

基于 YOLO v5 和多源数据集的水稻主要害虫识别方法

梁 勇¹ 邱荣洲² 李志鹏¹ 陈世雄¹ 张 钟¹ 赵 健¹

(1. 福建省农业科学院数字农业研究所, 福州 350003; 2. 福建省农业科学院植物保护研究所, 福州 350013)

摘要: 针对水稻稻纵卷叶螟和二化螟成虫图像识别中自动化程度较低的问题, 引入目标检测算法 YOLO v5 对监测设备和诱捕器上的稻纵卷叶螟和二化螟成虫进行识别与计数。依据稻纵卷叶螟和二化螟的生物习性, 采用自主研发的水稻害虫诱集与拍摄监测装置, 自动获取稻纵卷叶螟和二化螟成虫图像, 并与三角形诱捕器和虫情测报灯诱捕拍摄的稻纵卷叶螟和二化螟成虫图像共同构建水稻害虫图像数据集; 采用左右翻转、增加对比度、上下翻转的方式增强图像数据集; 对比了不同训练模型对三角形诱捕器和监测设备诱捕拍摄的水稻害虫图像的检测性能, 并对比稻纵卷叶螟成虫不同训练样本量对识别结果的影响, 用精确率、召回率、F1 值、平均精度评估各模型的差异。测试结果表明, 测试集图像为三角形诱捕器和监测设备诱捕拍摄虫害图像时, 稻纵卷叶螟识别的精确率和召回率分别达到 91.67% 和 98.30%, F1 值达到 94.87%, 二化螟识别的精确率和召回率分别达到 93.39% 和 98.48%, F1 值达到 95.87%。不同采样背景、设备构建的多源水稻害虫图像数据集可以提高模型对水稻害虫识别的准确性。基于 YOLO v5 算法设计的水稻害虫识别计数模型能够达到较高的识别准确率, 可以用于稻纵卷叶螟和二化螟成虫的田间种群监测。

关键词: 水稻; 稻纵卷叶螟; 二化螟; 深度学习; YOLO v5; 自动识别

中图分类号: TP391 文献标识码: A 文章编号: 1000-1298(2022)07-0250-09

OSID:



Identification Method of Major Rice Pests Based on YOLO v5 and Multi-source Datasets

LIANG Yong¹ QIU Rongzhou² LI Zhipeng¹ CHEN Shixiong¹ ZHANG Zhong¹ ZHAO Jian¹

(1. Institute of Digital Agriculture, Fujian Academy of Agricultural Sciences, Fuzhou 350003, China

2. Institute of Plant Protection, Fujian Academy of Agricultural Sciences, Fuzhou 350013, China)

Abstract: Accurate prediction of rice pest plays a very important role in ensuring high yield of rice and reducing economic losses. Manual rice pest survey methods in paddy fields are time-consuming. With the developments in computer vision technology and theory, machine learning and deep learning have been applied in automatic identification of agricultural pests, which have greatly improved image classification accuracy of rice pest. Target detection algorithm YOLO v5 was introduced to identify and count *Cnaphalocrocis medinalis* and *Chilo suppressalis* on monitoring equipment and traps. Based on the biological habits of *C. medinalis* and *C. suppressalis*, a multi-source rice pest images dataset was constructed from the images of adults of *C. medinalis* and *C. suppressalis*, which were captured by a self-developed rice pest trap and photo device, triangular traps and light traps. The number of images in the dataset were increased by flipping the image left to right, increasing the image contrast, and flipping the image up and down. The detection performance of different training models on rice pest images captured by triangle traps and monitoring device was compared, and the effects of different training sample sizes on the identification results were compared. Precision, recall, F1 score and average precision were used to evaluate the difference of each model. The models were tested on the rice pest images captured by triangle traps and monitoring device. The results showed that the precision and recall of *C. medinalis* were

收稿日期: 2022-02-11 修回日期: 2022-04-15

基金项目: 福建省自然科学基金项目(2020J011376)、福建省农业高质量发展协同创新工程项目(XTCXGC2021015)、福建省智慧农业科技
创新团队项目(CXTD2021013-1)和福建省农科院特色现代农业产业发展研究项目(AA2018-9)

作者简介: 梁勇(1986—), 男, 农艺师, 主要从事植物保护技术研究, E-mail: 278017592@qq.com

通信作者: 赵健(1973—), 男, 研究员, 博士, 主要从事农业信息化研究, E-mail: zhaojian@faas.cn

91.67% and 98.30%, respectively, and the F1 score was 94.87%. The precision and recall of *C. suppressalis* were 93.39% and 98.48%, respectively, and the F1 score was 95.87%. Multi-source rice pest images dataset constructed by different sampling background and equipment can improve the accuracy of rice pest by identification model. The rice pest identification and counting model developed based on YOLO v5 algorithm can achieve high identification accuracy and it can be used to monitor population of *C. medinalis* and *C. suppressalis* in the field.

Key words: rice; *Cnaphalocrocis medinalis*; *Chilo suppressalis*; deep learning; YOLO v5; automatic identification

0 引言

水稻害虫的准确预测对保证水稻高产、减少经济损失具有十分重要的作用^[1]。传统的水稻害虫测报工作主要由人工完成,害虫识别与计数效率低。随着计算机视觉技术的发展,机器学习和深度学习被应用到农业害虫的自动识别领域中。

传统机器学习主要基于计算机视觉进行害虫纹理、颜色、形状等特征提取,使用支持向量机(Support vector machine, SVM)^[2-3]、K 最近邻(K-nearest neighbor, KNN)^[4]和 AdaBoost 算法(Adaptive boosting, AdaBoost)^[5]等算法检测目标害虫。EBRAHIMI 等^[6]应用 SVM 算法识别温室草莓蚜虫,识别结果的平均错误率小于 2.25%。VAKILIAN 等^[7]提出了一种基于人工神经网络的甜菜夜蛾识别方法,识别结果的平均准确率为 90%。YAO 等^[8]研发了一款水稻害虫手持拍摄设备,并利用 AdaBoost 算法对稻田飞虱进行识别与自动计数,识别检测率为 85.2%。上述基于机器学习的农业害虫检测技术需要经过复杂的虫害图像特征设计,然而野外环境中,水稻害虫拍摄的背景复杂多变,拍摄受光线影响大,人工方式难以将水稻害虫颜色和形状特征从相似的水稻叶片和其它非目标昆虫等复杂背景中选取出来,因此利用机器学习方法难以满足水稻害虫全自动监测的需求。

