

DOI:10.12171/j.1000-1522.20240326

改进 YOLOv8n 的林业害虫检测方法

陈万志 袁航

(辽宁工程技术大学软件学院, 辽宁 葫芦岛 125105)

摘要:【目的】针对现有林业害虫检测方法检测速度慢, 检测类别少, 小目标害虫检测效果差等问题, 提出了一种改进 YOLOv8n 的林业害虫检测方法。【方法】首先, 采用高效多尺度级联注意力特征提取网络 EfficientViT 作为改进模型的主干网络, 降低计算复杂度, 提高检测速度; 其次, 通过构建多尺度自适应特征融合模块 DA-C2F 提升模型在复杂背景下害虫目标的聚焦能力和识别精度, 此外新增的小目标检测头 XSH 能够进一步提升小目标害虫的检测能力; 最后, 采用基于最小点距离交并比损失函数 MPDIoU 作为模型的边界框损失, 提升网络收敛速度, 进一步增强害虫目标的定位准确率。【结果】改进模型的检测精确率、召回率、平均精度、平均精度均值 (mAP50-95) 和 F_1 分数分别达到 98.6%、95.7%、98.3%、85.6% 和 0.979, 前 4 者较原模型分别提升了 3.9、2.6、2.8、2.5 个百分点, F_1 分数提升了 4.4%; 检测速度 (帧率) 达到了 95 帧/秒, 提升了 15.9%, 优于更轻量级的模型。此外, 对比其他检测模型, 改进模型对飞蛾类害虫的检测精确率提升了 11.2 个百分点, 并且两种独立飞蛾害虫综合检测的表现也更为优异。【结论】本研究提出的方法对于林业害虫的检测准确度更高, 检测速度更快, 且对多类别害虫的检测精度更高, 改进模型的泛化能力更强。

关键词: 深度学习; 卷积神经网络 (CNN); 林业害虫检测; YOLOv8n; 多尺度级联注意力特征提取网络; 多尺度自适应特征融合; 小目标检测头

中图分类号: S763.305; TP391.41 文献标志码: A 文章编号: 1000-1522(2025)02-0119-13

引文格式: 陈万志, 袁航. 改进 YOLOv8n 的林业害虫检测方法 [J]. 北京林业大学学报, 2025, 47(2): 119-131. Chen Wanzhi, Yuan Hang. Forestry pest detection method based on improved YOLOv8n [J]. Journal of Beijing Forestry University, 2025, 47(2): 119-131.

Forestry pest detection method based on improved YOLOv8n

Chen Wanzhi Yuan Hang

(School of Software, Liaoning Technical University, Huludao 125105, Liaoning, China)

Abstract: [Objective] In response to the problem of slow speed, narrow categories, and poor detection of small-target pests in existing forestry pest detection methods, a forestry pest detection method based on the improved YOLOv8n was proposed. [Method] Firstly, an efficient multi-scale cascade attention feature extraction network EfficientViT was adopted as the backbone of improved model to reduce computational complexity and enhance detection speed. Secondly, a multi-scale adaptive feature fusion module DA-C2F was constructed to improve the model's ability to focus on and accurately identify pest targets in complex backgrounds. Additionally, a newly added small-object detection head XSH further enhanced the detection capability for small pest objects. Finally, a minimum point distance IoU loss function MPDIoU was implemented as the bounding box loss for the model, accelerating convergence speed and further improving the accuracy of pest target localization. [Result] The improved model achieved a detection precision of 98.6%, recall of 95.7%, mean average precision of 98.3%, mean average precision at different thresholds (mAP50-95) of 85.6%, and an F_1 -score of 0.979. These metrics represented improvements of 3.9, 2.6, 2.8, 2.5 percentage points and 4.4%, respectively over the original model. The detection speed reached 95 frames per second with an improvement of 15.9%, also surpassed that of the lighter-weight model. Furthermore, in

收稿日期: 2024-10-07 修回日期: 2024-11-14

基金项目: 辽宁省教育厅科学研究基金面上项目 (2021LJKZ0327), 辽工程 GPU 资源支持项目 (2024-02)。

第一作者: 陈万志, 博士, 副教授。主要研究方向: 人工智能与智能信息处理, 网络与信息安全, 工控软件与数据分析等。Email: chenwanzhi@lntu.edu.cn 地址: 125105 辽宁省葫芦岛市龙湾南大街 188 号 502 信箱。

本刊网址: <http://j.bjfu.edu.cn>; <http://journal.bjfu.edu.cn>

comparison with other detection models, the improved model demonstrated an increase of 11.2 percentage points in detection precision for moth pests, and exhibited superior overall performance in detection of two independent moth pest species. [Conclusion] The proposed method has higher detection accuracy and faster detection speed for forestry pests, better detection accuracy for multiple categories of pests, and better generalization ability of the improved model.

Key words: deep learning; convolutional neural networks (CNN); forestry pest detection; YOLOv8n; multi scale cascaded attention feature extraction network; multi-scale adaptive feature fusion; small object detection head

林业在经济可持续发展和生态文明建设中具有至关重要的地位。由于病虫害的影响,近年来我国林业有害生物事件急剧增加,导致了巨大的经济损失,给林业发展带来了严峻挑战^[1]。因此,对林业害虫的识别和检测方法的有效探索具有重要意义^[2],并对林业产业的发展具有深远影响。然而,现有林业害虫检测方法在一定程度上仍依赖于苛刻的实验室条件,不仅限制了检测速率,而且对多种类害虫检测表现欠佳,尤其缺乏对小型害虫以及真实自然环境中害虫目标检测的有效考量。

传统的林业害虫识别与检测方法主要依赖于有限的专业技术人员,通过肉眼观察和形态学特征分析进行判别^[3]。这种方法不仅高度依赖技术人员知识储备和经验判断,而且效率低下,难以适应大规模实时监测的需求^[4]。随着机器视觉与计算机图像处理技术的不断进步,利用机器学习特别是深度学习算法来实现自动化、精确化的林业害虫识别与检测已成为研究热点^[5]。新技术的应用有望改变现有的病虫害防控体系,从而对整个林业产业链的发展产生深远影响。

早期对于害虫图像识别的技术主要依赖于人工特征选择方法和机器学习技术^[6]。Xie等^[7]提出了一种多任务稀疏表示结合多核学习技术(multiple-kernel learning, MKL)的昆虫识别方法,首先使用稀疏编码直方图量化原始特征,如昆虫的颜色、形状和纹理,并进一步使用MKL融合多个特征,结果表明其对24种常见害虫分类表现较好。Ebrahimi等^[8]采用具有差分核函数的支持向量机方法进行寄生虫分类和蓟马(*Thrips spp.*)检测,结果显示以区域和强度为颜色指标的支持向量机分类效果最好,平均误差小于2.25%,为温室大棚条件下的草莓(*Fragaria ananassa*)害虫检测提供了新的方法和思路。Wang等^[9]设计了一种新的昆虫图像分类系统,首先人工设计了昆虫身体、翅膀等7个基本几何特征,并使用人工神经网络与支持向量机,融合了前者良好的检测稳定性和后者更高的准确率,结果表明该系统对不同昆虫的分类结果准确率达93%。Li等^[10]使用多重

分形分析方法,基于局部特异性和全局图像特征,采用区域最小值选择策略分割小型害虫,结果显示其精确度为88.6%,高于传统模型。然而,以上基于传统机器学习的检测和分类方法多依赖于人工设计和特征提取^[11],工作效率低,无法适应大规模的检测任务,并且检测样本容易受到光照条件和环境变化的影响,模型泛化能力弱,同样不能适应真实环境下的检测。

随着深度学习模型的快速发展,卷积神经网络(convolutional neural networks, CNN)改善了传统分类网络方法的不足^[12]。基于深度学习的害虫检测方法可以自动学习害虫特征,大幅减少了数据处理初期的工作量,且基于深度学习模型的害虫检测方法具有检测速度快、检测精度高等优点^[13],逐渐成为害虫研究领域的主流方法。王金等^[14]提出了一种基于特征金字塔网络的faster R-CNN(faster region-convolutional neural network)改进模型,构建了包含5种常见仓储粮害虫的检测样本;使用改进模型对其进行检测,平均精度为96.69%;但该方法检测样本数量较少,针对于特殊环境下的害虫检测,泛化能力不强,并且检测速度较低。侯瑞环等^[15]针对基于深度学习的林业昆虫图像检测方法检测精度低和速度慢的问题,提出一种结合改进PANet结构与三支注意力机制的目标检测方法YOLOv4-TIA,精确率和召回率分别为85.9%和91.2%,但该方法使用的样本为特定实验环境下采集,且在提高检测速度的情况下检测精度没有明显提高。孙海燕等^[16]提出了一种基于注意力模型和轻量化YOLOv4的林业害虫检测方法,对数据集进行增广处理后,改进模型检测的平均精度达93.7%,并有效解决了基线模型存在漏检误检的问题,但该方法缺少对小目标害虫检测的考量。

