

大田环境下青贮玉米枯叶病检测模型

杨欢¹, 王钧¹, 李广^{1,2}, 吴江琪², 谈燕²

(1. 甘肃农业大学信息科学技术学院; 2. 甘肃农业大学林学院, 甘肃兰州 730070)

摘要: 为实现对青贮玉米枯叶病的精确检测,降低大田环境下的人工诊断成本,减少病害带来的影响,提出一种基于YOLOv7改进的智能检测与识别模型YOLOv7-MLD。首先,在YOLOv7网络的主干中添加DBB模块,增强主干的特征提取能力;其次,在3个输出特征层添加坐标注意力机制(CA)模块,增强对病害特征的提取能力;最后,将损失函数由CIoU替换为SIoU,以提高边界框的收敛速度和回归精度。在玉米枯叶病数据集的子集上进行实验,结果表明,YOLOv7-MLD模型的AP值达到84.2%,与原YOLOv7相比,F1值提高了5.9%,精确率和召回率分别提高了4.3%与7.3%。该模型实现了在田间复杂环境下对青贮玉米枯叶病病害的精准定位与识别,对于指导早期青贮玉米枯叶病病害防治具有十分重要的现实意义。

关键词: 青贮玉米; 枯叶病; YOLOv7-MLD; 目标检测; 注意力机制; 智慧农业

DOI: 10.11907/rjdk.231975

开放科学(资源服务)标识码(OSID):

中图分类号: TP391.41

文献标识码: A

文章编号: 1672-7800(2024)009-0193-07



Silage Maize Leaf Blight Detection Model in Field Environment

YANG Huan¹, WANG Jun¹, LI Guang^{1,2}, WU Jiangqi², TAN Yan²

(1. School of Information Science and Technology, Gansu Agricultural University;

2. School of Forestry, Gansu Agricultural University, Lanzhou 730070, China)

Abstract: In order to achieve accurate Detection of Leaf blight of silage Maize, reduce the cost of manual diagnosis in field environment and reduce the impact of the disease, a modified YOLOv7-MLD (Maize Leaf-Blight Detection) model was proposed. Firstly, Diverse Branch Block (DBB) module was added to the backbone of YOLOv7 network to enhance its feature extraction capability. Then a Coordinate Attention module is added to the three output feature layers to enhance the ability of extracting disease features. Finally, the loss function is replaced by CIoU with SIoU to improve the convergence speed and regression accuracy of the bounding box. Experiments were carried out on a subset of maize leaf wilt disease data set, and the results showed that the AP value of YOLOv7-MLD model reached 84.2%, the F1 value increased by 5.9%, the accuracy rate and recall rate increased by 4.3% and 7.3%, respectively, compared with the original YOLOv7. The model can accurately locate and identify the leaf blight of silage maize in the complex field environment, and has very important practical significance for guiding the prevention and control of the early leaf blight of silage maize.

Key Words: silage maize; leaf blight; YOLOv7-MLD; object detection; attention mechanism; smart agriculture

0 引言

青贮玉米是我国重要的饲料作物之一,广泛应用于畜牧业。青贮玉米用作牲畜饲料,具有营养价值丰富、适口性好、利用率高等特点^[1]。确保青贮玉米的高产稳产,对畜牧业有着重要意义。但在其生长过程中容易遭受各种

病害侵袭,其中枯叶病对花粒期的玉米危害较为严重,是玉米的主要叶部病害^[2]。感染了叶枯病真菌的青贮玉米在青贮过程中病原真菌也可能大量繁殖,进一步产生大量毒素化合物,对畜牧业生产造成影响^[3]。作为影响青贮玉米产量及品质的重要因素,玉米枯叶病的精准检测显得尤为重要^[4]。

在传统的农作物病害检测中,通常采用人工观察方法

收稿日期: 2023-09-14

扫描二维码阅读全文:



基金项目: 甘肃省高等学校产业支撑项目(2021CYZC-15, 2022CYZC-41); 甘肃省重点研发计划项目(22YF7FA116); 甘肃省财政专项(GSCZZ20160909)

作者简介: 杨欢(1994-), 男, 甘肃农业大学信息科学技术学院硕士研究生, 研究方向为深度学习、序列建模; 王钧(1982-), 男, 甘肃农业大学信息科学技术学院副教授、硕士生导师, 研究方向为农业信息化; 李广(1971-), 男, 甘肃农业大学林学院教授、博士生导师, 研究方向为作物模拟模型、系统集成和农业信息化。