深度学习可以自动逐层提取特征,有自己的特征生成器,识别速度和精确率优于机器学习,对复杂背景下的目标检测有很大的优势^[9]。LIU 等^[10]应用 8 层卷积神经网络(Convolutional neural network, CNN),实现了对水稻 12 种害虫的准确分类。TAN 等^[11]比较了深度学习和机器学习算法对 Plant Village 数据集中番茄叶片病害的识别效果,结果表明,深度学习算法识别的精确率、召回率、F1 值等指标都优于机器学习算法。KASINATHAN 等^[12]进行了机器学习算法和 CNN 算法在 IP102 数据集上的害虫检测精度对比,CNN 算法的检测精度高于机器学习算法。目前常用的深度学习目标检测网络有 Faster RCNN 算法(Faster region with convolutional

neural network)^[13]、单步多框检测器(Single shot multibox detector, SSD)^[14]和 YOLO 算法(You only look once)^[15]等。孙钰等^[16]使用改进的 Faster RCNN 算法能自动化地统计诱捕器中的红脂大小蠹数量。余小东等^[17]提出了一种基于残差网络(ResNet 50)的改进算法,实现农作物病虫害等级分类,准确率为 91.51%。YOLO 算法是基于回归的目标检测方法,能够同时分类和检测一幅图像。上述研究的病虫害训练数据集图像主要是从室内或者野外田间拍摄获得,室内图像是将害虫放在室内试验条件下拍摄。室内收集的病虫害图像可以有效消除外界光线的影响,简化图像处理,但与真实自然光下采集的图像有很大的不同^[18]。野外田间图像包括使用手机、相机等拍摄设备对野外植物叶片上的害虫进行拍摄,或者使用田间安装的虫情监测设备自动获取害虫图像^[19-20]。

由于自然环境下采集的病虫害图像背景多样,且采集设备不同,已有模型主要是在特定的采集背景和拍摄设备下训练出来的,对不同采集背景、不同采集设备图像的识别效果有待研究。因此,本研究从监测设备、三角形诱捕器、虫情测报灯 3 种不同采集背景中拍摄稻纵卷叶螟和二化螟成虫图像,提出一种基于 YOLO v5 算法的野外稻纵卷叶螟和二化螟成虫识别方法,构建 3 种不同采集背景的水稻稻纵卷叶螟和二化螟成虫图像数据集,将不同采集背景、不同设备的训练模型对野外三角形诱捕器和监测设备虫害图像的检测性能进行对比,建立最优的识别与计数模型,并对比稻纵卷叶螟图像不同训练数据量的模型识别结果,实现对稻纵卷叶螟和二化螟成虫图像的自动识别与计数。

1 数据获取

1.1 害虫样本采集

本研究应用自主研制的水稻害虫监测设备、三角形诱捕器、佳多虫情测报灯采集稻纵卷叶螟和二化螟,分别使用图像传感器、Sony RX100 型数码相机、小米 M5 手机等多种设备拍摄图像。水稻害虫诱集与拍摄装置包括太阳能供电组件、诱捕罩、拍摄

单元、害虫清理单元、集虫容器等部件,系统结构如图1所示。监测设备放置地点为福建省三明市洋溪镇(26°17'58"N,117°44'10"E)和三明市尤溪县(26°9'56"N,118°2'53"E),图像采集时间为2020年4—10月。

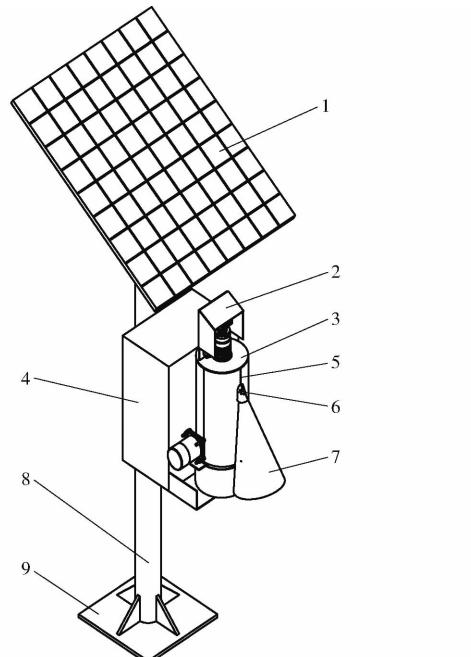


图1 水稻害虫诱集与拍摄装置示意图

Fig. 1 Schematic of trap and camera device for rice pest

1. 太阳能板 2. 镜头盖 3. 收集容器 4. 控制箱 5、6. 透气孔
7. 诱捕罩 8. 立柱 9. 托板

溪镇(26°17'58"N,117°44'10"E)和三明市尤溪县(26°9'56"N,118°2'53"E),图像采集时间为2020年4—10月。

利用不同拍摄设备获取2种水稻害虫,表1为不同设备获取的害虫图像数量。监测设备采用性信息素引诱,昆虫性信息素为北京中捷四方有限公司生产。害虫原始图像由嵌入监测设备里的图像传感器采集,由4G无线网络自动上传到服务器。原始图像分辨率为1800像素×1350像素,为提高上传效率,将其压缩为900像素×675像素,图像传感器四周附有LED补光灯。每天12:00采集1次,每次采集后,害虫清理单元清理掉前次拍摄后的害虫,保证每幅图的虫数为清理前24 h的虫数总量。三角形诱捕器所用粘板和性信息素为北京中捷四方有限公司生产,每隔3 d更换一次粘板,更换时对粘板上的害虫进行拍摄,1个月更换一次诱芯。室内采集的水稻害虫为福建省莆田市仙游县、福州市闽侯县两地虫情测报灯所诱捕,以白色底板作为辅助背景拍摄。图2为不同拍摄设备获取的水稻害虫图像。室内白板背景下拍摄的图像背景单一,光照均匀,拍摄背景为三角形诱捕器时,背景中含有水稻叶片和其它非目标昆虫,监测设备拍摄的图像分为稻纵卷

