

# 基于改进 YOLO 的棉花叶片病害检测

郭文娟<sup>1</sup>, 冯全<sup>2</sup>

(1. 甘肃政法大学网络空间安全学院, 甘肃 兰州 730070; 2. 甘肃农业大学机电工程学院, 甘肃 兰州 730070)

**摘要:**为实现棉花的智能化管理,针对复杂背景下棉花叶片病害检测准确率低的问题,基于改进 YOLO 算法对棉花叶片常见病害进行检测。分别在 YOLOX-S 和 YOLOv7 算法中引入 SE, CBAM 和 ECA 注意力模块,引导检测模型更关注棉花叶片病害区域特征,有效抑制背景噪声干扰,显著降低模型的漏减率。采用梯度加权类激活映射产生目标检测热图,可视化有效特征,理解模型的关注区域。结果表明:YOLOX-S+SE 模型、YOLOX-S+CBAM 模型和 YOLOX-S+ECA 模型的检测效果均优于 YOLOX-S 模型,并且 YOLOX-S+CBAM 模型的检测性能最优;YOLOv7+SE 模型、YOLOv7+CBAM 模型和 YOLOv7+ECA 模型的检测效果均优于 YOLOv7 模型,其中 YOLOv7+CBAM 模型的检测效果最好;与其他常见的目标检测模型相比,YOLOX-S+CBAM 模型和 YOLOv7+CBAM 模型的准确率、召回率、综合评价指标、平均准确率值均高于 Faster R-CNN 模型和 SSD 模型,综合比较结果,YOLOX-S+CBAM 模型的检测性能优于 YOLOv7+CBAM 模型,实现了检测速度、检测精度和模型体量之间的平衡,能够在复杂背景下对棉花叶片病害有较好的实时检测效果,对棉花病害防治具有重要的指导意义。

**关键词:**棉花;病害检测;YOLOX-S;YOLOv7;注意力机制

**中图分类号:**S225.6 **文献标志码:**A

## Cotton leaf disease detection based on improved YOLO

GUO Wenjuan<sup>1</sup>, FENG Quan<sup>2</sup>

(1. School of Cyberspace Security, Gansu University of Political Science and Law, Lanzhou, Gansu 730070, China;

2. College of Mechanical and Electrical Engineering, Gansu Agricultural University, Lanzhou, Gansu 730070, China)

**Abstract:** To achieve intelligent management of cotton and address the challenge of low accuracy in detecting cotton leaf diseases in complex environments, this paper presents results from using an improved YOLO algorithm for detecting common cotton leaf diseases. It incorporates the SE, CBAM, and ECA attention modules into the YOLOX-S and YOLOv7 algorithms to enhance the model's focus on diseased areas, effectively suppress background noise, and significantly reduce the omission rate. Using Gradient Weighted Class Activation Mapping to generate target detection heatmaps, visualize effective features, and understand the region of interest of the model. The experimental results demonstrate that the detection performance of the YOLOX-S+SE, YOLOX-S+CBAM, and YOLOX-S+ECA models surpassed that of the YOLOX-S model, with the YOLOX-S+CBAM model achieving the best performance. Similarly, the YOLOv7+SE, YOLOv7+CBAM, and YOLOv7+ECA models outperformed the YOLOv7 model, with the YOLOv7+CBAM model delivering the best detection performance. Compared to other common object detection models, the YOLOX-S+CBAM and YOLOv7+CBAM models exhibit higher values in accuracy rate, recall rate, comprehensive evaluation index, and average accuracy than the Faster R-CNN and SSD models. A comprehensive comparison shows that the YOLOX-S+CBAM model outperforms the YOLOv7+CBAM model, striking a balance between detection speed, accuracy, and model size. It demonstrates strong real-time detection capabilities for cotton leaf diseases in complex backgrounds. This research provides valuable guidance for the prevention and control of cotton diseases.

**Keywords:** cotton; disease detection; YOLOX-S; YOLOv7; attention mechanism

棉花是我国重要的农作物,是关系国家和民生的重要资源之一,但是棉花在生长过程中很容易受到病害影响,导致产量大幅降低,因此快速且准确识别棉花病害的种类是当务之急<sup>[1]</sup>。近年来,计算机技术的快速发展使得病害图像的智能识别技术成为精准农业发展的重要技术之一<sup>[2]</sup>。病害图像的识别算法能够快速高效地识别出病斑的颜色、形状、纹理等信息,显著缩减了识别过程所耗费的人力和时间。然而大多病害图像的识别算法用于处理背景简单的病害图像却无法应用于复杂环境中采集的病害数据,且很难实现在同一张图像上识别不同种类的病害<sup>[3]</sup>。

随着深度学习技术的快速发展,目标检测算法实现了自动从图像中提取到有效特征,解决了单一图像的多目标分类和定位问题<sup>[4-5]</sup>。目标检测算法分为两阶段算法和一阶段算法两类<sup>[6-7]</sup>,其中两阶段算法以 R-CNN 系列算法为代表,根据图像上已经生成的候选区域进行分类和边界回归<sup>[8]</sup>;一阶段算法以 SSD 算法<sup>[9]</sup>、YOLO 系列算法为代表,直接在图像上实现目标定位和目标分类<sup>[10]</sup>。

目标检测算法已成功应用于植株检测和计数<sup>[11]</sup>、果实采摘<sup>[12]</sup>、病虫害检测<sup>[13]</sup>等方面,均具有较高的检测精度。在农作物病害检测方面,李就好等<sup>[14]</sup>通过改进的 Faster R-CNN 模型检测苦瓜叶部病害,其平均检测精度值为 86.39%。叶中华等<sup>[15]</sup>用 SSD 模型在复杂背景病害数据集上检测,其平均检测精度值为 83.90%。Temmiranrat 等<sup>[16]</sup>利用 YOLOv3 模型检测水稻病害,检测效果理想,同时还该检测模型部署在服务器端。文斌等<sup>[17]</sup>在三七叶片的病害数据集上采用改进 YOLOv3 模型检测,改进模型的检测准确率高且鲁棒性强。毛锐等<sup>[18]</sup>采用改进 Faster-RCNN 模型检测小麦条锈病和黄矮病,平均检测精度值为 98.74%。Li 等<sup>[19]</sup>提出 YOLO-JD 检测模型,黄麻病虫害数据集上检测准确率为 96.63%。宋玲等<sup>[20]</sup>基于 YOLOX 模型提出了改进的 CCD 模型检测田间木薯叶病害,CCD 模型具有快且准确的检测能力。王卫星等<sup>[21]</sup>在荔枝病虫害数据集上采用改进的 YOLOv4 模型准确且快速地检测出图像中的病虫害目标。

由于采集病害数据集时光线变化、作物叶片遮挡、病斑相似、背景复杂等因素造成干扰,使得农作物叶片的病害检测存在很多难点,上述研究中难以提取到有效特征,进而影响最终的检测效果。YOLO

