

基于改进 Faster-RCNN 模型的粘虫板图像昆虫识别与计数

张银松 赵银娣^{*} 袁慕策

(中国矿业大学 环境与测绘学院,江苏 徐州 221116)

摘要 针对传统机器学习采用人工提取特征方法时,由于人为主观性而影响昆虫识别效果与计数准确性的
问题,采用图像特征自动提取方法,将深度学习目标检测模型引入昆虫的识别与计数领域,对 Faster-RCNN 目标检测
模型进行改进:针对昆虫体积小,图像分辨率较低的特点,用网络深度更深,运算量更小的深度残差网络
(ResNet50)代替原来的 VGG16,以提取更加丰富的特征;针对部分昆虫密集的特点,用 Soft-NMS 算法代替传统的
非极大值抑制(NMS)算法,以减少密集区域的漏检。结果表明:改进后 Faster-RCNN 模型的检测准确率达到
90.7%,较未改进的 Faster-RCNN 模型提高了 4.2%,可以运用于昆虫的分类计数。利用深度学习目标检测模型
进行昆虫识别与计数较传统的昆虫识别与计数方法更加方便,能够将昆虫的识别、定位和计数融为一体。

关键词 昆虫识别; 昆虫计数; Faster-RCNN; 残差网络; Soft-NMS

中图分类号 S24

文章编号 1007-4333(2019)05-0115-08

文献标志码 A

Insect identification and counting based on an improved Faster-RCNN model of the sticky board image

ZHANG Yinsong, ZHAO Yindi*, YUAN Muce

(School of Environment and Surveying, China University of Mining and Technology, Xuzhou 221116, China)

Abstract In view of the traditional machine learning using artificial extraction feature method, due to the subjectivity of
humans affecting the effect of insect recognition and the accuracy of counting, this study uses the automatic extraction of
image features and introduces the deep learning target detection model into insect recognition. Compared with the
counting field, the Faster-RCNN target detection model is improved: In view of the small insect size and low image
resolution, the deep residual network (ResNet50) with deeper network depth and smaller computational capacity is
used rather than the original VGG16. To extract more abundant features. Because of the high density of some insects, the
Soft-NMS algorithm is used to replace the traditional non-maximum value suppression (NMS) algorithm in order to
reduce the missed detection in dense areas. The results show that the improved Faster-RCNN model has an accuracy of
90.7%, which is 4.2% higher than that of the unmodified Faster-RCNN model, and can be applied to the classification
and counting of insects. The use of deep learning target detection model for insect identification and counting is more
convenient than traditional insect identification and counting methods. It can integrate insect identification, localization
and counting.

Keywords insect identification; insect count; Faster-RCNN; ResNet; Soft-NMS

昆虫识别与计数是农业虫害监测和预报的基
础^[1]。传统的昆虫识别方法主要依靠人眼观测昆虫
的外部形状和颜色特征,与已有准确记录的模式标

本进行对照鉴别;昆虫计数主要依靠人工计数^[2]。
这种依靠人工识别与计数昆虫的方法存在劳动强度
大、效率低、实时性差等问题。近年来,农业害虫发

收稿日期: 2018-06-30

基金项目: 徐州市重点研发项目(KC17055)

第一作者: 张银松,硕士研究生,E-mail:2321809315@qq.com

通讯作者: 赵银娣,副教授,博士,主要从事遥感数据处理,模式识别研究,E-mail:zhaoyd@cumt.edu.cn

生次数频繁,且影响范围大,而我国农民植保知识缺乏不能满足当前虫害监测的需求。

随着机器视觉、图像处理技术和模式识别技术的发展,对象识别技术得到了广泛研究和应用,如人脸识别,指纹识别等,该技术同样适用昆虫的识别。基于图像的昆虫识别与计数省时省力,已经成为研究昆虫识别与计数的热点,其识别和计数步骤包括:昆虫图像的采集和预处理、昆虫特征的提取和优化、模式识别和计数4块^[2]。特征提取是昆虫图像识别和计数的基础,早期用于昆虫识别的特征主要是昆虫图像的全局特征,如灰度直方图^[3-4]、颜色特征^[5-6]、纹理特征^[7]等,这类特征虽然易于提取,但是对于背景复杂的图像,基于全局属性的表达难有作为^[8];近些年随着计算机技术的发展,此类研究转向以局部图像特征为核心而设计的表达框架,如视觉词袋框架^[9]等,将多种特征融合,然后选择最优分类器作为输入。目前在试验研究中使用的昆虫计数方法主要是将昆虫从背景图像中分割出来,然后进行计数。为了使昆虫能有效的从背景里分割出来,要求昆虫与背景颜色有较大的差异且背景颜色均匀单调,同时要求拍照时为避免反光影响计数,尽量不要使用闪光灯等照明装置,这就有可能导致光线不足而影响分割;且这种方法由于外界环境的复杂性,目前处于实验室研究阶段。