表1 不同采样场景获取图像的数量

Tab. 1 Number of images captured in different sampling scenes

幅

诱集设备	拍摄设备	诱集地点	稻纵卷叶螟 图像数量	二化螟图像 数量
监测设备	图像传感器	三明市洋溪镇、三明市尤溪县	136	74
三角形诱捕器	智能手机(华为畅享9e、苹果iPhone X)	漳州市云霄县、厦门市同安区、福州市闽侯县	462	422
虫情测报灯	数码相机(Sony RX100型)、智能手机 (小米M5、苹果iPhone X)	莆田市仙游县、福州市闽侯县、宁德市霞浦县	5 828	1 385



图2 不同设备采集到的昆虫图像

Fig. 2 Collected insect images by different devices

叶螟和二化螟成虫图像。

1.2 监测设备系统设计

水稻害虫监测设备通过置于诱捕罩内部的诱芯吸引害虫,害虫靠近诱芯时,发现不是真正的雌蛾后垂直向上飞到诱捕罩顶部,从而将害虫诱捕进收集容器内。经过特定时长后摄像头对拍摄面板进行拍摄,且摄像头的镜头朝向拍摄面板的中心位置,整个拍摄面板均可以被拍摄下来,识别控制终端接收摄

像头拍摄的害虫图像信息,收到图像信息后发送到云端,与云端内部存储的害虫信息进行匹配,从而分析害虫的种类及数量,具体流程图如图3所示。

2 基于卷积神经网络的图像处理和分类

2.1 试验平台与参数设置

神经网络模型结构采用YOLO v5算法中的YOLO v5s,其结构见图4。模型训练采用的操作系

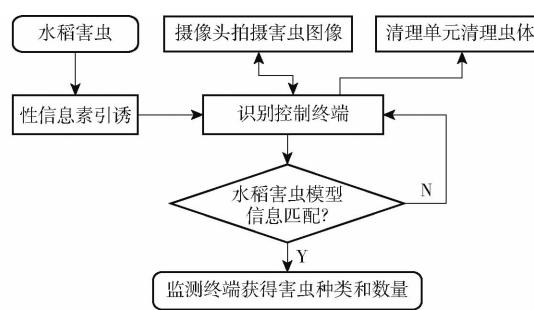


Fig. 3 Flow chart of rice pest counting

统为 Ubuntu 18.04, 训练和测试框架为 Pytorch, 服务器平台配置为: Intel Xeon CPU E5-2665 0 @ 2.40 GHz 处理器, 32 GB 运行内存, 11 GB GeForce RTX2080Ti 显卡, 使用 CUDA 10.2 版本并行计算框架配合 CUDNN 8.2 版本的深度神经网络应用程序编程接口 (API)。输入图像尺寸调整为 640 像素 \times 640 像素, 批量大小设置为 64, 训练步数为 500, 学习率为 0.01, 动量设为 0.937, 采用随机梯度下降 (SGD) 优化, 权重衰减为 0.0005。

2.2 数据集建立

本研究自建水稻害虫数据集, 为保证样本多样性, 设置了监测设备、三角形诱捕器、虫情测报灯 3 种诱捕拍摄方式, 并经农业专家标注确认。由于深度神经网络模型的训练需要大量的图像来提取有效的特征, 为了提高水稻目标害虫检测模型的泛化能力和鲁棒性, 同时避免模型过拟合, 对训练集进行了数据增强。采用左右翻转、增加图像对比度、上下翻转的方式对训练集进行扩充, 不同处理方式得到的图像如图 5 所示。将采集的原始图像长边使用固定值 800 像素, 另一边根据原始图像尺寸进行压缩, 再进行边界框标注。本文使用样本标注软件 TF

Label Tool, 标注稻纵卷叶螟、二化螟目标边界框。标注包括边界框坐标和类别两类信息, 以 txt 文本格式进行存储。

根据图像来源和图像标注类别, 将数据集分为 6 类, 如表 2 所示。数据集 A1 + A2、B1 + B2 分别为监测设备、三角形诱捕器获取的原始图像随机排列, 分别选取原始图像 100 幅到验证集和测试集, 余下扩增到 800 幅。数据集 A3、B3 分别为从室内拍摄的稻纵卷叶螟和二化螟的图像中随机选取 1 000 幅图像。数据集 A1 + A2 + A3 为从数据集 A1 + A2 中随机选取 500 幅图像, 再从数据集 A3 中选取 500 幅图像, 随机排列。数据集 B1 + B2 + B3 为从数据集 B1 + B2 中随机选取 500 幅图像, 再从数据集 B3 中随机选取 500 幅图像, 随机排列。训练集、验证集、测试集图像比例为 8:1:1。

室内白板背景下拍摄的稻纵卷叶螟的不同训练数据量与训练集如表 3 所示。首先将室内拍摄的 5 828 幅稻纵卷叶螟原始图像通过图像扩充到 6 000 幅, 随机排列图像, 其中图像总量按比例 1:2:3 分为数据集 A3_1000、A3_2000 和 A3_3000。数据集 A3_4000 由数据集 A3_1000 和 A3_3000 组成, 数据集 A3_5000 由数据集 A3_2000 和 A3_3000 组成, 数据集 A3_6000 由数据集 A3_1000 和 A3_5000 组成。训练集、验证集、测试集图像比例为 8:1:1。

2.3 模型的测试和评估

为了进一步验证模型的有效性, 需要在各种实际条件下检测算法的效率, 本研究以不同采样场景、不同设备采集图像构建的多源数据集和稻纵卷叶螟训练数据量为控制变量。为了评价本研究提出的水稻害虫检测模型的有效性, 选择精确率 (Precision,

