

施 杰, 林双双, 张 威, 等. 基于轻量化改进型 YOLOv5s 的玉米病虫害检测方法[J]. 江苏农业学报, 2024, 40(3): 427-437.
doi: 10.3969/j.issn.1000-4440.2024.03.005

基于轻量化改进型 YOLOv5s 的玉米病虫害检测方法

施 杰^{1,2}, 林双双¹, 张 威¹, 陈立畅¹, 张毅杰¹, 杨琳琳^{1,2}

(1. 云南农业大学机电工程学院, 云南 昆明 650201; 2. 云南省作物生产与智慧农业重点实验室, 云南 昆明 650201)

摘要: 针对复杂环境下目前现有的玉米病虫害检测方法的精度不理想、模型复杂、难以在移动端部署等问题, 本研究提出了基于轻量化改进型 YOLOv5s 的玉米病虫害检测方法。首先, 采用轻量级网络 GhostNet 替换原始 YOLOv5s 模型中特征提取网络和特征融合网络的卷积层, 降低模型的计算量和参数量, 提高运行速度, 以满足移动端的部署要求; 其次, 为弥补 GhostNet 所带来的检测精度下降缺陷, 在模型的主干特征提取网络中引入注意力机制, 更加全面地评估特征权值, 以增强玉米病虫害的特征, 减弱无关信息的干扰, 提升检测性能; 最后, 将模型的损失函数由 CIOU 替换为 EIOU, 以增强模型对目标的精确定位能力, 从而提升模型的收敛速度和回归精度。试验结果表明, 改进模型相比原始 YOLOv5s 模型在对供试玉米病虫害检测中, P 、 R 和 mAP 分别提高了 1.9 个百分点、2.2 个百分点和 2.0 个百分点, 分别达到了 94.6%、80.2% 和 88.8%; 在保持较高检测精度的同时, 模型的计算量、参数量和模型大小分别减少了 50.6%、52.9% 和 50.4%, 解决了检测模型在移动端的部署问题。

关键词: 玉米; 病虫害; 检测模型; YOLOv5s; 轻量化

中图分类号: TP391.41; S432

文献标识码: A

文章编号: 1000-4440(2024)03-0427-11

A corn disease and pest detection method based on lightweight improved YOLOv5s

SHI Jie^{1,2}, LIN Shuang-shuang¹, ZHANG Wei¹, CHEN Li-chang¹, ZHANG Yi-jie¹, YANG Lin-lin^{1,2}

(1. Faculty of Mechanical and Electrical Engineering, Yunnan Agricultural University, Kunming 650201, China; 2. The Key Laboratory for Crop Production and Smart Agriculture of Yunnan Province, Kunming 650201, China)

Abstract: Aiming at the problems of unsatisfactory detection accuracy, complex model and difficult deployment on mobile terminals in the existing maize disease and pest detection methods in complex environments, this study proposed a maize disease and pest detection method based on lightweight improved YOLOv5s. Firstly, the lightweight network GhostNet was used to replace the convolutional layer in the feature extraction network and feature fusion network in the original YOLOv5s model, which reduced the calculation and parameter amount of the model and improved the running speed to meet the deployment requirements of the mobile terminal. Secondly, in order to compensate for the problem of detection accuracy degradation caused by GhostNet, the normalization-based attention module (NAM) was introduced into the backbone feature

extraction network of the model to evaluate the feature weights more comprehensively, so as to enhance the characteristics of corn diseases and pests, weaken the interference of irrelevant information, and improve the detection performance. Finally, the loss function of the model was replaced by EIOU from CIOU to enhance the model's ability to accurately locate the target, so as to improve the convergence speed and regression accuracy of the model. The experimental results showed that compared with the original

收稿日期: 2023-05-18

基金项目: 国家自然科学基金项目(32260438); 云南省重大科技专项(202302AE09002002); 云南省作物生产与智慧农业重点实验室开放课题; 云南省教育厅科学研究基金项目(2023Y0985)

作者简介: 施 杰(1981-), 男, 云南昆明人, 博士, 副教授, 主要从事智能农业装备、机械故障诊断技术研究。(E-mail) km_shijie@126.com

通讯作者: 杨琳琳, (E-mail) 29545343@qq.com

YOLOv5s model, the P , R and mAP of the final improved model increased by 1.9 percentage points, 2.2 percentage points and 2.0 percentage points, respectively, reaching 94.6%, 80.2% and 88.8%. While maintaining high detection accuracy, the calculation amount, parameter amount and capacity of the model were reduced by 50.6%, 52.9% and 50.4%, which solved the deployment problem of the detection model on the mobile terminal.

Key words: corn; pests and diseases; detection model; YOLOv5s; lightweight

玉米是中国主要粮食作物,其种植面积和产量长期稳居三大谷物之首。近年来,玉米饲用消费和工业消费对玉米的需求均持续增长,玉米产业的健康稳定发展对国家粮食安全意义重大^[1]。研究表明,玉米生长期间的病虫害问题是影响其产量和质量的主要因素。因此,对玉米常见病虫害进行早期诊断与防治是获得丰产的重要举措^[2-3]。

