

基于改进 Faster R – CNN 的田间黄板害虫检测算法

肖德琴 黄一桂 张远琴 刘又夫 林思聪 杨文涛

(华南农业大学数学与信息学院, 广州 510642)

摘要: 针对黄板诱捕的害虫体积小、数量多和分布不均匀,难以进行害虫识别的问题,引入当前主流目标检测模型 Faster R – CNN 对黄板上的小菜蛾、黄曲条跳甲和烟粉虱等主要害虫进行识别与计数,提出一种基于改进 Faster R – CNN 的田间黄板害虫检测算法 (Mobile terminal pest Faster R – CNN, MPF R – CNN)。该算法将 ResNet101 网络与 FPN 网络相结合作为特征提取网络,并在 RPN 网络设计多种不同尺寸锚点对特征图像进行前景和背景判断,使用 ROIAAlign 替代 ROI Pooling 进行特征映射,以及使用双损失函数进行算法参数控制。对 2 440 幅样本图像的实验分析表明,在真实复杂的自然环境下,MPF R – CNN 对烟粉虱、黄曲条跳甲、小菜蛾和其他大型害虫 (体长大于 5 mm) 检测的平均精度分别为 87.84%、86.94%、87.42% 和 86.38%;在 35 cm × 25 cm 黄板上不超过 480 只的低密度下平均精度均值为 93.41%,在 480 ~ 960 只害虫的中等密度下平均精度均值为 89.76%。同时实验显示,在中低等密度下晴天和雨天的检测精度无明显差异,本算法计数结果与害虫计数决定系数为 0.925 5。将该算法置入以“微信小程序 + 云存储服务 + 算法服务器”为架构的小米 7 手机终端系统中进行应用测试,平均识别时间为 1.7 s。研究表明,该算法在精度和速度上均可支持当前便携式应用,为利用手机对蔬菜害虫进行快速监测与识别提供了技术支撑。

关键词: 害虫检测;黄板;害虫计数;机器学习;Faster R – CNN

中图分类号: TP391.41 **文献标识码:** A **文章编号:** 1000-1298(2021)06-0242-10

OSID: 

Pest Detection Algorithm of Yellow Plate in Field
Based on Improved Faster R – CNN

XIAO Deqin HUANG Yigui ZHANG Yuanqin LIU Youfu LIN Sicong YANG Wentao
(College of Mathematics and Informatics, South China Agricultural University, Guangzhou 510642, China)

Abstract: Realizing identification and counting of vegetable pests captured by yellow plates under complex conditions in the field is an essential prerequisite for targeted prevention and treatment pests and diseases of crop. Because of the small size, the large number and uneven distribution of pests trapped by yellow plates, it brings a great challenge to both manual and machine identification of pests. The current mainstream machine learning model Faster R – CNN was introduced to identify and count the main pests such as diamondback moth, striped flea beetle and bemisia tabaci on the yellow plates. It also proposed a modified Faster R – CNN pest detection algorithm (Mobile terminal pest Faster R – CNN, MPF R – CNN) based on Faster R – CNN. This algorithm combined ResNet101 network with FPN network as a feature extraction network and designed a variety of different size anchor pairs in the RPN network to judge the foreground and background of features. This algorithm also adopted ROIAAlign instead of ROI Pooling for feature mapping and a dual loss function for algorithm parameter control. The experimental analysis of 2 440 sample images showed that the average accuracy of MPF R – CNN in the detection of bemisia tabaci, striped flea beetle, diamondback moth and other large pests (body length greater than 5 mm) in the realistic and complex natural environment were 87.84%, 86.94%, 87.42% and 86.38%, respectively. The average accuracy in the low density of 0 ~ 480 on 35 cm × 25 cm yellow plate was 93.41%, and the mean accuracy in the case of the medium density of 480 ~ 960 was 89.76%. There was no significant difference between the detection accuracy in sunny and rainy days in medium and low density and the determination coefficient between the counting result of this algorithm and the insect count was 0.925 5. Simultaneously, the average recognition time of the algorithm was 1.7 s when it was put

收稿日期: 2020 – 12 – 31 修回日期: 2021 – 03 – 08

基金项目: 广州市科技计划项目 (201904010196) 和广东省重点领域研发计划项目 (2019B020217003, 2019B020214002)

作者简介: 肖德琴 (1970—), 女, 教授, 博士生导师, 主要从事物联网和农业图像视频处理研究, E-mail: deqinx@scau.edu.cn

into the Mi 7 mobile terminal system with the architecture of “WeChat applet + cloud storage server + algorithm server” for application test. The results showed that the present algorithm can support the current portable applications in terms of accuracy and speed and can provide technical support for the rapid mobile monitoring and identification of vegetable pests, which had a good promotion prospect.

