-and-excitation network, SENet)架构,并在多个数据集上展示了极高的推广能力。实验结果表明,SE 块在现有 CNN 中显著提高了性能。此外,SE 块生成的特征重要性值还可用于其他任务,如网络剪枝和模型压缩。SENet 在多个任务上表现出了最先进的性能,证明了其在特征提取和通道间关系建模方面的有效性,SE 网络结构如图 3 所示。




图 3 SE 网络结构

Fig. 3 SE network structure

2.2 Wise-IoU v2 损失函数

完整交并比(complete intersection over union, CIoU)虽然考虑了边界框回归的距离、重叠面积、中心点偏移和宽高比,但仍存在一些缺点,如未考虑训练数据集中高质量样本与低质量样本之间的边界框回归平衡问题,且当预测框与真实框的宽高比相同但宽度和高度的值不同时,将宽高比作为惩罚因子不能体现这两个框之间的真实差异。CIoU 计算方式为:

$$V = \frac{4}{p^2} \left(\arctan \frac{W^{gt}}{h^{gt}} - \arctan \frac{W}{h} \right) \quad (1)$$

$$\alpha = \frac{v}{1 - \text{IoU} + v} \quad (2)$$

$$\text{CIoU} = \text{IoU} - \frac{P^2(b, b^{gt})}{c^2} - \alpha v \quad (3)$$

$$L_{\text{CIoU}} = 1 - \text{IoU} + \frac{P^2(b, b^{gt})}{c^2} + \alpha v \quad (4)$$

为系统解决上述 CIoU 在样本平衡与几何惩罚上的局限,后续研究聚焦于设计更智能的梯度分配机制。其核心思路是让损失函数能自动区分简单与困难样本,并动态调整优化重心。WIoU 在此基础上做了进一步演进与改进为应对上述局限,研究者们致力于设计更具判别力的梯度分配策略。预测框和真实框的高度和宽度比例呈线性比例时,CIoU 损失函数中相对比例的惩罚项没有作用^[17]。研究者提出了高效交并比损失(efficient intersection over union version 1, EIou v1)^[18],针对目标检测中高质量与低质量样本之间的边界框平衡问题进行了改进。该方法采用了静态聚焦机制(static focusing mechanism, FM),但未能

充分利用非单调 FM 的潜力。WIoU^[19]在此基础上做了进一步演进与改进。Wise-IoU v2 通过设计动态非单调聚焦机制,为不同质量的预测样本分配更具区分度的梯度权重。这一优化有效缓解了简单样本主导训练的问题,使模型能够更专注于困难样本的回归优化,从而在保持高精度的同时提升了整体收敛效率。

WIoUV2 损失函数公式为:

$$L_{\text{wIoU}} = 1 - \frac{\sum_{i=1}^n w_i \text{IoU}(b_i, g_i)}{\sum_{i=1}^n w_i} \quad (5)$$

2.3 双向特征金字塔网络(BiFPN)结构

BiFPN 被引入到骨干网络和检测头之间,用以替代原有的传统特征金字塔网络(FPN)结构。BiFPN 通过双向信息流和自适应权重分配,有效融合多尺度特征图,提升了特征表达能力和目标检测的准确性。相比传统 FPN 仅自下而上的特征融合,BiFPN 引入双向机制,实现低层特征向高层和高层特征向低层的双向传递,增强了特征交互。水稻虫害种类繁多,外观差异大,导致检测难度增加,模型精度下降,BiFPN 结构如图 4 所示。




图 4 BiFPN 结构

Fig. 4 BiFPN structure

3 实验设置

3.1 实验环境

本研究图形处理单元配备 NVIDIA GeForce RTX 3060 显卡,搭载 20 GB 专用显存以支持大规模并行计算任务。为保证模型充分收敛,本文实验设置 100 个训练周期(epochs)。单次处理图像数量(batch size)设定为 16,以平衡计算效率与内存占用。数据装载时 CPU,所使用的线程数(works)为 0,实验所用的环境以及采用参数如表 2 所示。

