doi:10.6041/j.issn.1000-1298.2025.06.048

基于改进 YOLO v8n 的花生叶片病害检测方法

白　凯[1,2]　张玉杰[1,2]　苏邓文[1,2]　秦　涛[1,2]　彭志强[1,2]

(1. 油气钻采工程湖北省重点实验室(长江大学), 武汉 430100; 2. 长江大学计算机科学学院, 荆州 434023)

摘要: 针对花生叶片病害在复杂环境下相似特征难以准确识别的问题,提出一种基于改进 YOLO v8n 模型的检测算法 YOLO-ADM。首先,使用 ADown 模块代替部分 CBS 模块,降低下采样中的信息损失,减少了模型的参数量;其次,将可变形注意力(Deformable attention,DA)机制添加到 C2f 模块组成 C2f-DA 结构,替换了 SPPF 上层的 C2f 模块,使模型聚焦到花生叶片病害的特定区域,准确捕捉其特征;最后,设计了一种全新的多尺度特征融合网络 MFI Neck 代替了 YOLO v8n 原有的颈部网络,增强了模型对不同尺度特征的融合能力。通过在花生叶片病害数据集上进行实验,结果表明,改进算法的准确率、召回率、mAP@0.5 和 mAP@0.5:0.95 分别达到 92.3%、91.0%、95.6% 和 85.2%,相比原始的 YOLO v8n 分别提高 4.5、0.2、1.6、3.0 个百分点,且模型内存占用量减少 0.65 MB,参数量下降 3.70×10^5。本算法在保证模型轻量化的前提下提升了检测能力,能够有效满足复杂环境下花生叶片病害的识别需求,为叶片病害的检测和监控提供了技术参考。

关键词: 花生叶片病害; YOLO v8n; 目标检测; ADown; 可变形注意力

中图分类号: TP391　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)06-0518-09　　**OSID**:

Peanut Leaf Disease Detection Method Based on Improved YOLO v8n

BAI Kai[1,2]　ZHANG Yujie[1,2]　SU Dengwen[1,2]　QIN Tao[1,2]　PENG Zhiqiang[1,2]

(1. *Hubei Key Laboratory of Drilling and Production Engineering for Oil and Gas*, *Yangtze University*, *Wuhan* 430100, *China*
2. *School of Computer Science*, *Yangtze University*, *Jingzhou* 434023, *China*)

Abstract: Aiming to address the challenge of accurately identifying similar features of peanut leaf diseases in complex environments, an improved detection algorithm, YOLO-ADM, was proposed based on the YOLO v8n model. Firstly, the ADown module replaced part of the CBS module, reducing information loss during down sampling and decreasing the model's parameter count. Secondly, a deformable attention mechanism was integrated into the C2f module to form the C2f-DA structure, which replaced the C2f module in the upper layer of the SPPF. This modification enabled the model to focus on critical regions of peanut leaf diseases and effectively capture their distinguishing features. Finally, a novel multi-scale feature fusion network, termed MFI Neck, was designed to replace the original YOLO v8n neck network, enhancing the model's capacity for multi-scale feature fusion. Experimental results showed that the improved YOLO-ADM algorithm achieved precision of 92.3%, recall rate of 91.0%, mean average precision (mAP@0.5) of 95.6%, and mean average precision (mAP@0.5:0.95) of 85.2%. Compared with the original YOLO v8n model, these metrics were increased by 4.5, 0.2, 1.6, and 3.0 percentage points, respectively. This approach enhanced detection performance while maintaining model efficiency, effectively meeting the identification requirements of peanut leaf diseases in complex environments, and provided a reliable reference for the detection and monitoring of leaf diseases.

Key words: peanut leaf diseases; YOLO v8n; object detection; ADown; deformable attention

0　引言

花生与大豆、油菜籽、葵花籽、棉籽并列,是全球五大主要油籽作物之一,同时也是我国关键的油料和经济作物[1-2]。叶片病害是花生产量低和生长受损的主要原因之一,其影响花生光合作用,导致荚果

收稿日期: 2024-10-29　修回日期: 2024-12-30

基金项目: 中国高校产学研创新基金—新一代信息技术创新项目(2020ITA03012)和油气钻采工程湖北省重点实验室(长江大学)开放基金项目(YQZC202205)

作者简介: 白凯(1980—),男,副教授,博士,主要从事机器学习研究,E-mail: baikai@yangtzeu.edu.cn

成熟和物质积累受到严重干扰。早期识别和鉴定出花生叶片病害的种类对于遏制病害扩散、减少产量受损有着重要意义[3-6]。

近年来，深度学习技术在植物叶片病害识别领域得到了广泛的研究和应用[7-8]。通过结合机器学习与计算机视觉的先进算法，研究人员可以构建出智能化的病害检测系统，实现对农作物叶片病害的自动化识别与精准诊断。这不仅提高了农业生产的效率，还为精准农业提供了技术支持，大幅降低了人工检测的成本与误差[9]。在植物叶片病害分类的研究中，学者们持续探索新方法，以提升模型在病害识别中的准确性和鲁棒性[10-12]。在复杂的自然环境中，实现对植物叶片多种病害的精准检测是一项具有挑战性的任务。随着目标检测技术的不断发展[13]，相关算法对叶片病害的识别能力和定位能力持续得到提升[14-16]。尽管现有研究已经为植物叶片病害的识别和定位提供了多种方案，但在不同检测任务中，由于病害种类的多样性和田间场景的差异，常常面临不同的挑战。

目前，花生叶片病害的研究主要聚焦于病害分类任务。在实际应用场景中，花生叶片常常出现多种病害并发的现象，增加了病害检测任务的复杂性。尽管深度学习技术已在植物叶片病害识别领域取得了一定进展[17]，但在花生叶片病害目标检测方面，仍面临若干关键问题。首先，图像特征提取过程中，会导致细节特征的信息丢失，影响病害检测的准确性；其次，花生叶片的部分病害（如早斑病和晚斑病）相似程度较大，模型的特征注意范围不集中，难以区分相似病害；最后，在花生叶片病害任务中，存在较多遮挡目标，对残缺目标的检测面临较大挑战。

针对上述问题，本文构建一个花生叶片病害目标检测数据集，用于开展相关检测研究。YOLO v8 结合了多种实时目标检测器的优点，是一种兼顾速度和精度的单阶段目标检测模型，为使模型尽量轻量化，基于参数量最小的 YOLO v8n 进行改进，提出一种花生叶片病害检测算法 YOLO - ADM，通过引入 ADown 模块、可变形注意力机制和 MFI Neck 颈部网络，提高模型识别能力，以期为花生叶片病害的准确检测和监控提供技术支持。