农作物在种植期间依靠人工来观测病虫害的传统管理模式,存在着主观性强、工作量大等问题。随着人工智能和大数据技术的不断发展,利用基于深度学习的机器视觉技术对图像特征信息进行提取^[3-6],能有效解决病虫害检测准确率低、效率低等问题,这也是农作物种植管理智能化的重要研究方向。许多学者在这方面开展了大量研究。黄丽明等^[7]利用可分离卷积和倒残差结构对 YOLOv4 算法进行改进,以提高松材线虫识别的精度和效率,试验结果表明,改进后的算法平均精度达到 80.85%,参数大小为 44.20 MB;刘天真等^[8]利用 SE Block 结构改善了 YOLOv3 对自然场景下冬枣果实特征的提取能力,使平均精度达到 82.01%,实现了冬枣的快速精准识别;Farjon 等^[9]使用 Faster R-CNN 算法检测苹果花,模型检测精度为 68.00%;Ferentinos 等^[10]使用健康与患病的叶片来训练卷积神经网络模型,用于识别相应的患病叶片,检测精度达到 99.53%;苏俊楷等^[11]对 YOLOv5 的主干网络和颈部网络进行改进,使玉米病害的检测精度达到 95.93%;徐会杰等^[12]提出了 YOLOv3-Corn 的玉米叶片病虫害检测模型,该模型使用 Darknet-53 作为特征提取网络,并利用聚类算法选取先验框分别匹配到检测层中进行目标识别,模型检测精度为 93.31%。

虽然随着技术发展检测精度得到提升,但仍存在参数量大、模型复杂等问题,无法将其部署到边缘端移动设备中进行应用。周维等^[13]针对水稻病虫害检测精度低、速度慢、模型复杂度高、部署困难等问题,对 YOLOv4 进行改进,结果表明,改进后模型检测精度达到 79.38%,模型权重大小为 42.45 MB;邢洁洁等^[14]就垃圾检测算法在农田复杂环境下检测精度不高、模型

复杂等问题,对 YOLOv5s 进行轻量化改进,试验结果表明,模型最终精度达到了 90.90%,在保持精度的同时大幅减少模型复杂度,满足了边缘计算设备对模型的性能需求;张振国等^[15]为解决红花采摘机器人在检测时的精度低与实时性差的问题,提出 GSC-YOLOv3 算法,该算法先进行轻量化改进,再使用空间金字塔和注意力机制提高模型检测精度,检测结果表明,在测试集下的检测精度达到 91.89%,取得良好的效果。王卫星等^[16]为实时准确检测荔枝病虫害,以 YOLOv4 为基础进行轻量化改进,同时使用新特征融合方法和注意力机制,最终模型内存占用量比原始模型减小 84%,检测精度提升 4.13 个百分点,为农作物病虫害实时检测研究提供参考。

以上关于农作物病虫害检测的研究已经取得了较大进展,但针对玉米病虫害检测方面的研究较少。为解决玉米病虫害检测方法在复杂环境下检测精度不理想、模型复杂、难以在移动端部署等问题,本研究拟以 YOLOv5s 模型为基础,提出一种基于轻量化改进型的玉米病虫害检测方法。首先,采用轻量级网络 GhostNet 来替换原有模型中特征提取网络和特征融合网络的卷积层,以生成有效特征并降低模型复杂度,同时,引入注意力机制(Normalization-based attention module, NAM),减弱无关信息干扰特征,提高模型对玉米病虫害的检测性能。然后,再通过优化损失函数,来提升模型的收敛速度和回归精度,以满足复杂环境下的病虫害检测需求。最后,通过在自建数据集上的试验验证改进模型的有效性。

1 材料与方法

1.1 数据采集

本研究检测的对象为玉米病虫害图像。有研究结果显示,黏虫、灰飞虱、锈病和斑病是玉米生长过程中最为常见的病虫害,也是影响玉米产量和质量的主要因素之一^[17-19],因此选择这 4 种病虫害图像为研究对象,其病虫害样本图像见图 1。

模型训练后的鲁棒性和泛化性受到数据集质量




图1 采集的玉米病虫害图像样本

Fig.1 Image samples of maize pests and diseases collected in this study

的影响,为了降低数据集对模型的影响,本研究自建了玉米病虫害数据集。数据集的数据来源:在云南农业大学玉米种植试验田内采集的病虫害图像,在云南省昭通市昭阳区玉米种植田内采集的病虫害图像和源自网络的玉米病虫害图像。图像的采集时间为2022年7-9月,为满足数据集多样性的要求,分别在晴天、阴天和雨天,以正面、侧面、仰视等不同拍摄角度进行数据图像的采集,图像中包含了密集、稀疏、重叠、顺光、逆光等不同背景噪声的图像。图2为采集的部分图像样本。




图2 不同环境下采集的图像样本

Fig.2 Image samples collected in different environments

1.2 数据集制作

首先,对采集的图像进行旋转、平移、变亮、变暗、高斯噪声、椒盐噪声等数据增强处理,以实现数据集的扩展和多样化,从而提高模型训练的鲁棒性与泛化性。然后,采用 labelImg 工具对经数据增强后的1 985张图像进行特征标注。分别将玉米黏虫、灰飞虱、锈病和斑病标注为 N、H、X 和 B 4 个类别(标注时为避免由不同人标注而产生的细小差别,所有标注均为同一人完成,再由另一人检查以保证数据集标签的准确性。),并将其类别信息和位置信息保存为 XML 文件,再转换为 YOLOv5s 所需要的 TXT 格式文件。最后,划分训练集、验证集和测试

集,供模型训练和测试使用。表1为玉米病虫害图像数据集的详细信息。

表1 玉米病虫害图像数据集

Table 1 Maize pest and disease image dataset

病害名称	标注名称	训练集 (张)	验证集 (张)	测试集 (张)	图像总数 (张)
黏虫	N	486	79	69	634
灰飞虱	H	357	42	43	442
锈病	X	410	41	46	497
斑病	B	344	30	38	412
总数		1 597	192	196	1 985