3.2 数据集

IP102 数据集、Kaggle、Baidu、Google 网站采集水稻害

表 2 实验的硬件与软件环境配置

Table 2 Experimental hardware and software environment configuration

软/硬件	版本
操作系统	Windows 11 专业版
中央处理器(CPU)	IntelCorei5-12 400F(2.5 GHz)
显卡(GPU)	NVIDIA GeForce RTX 3060
内存	20 GB
编程语言版本	Python-3. 8. 0
GPU 并行计算平台	CUDA-11. 3
深度学习框架	PyTorch-1. 10. 1




图 5 水稻虫害数据集样例

Fig. 5 Rice pest dataset samples

虫图像,水稻虫害共 4 类,合计 3 376 张。数据集包括稻纵卷叶螟、飞蝗、黏虫、褐飞虱 4 种水稻害虫。使用 Labelimg 软件图片进行位置及类别标注,将数据集按 8:1:1 的比例随机划分为训练集、验证集和测试集,水稻虫害数据集如图 5 所示。

3.3 数据增强

为避免由于训练数据不足而导致过拟合问题,本研究

采用了水平翻转、随机对比度调整、颜色抖动、随机亮度调整和添加噪声的数据增强技术以扩充水稻虫害数据集,数据集包含 33 760 张图像。确保数据集的多样性,已提高模型的泛化能力。数据扩增的具体方式如图 6 所示。

3.4 数据分布

本研究使用的原始数据集包含 3 376 张图像,涵盖



图 6 数据增强

Fig. 6 Data augmentation

4 类害虫。为满足深度学习模型对数据量的需求并缓解潜在的类别不平衡问题,本研究实施了系统性的数据增强流程。经扩增后,数据集总量达到 33 760 张图像,扩增后各类别样本量有效抑制了长尾分布的形成,扩增前后各类别样本量及分布如图 7、8 所示。

3.5 评价指标

本研究采用多项指标综合评估模型性能,包括精确率 (precision, P)、召回率 (recall, R)、平均精度 (average

precision, AP)、mAP、模型参数量以及浮点运算量。其中, mAP 是目标检测领域的关键评价指标,它通过综合考量所有类别的精确率与召回率来计算得出。mAP 值越高,通常代表模型的综合检测性能越优越。

$$P = \frac{TP}{TP + FP} \tag{6}$$

$$R = \frac{TP}{TP + FN} \tag{7}$$




图 7 水稻虫害数据集扩充前样本量

Fig. 7 Sample size of rice pest dataset before expansion




图 8 水稻虫害数据集扩充后样本量

Fig. 8 Sample size of expanded rice pest dataset

$$AP = \int_0^1 P(R) dR \tag{8}$$

$$mAP = \frac{\sum_{i=1}^K AP_i}{K_{classes}} \tag{9}$$

其中,TP(true positives)是正类判断为正类;FP(false positives)是负类判断为正类;FN(false negatives)是正类判断为负类;TP+FP 即表示检测出的正样本总数,TP+FN 表示所有的正样本数。平均精度 AP 是不同召回率下的精确度的平均值, $P(R)$ 表示不同召回率下精确度。 K 为检测类别数; $AP(i)$ 为第 i 类缺陷的平均精度。

4 结果与分析

4.1 消融实验

为了验证各项改进模块的有效性,本研究进行了消融对比实验,已验证每个改进策略对模型性能的影响,并采用相同的训练策略。依次将 3 个改进策略添加到原 YOLOV8 算法模型中做全因子实验,在同一试验条件下训练 100 轮次,训练结果如表 3 所示。

表 3 中的消融实验结果表明,在控制实验条件一致的

表 3 消融实验

Table 3 Ablation experiment							(%)
模型	WIoU V2	SE	BiFPN	P	R	mAP	
1				89.6	78	85.2	
2	✓			90.6	78.3	86.1	
3		✓		91.1	81.9	86.2	
4			✓	90.5	78.7	86.4	
5	✓	✓		91.2	81.4	87.7	
6	✓		✓	91.7	79.7	88.2	
7		✓	✓	91.3	82.1	87.7	
8	✓	✓	✓	92.5	83.3	89.2	

