



郭小燕, 于帅卿. 一种轻量级 YOLOv5S 农作物虫害目标检测模型[J]. 南京农业大学学报, 2024, 47(5): 1009-1018.

GUO Xiaoyan, YU Shuaiqing. A lightweight YOLOv5S crop pest target detection model[J]. Journal of Nanjing Agricultural University, 2024, 47(5): 1009-1018.

## 一种轻量级 YOLOv5S 农作物虫害目标检测模型

郭小燕\*, 于帅卿

(甘肃农业大学信息科学技术学院, 甘肃 兰州 730070)

**摘要:** [目的] 本文提出一种轻量级 YOLOv5S 农作物虫害目标检测模型以解决在样本数量不足的情况下农作物虫害识别的问题。 [方法] 利用 Ghost 技术将 2 个 Ghost Bottle Block 线性特征提取模块封装为 1 个 GB 模块, 代替 YOLOv5S 中前 7 个 CBL、CSP、SPP 非线性特征提取模块, 从而约简了 YOLOv5S 的网络参数, 减轻了网络体量。 [结果] 在保证虫害检测效果的前提下降低网络对计算硬件与训练样本的依赖。为了验证模型的有效性, 对水稻、玉米、棉花、马铃薯、苜蓿 5 种农作物的 12 类虫害进行识别与定位, 多类别平均精度 (mAP) 为 91.31%, 比 YOLOv5S 模型高出 2.56 个百分点。 [结论] 通过与 SSD、Faster-RCNN、YOLOv5S 模型对比发现, 本文提出的模型在 mAP、F1-score、精确率 (Precision)、召回率 (Recall) 4 个评价指标均占优势, 尤其在小目标、密集目标、与背景相似目标的检测方面表现突出。

**关键词:** 农作物; 虫害; YOLOv5S; 轻量级; 目标检测

中图分类号: S24; TP39

文献标志码: A

文章编号: 1000-2030(2024)05-1009-10

## A lightweight YOLOv5S crop pest target detection model

GUO Xiaoyan, YU Shuaiqing

(College of Information Science and Technology, Gansu Agricultural University, Lanzhou 730070, China)

**Abstract:** [Objectives] A light weight YOLOv5S crop pest target detection model was proposed to solve the problem of identifying crop pests, when the sample quantity was insufficient. [Methods] Two Ghost Bottle Block linear feature extraction modules were encapsulated into one GB module using Ghost technology, replacing the first seven CBL, CSP and SPP nonlinear feature extraction modules in YOLOv5S, which reduced the parameters and the volume of YOLOv5S. [Results] The network's dependence on computing hardware and training samples was reduced while ensuring the effectiveness of pest detection. In order to verify the effectiveness of the model, 12 types of pests were identified and located for 5 crops, including rice, corn, cotton, potatoes and alfalfa. The multi category mean average precision (mAP) was 91.31%, which was 2.5 percentage points higher than the YOLOv5S model. [Conclusions] By comparing with SSD, Faster RCNN and YOLOv5S, it was found that the model proposed in this paper had advantages in mAP, F1 score, precision and recall evaluation indicators, especially in the detection of small targets, dense targets and targets similar to the background.

**Keywords:** crops; pest infestation; YOLOv5S; lightweight; object detection

大面积虫害影响农作物的产量和质量, 高效、准确地识别与定位虫害是有效防治的前提。随着人工智能的发展, 越来越多的学者尝试利用深度学习技术<sup>[1-2]</sup>进行虫害检测与定位, 以提高农作物识别的准确性与效率。目标检测技术<sup>[3-5]</sup>是一种通过提取待识别图像特征, 再对待识别目标进行精准识别与定位的可视化深度学习技术<sup>[6]</sup>。目前, 以 Faster-RCNN<sup>[7]</sup>模型为代表的 Two-Stage 目标检测方法以及以 YOLO 系列<sup>[8-13]</sup>为代表的 One-Stage 目标检测方法在农作物虫害等目标检测识别问题中均广泛应用。

郭子豪等<sup>[14]</sup>提出了一种基于改进 Faster-RCNN 模型的节肢动物目标检测方法, 提高了复杂背景环境下节肢动物目标检测的准确率, 平均精度为 71.7%, 较原始模型提高 4.53%。王玉庆<sup>[15]</sup>利用 Faster R-CNN 模型建立茶叶病虫害图像检测模型实现了病虫害的精准定位, 准确率达 98.7%。Bari 等<sup>[16]</sup>在 Faster-RCNN 中引入 RPN 网络进行水稻稻瘟病、褐斑病以及健康叶片识别, 准确率分别为 98.09%、98.85% 和 99.25%。从以上研究中发现, Faster-RCNN 模型已在目标检测、农作物病虫害识别方面有较好的表现, 但

收稿日期: 2023-10-12

基金项目: 国家自然科学基金项目 (32360437); 甘肃农业大学青年导师基金 (QAU-QDFC-2021-18); 甘肃农业大学科技创新基金 (盛彤笙创新基金) (GSAU-STIS-2021-16)

\* 通信作者: 郭小燕, 教授, 博士, 硕导, 研究方向为智能信息处理与深度学习, E-mail: guoxy@gsau.edu.cn。

其作为 Two-Stage 方法的代表,对于待识别图像需要先生成先验框再对先验框进行卷积运算,因此识别速度较慢且实时性差。YOLO 系列作为 One-Stage 的代表,将待识别图像目标框的生成与特征提取合并为一步,因此识别速度较快,实时性较好。杨堃等<sup>[17]</sup>利用改进的 YOLO5-VE 进行植物虫害检测,效果良好。Kasper-Eulaers 等<sup>[18]</sup>发现 YOLOv5S 在冬季检测休息区的重型货车时有效。Wang 等<sup>[19]</sup>等提出一种基于通道修剪的 YOLOv5S 深度学习算法进行苹果小果实检测,召回率 (Recall)、精确率 (Precision)、F1-Score 和错误检测率分别为 87.6%、95.8%、91.5% 和 4.2%。刘郡等<sup>[20]</sup>提出了一种基于 YOLO 的卷积神经网络的番茄病虫害检测算法,对 8 类番茄病虫害进行检测的平均精度为 85.09%。