1.3 YOLOv5s 模型

YOLO 系列算法^[20-22]采用回归思想,凭借检测精度高、推理速度快等优势,能够快速完成目标检测任务,在很多领域都取得了较为满意的结果,已成为主流算法之一。随着技术的发展,YOLOv5s 也一直被各领域的学者不断完善与优化,并展现出非常不错的性能。YOLOv5s 算法由输入端、主干网络、颈部网络以及预测头^[23]构成,其框架图如图3所示。

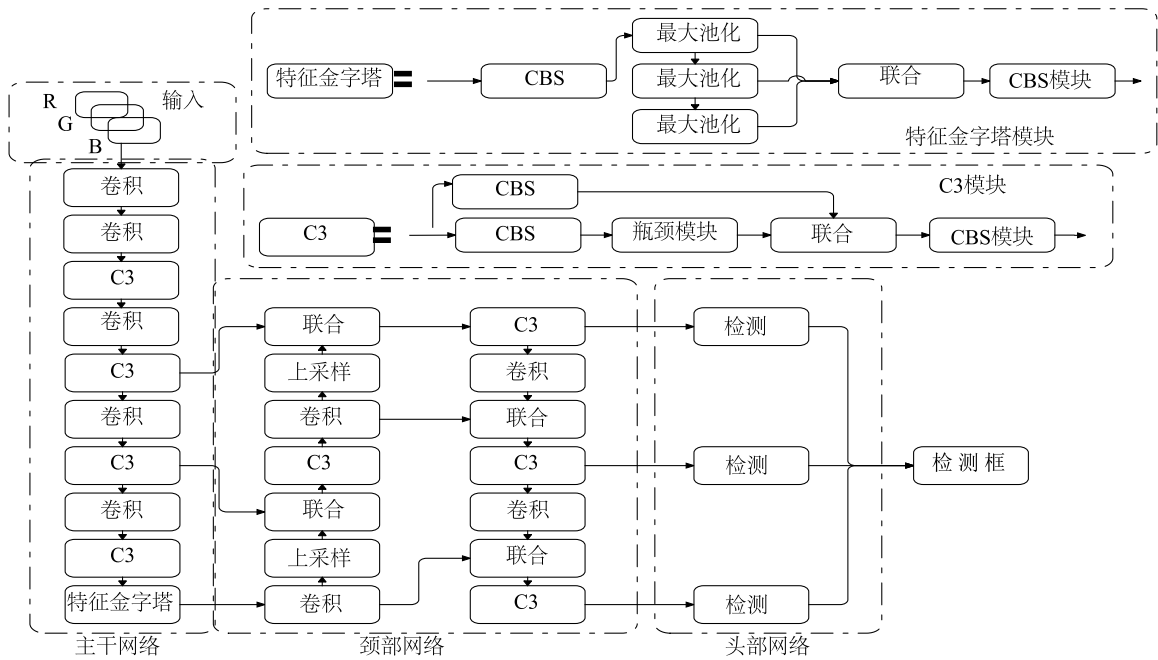
1.4 改进 YOLOv5s 模型

在移动端边缘计算设备的目标检测任务中,模型检测精度、速度和体积大小是评价模型性能的重要指标。对于单阶段目标检测,YOLO 系列算法在检测精度和速度上都具有明显优势,而 YOLOv5s 更是继承了YOLOv1~YOLOv4 的特点,成为目标检测领域的首选网络^[14]。因此,本研究拟针对移动端边缘计算设备能力受限的问题,研究了一种模型轻量化、添加注意力机制和优化损失函数的 YOLOv5s 改进模型,运用于玉米病虫害的目标检测。

1.4.1 引入轻量化 GhostNet 模块

传统卷积神经网络提取图片特征时,会产生特征信息冗余、计算量和参数量大等问题,YOLOv5s 具有较高检测精度也是由于其网络庞大,难以直接在移动端边缘计算设备进行部署,必须减少计算量和参数量。

通过在 YOLOv5s 中引入 GhostNet^[24]网络进行轻量化改进。GhostNet 是一种新型的轻量化网络,其利用简单的线性操作生成丰富的特征图,从而避免大量卷积运算,以减少模型计算量和参数量。Ghost Module 利用1×1卷积对输入的玉米病虫害图像目标特征进行缩减,再使用逐层卷积得到额外的特征图,最后将二者的结果进行堆叠生成新的病虫



R、G、B 为红、绿、蓝 3 个通道的颜色; C3: 跨阶段局部网络模块。

图 3 YOLOv5s 框架图

Fig.3 YOLOv5s frame diagram

害目标特征图,以此消除特征信息冗余,并获得轻量化模型。Ghost Bottlencks 是由 Ghost Module 组成的瓶颈结构(图 4),可分为主干部分和残差部分。当我们需要对特征层的宽和高进行压缩的时候,将 Ghost Bottlencks 的 Stride 设为 2,便可对特征层的宽和高进行压缩,此时,加入一个步长为 2×2 的深度可分离卷积在主干网络的 2 个 Ghost Module 中对特征层进行压缩,在残差部分也会加入一个步长为 2×2 的深度可分离卷积和 1×1 的普通卷积。

