doi:10.6041/j.issn.1000-1298.2018.12.023

基于深度学习的诱捕器内红脂大小蠹检测模型

孙 钰¹ 张冬月¹ 袁明帅¹ 任利利² 刘文萍¹ 王建新¹ (1.北京林业大学信息学院,北京 100083; 2.北京林业大学林学院,北京 100083)

摘要: 红脂大小蠹是危害我国北方地区松杉类针叶树种的重大林业入侵害虫,其虫情监测是森林虫害防治的重要 环节。传统的人工计数方法已经无法满足现代化红脂大小蠹监测的需求。为自动化识别并统计信息素诱捕器捕 获的红脂大小蠹,在传统信息素诱捕器中集成摄像头,自动采集收集杯内图像,建立蠹虫数据集。使用 K-means 聚 类算法优化 Faster R - CNN 深度学习目标检测模型的默认框,并使用 GPU 服务器端到端地训练该模型,实现了诱 捕器内任意姿态红脂大小蠹的目标检测。采用面向个体的定量评价和面向诱捕器的定性评价两种评价方式。实 验结果表明:较原始 Faster R - CNN 模型,该模型在困难测试集上面向个体和诱捕器的精确率-召回率曲线下面积 (Area under the curve,AUC)提升了 4.33% 和 3.28%。在整体测试集上个体和诱捕器 AUC 分别达 0.935 0、0.972 2。 该模型的检测速率为 1.6 s/幅,准确度优于 SSD、Faster R - CNN 等目标检测模型,对姿态变化、杂物干扰、酒精蒸发 等有较好的鲁棒性。改进后的模型可从被诱芯吸引的 6 种小蠹科昆虫中区分出危害最大的红脂大小蠹,自动化地 统计诱捕器内红脂大小蠹数量。

关键词: 红脂大小蠹; 信息素诱捕器; 深度学习; 目标检测; Faster R - CNN; K-means 中图分类号: TP391.4; S763.2 文献标识码: A 文章编号: 1000-1298(2018)12-0180-08

Detection Model of In-trap Red Turpentine Beetle Based on Deep Learning

SUN Yu¹ ZHANG Dongyue¹ YUAN Mingshuai¹ REN Lili² LIU Wenping¹ WANG Jianxin¹
 (1. School of Information Science and Technology, Beijing Forestry University, Beijing 100083, China
 2. College of Forestry, Beijing Forestry University, Beijing 100083, China)

Abstract: The red turpentine beetle (RTB) is a major forestry invasive insect that damages the coniferous species of pine trees in northern China. Therefore, the monitoring of RTB plays an important role in forestry pest controlling. However, traditional trap-based monitoring depends on human experts to manually recognize and count pests, which prohibits the modern RTB monitoring. To automatically recognize and count RTB captured by pheromone traps, a RGB camera was integrated in traditional cup trap to capture in-trap images and build the bark beetles dataset. The default boxes of Faster R - CNN object detection model based on deep learning were optimized by the K-means clustering algorithm. The optimized Faster R – CNN models were trained end to end by the GPU server, which enabled the in-trap detection of RTB with unconstrained postures. The models were evaluated by two metrics: the object oriented quantitative metric and the trap oriented qualitative metric. The experiments demonstrated that the optimized models outperformed the original Faster R - CNN model in terms of both metrics. The area under the curve (AUC) of precision-recall plot for object and trap on difficult test sets were increased by 4.33% and 3.28%, respectively. The AUC for object and trap on all test sets reached 0.935 0 and 0.9722, respectively. The detection speed of the model was 1.6 s per image. The optimized models outperformed the SSD, Faster R - CNN object detection models in terms of accuracy, which was robust to pose variance, bark interference, alcohol volatilization, etc. The proposed method distinguished and counted RTBs from the six species of scolytidae insects attracted by the pheromone lure, which could reduce the human cost of pest monitoring and forecasting.

