

曾林涛,马嘉昕,丁羽,等. 基于改进 YOLO v8 的苹果叶部病害检测方法[J]. 江苏农业科学,2025,53(5):147-156.

doi:10.15889/j.issn.1002-1302.2025.05.018

基于改进 YOLO v8 的苹果叶部病害检测方法

曾林涛^{1,2,3}, 马嘉昕^{1,2,3}, 丁羽^{1,2,3}, 许晓东^{1,2,3}

(1. 塔里木大学机械电气化工程学院, 新疆阿拉尔 843300; 2. 新疆特色农林产物利用与装备兵团重点实验室, 新疆阿拉尔 843300;

3. 新疆维吾尔自治区教育厅普通高等学校现代农业工程重点实验室, 新疆阿拉尔 843300)

摘要:针对苹果叶部病害在自然环境下形态和颜色特征较为复杂、区分度较低等特点,提出一种高效的病害检测模型,为病害的预防与科学化治理提供准确的依据。基于 YOLO v8 算法,在主干网络(backbone)末端,加入注意力机制 Shuffle Attention(SA),根据样本分布特点进行数据增强,引入 Mixup、Mosaic、Random 等数据增强方法增加特征表达能力,在提高检测性能的同时,不显著增加计算复杂度;在 neck 末端,使 C2f 模块与可变形卷积神经网络模块(Deformable Conv V2)相结合,以提升复杂背景下的检测性能,从而提高检测准确度,有效提高模型性能;为克服 CIoU 损失函数的局限性,采用 MPDIoU 损失函数,解决 CIoU 在特定场景下的限制。结果表明,相较于原始 YOLO v8 算法,本研究算法的平均准确率提升 3.5 个百分点, $mAP@0.5:0.95$ 提升 4.6 个百分点,精确率提升 3.6 个百分点,说明改进的算法在苹果叶部病害检测方面取得有效成果。

关键词:YOLO v8;苹果叶部病害;目标检测;Shuffle Attention;C2f_DCNV2;MPDIoU

中图分类号:S126;TP391.41 **文献标志码:**A **文章编号:**1002-1302(2025)05-0147-09

在当代社会背景下,农业的发展对粮食安全和经济发展具有不可或缺的作用^[1]。农作物的病害问题一直是农业生产面临的关键挑战之一,以苹果为例,叶部病害对其产量及品质造成的不良影响尤其明显。因此,对苹果叶部病害进行快速精确的检测与识别,对提升其生产效率和质量具有重要意义。

目前,深度学习技术在图像识别和分类领域已取得重大进展,特别是卷积神经网络(CNN)已成为目标识别和图像分类的核心技术。在苹果叶部病害检测领域,学者们尝试利用深度学习技术来提升检测精度。例如,王权顺等创新性地对 Faster R-CNN 技术进行改进,专门用于识别苹果叶片病害,该方法能在实际应用中实现非破坏性识别,且平均识别精度均值(mAP)达到 86.2%^[2]。Jiang 等设计了一个基于 Deep-CNN 的新模型,用以识别 5 种常见的苹果叶部病害, mAP 达到 78.80%^[3]。Sun 等提出的轻量级 CNN 模型能实时识别苹果叶部病害,

其 mAP 达到 83.12%^[4]。刘斌等通过快照集成方法构建了一个苹果叶部病害程度的识别模型,能准确识别苹果黑星病早晚期的发生程度,准确率高达 90.82%^[5]。张航等针对大规模多类别病虫害准确检测识别问题,提出一种基于卷积神经网络的方法,并采用随机梯度下降法进行优化,利用学习样本特征集识别病害,综合识别率超过 90%^[6]。贾少鹏等提出一种结合 CNN 与胶囊网络的新型病虫害检测模型,对农作物病虫害图像的识别准确率达到 93.75%,比传统 CNN 模型提高 3.55 百分点^[7]。

尽管前期研究已经在苹果叶部病害检测方面取得了显著成果,但这些方法在某些方面仍存在一定的局限性。例如,早期的一些研究对多尺度和复杂背景下的苹果叶部病害检测效果一般。在结合实际场景与实验室条件的应用研究中,VGG、GoogleNet、ResNet 等传统卷积神经网络模型的性能在训练阶段表现水平一般,且随着数据集规模的增大,训练时间相应延长^[8-9]。相比之下,YOLO 系列和 SSD 等单阶段检测算法虽然在检测速度上具有显著优势,但在准确性方面稍有欠缺。首先,在数据集标注不完整、样本分辨率低、背景复杂和光照条件不足的情况下,病虫害识别的准确度均会降低,进而会增加算法将背景误识别为病虫害的风险。此外,有关在复杂和非结构化背景中小范围目

收稿日期:2024-04-01

基金项目:新疆生产建设兵团第一师阿拉尔市科技计划(编号:2020ZB04)。

作者简介:曾林涛(1996—)男,河南周口人,硕士研究生,研究方向为农业机械化。E-mail:158123794@qq.com。

通信作者:丁羽,硕士,教授,硕士生导师,主要从事农业机械化研究。E-mail:dyandcae@163.com。

标病虫害的检测研究尚显不足;虽然通过模型融合的方法可以在一定程度上提高检测的准确率,但同时会显著增加计算量;在追求检测速度与准确性平衡的过程中,还需要对现有算法进行改进和优化,以适应复杂多变的实际农业环境。

针对以上问题,本研究以苹果常见的叶部病害为分析对象,提出一种以 YOLO v8 为基础框架的病害检测方法,增加注意力机制 Shuffle Attention (SA),将可变形卷积 V2 (Deformable Conv V2) 与 C2f 模块融合,最后使用 MPDIoU 损失函数替换 CIoU 损失函数^[10],以提高模型识别准确度。

