

doi:10.6041/j.issn.1000-1298.2026.10.026

基于 PDPI – YOLO 的辣椒病虫害识别算法

匡敏球^{1,2} 陈欣宇¹ 李晓坚¹ 邹学杰¹ 李旭^{1,3} 向阳¹ 陈崇林¹
吴艳华⁴ 邹湘军² 谢方平^{1,3}

(1. 湖南农业大学机电工程学院, 长沙 410128; 2. 佛山市中科农业机器人与智慧农业创新研究院, 佛山 528251;
3. 智能农机装备湖南省重点实验室, 长沙 410128; 4. 长沙县多莱农业科技有限公司, 长沙 410100)

摘要: 针对田间复杂环境下辣椒病虫害目标密集、尺度差异大以及现有检测模型部署难的问题,提出一种基于改进 YOLO 11n 的高效检测模型 PDPI – YOLO。以 YOLO 11n 为基础,采用 MobileNetV4 重构主干,强化对病虫害的多尺度特征提取;引入 SPPF_LSKA 模块融合大核注意力,增强全局上下文信息以提升对小尺度害虫的捕捉能力;利用 Dysample 动态上采样优化特征融合,提高对形态多变目标的定位精度;集成 EfficientHead 检测头,在保障速度的同时增强对密集和跨尺度目标的检测性能。对 Kaggle 上公开的 6 类常见辣椒病虫害公开数据集开展模型训练和检测试验。结果表明,改进后模型精确率、召回率、mAP50 和 mAP50 – 95 分别为 80.8%、75.7%、83.1% 和 43.5%,相比原模型分别提高 5.6、1.7、3.8、1.2 个百分点,将改进后模型部署至可视化用户界面中进行部署检测,单幅图像推理时间在 0.1 s 以内,满足实时检测的要求。结合自建的 2 种东山光皮辣椒病虫害数据集进行检测试验,单幅图像推理时间在 0.2 s 以内,表明模型具备一定的实时性、泛化性和鲁棒性。该模型为辣椒病虫害自动防控系统的构建及移动端智能植保装备的研发提供了技术支撑。

关键词: 辣椒; YOLO; 深度学习; 病虫害识别; 模型部署

中图分类号: S126 文献标识码: A 文章编号: 1000-1298(2026)10-0262-13 OSID: 

Pepper Disease and Pest Identification Algorithm Based on PDPI – YOLO

KUANG Minqiu^{1,2} CHEN Xinyu¹ LI Xiaojian¹ ZOU Xuejie¹ LI Xu^{1,3} XIANG Yang¹ CHEN Chonglin¹
WU Yanhua⁴ ZOU Xiangjun² XIE Fangping^{1,3}

(1. College of Mechanical and Electrical Engineering, Hunan Agricultural University, Changsha 410128, China
2. Foshan-Zhongke Innovation Research Institute of Intelligent Agriculture and Robotics, Foshan 528251, China
3. Hunan Province Key Laboratory of Intelligent Agricultural Machinery Equipment, Changsha 410128, China
4. Changsha Duolai Agricultural Science and Technology Co., Ltd., Changsha 410100, China)

Abstract: Accurate identification of pepper diseases and pests in complex field environments remains challenging due to dense target distributions, significant scale variations, and practical deployment constraints of existing detection models. To address these issues, PDPI – YOLO, a efficient detection model was proposed based on an enhanced YOLO 11n architecture. Firstly, the model reconstructed the feature extraction structure using MobileNetV4 as the backbone, leveraging its efficient inverted residual blocks and integrated attention mechanisms to enhance multi-scale feature representation. Secondly, the original SPPF module in the backbone was replaced by the SPPF_LSKA feature enhancement module. By integrating the large kernel attention (LSKA) mechanism, this module augmented global contextual information at the end of the backbone, providing superior top-level semantic inputs for the feature pyramid and thereby optimizing the efficacy of feature fusion within the pyramid structure. Furthermore, a dynamic upsampling operator (Dysample) was incorporated into the feature fusion process to adaptively enhance multi-level feature integration and localization accuracy. Finally, the EfficientHead optimized the detection head structure, ensuring high precision while handling dense and scale-varying targets.

收稿日期: 2025 – 10 – 29 修回日期: 2025 – 12 – 30
基金项目: 国家重点研发计划项目 (2022YFD2002003 – 3)、湖南省重点研发计划项目 (2025JK2028) 和湖南省研究生科研创新项目 (CX20251050)
作者简介: 匡敏球 (1998—), 男, 博士生, 主要从事农业智能感知与图像处理研究, E-mail: Kuang@stu.hunau.edu.cn
通信作者: 李旭 (1981—), 男, 副教授, 博士, 主要从事智能农业装备及其控制技术研究, E-mail: leexu@hunau.edu.cn

Experiments on a public Kaggle dataset of six common pepper diseases and pests showed that PDPI-YOLO achieved a precision of 80.8%, recall of 75.7%, mAP50 of 83.1%, and mAP50-95 of 43.5%, outperforming the baseline by 5.6, 1.7, 3.8, and 1.2 percentage points, respectively. When deployed in a visual interface, the model achieved inference times under 0.1 s per image, meeting real-time requirements. Validation on a self-built dataset of Dongshan smooth-skinned pepper further confirmed its generalization capability and robustness, with inference times below 0.2 s per image. This model can offer practical technical support for automated disease and pest monitoring systems and intelligent plant protection equipment in edge environments.

Key words: pepper; YOLO; deep learning; disease and pest identification; model deployment

0 引言

辣椒是我国重要的经济作物和蔬菜品种,种植规模与总产量均位居世界前列,在保障我国蔬菜供给、稳定市场价格和促进农业增收方面发挥着重要作用^[1-3]。辣椒在整个生育期内易受疫病、炭疽病、烟青虫和蚜虫等病虫害侵袭,影响辣椒的产量、品质与产业效益^[4-7]。因此,辣椒病虫害的快速准确识别与早期防控,对推动辣椒产业的绿色、智能和可持续发展具有重要意义。

传统病虫害识别方法高度依赖农业专家的目视诊断与经验判断,不仅耗时费力、主观性强,且易受观察者专业水平限制,难以实现大规模、标准化应用,尤其无法满足现代精准农业对病虫害实时监测与早期预警的需求^[8-9]。近年来,以卷积神经网络(CNN)和 Transformer 为代表的深度学习技术,在农业视觉感知任务中取得了显著进展^[10-12],YOLO、Faster R-CNN、SSD 等目标检测算法被广泛引入病虫害识别领域,展现出良好的应用前景。为克服田间环境复杂、病虫害特征微小及移动端部署资源受限等挑战,研究人员提出了多种基于深度学习的创新改进方案。一方面,针对实时检测与轻量化部署需求,部分研究致力于优化网络结构与降低计算复杂度,例如通过引入通道剪枝技术、结合轻量化网络(如 GoogLeNet)或引入无参注意力机制,在大幅减少模型参数数量的同时显著提升了推理速度与移动端检测效率^[13-16]。另一方面,面对病虫害形态复杂、区分度低及小目标遮挡等难题,学者广泛采用特征增强与多尺度融合策略,包括融合 ShuffleNetV2、GhostNetV2 等高效模块,以及引入动态加权注意力、A-down 下采样等机制,有效增强了模型对微小及遮挡目标的感知能力,在平衡效率的基础上显著提升了检测精度与召回率^[17-20]。此外,针对农业生产中的精细化管控需求,部分研究还构建了基于图像分割的病害分级识别模型或空地数据融合的立体监测系统,实现了对作物病害的高精度、全方位判定^[21-22]。