针对上述问题,本研究提出一种改进YOLOv8n的林业害虫检测方法,在降低模型尺寸的同时,提高其对于害虫目标的检测能力。首先,采用高效多尺度级联注意力特征提取网络EfficientViT_M0^[17]作为改进算法的特征提取网络,降低模型复杂度,提高算

法检测速度,并实现全局感受野和多尺度学习能力。其次,为解决害虫形态多样及真实检测环境中背景信息复杂导致的误检和漏检问题,提出多尺度自适应特征融合模块,重构每个检测头上层的特征融合模块,提升模型在复杂背景下对于害虫目标的聚焦能力。另外,为解决检测害虫目标体积小的问题,添加小目标检测层,提升模型对小目标害虫的检测能力,避免漏检的发生。最后,为进一步解决实际检测场景中害虫目标聚集度高导致目标不易定位的问题,采用基于最小点距离交并比的边界框回归损失函数 MPDIoU^[18],以提高目标边界框回归精度和检测准确率。

1 研究数据

1.1 数据集

采用 Liu 等^[19]在 2022 年公开的林业有害生物数据集。该数据集与传统林业害虫数据集不同,除存在实验室采样样本外,还收集了拍摄于真实环境

的害虫图像,增加了对自然条件下害虫检测的考量。它包含 17 种常见的林业害虫及部分害虫的不同形态,包括虫卵、幼虫、若虫以及成虫,共 31 个分类、7 163 张图像,数据集的标注采用 json 格式。但原始数据集标签格式不符合 YOLO 模型的要求,其间还掺杂着一些无效的重复图像以及质量较差的样本。

1.2 数据预处理

本研究对原始数据集进行预处理:将原始数据集采用的 json 标注信息转换为适用于 YOLO 模型的 txt 格式,使之符合模型检测的需求;人工筛选剔除数据集中同类重复的图像和低质量图像,保持数据集多样性的同时,减少冗余信息。

数据预处理后得到数据集图像共 6 960 张,每种类别的具体数量见表 1,其中数据集样例与同种害虫种类的不同形态如图 1 所示(由于数据集害虫种类较多,因篇幅有限,仅选择代表性示例)。原始数据集在其制作过程中已经进行过增强处理,因此本研究不需要再进行额外的数据增强。

表 1 数据集中害虫种类和数量

Tab. 1 Type and number of pests in the dataset

序号	中文名称	学名	张数
1	草履蚧(母)	<i>Drosicha contrahens</i> (female)	226
2	草履蚧(公)	<i>Drosicha contrahens</i> (male)	202
3	吉丁虫	<i>Chalcophora japonica</i>	188
4	桑天牛	<i>Apriona germari</i>	277
5	松斑天牛	<i>Monochamus alternatus</i>	216
6	黄刺蛾	<i>Cnidocampa flavescens</i>	277
7	黄刺蛾(蛹)	<i>Cnidocampa flavescens</i> (pupa)	199
8	美国白蛾	<i>Hyphantria cunea</i>	271
9	美国白蛾(幼虫)	<i>Hyphantria cunea</i> (larvae)	224
10	美国白蛾(蛹)	<i>Hyphantria cunea</i> (pupa)	184
11	人纹污灯蛾	<i>Spilarctia subcarnea</i>	188
12	人纹污灯蛾(幼虫单体)	<i>Spilarctia subcarnea</i> (larvae)	186
13	人纹污灯蛾(幼虫群体)	<i>Spilarctia subcarnea</i> (larvae2)	164
14	天牛幼虫	Cerambycidae (larvae)	196
15	霜天蛾	<i>Psilogramma menephron</i>	218
16	霜天蛾(幼虫)	<i>Psilogramma menephron</i> (larvae)	208
17	丝带凤蝶	<i>Sericinus montela</i>	329
18	丝带凤蝶(幼虫)	<i>Sericinus montela</i> (larvae)	201
19	星天牛	<i>Anoplophora chinensis</i>	326
20	桑树黄星天牛	<i>Psacotha hilaris</i>	218
21	柳蓝叶甲	<i>Plagiodera versicolora</i>	270
22	柳蓝叶甲(卵)	<i>Plagiodera versicolora</i> (ovum)	164
23	柳蓝叶甲(幼虫)	<i>Plagiodera versicolora</i> (larvae)	182
24	麻皮蝽	<i>Erthesina fullo</i>	286
25	麻皮蝽(若虫1)	<i>Erthesina fullo</i> (nymph)	175
26	麻皮蝽(若虫2)	<i>Erthesina fullo</i> (nymph2)	176
27	杨扇舟蛾	<i>Clostera anachoreta</i>	277
28	杨小舟蛾	<i>Micromelalopha troglodyta</i>	235
29	杨小舟蛾(幼虫)	<i>Micromelalopha troglodyte</i> (larvae)	226
30	油桐褐边绿刺蛾	<i>Latoia consocia</i>	267
31	油桐褐边绿刺蛾(幼虫)	<i>Latoia consocia</i> (larvae)	204
总计			6 960



图1 数据集中害虫示例

Fig. 1 Examples of pests in the dataset

2 模型的改进

2.1 改进 YOLOv8n 的林业害虫检测模型

YOLOv8 是 Ultralytics 公司开发的 YOLO(you only look once)系列目标检测模型在 2023 年的最新迭代版本^[20]。与之前各版本的 YOLO 模型相比, YOLOv8 检测速度更快和检测精度更高, 依据模型大小和计算复杂度分为 YOLOv8n、YOLOv8s、YOLOv8m、YOLOv8l 和 YOLOv8x 这 5 个版本^[21]。YOLOv8n 作为其中的轻量级模型, 有更快的检测速度和更少的硬件资源使用量, 更加符合害虫检测场景的实际要求。因此, 本研究以 YOLOv8n 作为基线检测模型, 并对其进行改进。

YOLOv8n 由骨干网络(Backbone)、颈部网络(Neck)和检测头(Head)组成^[22]。Backbone 包含了卷积集成模块(cross-stage-partial network block, CBS)、梯度级联连接单元(faster implementation of csp bottleneck with 2 convolutions, C2F)^[23]以及空间池化金字塔融合模块(spatial pyramid pooling fast, SPPF)^[24]。CBS 对输入的图像进行卷积运算、批量归一化和 SiLU(sigmoid linear unit)激活; C2F 将输入特征图的一部分特征通过分离、卷积和融合的操作, 保留原始特征的同时, 融合更深层次的特征表达, SPPF 模块将输入的特征映射在不同尺度上进行池

化操作, 并将池化后特征图融合, 以增强模型对多尺度特征的感知能力。Neck 部分使用特征金字塔网络融合不同尺度的特征图, 使高层语义特征和底层的空间细节特征融合。Head 部分采用了 Anchor-Free 的设计, 在融合特征图中直接预测目标的中心点坐标、宽度、高度和类别信息, 输出预测结果。

面对传统目标的检测, YOLOv8n 具有高效性、实时性和高准确度的特点, 检测效率和精度达到了较好的平衡^[22]。但在林业害虫检测的过程中, 害虫目标聚集度高、目标形态多样以及目标体积小会导致检测精度不足, 以及漏检、误检。因此, 本方法对其网络结构进行场景应用性改进, 具体结构如图 2 所示。

2.2 高效多尺度级联注意力特征提取网络 EfficientViT

本方法使用高效多尺度级联注意力特征提取网络中的轻量级网络 EfficientViT_M0 作为改进模型主干网络。常用的轻量级特征提取网络 MobileNet^[25]基于深度可分离卷积并引入反向残差连接, 减少计算量和模型大小; ShuffleNet^[26]使用组卷积和通道操作以减少计算复杂度, 并且通过融合不同组之间的特征信息, 丰富特征多样性, 在计算资源有限的条件下也能保证较好的性能。虽然上述两类轻量级特征提取网络都可以满足模型轻量化的需求, 但面对害虫在真实环境下的检测条件, 两者在对害虫目标全