1 材料与方法

1.1 图像数据采集

数据取自公开数据集 AppleLeaf 9 和在新疆阿克苏地区人工采集的数据^[11]。AppleLeaf 9 是从

PlantVillage、ATLDSD、PPCD2020、PPCD2021 中融合得到的数据,汇集了不同来源的图像,使得所提出的算法能够识别出更多种类的苹果叶部病害,可增强模型在应对环境变化时的鲁棒性。数据集中经过人工筛选的图片数据包括 263 幅斑点落叶病、621 幅黑腐病、435 幅褐斑病、408 幅灰斑病、317 幅锈病,共计 5 种病害 2 044 幅。使用 Mixup、Mosaic、Random 的方法对数据集进行扩充^[12],共得到 11 044 幅图片。数据集的多样性反映苹果叶部病害的真实多样性,通过随机方式将增强数据集分为训练集、验证集、测试集,其比例为 7 : 1 : 1,以降低数据集分割对试验结果的影响。采用交叉验证策略进一步执行 10 轮随机划分,在每轮划分后均进行模型训练及测试。最终,将 10 轮试验结果的平均值作为最终结果。表 1 为苹果叶部 5 种病害的主要症状和病原菌,图 1 为苹果叶部 5 种病害数据扩充后的效果。

表 1 苹果叶部 5 种病害的主要症状和病原菌

类别	主要症状	主要病原菌
斑点落叶病	常有褐色或黑色小圆形病斑,后逐渐扩大,叶上具棕紫色边	链格孢菌
黑腐病	病斑先为淡黄的圆形或放射状,后渐变为褐色,最后为黑色	苹果黑星菌
褐斑病	深褐色斑点在形态上与其他病变不同	苹果双壳菌
灰斑病	早期可见亚圆形黄褐色病斑,后变为灰色	梨叶点霉
锈病	病斑常为锈黄色斑点,斑点中心有褐色针状小点	山田胶锈菌

1.2 数据集处理

深度卷积神经网络模型对计算资源和存储资源的需求,与输入图像的分辨率直接相关^[13]。本研究以图像中的害虫对象为焦点,利用 MATLAB 视觉库对原始图像进行裁剪和归一化处理,将图像分辨率统一降至 640 × 640 像素,以有效管理图像数据,并为后续分析提供优化处理。另外,严格遵循 PASCAL VOC2007 标注格式,使用 labelme 标注工具对样本图像进行类别标注,为降低标注错误引入的噪声,对标注结果进行仔细校正,确保数据的准确性和一致性,这是一种有效的数据准备方法,不仅能够减少所需的计算和存储资源,还能够提高模型训练的效率和最终的识别准确率,是处理高分辨率农业图像数据集的一种实用策略。通过预处理和优化处理,可以在不牺牲太多图像细节的前提下,确保深度学习模型能够高效地处理和学习高质量的农业数据。将训练集和测试集按照 8 : 2 的比例进行随机划分,同时将各自的图像路径信息记录在相应的 train. txt 和 test. txt 文件中,以便于模型在训练与评估过程中进行引用。

1.3 目标检测模型及改进

YOLO v8 在继承前代 YOLO 模型优点的基础上,引入多项先进技术,以进一步提升性能^[14]。YOLO v8 模型的架构同样被划分为 4 个核心部分,分别为输入层 (Input)、主干网络 (Backbone)、特征融合模块以及检测头。在主干网络部分,YOLO v8 采用多个改良的卷积层 (Conv)、批量归一化层 (BN) 激活函数的组合,从输入图像中提炼多尺度且丰富的特征信息;在特征融合部分,策略融合多尺度特征信息,加强模型对目标尺寸变化的适应能力。YOLO v8 能更有效地整合和加强不同层次的特征信息。这种进阶的融合机制不仅可优化信息流动,还能增强模型对于尺度变化的鲁棒性,确保对小尺寸目标的检测能力。检测头部分通常包括多个并行的卷积层,分别用于预测目标的类别、边界框的位置和尺寸以及目标的置信度,最后引入新的优化策略或损失函数,以提高检测的准确性和鲁棒性,使模型能够在多个尺度上产生预测,进而显著提高检测的精度和速度^[15]。图 2 为原 YOLO v8 网络示意图。