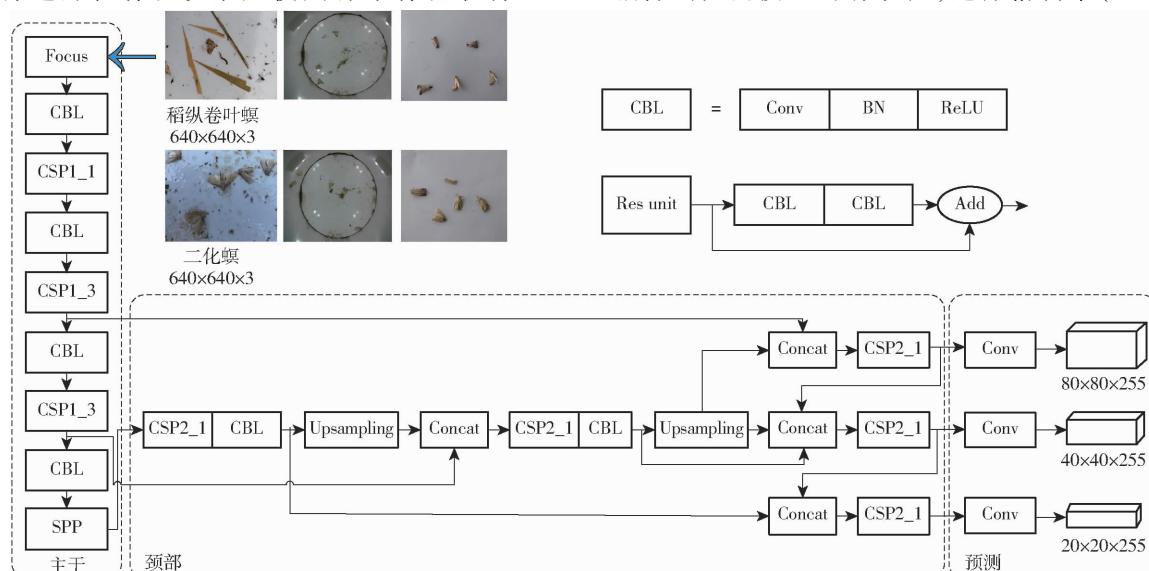


图 4 YOLO v5s 算法结构

Fig. 4 Structure of YOLO v5s algorithm

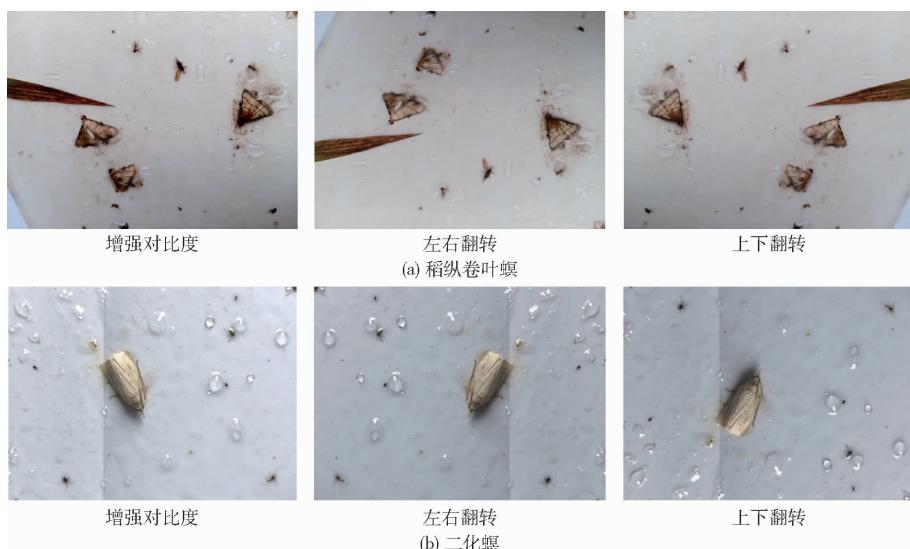


图 5 水稻害虫图像数据增强效果

Fig. 5 Data augmentation of rice pest images

表 2 不同数据集构成

Tab. 2 Composition of dataset

种类	数据集	图像来源	原始图像	标注框
			总量/幅	总数/个
稻纵卷叶螟	A3	虫情测报灯	1 000	3 198
	A1 + A2	监测设备	136	2 844
	A1 + A2 + A3	三角形诱捕器	462	
		数据集 A1 + A2	500	2 987
二化螟	B3	虫情测报灯	1 000	1 612
	B1 + B2	监测设备	74	3 004
	B1 + B2 + B3	三角形诱捕器	422	
		数据集 B1 + B2	500	2 349
		数据集 B3	500	

P)、召回率(Recall, R)、F1 值(F1 score)和平均精度

(Average precision, AP)作为评价指标。

3 结果与分析

3.1 不同训练模型对水稻害虫的识别结果

为了进一步测试模型对水稻害虫的识别能力, 对诱捕器和监测设备采集的害虫图像进行目标检测。通过训练集构建了 6 个识别模型, 其中 3 个稻纵卷叶螟模型, 3 个二化螟模型, 分别为基于室内白板背景图像集的 YOLO v5s_A3 和 YOLO v5s_B3、基于诱捕器和监测设备图像集的 YOLO v5s_A1 + A2 和 YOLO v5s_B1 + B2, 基于室内白板背景、诱捕器和监测设备图像集的 YOLO v5s_A1 + A2 + A3 和

表 3 室内白板背景下拍摄的稻纵卷叶螟数据集分布

Tab. 3 Dataset distribution of *C. medinalis* photographed by indoor whiteboard

类别	A3_1000	A3_2000	A3_3000	A3_4000	A3_5000	A3_6000
图像来源	虫情测报灯	虫情测报灯	虫情测报灯	A3_1000	A3_2000	A3_1000
图像总量/幅	1 000	2 000	3 000	A3_3000	A3_3000	A3_5000
标注框总数/个	3 591	6 675	10 021	13 612	16 696	20 287

