

# 基于YOLOv8改进的农业复杂场景害虫识别算法

李凌<sup>1</sup>, 朱健文<sup>2</sup>, 杨欢<sup>1</sup>

(1. 华南师范大学人工智能学院, 广东 佛山 528225;  
2. 广东外语外贸大学体育部, 广东 广州 510006)

**摘要:** 农业害虫的准确识别对于保障作物健康和提高产量至关重要。然而, 在复杂环境下, 传统害虫检测方法常因光照多变、杂草遮挡及背景杂乱等问题, 导致识别精度不足且环境适应性差。为解决该问题, 提出一种基于YOLOv8改进的农业害虫识别算法。首先, 采用空间深度卷积(SPD-Conv)模块替代传统卷积层, 增强了模型在低分辨率和小目标害虫图像中的特征提取能力, 尤其在小目标检测中减少了信息丢失; 其次, 结合Shuffle Attention(SA)注意力机制, 通过动态调整通道和空间维度的权重, 优化了模型在复杂背景中的目标聚焦能力, 有效减少了背景干扰, 提升了对害虫特征的识别精度; 最后, 采用FocalGIoU损失函数进行边界框回归, 改进了模型在密集目标和重叠目标上的定位精度, 特别适用于农业环境中的害虫群集和遮挡情况。实验结果表明, 改进后的算法在mAP@0.5和mAP@0.5-0.95上分别达到了95.2%和56.7%, 比原YOLOv8n模型提高了1.6%和1.3%。该方法显著提升了农业害虫识别准确性和稳定性, 为智能农业的精准监测提供了更高效、可靠的解决方案。

**关键词:** 智能农业; 害虫识别; YOLOv8; 空间深度卷积; SA; FocalGIoU

DOI: 10.11907/jjdk.241929

扫描二维码阅读全文:



中图分类号: TP183; TP391.41

文献标识码: A

文章编号: 1672-7800(2026)003-0195-09

## Pest Identification Algorithm in Complex Agricultural Scenes Based on Improved YOLOv8

LI Ling<sup>1</sup>, ZHU Jianwen<sup>2</sup>, YANG Huan<sup>1</sup>

(1. School of Artificial Intelligence, South China Normal University, Foshan 528225, China;  
2. Sports Department, Guangdong University of Foreign Studies, Guangzhou 510006, China)

**Abstract:** Accurate identification of agricultural pests is crucial for ensuring crop health and increasing yield. In complex environments, traditional pest detection methods face significant challenges, such as varying lighting conditions, weed obstructions, and cluttered backgrounds, resulting in poor accuracy and adaptability. To improve the detection precision and robustness in such complex scenarios, this paper proposes an improved agricultural pest identification algorithm based on YOLOv8. The specific improvements include: First, the introduction of a Spatial Depth Convolution (SPD-Conv) module to replace traditional convolution layers, enhancing the model's feature extraction ability in low-resolution and small-target pest images, particularly reducing information loss in small target detection. Second, the integration of a Shuffle Attention (SA) mechanism, which dynamically adjusts the weights of channels and spatial dimensions to optimize the model's focus on target areas in complex backgrounds, effectively reducing background interference and improving pest feature recognition accuracy. Finally, the use of the FocalGIoU loss function for bounding box regression improves the model's localization accuracy for dense and overlapping targets, making it particularly suitable for agricultural environments where pests often cluster or are occluded. Experimental results show that the improved algorithm achieves mAP@0.5 and mAP@0.5-0.95 values of 95.2% and 56.7%, respectively, an increase of 1.6% and 1.3% over the original YOLOv8n model. This method significantly improves the accuracy and stability of agricultural pest identification, providing a more efficient and reliable solution for precision monitoring in smart agriculture.

**Key Words:** intelligent agriculture; pest identification; YOLOv8; SPD-Conv; SA; FocalGIoU

收稿日期: 2025-02-19

基金项目: 广东省基础与应用基础研究基金项目(2020A1515110783)

作者简介: 李凌(2001-), 男, 华南师范大学人工智能学院硕士研究生, 研究方向为目标检测; 朱健文(1976-), 男, 硕士, 广东外语外贸大学体育部副教授、硕士生导师, 研究方向为目标检测; 杨欢(1986-), 男, 博士, CCF会员, 华南师范大学人工智能学院副研究员、硕士生导师, 研究方向为目标检测。本文通讯作者: 杨欢。

## 0 引言

随着全球人口的快速增长和对食品安全的日益重视,农产品的质量与生产量成为社会稳定和经济发展的重要支柱。农作物的生长环境直接影响其品质与产量,因而确保农作物的健康培育是现代农业管理的重中之重<sup>[1]</sup>。在农作物培育过程中,农业害虫是影响作物产量的关键因素,其不仅对作物造成直接损害,还可能引发连锁反应,影响生态系统稳定性,从而对农业生产的可持续性构成重大挑战。因此,及时准确地识别和控制害虫是保护农作物、提高农业产量的关键环节。

农业害虫识别是保障农作物健康生长的关键技术之一<sup>[2]</sup>。传统的人工检测方法在农业害虫识别中依然广泛应用,但存在诸多不足。首先,人工检测不仅耗费大量人力资源,且其识别过程往往缺乏准确性与实时性。这使得害虫的早期发现和及时处理变得极为困难,导致害虫快速扩散和农作物损失;其次,人工检测依赖于技术人员的经验,容易受到主观判断的影响,尤其在复杂的田间环境中,外部环境如天气变化、光照条件和农作物的生长状态都可能干扰检测结果,进一步降低了识别效率。