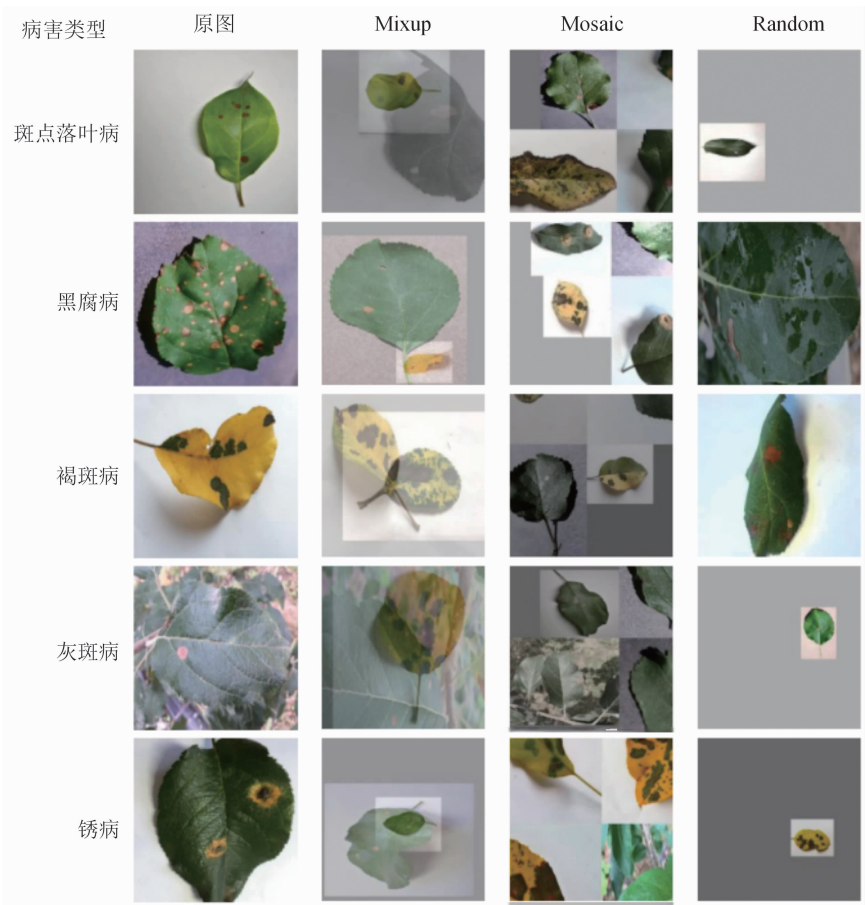


图1 苹果叶部 5 种病害数据扩充后的图像示例

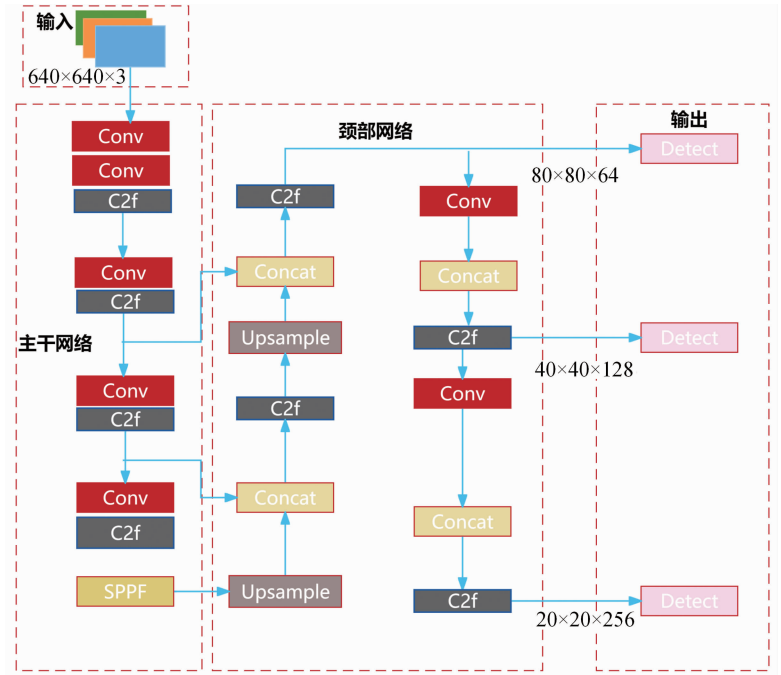


图2 原 YOLO v8 网络示意

1.3.1 置换注意力机制 注意力机制已被证明是增强卷积神经网络(CNN)性能的关键组件。置换

注意力机制(Shuffle Attention)构建于空间注意力(Spatial Attention)及通道注意力(Channel Attention)

之上^[16],通过特征分组与通道置换策略,发展出一种超轻量级注意力架构,该机制通过优化特征通道的组织,显著提升模型对关键信息的捕获能力,同时维持较低的计算复杂度。BAM、CBAM 等模型尽管能够实现性能的显著提升^[17],但它们不可避免地会增加计算负担。性能优化与计算成本之间的平衡是优化算法设计时必须考虑的关键因素。本研究提出一种轻量且高效的注意力模块,名为 Shuffle Attention (SA),意在提升卷积神经网络 (CNN) 的性能,同时解决传统注意力模型 (如 BAM、CBAM 等) 增加计算负担的问题。Shuffle Attention 模块通过高效的特征置换机制,优化信息流动与特征重组,实

现在保持轻量级架构的同时,提升模型的注意力聚焦水平与性能。Shuffle Attention (SA) 模块采用置换单元来高效整合空间与通道注意力机制,具体来讲,SA 模块首先将输入特征按通道维度划分为若干组,置换单元被应用于各个特征组,以有效描绘特征组在空间及通道维度上的依存关系;对经过处理的特征组进行汇集,并通过通道置换操作实现特征组间的互联,以促进模型在关键信息识别上的效能。加入 SA 注意力模块的目的是增强模型特征表达的综合性,并提升不同特征组之间的信息交换效率,图 3 为 SA 注意力机制的网络示意。




图3 SA 注意力机制网络示意

首先,SA 将输入沿着通道维度拆分为多组,每组内部独立地采用 Shuffle Attention (SA) 单元进行处理。SA 单元内部集成了空间注意力机制和通道注意力机制^[18]:空间注意力机制专注于捕捉空间维度上的特征依赖性,如图 3 中蓝色部分所示,强调模型对不同空间位置信息的敏感度和重视程度,具体实现使用的是群范数 (Group Norm, GN);在图 3 中将通道注意力机制标识为绿色,采用类 SE (Squeeze-and-Excitation) 策略^[19],强化通道间依赖性识别。Shuffle Attention (SA) 单元通过拼接操作实现组内信息整合,随后执行 Channel Shuffle,优化组间特征分布,促进亚特征间信息互通,增强模型表征力。

1.3.2 Neck 端改进 Deformable Conv v2 是深度学习领域中对标准卷积操作的一种先进适应,特别是在计算机视觉领域^[20]。作为可变形卷积网络 (Deformable Conv v1) 的进化版本,Deformable Conv v2 在 DCNv1 架构下,针对 ResNet-50 中的 Conv5 阶段,所有的 3×3 卷积层均采用可变形卷积进行更新。同时,为提高特征对齐的准确性,原有的标准 Aligned RoI Pooling 技术被可变形 RoI Pooling 技术取代^[21]。此外,在 DCNv2 的设计中,不仅 Conv5 阶

段,Conv3、Conv4 阶段中的所有 3×3 卷积层也同样被换成可变形卷积 (图 4),这一变化主要是为了提升模型对空间变形的适应性及其特征抽取的效率,进一步增强模型对于空间变形的适应能力和特征提取的效率。在 DCNv1 里,Deformable Conv 只学习 offset,具体计算公式为

$$y(p) = \sum_{k=1}^K w_k \cdot x(p + p_k + \Delta p_k) \quad (1)$$

式中: $y(p)$ 是输出或结果; w_k 是每个项的权重; p_k 、 Δp_k 是与 p 相关的参数; k 是求和的项数。每个项的权重由 w_k 决定,项的值由函数 $x(p + p_k + \Delta p_k)$ 得出,表示对输入内容加上调整项 p_k 、 Δp_k 后的结果进行加权求和。

在 DCNv2 中,通过增加采样点权重,所有 3×3 卷积层在 Conv3、Conv4、Conv5 阶段被可变形卷积替代^[22],增强模型的特征提取能力和空间适应性,具体计算公式为

$$y(p) = \sum_{k=1}^K w_k \cdot x(p + p_k + \Delta p_k) \cdot \Delta m_k \quad (2)$$

公式 (2) 在公式 (1) 基础上,对每个项的求和部分新增一个乘数 Δm_k ,这里的 m_k 表示某种额外的调整。通过引入偏移量 Δp_k 和权重 Δm_k ,增强模型