YOLO 系列目标检测技术具有在识别实时性方面的优势,近年来越来越多地被应用于图像目标检测、农作物虫害识别等方面<sup>[17-18]</sup>。其网络结构庞大,在模型训练过程中需要大量训练样本且耗费大量算力,这给在移动端、硬件水平有限、训练样本数量有限、样本多样性差的情况下进行虫害识别带来一定困难,因此研究利用普通计算设备且在有限样本下实现农作物虫害快速识别非常重要。

本文设计一个基于 One-Stage 的农作物虫害识别网络模型,通过结构调整与参数约简对 YOLOv5S 进行优化,利用 Ghost 技术将 2 个 Ghost Bottle Block 线性特征提取模块封装为 1 个 GB 模块,并用其代替 YOLOv5S 特征提取网络中前 7 个特征提取模块,实现了轻量级虫害目标检测。在试验中利用该模型进行水稻、玉米、棉花、马铃薯、苜蓿 5 种农作物 12 类常见虫害的识别,与 SSD、Faster-RCNN、YOLOv5S 对比,在多类别平均精度 (mAP)、F1-score、Precision、Recall 4 个评价指标均体现出一定优势,尤其在样本图像倾斜、小目标、密集目标、前景与背景相似目标的识别中表现突出。在训练样本数量受限、算力受限、硬件水平受限的情况下进行农作物虫害的实时识别时,该模型为设计轻量级模型提供了思路。

## 1 材料与方法

### 1.1 材料

采用 IP102 农作物虫害识别图像库,抽取水稻、玉米、棉花、马铃薯、苜蓿 5 种农作物的象甲、叶蝉、蚜虫、蝼蛄、叩甲、蚜虫成虫、白星花金龟、盲蝽、水疱甲虫、东方菜粉蝶、金针虫、蚜虫若虫 12 类常见虫害,共 16 965 张图像作为训练数据,随机抽取 80% 的数据作为训练集,10% 作为测试集,10% 作为验证集,数据如图 1 所示。

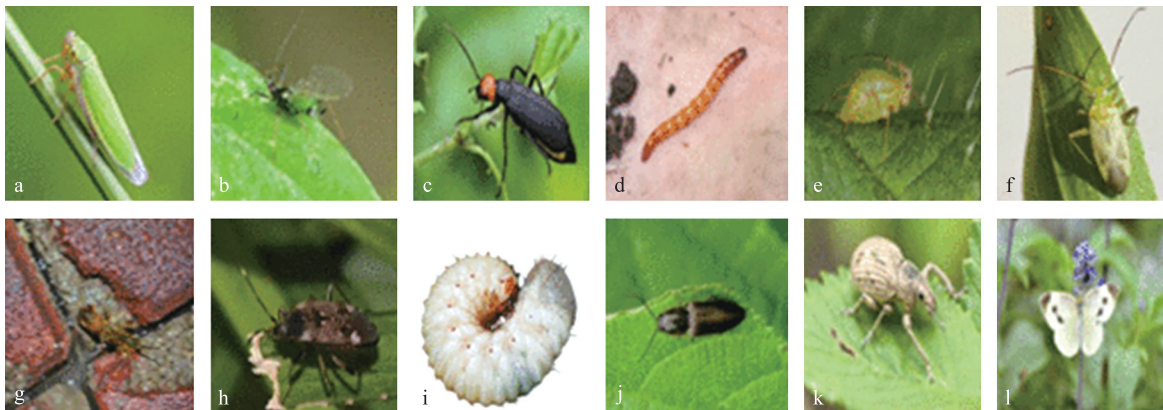


图 1 农作物害虫数据集

Fig. 1 Data set of crop pest

a. 叶蝉 Leafhopper; b. 白星花金龟 White star flower golden turtle; c. 水疱甲虫 Blister beetle; 象甲 Weevil; d. 蚜虫成虫 Aphid adults; e. 金针虫 Golden needle worm; f. 蚜虫若虫 Aphids (nymphs); g. 蝼蛄 Mole cricket; h. 盲蝽 Miridae; i. 蛴螬 Grubs; j. 叩甲 Percussion; k. 象甲 Weevil; l. 东方菜粉蝶 *Pieris orientalis*.

**1.1.1 数据增强** 在将样本图片输入网络模型前,首先进行数据增强以提升样本多样性,解决小目标与大目标识别效果不均衡的问题,从而提高网络的识别效率与泛化能力。从随机缩放、统一尺寸、随机剪裁、随机排布、图像拼接等方面进行数据增强。图 2 将 4 张图像融合为 1 张图片,从而将 1 个单目标检测问题转换为多目标检测问题。

**1.1.2 生成自适应锚框** 增强后的样本输入特征提取网络,根据样本标注的真值边界框 (ground truth bounding box) 采用 k-means<sup>[21-23]</sup> 聚类算法自适应生成先验锚框,从而加快识别效率。具体做法是迭代计

算每一个 Ground Truth 与中心点的交并比(intersection over union, IoU),选择距离最近的聚类中心点作为该类别,中心点的数量对应生成锚框的数量。图 3 为 1 个输入样本归一化后的分布和分别生成 5、6、7、8 个锚框时的聚类分布。

