

张凯萍,李国霞. 基于改进 YOLOX 的实时马铃薯叶片病害检测方法[J]. 江苏农业科学,2024,52(20):199-208.

doi:10.15889/j.issn.1002-1302.2024.20.024

# 基于改进 YOLOX 的实时马铃薯叶片病害检测方法

张凯萍<sup>1</sup>, 李国霞<sup>2</sup>

(1. 许昌电气职业学院信息工程系,河南许昌 461002; 2. 郑州大学物理学院,河南郑州 450001)

**摘要:**随着深度学习在图像识别领域的广泛应用,目标检测算法已取得显著进展。然而,在农业病害检测特别是马铃薯叶病害检测方面,仍面临诸多挑战,如自然光影响和数据不平衡问题等。为此,提出一种改进 YOLOX 的马铃薯叶病害检测方法。首先以轻量化 MobileNet v3 网络作为骨干替换原有的 CSPDarkNet53 网络,以提高模型在特征提取上的效率,同时减少计算量。其次引入 V 通道网络,增加模型对复杂光照环境的适应性,更精确地捕获纹理信息。最后设计一种自适应的交叉熵损失函数,以解决样本不平衡的问题,确保模型的鲁棒性和准确性。在公开数据集 PlantVillage 上进行试验验证,结果表明,改进模型平均准确率、浮点运算次数、内存和 FPS 分别为 98.55%、 $14.63 \times 10^9$  次、49.35 MB、125.92 帧/s。相比原始 YOLOX 模型,平均准确率和单帧识别速度分别提高 4.38 百分点、36.65%;浮点运算次数和内存分别降低 43.23%、34.33%。此外,与不同模型对比试验以及嵌入式平台上的试验结果均表明,本研究提出的改进 YOLOX 模型在准确率、计算效率和速度方面均具有明显的优势,为农作物叶片病害检测提供了一种有效的解决方案。

**关键词:**马铃薯病害检测;YOLOX;MobileNetv3;V 通道网络;交叉熵损失

**中图分类号:**S126;TP391.41 **文献标志码:**A **文章编号:**1002-1302(2024)20-0199-10

马铃薯是全球最重要的粮食作物之一,年产量近 3 亿 t,为全球超过十亿人口提供稳定的食物来源<sup>[1]</sup>。除了其在食品产业的核心地位,马铃薯在多个工业领域也有广泛应用<sup>[2]</sup>。然而,该农作物频繁地受到各种病害的侵袭,尤其是叶片病害,如晚疫病和早疫病。这些病害不仅可以影响植物的茎、根和果实,还可能严重损害作物的质量和产量。晚疫病和早疫病等疾病在早期阶段对于种植者来说常常难以识别<sup>[3]</sup>。因此,及时和准确地诊断叶片病害对于减缓经济损失至关重要。

传统的病害诊断方法主要依赖农民的经验 and 观察,这在准确性和可靠性上有局限。先进的诊断技术如光谱仪<sup>[4]</sup>和聚合酶链式反应<sup>[5]</sup>虽提高了诊断精度,但高成本和操作复杂性限制了其广泛应用。近年来,深度学习和卷积神经网络(CNN)的发展为农业病害检测带来了技术革命,并被证明是一种高效的作物病害识别方法<sup>[6-8]</sup>。例如,Khan 等成

功地运用 VGGNet-16 和 AlexNet 分离出感染区域并提取病害特征,实现了高达 98.6% 的识别准确率<sup>[9]</sup>;Liu 等设计了一种创新的特征提取结构,并通过引入密集连接策略显著提高了葡萄叶病害的识别准确性<sup>[10]</sup>。然而,大多数研究仍专注于单一类型的病害识别,限制了其在实际应用中的广泛性。

近年来,目标检测算法因能同时识别和定位多种病害而受到关注<sup>[11-13]</sup>。目标检测算法主要可分为两大类:第 1 类是基于候选框的双阶段目标检测算法,如 R-CNN、Fast R-CNN 和 Faster R-CNN<sup>[14-16]</sup>。这些算法首先从图像中提取候选区域,然后进行二次精细化,从而实现高精度的目标检测。如 Khalifa 等专门为马铃薯的早疫病和晚疫病设计了一种优化的 Faster-CNN 模型<sup>[17]</sup>;Zhang 等成功地应用改进的 Faster-CNN 模型来诊断番茄的多种病害<sup>[18]</sup>。虽然这些算法在病害检测精度上表现出色,却因其复杂的计算结构,难以在移动平台上实现实时应用。第 2 类是单阶段目标检测算法,这类算法更加注重检测速度,如 YOLO 系列和 SSD<sup>[19-22]</sup>,如赵越等成功地采用 YOLO v3 模型实现了马铃薯叶病害的准确诊断<sup>[23]</sup>;Rashid 等则利用 YOLO v5 开发了一种多级检测模型,并构建了一个全新的病害检测数据集<sup>[24]</sup>。Liu 等的研究也展示了

收稿日期:2023-10-06

基金项目:国家自然科学基金(编号:62002330)。

作者简介:张凯萍(1983—),女,河南许昌人,硕士,副教授,研究方向为机器学习、目标检测。E-mail:zhangkp1983@163.com。

通信作者:李国霞,教授,主要从事农业信息技术、计算机视觉研究。E-mail:zhangkp1983@163.com。

单阶段目标检测算法在多种植物病害诊断中的有效性,这些算法更适合用于资源有限的设备<sup>[25-27]</sup>。

尽管现有目标检测算法在准确性方面取得了显著进展,但在植物叶病害检测领域,仍然存在 3 个未解决的关键问题。(1)大多数算法过分侧重于特定数据集上的高准确性,却常常忽略了模型在资源有限的硬件平台上的实用性,这就产生了一个实际问题:如何在不牺牲准确性的前提下,优化模型以适应硬件限制;(2)现有研究往往未能充分考虑到自然环境下复杂的光照条件,这些变化容易引起色彩偏移,从而影响模型的检测准确性;(3)虽有理论突破,但嵌入式设备上的应用几乎是空白的,需验证其实用性和可行性。这些问题不仅是理论上的关注点,也影响农业实践的效率和准确性。