Key words: pest detection; yellow plate; pest counting; machine learning; Faster R - CNN

0 引言

广东省四季温度变化不大、降雨充沛,气候条件非常适合蔬菜害虫的生长繁殖,这导致蔬菜在生长过程中极易受到害虫的危害,蔬菜害虫的爆发降低了蔬菜产量而造成巨大的经济损失^[1-2]。对害虫进行预测是防治害虫的重要前提。目前,我国蔬菜害虫预测方法主要利用人工对黄板上的害虫进行分类和计数,但该方法存在缺乏客观性、效率低下、误差大等问题。因此,亟需一种快速、智能的黄板害虫检测方法。

近年来,国内外针对农田害虫图像检测算法已经取得显著成果^[3-6]。然而,这些研究均使用传统图像检测算法,存在对图像环境背景要求较高、扩展性不强、数据预处理复杂以及迁移性低等问题,使农田害虫图像检测算法无法大面积应用。

近年来,由于 Fast R - CNN、Faster R - CNN、YOLO 和 SSD 等深度学习算法具有良好的检测性能,因此应用深度学习算法进行农业害虫识别逐渐成为研究热点^[7-9]。已有算法^[10-13]对害虫检测精度都很高,但是这些算法均针对特定群体的害虫而设计,并未结合体积小、数量多和分布不均匀的特点对黄板诱捕的蔬菜害虫进行设计。同时,黄板害虫图像是像素较大的手机图像,而上述算法处理的是其他设备拍摄的图像,难以迁移使用。目前,在农业病害识别系统^[14-22]中缺乏关于黄板害虫检测的研究,而黄板诱捕害虫的应用却非常广泛。手机是一种可普遍应用的移动智能设备,是需要一种基于黄板诱捕害虫的便携式智能识别算法,从而实现利用手机对害虫进行检测和识别。

本文在用高清摄像机和传统图像处理技术对黄板害虫研究的基础上^[23],利用现有的深度学习技术^[24-27],提出一种基于改进 Faster R - CNN^[28]的田间黄板害虫检测算法 (Mobile terminal pest Faster R - CNN,MPF R - CNN),并在移动端中进行测试与应用。

1 材料与方法

1.1 数据采集

本实验图像采集于广东省广州市南沙区东升农场,采集设备为小米 7 手机。摄像头为 1 600 万像

素,拍摄距离为 35 cm,拍摄角度为 0°~10°之间,等效焦距为 35 mm。图像尺寸为 3 120 像素×4 128 像素,图像存储格式为 JPG,图像采集时间为 2017 年 6 月 1 日到 2017 年 9 月 30 日,拍摄时间段为 08:00—09:00。为了让实验更贴近真实的农场环境,所有的图像都是在自然条件下拍摄的,并且每月 1 日使用人工对黄板上粘连的害虫进行清理。本次实验一共制作了 20 张黄板,所有黄板的长均为 35 cm,宽为 25 cm。这 20 张黄板分别固定在东升农场面积为 1.3 hm²的蔬菜种植土地上,如图 1 所示。本次实验一共采集了 2 440 幅黄板害虫图像,其中晴天采集图像 1 708 幅,雨天采集图像 732 幅。黄板害虫图像如图 2 所示。




图 1 黄板分布图

Fig. 1 Yellow plates distribution diagram




图 2 黄色诱捕板害虫图像

Fig. 2 Pests images of yellow plates

1.2 数据集制作

黄板图像中的主要害虫种类为 3 种,分别是小菜蛾、黄曲条跳甲和烟粉虱。因此本次实验标签主要分为 4 类,分别是小菜蛾 (YL)、黄曲条跳甲 (TJ)、烟粉虱 (YL) 和其他大型害虫 (OT, 体长大于 5 mm)。

将其他大型害虫归为一类的主要目的是探究潜在的害虫爆发可能性,因为大型害虫的迁移能力强,在实际生产中容易出现大型害虫入侵的情况,这样可以增加算法在实际应用中的抗压能力。由于黄板图像中害虫的样本数量巨大,发生害虫黏连导致分不清的情况远远低于害虫处于独立的情况,并且在实际生产中去掉黏连害虫的数量对于整体黄板害虫预警不产生影响,所以本文对害虫进行标注时只对独立的害虫进行标注。使用 LabelImg 对数据进行标注,标注图像数量为 2 440 幅,其中小菜蛾样本数量为 267 435,黄曲条跳甲样本数量为 332 861,烟粉虱样本数量为 938 215,其他大型害虫样本数量为 100 751。各种害虫采集样本如图 3 所示。




图 3 害虫样本示例
Fig. 3 Samples of pest

1.3 数据集处理

为了提高 MPF R - CNN 害虫检测算法的准确率和检测速度,需要对数据集进行处理。由于原始图像尺寸为 3 120 像素 × 4 128 像素,远远大于正常深度学习训练图像。如果直接对该图像进行训练会因为图像缩放而导致图像特征丢失,也会因为尺寸过大而导致 GPU 内存溢出,因此需要将原来的图像裁剪为 16 份,裁剪后的图像尺寸为 780 像素 × 1 032 像素,裁剪后的图像如图 4a 所示。同时,为了让算法可以更好地识别复杂的自然环境,需要将数据集分成晴天和雨天数据集,然后将裁剪后的图像根据晴天和雨天数据集分别按照 8: 1: 1 的比例随机划分训练集、验证集和测试集。数据集划分完成后还需要将雨天和晴天对应的训练集、测试集和验证集分别进行混合,使训练集、测试集和验证集都存在雨天和晴天的数据。最后对训练集图像进行顺时针 90°、180°、270° 旋转,以及水平翻转和 Mosaic 增广。

Mosaic 增广的思想来源于 CutMix 数据增强的方式并在 YOLOv4 模型中应用。Mosaic 的原理是每次随机选取 4 幅图像并且随机对图像进行缩放、水平翻转、垂直翻转和色域变化后按照一定的比例对 4 幅图像进行截取后拼接出新的训练图像。因为黄板中存在很多不是检测目标的害虫和杂物作为检测背景,它们会严重影响算法检测的准确率,所以要使用 Mosaic 增广丰富检测物体的背景,这有利于训练算法对不同害虫的不同特征之间的权重分配。Mosaic 增广效果如图 4b 所示。




