doi:10.6041/j.issn.1000-1298.2025.10.047

基于改进 YOLO v8 的苹果叶片病害检测研究

徐洪丽[1]　安　凤[1]　史宇轩[2]

(1.山东农业大学信息科学与工程学院,泰安 271018;2.山东理工大学计算机科学与技术学院,淄博 255000)

摘要:针对当前苹果叶片病害目标检测算法在复杂环境中实时性差、精度低、存在误检和漏检的问题,本文聚焦于苹果叶片上常见的黑腐病、灰斑病、锈病和疮痂病,构建一种基于改进 YOLO v8 的苹果叶片病害检测模型。首先,将传统卷积操作(Conv)替换为局部卷积(PConv),并基于局部卷积设计出 C2f_Faster 模块,用于替换主干网络中的 C2f 模块,在降低模型计算量同时而不影响其精度;其次,在空间金字塔池化模块(SPPF)之后添加三重注意力机制,提升复杂背景下特征提取能力;最后,将 YOLO v8 中的损失函数 CIoU 替换为基于最小点距离交并比损失函数 MPDIoU 以提升病害目标定位准确率。验证实验表明,针对自然场景采集的苹果叶片病害图像数据集,优化后网络架构的计算量、参数量等指标相较于原 YOLO v8n 基线模型分别下降 20.9% 和 23%。同时,精确率、召回率和mAP@0.5 分别提高 1.5、2.9、2.2 个百分点,分别达到 89.2%、91.4%、94.6%。对比 YOLO v3、YOLO v5、YOLO v8n、YOLO v9n、YOLO v10n 模型,mAP@0.5 分别提高 3.5、3.0、2.2、2.4、2.6 个百分点。本研究提出的方法在维持实时处理性能的基础上显著提升了识别准确率,为苹果叶片病害边缘计算检测系统的开发提供了可靠的技术支撑。

关键词:苹果叶片;病害检测;深度学习;YOLO v8n;三重注意力机制

中图分类号:TP391　　**文献标识码**:A　　**文章编号**:1000-1298(2025)10-0530-09　　**OSID**:

Apple Leaf Disease Detection Method Based on Improved YOLO v8

XU Hongli[1]　AN Feng[1]　SHI Yuxuan[2]

(1. *School of Information Science and Engineering*, *Shandong Agricultural University*, *Taian* 271018, *China*
2. *College of Computer Science and Technology*, *Shandong University of Technology*, *Zibo* 255000, *China*)

Abstract: Aiming at the problems of poor real-time performance, low accuracy, false detections, and missed detections in current apple leaf disease target detection algorithms in complex environments, focusing on common diseases such as black rot, gray spot, rust, and scab on apple leaves, an improved YOLO v8-based detection model for apple leaf diseases was constructed. Firstly, the traditional convolution operation (Conv) was replaced with partial convolution (PConv), and based on PConv, the C2f_Faster module was designed to replace the C2f module in the backbone network, reducing the computational load of the model without compromising its accuracy. Secondly, a triple attention mechanism was added after the spatial pyramid pooling module (SPPF) to enhance feature extraction capabilities in complex backgrounds. Finally, the CIoU loss function in YOLO v8 was replaced with the minimum point distance-based intersection over union loss function MPDIoU to improve the localization accuracy of disease targets. Validation experiments showed that, for a dataset of apple leaf disease images collected in natural scenes, the computational load and parameter count of the optimized network architecture were reduced by 20.9% and 23%, respectively, compared with the original YOLO v8n baseline model. Meanwhile, precision, recall, and mAP@0.5 was increased by 1.5, 2.9, and 2.2 percentage points, reaching 89.2%, 91.4%, and 94.6%, respectively. Compared with YOLO v3, YOLO v5, YOLO v8n, YOLO v9n, and YOLO v10n models, mAP@0.5 was improved by 3.5, 3.0, 2.2, 2.4, and 2.6 percentage points, respectively. The method proposed significantly improved recognition accuracy while maintaining real-time processing performance, providing reliable technical support for the development of edge computing detection systems for apple leaf diseases.

Key words: apple leaf; disease detection; deep learning; YOLO v8n; triplet attention mechanism

收稿日期:2025-02-06　修回日期:2025-05-26

基金项目:山东省重点研发计划(乡村振兴科技创新提振行动计划)项目(2023TZXD058)

作者简介:徐洪丽(1976—),女,副教授,博士,主要从事智能算法和混沌理论、大数据及农业应用等研究,E-mail:coco2006@sdau.edu.cn

0　引言

作为我国农业经济的重要支柱产业，苹果种植业在促进区域经济发展和保障农户收入稳定增长方面发挥着不可替代的作用。近 10 年来，中国苹果种植面积一直保持在 1.93×10^6 hm^2 以上，年产量接近 5.0×10^7 t，其中 2023 年，全国苹果总产量达到 $4.960\,17 \times 10^7$ t，同比增长 4.3%。苹果的产量水平受多重环境因子的综合调控，其中土壤理化性质、气象条件、水分供应状况以及病虫害发生程度等均对其产生显著影响。在诸多影响因素中，苹果病害对产量形成的抑制作用尤为突出，是苹果产业可持续发展的关键限制因子之一，鉴于叶片病害具有较高的发生频率和显著的症状特征，其图像数据便于采集与分析，这使得叶部病变成为了苹果病害诊断的重要判别依据。我国目前对于病害检测多数局限于传统的方法，主要依靠专家和农户的主观诊断，该方法速度慢，误判率高。为了保证苹果种植业的发展，实现精准病害识别的技术方案取代传统人工鉴别方法，已成为推动智慧农业现代化发展的关键需求[1]。在农业信息化快速推进的背景下，智能化算法在农业生产中的应用日益普及。然而，传统机器学习方法（如支持向量机、随机森林及决策树等）仍存在局限性，其性能很大程度上取决于人工特征提取的质量和领域专家的经验积累，难以充分适应复杂的农业应用场景[2]。此外，这些方法建立的模型容易受到特征选择的影响，从而难以获得准确的结果。