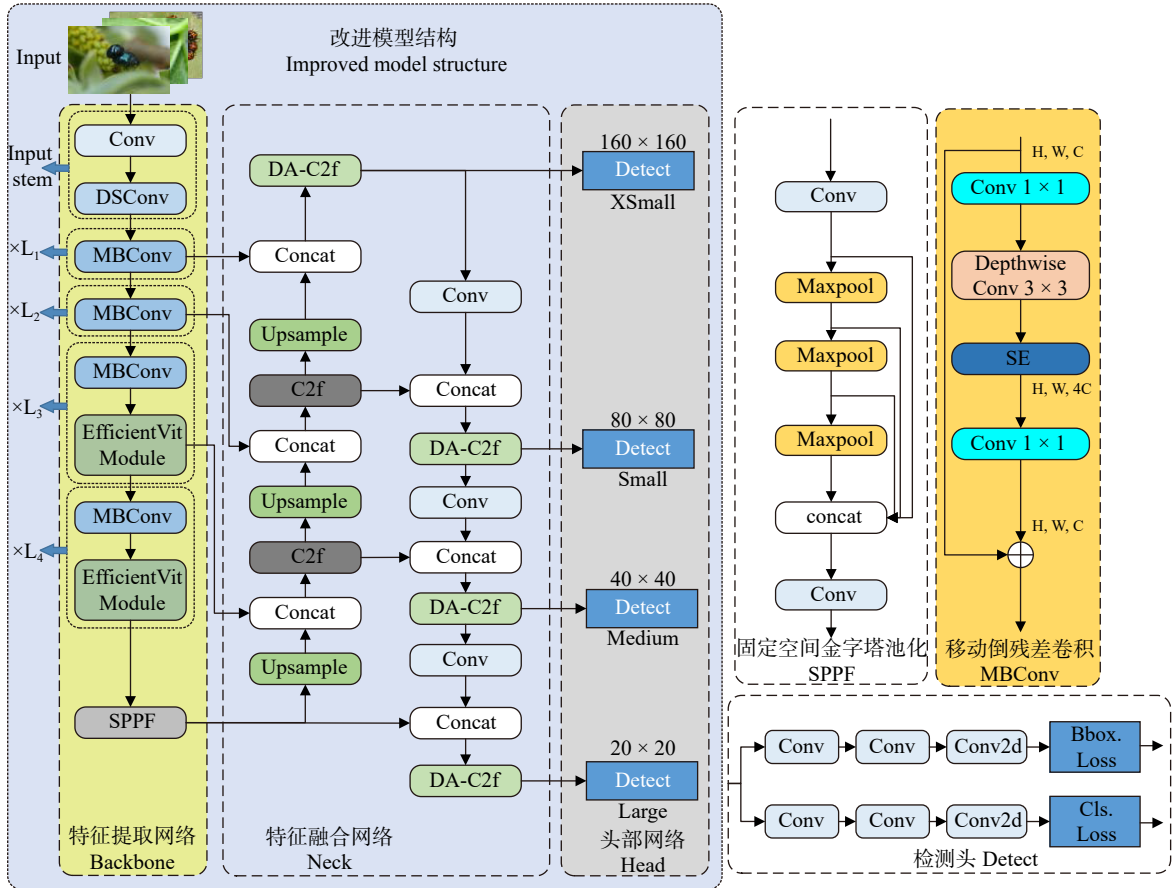


图 2 改进 YOLOv8n 的害虫检测模型
Fig. 2 Pest detection model based on improved YOLOv8n

局特征的把握上都缺少一定的考量,不能很好地处理复杂背景信息下的检测场景。而 EfficientViT 采用一系列的轻量级卷积操作和多尺度线性全局注意力模块提取图像特征,通过卷积操作捕捉图像的局部特征,并利用 Transformer 对其全局依赖关系进行捕捉,可以更好地满足害虫检测场景的需求。

在高效多尺度级联注意力特征提取网络中,害虫图片信息经过 Input Stem 进行降维和特征图生成,生成的特征图通过 L_1 、 L_2 、 L_3 和 L_4 进一步开展特征提取和融合,生成特征图金字塔,最后进入 SPPF 中聚合多尺度特征^[27]。EfficientViT_M0 中使用移动倒残差卷积(mobilenetV3 block convolution, MBConv)模块对输入图片信息进行特征提取,在 L_3 和 L_4 的移动倒残差卷积模块之后,加入多尺度线性全局注意力模块,实现输入信息的多尺度特征融合,并增强对害虫目标特征信息的表达能力。

2.3 移动倒残差卷积模块

移动倒残差卷积模块,通过一系列操作处理输入特征图,以提升特征的表达能力和模型的性能。首先,通过 1×1 的逐点卷积对输入的特征图进行升维操作,增加通道数;随后,对每个通道独立应用卷积核进行深度卷积,避免跨通道的信息混合;接下

来,引入 SE(squeeze-and-excitation)模块来校准通道间的特征重要性。SE 模块通过全局平均池化将每个空间位置的信息压缩成一个标量,随后通过两个全连接层,并使用 Sigmoid 激活函数得到每个通道的重新加权系数,最后,将这些系数与之前的特征图进行逐通道的乘法运算,从而增强重要特征,并抑制无关特征。

上述处理后的特征图通过另一组 1×1 的逐点卷积进行降维,与原始输入的特征图进行残差连接,使网络学习到更复杂的特征表示的同时,保留原始特征信息,并避免梯度消失的问题^[28]。其结构如图 2 中 MBConv 部分所示。SE 模块中的残差连接操作表示为

$$F_{out} = F_{in} \otimes \text{Sigmoid}(W_2(\text{ReLU}(W_1 \text{Pool}(F_{in})))) \quad (1)$$

式中: F_{in} 表示之前模块得到的特征图, F_{out} 表示通过 SE 后的输出特征图, ReLU 和 Sigmoid 为两个全连接层的激活函数, W_1 和 W_2 分别表示两个全连接层的权重矩阵, \otimes 表示基于元素的乘法。

2.4 多尺度线性全局注意力模块

多尺度线性全局注意力模块 EfficientViT Module (图 3)由多尺度线性注意力模块和带有小内核的深

度可分离卷积前馈网络 FFN + DWConv 组成^[17]。先将输入的特征图经过一个线性层分离出其 Q 、 K 、 V 对应的 tokens, 其次在多尺度线性注意力模块中进行并行操作, 分别经过 3×3 、 5×5 的两个深度可分离卷积和带有 ReLU 激活函数的线性全局注意力机制^[17]聚合附近的 Q 、 K 、 V , 增强模型的多尺度学习能力。其中, 设基于 ReLU 的全局注意力的输入为 $x \in \mathbf{R}^{N \times f}$, 则原始自注意力机制表示为

$$O_i = \sum_{j=1}^N \frac{\text{Sim}(Q_i, K_j)}{\sum_{j=1}^N \text{Sim}(Q_i, K_j)} V_j \quad (2)$$

式中: $Q = xW_Q$, $K = xW_K$, $V = xW_V$, Q_i 为矩阵 Q 的第 i 行, K_j 、 V_j 分别为矩阵 K 、 V 的第 j 列, 而 W_Q 、 W_K 、 W_V 表示可学习的线性映射矩阵, $W_Q \in \mathbf{R}^{f \times d}$, $W_K \in \mathbf{R}^{f \times d}$, $W_V \in \mathbf{R}^{f \times d}$; $\text{Sim}(\cdot, \cdot)$ 表示相似性函数; O_i 为输出矩阵 O 的第 i 行。

当使用相似性函数为 $\text{Sim}(Q, K) = \exp\left(\frac{QK^T}{\sqrt{d}}\right)$ 时, 式(2)为原始的 Softmax 注意力表达。为使模型更加轻量化, 采用 ReLU 线性注意力实现更大的感受野

并降低计算复杂度。在 ReLU 线性注意力中相似性函数可表示为

$$\text{Sim}(Q, K) = \text{ReLU}(Q)\text{ReLU}(K^T) \quad (3)$$

因此, 式(2)可改写为

$$\begin{aligned} O_i &= \sum_{j=1}^N \frac{\text{ReLU}(Q_i)\text{ReLU}(K_j^T)}{\sum_{j=1}^N \text{ReLU}(Q_i)\text{ReLU}(K_j^T)} V_j \\ &= \frac{\sum_{j=1}^N [\text{ReLU}(Q_i)\text{ReLU}(K_j^T)]V_j}{\text{ReLU}(Q_i) \sum_{j=1}^N \text{ReLU}(K_j^T)} \\ &= \frac{\sum_{j=1}^N \text{ReLU}(K_j^T)V_j}{\sum_{j=1}^N \text{ReLU}(K_j^T)} \end{aligned} \quad (4)$$