为解决以上问题,实现更精确和高效的马铃薯叶片病害检测,本研究基于 YOLOX 架构设计一种实时马铃薯叶片病害检测模型。使用 MobileNet v3 作为模型的骨干网络,以减轻计算负担和内存需求,保证模型不仅在高性能计算环境中有效,同时

也适用于资源受限的设备。为使模型在不同光照条件下都能保持较高的准确率,设计一个 V 通道定位网络,生成一组与 YOLOX 模型预测层尺度相匹配的特征图,以便更准确地捕捉由光照引发的纹理和颜色变化,提高模型对光照变化的鲁棒性。针对样本不平衡问题,提出一种自适应的惩罚系数,加快模型的收敛速度,进一步提升马铃薯叶片病害检测的性能。最后将所提方法部署在嵌入式设备上,以验证其能否满足实时和高精度的病害检测需求。

## 1 数据与方法

首先选定了一个合适的数据集并进行了数据增强,以模拟多种实际应用场景。其次,基于 YOLOX 框架,开发一个针对马铃薯叶片病害的改进识别算法。为全面验证模型性能,设计消融试验和与其他先进方法的对比试验,明确了模型的优缺点。进一步,将模型部署到嵌入式设备,验证其可行性和实用性。本研究框架如图 1 所示。

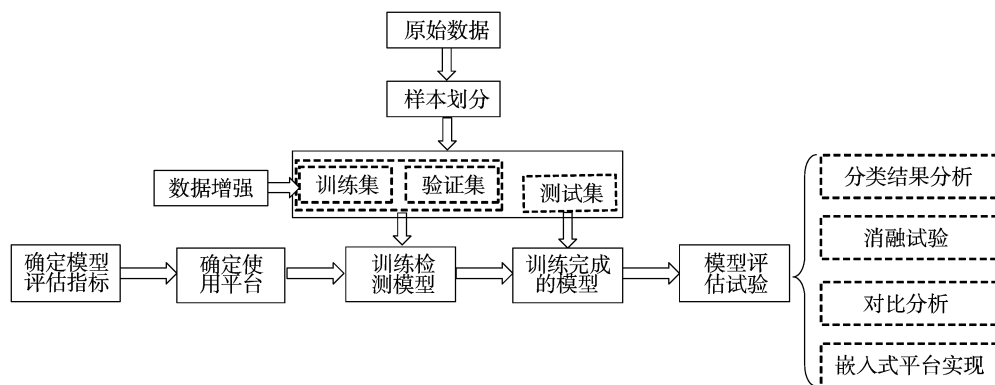


图1 马铃薯叶片病害检测研究框架

### 1.1 数据获取与处理

本研究使用公开可获取的 PlantVillage 数据集作为图像数据源,该数据集含有 54 309 张高质量图像,覆盖了 14 种不同农作物,例如苹果、蓝莓、樱桃、玉米等。本研究主要关注马铃薯叶片病害的自动检测,原始样本图片共 2 152 张,分辨率为 256 像素×256 像素,主要包括早疫病、晚疫病和健康叶片这 3 个类别,其详细描述见表 1。

本研究将 2 152 张马铃薯叶片图像依照 8:1:1 的比例分配到训练集、验证集和测试集中。鉴于样本数量有限可能引发过拟合,采用 CycleGAN<sup>[24]</sup> 这一先进的数据增强方法对训练样本进行优化,主要通过旋转、裁剪、翻转等手段来增加

样本多样性。增强后的数据集细节请参见表 2。

为进一步提高模型的准确性和可靠性,使用 Labeling 图形注释工具对表 2 中的图像样本进行精细的手动标注。在每张图像上,不论是健康或患病的叶片,都被准确地用一个矩形边界框标出。其位置坐标以  $(x_{\min}, y_{\min}, x_{\max}, y_{\max})$  形式给出。其中  $(x_{\min}, y_{\min})$  代表边界框左上角的坐标,  $(x_{\max}, y_{\max})$  代表边界框右下角的坐标。

经过以上的数据处理和增强,成功地扩大了样本数量,为后续模型的训练打下了坚实的基础。

### 1.2 马铃薯叶片病害检测方法

马铃薯叶片病害检测属于目标检测任务,其目的是在图像中准确定位和分类不同区域的病害。

表 1 马铃薯叶片类别图像及症状




类别	图像	症状	数量(张)
早疫病		初现于老叶,表现为小的黑色或深褐色斑点。该病害可能导致叶片枯萎,影响作物的光合作用,从而减少产量	1 000
晚疫病		在叶片边缘出现湿润的褐色或黑色斑点,迅速扩大导致叶片枯萎。病害能快速传播,有时可致整株作物死亡	1 000
健康叶片		健康的马铃薯叶片呈鲜绿色,无斑点或枯萎,是高产和良好光合作用的基础	152

表 2 数据增强后样本信息

张

类别	训练集		验证集	测试集
	原始样本	新增样本		
早疫病	800	800	100	100
晚疫病	800	800	100	100
健康叶片	122	150	15	15
总数	1 722 + 1 750 = 3 472		215	215

为了适应资源受限的设备环境,选用高效的 YOLOX 模型作为基线模型,进一步设计一种更为高效和精准的马铃薯叶片病害检测模型<sup>[28]</sup>。该模型力求实现目标检测准确性与计算效率之间的最优平衡,确保在资源有限的应用场合中仍能展示出卓越的性能。

