



基于TPH-YOLOv5和小样本学习的害虫识别方法

朱香元, 聂轰, 周旭

引用本文

朱香元, 聂轰, 周旭. 基于TPH-YOLOv5和小样本学习的害虫识别方法[J]. 计算机科学, 2022, 49(12): 257-263.

ZHU Xiang-yuan, NIE Hong, ZHOU Xu. Pest Identification Method Based on TPH-YOLOv5 Algorithm and Small Sample Learning [J]. Computer Science, 2022, 49(12): 257-263.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

基于改进Sigmoid卷积神经网络的手写体数字识别

Handwritten Numeral Recognition Based on Improved Sigmoid Convolutional Neural Network
计算机科学, 2022, 49(12): 244-249. <https://doi.org/10.11896/jsjkx.211000179>

基于反事实思考的视觉问答方法

Visual Question Answering Method Based on Counterfactual Thinking

计算机科学, 2022, 49(12): 229-235. <https://doi.org/10.11896/jsjkx.220600038>

深度学习方法在二维人体姿态估计的研究进展

Research Progress of Deep Learning Methods in Two-dimensional Human Pose Estimation

计算机科学, 2022, 49(12): 219-228. <https://doi.org/10.11896/jsjkx.210900041>

面向深度卷积神经网络的小目标检测算法综述

Small Object Detection Based on Deep Convolutional Neural Networks:A Review

计算机科学, 2022, 49(12): 205-218. <https://doi.org/10.11896/jsjkx.220500260>

用于协同过滤的序列解耦变分自编码器

Disentangled Sequential Variational Autoencoder for Collaborative Filtering

计算机科学, 2022, 49(12): 163-169. <https://doi.org/10.11896/jsjkx.211200080>

基于 TPH-YOLOv5 和小样本学习的害虫识别方法

朱香元¹ 聂 轩¹ 周 旭²

1 肇庆学院计算机科学与软件学院 广东 肇庆 526061

2 湖南大学信息科学与工程学院 长沙 410082

(zxyes@zqu.edu.cn)

摘要 深度卷积目标检测算法可自动识别农田害虫，实现对害虫的监测和预警，确保农业稳产、增产，在智慧农业中有着重要的应用。针对小目标害虫漏检率高和小样本害虫识别精度低的问题，首先，设计有针对性的小目标和小样本害虫数据增强方法，采用复制粘贴、裁剪、过采样等技术，保证样本规模及位置多样性特性，进而提升其对训练损失的贡献度；其次，构建基于微调的二阶段小样本学习策略，兼顾分阶段学习基类和新类害虫特征，确保在识别新类害虫的同时，不降低基类害虫的识别能力，以满足不断更新害虫数据的实际农业应用场景需求；最后，引入 TPH-YOLOv5 作为害虫识别算法。在 28 类害虫图像数据集上进行实验，结果表明，所提方法具有较高的学习效率和识别正确率，其精度、召回率、平均精度均值分别为 87.6%，84.9% 和 85.7%。

关键词：深度学习；害虫识别；注意力机制；小样本学习；TPH-YOLOv5；数据增强

中图法分类号 TP391

Pest Identification Method Based on TPH-YOLOv5 Algorithm and Small Sample Learning

ZHU Xiang-yuan¹, NIE Hong¹ and ZHOU Xu²

1 School of Computer Science and Software, Zhaoqing University, Zhaoqing, Guangdong 526061, China

2 College of Information Science and Engineering, Hunan University, Changsha 410082, China

Abstract Pest identification-based deep convolutional object detection is an important application of smart agriculture, which performs pest monitoring and ensures stable agricultural production. To solve the problems of high missed detection rate of small pests and low precision of small samples, a pest identification method based on the TPH-YOLOv5 algorithm and small sample learning is proposed. First, data augmentation for small objects and small samples is designed. Through copy and pasting, cropping, and oversampling, the number of training samples increases and the pest locations are diversified, which improves the contribution to training loss. Second, a two-stage small sample learning strategy based on fine-tuning is constructed. By learning the characteristics of basic and new categories of pests in different stages, the recognition precision of basic categories will not decrease while identifying new pests, which is suitable for the actual agricultural application of continuously collecting pest data. Finally, TPH-YOLOv5 is introduced as the pest identification algorithm. Rigorous tests are conducted on the 28 categories of pest images. The results show that the proposed method achieves high learning efficiency and recognition accuracy, with precision, recall, and mean average precision(mAP) of 87.6%, 84.9% and 85.7%, respectively.