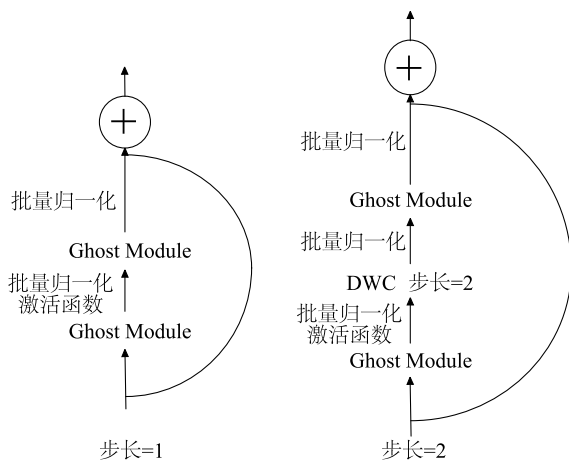


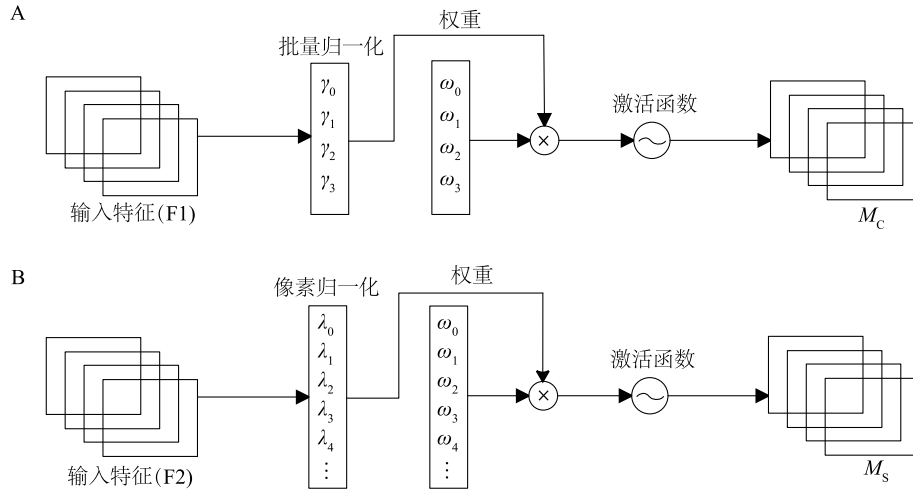
图 4 不同步长 Ghost 瓶颈结构

Fig.4 Ghost bottleneck structure with different step sizes

1.4.2 添加注意力机制 图像背景中存在杂草、土地和光线遮挡等问题导致对玉米病虫害的目标检测更为复杂。通过添加注意力机制可以增强模型对特征的捕捉能力,提高模型检测精度。玉米病虫害特征信息在图像中占比较小,模型更需减少对无关特征信息的关注度。所以,可以在 YOLOv5s 中添加基于标准化的注意力机制(Normalization-based attention module, NAM)^[25]。NAM 利用权重影响因子来增强显著性权值,从而提高注意力机制的性能。它通过批量归一化(Batch normalization, BN)^[26]的比例因子来表示权重的重要性,避免了像其他注意力机制一样使用全连接层和卷积层而造成计算量大的弊端。

NAM 基于卷积注意力机制(Convolutional block attention module, CBAM)^[27],又设计了通道和空间注意力子模块,如图 5 所示。以 BN 中的比例因子去计算通道方差用以表示通道注意力模块中权重的重要性,计算公式见公式(1)~公式(5)。

在玉米病虫害检测任务中, NAM 能够更加全面地评估特征权值,以增强玉米病虫害的特征,减弱复杂背景与无关信息的干扰,从而增强模型的鲁棒性和泛化能力,提升检测性能。



γ_i 和 λ_i : 缩放因子; ω_i : 权重; M_c 和 M_s : 通道注意力模块和空间注意力模块的输出特征。

图 5 通道 (A) 和空间注意力模块 (B)

Fig.5 Channel (A) and spatial attention modules (B)

$$B_{out} = \text{BN}(B_{in}) = \gamma \frac{B_{in} - \mu_B}{\sqrt{\sigma_B^2 + \varepsilon}} + \beta \quad (1)$$

$$W_\gamma = \frac{\gamma_i}{\sum_{i=0} \gamma_i} \quad (2)$$

$$W_\lambda = \frac{\lambda_i}{\sum_{i=0} \lambda_i} \quad (3)$$

$$M_c = \text{Sigmoid}\{W_\gamma[\text{BN}(F_1)]\} \quad (4)$$

$$M_s = \text{Sigmoid}\{W_\lambda[\text{BN}_s(F_2)]\} \quad (5)$$

式中, μ_B 和 σ_B : 小批量 B 的均值和标准差;

γ 和 β : 可训练的仿射变换参数(尺度和位移);

γ_i 和 λ_i : 通道注意力模块和空间注意力模块的每个通道的比例因子; W_γ 和 W_λ : γ_i 和 λ_i 的注意力权重; M_c 和 M_s : 通道注意力模块和空间注意力模块的输出特征。 F_1 和 F_2 : 输入特征变量。

1.4.3 边框损失函数优化 在模型训练中损失函数发挥了重要作用, 其能够评估模型预测框与真实框之间的距离。大多数算法选择标准性能度量(IoU)作为损失函数^[28]。但是, 当真实框与预测框 IoU 部分重叠或不重叠时便无法反映出二者的重合度和距离, 使得模型无法进行训练。YOLOv5s 模型使用 CIoU 损失函数, 它将两框之间的中心点距离、纵横比和重叠面积考虑进去, 使目标边框回归更加稳定。CIoU 损失函数见公式(6)~公式(9)。

$$L_{\text{CIoU}} = 1 - \text{IoU} + \frac{\rho^2(b, b^{gt})}{c^2} + av \quad (6)$$

$$a = \frac{v}{(1 - \text{IoU}) + v} \quad (7)$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h} \right)^2 \quad (8)$$

$$\text{IoU} = \frac{A \cap B}{A \cup B} \quad (9)$$

式中, h 和 w : 预测框的高和宽;

b 和 b^{gt} : 预测框中心点和目标框中心点;

a 和 v : 分别为权重系数和长宽比一致性的参数;

h^{gt} 和 w^{gt} : 真实框的高和宽;