YOLO v5s_B1 + B2 + B3。分别对测试数据集 A1 + A2 和 B1 + B2 进行检测验证, 精确率、召回率、F1 值

如表 4 所示, 检测结果见图 6。在实际测试中, YOLO v5s_A3 模型对野外监测设备和三角形诱捕

表 4 不同模型识别结果对比

Tab. 4 Comparison of identification results by different models

模型	训练集	测试集	精确率/%	召回率/%	F1 值/%	平均精度/%
YOLO v5s_A3	A3		55.59	83.26	66.67	87.13
YOLO v5s_A1 + A2	A1 + A2	A1 + A2	96.43	92.31	94.32	99.97
YOLO v5s_A1 + A2 + A3	A1 + A2 + A3		91.67	98.30	94.87	99.83
YOLO v5s_B3	B3		81.43	75.53	78.37	93.52
YOLO v5s_B1 + B2	B1 + B2	B1 + B2	93.39	98.48	95.87	99.74
YOLO v5s_B1 + B2 + B3	B1 + B2 + B3		91.50	97.29	94.31	99.94

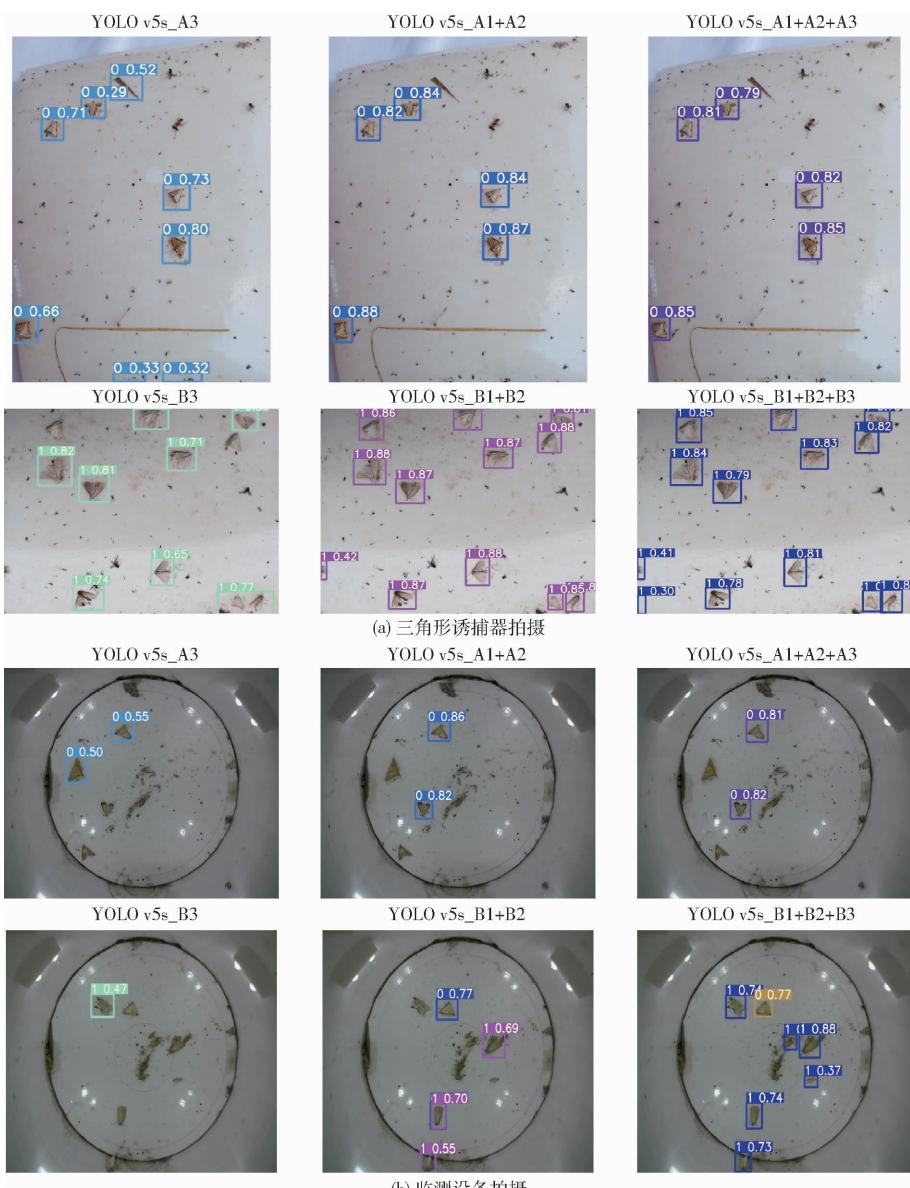


图 6 不同模型的检测结果

Fig. 6 Detection results for different models

器下采集的害虫图像的识别精确率较低,会将其它昆虫识别为稻纵卷叶螟成虫。YOLO v5s_B3 模型的召回率较低,二化螟成虫的漏检较多。YOLO v5s_A1 + A2 + A3 模型的 F1 值比 YOLO v5s_A1 + A2 模型略高,达到 94.87%,召回率为 98.30%。针对二化螟构建的 3 个模型,YOLO v5s_B1 + B2 模型的 F1 值较高,达到 95.87%,召回率为 98.48%。

3.2 不同训练样本量对识别结果的影响

为了验证不同训练样本量对水稻稻纵卷叶螟模型检测性能的影响,通过训练集构建了 6 个识别模型,分别为 YOLO v5s_A3_1000、YOLO v5s_A3_2000、YOLO v5s_A3_3000、YOLO v5s_A3_4000、YOLO v5s_A3_5000 和 YOLO v5s_A3_6000,分别对测试数据集 A3_1000 进行检测验证,不同训练集样本量训练出的模型精确率、召回率、F1 值如表 5 所

表 5 不同训练样本量的水稻害虫检测性能
Tab. 5 Detection performance of rice pest with different training sample sizes

