doi:10.6041/j.issn.1000-1298.2025.04.033

面向边缘计算的水稻病害检测方法与装置研究

周　成[1]　陈章彬[1]　杜雅刚[2]　房　欣[2]　姚立立[1]　周曹航[1]

(1.湖州师范学院信息工程学院,湖州 313000;2.黑龙江省农垦科学院农业工程研究所,哈尔滨 150030)

摘要:针对自然环境下水稻病害检测准确性与效率不高等问题,本文提出一种改进 YOLO v5s 的轻量化检测模型 YOLO-RD,并将其部署至边缘计算设备,设计便携式检测装置,实现水稻病害快速检测。通过引入 GhostNet 网络减少计算量和参数量。结合轻量级注意力机制 Shuffle Attention 和动态检测头 DyHead(Dynamic head),增强模型对水稻病害图像的特征提取和自适应检测能力。使用 Shape-IoU 替代 CIoU 损失函数,提升自然环境下检测精度。试验结果表明,YOLO-RD 模型在平均精度均值(mean Average Precision, mAP)达到 94.2% 的同时,大幅降低计算复杂度和参数量,具有良好的轻量化效果,与基准模型相比计算量、参数量和内存占用量分别减少 44.4%、43.2% 和 41.3%。与 YOLO 11n、YOLO v8n 和 YOLO v5n 等目标检测模型对比,本模型检测效果最佳。将模型在树莓派 4B 边缘计算设备上部署,单幅图像检测时间为 1.97 s,满足实际应用需求,可为水稻病害智能化检测提供高效可行的解决方案。

关键词:水稻病害;检测;YOLO v5s 模型;边缘计算;轻量化;树莓派 4B

中图分类号:S224.3　　**文献标识码**:A　　**文章编号**:1000-1298(2025)04-0353-10　　**OSID**:

Development of Rice Disease Detection Methods and Devices for Edge Computing

ZHOU Cheng[1]　CHEN Zhangbin[1]　DU Yagang[2]　FANG Xin[2]　YAO Lili[1]　ZHOU Caohang[1]

(1. *School of Information Engineering*, *Huzhou University*, *Huzhou* 313000, *China*

2. *Institute of Agricultural Engineering*, *Heilongjiang Academy of Land Reclamation Sciences*, *Harbin* 150030, *China*)

Abstract: Aiming to address the challenges of accuracy and efficiency in rice disease detection under natural conditions, a lightweight detection model, YOLO-RD, was presented based on an improved YOLO v5s framework. The model was optimized and successfully deployed on edge computing devices, enabling the creation of a portable device for fast rice disease detection. In the proposed model, GhostNet was integrated to reduce computational complexity and the number of parameters. Finally, the lightweight Shuffle Attention mechanism and the dynamic detection head DyHead were employed to enhance feature extraction and adaptive detection capabilities, particularly for complex disease features. Furthermore, the standard CIoU loss function was replaced by Shape-IoU to improve detection performance in challenging environments by focusing on shape-based regression. Experimental results demonstrated that YOLO-RD achieved a mean Average Precision (mAP) of 94.2%, while significantly reducing computational complexity and parameter size. Specifically, YOLO-RD reduced computation, parameters, and weight by 44.4%, 43.2%, and 41.3%, respectively, compared with the baseline model. In addition, the model outperformed detection models such as YOLO 11n, YOLO v8n, YOLO v5n, and others in terms of accuracy. When deployed on a raspberry Pi 4B edge computing device, YOLO-RD achieved an inference time of 1.97 s per image, meeting the requirements for real-time application. These findings suggested that YOLO-RD offered an efficient and robust solution for intelligent rice disease detection in practical agricultural scenarios.

Key words: rice disease; detection; YOLO v5s; edge computing; lightweight; raspberry Pi 4B

收稿日期:2024-10-11　修回日期:2024-12-09

基金项目:国家水稻产业技术体系综合试验站项目(CARS-01-95)和湖州市重点研发计划项目(2022ZD2048)

作者简介:周成(1973—),男,研究员,博士,主要从事智能农业装备研究,E-mail:nkzhoucheng@126.com

通信作者:姚立立(1993—),男,讲师,博士,主要从事智慧农作技术、大田物联网和农业传感器研究,E-mail:03120@zjhu.edu.cn

0 引言

作为我国主要粮食作物之一,水稻在全国粮食生产总量中占据重要比例,尽管水稻产业发展迅速,但水稻病害的侵袭仍然是一大难题[1]。我国水稻病害种类多样,流行频率高,对水稻产量和品质造成了严重影响[2]。纹枯病[3]、叶瘟病[4]、穗瘟病[5]和稻曲病[6]是常见的水稻病害,根据 2024 年发布的水稻病害预测报告,水稻纹枯病和稻瘟病的全国发病面积预计将分别达到 1.5×10^7 hm^2 和 4.0×10^6 hm^2[7]。然而传统的水稻病害识别方法主要依赖人工,不仅费时费力,而且由于植保专家的匮乏,种植人员的判断往往存在主观差异[8]。因此,为实现在自然环境中快速准确地识别水稻病害,需开发适用于边缘计算设备的轻量化模型,以帮助种植者及时采取针对性的预防措施,减少病害引起的减产和经济损失[9]。

随着深度学习的快速发展,农作物病害检测技术也取得新的突破。早期研究主要是采用卷积神经网络(Convolutional neural network, CNN)来检测水稻病害,这种方法的核心在于从整幅图像中提取特征,并利用这些特征来进行病害分类[10]。MATIN 等[11]采用 AlexNet 技术结合图像增强方法,成功检测出 3 种常见的水稻叶部病害,平均精度均值达 99%。但是,这类方法在面对复杂环境时容易产生误报或漏检[12]。由于真实的农田环境多变,这为病害检测增加了难度[13]。随着技术的发展,采用更先进的目标检测技术检测农作物病害的方法已经成为发展趋势[14-15]。同时为便于模型部署至边缘计算设备,一些研究者致力于目标检测模型的轻量化研究[16-17]。LIN 等[18]提出改进的 YOLO X-Tiny 用于烟草褐斑病的检测,在模型中引入卷积块注意力模块(Convolutional block attention modules, CBAM),使检测平均精度均值达到 80.56%。廖娟等[19]提出基于 YOLO v5 的轻量化水稻病害识别模型,通过 GsConv 提升推理速度,平均精度均值达 93.5%。马超伟等[20]基于 YOLO v8 模型,采用 PP-LCNet(PaddlePaddle lite convolutional neural network)等改进方法,使模型参数量减少 12.5%,为小麦病害检测的边缘部署提供参考方案。然而,现有研究在检测精度和模型复杂度的平衡上仍有改进空间,尤其是在水稻病害检测领域。