然而,光照变化、枝叶遮挡及背景干扰导致图像质量不一致,严重影响模型鲁棒性。其次,病虫害目标本身尺度差异大,且不同类别间形态、颜色特征相似,导致模型在精准区分与定位方面存在挑战^[23-25]。为此,本研究提出一种面向复杂田间环境的辣椒病虫害检测模型 PDPI-YOLO。基于 YOLO 11n 架构,通过引入优化的主干网络并改进多尺度特征增强模块,以增强模型对微小病虫害特征的感知与融合能力,从而实现更精准的识别精度。同时,采用动态上采样机制与高效检测头设计,以进一步提升模型对多尺度辣椒病虫害目标的识别性能。此外,基于该模型设计配套的图形用户界面系统,以期为田间辣椒病虫害智能诊断和植保装备研发提供技术支撑。

1 材料与方法

1.1 数据集构建与预处理

1.1.1 数据集构建

针对 6 类常见辣椒病虫害建立数据集,具体为绿桃蚜(*Myzus persicae* Sulz.)、银叶粉虱(*Bemisia tabaci*)、蓟马(*Thrips*)、棉铃虫(*Helicoverpa armigera*)、斜纹夜蛾(*Spodoptera litura*)和炭疽病(*Anthrax*),数据集由公开数据集和自制数据集组成,包含 6 类病虫害的特征与场景多样性。从 Kaggle 网站的公开数据集中选取涵盖绿桃蚜、银叶粉虱、蓟马、棉铃虫、斜纹夜蛾(<https://www.kaggle.com/datasets/indraagustian/red-chili-pepper-pests-dataset>)和炭疽病(<https://www.kaggle.com/datasets/prudhvi143413s/anthracnose-disease-in-chili-palnadu-ap>)的病虫害图像 5 486 幅,其中绿桃蚜、炭疽病、银叶粉虱和蓟马病斑大小差异显著,分别单独归为不同类别;而棉铃虫与斜纹夜蛾在病征形态上具有高度相似性,为避免模型混淆、提升检测性能,本研究在方法设计上将二者合并为一个检测类别。

针对辣椒病虫害易于夏季雨后发生的特点,自制数据集集中于暑期采集,采集地点为湖南省长

沙县多莱农业科技有限公司辣椒种植基地,采集设备为佳能 R50 型数码相机,拍摄时间集中在 07:00—09:00,采集数据过程避免人为移动叶片,维持辣椒叶片在自然环境下状态,确保数据贴近

真实种植环境,共采集 566 幅辣椒病害图像,主要为炭疽病和银叶粉虱,该部分数据集用于后期模型的泛化性验证。数据集部分辣椒病虫害图像如图 1 所示。




图 1 辣椒 6 种常见病虫害图像分类示例

Fig. 1 Example of image classification of six common pests and diseases of peppers

1.1.2 数据集预处理

采用的公共数据集中,前 5 类病虫害(绿桃蚜、银叶粉虱、蓟马、棉铃虫、斜纹夜蛾)图像共 4 994 幅,而炭疽病样本数量较少,仅为 492 幅。为提升模型泛化能力并缓解类别间分布不均衡问题,针对公共数据集中的炭疽病数据实施增强策略,通过采用

添加椒盐噪声、等比例缩放、随机平移、高斯噪声、高斯模糊、边缘强化、随机裁剪、随机填充、随机调整亮度和对比度的方式对数据集进行增强,以进一步确保数据样本充足和类别平衡。数据增强后的炭疽病图像示例如图 2 所示。

经过图像处理,最终构建的辣椒病虫害数据集




图 2 辣椒炭疽病病虫害数据集增强

Fig. 2 Augmented dataset on pepper anthracnose disease

总量为 7 454 幅图像。按照比例 8:1:1 将其划分为训练集 5 964 幅、验证集 745 幅与测试集 745 幅。此外,采用 X - Anylabeling 标注工具对全部有效图像进行精细化标注,清晰界定病害区域边界,为模型训练提供高质量的标签信息。

1.2 技术路线

技术路线如图 3 所示。在数据层面,构建 1 个由公共数据集与自制数据集组成的多源辣椒病虫害图像库,涵盖绿桃蚜、银叶粉虱、蓟马、棉铃虫、斜纹夜蛾及炭疽病 6 类典型病虫害。针对公共数据集中炭疽病数据样本较少,为缓解类别不均衡问题,采用椒盐噪声、高斯噪声、随机平移、高斯模糊、边缘强化、随机亮度与对比度调节等多种数据增强策略,以提升模型泛化能

力。在模型架构方面,基于 YOLO 11n 基准网络开展系统性改良:①运用 MobileNetV4 对主干网络进行重构,通过深度可分离卷积和注意力机制强化特征提取能力。②集成 SPPF_LSKA 模块,利用大核注意力机制优化多尺度特征融合。③引入动态上采样算子 Dysample 对特征融合过程加以改进,增强模型对多尺度目标的适应性。④设计高效检测头 EfficientHead,通过特征重加权机制优化计算资源分配。最终,通过模型量化压缩、热力图可视化分析以及 GUI 界面开发,达成从数据采集到田间部署应用的完整技术闭环,为农业植保领域提供高精度的智能检测方案。

1.3 辣椒病虫害识别模型

YOLO 11^[26]延续了 YOLO v8 的基础架构,在目




图 3 技术路线

Fig.3 Technological route

标检测能力上进行了多方面优化。该算法通过引入 C3k2 模块强化了特征提取过程,增强了对复杂环境下病虫害特征的判别能力。同时,在 SPPF 模块后融合了 C2PSA 注意力层,使模型能够更准确地聚焦于病虫害关键区域。在检测头部分采用深度可分离卷积重构类别分支,有效提升了计算效率。此外,模型通过动态平衡深度与宽度参数,在保持精度的同时提升了检测速度,更加适用于实时病虫害识别任务。

针对田间辣椒病虫害目标尺度差异大、特征相似性高以及现有模型计算负载重的问题,基于 YOLO 11n 提出轻量高效改进模型 PDPI-YOLO,主要围绕 4 个方面进行改进,如图 4 所示。采用改进的 MobileNetV4 替换原始主干,其深度可分离卷积与高效注意力机制显著增强复杂背景下病虫害特征的表征能力;设计 SPPF_LSKA 模块替代标准 SPPF,通过融合大核注意力机制增强主干末端的全局上下文信息,为特征金字塔提供更优质的顶层语义输入,