Key words: red turpentine beetle; pheromone traps; deep learning; object detection; Faster R - CNN; K-means

收稿日期:2018-06-12 修回日期:2018-08-29

基金项目:北京市科技计划项目(Z171100001417005)

作者简介:孙钰(1985一),男,副教授,主要从事智能感知与机器学习研究,E-mail: sunyv@ bjfu. edu. cn

通信作者:刘文萍(1971—),女,教授,博士生导师,主要从事计算机图像及视频分析与处理研究,E-mail: wendlyl@ vip.163.com

0 引言

红脂大小蠹为小蠹科、大小蠹属的一种昆虫,是 危害松科植物的蛀干害虫^[1]。1998年山西省首次 发现该虫后^[2],危害面积迅速扩大。2004年红脂大 小蠹扩散到陕西省、河北省、河南省多地,发生面积 超过5×10⁵hm²,枯死松树达600多万株^[3]。2005 年扩散到北京市门头沟区^[4]。近年在辽宁省凌源 市和建平县、内蒙古宁城具和喀喇沁旗发现该虫。

准确及时的虫情监测预警可指导早期防治,避 免重大经济和生态损失。红脂大小蠹成虫迁移能力 强、扬飞期长,对其数量和种群的动态监测是该虫防 治工作的重要环节。在红脂大小蠹成虫扬飞期,工 作人员根据松林分布情况悬挂诱捕器,并定期对林 间诱捕器中的红脂大小蠹进行人工识别和计数,存 在劳动强度大、费用高、效率低、主观性强等问题。

随着计算机技术的不断发展,基于计算机视觉、 图像处理及模式识别的害虫自动识别技术得到了广 泛研究。目前国内外的害虫识别研究工作主要为以 下两个方向:①基于计算机视觉的害虫特征提取。 识别方法多采用害虫图像的全局特征,如颜色特 征^[5-10]、形态特征^[5-6,8-14]、纹理特征^[5-6,9,12]等。 由于基于全局特征的描述能力具有局限性,近年出 现了许多局部特征与全局特征相结合的特征表达方 式^[12-13]。随后,FENG 等^[15]提出了使用文字描述的 语义相关视觉(Semantically related visual, SRV)属性 描述蛾类翅膀特征,谢成军等[16]提出了稀疏编码与 空间金字塔模型相结合的图像表示方式。②选择和 优化基于机器学习的分类模型。使用的分类器主要 有支持向量机 (Support vector machine, SVM)^[6-9,17-20] 分类器、人工神经网络^[7,11,21]、 K-nearest neighbor^[22]算法、主成分分析 (Principal component analysis, PCA)^[23]方法。

上述方法虽然取得了一定的进展,但仍无法满 足林业害虫全自动监测的需求。上述特征本质上仍 由人工预先设定,具有局限性。

相比传统方法,深度学习模型是直接由数据驱

动的特征及其表达关系的自我学习^[24]。研究人员 已开始探索使用深度学习进行害虫识别和检测。 DING 等^[25]使用深度学习对粘板诱捕器上的苹果蛾 进行计数,但仅将深度卷积神经网络作为滑动窗口 方法的分类器,导致可检测目标尺寸单一且运算量 巨大。杨国国等^[24]使用基于 AlexNet^[26]网络识别 自然背景中的茶园害虫,尽管 AlexNet 分类的平均 准确率达91.5%,但依赖交互式图像分割算法人工 定位害虫位置,导致无法实现自动统计害虫数量。 近年来,深度学习在目标检测领域表现突出,可以同 时实现目标的定位与识别。当前比较成功的深度学 习目标检测网络包括 Faster R - CNN^[27]、SSD^[28]、 RetinaNet^[29]、Mask R - CNN^[30]等,但模型都是针对 PASCOL VOC^[31]、COCO^[32]等通用大数据集设计,目 标的类内变化小且类间差异大。

为实现红脂大小蠹虫情自动监测,本文在传统 信息素诱捕器中集成摄像头,使用 K-means^[33]算法 改进基于深度学习的 Faster R - CNN 目标检测模 型,检测诱捕器背景中任意姿态的6种小蠹,克服虫 体破损、酒精蒸发、液面反光等困难,自动化地定位、 识别并计数危害最大的红脂大小蠹。

1 数据材料

1.1 诱捕器内图像采集

本文采用与文献[34]中的实用新型诱捕器相 似的漏斗形信息素诱捕器,如图1所示。以信息素 诱捕器捕获的小蠹科害虫为检测对象,选取可被信 息素吸引的6种小蠹作为实验样本。通过诱捕器与 林间捕捉方式在辽宁省凌源市和建平县获取寄主为 油松的红脂大小蠹样本,其余5种小蠹主要通过木 段饲养、树干解析或诱捕器方式在内蒙古自治区、陕 西省、北京市等地获取。小蠹样本数量如表1所示。

