

引用格式:彭盖伦,彭道刚,张浩,等.基于 Faster R-CNN 和模糊 PID 的巡检机器人云台控制研究 [J]. 微电子学与计算机, 2019,36(3):61-65. [PENG Gai-lun, PENG Dao-gang, ZHANG Hao, et al. Research on inspection robot PTZ control based on faster R-CNN and fuzzy PID[J]. Microelectronics & Computer,2019,36(3):61-65.]

基于 Faster R-CNN 和模糊 PID 的巡检机器人云台控制研究

彭盖伦,彭道刚,张 浩,夏 飞

(上海电力学院 自动化工程学院 上海发电过程智能管控工程技术研究中心,上海 200090)

摘 要:云台系统作为智能巡检机器人的视觉载体,承载着巡检机器人的核心功能,基于预置位的传统云台运作模式电厂复杂环境下显得乏力.针对复杂环境下云台预置位少、反应慢等问题,提出了一种基于 Faster R-CNN 和模糊 PID 的云台控制策略,利用 Faster R-CNN 检测并识别云台输送图像中的目标,根据目标与图片的位置关系判断云台运动方向,计算中心坐标的误差并送入模糊 PID 控制器进行参数调节来达到控制云台的目的.实验结果表明,利用 Faster R-CNN 进行目标检测识别可达到 90.8% 的准确率并且运行在毫秒级,模糊控制使云台能够快速反应并平稳运行,应用效果良好.

关键词: 巡检机器人;云台控制;Faster R-CNN;模糊 PID

中图分类号: TP391

文献标识码: A

文章编号: 1000—7180(2019)03—0061—05

Research on inspection robot PTZ control based on faster R-CNN and fuzzy PID

PENG Gai-lun,PENG Dao-gang,ZHANG Hao,XIA Fei

(School of Automation Engineering, Shanghai University of Electric Power, Shanghai Engineering Research Center of Intelligent Management and Control for Power Process, Shanghai 200090,China)

Abstract: As the carrier of vision for intelligent inspection robots, the pan/tilt system carries the core functions of the inspection robot. The traditional PTZ operation mode based on preset positions appears to be weak in substations, power plants and other complex environments. Aiming at the problem of less pre-position and slow response of the PTZ in complex environments, a PTZ control strategy based on Faster R-CNN and fuzzy PID is proposed. To detect and identify targets in the PTZ transmission image using Faster R-CNN. According to the position relationship between the target and the picture, the motion direction of the PTZ is judged, and the error of the center coordinate is calculated and sent to the fuzzy PID controller for parameter adjustment to achieve the purpose of controlling the PTZ. Experimental results show that the use of Faster R-CNN for target detection and identification can achieve an accuracy of 90.8% and run in milliseconds. The fuzzy control enables PTZ to respond quickly and run smoothly, and the application results is good.

Key words: inspection robot; PTZ control; Faster R-CNN; fuzzy PID

1 引言

电力巡检机器人的一般工作流程如下:巡检机

器人在接受巡检任务后,将按照既定的路线进行巡检.从出发点开始,每到达一个巡检任务点机器人将会停止并激活云台系统,云台摄像头找到指定设备

并拍摄图片或视频上传至后台监控系统,再对图像和视频进行处理和分析以判断设备的状态^[1]. 智能巡检机器人在执行巡检任务的过程中,要求云台的运动具有较高的控制精度,较好的稳定性和较快的反应速度以达到提升巡检效率的目的. 目前投入使用的巡检机器人主要根据云台预置位来定位设备位置,读取设备信息. 大型变电站和电厂环境中设备种类和数量繁多,常规云台 256 个预置位显得乏力. 此外,根据预置位追寻目标设备往往会导致所获取图像及视频信息质量的参差不齐.

针对上诉问题,一些研究人员提出如基于图像分析的策略^[2]来提升定位精度,但牺牲了响应速度,也并没有解决预置位限制的问题. 而深度学习在目标检测和目标识别领域表现优秀,其数学模型具有比浅层网络更优越的非线性逼近能力和泛化能力,在语音识别、复杂图像识别、复杂控制系统建模等领域表现出强大的性能^[3-5]. 其中 Faster R-CNN 在目标识别和目标检测中表现优异,在人脸检测、车牌识别等诸多领域已有成熟的应用,大量的数据已表明该算法几乎已能达到实时性要求^[6-7].