的自适应性。这种机制允许对不必要的采样点赋予零权重,从而增加了模型操作的灵活性。通过在输入特征图上应用 1 个独立的卷积层,获得偏移量 Δp_k 和权重 Δm_k ,该卷积层保持了与当前层相同的空间分辨率,从而优化了特征抽取的过程。输出特征图被分为 $3K$ 个通道,其中的 $2K$ 个通道专门用于表示偏移量的学习,余下 K 个通道经 sigmoid 层生成调制因子,增强模型的特征调整精度。这种架构在卷积过程中引入可学习的偏移量,使卷积核能够适应输入特征图中的几何变化,同时通过引入额外的可学习参数,决定每个采样点的偏移量。




图4 可变形卷积模块

C2f 模块通常包含 2 次卷积操作,伴随着批归

一化和激活函数; DCNv2 代表 Deformable Convolutional Networks v2;二者相结合的 C2f_DCN 模块,结合了常规卷积和可变形卷积(Deformable Convolution)的特性。DCN 能够让卷积核适应输入特征的几何变化,使网络能够更好地处理物体形状和姿态的变化,能够捕捉到更复杂的空间变换;C2f 结构通常通过重复的卷积操作增强特征学习能力,能够在保留重要信息的同时,更加深入地提炼特征,使后续层次能够构建更加丰富的特征表示。结合 C2f 和 DCN 二者特点的允许模型,不仅能在空间上获得更好的特征,在复杂的背景下或者在目标间存在遮挡的情况下,C2f_DCN 模型也更能通过其适应性和强大的特征学习能力,提高识别准确性,同时在特征级别上实现更深层次的抽象。这可以提升模型的泛化能力,从而在多样化的数据集上实现更好的性能。在计算效率上,尽管 DCN 增加了一些计算负担,但与直接扩大模型尺寸或增加层数相比,C2f_DCN 通过提供一种在计算上相对高效的方式来增强模型的识别能力。这种模块结合的设计理念是为了使模型能够更好地理解复杂的视觉信息,提高其在各种视觉任务上的表现。在实际的模型实现中,这种设计也使得模型更加模块化,更易于试验。图 5 为改进后的模型示意。

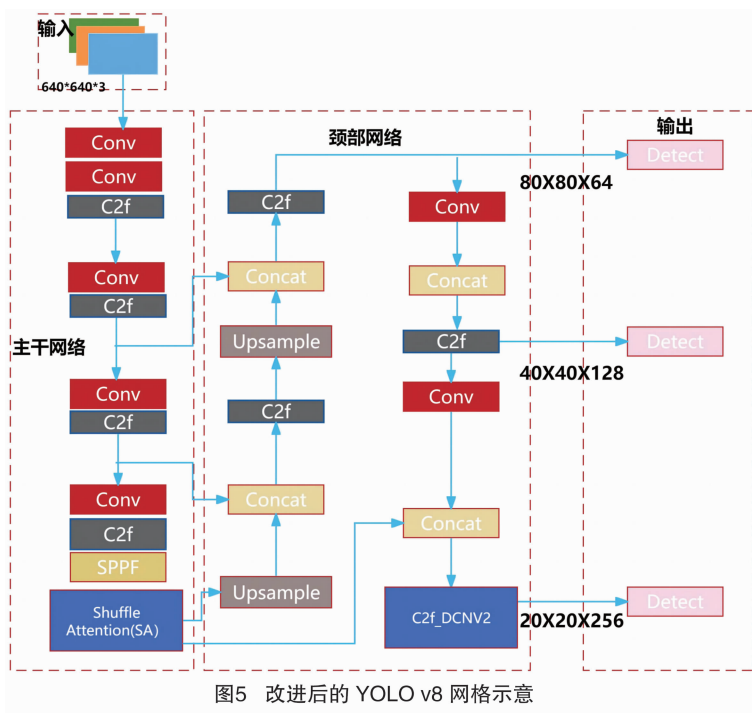


图5 改进后的 YOLO v8 网络示意

1.3.3 损失函数改进 使用 YOLO v8 模型检测苹果叶部病害时,CIoU (complete intersection over union) 损失函数虽然提供了边界框定位的准确性优

势^[18],但也存在一些可能的缺点。CIoU 损失函数优化了边界框的几何匹配,包括中心点距离和宽高比,这对于大尺寸目标的定位非常有效;然而,在检

测苹果叶部病害等细小目标时,这种方法不够灵敏,因为病害斑点如灰斑病、斑点落叶病等通常面积较小,且形状、大小多变。在苹果叶部病害检测中,病害斑点可能高度集中并重叠。CIoU 损失函数在处理多个高度重叠的小目标时,性能不如专门设计用来处理这种情况的损失函数;并且由于引入了更高的计算复杂度,增加了每次迭代的计算负担。因此,采用 MPDIoU 损失函数替换原网络中的 CIoU 损失函数^[23]。将最小点距离纳入考虑范围,使用最小点距离度量对损失函数进行重新描述,降低损失函数的总自由度,MPDIoU 损失函数的计算如公式(3)所示。

$$\mathcal{L}_{\text{MPDIoU}} = 1 - \text{IoU} + \frac{d_1^2}{h^2 + w^2} + \frac{d^2}{h^2 + w^2}; \quad (3)$$

$$d_1^2 = (x_1^{\text{pred}} - x_1^{\text{gt}})^2 + (y_1^{\text{pred}} - y_1^{\text{gt}})^2; \quad (4)$$

$$d_2^2 = (x_2^{\text{pred}} - x_2^{\text{gt}})^2 + (y_2^{\text{pred}} - y_2^{\text{gt}})^2. \quad (5)$$

式中: w 、 h 分别为网络中输入图片的宽、高; $(x_1^{\text{pred}}, y_1^{\text{pred}})$ 、 $(x_2^{\text{pred}}, y_2^{\text{pred}})$ 分别是预测框的左上角、右下角坐标; $(x_1^{\text{gt}}, y_1^{\text{gt}})$ 、 $(x_2^{\text{gt}}, y_2^{\text{gt}})$ 则分别是真实框的左上角、右下角坐标; IoU 是交并比,衡量预测区域与真实区