随着科技的进步,自动化害虫识别技术成为核心需求。借助计算机视觉和机器学习等先进的人工智能相关技术,现代农业逐渐向智能化方向发展。这些技术不仅能够提高害虫识别准确性和效率,还能实现对害虫的动态监测,为农业生产的管理和决策提供重要依据,因此人工智能相关技术不断被引入农业环境以辅助人工进行产业运作。张亚军<sup>[3]</sup>提出一种基于改进支持向量机(Support Vector Machine, SVM)算法的农业害虫图像识别方法,改进后的算法平均识别率为95.67%,相比其他算法有显著提升。Ke等<sup>[4]</sup>研究了一种改进的SVM算法,将其用于番茄病虫害检测,通过融合颜色纹理特征,并使用9倍交叉验证选择最优参数,该方法显著提高了检测准确性和效率。Cui等<sup>[5]</sup>提出一种基于SVM的储粮害虫检测方法,针对甲壳类害虫,使用20×20像素的害虫和背景图像进行训练和分类,SVM分类器的准确率达99.40%。

然而,传统的机器学习方法在处理小数据模型时表现较好,但它们无法有效学习特征之间的相互作用,且需人工提取特征,识别效率低下。相比之下,卷积神经网络(Convolutional Neural Network, CNN)作为深度学习的代表算法,能够自动提取特征,更好地捕捉复杂数据中的模式和关联<sup>[6]</sup>。因此,基于CNN的深度学习模型逐渐在农业害虫识别领域得到广泛应用。这些模型通过多层卷积操作自动提取图像特征,显著提高了识别准确性和效率,减少了人工干预。随着深度学习技术的发展,CNN在农业中的应用前景广阔,为精准农业和智能农作物管理提供了强大支持。梁万杰等<sup>[7]</sup>提出一种基于卷积神经网络的水稻二

化螟虫害识别方法,设计了一个10层卷积神经网络,识别精度为89.14%。程曦等<sup>[8]</sup>提出一种基于深度卷积神经网络的储粮害虫图像识别方法,简化数据预处理,识别精度达到97.61%。陈娟等<sup>[9]</sup>提出一种基于改进残差网络的北方园林害虫图像识别方法,优化超参数,平均识别准确率提高了9.6个百分点。王文周<sup>[10]</sup>研究了一种改进YOLOv3的水稻害虫在线识别与定向施药方法,平均检测准确率为82.3%,显著优于原始YOLOv3。彭红星等<sup>[11]</sup>提出一种基于改进ShuffleNet V2的轻量化农作物害虫识别模型,识别准确率和F1分数分别提高到79.49%和78.54%,识别速度显著提升。

农业害虫识别数据集构建非常严谨且困难,不仅要考虑识别场景的多样性和实用性,也需考虑数据集的合适大小和不同害虫类别间的样本均衡。若数据集过小,则会导致模型在训练后所得精度较低,而在农业害虫识别实验中的首要关注点必然是提高模型网络精确度,则需设计较为复杂的神经网络模型结构,也使得模型计算难度和调参难度较大。经过以上分析得知,在实验中针对设备性能有限的情况,对模型进行轻量化处理尤为必要<sup>[12]</sup>。郑果等<sup>[13]</sup>提出一种基于改进YOLOv7的水稻害虫识别方法,通过引入卷积块注意力和特征金字塔模块,增强识别精度,改进后的模型平均识别准确率为85.46%。马盼等<sup>[14]</sup>提出一种基于YOLOv8的棉蚜图像识别算法,通过使用YOLOv8l模型进行训练,mAP50达到0.926,展现出良好的实用价值。

然而,在实际农业环境中,常需要面对诸多复杂场景的识别,农业检测场景的复杂性主要体现在多种环境变量的干扰上。田间场景通常存在多变的光照条件,例如强光、阴影和不同时间的光线变化,使得图像质量不一,导致害虫特征的可见性波动。同时,田间杂草、植被以及农作物本身的复杂背景极易遮挡害虫目标,干扰特征提取过程。此外,农田环境中的害虫种类和形态各异,且大小不一,进一步增加了模型在识别小目标和低对比度目标时的难度。基于这些复杂性,农业害虫识别模型需要在动态环境下具备高鲁棒性和适应性,以确保对害虫的准确识别和分类。

本文YOLOv8改进算法针对农业害虫识别中的实际问题进行优化。在农业环境中,害虫通常具有小目标、低分辨率和复杂背景等特征,现有方法在这些条件下的表现较差。因此,本文研究创新性地引入了3个关键模块:SPD-Conv模块、SA注意力机制和FocalGIoU损失函数。SPD-Conv模块通过增强小目标和低分辨率图像的特征提取能力,解决了农业害虫图像中细节丢失的问题;SA注意力机制通过动态调整特征权重,有效应对杂草遮挡和背景复杂性,提升了模型在农业环境中的鲁棒性;FocalGIoU损失函数则在处理害虫重叠和群集时,显著提高了模型定位精度。本文在准备过程中,使用了ChatGPT进行文献调研。

使用此工具后,笔者根据需要对相关内容进行了审查和编辑,并对出版物的内容承担全部责任。研究可知,本文改进方法不仅在精度上取得了突破,还具备了针对农业实际应用的创新性和可行性,为智能农业的害虫监测提供了更高效、精准的解决方案。

1 实验数据集构建

为推动农业害虫识别技术的进步,本文研究构建了一个高质量且具有创新性的农业害虫数据集。该数据集主要来源于公开的害虫图像数据集 IP102,从中精心筛选出农业环境中常见的 8 类害虫,共计 3 393 张图像<sup>[15]</sup>。在筛选过程中,特别关注在不同光照、背景杂草和气候条件下拍摄的图像,以确保训练得到的模型能够适应实际应用场景,增强识别效果。

为了进一步提升数据集的质量,对各类害虫图片数量进行了合理平衡,既考虑了不同类别害虫的相对频率,又增强了模型对稀有害虫的识别能力。通过这种平衡,确保了数据集的多样性和代表性,使模型在面对真实环境中的变化时表现更加可靠。

