



基于多阶特征聚合的小样本虫害检测

曹佩佩, 李贺*, 任保见*

商丘学院计算机工程学院, 河南 商丘 476000

摘要: 在实际农田场景中, 部分虫害因难以采集而导致样本数量稀少, 传统检测方法难以在小样本条件下获得可靠的检测与分类效果。本研究旨在针对小样本虫害检测问题, 提升模型的泛化能力与检测性能。构建了包含 13 类虫害的 AgriPest-13 数据集, 其中包括 11 类常见虫害与 2 类少样本虫害(分别仅含 10 张与 30 张图像)。在此基础上, 提出改进的小样本检测方法 FSD-MOGA (Few-Shot Detection with Multi-Order Gated Aggregation)。该方法以小样本检测模型 MPSR 为基础, 引入多阶门控聚合模块(MOGA)以增强复杂背景下的特征表征能力, 并加入中心损失(Center Loss)以优化分类特征分布。实验表明, FSD-MOGA 在小样本场景下表现优异, 尤其在仅有极少样本的类别中表现更为稳定和准确: 10-shot 实验中 mAP 达到 37.0%, 较基线模型 MPSR 提升 9.4%, AP50、AP75 分别达到 57.8%和 29.9%; 30-shot 实验中 mAP 进一步提升至 44.0%, 较 MPSR 提高 2.6%, AP50、AP75 升至 73.6%和 45.5%。FSD-MOGA 能有效缓解虫害样本稀缺带来的检测困难, 为实际农田场景下的小样本虫害智能检测提供了一种可行且有效的技术方案。

关键词: 小样本检测; 虫害识别; 特征聚合; Center Loss; 智慧农业

1 引言

病虫害严重威胁农作物产量与品质, 其准确识别在农业生产中具有重要现实意义。国家农作物病虫害测报网数据显示, 2025 年小麦、水稻、玉米等作物的病虫害发生面积预计较 2024 年增加约 6.2%, 其中小麦蚜虫、褐飞虱、棉铃虫等害虫的发生强度显著加剧。气候变暖加快害虫繁殖, 对粮食安全构成更加严峻的挑战^[1]。目前多数地区仍广泛采用化学农药防治, 但这种方式存在环境污染与抗药性风险, 且在部分地区因环保或成本限制难以及时部署, 导致减产严重。因此, 通过前期监测与智能识别掌握虫情动态, 是减少农药使用、指导精准防控的关键。

早期的虫害检测主要依赖手工特征与传统分类器(如 SVM、随机森林等), 这些方法在复杂的田间环境中常因特征不足、泛化差、鲁棒性低而难以可靠应用^[2-7]。近年来, 深度学习兴起, 通过端到端特征学习显著提升识别性能^[8]。在农作物病虫害检测领域, 不少研究在目标检测框架下取得了优异成果: 例如, 彭

红星等基于 SSD 的多尺度融合方法在复杂环境下对苹果、荔枝、脐橙、皇帝柑的平均检测精度达 88.4%^[9]; Ge 等在 YOLOv5s 中嵌入 CBAM 注意力机制用于番茄检测, 在花、绿番茄、红番茄上的准确率均达到 93%以上^[10]; 宫妍等基于 YOLOv7 的优化算法, 针对玉米小目标虫害检测的平均精度达到 99.4%^[11]; Teng 等提出了 MSR-RCNN, 通过超分辨率组件、特征融合机制和特征加权机制增强了特征表达能力, 解决了多尺度、高相似农作物虫害的问题^[12]; Qi 等基于 Deformable DETR 模型引进一个挤压激励模块, 在 Pest24 公开数据集上准确度达到 72.5%^[13]; Bai 等基于 DETR 模型进行了轻量化改进, 以适应实时农作物害虫检测任务的需求^[14]; Liu 等提出的 GA-Mask R-CNN 模型有效解决了水稻螟虫和卷叶虫的识别难题^[15]。在小样本学习领域, 已有研究为解决标注数据稀缺问题提供了重要的技术支持: Zhou 等提出的 VLCD 和 VLCD-T 模型基于视觉-语言模型(VLM), 通过聚类筛选代表性病害图像, 并生成细粒度文本提示, 在少样本作物病害分类中展现了优于传统单模态方法的性能^[16]; He

等在 Faster R-CNN 框架下设计了特征聚合模块（FAM），融合支持集与查询集的上下文特征，该方法在 PestDet20 热带害虫数据集中取得了优异的实验结果^[17]。