1　数据收集和预处理

目前，用于花生叶片病害目标检测的公共数据集较为有限。AISHWARYA 等[18]在印度卡纳塔克邦田间拍摄了 3 059 幅原始图像，涵盖了早斑病、晚斑病、营养缺乏、锈病及早锈病 5 类常见花生叶片病害形态。SASMAL 等[19]用智能手机摄像头在印度西孟加拉邦的田间环境拍摄了 1 720 幅原始图像，包括叶斑病（早斑病和晚斑病）、链格孢叶斑病、锈病及莲座病 4 类病害形态。鉴于这两项研究提供的原始数据较为繁杂，本实验从中筛选出适合目标检测任务的图像，并结合网络资源，最终收集适用于花生叶片病害目标检测的图像 1 125 幅，包括花生早斑病 200 幅、晚斑病 269 幅、锈病 200 幅、链格孢叶斑病 371 幅以及莲座病 85 幅。花生叶片病害的形态特征如图 1 所示。



图 1　花生叶片病害形态特征

Fig. 1　Morphological characteristics of peanut leaf diseases

为了减少网络训练的显存和内存占用，统一图像比例，对原始图像进行等比例缩放，将图像宽度分辨率统一处理为 640 像素。然后使用 X - AnyLabeling 图像标注软件对花生病害图像进行标注，以 YOLO 格式构建花生叶片病害数据集标签。为了丰富样本数据集，模拟真实情况光线与设备限制的情况，通过镜像、旋转、高斯模糊、变亮、变暗的操作（图 2）对图像进行数据增强，增强后共有 5 625 幅图像。然后将增强后的数据集按比例 8∶1∶1 划分为训练集、验证集和测试集，数据集的划分如表 1 所示。

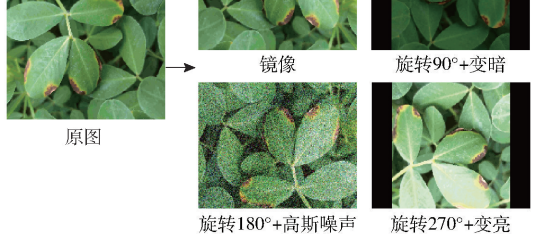

图 2　数据增强处理

Fig. 2　Data enhancement processing

表 1　数据集图像数量

Tab. 1　Number of images in dataset

花生病害	样本总数	训练集	验证集	测试集
早斑病	1 000	800	100	100
晚斑病	1 345	1 076	134	135
锈病	1 000	800	100	100
链格孢叶斑病	1 855	1 484	185	186
莲座病	425	340	42	43
总数	5 625	4 500	561	564

2　花生叶片病害识别模型设计

2.1　模型结构概述

YOLO v8 骨干网络采用改进 Darknet - 53 结构，

结合 C2f 模块,利用丰富的梯度流信息增强特征提取能力,能够精准捕捉花生叶片上细微且复杂的病害特征,颈部通过多尺度特征融合有效结合浅层与深层信息,头部采用高效的解耦结构,提升了分类和定位的精度[20]。根据不同的应用场景和需求,YOLO v8 提供了 n、s、l、m、x 共 5 个版本,其网络深度和宽度依次增加,检测精度逐渐提高。为保证算法的实时性和模型大小可控,满足资源受限设备(如移动设备、嵌入式系统等)的需求,本文选择参数量最小、推理速度最快的 YOLO v8n 作为基础模型进行改进。

虽然 YOLO v8n 已具有较好的目标检测性能,但在花生叶片病害的目标检测任务中,仍存在对相似目标及残缺目标检测不够精准的问题,为此,本文基于 YOLO v8n 进行改进,提出一个新的检测模型 YOLO - ADM。使用 ADown 代替部分 CBS 模块,保留更多的特征信息,减少模型的参数量;将可变形注意力机制引入到 C2f 模块组成 C2f - DA 结构,替换 SPPF 上层的 C2f 模块,增强了局部特征和全局上下文的交互能力;提出一种新的多尺度特征融合网络 MFI Neck,提高网络对残缺目标和相似病害的检测能力,为复杂背景下花生叶片病害的识别提供新方案。改进模型如图 3 所示。

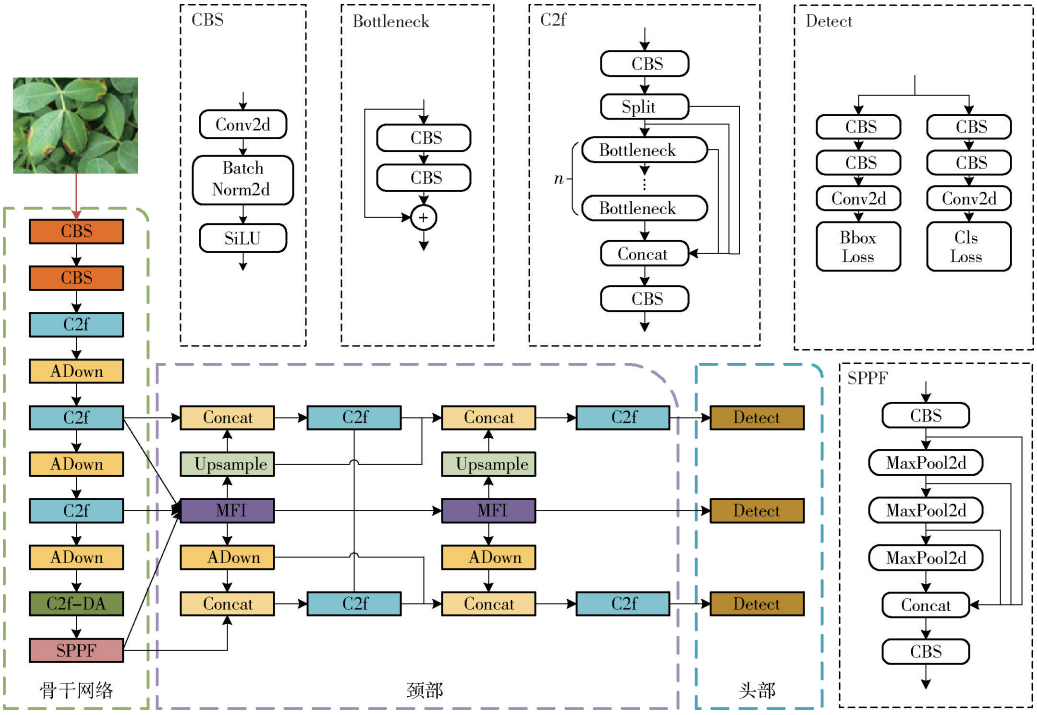

图 3 YOLO - ADM 整体网络结构图

Fig. 3 YOLO - ADM overall network structure diagram

2.2 ADown 模块

在花生叶片病害的真实检测场景中,病害目标与背景高度融合,且部分病害目标存在相似纹理特征的挑战,普通的 CBS 模块进行下采样时,可能忽略一些细微特征,导致特征提取不够完整。为了改善这一问题,本文引入 YOLO v9[21] 中 ADown 下采样模块,替换 YOLO v8 中部分 CBS 模块,实现了模型的进一步轻量化。如图 4 所示,ADown 模块通过结合平均池化和最大池化的并行操作,首先通过平均池化对输入特征进行下采样,保留关键特征信息。随后,将特征分为两路进行并行处理:一路通过 3×3 卷积进行特征提取,降低计算复杂度;另一路通过 3×3 最大池化获取更多特征信息,以弥补卷积操作可能导致的特征丢失,接着再进行 1×1 卷积。最终,通过拼接操作融合特征,在降低空间维度的同时