域的重叠程度; d_1 、 d_2 是 2 个距离度量,表示从预测区域到真实区域的距离。MPDIoU 损失函数通过考虑 IoU 和距离的平方和,来优化模型的精度,减少预测和真实区域之间的差异。

MPDIoU 损失函数能够在预测框和真实框的中心点不重叠的情况下,通过设计的惩罚项促使预测框向真实框靠近,从而提高检测的准确率。在预测框和真实框中心点完全重叠,且长宽比相同但大小不一致的情况下,MPDIoU 损失函数可通过特定的惩罚项^[24],避免损失函数退化为简单的 IoU 损失,确保模型能够对这种差异给予足够的关注。与 CIoU 损失函数相比,MPDIoU 损失函数在设计上更加简洁,计算过程更为高效,这有助于加快模型的训练速度^[25]。通过有效处理各种复杂情况下的预测偏差,MPDIoU 损失函数能够更稳定地引导模型收敛,避免训练过程中的震荡或者收敛速度过慢^[26]。

1.3.4 模型整体结构 为提高苹果叶片病害检测的精确度,提出一种改进优化的网络架构,即主要以 YOLO v8 算法为基础进行改进优化,具体如图 6 所示。

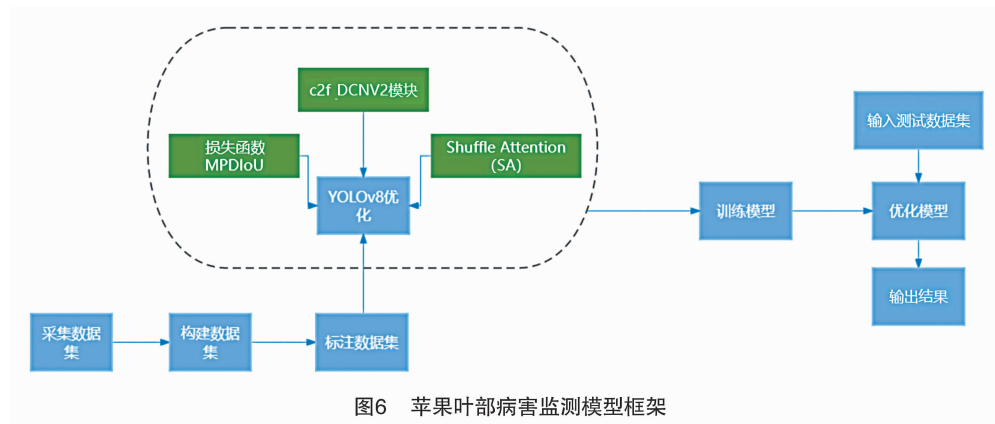


图6 苹果叶部病害监测模型框架

Backbone: SA 注意力机制位于主干网络 (backbone) 的末尾,紧跟在空间金字塔池化 (SPPF) 层之后。在整个模型架构中,主干网络负责从输入图像中提取基础特征,而 SA 注意力机制的引入,是为了在该过程的最后阶段进一步增强模型对特征的注意和提取效率。通过在主干网络的深层部分引入 SA 机制,YOLO v8 能够更有效地捕捉和利用复杂的特征关系,从而提升目标检测的性能,进一步实现轻量化。

Neck:模型的头部深层部分,特别是在处理特征金字塔的最终阶段。位于 Backbone (主干网络) 和 Neck (特征融合网络) 之后,负责最终的目标检测

任务。Neck 在准备进行最终目标检测的阶段,通过使用可变形卷积技术,增强模型对小尺寸目标的检测能力,同时增加对目标形状和姿态变化的适应性,使模型变得高效、快速。

通过引入 MPDIoU 损失函数来替代 CIoU 损失函数,能够更稳定地引导模型收敛,避免训练过程中的震荡或者收敛速度过慢,最终提高检测精度。

2 试验结果与分析

2.1 试验环境

本试验于 2023 年 6—11 月在塔里木大学南疆特色农林产物利用与装备兵团重点实验室 (40.54°N,

81.29°E) 进行。训练平台硬件: Intel® Core™ i7 – 11700, 运行内存为 32 GB, GPU 为英伟达 GTX3080TI, 显存大小为 12 GB。操作环境配置: 操作系统为 Windows 10, 编程语言为 Python 3.7, 深度学习框架版本为 1.8.0, 搭配的 CUDA 版本为 11.1。

2.2 评价指标

采用精确度 (precision, P)、召回率 (recall, R)、平均精度 (average precision, AP) 及平均精度均值 (mean average precision, mAP)^[25] 作为评估指标, 其中 P 量度正样本检测的准确性; R 评估正样本检测的全面性; AP 计算单一类别下精确度 – 召回率曲线的积分面积; mAP 为所有类别 AP 的均值, 反映整体性能。

$$P = \frac{TP}{TP + FP} \times 100\%; \quad (6)$$

$$R = \frac{TP}{TP + FN} \times 100\%; \quad (7)$$

$$AP = \int_0^1 P(R) dR; \quad (8)$$

$$mAP = \frac{1}{m} \sum_{i=1}^m AP_i. \quad (9)$$

式中: m 代表样本的类别总数; $p(r)$ 是以 Recall 为参数的 Precision 函数; TP (true positives) 表示被正确分类的正样本数量; TN (true negatives) 指的是被正确分类的负样本的数量; FP (false positives) 是指被错误地标记为正样本的负样本数量。

2.3 消融试验

为验证算法的有效性, 本研究执行消融试验。

为保证对比的合理性, 所有模型均使用相同的数据集, 并在相同的参数环境下进行训练, 共试验 5 种不同的改进方法。在 epoch 被设为 250 时, 试验模型的对比结果如表 2、图 7 所示。改进 1 引入 Shuffle Attention (SA) 注意力机制, 可在特征提取的最后阶段进一步增强模型对特征的注意和提取效率, 从而提升目标检测的性能, 进一步实现轻量化。改进 2 是在 YOLO v8 框架中引入 Deformable Conv v2 (可变形卷积 v2), 以增强模型对小尺寸目标的检测能力, 同时增加对目标形状和姿态变化的适应性, 使模型变得高效、快速。改进 3 以 YOLO v8 为框架, 引入 MPDIoU 损失函数, 用来替代 CIoU 损失函数, 能够更稳定地引导模型收敛, 避免训练过程中的震荡或收敛速度过慢, 最终提高检测精度。改进 4 将 Shuffle Attention (SA) 注意力机制紧紧放在空间金字塔池化 (SPPF) 层之后, Neck 部分采用 Deformable Conv v2 (可变形卷积 v2) 与 c2f 相结合的模块, 以提升复杂背景下的性能, 从而提高识别准确度。最后将改进 1、改进 2、改进 3、改进 4 集成在一起, 综合考虑多尺度特征、全局和局部特征以及更强的特征提取能力, 使模型能够更好地捕捉全局和局部特征, 这有助于模型更准确地定位和识别苹果叶部病害。结果表明, 本研究算法的精确度、召回率、 $mAP@0.5$ 分别较原 YOLO v8 上升 3.6、1.0、3.5 百分点, 说明本研究算法在苹果叶部病害特征的识别和定位上更加优秀。