总体而言，现有研究已通过注意力机制嵌入、轻量化网络设计、数据增强和跨模态融合等策略，在特定场景下的检测中取得了显著进展。然而，这些优化模型仍然存在明显的局限性：大多数模型依赖于充足的标注数据，而针对少样本场景的解决方案往往集中于单一层级或单一模态的特征融合，未能有效捕捉小样本虫害的多尺度特征和细粒度差异；此外，现有的小样本检测方法通常仅专注于特征增强或数据扩充的单一维度，尚未能综合考虑各维度的协同作用。

在实际农田应用中，虫害检测面临更多挑战。首先，虫害种类繁多且部分害虫样本极难采集；其次，某些虫害仅在特定季节或生长阶段出现，导致标注数据极为稀缺。基于这些实际问题，传统的检测方法与标准深度学习模型在少样本条件下的性能往往难以满足需求，且其泛化能力存在较大局限。因此，如何在标注数据极为有限的条件下，尤其是在弱监督或无监督场景下，实现高精度的虫害检测与识别，成为提升农业生产中虫害管理实际应用价值的关键研究方向。

2 材料与方法

2.1 实验框架与配置

研究模型训练与测试在基于 PyTorch 的深度学习框架中进行，且所有的数据增强、模型评估及可视化等过程均在 Python 环境下实现。具体的硬件配置

为：计算机操作系统使用 Linux Ubuntu 20.04，CPU 型号为 Xeon(R) Platinum 8352V，内存为 90GB，GPU 为 1 块 RTX 4090，显存为 24GB。所使用的 CUDA 版本为 11.3，PyTorch 版本为 1.10.0，编程语言为 Python 3.8。

2.2 小样本虫害数据集 AgriPest-13 构建

实际田间场景中，部分虫害因其受季节性原因导致图像数据难以采集。因此，本研究构建了一个小样本虫害数据集 AgriPest-13，旨在更全面地解决农田中的虫害识别问题。结合公开数据集和自采集的虫害图像，构建了一个包含 13 类虫害的综合数据集（表 1，图 1）。该数据集包括了蚜虫、棉铃虫、草蛉、多异瓢虫、绿盲蝽、麦圆蜘蛛、烟盲蝽、褐飞虱、茶翅蝽、黑食蚜盲蝽、牧草盲蝽、苜蓿盲蝽和白背飞虱，共计

表 1 小样本虫害数据集 AgriPest-13 的内容组成
Table 1 Contents of the small-sample pest dataset AgriPest-13

物种	图片(张)	物种	图片(张)
蚜虫	717	褐飞虱	556
Aphid		<i>Nilaparvata lugens</i>	
棉铃虫	533	茶翅蝽	271
<i>Helicoverpa armigera</i>		<i>Halyomorpha halys</i>	
草蛉	369	黑食蚜盲蝽	72
Lacewing		<i>Deraeocoris punctulatus</i>	
多异瓢虫	704	牧草盲蝽	107
<i>Hippodamia variegata</i>		<i>Lygus pratensis</i>	
绿盲蝽	365	苜蓿盲蝽	93
<i>Apolygus lucorum</i>		<i>Adelphocoris lineolatus</i>	
麦圆蜘蛛	425	白背飞虱	190
<i>Penthaleus major</i>		<i>Sogatella furcifera</i>	
烟盲蝽	175		
<i>Nesidiocoris tenuis</i>			



图 1 AgriPest-13 数据集图片示例

Fig. 1 Construction of the AgriPest-13 dataset

4 577 张图像,并通过 EasyDL 平台生成了 29 625 个标注文件,数据格式为 COCO。此外,还将多异瓢虫和草蛉划分为新类,分别包含 10 张和 30 张图像及相应的标注文件。

2.3 多阶特征聚合小样本检测整体模型结构

本研究提出的 FSD-MOGA 模型整体结构包括特征提取、多尺度特征融合、候选区域生成以及检测头优化四个部分,模型结构如图 2 所示。首先,输入图像通过 ResNet101 backbone 提取多层特征,生成不同尺度的特征图(C2-C5),其中特征图的尺寸逐层减半,通道数逐层增加(从 256 到 2 048)。然后将这些特征送入 FPN(特征金字塔网络),将不同层级的特征整合成统一通道数的多尺度特征图(P2-P5)。然后通过 RPN(区域建议网络)在这些特征图上生成候选