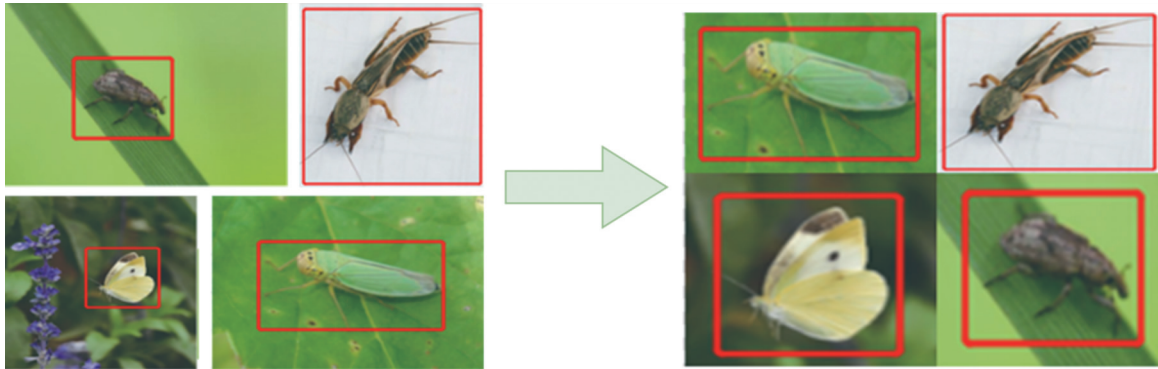


图 2 农作物害虫数据增强

Fig. 2 Data enhancement of crop pest

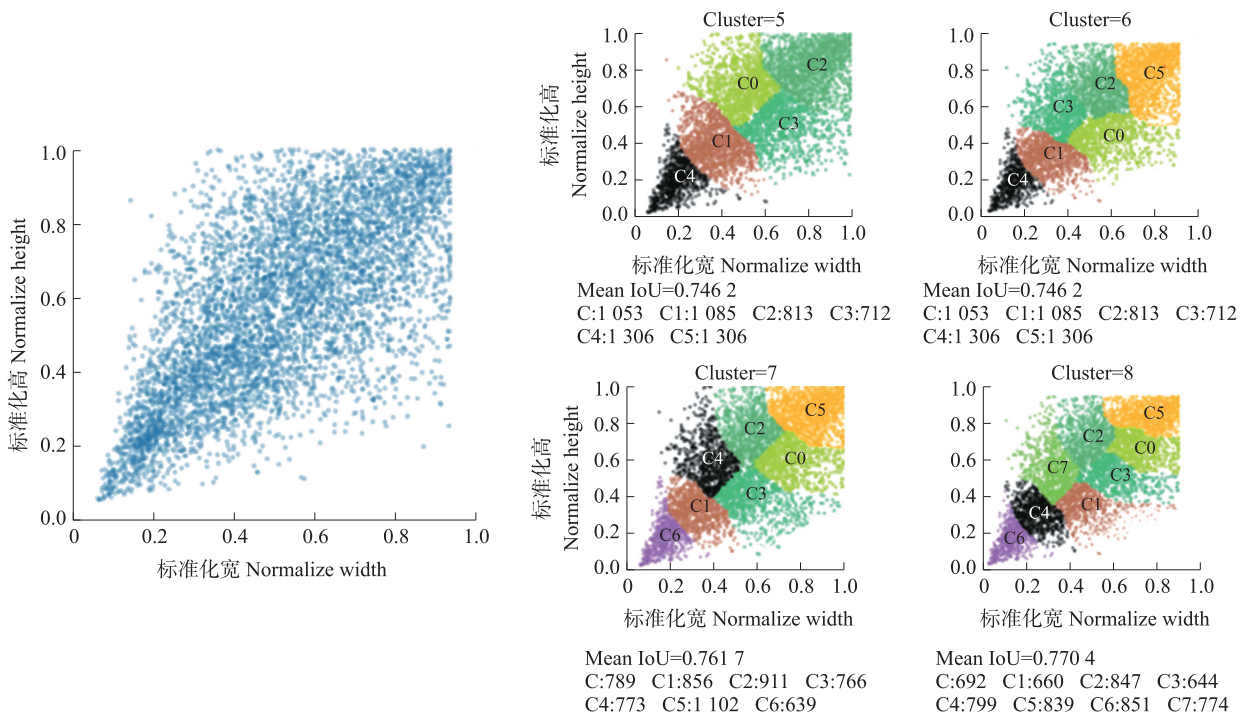


图 3 生成自适应锚框

Fig. 3 Generating adaptive anchor box

### 1.2 方法

**1.2.1 YOLOv5S 模型** YOLOv5S 虫害目标检测模型包括样本预处理、特征提取(Backbone)、特征融合(Neck)、预测出结果(Prediction)4 个部分,如图 4 所示。

**1.2.2 基于 YOLOv5S 的农作物虫害识别模型** 1) 模型结构 Ghost Net<sup>[24]</sup> 由华为诺亚方舟实验室在 CVPR2020(IEEE Conference on Computer Vision and Pattern Recognition,即 IEEE 国际计算机视觉与模式识别会议)中提出,采用线性卷积(只包含卷积操作)替代特征提取的部分非线性卷积(包含卷积、批归一化,ReLU)操作,用于消除网络特征提取层不必要的冗余,从而降低参数。将 2 个 Ghost 模块封装为 1 个 Ghost Bottle Block(GB),并用其替换 YOLOv5S 中前 7 个模块,从模型轻量化方面优化网络,如图 5 所示。

一幅 608×608×3 的输入图像经过特征提取网络、特征融合网络以及预测网络,生成维度为 54、尺寸分别为 19×19、38×38、76×76 的 3 种矩形框,分别拟合不同大小的农作物虫害目标,其中 54 代表每个预测框分别生成的 3 个 18 维的预测框,如图 6 所示。待识别目标有 13 类(12 类虫害值、1 类背景值),最后采取非极大抑制(non-maximum suppression,NMS)进行后处理,将置信度和 IoU 低于特定阈值的预测框舍弃,生