原始图像由嵌入诱捕器收集杯中的图像传感器 采集。图 1a 为通过改造诱捕器收集杯实现图像数 据采集。首先在传统诱捕器收集杯杯壁水平嵌入摄 像头。摄像头感光元件尺寸为 1/2.5",分辨率为 2048 像素×1536 像素,搭配 2.1 mm 定焦镜头,与



图 1 数据采集与标注

Fig. 1 Data acquisition and label

表1 小蠹样本数量

Та	ıb.	1	Numbe	r of	scolytidae	specimens
----	-----	---	-------	------	------------	-----------

长卡	红脂	松十二	华山松	云杉八	六齿	四眼
作平	大小蠹	齿小蠹	大小蠹	齿小蠹	小蠹	小蠹
训练集	90	53	99	76	51	78
测试集	68	25	33	48	57	51
总计	158	78	132	124	108	129

杯底距离为 6.6 cm。杯壁附有 LED 补光灯。

诱捕器收集杯中含酒精,酒精最多占收集杯容 积的 1/5。随机投入 1~6 种可被信息素诱芯吸引 的小蠹,共采集 2 593 幅图像。因杯壁部分没有检 测意义,采集后直接将其排除。首先对原始图像进 行高斯降噪处理,然后进行灰度处理,并对产生的灰 度图像进行霍夫圆检测^[35],定位圆形杯底,最后根 据检测出的圆形杯底对原图像进行裁剪。图 1b 为 拍摄原图,图 1c 为裁剪后图像,裁剪后分辨率为 1 295 像素 × 1 295 像素。

图像标注由采集人员完成并经昆虫学家确认, 标注包括边界框坐标和类别两类信息。图 1d 是对



(e)拥挤、酒精风干





(f)拥挤、加入无关虫类

图 1c 的标注,边界框为包围小蠹的最小长方形,红 色代表红脂大小蠹。

1.2 数据集建立

为了验证模型的有效性,训练集和测试集分别 使用不同的小蠹样本。划分1913幅图像作为训练 集,680 幅图像作为测试集。小蠹样本使用情况如 表1所示。模型训练集和测试集均包含多种姿态和 不同破损程度的小蠹图像,部分图像出现小蠹身体 接触或遮挡。拍摄过程中,小蠹多数沉至杯底,少数 漂浮在酒精液面,且多数图像的拍摄过程受到倒影、 反光等环境影响。本文根据小蠹图像识别的难易程 度把测试集分为简单测试集和困难测试集,分别为 490 幅和 190 幅。困难测试集中的图像多为虫体残 破、小蠹数量多且拥挤的图像,同时加入了诱捕器收 集杯中酒精挥发后的小蠹图像(训练集中不包括此 类图像),采集图像时在诱捕器收集杯中加入了松 针、树皮、少量其他昆虫(蚂蚁、小灰长角天牛)作为 复杂背景。图 2a~2d 为简单测试集,图 2e~2h 为 困难测试集。



(g)拥挤、反光

图 2 测试集中典型图像 Fig. 2 Typical images of test sets

2 检测方法

诱捕器内小蠹检测的难点主要有:①类间差异 小。被信息素诱芯吸引的6种小蠹均为小蠹科,其 中华山松大小蠹与红脂大小蠹同属大小蠹属。②类 内变化大。小蠹落入收集杯后不仅姿态、位置各异, 并且包含不同个体大小及肢体破损。③背景不一 致。收集杯内可能落入松针、树皮等杂质,酒精会反 光,并因蒸发导致液面高度变化。针对上述问题,本 文改进基于深度学习的 Faster R - CNN 目标检测模 型,以实现诱捕器内的全自动红脂大小蠹检测。

2.1 Faster R-CNN 目标检测模型

REN 等^[27]提出了 Faster R - CNN 目标检测模型,由区域建议网络(Region proposal network, RPN)和 Fast R - CNN^[36]组成。RPN和 Fast R - CNN 共享卷积特征,可有效地缩短检测时间。Faster R - CNN 在第1阶段最后卷积层输出的特征图上添加全卷积 RPN,以密集分布的不同宽高比和尺寸的默认框为基准,生成高质量候选区域;在第2阶段,Fast R - CNN 负责学习候选区域特征并对其进行目标分类和检测框回归。Faster R - CNN 通过交替运行梯度下降方法,轮流优化 RPN和 Fast R - CNN,实现共享