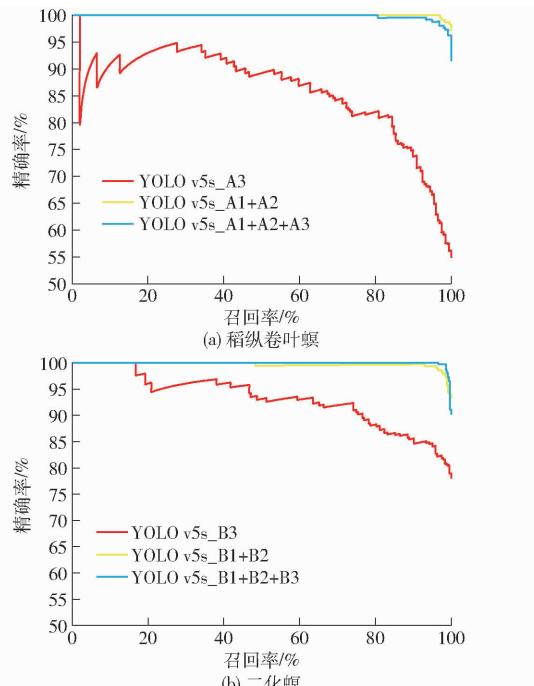
模型	训练集	训练集样本量	精确率/%	召回率/%	F1 值/%
YOLO v5s_A3_1000	A3_1000	800	96.07	99.19	97.61
YOLO v5s_A3_2000	A3_2000	1 600	97.61	99.46	98.53
YOLO v5s_A3_3000	A3_3000	2 400	94.60	99.73	97.10
YOLO v5s_A3_4000	A3_4000	3 200	90.64	99.19	94.72
YOLO v5s_A3_5000	A3_5000	4 000	97.10	99.46	98.26
YOLO v5s_A3_6000	A3_6000	4 800	98.40	99.46	98.92

示。模型的检测性能随着训练集样本量的增加而提高。当训练图像样本量少于 3 200 幅时,F1 值会随着训练集样本量的增加先增高后降低。当训练图像样本量超过 3 200 幅时,F1 值会随着训练样本量的增加而增加。YOLO v5s_A3_6000 模型的 F1 值为

98.92%, 精确率为 98.40%, 召回率为 99.46%, 在 6 个训练模型中最高。

3.3 不同模型精确率-召回率曲线比较

分别取测试数据集 A1 + A2 和 B1 + B2 对模型进行检测验证, 不同模型稻纵卷叶螟和二化螟的精确率-召回率曲线如图 7 所示。YOLO v5s_A3、YOLO v5s_A1 + A2、YOLO v5s_A1 + A2 + A3 模型的平均精度分别为 87.13%、99.97%、99.83% (表 4), 结果表明模型 YOLO v5s_A1 + A2 的平均精度均高于模型 YOLO v5s_A3 和 YOLO v5s_A1 + A2 + A3。YOLO v5s_B3、YOLO v5s_B1 + B2、YOLO v5s_B1 + B2 + B3 模型的平均精度分别为 93.52%、99.74%、99.94% (表 4), YOLO v5s_B1 + B2 和 YOLO v5s_B1 + B2 + B3 模型的平均精度相近, YOLO v5s_B1 + B2 和 YOLO v5s_B1 + B2 + B3 相比 YOLO v5s_B3 模型有更高的精确率。



6 042 只, 二化螟训练样本量 1 496 幅, 共 4 616 只。用诱捕器和监测设备图像集 A1 + A2 和 B1 + B2 分别作为测试集, 模型 YOLO v5s_A1 + A2 + A3 的精确率和召回率分别达到 91.67% 和 98.30%, F1 值达到 94.87%, YOLO v5s_B1 + B2 精确率和召回率分别达到 93.39% 和 98.48%, F1 值达到 95.87%。本研究与姚青等^[21]基于双线性注意力网络的农业灯诱害虫细粒度图像识别结果比较, 训练集的稻纵卷叶螟和二化螟样本量更大, 背景干扰少, 模型测试结果表明, YOLO v5s 网络模型能够达到较高的识别精确率, 可用于稻纵卷叶螟和二化螟成虫的田间种群智能监测。

4.2 数据集多样性与检测性能

不同采集背景、不同采集设备获得的图像训练出来的模型对田间害虫监测的实际效果还有待进一步研究。深度学习需要大量的计算, 在不损失精度的情况下, 可以结合不同的网络模型对测试集图像进行测试。本研究中模型 YOLO v5s_A3 和 YOLO v5s_B3 对野外监测设备和三角形诱捕器采集的害虫图像的识别精确率较低, YOLO v5s_A3 和 YOLO v5s_B3 模型的 F1 值分别低于模型 YOLO v5s_A1 + A2 和 YOLO v5s_B1 + B2。这一结果与训练背景有关, 室内白板背景下拍摄的水稻图像背景单一, 干扰少, 害虫特征清晰, 监测设备和三角形诱捕器的背景多样, 复杂性更高, 含有其它非目标昆虫, 且受野外光线影响。王卫民等^[22]的模型识别效果与背景的复杂性有关, 在白色背景图像上精确率高, 而对背景为圆形网格的图像识别效果最差。翟肇裕等^[23]指出用不具有代表性的原始数据集进行数据增强时, 不能满足训练样本的高质量。邱荣洲等^[24]研究发现在田间草地贪夜蛾识别计数中, 识别率受采样背景的影响, 去除图像背景会降低识别的查全率。因此室内白板背景下拍摄的水稻害虫图像训练出来的模型并不能有效满足实际田间复杂背景下水稻害虫的识别。不同采样场景、不同设备采集的水稻害虫图像可以提高模型对水稻害虫识别的准确性。YOLO v5s_A1 + A2 + A3 融合了监测设备、三角形诱捕器、虫情测报灯 3 个不同采集背景, 模型识别效果较好, 这说明训练过程中, 模型会提取训练图像中的背景特征加以训练, 提高训练图像背景的多样性, 可以使模型对环境特征的改变进行区分。这与周爱明等^[25]的研究结果相一致, 多样本加入训练可使分类模型更加鲁棒和高效。因此数据集的变化越多, 训练模型的泛化效果越好。基于室内白板背景、诱捕器和监测设备二化螟图像训练的模型 YOLO v5s_B1 + B2 + B3 在经室内白板背景下拍摄的二化螟图像训