成最终的目标检测预测框。

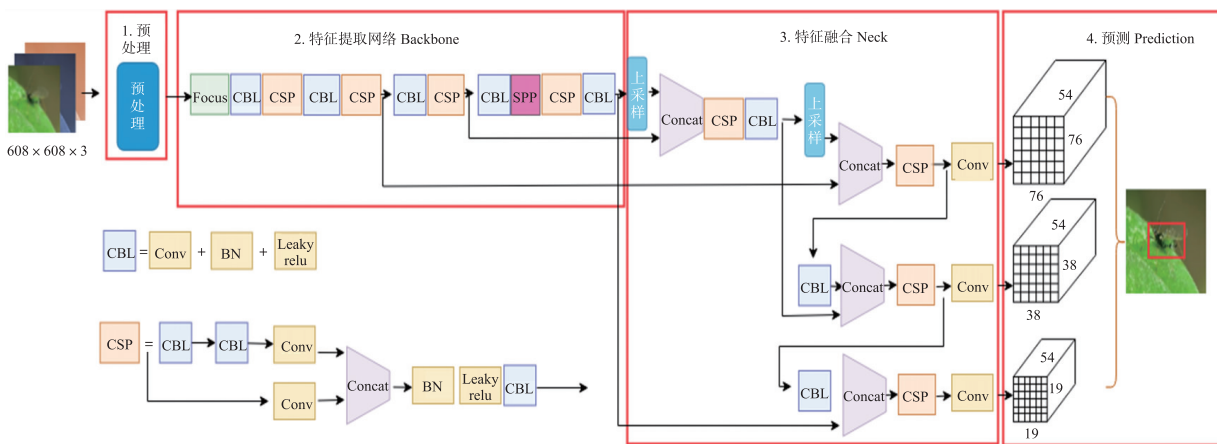


图 4 YOLOv5S 模型

Fig. 4 YOLOv5S model

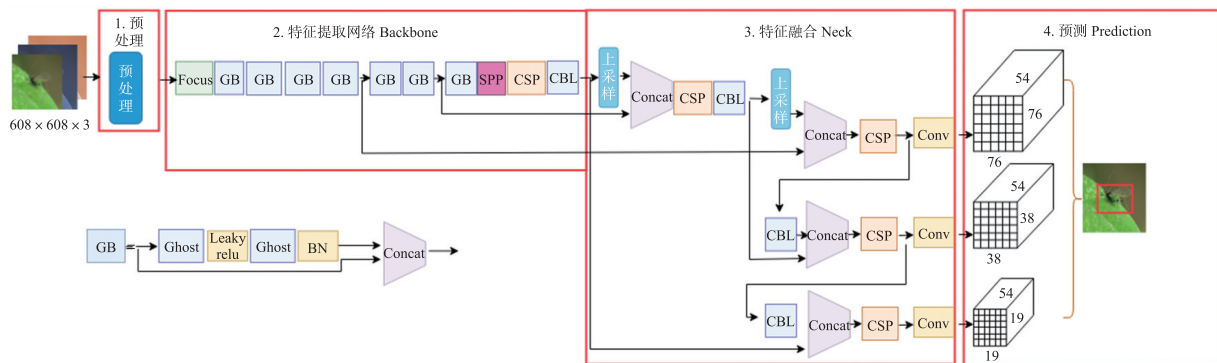


图 5 基于 YOLOv5S 的农作物虫害识别模型

Fig. 5 YOLOv5S crop pest identification model




图 6 输出向量

Fig. 6 Output vector

$X, Y$  代表预测框中心点坐标;  $W, H$  为预测框的宽度和高度;  $C$  表示预测框里含有检测目标的置信度; 类别表示在假定预测框中有目标的前提下, 属于某一种虫害的条件概率。  $X, Y$  represent the center point coordinates of the prediction box;  $W, H$  are the width and height of the prediction box;  $C$  represents the confidence level of the detection target contained in the prediction box; Category represents the conditional probability of belonging to a certain pest, assuming there is a target in the predicted box.

2) 模型评价 深层网络在大量卷积过程中产生的冗余计算影响网络效率, 耗费不必要的算力, 采用 Ghost 模块降低网络参数, 如图 7 所示。

非线性卷积计算量为  $c \times k \times k \times n \times H' \times W'$ , 其中  $k$  为非线性卷积核的尺寸。 Ghost 模块卷积需要经过 2 个阶段(图 7-b): 第 1 个阶段为非线性卷积, 生成  $m$  个特征图像; 第 2 个阶段为线性卷积, 对于  $m$  个特征图像的每一幅图像执行  $s$  步线性操作, 其中包括 1 次恒等映射与  $s-1$  次线性卷积  $(\phi_1, \phi_2, \dots, \phi_{s-1})$ , 分别生成  $1 \times m$  与  $(s-1) \times m$  个特征图, 最后将两次结果叠加 (Concat), 计算量为  $m \times k \times k \times n \times h' \times w' + (s-1) \times m \times h' \times w' \times d \times d$ , 其中,  $d$  为线性卷积核尺寸, 且  $m \times 1 + (s-1) \times m = n$ , 即  $m = s/n$ , Ghost 模块与普通卷积的理论压缩比如下:

$$p = \frac{m \times k \times k \times n \times h' \times w' + (s-1) \times m \times h' \times w' \times d \times d}{c \times k \times k \times n \times h' \times w'} = \frac{m \times k \times k \times n + (s-1) \times m \times d \times d}{c \times k \times k \times n} \quad (1)$$




图 7 CNN 非线性模块(a)与 Ghost 模块(b)

Fig.7 CNN nonlinear module(a) and Ghost module(b)

a. 大小为  $W \times H \times c$  的图像经过普通的非线性卷积生成  $H' \times W' \times n$  的图像。 $W, H$  分别代表输入图像的宽和高; $H' \times W'$  分别代表卷积后图像的宽和高; $c, n$  分别代表卷积前后图像的通道数。

a. The image with a size of  $W \times H \times c$  is subjected to ordinary nonlinear convolution to generate an image of  $H' \times W' \times n$ .  $W$  and  $H$  represent the width and height of the input image, respectively;  $H' \times W'$  represent the width and height of the convolved image, respectively;  $c, n$  represent the number of channels in the image before and after convolution.