Keywords Deep learning, Pest identification, Attention mechanism, Small sample learning, TPH-YOLOv5, Data augmentation

1 引言

病虫害是影响农作物产量的主要因素^[1]。在农业管理过程中，需要收集有害生物信息进行虫情分析，加强病虫害的监测与预报管理，确保农业稳产增产和重要农产品的有效供给。然而，由于农田害虫的多样性和信息类型的复杂性，通过人工

观察、统计的传统害虫监测方式已经难以满足现代大规模农业生产对虫害预防工作的需求。

害虫识别是以自然环境下拍摄或虫情测报灯等虫情信息智能设备采集的害虫图像为研究对象，通过目标检测算法自动实现害虫的精准识别和定位。利用计算机视觉和深度学习的方法进行害虫识别能有效实现害虫的自动分类与预测，在

到稿日期：2022-10-25 返修日期：2022-11-27

基金项目：广东省普通高校重点领域专项(新一代信息技术)(2021ZDZX1028)；中国高校产学研创新基金“新一代信息技术创新项目”(2021ITA02027)

This work was supported by the Special Projects in for Key Fields of Ordinary Colleges and Universities in Guangdong Province(New Generation Information Technology) (2021ZDZX1028) and “New Generation Information Technology Innovation Project” of the Industry-University-Research Innovation Fund for China University(2021ITA02027).

通信作者：周旭(zhxu@hnu.edu.cn)

智慧农业^[2]中有着重要的应用。相比传统机器学习害虫识别方法的精度完全依赖于手工提取的害虫的几何、颜色、纹理、形态等特征,深度学习害虫识别方法能自动提取害虫的复杂、高维特征,具有较强的特征表达和抽象能力,识别精度和效率更高^[3]。

目前,国内外学者已广泛开展基于深度卷积目标检测算法的农田害虫识别研究。根据害虫图像获取来源方式的不同,该项研究可分为两类。

一类是针对虫情测报灯等智能设备采集的害虫图像识别。文献[4]将通道注意力机制与卷积神经网络相融合,实现了16类害虫图像识别,平均精度均值(mean Average Precision, mAP)达75.46%。文献[5]提出了基于无锚框的AFRCNN害虫识别方法,用于识别24类害虫,其mAP和召回率分别为56.4%和85.1%。文献[6]提出了基于YOLOv5的水稻害虫识别方法,用于识别虫情测报灯等3种监测设备拍摄的两类水稻害虫,其mAP和召回率分别为92.53%和98.39%。

另一类是针对自然环境下采集的害虫图像识别。文献[7]提出了一种基于图像融合的害虫图像增强方法,能提高稻飞虱、麦蜘蛛等4类害虫的识别精度。文献[8]提出了一种基于Coarse-to-Fine网络的害虫识别方法,设计了粗、细、全局3个检测网络来完成害虫识别,其mAP为76.8%。文献[9]将害虫上下文信息应用于卷积神经网络,设计了融合图像视觉特征和上下文先验信息的病虫害图像识别模型。文献[10]提出了一种基于混合全局与局部特征的害虫检测方法,在16类害虫上获得了75.03%的mAP。文献[11]设计了一种基于空间和通道注意力机制的害虫目标检测模型,获得了96.5%的识别准确率。

鉴于农业领域的特殊性以及各类害虫生活习性各异,图像采集难度较大,农业害虫领域公开的图像数据集非常稀少。2020年,南开大学和英国卡迪夫大学的研究人员提出了IP102数据集^[12]。该数据集包含75 222张害虫图片,涵盖102个害虫种类,其中约19 000幅图像用于害虫目标检测,是迄今为止自然环境下采集的最大的农业害虫开源图像数据集。公开害虫图像数据集^[13-14]的建立,有力推动了害虫识别的研究。

与自然场景下采集的害虫图像识别相比,虫情测报灯等智能设备采集的害虫图像识别更具挑战性。首先,形态差异大。害虫已被杀死、烘干,其颜色多呈黑色或黑褐色,有些害虫甚至形体不全,由于拍摄角度固定,与害虫活体形态差异较大。如图1所示,图1(a)—图1(c)为虫情测报灯采集的害虫图像示例,图1(d)—图1(f)为自然环境下拍摄的害虫图像示例。其次,背景复杂。由于虫情测报灯是利用昆虫的趋光性诱集昆虫,除了捕获到害虫以外,还诱集了很多细小的昆虫。大量昆虫聚集,密度高又相互遮挡,进而形成了复杂的干扰背景,如图1(g)所示。最后,目前尚未建立公开的虫情测报灯等智能设备采集的害虫图像数据集。虽然已有少量研究成果发表,但其图像均来源于实验室范围内采集的图像,数据量较少。

为了应对上述挑战,本文提出了一种基于TPH-YOLOv5和小样本学习的害虫识别方法,尝试从较少数量的害虫样本数据中学习得到害虫识别方法,本文的主要创新点总结如下:

(1)设计了有针对性的小目标和小样本害虫数据增强方法,使模型更加关注小目标和小样本害虫,通过提升其对训练损失的贡献度,带来了识别精度和泛化能力的提升。

(2)构建了基于微调的二阶段小样本学习策略,通过分阶段学习基类和新类害虫特征,有效地完成了小样本害虫识别任务,特别适用于虫情测报灯等智能设备不断采集害虫数据的实际农业应用场景。