所有筛选出的害虫图像经过数据集格式转换,从 VOC 格式转为适用于 YOLO 模型训练的格式,确保数据集能够最大限度地发挥 YOLO 模型的优势。最终,按照 8:1:1 的比例创建了训练集、验证集和测试集,确保模型在不同阶段的有效性和可靠性。这种系统化的构建方法为后续研究提供了坚实基础,并为农业害虫的自动化识别奠定了基础,预计将显著提升农作物的生产效率和保障粮食安全。

数据集中各类害虫训练集、验证集、测试集的详细信息如表 1 所示。

Table 1 Detailed information of pest datasets  
表 1 害虫数据集数据明细

| 待检测标   | 训练集<br>数量 | 验证集<br>数量 | 测试集<br>数量 | 标签                    |
|--------|-----------|-----------|-----------|-----------------------|
| 蛴螬     | 330       | 46        | 60        | grub                  |
| 蝼蛄     | 398       | 55        | 48        | mole cricket          |
| 蚜虫     | 409       | 36        | 48        | aphids                |
| 跳甲     | 276       | 39        | 30        | flea beetle           |
| 牧草盲蝽   | 281       | 31        | 36        | tarnished plant bug   |
| 豆科水疱甲虫 | 360       | 43        | 32        | legume blister beetle |
| 斑衣蜡蝉   | 254       | 46        | 38        | lycorma delicatula    |
| 叶蝉科    | 406       | 43        | 48        | cicadellidae          |
| 总数     | 2 714     | 339       | 340       |                       |

尽管 YOLO 系列最初是为动态场景中的目标检测而设计,但由于其优异的实时性和高效性,YOLOv8 模型(特别是 YOLOv8n 版本)非常适合在资源有限的农业环境中应用。在农业害虫识别任务中,YOLOv8n 模型以其轻量级的结构,在确保准确性的同时减少了计算负担,从而更适合在低功耗设备上实现实时目标检测。尽管本文使用的数据集相对较小,但该数据集通过精心挑选和数据增强等手

段,在保证数据多样性的同时,已能为模型提供足够的训练数据。未来,随着数据集规模的扩大和更多农业场景数据的加入,YOLOv8 系列将继续在农业害虫监测中展现其高效性和可扩展性。

2 农业害虫识别网络

2.1 YOLOV8 网络模型原理与结构

YOLOv8 是一种高性能、轻量级的目标检测模型,其基于深度学习技术,具备实时检测和高精度的特点,广泛应用于多个领域<sup>[16]</sup>。该模型包括多个版本,如 YOLOv8n、YOLOv8s 和 YOLOv8m,旨在满足不同应用需求。本文以 YOLOv8n 模型作为基础结构,作进一步改进,以提升其在复杂场景下的检测能力。YOLOv8 的结构可以分为 3 个主要部分:骨干网络(Backbone)、颈部网络(Neck)和检测头(Head),其在模型架构上的具体创新包括引入了 1 个全新的骨干网络、1 个全新的无锚框检测头和 1 个全新的损失函数。

首先,Backbone 是 YOLOv8 的特征提取部分,其设计目的是提取图像中的重要特征信息。YOLOv8 采用了一种改进的骨干网络架构,这种架构在保持高效计算的同时,能够更好地捕捉图像中的细节信息。通过多层卷积操作,骨干网络逐层提取并压缩图像特征,最终生成一个高维度的特征图。这些特征图包含了图像中不同尺度、不同层次的信息,为后续目标检测提供了坚实基础。

其次,Neck 的主要功能是进一步处理和融合骨干网络提取的特征图。YOLOv8 中的颈部网络通常采用特征金字塔网络(Feature Pyramid Networks,FPN)或者路径聚合网络(Path Aggregation Network,PANet),这些网络结构能够有效地结合不同尺度的特征图,从而增强模型对多尺度目标的检测能力。通过这种多层次的特征融合,YOLOv8 能够在各种复杂的场景中保持较高的检测精度。

最后,Head 是 YOLOv8 的最终输出部分,负责生成目标检测结果。检测头根据从颈部网络传递来的融合特征图进行分类和定位。在 YOLOv8 中,检测头采用了锚框机制,在每个特征图上生成多个预定义的锚框,并根据这些锚框预测目标的类别和边界框。通过对这些预测进行后处理,YOLOv8 能够高效地生成高质量的目标检测结果。

2.2 改进的网络结构

在 YOLOv8n 模型的基础上,本文进行了多项创新改进,以提升其性能和适应性,其中改进内容包括:

(1)引入 SPD-Conv 模块。在网络的卷积层引入了空间深度卷积(SPD-Conv)模块,该模块通过将空间信息转化为深度信息,有效保留了图像细节。SPD-Conv 模块不仅简化了特征提取过程,还提高了模型在低分辨率和小目标检测中的表现。该模块的加入,使得 YOLOv8n 在农业害虫识别中能够更加精准地捕捉到微小目标和复杂环境中

的细微特征,从而显著提升了检测精度和准确性。

(2)添加SA注意力机制。在模型中引入了SA注意力机制,旨在增强模型对复杂场景中特征的专注能力。SA机制通过动态调整通道权重,使得模型能够更好地捕获重要信息,提升对农业害虫的识别能力。这种创新设计有助于YOLOv8n在多变的农作物生长环境中,准确定位和识别不同种类的害虫,进一步提高了模型鲁棒性和准确性。

(3)优化损失函数。对损失函数进行了优化,选择FocalGIoU作为边界框回归损失函数,以提升模型在复杂环境中的训练稳定性和收敛速度。相比其他常见损失函数,FocalGIoU能够更有效地处理密集目标和重叠区域,提高模型对这些情况的适应性。这一改进使得YOLOv8n在面对复杂农业场景时,表现出更高的准确性和可靠性,为实际应用提供了有力支持。