假定  $k = d$ , 且  $s \leq c$ , 则:

$$p = \frac{s+c-1}{s \times c} \approx \frac{1}{s} \quad (2)$$

式中: $s > 1$ 。

表 1 分别列举了 YOLOv5S 网络与本文网络不同模块的网络参数量,其中 YOLOv5S 为  $2.65 \times 10^7$ , 本文网络为  $5.38 \times 10^6$ , 再分别与 2 个网络相同模块的参数量相加, 则 2 个网络的参数量分别为  $8.78 \times 10^7$  与  $6.66 \times 10^7$ , 因此实际参数压缩比为 0.75。

表 1 网络参数量对比

Table 1 Comparison of network parameters number

序号 No.	YOLOv5		本文网络 Network in this paper	
	模型 Module	参数量 Number of parameters	模型 Module	参数量 Number of parameters
1	Focus	8 800	Focus	8 800
2	CBL	115 520	Ghost model	27 960
3	CSP	309 120	Ghost model	65 120
4	CBL	461 440	Ghost model	100 720
5	CSP	3 285 760	Ghost model	697 920
6	CBL	1 844 480	Ghost model	380 640
7	CSP	13 125 120	Ghost model	2 624 640
8	CBL	7 375 360	Ghost model	1 478 080
合计 Total		$2.65 \times 10^7$	$5.38 \times 10^6$	
相同结构参数量 Same structural parameters number		$6.13 \times 10^7$	$6.13 \times 10^7$	
总参数量 Total number of parameters		$8.78 \times 10^7$	$6.66 \times 10^7$	

## 2 结果与分析

### 2.1 试验环境

硬件环境为配置 NVIDIA Ge Force GTX 1080Ti 显卡的 GPU 图像工作站;软件环境为 Ubuntu18.04 操作系统、PyTorch 深度学习框架以及 Python 语言。模型训练采用流水线方式,使用随机梯度下降方法优化整个网络模型。网络模型运行 120 个 epoch,选择自适应时刻估计方法(adaptive moment estimation)作为优化器,设置动量因子为 0.93,权重衰减为 0.000 1,学习率为 0.11。

### 2.2 可视结果

从混淆矩阵(图 8)发现本文网络识别效果较好,其中白星花金龟、蝼蛄以及蛴螬识别率为 100%,叶蝉、盲蝽识别率也较高,分别为 95%和 94%,蚜虫成虫的识别率偏低,为 78%,这与样本质量以及待识别目标的大小与密集程度有关。12 类病害平均识别率为 91%。

目标可视定位检测结果如图 9 所示,图 9-a 为 12 类农作物虫害的目标检测识别可视结果,图 9-b 为叶蝉、蝼蛄和对白星花金龟样本进行倾斜测试时的检测识别效果。根据端正样本以及倾斜样本的识别结果,本文网络具有较好的识别力与鲁棒性。




图 8 混淆矩阵

Fig. 8 Confusion matrix

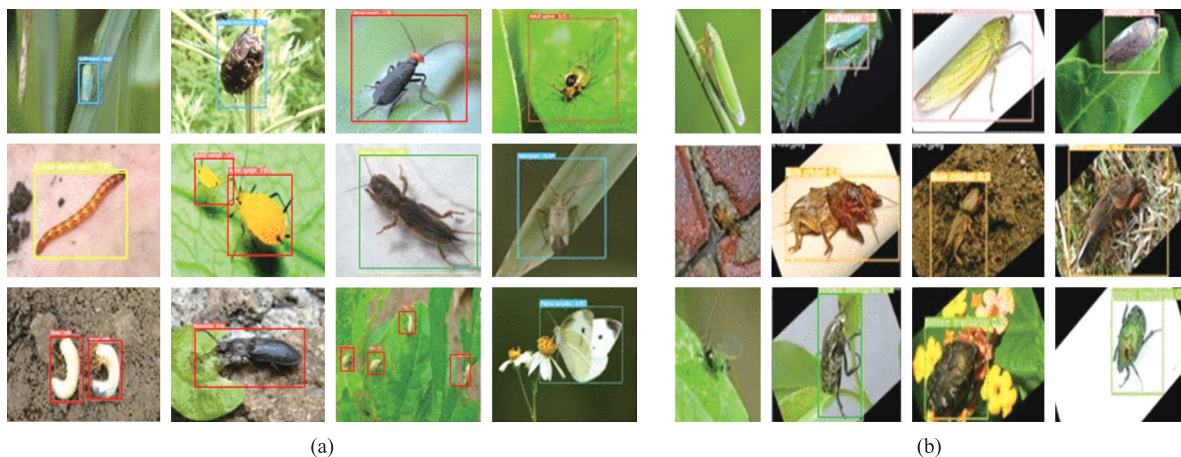


图 9 可视识别 (a) 和旋转测试 (b) 结果

Fig. 9 Visual recognition (a) and rotation test (b) results

2.3 对比试验

2.3.1 模型对比 从表 2 可以看出:单目标多框检测(SSD)模型参数量最小,为  $4.7 \times 10^6$ ,然而其单张图片处理时间为 5 490 s,用时较长;快速区域卷积网络(Faster-RCNN)模型大小为  $15 \times 10^6$ ,识别时间为 145 s;YOLOv5S 模型参数量最多,为  $66 \times 10^6$ ,而其识别速度与 Faster-RCNN 和 SSD 相比有较大提高;本文网络是在 YOLOv5S 基础上进行约简,模型参数量为  $49.5 \times 10^6$ ,识别时间最短,为 19 ms。