图 4 训练集图像
Fig. 4 Images of training set

2 MPF R - CNN 害虫检测算法设计

Faster R - CNN 是目标检测领域中的经典算法之一。针对诱捕黄板害虫的识别和计数,本文提出的基于 Faster R - CNN 改进的 MPF R - CNN 害虫检测算法结构包括特征提取网络、区域建议网络 (RPN) 和检测网络 3 部分,算法结构如图 5 所示,其中特征提取网络使用了 ResNet101 + FPN 网络对图像进行卷积提取特征, RPN 网络经过设计后使用了多种不同尺寸的锚点 (anchors) 对图像区域进行前景和背景判断,并进行边框回归,检测网络则使用 ROIOAlign 方法对害虫进行检测和分类。此外,还设计双损失函数加速算法的收敛速度。

2.1 ResNet101 + FPN 特征提取网络设计

FPN 网络是 LIN 等^[29]在 2017 年提出的,该网络通过对特征提取网络中的每一个相连特征层的特征图进行叠加连接的方法,解决了小物体特征在多次卷积和池化操作后模糊甚至丢失的情况。因为 Faster R - CNN 原本的特征提取网络结构比较单一,难以处理不同害虫之间的体积、纹理和尸体完整度保留性(不同的害虫死亡后身体存在不同部分或部位容易出现脱落或者被风吹走情况)等差异问题,而具有多层次特征提取能力的 FPN 网络能更好地解决该问题。本文以 ResNet101^[30]为主干网络加上 FPN 网络设计,该网络结构如图 6 所示,可以分为 3 个路线:




图5 MPF R-CNN 害虫检测算法结构

Fig. 5 Structure of MPF R-CNN pest detection algorithm




图6 特征提取网络

Fig. 6 Feature extraction network

(1) 自底向上的路线: ResNet101 网络自底向上卷积, 该过程有 {C1, C2, C3, C4, C5} 5 个卷积层。

(2) 自顶向下的路线: 在 FPN 网络中自顶向下对 {M4, M3, M2, M1} 特征信息进行上采样操作, 让低维度的特征信息更加突出。

(3) 横向连接路线: 使用 1×1 的卷积核对 ResNet101 网络与 FPN 网络的每一层图像特征进行卷积融合。

ResNet101 与 FPN 网络融合之后, 需使用卷积核进行卷积从而让混叠效应消失。为了保证高维度特征信息不丢失, 以及更加突出低维度特征, 必须控制实现高维度的卷积核相对较小, 而低维度的卷积核需相对较大, 并且低维度卷积核需尽量防止多个目标特征信息融合在一起的情况, 因此本文分别使用了 2×2 、 2×2 、 3×3 、 3×3 、 5×5 共 5 个不同卷积核分别对 FPN 不同维度的特征进行卷积。最后将 5 种不同尺寸的特征图像 {p1, p2, p3, p4, p5} 输入到 RPN 网络, 其中 p1、p2、p3、p4、p5 对应的原图像像素尺寸为 364×524 、 181×261 、 89×129 、 42×64 、 23×33 。

2.2 基于多滑动窗口的 MPF R-CNN 区域建议网络设计

区域建议网络 (RPN) 是一个全卷积网络, 其过程是对特征图像使用滑动窗口产生锚点, 并对锚点区域进行前景和背景判断以及边框回归。在本实验中体积最小的害虫烟粉虱为 $23 \text{ 像素} \times 25 \text{ 像素}$ 到 $35 \text{ 像素} \times 35 \text{ 像素}$ 之间, 而体积最大的其他常见大型害虫在 $90 \text{ 像素} \times 100 \text{ 像素}$ 到 $130 \text{ 像素} \times 140 \text{ 像素}$ 之间。为了产生多种不同维度特征和不同尺寸的锚点以覆盖不同尺寸的害虫, 本文 RPN 网络滑动窗口过程如图 7 所示, 在 RPN 网络中设计了 3 种不同的滑动窗口:

- (1) 3×3 滑动窗口: 对 {p1, p2, p3, p4, p5} 5 种特征图进行全卷积, 产生 5 种尺寸的锚点, 这 5 种锚点对应的尺寸 (映射到黄板图像的尺寸) 分别为 { $30 \text{ 像素} \times 30 \text{ 像素}$, $36 \text{ 像素} \times 36 \text{ 像素}$, $72 \text{ 像素} \times 72 \text{ 像素}$, $96 \text{ 像素} \times 96 \text{ 像素}$, $192 \text{ 像素} \times 192 \text{ 像素}$ }。
- (2) 5×5 滑动窗口: 对 p1 和 p2 特征图进行滑动, 产生 2 种锚点, 它们尺寸分别为 $50 \text{ 像素} \times 50 \text{ 像素}$ 和 $60 \text{ 像素} \times 60 \text{ 像素}$ 。
- (3) 1×1 的滑动窗口: 对 p4 和 p5 特征图进行滑动, 产生 2 种锚点, 它们尺寸分别为 $32 \text{ 像素} \times 32 \text{ 像素}$ 和 $64 \text{ 像素} \times 64 \text{ 像素}$ 。

同时每种锚点都使用 3 种长宽比例 {1:1, 1:2, 2:1}, 因此一共有 21 种不同比例的锚点产生特征框, 对害虫图像中的目标进行前景和背景判断。虽然对 p1 特征图使用 3×3 滑动窗口产生尺寸为