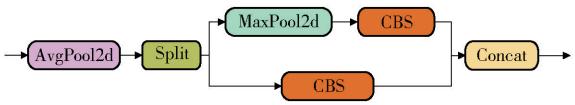

图 4 ADown 模块结构图

Fig. 4 ADown module structure diagram

保留更多有效信息,减少叶片小病斑在特征提取过程中可能丢失的细节信息。这一设计提升了模型在病害检测中的准确性和鲁棒性,尤其在病害目标与背景高度融合的情况下,仍能维持较高的检测精度。

2.3 C2f - DA 模块

在花生叶片病害识别任务中,伴随着诸多干扰因素,如健康叶片、土壤颗粒等,使得病害区域的精确识别更加复杂。由于病害的发病位置和形态各异,并且在不同图像中呈现出不同的尺度和占比,传统的目标检测模型在处理这类复杂的病害场景时容

易受到背景和非病害信息的干扰。为了增强模型对叶片病害特征的感知能力，同时减少背景干扰，在 YOLO v8 模型的 C2f 模块中引入了可变形注意力机制[22]。普通自注意力在处理图像时需要在全局范围内计算所有位置之间的相关性，这虽然能捕捉到全局上下文信息，但会导致计算量变大，不适合处理高分辨率的图像。并且，普通自注意力会同时考虑所有区域，容易受到复杂背景和噪声的干扰，无法有效地聚焦于病害目标区域。相比之下，可变形注意力机制是一种具备更高空间灵活性和效率的机制。它通过学习可变的注意力区域，动态调整每个位置的注意力权重，使得模型能够有选择性地聚焦于与任务相关的关键区域，而忽略无关的背景信息。通过引入可学习的偏移量，使得每个查询位置不再仅关注其固定邻域内的特征，而是通过自适应地选择在图像中具备更强语义相关性的区域。这样的机制能够有效减少无关区域的干扰，并且显著降低注意力计算的复杂度。可变形注意力的信息流如图 5 所示。

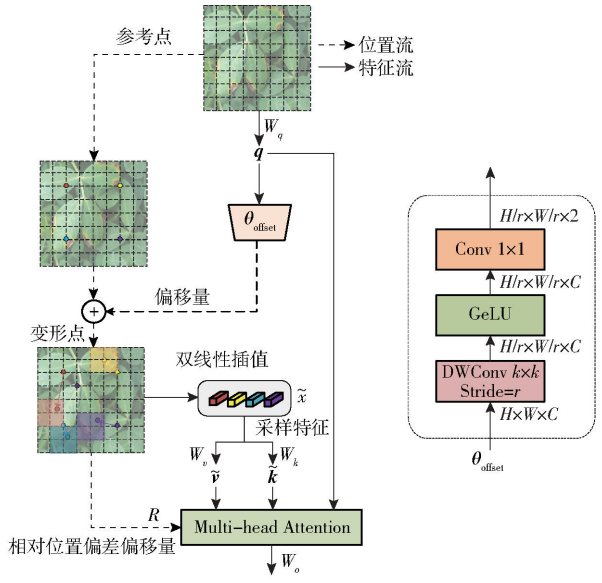

图 5　可变形注意力信息流程图

Fig. 5　Deformable attention information flow diagram

在可变形注意力机制中，输入特征图 $x\in R^{H\times W\times C}$ 首先被映射到一个均匀的参考网格。为了获取每个参考点的偏移量，输入特征图 x 会经过线性投影得到查询向量 $\boldsymbol{q}=xW_q$，通过一个轻量子网络 θ_{offset}，生成偏移量 Δp。

在获取每个参考点的偏移量后，特征图在变形点的位置上进行采样，作为键和值与查询向量一起传入多头注意力机制中。其中，采样函数通常被设计为双线性插值，使得采样过程是可微的，从而可以在网络中进行反向传播优化。

与现有的多头注意力方法类似，对 $\boldsymbol{q}$、$\boldsymbol{k}$、$\boldsymbol{v}$ 进行多头注意计算，并引入相对位置偏移 R，注意头的输出公式为

$$z^{(m)}=\sigma\left(\frac{\boldsymbol{q}^{(m)}\tilde{\boldsymbol{k}}^{(m)\mathrm{T}}}{\sqrt{d}}+\Phi(\hat{B};R)\right)\tilde{\boldsymbol{v}}^{(m)} \tag{1}$$

式中　σ——softmax 函数

$\tilde{\boldsymbol{k}}$、$\tilde{\boldsymbol{v}}$——变形后的键、值

d——键向量维度

$\hat{B}$——输入特征图或其变形形式

$\Phi(\hat{B};R)\in R^{HW\times H_GW_G}$ 表示位置嵌入，每个注意力头被拼接在一起，并通过 W_o 投影得到最终的输出 z。

如图 6 所示，将可变形注意力机制加在 C2f 中，组成 C2f－DA 模块，替换 SPPF 上方的 C2f 模块，通过动态调整注意力点的位置，提高了对不规则目标区域的关注能力，极大提升了模型在处理复杂空间特征时的表现。使模型更聚焦于图像中的重要区域，从而增强特征表示，提高检测精度。该模块可以有效减少背景噪声的影响，增强模型的鲁棒性。

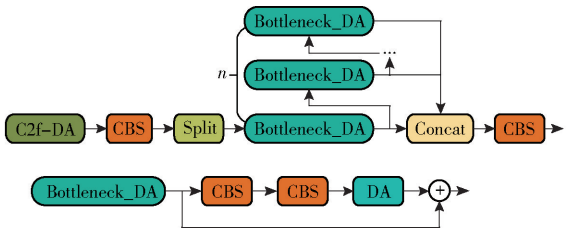

图 6　C2f－DA 模块结构图

Fig. 6　C2f－DA module structure diagram

2.4　MFI Neck

YOLO v8 的颈部网络负责融合来自不同层次的特征图。在花生叶片病害数据集中，存在大量的叶片缺失和遮挡重叠的情况，采用原有的 PAN－FPN 结构对不同特征的融合不足。针对上述问题，本文结合 PKI(Poly kernel inception module)结构[23]，构建了一种新的融合不同尺度的 MFI(Multi-scale features inception)模块。如图 7 所示，该模型可以同时接收 3 个不同尺度的特征信息，使用 ADown 对大尺度特征输入进行下采样，保留更多特征信息；对中尺度特征输入使用 1×1 卷积调整通道数；接收的小尺度输入，需要先进行上采样，使其特征尺度与其他两个输入保持一致，再进行 1×1 卷积调整通道数。然后通过 Concat 拼接 3 个尺度的信息，并利用 Inception-style 的并行深度卷积模式捕获多尺度信息，从而使每个尺度的特征都富含更多上下文信息，对并行深度卷积后的输出进行 1×1 卷积，压缩和融合由不同卷积核提取的多尺度特征，加强对真实特征的捕获能力，最后与 Concat 拼接的 3 个尺度原始特征进行相加，减少尺度融合导致的信息丢失。