2.3.2 结果对比 为了进一步评估网络性能,分别采用 mAP、Precision、F1-score 作为评价指标,将 Faster-RCNN、SSD<sup>[25-26]</sup>、YOLOv5S 在相同试验环境下与本文网络进行对比,见表 3。从平均精度(AP)来看,4 种方法对象甲成虫的识别精确率都较低,叶蝉的识别精确率普遍较高,这可能与其辨识度、样本数据质量、待识别目标的大小、待识别目标密集程度有关。Faster-RCNN、SSD 和 YOLOv5S 的多类平均精度(mAP)分别为 80.83%、76.31%和 88.75%,而本文网络最高,为 91.31%。这说明通过 Ghost 约简 YOLOv5S 网络后,减小了参数数量,实现了网络轻量化,同时提高了模型对于农作物虫害的识别效率。

表 2 模型对比

Table 2 Model comparison

识别模型 Identification model	识别准确率/% Identification accuracy	模型参数量 Model parameter number	单张图片识别时间/ms Single image recognition time
Faster-RCNN	80.83	15×10 <sup>6</sup>	145
SSD	76.31	4.7×10 <sup>6</sup>	5 490
YOLOv5	88.75	66×10 <sup>6</sup>	34
本文网络 Network of this paper	91.3	49.5×10 <sup>6</sup>	19

表 3 模型平均精确率结果对比

Table 3 Comparison of average precision (AP) results of model

农作物类别 Crop category	虫害类别 Pest Category	Faster-RCNN	SSD	YOLOv5	本文网络 Network of this paper
水稻 Rice	叶蝉 Leafhopper	93.45	87.22	97.16	97.41
	白星花金龟 White star flower golden turtle	83.23	82.23	90.05	93.43
	水疱甲虫 Blister beetle	74.16	71.12	85.12	85.49
玉米 Corn	蚜虫成虫 Aphid adults	68.16	62.35	87.12	95.46
	金针虫 Golden needle worm	83.17	74.33	91.03	93.44
	蚜虫若虫 Aphids nymphs	62.36	58.22	81.18	82.35
棉花 Cotton	蝼蛄 Mole cricket	93.15	91.19	98.01	100
	盲蝽 Miridae	79.16	77.12	86.12	85.44
马铃薯 Potato	蛴螬 Crubs	95.32	91.13	96.03	96.39
	叩甲 Percussion	72.23	66.15	83.03	85.39
苜蓿 Alfalfa	象甲 Weevil	73.45	67.35	77.02	82.47
	东方菜粉蝶 Pieris orientalis	92.16	87.25	93.12	98.39
多类平均精度 mAP		80.83	76.31	88.75	91.31

从图 10 可知:本文网络的召回率为 0.62 时,模型精确率小幅度下降;当召回率不断增加时,精确率基本保持恒定,证明本文模型召回率、精确率 2 个评价指标具有较高程度的一致性,并且均有较高的取值。相比 SSD 模型,召回率提高时,精确率急剧变化,这说明 2 个评价指标在 SSD 模型中很难兼得。YOLOv5S 网络随着召回率的变化,虽然精确率也有一定程度的波动,且召回率、精确率 2 个指标也表现出较强的一致性,与本文模型相比在单个指标的表现上有一定差距。Faster-RCNN 模型的召回率在一定范围变化时,精确率也有较明显的波动。当 Score 阈值取 0.5 时,随着精确率的变化,F1-Score 基本保持恒定,并且保持较高的取值。然而,YOLOv5S、SSD、Faster-RCNN 均有不同程度的波动,证明在样本量有限的情况下适当约简网络可以提升识别效果。

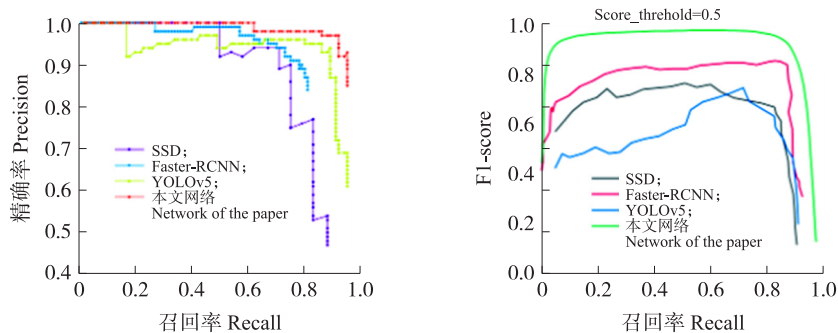


图 10 联合评价  
Fig. 10 Joint evaluation

从 4 个损失函数(Loss)与 mAP 的迭代曲线(图 11)可知,Faster-RCNN 的 Loss 曲线在迭代过程中出现剧烈的上下波动,SSD 网络也有小范围波动,相比之下,YOLOv5S 与本文网络 Loss 曲线相对平坦,然而 YOLOv5S 网络在迭代 5 000 次后,Loss 曲线基本恒定,而本文网络在迭代 11 000 后还有一个较明显的下降,在迭代结束时本文网络和 YOLOv5S 相比收敛于一个更小的取值。SSD 网络的平均识别率在迭代 9 000 次时基本稳定,相比之下,Faster-RCNN 的 mAP 曲线随着迭代次数的增加一直呈上升趋势,在迭代 16 000 次时趋于稳定,YOLOv5S 的 mAP 曲线也相对稳定,本文网络在迭代 10 000 次前,mAP 曲线对迭代