前提下,首先,单独引入 WIoU V2 损失函)使得模型的精度从 89.6%提升至 90.6%,召回率从 78%增加至 78.3%,mAP 从 85.2%提升至 86.1%,表明该损失函数在边界框回归任务中提升了定位准确性。进一步加入 SE 模块后,模型的精度从 90.6%提升至 91.2%,召回率显著提升,从 78.3%增加至 81.4%,mAP 提升至 87.7%,这表明 SE 模块通过通道注意力机制增强了模型对重要特征的表达能力,提高了检测的全面性。最终,结合 BiFPN 结构,模型性能获得最大提升,P 达到 92.5%,R 提升至 83.3%,mAP 达到 89.2%,这表明 BiFPN 有效加强了多尺度特征融合,提升了模型对不同大小目标的检测能力。

综上,逐步引入 WIoU V2、SE 和 BiFPN 模块显著提升了 YOLOv8n 的检测性能,验证了各模块在目标检测任务中的有效性。

4.2 对比试验

为展现本研究算法网络的性能优势,将其与多个主流目标检测网络 YOLOv5、YOLOv8、YOLOv9、YOLOv10 及 Faster R-CNN 进行了对比。本研究在相同的实验环境、相同的数据集上进行测试。本研究使用共 3 个指标来评估模型:mAP50、P、R。本研究算法为评估模型的稳定性和排除随机因素的影响,所有对比实验均在 3 种不同的随机种子下独立重复进行 3 次。本研究算法报告的性能指标均为 3 次独立实验结果的算术均值±标准差,以全面反映模型的平均性能与稳定性不同目标对比结果不同目标对比结果如表 4 所示。

对比实验结果显示本研究算法主要指标与其他网络相比都为最高。平均精度均值与 YOLOv5、YOLOv8、YOLOv9、YOLOv10、Faster R-CNN 模型相比分别提高 5.1%、4.2%、8%、4.1%和 29.45%。检测精确率与 YOLOv5、YOLOv8、YOLOv9、YOLOv10、Faster R-CNN 模型相比分别提高 4.1%、2.9%、5.4%、4.9%和 50.43%。相比 YOLOv5、YOLOv8、YOLOv9、YOLOv10、Faster R-CNN 模型召回率分别提高 4.8%、5.3%、3.4%、5%和 18.21%。本文改进的模型可以在参数数量较小的情况下使得精度、召回率和平均精度均值都有一定程度的提升,证明了改进工作的有效性。

表 4 不同模型下对水稻虫害数据集的对比结果

Table 4 Comparison results of different models on rice pest dataset (%)

模型	mAP50	P	R
YOLOv5	84.10	88.40	78.50
YOLOv8	85.20	89.60	78.0
YOLOv9	86.40	87.10	79.90
YOLOv10	85.10	87.60	78.30
Faster R-CNN	59.75	42.07	65.09
本文	89.20±0.03	92.50±0.05	83.30±0.04

4.3 实例检测

图 9 和 10 所示为本研究所提出的算法相比于原始的 YOLOv8 模型,原始模型在处理背景复杂的图像时,存在明显误检。在图 7(d)中,模型将目标区域(褐飞虱)误识别为稻纵卷叶螟,显示其对纹理和颜色干扰敏感,泛化能力有限,影响检测准确性。相比之下,图 10 为本文改进模型的检测结果,显示出更强的目标辨别能力与边界拟合能力。该模型在相同图像条件下,准确识别虫害目标,避免了误识别问题,说明改进后的网络结构更有效地提取了关键特征,并能更紧密地框定虫体轮廓,置信度的提高说明