进行判断。然而,该方法在发病初期很难及时发现病害,且在大田环境中效率低下。同时,由于对病害情况判断不精准,导致喷洒农药时作物容易遭受农药残留的影响,危害牲畜健康,进而危害人体健康^[5]。随着智慧农业的发展,作物的早期病害检测作为针对性的防治手段已经成为智慧农业在病害研究方面的发展趋势^[6]。利用无人机获得农田信息,覆盖范围广、实效性强且客观准确,较传统检测方法具有无可比拟的优势^[7]。应用深度学习技术对无人机航拍的农田照片进行检测,能够在枯叶病发病早期发现青贮玉米染病情况,为后续喷洒农药提供精准的区域位置信息,减少了农药使用量,并保证青贮玉米的产量和品质不受影响,减少经济损失。

根据应用场景不同,基于深度学习的作物病害检测可分为基于固定式简单环境和基于田间复杂环境的两大作物病害检测方法。文献[8-9]使用改进卷积神经网络对玉米叶片病害识别进行研究,取得了较好的检测效果。文献[10]提出一种结合迁移学习和模型压缩的卷积神经网络用于玉米病害识别,能够在小样本场景下确保识别精确率,并进一步实现模型的轻量化。文献[11]提出的改进YOLOv5算法在增加极少复杂度的情况下明显提升了算法效率和性能,并且效果优于传统的YOLOv5s算法。文献[12]改进了YOLOX算法,改进后的模型不仅对农作物叶片病害识别具有较高的精度和较快的检测速度,参数量和计算量较少,而且易于部署在手机等移动设备。文献[13]改进了YOLOv4算法,实现了对苹果叶片多种病害目标的精准识别。文献[14]利用YOLOv5架构识别玉米作物病害,得到的模型具有较高准确率,有望在设备中进行应用,以解决玉米叶片病害检测问题。文献[15]比较了YOLOv4和YOLOv7在早期阶段进行植物病害识别的性能,结果表明,YOLOv7具有更好的性能。虽然上述方法取得了很好的检测效果,但这种基于固定式简单环境的病害检测方法,图像背景简单,使用场景和监测范围有限,无法对复杂的大田环境进行检测^[16]。

为了解决大田复杂环境下青贮玉米枯叶病检测问题,本文以实际大田田间复杂背景下无人机拍摄的玉米枯叶病图像为研究对象,针对大田环境中的各种复杂条件,改进了YOLOv7的特征提取能力,提出一种智能检测与识别模型YOLOv7-MLD(Maize Leaf-blight Detection),实现了对复杂田间背景下玉米枯叶病的精准检测,为指导早期青贮玉米枯叶病病害防治及其智能化检测系统和设备研发提供了技术支撑。

1 研究方法

1.1 YOLOv7算法

YOLOv7是YOLO系列的模型之一,与以往版本相比,YOLOv7具有更高的精度和更快的推理速度^[17]。其网络

结构主要分为3个部分:Input、Backbone与Head。Input部分主要对输入图像进行预处理,将输入的任意尺寸图像自适应放缩为640×640像素大小的RGB图片,并对数据进行Mosaic与Mixup增强,然后输入到Backbone中。Backbone部分为网络的主干,由卷积模块、高效层聚合网络(Efficient Layer Aggregation Network, ELAN)^[18]与MP模块构成,主要用于特征提取。其中,卷积模块由卷积层、数据归一化层和激活函数组成,激活函数采用Sigmoid加权线性单元(Sigmoid-weighted Linear Unit, SiLU)^[19]。ELAN通过控制最短和最长的梯度路径,增强网络的特征学习能力,提高模型的鲁棒性。MP模块有两个分支,作用是进行下采样。为增强模型的特征提取能力,其采用残差结构连接。Head部分主要包含SPPCSPC、结构重参化RepConv与Detect 3个模块。SPPCSPC由金字塔池化结构(Spatial Pyramid Pooling, SPP)^[20]与跨阶段区域网络(Cross Stage Partial, CSP)^[21]组成,结构重参化RepConv模块在训练时将3个分支叠加后输出,推理时会将分支的参数重参数化到主分支上。Detect模块最终输出3个不同尺寸的预测结果,包含目标边界框坐标、置信度和类别信息,从而实现多目标的多尺度预测。