运用人工提取特征进行昆虫识别然后进行分割计数的方法虽然取得了一定的成果,但存在一定的局限性,在昆虫特征提取上,需要人为选取昆虫特征,人为主观性会影响识别效果;在计数上,昆虫分割过程中,由于光线不足、昆虫粘黏等因素的影响,产生的一些孤立点,无关小区域等会影响计数的准

确性;并且这种方法目前只应用于蔬菜害虫的计数,对于田间害虫由于其外界环境原因还在试验阶段。2006年提出的深度学习^[10],凭借其自动提取特征的优势,极大的促进了机器学习的发展。其中卷积神经网络(Convolutional Neural Network,CNN)在图像识别上的应用尤为广泛^[11-14],而且由CNN发展而来的目标检测框架,如Faster-RCNN^[15]、YOLO^[16]、SSD^[17]等,在识别的基础上实现目标的定位,为计数提供了基础,目前用目标检测模型已实现了人群计数^[18]和细胞计数^[19]。由于在识别过程中,卷积神经网络可自动提取多种特征,一定程度上降低了人工提取特征对图像质量如光线强度的要求,另外目标检测模型使识别和定位融合在一个网络,避免了目标与背景分离时对背景图像的要求。本研究尝试利用Faster-RCNN目标检测模型对粘虫板昆虫图像进行检测识别,并在识别的基础上实现分类计数。由于粘虫板采集的昆虫图像具有目标小、部分昆虫密集粘黏等特点,故影响识别效果。本研究拟在Faster-RCNN目标检测模型的基础上进行改进,旨在训练出适合昆虫识别与计数的模型,以期达到与人眼计数准确性相近的效果。

1 材料与方法

1.1 数据来源与处理

本试验数据根据黄板诱虫原理^[20-21]由野外利用粘虫板采集获得,再利用高清相机对粘虫板进行拍照,获取包含昆虫的粘虫板彩色图像;由于野外采集的昆虫种类较多,而大部分昆虫数量较少,本试验选取数量最多的2类昆虫(蚜虫和潜叶蝇)作为研究对象(图1)。利用相机拍摄的原图大小为5 186×3 456像素,训练和测试的数据集来自对整幅粘虫板

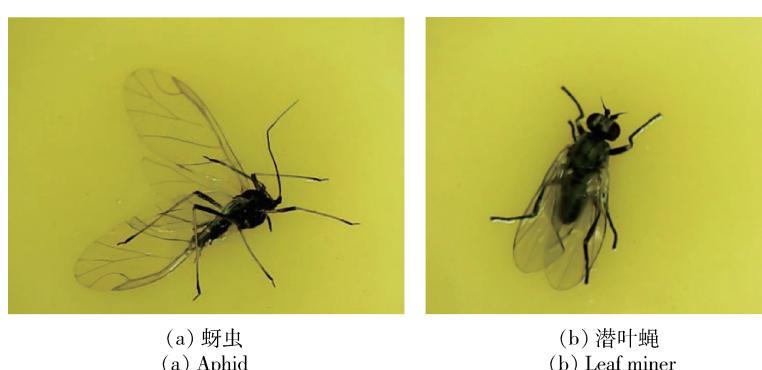


图1 试验研究对象蚜虫和潜叶蝇

Fig. 1 Experimental study objects aphid and leaf miner

的抠图,由于 Faster-RCNN 模型对输入图像没有限制,所以可以抠取任何尺寸包含昆虫的图像,包括单虫图像和多虫图像。其中 920 幅作为训练样本,307 幅作为测试样本。由于深度学习所需的样本量比较大,往往需要给图像增加头文件进行管理,即 xml 文件,xml 文件中包含图像的名称、标注类别、图像尺寸等信息。