计算机视觉与深度学习技术的快速发展为农作物病害智能识别研究提供了新的技术路径。目前，基于深度学习框架的农作物病害检测模型主要呈现两种典型架构：第 1 种是两阶段目标检测模型，代表性模型包括 R－CNN[3-4] 和 Faster R－CNN[5]。这些模型在检测农作物叶子病害方面表现较为准确，但由于网络模型较大，检测速度较慢，实际应用效果有限。第 2 种是单阶段目标检测模型，代表算法为 SSD[6] 和 YOLO[7] 等，这些模型检测速度快、实时性好，发展较为成熟。文献[8－12]基于深度学习的目标检测方法相较于传统的图像处理技术具有更高的准确率，这类方法通常通过引入新型网络模块来提高检测精度，但其研究重点往往集中在优化模型性能上，而忽略了模型参数规模和计算复杂度的控制。经过轻量化处理的模型[13-17]虽然显著提升了检测速度，但其精度改善效果有限，目前能够同时保证检测效率和准确性的方法仍然较为稀缺。

为解决上述问题，本文提出一种改进 YOLO v8 的苹果病害检测模型，使用 C2f_Faster 模块代替 C2f 模块降低模型的参数量和计算量，加入三重注意力机制旨在提升模型抑制背景干扰的能力，采用 MPDIoU 作为边界框回归损失函数提升目标边界框的回归精度和检测精度，以实现模型轻量化同时提高检测精度。

1　材料与方法

1.1　数据集构建

本研究以苹果的 4 种病害类别图像为研究对象，分别为黑腐病、灰斑病、锈病和疮痂病，每种病害图像实例如图 1 所示，所用数据集来自 PlantVillage 数据集和其他开源数据集平台，该数据集包含了单一背景和在真实苹果园中拍摄的带有病害的苹果树叶片、果实和枝干的图像。这些样本图像采集环境具有较高的复杂性，可能同时存在健康叶片、果实、枝干等干扰目标，且易受光照条件变化和拍摄角度差异等因素的影响，本研究构建的数据集经过严格的质量控制流程，其中包含经过人工筛选的苹果叶片病害样本图像。



(a) 黑腐病　(b) 灰斑病　(c) 锈病　(d) 疮痂病

图 1　苹果叶片病害实例

Fig. 1　Examples of apple leaf diseases

在数据标注环节，采用开源的 LabelImg 可视化标注工具对病害区域进行精确标注，将检测目标的边界框坐标信息及其对应的病害类别标签以 XML 格式进行结构化存储，确保数据标注的准确性和规范性。随后，将数据集按照比例 7∶2∶1 划分为训练集、验证集和测试集，数据分布情况如表 1 所示，最终构建符合 VOC 标准格式的数据集。

表 1　苹果叶片病害数据集样本数

Tab. 1　Apple leaf disease dataset　　幅

病害名称	训练集	验证集	测试集	总数
黑腐病	985	281	142	1 408
灰斑病	966	276	139	1 381
锈病	952	271	136	1 359
疮痂病	931	267	141	1 339

在目标检测任务中，数据集的质量通常直接影响训练模型的性能[18]。为增强模型的泛化性能和鲁棒性，本文运用了数据增强方法，旨在补充数据集中的小目标样本，并提升模型的泛化能力。Mosaic 数据增强通过对 4 幅输入图像执行随机翻转、尺度变换和色彩空间调整等操作，将其拼接整合为单幅

合成图像,同时生成相应的目标边界框标注信息。此方法显著丰富了数据集中的小目标和背景信息[19]。Mixup 数据增强则通过对 2 幅图像进行变换后,以一定比例对图像和边框进行融合,从而增强模型的鲁棒性[20]。将这 2 种数据增强方法结合使用,不仅能强化目标特征并丰富背景信息,而且在训练阶段,通过单次图像输入,即可计算多幅原始图像的相关数据,进而提升训练效率。这种联合方法不仅能增强模型对小目标的检测精度,还能有效提升模型的泛化能力。

1.2 YOLO v8 模型介绍

YOLO v8 是 YOLO 系列的较新版本,与当前广泛使用的 YOLO v5 网络[21]相比,YOLO v8 在检测精度和速度方面表现出了优越性。YOLO v8 提供了 5 种不同的模型,分别是 n、s、l、m 和 x,以适应不同的应用场景和需求。这些模型的网络深度依次增加,检测精度也随之提高。其中,YOLO v8n 具有最小的参数量和最快的检测速度。为了保证算法的实时性并控制模型的尺寸,本研究选用了 YOLO v8n 版本。

YOLO v8 网络架构包含 3 个核心组件:主干网络、颈部网络以及头部网络[22]。在数据预处理阶段,输入端融合了马赛克数据扩增技术、智能锚框自适应计算模块以及灰度自适应填充策略,特征提取的核心网络架构则集成了 Conv、C2f 和 SPPF 结构,其中 C2f 模块作为特征提取的关键组件,在 YOLO v7 的 ELAN 架构基础上进行了优化改进。该模块通过引入多分支结构和跨层连接机制,有效改善了梯度传播效率,从而构建出具有更优特征提取能力的网络单元[23]。特征融合模块采用路径聚合网络(PANet)架构,有效提升了多尺度目标特征的整合能力。检测输出模块采用解耦式设计,将分类与定位任务分离,主要由损失函数计算和目标框筛选两部分构成。具体而言,YOLO v8 的损失计算机制包含样本分配策略和损失函数计算 2 个关键环节,其中通过任务对齐分配器(Task aligned assigner)实现正样本筛选,该策略综合考虑分类置信度与回归精度的加权得分;分类分支采用二元交叉熵损失(BCE Loss),回归分支结合了分布焦点损失(DF Loss)和完全交并比损失函数(CIoU Loss)。

相较于前代版本,YOLO v8 在网络架构上的主要改进体现在特征提取主干和检测头 2 个核心组件的创新设计。它将 YOLO v5 中的 C3 结构替换为更复杂的 C2f 结构,优化了梯度流。同时,对不同尺度的模型进行了通道数调整,精简了模型结构,从而显著提升了模型性能并实现了更高的轻量化[24]。此外,YOLO v8 对检测头结构进行了重要改进,采用了解耦式设计将分类任务与回归任务分离,同时引入了无锚框(Anchor-Free)检测机制。这种改进策略显著降低了候选框的预测数量,有效提升了非极大值抑制(NMS)的计算效率。