图 7 不同模型的稻纵卷叶螟和二化螟的精确率-召回率曲线
(a) 稻纵卷叶螟
(b) 二化螟

Fig. 7 Precision - recall curves of *C. medinalis* and *C. suppressalis* in different models

4 讨论

4.1 YOLO v5s 算法与水稻害虫监测

本研究从水稻害虫监测应用出发, 利用 YOLO v5s 网络模型对监测设备、三角形诱捕器、虫情测报灯 3 个不同采样场景、设备构建的稻纵卷叶螟和二化螟图像集进行训练, 采集稻纵卷叶螟和二化螟成虫原始图像 8 307 幅, 有效丰富了实际不同场景中的应用, 其中稻纵卷叶螟训练样本量 1 598 幅, 共

练后,识别结果的 F1 值比 YOLO v5s_B1 + B2 低,这一结果与 YOLO v5s_A1 + A2 + A3 模型训练的结果相反,造成这一结果有可能跟训练集的组成有关,在各组训练集图像总量一致的情况下,增加室内白板背景下拍摄的数据集 B3 图像时,数据集 B1 + B2 的图像量也按比例减少。

4.3 数据量与检测性能

深度学习需要不同条件下采集的实际图像,所有图像都需要正确的标记,这通常是一个费时费力和容易出错的过程^[26]。LECUN 等^[27]推荐了包含 50 000 个训练示例的数据集,与 ImageNet 数据集中 1 400 多万个样本数据相比,利用深度学习进行病虫害检测面临的最关键问题是农业病虫害图像数据库样本小。本研究发现,训练数据量会影响水稻稻纵卷叶螟的检测,随着训练样本量的提高,模型对稻纵卷叶螟的检测性能也随之提高,当训练图像样本量少于 3 200 时,模型的检测性能会下降,而当训练集样本量超过 3 200 时,F1 值随着训练集样本量的增加而增加,当训练集样本量为 4 800 幅时,YOLO v5s_A3_6000 模型的 F1 值为 98.92%,达到最高。研究结果与 TIAN 等^[28]报道的当训练图像量超过 3 000 时,训练集对模型的性能没有进一步显著影响的结果存在差异。

5 结论

(1) 根据水稻稻纵卷叶螟和二化螟成虫的生物习性,采用自主研发的水稻害虫诱集与拍摄装置,自

动获取稻纵卷叶螟和二化螟成虫图像,并构建了 3 种不同采集背景下的稻纵卷叶螟和二化螟成虫图像数据集。

(2) 通过对所选模型对野外采集与实验室采集背景下水稻害虫的识别效果,模型 YOLO v5s_A3 和 YOLO v5s_B3 的 F1 值低于模型 YOLO v5s_A1 + A2 和 YOLO v5s_B1 + B2, 表明室内白板背景下水稻害虫图像训练的模型对监测设备和诱捕器上的稻纵卷叶螟和二化螟成虫识别率降低,室内环境拍摄的水稻害虫图像并不能有效满足实际田间害虫识别要求。

(3) 用诱捕器和监测设备采集的稻纵卷叶螟和二化螟成虫图像进行测试,模型对稻纵卷叶螟成虫识别的精确率和召回率分别达到 91.67% 和 98.30%,F1 值达到 94.87%,对二化螟成虫识别的精确率和召回率分别达到 93.39% 和 98.48%,F1 值达到 95.87%,结果表明本研究的目标检测算法 YOLO v5 可以对监测设备和诱捕器上的稻纵卷叶螟和二化螟成虫进行自动识别。

(4) 对比稻纵卷叶螟成虫不同训练集样本量的识别效果,随着训练集样本量的提高,模型对稻纵卷叶螟成虫的检测性能先增大后降低,当训练图像样本量为 4 800 幅时,训练模型的 F1 值为 98.92%,达到最高,在病虫害采集有限的数据样本下,可以选择合适的数据量来进行训练,从而得到最优的训练模型。

参 考 文 献

- [1] 刘万才, 陆明红, 黄冲, 等. 水稻重大病虫害跨境跨区域监测预警体系的构建与应用[J]. 植物保护, 2020, 46(1): 87–92.
LIU Wancai, LU Minghong, HUANG Chong, et al. Construction and application of cross border and cross regional monitoring and early warning system for major rice diseases and insect pests[J]. Plant Protection, 2020, 46(1): 87–92. (in Chinese)
- [2] 马鹏鹏, 周爱明, 姚青, 等. 图像特征和样本量对水稻害虫识别结果的影响[J]. 中国水稻科学, 2018, 32(4): 405–414.
MA Pengpeng, ZHOU Aiming, YAO Qing, et al. Influence of image features and sample sizes on rice pest identification[J]. Chinese Journal of Rice Science, 2018, 32(4): 405–414. (in Chinese)
- [3] 杨信廷, 刘蒙蒙, 许建平, 等. 自动监测装置用温室粉虱和蓟马成虫图像分割识别算法[J]. 农业工程学报, 2018, 34(1): 164–170.
YANG Xinting, LIU Mengmeng, XU Jianping, et al. Image segmentation and recognition algorithm of greenhouse whitefly and thrip adults for automatic monitoring device[J]. Transactions of the CSAE, 2018, 34(1): 164–170. (in Chinese)
- [4] LI F, XIONG Y. Automatic identification of butterfly species based on HoMSC and GLCMoIB[J]. The Visual Computer, 2018, 34(11): 1525–1533.
- [5] 杨丽丽, 张大卫, 罗君, 等. 基于 SVM 和 AdaBoost 的棉叶螨危害等级识别[J]. 农业机械学报, 2019, 50(2): 14–20.
YANG Lili, ZHANG Dawei, LUO Jun, et al. Automatic recognition for cotton spider mites damage level based on SVM and AdaBoost[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(2): 14–20. (in Chinese)
- [6] EBRAHIMI M A, KHOSHTAGHAZ 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.
- [7] VAKILIAN K A, MASSAH J. Performance evaluation of a machine vision system for insect pests identification of field crops using artificial neural networks[J]. Archives of Phytopathology and Plant Protection, 2013, 46(11): 1262–1269.
- [8] YAO Q, XIAN D X, LIU Q J, et al. Automated counting of rice planthoppers in paddy fields based on image processing[J]. Journal of Integrative Agriculture, 2014, 13(8): 1736–1745.