1.2 Faster-RCNN 原理及改进

Faster-RCNN 将目标检测的 4 个基本步骤(候选区域生成、特征提取、分类和位置修正)统一到一个深度网络框架之内。其基本流程如下:待检测图片经过一个 RPN 网络,生成候选区域,由于 RPN 网络生成的候选区域检测框具有高度的重叠,用

NMS 算法进行抑制;之后利用 Fast-RCNN 网络对候选区域进行检测,其中 Fast-RCNN 检测网络中包含一个 CNN 特征提取网络,然后通过 softmax 回归算法对目标进行分类,并通过多任务损失边框回归算法,得到检测框边界的坐标。

本研究在 Faster-RCNN 目标检测模型的基础上进行改进:针对昆虫体积小,图像分辨率较低的特点,用网络深度更深,运算量更小的深度残差网络(ResNet)^[22]代替原来的 VGG16^[23] 网络,以提取更加丰富的特征;针对部分昆虫密集的特点,用 Soft-NMS 算法代替传统的 NMS 算法,以减少密集区域的漏检。Faster-RCNN 模型架构图及改进后的结构见图 2。

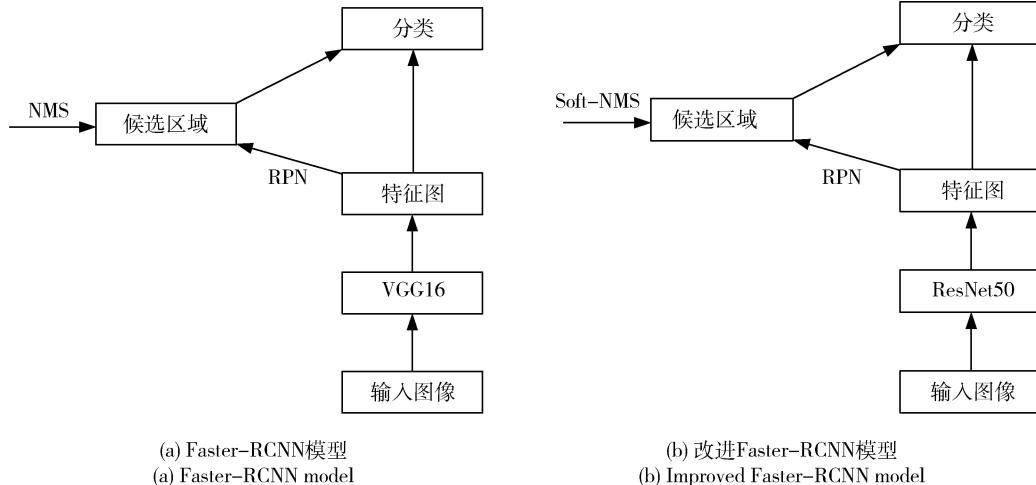


图 2 Faster-RCNN 模型和改进的 Faster-RCNN 模型结构图

Fig. 2 Faster-RCNN model structure and improved model design of Faster-RCNN

1.2.1 Soft-NMS^[24] 算法

NMS 是目标检测的重要部分。NMS 首先将所有检测框的得分进行排序找出最大得分的检测框 M ,然后计算所有的检测框与 M 的重叠度(IOU),如果 IOU 大于预先设定的阈值,则此检测框被抑制。在 Faster-RCNN 中因为 RPN 网络生成的检测框具有高度的重叠,为了较少冗余,同样使用了 NMS 方法对检测框进行后处理。IOU 为 2 个检测框 A 、 B 的重叠度,计算公式为:

$$\text{IOU} = (A \cap B) / (A \cup B) \quad (1)$$

即检测框 A 、 B 重叠的面积占 A 、 B 并集的面积比例:

$$\text{IOU} = S_I / (S_A + S_B - S_I) \quad (2)$$

式中: S_A 为检测框 A 的面积, S_B 为检测框 B 的

面积, S_I 为检测框 A 、 B 重叠区域的面积。传统的 NMS 处理方法可以通过以下分数重置函数表达:

$$S_i = \begin{cases} S_i & \text{IOU}(M, b_i) < N_t \\ 0 & \text{IOU}(M, b_i) \geq N_t \end{cases} \quad (3)$$