1.3 YOLO v8 的改进

YOLO v8n 在众多目标检测算法中表现出较高的精度和较快的速度。在应用于苹果叶片病害检测任务时,由于目标检测环境复杂且大多数病斑较小,导致其特征信息难以有效提取,常出现误检和漏检的问题。本研究设计了一种基于优化 YOLO v8 架构的苹果叶片病害识别模型,其网络拓扑结构如图 2 所示。

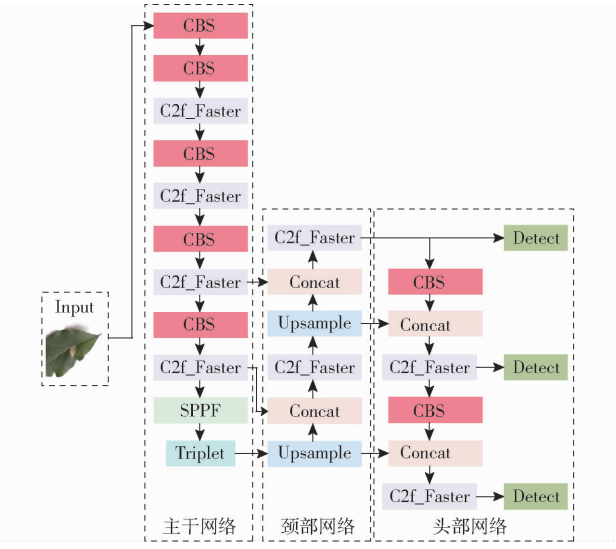


图 2 改进后 YOLO v8 网络结构

Fig. 2 Improved YOLO v8 network structure

1.3.1 设计 C2f_Faster 模块

本文算法的识别目标物是苹果叶片病害,其种类较多,且不同种类病害的病斑相似,如果使用目前主流的卷积方法,由于频繁进行内存访问,导致每秒浮点运算次数较低,同时也带来了较高的延迟。文献[25]提出了一种高效的部分卷积(PConv)策略,其核心思想是通过优化卷积操作来降低特征冗余和内存消耗。图 3 中,c 指通道数,用于表示特征图的总量;h 为高度,即数据在垂直维度上的单元数目;w 为宽度,标志着水平方向的数据单元个数;k 则对应卷积核尺寸,描述其在空间尺度上的大小,该方法的创新之处在于仅对输入特征图的部分通道执行卷积运算以获取空间特征,同时保留其他通道不变。具体实现中,通过选择输入特征图的首个或末个连续通道作为代表性特征进行计算,充分利用了内存的连续性和规则性。相较于标准卷积运算,在输入张量维度相同的条件下,部分卷积能够显著降低计算负荷和模型参数规模,对比结果见表 2,其计算量比和参数量比分别是 36.7% 和 25.0%,不仅维持了特

征提取的通用性，还显著减少了计算负担和内存访问开销。

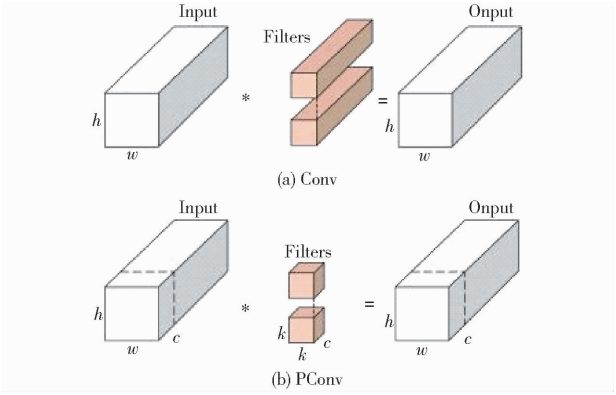


图 3　PConv 原理图

Fig. 3　PConv schematic

表 2　PConv 与 Conv 对比结果

Tab. 2　PConv *vs* Conv comparison results

卷积方法	输入尺寸	计算量	参数量
PConv	(1,64,224,224)	6.50×10^{8}	9 216
Conv	(1,64,224,224)	1.76×10^{9}	36 864

为了使得网络模型能够更加充分地利用输入通道中的所有信息，可以在初始模型的快速主干网络 FasterNet 中，首先采用 PConv，然后在其后添加 2 个逐点卷积层（Pointwise convolution，PWConv）。在 2 个 PWConv 层之间，嵌入了批量归一化和 ReLU 激活函数操作，最后通过残差连接将各层相连，从而构建出一个高效的快速模块（Faster-block）。该快速模块的结构如图 4 所示。

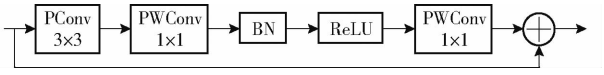


图 4　FasterNet 结构图

Fig. 4　FasterNet structure

初始模型的主干网络中的 C2f 模块由标准卷积（Conv）和多个瓶颈（Bottleneck）层构成。在进行卷积运算时，由于瓶颈层的存在，需要进行大量的跳跃连接和额外的拆分操作，这使得网络结构变得更加复杂，并且计算量大，难以满足苹果叶片病害检测的需求。为了解决这一问题，本文提出将 C2f 结构中的瓶颈层替换为 Faster-block，并将 C2f 主干网络与 FasterNet 网络进行融合，形成了新的 C2f_Faster 模块。相较于传统 C2f 模块，C2f_Faster 模块在确保检测准确率稳定的前提下，有效提升了模型的推理效率并降低了计算资源消耗。C2f_Faster 模块的结构如图 5 所示。