系列算法实现了基于卷积神经网络的端到端目标检测。注意力机制模块在模型中的应用能够有效忽略干扰因素的影响,提高目标检测的精度。鉴于此,本文以棉花常见的病害为研究对象,选取轻量化且实时性强的 YOLOX-S 和 YOLOv7 为检测模型,在 YOLOX-S 和 YOLOv7 模型中分别引入 SE、CBAM 以及 ECA 注意力模块,以增强模型对病害特征的提取能力,使得模型具有高准确率、强实时性和强鲁棒性。

## 1 理论基础

### 1.1 YOLOX-S 网络模型

YOLOX 模型<sup>[22]</sup>实现了端到端的目标检测,能够直接预测出锚框的位置和大小,将目标的中心位置定义为正样本,同时预定义尺度样本,合理分配正负样本,检测速度快且准确率高。根据网络模型大小,YOLOX 划分为五个标准模型,即 YOLOX-S、YOLOX-M、YOLOX-L、YOLOX-X 和 YOLOX-DarkNet53。由于棉花病害需要进行实时检测,因此本文研究对象为轻量级模型 YOLOX-S。

YOLOX-S 模型由输入端、骨干网络、颈部和预测端四部分构成,其网络结构如图 1 所示。YOLOX-S 模型在输入端通过数据增强对输入的病害图像进行预处理;骨干网络中采用 CBL 和 SPP 模块增强了特征提取能力;颈部采用 FPN 结构融合特征;预测端首先将特征融合后的输出通过解耦头分解成类别概率、置信度和位置三部分信息,而后分别计算后拼接得到预测结果,然后将三个不同尺度的预测结果合并后输出最终预测结果。与之前的 YOLO 系列网络相比,YOLOX 模型采用 Anchor-free 检测器,取消了预测端多个用于预测物体类别和位置的锚框,减少了较多的检测头处的参数量;YOLOX 模型采用轻量解耦头代替了 YOLO 检测头,提高了模型的收敛速度;YOLOX 模型加入了标签分配策略,有效缩短了训练时间。

### 1.2 YOLOv7 网络模型

YOLOv7 模型<sup>[23]</sup>能够以较快的检测速度获得较高的检测精度,YOLOv7 模型由输入端、骨干网络和检测头三部分构成,其网络结构如图 2 所示。输入病害图片在输入端经过预处理,通过数据增强、图像填充和自适应锚框后得到  $640 \times 640 \times 3$  大小的图片并作为模型输入;骨干网络由 CBS 模块、MP 模块和 ELAN 模块组成,实现对输入图片特征的提

取;检测头由 SPPCSPC 模块、RepConv 模块和具有 ELAN 结构的 PAN 模块组成,可实现病害类别预测和病害目标边界锚定,最终输出三个具有不同尺寸

的病害预测结果,完成多目标多尺度预测。  
YOLOv7 模型在特征提取、网络结构和训练方式等方面均优于其他 YOLO 模型。YOLOv7 模型采用高效聚合模块增强了提取特征的能力,在网络结构中引入重参数化的操作减少了推理时间,训练过程中添加了辅助训练模块有效提升了模型的精度。

### 1.3 注意力机制

1.3.1 SE 注意力机制 SE(Squeeze and Excitation) 注意力机制<sup>[24]</sup>首先经过学习获得各个特征的通道重要性,然后根据其重要程度在进行卷积运算时加强关键特征通道信息,同时抑制非关键特征通道信息。SE 注意力机制结构如图 3 所示。SE 注意力机制能够有效解决深层神经网络中通道权重分布不平

衡的问题,通过加权特征图,使得检测模型对病害特征更敏感,同时能更好地抑制次要特征对病害检测结果的影响。

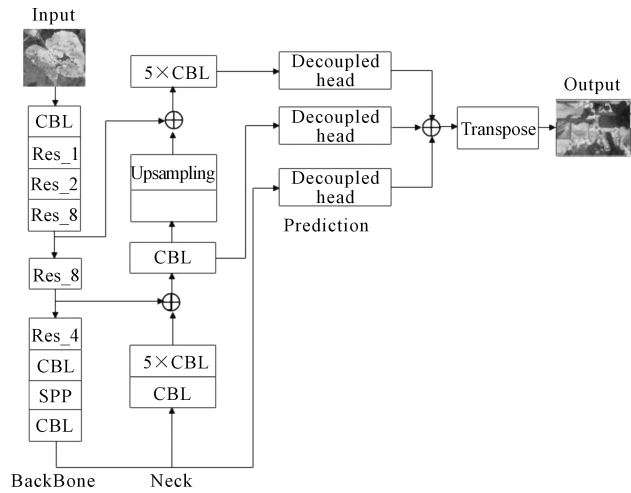


图 1 YOLOX-S 网络结构图

Fig.1 Framework of YOLOX-S

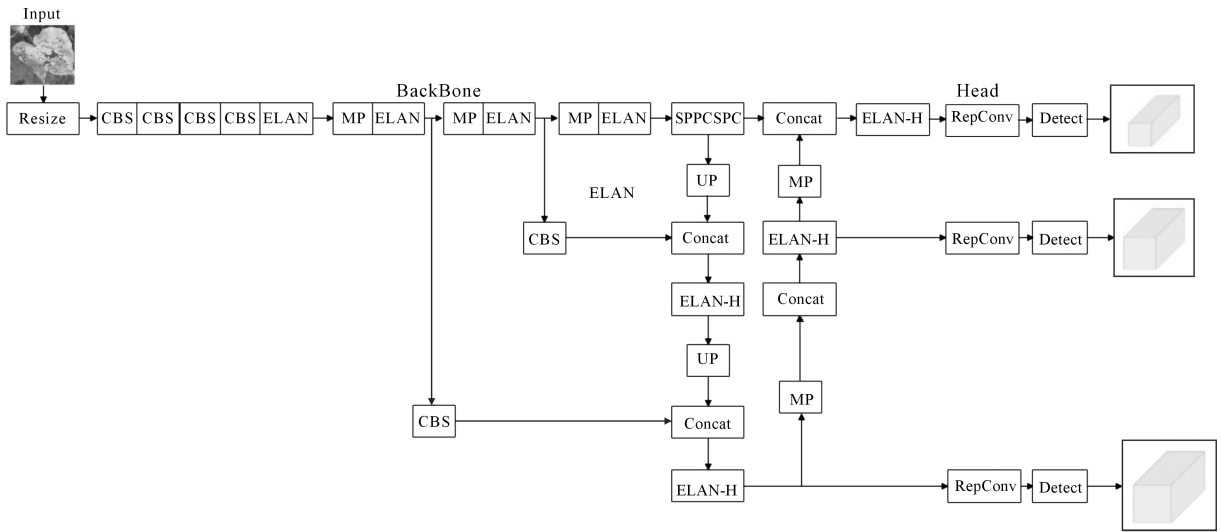


图 2 YOLOv7 网络结构图

Fig.2 Framework of YOLOv7

1.3.2 CBAM 注意力机制 CBAM (Convolutional Block Attention Module) 注意力机制<sup>[25]</sup>兼顾了通道注意力与空间注意力的优势,通过更多有用的注意力信息使得模型能够分配权重。CBAM 注意力机制结构如图 4 所示,首先输入的特征经过通道注意力模块学习到关键的通道特征,然后通过空间注意力模块获取重要的特征,最后输入重要的特征信息。CBAM 注意力机制通过串联通道模块和空间模块的方式给予病害特征更多关注,检测模型所提取的病害特征指向性更强,对病害检测任务更有优越性。