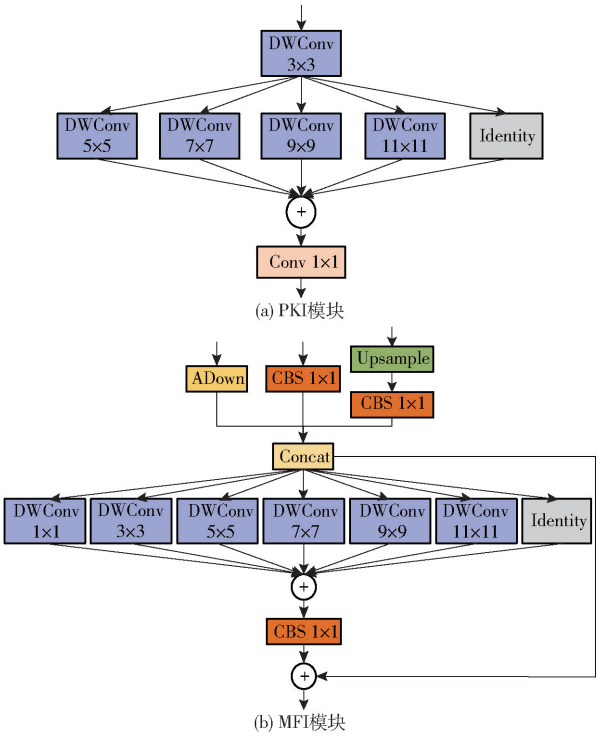

图 7 多尺度融合模块 MFI 结构图

Fig. 7 Multi-scale fusion module MFI structure diagrams

如图 8 所示,在颈部网络中,通过不同特征金字塔层(P3、P4、P5)的深度融合,利用了两个 MFI 模块对不同层的特征进行整合。这种设计在处理复杂场景和不同尺寸的目标时更加灵活,特别是在小目标检测上可能具备更好的效果。通过上下采样和特征拼接操作,模型有效结合了浅层和深层特征,进一步提升了对目标的定位和分类能力。相比之下,YOLO v8 虽然也采用了特征融合策略,但该模型的特征融合方式更加深入且多样化,能够更有效地整合不同层次和尺度的特征信息。这对于捕捉花生病害的局部特征,特别是缺失叶片和病害的早期症状,具有很大帮助,可以有效提高花生叶片病害检测的检测精度和鲁棒性。

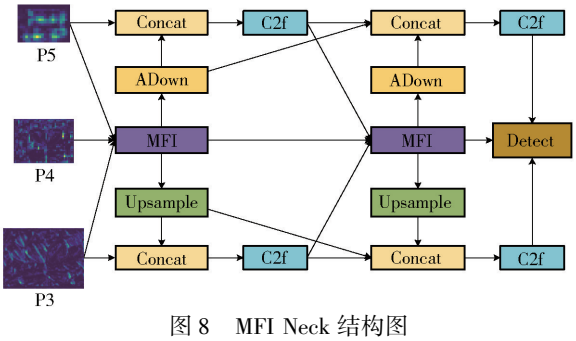

图 8 MFI Neck 结构图

Fig. 8 MFI Neck structure diagram

3 实验

3.1 实验环境配置与参数设置

实验在同一个实验平台上运行,处理器型号为 Intel i5 - 12490F,显卡型号为 NVIDIA GeForce RTX 2080ti,显存 11 GB,内存 32 GB,操作系统为 Ubuntu 22.04.3,环境为 Pytorch 2.3.1, Cuda 12.1, Python 3.10.12。图像输入尺寸为 640 像素 ×640 像素,批次大小为 16,训练轮次设为 300,初始学习率设为 0.01。

3.2 评价指标

采用精确率(Precision, P)、召回率(Recall, R)和平均精度均值(mean Average Precision, mAP)作为花生叶片病害识别的主要评价指标。其中,mAP 为每个类别的平均精度(Average precision, AP)的平均值,是衡量模型性能的关键标准。mAP 包括 mAP@0.5 和mAP@0.5:0.95, mAP@0.5 表示交并比(Intersection over union, IoU)即阈值为 0.5 时的平均精度均值,mAP@0.5:0.95 为 IoU 阈值从 0.5 到 0.95(步长为 0.05)范围内计算得到的平均值。

3.3 实验结果与分析

3.3.1 加入 ADown 对模型的影响

在目标检测模型中,主干网络负责提取图像特征,捕获图像中的纹理、边缘和更高层次的语义信息,不同的特征提取方式对目标检测模型的性能、效率和识别能力有着直接影响。本实验将 YOLO v8n 第 5 层和第 7 层的 CBS 模块替换为 ADown 模块,提高模型对原始图像提取能力,增强模型的识别能力。如图 9 所示,对模型第 5 层的特征图进行可视化分析,可以发现,ADown 模块能够更好地保留图像中的细节信息,尤其是在病斑的边缘和纹理区域,强化了对形状复杂、尺度多样的病斑特征的感知能力,同时有效降低了背景区域的干扰响应。这种改进优化了模型的目标识别能力和对复杂病害的检测性能,为精确农业中的病害诊断提供了更高效的方法支持。

如表 2 所示,使用 ADown 模块替换主干网络中的 CBS 模块后,模型识别能力增强,mAP@0.5 提高 0.3 个百分点,mAP@0.5:0.95 提升 0.8 个百分点,表明在骨干网络使用 ADown 模块可以提高模型的特征提取能力,适合花生叶片病害检测任务的特征提取场景。将 ADown 模块引入颈部网络后,模型性能变化不大,原因在于颈部网络主要负责高级特征提取和检测,需要更复杂的特征表示以支持目标检测任务[24]。同时,由于 ADown 模块的参数量较小,在骨干网络和颈部网络中同时引入,可以有效减少模型的参数量,提高模型检测效率。