⁽g) 不含红脂大小蟗

参数的快速目标检测。RPN 训练阶段,仅将与标注 框交并比(Intersection over union, IoU)超过 70% 的 默认框记做正默认框,将与标注框 IoU 不超过 30% 的默认框记做负默认框,舍弃其余的默认框。模型 使用的损失函数由目标分类损失 L_{cls} 和检测框回归 损失 L_{reg} 组成。 L_{cls} 是判断是否为目标的对数损失, L_{cls} 、 L_{reg} 的计算公式为

$$\begin{split} L_{\rm cls}(p_i,p_i^*) &= -\lg(p_i^*p_i + (1-p_i^*)(1-p_i)) \\ & (1) \\ L_{\rm reg}(t_i,t_i^*) &= \begin{cases} 0.5(t_i-t_i^*)^2 & (|t_i-t_i^*|<1) \\ |t_i-t_i^*|-0.5 & (|t_i-t_i^*|\ge 1) \end{cases} \end{split}$$

式中 *i*——默认框序号

- *p_i* ——默认框预测为目标的概率,如果默认 框为正默认框,则*p_i^{*}* 为1,若为负默认 框则为0
- *t_i*——检测框的4个参数位置,表示检测框相 对于默认框的偏移量
- t^{*}_i ——与正默认框相关的标注框的参数位 置,表示标注框相对于默认框的偏移量

当 t_i 和 t_i^{*} 越接近时,生成的检测框越准确。模型使用的损失函数计算公式为

$$L(p_{i}, t_{i}) = \frac{1}{N_{\text{cls}}} \sum_{i} L_{\text{cls}}(p_{i}, p_{i}^{*}) + \lambda \frac{1}{N_{\text{reg}}} \sum_{i} p_{i}^{*} L_{\text{reg}}(t_{i}, t_{i}^{*})$$
(3)

式中 N_{els}——每幅图像随机采样的默认框的数量 N_{reg}——默认框中心点数量 λ——平衡权重

使用 N_{els}、N_{reg}和平衡权重 λ 对两种损失进行标 准化。

2.2 基于 K-means 的默认框改进

Faster R - CNN 输出各默认框内的目标类别及 位置调整值。Faster R - CNN 使用 3 × 3 窗口在第 1 阶段最后卷积层输出的特征图上滑动,每个窗口的 中心点映射到原始图像,根据映射的中心点在原始 图像上生成不同比例和尺寸的默认框。原始的 Faster R - CNN 是人为指定如表 2 所示的原始默认 框,以 256 像素×256 像素的框为基础框,生成默认 框宽高比分别为 0.5、1、2,与基础框面积比为 0.062 5、0.25、1、4 的 12 个默认框。RPN 训练阶段, 只有正默认框才能生成两种损失。受镜头焦距、拍 摄距离和小蠹体型的约束,小蠹数据集的目标大小 和通用数据集存在较大差异,本文使用 K-means 方 法对小蠹数据集中的标注框进行聚类分析,选取适 合检测诱捕器内红脂大小蠹的默认框,聚类过程中 默认框与标注框之间距离的计算公式为

$$d(b_{ground}, b_{default}) = 1 - \frac{b_{ground} \cap b_{default}}{b_{ground} \cup b_{default}}$$
(4)

式中 bground ——训练集标注框

b_{default}——默认框

聚类前后模型采用的默认框尺寸如表2所示。

表 2 默认框优化前后尺寸对比

			Tab. 2	Compa	arison of s	ize of de	fault boxe	s before a	and after	optimiza	tion		像素
		1	2	3	4	5	6	7	8	9	10	11	12
优化后	宽	51	30	59	77	38	75	45	65	64	52	44	56
	高	59	52	49	76	61	51	46	61	40	31	70	73
优化前	宽	91	181	362	724	64	128	256	512	45	90	181	362
	高	45	90	181	362	64	128	256	512	91	181	362	724

图 3 中图像分辨率为 600 像素 × 600 像素,是 模型的输入分辨率,图像中绿框为一组原始的默认 框,红框为聚类后的一组默认框,相比之下聚类后的 默认框与红脂大小蠹重合度更高,有效减少了消耗 计算资源但不生成训练误差的默认框数量,更加有 利于梯度的生成。

2.3 红脂大小蠹检测流程

红脂大小蠹的检测流程如图 4 所示,首先将从 诱捕器中采集的小蠹图像进行预处理。预处理包括 将图像缩放至 600 像素×600 像素,RGB 各通道归 一化至正态分布。然后将预处理后的图像输入模型 进行 检 测,使用 非极大值抑制(Non-maximum suppression, NMS)方法去除同类之间 IoU 大于 50% 的检测框, 按分类信心排序后, 最多输出 100 个检测 结果。图 4 中的红色方框为检测结果, 图像左上角 标注出红脂大小蠹的数量。