30 像素×30 像素的锚点和对 p5 特征图使用 1×1 滑动窗口产生 32 像素×32 像素的锚点之间相差不大,但是它们对应的特征维度不一样导致它们对目标检测的判断参数也不一样,因此本文 RPN 网络可以针对不同尺寸的害虫有不同尺寸和不同维度的锚点进行对应。




图 7 RPN 网络滑动窗口过程

Fig. 7 Sliding window process of RPN network

2.3 基于 ROIAlign 的 MPF R-CNN 检测网络设计

在检测区域中,需要对特征图进行一定比例的特征映射操作。ROI Pooling 是 Faster R-CNN 原本的特征映射方法,如果使用该方法进行特征映射,就难以避免出现因取整操作造成如图 8 所示的特征偏差,这对黄板害虫检测影响非常大。因为害虫体积小,所对应的特征像素少,一旦发生特征偏差就容易出现重要特征像素消失的情况。为了解决该问题,在 MPF R-CNN 中使用 ROIAlign^[31] 代替 ROI Pooling。




图 8 ROI Pooling 特征映射过程和 ROIAlign 特征映射过程

Fig. 8 Process of ROI Pooling feature mapping and ROIAlign feature mapping

ROIAlign 特征映射过程如图 8 所示,其主要步骤为:

- (1) 先遍历每一个特征建议区域并保持浮点数边界不做量化。
- (2) 进一步根据候选区域分割成 $K \times K$ 的不作

量化的单元。为了适应特征提取网络产生的不同尺寸的特征图,本算法 K 的计算公式为

$$K = \frac{\text{Min}(l, w)}{c} \tag{1}$$

式中 l ——输入图像长
 w ——输入图像宽
 c ——特征图像建议区域产生过程中锚点所对应的正方形的原图像的边值(如,使用 1×1 的滑动窗口对 p4 特征图进行滑动产生 32 像素×32 像素的锚点, c 便为 32)

(3) 对每个单元使用双线性插值法将该单元分成 4 个具有浮点值的像素点。

(4) 对每个单元进行最大池化操作,将 4 个浮点数合并成为一个浮点数。

本文使用 ROIAlign 在对特征图进行映射时使用了双线性插值法和浮点运算,这样 ROIAlign 特征映射的结果不会出现 ROI Pooling 特征偏差的情况,因此更符合黄板害虫的检测需求。

2.4 基于双损失函数的 MPF R-CNN 算法回归与分类优化

由于黄板上存在大量的害虫,如果只使用单函数做回归和分类任务,参数收敛的时间就相对较长,因此本文使用 2 种损失函数分别作用于 RPN 网络和检测网络。RPN 网络损失函数(RPN loss)为

$$L(\{p_i\}, \{t_i\}) = \frac{1}{N_{\text{cls}}} \sum_i L_{\text{cls}}(p_i, p_i^*) + \lambda \frac{1}{N_{\text{reg}}} \sum_i p_i^* L_{\text{reg}}(t_i, t_i^*) \tag{2}$$

其中 $L_{\text{cls}}(p_i, p_i^*) = -\ln(p_i p_i^* + (1 - p_i^*)(1 - p_i))$

$$\tag{3}$$

$$L_{\text{reg}}(t_i, t_i^*) = \sum_i \text{smooth}(t_i, t_i^*) \tag{4}$$

$$\text{smooth}(t_i, t_i^*) = \begin{cases} 0.5(t_i - t_i^*)^2 & (|t_i - t_i^*| < 1) \\ 0.5 & (|t_i - t_i^*| \geq 1) \end{cases} \tag{5}$$

式中 N_{cls} ——分类样本数(本网络中为 4)
 N_{reg} ——网络回归样本总数(本网络为 4 000)
 p_i ——第 i 个候选框区域目标的预测概率
 p_i^* ——第 i 个建议候选框区域的判断值
 t_i ——第 i 个预测边框的坐标
 t_i^* ——第 i 个真实边框的坐标
 L_{cls} ——分类损失函数
 L_{reg} ——边框回归损失函数
 λ ——回归和分类比重的权值参数(在训练中设置为 2 000)

本文使用上述设置的目的是使 RPN 网络进行分类和回归权重比为 2: 1, 从而使 RPN 网络稍微侧重于分类任务。虽然使用 L_{reg} 损失函数可以减弱损失函数在定值期间的波动情况和训练初期不稳定的情况, 但是在检测网络部分并不适合运用 L_{reg} 函数来执行回归任务。因为 L_{reg} 函数要求独立计算出 4 个边框点损失并假设这 4 个点相互独立。实际上, 这 4 个边框点有联系, 这导致了最终的回归不够准确并且时间较长。因此本文在检测网络区域使用 CIoU loss 损失函数^[32], 计算式为

$$L_{CIoU} = 1 - I_{oU} + \frac{p^2(b, b^{gt})}{d^2} + \alpha v \tag{6}$$

其中

$$\alpha = \frac{v}{1 - I_{oU} + v'} \tag{7}$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{gt}}{l^{gt}} - \arctan \frac{w^r}{l^r} \right)^2 \tag{8}$$

式中 α ——权重参数 p ——欧氏距离
 b ——预测框中心 b^{gt} ——真实框中心
 d ——预测框和真实框的最小包围的对角线长度
 v ——长宽比相似性衡量值
 w^r ——边框宽度 l^r ——边框长度
 w^{gt} ——预测边框宽度
 l^{gt} ——预测边框长度
 I_{oU} ——预测的边框和真实的边框交集和并集的比值