针对上述问题,本文提出一种以 YOLO v5s 为基准模型,通过对骨干网络、颈部网络、检测头及损失函数进行改进的模型 YOLO-RD。该模型便于部署至边缘计算设备中,以满足水稻病害检测实际使用场景。

1 材料与方法

1.1 水稻病害图像采集

本试验中的水稻病害图像于 2023 年 9—10 月在湖州市吴兴区试验田(湖州市农业科学研究院农业试验基地)、南浔区试验田(善琏镇试验田)、德清县试验田(百粮山试验田)等地采集,如图 1 所示。采集设备为带有高清摄像头的 iPhone11 手机,采集距离 10~30 cm,图像分辨率为 3 024 像素×3 024 像素。为确保构建自然田间环境的病害图像数据集,采集过程以不同角度、时间段、光照和田间条件进行拍摄,共获取 1 100 幅病害图像,采集的水稻病害图像包括纹枯病、叶瘟病、穗瘟病和稻曲病 4 种病害,如图 1 所示。

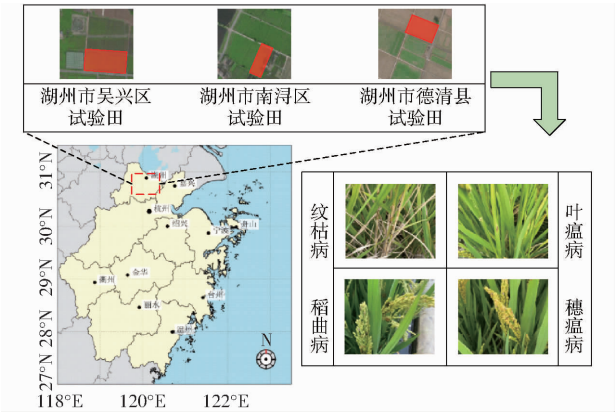

图 1 水稻病害图像采集地点与病害图像

Fig. 1 Rice disease collection locations and images

1.2 水稻病害数据集构建

为确保模型的泛化能力和鲁棒性,针对自然环境下采集的水稻病害图像,采用数据增强技术对数据进行扩充,使用翻转、镜像、噪声、亮度、平移等方式随机组合。通过这些数据增强方法共得到 8 800 幅病害图像,将数据集按照比例 8∶1∶1 划分为训练集(7 040 幅)、测试集(880 幅)和验证集(880 幅),其中部分图像包含多种病害,最终数据集标注数量如表 1 所示。

表 1 水稻病害数据集各类别标注数量

Tab. 1 Annotated quantities of each category in rice disease dataset

病害类别	训练集	验证集	测试集	总计
纹枯病	9 142	1 278	1 159	11 579
叶瘟病	12 797	1 438	1 496	15 731
穗瘟病	44 584	5 343	5 316	55 243
稻曲病	8 382	1 053	1 112	10 547

2 水稻病害检测方法与装置

2.1 YOLO v5

为适应不同场景的需求,YOLO v5 模型根据网

络的宽度和深度分 5 个版本，为 YOLO v5n、YOLO v5s、YOLO v5m、YOLO v5l 和 YOLO v5x，检测速度逐渐递减，而精度逐渐提升。鉴于本文的目标是将模型部署到边缘计算设备中，且对实时性有一定要求，选择 YOLO v5s 作为基准模型进行改进，以平衡检测精度与计算复杂度[21]。

2.2　GhostNet 轻量化网络

由于本模型需要部署在计算能力有限的边缘计算设备中，所以必须减少网络计算量和参数量。为此，在骨干网络和颈部网络中引入轻量级的 GhostNet 结构，其通过使用深度可分离卷积来实现网络轻量化[22]。首先，采用 GhostConv 模块替代原来的卷积结构，通过 1×1 卷积减少通道数，压缩特征图并提取重要特征。其次，使用深度可分离卷积对这些重要特征进行处理，生成 Ghost 特征图。最后，将压缩后的特征图与处理后的 Ghost 特征图合并，生成计算量较低但仍然高效的输出特征图。C3Ghost 模块则通过在原 C3 模块中引入 Ghost Bottleneck 结构，在保持特征提取能力前提下，进一步降低模型计算量和参数量。这一改进显著提升了模型轻量化效果，增强运行效率。

2.3　Shuffle Attention 注意力机制

为提升轻量化改进后的 YOLO v5s 模型在复杂环境下对水稻病害图像的特征提取能力，引入一种轻量级的 Shuffle Attention 注意力机制[23]。它通过结合通道注意力和空间注意力来增强模型对重要特征的关注，同时保持较低的计算量。

首先，Shuffle Attention 对输入的特征组进行分组，将特征图 $G \in I^{C\times H\times W}$（其中，$C$、$H$、$W$ 分别表示通道数、特征图高度和宽度）按通道维度划分为 O 组 $G=[G_1,G_2,\cdots,G_I]\in I^{C/O\times H\times W}$。接着特征图会被分成 2 条分支 G_{t1} 和 G_{t2}，G_{t1}、$G_{t2}\in I^{C/O\times H\times W}$，分别处理通道和空间注意力。对于通道注意力部分，通过全局平均池对 G_{t1} 进行操作，得到通道维度的平均值。其次，在空间注意力部分，G_{t2} 通过组归一化处理得到空间维度上的特征值。然后，通道和空间注意力的结果分别通过 Sigmoid 激活函数处理，并与原特征拼接在一起。最终，使用通道混洗操作实现子特征组之间的通信，确保输出的特征图与输入尺寸相同，如图 2 所示。图中 $F_C(\cdot)$ 表示线性函数，$\sigma(\cdot)$ 表示 Sigmoid 激活函数，F_{gp} 表示平均池化函数，GN 表示组归一化函数。这种机制能够有效提高模型在复杂环境下的特征提取能力，特别是在水稻病害检测中，能强化模型对病害区域的关注，提升检测精度和鲁棒性，同时保持较低的计算开销。