1.2 基于改进YOLOv7的病害检测模型

在大田环境中,青贮玉米的枯叶病检测面临多个难点,包括光照不均、强光、暗光等不同光照条件和叶片遮挡的影响,无人机运动拍摄时导致的图像模糊以及发病初期染病区域小造成的检测困难等。由于这些因素的存在,导致原始YOLOv7对叶片病害的检测性能较差。为提高模型的整体检测精度,满足大田复杂环境下的应用需求,本文在YOLOv7网络的基础上,提出一种改进YOLOv7的智能检测与识别模型YOLOv7-MLD。首先在YOLOv7网络的主干中添加DBB(Diverse Branch Block)模块^[22],增强主干的特征提取能力;然后在3个输出特征层添加坐标注意力机制CA(Coordinate Attention)^[23],通过结合空间和通道信息,降低图像中无关目标和背景对病害检测的干扰,增强对病害特征的提取能力;最后将损失函数由CIoU替换为SIoU^[24],提高边界框的收敛速度和回归精度。YOLOv7-MLD模型结构如图1所示。

1.2.1 DBB模块嵌入

DBB(Diverse Branch Block)是一个类似Inception的多分支结构,由清华大学&旷视科技的丁霄汉等^[22]提出。与借鉴ResNet残差结构实现结构重参数化的RepVGG网络相比,DBB是借鉴Inception实现结构重参数化的^[25]。其将Inception的多分支、多尺度思想与重参数化思想进行了结合。由于多分支结构类型更丰富,感受野更加多样化,各操作具有不同的计算复杂度,因此更具有通用性,可用来替换单个卷积进行训练。这使得DBB可以作为一种等价嵌入模块直接插入到网络主干结构中,从而明显提升各种优秀主干特征提取网络的特征提取能力。