式(6)优点在于能够对检测框的覆盖面积、中心点距离和长宽比例 3 方面进行调整, 加速模型收敛。

3 实验结果与分析

3.1 实验环境与评价指标

本文实验算法操作平台为台式计算机, 计算机处理器为 Intel Core i7 - 9700, 默认频率为 3. 0 GHz, 硬盘容量 8 TB, 内存 16 GB, 显卡 NVIDIA 2080TI。开发环境为: ubuntu 16. 04, Python 3. 6, anaconda 1. 9. 12, CUDA 版本为 10. 0。本文的目标检测网络在训练前, 先在 ImageNet 数据集上进行预训练, 作

为 ResNet101 + FPN 初始训练参数, 这样可以大大减少 ResNet101 + FPN 网络的训练时间。ResNet101 + FPN 初始化参数如表 1 所示。

表 1 初始化参数

Tab. 1 Initialization parameters

参数	数值
初始化学学习率	0. 003
权重衰减速率	0. 000 5
学习率衰减速率	0. 1
学习率衰减步长	30 000
冲量	0. 9
迭代次数	15 000

采用平均精度(Average precision, AP)作为每一种害虫检测的评价指标, 同时采用平均精度均值(Mean average precision, mAP)作为算法整体性能评价指标。

此外, 当害虫大爆发时, 对不计其数的害虫进行计数并无实际生产意义, 应在害虫爆发前进行预警并做出相应的害虫防治措施。本文通过咨询农学专家, 当黄板害虫数量达到 960 只时预示害虫数量已经非常多, 应及时预警。因此在害虫实际数量大于 1 600 只时, 按照 1 600 只计算, 也就是分割后的图像上害虫数量大于 100 只按照 100 只计算, 并且当算法检测害虫数超过 60 只时就会发出害虫爆发预警, 让人工及时地采取相应的害虫防治措施并清理黄板。同时, 害虫数量在 60 ~ 100 只之间, 每增加 10 只算法都会发出一次严重预警。因此在本文算法中的平均精度(AP) 的参数(FP) 范围设定在 0 ~ 100 只害虫。

3.2 不同特征网络模型精度测试与分析

本实验采用不同的图像特征提取网络(VGG - 16、ResNet50、ResNet101、ResNet152、ResNet50 + FPN、ResNet101 + FPN、ResNet152 + FPN) 对黄板害虫进行目标检测。网络训练完成后使用平均精度作为每种害虫的目标检测评价指标并使用平均精度均值作为整个网络对所有害虫识别性能的评价指标。不同网络的对比结果如表 2 所示。

表 2 不同特征提取网络的模型性能结果对比

Tab. 2 Comparison of model performance results of different feature extraction networks

特征提取网络	平均精度(AP) /%				平均精度均值	平均检测	训练时间/
	烟粉虱	黄曲条跳甲	小菜蛾	其他大型害虫	(mAP) /%	时间/s	min
VGG - 16	53. 33	61. 42	68. 63	65. 56	62. 23	0. 31	812
ResNet50	74. 41	72. 51	70. 13	75. 36	73. 10	0. 33	1 592
ResNet101	76. 64	77. 35	78. 21	76. 34	77. 13	0. 33	1 605
ResNet152	73. 47	75. 59	78. 98	77. 38	76. 35	0. 41	1 624
ResNet50 + FPN	85. 23	85. 64	86. 42	84. 68	85. 49	0. 35	1 684
ResNet101 + FPN	87. 84	86. 94	87. 42	86. 38	87. 14	0. 36	1 721
ResNet152 + FPN	83. 51	81. 32	82. 81	80. 57	82. 05	0. 44	1 733

从表 2 可以看出,使用 ResNet101 + FPN 网络时,本模型检测效果最好,达 87.14%。当本模型以 VGG-16 作为特征提取网络时,检测平均精度都低于 70% 且最后检测结果非常容易出现一个区域建议框内有多个目标的情况。造成此种情况最主要的原因是害虫的体积过小导致有一些特征无法通过多次卷积进行特征提取。当本模型以 ResNet50 为特征提取网络时,整体的平均精度均值比 VGG-16 提高了 10.87 个百分点,是因为残差网络可以解决深度卷积网络梯度消失的问题。此外,ResNet50、ResNet101 和 ResNet152 都存在每种害虫检测平均检测精度相差较大的情况,是由于不同尺寸的害虫在不同深度的卷积下特征表达的清晰度不一样,有的特征可能更加明显,有的特征可能已经丢失。当残差网络加入 FPN 网络后,检测平均精度均值均有所提高,但是模型的整体训练时间和检测时间都增加了。造成这一现象的主要原因是参数的增加导致计算的复杂度增加。此外,其他大型害虫检测的平均精度在 ResNet50 + FPN、ResNet101 + FPN 和 ResNet152 + FPN 网络中均比小菜蛾、黄曲条跳甲和烟粉虱检测的平均精度低。导致上述结果的原因,一方面是大型害虫样本数量较少,并且样本集合由食蝇蜜蜂、瓢虫和金龟子多种害虫样本组成,所以单一大型害虫样本数量则更少;另一方面,由于大型害虫都是体积较大,特征相对丰富,因此平均精度相差并不是很大,在 ResNet101 + FPN 中与平均精度最高的烟粉虱相差只有 1.46 个百分点。