3 实验与结果分析

3.1 模型训练

本文中检测模型采用 ResNet50^[37] 为特征提取器,训练阶段采用动量为 0.9 的随机梯度下降算法(Stochastic gradient descent,SGD)进行优化,初始学 习速率为 3 × 10⁻⁴。软件实现基于 TensorFlow 深度 学习框架,硬件平台采用 AMD Ryzen 1700X CPU



图 3 原始默认框和聚类后默认框对比 Fig. 3 Comparison between original default boxes and clustered default boxes



Fig. 4 Flow chart of red turpentine beetle detection

(64 GB内存)加 Nvidia TITAN Xp GPU(12 GB 显存)。

为了更加详尽地评价本文检测模型,本文使用 面向个体的定量评价指标和面向诱捕器的定性评价 指标^[25]。面向个体的评价指标主要针对红脂大小 蠹个体检测效果进行评价,面向诱捕器的评价指标 主要针对检测图像中是否存在红脂大小蠹的效果进 行评价。

3.2 面向个体的定量评价

面向个体的精确率和召回率的计算公式为

$$p = \frac{T_{positive}}{N_{detected}} \times 100\%$$
 (5)

$$r = \frac{T_{positive}}{N_{ground}} \times 100\%$$
 (6)

式中 p——面向个体的精确率 r----面向个体的召回率

0





检测框和标注框类别相同且 IoU 大于 50% 为 真正类。面向个体的精确率和召回率的调和平均值 计算公式为

$$F_{\beta} = (1 + \beta^2) \frac{pr}{\beta^2 p + r} \tag{7}$$

式中 B——调和参数,设为2

本文采用面向个体的精确率--召回率的曲线下 面积(Area under the curve, AUC)^[31]作为定量评价 指标,简称个体 AUC,曲线如图 5 所示。实验结果 表明使用 K-means 算法进行参数优化后的红脂大小 蠹检测模型在困难测试集上个体 AUC 达到了 0.8627,在简单测试集上个体 AUC 达到了 0.9859, 在整体测试集上个体 AUC 达到了 0.935 0。改进后 的模型相对于未改进模型在困难测试集上个体 AUC 提高了 4.33%。基于 SSD 的红脂大小蠹检测 模型 SSD300 和 SSD512 在困难测试集上个体 AUC 分别为 0.529 1 和 0.428 3, 在整体测试集上个体 AUC 分别为 0.708 2 和 0.678 8。

3.3 面向诱捕器的定性评价

面向诱捕器的精确率和召回率的计算公式为

$$p' = \frac{T'_{positive}}{N'_{detected}} \times 100\%$$
(8)

$$r' = \frac{T'_{positive}}{N'_{ground}} \times 100\%$$
⁽⁹⁾

式中 p'----面向诱捕器的精确率

r'——面向诱捕器的召回率

T'_{positive}——真正类数量

一存在红脂大小蠹的图像数量 N' ground ----

N'detected ——检测出含红脂大小蠹的图像数量

本文采用面向诱捕器的精确率--召回率 AUC 作

如果模型在一幅诱捕器图像中至少正确检测出 一只红脂大小蠹,则认为是真正类。面向诱捕器的 精确率和召回率的调和平均值的计算公式为

$$F'_{\beta} = (1 + \beta^2) \frac{p'r'}{\beta^2 p' + r'}$$
(10)



图 5 测试集的个体精确率--召回率曲线



为定性评价指标,简称诱捕器 AUC,曲线如图 6 所示。实验结果表明:使用 K-means 算法进行默认框 优化后,模型在困难测试集上诱捕器 AUC 达到了 0.9447,在简单测试集上诱捕器 AUC 达到了 0.9834, 在整体测试集上诱捕器 AUC 达到了 0.9722。改进

后的模型相对于原始模型在困难测试集上诱捕器 AUC 提高了 3.28%。基于 SSD 的红脂大小蠹检测 模型 SSD300 和 SSD512 在困难测试集上诱捕器 AUC 分别为 0.854 1 和 0.870 2,在整体测试集上诱 捕器 AUC 分别为 0.855 9 和 0.921 1。