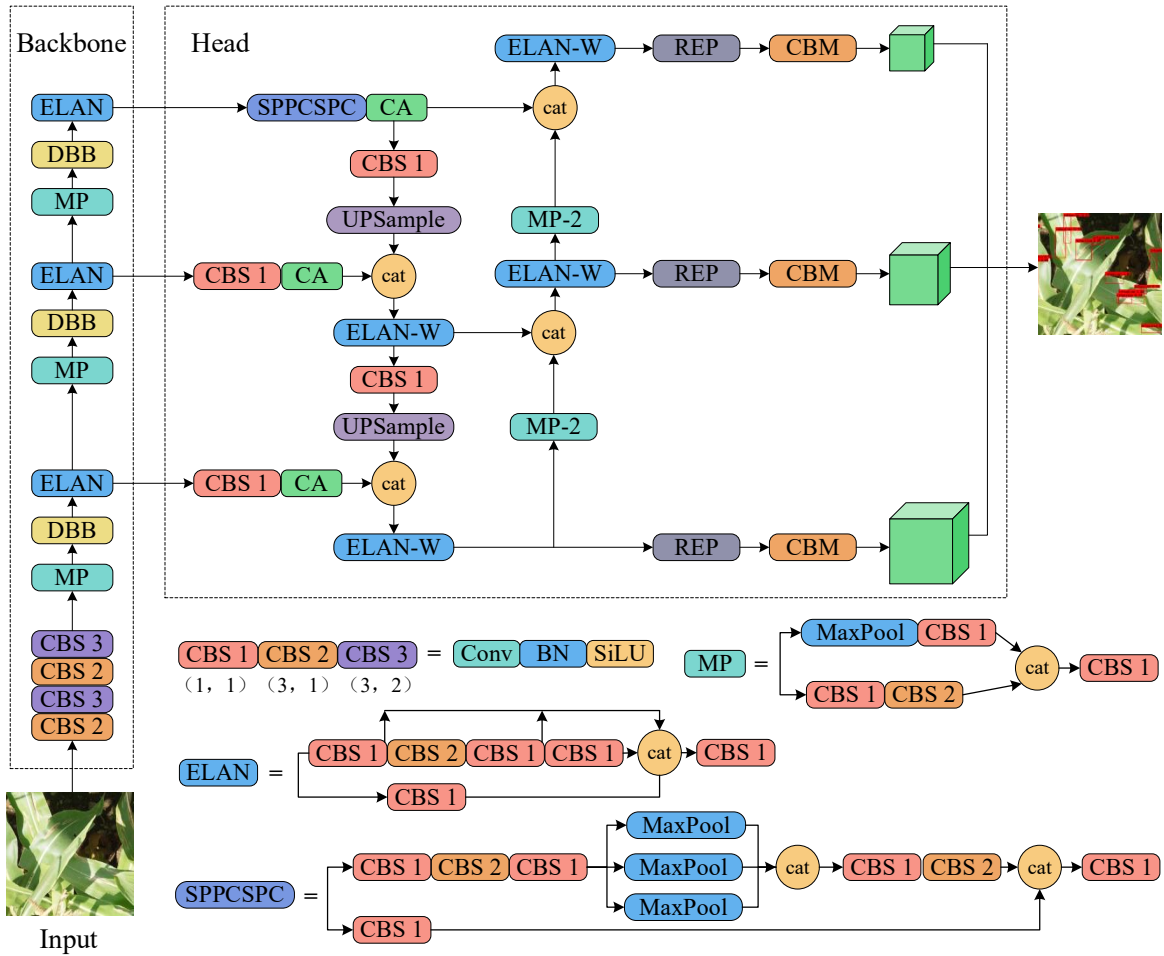


Fig. 1 YOLOv7-MLD model structure

图1 YOLOv7-MLD模型结构

DBB解耦了训练和推理结构,在训练时采用复杂的多分支微结构,且保持网络整体结构不变。而在推理或部署时,针对训练好的参数以线性组合的方式计算出对应的单路结构参数,仅采用等价变换后的结构及对应参数(多分支转换为单卷积),使得推理耗时损失极小。DBB在训练/推理时的模块结构如图2所示。其中, K 为卷积核大小 (convolution kernel size), 1×1 代表大小为 1×1 的卷积核。

本文在原有的主干特征提取网络基础上,在 ELAN 与 MP 模块中间嵌入 DBB 模块。通过组合不同尺度的卷积,获取不同大小的感受野,丰富了特征空间的多样性,提升了单一卷积的表达能。在提高精度同时,可以保证较快的推理速度。

1.2.2 坐标注意力机制融合

注意力机制可以提高网络对目标病害的检测能力,使其更关注相关信息并抑制冗余无关的干扰信息。坐标注意力模块具有轻量、高效的特点。其通过将病害图像的空间坐标信息嵌入通道特征中,显式构建通道间的远距离依赖关系,从而增强了模型对通道信息的敏感度,并聚合了位置信息。坐标注意力模块具体结构如图3所示。首先,对输入特征进行水平和垂直平均池化,生成具有方向特征图。然后,在空间维度上拼接这两个特征图,通过

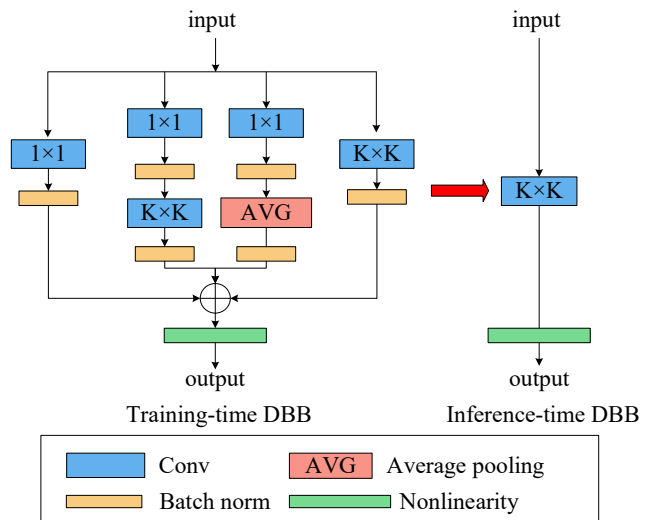


Fig. 2 DBB module structure

图2 DBB模块结构

1×1 卷积降维,使用 BN 层和非线性激活层对空间信息进行编码,生成具有空间位置信息的注意力图。接着,使用 1×1 卷积在水平和垂直方向降维,并使用 sigmoid 激活函数实现归一化和加权。最后,将两个注意力图应用于原输入特征图,实现空间坐标信息在通道上的加权融合。