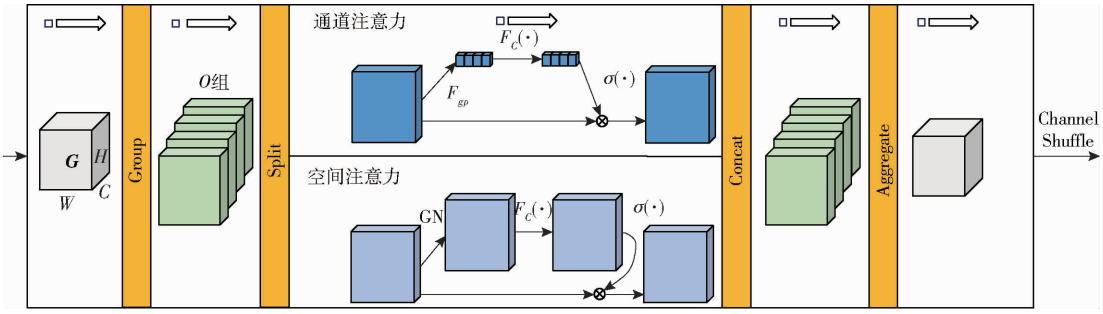

图 2　Shuffle Attention 注意力机制结构图

Fig. 2　Structure of Shuffle Attention mechanism

2.4　DyHead 动态检测头

本文的数据集涵盖多种水稻病害，部分病害特征尺寸小，同时采集过程中拍摄了不同品种的水稻病害图像。为应对这些复杂情况，提高检测精度，采用一种动态检测头 DyHead[24]。该检测头集成尺度感知、空间感知和任务感知等多个自注意力机制，有效增强模型的检测能力，同时保持较低的计算复杂度。

如图 3 所示，首先，DyHead 将输入的特征图转换为三维张量，其中 L 表示层数，S 表示特征图高度和宽度。其次，DyHead 依次应用尺度感知自注意力（Q_L）、空间感知自注意力（Q_S）和任务感知自注意力（Q_C），逐层优化病害检测的特征提取过程。最后，输出检测结果。这种方法不仅增强模型对不同尺度病害特征的感知，还通过空间注意力识别图像中的空间差异，提高病害目标的定位和分类精度。DyHead 具有自适应的特征金字塔结构，使模型能够在不同尺度下灵活提取关键特征尤其在小病斑检测上，表现出优异的性能，同时也提升模型在复杂场景中的鲁棒性，提高对多种水稻病害的检测能力。

2.5　Shape－IoU 损失函数

在目标检测中，损失函数是衡量预测结果与真实结果之间差异的关键，对于模型训练至关重要。YOLO v5s 模型原有的 CIoU 损失函数在目标遮挡较少时表现良好，但在本文中，水稻处于拔节期至孕穗期，病害目标严重遮挡，CIoU 无法满足准确检测需

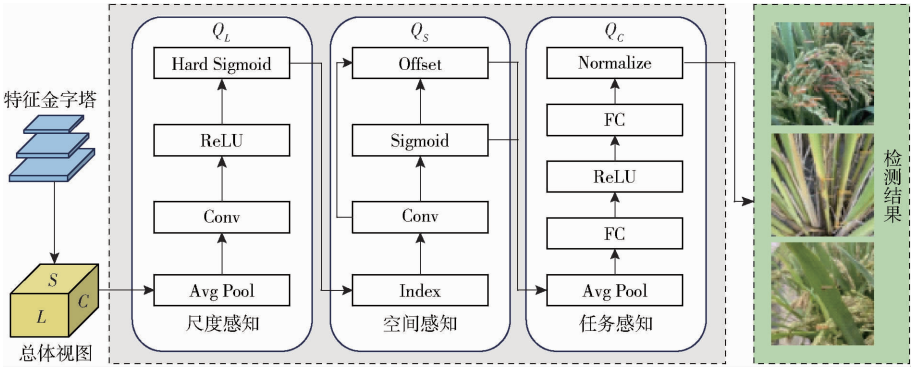

图 3 DyHead 结构图

Fig. 3 Structure of DyHead

求。因此,引入 Shape - IoU 损失函数,这种新的边界框回归方法更加注重目标形状与尺寸,以提升模型针对目标被遮挡情况下的检测能力[25]。如图 4 所示,其中 w^{gt} 和 h^{gt} 分别为真实框宽度和高度,x_c^{gt} 和 y_c^{gt} 为其中心点坐标,w 和 h 为预测框宽度和高度,x_c 和 y_c 为预测框中心点坐标。

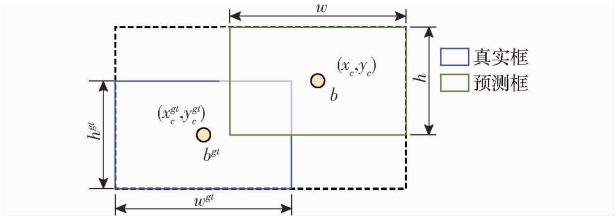

图 4 Shape - IoU 损失函数原理图

Fig. 4 Principle of Shape - IoU loss function

Shape - IoU 是通过计算真实框和预测框之间的重叠面积及合并后总面积来衡量 2 个边界框重叠程度,其值在 0 ~ 1 之间。最后,将该重叠程度转换为损失值,用于指导模型训练和优化。

这种方法能够更加准确地处理目标遮挡和形状差异,显著提升模型在复杂场景下的性能。

2.6 改进 YOLO v5s 网络结构

为提升 YOLO v5s 模型在边缘计算设备上的适用性,本文提出一种改进模型 YOLO - RD。首先,针对骨干网络和颈部网络进行优化,使用 GhostNet 替换部分 C3 模块和 Conv 模块,以减少计算量并提升推理效率。然后,在骨干网络中引入 Shuffle Attention 机制,增强特征提取能力。在颈部网络的 Concat 模块后也引入 Shuffle Attention,以提高模型在不同角度、光照条件和田间环境下的鲁棒性。其次,针对病害特征尺寸小以及水稻不同品种特征差异较大的问题,采用 DyHead 动态检测头,进一步提升模型对细小病害特征的捕捉能力。DyHead 结合多尺度、空间和任务感知的自适应检测机制,特别适合在复杂背景下对小目标的检测。最终,本文将原有的 CIoU 损失函数替换为更加关注目标形状的 Shape - IoU 损失函数,这一改进通过考虑边界框的形状和尺寸,尤其在目标被遮挡较为严重的情况下,显著提升了模型检测性能。这种多方位的改进,结合轻量化、特征提取和损失函数优化,使 YOLO - RD 模型在边缘计算设备上具备较强的适应性和鲁棒性,YOLO - RD 模型网络结构如图 5 所示。