3.3 不同密度下的检测结果分析

虽然本算法在采用 ResNet101 + FPN 作为特征提取网络时,平均精度均值达到 87.14%。但是分析检测结果时发现,不同分割图像之间的检测结果存在较大差异,其中害虫密度和天气是造成差异的主要因素。为了更易分析不同密度对本算法检测结果的影响,本文根据害虫的数量将测试集图像分为低、中、高 3 种密度层次,根据农事专家建议,最终确定每 54.68 cm² 内(按 16 等份分割后图像对应的实际尺寸)害虫数量在 0~30 之间为低密度,害虫数量在 30~60 之间为中密度,害虫数量大于 60 为高密度。按照以上标准将 3 904 幅分割后的测试图像进行低、中、高密度划分后,结果如表 3 所示。

从表 3 可以看出,本算法在低密度下平均精度均值可达 96.34%,但随着害虫密度上升算法平均精度均值有所下降。因为随着害虫密度的上升,害虫出现堆叠和黏连的情况越多,并且害虫密度高的图像中害虫由于死亡时间过长尸体完整度保留性相

表 3 不同密度下检测结果

Tab.3 Detection results at different densities			
密度等级	平均精度均值/%	平均召回率/%	图像数量
低	96.34	64.58	1 008
中	91.27	86.51	1 344
高	85.79	79.73	1 552

对较低,所以本算法在高密度下平均精度均值只有 85.79%。然而,本算法在低密度下召回率较低,是因为低密度区域害虫总数少,然而漏检的害虫数量虽然少,但是其所占的比重比较大。此外,由于害虫具有分布不均匀特点,因此分割前的图像会包含不同密度等级的分割图像,为了分析算法合并后的效果,所以本文按照害虫总数在 0~480 之间为低密度、480~960 之间为高密度和大于 960 为高密度的标准对分割前的图像进行划分。将 3 904 幅分割后测试图像检测完成后合并成 244 幅图像,结果如表 4 所示。通过对比表 3 和表 4 表明,虽然本算法是对分割后的图像进行检测,但是合并后的检测结果依旧能反映原来的图像情况。

表 4 合并后图像不同密度下检测结果

Tab.4 Detection results of images with different densities after merging			
密度等级	平均精度均值/%	平均召回率/%	图像数量
低	93.41	69.63	72
中	89.76	88.49	83
高	86.48	75.37	89

3.4 不同天气下的检测结果分析

为了分析本算法在不同天气下的检测效果,本文将已经按低、中、高密度图像划分后的测试图像根据晴天和雨天进一步划分。晴天和雨天不同密度害虫检测结果如图 9、10 所示。通过对图 9a 和图 10a 进行分析,可以发现在低密度区域下晴天和雨天检测结果相差不大,这是因为雨天相机的曝光率低,所以雨天害虫特征比较清晰。通过对图 9b 和图 10b 进行分析,可以看出在中密度区域晴天和雨天检测结果相差不大的情况下,均出现了将 2 个黏连一起的小菜蛾识别为同一个体情况,这是因为数据标注时未将黏连的害虫进行标注。通过对图 9c 和图 10c 进行分析,可以发现在高密度区域下雨天相比晴天出现更多害虫漏检的情况。中低密度不会出现以上情况是因为雨水会降低黄板的粘性导致害虫出现位移、堆叠或掉落的情况,而在高密度下的图像中因害虫的数量多以及黄板放置的时间长,所以更容易出现漏检情况。总体而言,虽然本算法在高密度下雨天的检测召回率会低一些,但是在高、中、低密度下晴天和雨天的检测准确率差距不大。




图 9 晴天不同密度害虫检测结果

Fig. 9 Pest detection results of different densities in sunny days




图 10 雨天不同密度害虫检测结果

Fig. 10 Pest detection results of different densities on rainy days

3.5 黄板害虫计数分析

害虫数量是非常重要的农业信息,因此本文将 244 幅测试图像中的害虫数量与本算法计数结果进行统计分析。从图 11 中可知,算法害虫计数结果与害虫实际数量的决定系数为 0.925 5。当害虫实际数量低于 480 时,算法计算结果处于相关性函数上方,侧面说明本算法在害虫低密度时计数准确率较高并且害虫密度是影响本算法的重要因素。




图 11 害虫总数与算法计数结果相关性分析

Fig. 11 Correlation analysis between total number of pests and counting results of algorithm

同时,从图 12 可以看出不同害虫在计数差值之间存在一定差异。烟粉虱的差值相对其他害虫较大,主要是因为烟粉虱体积小且数量最多,导致算法更加容易出现漏检的情况。黄曲条跳甲计数结果的平均差值和最小差值比小菜蛾低,但最大差值比小菜蛾高,是因为黄板在环境复杂的田间,偶尔会出现黄曲条跳甲害虫因为环境变化突然增多的情况,导致算法出现较大的计数差,而这是实际生产中一定会出现的情况但偏差仍然在可接受的范围内。总体而言,本算法对害虫的计数结果能一定程度反映害