图1 害虫图像示例

Fig. 1 Examples of pest images

2 数据集与数据探索

本文的害虫图像数据集为虫情测报灯拍摄的776张害虫图片,分辨率为 $5\ 475 \times 3\ 684$,涵盖28类,共1 673只害虫。

害虫样本标签分布如图2所示,数量最多的是八点灰灯蛾,共342只;最少的是豆野螟,仅有2只;瓜绢野螟等8类样本数量少于10只,稻纵卷叶螟等4类害虫样本数量在10~20之间,害虫样本在数十个量级的高达23类,占样本总类别的82%。与大多数实际应用场景的数据分布相似,本文的数据整体呈现自然的长尾分布,类别间样本数量不均衡,为典型的小样本数据^[15-16]。

害虫标签宽高分布如图3所示,计算所有害虫标签与整幅图像的面积比,其平均值为1.07%。在1 673只害虫中,有330只面积比小于0.12%,主要为白背飞虱等3类害虫,占样本总量的19.72%;有533只面积比小于1%,主要为大螟等10类害虫,占样本总量的31.86%。依据国际光学工程学会将面积比低于0.12%的数据定义为小目标^[17]可知,本文的研究对象主要为中小目标数据。

通过数据探索发现,本文的样本数据极其稀缺。为实现标注有限的小样本数据集上构建害虫识别方法,一方面,可以通过数据增强方法扩充原有数据量,避免小样本数据带来的识别模型过拟合问题;另一方面,可以构建二阶段害虫学习策略,将模型微调与数据增强相结合,引入注意力机制来关注小目标和小类别害虫检测,确保识别模型能快速学习样本,提

高泛化能力。

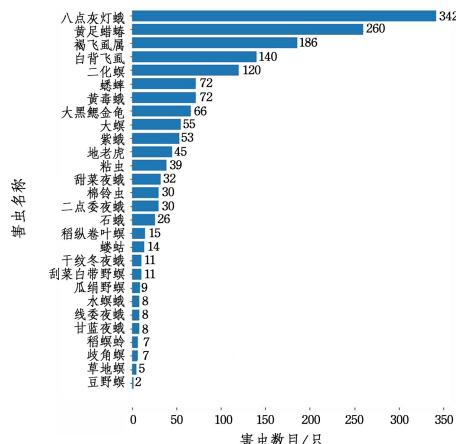


图2 害虫类别标签分布

Fig. 2 Number of pests of each category

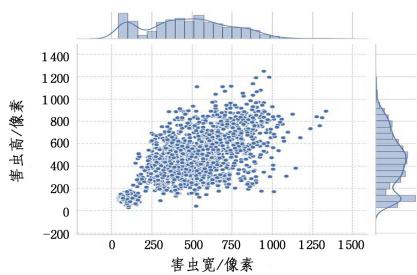


图3 害虫标签宽高分布

Fig. 3 Width and height distribution of pests

3 本文方法

本文方法主要包含数据预处理、基于微调的二阶段小样本学习策略、目标检测模型、实时害虫预测等部分，整体流程如图4所示。

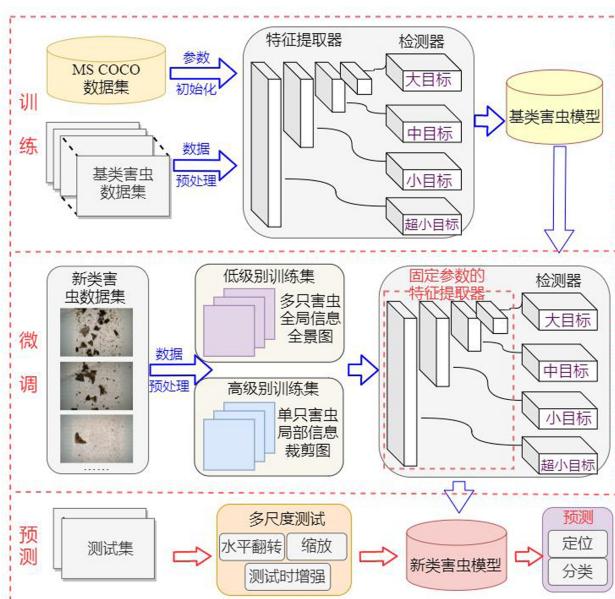


图4 本文方法的整体流程

Fig. 4 Overall framework of the proposed method

3.1 数据预处理

针对人工标注害虫数据不足的问题，分别设计了小目标

害虫数据增强、小样本害虫数据增强，以及其他害虫数据增强方法，通过过采样、复制粘贴、裁剪、图像插值、在线数据增强等方法进行数据预处理，以期实现从原始数据集中获取更多的训练数据。数据预处理流程如图5所示。

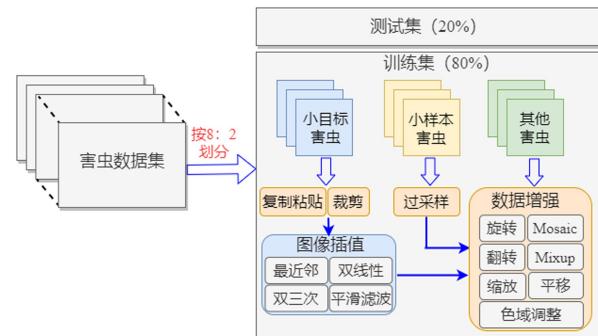


图5 数据预处理流程

Fig. 5 Procedure of data preprocessing

3.1.1 小目标数据增强

由于数据集中存在小目标样本少、所覆盖的整张图片的面积小、位置缺乏多样性等问题，使得目标检测模型往往更加关注中等目标和大目标，即使小目标清晰可见，依然比中等目标和大目标具有更高的漏检率^[14]。因此，针对面积比小于1%的害虫进行有针对性的数据增强，通过复制粘贴、裁剪、图像插值，既能增加小目标样本数量，加强小目标害虫的位置变化，又能提高图像分辨率，从而提升模型对小目标特征的学习能力。