2.7 检测装置需求

为了解决当前水稻病害检测主要依赖人工识别、缺乏专业便携式检测装置等问题,研发一种满足实时检测的装置。本装置硬件系统由边缘计算模块、供电模块、图像采集模块以及显示模块构成[17]。边缘计算模块中选择树莓派 4B 作为改进后模型部署的边缘计算设备,其拥有博通 BCM2711 CPU、配备 8 GB 内存,软件环境为 64 位 Raspberry Pi OS、深度学习框架为 PyTorch 1.11.0 以及 Python 3.9.2,其计算能力满足本改进模型部署,相较 Jetson Nano 边缘计算设备成本低 50% 以上。供电模块则是由锂电池、不间断供电主板和自锁开关构成,为边缘计算模块提供电源并实现充电等功能。图像采集模块由 800 万像素摄像头构成,用于水稻病害实时图像采集。显示模块由 5 英寸触摸屏构成,实现软件及检测结果的显示。本硬件系统结构及工作流程如图 6 所示,首先,将供电模块自锁开关开启,系统开始运行。接着,点击显示模块中软件的检测功能,其通过边缘计算模块调用图像采集模块,该模块再将采集到的水稻病害图像传输到边缘计算模块,其内置模型进行本地检测。最后,将检测结果由显示模块显示。

检测装置结构以便携性为主,同时针对水稻病害发生在不同部位,如叶部、茎部、穗部等,在检测装置中设计可折叠的采集杆,便于使用者获取水稻不同部位的病害图像,这种设计不仅增强装置灵活性和适用性,还提升检测全面性和效率,装置整体结构如图 7 所示。

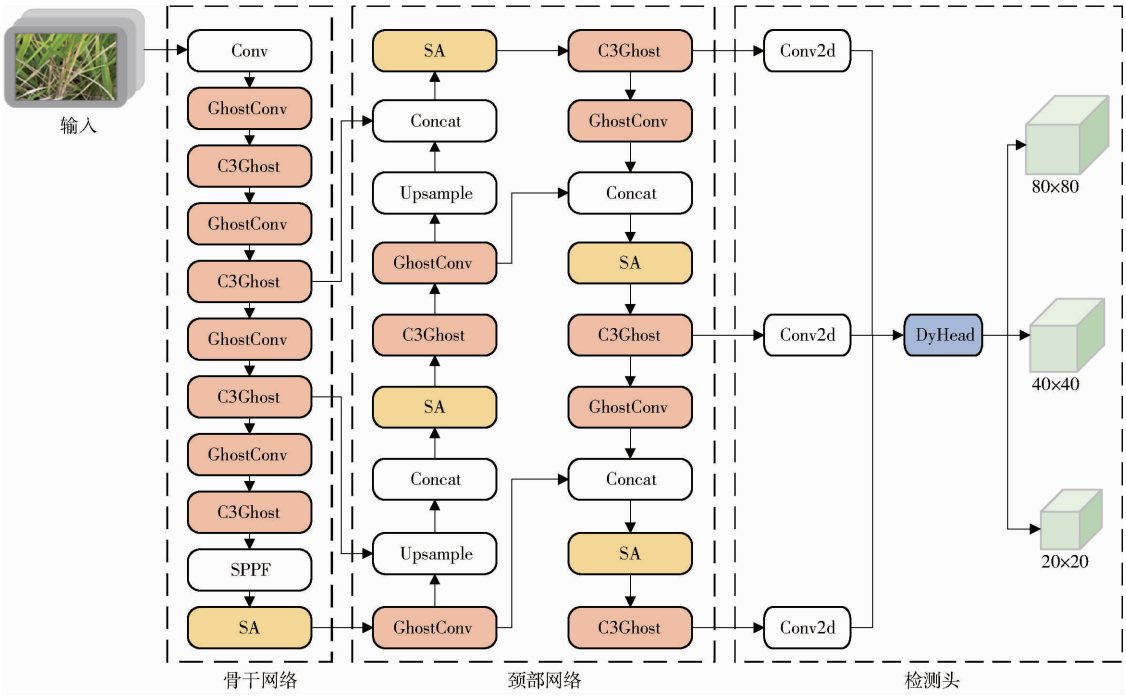

图 5　YOLO－RD 模型网络结构图

Fig. 5　Structure of YOLO－RD model network

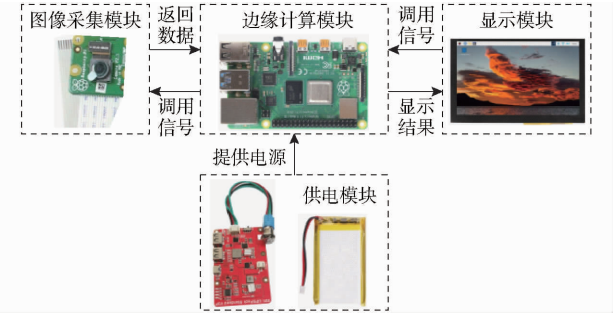

图 6　硬件系统结构及工作流程图

Fig. 6　Hardware system architecture and workflow

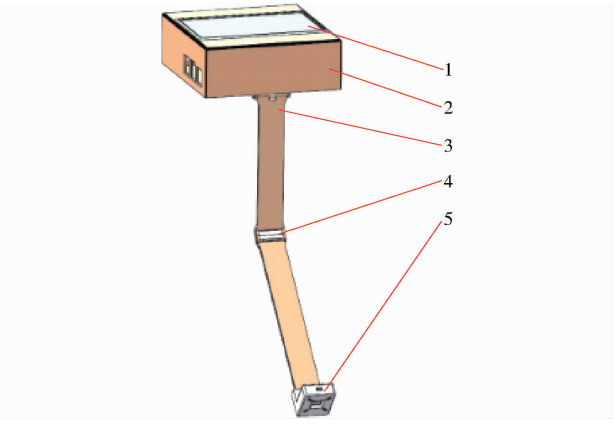

图 7　装置整体结构图

Fig. 7　Overall structural design of device

1. 显示模块　2. 边缘计算、供电模块　3. 可折叠采集杆　4. 折叠关节　5. 图像采集模块

2.8　试验指标

为客观评价改进后模型性能，采用精确率（Precision，P）、召回率（Recall，R）、平均精度均值（mAP @ 0.5）、浮点计算量（FLOPs）、参数量（Parameters）、内存占用量（Weights）和每幅图像平均推理时间（Inference time）作为评估指标。精确率和召回率衡量模型误检和漏检情况，平均精度均值用于评估整体检测精度，浮点计算量表示计算复杂度，参数量和内存占用量反映模型轻量化程度，推理时间则衡量模型的实时性。