**1.2.1 YOLOX 模型** YOLOX 是一种不依赖先验框的单阶段目标检测模型,其由 CSPDarkNet53 主干网络、特征金字塔网络(FPN)、路径聚合网络(PAN)和预测头(Head)四大核心模块组成<sup>[28-29]</sup>。这些模块联合工作,实现了对目标检测任务的高效准确处理。

在 YOLOX 的工作流程中,CSPDarkNet53 首先作为特征提取器,从输入图像中提取出基础视觉特征。接着,FPN 构建了一个多层次的特征图,实现了对不同尺寸和复杂度目标的高效识别。它将主干网络提取的高级和低级特征融合,增强对小目标的检测性能。PAN 进一步优化以上流程,它通过上下采样和横向连接,强化 FPN 中不同层级特征图之

间的信息传递,提升模型在多尺度目标检测上的表现。最后,Head 的 Cls 分支对目标框内的对象进行属性分类并预测类别概率;Reg 分支预测目标框的精确坐标;Obj 分支判断目标框内对象是前景还是背景。这 3 个分支共同输出目标的分类标签和具体的边界框坐标,完成目标的最终分类和定位。总体而言,YOLOX 模型在复杂场景和多尺度目标检测方面表现优秀,但也存在一些不足,如计算复杂度高和对复杂光照、低对比度环境的识别能力有限。尽管一些研究尝试通过引入通道注意力机制来改善这些问题,提高模型对关键特征的敏感性和整体的检测精度,但这些改进仍有局限性。

为进一步提升模型的性能和适用范围,本研究基于前人的工作进行了一系列创新性的优化。首先,用轻量级的 MobileNet v3 网络替代原始的 CSPDarkNet53 主干网络。这一改变旨在减少计算负担并提高模型在资源受限环境下的运行效率。其次,引入 V 通道网络以增强模型在复杂光照条件下的目标检测准确性。最后,设计一种自适应的交叉熵损失函数,以提升模型的鲁棒性,同时增加模型的识别准确性。

**1.2.2 轻量化骨干网络** 为优化模型的计算效率和实时性能,选用更为轻量级的 MobileNet v3 网络替代原有的 CSPDarkNet53 主干网络<sup>[30]</sup>,其基本结构如图 2 所示。

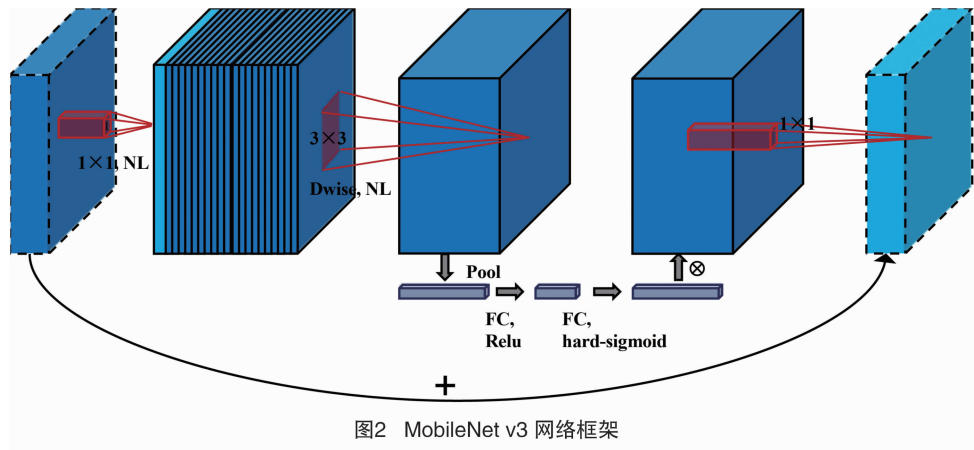


图2 MobileNet v3 网络框架

MobileNet v3 继承了 MobileNet v1 和 v2 的核心优点,尤其突出了深度可分离卷积 (Depthwise Separable Convolutions, 简称 DSC) 和反向残差块的应用。DSC 是一种高效的卷积方法,它通过分解传统卷积操作以减少计算量。具体而言,DSC 首先在每个输入通道上独立应用卷积,然后再通过  $1 \times 1$  的点态卷积将这些通道的输出合并。这样做的优势是,与传统的  $3 \times 3$  卷积相比,DSC 能够将计算量减少到原来的  $1/9$  到  $1/8$ 。

MobileNet v3 还解决了非线性激活函数可能对低维特征造成的不良影响。具体地,其反向残差块通过 2 次  $1 \times 1$  的卷积操作实现特征维度的先升后降,以此减轻激活函数对原始特征的影响。此外,MobileNet v3 的反向残差块还引入了信道注意力模块 (squeeze-and-excitation, SE) 以提升网络对显著性特征的识别能力。

1.2.3 V 通道网络 为更有效地捕捉马铃薯叶片病害的纹理信息,引入了一种基于 HSV 颜色空间的特征提取策略。该策略致力于解决在自然环境下,由于光线、遮挡和阴影等因素,造成的图像亮度变化问题。3 种马铃薯叶病害的 HSV 颜色空间如图 3 所示。

在自然环境下捕获的图像常受到自然光、遮挡和阴影等因素的影响,导致对亮度极为敏感。而在 RGB 颜色空间 (图 3-a) 中,这些细微的亮度变化往往难以准确捕捉。为此,本文在 RGB 基础之上加入了一个 HSV 颜色空间分支,如图 3-b、图 3-d、图 3-e 所示。在 HSV 颜色空间中,H (色相) 通道描述颜色在光谱中的位置,其值域范围为  $0^\circ \sim 360^\circ$ ,S (饱和度) 通道反映所选颜色的纯度与其最大纯度之间的比例,V (明度) 通道反映了颜色的亮暗信息,其取值范围为  $0 \sim 1$ 。