图 4 YOLO 11n 和改进 YOLO 11n 网络结构

Fig.4 Network architecture of YOLO 11n and improved YOLO 11n model

从而优化金字塔结构的特征融合效能,提升对小尺度病斑及虫体的特征捕捉精度;引入 Dysample 算子改进解码过程,其内容感知特性精准恢复病虫害目标的边缘细节与形态特征,增强多尺度目标定位鲁棒性;采用参数自适应的 EfficientHead 重构检测头,通过动态特征重校准机制聚焦判别性区域,在降低计算复杂度的同时保障分类与定位精度。4 处改进形成“特征提取-上下文融合-定位优化-高效决策”的协同优化链路,有效提升模型在田间复杂环境中辣椒病虫害识别的泛化性与实用性。

1.3.1 MobileNetV4 主干网络

目标检测模型的性能很大程度取决于其主干网络的特征提取能力,本文采用改进的 MobileNetV4^[27] 架构替代 YOLO 11 的原始主干,从而构建 1 个兼具高效性与强表征能力的特征提取

器。改进的 MobileNetV4 主干中的 UIB (Universal Inverted Bottleneck) 网络结构如图 5 所示,该架构基于深度可分离卷积构建,在保持较高运行效率的同时,增强了模型对多尺度特征提取能力。通过优化宽度与深度比例并引入高效的瓶颈层,在资源受限条件下仍能维持信息流畅传递与层次化特征的有效构建。该主干网络还融合了增强型高效注意力机制,使模型能够自适应地聚焦于对判别辣椒病虫害病斑区域和虫体轮廓等目标更为关键的空间与通道特征。同时,通过引入优化的特征融合路径,模型能够在多尺度上有效结合浅层细节信息与深层语义信息,从而兼顾细小病斑边缘、虫害纹理等局部特征以及整体形态和类别等高阶表征。这些设计共同提升了主干网络在有限计算资源下的特征丰富度与判别能力。




图 5 MobileNetV4 主干中的 UIB 网络结构
Fig.5 UIB network architecture in MobileNetV4 backbone

将改进的 MobileNetV4 作为主干网络集成到 YOLO 11 框架中,为辣椒病虫害识别任务带来了多方面的针对性优势。首先,该主干网络所采用的高效架构设计,使其在保持较强特征提取能力的同时具备良好的计算效率,使得模型更适合部署在移动终端和无人机等田间应用边缘计算设备上,实现低功耗、实时田间巡检,满足农业场景对即时响应的迫切需求。其次,高效注意力机制与优化特征融合的协同作用,极大地提升了模型对辣椒叶片图像中细微、早期小目标病状和形态多变的小型虫害的感知与区分能力。该机制能够抑制土壤和杂草等复杂背景的干扰,同时强化对低对比度、模糊病斑区域或与叶片颜色相近虫体的特征响应。最后,改进主干网络增强的多尺度特征表示能力,确保了模型能够同时鲁棒地处理不同大小、处于不同生长阶段的病虫害目标,这对于辣椒植株从苗期到结果期可能出现的各类病虫害全景监测至关重要。因此,该改进在理论上为提升辣椒病虫害识别的精度、鲁棒性及实际部署可行性提供了强有力的架构支撑。

1.3.2 SPPF_LSKA

在改进的 MobileNetV4 主干网络提取的多层次特征基础上,进一步以创新的 SPPF_LSKA 模块替代标准 SPPF (Spatial pyramid pooling-fast) 结构,旨在显著增强模型对多尺度上下文信息的融合能力与对关键区域的聚焦能力。SPPF_LSKA 模块结构如图 6 所示,该模块的核心创新在于将大核空间注意力 (Large kernel spatial attention, LSKA) 机制深度融入空间金字塔池化框架。标准 SPPF 通过并行多分支池化操作有效捕获不同尺度的感受野信息,但其池化操作本身是固定且无差别的。SPPF_LSKA 则通过引入可学习的大核空间注意力机制,赋予模型在特征融合过程中动态感知并强化图像中对病虫害识别最具判别性空间区域的能力。LSKA 利用具有较大感受野的卷积核 (或等效操作) 生成空间注意力权重图,能够跨越局部区域,建模长距离依赖关系,精准定位如辣椒叶片上分散的病斑簇、虫害聚集区或具有诊断意义的局部纹理模式 (如霉层分布、坏死边缘)。




图 6 SPPF_LSKA 模块结构
Fig. 6 SPPF_LSKA module structure

将 SPPF_LSKA 模块集成于改进的 MobileNetV4-YOLO 11 架构中,为辣椒病虫害识别任务带来了关键的协同提升。首先,其强大的多尺度上下文融合与动态空间选择能力,可有效解决辣椒叶片图像中病虫害目标常面临的尺度多变性与空间分布复杂性问题。无论是单个细小的早期病斑、成片扩散的中期病症,还是形态各异的虫体分布,SPPF_LSKA 都能自适应地融合最相关的上下文信息并精确聚焦于目标核心区域,显著提升了模型对目标整体形态与局部细节关联性的理解。其次,该模块对复杂背景干扰与目标遮挡具有更强的鲁棒性。LSKA 机制能够有效抑制叶片纹理、水滴反光、土壤背景等无关噪声的响应,同时即使在叶片相互遮挡或病斑部分模糊的情况下,也能依据长距离上下文线索保持对关键病虫害区域的高置信度激活。最后,SPPF_LSKA 与改进的 MobileNetV4 主干网络形成的协同特征处理流,共同优化了从基础特征提取到高层语义融合的全过程,使得模型能够更精准地捕捉辣椒病虫害特有的、细微且多变的视觉模式,从而在理论上为提升识别的准确性、泛化性和在复杂田间环境下的稳定性提供了关键的架构支持。

1.3.3 Dysample 上采样

在特征解码与目标定位的关键阶段,采用创新的 Dysample^[28] (Dynamic upsampling) 模块替代传统的插值上采样操作,旨在解决上采样过程中特征细节丢失与空间信息恢复不精确的问题,从而提升小目标和边缘模糊目标的定位精度。Dysample 上采样过程如图 7(其中 H 表示特征图高度, W 表示特征图宽度, C 表示特征图通道数。采样点生成器根据高度和宽度方向上的采样步长 sH 与 sW ,并结合超参数 $2g$ 生成采样点集;随后,网格采样函数 (Grid-sample) 依据这些采样点对输入特征图 x 进行重采样,最终输出上采样后的特征张量 X' ,其维度由新的高度 H' 、宽度 W' 和通道数 C' 表示) 所示,该模块