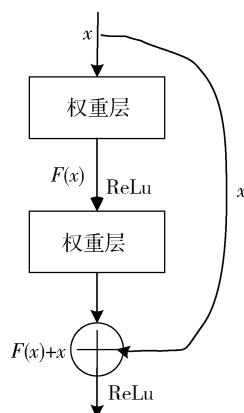
式中: S_i 为第 i 个检测框的得分; M 为得分最大的检测框; b 为检测框集合; b_i 为 b 集合中第 i 个检测框; N_t 为自设定的一个阈值。在式(3)中, NMS 采用了硬阈值判断相邻阈值是否保留。这种方法的一大缺点是当检测框 b_i 包含于 M 的物体时,在检测阈值较低的情况下,该物体将会错过检测。而 Soft-NMS 通过衰减与检测框 M 有重叠的相邻检测框的检测分数是对 NMS 的有效改进。

Soft-NMS 分数重置函数表示为:

$$S_i = \begin{cases} S_i & \text{IOU}(M, b_i) < N_t \\ S_i(1 - \text{IOU}(M, b_i)) & \text{IOU}(M, b_i) \geq N_t \end{cases} \quad (4)$$

1.2.2 ResNet

随着网络的加深,出现了训练集准确率下降的现象,而这一情况并不是由于过拟合等原因而造成的。针对这一问题,ResNet 网络于 2015 年首次提出,之后检测、分割和识别等领域都纷纷使用 ResNet 网络。ResNet 包括 ResNet50、ResNet101 和 ResNet152 网络等,本研究用的是 ResNet50 网络,主要思想是在标准的前馈神经网络上,加一个跳跃绕过一些层的连接,每绕过一层就产生一个残差块(图 3)。



x 为输入, $F(x)$ 为残差映射, ReLu 为激活函数。

x is the input; $F(x)$ is the residual map; ReLu is the activation function.

图 3 ResNet 残差块结构图

Fig. 3 Residual block structure of ResNet

残差块可定义为:

$$y = F(x, \{W_i\}) + x \quad (5)$$

式中: x, y 为输入和输出, $F(x, \{W_i\})$ 为学习到的残差映射, W_i 为第 i 层的权重。若包含 2 层(图 3), 则:

$$F = W_2 \sigma(W_1 x) \quad (6)$$

式中 σ 为非线性函数 relu。

2 结果与分析

2.1 试验环境

本试验采用 caffe 作为深度学习框架使用 GPU 对训练过程进行加速,其使用的硬件配置是 i5 处理器、16 G 的内存、NVIDIA GTX1060 的显卡;软件环境是 Ubuntu14.04 系统, python2.7, GPU 加速库采用 CUDA8.0 和 CUDNN5.1。

2.2 识别结果

本试验在 Faster-RCNN 目标检测模型的基础上,主要进行了 2 方面的改进:1) 使用 ResNet 网络作为特征提取网络来代替原来的 VGG16 网络;2) 使用 Soft-NMS 算法代替传统的 NMS 算法,并分别做了对比试验,为实现整个网络的端到端训练^[25], 模型训练方式采用的是 Fast-RCNN 和 RPN 近似联合训练方式。本研究分别分析单一改进和 2 方面改进的效果,相较于 Faster-RCNN 原有模型,其他 3 种均为改进模型。模型测试结果见表 1。平均识别率 AP 的表达式为:

表 1 4 种模型对蚜虫和潜叶蝇的平均识别率

Table 1 Average recognition rate of aphids and leaf miners in 4 models

模型 Model	蚜虫 Aphid	潜叶蝇 Leaf miner	综合平均识别率 Integrated average recognition rate
Faster-RCNN(VGG16)	0.874	0.856	0.865
Faster-RCNN(ResNet50)	0.896	0.882	0.889
Faster-RCNN(VGG16) + Soft-NMS	0.883	0.862	0.873
Faster-RCNN(ResNet50) + Soft-NMS	0.912	0.901	0.907

注:综合平均识别率为 2 类昆虫的平均识别率的均值。Faster-RCNN(VGG16) 为未经改进的模型, Faster-RCNN(ResNet50) 为用 ResNet50 网络替换 VGG16 网络而改进的模型, Faster-RCNN(VGG16) + Soft-NMS 为用 Soft-NMS 算法替换 NMS 算法而改进的模型, Faster-RCNN(ResNet50) + Soft-NMS 为用 ResNet50 网络替换 VGG16 网络且用 Soft-NMS 算法替换 NMS 算法而改进的模型。