图3 3种马铃薯叶病害的HSV颜色空间

在马铃薯叶片病害检测中, H 通道和 S 通道对颜色类型和纯度有良好的识别, 但它们容易受到自然环境中光照和阴影的影响, 导致特征信息的丢失或削弱。相较之下, V 通道专注于颜色的明暗度, 具有更高的敏感性和稳健性, 特别是在复杂的光照条件下。这使得 V 通道成为一个理想的选择, 能够更准确地捕捉和定位与病害相关的纹理信息。为此, 本研究设计一个专门的 V 通道定位网络, 其中采用了最大池化操作进行降采样。这不仅减少了计算的复杂性, 还生成了一组与 YOLOX 模型预测层尺度相匹配的特征图。这种设计精准地捕捉了与纹理相关的位置信息, 从而提高了模型在复杂环境下的病害检测精度。

1.2.4 自适应交叉熵损失 原始 YOLOX 模型采用 BCELoss 函数进行训练, 主要用于类别预测和置信度预测, 其数学表达式如公式(1)和公式(2)所示。

$$L_i = -y_i \ln y_i' - (1 - y_i) \ln(1 - y_i') \\ = \begin{cases} -\ln y_i', & y_i = 1 \\ -\ln(1 - y_i'), & y_i = 0 \end{cases}; \quad (1)$$

$$L_{BCE} = \frac{1}{n} \sum_{i=1}^n L_i. \quad (2)$$

式中:  $L_i$  为像素  $i$  生成的  $L_{BCE}$  值;  $y_i$  为像素  $i$  的真实标签, 正标签为 1, 负标签为 0, 表示前景对象类别和背景;  $y_i'$  为像素  $i$  的预测值, 取值范围为  $[0, 1]$ ;  $n$  为总像素数。

BCELoss 鼓励模型对每个样本的预测结果和实际标签接近。但这种损失函数并不考虑数据中各类别样本的分布情况。因此, 当面对数据分布严重不平衡的场景时, 仅依赖 BCELoss 可能会导致模型的预测存在显著的偏见, 特别是对少数样本的类别。从表 2 中的马铃薯叶片样本数据可以明显看出, 类别不平衡的问题是非常突出的。如果单纯地使用 BCELoss 作为损失函数进行训练, 可能会导致模型对多数样本的类别过度拟合, 而忽视了少数样本的类别, 进而导致严重的识别偏差。为此, 本文提出了一种样本自适应的交叉熵损失函数, 该函数通过一个自适应惩罚系数进行动态权重调整。具体的数学表达式为公式(3)至公式(6)。

$$\alpha = \begin{cases} \arctan\left(\frac{P+N}{P+\delta}\right) & y=1 \\ \arctan\left(\frac{P+N}{N+\delta}\right) & y=0 \end{cases}, \quad \alpha \in [0, \frac{\pi}{2}]; \quad (3)$$

$$\beta = \sin \alpha, \beta \in [0, 1]; \quad (4)$$

$$BCELoss_{\beta} = -\beta y \ln y' - \beta(1 - y) \ln(1 - y'); \quad (5)$$

$$L_{BCE-\beta} = \frac{1}{1 + \exp(BCELoss_{\beta})}. \quad (6)$$

式中:  $\beta$  为样本自适应惩罚系数;  $L_{BCE-\beta}$  为样本自适应交叉熵损失函数;  $P$  为网络训练反馈的正样本量总数;  $N$  为网络训练反馈的总负样本量;  $\delta$  为最小值。

样本自适应惩罚系数的引入使得损失函数能够根据训练过程中正负样本的数量进行自适应调整。例如, 当健康叶片的数量较少时, 该系数会增加健康叶片在损失函数中的权重, 从而强化模型对少数类的识别能力。反之, 如果病害叶片数量减少, 病害叶片的权重会相应提升。这种动态调整机制有助于模型在不同阶段保持正负样本间的平衡, 从而提高模型的稳定性和准确性。此外, 还使用了 Sigmoid 函数作为激活函数, 以确保损失值输出在  $[0, 1]$  范围内, 进一步增强模型的训练稳定性。

1.2.5 马铃薯叶片病害检测模型框架 马铃薯叶片病害检测模型结构如图 4 所示, 由 6 个核心模块组成, 包括主干网络 (Backbone)、V 字通道 (V channel)、注意力通道 (CBAM)、特征金字塔网络 (FPN)、路径聚合网络 (PAN) 和预测头 (Detection head)。本研究使用 MobileNet v3 网络作为主干特征提取, 并引入 V 字通道生成一组与主干网络尺度相配的特征图, 以便更准确地捕捉由光照引发的纹理和颜色变化, 其他模块和原有 YOLOX 模型保持一致。