图 9 原模型检测结果

Fig. 9 Detection results of the original model




图 10 本研究模型检测结果

Fig. 10 Detection results of the proposed model

了模型对检测结果更加自信,误报率和漏报率降低,从而提升整体检测准确性和可靠性。能够更好地满足实际应用中的检测需求。通过对网络结构的优化和算法的改进,本研究的算法在捕捉复杂虫害特征方面表现得更加敏感和精准,显著增强了对多样化虫害的识别能力。这不仅提升了模型的检测效果,也为水稻病虫害的早期监测和精准防治提供了坚实的技术保障,促进了水稻健康管理的科学化和高效化,具有重要的实际应用价值。

5 结 论

针对传统算法在识别水稻小目标害虫时存在的特征提取困难与识别精度不足的问题,本研究构建了包含 4 种常见水稻害虫的数据集。为防止训练数据不足导致的过拟合,采用了水平翻转、特征向量增强放及添加噪声等多样化数据增强手段,将原始数据扩充至 33 760 张图像,保证了数据集的多样性与代表性,显著提升了模型的泛化能力。基于此数据集,提出了改进的 YOLOv8n 算法:首先融合 SE 注意力机制模块,强化模型对关键虫害特征的聚焦能力,减少背景干扰,提升特征表达效果;其次引入 Wise-IoUv2 损失函数,优化回归精度,提升定位性能。最后 BiFPN 通过双向信息流和自适应权重分配,有效融合多尺度特征图,提升了特征表达能力和目标检测的准确性。消融实验及对比实验结果表明,改进模型的 mAP 较原始 YOLOv8n 提升 4%,达到 89.2%,显著降低了漏检和误检,验证了所提方法在水稻虫害检测任务中的有效性与实用价值。未来研究将聚焦于模型的轻量化设计,在保证检测精度的同时,实现算法在移动端和嵌入式设备上的高效部署,推动智能农业中水稻虫害检测技术的广泛应用。

参考文献

[1] Shi S H, Zhou S W, Lei Y D, et al. Burgeoning food demand outpaces sustainable water supply in China[J]. Agricultural Water Management, 2024, 301: 108936.

[2] 朱周华,周怡纳,侯智杰,等. 基于改进 Vision Transformer 的水稻叶片病害图像识别[J]. 电子测量技术,2025,48(10):153-160.

Zhu Zhouhua, Zhou Yina, Hou Zhijie, et al. Rice leaf disease image recognition based on improved vision transformer[J]. Electronic Measurement Technology, 2025, 48(10): 153-160.

[3] Singh P, Verma A, Alex J S R. Disease and pest infection detection in coconut tree through deep learning techniques[J]. Computers and Electronics in Agriculture, 2021, 182: 105986.

[4] Zhang Z L, Guo H S, Zhang Y, et al. Towards accurate field counting of small pests with visual prompts [J]. Computers and Electronics in Agriculture, 2025, 237(Part B): 110635.