式(4)表明: 只需要计算 $(\sum_{j=1}^N \text{ReLU}(K_j^T)V_j) \in \mathbf{R}^{d \times d}$ 和 $(\sum_{j=1}^N \text{ReLU}(K_j^T)) \in \mathbf{R}^{d \times 1}$ 一次, 此后在每次需要时均可查询。该方法仅需线性的时间复杂度 $O(n)$ 与空间复杂度 $O(n)$, 从而实现在多尺度学习中的高效计算, 并显著减少对硬件资源的占用。

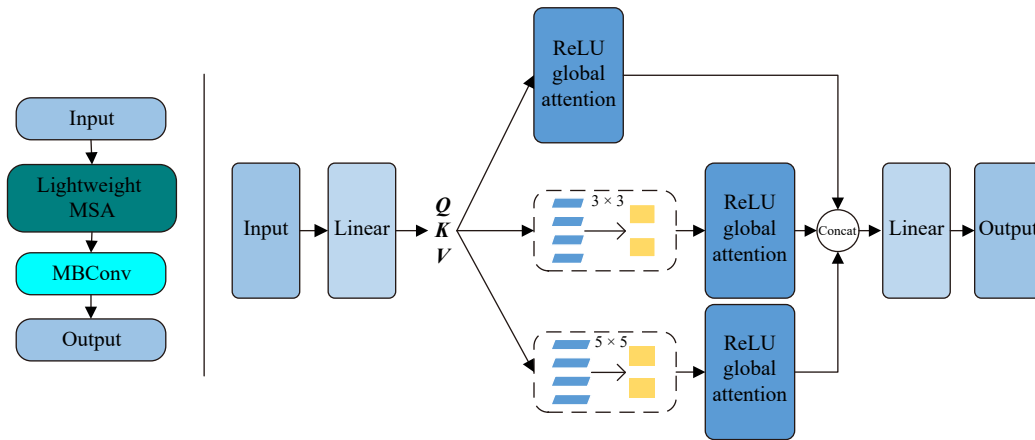


图3 EfficientViT 模块结构

Fig. 3 EfficientViT module structure

2.5 多尺度自适应特征融合模块 DA-C2F

真实场景下害虫检测的背景信息较为复杂, 在该环境下进行目标识别容易受到环境信息的干扰, 易导致害虫目标的漏检和误检问题^[16]。

CBAM(convolutional block attention module)^[29]主要通过通道和空间注意力机制增强固定位置的特征, GAM(global attention mechanism, GAM)^[30]着重于在全局范围内捕捉信息以达到更广的感受野。可变形注意力(deformable attention)^[31]能够动态调整卷积核的采样位置, 从而更好地捕捉到害虫在图像中的非刚性变形和姿态变化。与可变形注意力相比较, CBAM 和 GAM 这两个常用注意力机制在处理

目标物体几何形态变化方面都不够灵活, 无法很好地适应害虫检测的环境。因此, 可变形注意力更符合害虫目标检测的要求。因此, 本研究提出由空洞卷积(dilated convolution)^[32]和可变形注意力组成的多尺度自适应特征融合模块 DA-C2F(图4), 重构检测头上层的 C2F, 以提高模型对害虫目标的定位准确度和聚焦能力。

构建的模块 DA-C2F 利用空洞卷积进一步扩大模型的感受野^[32], 整合害虫图像和背景所包含的上下文信息, 并进一步有效地捕捉图像中的多尺度信息, 更好地处理不同尺寸目标的特征需求。可变形注意力机制能够使模型自适应调整其注意力焦点^[31],

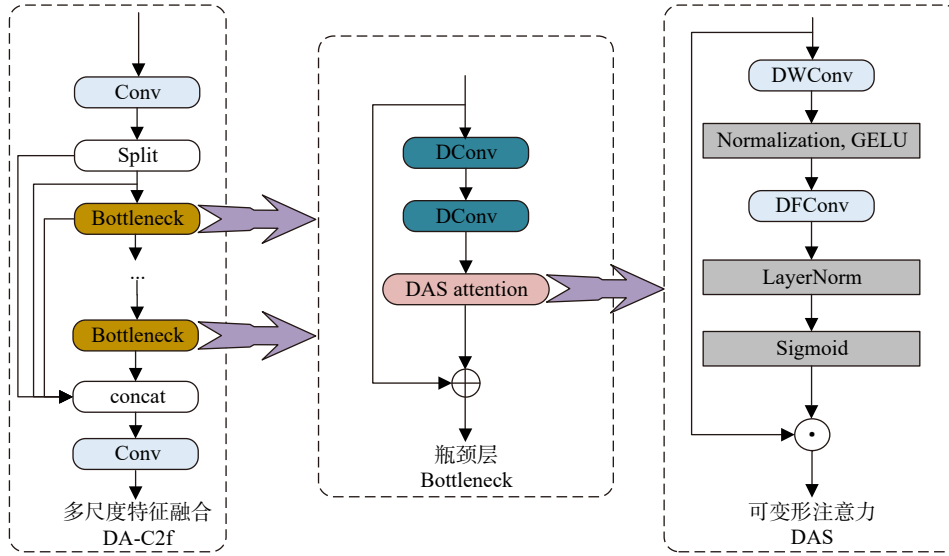


图 4 多尺度自适应特征融合模块

Fig. 4 Multi-scale adaptive feature fusion module

对于种类多样、形态多样的害虫目标更能实现准确的聚焦定位。在有较大感受野的前提下,可变形卷积在背景信息的影响下,仍能对害虫目标实现较高的关注度,也可以解决真实检测环境下害虫姿态具有较大不确定性及遮挡情况不一的问题,增强模型的鲁棒性和泛化能力。

式(5)表示在可变形注意力机制中输入的害虫特征图 X 通过瓶颈层。该层使用深度分离卷积进行操作,权重记为 W_1 , 得到压缩后的特征图为 X_c , 其中采用 GELU 作为非线性激活函数。

$$X_c = \text{GELU}(\text{InstanceNorm}(XW_1)) \quad (5)$$

随后,压缩后的特征图 X_c 经过可变形卷积处理,得到的结果记作 $\text{deform}(p)$, 其中 K 为卷积核的大小, w_k 和 w_p 分别代表卷积核的权重和偏移量的权重, $p_{\text{ref},k}$ 为偏移之前参考点的位置, p_k 为参考点的偏移量。可变形卷积处理如式(6)。

$$\text{deform}(p) = \sum_{k=1}^K w_k \cdot w_p \cdot X(p_{\text{ref},k} + \Delta p_k) \quad (6)$$

对可变形卷积处理后的特征图 X_c 进行归一化处理,记为 LayerNorm, 并由 Sigmoid 函数进行激活。式(7)中 σ 表示 Sigmoid 激活函数,得到的注意力门控 A 是一个与输入特征图形状相同的张量,用于强调重要特征信息,并抑制无关特征信息的表达。

$$A = \sigma(\text{LayerNorm}(\text{deform}(X_c))) \quad (7)$$

最后,将输入特征图 X 与注意力门控 A 逐元素相乘得到输出特征图 X_{out} , 式(8)中 \odot 表示点乘运算。

$$X_{\text{out}} = X \odot A \quad (8)$$

2.6 增强小目标害虫检测头 XSH

在 YOLOv8n 架构中,集成了 3 组检测头,各自

关联于不同尺度的特征图,尺寸分别为 80×80 像素、 40×40 像素、 20×20 像素,以实现针对不同尺寸目标的检测。这些检测头分别针对的最小可见目标为 8×8 像素、 16×16 像素、 32×32 像素。但在真实害虫检测场景中,通常检测害虫的目标体积小,容易导致漏检。故本方法在 YOLOv8n 原有 3 个检测头的基础上,添加 1 个检测特征图大小为 160×160 像素的小目标检测头(xsmall object detection head, XSH),以增强模型对于小目标害虫的检测能力,提高模型检测准确度。