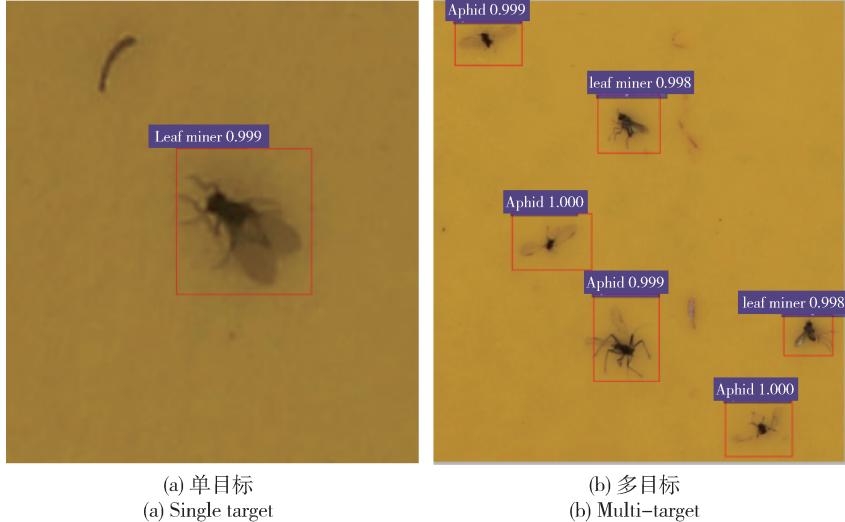
Notes: The average recognition rate in the table is the mean of the average recognition rates of the two types of insects. Faster-RCNN (VGG16) is an unmodified model, Faster-RCNN (ResNet50) is an improved model for replacing VGG16 network with ResNet50 network, and Faster-RCNN (VGG16) + Soft-NMS is used to replace NMS algorithm with Soft-NMS algorithm. The improved model, Faster-RCNN (ResNet50) + Soft-NMS, is a model that replaces the VGG16 network with the ResNet50 network and replaces the NMS algorithm with the Soft-NMS algorithm.

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

式中： P 为准确率； R 为召回率。

由表 1 可见, 使用 ResNet50 网络作为特征提取网络来代替原来的 VGG16 基础特征网络, 综合平均识别率提高了 2.4%, 由原来的 0.865 提高至 0.889; 使用 Soft-NMS 替代传统的 NMS 算法, 综合平均识别率提高 0.8%, 由原来的 0.865 提高至

0.873; 而使用 ResNet50 网络代替原来的 VGG16 基础特征网络, 并且由 Soft-NMS 替代传统的 NMS, 综合平均识别率提高了 4.2%, 达到 0.907。由数据可以看出, 采用 ResNet50 替代 Faster-RCNN 模型中的 VGG16 网络并且采用 Soft-NMS 替代原有的 NMS 算法得到的结果最佳, 可以满足害虫分类计数的要求。本研究选取该训练模型进行测试, 分为单目标测试和多目标测试, 测试结果见图 4。



Aphid, 蚜虫; Leaf miner, 潜叶蝇。下图同 The same below.

图 4 改进 Faster-RCNN 目标检测模型的测试结果

Fig. 4 The test results of the improved Faster-RCNN target detection model

2.3 昆虫计数

目标识别结果以检测框的方式呈现(图 4), 其中包括目标类别和目标属于这个类别的得分(S)。本研究的计数方式是: 遍历所有的检测框, 设定阈值 N , 当 $S > N$ 时, 则认为属于该类目标, 此时此检测框参与统计; 当 $S \leq N$ 时, 则认为不属于该类目标, 此检测框不参与统计。定义方式如下:

$$S_i = \begin{cases} 1 & S_i > N \\ 0 & S_i \leq N \end{cases} \quad (7)$$

式中: S_i 为第 i 个检测框的得分, N 为自制定的阈值; 本研究设定阈值 $N=0.8$ 。任选 2 块区域进行计数, 所选的 2 个区域分别为密集和稀疏区域, 结果见图 5。

昆虫计数的准确率却决于识别效果, 识别率越高, 计数越准确, 本研究选取的计数模型是经过 ResNet50 网络替换 VGG16 网络且用 Soft-NMS 算法替换 NMS 算法而改进的模型, 即表 1 中 Faster-RCNN(ResNet50) + Soft-NMS 模型, 利用本研究