[5] 张赫. 基于深度学习的作物虫害快速识别与分割算法

- 研究[D]. 杭州:杭州电子科技大学,2021:2.
- Zhang He. Research on deep learning-based rapid identification and segmentation algorithms for crop pests[D]. Hangzhou: Hangzhou Dianzi University, 2021: 2.
- [6] 范金豪,崔立志. 基于 YOLO_ES 的垃圾分类目标检测模型[J]. 电子测量技术,2023,46(1):160-166.
- Fan Jinhao, Cui Lizhi. Waste classification object detection model based on YOLO_ES[J]. Electronic Measurement Technology, 2023, 46(1): 160-166.
- [7] Chen J D, Zhang D F, Zeb A, et al. Identification of rice plant diseases using lightweight attention networks [J]. Expert Systems with Applications, 2021, 169: 114514.
- [8] 李咏然,臧兆祥,唐庭龙. 针对多尺度和小目标的道路缺陷检测模型[J]. 电子测量与仪器学报,2025, 39(8):30-41.
- Li Yongran, Zang Zhaoxiang, Tang Tinglong. Road defect detection model for multi-scale and small targets [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(8): 30-41.
- [9] 张永宏,许鑫豪,尹贺峰,等. MFSF-DETR:一种基于多尺度特征移位融合的 PCB 缺陷与元件检测算法[J]. 仪器仪表学报,2025,46(8):266-285.
- Zhang Yonghong, Xu Xinhao, Yin Hefeng, et al. MFSF-DETR: A PCB defect and component detection algorithm based on multi-scale feature shift fusion[J]. Chinese Journal of Scientific Instrument, 2025, 46(8): 266-285.
- [10] Wang C, Bochkovskiy A, Liao H-Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition, Vancouver: IEEE, 2023: 7464-7475.
- [11] Li C Y, Li L L, Jiang H L, et al. YOLOv6: A single-stage object detection framework for industrial applications[PP/OL]. V1. (2022-09-06) [2025-08-25]. <http://ui.adsabs.harvard.edu/abs/2022arXiv220902976L/abstract>.
- [12] Wang C, Liao H-Y M, Wu Y, et al. CSPNet: A new backbone that can enhance learning capability of CNN [C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Seattle: IEEE, 2020: 390-391.
- [13] Liu S, Qi L, Qin H F, et al. Path aggregation network for instance segmentation [C]// IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 8759-8768.
- [14] 车琳,蒋沁宏,王也,等. 我国水稻五大产区虫害发生及防控情况差异的比较分析[J]. 植物保护,2022, 48(3):233-241.
- Che Lin, Jiang Qinghong, Wang Ye, et al. Comparative analysis of pest occurrence and control in the five major rice-producing regions of China [J]. Plant Protection, 2022, 48(3): 233-241.
- [15] Cuenca-Medina M, González-Mas N, Martínez-Anguita Ó, et al. A new aphid IPM strategy based on the use of endophytic entomopathogenic ascomycetes that reduces treatment risks to the generalist predator *Chrysoperla carnea* (Stephens) [J]. Journal of Invertebrate Pathology, 2025, 211: 108357.
- [16] 付建军,陈林,童华敏,等. 基于改进 EfficientNet 的海上风机叶片早期缺陷检测及分类[J]. 电子测量技术, 2024,47(16):110-119.
- Fu Junjun, Chen Lin, Tong Huamin, et al. Early defect detection and classification of offshore wind turbine blades based on improved EfficientNet [J]. Electronic Measurement Technology, 2024, 47(16): 110-119.
- [17] 许晓阳,高重阳. 改进 YOLOv7-tiny 的轻量级红外车辆目标检测算法[J]. 计算机工程与应用, 2024, 60(1):74-83.
- Xu Xiaoyang, Gao Chongyang. Improving YOLOv7-tiny lightweight infrared vehicle detection algorithm [J]. Computer Engineering and Applications, 2024, 60(1): 74-83.
- [18] Zhang Y F, Ren W Q, Zhang Z, et al. Focal and efficient IOU loss for accurate bounding box regression [J]. Neurocomputing, 2022, 506(C): 146-157.
- [19] 李茂,肖洋秩,宗望远,等. 基于改进 YOLOv8 模型的轻量化板栗果实识别方法[J]. 农业工程学报,2024, 40(1):201-209.
- Li Mao, Xiao Yangyi, Zong Wangyuan, et al. A lightweight chestnut fruit recognition method based on improved YOLOv8 model [J]. Transactions of the Chinese Society of Agricultural Engineering, 2024, 40(1): 201-209.

作者简介

王金聪,博士,主要研究方向为电气自动化、计算机视觉与人工智能。

E-mail:321475025@qq.com

于志超(通信作者),硕士,主要研究方向为计算机视觉。

E-mail:753167881@qq.com

杨海峰,硕士,主要研究方向为计算机视觉。

E-mail:321475025@qq.com

汤普然,硕士生,主要研究方向为计算机视觉。

E-mail:321475025@qq.com

张志伟,硕士生,主要研究方向为计算机视觉。

E-mail:321475025@qq.com