2.7 基于最小点距离交并比损失函数 MPDIoU

在实际害虫检测场景中,部分害虫目标聚集度高和重叠情况严重导致在检测过程中边界框回归速率下降,回归精度降低^[33],从而造成对害虫目标定位的不精确和漏检。而原始模型的损失函数 CIoU (Complete IoU Loss)^[34]在此情况下性能受到限制。因此,为提高害虫检测的精确度,加快模型收敛速度,采用基于最小点距离交并比损失函数(minimum point distance intersection over union, MPDIoU)^[18]作为改进模型的边界框回归损失。MPDIoU 通过最小化预测害虫边界框与真实害虫标注框左上角点和右下角点的距离使得预测框逼近真实框范围,简化了计算过程,且同时综合考量了中心点距离、宽度与高度偏差,以及框间的重叠和非重叠区域,更适用于目标聚集度高的害虫检测场景。设 A 和 B 为任意的两个图形, w 和 h 分别为输入图形的宽度和高度, MPDIoU 计算公式为

$$d_1^2 = (x_1^B - x_1^A)^2 + (y_1^B - y_1^A)^2 \quad (9)$$

$$d_2^2 = (x_2^B - x_2^A)^2 + (y_2^B - y_2^A)^2 \quad (10)$$

$$\text{MPDIoU} = \frac{A \cap B}{A \cup B} - \frac{d_1^2}{w^2 + h^2} - \frac{d_2^2}{w^2 + h^2} \quad (11)$$

$$L_{\text{MPDIoU}} = 1 - \text{MPDIoU} \quad (12)$$

式中: (x_1^A, y_1^A) 、 (x_2^A, y_2^A) 分别表示图形 A 的左上和右下角点坐标, (x_1^B, y_1^B) 、 (x_2^B, y_2^B) 分别为图形 B 的左上和右下角点坐标, d_1 、 d_2 分别表示图形 A 与 B 左上与右下角点的欧氏距离, L_{MPDIoU} 表示基于最小点距离交并比的边界框回归损失函数。

3 研究方法

本研究均在 64 位 Windows10 系统下进行, CPU 为 Intel Core i5-12600K, 内存 16 GB, 显卡 NVIDIA GeForce RTX 3060, 显存 12 GB, 使用 PyCharm2023.2.4 作为开发工具, Python 版本 3.8, 采用 PyTorch1.10.0 作为深度学习框架。

YOLOv8 输入图像尺寸统一为 640×640 像素, 模型训练阶段设置训练轮数(epochs)为 200, 初始学习率为 0.01, 动量(momentum)为 0.937, 批量尺寸(batch size)为 16, 采用随机梯度下降(SGD)进行优化。

3.1 改进模块的有效性评价

本方法由高效多尺度级联注意力特征提取网络, 构建多尺度自适应特征融合模块, 增添小目标检测头和采用基于最小点距离交并比的边界框损失函数 MPDIoU 组成。高效多尺度级联注意力特征提取网络的引入, 不仅可以降低网络的复杂程度, 也使得模型在处理复杂背景下的害虫图像时, 能够更快速地提取有效特征, 从而提升检测的速度与准确性。构建的多尺度自适应特征融合模块, 可以增强模型对于不同类型害虫, 尤其是具有多阶段多形态害虫的检测能力, 且通过调整模型对不同尺度特征的关注程度, 可以改善害虫检测过程中可能出现的误检和漏检现象。新增加的小目标检测头用于提高模型对环境中小目标害虫的关注能力, 对于提高检测模型的鲁棒性至关重要。在林业害虫预警防范中, 越早发现害虫就可以越早进行干预, 检测越精准即可治理越及时; 无论是个体较小的害虫, 还是害虫早期的幼虫、若虫或卵, 都在害虫检测的情况中占有一定比例。因此, 小目标害虫的精准检测, 可以为治理工作提供关键的有效信息。最后, 边界框损失函数的性能则直接关系到检测结果的位置精度。害虫目标与很多传统的检测目标不同, 它在形态上具有多样性, 在自然界中也存在着多种表现形式, 尤其是早期害虫形态多存在聚集情况, 这无疑会加大其定位难度。在应用前述改进的同时, 采用性能更加优秀的

基于最小点距离交并比的损失函数, 能够更好地增强模型对于不同种类和表现形式的害虫的边界框定位精度, 从而整体提升模型性能; 也可进一步提高模型在实际应用场景中的鲁棒性和适应性, 确保在复杂自然环境中也能实现高效准确的害虫检测。

为了全面评估所提方法的有效性, 验证各模块改进的必要性和有效性, 使用预处理后的林业害虫数据集在原模型和改进模型上进行一系列的消融实验。

3.2 评价指标

为衡量改进模型的检测效果, 采用精确度(precision, P)、召回率(recall, R)、平均精度(mean average precision, mAP)、平均精度均值(mean average precision from 50% to 95%, mAP50-95)、模型检测速度(帧率)以及 F_1 分数作为评价指标。

$$P = \frac{T_P}{T_P + F_P} \times 100\% \quad (13)$$

$$R = \frac{T_P}{T_P + F_N} \times 100\% \quad (14)$$

$$P_A = \int_0^1 P(R) dR \quad (15)$$

$$\text{mAP} = \frac{1}{M} \sum_{k=1}^M P_{Ak} \quad (16)$$

$$F_1 = \frac{2PR}{P+R} \quad (17)$$

式中: T_P 为模型正确预测的正样本数目, F_P 为错误预测的正样本数, F_N 为错误预测的负样本数量^[35], M 代表害虫种类的数量, P_{Ak} 代表第 k 个害虫类别的平均精确率。mAP50-95 为平均精度在阈值 0.50 ~ 0.95 的平均值, 可以全面地反映改进模型在不同精度下对害虫的检测效果。 F_1 分数范围为 0 ~ 1, 越接近 1, 表明效果更优; 它可综合评估模型对各类害虫识别的精确度和完整度, 并且在害虫类别较多的条件下, 可直观地反映模型对于样本不平衡的多类别检测效果。

3.3 检测热力图

为进一步验证改进模型与原模型的性能差距, 利用 Grad-CAM(gradient-weighted class activation mapping)对图片生成检测热力图^[36]。Grad-CAM 是一种可视深度神经网络中的注意力机制的方法, 通过计算梯度确定网络中对特定类别的预测起到重要作用的部分^[37]。热力图可直观展示出不同方法对于目标位置关注的准确度和置信度情况, 暖色区域为热力值, 其位置代表模型对于目标的关注位置, 其颜色的深浅代表模型对于目标的置信度高低。

4 结果与分析

4.1 改进模块的有效性

采用 EfficientViT 对原模型进行轻量化改进后,模型复杂度有明显的下降,检测速度得到了大幅提升,帧率提高至 98,较原模型提升了 19.5%,且由于新的特征提取网络有更好的多尺度特征学习能力,可以更有效地提取复杂背景下的害虫目标特征,一定程度上提高了模型的检测能力,检测精确率较原模型提升了 1.2 个百分点,召回率提升了 0.8 个百分点,但平均精度与平均精度均值提升较小(表 2)。进一步将构建的 DA-C2F 应用于模型中后,由空洞卷积带来的更大感受野和可变形注意力对害虫目标更强的聚焦能力,以及构建模块配合上述特征提取网络可进一步增强模型对于多形态害虫的多尺度特征学习能力,且对复杂背景下的害虫目标有更好的定位准确度,检测精确率有明显增加,较原模型提升了 2.1 个百分点,召回率提升了 1.3 个百分点,平均精度与平均精度均值分别提升了 1.4 和 0.7 个百分点,模型检测速度较单独采用轻量化特征提取网络时有所下降,但仍优于原模型(表 2)。在不应用前两步改进的同时,单独增加小目标检测头,由于数据集中小目标害虫的数量占有一部分比例,模型检测准确度有明显提升,检测精确率提升了 2.8 个百分点,召回率提升了 1.7 个百分点,由于未应用上述轻量化设计,新增的小目标检测头一定程度上增加了模型的复杂度,检测速度较原模型下降了 7.3%(表 2),此部分实验表明增加小目标检测头可以有效提升模型的检测精确度。在应用上述改进的同时增加小目