在本实验中，首先，从数据集中选取14张图片作为背景模板；然后，以0.5的概率选择小目标害虫，通过平滑滤波等方式进行图像插值；最后，以位置随机的方式粘贴在背景模板上，生成新的害虫样本。粘贴时，不与模板中的已有害虫重叠，且至少与图片边界相距5个像素点。背景模板和复制粘贴后的新样本示例如图6所示。



(a) 原始图片

(b) 复制粘贴8个微小害虫

图6 复制粘贴数据增强示例

Fig. 6 Examples of copy and pasting

数据集原始图像分辨率为 5475×3684 ，当输入原图进行训练时，目标检测模型会自动将其压缩至 640×640 ，导致小目标分辨率较低，严重影响其识别精度。因此，我们从原图中裁剪出所有小目标害虫，通过双线性插值方法对图像进行上采样，生成新的图像样本。

与包含多只害虫全局信息的原始图像对应，裁剪后的新样本构成了一个高级别数据集，包含单只害虫丰富的局部信息，可与低级别的害虫全景图构成完整的训练数据集。

3.1.2 小样本数据增强

对样本数量少于50的害虫类别进行过采样数据增强。根据各类害虫样本数量的不同，将过采样率分别设置为2倍、3倍、4倍，生成新样本，以有效缓解害虫数量极度不平衡的问题，显著提升模型在小样本数据中的特征提取能力和学习效率。

3.1.3 线上数据增强

对小样本和小目标害虫进行有针对性的数据增强后,再进行线上数据增强,具体方法包括:旋转、翻转、缩放、色域调整、平移、Mosaic^[18]、Mixup^[19]。通过一系列数据增强,有效降低了模型对目标位置、色彩等属性的依赖,增加了训练样本的数量以及多样性,提高了模型的泛化能力。

3.2 目标检测模型

作为无人机捕获图像场景下性能优异的目标检测模型,TPH-YOLOv5^[20]有效解决了小目标与密集目标检测问题。鉴于害虫识别任务大部分为中小目标,且害虫密集,与遥感图像目标识别较为相似,因此引入 TPH-YOLOv5 作为本文的害虫目标检测模型。

TPH-YOLOv5 在 YOLOv5^[21]的基础上主要做了 3 方面的改进:1)设计了 Transformer 编码器,置于骨干网络的最底层和每个检测器中,旨在有效获取全局信息和丰富的上下文信息;2)将检测器调整为 4 个,增加 1 个专门用于超小目标的检测器;3)集成了卷积块注意力模型(Convolutional Block Attention Module, CBAM)^[22],如图 7 所示,CBAM 模型包含通道注意力(Channel Attention Module, CAM)模块和空间注意力(Spatial Attention Module, SAM)模块,分别用于提取通道注意力和空间注意力,通过通道和空间注意力的自适应特征提纯,来寻找密集害虫场景下的注意力区域。

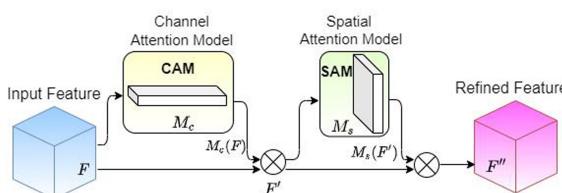


图 7 卷积块注意力模型

Fig. 7 Convolutional block attention module

给定输入特征 $F \in \mathbb{R}^{C \times H \times W}$, 其中 C, H 和 W 分别为特征图的通道数、高和宽。经过 CAM 后获得通道注意力特征 M_c , 如式(1)所示, M_c 与特征图 F 相乘, 获得特征 F' ; F' 经过 SAM 后获得空间注意力特征 M_s , 如式(2)所示, M_s 与特征图 F' 相乘, 获得提纯特征 F'' 。

$$F' = M_c(F) \otimes F \quad (1)$$

$$F'' = M_s(F') \otimes F' \quad (2)$$

3.2.1 引入通道注意力模块 CAM

引入通道注意力模块 CAM, 以关注图片中对害虫分类有帮助的信息, 维持通道维度 C 不变, 压缩空间维度 H 和 W 。CAM 的详细设计流程如图 8 所示。

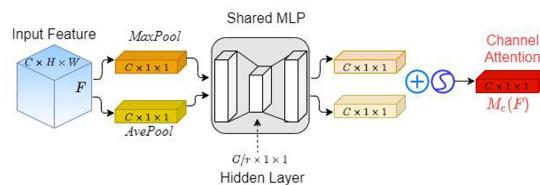


图 8 通道注意力模块

Fig. 8 Channel attention module

输入特征图 F 并行经过最大池化 MaxPool 和平均池化 AvgPool, 获得最大池化特征 F_{\max}^c 和平均池化特征 F_{avg}^c , 特征向前传播至共享多层感知机(Multilayer Perceptron, MLP)。经过 MLP 后, 对特征进行元素级(Element-wise)相加 \oplus , 通过 Sigmoid 函数进行非线性变换, 得到通道注意力特征 M_c , 如式(3)所示:

$$\begin{aligned} M_c(F) &= \sigma(\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{MaxPool}(F))) \\ &= \sigma(W_1(W_0(F_{\text{avg}}^c)) + W_1(W_0(F_{\max}^c))) \end{aligned} \quad (3)$$

MLP 中包含一个隐层, 隐层的神经元个数设为 C/r , 其中 r 为缩小因子。式(3)中, σ 表示 sigmoid 函数, W_0 和 W_1 表示 MLP 的权重, 其中 $W_0 \in \mathbb{R}^{C/r \times C}$, $W_1 \in \mathbb{R}^{C \times C/r}$ 。 W_0 和 W_1 共享输入特征 F , 与其他卷积神经网络类似, W_0 后接 ReLU 激活函数。

3.2.2 引入空间注意力模块 SAM

本文利用特征的空间关联性, 引入了空间注意力模块 SAM, 来关注图片中害虫的位置信息, 对通道注意力特征进行有效补充。维持空间维度 H 和 W 不变, 压缩通道维度 C 。

如图 9 所示, 输入特征图 F' 沿通道方向经过最大池化 MaxPool 和平均池化 AvgPool 后得到 2 个 $1 \times H \times W$ 大小的跨通道空间特征图 F'_{\max}^s 和 F'_{avg}^s ; 然后进行通道拼接和 7×7 卷积, 将其转变为单通道特征图, 通过 sigmoid 函数进行非线性变换, 得到空间注意力特征 M_s , 如式(4)所示:

$$\begin{aligned} M_s(F') &= \sigma(f^{7 \times 7}([\text{AvgPool}(F'); \text{MaxPool}(F')])) \\ &= \sigma(f^{7 \times 7}([F'_{\text{avg}}^s; F'_{\max}^s])) \end{aligned} \quad (4)$$

其中, σ 表示 sigmoid 函数, $f^{7 \times 7}$ 表示卷积核为 7×7 的卷积操作。

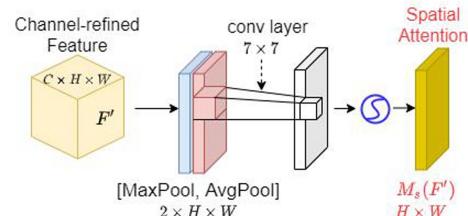


图 9 空间注意力模块

Fig. 9 Spatial attention module

3.3 基于微调的二阶段小样本学习策略

本文构建了基于微调的二阶段小样本学习策略, 具体步骤如图 10 所示。

Step 1 划分数据集。将数据集划分为基类 X_b 和新类 X_n , 其中基类包括样本数大于 20 的 16 类害虫, 新类包括样本数小于 20 的 12 类害虫。

Step 2 训练(Training Stage)。采用 MS COCO 数据集初始化特征提取器的参数 θ , 输入基类数据 X_b , 对模型进行第一阶段的训练, 得到特征提取器 f_θ 和基类害虫检测器 $C(. | W_b)$ 。

训练阶段采用与 YOLOv5 目标检测模型一致的损失(Loss)计算方法。通过不断调整检测器参数 W_b , 最小化训练损失 Loss, 获得基类害虫检测器 $C(. | W_b)$ 。训练损失由置信

度损失(objectness loss,obj_loss)、分类损失(classes loss,cls_loss)和定位损失(location loss,box_loss)3部分组成,如式(5)所示:

$$Loss = \lambda_1 obj_loss + \lambda_2 cls_loss + \lambda_3 box_loss \quad (5)$$

其中, $\lambda_1,\lambda_2,\lambda_3$ 为平衡系数。各类损失的计算方法请参阅文献[21]。

Step 3 微调(Fine-tuning Stage)。输入新类数据 X_n ,与基类数据 X_b 组成新数据集,对模型进行第二阶段的训练。训练时固定特征提取器 f_θ 的参数 θ ,对基类检测器 $C(\cdot|W_b)$ 进行微调,得到新类害虫检测器 $C(\cdot|W_n)$ 。

基于微调的二阶段小样本学习策略,先学习训练样本丰富的基类害虫特征,构建基类害虫检测器;在此基础上加入训练样本稀少的新类害虫数据,通过固定特征提取器的参数,仅在基类害虫检测器上进行模型微调,来构建新类害虫检测器,确保在识别新类害虫的同时,不降低基类害虫的识别能力。