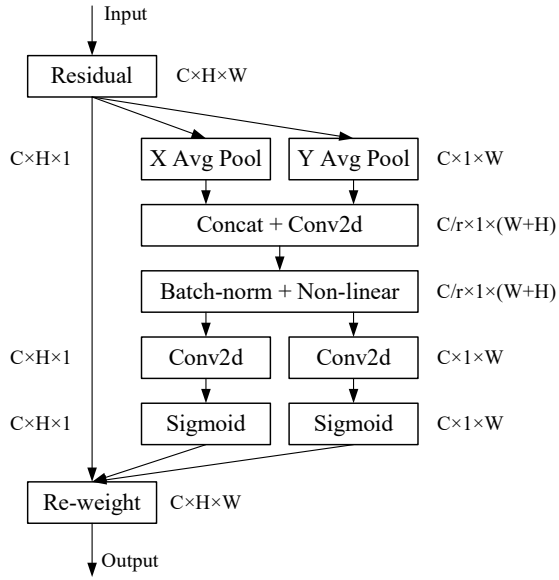


Fig. 3 Coordinate attention mechanism

图3 坐标注意力机制

本文在3个输出特征层添加坐标注意力机制,将空间位置信息嵌入到通道注意力中。在主干网络中,随着卷积次数增加,特征图的特点由分辨率高、通道少变为分辨率低、通道多。在此处增加坐标注意力机制,可以将其编码的空间信息充分嵌入通道中,加强主干网络对于空间坐标信息的提取,有利于提高对检测目标对象的定位和识别能力。

1.2.3 损失函数改进

在目标检测中,损失函数的定义起着重要作用。在YOLOv7算法中,CIoU损失函数没有考虑到预测框与真实框之间的方向不匹配。这种不匹配可能会导致算法的收敛速度较慢,收敛效率较低,并且最终产生的模型性能可能会较差。为解决此问题,本文使用SIoU损失函数替换CIoU损失函数,SIoU可以提高训练速度和推理的准确率^[24]。其考虑了真实框与预测框之间的向量角度,共包含4部分:角损失(angle cost)、距离损失(distance cost)、形状损失(shape cost)以及交并比损失U(intersection overunion)。图4为SIoU参数示意图。其中, B 、 B^{GT} 点分别为预测框中心点及真实框中心点, C_w 、 C_h 分别为 B 和 B^{GT} 点的横坐标与纵坐标之差, α 为两点连线与水平线的夹角, (b_{cx}, b_{cy}) 为预测框中心坐标, $(b_{cx}^{gt}, b_{cy}^{gt})$ 为真实框中心坐标, σ 为真实框与预测框中心点距离。

SIoU考虑到预测框与真实框相对位置的方向,将两框中心点连线与水平和垂直方向的两个夹角引入损失函数中。SIoU综合考虑了角度、距离、形状和IoU等4种因素,计算方法如式(1)所示。其中, Δ 为距离损失, Ω 为形状损失。

$$L_{SIoU} = 1 - IoU + \frac{\Delta + \Omega}{2} \quad (1)$$




Fig. 4 SIoU parameter diagram

图4 SIoU参数示意图

角度损失计算公式如下:

$$\Lambda = 1 - 2 \sin^2(\arcsin(x) - \frac{\pi}{4}) \quad (2)$$

其中, $x = \frac{C_h}{\sigma} = \sin(\alpha)$ 。

根据角度损失,定义距离损失计算公式如下:

$$\Delta = \sum_{t=x,y} (1 - e^{-\rho_t}) \quad (3)$$

其中, $\rho_x = (\frac{b_{cx}^{gt} - b_{cx}}{c_w})^2$, $\rho_y = (\frac{b_{cy}^{gt} - b_{cy}}{c_h})^2$, $\gamma = 2 - \Lambda$ 。

形状损失定义如下:

$$\Omega = \sum_{t=w,h} (1 - e^{-w_t})^\theta \quad (4)$$

其中, $w_w = \frac{|w - w^{gt}|}{\max(w, w^{gt})}$, $w_h = \frac{|h - h^{gt}|}{\max(h, h^{gt})}$ 。

式中, θ 控制对形状损失的关注程度。为避免过于关注形状损失而减少对预测框的移动, θ 范围为2~6。 w 、 h 为真实框的宽和高, w^{gt} 、 h^{gt} 为预测框的宽和高。

2 实验与结果分析

2.1 实验数据集

玉米枯叶病数据集(<https://osf.io/p67rz/>)是目前公开最大的玉米单一病害数据集^[26]。该数据集创建者通过给玉米接种枯叶病致病真菌(*Setosphaeria turcica*)使玉米感染病害,并采用“手持式”相机、“行进式”机械臂和无人机3种拍摄方式拍摄玉米感染了枯叶病的照片。本文选择其中的无人机拍摄数据集(drone set)作为研究对象。无人机型号为大疆Matrice 600,飞行高度为6 m,速度为1 m/s,每2 s采集一次图像。

在无人机拍摄数据集中,选择青贮期之前的玉米照片作为研究数据集,最终得到2386张图片用于训练与测试网络模型性能。数据集按照7:2:1的比例随机划分,训练集、验证集和测试集图像分别为1670、477、239幅。在训练过程中对应用数据进行增强处理,主要方法包括直方图均衡变换、拉普拉斯锐化变换、Mosaic增强与Mixup增强,以提高模型的泛化性能和鲁棒性。