标检测头时,由于采用了轻量级的特征提取网络和多尺度自适应特征融合模块,模型在检测速度方面得到明显回升,保持相当水平检测精确率的同时,较单独增加小目标检测头的检测速度提升了 14.5%,进一步验证了以上 3 个模块对于模型的综合提升性能,其与原模型相比,检测精确率提升了 2.5 个百分点,召回率提高了 1.9 个百分点,平均精度与平均精度均值分别提升了 2.2 和 1.4 个百分点(表 2)。最后,改进模型采用基于最小点距离交并比的边界框损失函数改善其对害虫目标边界框的回归精度和速度;相较于原始模型 YOLOv8n,改进模型在精确率、召回率、平均精度、平均精度均值上分别提升了 3.9、2.6、2.8、2.5 个百分点(表 2),并且改进模型的 F_1 分数和检测速度较原始模型分别提升 4.4% 和 15.9%,虽然与单独采用轻量化特征提取网络的改动相比有所降低,但其他评价指标均达到最优,综合性能更优。综上所述,所提方法在检测准确度和检测速度方面都有更好的表现。且消融实验结果表明:各部分改进相较于原模型均有其对应优化,改进模型在各项评价指标中都能有更好的表现,检测精度和速度也能达到更好的平衡。

4.2 不同模型检测对比

4.2.1 典型模型检测

实验结果(表 3)表明:改进模型在经过 200 轮次的训练后精确度为 98.6%,召回率为 95.7%,平均精度为 98.3%,平均精度均值为 85.6%, F_1 分数为 0.979。训练过程中的分类损失值和边界框损失值与基线模型 YOLOv8n 的对比(图 5)显示:在两个模型的训练过程中,改进模型在分类损失和边界框损失

表 2 消融实验结果

Tab. 2 Results of ablation experiments

原始模型	+EfficientViT	+DA-C2F	+XSH	+MPDIoU	P/%	R/%	mAP/%	mAP50-95/%	帧率	F_1 分数
					94.7	93.1	95.5	83.1	82	0.938
	√				95.9	93.9	95.8	83.4	98	0.949
YOLOv8n	√	√			96.8	94.4	96.9	83.8	91	0.956
			√		97.5	94.8	96.9	84.0	76	0.961
	√	√	√		97.2	95.0	97.7	84.5	87	0.960
	√	√	√	√	98.6	95.7	98.3	85.6	95	0.979

注: +EfficientViT、+DA-C2F、+XSH、+MPDIoU 分别表示在原始模型基础上增加高效多尺度级联注意力特征提取网络、多尺度自适应特征融合模块、增强小目标害虫检测头、基于最小点距离交并比损失函数。P 为精确度, R 为召回率, mAP 为平均精度, mAP50-95 为平均精度均值, 模型检测速度用帧率(每秒帧数)表示。

表 3 典型模型检测结果对比

Tab. 3 Comparison of typical model detection results

模型	P/%	R/%	mAP/%	mAP50-95/%	帧率	F_1 分数
YOLOv5n	90.3	88.3	95.3	83.7	86	0.893
YOLOv8n	94.7	93.1	95.5	83.1	82	0.938
改进模型	98.6	95.7	98.3	85.6	95	0.979

的收敛速度均优于 YOLOv8n, 且改进模型收敛的损失值均低于 YOLOv8n。这表明改进模型不仅在害虫分类方面性能更好, 同时也能更精准地定位目标, 对害虫目标边界框的定位也更加准确。

为了进一步验证改进后网络模型的有效性, 使用处理后的同一数据集在 YOLOv8n 原模型和 YOLOv5n 上进行训练, 并将原模型的客观数据和可视化检测结果与改进模型进行比较。由于 YOLOv5n 在模型复杂度和参数量方面较 YOLOv8n 均更低, 因此在检测速度方面, YOLOv5n 的推理速度快于 YOLOv8n, 但其检测准确度较低; 而改进模型不仅在精确率、召回率、平均精度、平均精度均值和 F_1 分数方面有显著提升, 且在检测速度方面, 较 YOLOv5n 也有 10% 的提高, 这证明了改进模型在复杂背景下对害虫目标的识别效率更加优越; 相较于基线模型 YOLOv8n, 改进模型在精确率、召回率、平均精度、平均精度均值方面分别提升了 3.9、2.6、2.8、2.5 个百分点, F_1 分数提升了 4.4%; 且通过特征提取网络的轻量化设计和损失函数的优化, 改进模型在对于害虫目标的检测速度上有显著提高, 相较于 YOLOv8n 提升 15.9%(表 3)。以上结果表明, 改进模型不仅在检测准确度等各项指标上有明显提升, 且与更加轻量化的模型相比较, 检测速度也更优, 综合性能更佳。

4.2.2 单类害虫检测

为验证改进模型在单类害虫检测方面的有效性, 将本数据集中的油桐褐边绿刺蛾(*Latoia consocia*)、

杨舟扇蛾(*Clostera anachoreta*)的检测精确率、召回率和平均精度与文献 [38] 中的同类害虫分别进行比较。比较结果(表 4)显示: 虽然文献 [38] 在两种害虫的检测精度方面略高于改进模型, 但在召回率和平均精度方面, 改进模型均显著高于文献模型。此外, 在害虫真实检测场景下, 模型对于害虫的识别不仅要准确, 也要具有足够的鲁棒性和稳定性。综上可知, 改进模型具有更好的检测稳定性, 综合性能更优。

4.2.3 飞蛾类害虫检测

为进一步验证改进模型的可行性与泛化能力, 将本数据集中美国白蛾(*Hyphantria cunea*)、黄刺蛾(*Cnidocampa flavescens*)和人纹污灯蛾(*Spilarctia subcarnea*)等 8 种飞蛾类害虫的平均检测精确率与文献 [5] 中的飞蛾类害虫检测结果进行比较。比较结果(表 5)显示改进模型在多种飞蛾类害虫的检测表现中更优。对比模型针对的检测类别较少, 而改进模型即使在面对形态相似的多类飞蛾害虫检测时也有更好的表现, 有更强的泛化能力。

4.3 不同模型预测效果对比

为更直观地将改进模型与原模型的性能差别进行比较, 选择测试集的图片分别使用改进模型与原模型进行预测, 预测结果如图 6 所示。图 6 第 1 行显示: 与 YOLOv5n 和 YOLOv8n 相比, 改进模型在害虫的检测准确度方面表现更优, 置信度分别提高了 6.9% 和 5.7%, 并且预测框定位较其他两个模型更加贴合害虫目标的真实标注框, 定位更加精准。图 6 第 2 行显示: 由于数据集中害虫种类较多, 且单




图 5 改进模型与基线模型 YOLOv8n 的损失对比

Fig. 5 Loss comparison of the improved model and baseline model YOLOv8n

表 4 两类害虫检测结果对比

Tab. 4 Comparison of detection results of two types of pests

害虫种类	模型	P/%	R/%	mAP/%	F_1 分数
油桐褐边绿刺蛾	YOLOv5s ^[38]	100.0	60.50	64.30	0.754
	改进模型	98.9	100.00	99.50	0.994
杨舟扇蛾	YOLOv5s ^[38]	100.0	52.99	52.99	0.693
	改进模型	99.3	100.00	99.70	0.996

表 5 飞蛾类害虫检测结果对比

Tab. 5 Comparison of detection results of moth pests

模型	P	mAP
MRA-YOLOX ^[5]	87.0	
改进模型	98.2	98.5

类害虫存在多形态影响,在使用 YOLOv5n 进行检测时出现了误检的情况,而改进模型和 YOLOv8n 都能准确识别出害虫的种类,并且给出对应的边界框,但改进模型的置信度较其也有提升,且对目标定位也更加精确。图 6 第 3 行显示:改进模型在检测置信度上仍高于基线模型,但 YOLOv5n 在此类特征明显,且背景与害虫目标有明显对比的情况下,置信度与改进模型一致,达到了 93%。图 6 第 4 行显示:

在面对环境背景较为复杂且目标聚集度较高的情况下, YOLOv5n 出现了较为严重的漏检情况,在图像中间和右下都未能识别出目标的位置,基线模型对于图像右下角的害虫目标也出现了漏检,且对左上的目标出现了单一目标重复检测的问题;而改进模型对于复杂情况的害虫目标检测效果显著更优,能够有效识别图像中的害虫目标,检测准确度更高,且预测框定位精准,未出现重复检测情况,有效解决了复杂环境检测易出现漏检、误检的问题。因此,改进模型对于真实场景下的林业害虫检测有较好的检测能力和适应性。