图 3 SE 模块结构图

Fig.3 Structure of SE module

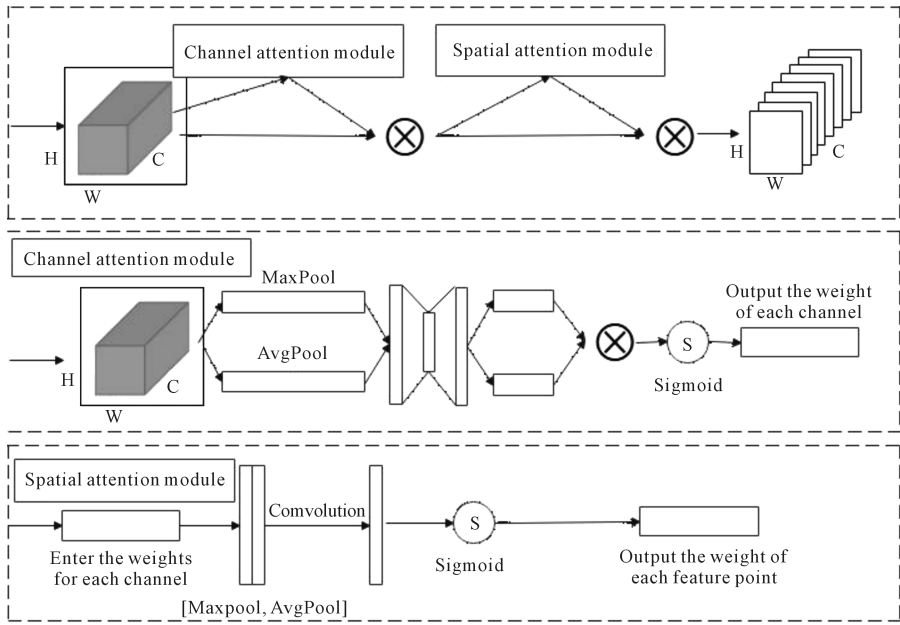


图 4 CBAM 模块结构图  
Fig.4 Structure of CBAM module

1.3.3 ECA 注意力机制 ECA (Efficient Channel Attention) 通道注意力机制<sup>[26]</sup> 采用了不降维局部跨通道的交互方式,通道上通过一维卷积进行滑动滤波,实现了以较少参数进行跨通道的交互,有效避免通道削减。ECA 注意力机制结构如图 5 所示。ECA 注意力机制实现简单,通过采用 ECA 使得检测模型能够动态调整特征图中各个通道的权重,从而更高效地使用特征图中的关键特征信息。

## 2 棉花叶片病害检测模型构建

棉花数据集多采集于复杂的田间环境,导致病害数据集干扰信息较多且噪声较大,进而降低模型对棉花病害特征的学习效率。注意力机制能够使得检测模型更关注重要的棉花病害特征,同时弱化噪声的干扰,因此在 YOLOX-S 模型和 YOLOv7 模型中分别引入 SE 注意力机制、CBAM 注意力机制和 ECA 注意力机制来提高模型对棉花病害的检测能力。

避免更改 YOLOx 模型 Darknet53 的网络结构,使得模型训练时能够直接加载预训练权重,本文在骨干网络 Darknet53 的三个输出分支上分别引入 SE 注意力机制、ECA 注意力机制和 CBAM 注意力机制,从而增强各分支的特征表达,使 YOLOx 模型能够有选择性地加强关键特征,同时有效抑制无用特征,改进的 YOLOX-S 模型网络结构如图 6 所示。

为进一步提高模型的检测性能,在主干网络输出三个特征层后分别引入注意力机制模块,以提高特征




图 5 ECA 模块结构图  
Fig.5 Structure of ECA module

层表达力。改进的 YOLOv7 模型网络结构如图 7 所示。

## 3 数据采集

### 3.1 试验平台

本文试验操作系统为 Windows10,电脑配备 16GB 内存,使用 Pytorch1.10.2 作为深度学习框架,试验相关的硬件配置与模型参数如表 1 所示。

### 3.2 试验数据集

本文数据集取自采集的棉花叶片图像,共 1260 张,数据集样本均为在实际大田复杂环境中拍摄的叶片病害图像。数据集包含了 5 种棉花的常见病害,即炭疽病、褐斑病、黄萎病、枯萎病和轮纹病,如图 8 所示。