本文针对云台预置位少、反应慢等问题提出了一种提出了结合 Faster R-CNN 和模糊 PID 的云台控制策略思路. 由 Faster R-CNN 实现目标识别和目标检测,并将图片主体的位置偏差作为自适应模糊 PID 的输入量,通过模糊推理自整定 PID 参数以达到快速调整云台位置的目的. 实验结果表明,在该控制策略下云台控制具有较高的精度和较快的反应速度,能提高巡检机器人云台捕获图像的效率,具有一定的应用价值.

2 系统结构及控制方案

云台的整体控制策略如图 1 所示,云台摄像机拍摄原始图片,并将获得的每帧图片送入 Faster R-CNN 网络中检测并识别. 在识别目标的任务中, FasterR-CNN 会输出包含各类设备的概率矩阵,根据所得概率值与设定置信区间的关系判定目标是否被找到;RPN 分支用于生成候选区域,完成边界框回归,输出其坐标矩阵. 本文以目标中心坐标与图像中心位置的欧氏距离判断目标主体是否处于最佳位置,如果在运动过程中目标被判定为未识别或未处于最佳位置,则将该误差送入自适应模糊 PID 控制器中进行调整参数控制云台选择合适的速度和方向运动找到最佳位置.

根据巡检机器人应用场景的特点,机器人相对

于待检目标设备(仪表、绝缘子、变压器、线路等)处于下方位,同时,由于目前大多数应用型巡检机器人采用激光导航系统,机器人轨道铺设于两侧待检设备的中间. 因此当巡检机器人到达巡检任务点时,可设置云台开始检测的标准位置为水平 ± 90 度,垂直 ± 45 度,这样的初始位姿设置可提高目标设备被找到的概率,减少多余的寻找动作,节省完成任务的时间.




图 1 云台控制策略

3 关键技术

3.1 基于图像的反馈控制

云台系统是典型的二自由度运动系统,被控对象为云台电机转动速度. 为了实现对云台控制的实时跟踪,本文采用基于图像的反馈控制. 基于图像的控制策略关键在于计算 Faster R-CNN 网络所给出的目标框和图片坐标中心的位置关系如图 2 所示. 通过 GT 在图像中的位置关系来判断云台水平/垂直方向选择,即以图像中心为坐标原点建立二维平面坐标系,以像素值为坐标单位值. 在该坐标系下判断云台应选择的水平/垂直方向. 本文规定云台运动顺序为先水平再垂直,即云台启动后首先在水平方向达到误差范围之内之后再垂直方向的动作.




图 2 位置关系图

两者中心位置的距离误差用作模糊控制器的输入,并由模糊控制器调节参数来控制云台电机转动速度. 本文将两者中心位置的欧式距离作为距离误

差,其计算公式如下:

$$\rho = \sqrt{(x-x')^2 + (y-y')^2}$$
 (1)

式中, ρ 为欧氏距离, (x,y) 和 (x',y') 分别是图片中心坐标和目标框中心点坐标. 本文选取水平运动方向用于误差分析实验验证,设定云台对准偏离图像中心 50 像素左右的目标.

本文将图像平面坐标下像素误差作为控制输入,致力于将相机光轴对准目标,使目标始终保持在图像中心. 采用此策略所采集到的图片具有良好的图像性质,能满足后台对图像做进一步处理的基本要求. 利用阈值来限定模糊 PID 控制器接近稳态时的动作,即当目标中心在图像中心一定阈值范围内的矩形中心时认为已经捕获目标. 此时电机停转,保持云台在当前位置. 控制算法流程如图 3 所示.

3.2 模糊控制器设计

模糊控制理论在工程应用上相当成熟,对于伺服电机的控制表现良好^[8]. 本文将 Faster R-CNN 所得目标中心坐标与图像中心坐标的误差 e 、误差变化率 α 作为模糊控制器的输入量,输出选取 PID 控制器的

三个参数的修正值 $\Delta K_p, \Delta K_i, \Delta K_d$,而不是输出系数 k_p, k_i, k_d ,这样更能平稳地调节参数,不会使控制效果不稳定. $\Delta K_p, \Delta K_i, \Delta K_d$ 模糊推理规则如表 1 所示,其中 E 和 EC 是 e 和 α 模糊化后的量.