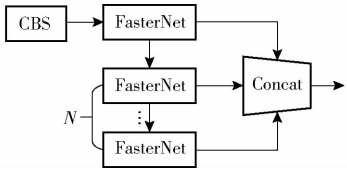


图 5　C2f_Faster 结构图

Fig. 5　C2f_Faster structure diagram

1.3.2　添加 Triplet 注意力机制

自然环境中苹果叶片的生长环境复杂，病害图像在采集过程中受到多种干扰因素的影响，不仅导致了大量纹理特征丢失，还引入了冗余信息，从而使得从病害图像中提取有效特征变得困难。注意力机制能够帮助模型聚焦于图像中的目标特征，避免复杂背景的干扰，从而更有效地提取轨道扣件的特征信息。具有代表性的注意力机制包括 SE[26] 和 SAM[27]，其中空间注意力机制侧重于提取不同通道中的特征信息，但往往忽略了通道间的信息交互；相比之下，通道注意力机制主要聚焦于特征通道间的依赖关系，但在处理过程中可能无法充分整合空间维度的特征信息。为了克服这些局限，本文提出在 SPPF 层后引入三重注意力机制（Triplet Attention）[28]。该机制通过角度旋转和残差变换实现跨维度的信息交互，能够同时处理通道和空间信息的融合，对通道和空间信息进行有效编码，使得模型能够更加专注于轨道扣件的特征，避免道砟等无关信息的干扰。

Triplet Attention 分支网络结构如图 6 所示。给定一个输入张量 $\boldsymbol{\chi}\in\mathbf{R}^{C\times H\times W}$，该张量被传递至 Triplet Attention 的 3 个不同分支。该注意力机制的

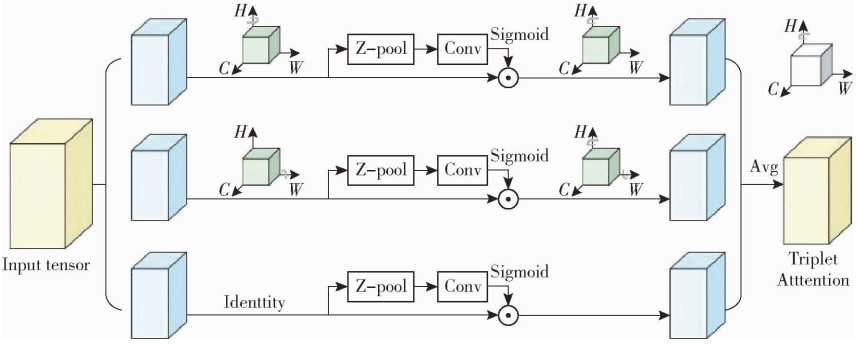


图 6　Triplet Attention 结构图

Fig. 6　Structure of Triplet Attention

实现过程可分为以下几个关键步骤:首先,输入特征张量经池化层压缩至 $2\times H\times W$ 尺度,随后通过卷积运算和 Sigmoid 激活函数生成相应尺度的注意力权重。为有效处理通道与空间维度的特征交互,输入特征通过张量旋转操作分别转换为 $H\times C\times W$ 和 $W\times H\times C$ 2 种维度表示。接着,采用 Z-Pool 池化方法对旋转后的特征图进行空间信息聚合,在保留通道间相关性的同时实现特征压缩[29]。池化后的特征张量被调整为 $2\times C\times W$ 和 $2\times H\times C$ 尺度,经过 7×7 卷积核和批量归一化层处理后生成 $1\times H\times C$ 的中间特征。通过引入残差连接机制计算各分支权重,并将批量归一化后的特征图旋转恢复至原始维度。最终,将 3 个 $C\times H\times W$ 尺度的输出张量进行特征融合,得到注意力机制的最终输出结果。

该注意力机制通过对 3 条路径生成的新特征进行相加并求取平均值,从而增强了空间与通道之间的信息交互能力,进而提升了模型的检测精度。

1.3.3 引入 MDPIoU 损失函数

在实际叶片病害检测中,一些病斑目标聚集度较高且遮挡情况严重,这会导致边界框回归的速度下降,回归精度降低[30],进而影响对病害目标的精确定位和可能出现的漏检问题。而传统模型所采用的损失函数 CIoU(Complete IoU loss)[31]在这种情况下表现不佳,限制了检测性能。为了解决这一问题,提高病害检测的精度并加速模型的收敛过程,本文提出采用基于最小点距离交并比(MPDIoU)[32]的改进损失函数,替代传统的回归损失函数。MPDIoU 通过直接优化预测框与真实框之间左上角和右下角关键点的距离度量,实现了更精确的边界框回归,从而使得预测框更加接近真实框,同时简化了计算过程。与此同时,MPDIoU 还综合考虑了目标中心点的距离、框的宽高偏差以及框之间的重叠和非重叠区域,从而更适用于目标高度聚集的病害检测场景。设 A 和 B 为任意 2 个图形,MPDIoU 计算公式为

$$MPDIoU=\frac{A\cap B}{A\cup B}-\frac{d_1^2}{w^2+h^2}-\frac{d_2^2}{w^2+h^2} \tag{1}$$

其中

$$d_1^2=(x_1^B-x_1^A)^2+(y_1^B-y_1^A)^2 \tag{2}$$

$$d_2^2=(x_2^B-x_2^A)^2+(y_2^B-y_2^A)^2 \tag{3}$$

可得

$$L_{MPDIoU}=1-MPDIoU \tag{4}$$

式中 (x_1^A,y_1^A)——图形 A 左上角的坐标

(x_2^A,y_2^A)——图形 A 右下角的坐标

(x_1^B,y_1^B)——图形 B 左上角的坐标

(x_2^B,y_2^B)——图形 B 右下角的坐标

d_1^2——图形 A 和图形 B 的左上角及右下角点之间的欧氏距离

d_2^2——图形 B 的左上角及右下角点之间的欧氏距离

L_{MPDIoU}——基于最小点距离交并比(MPDIoU)度量的边界框回归损失函数

2 实验结果与分析

2.1 实验环境与参数配置

本研究采用英特尔酷睿 i7-13700HX 处理器,配备 NVIDIA GeForce RTX 4060 图形处理器,拥有 16 GB 的显存,操作系统选用 Windows 11,Python 版本为 3.8.19,CUDA 版本则为 11.6,使用了 PyTorch 1.13 框架进行训练。在训练过程中,设定迭代次数为 200 次,每个批次的图像数量为 32 幅,且输入图像的尺寸被设定为 640 像素×640 像素。