框,通过 ROI Align 层,将不同大小的区域特征统一采样为固定大小的特征图。在检测头部分,FSD-MOGA 模型采用了一种双分支结构,分别用于分类和回归任务。特征首先经过 Multi-Order Gated Aggregation (MOGA)模块进行优化,该模块通过多阶特征聚合增强了特征的表达能力。随后,通过全局平均池化对特征进行降维。处理后的特征同时送入分类分支和回归分支,分类分支通过全连接层预测类别概率,回归分支通过类似的全连接层结构精细调整边界框位置。在训练过程中,分类分支输出的特征向量不仅用于计算分类损失,同时被用于计算 Center Loss,通过最小化同类特征与其类中心的距离来增强特征的判别性。最终,模型输出检测到的边界框坐标、类别标签和置信度分数。




图 2 FSD-MOGA 模型整体结构图

Fig. 2 Overall architecture of the FSD-MOGA model

MPSR (Multi-scale Positive Sample Refinement) 通过生成多尺度的正样本作为目标金字塔,并在不同尺度上优化预测结果,如图 3 所示。首先将输入图像通过主干网络提取特征,后续在 RPN 生成候选区域提议,同时,目标金字塔通过调整目标的尺度生成。这些金字塔图像输入到 MPSR 分支,并与主检测分支并行工作。通过 RoIAlign 提取 RoI,并通过检测头进行分类与边界框回归。最后,通过损失函数计算,优化模型。

在特征处理阶段引入 Multi-Order Gated Aggregation (MOGA)模块,对输入特征进行多阶特征聚合。MOGA 模块包含三条具有不同复杂度的特征处理路径,分别对应一阶(1st order)、二阶(2nd order)和三阶(3rd order)语义表达。这些路径分别提取不同感受野和语义层次的信息,最终通过门控机制实现自适应融合,从而生成表达更丰富的增强特征。

此外,在损失函数阶段引入了 Center Loss 模块,用于提升特征的类内聚合性和类间可分性。如图 4

所示, 该模块为每一个类别维护一个可学习的类别中心向量矩阵, 在训练过程中动态更新。通过最小化样本特征与其对应类别中心之间的欧氏距离,

Center Loss 能有效约束特征分布, 增强同类样本的聚集性, 并间接拉远不同类别之间的距离, 从而提升特征的判别能力。




图3 MPSR 流程结构图

Fig. 3 MPSR Workflow diagram




图4 Center Loss 实现过程

Fig. 4 Implementation process of Center Loss

2.4 评价指标

为了评估目标检测模型的有效性, 评价指标是重要依据。其主要的任务评估包括单个框的重叠情况和整体的性能评估。针对单框层面来说 Intersection over Union (IoU)是评估单个预测框与真实框重叠程度的指标, 而对于整体的性能来说平均精度 (AP , Average Precision) 是核心评估指标。

IoU 的计算如式 (1) 所示:

$$IoU = \frac{\text{Intersection Area}}{\text{Union Area}} \quad (1)$$

式中, Intersection Area 代表交集面积指预测框和真实框重叠部分的面积。Union Area 代表并集面积指预测框和真实框的总面积减去交集部分的面积。IoU 代表真实框与预测框的一个匹配度, 通常认为 $IoU \geq 0.5$ 表示预测准确, 否则认为是误检。

平均精度 (AP , Average Precision) 的计算是基于

IoU、Precision（精确率）和 Recall（召回率）来衡量模型的检测能力。计算公式如下：

$$Precision=\frac{True\ Positives(TP)}{True\ Positives(TP)+False\ Positives(FP)}$$

(2)

$$Recall=\frac{True\ Positives(TP)}{True\ Positives(TP)+False\ Negatives(FN)}$$

(3)

$$AP=\int_0^1 P(R)dR$$

(4)

其中，True Positive(TP)表示真阳性，预测为目标类别，实际为该类别的正确预测数。False Positive(FP)表示假阳性，预测为目标类别，但实际不属于该类别的错误预测数。False Negative(FN)表示假阴性，实际属于目标类别，但未能检测到的数量。其中 $P(R)$ 表示在不同 Recall 值下的 Precision。 AP_{50} 是指在 $IoU=0.5$ 时的平均精度； AP_{75} 是指在 $IoU=0.75$ 时的平均精度； AP_S 、 AP_M 、 AP_L 分别是针对小目标、中目标和大目标的平均精度。通过这种多维的 AP 评估结果能够更直观的去观察模型针对不同情况的优势，为模型优化提供了依据。