4.4 检测热力图对比

图 7 显示:改进模型对于目标位置的关注更加精确,热力值更高,而原模型和 YOLOv5n 均出现了

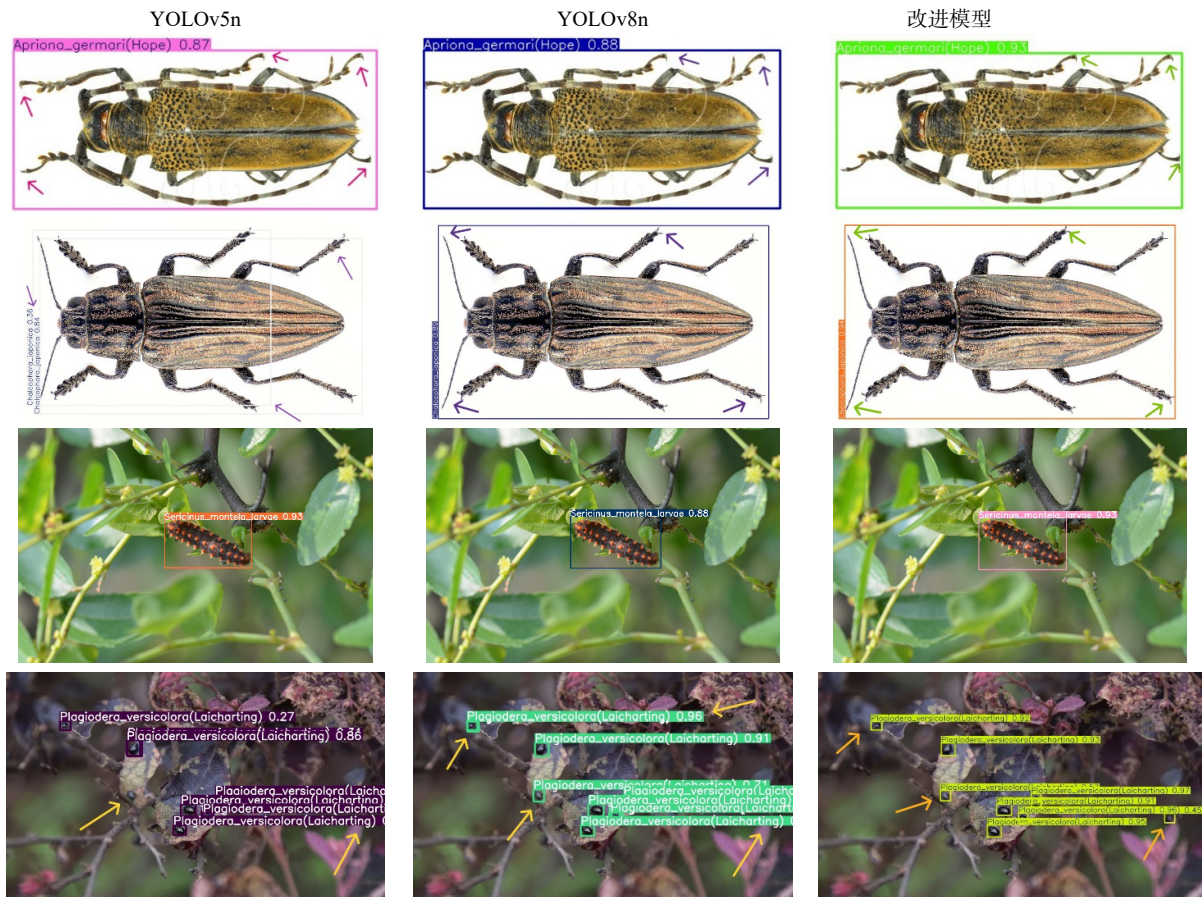


图 6 不同模型预测效果对比

Fig. 6 Comparison of prediction effect of different models



图 7 检测热力图对比

Fig. 7 Comparison of heat maps for detection

对小目标害虫的漏检,未能有效给予目标位置相应的关注,且由于原模型对害虫特征融合出现偏差,对害虫目标周围的环境给予了过度关注,导致其出现了重复检测的误检问题。

综上所述,改进 YOLOv8n 的检测方法不仅提升了检测的精度,并且提高了检测的速度,可以更好地满足真实环境下对林业害虫实时检测的需求。

5 结 论

本研究针对现有林业害虫检测深度学习方法中存在的问题,提出了一种改进 YOLOv8n 的检测方法:引入高效多尺度级联注意力特征提取网络 EfficientViT_M0 以降低模型复杂度,构建多尺度自适应特征融合模块 DA-C2F,并将检测头上层的 C2F 进行了重构,增加了小目标检测头提升模型对于小体积害虫目标的检测能力,采用基于最小点距离交并比损失函数 MPDIoU 作为改进模型的边界框损失函数。

实际场景数据集实验结果以及与 YOLOv8n 原模型的对比和消融实验,均验证了所提方法的有效性。与原模型相比,改进模型的性能指标精确率、召回率、平均精度、平均精度均值分别提升了 3.9、2.6、2.8、2.5 个百分点, F_1 分数和检测速度分别提升了 4.4% 和 15.9%。与更加轻量级的模型 YOLOv5n 相比,改进模型具有更快的检测速度。此外,与其他飞蛾类害虫检测模型相比,本方法效果更优。这进一步验证了其实际应用的可行性。

综上,本方法对于复杂情况下的害虫检测效果更优,且速度更快,能够满足在实际部署应用场景对于林业害虫检测模型的轻量化要求,并且对于多类别和不同形态的害虫都能进行有效检测,更符合真实条件下的林业害虫检测需求,泛化能力更优。虽然本研究针对于林业害虫的检测方法做出了系列优化,并取得了显著效果,但尚未开展实时环境中林业作业机器人协同工作的实证测试。下一步的工作将考虑不同环境因素对于林业害虫检测的影响,进一步优化方法,并结合作业机器人硬件部署研究多变自然条件下实现害虫的有效识别与监控,进而为林业保护提供更为坚实的技术支撑。

参 考 文 献

- [1] Zhao Z H, Yang M, Yang L M, et al. Predicting the spread of forest diseases and pests[J]. *IEEE Access*, 2020, 8: 199803–199812.
- [2] 赵严,刘应安,业巧林,等.基于深度学习的林业害虫检测优化[J].*液晶与显示*,2022,37(9):1216–1227.
Zhao Y, Liu Y A, Ye Q L, et al. Forestry pest detection based on deep learning[J]. *Chinese Journal of Liquid Crystals and Displays*, 2022, 37(9): 1216–1227.
- [3] Zha M F, Qian W B, Yi W K, et al. Lightweight YOLOv4-based forestry pest detection method using coordinate attention and feature fusion[J]. *Entropy*, 2021, 23: 1587–1605.
- [4] Liu D Y, Lü F, Guo J, et al. Detection of forestry pests based on improved YOLOv5 and transfer learning[J]. *Forests*, 2023, 14: 1484–1500.
- [5] 王中天,邹颖波,吴昌霖,等.超越单一感知的农田害虫检测算法 MRA-YOLOX[J].*计算机工程与应用*,2024,60(16):206–216.
Wang Z T, Zou Y B, Wu C L, et al. MRA-YOLOX, for pest detecting in farmland beyond single perception[J]. *Computer Engineering and Applications*, 2024, 60(16): 206–216.
- [6] Huang J Y, Huang Y, Huang H L, et al. An improved YOLOX algorithm for forest insect pest detection[J]. *Computational Intelligence and Neuroscience*, 2022, 5787554: 1–12.
- [7] Xie C J, Zhang J, Li R, et al. Automatic classification for field crop insects via multiple-task sparse representation and multiple-kernel learning[J]. *Computers and Electronics in Agriculture*, 2015, 119: 123–132.
- [8] Ebrahimi M A, Khoshtaghaza M H, Minaei S, et al. Vision-based pest detection based on SVM classification method[J]. *Computers and Electronics in Agriculture*, 2017, 137: 52–58.
- [9] Wang J N, Lin C T, Ji L Q, et al. A new automatic identification system of insect images at the order level[J]. *Knowledge-Based Systems*, 2012, 33: 102–110.
- [10] Li Y, Xia C L, Lee J M. Detection of small-sized insect pest in greenhouses based on multifractal analysis[J]. *Optik-International Journal for Light and Electron Optics*, 2015, 126: 2138–2143.
- [11] 赵辉,黄鏢,王红君,等.基于改进 YOLOv7 的农田复杂环境下害虫识别算法研究[J].*农业机械学报*,2023,54(10):246–254.
Zhao H, Huang B, Wang H J, et al. Pest identification method in complex farmland environment[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(10): 246–254.
- [12] 姜晟,曹亚芄,刘梓伊,等.基于改进 Faster RCNN 的茶茶叶部病害识别[J].*华中农业大学学报*,2024,43(5):41–50.
Jiang S, Cao Y F, Liu Z Y, et al. Recognition of tea leaf diseases based on improved Faster RCNN[J]. *Journal of Huazhong Agricultural University*, 2024, 43(5): 41–50.
- [13] 蒋心璐,陈天恩,王聪,等.农业害虫检测的深度学习算法综述[J].*计算机工程与应用*,2023,59(6):30–44.
Jiang X L, Chen T E, Wang C, et al. Survey of deep learning algorithms for agricultural pest detection[J]. *Computer Engineering and Applications*, 2023, 59(6): 30–44.
- [14] 王金,李颜娥,冯海林,等.基于改进的 Faster R-CNN 的小目标储粮害虫检测研究[J].*中国粮油学报*,2021,36(9):164–171.
Wang J, Li Y E, Feng H L, et al. Detection of small target stored grain pests detection based on improved Faster R-CNN[J]. *Journal of the Chinese Cereals and Oils Association*, 2021, 36(9): 164–171.
- [15] 候瑞环,杨喜旺,王智超,等.一种基于 YOLOv4-TIA 的林业害虫实时检测方法[J].*计算机工程*,2022,48(4):255–261.
Hou R H, Yang X W, Wang Z C, et al. A real-time detection method for forestry pest based on YOLOv4-TI-A[J]. *Computer Engineering*, 2022, 48(4): 255–261.
- [16] 孙海燕,陈云博,封丁惟,等.基于注意力模型和轻量化 YOLOv4