图 7 Dysample 上采样过程
Fig. 7 Dysample upsampling process

核心在于其动态内容感知与自适应感受野特性,不同于静态的插值方法(如双线性或最近邻),Dysample 通过学习预测 1 组与输入特征内容相关的动态上采样核。这些核能够根据特征图中局部区域的语义内容(如病斑边缘、虫体轮廓、叶片纹理)和上下文信息,自适应地调整上采样操作的权重分布。同时,其设计通常结合可变形卷积的思想或轻量级子网络预测偏移量,使采样过程能够灵活地聚焦于对目标重建至关重要的非规则邻域信息,而非局限于固定网格位置。这种动态、内容驱动的上采样机制,可显著提升了特征图在分辨率提升过程中的细节保留能力与几何结构重建的准确性。

将 Dysample 模块集成到改进的 MobileNetV4 主干网络与 SPPF_LSKA 特征融合模块构成的框架中,为辣椒病虫害检测的定位精度带来了质的提升,尤其针对该类任务的关键挑战。其细节保留与边缘重建能力,对于精确刻画微小、早期且边缘模糊的辣椒病斑以及形态纤细、颜色与叶片相近的虫害轮廓至关重要。Dysample 能够有效抑制标准上采样造成的细节模糊和锯齿效应,生成更高保真度的特征图,确保检测头获取更清晰的目标边界信息。其次,其动态适应性与内容感知特性,赋予了模型在复杂叶片表面结构和背景干扰下,依然能精准恢复病虫害目标真实形状和大小的能力。模块能够自适应地“感知”病斑或虫体的固有形态及其与周围组织的边界关系,即使在目标部分被遮挡或与背景低对比度的情况下,也能引导特征重建过程聚焦于关键判别区域。最后,Dysample 与 SPPF_LSKA 模块提供的丰富多尺度上下文信息以及 MobileNetV4 主干提取的强判别性基础特征形成协同,共同优化了从低分辨率语义特征到高分辨率定位信息的解码过程,理论上为提升辣椒病虫害检测框的定位精度以及减少对小目标和模糊目标的漏检提供了关键的机制保障。

1.3.4 EfficientHead 检测头

作为目标检测流程的最终决策层,为充分发挥改进模块提取的丰富多尺度特征与高保真定位信息的潜力,采用 EfficientHead^[29] 检测头替代原始设计,

旨在通过动态参数机制与特征选择能力,提升对病虫害目标的分类与定位精度。EfficientHead 检测头结构如图 8 所示,该检测头摒弃了传统检测头中冗余的固定卷积堆叠,构建了参数高效共享的多层感知结构,增强了特征复用与表达能力。同时,其引入动态特征选择与重校准机制:通过嵌入轻量级的通道与空间注意力单元,使检测头能够依据输入特征的自适应重要性权重,动态调整不同特征通道及空间位置对最终分类与回归任务的贡献度。这种设计确保模型将有限的计算资源集中于最具判别性的特征维度,有效抑制无关噪声干扰,提升特征利用效率。




Fig.8 EfficientHead detection head structure

集成 EfficientHead 检测头至改进架构末端,为辣椒病虫害识别任务带来关键的精度与效率协同提升。首先,其动态特征重校准能力显著增强了对形态多样、尺度差异大的病虫害目标的判别鲁棒性。其能自适应地强化对病斑特异纹理或虫害关键部位的特征响应,弱化叶片背景、光照伪影等干扰,大幅提升小目标和相似病虫害类别的区分度。其次,检测头在结构设计上注重计算效率与性能的平衡,确保整个模型在资源受限的田间部署环境中仍能维持实时检测帧率,满足农业现场巡检的即时性需求。最终,EfficientHead 作为优化链路的终端决策单元,与 Dysample 恢复的精细空间信息、SPPF_LSKA 融合的全局上下文以及 MobileNetV4 提取的判别性基础特征深度协同,共同构建了从特征提取到目标解析全流程高效、精准的辣椒病虫害智能识别系统。

1.4 试验环境与评价指标

1.4.1 试验环境

模型训练与测试均在统一的高性能计算环境下完成,硬件配置采用 Intel® Core™ i5 - 13600KF CPU 和 NVIDIA GeForce RTX 3060 Ti (8 GB 显存)

显卡,软件环境为 Windows 11 企业版 64 位操作系统,开发环境基于 Python 3.8,在 PyCharm 社区版中使用 PyTorch 深度学习框架实现所有算法。为确保试验结果的可比性与可靠性,所有消融试验及性能分析均在此环境下进行,使用相同数据集和参数设置,以对比各模型性能差异及优化效果,训练参数如表 1 所示。

表 1 训练参数
Tab.1 Training parameters

参数	数值/型式
输入图像尺寸	640 × 640 × 3
优化器	SGD
优化器动量	0.937
优化器权重衰减系数	0.000 5
初始学习率	0.01
批次大小	16
Epoch	400

1.4.2 模型评价指标

采用精确率 (Precision, P)、召回率 (Recall, R)、平均精度均值 (mean Average Precision, mAP) 和模型参数量 (Parameters) 作为核心评价指标。其中,mAP50 的计算基于交并比 (Intersection over union, IoU) 阈值为 0.5 时各类别平均精度 (AP) 的均值,mAP50 - 95 的计算基于交并比阈值为 0.5 ~ 0.95 之间时各类别平均精度 (AP) 的均值。

2 结果与讨论

2.1 消融试验

消融试验是深度学习模型优化过程中的关键验证方法,通过系统性地移除或调整模型组件来评估各模块对整体性能的贡献^[30]。为检验提出的改进模块对模型性能的提升作用,设计了 4 组消融试验:将原始主干替换成 MobileNetV4 主干网络、SPPF_LSKA 模块替代标准 SPPF、Dysample 模块替代传统的插值上采样和引入 EfficientHead,分别用 A、B、C、D 表示。结果如表 2 所示。

由表 2 可知,基准模型精确率为 75.2%、召回率为 74.0%,mAP50 为 79.3%。单独引入 MobileNetV4 主干网络后,各项核心精度指标均获得显著提升,准确率提升 2.1 个百分点,mAP50 提升 1.6 个百分点,尽管参数量有所增长,但有效提升了模型的特征提取能力。在模型引入 MobileNetV4 主干网络的基础上集成 SPPF_LSKA 特征增强模块,模型的精确率、召回率和 mAP50 得到进一步优化,分别达到 78.4%、75.4% 和 81.8%,这表明该模块有效增强了多尺度特征的融合与表征能力。然而,此

表 2 PDPI-YOLO 消融试验结果

Tab. 2 PDPI-YOLO ablation experiment results

YOLO 11n	A	B	C	D	精确率/%	召回率/%	mAP50/%	mAP50-95/%	参数量
√	×	×	×	×	75.2	74.0	79.3	42.2	2.580×10^6
√	√	×	×	×	77.3	74.7	80.9	43.0	5.430×10^6
√	√	√	×	×	78.4	75.4	81.8	42.8	1.204×10^7
√	√	√	√	×	79.1	76.4	81.2	42.6	1.205×10^7
√	√	√	√	√	80.8	75.7	83.1	43.5	1.178×10^7