3 结果

3.1 与主流模型对比结果

为验证 FSD-MOGA 模型在小样本虫害检测任务中的性能，本文在 AgriPest-13 数据集上设置 10-shot 与 30-shot 两种实验方案，并与 Faster R-CNN^[18]、YOLOv3^[19]、DINO^[20]、Meta R-CNN^[21]、FSDetView^[22]以及 MPSR^[23]等模型进行了对比。评价指标包括 AP 、 AP_{50} 、 AP_{75} 以及不同目标尺度下的检测性能指标 AP_S 、 AP_M 和 AP_L ，实验结果如表 2 所示。

在 10-shot 实验中，FSD-MOGA 模型取得了 37.0% 的 AP 值， AP_{50} 和 AP_{75} 分别达到 57.8%和 29.9%。相比于其他对比模型，FSD-MOGA 在整体检测性能上表现最优。其中，MPSR 模型的 AP 值为 27.6%，而 FSD-MOGA 在此基础上提升至 37.0%。同时，在大目标检测指标 AP_L 上，FSD-MOGA 达到了 39.9%，表现出较好的目标表征能力。

在 30-shot 实验中，随着样本数量增加，各模型性能均有所提升。其中，FSD-MOGA 模型取得 44.0%的 AP 值， AP_{50} 和 AP_{75} 分别达到 73.6%和 45.5%。相比 MPSR 模型， AP 提升至 44.0%， AP_L 指标达到 44.0%。

表 2 10-shot 和 30-shot 下两类新型虫害的检测性能对比(%)

Table 2 Comparison of detection performance (%) for two novel pest categories under 10-shot and 30-shot settings

Shot	Baseline	AP	AP_{50}	AP_{75}	AP_S	AP_M	AP_L
10	Faster R-CNN	0	0	0	-	0	0
	YOLOv3	8.1	22.7	4.7	-	16.9	8.6
	DINO	18.9	34.0	15.7	-	1.4	21.5
	Meta R-CNN	15.1	36.6	9.3	-	3.3	15.7
	FSDetView	9.3	24.4	4.5	-	1.3	10.2
	MPSR	27.6	53.3	24.2	-	27.0	27.9
	FSD-MOGA	37.0	57.8	29.9	-	26.4	39.9
30	Faster R-CNN	0.9	5.6	0.1	-	0	1.0
	YOLOv3	6.7	20.8	3.3	-	8.2	7.1
	DINO	8.0	18.0	6.4	-	32.8	8.2
	Meta R-CNN	19.7	47.8	13.2	-	45.0	34.0
	FSDetView	29.2	58.0	27.1	-	4.0	31.3
	MPSR	41.4	70.2	41.0	-	61.5	41.5
	FSD-MOGA	44.0	73.6	45.5	-	75.2	44.0

此外，在 APM 指标上，FSD-MOGA 取得 75.2% 的检测结果，表明模型在中等尺度目标检测中具有较好的稳定性。

综合 10-shot 与 30-shot 实验结果可以看出，FSD-MOGA 在不同样本规模条件下均保持较好的检测性能，能够有效提升少样本虫害目标的检测精度。

3.2 消融实验结果

表为验证 Center Loss 与 MOGA 模块对模型性能的影响，在 AgriPest-13 数据集上进行了消融实验，实验结果如表 3 所示。

在 10-shot 实验中，基线模型 MPSR 的 AP 值为 27.6%。当仅引入 Center Loss 模块后，AP 提升至 28.9%，AP₇₅ 提升至 26.5%。当仅引入 MOGA 模块

后，AP 提升至 29.2%，AP₇₅ 达到 26.9%。同时引入 Center Loss 与 MOGA 模块后，模型性能进一步提升，AP 达到 37.0%，AP₅₀ 和 AP₇₅ 分别达到 57.8% 和 29.9%。

在 30-shot 实验中，基线模型 MPSR 的 AP 值为 41.4%。加入 Center Loss 模块后，AP 提升至 42.7%；加入 MOGA 模块后，AP 提升至 42.9%。当两个模块共同作用时，模型性能达到最佳，AP 提升至 44.0%，AP₅₀ 和 AP₇₅ 分别达到 73.6% 和 45.5%。同时，在 AP_M 和 AP_L 指标上也取得了更优结果。