表 2 消融试验

模型	Shuffle Attention (SA)	Deformable Conv v2	MPDIoU (损失函数)	精确度 (%)	召回率 (%)	$mAP@0.5$ (%)	$mAP@0.5:0.95$ (%)
YOLO v8	–	–	–	90.0	93.5	93.7	64.2
改进 1	✓	–	–	90.2	93.1	95.4	62.3
改进 2	–	✓	–	92.4	92.8	95.7	67.8
改进 3	–	–	✓	91.7	94.2	94.0	62.1
改进 4	✓	✓	–	93.1	92.4	96.8	64.2
本研究算法	✓	✓	✓	93.6	94.5	97.2	68.8

2.4 对比试验

为评估本研究提出模型的性能, 选取 Faster R – CNN^[23]、YOLO v5、YOLO v8 以及本研究改进算法, 共计 4 种网络模型, 在统一训练环境及自建数据集上进行比较试验。从准确率、召回率、 $mAP@0.5$ 、检测速度等方面进行对比试验, 所有数据均使用平均值。从表 3 得出, 对于苹果叶部病害目标检测场景, 一般卷积神经网络 Faster R – CNN 的检测效果较

差, 改进后的模型检测效果较优秀, 本研究算法的平均精度值 $mAP@0.5$ 比 Faster R – CNN、YOLO v5 模型分别提高 32.9、27.9 百分点, 比 YOLO v8 模型提高 3.5 百分点。

除此之外, 在 1 000 幅测试集图片上进行对比试验, 不同模型对各种病害的平均检测精度如表 4 所示。改进后的模型在测试集上对各种病害的平均检测精度明显优于其他模型, 展现出更高的准确

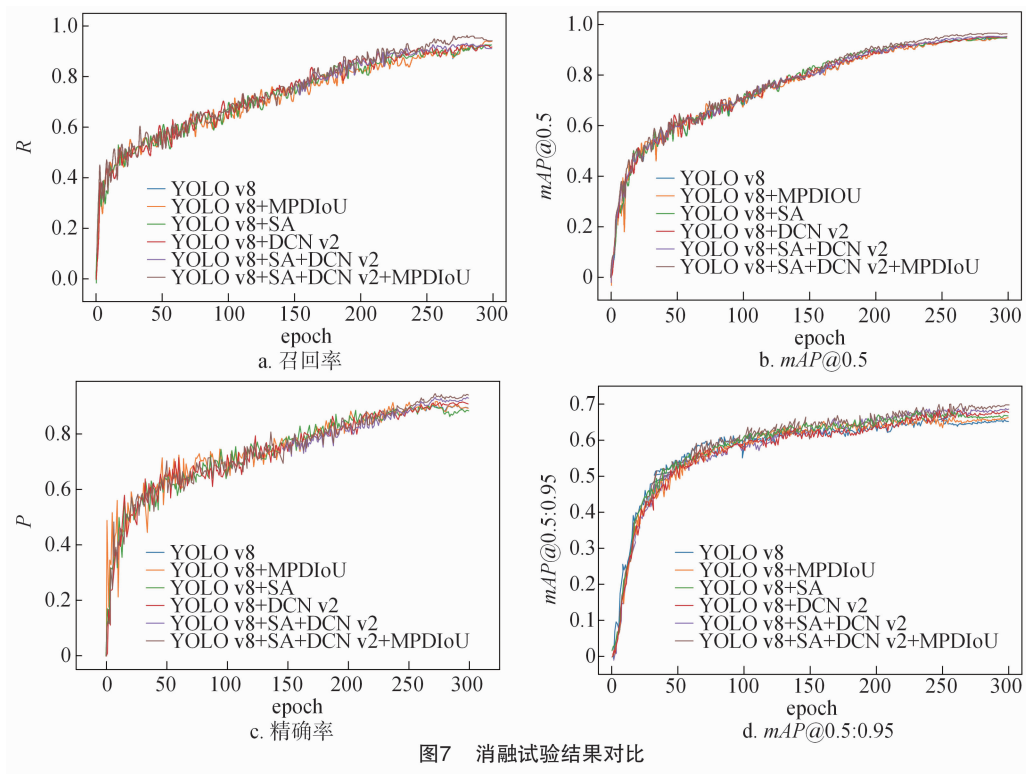


图7 消融试验结果对比

表3 不同模型检测效果对比试验

模型	输入尺寸	$mAP@0.5$ (%)	$mAP@0.5:0.95$ (%)	浮点运算数 GFLOPs
Faster R-CNN	640×640	64.3	27.6	226.6
YOLO v5	640×640	69.3	23.9	15.8
YOLO v8	640×640	93.7	64.2	8.2
本研究算法	640×640	97.2	68.8	7.9

表4 不同模型对病害的平均检测精度对比

病害类型	平均检测精度 (%)			
	Faster R-CNN	YOLO v5	YOLO v8	本研究算法
斑点落叶病	65.2	71.6	82.4	88.2
褐斑病	77.2	72.5	94.9	93.4
灰斑病	59.5	71.8	98.1	99.2
锈病	77.9	78.5	93.9	96.6
黑腐病	66.1	68.0	86.0	90.6

度和召回率,在不同病害种类上取得了更好的检测结果(图8)。这意味着本研究提出的模型能够更精确地定位和识别各种病害,从而提高病害检测的整体性能。

3 结论与讨论

针对苹果的5种叶部病害,本研究采用 Mixup、Mosaic、Random 等数据增强方法对病害数据进行扩充,增强特征表达能力,通过 LabelImg 工具对苹果