模型训练时将数据集划分为训练集、验证集和测试集,棉花叶片病害数据集中各类病害图片的数量如表 2 所示。

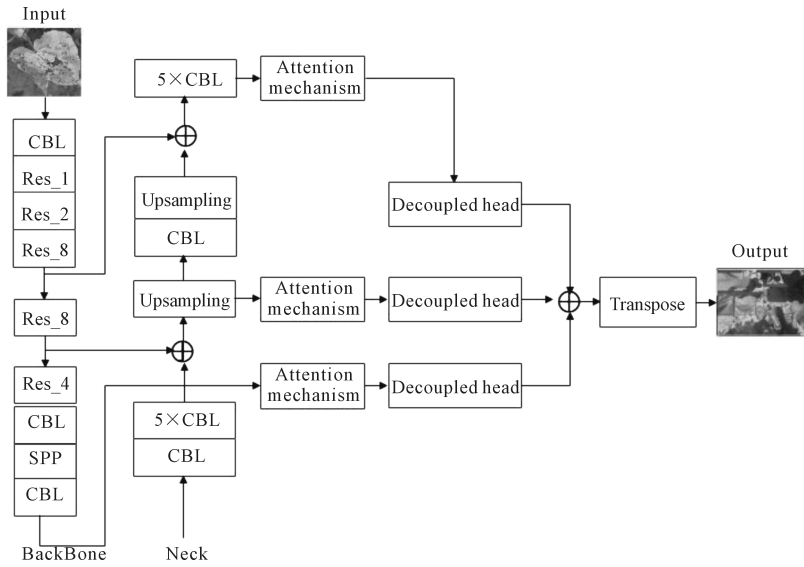


图 6 改进 YOLOX-S 网络结构图

Fig.6 Framework of improved YOLOX-S

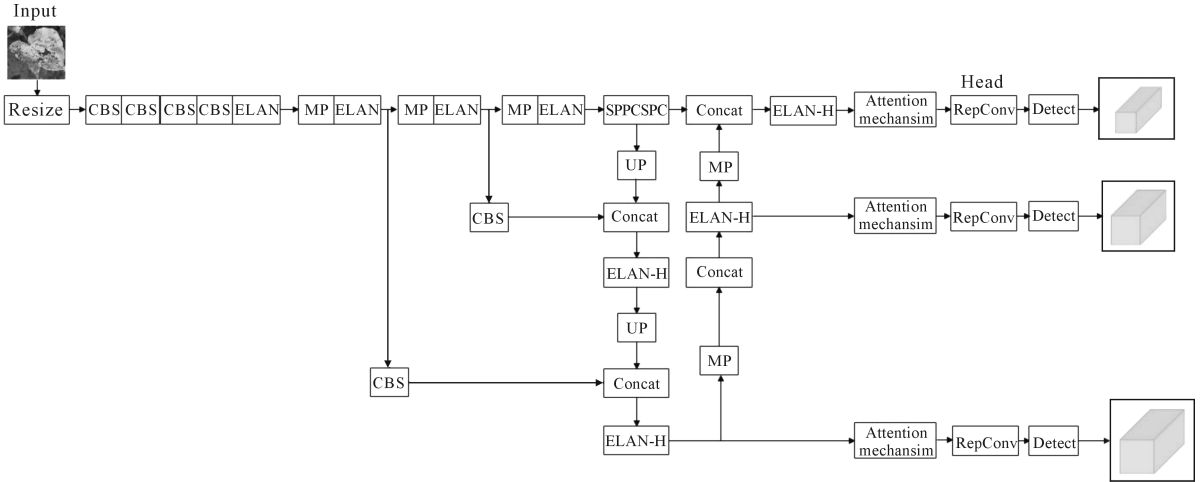


图 7 改进 YOLOv7 网络结构图

Fig.7 Framework of improved YOLOv7

表 1 试验相关硬件配置和模型参数

Table 1 Test-related hardware configuration and model parameters

名称 Name	配置 Configuration	名称 Name	取值 Value
GPU	RTX3070Ti	Size of images	640×640
CPU	AMD Ryzen 7 5800X @ 3.8GHz	Learning rate	$5 \times 10^{-4}$
CUDA	11.3	Optimizer	Adam
CuDNN	8.2.1	Batch size	4

表 2 各类病害图片的数量表

Table 2 Number of images of various diseases

病害类型 Disease type	图片数量 Number of images	训练集 Training set	验证集 Validation set	测试集 Test set
炭疽病 Anthracnose	250	203	22	25
褐斑病 Cercospora leaf spot	285	231	26	28
黄萎病 Verticillium wilt	230	187	20	23
枯萎病 Fusarium wilt	270	219	24	27
轮纹病 Wheel disease	225	181	21	23

病害数据集构建流程如图 9 所示。经过图像预处理后,得到棉花病害数据集;使用 Labellmg 软件对图像进行标注;将数据集划分为训练集、验证集和测试集;采用亮度变换、添加噪声、缩放、旋转和镜像等操作对图像进行增强,最终获得棉花病害数据集样本。

### 3.3 评价指标

模型的检测精度和速度、模型参数量能够体现出来模型的性能优劣,采用准确率  $P$ 、召回率  $R$ 、综合评价指标  $F1$  值、平均准确率  $mAP$ 、帧率  $FPS$  和参数量对检测结果进行评价。

准确率  $P$  和召回率  $R$  分别按式(1)和式(2)进行计算。

$$P = \frac{TP}{TP + FP} \times 100\% \quad (1)$$

$$R = \frac{TP}{TP + FN} \times 100\% \quad (2)$$

式中, $TP$  为检测正确的正样本数目; $FP$  为检测错误的正样本数目; $FN$  为检测错误的负样本数目。

$F1$  值是准确率  $P$  和召回率  $R$  的调和平均数,其计算公式如式(3)所示。

$$F1 = \frac{2 \times P \times R}{P + R} \quad (3)$$

$mAP$  是将所有病害类的平均精度值  $AP$  取平均值的结果, $mAP$  值越高,模型的检测性能就越好。平均精度值  $AP$  的定义如式(4)所示, $mAP$  值的定义如式(5)所示。

$$AP = \int_0^1 PR ds \quad (4)$$

$$mAP = \frac{1}{N} \sum_{m=1}^N AP_m \quad (5)$$

式中, $N$  为病害的类别数目; $AP_m$  表示第  $m$  个病害类的平均精度值  $AP$ 。


帧率  $FPS$  表示检测模型每秒所处理的图片数量, $FPS$  值越大表明模型的检测速度越快。

### 3.4 结果与分析

3.4.1 采用不同注意力机制的 YOLOX-S 模型检测效果 为探究基于不同注意力机制的 YOLOX-S 模型对棉花病害的检测效果,在相同的试验条件下对比  $P$ 、 $R$ 、 $F1$  值、 $mAP$ 、 $FPS$  和参数量等指标值,试验结果如图 10 所示,检测效果如图 11 所示。

由图 10 可知,在 YOLOX-S 模型中分别引入三种注意力机制后,YOLOX-S+SE 模型、YOLOX-S+CBAM 模型和 YOLOX-S+ECA 模型的  $P$ 、 $R$ 、 $F1$  值、 $mAP$ 、 $FPS$  均高于 YOLOX-S 模型,检测效果均优于 YOLOX-S 模型,且四种模型的参数量基本持平,其中 YOLOX-S+CBAM 模型检测效果最佳。

从图 11 可以看出,引入注意力机制使得模型能够更好地关注病害的表面特征和区分不同的病害特征,YOLOX-S+SE 模型、YOLOX-S+CBAM 模型和 YOLOX-S+ECA 模型相较于 YOLOX-S 模型出现



■ YOLOX-S ■ YOLOX-S+SE ■ YOLOX-S+CBAM ■ YOLOX-S+ECA

注:引入 SE 注意力机制的 YOLOX-S 模型简称为 YOLOX-S+SE;引入 CBAM 注意力机制的 YOLOX-S 模型简称为 YOLOX-S+CBAM;引入 ECA 注意力机制的 YOLOX-S 模型简称为 YOLOX-S+ECA。下同。

Note: The YOLOX-S model after introducing the SE attention mechanism is called YOLOX-S+SE for short; the YOLOX-S after introducing the ECA is called YOLOX-S+ECA for short; the YOLOX-S model after introducing CBAM is called YOLOX-S+CBAM for short. The same below.