图3 云台控制流程图

表1 模糊控制规则

		EC		
		ΔK_p	ΔK_i	ΔK_d
E	NB	NB NM NS ZO PS PM PB	NB NM NS ZO PS PM PB	NB NM NS ZO PS PM PB
	NM	PB PB PB PB PS ZO NS	PB PB PB PB NS NM NB	PB PB PB PB NS NM NB
	NS	PB PB PM PM ZO NS NM	PB PB PM PM NM NB NB	PB PB PM PM ZO PS PM
	ZO	PB PM PM PS NS NM NB	PB PM PS PS NB NB NB	PB PM PM NS PM PB PB
	PS	ZO ZO ZO ZO ZO ZO ZO	ZO ZO ZO ZO ZO ZO ZO	ZO ZO ZO ZO ZO ZO ZO
	PM	NB NM NS PS PM PM PB	NB NB NB PS PS PM PB	PB PB PM NS PM PM PB
	PB	NM NS ZO PMPBPB PB	NB NB NM PM PM PB PB	PM PS ZO NM PM PB PB
		NS ZO PSPBPB PB PB	NB NM NS PBPBPB PB	NS NM NB NBPBPB PB

3.3 Faster R-CNN 目标检测与识别

Faster R-CNN 的网络结构如图 4 所示,Faster R-CNN 可看作是由生成目标候选区的 RPN(Regional Proposal Network)和利用这些候选区的 Fast R-CNN 检测器组成的. 整个目标候选区域提取、深度特征提取、目标识别和检测过程都融入在一个深度神经网络模型中. 其中,RPN 是一个完全卷积网络(FCN),其输入前一层为任意大小的特征图,输出为一系列的矩形目标候选区域. Fast R-CNN 网络基于 RPN 提取的候选框检测并识别主体. RPN 和 Fast R-CNN 都是在共享卷积网络的最后一层添加相应的层得到的. 这一部分包括兴趣区域池化层(RoI Pooling Layer)和全连接层(Fully

Connected layers, FC)等.




图4 Faster R-CNN 结构

根据本文数据体量选用了 ZFnet 结构主体.

ZFnet 主体包含 5 个卷积层, 图片输入在经过卷积运算后, 将在最后一个卷积层得到特征图 (Feature Map). 特征图是图像的深层卷积特征, 表现为相似物体的深度特征非常接近, 不同物体的深度特征是非常不同的. 因此, 对象可在特征映射下表现良好的区分度.

(1) RPN 网络训练

RPN 的训练是端到端的, 使用的优化方法是反向传播和随机梯度下降, 损失函数是分类误差和回归误差的联合损失^[9]:

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

式中, i 表示第 i 个 anchor 点; $p_i^* = 1$ 表示第 i 个 anchor 点为正样本; t_i^* 表示候选区域边框和真实目标边框之间的偏差; N_{cls} 和 N_{reg} 分别为分类损失函数与位置回归损失函数的归一化系数; λ 为两者之间的权重参数.

分类损失是两个类别 (目标和非目标) 的对数损失:

$$L_{\text{cls}}(p_i, p_i^*) = -\log[p_i^* p_i + (1 - p_i^*)(1 - p_i)] \quad (3)$$

位置回归损失为检测框与真实框的误差:

$$L_{\text{reg}}(t_i, t_i^*) = R(t_i - t_i^*) \quad (4)$$

式中, R 是鲁棒的损失函数 (smooth $_{L_1}$):

$$\text{smooth}_{L_1}(x) = \begin{cases} 0.5x^2 & \text{if } |x| < 1 \\ |x| - 0.5 & \text{otherwise} \end{cases} \quad (5)$$

在训练时, 正样本为与任意的真实边框 (Ground Truth, GT) 的 IoU 大于 0.7 的候选区域; 负样本为与所有 GT 的 IoU 小于 0.3 的候选区域. 而不属于以上两种情况的目标候选区域不在训练中使用.

(2) 共享卷积

Faster R-CNN 的优势在于 RPN 和 Fast R-CNN 两个网络能够共享卷积层的参数, 而不用单独训练两个独立的网络. 这样所有过程都可以再 GPU 中运行, 从而大大提高了整个检测速度却不降低检测精度. 因此本文采用联合训练的方法, 即在每次迭代过程中, 前向传播时将 RoI 视为固定的, 在反向传播时将 RPN 的损失和 Fast R-CNN 的损失合并. 整体训练遵循如下过程:

①利用 ImageNet 图像分类任务中的训练数据对 ZFnet 模型进行预训练;

②使用第一步生成的候选框作为输入, 使用①中预训练的 ZFnet 初始化, 并训练 Fast-R-CNN 网络.