Fig. 6 Curves of trap precision - recall on test sets

3.4 结果分析

实验结果表明基于 SSD 的红脂大小蠹检测模型 SSD300 和 SSD512 检测性能已经不能满足虫情监测要求。同时,改进后的模型泛化能力更强,更加适用于诱捕器内红脂大小蠹虫情监测。选择分类信心 0.5 为检测阈值,模型在困难测试集上面向个体的精确率、召回率、 F_{β} 分别为 87.25%、74.62%、0.7684,面向诱捕器的精确率、召回率、 F'_{β} 分别为 95.12%、97.5%、0.9701;在简单测试集上面向个体的精确率、召回率、 F_{β} 分别为 97.03%、95.81%、0.9605,面向诱捕器的精确率、召回率、 F'_{β} 分别为 98.49%、98%、0.981;在整体测试集上面向个体的

RT

精确率、召回率、 F_{β} 分别为 92.53%、85.29%、0.8665, 面向诱捕器的精确率、召回率、 F'_{β} 分别为 97.51%、 97.86%、0.9779。改进后的模型检测速率为 1.6 s/幅。影响红脂大小蠹检测模型效果的主要原 因如下:在诱捕器中的小蠹过于拥挤或者遮挡严重 的情况下会造成检测结果出现部分红脂大小蠹定位 不准,如图7a所示;虫体过于残破造成部分红脂大 小蠹漏检,如图7b所示;测试集中酒精风干后的图 像未在训练集中出现,相同的小蠹样本在酒精风干 后的图像相对在酒精中的图像尺寸会变小,造成检 测错误,如图7c所示;酒精风干后的松十二齿小蠹 易被误检为红脂大小蠹,如图7d所示。



(c) 检测错误



(d) 松十二齿小蠹误认为红脂大小蠹

图 7 典型错误示例 Fig. 7 Typical false detections

4 结束语

(a) 检测框定位不准

改进的深度学习目标检测模型 Faster R - CNN 符 合大多数研究对于小蠹样本及拍摄条件严格的要求, 避免了预处理及特征提取阶段的人工干预。使用 Kmeans 聚类方法对模型的默认框进行改进后,有效减少 了消耗计算资源但不生成训练误差的默认框数量。改进后的模型在困难测试集上的个体 AUC、诱捕器 AUC 分别提高了 4.33%、3.28%,整体测试集上的个体 AUC、诱捕器 AUC 分别达到了 0.935 0、0.972 2,实验证 明,该模型可有效定位、识别和计数信息素诱捕器内危 害最大的红脂大小蠹。

(b)漏检

- 2 徐洪儒,李颖超,李镇宇. 红脂大小蠹在中国成灾原因及扩散趋势分析[J]. 植物检疫,2006,20(5): 278-280. XU Hongru, LI Yingchao, LI Zhenyu. The analysis of outbreak reason and spread directions of *Dendroctonus valens*[J]. Plant Quapantine,2006,20(5): 278-280. (in Chinese)
- 3 潘杰,王涛,温俊宝,等. 红脂大小蠹传入中国危害特性的变化[J]. 生态学报, 2011, 31(7):1970-1975. PAN Jie, WANG Tao, WEN Junbao, et al. Changes in invasion characteristics of *Dendroctonus valens* after introduction into China [J]. Acta Ecologica Sinla, 2011, 31(7):1970-1975. (in Chinese)
- 4 赵建兴,杨忠岐,任晓红,等. 红脂大小蠹的生物学特性及在我国的发生规律[J]. 林业科学,2008,44(2):99-105.
 ZHAO Jianxing, YANG Zhongqi, REN Xiaohong, et al. Biological characteristics and occurring law of *Dendroctonus valens* in China
 [J]. Scientia Silvae Sinicae, 2008, 44(2): 99-105. (in Chinese)
- 5 WANG J, JI L, LIANG A, et al. The identification of butterfly families using content-based image retrieval [J]. Biosystems Engineering, 2012, 111(1): 24-32.
- 6 YAO Q, LÜ J, LIU Q, et al. An insect imaging system to automate rice light-trap pest identification [J]. Journal of Integrative Agriculture, 2012, 11(6): 978-985.
- 7 WANG J, LIN C, JI L, et al. A new automatic identification system of insect images at the order level [J]. Knowledge Based Systems, 2012, 33: 102 110.
- 8 韩瑞珍,何勇.基于计算机视觉的大田害虫远程自动识别系统[J].农业工程学报,2013,29(3):156-162. HAN Ruizhen, HE Yong. Remote automatic identification system of field pests based on computer vision [J]. Transactions of the CSAE, 2013, 29(3):156-162. (in Chinese)
- 9 洗鼎翔,姚青,杨保军,等. 基于图像的水稻灯诱害虫自动识别技术的研究[J]. 中国水稻科学, 2015, 29(3): 299-304. XIAN Dingxiang, YAO Qing, YANG Baojun, et al. Automatic identification of rice light trapped pests based on images [J]. Chinese Journal of Rice Science, 2015, 29(3): 299-304. (in Chinese)
- 10 肖德琴,张玉康,范梅红,等. 基于视觉感知的蔬菜害虫诱捕计数算法[J/OL]. 农业机械学报,2018,49(3):51-58. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 20180306&journal_id = jcsam. DOI:10.6041/j.issn. 1000-1298.2018.03.006.