叶部病斑进行标注。

本研究提出一种改进的 YOLO v8 目标检测模型,针对所用数据集分辨率较低且目标多为小目标的特点,在主干网络空间金字塔池化(SPPF)层之后引入 Shuffle Attention(SA)注意力机制,在头部检测时通过加入 Dcnv2 与 C2f 相结合的模块,提高网络对低分辨率图像的检测效果,同时增强对目标形状和姿态变化的适应性,使模型变得高效、快速。最后引入目标损失函数 MPDIoU,解决 CIoU 损失函数的局限性,提高模型检测的准确率。改进后模型的目标检测精确率为 93.6%, $mAP@0.5$ 达到 97.2%,相较原始模型分别提升 3.6、3.5 百分点。

本研究方法能够快速准确地检测出苹果叶片上不同种类的病斑,通过检测病斑的形态、大小、颜色、分布等特征,初步判断苹果叶部病害发生的严重程度,有助于及时采取相应的防治措施,对苹果园的危害管理和控制具有积极的意义。然而本研究算法的计算量与原 YOLO v8 模型相比并没有明显降低,在减少模型的参数量和计算负担上还有优化空间,还需对网络结构作进一步改进,使其更加轻量高效。

参考文献:

[1] 李娜,田云龙,张蕾,等. 中国化肥减量增效行动与技术研究

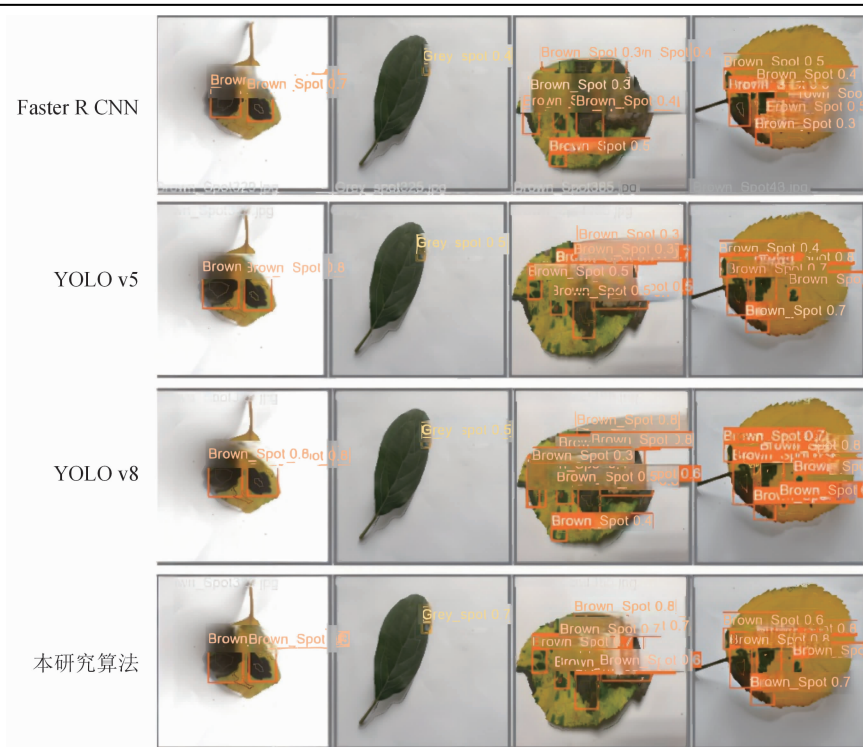


图8 不同检测模型的检测效果

- [J/OL]. 农业资源与环境学报, (2024 - 03 - 11) [2024 - 06 - 09].
- [2] 王权顺, 吕 蕾, 黄德丰, 等. 基于改进 YOLO v4 算法的苹果叶部病害缺陷检测研究[J]. 中国农机化学报, 2022, 43 (11): 182 - 187.
- [3] Jiang P, Chen Y H, Liu B, et al. Real - time detection of apple leaf diseases using deep learning approach based on improved convolutional neural networks[J]. IEEE Access, 2019, 7: 59069 - 59080.
- [4] Sun H N, Xu H W, Liu B, et al. MEAN - SSD: a novel real - time detector for apple leaf diseases using improved light - weight convolutional neural networks[J]. Computers and Electronics in Agriculture, 2021, 189: 106379.
- [5] 刘 斌, 徐皓玮, 李承泽, 等. 基于快照集成卷积神经网络的苹果叶部病害程度识别[J]. 农业机械学报, 2022, 53 (6): 286 - 294.
- [6] 张 航, 程 清, 武英洁, 等. 一种基于卷积神经网络的小麦病害识别方法[J]. 山东农业科学, 2018, 50 (3): 137 - 141.
- [7] 贾少鹏, 高红菊, 杭 潇. 基于深度学习的农作物病虫害图像识别技术研究进展[J]. 农业机械学报, 2019, 50 (增刊 1): 313 - 317.
- [8] Deng F, Pu S L, Chen X H, et al. Hyperspectral image classification with capsule network using limited training samples[J]. Sensors, 2018, 18 (9): 3153.
- [9] 龙 阳, 肖小玲. 基于多注意力机制的苹果叶部病害检测方法[J]. 江苏农业科学, 2023, 51 (23): 178 - 186.
- [10] 王金鹏, 何 萌, 甄乾广, 等. 基于 COF - YOLOv 8n 的油茶果静、动态检测计数[J]. 农业机械学报, 2024, 55 (4): 193 - 203.
- [11] Zhang X H, Li H L, Sun S H, et al. Classification and identification of apple leaf diseases and insect pests based on improved ResNet - 50 model[J]. Horticulturae, 2023, 9 (9): 1046.
- [12] 陈佳慧, 王晓虹. 改进 YOLO v5 的无人机航拍图像密集小目标检测算法[J]. 计算机工程与应用, 2024, 60 (3): 100 - 108.
- [13] 张艳宁, 王 鹏, 张 磊, 等. 面向无人移动平台的自主进化学学习研究进展与展望[J]. 科学通报, 2023, 68 (35): 4821 - 4843.
- [14] Huangfu Z M, Li S Q. Lightweight you only look once v8: an upgraded you only look once v8 algorithm for small object identification in unmanned aerial vehicle images[J]. Applied Sciences, 2023, 13 (22): 12369.
- [15] Yue X, Qi K, Na X Y, et al. Improved YOLO v8 - Seg network for instance segmentation of healthy and diseased tomato plants in the growth stage[J]. Agriculture, 2023, 13 (8): 1643.
- [16] Qian K, Wang S Q, Zhang S J, et al. SiamPKHT: hyperspectral Siamese tracking based on pyramid shuffle attention and knowledge distillation[J]. Sensors, 2023, 23 (23): 9554.
- [17] 陈 军, 孙丽丽, 孟洪兵, 等. 融合瓶颈注意力模块的改进 YOLO v7 织物疵点检测算法[J]. 棉纺织技术, 2024, 52 (3): 53 - 60.
- [18] 赵宗扬, 康杰虎, 吴 斌, 等. 基于 FRL - Net 的高鲁棒性多尺度小样本轨道入侵异物检测方法研究[J]. 仪器仪表学报, 2024, 45 (1): 239 - 249.
- [19] Sharma S, Kumar V, Rana K P S. Automatic oscillations detection and quantification in process control loops using linear predictive coding[J]. Engineering Science and Technology, an International Journal, 2020, 23 (1): 123 - 143.
- [20] 刘 鑫, 马本学, 李玉洁, 等. 基于改进 YOLO v7 - ByteTrack 的干制哈密大枣缺陷检测与计数系统[J]. 农业工程学报, 2024, 40 (3): 303 - 312.