ρ^2 : 两框中心点间的欧式距离;

c : 同时包含两框最小封闭包矩形框的对角线距离;

IoU : 损失函数; A : 真实框的集合; B : 预测框的集合。

虽然 CIoU 损失函数弥补了 IoU 损失函数的不足, 但还是忽略了边框尺寸与其置信度存在的真实差异。针对这一问题, Zhang 等^[29]提出了 EIoU (Efficient intersection over union) 损失函数。EIoU 损失函数的惩罚项是将纵横比影响因子拆开, 计算目标框和锚框的长、宽, 它包括标准性能度量损失、中心点距离损失和宽高损失三部分。EIoU 损失函数公

所有检测样本中正确样本数量的比例; mAP :所有类别 AP 值的平均值。

2 结果与分析

为验证本研究所提出的 YOLOv5s 改进模型的优越性,在相同试验环境下使用同一数据集进行试验验证。

2.1 YOLOv5 模型轻量化结果

由于 YOLOv5s 模型提取图像特征时会产生特征信息冗余以及计算量和参数量大等问题,影响了其在移动端的部署应用,本研究对 YOLOv5s 模型进行不同程度的轻量化模块替换,并进行了对比试验,结果见表 2。从试验结果来看,经轻量化改进的 YOLOv5s-G1、YOLOv5s-G2 和 YOLOv5s-G 模型在计算量、参数量和模型大小方面都大幅下降,其中 YOLOv5s-G1 分别减少 32.9%、27.1% 和 27.0%, YOLOv5s-G2 分别减少 45.6%、41.4% 和 39.7%, YOLOv5s-G 分别减少 50.6%、52.9% 和 50.4%,可见 YOLOv5s-G 的轻量化效果最好。但模型轻量化后,网络的深度、卷积量和特征提取能力也下降了,导致 P 、 R 和 mAP 值都下降。其中,YOLOv5s-G2 的

mAP 值相比原模型下降了 7.1 个百分点;YOLOv5s-G1 的 mAP 值下降 3.3 个百分点,降幅最小;YOLOv5s-G 是改进后轻量化效果最好的模型,且 mAP 仅比 YOLOv5s-G1 低 1.3 个百分点。证明在 YOLOv5s 模型中引入 GhostNet 能够实现轻量化,但是检测精度也有所下降,达不到移动端的应用需求。因此,以 YOLOv5s-G 为基础进一步改进,提升其检测精度。

2.2 添加注意力机制结果

通过引入注意力机制(NAM)来加强模型对目标特征的捕捉能力,使模型学习到更多有效信息,以提升检测精度。为了验证添加 NAM 后对 YOLOv5s-G 模型检测精度的影响,进行了对比试验。由表 3 可知,YOLOv5s-G-N[引入注意力机制(NAM)的 YOLOv5s-G 模型]在计算量、参数量和模型大小基本不变的情况下, P 、 R 和 mAP 分别提升了 4.9 个百分点、4.3 个百分点和 4.9 个百分点。这是由于引入 NAM 后,玉米病虫害特征得到增强,复杂背景与无关信息干扰减弱,从而提升了模型检测精度。

表 2 YOLOv5s 模型轻量化试验结果

Table 2 Lightweight experiment results of YOLOv5s model

模型	精确率 (%)	召回率 (%)	平均精度均值 (%)	计算量 (G)	参数量 ($\times 10^6$)	模型大小 (MB)
YOLOv5s	92.7	78.0	86.8	15.8	7.0	14.1
YOLOv5s-G1	88.7	74.5	83.5	10.6	5.1	10.3
YOLOv5s-G2	85.9	74.8	79.7	8.6	4.1	8.5
YOLOv5s-G	88.8	75.8	82.2	7.8	3.3	7.0

YOLOv5s:原始模型;YOLOv5s-G1:将主干网络中的 Conv、C3 模块替换为 GhostConv、C3Ghost 模块的轻量化改进模型;YOLOv5s-G2:对主干网络进行轻量化改进,而颈部网络中仅是 C3 模块替换为 C3Ghost 模块的改进模型;YOLOv5s-G:将主干网络和颈部网络都进行轻量化的改进模型。

表 3 YOLOv5s-G-N 与 YOLOv5s-G 模型对比试验结果

Table 3 Comparison test results of YOLOv5s-G-N and YOLOv5s-G

模型	精确率 (%)	召回率 (%)	平均精度均值 (%)	计算量 (G)	参数量 ($\times 10^6$)	模型大小 (MB)
YOLOv5s-G	88.8	75.8	82.2	7.8	3.3	7.0
YOLOv5s-G-N	93.7	80.1	87.1	7.8	3.3	7.0

YOLOv5s-G-N:引入注意力机制(NAM)的 YOLOv5s-G 模型。

2.3 边框损失函数优化结果

本研究对比了 EIoU 损失函数和 CIoU 损失函数对 YOLOv5s 模型性能的影响。图 7 为经 200 轮迭代后,2 种采用不同损失函数的 YOLOv5s 模型的损

