

基于 Faster-RCNN 的机场跑道异物识别定位技术研究

蒋 进, 唐碧蔚, 宋少雷, 靳 超, 何志勇

(中国航空无线电电子研究所, 上海 200241)

[摘 要] 针对机场跑道异物(FOD)识别检测,分析了机场跑道环境特性,建立了针对机场FOD图像识别数据库,提出了一种基于Faster-RCNN的机场跑道异物识别定位系统,通过无人机系统对机场跑道进行图像采集,运用Faster-RCNN算法框架完成异物种类识别,并结合无人机地理位置信息进行位置换算求解,得到机场FOD的类别信息和位置信息。经验证,该系统可高效完成机场FOD检测识别及定位任务。

[关键词] 机场跑道异物; 无人机; 目标识别; Faster-RCNN

[中图分类号] TP391.41 [文献标识码] A [文章编号] 1006-141X(2020)03-0008-05

Research on Identification and Location of Foreign Object Debris on Airport Runway Based on Faster-RCNN

JIANG Jin, TANG Bi-wei, SONG Shao-lei, JIN Chao, HE Zhi-yong

(China National Aeronautical Radio Electronics Research Institute, Shanghai 200241, China)

Abstract: Aiming at airport Foreign Object Debris(FOD) identification, the characteristics of the airport runway environment is analyzed, and an image recognition database of the airport FOD is set up. An airport FOD identification and locating system is proposed based on Faster-RCNN, runway image acquisitions carried out based on the unmanned aerial vehicle (UAV) system, using Faster-RCNN algorithm framework for FOD identification, and combining the UAV position location to get the FOD category information and location information. It has been verified that the system can efficiently complete the airport FOD identification and locating task.

Key words: foreign object debris; UAV; target identification; Faster-RCNN

机场跑道异物(FOD: Foreign Object Debris)主要指在机场跑道道面会对飞机安全起降带来隐患的外来物质,包括金属器件、碎石块、纸制品、动植物等^[1]。FOD容易损坏飞机轮胎或被发动机吸入,造成飞机滑偏或发动机停火。目前,国外已使用多种FOD探测系统,包括新加坡iFerret系统、英国Tarsier系统、

以色列FODetect系统以及美国FOD Finder系统,而国内机场跑道依然采用人工检测方式。

FOD探测研究主要包括雷达探测技术研究和视频图像识别技术研究。由于雷达探测技术对FOD探测虚警率和漏检率高,且探测得到信息有限,存在一定局限性,本文研究视频图像识别技术。

收稿日期: 2020-08-17

引用格式: 蒋进, 唐碧蔚. 基于Faster-RCNN的机场跑道异物识别定位技术研究[J]. 航空电子技术, 2020, 51(3): 08-12.

国内外学者对基于视频图像识别技术做了大量研究, Chadwick 等人分别研究了基于视频的固定式 FOD 检测系统和基于视频的移动式 FOD 检测系统, 固定式 FOD 检测系统对同一场景下不同时刻图像进行对比分析, 移动式则采用双摄像机构成立体视觉系统分析道面深度信息^[2]; 北京航空航天大学研究人员提出通过当前图像与事先提取的跑道背景差分运算得到 FOD 信息^[3]; 王宇等提出了一种基于边缘特征的异物检测方法^[4]; 郑浪等改进区域生长算法, 通过改进区域生长准则, 对分割区域按融合三要素法则进行合并, 得到机场跑道异物的分割图像从而实现异物检测^[5]。分析可知, 目前研究成果仍聚焦于基于图像对比检测与图像分割的 FOD 检测, 缺少或难以获取 FOD 类别信息。

本文提出一种高效 FOD 检测识别定位方法, 采用无人机进行机场跑道图像采集, 引入深度神经网络进行目标检测识别, 最后结合无人机 GPS 定位信息换算得到 FOD 具体位置信息, 在信息内容和检测识别效率上都得到了较大的提高。

1 无人机图像采集

采用多旋翼无人机携带 Tarot T10X 云台相机进行图像采集, 具备独立 IMU 云台控姿, 保证图像采集的稳定。相机内置 10 倍光学变焦镜头, 光圈值 F2.0, 采用 1/3 英寸彩色 CMOS4 图像传感器, 输出图像为 1920×1080 像素。

无人机飞行航线规划遵循内缩原则和长航线原则, 采用迂回式航线规划策略, 规划结果示意图如图 1 所示。




图 1 航线示意图

假设无人机拍摄角度为垂直向下, 无人机飞行速度为 v , 图像采集航向重叠率和旁向重叠率为 ω , λ 。图像密度 I 计算公式如下^[6]:

$$I = (H \square W_{\text{sensor}}) / (F \square W_{\text{img}})$$

其中 H 为飞行高度, W_{sensor} 为相机 CMOS 宽度, W_{img} 为图像宽度, F 为摄像头焦距。

则单张图像对应实际覆盖距离公式如下:

$$\begin{cases} P_{\text{real}} = P_{\text{img}} \square I \\ H_{\text{real}} = H_{\text{img}} \square I \end{cases}$$