2.2 模型训练

2.2.1 训练环境

模型训练使用中科曙光云计算平台,硬件环境为:处理器为多核心 1*7186H 32C,主频 2.7 GHz,内存 128 G,2 个 GPU 加速卡。软件环境为:Python3.6 版本、PyTorch1.9 框架、OpenCV 4.1.1 图像处理库。

2.2.2 参数设置

网络训练参数设置如下:图像输入尺寸为 640×640 像素, batch_size 大小为 32,初始学习率为 0.001。采用随机梯度下降(Stochastic Gradient Descent, SGD)方法优化模型,设置动量因子为 0.937,权重衰减因子为 0.000 5。模型共训练 300 轮,每迭代一个轮次保存当前最优权重,最后得到识别精度最高的模型。

2.2.3 评价指标

本文采用精确率(Precision, P)、召回率(Recall, R)、平均精确率(Average precision, AP)、调和平均值(F1 score, F1)来评价模型性能。

精确率为模型检测正确结果的占比,计算方法如式(5)所示。其中,真阳性(True Positive, TP)表示被正确预测的正样本病害数量,假阳性(False Positive, FP)表示将负样本病害预测为正样本的病害数量。召回率表示模型检测出目标类型数据的能力,计算方法如式(6)所示,其中假阴性(False Negative, FN)表示正样本病害被错误预测为负样本的情况。AP 值是目标检测模型的重要评价指标之一,计算方法如式(7)所示。AP 值通过对 P-R(Precision-Recall)曲线积分得到,表示 P 和 R 之间的面积,用于衡量模型在识别目标时的准确性和完整性。F1 值表示 P 和 R 的调和平均值,用来综合反映模型的精确率与召回率,计算方法如式(8)所示。

$$P = \frac{TP}{TP + FP} \quad (5)$$

$$R = \frac{TP}{TP + FN} \quad (6)$$

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

$$F1 = \frac{2PR}{P + R} \quad (8)$$

2.3 消融实验

为了验证改进模型中各模块的有效性,对模型进行消融实验。实验结果如表 1 所示。

由表 1 可以看出,3 种改进方法均提升了各项指标。

Table 1 Ablation experiment results

表 1 消融实验结果 %

序号	DBB	CA	SIoU	精确率	召回率	平均精度	F1 值
1				81.3	74.8	78.2	77.9
2	√			84.7	80.6	76.3	82.6
3		√		85.1	78.3	81.7	81.6
4			√	83.2	81.5	80.4	82.3
5	√	√	√	85.6	82.1	84.2	83.8

网络主干加入 DBB 模块后,算法精确率与召回率都有明显提升,验证了该模块可以有效提取特征。融合坐标注意力机制后,算法精确率的提升最大,可见加入注意力机制后降低了算法的误检率。CIoU 损失函数替换为 SIoU 函数后,算法的召回率提升明显,精确率稍有提升。经过整合 3 种改进方法后,YOLOv7-MLD 算法的精确率和召回率达到最高,相比 YOLOv7 算法精确率由 81.3% 提升到 85.6%,召回率由 74.8% 提升到 82.1%,AP 值由 78.2% 提高到 84.2%,F1 值由 77.9% 提高到 83.8%。

由于 DBB 引入了不同感受野、不同复杂度的多分支结构,在检测不同大小枯叶病感染面积时显著提升了原有模型的精度。注意力机制模块通过结合空间和通道信息,降低了图像中大片绿叶等目标和大田中复杂背景对病害检测的干扰。SIoU 损失函数使用平滑的 IoU 计算方式来计算预测框与真实框之间的交并比,并将其作为定位损失的一部分,可以减少定位误差对总体损失的影响,提高了病害目标检测精度。

因此,本文改进的算法中各个模块都对模型性能有正向提升,使得模型在青贮玉米病害检测中的表现比原始的 YOLOv7 更加优异,能够更准确地检测出病害区域。

2.4 不同检测模型性能比较

为评价改进模型的性能,用 Faster RCNN、YOLOv4、YOLOv5s、YOLOv7 模型采用相同数据集,在相同实验环境下进行对比实验,其中 Faster R-CNN 使用 ResNet-50 作为主干网络。最终的实验结果对比如表 2 所示。

Table 2 Detection performance of different models

表 2 不同模型检测性能

模型	精确率	召回率	平均精度	F1 值
Faster RCNN	56.4	72.5	82.3	63.4
YOLOv4	73.1	63.2	78.6	67.8
YOLOv5s	75.2	68.5	72.4	71.7
YOLOv7	81.3	74.8	78.2	77.9
YOLOv7-MLD	85.6	82.1	84.2	83.8