3.3.2 注意力模块对比

注意力机制能够显著增强神经网络对任务目标

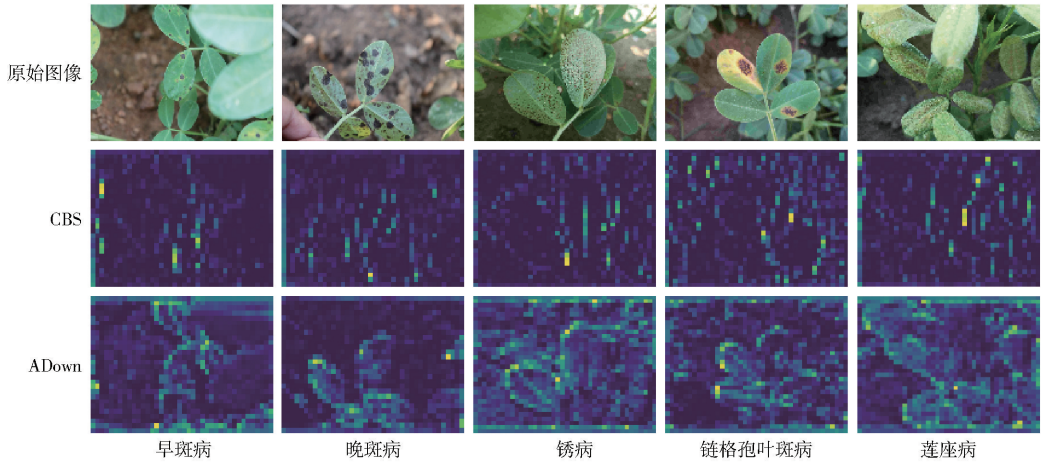

图 9　特征可视化结果

Fig. 9　Feature visualization result

表 2　ADown 对模型的影响

Tab. 2　Effect of ADown on model

位置	精确率/%	召回率/%	mAP@0.5/%	mAP@0.5:0.95/%	参数量
YOLO v8n	87.8	90.8	94.0	82.2	3.01×10^6
Backbone	90.2	90.8	94.3	83.0	2.73×10^6
Neck	90.3	89.7	94.0	82.1	2.88×10^6
Backbone + Neck	92.0	88.6	94.2	82.9	2.59×10^6

的识别能力。为深入分析不同注意力机制模块对网络模型性能的影响，对 CBAM（Convolutional block attention module）、SE（Sequeeze-and-excitation）、SimAM（Simple parameter-free attention module）、EMA（Efficient multi-scale attention）以及 DA 5 种注意力模块进行对比实验。将其分别添加到 C2f 模块中，替换 SPPF 上层的 C2f 模块。由表 3 可知，添加 CBAM、SE、EMA 均能在一定程度上提升模型的检测性能。然而，当引入可变形注意力机制后，模型在识别病害区域的表现上更加优异，在构建的花生叶片病害目标检测数据集中，精确率(89.8%)、召回率(90.1%)、mAP@0.5(94.6%)和 mAP@0.5:0.95(82.9%)相较原模型均有较大提升，这表明，与其他注意力机制相比，可变形注意力机制能够更有效地引导模型关注病害特征区域，减少对无关背景的干扰，从而提升整体的识别精度。

表 3　注意力机制对比实验结果

Tab. 3　Comparison results of attention mechanisms

%

注意力机制	精确率	召回率	mAP@0.5	mAP@0.5:0.95
CBAM	90.6	89.9	94.2	82.7
SE	90.4	89.0	94.1	82.2
SimAM	89.2	89.2	93.5	81.6
EMA	90.2	89.5	94.2	82.9
DA	89.8	90.1	94.6	82.9

3.3.3　颈部网络对比

颈部网络的主要功能是对主干网络提取的特征进行进一步处理和融合，以增强特征表达能力，从而提升模型对不同尺度目标的检测性能。选择合适的颈部网络能够有效应对小目标或缺损目标的检测挑战。为验证 MFI Neck 在花生叶片病害检测任务中的有效性，本文将其与常用的目标检测颈部网络（PAN－FPN、GFPN[25] 和 BiFPN）进行对比分析，实验结果如表 4 所示。由表 4 可知，采用 MFI Neck 能够显著提升检测性能，其中 mAP@0.5 提高 0.8 个百分点，mAP@0.5:0.95 提高 1.2 个百分点。结果表明，多尺度特征融合策略结合特征扩散机制，能够使每个尺度的特征包含更丰富的上下文信息，从而更加有利于目标的精确检测和分类。这一方法为提升目标检测任务的综合性能提供了有效途径，特别是在复杂场景下具有显著优势。

表 4　颈部网络对比实验结果

Tab. 4　Comparison results of neck network　%

颈部网络	精确率	召回率	mAP@0.5	mAP@0.5:0.95
PAN－FPN	87.8	90.8	94.0	82.2
GFPN	91.6	87.7	93.9	82.3
BiFPN	89.2	89.2	93.5	81.6
MFI Neck	90.0	90.6	94.8	83.4

3.3.4　消融实验

图 10 为改进模型 YOLO－ADM 与基线模型 YOLO v8n 在训练过程中的性能对比。结果表明，YOLO－ADM 在精确率和召回率方面均优于基线模型，并在不同 IoU 阈值下展现出更高的检测准确率。此外，YOLO－ADM 的训练曲线收敛性更好且更稳定，表明该算法在模型拟合过程中的鲁棒性更好，具有更优的识别性能。

为了进一步验证改进方法对模型整体性能的影

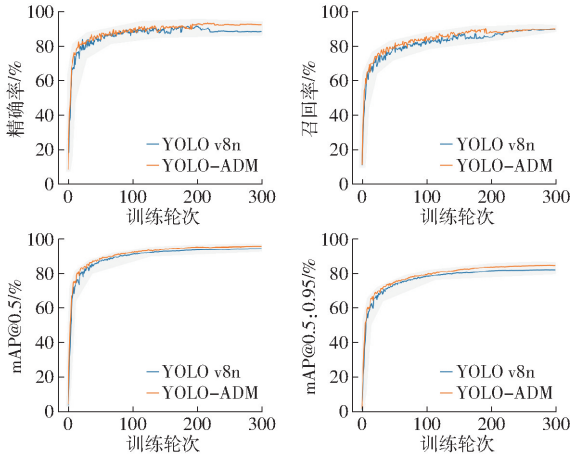

图 10 YOLO－ADM 和 YOLO v8n 结果对比

Fig. 10 Comparison chart of YOLO－ADM and YOLO v8n results

响,以 YOLO v8n 为基准进行消融实验,结果如表 5 所示。在 YOLO v8n 基础上分别加入改进模块 ADown、C2f－DA 和 MFI Neck 后,模型的精确率、mAP@0.5 和 mAP@0.5:0.95 均有所提升。为进一步验证改进效果,对 3 个模块进行两两组合,结果显示,组合后的性能较单一改进更佳,证明了改进的有效性。最后本研究算法将 ADown、C2f－DA、MFI Neck 集成在一起组成 YOLO－ADM 模型,综合考虑特征提取,多尺度融合的能力,结果表明,YOLO－ADM 比原有 YOLO v8n 的精确率提升 4.5 个百分点,召回率提升 0.2 个百分点,mAP@0.5 提升 1.6 个百分点,mAP@0.5:0.95 提升 3.0 个百分点。模型的浮点运算量虽略有提升,但由于采用 ADown 模块替换掉了大部分 CBS 模块,使模型内存占用量减少 0.65 MB,参数量减少 3.70×10^5。充分说明了本文算法在花生叶片病害特征识别和定位中的优越性。