注：√表示使用该模块，×表示不使用该模块。

时模型参数量大幅增加,且对更为严格的综合指标 mAP50-95 的优化效果并不明显。当继续引入 Dysample 上采样模块后,精确率与召回率达到最大值,体现了其在提升目标定位精度方面的优势。最终,集成所有 4 个模块的完整 PDPI-YOLO 模型,在准确率、mAP50、mAP50-95 均达到峰值,尤其是 mAP50 提升至 83.1%,证明了各模块协同工作的最优成效。

进一步剖析各组合结果,SPPF_LSKA 的加入虽显著提升了模型精确率和召回率,但使参数量从 5.430×10^6 上升至 1.204×10^7 。而当最终的 EfficientHead 替换原有检测头后,完整模型在维持高精度的同时,参数量从 1.205×10^7 降至 1.178×10^7 ,表明 EfficientHead 通过优化结构设计成功实现了参数精简与计算资源的更高效配置,达成了“提高精度、减少参数”的效果。此外,从 mAP50-95 这一综合评判指标来看,4 个模块改进组合模型在所有配置中取得了最优效果,说明各创新模块的协同作用最终显著增强了模型在不同检测难度下的整体鲁棒性。综上所述,该消融试验不仅逐步验证了每个组件对提升检测精度的有效性,更重要的是,揭示了 PDPI-YOLO 通过模块化创新与系统集成,最终实现了精度提升与模型复杂度优化之间的最佳平衡。

2.1.1 替换不同主干网络消融试验

为系统探究不同主干网络替换对辣椒病虫害识别模型性能的影响,设计 4 组试验,将 YOLO 11n 模型主干网络分别替换为 StarNet、FasterNet 和 MobileNetV4 等主干网络,并与原始模型进行性能对比。结果如表 3 所示。

表 3 替换不同主干网络的模型性能

Tab. 3 Performance of models with different backbone networks

不同主干	精确率/%	召回率/%	mAP50/%	mAP50-95/%	参数量
原始主干	75.2	74.0	79.3	42.2	2.58×10^6
StarNet	72.2	70.2	74.5	39.5	1.94×10^6
FasterNet	76.2	73.9	77.4	42.4	3.90×10^6
MobileNetV4	77.3	74.7	80.9	43.0	5.45×10^6

由表 3 可知,将原始主干网络替换为 StarNet、FasterNet 及 MobileNetV4 后,模型性能呈现出显著差异。其中,MobileNetV4 主干网络在各评价指标均取得最优结果,其精确率、召回率、mAP50 和 mAP50-95 分别达到 77.3%、74.7%、80.9%、43.0%,均超越原始模型及其他对比主干。相比之下,FasterNet 在精确率略有提升,但召回率与 mAP50 表现不及原始模型,性能改善有限;而 StarNet 的引入则导致所有核心指标均出现明显下降,表明其特征提取能力与本任务适配度不佳。该对比结果充分验证了 MobileNetV4 作为主干网络在辣椒病虫害检测任务中的有效性,其独特的通用倒瓶颈与注意力机制能够更好地平衡特征表征能力与计算效率。

进一步分析 MobileNetV4 主干的卓越性能,其关键在于该网络架构的先进性。相较于其他主干网络,MobileNetV4 通过其精心设计的通用倒瓶颈块与高效的 Mobile MQA 注意力机制,实现了更强大的多尺度特征提取与融合能力。这在复杂田间环境下尤为重要,因辣椒病虫害目标尺度差异悬殊且常与背景混杂。MobileNetV4 召回率与 mAP50 分别提升 0.7、1.6 个百分点,直接反映了该网络对各类尺寸目标,尤其是易漏检的小尺度病斑或虫体,具备了更优异的捕捉能力与定位精度。同时,其在 mAP50-95 上的领先,进一步证明了模型整体检测性能的鲁棒性得到了增强。综上所述,该消融试验确证了引入 MobileNetV4 作为 PDPI-YOLO 模型主干网络的合理性与必要性,其为后续模块的优化奠定了高效且鲁棒的特征基础。

2.1.2 替换不同上采样模块消融试验

为系统探究不同上采样模块对辣椒病虫害识别模型性能的影响,设计 3 组试验,在替换 MobileNetV4 主干网络和改进 SPPF_LSKA 模块的基础上,将原始上采样模块分别替换为 CARAFE 和 Dysample,并与前期消融试验模型进行性能对比分析。结果如表 4 所示。

由表 4 可知,引入 CARAFE 机制使准确率提升

表 4 替换不同上采样模块的模型性能
Tab.4 Performance of models with different

添加不同上采样	oversampling modules				
	精确率/%	召回率/%	mAP50/%	mAP50 - 95/%	参数量
YOLO 11n + A + B	78.4	75.4	81.8	42.8	1.204×10^7
CARAFE	79.6	74.5	81.1	42.7	1.218×10^7
Dysample	79.1	76.4	81.2	42.6	1.205×10^7

1.2 个百分点,但召回率降低 0.9 个百分点,mAP50 同步下降 0.7 个百分点。相比之下,采用 Dysample 机制在保持准确率在提升 0.7 个百分点的同时,召回率提升 1 个百分点,体现了其增强目标捕获能力的优势。而 CARAFE 通过内容感知的特征重组提升特征表示质量,有助于降低误检,但可能削弱对小尺度目标的敏感性;Dysample 则通过动态上采样策略优化特征图的空间分辨率,更有效地保留细节信息,从而提升对困难样本的检测能力。尽管 2 种机制均带来特定指标的改善,但 Dysample 在维持精度平衡的同时实现召回率的显著提升,这对需要最小化漏检率的农业病虫害检测任务具有关键价值。试验结果验证了 Dysample 在模型优化中的综合优势。

2.1.3 替换不同检测头消融试验

为系统探究不同检测头模块对辣椒病虫害识别模型性能的影响,设计 3 组试验,在替换 MobileNetV4 主干网络、改进 SPPF_LSKA 模块和添加替换 Dysample 上采样模块,将原始检测头分别替换为 LADH、SEAMHead 和 EfficientHead 等不同检测头,并与前期消融试验模型进行性能对比分析。结果如表 5 所示。

表 5 替换不同检测头模块的模型性能
Tab.5 Performance of models with different

不同检测头	detection head modules				
	精确率/%	召回率/%	mAP50/%	mAP50 - 95/%	参数量
YOLO 11n + A + B + C	79.1	76.4	81.2	42.6	1.205×10^7
LADH	78.2	76.4	81.4	42.4	1.175×10^7
SEAMHead	79.2	75.7	82.3	43.0	1.196×10^7
EfficientHead	80.8	75.7	83.1	43.5	1.178×10^7