由表 2 可知,YOLOv7-MLD 模型在精确率和召回率指标上均优于其他经典网络,F1 值分别比 Faster R-CNN、YOLOv4、YOLOv5s 和 YOLOv7 高出 20.5%、16.1%、12.2% 与 5.9%。因此,YOLOv7-MLD 青贮玉米枯叶病检测模型在检测精度方面有较大优势,相比原 YOLOv7 模型有较大提升,可以实现大田环境下对青贮玉米枯叶病目标的准确识别。

2.5 模型检测效果

将改进后的模型在测试集中进行测试,检测效果如图 5 所示。可以看出,改进后的模型在不同光照、遮挡以及运动模糊等复杂环境下,可以准确识别出青贮玉米叶面枯叶病感染区域,误检和漏检情况很少发生。尤其是在发病区域很小的条件下,仍能准确识别出染病情况,为早期发现病害奠定了基础。结果表明,改进后的模型对复杂环境下青贮玉米枯叶病的识别效果较好。



Fig. 5 Detection effect of the model under various conditions

图5 模型在各种条件下的检测效果

3 结语

为掌握大田环境下青贮玉米的枯叶病发病情况,有针对性地实行农药喷洒防治,本文对目标检测模型YOLOv7进行了相应改进,包括网络主干结构调整、特征融合方式改进、损失函数优化等。实验结果表明,改进的方法提升了模型的精确率与召回率。在测试集上的检测效果表明,该方法可以在复杂条件下检测到更多的病害区域目标,改进后的模型在识别精度上具有明显优势。

本文对青贮玉米枯叶病检测的研究仍存在不足,即未进行模型检测速度的实验研究。在后续研究工作中,除需进一步提高检测精度外,还需对模型进行轻量化和实时化探索研究,以便模型能够在算力受限的移动设备上实时、快速的病害目标检测。

参考文献:

[1] WANG L P, BAI L F, WANG T H, et al. Effects of different nitrogen levels on nitrogen accumulation and transport in silage maize[J]. *Crops*, 2023 (4):165-173.
王丽萍,白岚方,王天昊,等. 不同施氮水平对青贮玉米植株氮素积累和转运的影响[J]. *作物杂志*, 2023(4):165-173.

[2] WANG A J. Analysis of pathogenesis and control strategy of maize big spot disease[J]. *South China Agriculture*, 2019, 13(30):17-18.
王爱军. 玉米大斑病的发病原因及防治策略分析[J]. *南方农业*, 2019, 13(30):17-18.

[3] QI H X, LU G X, LI Z R, et al. Identification and pathogenicity of alternaria leaf blight strains in silage maize in Qinghai province[J]. *Acta Prataculturae Sinica*, 2021, 30(6):94-105.
祁鹤兴,芦光新,李宗仁,等. 青海省青贮玉米链格孢叶枯病病原菌鉴定及其致病力分析[J]. *草业学报*, 2021, 30(6):94-105.

[4] JI T. Research on monitoring methods of maize pests and diseases based on machine vision[D]. Wuhu: Anhui Polytechnic University, 2017.
吉涛. 基于机器视觉的玉米病虫害监测方法研究[D]. 芜湖:安徽工程大学, 2017.

[5] YANG Y. Accurate real-time detection of maize leaf blight based on improved convolutional neural network [D]. Zhenjiang: Jiangsu University, 2021.
杨育. 基于改进卷积神经网络的玉米枯叶病精准实时检测研究[D]. 镇江:江苏大学, 2021.

[6] XU Y X, ZHANG J Z, LAN Y B, et al. Research progress of early crop disease identification based on infrared thermal imaging and machine learning[J]. *Journal of Chinese Agricultural Mechanization*, 2023, 44(5):188-197.
徐衍向,张敬智,兰玉彬,等. 基于红外热成像和机器学习的作物早期病害识别研究进展[J]. *中国农机化学报*, 2023, 44(5):188-197.