## 2 马铃薯叶片病害检测试验

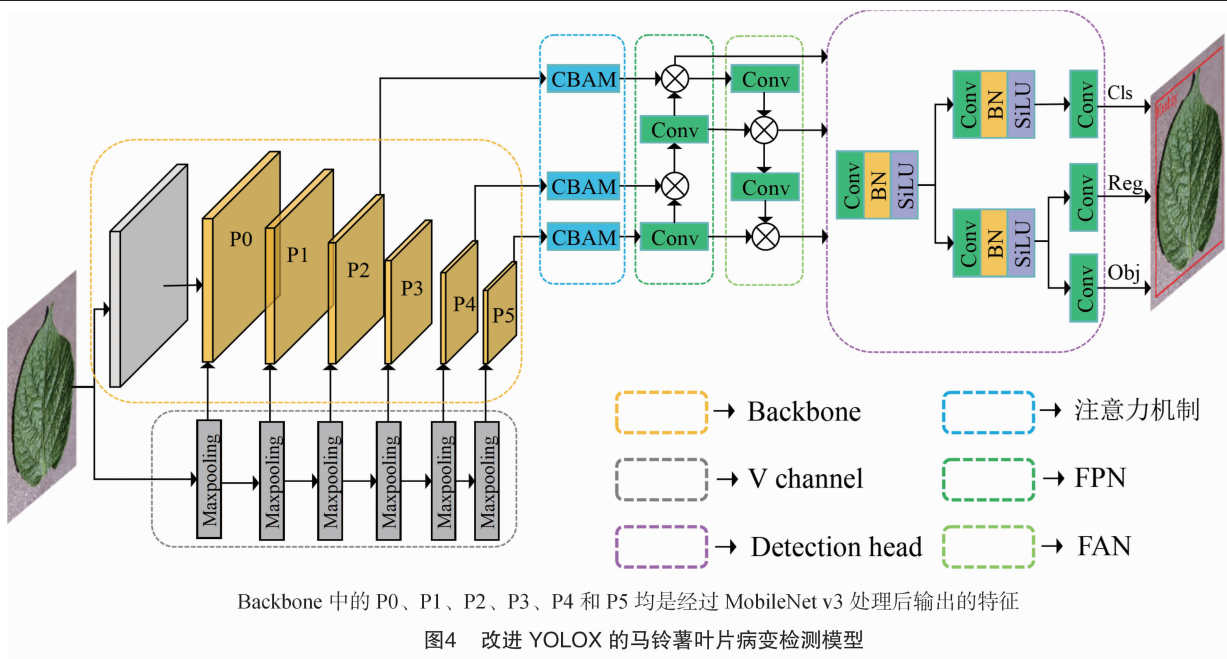
### 2.1 试验环境

本试验将使用一台配置较高的计算机进行所有模型训练, 以确保结果的一致性和可靠性。该机器配备了 12 代英特尔酷睿 i5 - 12400F CPU、NVIDIA GeForce RTX 3060 GPU 以及 16 GB 的运行内存。软件环境方面, 选择了 Ubuntu 20.04 作为操作系统, 使用 VScode 作为编译器工具, 并采用了支持 CUDA 11.3 的 PyTorch 1.10.1 框架。此次试验于 2023 年 8 月 25 日于许昌电气职业学院信息工程系 227 实验室完成。

### 2.2 评价指标

在本研究中, 模型性能的评估采用了多角度的指标。首先, 使用平均精度均值 (mean average precision, 简称  $mAP$ ) 来衡量模型在识别和分类马铃薯叶片病





害方面的准确性。 $mAP$  是一个综合性的指标,它计算了模型在所有类别上平均检测精度的平均值。具体而言, $mAP$  是根据召回率 (recall,  $R$ ) 和精度 (precision,  $P$ ) 在各个类别上计算的  $AP$  值的平均,其数学定义见公式(7)和公式(8),其中  $M$  表示病害类别。在这里,选用 0.5 作为评估标准。

$$AP = \int_0^1 P(R) dR; \quad (7)$$

$$mAP = \frac{\sum_{j=1}^M AP_j}{M}。 \quad (8)$$


除了关注模型的精度,还重点考虑了其计算效率和实用性。在这方面,模型的浮点运算次数 (FLOPs) 和内存 (Size) 被用作 2 个关键指标,用以衡量模型对计算资源的需求程度。低 FLOPs 数值通常意味着模型更为轻量级,因此更适用于资源受限的环境。同时,也采用单帧图像识别速度 (FPS) 作为另一个评价指标,以量化模型的实时性和识别

效率。高 FPS 值表明模型能够在短时间内处理更多的图像,这在需要实时反馈的应用场景中具有非常重要的意义。通过这 2 个综合性指标,不仅可以全面评估模型的性能,还能更准确地确定其在实际应用中的适用性和局限性。

### 2.3 模型训练

模型训练涉及多个设置和参数。具体来说,训练总共进行了 200 个 epoch,每个批次的大小设置为 4,优化器选用 SGD。输入图像的尺寸是 224 像素  $\times$  224 像素,学习速率设置为 0.001,权重衰减因子为 0.0005,而动量因子为 0.937。

图 5-a 展示了在 200 个 epoch 内,训练和验证损失的变化情况。尽管起初的损失值较高,但随着 epoch 数量的增加,损失值逐渐减少,大约在 150 个 epoch 后趋于稳定。同时,训练与验证损失在整个过程中保持了相对的一致性,表明模型既没有出现拟合也没有出现欠拟合。进一步地,图 5-b 显示



了模型在训练集上的  $mAP$  随损失减小而逐步提高。在完成 150 个 epoch 后,  $mAP$  值基本稳定, 并在 200 个 epoch 时达到了高达 98.6% 的准确度。

### 3 结果与分析

#### 3.1 分类结果分析

为直观地展示优化后的 YOLOX 模型在马铃薯叶片病害数据集上的识别与分类性能, 根据测试集结果绘制了一张混淆矩阵, 详见图 6。从总体表现来看, 该模型在识别晚疫病和健康叶片方面几乎达到了完美的准确率。然而, 在早疫病的识别上, 部分样本被错误地归为晚疫病, 这可能源于早疫病和晚疫病在某些特征, 如颜色和纹理等方面的相似性, 从而导致模型在区分这 2 种病害时出现一定程度的混淆。尽管如此, 考虑到植物病害识别本身的复杂性和挑战性, 该模型的整体表现仍然较为出色。