改进的YOLOv8网络结构如图1所示。

### 2.3 SPD-Conv 模型

为了解决农业害虫在低分辨率和小目标检测中容易造成细节丢失的问题,在YOLOv8n模型的卷积层引入了空间深度卷积(SPD-Conv)模块。该模块通过将空间信息转化为深度信息,有效保留了图像细节,从而显著提升了模型在复杂环境中的识别能力。

SPD-Conv模块由1个空间到深度(SPD)层和1个非步长卷积(Conv)层组成<sup>[17]</sup>。SPD层通过重排输入特征图的空间结构,将空间信息转换为深度信息,而不丢失任何细节信息。随后,Conv层在深度维度上进行卷积操作,从而在保留细节信息的同时,实现下采样特征图的效果。

SPD-Conv模块的设计思想是通过空间到深度的转




Fig. 1 Improved YOLO v8 network structure

图1 改进的YOLOv8网络结构

换,保留更多细节信息,从而增强模型对小物体和低分辨率图像的识别能力。具体而言,SPD-Conv模块可灵活应用于大多数卷积神经网络(CNN)架构,通过替换现有的步长卷积层和池化层,实现更有效的特征提取。通过优化特征提取过程,SPD-Conv模块能够更好地适应各种视觉任务,尤其是在复杂场景中,提高了对检测目标的识别精度和可靠性,为实际应用提供了强有力的支持。其具体结构如图2所示。




Fig. 2 SPD-Conv module structure

图2 SPD-Conv 模块结构

该模块的引入不仅简化了网络结构,使其更加高效,而且在保持网络深度的同时,提升了模型整体性能。在农业害虫检测中,优化特征的提取过程能够显著提高对目标的识别精度和可靠性,特别是在复杂的生长环境中。此外,SPD-Conv模块在处理不同种类的害虫时,能够更好地

适应多样化的视觉特征,提升模型在真实场景中的应用价值。因此,SPD-Conv模块在本文研究中的作用至关重要,为农业害虫的准确检测提供了有力支持,确保了研究成果能够在实际农业管理中发挥更大作用。

## 2.4 SA 注意力机制

在面对多变的农作物生长环境时,特征可能受到杂草和光照变化的干扰,因而在YOLOv8n模型中引入了SA注意力机制。这一机制通过动态调整通道权重,有效融合重要信息,增强了模型对农业害虫的识别准确性和鲁棒性。

SA注意力机制是一种轻量且高效的注意力模块,通

过对输入特征进行分组、计算通道注意力和空间注意力,并最终融合注意力信息以增强特征表达,其结构如图3所示<sup>[18]</sup>。其中, $C$ 表示输入特征图的通道数, $H$ 和 $W$ 分别表示特征图的高度和宽度, $G$ 表示输入特征分组数, $\mathcal{F}_{gp}$ 表示全局平均池化操作, $\mathcal{F}_c$ 表示线性层,GN表示对特征图进行标准化处理。




Fig. 3 SA module structure

图3 SA模块结构

SA注意力机制首先将输入特征 $X \in \mathbb{R}^{C \times H \times W}$ 分组为多个子特征,输入特征被分为 $G$ 组,其中每个子特征随着组的数量独立捕获特定信息;接着,特征图被分为两个分支,分别处理通道注意力和空间注意力。

通道注意力分支通过全局平均池化操作得到特征,其计算公式如式(1)所示。

$$s = \mathcal{F}_{gp}(X_{k1}) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W X_{k1}(i, j) \quad (1)$$

其中, $s$ 表示全局平均池化后的特征, $X_{k1}$ 表示通道注意力分支中的输入特征。

通过一个线性层和Sigmoid激活函数生成通道注意力权重,其计算公式如式(2)所示。

$$X'_{k1} = \sigma(\mathcal{F}_c(s)) \cdot X_{k1} = \sigma(W_1 s + b_1) \cdot X_{k1} \quad (2)$$

其中, $X'_{k1}$ 表示通道注意力分支的输出特征, $W_1$ 和 $b_1$ 表示通道注意力分支的变换参数。

空间注意力分支通过卷积操作和Group Norm得到空间维度的注意力权重,其计算公式如式(3)所示。

$$X'_{k2} = \sigma(W_2 \cdot \text{GN}(X_{k2}) + b_2) \cdot X_{k2} \quad (3)$$

其中, $X'_{k2}$ 表示空间注意力分支的输出特征, $X_{k2}$ 表示空间注意力分支中的输入特征, $W_2$ 和 $b_2$ 表示空间注意力分支的变换参数。

最后,通道注意力和空间注意力的结果被拼接(concat)起来,即 $X'_k = [X'_{k1}, X'_{k2}] \in \mathbb{R}^{C/G \times H \times W}$ ,形成最终的输出特征。

在最终聚合阶段,采用了ShuffleNetv2中的channel shuffle操作以确保不同组子特征的交互。通过这种方式,最终生成一个与输入 $X$ 维度相同的注意力图。

Shuffle Attention(SA)模块在计算机视觉中已得到广泛应用,将其应用于农业害虫识别任务,并对其进行了创

新性调整。在传统SA模块中,通道和空间的注意力分配是静态的,而农业环境中的图像背景复杂且目标小,因此对SA模块进行了改进。具体而言,通过动态调整通道和空间权重,使得模型在复杂背景中能够优先关注害虫区域,尤其在存在杂草遮挡和背景噪声的情况下。此外,为了提升农业害虫检测精度,在SA模块中增加了对害虫形态和颜色等特征的关注,进一步优化了背景的抑制效果。这样,SA模块能够在不同农业环境中自适应地识别并突出害虫目标,从而提升了模型鲁棒性和精度。