失曲线。可见 EIoU 损失函数和 CIoU 损失函数都表现出了较快的预测回归过程,但在收敛速度上 EIoU 损失函数更为优越。

为进一步验证 EIoU 损失函数对 YOLOv5s-G-N

轻量化改进模型的效果,本研究将 YOLOv5s-G-N-E 模型(经过 EIou 损失函数优化的 YOLOv5s-G-N 模型)与 YOLOv5s-G-N 模型行了试验对比。由表 4 可知,YOLOv5s-G-N-E 模型在计算量、参数量和模型大小不变的情况下, P 、 R 、 mAP 分别提高了 0.9 个百分点、0.1 个百分点和 1.7 个百分点。究其原因这是由于 EIou 损失函数弥补了 CIou 损失函数边界框尺寸与其置信度存在的真实差异,使目标框与锚框相差最小,从而改善了模型性能。




图 7 边界损失函数迭代后的损失曲线图

Fig.7 The loss curve after the iteration of frame loss function

表 4 YOLOv5s-G-N-E 与 YOLOv5s-G-N 模型对比试验结果

Table 4 Comparison test results of YOLOv5s-G-N-E and YOLOv5s-G-N

算法模型	精确率 (%)	召回率 (%)	平均精度均值 (%)	计算量 (G)	参数量 ($\times 10^6$)	模型大小 (MB)
YOLOv5s-G-N	93.7	80.1	87.1	7.8	3.3	7.0
YOLOv5s-G-N-E	94.6	80.2	88.8	7.8	3.3	7.0

YOLOv5s-G-N-E: 经过 EIou 损失函数优化的 YOLOv5s-G-N 模型。

2.4 模型有效性

2.4.1 消融试验 结果(表 5)显示,I 是原始 YOLOv5s 模型,其对玉米病虫害检测的 mAP 为 86.8%;II 是采用轻量化网络改进的模型,其 mAP 降低至 82.2%;III 是在轻量化基础上引入 NAM 的模型,其 mAP 提升至 87.1%;IV 是在 III 模型中将损失函数替换为 EIou 的模型,其 mAP 更是提升至 88.8%。综上,本研究对 YOLOv5s 模型的改进是有效的。

表 5 消融试验对比结果

Table 5 Comparison results of ablation experiments

模型	精确率 (%)	召回率 (%)	平均精度均值 (%)
I	92.7	78.0	86.8
II	88.8	75.8	82.2
III	93.7	80.1	87.1
IV	94.6	80.2	88.8

I 是原始 YOLOv5s 模型; II 是采用轻量化网络改进的模型; III 是在轻量化基础上引入 NAM 机制的模型; IV 是在 III 模型中将损失函数替换为 EIou 的模型。

2.4.2 YOLOv5s-G-N-E 模型的性能 将 YOLOv5s-G-N-E 模型与原始 YOLOv5s 模型进行对比试验。由表 6 可知,除了斑病检测在 R 、 mAP 上有所下降外,在对所有类别病虫害检测中,YOLOv5s-G-N-E 模型的 P 、 R 和 mAP 比原始 YOLOv5s 模型提高了 1.9 个百分点、2.2 个百分点和 2.0 个百分点,分别达到 94.6%、80.2% 和 88.8%;特别是对黏虫和灰飞虱的检测, P 和

R 值提升较为明显。同时,YOLOv5s-G-N-E 模型的计算量、参数量和模型大小都分别降低至 50.6%、52.9% 和 50.4%。由此说明,YOLOv5s-G-N-E 模型比原始 YOLOv5s 模型更轻量化,但仍然保持了较高的检测精度,适于在移动端进行部署应用。

为了更直观地比较 YOLOv5s-G-N-E 模型与原始 YOLOv5s 模型对玉米病虫害的检测效果,采用玉米病虫害测试集图像进行检测,其中检测效果如图 8 所示。从图 8 可知,在复杂环境、种植密集的情况下,原始 YOLOv5s 模型由于受到严重背景干扰,出现可信度低、斑病漏检和错检等情况,影响了模型的检测效果。而 YOLOv5s-G-N-E 模型由于引入注意力机制和优化了边框损失函数,能够全面地评估目标特征权值,并使得目标框与锚框相差最小,从而增强玉米病虫害的特征,减弱复杂背景与无关信息干扰特征,进而提升了模型的检测精度。

2.4.3 不同检测模型性能对比 为了验证 YOLOv5s-G-N-E 模型优越性,本研究将其与目前主流的目标检测模型(Faster-RCNN、YOLOv5x、YOLOv5s、YOLOv7-Tiny)进了试验对比。由表 7 可知,Faster-RCNN 相较于其他模型在计算量、参数量和模型大小方面均比较大,且平均精度均值只有 75.3%,无法满足检测要求;YOLOv5x 的平均精度均值能够达到 89.4%,但计算量、参数量和模型庞大,严重占用了芯片的计算资源,不适用于移动端的部