其中 P_{img} 为旁向图像宽度, H_{img} 为航向图像宽度, P_{real} 为旁向实际覆盖距离, H_{real} 为航向实际覆盖距离。

设 v 为无人机飞行速度, 则相机拍摄频率可得:

$$Hz_{\text{shot}} = v / (H_{\text{img}} \square I (1 - \lambda))$$

2 FOD 识别与定位

2.1 识别定位系统框架

FOD 识别定位系统框架如图 2 所示。由于机场环境特殊, 且 FOD 图像真实样本较少, 对于基于 Faster-RCNN 算法的训练限制较大。本文采用同类型航拍数据集进行预训练以减少对训练数据集的需求, 同时对无人机采集的图像进行处理和人工确认, 补充 FOD 样本数据集, 从而实现识别模型的不断完善, 解决样本集不全的问题。




图 2 FOD 识别定位系统框架示意图

2.2 Faster-RCNN 算法

目前, 主流的深度学习目标检测框架可以分为 One-Stage 和 Two-Stage 两种。One-Stage 指的是算法不需要提取图像中的候选边框, 直接进行目标位置的回归与识别, 相较于 Two-Stage 的 Faster R-CNN 算法具有更快的检测速度, 但精度会有所降低。考虑到机场 FOD 体积面积相对较小, 且对于目标识别的实时性要求不高, 所以本文选用 Faster-RCNN 算

法框架^[7]。其主要结构如图3所示。




图3 Faster-RCNN 算法框架图

Faster-RCNN 算法框架主要分为四部分，卷积神经网络层、RPN网络层、ROI池化层和目标分类与边界框回归。

各部分主要功能如下：

(1) 卷积神经网络层：通过卷积、激活和池化操作，提取图像特征图；

(2) RPN网络层：共分为两条线，分别是通过 softmax 分类器进行前景与背景分类与计算建议窗口的偏移量，最后综合获取候选区域，并进行剔除过滤；

(3) ROI池化层：对区域候选框进行归一化处理，得到固定大小的特征表示；

(4) 目标分类与边界框回归：通过两个全连接层，分别采用 softmax 实现多目标分类和回归模型对边界框调整，实现目标类别与位置确定。

本文采用的深度特征提取网络为 ResNet-50 网络，也即深度残差 50 层网络。ResNet-50 网络结构图如图4所示，主要包括 Identity Block 和 Conv Block。其中 Identity Block 的输入输出维度一样，可串联增加网络深度。Conv Block 的输入输出维度不一致，用于改变网络维度。ResNet-50 网络参数^[7]如表1所示。

表1 Res Net-50 网络参数表

卷积类型	输出尺寸	卷积尺寸与特征通道数
卷积层 (Conv2d)	112×112	$7 \times 7, 64, \text{stride}=2$
池化层 (max pooling2d)	56×56	$3 \times 3, 64, \text{stride}=2$
卷积块 (Conv2d+BN+Relu)	56×56	$[1 \times 1, 64; 3 \times 3, 64; 1 \times 1, 256] \times 3$
卷积块 (Conv2d+BN+Relu)	28×28	$[1 \times 1, 128; 3 \times 3, 128; 1 \times 1, 512] \times 4$
卷积块 (Conv2d+BN+Relu)	14×14	$[1 \times 1, 256; 3 \times 3, 256; 1 \times 1, 1024] \times 6$
卷积块 (Conv2d+BN+Relu)	7×7	$[1 \times 1, 512; 3 \times 3, 512; 1 \times 1, 2048] \times 3$




图4 ResNet-50 网络层次图

2.3 数据集选择与训练

由于机场环境特殊，获取深度学习训练样本数量较少，为得到更好的训练效果，采用迁移学习策略。迁移学习的目标就是将某个领域或任务上学习到的知识应用到不同的但相关的领域或问题中。为此采用相近的航拍数据进行预训练，选用 ICCV2018 Workshop 举办 Vision Meets Drone: A Challenge（简称：VisDrone2018）数据集作为模型的预训练数据集，如图5所示。VisDrone2018 数据集均由无人机采集，共八千多张图像，经手工标注而成，数据集包括行人、车辆等目标，与机场跑道异物识别有一定的类似性。

采用 VisDrone2018 数据集进行预训练，设置模

型学习率为0.0005，minibatch为64，训练迭代500次，得到基础模型。




图5 VisDrone2018 数据集示例

采用混凝土路面模仿机场跑道路面, 将 FOD 分 (1) 飞机发动机连接件 (螺帽、螺钉、垫圈、保险丝等); (2) 机械工具 (螺丝刀、扳手等); (3) 飞行物品 (私人证件、水壶、钱包、手机等); (4) 野生动物 (蛇, 鸟, 猛禽等); (5) 树叶、石头和沙子、道面材料、木块、塑料、纸制品等进行图像样本采集, 并进行人工标注, 如图 6 所示。自制训练集共 400 张图片, 包含 5 类目标 1000 多个。