2.2 评价指标

为对改进后 YOLO v8n 模型的性能进行评估,本文采用了多维度评价指标,包括精确率(Precision,P)、平均精度均值(mean Average Precision,mAP@0.5)、召回率(Recall,R)、参数量(Params)、计算量(GFLOPs)以及帧率(Frames per second,FPS)。

2.3 消融实验

为了展示改进后的 C2f_Faster 模块、Triplet 注意力机制的引入以及 MPDIoU 损失函数的应用对 YOLO v8n 模型算法产生的具体影响,在保持实验环境和配置统一的前提下,展开了消融实验,实验结果如表 3 所示。

表 3 不同改进方法的模型性能对比

Tab.3 Comparison of model performance of different improvement methods

模型	P/%	R/%	mAP@0.5/%	参数量	计算量	帧率/(f·s^{-1})
YOLO v8n	87.7	88.5	92.4	3 006 428	8.1×10^9	106.3
YOLO v8n-C2f_Faster	87.9	89.3	93.1	2 301 228	6.3×10^9	114.3
YOLO v8n-Triplet	88.1	88.7	92.6	3 006 428	8.2×10^9	96.8
YOLO v8n-MPDIoU	87.8	89.6	93.3	3 006 428	8.1×10^9	106.3
YOLO v8n-Triplet-MPDIoU	88.3	89.0	94.2	3 006 428	8.2×10^9	96.8
YOLO v8n-C2f_Faster-Triplet	88.4	88.9	94.0	2 301 428	6.4×10^9	105.7
YOLO v8n-C2f_Faster-Triplet-MPDIoU	89.2	91.4	94.6	2 301 428	6.4×10^9	106.3

根据表 3 的数据看出，本文所提出模型的精确率、召回率以及平均精度均值分别提升 1.5、2.9、2.2 个百分点，均超越了其他对比模型。具体而言，与 YOLO v8n 模型相比，本文提出的改进模型在检测精度和召回能力上均取得了显著提升，其中精确率从 87.7% 提升至 89.2%，这主要归因于本文设计的跨尺度特征融合机制，通过建立高阶语义信息与低层细节特征的动态权重关联，有效缓解了复杂背景下相似物体的误识别问题。召回率从 88.5% 提升至 91.4%，表明模型对正样本的捕捉能力显著增强。从特征空间理论看，这得益于改进的注意力模块通过通道和空间双路约束，增强了小目标特征的显著性表达，使特征金字塔在传递过程中更好地保留了小尺度目标的梯度信息。mAP@0.5 增长 2.2 个百分点，这表明模型在 IoU 阈值 0.5 的邻域内保持了更稳定的检测质量，反映了改进后的边界框回归损失函数对定位精度的优化效果。同时计算量、参数量降低了 20.9%、23%，帧率也提高了，模型轻量化设计呈现出典型的“双下降”特性。因此，本文模型在目标检测任务中表现出了更为出色的检测效果，为实时监测系统中精度-速度的权衡问题提供了新的解决方案框架。

2.4　C2f_Faster 加入不同注意力机制的对比实验

为了验证 Triplet 注意力机制的优越性，将多种代表性注意力机制整合到改进的 YOLO v8n - C2f_Faster 模型进行对比实验。其中，基于 Transformer 架构的 DAT（Deformable attention Transformer）通过可变形卷积动态学习注意力偏移，能够自适应聚焦不规则目标区域；源自语义分割的 SegNeXt 注意力结合多尺度卷积和空间注意力，通过多分支结构增强重要区域特征响应；采用局部窗口计算方式的 LocalWindow 注意力有效降低计算复杂度，适合处理高分辨率图像；而 MPCA（Multi-path cross attention）则通过多路径分支融合不同特征层上下文信息，特别适用于小目标检测。这些机制与通过三重分支实现跨维度交互的 Triplet 注意力一同进行了系统对比，实验结果如表 4 所示，充分验证了 Triplet 注意力在实时目标检测任务中的综合优势。

从表 4 的对比结果可以看出，所有注意力机制的 mAP@0.5 均低于 Triplet，尽管在精度方面，只有 SegNeXt 和 DAT 的性能超过 Triplet，而在召回率上，也只有 MPCA 的表现优于 Triple，但 Triplet 注意力机制在该苹果叶片病害数据集上的表现远超其他机制。尽管 Triplet 的计算量并不是所有注意力机制中最低的，但其检测效果明显优于其他方法，Triplet 注意力机制的核心创新在于其三重交互建模，相较于传统单一维度的注意力，其能够更全面地捕捉特征间的长程依赖关系，显著提高了在复杂环境下的检测精度，充分验证了 Triplet 注意力在实时目标检测任务中的综合优势。

表 4　不同注意力机制在模型中的性能表现对比

Tab.4　Comparison of performance of different attention mechanisms in models

模型	P/%	R/%	mAP@0.5/%	计算量	帧率/(f·s^{-1})
SegNeXt	90.7	86.0	93.7	6.4×10^{9}	103.2
DAT	89.5	87.6	93.6	6.5×10^{9}	101.4
LocalWindow	88.7	88.7	93.7	6.4×10^{9}	105.6
MPCA	87.4	89.8	93.8	6.3×10^{9}	103.4
Triplet	88.4	88.9	94.0	6.4×10^{9}	105.7

2.5　C2f_Faster 加入 Triplet 注意力机制修改不同损失函数的对比实验

为了验证 MPDIoU 损失函数的优越性，改进的 YOLO v8n - C2f_Faster - Triplet 模型分别修改为 WIoU、EIoU、SIoU、Inner - MPDIoU 与 MPDIoU 损失函数，并进行了实验比较，实验结果如表 5 所示。

表 5　不同损失函数模型性能对比

Tab.5　Performance comparison of different loss function models

模型	P/%	R/%	mAP@0.5/%	帧率/(f·s^{-1})
CIoU	88.4	88.9	94.0	105.7
WIoU	88.2	88.3	93.4	107.3
EIoU	87.9	87.2	93.3	106.6
SIoU	88.8	87.5	93.5	107.9
Inner - MPDIoU	86.7	89.1	94.0	108.2
MPDIoU	89.2	91.4	94.6	106.4