由表 5 可知,LADH 检测头在维持召回率为 76.4% 的同时,精确率有所下降,综合指标未见显著提升;SEAMHead 将精确率与 mAP50 分别提高至 79.2% 与 82.3%,但召回率降低 0.7 个百分点;EfficientHead 则实现了最优精确率(80.8%)与 mAP50(83.1%)、召回率(75.7%),并在 mAP50 - 95

取得最高值(43.5%),表明改进模块的有效性和优势。

不同检测头性能差异反映其结构设计效率。LADH 侧重于保持目标覆盖能力,但特征判别性不足;SEAMHead 通过注意力机制增强特征整合,提升类间区分度,却在一定程度上牺牲了召回率;EfficientHead 则通过优化计算资源分配与引入动态算子,在保持较高召回水平的同时显著提升分类与定位精度。其全面而均衡的性能表现,验证了该结构在复杂多尺度目标检测任务中的有效性与工程实用性,故被采纳为最终模型的检测头方案。

2.2 性能试验

为全面评估改进的 PDPI-YOLO 模型在辣椒病虫害识别识别中的综合表现,选取当前主流的目标检测算法进行对比试验,包括 YOLO v5n、YOLO v6n、YOLO v8n、YOLO v9t、YOLO v10n、YOLO 11n、YOLO 12n、YOLO 13n 和 PDPI-YOLO。所有模型在相同数据集和硬件平台进行训练与测试,参数配置保持完全一致。不同算法训练结果如表 6 所示。

表 6 不同检测算法训练结果
Tab.6 Training results of different detection algorithms

算法	精确率/%	召回率/%	mAP50/%	mAP50 - 95/%	参数量
YOLO v5n	75.8	65.3	75.7	39.4	2.500×10^6
YOLO v6n	76.7	74.2	77.3	40.5	4.230×10^6
YOLO v8n	76.6	72.0	77.1	40.8	3.010×10^6
YOLO v9t	77.7	74.8	79.5	41.8	1.970×10^6
YOLO v10n	72.3	70.3	76.3	41.4	2.700×10^6
YOLO 11n	75.2	74.0	79.3	42.2	2.580×10^7
YOLO 12n	72.7	70.4	74.6	39.9	2.510×10^7
YOLO 13n	75.0	74.5	78.9	42.2	2.450×10^7
PDPI-YOLO	80.8	75.7	83.1	43.5	1.178×10^7

表 6 为 PDPI-YOLO 与 YOLO 系列多个变体在相同数据集和试验设置下的训练结果。从 mAP50 来看,PDPI-YOLO 为 83.1%,明显优于 YOLO v5n(75.7%)、YOLO v8n(77.1%)、YOLO 12n(74.6%)以及 YOLO 13n(78.9%),提升均超 4 个百分点,体现出其在检测精度方面的显著优势。在更为严格的 mAP50 - 95 上,PDPI-YOLO 达到 43.5%,分别比 YOLO v5n、YOLO v6n、YOLO v9t 和 YOLO v10n 高 4.1、3.0、1.7、2.1 个百分点,说明该模型在高 IoU 阈值条件下具备更强的目标定位精度和鲁棒性,尤其在复杂场景中对目标边界的预测更加准确。此外,PDPI-YOLO 的参数量为 1.178×10^7 ,虽然高于 YOLO v5n、YOLO v6n 和 YOLO 13n 等所有对比模型,但从综合检测性能指标来看,PDPI-YOLO 的精确率、召回率、mAP50 和 mAP50 - 95 均高于其他 SOTA

模型, 相较基准模型 YOLO 11n 分别提升 5、6、1.7、3.8、1.2 个百分点, 表明其在追求高性能的同时, 仍维持了相对合理的模型参数量, 整体架构具有良好的实用性。

2.3 各模型可视化检测结果

目标检测模型的性能在较大程度上取决于高质量且多样化的训练数据。在设施农业环境中, 辣椒病虫害图像采集时常遭遇复杂光照、枝叶遮蔽、背景干扰等难题, 这致使原始样本数量受限、类别分布不均衡, 对模型的训练效果与泛化能力造成严重影响。为增强模型在真实场景中的鲁棒性, 基于公开的病虫害数据集、经数据增强策略扩充后的测试集, 以及自行采集的东山光皮辣椒病虫害图像数据集, 系统地开展 PDPI-YOLO 模型的可视化检测性能与泛化能力的对比分析。不同模型在各类病虫害识别任务中的可视化检测结果如图 9 (其中红色框标记为漏检的病虫害目标, 紫色框标记为误检的病虫害目标,

下同) 所示。

由图 9 可知, 在绿桃蚜、银叶粉虱和蓟马等微小目标病虫害识别中, 改进的 PDPI-YOLO 模型表现出更强的检测稳定性, 未出现明显漏检或误检; 而对比模型 (如 YOLO v5n、YOLO v9t、YOLO v10n、YOLO 11n、YOLO 13n 等) 普遍存在不同程度的漏检现象, YOLO v9t、YOLO v10n、YOLO 11n 和 YOLO 13n 等新一代模型虽整体检测能力提升, 但在颜色相近与结构复杂的条件下仍存在边界模糊、鲁棒性不足的问题。分析其原因, 上述 3 类害虫体型微小、纹理特征弱, 在遮挡与光照不均条件下易导致关键特征丢失、边界模糊, 从而引发传统模型的特征响应衰减。相比之下, PDPI-YOLO 通过优化特征提取结构, 增强了对低信噪比小目标的感知能力, 提升了检测完整性。对于棉铃虫与斜纹夜蛾等体型较大的害虫, 虽易于识别, 但 PDPI-YOLO 仍展现出更高的检测置信度与定位精度, 表明其特征判别能力得到进一




图 9 不同模型病虫害可视化识别效果

Fig.9 Visual identification performance for pests and diseases across different models

步强化。在炭疽病识别任务中,由于病斑区域在阴影条件下与背景在颜色和形态上高度相似,原始模型普遍出现误检现象;而 PDPI-YOLO 有效抑制了光照变化引入的噪声干扰,显著降低误报率,体现出更强的环境适应性与鲁棒性。

在自采的东山光皮辣椒病虫害数据集上的测试结果如图 10 所示,辣椒病虫害等目标在剧烈光照变化下易出现特征退化与边界模糊,导致多模型发生误检或漏检。由图 10 可知,YOLO 11n 在该数据集上对小目标存在相似性干扰敏感、特征区分能力不足的问题;而改进的 PDPI-YOLO 则在微小害虫识别上表现更优,漏检率明显降低。尽管 YOLO 11n 对炭疽病等较大病斑区域具备一定检测能力,但仍存在特征响应不完整导致的漏检现象。试验结果表明,现有主流模型虽在整体检测性能上有所提升,但在颜色相近、结构复杂或低对比度场景下仍面临边界定位不准、特征判别模糊等挑战。相比之下,PDPI-YOLO 在“光照变化+相似背景”双重干扰条件下展现出显著优势,能够准确识别嵌入叶片背景中的细长型害虫及与背景颜色相近的病斑区域,检测框更加紧凑,定位更为精确。该结果充分验证了所引入的轻量化主干、轻量化检测头与优化上采样结构在增强多尺度特征表达、提升小目标感知与抗干扰能力方面的有效性,为复杂农业环境下高鲁棒性视觉感知系统的构建提供了可靠的技术路径。