- [9] 王相友, 李晏兴, 杨振宇, 等. 基于改进 YOLO v4 模型的马铃薯中土块石块检测方法[J]. 农业机械学报, 2021, 52(8): 241–247.
WANG Xiangyou, LI Yanxing, YANG Zhenyu, et al. Detection method of clods and stones from impurified potatoes based on improved YOLO v4 algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(8): 241–247. (in Chinese)
- [10] LIU Z Y, GAO J F, YANG G G, et al. Localization and classification of paddy field pests using a saliency map and deep convolutional neural network[J]. Scientific Reports, 2016, 6(1): 1–12.
- [11] TAN L J, LU J Z, JIANG H Y. Tomato leaf diseases classification based on leaf images: a comparison between classical machine learning and deep learning methods[J]. AgriEngineering, 2021, 3(3): 542–558.
- [12] KASINATHAN T, SINGARAJU D, UYYALA S R. Insect classification and detection in field crops using modern machine learning techniques[J]. Information Processing in Agriculture, 2021, 8(3): 446–457.
- [13] KARAR M E, ALSUNAYDI F, ALBUSAYMI S, et al. A new mobile application of agricultural pests recognition using deep learning in cloud computing system[J]. Alexandria Engineering Journal, 2021, 60(5): 4423–4432.
- [14] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[C]// European Conference on Computer Vision-ECCV, 2016: 21–37.
- [15] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779–788.
- [16] 孙钰, 张冬月, 袁明帅, 等. 基于深度学习的诱捕器内红脂大小蠹检测模型[J]. 农业机械学报, 2018, 49(12): 180–187.
SUN Yu, ZHANG Dongyue, YUAN Mingshuai, et al. Detection model of in-trap red turpentine beetle based on deep learning [J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(12): 180–187. (in Chinese)
- [17] 余小东, 杨孟辑, 张海清, 等. 基于迁移学习的农作物病虫害检测方法研究与应用[J]. 农业机械学报, 2020, 51(10): 252–258.
YU Xiaodong, YANG Mengji, ZHANG Haiqing, et al. Research and application of crop diseases detection method based on transfer learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(10): 252–258. (in Chinese)
- [18] LIU J, WANG X W. Plant diseases and pests detection based on deep learning: a review[J]. Plant Methods, 2021, 17(1): 17–22.
- [19] 刘德营, 王家亮, 林相泽, 等. 基于卷积神经网络的白背飞虱识别方法[J]. 农业机械学报, 2018, 49(5): 51–56.
LIU Deying, WANG Jialiang, LIN Xiangze, et al. Automatic identification method for *Sogatella furcifera* based on convolutional neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(5): 51–56. (in Chinese)
- [20] LI W Y, WANG D J, LI M, et al. Field detection of tiny pests from sticky trap images using deep learning in agricultural greenhouse[J]. Computers and Electronics in Agriculture, 2021, 183: 106048.
- [21] 姚青, 姚波, 吕军, 等. 基于双线性注意力网络的农业灯诱害虫细粒度图像识别研究[J]. 中国农业科学, 2021, 54(21): 4562–4572.
YAO Qing, YAO Bo, LÜ Jun, et al. Research on fine-grained image recognition of agricultural light trap pests based on bilinear attention network[J]. Scientia Agricultura Sinica, 2021, 54(21): 4562–4572. (in Chinese)
- [22] 王卫民, 符首夫, 顾榕蓉, 等. 基于卷积神经网络的虫情图像分割和计数方法[J]. 计算机工程与科学, 2020, 42(1): 110–116.
WANG Weimin, FU Shoufu, GU Rongrong, et al. An insect image segmentation and counting method based on convolutional neural network[J]. Computer Engineering and Science, 2020, 42(1): 110–116. (in Chinese)
- [23] 翟肇裕, 曹益飞, 徐焕良, 等. 农作物病虫害识别关键技术研究综述[J]. 农业机械学报, 2021, 52(7): 1–18.
Zhai Zhaoyu, CAO Yifei, XU Huanliang, et al. Review of key techniques for crop disease and pest detection [J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(7): 1–18. (in Chinese)
- [24] 邱荣洲, 赵健, 何玉仙, 等. 基于性诱和深度学习的草地贪夜蛾成虫自动识别计数方法[J]. 昆虫学报, 2021, 64(12): 1444–1454.
QIU Rongzhou, ZHAO Jian, HE Yuxian, et al. An automatic identification and counting method of *Spodoptera frugiperda* (Lepidoptera: Noctuidae) adults based on sex pheromone trapping and deep learning[J]. Acta Entomologica Sinica, 2021, 64(12): 1444–1454. (in Chinese)
- [25] 周爱明, 马鹏鹏, 席天宇, 等. 基于深度学习的蝴蝶科级标本图像自动识别[J]. 昆虫学报, 2017, 60(11): 1339–1348.
ZHOU Aiming, MA Pengpeng, XI Tianyu, et al. Automatic identification of butterfly specimen images at the family level based on deep learning method[J]. Acta Entomologica Sinica, 2017, 60(11): 1339–1348. (in Chinese)
- [26] BARBEDO J G A. Impact of dataset size and variety on the effectiveness of deep learning and transfer learning for plant disease classification[J]. Computers and Electronics in Agriculture, 2018, 153(40): 46–53.
- [27] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278–2324.
- [28] TIAN Y, YANG G D, WANG Z, et al. Apple detection during different growth stages in orchards using the improved YOLO-V3 model[J]. Computers and Electronics in Agriculture, 2019, 157(3): 417–426.