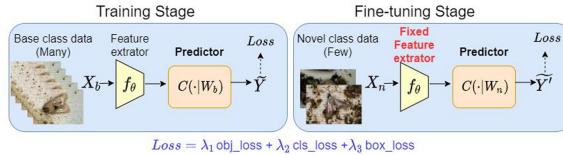


图 10 基于微调的二阶段小样本学习方法

Fig. 10 Two-stage small sample learning based on fine-tuning

3.4 实时害虫预测

如图 4 所示,采用多尺度测试方法实时预测害虫。多尺度测试细节包括:1)放大图像为原图的 1.3 倍;2)分别缩小图像为原图的 0.5 倍、0.67 倍、0.83 倍;3)水平翻转图像。将包括原图在内的 6 张图像分别送入新类害虫模型中进行预测,通过非极大值抑制得到最终的害虫预测结果。

4 实验及结果分析

4.1 实验环境与参数设置

本文实验的硬件环境采用 Intel(R) Xeon(R) E5-2630 v4 @ 2.20GHz 处理器、4 块 NVIDIA Tesla K80 显卡;软件环境采用基于 Python 3.9 的 Pytorch 1.10 深度学习框架,CUDA 11.3 和 Ubuntu 16.04.2 LTS 操作系统。

训练 TPH-YOLOv5 的配置参数采用带动量的随机梯度下降方法对网络进行优化,动量值取 0.9,迭代 300 次,批处理大小为 16,初始学习率为 0.01,学习率变化参数为 0.2。

4.2 评价指标

采用精度(Precision)、召回率(Recall)、平均精度(Average Precision,AP)、mAP 来定量评估本文提出的害虫识别方法。其中,AP 为算法在 PR(Precision-Recall)曲线下的面积,是衡量算法基于精度和召回率的综合检测性能指标;mAP 为所有类别的 AP 平均值。常用重叠区域交并比(Intersection-over-Union,IoU)来确定检测出的目标数量,记 IoU 阈值为 0.5 时的平均精度均值为 mAP@0.5。

4.3 实验结果分析

首先,验证数据增强方法和基于微调的二阶段小样本学

习策略的有效性。以 TPH-YOLOv5 为基线程序(Baseline),逐渐加入小目标害虫数据增强、小样本害虫数据增强和线上数据增强方法,将基于微调的二阶段小样本学习策略应用于 TPH-YOLOv5 方法中,比较其与基线程序的 mAP@0.5 和每轮训练迭代时间,实验结果如表 1 所列,其中√表示采用该方法。

表 1 害虫识别结果

Table 1 Pests recognition results

方法	实验结果			
Baseline (TPH-YOLOv5)	√	√	√	√
小目标数据增强		√	√	√
小样本数据增强			√	√
线上数据增强				√
mAP@0.5 (TPH-YOLOv5)	0.56	0.73	0.80	0.83
运行时间/轮(单位:分)	3	4.5	4.3	9
mAP@0.5 (二阶段 TPH-YOLOv5)	0.56	0.75	0.83	0.86
运行时间/轮(单位:分)	3.2	4.7	4.6	9.2

由表 1 可知,在基线程序 TPH-YOLOv5 上应用小目标/小样本/线上害虫数据增强方法,mAP@0.5 分别提升了 17%、7% 和 3%,表明复制粘贴、裁剪、过采样等方法不仅可以增加训练样本数目,使模型更关注小目标和小样本害虫,还可提升其对训练损失的贡献度,从而带来识别精度和泛化能力的大幅提升。

另外,基于微调的二阶段 TPH-YOLOv5 方法比 TPH-YOLOv5 方法 mAP@0.5 提升了 3%,表明基于微调的二阶段小样本学习策略简单高效,通过分阶段学习基类和新类害虫特征,能有效完成小样本害虫识别任务,特别适用于虫情测报灯等智能设备不断采集害虫数据的实际农业应用场景。在应用本文方法时,可将已采集的害虫图像作为基类数据,将新采集的害虫图像作为新类数据,通过不断将新类加入基类害虫识别模型进行第二阶段的训练,来确保在精准识别出新类害虫的同时,不降低基类害虫的识别精度。

基于微调的二阶段 TPH-YOLOv5 方法损失随迭代轮次的收敛情况如图 11 所示。由图 11 可知,训练和验证阶段的分类损失 cls_loss、定位损失 box_loss、置信度损失 obj_loss 随着迭代轮次的增加而快速收敛。训练阶段,置信度损失 obj_loss 在 3 类损失中数值最低,迭代约 50 轮后损失曲线趋于平缓;定位损失 box_loss 在前 20 轮迭代过程中迅速下降,经过 250 轮迭代后,损失值稳定在 0.018 左右;分类损失 cls_loss 的收敛趋势与定位损失类似。验证阶段损失的收敛情况与训练过程相似。通过分析训练和验证阶段的损失收敛情况可知,3 类损失曲线平滑、无震荡,说明害虫识别模型收敛速度快,拟合效果好。推理一张害虫图片的时间约为 0.481 s,能满足实际农业应用场景中实时害虫识别和定位的需求。

图 12 给出了基于微调的二阶段 TPH-YOLOv5 方法在验证集上的精度、召回率和 mAP@0.5 的性能曲线。由图 12 可知,性能曲线整体呈现震荡上升的趋势,迭代约 50 轮后,性