该机制的引入,增强了模型对复杂场景中特征的关注能力。在农业害虫检测中,动态调整通道权重的设计能够显著提高对目标重要信息的捕获,尤其是在多变的农作物生长环境中。通过更好地融合局部特征和全局特征,SA机制提升了模型识别精度和鲁棒性,使其在面对不同种类害虫时表现更加出色。综上,SA注意力机制在本文研究中的重要性不言而喻,为农业害虫的有效识别提供了强有力的支持,并确保研究成果能够在实际应用中取得更佳效果。

## 2.5 FocalGIoU 损失函数

考虑到复杂场景中密集目标和重叠区域可能导致模型训练不稳定,YOLOv8n模型中选择FocalGIoU作为边界框回归损失函数。该损失函数能够更有效地处理这些问题,提高了模型训练稳定性和准确性,为实际应用提供了更强大的支持。

YOLOv8版本默认采用CIoU作为其边界框回归损失函数,该函数通过比较预测框和目标框的纵横比,有效评估预测框与真实框之间的位置差异<sup>[19]</sup>。然而,CIoU虽然在预测框和目标框的匹配度量上有更好的性能,但在一些计算资源有限或者对匹配度量要求不高的应用场景中,GIoU

具有独特的优势<sup>[20]</sup>。同时,GIoU能够有效处理预测框和目标框完全不重叠的情况,在这些情况下仍然能够提供有效的梯度信号。为了进一步提升模型在处理不平衡样本分布时的性能,在GIoU基础上引入Focal机制,构建Focal GIoU损失函数<sup>[21]</sup>。FocalLoss函数公式如式(4)所示。

$$FocalLoss = -\alpha(1 - p_i)^\gamma \lg p_i \quad (4)$$

其中, $p_i$ 表示模型预测概率, $\alpha$ 表示平衡参数,用来平衡正、负样本的比例, $\gamma$ 表示可调节的聚焦参数,用来减少易分类样本的损失。

GIoU表达式如式(5)所示。

$$GIoU = IoU - \frac{C - (A \cup B)}{C} \quad (5)$$

其中, $C$ 表示包含预测框和目标框的最小闭包区域, $A$ 和 $B$ 分别表示预测框和目标框。

通过在GIoU基础上添加Focal机制,Focal GIoU不仅能够更好地处理目标检测任务中的边框回归问题,还能有效解决样本分布不平衡的问题,使得模型在实际应用中表现更加出色。通过这种方式,Focal GIoU损失函数不仅能够提升模型在目标检测任务中的准确率,还能够提高其在复杂环境下的鲁棒性和稳定性。

在农业场景中,害虫识别往往面临目标密集、遮挡严重和目标形态差异较大的挑战,特别是在低分辨率图像和复杂背景下,这些因素会显著影响模型检测精度和稳定性。FocalGIoU损失函数能够在这些情况下提供显著的性能提升:其聚焦机制可以减少对易分类样本的关注,从而将更多计算资源用于难以区分的害虫区域,如被遮挡或部分重叠的目标。这种设计有助于增强模型在害虫密集区的辨识能力,有效降低了因遮挡和小目标重叠造成的误检和漏检情况。

同时,与常规的IoU损失函数相比,FocalGIoU更适合处理目标边界不规则、尺寸变化较大的农业害虫图像。农业场景下的害虫图像往往存在显著的边缘模糊、形态不一等问题,FocalGIoU通过对边界匹配精度的提升,确保在处理这些变化时仍然保持较高的检测准确性。此外,其在复杂背景下的自适应性提高了模型对田间场景的鲁棒性,使模型能够在多样化的农作物背景中精准区分出害虫目标。这种损失函数的优化设计,显著提升了模型在复杂农业环境下的稳定性和识别精度,使其在实际应用中更具实用性,为田间害虫监测提供了更高效、可靠的解决方案。

优化后的损失函数,特别是FocalGIoU的引入,提升了模型在复杂环境中的训练稳定性和准确性。通过有效处理密集目标和重叠区域的能力,该损失函数显著提高了模型的适应性。在农业害虫检测任务中,这种优化能够确保模型在面对实际应用中的挑战时,依然保持高水平的表现。损失函数的优化在本文研究中发挥了关键作用,为农业害虫的准确检测提供了重要保障,促进了研究成果在农业管理中的有效应用。

### 3 实验与结果分析

#### 3.1 实验运行环境

本文实验在基于Docker 20.10.10、Python 3.10.12和PyTorch 2.0.1构建的深度学习环境中完成。实验所使用的显卡为Nvidia GeForce RTX 3080,具有10 GB的显存,为模型训练提供了充足的计算资源和存储空间。同时,系统配备了32 GB的内存,进一步提升了数据处理和模型训练效率。此外,CUDA版本为11.8,cuDNN版本为8.6.0,确保了深度学习框架与硬件之间的最佳兼容性,最大限度地释放计算潜能,提升实验整体性能与效果。

#### 3.2 模型测试指标

为评估改进算法的性能,本文所采用的评价指标包括常见的平均精度(mAP)、参数量(Params)和浮点运算量(FLOPs),这些指标用于全面评估模型性能和资源占用情况。

mAP是评估目标检测模型性能的关键指标,包括mAP@0.5和mAP@0.5-0.95两种类型。mAP@0.5表示在IoU阈值为0.5时,计算每类的平均精度,然后取所有类别的平均值;而mAP@0.5-0.95则是在不同IoU阈值(从0.5到0.95,步长0.05)下的平均mAP值。mAP@0.5-0.95可以更全面地反映模型在不同精度要求下的表现,值越高,模型检测效果越好。