2.9　试验环境及训练参数

本试验主要模型训练与测试在服务器上完成，该服务器硬件配置为 Intel（R）Xeon（R）E5－2650 v3 CPU，128 GB 内存，NVIDIA GeForce RTX 4090（24G）GPU。软件环境为 Linux 5.14.0 操作系统，深度学习框架为 PyTorch 1.11.0、CUDA 11.3.1 以及 Python 3.9.18。

训练参数为：初始学习速率设置为 0.01，输入图像尺寸为 640 像素 ×640 像素，动量值为 0.937，迭代次数和批量大小设置为 300 和 64，选用官方 YOLO v5s.pt 预训练权重进行训练。

3　结果与讨论

3.1　消融试验

为验证每个改进策略有效性，以 YOLO v5s 为基准模型，通过消融试验逐步引入改进策略，评估模型改进后的效果，试验结果如表 2 所示。首先，在骨干网络和颈部网络中引入 GhostNet 模块，替换部分 Conv 和 C3 模块，使模型参数量和内存占用量分别降低 47.5% 和 45.6%，浮点计算量从 1.6×10^{10} 下

表 2 消融试验结果

Tab. 2 Results of ablation experiments

GhostNet	SA	DyHead	Shape－IoU	平均精度均值/%	浮点计算量	参数量	内存占用量/MB	推理时间/ms
－	－	－	－	95.4	1.6×10^{10}	7.03×10^{6}	13.8	6.18
√	－	－	－	92.8	8.2×10^{9}	3.69×10^{6}	7.5	6.88
√	√	－	－	93.3	8.2×10^{9}	3.69×10^{6}	7.5	7.72
√	√	√	－	93.8	8.9×10^{9}	3.99×10^{6}	8.1	12.95
√	√	√	√	94.2	8.9×10^{9}	3.99×10^{6}	8.1	13.25

注：“√”表示采用该改进策略，“－”表示未采用该改进策略。

降到 8.2×10^{9}。尽管平均精度均值略微降低 2.6 个百分点，但也在合理范围。这证实该方法在使模型轻量化的同时保证较好的检测能力。接着，在轻量化基础上加入 SA(Shuffle Attention)注意力机制，以增强模型对水稻病害关键特征的关注度。从表 2 可以看到，该注意力机制加入后，模型参数量和内存占用量基本不变的情况下平均精度均值上升 0.5 个百分点。然后，将检测头更换为 DyHead 动态检测头，进一步增强模型对复杂环境下小目标检测能力，使平均精度均值又提升 0.5 个百分点。最后，用 Shape－IoU 损失函数替换原有的 CIoU 损失函数，使模型更加关注水稻病害特征形状本身，平均精度均值达到 94.2%，推理时间为 13.25 ms。经过这一系列改进，YOLO－RD 模型在计算量、参数量、内存占用量方面均表现出显著优势，推理时间也满足实际需求。与基准模型相比，计算量、参数量和内存占用量分别减少 44.4%、43.2% 和 41.3%，满足边缘计算设备的部署需求，为后续的部署应用奠定基础。

3.2 不同轻量化改进对比

为选择最优轻量化改进，分别在 YOLO v5s 模型中引入 ShuffleNetv2[26]、MobileNetv3[27]、EfficientViT[28]、PP－LCNet[20]和 GhostNet[22]等轻量化网络进行试验，结果如表 3 所示。通过对比可以看出，引入 GhostNet 的表现最为优异，其平均精度均值达到 92.8%，且在大幅降低浮点计算量和参数量的同时，仍保持出色的检测精度。相比之下，采用 ShuffleNetv2 和 MobileNetv3 尽管在浮点计算量和参数量上更为轻量化，但其平均精度均值相对较低，表明在面对复杂水稻病害检测时存在局限性。采用 EfficientViT 不仅参数量和浮点计算量高于 GhostNet，而且其平均精度均值也低于后者。引入 PP－LCNet 在参数量、浮点计算量和内存占用量方面与 GhostNet 较为接近，但其平均精度均值同样不及后者。结合上述分析得出，GhostNet模块的引入在确保模型低计算复杂度的同时，极大提升模型精度和鲁棒性，使其成为模型轻量化改进最理想的选择。

表 3 不同轻量化改进模型结果对比

Tab. 3 Comparison results of different lightweight improved models

模型	平均精度均值/%	浮点计算量	参数量	内存占用量/MB
ShuffleNetv2	72.0	1.9×10^{9}	8.50×10^{5}	2.0
MobileNetv3	74.6	2.3×10^{9}	1.38×10^{6}	3.0
EfficientViT	91.2	9.9×10^{9}	5.32×10^{6}	11.0
PP－LCNet	85.6	5.8×10^{9}	2.93×10^{6}	6.0
GhostNet	92.8	8.2×10^{9}	3.01×10^{6}	7.5

3.3 不同注意力机制改进对比

为证明引入 SA 注意力机制的性能最优，以轻量化改进模型为基础，分别引入传统的 CA(Coordinate attention)[29]、CBAM[18]和轻量的 ECA(Efficient channel attention)[1]、EMA(Efficient multi-scale attention)[29]、SimAM(Similarity-aware activation module)[29]等注意力机制，其中各注意力机制都添加在模型的相同位置进行对比试验。通过表 4 可以看出，相较于未引入注意力机制前的平均精度均值，引入 CBAM 和 SimAM 注意力机制平均精度均值均提升 0.2 个百分点，引入 SA 注意力机制则提升 0.5 个百分点，表现最佳。这是由于 SA 注意力通过其独特的通道分组与混洗操作，允许不同特征组之间的交互，使其更好地在病害与背景之间区分得到最优的效果。然而在引入 CA、ECA 和 EMA 注意力机制后平均精度均值则出现下降情况，EMA 注意力机制甚至降低 1.9 个百分点。这是因为它们在空间信息、通道建模或多尺度信息融合上存在不足，导致平均精度均值下降。由上述分析可知，SA 注意力机制在保持计算量基本不变情况下，提升了模型水稻病害检测的能力，并证明其相较其他注意力机制的优越性。

3.4 与其他目标检测模型对比

为评估改进模型 YOLO－RD 的性能，本文与主

表 4　不同注意力机制改进模型结果对比

Tab. 4　Comparison results of improved models with different attention mechanisms

模型	平均精度均值/%	浮点计算量	参数量	内存占用量/MB
	92.8	8.2×10^{9}	3.01×10^{6}	7.5
CA	92.7	8.4×10^{9}	3.78×10^{6}	7.7
CBAM	93.0	8.4×10^{9}	3.81×10^{6}	7.7
ECA	92.4	7.8×10^{9}	3.56×10^{6}	7.3
EMA	90.9	1.1×10^{10}	3.71×10^{6}	7.5
SimAM	93.0	8.2×10^{9}	3.69×10^{6}	7.5
SA	93.3	8.2×10^{9}	3.69×10^{6}	7.5