王九玲,周会国,李文峰. 基于轻量化密集尺度网络的番茄叶片病害识别算法[J]. 江苏农业科学,2025,53(5):156-164.

doi:10.15889/j.issn.1002-1302.2025.05.019

基于轻量化密集尺度网络的番茄叶片病害识别算法

王九玲¹,周会国²,李文峰³

(1. 安阳职业技术学院,河南安阳 455000; 2. 郑州大学信息工程学院,河南郑州 450001;

3. 中国空间技术研究院西安分院,陕西西安 710100)

摘要:番茄叶片病害识别是农业智能化的重要应用之一,准确快速的病害识别对于番茄的健康生长和高产至关重要。然而,现有的模型在实际应用中常常由于背景复杂、病害尺度不一致等原因,难以实现高效准确的识别。因此,本研究提出了一种轻量化密集尺度网络,以提高番茄叶片病害识别的准确性和效率,并能够在低成本设备上实现快速识别。首先,网络通过使用不同扩张率卷积的密集连接结构,增强了对不同尺度病害的适应能力。具体来说,通过在网络中引入多种扩张率的卷积核,使得模型能够更好地捕捉到不同尺度病害的特征。其次,采用协调注意力尺度融合方法,替换了传统的拼接连接。此方法能够在不同尺度特征之间建立更加紧密的联系,提升特征提取的有效性,从而增强整体模型的识别能力。结果表明,优化后的模型在测试数据集上的准确率达到 0.968,优于现有的重量级网络(AlexNet、VGG16、VGG19 和 ResNet50)和轻量级网络(DenseNet121、GoogleNet、MobileNet、ShuffleNet v2 和 GhostNet)。本研究为实现低成本设备上的高效番茄叶片病害识别提供了新的方法和思路,具有重要的理论意义和实际应用价值。

关键词:密集尺度网络;轻量化;番茄叶片病害;多尺度变化

中图分类号:S126;TP391.41 **文献标志码:**A **文章编号:**1002-1302(2025)05-0156-09

番茄是世界上最重要的蔬菜作物之一,具有丰富的营养价值和广泛的经济效益^[1-3]。全球番茄产量占据重要地位,我国更是世界上最大的番茄生产国之一。然而在生长过程中,番茄容易受到各种病原菌、害虫等的侵害,导致产量和品质严重下降,给农业生产带来重大损失^[4]。随着设施农业的发展和消费者对番茄品质的要求提高,番茄叶片病害的防控成为了一个亟待解决的问题。因此,准确及时地识别和诊断番茄叶片病害,是实现番茄病害防治

和智能化病害管理的关键技术。

长期以来,番茄叶片病害识别主要依赖于人工观察和经验判断,这种方法不仅耗时耗力,识别结果也容易受到人为因素的影响,导致判断存在不准确性和不稳定性^[5]。近些年,随着数字图像处理、计算机视觉以及机器学习等技术的快速发展,基于图像的番茄叶片病害自动识别技术逐渐成为研究热点^[6-8]。这种方法通过对采集的番茄叶片图像进行预处理、特征提取以及分类识别等过程,实现对常见番茄叶片病害的自动检测和识别,可有效提高识别效率和准确率^[9]。充分利用这些前沿技术,开发快速精准的番茄叶片病害识别系统,对促进番茄病害的防治与智能化管理意义重大。

陈智超等采用 Bi-LSTM(双向长短期记忆网络)和多尺度卷积神经网络相结合的模型,通过双

收稿日期:2024-07-01

基金项目:国家自然科学基金(编号:62002330)。

作者简介:王九玲(1988—),女,河南安阳人,硕士,讲师,主要从事计算机技术研究。E-mail:wangmin213a@163.com。

通信作者:周会国,博士,教授,主要从事计算机应用研究。E-mail:zhouhuiguo1979@163.com。

[21] Xie Y H, Yin B, Han X W, et al. Improved YOLO v7 - based steel surface defect detection algorithm [J]. Mathematical Biosciences and Engineering, 2024, 21(1): 346 - 368.

[22] Iqbal J, Munir M A, Mahmood A, et al. Leveraging orientation for weakly supervised object detection with application to firearm localization [J]. Neurocomputing, 2021, 440: 310 - 320.

[23] 刘毅君,何亚凯,吴晓媚,等. 基于改进 Faster R-CNN 的马铃薯发芽与表面损伤检测方法[J]. 农业机械学报, 2024, 55(1):

371 - 378.

[24] 舒振宇,秦昊. 基于 SKNet 注意力机制的飞机类型识别算法[J]. 中南民族大学学报(自然科学版), 2024, 43(1): 69 - 77.

[25] 麻斯亮,许勇. 最小点距离的边界框回归损失函数及其应用[J]. 小型微型计算机系统, 2024, 45(11): 2695 - 2701.

[26] 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.