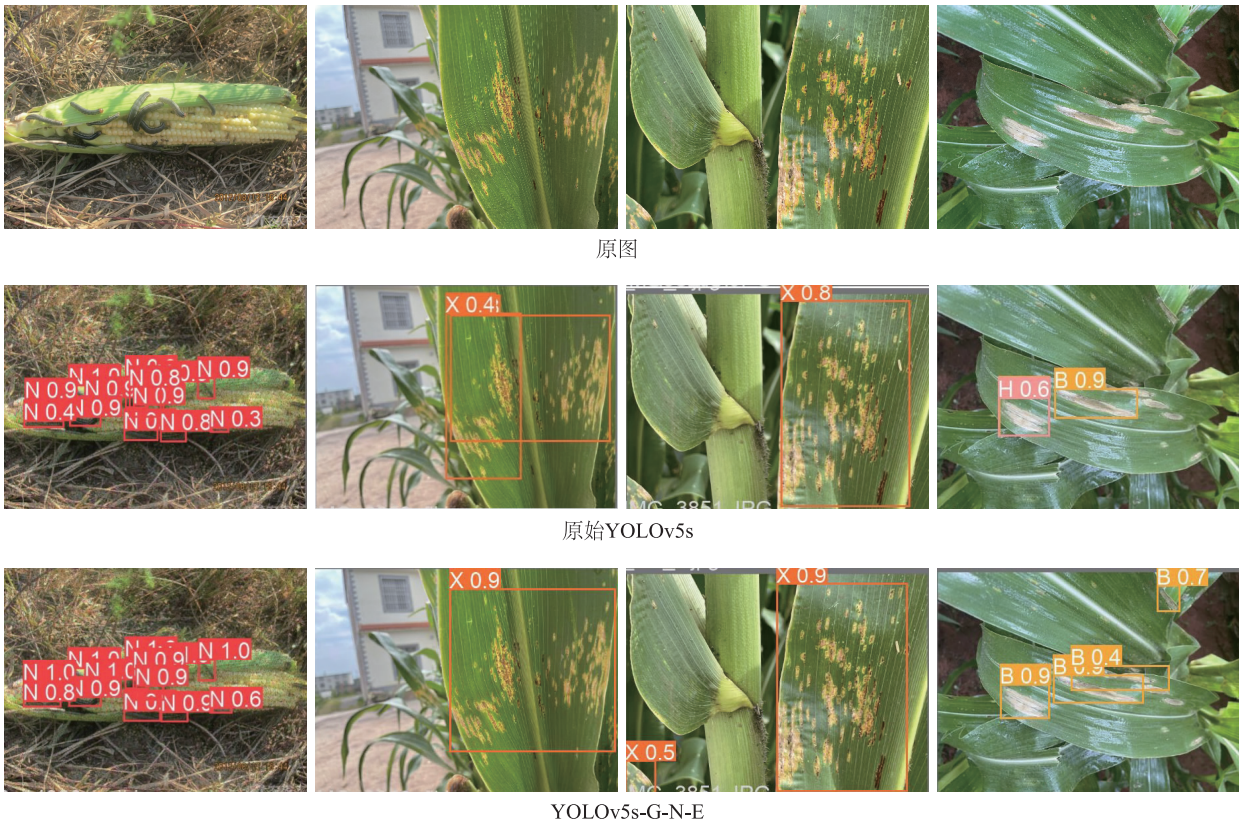
署;YOLOv5s 与 YOLOv7-Tiny 各方面的性能指标相近,但综合性能不及本研究的 YOLOv5s-G-N-E 模型。YOLOv5s-G-N-E 模型虽然在平均精度均值上比 YOLOv7-Tiny 低 1.6 个百分点,但在计算量、参数量和模型大小上有明显优势,在满足移动端设备应用要求的同时还能节省计算资源。

表 6 最终模型试验对比

Table 6 Comparison of final model tests

算法模型	类别	精确率 (%)	召回率 (%)	平均精度均值 (%)	计算量 (G)	参数量 (×10 ⁶)	模型大小 (MB)
YOLOv5s	全部类别	92.7	78.0	86.8	15.8	7.0	14.1
	黏虫	92.7	78.4	87.6			
	灰飞虱	90.9	90.8	94.9			
	锈病	91.7	68.8	79.8			
	斑病	95.4	74.0	84.9			
YOLOv5s-G-N-E	全部类别	94.6	80.2	88.8	7.8	3.3	7.0
	黏虫	93.9	78.4	88.1			
	灰飞虱	97.2	100.0	99.0			
	锈病	90.5	74.2	85.7			
	斑病	96.7	68.1	82.6			

YOLOv5s-G-N-E;经过 EIoU 损失函数优化、引入注意力机制 (NAM)、将主干网络和颈部网络都进行轻量化改进的 YOLOv5s 模型。



YOLOv5s-G-N-E;经过 EIoU 损失函数优化、引入注意力机制 (NAM)、将主干网络和颈部网络都进行轻量化改进的 YOLOv5s 模型。N: 黏虫; H: 灰飞虱; X: 锈病; B: 斑病。矩形框上的数字表示该病虫害的可信度,可信度越高,模型检测越准确。

图 8 检测效果对比
Fig.8 Comparison of detection results

表 7 不同检测模型性能对比结果

Table 7 Comparison of performance of different detection models

模型	平均精度均值 (%)	计算量 (G)	参数量 ($\times 10^6$)	模型大小 (MB)
Faster-RCNN	75.3	454.3	28.3	110.9
YOLOv5x	89.4	203.8	86.2	169.1
YOLOv5s	86.8	15.8	7.0	14.1
YOLOv7-Tiny	89.7	13.2	6.0	12.0
YOLOv5s-G-N-E	88.1	7.8	3.3	7.0

YOLOv5s-G-N-E: 经过 EIoU 损失函数优化、引入注意力机制 (NAM)、将主干网络和颈部网络都进行轻量化改进的 YOLOv5s 模型。Faster-RCNN、YOLOv5x、YOLOv5s、YOLOv7-Tiny 为目前主流的目标检测模型。

3 结论

(1) 本研究以 YOLOv5s 模型为基础, 采用轻量级网络 GhostNet 对其进行轻量化改进, 再通过添加注意力机制 (NAM) 增强特征, 并用损失函数 EIoU 代替 CIOU 提升模型的收敛速度和回归精度, 得到了改进后的 YOLOv5s-G-N-E 模型。并将其与 Faster-RCNN、YOLOv5x、YOLOv5s 和 YOLOv7-Tiny 模型进行性能对比, 结果表明 YOLOv5s-G-N-E 模型在保持较小计算量、参数量和模型大小的同时, 取得了较高的检测精度。