实验结果表明，Center Loss 与 MOGA 模块均能够提升模型的小样本检测性能，二者结合后能够进一步增强模型的特征表达能力与检测效果。

表 3 FSD-MOGA 模型在 10-shot 和 30-shot 设置下的消融实验结果 (%)

Table 3 Ablation study results (%) of the FSD-MOGA model under 10-shot and 30-shot settings

Shot	MPSR		AP	AP ₅₀	AP ₇₅	AP _s	AP _M	AP _L
	Center Loss	MOGA						
10			27.6	53.3	24.2	-	27.0	27.9
	+		28.9	53.9	26.5	-	23.8	29.8
		+	29.2	54.7	26.9	-	40.6	29.5
	+	+	37.0	57.8	29.9	-	26.4	39.9
30			41.4	70.2	41.0	-	61.5	41.5
	+		42.7	73.1	41.1	-	72.8	42.7
		+	42.9	71.9	43.6	-	72.8	42.9
	+	+	44.0	73.6	45.5	-	75.2	44.0

3.3 可视化分析

为验证 FSD-MOGA 模型在虫害目标检测中的表现，对模型检测结果进行了可视化分析。

如图 5 所示，第一行为虫害（依次为棉铃虫、褐飞虱、茶翅蝽、黑食蚜盲蝽和多异瓢虫）原始图像，第 1 至第 4 列为基类目标图像，第 5 列为新类目标图像；第 2 至第 7 行分别为主干网络(backbone)的可视化输出。明显看出，在棉铃虫（第 1 列）与茶翅蝽（第 3 列）检测中，FSD-MOGA 模型能够提取更加完整的目标轮廓信息；在褐飞虱（第 2 列）与黑食蚜盲蝽（第 4 列）检测中，模型对背景区域的抑制效果更加明显；在多异瓢虫（第 5 列）检测中，模型能够准确聚焦于虫害区域，实

现有效检测。由此认为 FSD-MOGA 模型比 MPSR 能更加完整地关注虫害目标区域，并有效减少背景区域的响应，得到的目标信息更全面，检测结果更精确。

为进一步验证各模块对模型性能提升的具体贡献，针对新类目标（草蛉和多异瓢虫）的检测效果进行了模块化可视化分析，展示不同模块在细化目标特征、改善检测性能方面的作用。

如图 6 所示，引入 MOGA 模块后，模型对目标区域的响应增强；引入 Center Loss 后，背景噪声干扰有所减少。当同时引入两种模块后，模型能够进一步提升目标区域的关注能力，并减少误检与漏检现象。




图 5 FSD-MOGA 与 MPSR 在虫害检测中的可视化结果对比
Fig. 5 Visual comparison of pest detection results between FSD-MOGA and MPSR




图 6 FSD-MOGA 在新类目标检测中的消融实验可视化对比
Fig. 6 Visualization comparison of ablation experiments for FSD-MOGA in novel-class object detection

4 讨论

本研究针对农业场景中虫害样本难以获取、类别分布不均衡等问题，对小样本虫害检测模型进行了优化。实验结果表明，FSD-MOGA 在 10-shot 与 30-shot 条件下均取得了优于传统方法的检测效果，说明所提出方法能够有效提升小样本条件下的目标检测性能。

与传统双阶段检测模型相比，FSD-MOGA 在复杂农业背景中的目标表征能力更强。传统模型在小样本条件下容易出现目标特征不足、背景干扰严重等问题，而本研究通过引入 MOGA 模块，实现了多阶特征的自适应融合，使模型能够同时关注局部细节信息与全局语义信息，从而增强了对虫害目标的特征表达能力。尤其是在虫害与背景颜色、纹理相近的情况下，模型仍能够保持较好的检测效果。

此外，Center Loss 的引入进一步增强了特征空间中的类内紧凑性，使模型在新类迁移过程中能够学习更加稳定的类别中心分布。实验结果显示，Center Loss 对于减少背景误检具有积极作用，尤其在复杂背景与多目标场景下，模型的鲁棒性得到明显提升。

通过可视化结果可以发现，FSD-MOGA 相比基线模型能够更加准确地聚焦于虫害区域，同时减少背景区域的响应。这表明多模块协同优化能够有效改善小样本检测过程中存在的目标信息不足问题，提高模型的泛化能力。