能曲线趋于平缓,此时精度、召回率和 mAP@0.5 值分别为 87.6%,84.9% 和 85.7%。

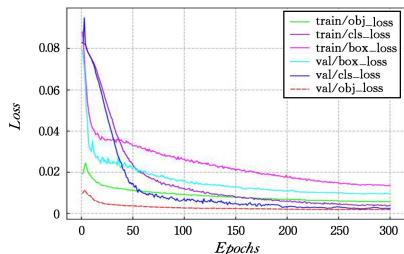


图 11 二阶段 TPH-YOLOv5 方法的损失收敛情况

Fig. 11 Loss convergence of two-stage TPH-YOLOv5 method

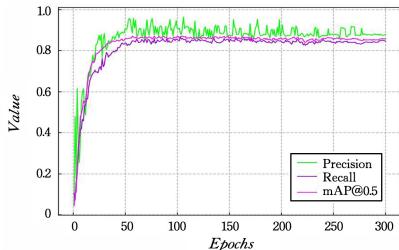


图 12 二阶段 TPH-YOLOv5 方法的性能

Fig. 12 Performance of two-stage TPH-YOLOv5 method

本文对测试集中的图片进行了检测,并选取了不同场景下的若干识别结果进行展示。如图 13 所示,基于微调的二阶段 TPH-YOLOv5 方法可以实现对多类害虫的有效识别。得益于有针对性的数据增强和二阶段小样本学习策略,在简单或复杂干扰背景中,噪声图像、微小害虫、被遮挡害虫都能被正确定位和分类。

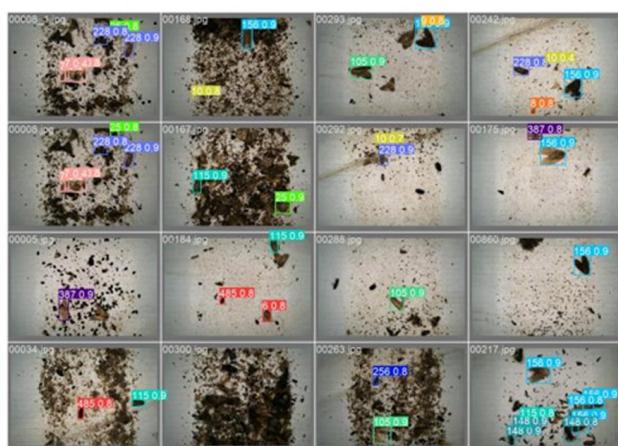


图 13 在测试集上的识别结果示例

Fig. 13 Detection results on test set

为进一步验证基于微调的二阶段 TPH-YOLOv5 方法的有效性,使用 Grad-CAM^[23]对随机挑选的 10 类害虫识别结果进行可视化,如图 14 所示,第 1,3 列为害虫原图,第 2,4 列为识别结果,方框定位出害虫在图片中的位置,方框右上角的数字表示害虫类别编号。从图中可以看出,本文提出的害虫识别方法采用了 CBAM 注意力机制,通过联合使用平均池化和最大池化操作,来提取害虫图片的跨通道和空间特征,关注于害虫的分类和位置信息,较好地实现了密集和遮挡背景下的害虫分类和定位。

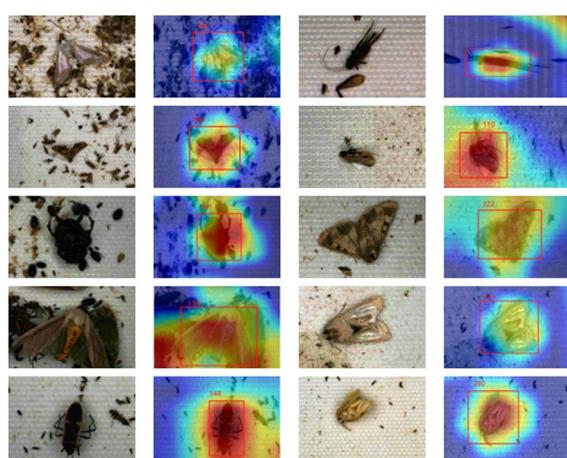


图 14 Grad-CAM 可视化害虫识别结果示例

Fig. 14 Pest recognition results through Grad-CAM visualization

结束语 本文提出了一种基于 TPH-YOLOv5 和小样本学习的害虫识别方法,通过对小目标和小样本害虫进行有针对性的数据增强,构建基于微调的二阶段小样本学习策略,提升了模型对微小害虫和小样本害虫的关注;通过分阶段学习基类和新类害虫特征,确保在精准识别新类害虫的同时,不降低基类害虫的识别能力。在 28 类害虫图像数据集上的实验结果表明,所提方法具有较高的学习效率和识别正确率,适用于不断更新害虫数据的实际农业应用场景。

虫情测报灯等虫情信息智能设备采集的图像中聚集了大量昆虫,遮挡和密集害虫分布、有益昆虫和无需监测昆虫的干扰成为了影响害虫识别性能的主要因素。下一步拟通过注意力机制充分挖掘基于上下文信息的害虫检测目标区域,以进一步提高复杂场景下的害虫识别性能。