次数敏感,而 10 000 次后相对稳定。根据 4 种网络的 Loss 曲线和 mAP 曲线,本文网络具有较明显优势,同时网络对于迭代次数保持敏感。

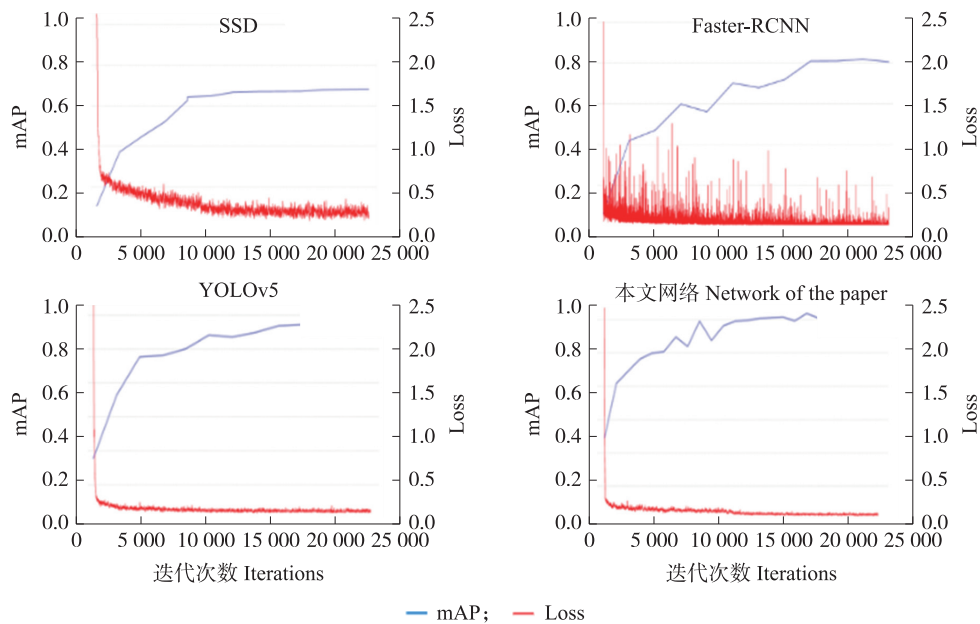


图 11 损失函数

Fig. 11 Loss function

为了进一步验证模型在待识别目标与背景颜色纹理相近、尺寸较小且密集出现的情况下本文模型的识别效果,设计小目标试验(图 12,表 4)。选用待识别虫害与和叶面背景相似且目标尺寸小、个体密集的蚜虫若虫图像进行对比试验,共有 16 只蚜虫,SSD 和 Faster-RCNN 均检测出 7 只目标蚜虫,其中背景相似的 5 只蚜虫以及个体极小的 4 只蚜虫均漏检。YOLOv5S 共检测出 13 只,漏检 3 只,均为背景相似蚜虫。




图 12 小目标虫害识别对比

Fig. 12 Comparison of small target pest identification

本文网络检测出全部 16 只蚜虫,识别率为 100%。在其他密集目标、小目标、与背景相似目标试验中均有类似结果(表 2)。YOLO 模型加入了多尺度的特征图识别,对于小目标的检测比 Faster-RCNN 等其他模型识别更占优势,并且本网络模型在 YOLOv5S 模型加了 Ghost 模块使得模型变得更加轻量化,在数据量有限且少量数据集的条件下更加适合检测。

表 4 小目标试验对比

Table 4 Comparison of small target tests

识别模型 Identification model	mAP/%	模型参数 Number of parameters
Faster-RCNN	76.14	15×10 <sup>6</sup>
SSD	76.31	4.7×10 <sup>6</sup>
YOLOv5	79.14	66×10 <sup>6</sup>
本文网络 Network of this paper	99.6	49.5×10 <sup>6</sup>

### 3 结论

虫害影响农作物的产量与质量,利用目标检测技术进行识别时需要大量的高质量、多样化的虫害样本进行模型的长时间训练,这对于计算硬件设备、训练样本都具有较高的要求。为了解决在有限计算资源、有限样本条件下农作物虫害识别的实时性问题,本文在 YOLOv5S 模型的基础上将 Focus、CBL、CSP、SPP

等非线性卷积模块替换为 Ghost Bottle Block 线性卷积模块,约简网络参数,使得网络更加轻量化,对水稻、玉米、棉花、马铃薯、苜蓿 5 种农作物 12 类常见虫害进行分类识别,并且对比 YOLOv5S、SSD、Faster-RCNN 目标检测模型。

随着目标检测网络层数的增加,传统的 CNN 部分会产生大量的冗余计算以及冗余特征图,这些冗余特征不仅会对网络造成负担,影响识别速度,而且对于识别效果造成负面影响,因此采用线性卷积的方式代替传统的非线性卷积操作可以约简网络参数,可以使网络更加轻量化,从而节约计算资源,提升识别效率,降低网络对训练样本数量的要求。通过对比试验发现,约简后的网络不仅不会影响识别效果,而且在 mAP、F1-score、Precision、Recall 4 个指标上都占有一定优势,这说明利用深度学习技术进行农作物虫害识别并解决计算资源缺乏、样本量少、实时性差等问题时,提升算力、增加样本数量并不是唯一的途径,进行适当的网络约简也是一个有效选择。另外,小体量的虫害检测模型,对于模型的部署与产品化同样带来一定的便利。