通过对表 5 中的实验结果进行比较分析，本文所提出的 MPDIoU 损失函数的精确率、召回率以及平均精度均值这 3 个核心性能指标，均展现出了相对于其他损失函数的优越性，通过直接最小化预测框与真实框的顶点距离之和，实现更精细的几何约束，相较于 CIoU 损失函数，精确率、召回率和 mAP@0.5 分别提升了 0.8、2.5、0.6 个百分点。虽然 Inner - MPDIoU 损失函数帧率的表现最佳，但其平均精度均值显著低于 MPDIoU 损失函数，揭示了 Inner - MPDIoU 损失函数计算简化带来的表征能力损失。因此，MPDIoU 损失函数在改进的模型中展现了更优的性能，能够显著提升模型的定位精度。

2.6　不同检测模型性能对比实验

为了充分验证本文所提算法的优越性进行了对比实验，将其与当前主流的病害检测算法进行了比较。参与对比的算法涵盖了 YOLO v3、YOLO v5、YOLO v8n、YOLO v9n、YOLO v10n 以及本文所改进的算法。实验的具体结果见表 6。

表 6 不同检测模型性能对比

Tab. 6 Performance comparison of different detection models

模型	P/%	R/%	mAP@0.5/%	参数量	计算量	帧率/(f·s^{-1})
YOLO v3	86.9	90.0	91.1	103 667 324	2.31×10^{10}	54.5
YOLO v5	85.6	91.6	91.6	2 503 724	7.2×10^{9}	95.0
YOLO v9n	87.5	89.1	92.2	1 971 564	7.6×10^{9}	102.1
YOLO v10n	86.8	87.3	92.0	2 265 948	8.2×10^{9}	106.8
YOLO v8n	87.7	88.5	92.4	3 006 428	8.1×10^{9}	106.3
YOLO v8n－C2f_Faster－Triplet－MPDIoU	89.2	91.4	94.6	2 301 428	6.4×10^{9}	106.3

根据表 6 的数据，虽然 YOLO v3 在本次目标检测任务中表现出较高的召回率，但其计算量较大，较高的召回率源于传统多尺度预测架构对病斑尺寸多样性的适应性，符合特征金字塔的尺度不变性理论，但计算量显著增加暴露了串行特征融合的计算冗余问题，这与现代轻量化网络的深度可分离卷积定理相悖；相较而言，YOLO v5 虽然得益于 CSPNet 结构的梯度分流优化使计算量大幅减少，但病斑与健康组织间的低对比度特征需要更强的通道-空间协同注意力，准确率仍不及本文提出的算法；对比 YOLO v9n 与 YOLO v8n，尽管 YOLO v9n 的计算量有所减少，但结构先验弱化导致特征表示能力降低，使其平均精度均值却下降了 0.2 个百分点。而 YOLO v10n 动态标签分配策略在类别不平衡数据中产生梯度偏差，并且无注意力引导的密集预测加剧了病斑边缘定位模糊问题。从平均精度均值和计算量这 2 个维度来看，本文所改进的模型均表现更佳。特别是改进后的 YOLO v8n，在轻量化方面展现出了显著优势。这进一步证实了本文所提出的算法在苹果叶片病害检测任务中的高效性和优越性。

2.7 可视化对比验证

为进一步验证所提出算法的检测性能，选取了自然背景、部分遮挡背景、复杂背景和模糊背景的场景对 4 种病害进行模型验证。在实验中，将本文提出的算法与 YOLO v8n 及其改进版本进行比较。检测结果如图 7 所示。



图 7 检测结果对比图

Fig. 7 Comparison chart of test results

通过对实验结果的对比分析，改进后的 YOLO v8n 算法在识别精度和边界框回归效率方面均表现更优。这表明该算法能够有效解决复杂背景下苹果叶片病害识别不准确问题，并能够改善苹果叶片病害的目标定位精度和特征识别效果，显著减少了由于背景与病害特征相似性导致的误检与漏检现象。尽管本研究在轻量化改进和检测性能上取得了显著成果，数据集中早期病斑样本占比通常较少，模型可能对轻微病斑的敏感度不足，影响早期预警效果，模型对叶片高度重叠、泥土附着或虫害损伤等干扰因素的区分能力有限，在田间复杂场景中可能出现假阳性，未来研究将重点推进算法在田间连续监测的嵌入式设备的实用化部署。图 8 和图 9 为改进模型的实验结果图。

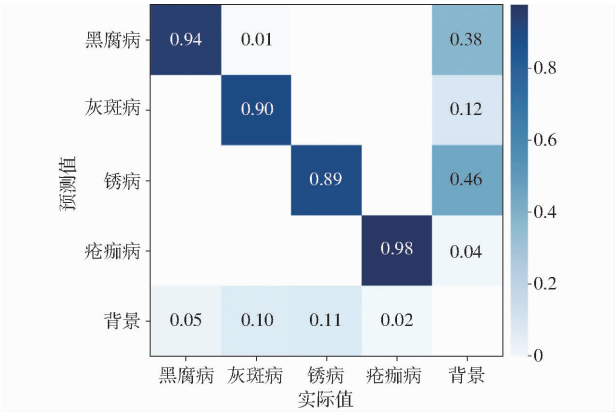


图 8 归一化混淆矩阵

Fig. 8 Confusion matrix normalized

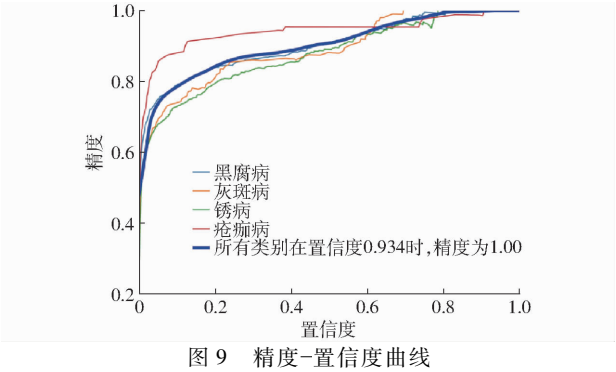


图 9 精度-置信度曲线

Fig. 9 Precision－confidence curve

通过对图 8 实验结果图的分析，由于黑腐病和

锈病的病害性状表现相似，其中有 1 个锈病检测为黑腐病，有 1 个黑腐病检测为锈病；归一化后的数值表示每个病害类别被预测正确的比例。消除了不同类别样本数的差异，便于比较模型在各个类别上的表现。