参 考 文 献

- [1] LAWRENCE C N, MOATAZ A, MOHAMMED A. Recent advances in imageprocessing techniques for automated leaf pest and disease recognition - A review[J]. Information Processing in Agriculture, 2021, 8(1): 27-51.
- [2] MISBAH P, NIVEDITA P, HITESHRI Y, et al. Artificial cognition for applications in smart agriculture: A comprehensive review[J]. Artificial Intelligence in Agriculture, 2020, 4: 81-95.
- [3] ZHOU F Y, JIN L P, DONG J. Review of Convolutional Neural Network[J]. Chinese Journal of Computers, 2017, 40(6): 1229-1251.
- [4] LIU L, WANG R, XIE C, et al. PestNet: An End-to-End Deep Learning Approach for Large-Scale Multi-Class Pest Detection and Classification[J]. IEEE Access, 2019, 7: 45301-45312.
- [5] JIAO L, DONG S, ZHANG S, et al. AF-RCNN: An anchor-free convolutional neural network for multi-categories agricultural pest detection[J]. Computers and Electronics in Agriculture, 2020, 174: 105522.
- [6] LIANG Y, QIU R Z, LI Z P, et al. Identification Method of Major Rice Pests Based on YOLO v5 and Multi-source Datasets [J]. Transactions of the Chinese Society for Agricultural, 2022, 53(7): 250-258.
- [7] LI R, WANG R, ZHANG J, et al. An Effective Data Augmentation Strategy for CNN-Based Pest Localization and Recognition

- in the Field[J]. IEEE Access, 2019, 7:160274-16028.
- [8] LI R,WANG R,XIE C,et al. A coarse-to-fine network for aphid recognition and detection in the field[J]. Biosystems Engineering, 2019, 187:39-52.
- [9] WANG F,WANG R,XIE C,et al. Fusing multi-scale context-aware information representation for automatic in-field pest detection and recognition[J]. Computers and Electronics in Agriculture, 2020, 169:105222.
- [10] LIU L,XIE C,WANG R,et al. Deep Learning Based Automatic Multiclass Wild Pest Monitoring Approach Using Hybrid Global and Local Activated Features[J]. IEEE Transactions on Industrial Informatics, 2021, 17(11):7589-7598.
- [11] YANG X,LUO Y,LI M,et al. Recognizing Pests in Field-Based Images by Combining Spatial and Channel Attention Mechanism [J]. IEEE Access, 2021, 9:162448-162458.
- [12] WU X,ZHAN C,LAI Y K,et al. IP102: A Large-Scale Benchmark Dataset for Insect Pest Recognition[C]// 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2019:8779-8788.
- [13] LI Y,WANG H,DANG L M,et al. Crop pest recognition in natural scenes using convolutional neural networks[J]. Computers and Electronics in Agriculture, 2020, 169:105174.
- [14] LIU Y,LIU S,XU J,et al. Forest pest identification based on a new dataset and convolutional neural network model with enhancement strategy[J]. Computers and Electronics in Agriculture, 2022, 192:106625.
- [15] KANG B,LIU Z,WANG X,et al. Few-Shot Object Detection via Feature Reweighting[C]// 2019 IEEE/CVF International Conference on Computer Vision(ICCV). 2019:8419-8428.
- [16] SUN B,LI B,CAI S,et al. FSCE: Few-Shot Object Detection via Contrastive Proposal Encoding[C]// 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2021:7348-7358.
- [17] TONG K ,WU Y. Deep learning-based detection from the perspective of small or tiny objects:A survey[J]. Image and Vision Computing, 2022, 123:104471.
- [18] BOCHKOVSKIY A,WANG C Y,IAO H. YOLOv4: Optimal Speed and Accuracy of Object Detection[J]. arXiv:2004.10934, 2020.
- [19] ZHANG H,CISSE M,DAUPHIN Y N,et al. Mixup: Beyond empirical risk minimization[J]. arXiv:1710.09412, 2017.
- [20] ZHU X,LYU S,WANG X,et al. TPH-YOLOv5: Improved YOLOv5 Based on Transformer Prediction Head for Object Detection on Drone-captured Scenarios[C]// 2021 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW). 2021:2778-2788.
- [21] WANG Z,JIN L,WANG S, et al. Apple stem/calyx real-time recognition using YOLO-v5 algorithm for fruit automatic loading system[J]. Postharvest Biology and Technology, 2022, 185:111808.
- [22] WOO S,PARK J,LEE J,et al. CBAM: Convolutional block attention module[C]// Proceedings of the European Conference on Computer Vision(ECCV). 2018:3-19.
- [23] SELVARAJU R R,COGSWELL M,DAS A,et al. Gradcam: Visual explanations from deep networks via gradient-based localization[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition(CVPR). 2017:618-626.



ZHU Xiang-yuan, born in 1974, Ph.D, associate professor. Her main research interests include parallel computing, computer vision, and applications of deep learning.



ZHOU Xu, born in 1983, Ph.D, associate professor. Her main research interests include big data mining and parallel computing.

(责任编辑:喻藜)