虫真实的数量情况,并且计数结果与害虫实际数量的平均差值较小。




图 12 害虫算法计数与害虫实际数量差值

Fig. 12 Difference between algorithm count of pests and actual number of pests

3.6 移动端应用测试

为了测试算法在实际应用中的情况,本文在以“微信小程序 + 云存储服务器 + 算法服务器”为架构的黄板害虫检测系统上,使用了 4 台算法服务器并利用小米 7 手机对测试集进行测试。如图 13a 所示对图像进行上传操作,并如图 13b 所示使用微信小程序后台测试工具进行测试。结果表明,黄板害虫检测系统能正常完成黄板害虫图像上传、图像分割、图像检测、图像合并以及图像检测任务,平均每次检测时间为 1.7 s,对于每次检测任务仅需要 3% 的 CPU 资源消耗和 228 MB 的内存占用。由于图像被分割成 16 份,所以平均每幅分割图像检测时间为 0.425 s,与原本每幅分割图像检测时间 0.36 s 相差不大,造成时间差距的原因是图像传输过程中需要一定的时间。同时,手机上传晴天和雨天黄板害虫图像检测结果如图 13c、13d 所示,表明本文算法对于晴天和雨天黄板害虫的检测结果差距不大,因此本文算法在移动端应用具有可行性。




图 13 小程序应用测试结果

Fig. 13 Applet test results

4 结论

(1) 用智能手机作为载体,将基于 Faster R - CNN 改进的害虫检测算法 MPF R - CNN 应用于黄板害虫的识别。通过对 ResNet101 + FPN 特征提取

网络、RPN 网络进行设计,使用 ROIAlign 替代 ROI Pooling,以及使用双损失函数进行算法优化和控制,在真实复杂的自然环境下对烟粉虱、黄曲条跳甲、小菜蛾和其他大型害虫(体长大于 5 mm)检测的平均精度分别为 87.84%、86.94%、87.42% 和 86.38%。

(2)进一步实验表明,MPF R-CNN 在 35 cm × 25 cm 黄板上不超过 480 只的低密度下平均精度均

值高达 93.41%,并且计数结果与害虫计数决定系数为 0.925 5。

(3)通过“微信小程序+云存储服务器+算法服务器”为架构的系统对算法进行应用测试,结果表明,该算法能支持当前便携式应用,且该系统平均每次检测时间为 1.7 s。随着未来样本数的提升、手机拍摄技术的升级以及对合并边缘极少数害虫进行去重优化,该算法的检测精度会进一步提升。

参 考 文 献

- [1] 刘刚. 广东省通报夏季蔬菜病虫害发生趋势[J]. 农药市场信息, 2018(13): 55.
LIU Gang. Guangdong Province notified the trend of summer vegetable diseases and insect pests [J]. Pesticide Market Information, 2018(13): 55. (in Chinese)
- [2] 郑庆伟. 广东省冬种蔬菜病虫害发生动态[J]. 农药市场信息, 2019(1): 56.
ZHENG Qingwei. Occurrence dynamics of diseases and insect pests of winter vegetables in Guangdong Province [J]. Pesticide Market Information, 2019(1): 56. (in Chinese)
- [3] 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)
- [4] 陈娟, 陈良勇, 王生生, 等. 基于改进残差网络的园林害虫图像识别[J/OL]. 农业机械学报, 2019, 50(5): 187–195.
CHEN Juan, CHEN Liangyong, WANG Shengsheng, et al. Pest image recognition of garden based on improved residual network [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(5): 187–195. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20190522&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2019.05.022. (in Chinese)
- [5] LARIOS N, SORAN B, SHAPIRO L G, et al. Haar random forest features and SVM spatial matching kernel for stonefly species identification[C]// 2010 20th International Conference on Pattern Recognition. IEEE, 2010.
- [6] NAZRI A, MAZLAN N, MUHARM F. PENYEK: automated brown planthopper detection from imperfect sticky pad images using deep convolutional neural network[J]. PLoS ONE, 2019, 13(12): e0208501.
- [7] CHOWDHURY R R, PREETOM S A, MOHAMMED E A, et al. Identification and recognition of rice diseases and pests using convolutional neural networks[J]. Biosystems Engineering, 2020, 194: 112–120.
- [8] LI Wenyong, WANG Dujin, LI Ming, 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.
- [9] 祝诗平, 卓佳鑫, 黄华, 等. 基于 CNN 的小麦籽粒完整性图像检测系统[J/OL]. 农业机械学报, 2020, 51(5): 36–42.
ZHU Shiping, ZHUO Jiaxin, HUANG Hua, et al. Wheat grain integrity image detection system based on CNN [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(5): 36–42. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20200504&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2020.05.004. (in Chinese)
- [10] 程曦, 吴云志, 张友华, 等. 基于深度卷积神经网络的储粮害虫图像识别[J]. 中国农学通报, 2018, 34(1): 154–158.
CHENG Xi, WU Yunzhi, ZHANG Youhua, et al. Image recognition of stored grain pests: based on deep convolutional neural network [J]. Chinese Agricultural Science Bulletin, 2018, 34(1): 154–158. (in Chinese)
- [11] 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.
- [12] MICHAEL G S, ALEJANDRO V, HENRY R, et al. AI-powered banana diseases and pest detection[J]. BioMed Central, 2019, 15(1): 92.
- [13] JIAO Lin, DONG Shifeng, ZHANG Shengyu, 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.
- [14] 杨红珍, 张建伟, 李湘涛, 等. 基于图像的昆虫远程自动识别系统的研究[J]. 农业工程学报, 2008, 24(1): 188–192.
YANG Hongzhen, ZHANG Jianwei, LI Xiangtao, et al. Remote automatic identification system based on insect image [J]. Transactions of the CSAE, 2008, 24(1): 188–192. (in Chinese)
- [15] 龚爱平, 吴武豪, 裴正军, 等. 基于 Android 系统手机的叶面积测量方法[J/OL]. 农业机械学报, 2013, 44(9): 203–208.
GONG Aiping, WU Wuhao, QIU Zhengjun, et al. Leaf area measurement using Android OS mobile phone [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(9): 203–208. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20130936&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2013.09.036. (in Chinese)
- [16] 田有文, 郑鹏辉, 许童羽, 等. 基于安卓的黄瓜叶部病害程度检测系统的研发[J]. 计算机工程与设计, 2016, 37(5): 1411–1416.