计数模型进行计数与用人眼计数进行对比, 其结果见表 2。可以看出, 对于图 5(a), 模型统计结果较人眼真实统计结果, 漏测 1 个, 综合计数准确率为 19/20; 对图 5(b), 模型统计结果较人眼真实统计结果, 漏测 1 个, 综合准确率 9/10。

3 结论与讨论

本研究针对传统机器学习人工提取特征由于人为主观性而影响识别效果和计数准确性的问题, 将目标检测模型 Faster-RCNN 引入昆虫的识别与计数领域。针对昆虫体积小、部分昆虫密集粘黏而影响识别效果的问题, 对 Faster-RCNN 目标检测模型进行改进。针对昆虫体积小, 图像分辨率较低的特点, 用网络深度更深, 运算量更小的深度残差网络(ResNet50)代替原来的 VGG16, 以提取更加丰富的特征; 针对部分昆虫密集的特点, 用 Soft-NMS 算法代替传统的非极大值抑制(NMS)算法, 以减少密集区域的漏检。试验结果表明, 2 类昆虫识别的综合

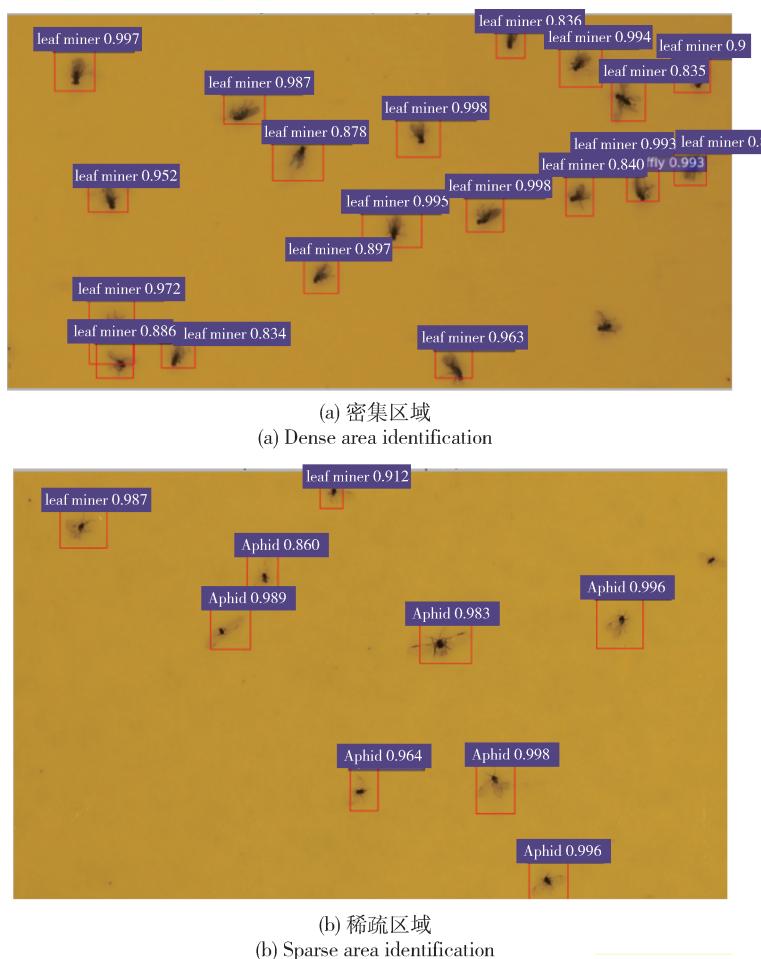


图5 改进 Faster-RCNN 目标检测模型计数实例

Fig. 5 Improved Faster-RCNN target detection model count example

表2 改进 Faster-RCNN 目标检测模型计数与人眼计数的对比统计结果

Table 2 Improved statistical results of the Faster-RCNN target detection model and the human eye count

识别区域 Identification area	人眼计数 Human eye count				模型计数 Model count			
	蚜虫 Aphid	潜叶蝇 Leaf miner	蚜虫 Aphid	潜叶蝇 Leaf miner	蚜虫 Aphid	潜叶蝇 Leaf miner	蚜虫 Aphid	潜叶蝇 Leaf miner
密集区域(图5(a)) Dense areas (图5(a))	2	18	2	17				
稀疏区域(图5(b)) Sparse area (图5(b))	10	0	9	0				