尽管本文方法取得了较好的实验结果，但仍存在一定局限性。首先，当前实验仅在 AgriPest-13 数据集上进行验证，数据规模相对有限，模型在更大规模、多场景农业数据集上的泛化能力仍需进一步研究。其次，本研究主要针对静态图像进行虫害检测，对于复杂环境下的实时视频检测任务尚未展开深入研究。此外，模型在极小目标与严重遮挡场景中的检测性能仍有进一步提升空间。

未来研究可从以下几个方面展开：一是扩展更多农业场景数据集，提升模型跨场景泛化能力；二是结合轻量化网络结构与边缘部署技术，实现无人机与智能终端上的实时检测；三是进一步融合 Transformer、自监督学习等方法，提高模型在复杂场景中的特征建模能力，为农业病虫害智能监测提供更加高效的技术方案。

5 结论

针对农业虫害样本获取困难以及小样本条件下检测性能不足的问题而构建的 AgriPest-13 小样本虫害

数据集，以及在此基础上提出的基于 MPSR 改进的 FSD-MOGA 模型，通过引入 MOGA 模块与 Center Loss，增强了模型的多尺度特征融合能力与特征判别能力，提升了小样本虫害检测性能。该模型在本实验条件下在小样本虫害检测任务中表现出较好的检测精度与鲁棒性，为农业场景中的智能虫害监测提供了一种有效方案。未来，可进一步结合轻量化部署、自监督学习以及多模态信息融合等方法，提升模型在复杂农业环境中的实时检测能力与泛化性能，并扩展至无人机巡检、智能植保等实际应用场景，为精准农业发展提供技术支持。

参考文献

- [1] Strange R N, Scott P R. Plant disease: a threat to global food security. *Annual Review of Phytopathology*, 2005, 43: 83-116.
- [2] Ahmed S, Marwat S N K, Brahim G B, et al. IoT based intelligent pest management system for precision agriculture. *Scientific Reports*, 2024, 14(1): 31917.
- [3] Weeks P J D, O'Neill M A, Gaston K J, et al. Automating insect identification: exploring the limitations of a prototype system. *Journal of Applied Entomology*, 1999, 123(1): 1-8.
- [4] Gaston K J, O'Neill M A. Automated species identification: why not?. *Philosophical Transactions of the Royal Society of London. Series B, Biological Sciences*, 2004, 359(1444): 655-667.
- [5] Hayashi M, Tamai K, Owashi Y, et al. Automated machine learning for identification of pest aphid species (Hemiptera: Aphididae). *Applied Entomology and Zoology*, 2019, 54(4): 487-490.
- [6] Li W, Zheng T, Yang Z, et al. Classification and detection of insects from field images using deep learning for smart pest management: A systematic review. *Ecological Informatics*, 2021, 66: 101460.
- [7] Li W, Wang D, Li M, et al. Field detection of tiny pests from sticky trap images using deep learning in agricultural greenhouse. *Computers and Electronics in Agriculture*, 2021, 183: 106048.
- [8] Preti M, Verheggen F, Angeli S. Insect pest monitoring with camera-equipped traps: strengths and limitations. *Journal of Pest Science*, 2021, 94(2): 203-217.
- [9] 彭红星, 黄博, 邵园园, 等. 自然环境下多类水果采摘目标识别的通用改进 SSD 模型. *农业工程学报*, 2018, 34(16): 155-162.
- Peng H X, Huang B, Shao Y Y, et al. General improved SSD model for picking object recognition of multiple fruits in natural environment. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2018, 34(16): 155-162.