图 6 机场跑道异物识别训练数据集

将自制数据集按 8:2 比例随机生成训练集和测试集, 其中 80% 作为训练数据集, 剩余的 20% 作为验证数据集采用训练数据集进行模型训练, 设置模型学习率为 0.00001, minibatch 为 64, 训练迭代 1000 次, 得到 FOD 识别计算模型。

3 目标位置换算

经过目标识别模型得到 FOD 在图像中的图像目标, 并不是目标在机场跑道实际坐标位置, 需进行位置转换。采集的每一张图像都有地理 GPS 坐标位置 L_0 经过机体坐标换算可得到相机中心位置 $L_1 = L_0 + \overline{L_d}$ 。设图像中心坐标为 x_0 , 目标位置为 x_1 , 则目标实际位置 L_2 为:

$$L_2 = (x_1 - x_0) \square I + L_1$$

4 FOD 识别定位试验

在某机场, 无人机按照本文中所述的路径规划方法, 飞行高度 30 m, 相机焦距 10 mm, 保持 10

m/s 飞行速度进行飞行。其中, 单张图像覆盖范围 $14.4\text{m} \times 8.1\text{m}$, 60% 航向图像重叠率情况下, 拍摄频率 3 Hz, 拍摄全域离散图像。一共飞行 10 个架次, 每次在跑道上的不同位置, 放置不同数量、不同种类的异物。

地面站中的检测识别系统对无人机下传的图像依次进行处理, 处理环境为 win10 专业版操作系统, CPU Intel i5-8400, NVIDIA 显卡 RTX2060 移动版, 8G 内存, 500G 加 128G 双固态硬盘。处理结果如图 8 所示, 标示出异物的类别、坐标信息和置信度信息。表 2 给出了 10 个架次飞行后的异物识别率、准确率和定位平均偏差, 从表中可以得出: 1) 召回率 (recall) 为正确识别异物数量占样本总异物数量比例, 测试结果最低为 97.5%, 最高 100%, 平均 99.4%, 未识别均为小型石块, 且像素大小少于 32×32 像素, 小于 Faster-RCNN 算法最小识别尺寸; 2) 准确率 (precision) 为正确识别异物数量占总识别目标数量的比例, 测试结果最低 90%, 最高 95%, 平均 91.6%; 3) 定位偏差受无人机定位数据和图像偏差计算影响, 考虑机场跑道形状规则, 对定位精度要求有限, 所以选择 GPSM8N 定位模块, 该 GPS 双模工作模式最高精度可达 0.5-1 米, 将实际物品位置与识别定位数据对比可得, 定位评价偏差最小 0.7 米, 最大 1.2 米, 平均 0.91 米; 4) 单张图像处理时间最长 0.260s, 最短 0.229s, 平均处理时间为 0.237s。




图 7 单图形识别定位结果

表 2 实测识别正确率

飞行架次	1	2	3	4	5	6	7	8	9	10
异物个数	10	15	20	25	30	40	50	60	70	80
识别个数	10	15	20	25	30	40	49	60	69	78
召回率	100%	100%	100%	100%	100%	100%	98%	100%	98.5%	97.5%
准确率	90.0%	93.3%	95.0%	93.3%	91.5%	92.5%	92%	91.6%	91.4%	90.0%
定位平均偏差 / 米	0.8	1.2	0.9	0.8	1.1	0.8	1.0	0.9	0.8	0.9
处理时间 s/ 张	0.234	0.229	0.235	0.256	0.260	0.238	0.234	0.234	0.232	0.234

5 结束语

本文通过引进无人机勘察与 Faster-RCNN 目标识别算法框架,利用 VisDrone2018 数据集进行模型预训练,并自制数据集完成模型训练,搭建了一套机场 FOD 识别定位系统,经过验证,可满足机场 FOD 识别定位作业需求,也为其他类似应用场景提供了工程可实现技术。

参 考 文 献

- [1] 国家民航总局机场司民航安全技术中心. FOD 防范手册 [Z]. 北京: 国家民航总局机场司民航安全技术中心, 2009: 1-5.
- [2] CHADWICK A., EVANS R., FINDLAY D., et al. Airport runway debris detection study [R]. 2001.
- [3] XU Q, NING H, CHEN W. Video-based foreign object

debris detection [C]. IEEE International Workshop on Imaging Systems and Techniques (IST 2009), Shenzhen, China, May 11-12, 2009: 119-122.

- [4] 王宇, 吴炜, 张德银. 基于计算机视觉的机场跑道异物检测识别系统 [J]. 电视技术, 2010, 34(5): 102-104, 116.
- [5] 郑浪, 罗天洪, 王成琳. 适用于机场跑道异物检测的区域生长改进算法 [J]. 现代电子技术, 2020, 43(09): 51-54.
- [6] 于越. 基于无人机的航拍车辆目标视觉检测与地理定位系统 [D]. 东南大学, 2019.
- [7] REN Shaoqing, HE Kaiming, GIRSHICK Ross. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6).
- [8] 于晨. 基于深度学习的机场跑道异物检测与识别技术研究 [D]. 北京工业大学, 2019.