参数量(Params)表示模型的内存占用,通常以百万(M)为单位,参数量越小,模型占用内存越少,适合资源有限的场景。浮点运算量(FLOPs)衡量模型计算复杂度,通常以GFLOPs(十亿次浮点运算)为单位,FLOPs越低,模型所需的计算资源越少,运行速度越快。

本文在实验过程中综合考虑这些指标,旨在找到性能与资源占用之间的最佳平衡,从而选择出最适合实际应用的模型。这一策略确保了模型在保持高准确度的同时,能够有效减少内存和计算资源的消耗,使其更具实用性和可操作性。

#### 3.3 对比实验

为了进一步验证本文改进的YOLOv8算法对农业害虫识别的检测性能,选取多种目前较为先进和流行的目标检测模型及其改进模型,并基于制作的常见农业害虫数据集进行对比实验,各模型的训练轮次皆为300轮,得到的实验结果如表2所示。对比结果表明,本文改进算法相较于基线YOLOv8n在mAP@0.5和mAP@0.5-0.95指标上分别提升了1.6%和1.3%,性能表现比其他模型更优异。即使在参数量和计算量上有略微提升,但鉴于精度值的提升,亦在可接受的范围之内。

由表2可知,改进算法在自制数据集上的表现与YOLOv8s模型比较接近,但其在精度值较高的同时依然保持较小的参数量和计算量,对比YOLOv8s模型在Params和

Table 2 Comparative experiments  
表 2 对比实验

| 模型         | mAP@0.5/% | mAP@0.5-0.95/% | Params/10 <sup>6</sup> | FLOPs/10 <sup>9</sup> |
|------------|-----------|----------------|------------------------|-----------------------|
| YOLOv5s    | 92.8      | 53.4           | 7.0                    | 15.8                  |
| YOLOv7tiny | 89.5      | 48.1           | 6.0                    | 13.1                  |
| YOLOv7     | 90.9      | 50.3           | 36.5                   | 103.3                 |
| YOLOv7x    | 94.1      | 54.9           | 70.8                   | 188.1                 |
| YOLOv8n    | 93.6      | 55.4           | 3.0                    | 8.1                   |
| YOLOv8s    | 94.8      | 56.0           | 11.1                   | 28.5                  |
| 本文算法       | 95.2      | 56.7           | 3.4                    | 12.4                  |

FLOPs 上分别降低了  $7.7\times10^6$  和  $16.1\times10^9$ 。相较于所对比的 YOLOv5 系列算法和 YOLOv7 系列算法等主流模型,本文算法的精度更高,mAP@0.5 和 mAP@0.5-0.95 值分别为 95.2% 和 56.7%,同时避免了检测过程中大量的计算资源开销,相较于除 YOLOv8n 基线模型外的其他模型更加轻量化。综上可知,本文模型不仅各项检测性能优势显著,在轻量化方面也十分优秀。相比 YOLO 系列其他主流检测模型,如 YOLOv7tiny、YOLOv7 和 YOLOv5s,本文算法的 mAP@0.5 值分别提高了 5.7%、4.3% 和 2.4%。

表 2 中,改进后的模型虽然在精度上显著提升,但在参数量和计算复杂度上仍有优化空间。尽管 YOLOv8n 在参数量和计算量上相比其他 YOLO 版本较小,但在提升精度的同时,计算复杂度有所增加。考虑到农业害虫检测任务对实时性和计算资源的要求,YOLOv8n 已在保证较高精度的基础上实现了较好的计算效率,适用于资源受限的农业环境。未来工作将集中在通过模型压缩技术(如剪枝和量化)进一步优化计算效率,同时保持精度提升,以适应更广泛的应用需求。

由对比实验结果可知,本文改进算法在多个关键指标上均表现出色。与其他主流 YOLO 模型相比,该算法不仅在检测精度上有显著提升,在参数量和计算复杂度上也实现了良好控制,展现出卓越的轻量化和高效性。这一性能优势得益于创新模块的合理引入与整体结构的优化设计,使模型在保持高检测精度的同时,能够适应资源受限的实际应用场景,为农业害虫检测提供了一个更加高效、精准的解决方案。这种创新设计在保证模型轻量化的基础上,提升了对密集目标和复杂背景的检测能力,进一步彰显了本文研究在农业智能化管理中的应用价值。

3.4 消融实验

为进一步验证本文算法的有效性,设置了一系列消融实验,以探究算法中各模块对模型性能的具体影响。实验中考虑了 SPD-Conv 模块、SA 模块和 Focal Glou 模块 3 个因素,依次将 3 个模块添加到原 YOLOv8n 算法模型中,训练轮次皆为 300 轮,得到的实验结果如表 3 所示。

根据消融实验结果可知,在引入各模块后,原 YOLOv8n 基线模型的性能都得到了不同程度的提升。在引入 SPD-Conv 代替传统卷积模块后,模型的 mAP@0.5-0.95 指标提升了 0.5%。在添加 SA 注意力机制后,mAP@0.5 指

Table 3 Ablation experiment  
表 3 消融实验

| 方法      | SPD-Conv | SA | Focal Glou | mAP@0.5/% | mAP@0.5-0.95/% | Params/10 <sup>6</sup> | FLOPs/10 <sup>9</sup> |
|---------|----------|----|------------|-----------|----------------|------------------------|-----------------------|
| YOLOv8n |          |    |            | 93.6      | 55.4           | 3.0                    | 8.1                   |
| 改进 1    | √        |    |            | 93.7      | 55.9           | 3.4                    | 12.4                  |
| 改进 2    | √        | √  |            | 94.4      | 55.3           | 3.4                    | 12.4                  |
| 本文算法    | √        | √  | √          | 95.2      | 56.7           | 3.4                    | 12.4                  |