(2) 在不同环境下采集了玉米病虫害图像, 通过数据增强方法对图片集进行扩充, 建立了玉米病虫害数据集, 用于模型的训练和验证。经测试本研究所构建的 YOLOv5s-G-N-E 模型对供试玉米病虫害检测的 P 、 R 和 mAP 分别为 94.6%、80.2% 和 88.8%, 同时在计算量、参数量和模型大小方面分别减少 50.6%、52.9% 和 50.4%。本研究所构建的 YOLOv5s-G-N-E 模型在复杂背景下的检测精度优于原始模型, 为玉米病虫害目标检测提供了新的模型, 并为检测模型在移动端设备上的部署应用提供了选择。

(3) 由于条件所限, 本研究建立的玉米病虫害图像数据集样本有限, 后续研究将进一步对数据集进行补充, 再结合迁移学习以提升检测模型的泛化能力。

参考文献:

[1] 代瑞熙, 徐伟平. 中国玉米增产潜力预测[J]. 农业展望, 2022, 18(3): 41-49.

[2] 王文明. 玉米常见病虫害防治措施探讨[J]. 农业开发与装备, 2017(12): 149-151.

[3] 安艳丽. 玉米常见病害的识别与防治[J]. 农业与技术, 2017, 37(18): 44.

[4] 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.

[5] THEODORIDIS S, KOUTROUMBAS K. Lecture notes in computer science [J]. Algorithmica, 2016, 540(8): 169-195.

[6] 陈桂珍, 龚声蓉. 计算机视觉及模式识别技术在农业生产领域的应用[J]. 江苏农业科学, 2015, 43(8): 409-413.

[7] 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.

[8] 刘天真, 滕桂佳, 苑迎春, 等. 基于改进 YOLOv3 的自然场景下冬枣果实识别方法[J]. 农业机械学报, 2021, 52(5): 17-25.

[9] FARJON G, KRIKEB O, HILLEL A B, et al. Detection and counting of flowers on apple trees for better chemical thinning decisions [J]. Precision Agriculture, 2019, 21(3): 503-521.

[10] FERENTINOS K P. Deep learning models for plant disease detection and diagnosis [J]. Computers and Electronics in Agriculture, 2018, 145: 311-318.

[11] 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] 徐会杰, 黄仪龙, 刘曼. 基于改进 YOLOv3 模型的玉米叶片病虫害检测与识别研究[J]. 南京农业大学学报, 2022, 45(6): 1276-1285.

[13] 周维, 牛永真, 王亚伟, 等. 基于改进的 YOLOv4-GhostNet 水稻病虫害识别方法[J]. 江苏农业学报, 2022, 38(3): 685-695.

[14] 邢洁洁, 谢定进, 杨然兵, 等. 基于 YOLOv5s 的农田垃圾轻量化检测方法[J]. 农业工程学报, 2022, 38(19): 153-161.

[15] 张振国, 邢振宇, 赵敏义, 等. 改进 YOLOv3 的复杂环境下红花丝检测方法[J]. 农业工程学报, 2023, 39(3): 162-170.

[16] 王卫星, 刘泽乾, 高鹏, 等. 基于改进 YOLOv4 的荔枝病虫害检测模型[J]. 农业机械学报, 2023, 54(5): 227-235.

[17] 陈玉冲, 龙梦玲, 郭辉, 等. 灰飞虱研究的文献计量分析[J]. 江苏科技信息, 2021, 38(15): 22-25, 53.

[18] 杨春媛. 玉米常见病害的发病症状及防治措施[J]. 乡村科技, 2017(24): 63-64.

[19] 路兴涛, 吴翠霞, 张勇, 等. 玉米灰飞虱与粗缩病的发生规律及综合防治策略[J]. 安徽农业科学, 2013, 41(19): 8168-8169.

[20] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection [C]. New York: IEEE, 2016.

[21] REDMON J, FARHADI A. YOLOv3: an incremental improvement [J]. arXiv Preprint, 2018. DOI: 10.48550/arXiv.1804.02767.

[22] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: optimal speed and accuracy of object detection [J]. arXiv Preprint, 2020. DOI: 10.48550/arXiv.2004.10934.

- [23] 郭 磊,王邱龙,薛 伟,等. 基于改进 YOLOv5 的小目标检测算法[J]. 电子科技大学学报,2022,51(2):251-258.
- [24] 李文婧,徐国伟,孔维刚,等. 基于改进 YOLOv4 的植物叶茎交点目标检测研究[J]. 计算机工程与应用,2022,58(4):221-228.
- [25] LIU Y C, SHAO Z R, TENG Y, et al. NAM: normalization-based attention module[J]. arXiv Preprint, 2021. DOI: 10.48550/arXiv.2111.12419.
- [26] 孔德鹏,常天庆,戴文君,等. 基于排序选择和精英引导的改进人工蜂群算法[J]. 控制与决策,2019,34(4):781-786.
- [27] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [M]. Cham: Springer International Publishing, 2018.
- [28] YU J, JIANG Y, WANG Z, et al. Unitbox: an advanced object detection network [J]. ACM, 2016. DOI: 10.1145/2964284.2967274.
- [29] ZHANG Y F, REN W, HANG Z, et al. Focal and efficient IOU loss for accurate bounding box regression[J]. Neurocomputing, 2022,506:146-157.

(责任编辑:陈海霞)