#### 3.2 消融试验

本研究设计的马铃薯叶片病害检测模型, 是在先进检测模型 YOLOX 框架上进行了一系列创新性的改进。具体而言, 所提模型以更轻量级 MobileNet

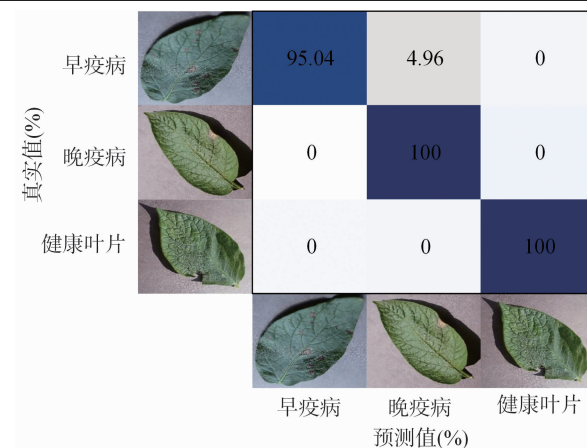


图6 3种马铃薯叶片病害的混淆矩阵

v3 网络替换原有的 CSPDarkNet53 网络, 同时引入 V 通道定位网络, 并提出一种自适应的交叉熵损失函数 ( $L_{BCE-\beta}$ ), 以实现更加精准和高效的马铃薯叶病害检测。为了量化这些改进措施带来的性能提升, 试验对比使用 CSPDarkNet53 与 MobileNet v3 作为骨干网络时, V 通道定位网络和自适应交叉熵损失函数对模型性能的具体影响, 各性能指标如表 3 所示。

表3 消融试验结果

模型	主干网络	V 通道	$L_{BCE-\beta}$	$mAP$ (%) ↑	FLOPs ( $\times 10^9$ 次) ↓	Size (MB) ↓	FPS (帧/s) ↑
YOLOX	CSPDarkNet53	—	—	93.87	25.77	75.15	92.15
		✓	—	94.85	25.84	77.33	90.33
		—	✓	95.60	25.77	75.15	92.19
		✓	✓	96.15	25.84	77.33	90.31
	MobileNet v3	—	—	95.44	14.51	48.64	127.20
		✓	—	96.82	14.63	49.35	125.44
		—	✓	97.47	14.51	48.64	127.18
		✓	✓	98.55	14.63	49.35	125.92

注:“✓”表示采用策略;“—”表示没有采用策略。

由表 3 可知, 当使用更轻量级的 MobileNet v3 作为检测模型的骨干网络, 相对于传统的 CSPDarkNet53, 模型在多个性能指标上都有明显提升。具体来说, 模型的  $mAP$  从 93.87% 增加到 95.44%, 实现 1.57 个百分点的提升。更值得注意的是, 模型的浮点运算次数 (FLOPs) 从  $25.77 \times 10^9$  次大幅降低到  $14.51 \times 10^9$  次, 减少了 43.69%; 内存从 75.15 MB 降低到 48.64 MB, 降低了 35.28%, 这意味着模型在保持高准确率的同时, 显著减少了计算复杂性和空间资源需求。此外, 模型的单帧识别速度 (FPS) 从 92.15 帧/s 提升至 127.20 帧/s, 提高

38.03%, 表明模型在实时性和识别效率方面也有显著改进。

进一步观察表 3, 可以明确地看出引入 V 通道定位网络和自适应交叉熵损失函数 ( $L_{BCE-\beta}$ ) 对模型精度具有正向积极的作用。以 CSPDarkNet53 为基础的模型在引入这 2 项改进后, 其  $mAP$  值从 93.87% 提升至 96.15%, 增幅为 2.28 个百分点。而以 MobileNet v3 为基础的模型则从 95.44% 提升至 98.55%, 增幅为 3.11 个百分点。值得一提的是, 这 2 项改进几乎没有增加模型的计算负担。具体来说, 无论是 FLOPs、Size 还是 FPS, 三者的变化都相对微

小,这进一步证实了这些改进措施在提高精度的同时,并没有对模型的计算效率和实时性造成不利影响。

综上,V 通道定位网络 and 自适应交叉熵损失函数的引入对模型的整体性能有所提升,尤其在采用 MobileNet v3 为骨干网络的情况下,这一效果更为显著。这不仅进一步证明了本研究所提改进策略的有效性,也表明了这些策略在实际应用中具有更广泛的适用性和优越性,确保了本研究提出的检测模型在马铃薯叶病害检测任务上有着更出色的表现。

### 3.3 对比试验

为进一步评估所提出改进 YOLOX 模型在目标检测方面的性能,在相同的数据集和硬件配置条件下,依据控制变量法原则,进行了一系列对比试验。这些对比试验涵盖了多种主流的目标检测算法,包括 Faster RCNN、SSD、RetinaNet、YOLO v5,以及原始版本的 YOLOX 模型。图 7 详细呈现了各检测模型在 4 个关键评估指标上的性能比较。

在马铃薯叶病害检测任务中,本研究的改进 YOLOX 模型在  $mAP$  方面表现出色,达到了 98.55%。这一结果显著优于目前主流的其他目标检测算法,如 Faster RCNN 的 97.27%。值得注意的是,尽管 Faster RCNN 在精度上与改进的 YOLOX 接

近,但在计算效率和实时性方面明显不足。

在计算复杂度方面,改进的 YOLOX 只需  $14.63 \times 10^9$  浮点运算次数(FLOPs)就能完成高精度的马铃薯叶病害检测,远低于 Faster RCNN 的  $75.62 \times 10^9$  浮点运算次数(FLOPs)和 RetinaNet 的  $87.6 \times 10^9$  浮点运算次数(FLOPs)。这一优势在实际应用中尤为重要,尤其是在需要快速、准确诊断的农业场景中。