图 10 自建数据集可视化检测结果

Fig. 10 Visualisation of detection results for self-built dataset

2.4 辣椒病虫害热力图检测图像分析

为评估在复杂农业场景下 PDPI-YOLO 模型检测鲁棒性,选取涵盖密集种植与多变光照条件的辣椒病虫害图像,采用 GradCAM^[31-32] (Gradient-weighted class activation mapping) 方法生成各类病虫害识别热力图,以可视化方式分析模型的特征响应机制。由图 11 可知,YOLO 11n 在该条件下表现出显著的注意力分散现象,其激活区域广泛分布于背景纹理及非目标区域,受光照不均与复杂背景干扰明显,关键病害特征响应强度较弱。相比之下,




图 11 改进前后不同病虫害识别的可视化热力图检测效果

Fig. 11 Visual heatmap detection performance for identifying different pests and diseases before and after improvement

PDPI-YOLO 生成的热力图在绿桃蚜、银叶粉虱、炭疽病等多种典型病害上均呈现出高度集中的空间激活模式,显著聚焦于目标主体区域,且响应强度更高、边界更清晰。

PDPI-YOLO 在弱光、强光及部分遮挡等挑战性条件下仍保持稳定的特征定位能力,有效抑制了无关区域的噪声响应。该结果表明,所提优化策略增强了网络对判别性特征的选择性关注能力,提升了特征提取过程的空间一致性与语义敏感性。通过增强关键区域的响应增益并抑制背景干扰,PDPI-YOLO 显著提高了模型在复杂农业环境下的决策可靠性与泛化性能,验证了其在多变光照与复杂背景条件下具备更强的检测鲁棒性与环境适应性。

2.5 部署试验

为评估改进模型在实际应用场景中的部署效能,将 PDPI-YOLO 模型整合至基于 PyQt5 框架开发的图形用户界面 (GUI) 平台,以进行可视化部署测试,结果如图 12 所示。该平台不仅支持图像输入、模型推理和结果可视化功能,还允许用户同时加载改进前后的模型进行对比试验。通过该界面,用户能够直接利用摄像头实时采集辣椒病虫害图像或



图 12 PDPI-YOLO 模型的 GUI 可视化部署结果

Fig. 12 GUI visualisation of PDPI-YOLO model deployment results

上传本地存储的图像至系统中。一旦模型加载完成,即可迅速对病虫害目标进行检测与分类,并在界面上动态显示检测结果及每类目标的相关统计信息。

在 GUI 系统的测试过程中,针对部署后图像的检测结果显示,界面响应流畅,模型推理时间仅为 0.020 s,单幅图像推理时间均控制在 0.1 s 以内,确保了高效的目标检测和标注能力。此外,在使用自建的东山光皮辣椒数据集进行的部署检测试验中,模型处理单幅图像平均推理时间为 0.185 s,所有测试图像推理时间均未超过 0.2 s,表现出较高的鲁棒性和用户体验一致性,满足复杂环境下实时视觉引导的需求。

3 结论

(1)构建了一种高效的辣椒病虫害检测模型 PDPI-YOLO,通过系统性地集成 MobileNetV4 主干网络、SPPF_LSKA 特征增强模块、Dysample 动态上

采样算子及 EfficientHead 检测头,提升了模型在田间复杂环境下对多尺度、密集辣椒病虫害识别精度与效率。提出的 PDPI-YOLO 模型精确率、召回率、mAP50 和 mAP50-95 分别达到 80.8%、75.7%、83.1% 和 43.5%,较基准模型 YOLO 11n 分别提升 5.6、1.7、3.8、1.2 个百分点,验证了模型改进方案的有效性。

(2)通过 MobileNetV4 主干网络、SPPF_LSKA 特征增强模块、Dysample 动态上采样算子和 EfficientHead 检测头的系统集成,有效解决了复杂田间环境下病虫害目标尺度差异大、特征相似性高导致的检测难题,实现了感受野扩展、多尺度特征融合与计算效率的平衡优化。

(3)模型在公开数据集与自建东山光皮辣椒数据集上均保持稳定性能,单幅图像推理时间分别低于 0.1 s 和 0.2 s,兼具实时性、泛化性与鲁棒性,为田间移动端智能植保装备的研发提供了可靠的技术基础。

参 考 文 献

[1] 邹学校,胡博文,熊程,等. 中国辣椒育种 60 年回顾与展望[J]. 园艺学报, 2022, 49(10): 2099-2118.
ZOU Xuexiao, HU Bowen, XIONG Cheng, et al. Review and prospects of pepper breeding for the past 60 years in China[J]. Acta Horticulturae Sinica, 2022, 49(10): 2099-2118. (in Chinese)

[2] 匡敏球,李旭,陈楠,等. 基于改进 YOLOv8n 的轻量化辣椒花目标检测方法[J]. 农业工程学报, 2025, 41(12): 198-207.
KUANG Minqiu, LI Xu, CHEN Shang, et al. Lightweight chili flower target detection method based on improved YOLOv8n [J]. Transactions of the CSAE, 2025, 41(12): 198-207. (in Chinese)

[3] 李旭,刘青,匡敏球,等. 基于改进 YOLOX 的自然环境下辣椒果实检测方法[J]. 农业工程学报, 2024, 40(21): 119-126.
LI Xu, LIU Qing, KUANG Minqiu, et al. Detecting chili pepper fruits in a natural environment using improved YOLOX[J]. Transactions of the CSAE, 2024, 40(21): 119-126. (in Chinese)

[4] 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.

[5] LIU J, WANG X, CHEN Q. Intelligent deep learning architecture for precision vegetable disease detection advancing agricultural new quality productive forces[J]. Frontiers in Plant Science, 2025, 16: 1611865.

[6] 翟肇裕,曹益飞,徐焕良,等. 农作物病虫害识别关键技术研究综述[J]. 农业机械学报, 2021, 52(7): 1-18.
ZHAI Zhaoyu, CAO Yifei, XU Huanliang, et al. Review of key techniques for crop disease and pest detection[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(7): 1-18. (in Chinese)

[7] 李子涵,周省邦,赵戈,等. 基于卷积神经网络的农业病虫害识别研究综述[J]. 江苏农业科学, 2023, 51(7): 15-23.

[8] RAMALINGAM K, PAZHANIVELAN P, JAGADEESWARAN R, et al. YOLO deep learning algorithm for object detection in agriculture: a review[J]. Journal of Agricultural Engineering, 2024, 55(4): 1-15.