图 10 基于不同注意力机制的 YOLOX-S 检测结果

Fig.10 YOLOX-S detection results based on different attention mechanisms

漏检的情况较少,检测性能更好。由此可知,YOLOX-S+CBAM 模型具有最强的检测能力,其次是 YOLOX-S+SE 模型,最后是 YOLOX-S+ECA 模型。

为了更好地理解模型的检测过程,采用梯度加权类激活映射(Grad-CAM, gradient-weighted class activation mapping)<sup>[27]</sup>分别对上述模型的输出层进行可视化分析。Grad-CAM 通过梯度计算最后一个卷积层各神经元的重要性,绘制热图,显示图像中用于预测目标的重要区域。热图中颜色越红的区域代表关注度越高,更具有辨别力,也是模型检测时最感兴趣的区域。基于不同注意力机制的 YOLOX-S 模型提取棉花病害特征的可视化结果如图 12 所示。

从图 12 可以看出,YOLOX-S 模型的热图分布杂乱,彩色部分分布在叶片四周,表明该模型检测过程中所关注的病害区域过多,导致产生病害误检或漏检现象。引入三种不同注意力机制后模型热图的彩色部分集中于叶片主体部分,能让检测模型学习到重点关注的部分,使得模型更高效聚集到病害图像难区分的特征信息的提取。其中 YOLOX-S+CBAM 模型热图的彩色部分集中于叶片病害处,模型在识别阶段将叶片的病害区域作为重点关注对象,识别出病害目标,有效过滤了不重要的病害特征信息,提高了模型检测性能。



图 8 病害样本图像

Fig.8 Disease sample images

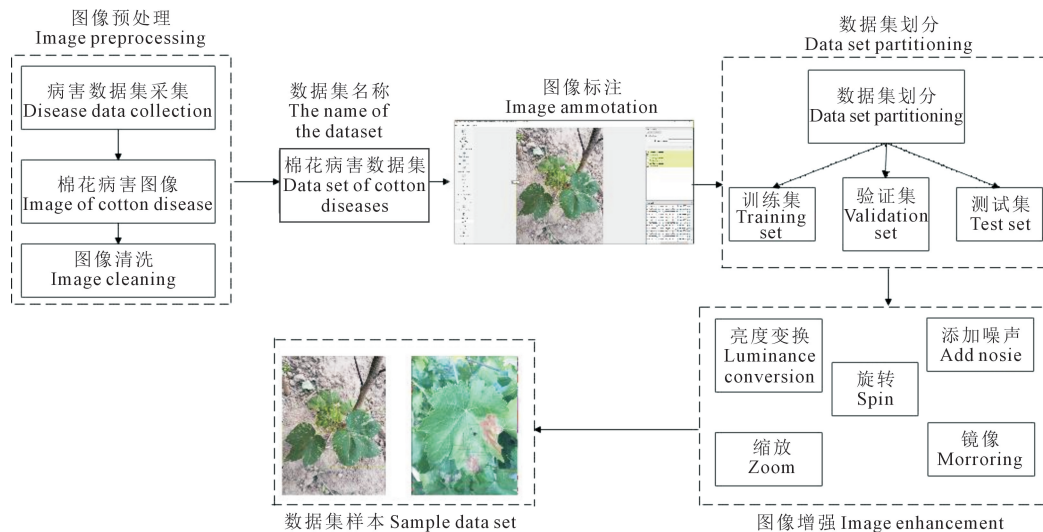


图 9 病害数据集构建流程图

Fig.9 Flowchart of disease dataset construction




图 11 基于不同注意力机制的 YOLOX-S 检测效果图

Fig.11 YOLOX-S detection rendering based on different attention mechanisms

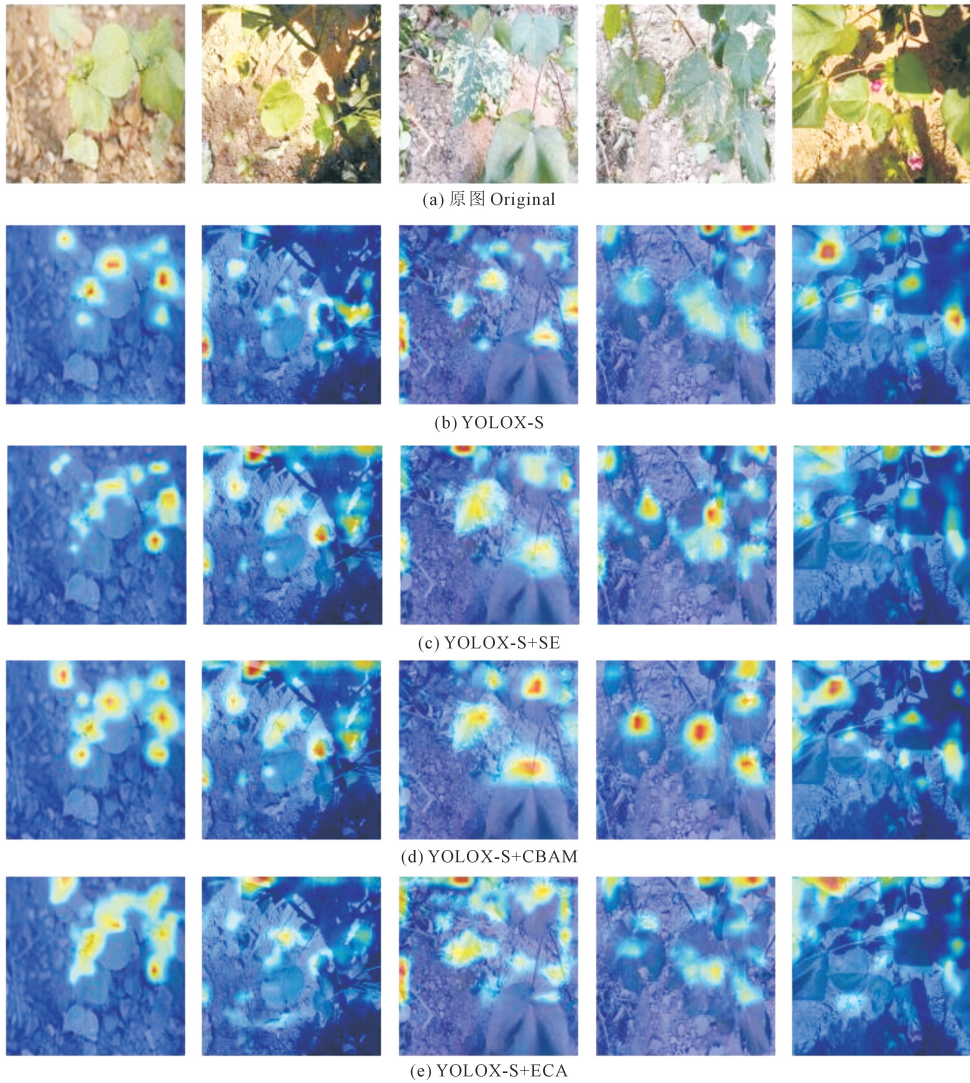


图 12 基于不同注意力机制的 YOLOX-S 模型热力图

Fig.12 YOLOX-S model heat map based on different attention mechanisms

3.4.2 采用不同注意力机制的 YOLOv7 模型检测效果 为探究基于不同注意力机制的 YOLOv7 模型对棉花病害的检测影响,保持试验条件不变,对比  $P$ 、 $R$ 、 $F1$  值、 $mAP$ 、 $FPS$  和参数量等指标值,试验结果如图 13 所示,检测效果如图 14 所示。

从图 13 可知,在 YOLOv7 模型中分别引入三种注意力机制后,YOLOv7+SE 模型、YOLOv7+CBAM 模型和 YOLOv7+ECA 模型的  $P$ 、 $R$ 、 $F1$  值、 $mAP$  均高于 YOLOv7 模型,四种模型的  $FPS$  值基本接近,引入注意力机制的三种模型的参数量略高于 YOLOv7 模型。引入注意力的模型中,YOLOv7+CBAM 模型具有最好的检测效果,其次是 YOLOv7+SE 模型,最后是 YOLOv7+ECA 模型。