根据图 9 所示的精度-置信度曲线，在苹果叶片病害识别任务中可观察到：当置信度较低，模型执行“宽松筛选”策略，大量预测结果被纳入，此时精度表现波动明显且总体水平不高；置信度升高后，模型转向“严格筛选”，仅保留那些与目标特征高度吻合的预测，精度逐渐趋于稳定。随着置信度进一步提高，精度呈上升趋势并最终达到饱和。该现象表明，YOLO v8 所采用的 CSPDarknet 骨干网络及分类头结构，能够有效学习到具有判别力的苹果叶片病害特征。在高置信度条件下，模型凭借深层特征实现“真实病害目标”与“背景或误检”的准确区分，反映出特征学习方法在本任务中具有良好的有效性。此外，4 类病害各自的曲线形态与整体曲线高度一致，意味着模型对不同病害的识别行为保持一致，未见某类病害出现明显偏离，所训练的特征提取器展现出较强的泛化能力与普适性。

3　结论

（1）提出了一种改进 YOLO v8n 的检测方法。通过构建 C2f_Faster 模块，实现了网络的轻量化，有效减少了参数量和计算量，从而确保了实时性要求，加入 Triplet 注意力机制来提高模型在复杂环境下苹果叶片病害检测的准确率，采用基于最小点距离交并比损失函数 MPDIoU 作为边界框损失函数，从而更精确地提升模型的预测效果。

（2）对 YOLO v8n－C2f_Faster 模型进行了两方面的性能优化研究。在注意力机制方面，实验对比了 SegNeXt、DAT、LocalWindow、MPCA 和 Triplet 5 种模块的性能表现。测试数据显示，所有注意力机制均能有效提升基础模型的检测能力，其中 Triplet 注意力凭借其独特的三重分支结构，在苹果叶片病害检测任务中展现出最优的综合性能。在损失函数优化方面，评估了 WIoU、EIoU、SIoU、Inner－MPDIoU 和 MPDIoU 5 种边界框回归损失函数。实验结果表明，MPDIoU 损失函数通过引入最小点距离约束，使模型的定位精度得到显著提升，边界框回归误差降低，特别适合处理叶片病害这类形状不规则的检测目标。

（3）在相同实验条件下，将本文所改进的算法与 YOLO v3、YOLO v5、YOLO v8n、YOLO v9n、YOLO v10n 模型进行比较。实验结果表明，本文算法在自制苹果叶片病害数据集上取得了较优效果，改进模型精确率、召回率和平均精度均值分别提升 1.5、2.9、2.2 个百分点，同时计算量、参数量降低 20.9%、23%，成功实现了“更小更快更准”的设计目标。

参　考　文　献

[1] 邵明月，张建华，冯全，等. 深度学习在植物叶部病害检测与识别的研究进展[J]. 智慧农业（中英文），2022，4(1)：29－46.
SHAO Mingyue，ZHANG Jianhua，FENG Quan，et al. Research progress of deep learning in plant leaf disease detection and recognition[J]. Smart Agriculture，2022，4(1)：29－46.（in Chinese）

[2] CHAKRABORTY S，PAUL S，RAHAT-UZ-ZAMAN M. Prediction of apple leaf diseases using multiclass support vector machine [C]//2021 2nd International Conference on Robotics，Electrical and Signal Processing Techniques，2021.

[3] GIRSHICK R，DONAHUE J，DARRELL T，et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition，2013：580－587.

[4] GIRSHICK R. Fast R－CNN[C]//2015 IEEE International Conference on Computer Vision（ICCV），2015：1440－1448.

[5] REN S，HE K，GIRSHICK R，et al. Faster R－CNN：towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence，2016，39(6)：1137－1149.

[6] LIU W，ANGUELOV D，ERHAN D，et al. SSD：single shot multibox detector[C]// European Conference on Computer Vision，Springer，Cham，2016.

[7] CHITHAMBARATHANU M，JEYAKUMAR M K. Survey on crop pest detection using deep learning and machine learning approaches[J]. Multimedia Tools and Applications，2023，82(27)：42277－42310.

[8] 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）

[9] 李云红，张蕾涛，李丽敏，等. 基于 CycleGAN－IA 方法和 M－ConvNext 网络的苹果叶片病害图像识别[J]. 农业机械学报，2024，55(4)：204－212.
LI Yunhong，ZHANG Leitao，LI Limin，et al. Image recognition of apple leaf disease based on CycleGAN－IA method and M－Convnext network[J]. Transactions of the Chinese Society for Agricultural Machinery，2024，55(4)：204－212.（in Chinese）

[10] QIU Z，XU Y，CHEN C，et al. Enhanced disease detection for apple leaves with rotating feature extraction[J]. Agronomy，2024，14(11)：2602.

[11] 周绍发，肖小玲，刘忠意，等. 改进的基于 YOLOv5s 苹果树叶病害检测[J]. 江苏农业科学，2023，51(13)：212－220.
ZHOU Shaofa，XIAO Xiaoling，LIU Zhongyi，et al. Improved leaf disease detection in apple trees based on YOLOv5s[J]. Jiangsu Agricultural Science，2023，51(13)：212－220.（in Chinese）