XIAO Deqin, ZHANG Yukang, FAN Meihong, et al. Vegetable pest counting algorithm based on visual perception [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(3):51 - 58. (in Chinese)

- 11 KANG S H, CHO J H, LEE S H. Identification of butterfly based on their shapes when viewed from different angles using an artificial neural network [J]. Journal of Asia-Pacific Entomology, 2014, 17(2): 143 149.
- 12 WEN C, GUYER D. Image-based orchard insect automated identification and classification method [J]. Computers and Electronics in Agriculture, 2012, 89: 110-115.
- 13 WEN C, WU D, HU H, et al. Pose estimation-dependent identification method for field moth images using deep learning architecture[J]. Biosystems Engineering, 2015, 136: 117-128.
- 14 李震,邓忠易,洪添胜,等. 基于神经网络的实蝇成虫图像识别算法[J/OL]. 农业机械学报,2017,48(增刊):129-135.
 http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 2017s021&journal_id = jcsam. DOI:10.6041/j.issn.1000-1298.2017.S0.021.
 LI Zhen DENC Zhongvi HONC Tianshang et al. Image recognition algorithm for fruit flies based on hn neural network[I/OL]

LI Zhen, DENG Zhongyi, HONG Tiansheng, et al. Image recognition algorithm for fruit flies based on bp neural network [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48 (Supp.): 129 - 135. (in Chinese)

- 15 FENG L, BHANU B, HERATY J. A software system for automated identification and retrieval of moth images based on wing attributes[J]. Pattern Recognition, 2016, 51: 225-241.
- 16 谢成军,李瑞,董伟,等. 基于稀疏编码金字塔模型的农田害虫图像识别[J]. 农业工程学报, 2016, 32(17): 144-151.
 XIE Chengjun, LI Rui, DONG Wei, et al. Recognition for insects via spatial pyramid model using sparse coding [J].
 Transactions of the CSAE, 2016, 32(17): 144-151. (in Chinese)
- 17 EBRAHIMI M A, KHOSHTAGHAZA M H, MINAEI S, et al. Vision-based pest detection based on SVM classification method [J]. Computers & Electronics in Agriculture, 2017, 137(C): 52 - 58.
- 18 GARCÍA J, POPE C, ALTIMIRAS F. A distributed k-means segmentation algorithm applied to Lobesia botrana recognition [J]. Complexity, 2017(2017): ID5137317.
- 19 田冉,陈梅香,董大明,等. 红外传感器与机器视觉融合的果树害虫识别及计数方法[J]. 农业工程学报, 2016, 32(20): 195-201.

TIAN Ran, CHEN Meixiang, DONG Daming, et al. Identification and counting method of orchard pests based on fusion method of infrared sensor and machine vision [J]. Transactions of the CSAE, 2016, 32(20): 195 - 201. (in Chinese)

20 肖志云,刘洪. 小波域马铃薯典型虫害图像特征选择与识别[J/OL]. 农业机械学报, 2017, 48(9):24-31. http://www.jcsam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 20170903&journal_id = jcsam. DOI:10.6041/j.issn.1000-1298.2017.09.003.

XIAO Zhiyun, LIU Hong. Features selection and recognition of potato typical insect pest images in wavelet domain [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(9):24 - 31. (in Chinese)

21 ESPINOZA K, VALERA D L, TORRES J A, et al. Combination of image processing and artificial neural networks as a novel approach for the identification of *Bemisia tabaci* and *Frankliniella occidentalis* on sticky traps in greenhouse agriculture [J].