流的目标检测模型进行对比试验，同时从便于在边缘计算设备部署的角度，YOLO 系列都是选择其内存占用量最轻量版本进行对比，分别为 Faster R－CNN[15]、SSD[15]、YOLO v5n[21]、YOLO v6n[30]、YOLO v7－tiny[31]、YOLO v8n[20]、YOLO v9t[32]、YOLO v10n[32]和 YOLO 11n[32]，它们在检测平均精度均值、参数量、内存占用量以及推理时间等方面表现如表 5 所示。YOLO－RD 模型平均精度均值表现最为优异，平均精度均值达到 94.2%，比 YOLO 5n 的 87.7%高 6.5 个百分点，相比最新的 YOLO 11n 则高 21.5 个百分点。此外，YOLO－RD 与传统的目标检测模型对比也有优势，比 Faster R－CNN 平均精度均值高 26.7 个百分点，比 SSD 的平均精度均值高 64.5 个百分点，说明其在复杂环境下的检测优势。YOLO－RD 的参数量为 3.99×10^{6}，比 YOLO v7－tiny 少 33.7%，比 YOLO v6n 少 13.8%，大幅减轻计算负担。YOLO v8n 的推理时间最快，仅需 5.40 ms，而 YOLO－RD 的推理时间为 13.24 ms，但其可在精度上弥补这一劣势，在准确性和实时性之间取得较好的平衡。相比之下，虽然 YOLO v10n 的推理时间为 9.40 ms，但其检测平均精度均值仅为 82.8%，表明其在实际复杂场景中适用性不足。通过对比试验结果可以看出，YOLO－RD 模型在复杂背景和光照条件下，凭借其优异的检测精度和合理的计算资源需求，更适于边缘计算设备的部署。

表 5　与其他目标检测模型检测性能对比

Tab. 5　Comparison of detection performance with other object detection models

模型	平均精度均值/%	浮点计算量	参数量	内存占用量/MB	推理时间/ms
Faster R－CNN	67.5	1.2×10^{11}	4.11×10^{7}	315.1	20.62
SSD	29.7	1.5×10^{10}	1.34×10^{7}	103.9	9.30
YOLO v5n	87.7	4.2×10^{9}	1.77×10^{6}	3.7	6.70
YOLO v6n	73.7	1.1×10^{10}	4.63×10^{6}	9.9	6.88
YOLO v7－tiny	79.1	1.3×10^{10}	6.02×10^{6}	11.7	5.81
YOLO v8n	81.5	8.2×10^{9}	3.01×10^{6}	6.0	5.40
YOLO v9t	72.7	1.1×10^{10}	2.62×10^{6}	5.8	48.50
YOLO v10n	82.8	8.2×10^{9}	2.70×10^{6}	5.5	9.40
YOLO 11n	72.7	6.3×10^{9}	2.58×10^{6}	5.3	8.40
YOLO－RD	94.2	8.9×10^{9}	3.99×10^{6}	8.1	13.24

3.5　检测结果

为检验 YOLO－RD 模型对不同水稻病害类别检测的性能，根据模型检测结果进行分析。如表 6 所示，YOLO－RD 对这 4 种水稻病害检测平均精度均值分别为 94.3%（纹枯病）、87.2%（叶瘟病）、96.2%（穗瘟病）、99.3%（稻曲病）。对稻曲病的检测平均精度均值最高，表明该模型能够准确捕捉稻曲病的关键特征，漏检和误检率极低。而对叶瘟病则略差，这是由于叶瘟病的病斑通常分布在窄长的叶片上，特征尺寸小且不规则，颜色特征不唯一，使得叶瘟病检测变得更加困难。

表 6　不同水稻病害类别检测结果

Tab. 6　Detection results of different rice disease categories　%

类别	精确率	召回率	平均精度均值
纹枯病	96.4	89.6	94.3
叶瘟病	95.5	81.9	87.2
穗瘟病	95.9	92.5	96.2
稻曲病	98.7	98.0	99.3

为更加直观地展示本文模型检测效果，采用 YOLO－RD 的检测图与 Grad－CAM（Gradient-weighted class activation mapping）热力图对不同病害的检测结果进行可视化。由图 8b 可以观察到，YOLO－RD 模型能够精准地识别出水稻病害的病变区域，尤其是在纹枯病、穗瘟病和稻曲病的检测中，检测边界框覆盖所有显著的病斑，表明模型的高检测精度。由图 8c 所示，Grad－CAM 热力图则展示模型对不同病害特征的关注度，其中颜色越红代表模型越关注的部分。稻曲病的热力图集中在病斑核心区域，说明模型提取到关键的病害特征。而在叶瘟病的检测中，尽管模型也能够捕捉到大部分病斑，但热力图显示部分细微病斑的关注度还有欠缺，表明模型在处理该类病害时仍有改进空间。YOLO－RD 模型对不同病害的检测表现优异，能够在大多数场景下准确检测病斑并定位病害特征区域，但对于一些复杂且细微的病斑特征仍需进一步优化。

3.6　边缘计算设备模型部署及装置性能试验

为测试 YOLO－RD 在边缘计算设备上的检测性能，本文在树莓派 4B 边缘计算设备上部署并测试改进后的模型效果。选用 880 幅水稻病害图像展开测试，测试结果为 YOLO－RD 在树莓派 4B 上的