由图 14 可以得出,采用 YOLOv7 模型检测时,既有漏检又有误检,如上图每张图片都有漏检,左起第二张图片 and 最后一张图片有误检。引入注意力机制后,YOLOv7+SE 模型、YOLOv7+CBAM 模

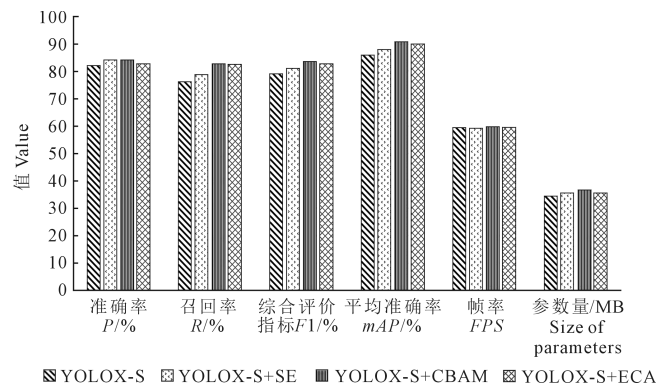


图 13 基于不同注意力机制的 YOLOv7 检测结果

Fig.13 YOLOv7 detection results based on

different attention mechanisms

型和 YOLOv7+ECA 模型漏检和误检情况有所改善,尤其 YOLOv7+CBAM 模型具有最优的检测效果。

为了验证引入不同注意力机制后各模型检测性能的差异,不同模型可视化比较如图 15 所示。



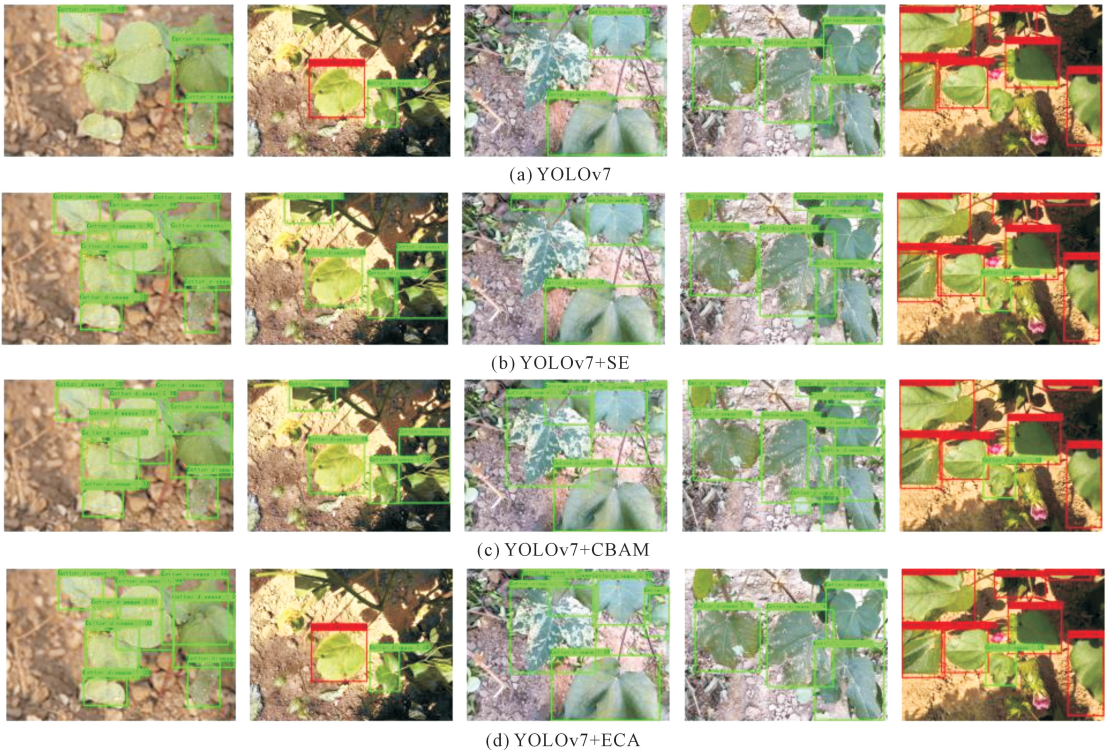


图 14 基于不同注意力机制的 YOLOv7 检测效果图

Fig.14 YOLOv7 detection rendering based on different attention mechanisms

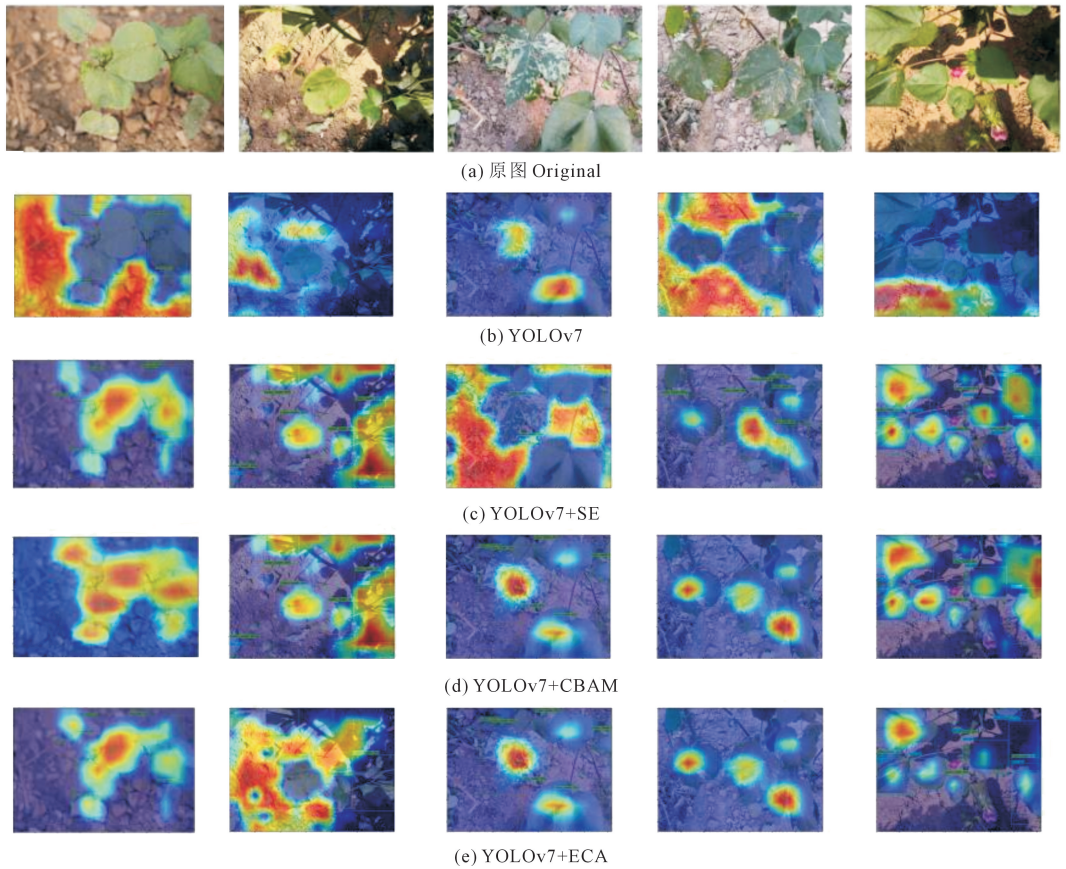


图 15 基于不同注意力机制的 YOLOv7 模型热力图

Fig.15 YOLOv7 model heat map based on different attention mechanisms

从图 15 可以看出, YOLOv7 模型对病害区域的关注比较分散, 虽然也关注了病害区域, 但更多是关注到了背景区域, 致使模型检测时常有误检或漏检现象发生。YOLOv7+SE 模型和 YOLOv7+ECA 模型较好地关注了病害位置, 左起第三张图片中 YOLOv7+SE 模型关注的是病害无关区域, 导致病害漏检; 左起第二张图片中 YOLOv7+ECA 模型关注了背景区域, 导致病害误检。总体来说, YOLOv7+CBAM 模型对叶片的病害位置定位更加准确, 从而获得高于其他模型的病害检测精度。

3.4.3 采用不同目标检测模型的检测效果 为探究不同的目标检测模型对棉花病害的检测效果, 保持试验条件不变, 对比  $P$ 、 $R$ 、 $F1$  值、 $mAP$ 、 $FPS$  和参数量等指标值, 试验结果如表 3 所示。

表 3 不同目标检测模型的棉花病害检测结果

Table 3 Detection results of cotton diseases based on different target detection models

模型 Model	准确率 $P/\%$	召回率 $R/\%$	综合评价 指标 $F1/\%$	平均准 确率 $mAP/\%$	帧率 $FPS$ /(帧· $s^{-1}$ )	参数量 Size of parameters /MB
Faster R-CNN	79.8	74.42	77.02	80.38	15.87	569.37
SSD	78.05	72.26	75.04	72.43	111.68	53.16
YOLOX-S +CBAM	88.09	76.60	81.94	86.90	80.73	34.87
YOLOv7+ CBAM	84.26	82.69	83.47	90.82	59.60	36.62

注: 准确率  $P$  表示所有被识别的棉花病斑中, 真正棉花病斑所占的比例; 召回率  $R$  表示识别的棉花病斑数量与测试集中所有实际棉花病斑数量的比值; 综合评价指标  $F1$  是准确率  $P$  和召回率  $R$  的调和平均数, 用于评价  $P$  和  $R$  的兼容性; 平均准确率  $mAP$  表示对所有类别的平均精度值  $AP$  再求取的平均值; 帧率  $FPS$  表示模型检测每帧图像所需的时间; 参数量表示模型在棉花病害数据集上训练后产生的模型大小。