在模型所占内存方面,改进的 YOLOX 模型仅为 49.35 MB,远小于 Faster RCNN (317.49 MB) 和 RetinaNet(292.3 MB)。这意味着在边缘计算或嵌入式系统中,改进的 YOLOX 模型更易于部署。最后,单帧识别速度上,改进的 YOLOX 以 125.92 帧/s 的速度运行,远高于其他所有模型。这一点对于实时马铃薯疫病检测尤为关键,可以有效地指导农民及时采取防治措施。

综合以上评估指标,改进的 YOLOX 模型在马铃薯疫病检测方面表现卓越,不仅在准确性上达到了高水平,同时也在计算复杂度、模型体积和实时性方面展示了明显优势。相较于 Faster RCNN、SSD、RetinaNet 以及原始版本的 YOLOX,改进的 YOLOX 在综合性能上具有明显优势。因此,该模型在马铃薯疫病检测的研究和应用中具有极高的价值。




图7 不同检测模型的性能对比

### 3.4 马铃薯叶病害检测

本研究所提的基于 YOLOX 的改进模型进行了马铃薯叶病害的详细检测和分类。图 8 展示了模型在多种场景下的高效性和准确性。模型成功区分

了早疫病、晚疫病和健康叶片 3 类,并在各自的 3 个不同实例上进行了有效验证。即便在早疫病和晚疫病的微小病变区域内,模型也展现了高度的敏感性和精确度。在所有测试场景中,模型的置信度得



分最低达到了 0.91。这一出色表现可归功于模型采用的先进骨干网络 MobileNet v3, 以及新增的 V 通道定位网络 and 自适应交叉熵损失函数。这些改进不仅增强了模型的特征提取能力, 还提升了其分类精度。值得一提的是, 模型即便在健康叶片出现非病害性质破损的情况下, 也能进行准确分类, 进一步证实了其鲁棒性。总体而言, 本模型在精确度和敏感性上达到了高标准, 特别是在处理复杂和微小的病害特征方面表现优异, 显示出广泛的应用潜力。




图8 改进 YOLOX 模型的检测结果可视化

### 3.5 嵌入式装置中马铃薯叶片病害的检测效果

为实际评估改进的 YOLOX 模型在马铃薯叶病害检测中的性能, 采用 NVIDIA Jetson Nano 作为边缘计算平台。该设备与农业检查机器人和马铃薯叶病害识别系统相结合, 能够在现场实时识别并标记出受病害的马铃薯叶片。软件环境包括 TensorRT-7.1.3.0 和 JetPack-4.4.1, 图像输入大小设置为 224 像素 × 224 像素。通过 TensorRT 的模型量化和优化, 本文在 Jetson Nano 上进行了模型检测精度 ( $mAP$ ) 和推理速度 (FPS) 测试。由于计算资源有限, 嵌入式装置测试中只测试了计算效率和体积较小的原始 YOLOX 和改进的 YOLOX 模型, 结果如表 4 所示。

表 4 对比了在嵌入式设备 NVIDIA Jetson Nano 上, 原始 YOLOX 模型和改进的 YOLOX 模型在  $mAP$  与 FPS 方面的性能。数据显示, 改进的 YOLOX 在  $mAP$  方面从 94.17% 上升至 98.55%, FPS 也从 2.17

帧/s 增加至 3.94 帧/s。更值得注意的是, 在利用 TensorRT 加速后, 该模型在保持相同  $mAP$  的同时, FPS 大幅提升至 10.37 帧/s。这些结果明确证实了改进的 YOLOX 模型在精度和速度上都有显著提升。尤其在应用 TensorRT 加速之后, 模型速度近乎提升了 5 倍, 从而更有效地满足了马铃薯叶片病害检测的实时性需求。综合来看, 改进的 YOLOX 模型在嵌入式环境中表现出了高效和高准确度, 具有很高的应用潜力。

表 4 嵌入式设备上的性能比较

模型	$mAP$ (%) ↑	FPS (帧/s) ↑
YOLOX	94.17	2.17
改进的 YOLOX	98.55	3.94
改进的 YOLOX - TensorRT (FP16)	98.55	10.37

## 4 结论与讨论

为精确高效地检测马铃薯叶病害, 提出一种基于改良 YOLOX 架构的先进识别方法。该方法以轻量级 MobileNet v3 替代原有的 CSPDarkNet53, 优化了特征识别和计算效率; 结合 V 通道定位网络, 精确捕捉纹理信息; 并应用自适应交叉熵损失函数解决了样本不平衡问题, 从而增强了模型的鲁棒性和准确性。

试验数据进一步证实了本研究中改进 YOLOX 模型的显著性能提升。该模型在  $mAP$  方面达到了 98.55%, 比原始 YOLOX 模型提高了 4.38 百分点。在计算效率方面, 模型的 FLOPs 为  $14.63 \times 10^9$  次, 内存占用仅为 49.35 MB, 分别比原始模型降低了  $11.14 \times 10^9$  次和 25.80 MB。此外 FPS 提升到 125.92 帧/s, 比原始模型快了 36.65%。综合性能对比分析也表明, 改进的 YOLOX 模型与 FasterCNN、SSD、RetinaNet 和 YOLO v5 等主流检测模型相比, 具有明显的优势。

在嵌入式平台测试中, 改进 YOLOX 模型平均准确率为 98.55%, 相比原始 YOLOX 模型提高了 4.38 百分点。进一步采用 TensorRT 加速后模型的检测速度为 10.37 帧/s, 实时检测速度得到显著提升。

综上, 本研究提出的改进 YOLOX 模型在准确率、计算效率和速度方面都表现出色, 不仅能推动农业病害检测技术的进一步发展, 也为相关领域提供了有价值的参考和启示。