标提升了 0.7%,同时并未造成计算开销,使得在计算资源利用量相同的情况下加强了模型总体性能。当引入 Focal Glou 损失函数代替原本的 Clou 损失函数时,在几乎不变的计算成本下显著提升了模型性能,mAP@0.5-0.95 指标提升了 0.8%,mAP@0.5 指标提升了 1.4%。

SPD-Conv 模块通过将传统卷积层替换为空间深度卷积,有效保持了小目标和低分辨率图像的细节信息,尤其在农业害虫识别中,害虫通常是小目标且图像分辨率较低。传统卷积操作可能导致小目标特征丢失,而 SPD-Conv 通过更精确地保留空间信息,提高了模型在小目标检测上的表现。此模块加入后,模型在 mAP@0.5-0.95 指标上提升了 0.5%,证明了其在小目标检测中的优势。

SA 注意力机制通过动态调整通道和空间权重,使模型能够更有效地关注害虫区域,减少复杂背景干扰。在农业害虫识别中,背景通常比较复杂,且可能存在大量杂草或植物遮挡,SA 机制通过关注重要特征区域,显著提高了模型检测精度。加入 SA 模块后,模型在 mAP@0.5 指标上提升了 0.7%,且没有增加额外的计算开销,表明其在提高性能的同时保持了较高的效率。

FocalGlou 损失函数通过结合 Focal Loss 机制,强调对难检测目标(如重叠或密集的害虫目标)的学习,减少了易分类样本的影响。在农业害虫检测中,害虫可能由于群聚或遮挡导致检测困难,FocalGlou 优化了模型对这些难点的适应能力,显著提高了模型在复杂目标区域的定位精度。实验结果显示,FocalGlou 的加入使 mAP@0.5-0.95 提升了 0.8%。

在综合引入所有模块后,本文算法的 mAP@0.5 和 mAP@0.5-0.95 分别较基线模型提升了 1.6% 和 1.3%,展示了优异的性能表现。同时,尽管引入多个模块,参数量和计算复杂度仅略微增加,确保了模型的轻量化特性,进一步验证了本文研究在农业害虫检测场景中的有效性和创新性。这一性能上的提升和资源效率的平衡,使得改进后的模型在实际应用中具备更高的可靠性与实用价值,为后续研究和实践提供了坚实的基础。

3.5 鲁棒性测试

为了验证算法在实际农业检测场景中的性能表现,即本文模型能否适应现实农业环境中复杂多变的检测环境,在佐治亚大学等机构设立的网址(<https://www.insectimages.org/index.cfm>)中提取出贴合实际场景的相关害虫图片。

其中,情境包括简单场景和复杂场景两种常见的检测环境,害虫种类包括数据集中所有的8种常见农业害虫,对以上两种场景分别进行模型检测性能测试,以验证模型在实际检测环境中不同场景下的综合检测能力。简单场景和复杂场景下的检测结果分别如图4、图5所示。




Fig. 4 Detection results of simple scenes

图4 简单场景检测结果



Fig. 5 Detection results of complex scenes

图5 复杂场景检测结果

根据检测结果可知,在简单场景下,本文模型检测精度(置信度)对各类害虫均能够稳定达到70%以上,展现了模型在简单环境中的出色能力和稳定性。在复杂场景中,尽管该模型在部分害虫种类的检测结果上出现了略微的精度下降,但某些害虫种类在相对复杂的环境下反而取得了置信度的提升,达到了80%以上的优秀水平,表明本文模型在不同环境下的适应性良好,仍能达到令人满意的检测性能。综合来看,本文模型在多种实际应用场景下的检测结果展现出其卓越的检测能力,充分证明了其在多场景实验中的有效性和可靠性。

通过对多样化场景的全面测试可知,本文模型的鲁棒性得到了进一步验证。实验不仅涵盖了典型的农业害虫检测环境,还特意引入了不同光照、遮挡和背景复杂度的变量,以严谨的方式模拟实际应用中的多重复杂情况。这种针对模型适应性的系统性评估方法,使得实验更加全面,且能够有效揭示模型在复杂多变环境中的潜在弱点和优势。这种创新性的实验设计为模型鲁棒性的科学评估提供了坚实的数据支持,同时也进一步提升了实验结果的普适性和可信度,为未来农业害虫检测系统的优化和推广提供了重要的理论依据。

## 4 结语

本文选取农业环境中的蛴螬、蝼蛄、蚜虫等8种常见害虫构建数据集,针对基于传统机器学习和神经网络的害

虫识别方法中存在的检测精度差、效率低等问题,提出了一种基于YOLOv8改进的农业害虫识别算法,能够对复杂场景下的害虫图像进行精准识别。首先,通过在YOLOv8模型中引入SPD-Conv模块以代替传统的卷积模块,显著提升了模型在处理低分辨率图像和进行小物体检测方面的能力,这对于实际农业场景下的检测至关重要;其次,引入SA注意力机制,有效提高了模型对害虫目标的关注度,使其在复杂背景中更好地识别出目标,并有效抑制了背景等一般特征的干扰,从而提升了检测准确性;最后,将YOLOv8模型的原损失函数替换为Focal GIoU,通过强调困难样本的学习,提升了模型在目标检测中的表现,特别是在处理难以检测的害虫时能够展现出更强的能力。这些改进共同推动了模型在实际应用中的性能提升,确保了其在农业害虫识别任务中的有效性和可靠性。

本文改进后的模型在mAP@0.5和mAP@0.5-0.95值上分别达到了95.2%、56.7%,效果显著。与原基线YOLOv8n模型相比,尽管该改进模型的参数量和计算量小幅增加,但其mAP@0.5和mAP@0.5-0.95的指标分别提升了1.6%和1.3%。这一提升不仅在确保检测速率的基础上进一步增强了检测精确度,也证明了本文模型在处理复杂数据时的有效性。面对不同场景下的农业环境,本文模型展现出了较高的稳定性和鲁棒性,能够很好地满足实际场景检测需求。这为害虫视觉检测工具性能提升提供了一种有效方法,同时显示出本文模型在真实场景中的应用潜力和应用价值。