表 5 消融实验结果

Tab. 5 Results of ablation experiments

模型	精确率/%	召回率/%	mAP@0.5/%	mAP@0.5:0.95/%	模型内存占用量/MB	参数量	浮点运算量
YOLO v8n	87.8	90.8	94.0	82.2	5.98	3.01×10^6	8.1×10^9
YOLO v8n + A	92.0	88.6	94.2	82.9	5.20	2.59×10^6	7.4×10^9
YOLO v8n + D	89.8	90.1	94.6	82.9	6.12	3.07×10^6	8.1×10^9
YOLO v8n + M	90.0	90.6	94.8	83.4	5.71	2.85×10^6	9.2×10^9
YOLO v8n + A + D	91.6	91.6	95.3	84.2	5.34	2.66×10^6	7.5×10^9
YOLO v8n + A + M	91.2	91.3	95.2	84.7	5.19	2.57×10^6	8.7×10^9
YOLO v8n + D + M	90.1	90.9	94.9	83.8	5.85	2.92×10^6	9.3×10^9
YOLO－ADM(本文)	92.3	91.0	95.6	85.2	5.33	2.64×10^6	8.8×10^9

注:A 为 ADown 模块,D 为 C2f－DA 模块,M 为 MFI Neck 网络。

3.3.5 Grad－CAM 可视化结果

Grad－CAM 热力图是一种基于梯度信息的可视化方法,用于解释卷积神经网络的决策过程。它能将任意结构的卷积神经网络在不同区域的关注度以颜色区分的方式呈现出来。通过这种方式,研究人员可以直观地了解模型对特定区域的重视程度[26]。本研究对 YOLO v8n 和 YOLO－ADM 进行了热力图可视化。由图 11 可知,原始 YOLO v8n 对叶片复杂信息的集中度较低,受环境影响较大,对花生叶片病害的关注范围较广,存在模糊信息,导致不能充分提取特征信息,从而影响识别精度。而 YOLO－ADM 可以更加关注叶片本身的特征,对背

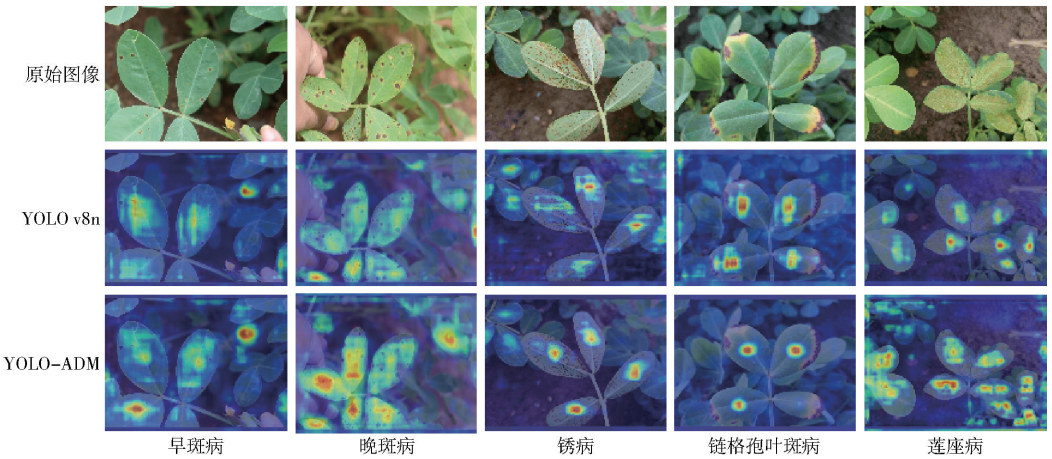

图 11 Grad－CAM 对比图

Fig. 11 Grad－CAM comparison chart

景的关注度降低，将模型的关注点集中在叶片的复杂特征上，显著提升对病害区域的聚焦能力，有效过滤背景干扰信息，从而有效提高识别准确度。

3.3.6　不同模型识别情况对比

为了进一步验证改进模型在花生叶片病害的识别效果，选取了具有代表性的目标检测模型进行对比，包括 YOLO v5n、YOLO v6n、YOLO v7-tiny、YOLO v8n、YOLO v9t、RT-DETR-L 以及 YOLO v10n。将这些模型与本文所提 YOLO－ADM 进行比较，结果如表 6 所示。实验结果表明，YOLO v6n 识别精度表现最不理想，其精确率、召回率和 mAP 均处于最低水平。相较之下，未改进的 YOLO v8n 模型在识别花生叶片病害任务中表现较佳，具有较高精度，适用于此类病害检测任务。改进 YOLO－ADM 模型在识别能力上展现了显著优势，各项性能指标均表现优异，在精确率（92.3%）、召回率（91.0%）、mAP@0.5（95.6%）和 mAP@0.5:0.95（85.2%）上，均优于其他模型。相较于 YOLO 系列模型，本文模型不仅提高了检测准确性，减少了误检和漏检，同时在总体检测性能上表现最为优异，适合病害检测的复杂任务。

表 6　与其他模型对比实验结果

Tab. 6　Comparison of experimental results with other models　%

模型	精确率	召回率	mAP@0.5	mAP@0.5:0.95
YOLO v5n	88.4	88.4	92.9	80.4
YOLO v6n	84.3	82.7	86.9	75.7
YOLO v7-tiny	86.2	87.5	91.6	77.1
YOLO v8n	87.8	90.8	94.0	82.2
YOLO v9t	89.4	85.6	93.0	81.4
YOLO v10n	86.3	88.4	92.0	79.4
RT-DETR-L	89.4	85.2	91.4	79.3
YOLO－ADM（本文）	92.3	91.0	95.6	85.2

3.3.7　可视化对比

选取 RT－DETR－L、YOLO v8n、YOLO v10n 和 YOLO－ADM 进行可视化对比（图 12），由图 12 可知，YOLO－ADM 在花生叶片病害检测任务中展现出显著的优越性，YOLO－ADM 能够精准地识别和定位花生叶片上的病斑。在图像中的每个病害类型检测中，YOLO－ADM 检测框几乎覆盖了所有病害区域，表现出对细小病斑和边缘区域的更高敏感度。特别是在叶片上病斑形状不规则或边缘不清晰的情况下依然能够有效识别。由图 12 可以看出，原有 YOLO v8n 模型在叶片遮挡和残缺位置存在较多误检的目标，导致识别精度降低，反映出 YOLO－ADM 对边缘区域相似目标的检测能力更强。综上所述，在花生叶片病害的检测任务中，改进 YOLO－ADM 在识别精度、边界定位、多病害区分及抗干扰能力方面表现优异，显示出较强的综合性能。