平均准确率达到 90.7%，较原 Faster-RCNN 提高了 4.2%。在昆虫计数上，本研究利用改进 Faster-RCNN 目标检测模型识别的结果进行计数，计数结果与人眼统计结果相比，其计数的准确率达 90% 以上。

本研究在昆虫识别上实现了卷积神经网络对昆虫特征的自动提取，避免了人工提取特征的主观性；

在昆虫计数上，弥补了以往方法由于光线不足、昆虫粘黏等因素造成昆虫计数不准确的不足，在一定程度上克服了昆虫计数中目标和背景必须存在较大差异性的限制，以及以往只适合在温室蔬菜害虫计数的环境限制。另外，本研究训练的模型集分类、识别和计数于一体，简化了模型结构，实现了端到端的检测。本研究也存在不足，计数结果的准确性依赖于

识别的效果。从试验结果可以看出对图像边缘的识别效果并不好,存在漏测的情况;对一些体积较小的昆虫,识别效果有待进一步提高。后续研究将通过增加上下文信息和多尺度提取特征的方法对本模型进行改进。

参考文献 References

- [1] 黄世国. 基于图像的昆虫识别关键技术研究[D]. 西安: 西北大学, 2008
Huang S G. Research on the key technologies of image-based insectrecognition[D]. Xi'an: Northwest University, 2008 (in Chinese)
- [2] 姚青, 吕军, 杨保军, 薛杰, 郑宏海, 唐健. 基于图像的昆虫自动识别与计数研究进展[J]. 中国农业科学, 2011, 44(14): 2886-2899
Yao Q, Lü J, Yang B J, Xue J, Zheng H H, Tang J. Progress in research on digital image processing technology for automatic insect identification and counting [J]. *Scientia Agricultura Sinica*, 2011, 44(14): 2886-2899 (in Chinese)
- [3] Zhu L Q, Zhang Z. Auto-classification of insect images based on color histogram and GLCM[C]. In: 2010 Seventh International Conference on Fuzzy Systems and Knowledge Discovery. Yantai: IEEE, 2010: 2589-2593
- [4] 范艳峰,甄彤. 谷物害虫检测与分类识别技术的研究及应用[J]. 计算机工程, 2005, 31(12): 187-189
Fan Y F, Zhen T. Research and application of grain pests detection and classificationtechnology[J]. *Computer Engineering*, 2005, 31(12): 187-189 (in Chinese)
- [5] 刘芳, 沈佐锐, 张建伟, 杨红珍. 基于颜色特征的昆虫自动鉴定方法[J]. 昆虫知识, 2008, 45(1): 150-153
Liu F, Shen Z R, Zhang J W, Yang H Z. Automatic insect identification based on color characters[J]. *Chinese Bulletin of Entomology*, 2008, 45(1): 150-153 (in Chinese)
- [6] Cho J, Choi J, Qiao M, Ji C W, Kim H Y, Uhm K B, Chon T S. Automatic identification of whiteflies, Aphids and thrips in greenhouse based on image analysis[J]. *International Journal of Mathematics & Computers in Simulation*, 2007, 1(1): 46-53
- [7] Zhao J, Cheng X P. Field pest identification by an improvedgabor texture segmentation scheme[J]. *New Zealand Journal of Agricultural Research*, 2007, 50(5): 719-723
- [8] 杨国国, 鲍一丹, 刘子毅. 基于图像显著性分析与卷积神经网络的茶园害虫定位与识别[J]. 农业工程学报, 2017, 33(6): 156-162
Yang G G, Bao Y D, Liu Z Y. Localization and recognition of pests in Tea plantation based on image saliency analysis and convolutional neural network[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2017, 33 (6): 156-162 (in Chinese)
- [9] 王利强. 点特征配准算法及其在储粮害虫种类识别中的应用研究[D]. 郑州: 河南工业大学, 2011
Wang L Q. Study point feature matching algorithm and its application in stored grain pest speciesidentification [D]. Zhengzhou: Henan University of Technology, 2011 (in Chinese)
- [10] Hinton G E. Reducing the dimensionality of data with neuralnetworks[J]. *Science*, 2006, 313(5786): 504-507
- [11] 张文达, 许悦雷, 倪嘉成, 马时平, 史鹤欢. 基于多尺度分块卷积神经网络的图像目标识别算法[J]. 计算机应用, 2016, 36(4): 1033-1038
Zhang W D, Xu Y L, Ni J C, Ma S P, Shi H H. Image target recognition method based on multi-scale block convolutional neural network[J]. *Journal of Computer Applications*, 2016, 36(4): 1033-1038 (in Chinese)
- [12] 田壮壮, 占荣辉, 胡杰民, 张军. 基于卷积神经网络的SAR图像目标识别研究[J]. 雷达学报, 2016, 5(3): 320-325
Tian Z Z, Zhan R H, Hu J M, Zhang J. SAR ATR based on convolutional neural network[J]. *Journal of Radars*, 2016, 5 (3): 320-325 (in Chinese)
- [13] 黄洁, 姜志国, 张浩鹏, 姚远. 基于卷积神经网络的遥感图像舰船目标检测[J]. 北京航空航天大学学报, 2017, 43(9): 1841-1848
Huang J, Jiang Z G, Zhang H P, Yao Y. Ship object detection in remote sensing images using convolutional neuralnetworks[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2017, 43(9): 1841-1848 (in Chinese)
- [14] 周俊宇, 赵艳明. 卷积神经网络在图像分类和目标检测应用综述[J]. 计算机工程与应用, 2017, 53(13): 34-41
Zhou J Y, Zhao Y M. Application of convolution neural network in image classification and object detection [J]. *Computer Engineering and Applications*, 2017, 53(13): 34-41 (in Chinese)
- [15] Ren S Q, He K M, Girshick R, Sun J. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(6): 1137-1149
- [16] Redmon J, Divvala S, Girshick R, Farhadi A. You only look once: Unified, real-time object detection[C]. In: 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 779-788