## 参考文献:

- [1] YULITA N I, PRABUWONO S A, ARDIANSYAH F, et al. Pest detection in agricultural farms using SqueezeNet and multi-layer perceptron model [J]. International Journal of Advanced Computer Science and Applications (IJACSA), 2024, 15(6): 0150680.
- [2] GUO B, WANG J, GUO M, et al. Overview of pest detection and recognition algorithms [J]. Electronics, 2024, 13(15): 3008.
- [3] ZHANG Y J. Image recognition of agricultural pest based on improved support vector machine [J]. Journal of Chinese Agricultural Mechanization, 2021, 42(2): 146-152.  
张亚军. 基于改进支持向量机算法的农业害虫图像识别研究[J]. 中国农机化学报, 2021, 42(2): 146-152.
- [4] JIANG K. Research and implementation of tomato disease and insect pest detection method based on improved SVM [D]. Shenyang: Shenyang Ligong University, 2023.  
蒋珂. 基于改进型SVM的番茄病虫害检测方法研究与实现[D]. 沈阳: 沈阳理工大学, 2023.
- [5] CUI F, XIAO H, ZHOU C, et al. Stored-grain pests detection based on SVM [C]//Xiamen: The 2019 2nd International Conference on Mathematics, Modeling and Simulation Technologies and Applications, 2019.
- [6] PRAJAKTA T, SANKAR R V. Advanced pest detection strategy using hybrid optimization tuned deep convolutional neural network [J]. Journal of Engineering, Design and Technology, 2024, 22(3): 645-678.
- [7] LIANG W J, CAO H X. Identification of rice insect pests based on CNN

- model[J]. Jiangsu Agricultural Sciences, 2017, 45(20): 241-243, 253.
- 梁万杰,曹宏鑫. 基于卷积神经网络的水稻虫害识别[J]. 江苏农业科学, 2017, 45(20): 241-243, 253.
- [8] CHENG X, WU Y Z, ZHANG Y H, et al. Image recognition of stored grain pests: based on deep convolutional neural network[J]. Chinese Agricultural Science Bulletin, 2018, 34(1): 154-158.
- 程曦,吴云志,张友华,等. 基于深度卷积神经网络的储粮害虫图像识别[J]. 中国农学通报, 2018, 34(1): 154-158.
- [9] CHEN J, CHEN L Y, WANG S S, et al. Pest image recognition of garden based on improved residual network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(5): 187-195.
- 陈娟,陈良勇,王生生,等. 基于改进残差网络的园林害虫图像识别[J]. 农业机械学报, 2019, 50(5): 187-195.
- [10] WANG W Z. Research on rice pests' on-line identification and directional application based on improved Yolov3[D]. Hefei: Anhui Agriculture University, 2020.
- 王文周. 基于改进YOLOv3的水稻害虫在线识别与定向施药的研究[D]. 合肥:安徽农业大学, 2020.
- [11] PENG H X, XU H M, LIU H N. Lightweight agricultural crops pest identification model using improved ShuffleNet V2[J]. Transactions of the Chinese Society of Agricultural Engineering, 2022, 38(11): 161-170.
- 彭红星,徐慧明,刘华鼎. 基于改进ShuffleNet V2的轻量化农作物害虫识别模型[J]. 农业工程学报, 2022, 38(11): 161-170.
- [12] LIANG J, TIAN M, LIU X. Rapid detection of multi-scale cotton pests based on lightweight GBW-YOLOv5 model[J]. Pest Management Science, 2024, 80(6): 2738-2750.
- [13] ZHENG G, JIANG Y S, SHEN Y L. Recognition of rice pests based on improved YOLOv7[J]. Journal of Huazhong Agricultural University, 2023, 42(3): 143-151.
- 郑果,姜玉松,沈永林. 基于改进YOLOv7的水稻害虫识别方法[J]. 华中农业大学学报, 2023, 42(3): 143-151.
- [14] MA P, YANG Z H, WAN H, et al. A new cotton aphid image recognition algorithm and software based on YOLOv8[J]. Journal of Intelligent Agricultural Mechanization, 2023, 4(3): 42-49.
- 马盼,杨子恒,万虎,等. 基于YOLOv8网络的棉蚜图像识别算法及软件系统设计[J]. 智能化农业装备学报(中英文), 2023, 4(3): 42-49.
- [15] WU X, ZHAN C, LAI Y K, et al. IP102: a large-scale benchmark dataset for insect pest recognition[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 8787-8796.
- [16] JOCHER G, CHAURASIA A, QIU J. Ultralytics YOLOv8 (8.0.0) [EB/OL]. <https://docs.ultralytics.com/zh/models/yolov8/>.
- [17] SUNKARA R, LUO T. No more strided convolutions or pooling: a new CNN building block for low-resolution images and small objects[C]//Joint European Conference on Machine Learning And Knowledge Discovery in Databases, 2022: 443-459.
- [18] ZHANG Q L, YANG Y B. SA-NET: shuffle attention for deep convolutional neural networks[C]//ICASSP 2021-2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2021: 2235-2239.
- [19] ZHENG Z, WANG P, REN D, et al. Enhancing geometric factors in model learning and inference for object detection and instance segmentation[J]. IEEE Transactions on Cybernetics, 2021, 52(8): 8574-8586.
- [20] REZATOFIGHI H, TSOI N, GWAK J Y, et al. Generalized intersection over union: a metric and a loss for bounding box regression[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 658-666.
- [21] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]//Proceedings of the IEEE International Conference on Computer Vision, 2017: 2980-2988.

(责任编辑:孙 娟)