Note: The accuracy rate  $P$  represents the proportion of true cotton lesions among all identified cotton lesions; the recall rate  $R$  represents the ratio of the number of identified cotton lesions to the number of actual cotton lesions in the test set; the comprehensive evaluation index  $F1$ , a harmonic mean of accuracy rate  $P$  and recall rate  $R$ , was used to evaluate the compatibility of  $P$  and  $R$ ; the average accuracy  $mAP$  represents the average of the average accuracy value  $AP$  of all categories; the frame rate  $FPS$  represents the time needed for the model to detect each image; the parameter quantity represents the model size that the model produces after training on the cotton disease data set.

由表 3 可知, 相比 Faster R-CNN 模型, YOLOX-S+CBAM 模型的  $P$ 、 $R$ 、 $F1$ 、 $mAP$  值分别提升了 8.29、2.18、4.92、6.52 个百分点,  $FPS$  值提升了 64.86 帧· $s^{-1}$ , 参数量仅为 Faster R-CNN 模型的 6.12%; 相比 SSD 模型, YOLOX-S+CBAM 模型的  $P$ 、 $R$ 、 $F1$ 、 $mAP$  值

分别提升了 10.04、4.34、6.90、14.47 个百分点,  $FPS$  值降低了 30.95 帧· $s^{-1}$ , 参数量降低了 18.29 MB。

相比 Faster R-CNN 模型, YOLOv7+CBAM 模型的  $P$ 、 $R$ 、 $F1$ 、 $mAP$  值分别提升了 4.46、8.27、6.45、10.44 个百分点,  $FPS$  值提升了 43.73 帧· $s^{-1}$ , 参数量仅为 Faster R-CNN 模型的 6.43%; 相比 SSD 模型, YOLOv7+CBAM 模型的  $P$ 、 $R$ 、 $F1$ 、 $mAP$  值分别提升了 6.21、10.43、8.43、18.39 个百分点,  $FPS$  值降低了 52.08 帧· $s^{-1}$ , 参数量降低了 16.54 MB。

综上可得, 虽然 SSD 模型运行速度最快, 但是该模型的检测精度较低, 检测性能不够理想; 相比 YOLOv7+CBAM 模型, YOLOX-S+CBAM 模型的检测速度更快,  $FPS$  值提升了 21.13 帧· $s^{-1}$ ; 检测精度方面, YOLOX-S+CBAM 模型的  $F1$  和  $mAP$  值分别低于 YOLOv7+CBAM 模型的 1.53 和 3.92 个百分点, 相差不多, 而两种模型的参数量基本持平。因此, YOLOX-S+CBAM 模型的综合表现最好, 能够实现复杂背景下棉花叶部病害的准确快速检测。

## 4 结 论

1) YOLOX-S+SE 模型、YOLOX-S+CBAM 模型和 YOLOX-S+ECA 模型的检测性能均优于未引入注意力模块的 YOLOX-S 模型, 其中 YOLOX-S+CBAM 模型的检测效果最好, 其次是 YOLOX-S+SE 模型, 最后是 YOLOX-S+ECA 模型。Grad-CAM 可视化热图表明, 引入注意力机制后使得模型能够提取到更多更有用的特征, 增强了模型的鲁棒性。

2) YOLOv7 模型中引入注意力模块后模型的检测性能均高于 YOLOv7 模型, YOLOv7+CBAM 模型具有最好的检测效果, 其次是 YOLOv7+SE 模型, 最后是 YOLOv7+ECA 模型。通过 Grad-CAM 可视化可以看出, CBAM 注意力机制增强了特征图中关键通道特征和空间特征, 有效提高了对病害目标的检测精度, 改善了由遮挡重叠引起的误检和漏检问题。

3) 与常见的目标检测模型相比, YOLOX-S+CBAM 模型的检测性能最好, 实现了精度高且体量小的目标检测模型, 快速识别病害目标的同时保证了较高的检测精度, 可为后续棉花病害的检测提供技术支持。