本研究所提出的方法适用于公开的叶片数据集,但并未涉及受到实际光照等复杂环境影响的农田叶片数据。下一步,可利用无人机采集农田叶片数据集进行处理与测试,使模型可以更好地应用于农田生产实践。另外,可考虑使用一些传统机器学习与深度学习方法与本研究方法进行对比,以改进或选择最适于分析农田环境下由无人机采集的叶片图像的算法。

#### 参考文献:

- [1] 赵丙秀,董 宁. 基于 WOA-BP 神经网络下马铃薯产量预测分析模型[J]. 农机化研究,2024,46(3):47-51.
- [2] 刘崇林,赵胜雪,胡 军,等. 两种淀粉薯收获期茎秆机械特性的试验研究[J]. 农机化研究,2020,42(6):117-122.
- [3] 胡新元,孙小花,罗爱花,等. 叶面喷施硫酸锌对马铃薯抗病性和产量的影响[J]. 西北农业学报,2023,32(8):1187-1193.
- [4] 王 凡,李永玉,彭彦昆,等. 便携式马铃薯多品质参数局部透射光谱无损检测装置[J]. 农业机械学报,2018,49(7):348-354.
- [5] 刘二龙,魏 霜,关丽军,等. 马铃薯成分微滴数字聚合酶链式反应定量检测方法建立[J]. 粮食与油脂,2021,34(3):120-123.
- [6] Minaee S, Boykov Y, Porikli F, et al. Image segmentation using deep learning: a survey[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(7): 3523-3542.
- [7] Zhao Z Q, Zheng P, Xu S T, et al. Object detection with deep learning: a review[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(11): 3212-3232.
- [8] Chen X, Wan M J, Ma C, et al. Recognition of small targets in remote sensing image using multi-scale feature fusion-based shot multi-box detector[J]. Optics and Precision Engineering, 2021, 29(11): 2672-2682.
- [9] Khan M A, Akram T, Sharif M, et al. CCDF: automatic system for segmentation and recognition of fruit crops diseases based on correlation coefficient and deep CNN features[J]. Computers and electronics in agriculture, 2018, 155: 220-236.
- [10] Liu B, Ding Z F, Tian L L, et al. Grape leaf disease identification using improved deep convolutional neural networks[J]. Frontiers in Plant Science, 2020, 11: 1082.
- [11] Abbas A, Jain S, Gour M, et al. Tomato plant disease detection using transfer learning with C-GAN synthetic images[J]. Computers and Electronics in Agriculture, 2021, 187: 106279.
- [12] Zhang K K, Wu Q F, Chen Y P. Detecting soybean leaf disease from synthetic image using multi-feature fusion faster R-CNN[J]. Computers and Electronics in Agriculture, 2021, 183: 106064.
- [13] Saeed A, Abdel-Aziz A A, Mossad A, et al. Smart detection of tomato leaf diseases using transfer learning-based convolutional neural networks[J]. Agriculture, 2023, 13(1): 139.
- [14] 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, Columbus, OH, USA. IEEE, 2014: 580-587.
- [15] Girshick R. Fast R-CNN[C]//2015 IEEE International Conference on Computer Vision (ICCV). Santiago, Chile. IEEE, 2015: 1440-1448.
- [16] Ren S Q, He K M, 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, 2017, 39(6): 1137-1149.
- [17] Khalifa N E M, Taha M H N, Abou El-Maged L M, et al. Artificial intelligence in potato leaf disease classification: a deep learning approach[M]//Hassanien A E, Darwish A. Machine learning and big data analytics paradigms: analysis, applications and challenges. Cham: Springer International Publishing, 2021: 63-79.
- [18] Zhang Y, Song C L, Zhang D W. Deep learning-based object detection improvement for tomato disease[J]. IEEE Access, 2020, 8: 56607-56614.
- [19] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA. IEEE, 2016: 779-788.
- [20] Redmon J, Farhadi A. YOLO9000: better, faster, stronger[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA. IEEE, 2017: 6517-6525.
- [21] 朱 格, 徐 燕, 孙莹莹, 等. Darknet 深度学习框架下基于 YOLO v3 的病虫害识别和农药喷洒系统[J]. 农业与技术, 2023, 43(10): 33-38.
- [22] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector[M]//Leibe B, Matas J, Sebe N, et al. Computer vision - ECCV 2016. Cham: Springer International Publishing, 2016: 21-37.
- [23] 赵 越, 赵 辉, 姜永成, 等. 基于深度学习的马铃薯叶片病害检测方法[J]. 中国农机化学报, 2022, 43(10): 183-189.
- [24] Rashid J, Khan I, Ali G, et al. Multi-level deep learning model for potato leaf disease recognition[J]. Electronics, 2021, 10(17): 2064.
- [25] Liu J, Wang X W. Tomato diseases and pests detection based on improved YOLV3 convolutional neural network[J]. Frontiers in Plant Science, 2020, 11: 898.
- [26] 宋 玲, 曹 勉, 胡小春, 等. 基于 YOLOX 的复杂背景下木薯叶病害检测方法[J]. 农业机械学报, 2023, 54(3): 301-307.
- [27] 刘延鑫, 王俊峰, 杜传印, 等. 基于 YOLO v3 的多类烟草叶部病害检测研究[J]. 中国烟草科学, 2022, 43(2): 94-100.
- [28] 张剑飞, 柯 赛. 基于 YOLOX-s 的农业害虫检测研究[J]. 计算机技术与发展, 2023, 33(5): 208-213.
- [29] 沈志豪, 刘金江, 张建洋. 基于改进 YOLOX-s 的田间麦穗检测及计数[J]. 江苏农业科学, 2023, 51(12): 164-171.
- [30] Howard A, Sandler M, Chen B, et al. Searching for MobileNet v3[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, Korea (South). IEEE, 2019: 1314-1324.