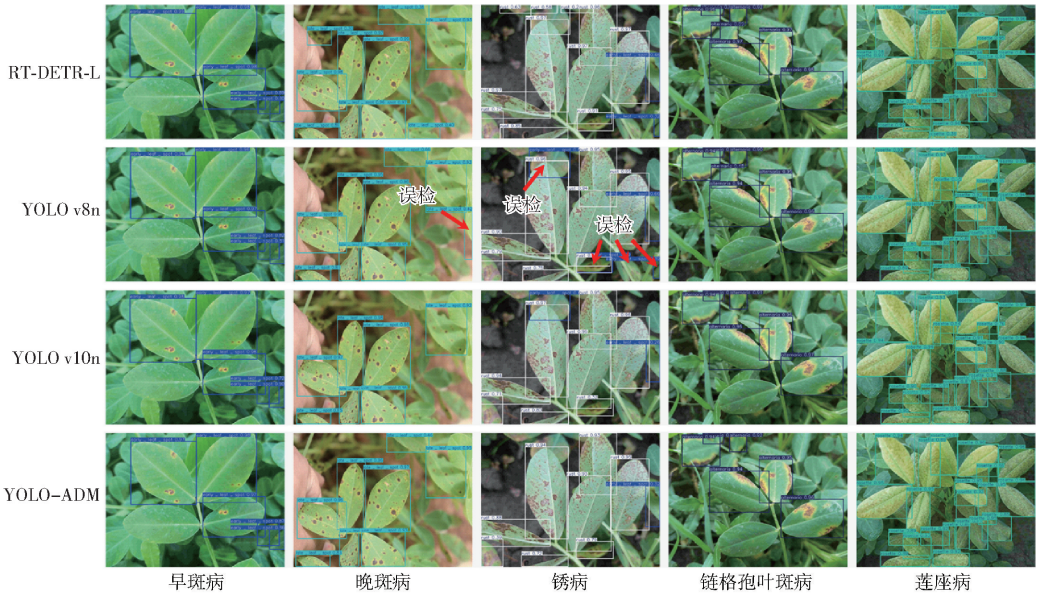

图 12　可视化对比图

Fig. 12　Visualization comparison chart

4　结论

（1）针对花生叶片病害在复杂环境下相似病害和残缺目标难以准确识别问题，本文根据现有公开数据集，结合网络搜索进行补充并标记，建立了一个包含 5 类花生常见叶片病害的目标检测数据集。在此基础上，对 YOLO v8n 模型进行改进，提出了一种新的病害检测算法 YOLO－ADM，实现了对 5 类花生叶片病害的准确识别。

（2）通过使用 ADown 模块代替部分 CBS 模

块,保留更多特征信息,减少了模型参数量;将可变形注意力机制引入 C2f 模块组成 C2f - DA 结构,替换 SPPF 上层的 C2f 模块,提高了模型对关键特征信息的关注度,减少了复杂环境对识别准确度的影响;提出了一种全新的多尺度特征融合网络 MFI Neck,增强了颈部网络对不同特征层的融合能力,提高了模型对不同尺度花生叶片病害的识别能力。

(3)实验结果表明,YOLO - ADM 的识别精确率和召回率达到 92.3% 和 91.0%,mAP@0.5 和 mAP@0.5:0.95 达到 95.6% 和 85.2%,相比原始 YOLO v8n 分别提高 4.5、0.2、1.6、3.0 个百分点,且参数量和模型内存占用量均有减小,证明了该模型对花生叶片病害识别的有效性和可行性。

参 考 文 献

[1] 申海洋,罗伟文,吴峰,等. 花生机械化收获装备与技术研究进展[J]. 农业机械学报,2024,55(8):21 - 38.
SHEN Haiyang, LUO Weiwen, WU Feng, et al. Research progress on mechanized harvesting equipment and technology for peanut[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(8): 21 - 38. (in Chinese)

[2] WANG Y, WANG D, LI C, et al. Effects of high-energy electron rays on groundnut cake: kinetics of aflatoxins degradation and changes in physicochemical quality[J]. Food Control, 2024, 166: 110709.

[3] DEVI K S, SRINIVASAN P, BANDHOPADHYAY S. H2K - A robust and optimum approach for detection and classification of groundnut leaf diseases[J]. Computers and Electronics in Agriculture, 2020, 178: 105749.

[4] KANKAM F, AKPATSU I B, TENGEY T K. Leaf spot disease of groundnut: a review of existing research on management strategies[J]. Cogent Food & Agriculture, 2022, 8(1): 2118650.

[5] 于沐,杨海棠,胡延岭,等. 河南省 316 份花生资源抗叶斑病的抗性评价分析[J]. 种子,2024,43(6):86 - 90.
YU Mu, YANG Haitang, HU Yanling, et al. Evaluation and analysis of resistance to leaf spot disease in 316 arachis hypogaea resources in Henan Province[J]. Seed, 2024, 43(6): 86 - 90. (in Chinese)

[6] 李莹,于静,张霞,等. 不同花生品种对花生镰孢菌根腐病及叶斑病田间抗性评价[J]. 花生学报,2024,53(2):69 - 76.
LI Ying, YU Jing, ZHANG Xia, et al. Evaluation on resistance of peanut varieties against peanut root rot and leaf spot[J]. Journal of Peanut Science, 2024, 53(2): 69 - 76. (in Chinese)

[7] 马铁民,曲浩,高雅,等. 基于超分辨率生成对抗网络的玉米病害分类识别方法[J]. 农业机械学报,2024,55(11):49 - 56,67.
MA Tiemin, QU Hao, GAO Ya, et al. Maize disease classification and recognition method based on super-resolution generative adversarial networks[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 49 - 56, 67. (in Chinease)

[8] 王志强,于雪莹,杨晓婧,等. 基于 WGAN 和 MCA - MobileNet 的番茄叶片病害识别[J]. 农业机械学报,2023,54(5):244 - 252.
WANG Zhiqiang, YU Xueying, YANG Xaojing, et al. Tomato leaf diseases recognition based on WGAN and MCA - MobileNet [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(5): 244 - 252. (in Chinese)

[9] SARKAR C, GUPTA D, GUPTA U, et al. Leaf disease detection using machine learning and deep learning: review and challenges[J]. Applied Soft Computing, 2023, 145: 110534.

[10] JIANG F, LU Y, CHEN Y, et al. Image recognition of four rice leaf diseases based on deep learning and support vector machine[J]. Computers and Electronics in Agriculture, 2020, 179: 105824.

[11] XU L, CAO B, ZHAO F, et al. Wheat leaf disease identification based on deep learning algorithms[J]. Physiological and Molecular Plant Pathology, 2023, 123: 101940.