#### 参考文献 References:

- [1] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [2] Kamilaris A, Prenafeta-Boldó F X. Deep learning in agriculture: a survey[J]. Computers and Electronics in Agriculture, 2018, 147: 70-90.
- [3] 赵世达, 王树才, 郝广钊, 等. 基于单阶段目标检测算法的羊肉多分体实时分类检测[J]. 农业机械学报, 2022, 53(3): 400-411.  
Zhao S D, Wang S C, Hao G Z, et al. Mutton multipartite real-time classification and detection based on single-stage object detection algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(3): 400-411 (in Chinese with English abstract).
- [4] 杨军奇, 冯全, 王书志, 等. 基于改进 YOLOv4 的田间密集小目标检测方法[J]. 东北农业大学学报, 2022, 53(5): 69-79.  
Yang J Q, Feng Q, Wang S Z, et al. Method for detection of farmland dense small target based on improved YOLOv4[J]. Journal of Northeast Agricultural University, 2022, 53(5): 69-79 (in Chinese with English abstract).
- [5] 宋怀波, 高钰莹, 何东健. 果实目标深度学习识别技术研究进展[J]. 农业机械学报, 2023, 54(1): 1-19.  
Song H B, Shang Y Y, He D J. Review on deep learning technology for fruit target recognition[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(1): 1-19 (in Chinese with English abstract).
- [6] 刘斌, 贾润昌, 朱先语, 等. 面向移动端的苹果叶部病虫害轻量级识别模型[J]. 农业工程学报, 2022, 38(6): 130-139.  
Liu B, Jia R C, Zhu X Y, et al. Lightweight identification model for apple leaf diseases and pests based on mobile terminals[J]. Transactions of the Chinese Society of Agricultural Engineering, 2022, 38(6): 130-139 (in Chinese with English abstract).
- [7] Ren S, He K, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137-1149.
- [8] Redmon J, Farhadi A. YOLO9000: better, faster, stronger[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu: IEEE, 2017: 6517-6525.
- [9] 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.
- [10] Han X, Chang J, Wang K. Real-time object detection based on YOLO-v2 for tiny vehicle object[J]. Procedia Computer Science, 2021, 183: 61-72.
- [11] Redmon J, Farhadi A. YOLOv3: an incremental improvement[EB/OL]. [2023-06-10]. <http://arxiv.org/abs/1804.02767>.
- [12] Bochkovskiy A, Wang C Y, Liao H Y M. YOLOv4: optimal speed and accuracy of object detection[EB/OL]. [2023-09-10]. <http://arxiv.org/abs/2004.10934>.
- [13] Benjumea A, Teeti I, Cuzzolin F, et al. YOLO-Z: improving small object detection in YOLOv5 for autonomous vehicles[EB/OL]. [2023-08-20]. <http://arxiv.org/abs/2112.11798>.
- [14] 郭子豪, 董乐乐, 曲志坚. 基于改进 Faster RCNN 的节肢动物目标检测方法[J]. 计算机应用, 2023, 43(1): 88-97.  
Guo Z H, Dong L L, Qu Z J. Arthropod object detection method based on improved Faster RCNN[J]. Journal of Computer Applications, 2023, 43(1): 88-97 (in Chinese with English abstract).
- [15] 王玉庆. 基于无人机的茶叶病虫害防治系统研究[D]. 徐州: 中国矿业大学, 2019.  
Wang Y Q. Research on tea pest control system based on UAV[D]. Xuzhou: China University of Mining and Technology, 2019 (in Chinese with English abstract).
- [16] Bari B S, Islam M N, Rashid M, et al. A real-time approach of diagnosing rice leaf disease using deep learning-based faster R-CNN framework[J]. PeerJ Computer Science, 2021, 7: e432.
- [17] 杨堃, 范习健, 薄维昊, 等. 基于视觉加强注意力模型的植物病虫害检测[J]. 南京林业大学学报(自然科学版), 2023, 47(3): 11-18.  
Yang K, Fan X J, Bo W H, et al. Plant disease and pest detection based on visual attention enhancement[J]. Journal of Nanjing Forestry University (Natural Sciences Edition), 2023, 47(3): 11-18 (in Chinese with English abstract).

- [18] Kasper-Eulaers M, Hahn N, Berger S, et al. Short communication: detecting heavy goods vehicles in rest areas in winter conditions using YOLOv5[J]. *Algorithms*, 2021, 14(4): 114.
- [19] Wang Z P, Jin L Y, 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.
- [20] 刘君, 王学伟. 基于 YOLO 的番茄病虫害识别算法[J]. *中国瓜菜*, 2020, 33(9): 18-22, 38.  
Liu J, Wang X W. Tomato disease and pest detection algorithm based on YOLO convolutional neural network[J]. *China Cucurbits and Vegetables*, 2020, 33(9): 18-22, 38 (in Chinese with English abstract).
- [21] 张志勇, 路小娟, 孔令刚, 等. K-means 结合 RBF 神经网络预测线性菲涅尔集热回路出口熔盐温度[J]. *农业工程学报*, 2021, 37(3): 213-222.  
Zhang Z Y, Lu X J, Kong L G, et al. Predicting molten salt temperature at the circuit outlet of linear Fresnel heat collector using K-means combined with RBF neural network[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2021, 37(3): 213-222 (in Chinese with English abstract).
- [22] 罗兴隆, 贺兴时, 杨新社. 二分 k-means 锚点提取的快速谱聚类[J]. *计算机工程与应用*, 2023, 59(16): 74-81.  
Luo X L, He X S, Yang X S. Fast spectral clustering based on anchor point extraction with bisecting k-means[J]. *Computer Engineering and Applications*, 2023, 59(16): 74-81 (in Chinese with English abstract).
- [23] 康玮, 曹文庚, 徐丽霞, 等. 基于 K-means 聚类与泰森去丛聚的代表性地下水位计算方法[J]. *南水北调与水利科技*, 2022, 20(5): 876-885.  
Kang W, Cao W G, Xu L X, et al. Calculation method of representative groundwater level based on K-means cluster analysis and Thiessen de-clustering[J]. *South-to-North Water Transfers and Water Science & Technology*, 2022, 20(5): 876-885 (in Chinese).
- [24] Han K, Wang Y H, Tian Q, et al. GhostNet: more features from cheap operations[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE, 2020: 1577-1586.
- [25] Lu X C, Ji J, Xing Z Q, et al. Attention and feature fusion SSD for remote sensing object detection[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 5501309.
- [26] Loraksa C, Mongkolsomlit S, Nimsuk N, et al. Development of the osteosarcoma lung nodules detection model based on SSD-VGG16 and competency comparing with traditional method[J]. *IEEE Access*, 2022, 10: 65496-65506.

责任编辑: 刘怡辰