- TIAN Youwen, ZHENG Penghui, XU Tongyu, et al. Developing detecting system for cucumber leaf disease severity based on Android[J]. Computer Engineering and Design, 2016, 37(5): 1411 – 1416. (in Chinese)
- [17] CAI Jiahao, XIAO Deqin, LÜ Lishan, et al. An early warning model for vegetable pests based on multidimensional data[J]. Computers and Electronics in Agriculture, 2019, 156: 217 – 226.
- [18] 戴建国, 赖军臣. 基于图像规则与Android手机的棉花病虫害诊断系统[J/OL]. 农业机械学报, 2015, 46(1): 35 – 44. DAI Jianguo, LAI Junchen. Image-rule-based diagnostic expert system for cotton diseases and pests based on mobile terminal wit Android system[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(1): 35 – 44. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20150106&journal_id=jcsam. DOI: 10. 6041/j. issn. 1000-1298. 2015. 01. 006. (in Chinese)
- [19] 薛丽娜, 吴晟. 基于Android平台的马铃薯虫害指认诊断系统[J]. 安徽农业科学, 2015, 43(28): 346 – 348. XUE Li'na, WU Sheng. Potato pest identification system based on Android [J]. Journal of Anhui Agricultural Sciences, 2015, 43(28): 346 – 348. (in Chinese)
- [20] 叶海建, 郎睿. 基于Android的自然背景下黄瓜霜霉病定量诊断系统[J/OL]. 农业机械学报, 2017, 48(3): 24 – 29. YE Haijian, LANG Rui. Cucumber downy mildew severity quantifying diagnosis system suitable for natural backgrounds based on Android [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(3): 24 – 29. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20170303&journal_id=jcsam. DOI: 10. 6041/j. issn. 1000-1298. 2017. 03. 003. (in Chinese)
- [21] PETHYBRIDGE S J, NELSON S C. LEAF doctor: a new portable application for quantifying plant disease severity[J]. Plant Disease, 2015, 99(10): 1310 – 1316.
- [22] PETHYBRIDGE S J, NELSON S C. Estimate, a new iPad application for assessment of plant disease severity using photographic standard area diagrams[J]. Plant Disease, 2018, 102(2): 276 – 281.
- [23] 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. XIAO Deqin, ZHANG Yukang, FAN Meihong, et al. Pest counting algorithm based on visual perception [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 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. (in Chinese)
- [24] 樊湘鹏, 周建平, 许燕, 等. 基于改进卷积神经网络的复杂背景下玉米病害识别[J/OL]. 农业机械学报, 2021, 52(3): 210 – 217. FAN Xiangpeng, ZHOU Jianping, XU Yan, et al. Corn disease recognition under complicated background based on improved convolutional neural network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(3): 210 – 217. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20210323&journal_id=jcsam. DOI: 10. 6041/j. issn. 1000-1298. 2021. 03. 023. (in Chinese)
- [25] 冯帅, 许童羽, 周云成, 等. 基于深度卷积神经网络的水稻知识文本分类方法[J/OL]. 农业机械学报, 2021, 52(3): 257 – 264. FENG Shuai, XU Tongyu, ZHOU Yuncheng, et al. Rice knowledge text classification based on deep convolution neural network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(3): 257 – 264. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20210329&journal_id=jcsam. DOI: 10. 6041/j. issn. 1000-1298. 2021. 03. 029. (in Chinese)
- [26] 王浩云, 肖海鸿, 马仕航, 等. 基于MRE-PointNet+AE的绿萝叶片外形参数估测算法[J/OL]. 农业机械学报, 2021, 52(1): 146 – 153. WANG Haoyun, XIAO Haihong, MA Shihang, et al. Estimation algorithm of leaf shape parameters of scirpus sibiricum based on MRE-PointNet and autoencoder model[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(1): 146 – 153. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20210116&journal_id=jcsam. DOI: 10. 6041/j. issn. 1000-1298. 2021. 01. 016. (in Chinese)
- [27] 侯俊铭, 姚恩超, 朱红杰. 基于卷积神经网络的蓖麻种子损伤分类研究[J/OL]. 农业机械学报, 2020, 51(增刊1): 440 – 449. HOU Junming, YAO Enchao, ZHU Hongjie. Classification of castor seed damage based on convolutional neural network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(Supp. 1): 440 – 449. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=2020s152&journal_id=jcsam. DOI: 10. 6041/j. issn. 1000-1298. 2020. S1. 052. (in Chinese)
- [28] 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 and Machine Intelligence, 2017, 39(6): 1137 – 1149.
- [29] LIN T Y, DOLLAR P, PIRSHICK R, et al. Feature pyramid networks for object detection [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE Computer Society, 2017.
- [30] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2016.
- [31] HE K, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN [C] // IEEE Transactions on Pattern Analysis & Machine Intelligence. IEEE, 2017.
- [32] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: faster and better learning for bounding box regression[C] // AAAI Conference on Artificial Intelligence, 2020: 12993 – 13000.