- 22 YALCIN H. Vision based automatic inspection of insects in pheromone traps [C] // Fourth International Conference on Agro-Geoinformatics, 2015: 333 338.
- 23 范一峰,王义平. 基于 Gabor 滤波和类内 PCA 的昆虫识别[J]. 计算机应用与软件, 2013, 30(4): 75-76. FAN Yifeng, WANG Yiping. Insect recognition based on Gabor filter and with-in class PCA[J]. Computer Applications and Software, 2013, 30(4): 75-76. (in Chinese)
- 24 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 Guoguo, BAO Yidan, LIU Ziyi. Localization and recognition of pests in tea plantation based on image saliency analysis and convolutional neural network [J]. Transactions of the CSAE, 2017, 33(6): 156-162. (in Chinese)

- 25 DING W, TAYLOR G. Automatic moth detection from trap images for pest management [J]. Computers and Electronics in Agriculture, 2016, 123: 17 - 28.
- 26 KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks [C] // Advances in Neural Information Processing Systems, 2012: 1097 1105.
- 27 REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [C] // International Conference on Neural Information Processing Systems, 2015: 91 - 99.
- 28 LIU W, ANGUELOV D, ERHAN D, et al. Ssd: single shot multibox detector [C] // European Conference on Computer Vision, ECCV 2016,2016: 21 - 37.
- 29 LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2980 - 2988.
- 30 HE K, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2961 2969.
- 31 EVERINGHAM M, ESLAMI S M A, VAN GOOL L, et al. The pascal visual object classes challenge: a retrospective [J]. International Journal of Computer Vision, 2015, 111(1): 98 - 136.
- 32 LIN T Y, MAIRE M, BELONGIE S, et al. Microsoft COCO: common objects in context[C] // European Conference on Computer Vision. Springer, Cham, 2014: 740 - 755.
- 33 MACQUEEN J. Some methods for classification and analysis of multivariate observations [C] // Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability, 1967: 281 - 297.
- 34 宗世祥,骆有庆,许志春,等. 沙棘木蠹蛾性信息素林间诱蛾活性试验[J]. 北京林业大学学报,2006,28(6):109-112. ZONG Shixiang, LUO Youqing, XU Zhichun, et al. Field trapping trials of sex pheromone for *Holcocerus hippophaecolus* (Lepidoptera:Cossidae)[J]. Journal of Beijing Forestry University, 2006, 28(6):109-112. (in Chinese)
- 35 HOUGH P V C. Method and means for recognizing complex patterns: US3069654[P]. 1962-12-18.
- 36 GIRSHICK R. Fast R-CNN[C] // Computer Vision(ICCV), 2015 IEEE International Conference on. IEEE, 2015: 1440-1448.
- 37 HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770 - 778.

(上接第 142 页)

17 刘宣佐. 轴流风机数值模拟的若干问题探讨[D]. 杭州:浙江大学, 2015:34-51.
 LIU Xuanzuo. Discussion and analysis on several issues about the numerical simulation of the axial flow fan[D]. Hangzhou:
 Zhejiang University, 2015:34-51. (in Chinese)

- 18 YAKHOT V, ORSZAG S A, THANGAM S, et al. Development of turbulence models for shear flows by a double expansion technique[J]. Physics of Fluids, 1992, 4(7):1510-1520.
- 19 吴宗泽. 机械设计师手册(上册)[M]. 北京:机械工业出版社, 2006:841.
- 20 郭嫱. 叶顶间隙泄漏涡流及空化流场特性研究[D]. 北京:中国农业大学, 2017:22-26. GUO Qiang. Study on characteristics of the blade tip leakage vortex flow and the cavitating flow field [D]. Beijing: China Agricultural University, 2017:22-26. (in Chinese)
- 21 HUNT J C R, WRAY A A, MOIN P. Eddies, streams, and convergence zones in turbulent flows [C] // Center for Turbulence Research Proceedings of the Summer Program, 1988:193 - 208.
- 22 于雷,王成军,赵冬凯,等.中心分级燃烧室冷态流场的大涡模拟[J]. 沈阳航空航天大学学报,2017,34(3):43-49. YU Lei, WANG Chengjun, ZHAO Dongkai, et al. Large-eddy simulation of non-reacting flow in a central staged combustor[J]. Journal of Shenyang Aerospace University, 2017, 34(3):43-49. (in Chinese)
- 23 邓书辉. 低屋面横向通风牛舍环境数值模拟及优化[D]. 北京:中国农业大学, 2015:26-27. DENG Shuhui. Numerical simulation and optimization of environment in low profile cross ventilated dairy cattle barn [D]. Beijing: China Agricultural University, 2015:26-27. (in Chinese)