- [17] Liu W, Anguelov D, Erhan D, Szegedy C, Reed S, Fu C Y, Berg A C. SSD: single shot multibox detector [C]. In: *Computer Vision-ECCV 2016*. Cham: Springer International Publishing, 2016: 21-37
- [18] 车广富. 基于深度学习的复杂场景行人计数方法的研究[D]. 北京:北京邮电大学, 2017
Che G F. Research on pedestrian counting method based on deep learning in complex scenes[D]. Beijing: Beijing University of Posts and Telecommunications, 2017 (in Chinese)
- [19] 贾洪飞. 基于深度学习的白细胞分类计数的研究[D]. 深圳:深圳大学, 2017
Jia H F. The Research of leukocytes classification based on deep learning [D]. Shenzhen: Shenzhen University, 2017 (in Chinese)
- [20] 罗金燕, 周艳孔, 李惠明. 蔬菜大棚植物诱源黄板诱虫效果研究[J]. 中国植保导刊, 2010, 30(11): 23-25
Luo J, Zhou Y K, Li H M. Study on insect trapping efficiency of yellow board with plant attractant in vegetable greenhouse [J]. *China Plant Protection*, 2010, 30(11): 23-25 (in Chinese)
- [21] 董宁禹, 刘占卿, 赵世民, 刘欢欢, 王枫, 刘涛, 马玉欣, 蒋士君. 太阳能杀虫灯和诱虫黄板绿色防控技术在烟草生产上的应用效果[J]. 河南农业科学, 2015, 44(8): 83-86
- Dong N Y, Liu Z Q, Zhao S M, Liu H H, Wang F, Liu T, Ma Y X, Jiang S J. Application effects of green prevention and control technology of solar insecticidal lamp and yellow template in tobacco production [J]. *Journal of Henan Agricultural Sciences*, 2015, 44(8): 83-86 (in Chinese)
- [22] He K M, Zhang X Y, Ren S Q, Sun J. Deep residual learning for image recognition [C]. In: *2016 IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas: IEEE Computer Society, 2016: 770-778
- [23] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [J]. *Computer Science*, 2014: 1-14
- [24] Bodla N, Singh B, Chellappa R, Davis L S. Soft-NMS improving object detection with one line of code [C]. In: *2017 IEEE International Conference on Computer Vision (ICCV)*. Venice: IEEE, 2017: 5562-5570
- [25] 温明莉, 赵轩, 蔡梦倩. 基于深度学习的端到端验证码识别[J]. 无线互联科技, 2017(14): 85-86
Wen M L, Zhao X, Cai M Q. End-to-end verification code identification based on depth learning [J]. *Wireless Internet Technology*, 2017(14): 85-86 (in Chinese)

责任编辑: 刘迎春