- [10] Ge Y, Lin S, Zhang Y, et al. Tracking and counting of tomato at different growth period using an improving YOLO-deepsort network for inspection robot. *Machines*, 2022, 10(6): 489.
- [11] 宫妍,翟俊杰,王凯,等. 基于改进 YOLOv7 的玉米作物害虫检测研究. *计算机测量与控制*, 2024, 32(9): 58-65.
- Gong Y, Zhai J J, Wang K, et al. Study on corn crop pest detection based on improved YOLOv7. *Computer Measurement & Control*, 2024, 32(9): 58-65.
- [12] Teng Y, Zhang J, Dong S F, et al. MSR-RCNN: a multi-class crop pest detection network based on a multi-scale super-resolution feature enhancement module. *Frontiers in Plant Science*, 2022, 13: 810546.
- [13] Qi F, Chen G M, Liu J Y, et al. End-to-end pest detection on an improved deformable DETR with multihead criss cross attention. *Ecological Informatics*, 2022, 72: 101902.
- [14] Bai Y Z, Hou F J, Fan X Y, et al. A lightweight pest detection model for drones based on transformer and super-resolution sampling techniques. *Agriculture*, 2023, 13(9): 1812.
- [15] Liu S T, Fu S H, Hu A R, et al. Research on insect pest identification in rice canopy based on GA-mask R-CNN. *Agronomy*, 2023, 13(8): 2155.
- [16] Zhou Y, Yan H, Ding K, et al. Few-shot image classification of crop diseases based on vision-language models. *Sensors (Basel)*, 2024, 24(18): 6109.
- [17] He S, Jin B, Sun X, et al. Few-shot object detection for pest insects via features aggregation and contrastive learning. *Frontiers in Plant Science*, 2025, 16: 1522510. DOI: 10.3389/fpls.2025.1522510
- [18] 李开敬,许燕,周建平,等. 基于 Faster R-CNN 和数据增强的棉田苗期杂草识别方法. *新疆大学学报(自然科学版)(中英文)*, 2021, 38(4): 450-456.
- Li K J, Xu Y, Zhou J P, et al. Cotton field seedling weed identification method based on faster R-CNN and data enhancement. *Journal of Xinjiang University (Natural Science Edition in Chinese and English)*, 2021, 38(4): 450-456.
- [19] Redmon J, Farhadi A. YOLOv3: An Incremental Improvement [PP/OL]. 2018, arXiv.1804.02767.
- [20] Zhang H, Li F, Liu S L, et al. DINO: DETR With improved DeNoising anchor boxes for end-to-end object detection[PP/OL]. 2022, arXiv./2203.03605.
- [21] Huisman M, Van Rijn J N, Plaat A. A survey of deep Meta-learning. *Artificial Intelligence Review*, 2021, 54(6): 4483-4541.
- [22] Köhler M, Eisenbach M, Gross H M. Few-shot object detection: a comprehensive survey. *IEEE Transactions on Neural Networks and Learning Systems*, 2024, 35(9): 11958-11978.
- [23] Wu J X, Liu S T, Huang D, et al. Multi-scale positive sample refinement for few-shot object detection[C]//Computer Vision – ECCV 2020. Cham: Springer, 2020: 456-472.

引用本文: 曹佩佩,李贺,任保见. 基于多阶特征聚合的小样本虫害检测[J]. *农业大数据学报*, 2026,8(3): 296-304. DOI: 10.19788/j.issn.2096-6369.000141.

CITE: CAO PeiPei, LI He, REN BaoJian. Few-Shot Pest Detection via Multi-Order Feature Aggregation[J]. *Journal of Agricultural Big Data*, 2026,8(3): 296-304. DOI: 10.19788/j.issn.2096-6369.000141.

Few-Shot Pest Detection via Multi-Order Feature Aggregation

CAO PeiPei, LI He*, REN BaoJian*

ShangQiu University, College of Computer Engineering, Shangqiu 476000, Henan, China

Abstract: In real farmland scenarios, some pest species are difficult to collect, resulting in very limited sample sizes. Traditional detection methods struggle to achieve reliable detection and classification performance under such few-shot conditions. This study aims to address the problem of few-shot pest detection by improving the model's generalization ability and detection performance. A dataset named AgriPest-13 containing 13 pest categories was constructed, including 11 common pest species and 2 few-shot pests with only 10 and 30 images respectively. Based on this dataset, an improved few-shot detection method, FSD-MOGA (Few-Shot Detection with Multi-Order Gated Aggregation), is proposed. The method is developed upon the classic few-shot detection model MPSR, integrating a Multi-Order Gated Aggregation (MOGA) module to enhance feature representation under complex backgrounds and incorporating Center Loss to optimize the distribution of classification features. Compared with the original MPSR model, FSD-MOGA achieves significant performance improvements in few-shot pest detection tasks, particularly demonstrating more stable and accurate detection for categories with extremely limited samples. FSD-MOGA effectively alleviates the detection challenges caused by scarce pest samples and provides a feasible and efficient solution for intelligent pest detection in real agricultural environments with limited data.

Keywords: few-shot detection; pest recognition; feature aggregation; Center Loss; smart agriculture