- 的林业害虫检测方法[J]. 计算机应用, 2022, 42(11): 3580–3587.
- Sun H Y, Chen Y B, Feng D W, et al. Forestry pest detection method based on attention model and lightweight YOLOv4[J]. *Journal of Computer Applications*, 2022, 42(11): 3580–3587.
- [17] Cai H, Li J, Hu M, et al. EfficientViT: lightweight multi-scale attention for high-resolution dense prediction[C]//Cristina C. 2023 IEEE/CVF International Conference on Computer Vision (ICCV). Paris: IEEE, 2023: 17256–17267.
- [18] Ma S L, Xu Y. MPDIoU: a loss for efficient and accurate bounding box regression[J/OL]. arXiv: 2307.07662v1. [2023–07–14]. <https://doi.org/10.48550/arXiv.2307.07662>.
- [19] Liu B, Liu L Y, Zhou R, et al. A dataset for forestry pest identification[J]. *Frontiers in Plant Science*, 2022, 13: 1–10.
- [20] Varghese R, Sambath M. YOLOv8: a novel object detection algorithm with enhanced performance and robustness[C]//Curran Associates, Inc. 2024 International Conference on advances in data engineering and intelligent computing systems (ADICS). Chennai: IEEE, 2024: 1–6.
- [21] 彭菊红, 张弛, 高谦, 等. 基于改进的 YOLOv8 算法的钢材缺陷检测[J/OL]. *计算机工程* [2024–07–15]. <https://doi.org/10.19678/j.issn.1000-3428.00EC0069283>.
- Peng J H, Zhang C, Gao Q, et al. Steel defect detection based on improved yolov8 algorithm[J/OL]. *Computer Engineering* [2024–07–15]. <https://doi.org/10.19678/j.issn.1000-3428.00EC0069283>.
- [22] 惠卓凡, 李鹏龙, 沈烈, 等. 基于改进 YOLOv8 的渔港船舶进出港目标检测与统计方法[J]. *大连海洋大学学报*, 2024, 39(3): 498–505.
- Hui Z F, Li P L, Shen L, et al. Detection and statistics method of ship entry and exit in a fishing port based on improved YOLOv8[J]. *Journal of Dalian Ocean University*, 2024, 39(3): 498–505.
- [23] Wang C Y, Liao H Y M, Wu Y H, et al. CSPNet: a new backbone that can enhance learning capability of CNN[C]// O’Conner L. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Seattle: IEEE, 2020: 1571–1580.
- [24] He K M, Zhang X Y, Ren S Q, 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.
- [25] Howard A, Sandler M, Chu G, et al. Searching for mobilenetv3[C]// O’Conner L. Proceedings of the IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019: 1314–1324.
- [26] Ma N, Zhang X, Zheng H T, et al. Shufflenet v2: practical guidelines for efficient cnn architecture design[C]//Ferrari V. Proceedings of the European conference on computer vision (ECCV). Munich: EACV, 2018: 116–131.
- [27] 廖晓辉, 谢子晨, 辛忠良, 等. 基于轻量化 YOLOv5 的电气设备外部缺陷检测[J]. *郑州大学学报(工学版)*, 2024, 45(4): 117–124.
- Liao X H, Xie Z C, Xin Z L, et al. Electrical equipment external defect detection based on YOLOv5[J]. *Journal of Zhengzhou University (Engineering Science)*, 2024, 45(4): 117–124.
- [28] 徐杨, 熊举举, 李论, 等. 采用改进的 YOLOv5s 检测花椒簇[J]. *农业工程学报*, 2023, 39(16): 283–290.
- Xu Y, Xiong J J, Li L, et al. Detection pepper clusters using improved YOLOv5s[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2023, 39(16): 283–290.
- [29] Sanghyun W, Jongchan P, Joon Y L, et al. CBAM: convolutional block attention module[C]// Ferrari V. Proceedings of the European conference on computer vision (ECCV). Munich: EACV, 2018: 3–19.
- [30] Liu Y, Shao Z, Hoffmann N. Global attention mechanism: retain information to enhance channel-spatial interactions[J/OL]. arXiv: 2112.05561. [2023–07–14]. <https://doi.org/10.48550/arXiv.2112.05561>.
- [31] Farzad S, Nader A, Soroush S, et al. DAS: a deformable attention to capture salient information in CNNs[J/OL]. arXiv: 2311.12091. [2024–07–14]. <https://doi.org/10.48550/arXiv.2311.12091>.
- [32] Yu F, Koltun V, Funkhouser T. Dilated residual networks[C]// O’Conner L. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu: IEEE, 2017: 472–480.
- [33] 赵文仓, 徐长凯, 王春鑫. 基于优化边界框回归的目标检测[J]. *高技术通讯*, 2021, 31(7): 747–753.
- Zhao W C, Xu C K, Wang C X. Target detection based on optimized bounding box regression[J]. *Chinese High Technology Letters*, 2021, 31(7): 747–753.
- [34] 周涛, 王骥, 麦仁贵. 基于改进 YOLOv8 的实时菠萝成熟度目标检测方法[J/OL]. *华中农业大学学报* [2024–07–16]. <http://kns.cnki.net/kcms/detail/42.1181.S.20240422.1423.006.html>.
- Zhou T, Wang J, Mai R G. Real-time object detection method of pineapple ripeness based on improved YOLOv8[J/OL]. *Journal of Huazhong Agricultural University* [2024–07–16]. <http://kns.cnki.net/kcms/detail/42.1181.S.20240422.1423.006.html>.
- [35] 李爽, 张潇巍, 谭旭, 等. 基于深度学习的树木根系探地雷达多目标参数反演识别[J]. *北京林业大学学报*, 2024, 46(4): 103–114.
- Li S, Zhang X W, Tan X, et al. Deep learning-based inverse identification of multi-target parameters for tree rooting ground-penetrating radar[J]. *Journal of Beijing Forestry University*, 2024, 46(4): 103–114.
- [36] Selvaraju R R, Cogswell M, Das A, et al. Grad-CAM: visual explanations from deep networks via gradient-based localization[C]// O’Conner L. 2017 IEEE International Conference on Computer Vision (ICCV). Venice: IEEE, 2017: 618–626.
- [37] 张新月, 胡广锐, 李浦航, 等. 基于改进 YOLOv8n 的轻量化红花识别方法[J]. *农业工程学报*, 2024, 40(13): 163–170.
- Zhang X Y, Hu G R, Li P H, et al. Recognizing safflower using improved lightweight YOLOv8n[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2024, 40(13): 163–170.
- [38] 陈中垚. 基于 YOLOv5s 的林业害虫目标检测方法分析[J]. *电子技术*, 2024, 53(3): 53–57.
- Chen Z Y. Analysis of forest pest target detection method based on YOLOv5s[J]. *Electronic Technology*, 2024, 53(3): 53–57.

(责任编辑 吴娟
责任编委 陈志泊)