[12] 张家瑜,朱锐,邱威,等. 基于选择性注意力神经网络的木薯叶病害检测算法[J]. 农业机械学报,2024,55(5):254 - 262,272.
ZHANG Jiayu, ZHU Rui, QIU Wei, et al. Cassava leaf disease detection algorithm based on selective attention natural network [J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(5): 254 - 262, 272. (in Chinese)

[13] 山显英,张琳,李泽慧. 深度学习驱动下的目标检测研究进展综述[J]. 计算机工程与应用,2025,61(1):24 - 41.
SHAN Xianying, ZHANG Lin, LI Zehui. Review of research progress in object detection driven by deep learning[J]. Computer Engineering and Applications, 2025, 61(1): 24 - 41. (in Chinese)

[14] 袁杰,谢霖伟,郭旭,等. 基于改进 YOLO v7 的苹果叶片病害检测方法[J]. 农业机械学报,2024,55(11):68 - 74.
YUAN Jie, XIE Linwei, GUO Xu, et al. Apple leaf disease detection method based on improved YOLO v7[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 68 - 74. (in Chinese)

[15] LIU B, HUANG X, SUN L, et al. MCDCNet: multi-scale constrained deformable convolution network for apple leaf disease detection[J]. Computers and Electronics in Agriculture, 2024, 222: 109028.

[16] 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)

[17] SHAO M Y, ZHANG J H, FENG Q, et al. Research progress of deep learning in detection and recognition of plant leaf diseases[J]. Smart Agriculture, 2022, 4(1): 29.

(下转第 564 页)

v5s algorithm and CBAM: validation through TPA, colorimeter, and PLSR analysis[J]. Food Chemistry: X, 2023, 19: 100733.
[22] ZHOU L, XIE X, JIANG L, et al. Diagnosis of cryptocaryoniasis in large yellow croaker (*Larimichthys crocea*) by real-time object detection based on YOLO v3[J]. Aquaculture, 2024, 581: 740418.
[23] PRASETYO E, SUCIATI N, FATICHAH C. YOLO v4 - tiny with wing convolution layer for detecting fish body part[J]. Computers and Electronics in Agriculture, 2022, 198: 107023.
[24] DU L, LU Z, LI D. A novel automatic detection method for breeding behavior of broodstock based on improved YOLO v5[J]. Computers and Electronics in Agriculture, 2023, 206: 107639.
[25] GAO X, YU A, TAN J, et al. GSD - YOLOX: lightweight and more accurate object detection models[J]. Journal of Visual Communication and Image Representation, 2024, 98: 104009.
[26] WANG H, ZHANG S, ZHAO S, et al. Fast detection of cannibalism behavior of juvenile fish based on deep learning[J]. Computers and Electronics in Agriculture, 2022, 198: 107033.
[27] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLO v7: 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.
[28] GE Z, LIU S, WANG F, et al. YOLOX: exceeding YOLO series in 2021[J]. arXiv Preprint, arXiv:2107.08430, 2021.
[29] DAI X, CHEN Y, XIAO B, et al. Dynamic head: unifying object detection heads with attentions[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 7373 - 7382.
[30] 李文涛,张岩,莫锦秋,等. 基于改进 YOLO v3 - tiny 的田间行人与农机障碍物检测[J]. 农业机械学报,2020,51(增刊1):1 - 8,33.
LI Wentao, ZHANG Yan, MO Jinqiu, et al. Detection of pedestrian and agricultural vehicles in field based on improved YOLO v3 - tiny[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(Supp. 1): 1 - 8, 33. (in Chinese)
[31] 刘莫尘,高甜甜,马宗旭,等. 基于 MSRCR - YOLO v4 - tiny 的田间玉米杂草检测模型[J]. 农业机械学报,2022,53(2): 246 - 255, 335.
LIU Mochen, GAO Tiantian, MA Zongxu, et al. Target detection model of corn weeds in filed environment based on MSRCR algorithm and YOLO v4 - tiny[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(2): 246 - 255, 335. (in Chinese)
[32] 李健源,柳春娜,卢晓春,等. 基于改进 YOLO v5s 和 TensorRT 部署的鱼道过鱼监测[J]. 农业机械学报,2022,53(12): 314 - 322.
LI Jianyuan, LIU Chunna, LU Xiaochun, et al. Fish passage monitoring based on improved YOLO v5s and TensorRT deployment[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(12): 314 - 322. (in Chinese)
[33] 王昱,姚兴智,李斌,等. 基于改进 YOLO v7 - tiny 的甜椒畸形果识别算法[J]. 农业机械学报,2023,54(11):236 - 246.
WANG Yu, YAO Xingzhi, LI Bin, et al. Malformed sweet pepper fruit identification algorithm based on improved YOLO v7 - tiny[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(11): 236 - 246. (in Chinese)

(上接第 526 页)

[18] AISHWARYA M P, REDDY A P. Dataset of groundnut plant leaf images for classification and detection[J]. Data in Brief, 2023, 48: 109185.
[19] SASMAL B, DAS A, DHAL K G, et al. A novel groundnut leaf dataset for detection and classification of groundnut leaf diseases[J]. Data in Brief, 2024, 55: 110763.
[20] JU R Y, CAI W. Fracture detection in pediatric wrist trauma X-rayimages using YOLO v8 algorithm[J]. Scientific Reports, 2023, 13(1): 20077.
[21] WANG C Y, YEH I H, LIAO H Y M. YOLO v9: learning what you want to learn using programmable gradient information [J]. arXiv Preprint, arXiv:2402.13616,2024.
[22] XIA Z, PAN X, SONG S, et al. Vision transformer with deformable attention[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 4794 - 4803.
[23] CAI X, LAI Q, WANG Y, et al. Poly kernel inception network for remote sensing detection[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 27706 - 27716.
[24] 时雷,杨程凯,雷镜楷,等. 基于改进 YOLO v8s 的小麦小穗赤霉病检测研究[J]. 农业机械学报,2024,55(7):280 - 289.
SHI Lei, YANG Chengkai, LEI jingkai, et al. Wheat spikelet detection of fusarium head blight based on improved YOLO v8s [J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(7): 280 - 289. (in Chinese)
[25] JIANG Y, TAN Z, WANG J, et al. GiraffeDet: a heavy-neck paradigm for object detection[J]. arXiv Preprint, arXiv:2202.04256, 2022.
[26] 李鑫,南新元. 基于改进 YOLO v7-tiny 算法的多种类不均衡样本水稻害虫检测[J]. 山东农业科学,2024,56(6):133 - 142.
LI Xin, NAN Xinyuan. Detection of rice pests in multi-species unbalanced samples based on improved YOLO v7-tiny algorithm [J]. Shandong Agricultural Sciences, 2024, 56(6): 133 - 142. (in Chinese)