[7] WANG Q, SHU X B, LIU Y. Research on information acquisition system

- of unmanned aerial vehicle based on computer vision[J]. *Journal of Agricultural Mechanization Research*, 2018, 40(10):235-238.
- 王琴,舒晓斌,刘勇. 基于计算机视觉的无人机农田信息获取系统研究[J]. *农机化研究*, 2018, 40(10):235-238.
- [8] LI S Q, CHEN C, ZHU T, et al. Plant leaf disease identification based on lightweight residual network[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(3):243-250.
- 李书琴,陈聪,朱彤,等. 基于轻量级残差网络的植物叶片病害识别[J]. *农业机械学报*, 2022, 53(3):243-250.
- [9] HUI Q J, SUN J. Research on maize leaf disease recognition model based on multi-scale feature metric meta-learning[J]. *Jiangsu Agricultural Sciences*, 2023, 51(9):199-206.
- 惠巧娟,孙婕. 基于多尺度特征度量元学习的玉米叶片病害识别模型研究[J]. *江苏农业科学*, 2023, 51(9):199-206.
- [10] DENG P F, GUAN Z, WANG Y Y, et al. Identification method of maize disease based on transfer learning and model compression[J]. *Computer Science*, 2022, 49(S2):444-449.
- 邓鹏飞,官铮,王宇阳,等. 基于迁移学习和模型压缩的玉米病害识别方法[J]. *计算机科学*, 2022, 49(S2):444-449.
- [11] SU J K, DUAN X H, YE Z B. Research on corn disease detection based on improved YOLOv5 algorithm[J]. *Journal of Frontiers of Computer Science & Technology*, 2023, 17(4):933-941.
- 苏俊楷,段先华,叶赵兵. 改进YOLOv5算法的玉米病害检测研究[J]. *计算机科学与探索*, 2023, 17(4):933-941.
- [12] LI K S, YANG Z S, JIANG Z F, et al. Detection and identification of crop leaf diseases based on improved YOLOX-Nano[J]. *Journal of South China Agricultural University*, 2023, 44(4):593-603.
- 李康顺,杨振盛,江梓锋,等. 基于改进YOLOX-Nano的农作物叶片病害检测与识别方法[J]. *华南农业大学学报*, 2023, 44(4):593-603.
- [13] ZHAO J W, TIAN G Z, QIU C, et al. Apple leaf disease detection method based on improved YOLOv4 algorithm[J]. *Jiangsu Agricultural Sciences*, 2023, 51(9):193-199.
- 赵嘉威,田光兆,邱畅,等. 基于改进YOLOv4算法的苹果叶片病害检测方法[J]. *江苏农业科学*, 2023, 51(9):193-199.
- [14] AUSTRIA Y C, MIRABUENO M C A, LOPEZ D J D, et al. EZM-AI: a Yolov5 machine vision inference approach of the Philippine corn leaf diseases detection system[C]//2022 IEEE International Conference on Artificial Intelligence in Engineering and Technology, 2022: 1-6.
- [15] WANG X M, TANG S H. Comparative study on leaf disease identification using Yolov4 and Yolov7 algorithm[J]. *AgBioForum*, 2023, 25(1):58-67.
- [16] JIANG X L, CHEN T E, WANG C, et al. Small object detection algorithm of agricultural pest image in field environment[J]. *Computer Engineering*, 2024, 50(1):232-241.
- 蒋心璐,陈天恩,王聪,等. 大田环境下的农业害虫图像小目标检测算法[J]. *计算机工程*, 2024, 50(1):232-241.
- [17] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023:7464-7475.
- [18] ZHANG X, ZENG H, GUO S, et al. Efficient long-range attention network for image super-resolution[C]//European Conference on Computer Vision, 2022: 649-667.
- [19] ELFWING S, UCHIBE E, DOYA K. Sigmoid-weighted linear units for neural network function approximation in reinforcement learning[J]. *Neural Networks*, 2018, 107: 3-11.
- [20] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 37(9): 1904-1916.
- [21] LIU W, HASAN I, LIAO S. Center and scale prediction: anchor-free approach for pedestrian and face detection[J]. *Pattern Recognition*, 2023, 135: 109071.
- [22] DING X H, ZHANG X Y, HAN J G, et al. Diverse branch block: building a convolution as an inception-like unit[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 10881-10890.
- [23] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13713-13722.
- [24] GEVORGYAN Z. SIoU loss: more powerful learning for bounding box regression[DB/OL]. <https://arxiv.org/abs/2205.12740>.
- [25] WANG P, CHEN P, YUAN Y, et al. Understanding convolution for semantic segmentation[C]//2018 IEEE Winter Conference on Applications of Computer Vision, 2018: 1451-1460.
- [26] TYR W H, STEWART E L, NICHOLAS K, et al. Image set for deep learning: field images of maize annotated with disease symptoms[J]. *BMC Research Notes*, 2018, 11(1):440.

(责任编辑:黄健)