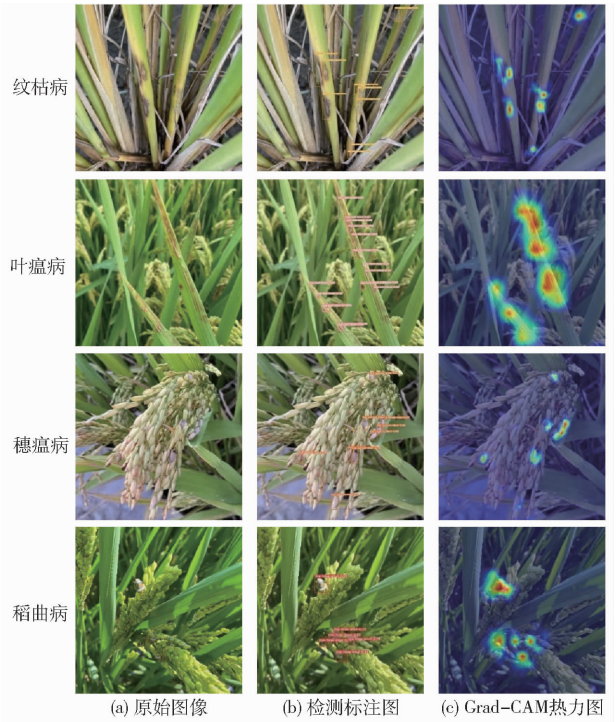

图 8 YOLO－RD 模型检测可视化结果

Fig. 8 Visualization of detection results of YOLO－RD model

单幅图像推理时间为 1.97 s，稍高于 YOLO v5s 的 1.19 s，但检测平均精度均值仍保持较高水平，为 96.8%，接近 YOLO v5s 的 97.3%，体现 YOLO－RD 模型在计算性能和检测平均精度均值上达到很好的平衡，符合实际水稻病害检测性能要求。

为验证边缘计算设备部署模型后的实际检测效果，开展检测装置结构与田间试验，如图 9 所示。首先，将改进后的模型部署于基于 PyQT 设计的可视化界面中。其次，配置边缘计算设备的运行环境，以确保其与模型的适配性。随后，边缘计算设备与供电模块、图像采集模块及显示模块进行集成，并装配至检测装置上，最终实现模型的本地化部署。并通过装置结构试验，可折叠采集杆能顺畅折叠与展开，其中完全展开后长度可达 320 mm，满足田间检测需求。该装置于 2024 年 9 月在浙江省湖州市南浔区的试验田中进行田间试验，效果如图 10 所示。可以看出，本装置能够准确检测出水稻病害同时提供相应防治建议，验证其在实际环境中能提供可靠的水稻病害检测。



图 9 边缘计算设备模型部署及装置试验流程图

Fig. 9 Flowchart of model deployment on edge computing devices and device experiment



图 10 检测结果

Fig. 10 Detection results

4 结论

(1)在 YOLO v5s 基础上进行改进，首先，引入 GhostNet 以减少计算量和参数量，其次，加入轻量级注意力机制 Shuffle Attention 增强特征提取能力，并通过 DyHead 实现自适应检测头调整。最后，使用 Shape－IoU 替代 CIoU，提升了模型在复杂水稻病害图像中的表现。结果显示，YOLO－RD 模型相较于原模型，平均精度均值仅降低 1.2 个百分点，但计算量、参数量和内存占用量分别减少 44.4%、43.2% 和 41.3%。

(2)与主流目标检测模型 Faster R－CNN、SSD、YOLO v5n、YOLO v6n、YOLO v7－Tiny、YOLO v8n、YOLO v9t、YOLO v10n 和 YOLO 11n 等模型对比，YOLO－RD 平均精度均值均优于这些模型，并在计算量、参数量、内存占用量等轻量化方面表现出明显优势，证明该模型在保证检测平均精度均值的同时，提升了检测效率，适用于自然环境下的水稻病害检测。

(3)YOLO－RD 模型成功部署至树莓派 4B 边缘计算设备，单幅图像的推理时间为 1.97 s，部署的检测效果与原 YOLO v5s 相当。同时完成检测装置设计与试验，满足水稻病害检测的实际应用需求。

(4)提出的 YOLO－RD 模型在减少计算量和参数量的同时，保持了较高的检测精度，验证了其在自然环境中水稻病害检测的可行性和实用性。模型适用于边缘计算设备，为便携式水稻病害检测装置的研发提供参考方案。

参 考 文 献

[1] 袁培森,欧阳柳江,翟肇裕,等. 基于 MobileNetV3Small－ECA 的水稻病害轻量级识别研究[J]. 农业机械学报,2024,55(1):253－262.
YUAN Peisen, OUYANG Liujiang, ZHAI Zhaoyu, et al. Lightweight identification of rice diseases based on improved ECA and MobileNetV3Small[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(1): 253－262. (in Chinese)

[2] 赵春江. 农业知识智能服务技术综述[J]. 智慧农业(中英文),2023,5(2):126－148.
ZHAO Chunjiang. Agricultural knowledge intelligent service technology: a review[J]. Smart Agriculture, 2023, 5(2): 126－148. (in Chinese)

[3] 毛瑞清,唐启源,黄益国,等. 不同生态点和播期对再生稻生育期、产量和纹枯病的影响[J]. 江苏农业科学,2024,52(14):107－113.
MAO Ruiqing, TANG Qiyuan, HUANG Yiguo, et al. Influences of different ecological sites and sowing dates on growth period, yield and sheath blight of retooning rice[J]. Jiangsu Agricultural Sciences, 2024, 52(14): 107－113. (in Chinese)

[4] CHAKRABARTY A, AHMED T S, ISLAM U F M, et al. An interpretable fusion model integrating lightweight CNN and transformer architectures for rice leaf disease identification[J]. Ecological Informatics, 2024, 82:102718.

[5] 李婷,任萍,马锐,等. 木霉复合菌剂与拮抗性腐熟堆肥对水稻生长及稻瘟病的防控研究[J]. 中国土壤与肥料,2023(6):219－224.
LI Ting, REN Ping, MA Rui, et al. Study on rice growth and biocontrol of rice blast by Trichoderma-containing microbial complex inoculants and compost with antagonistic effects[J]. Soil and Fertilizer Sciences in China, 2023(6):219－224. (in Chinese)

[6] SHARMA P, KHADKA B R, BAIDYA S. Evaluation of fungicides to manage rice false smut (*Ustilaginoidea virens*) in the hills of Nepal[J]. Heliyon, 2024, 10(14): e34151.

[7] 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.

[8] 张领先,韩梦瑶,丁俊琦,等. 作物病害智能诊断与处方推荐技术研究进展[J]. 农业机械学报,2023,54(6):1－18.
ZHANG Lingxian, HAN Mengyao, DING Junqi, et al. Research progress in intelligent diagnosis and prescription recommendation of crop diseases[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(6): 1－18. (in Chinese)

[9] 杨宁,程巍,张钊源,等. 基于 FPGA 加速的 Mask R－CNN 稻瘟病高通量自适应识别模型研究[J]. 农业机械学报,2024,55(7):298－304,314.
YANG Ning, CHENG Wei, ZHANG Zhaoyuan, et al. Research on high-througput adaptive recognition Mask R－CNN model for rice blast disease based on FPGA acceleration[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(7): 298－304,314. (in Chinese)

[10] AHAD M T, LI Y, SONG B, et al. Comparison of CNN-based deep learning architectures for rice diseases classification[J]. Artificial Intelligence in Agriculture, 2023, 9: 22－35.