[12] LI T, ZHANG L, LIN J. Precision agriculture with YOLO - Leaf: advanced methods for detecting apple leaf diseases[J]. Front Plant Sci., 2024,15:1452502.
[13] 赵鑫,马明涛,王丽芬,等.基于 YOLOv5 的轻量化苹果叶片病害检测[J].自动化应用,2024,65(18):146 - 148.
ZHAO Xin, MA Mingtao, WANG Lifen, et al. Lightweight apple leaf disease detection based on YOLOv5[J]. Automation Application, 2024, 65(18): 146 - 148. (in Chinese)
[14] 李小祥,张洁,秦柯贝,等.基于改进 YOLOv8 的轻量级复杂环境苹果叶片病害检测方法[J/OL].南京农业大学学报,1 - 14[2025 - 04 - 11]. DOI: 10.7685/jnau.200403023.
LI Xiaoxiang, ZHANG Jie, QIN Kebe, et al. Lightweight apple leaf disease detection method in complex environments based on improved YOLOv8[J/OL]. Journal of Nanjing Agricultural University, 1 - 14[2025 - 04 - 11]. DOI: 10.7685/jnau.200403023. (in Chinese)
[15] 李智慧.基于轻量化 GMNC - YOLO 的苹果叶片病害检测及系统设计[D].武汉:武汉轻工大学,2024.
LI Zhihui. Apple leaf disease detection and system design based on lightweight GMNC - YOLO[D]. Wuhan: Wuhan Polytechnic University, 2024. (in Chinese)
[16] ZOU H, LV P, ZHAO M. Detection of apple leaf diseases based on LightYOLO - AppleLeafDx[J]. Plants, 2025,14(4):599.
[17] GAO L, ZHAO X, YUEX, et al. A lightweight YOLOv8 model for apple leaf disease detection[J]. Applied Sciences, 2024, 14(15):6710.
[18] ZHAO Y, SHI Y, WANG Z. The improved YOLOV5 algorithm and its application in small target detection[C]// Lecture Notes in Computer Science, 2022:679 - 688.
[19] 赵艳芹,崔翊超.基于改进 YOLOv8 算法的草莓采摘目标检测算法[J].高师理科学刊,2024,44(10):46 - 51.
ZHAO Yanqin, CUI Yichao. Strawberry picking target detection algorithm based on improved YOLOv8[J]. Journal of Science of Teachers' College and University, 2024, 44(10): 46 - 51. (in Chinese)
[20] 叶之骞,钟紫鹏,邓永聪,等.基于 Mixup 数据增强的 CNN - GRU 深度学习电火花线切割放电状态识别[J].机械,2023,50(9):8 - 15.
YE Zhiqian, ZHONG Zipeng, DENG Yongcong, et al. EDM wire-cut discharge state recognition based on Mixup data-enhanced CNN - GRU deep learning[J]. Machinery, 2023, 50(9): 8 - 15. (in Chinese)
[21] 孙丰刚,王云露,兰鹏,等.基于改进 YOLOv5s 和迁移学习的苹果果实病害识别方法[J].农业工程学报,2022,38(11):171 - 179.
SUN Fenggang, WANG Yunlu, LAN Peng, et al. An apple fruit disease recognition method based on improved YOLOv5s and transfer learning[J]. Tiansactions of the CSAE,2022,38(11):171 - 179. (in Chinese)
[22] XIE Shuang, SUN Hongwei. Tea - YOLOv8s: a tea bud detection model based on deep learning and computer vision[J]. Sensors,2023,23(14):6576.
[23] 杨玮,伏冬朔,吴龙起,等.基于改进 YOLO v7 的番茄黄化曲叶病毒病分级检测方法[J].农业机械学报,2025,56(6):527 - 534.
YANG Wei, FU Dongshuo, WU Longqi, et al. Tomato yellow leaf curl virus disease grading detection method based on improved YOLO v7[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(6): 527 - 534. (in Chinese)
[24] 白凯,张玉杰,苏邓文,等.基于改进 YOLO v8n 的花生叶片病害检测方法[J].农业机械学报,2025,56(6):518 - 526,564.
BAI Kai, ZHANG Yujie, SU Dengwen, et al. Peanut leaf disease detection method based on improved YOLO v8n[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(6): 518 - 526,564. (in Chinese)
[25] CHEN J R, KAO S O, HE h et al. Run, don't walk: chasing higher FLOPS for faster neural networks[C]// 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, 2023:12021 - 12031.
[26] 张胜伟,张瑞雨,陈天佑,等. 绿豆种子离散元仿真参数标定与排种试验[J]. 农业机械学报, 2022, 53(3): 71 - 79.
ZHANG Shengwei, ZHANG Ruiyu, CHEN Tianyou, et al. Calibration of simulation parameters of mung bean seeds using discrete element method and verification of seed-metering test[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(3): 71 - 79. (in Chinese)
[27] 刘洋,李全勇,顾健,等.基于改进 YOLO V5 的缺陷识别与定量分析[J].无损检测,2023,45(1):14 - 19,22.
LIU Yang, LI Quanyong, GU Jian, et al. Defect recognition and quantitative analysis based on improved YOLO V5[J]. Nondestructive Testing,2023,45(1):14 - 19,22. (in Chinese)
[28] 张玉玉,邴树营,纪元浩,等.基于改进 YOLOv8s 的玫瑰鲜切花分级方法[J].智慧农业(中英文),2024,6(2):118 - 127.
ZHANG Yuyu, BING Shuying, JI Yuanhao, et al. A grading method for rose fresh cut flowers based on improved YOLOv8s[J]. Smart Agriculture,2024,6(2):118 - 127. (in Chinese)
[29] 吴慧海,沈文忠.基于 TA - YOLO 的电力设备红外图像检测方法[J].信息技术与信息化,2022(3):17 - 20.
WU Huihai, SHEN Wenzhong. Infrared image detection method for power equipment based on TA - YOLO[J]. Information Technology and Informatization,2022(3):17 - 20. (in Chinese)
[30] 赵文仓,徐长凯,王春鑫.基于优化边界框回归的目标检测[J].高技术通讯,2021,31(7):747 - 753.
ZHAO Wencang, XU Changkai, WANG Chunxin. Target detection based on optimized bounding box regression[J]. High Technology Letters,2021,31(7):747 - 753. (in Chinese)
[31] 周涛,王骥,麦仁贵.基于改进 YOLOv8 的实时菠萝成熟度目标检测方法[J].华中农业大学学报,2024,43(5):10 - 20.
ZHOU Tao, WANG Ji, MAI Rengui. A real-time pineapple ripeness target detection method based on improved YOLOv8[J]. Journal of Huazhong Agricultural University,2024,43(5):10 - 20. (in Chinese)
[32] MA S, XU Y. MPDIoU: a loss for efficient and accurate bounding box regression[J]. arXiv:2307.07662,2023.