[9] CHAKRABARTY S, DEB C K, MARWAHA S, et al. Application of artificial intelligence in insect pest identification—a review[J]. Artificial Intelligence in Agriculture, 2026, 16(1): 44-61.

[10] LI X, PAN J, XIE F, et al. Fast and accurate green pepper detection in complex backgrounds via an improved YOLOv4-tiny model[J]. Computers and Electronics in Agriculture, 2021, 191: 106503.

[11] LIU X, ZHANG Q, MIN W, et al. Solutions and challenges in AI-based pest and disease recognition[J]. Computers and Electronics in Agriculture, 2025, 238: 110775.

[12] 朱惠斌,王明鹏,白丽珍,等. 基于视觉识别的玉米病虫害检测与精准变量喷药系统研究[J]. 农业机械学报, 2024, 55(增刊 2): 210-221.
ZHU Huibin, WANG Mingpeng, BAI Lizhen, et al. Maize pest and disease detection and precise variable spraying system based on visual recognition[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(Supp. 2): 210-221. (in Chinese)

[13] 李震,李佳盟,王楠,等. 基于轻量化改进模型的小麦白粉病检测装置研发[J]. 农业机械学报, 2023, 54(增刊 2): 314-322.

- LI Zhen, LI Jiameng, WANG Nan, et al. Development of detector for wheat powdery mildew based on lightweight improved deep learning model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(Supp. 2): 314–322. (in Chinese)
- [14] 彭红星, 何慧君, 高宗梅, 等. 基于改进 ShuffleNetV2 模型的荔枝病虫害识别方法[J]. 农业机械学报, 2022, 53(12): 290–300.
PENG Hongxing, HE Huijun, GAO Zongmei, et al. Litchi diseases and insect pests identification method based on improved ShuffleNetV2[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(12): 290–300. (in Chinese)
- [15] 吴六爱, 许雪珂. 基于改进 YOLOv10n 的轻量化番茄叶片病虫害检测方法[J]. 智慧农业(中英文), 2025, 7(1): 146–155.
WU Liucan, XU Xueke. Lightweight tomato leaf disease and pest detection method based on improved YOLOv10n[J]. Smart Agriculture, 2025, 7(1): 146–155. (in Chinese)
- [16] 戴敏, 孙文靖, 缪宏. 基于轻量化 CBAM-GoogleNet 的辣椒病虫害识别[J]. 中国农机化学报, 2025, 46(2): 224–229, 252.
DAI Min, SUN Wenjing, MIAO Hong. Identification of pepper pests and diseases based on lightweight CBAM-GoogleNet[J]. Journal of Chinese Agricultural Mechanization, 2025, 46(2): 224–229, 252. (in Chinese)
- [17] 杨锋, 姚晓通. 基于改进 YOLOv8 的小麦叶片病虫害检测轻量化模型[J]. 智慧农业(中英文), 2024, 6(1): 147–157.
YANG Feng, YAO Xiaotong. Lightweight wheat leaf diseases and pests detection model based on improved YOLOv8[J]. Smart Agriculture, 2024, 6(1): 147–157. (in Chinese)
- [18] 王春桃, 谢伟斌, 肖德琴. 基于 YOLO-SVP 的小尺寸蔬菜害虫检测模型研究[J]. 农业机械学报, 2026, 57(5): 364–372.
WANG Chuntao, XIE Weibin, XIAO Deqin. Detection model for small-sized vegetable pests based on YOLO-SVP[J]. Transactions of the Chinese Society for Agricultural Machinery, 2026, 57(5): 364–372. (in Chinese)
- [19] YUE X J, LI H F, SONG Q K, et al. YOLOv7-GCA: a lightweight and high-performance model for pepper disease detection[J]. Agronomy, 2024, 14(3): 618.
- [20] 李芳, 危疆树, 王玉超, 等. 基于改进 YOLOv8n 模型的辣椒病害检测方法[J]. 江苏农业科学, 2024, 52(13): 201–210.
- [21] 郭伟, 党梦佳, 贾箫, 等. 基于深度学习的小麦条锈病害等级识别[J]. 华南农业大学学报, 2023, 44(4): 604–612.
GUO Wei, DANG Mengjia, JIA Xiao, et al. Grade classification of wheat stripe rust disease based on deep learning[J]. Journal of South China Agricultural University, 2023, 44(4): 604–612. (in Chinese)
- [22] 闫云才, 郝硕亨, 高亚玲, 等. 基于空地多源信息的猕猴桃果园病虫害检测系统设计[J]. 农业机械学报, 2023, 54(增刊 2): 294–300.
YAN Yuncan, HAO Shuoheng, GAO Yaling, et al. Design of kiwifruit orchard disease and pest detection system based on aerial and ground multi-source information[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(Supp. 2): 294–300. (in Chinese)
- [23] SHOAIB M, SADEGHI-NIARAKI A, ALI F, et al. Leveraging deep learning for plant disease and pest detection: a comprehensive review and future directions[J]. Frontiers in Plant Science, 2025, 16: 1538163.
- [24] 许毓超, 吴茜, 张兵元, 等. 轻量级深度学习网络在农作物目标检测的应用进展[J]. 中国农机化学报, 2025, 46(3): 261–270.
XU Yuchao, WU Qian, ZHANG Bingyuan, et al. Review on lightweight deep learning networks for object detection in crops[J]. Journal of Chinese Agricultural Mechanization, 2025, 46(3): 261–270. (in Chinese)
- [25] 蒲攀, 刘勇, 张越, 等. 融合动态词典特征和 CBAM 的苹果病虫害命名实体识别方法[J]. 农业机械学报, 2024, 55(12): 333–343.
PU Pan, LIU Yong, ZHANG Yue, et al. Named entity recognition of apple diseases and pests based on dynamic dictionary features and CBAM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(12): 333–343. (in Chinese)
- [26] KHANAM R, HUSSAIN M. YOLO v11: an overview of the key architectural enhancements[J]. arXiv Preprint, arXiv:2410.17725, 2024.
- [27] QIN D, LEICHCNER C, DELAKIS M, et al. MobileNetV4: universal models for the mobile ecosystem[C]//European Conference on Computer Vision, 2024: 78–96.
- [28] LIU W, LU H, FU H, et al. Learning to upsample by learning to sample[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision, 2023: 6027–6037.
- [29] TAN M, PANG R, LE Q V. Efficientdet: scalable and efficient object detection[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 10781–10790.
- [30] KUANG M, XIE F, LIU D, et al. A refined YOLO v5n-based method for detecting pepper flower objects integrating transfer learning[J]. Applied Soft Computing, 2026, 188: 114400.
- [31] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-cam: visual explanations from deep networks via gradient-based localization[C]//Proceedings of the IEEE International Conference on Computer Vision, 2017: 618–626.
- [32] KUANG M, LI X, XIE F, et al. Advancements and prospects in key technologies for robotic pollination in greenhouse pepper breeding: a review[J]. Frontiers in Plant Science, 2026, 17: 1778541.