[11] MATIN M M, KHATUN A, MOAZZAM M G, et al. An efficient disease detection technique of rice leaf using AlexNet[J]. Journal of Computer and Communications, 2020, 8(12): 49－57.

[12] 金婷婷,房建东,赵于东. 注意力特征融合的番茄叶部早期病斑诊断算法[J]. 电子测量技术,2024,47(4):156－164.
JIN Tingting, FANG Jiandong, ZHAO Yudong. Early lesion diagnosis algorithm of tomato leaf based on attention feature fusion [J]. Electronic Measurement Technology, 2024, 47(4): 156－164. (in Chinese)

[13] 侯琛,牛培宇. 农业知识图谱技术研究现状与展望[J]. 农业机械学报,2024,55(6):1－17.
HOU Chen, NIU Peiyu. Review of research status and prospects of agricultural knowledge graphs[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(6): 1－17. (in Chinese)

[14] 温艳兰,陈友鹏,王克强,等. 基于机器视觉的病虫害检测综述[J]. 中国粮油学报,2022,37(10):271－279.
WEN Yanlan, CHEN Youpeng, WANG Keqiang, et al. An overview of plant diseases and insect pests detection based on machine vision[J]. Journal of the Chinese Cereals and Oils Association, 2022, 37(10): 271－279. (in Chinese)

[15] HARUNA Y, QIN S, MBYAMM KIKI M J. An improved approach to detection of rice leaf disease with gan-based data augmentation pipeline[J]. Applied Sciences, 2023, 13(3): 1346.

[16] LI J, LIU Y, LI C, et al. Pineapple detection with YOLO v7－Tiny network model improved via pruning and a lightweight backbone sub-network[J]. Remote Sensing, 2024, 16(15): 2805.

[17] HONG Q, JIANG L, ZHANG Z, et al. A lightweight model for wheat ear fusarium head blight detection based on RGB images [J]. Remote Sensing, 2022, 14(14): 3481.

[18] LIN J, YU D, PAN R, et al. Improved YOLO X-Tiny network for detection of tobacco brown spot disease[J]. Frontiers in Plant Science, 2023, 14: 1135105.

[19] 廖娟,刘凯旋,杨玉青,等. 基于 RDN－YOLO 的自然环境下水稻病害识别模型研究[J]. 农业机械学报,2024,55(8):

233 – 242.
LIAO Juan, LIU Kaixuan, YANG Yuqing, et al. Rice disease recognition in natural environment based on RDN – YOLO[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(8): 233 – 242. (in Chinese)
[20] 马超伟,张浩,马新明,等. 基于改进 YOLO v8 的轻量化小麦病害检测方法[J]. 农业工程学报,2024,40(5):187 – 195.
MA Chaowei, ZHANG Hao, MA Xinming, et al. Method for the lightweight detection of wheat disease using improved YOLO v8[J]. Transactions of the CSAE, 2024, 40(5): 187 – 195. (in Chinese)
[21] SUN J, YOU J, LI F, et al. Research on improvement strategies for a lightweight multi-object weed detection network based on YOLO v5[J]. Crop Protection, 2024, 186: 106912.
[22] 顾文娟,魏金,阴艳超,等. 基于改进 DeepLabv3 + 的番茄图像多类别分割方法[J]. 农业机械学报,2023,54(12):261 – 271.
GU Wenjuan, WEI Jin, YIN Yanchao, et al. Multi-category segmentation method of tomato image based on improved DeepLabv3 + [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(12): 261 – 271. (in Chinese)
[23] 赵永杰,蒲六如,宋磊,等. 基于 Shuffle – ZoeDepth 单目深度估计的苗期玉米株高测量方法[J]. 农业机械学报,2024,55(5):235 – 243,253.
ZHAO Yongjie, PU Liuru, SONG Lei, et al. Measurement method of seedling stage maize height based on Shuffle – ZoeDepth monocular depth estimation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(5): 235 – 243, 253. (in Chinese)
[24] SHEN X, ZHANG C, LIU K, et al. A lightweight network for improving wheat ears detection and counting based on YOLO v5s [J]. Frontiers in Plant Science, 2023, 14: 1289726.
[25] ZHANG H, ZHANG S. Shape – IoU: more accurate metric considering bounding box shape and scale[J/OL]. ArXiv, (2023 – 12 – 29)[2024 – 10 – 24]. https://arxiv.org/abs/2312.17663.
[26] ZHOU H, CHEN J, NIU X, et al. Identification of leaf diseases in field crops based on improved ShuffleNetV2[J]. Frontiers in Plant Science, 2024, 15: 1342123.
[27] JIAO Z, DONG H, DIAO N. Separable CenterNet detection network based on MobileNetV3—an optimization approach for small-object and occlusion issues[J]. Mathematics, 2024, 12(16): 2524.
[28] YUAN Q, ZOU S, WANG H, et al. A lightweight pine wilt disease detection method based on vision transformer-enhanced YOLO[J]. Forests, 2024, 15(6): 1050.
[29] JING J, ZHANG S, SUN H, et al. YOLO – PEM: a lightweight detection method for young "Okubo" peaches in complex orchard environments[J]. Agronomy, 2024, 14(8): 1757.
[30] 许德刚,王再庆,邢奎杰,等. 改进 YOLO v6 的遥感图像目标检测算法[J]. 计算机工程与应用,2024,60(3):119 – 128.
XU Degang, WANG Zaiqing, XING Kuijie, et al. Remote sensing image target detection algorithm based on improved YOLO v6[J]. Computer Engineering and Applications, 2024, 60(3): 119 – 128. (in Chinese)
[31] 马中杰,罗晨,骆巍,等. 基于改进 YOLO v7 – tiny 的玉米种质资源雄穗检测方法[J]. 农业机械学报,2024,55(7):290 – 297.
MA Zhongjie, LUO Chen, LUO Wei, et al. Tassel detection method of maize germplasm resources based on improved YOLO v7 – tiny[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(7): 290 – 297. (in Chinese)
[32] KHANAM R, HUSSAIN M. YOLO v11: an overview of the key architectural enhancements[J/OL]. ArXiv, (2024 – 10 – 23)[2024 – 10 – 24]. https://arxiv.org/abs/2410.17725.