## 参 考 文 献:

- [1] 王晋伟, 赵丽红, 师勇强, 等. 棉花病害全程防治技术研究初报[J]. 中国棉花, 2020, 47(5): 20-22, 46.  
WANG J W, ZHAO L H, SHI Y Q, et al. Preliminary report on the whole process control techniques of cotton diseases[J]. China Cotton, 2020, 47(5): 20-22, 46.
- [2] 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 Z Y, CAO Y F, XU H L, 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.
- [3] 黄林生, 罗耀武, 杨小冬, 等. 基于注意力机制和多尺度残差网络的农作物病害识别[J]. 农业机械学报, 2021, 52(10): 264-271.
- HUANG L S, LUO Y W, YANG X D, et al. Crop disease recognition based on attention mechanism and multi-scale residual network [J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(10): 264-271.
- [4] 陈科圻, 朱志亮, 邓小明, 等. 多尺度目标检测的深度学习研究综述[J]. 软件学报, 2021, 32(4): 1201-1227.
- CHEN K Q, ZHU Z L, DENG X M, et al. Deep learning for multi-scale object detection: a survey [J]. Journal of Software, 2021, 32(4): 1201-1227.
- [5] LIU Y, SUN P, WERGELES N, et al. A survey and performance evaluation of deep learning methods for small object detection[J]. Expert Systems with Applications, 2021, 172: 114602.
- [6] 王鑫鹏, 王晓强, 林浩, 等. 深度学习典型目标检测算法的改进综述[J]. 计算机工程与应用, 2022, 58(6): 42-57.
- WANG X P, WANG X Q, LIN H, et al. Review on improvement of typical object detection algorithms in deep learning [J]. Computer Engineering and Applications, 2022, 58(6): 42-57.
- [7] 杨锋, 丁之桐, 邢蒙蒙, 等. 深度学习的目标检测算法改进综述[J]. 计算机工程与应用, 2023, 59(11): 1-15.
- YANG F, DING Z T, XING M M, et al. Review of object detection algorithm improvement in deep learning[J]. Computer Engineering and Applications, 2023, 59(11): 1-15.
- [8] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [C]//Proceedings of the 28th International Conference on Neural Information Processing Systems-Volume 1, Montreal Canada: MIT Press, 2015: 91-99.
- [9] LIU W, ANGELOV D, ERHAN D, et al. SSD: single shot MultiBox detector [C]//Computer Vision-ECCV 2016, Amsterdam, The Netherlands: Springer International Publishing, 2016: 21-37.
- [10] 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.
- [11] 易诗, 李俊杰, 张鹏, 等. 基于特征递归融合YOLOv4网络模型的春见柑橘检测与计数[J]. 农业工程学报, 2021, 37(18): 161-169.
- YI S, LI J J, ZHANG P, et al. Detecting and counting of spring-see citrus using YOLOv4 network model and recursive fusion of features[J]. Transactions of the Chinese Society of Agricultural Engineering, 2021, 37(18): 161-169.
- [12] 彭红星, 李荆, 徐慧明, 等. 基于多重特征增强与特征融合SSD的荔枝检测[J]. 农业工程学报, 2022, 38(4): 169-177.
- PENG H X, LI J, XU H M, et al. Litchi detection based on multiple feature enhancement and feature fusion SSD [J]. Transactions of the Chinese Society of Agricultural Engineering, 2022, 38(4): 169-177.
- [13] 黄丽明, 王懿祥, 徐琪, 等. 采用YOLO算法和无人机影像的松材线虫病异常变色木识别[J]. 农业工程学报, 2021, 37(14): 197-203.
- HUANG L M, WANG Y X, XU Q, et al. Recognition of abnormally discolored trees caused by pine wilt disease using YOLO algorithm and UAV images[J]. Transactions of the Chinese Society of Agricultural Engineering, 2021, 37(14): 197-203.
- [14] 李就好, 林乐坚, 田凯, 等. 改进Faster R-CNN的田间苦瓜叶部病害检测[J]. 农业工程学报, 2020, 36(12): 179-185.
- LI J H, LIN L J, TIAN K, et al. Detection of leaf diseases of balsam pear in the field based on improved Faster R-CNN [J]. Transactions of the Chinese Society of Agricultural Engineering, 2020, 36(12): 179-185.
- [15] 叶中华, 赵明霞, 贾璐. 复杂背景农作物病害图像识别研究[J]. 农业机械学报, 2021, 52(S1): 118-124, 147.
- YE Z H, ZHAO M X, JIA L. Research on image recognition of crop diseases in complex background [J]. Transactions of the Chinese Society of Agricultural Machinery, 2021, 52(S1): 118-124, 147.
- [16] TEMNIRANRAT P, KIRATIRATANAPRUK K, KITVIMONRAT A, et al. A system for automatic rice disease detection from rice paddy images serviced via a Chatbot [J]. Computers and Electronics in Agriculture, 2021, 185: 106156.
- [17] 文斌, 曹仁轩, 杨启良, 等. 改进YOLOv3算法检测三七叶片病害[J]. 农业工程学报, 2022, 38(3): 164-172.
- WEN B, CAO R X, YANG Q L, et al. Detecting leaf disease for panax notoginseng using an improved YOLOv3 algorithm [J]. Transactions of the Chinese Society of Agricultural Engineering, 2022, 38(3): 164-172.
- [18] 毛锐, 张宇晨, 王泽玺, 等. 利用改进Faster-RCNN识别小麦条锈病和黄矮病[J]. 农业工程学报, 2022, 38(17): 176-185.
- MAO R, ZHANG Y C, WANG Z X, et al. Recognizing stripe rust and yellow dwarf of wheat using improved Faster-RCNN [J]. Transactions of the Chinese Society of Agricultural Engineering, 2022, 38(17): 176-185.
- [19] LI D W, AHMED F, WU N L, et al. YOLO-JD: a deep learning network for jute diseases and pests detection from images [J]. Plants, 2022, 11(7): 937.
- [20] 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.
- SONG L, CAO M, HU X C, et al. Detection of cassava leaf diseases under complicated background based on YOLOX [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(3): 301-307.
- [21] 王卫星, 刘泽乾, 高鹏, 等. 基于改进YOLO v4的荔枝病虫害检测模型[J]. 农业机械学报, 2023, 54(5): 227-235.
- WANG W X, LIU Z Q, GAO P, et al. Detection of litchi diseases and insect pests based on improved YOLO v4 model [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(5): 227-235.
- [22] ZHENG G, LIU S T, WANG F, et al. YOLOX: exceeding YOLO series in 2021 [DB/OL]. arXiv, 2021 (2021-07-18). <http://arxiv.org/pdf/2107.08430v1>.
- [23] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: train-able bag-of-freebies sets new state-of-the-art for real-time object detectors [DB/OL]. arXiv, 2022 (2022-07-06). <https://arxiv.org/abs/2207.02696>.
- [24] HU J, SHEN L, SUN G. Squeeze-and-Excitation networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA: IEEE, 2018: 7132-7141.
- [25] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [C]//Computer Vision-ECCV 2018, Munich, Germany: Springer International Publishing, 2018: 3-19.
- [26] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: efficient channel attention for deep convolutional neural networks [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Seattle, WA, USA: IEEE, 2020: 11531-11539.
- [27] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: visual explanations from deep networks via gradient-based localization [J]. International Journal of Computer Vision, 2020, 128(2): 336-359.