③使用第二步训练的 Fast R-CNN 参数初始化 RPN, 将 RPN 特征提取网络参数固定, 仅学习 RPN 特有的参数层. 此时, RPN 与 Fast-R-CNN 网络共享特征提取网络参数;

④使用第三步训练的 RPN 网络重新生成候选框, 固定 Fast R-CNN 特征提取网络参数, 按照参数训练 Fast R-CNN 网络. 最终两个网络完全共享参数.

为了进一步提高检测的时效和准确度, 本文将目标的检测问题转化为二元分类问题 (目标和背景), 训练的策略采用 fine-tuning 技术. 训练过程中设置学习率从 0.001 开始, 然后在 50K 步后下降到 0.0001.

4 实验

本实验对象是基于实验室巡检机器人的云台系统. 云台系统硬件主要由摄像头、图像采集卡、电机驱动器和工控机等组成^[10], 实验室云台摄像头的帧数约为每秒 30 帧 (Frames Per Second, FPS), 即每隔 33 ms 采集一次数据, 因此采样时间为 33 毫秒. 本文在 Visual Studio 2015 平台下实现控制算法, 并装载在工控机中, 由工控机通过 TCP/IP 协议与云台系统通讯和发送控制命令. 实验选取水平方向运动作为测试验证, 将待测设备设置在偏离云台摄像头光心 100 像素左右, 按照图 3 算法流程进行验证.

用于 FasterR-CNN 训练的主要硬件配置如下: CPU: Intel 酷睿 i7-7800x, GPU: GeForce GTX1080ti. 软件环境选择在 Linux 系统下安装 Caffe 深度学习框架来实现卷积神经网络模型的搭建.

4.1 实验数据集

本文利用实验室云台以不同角度拍摄原始数据, 通过 Opencv 图像变换获得 1 120 张图片, 并处理成 VOC2007 数据集^[11] 的格式用于 FasterR-CNN 训练. 对其中 1 000 张人工标注作为训练数据集, 剩余 120 张图片用作验证数据集.

4.2 实验结果

对于二分类 1 000 张样本的目标检测与识别任务, Faster R-CNN 的识别率为 90.8%, 用时 68 ms. 图 5 给出了实验中水平方向误差, 可知目标设备与图像中心误差基本保持在 50 像素以内, 少部分超出




图5 水平方向像素偏差

误差范围,但在可接受范围内.云台整体能够在稳定状态下运行.

本文对比了一些典型算法在本文数据集下的检测数据,如表2所示,相比于R-CNN, Fast R-CNN 和 Faster R-CNN 在检测时间和识别准确率表现更好,而 Faster R-CNN 相比 Fast R-CNN 检测时间降低了一个数量级,达到了毫秒级别,可满足检测实时性.因此,总体上采用 Faster R-CNN 算法用于目标检测识别可基本满足要求.

表2 不同方法效果对比

	训练样本	时间/s	准确率/%
R-CNN	1 000	24.3	84.2
Fast R-CNN	1 000	1.8	90.8
Faster R-CNN	1000	0.068	90.8

5 结束语

巡检机器人云台的目的在于在短时间内拍摄良好的图片供后台处理分析,本文利用深度学习下的 Faster R-CNN 算法并结合图像坐标关系为智能巡检机器人云台系统摆脱云台预置位供了新的思路,具有一定应用价值.实验结果表明,Faster R-CNN 设备检测中的准确率为 90.8%,检测时间为毫秒级,为云台系统的实时控制做好了铺垫.通过云台测试实验表明,基于图像中心坐标的控制策略也能够稳定运行.针对电厂复杂环境下的设备检测与识别问题,笔者将在下一步的工作中深入研究.

参考文献:

[1] 鲁守银,张营,李建祥,等. 移动机器人在高压变电站中

的应用[J]. 高电压技术,2017,43(1):276-284.

[2] 张游杰,焦荣华. 一种基于图像分析的云台预置位控制方法[J]. 现代电子技术,2012,35(10):57-60.

[3] LIU Z Y, ZHAO X Y, SUI J C. PTZ control system of indoor rail inspection robot based on neural network prediction model[J]. Procedia Computer Science, 2017 (107): 206-211.

[4] 郑仕伟,韩俊刚. 基于深度学习的非接触掌纹识别方法[J]. 微电子学与计算机,2018,35(4):98-102.

[5] WANG A R, LU J W, CAI J F, et al. Large-margin multi-modal deep learning for RGB-D object recognition[J]. IEEE Transactionson Multimedia, 2015, 17 (11): 1887-1898.

[6] WU D, WU J S, ZENG R, et al. Kernel principal component analysis network for image classification [J]. Journal of Southeast University, 2015, 31(4): 469-472.

[7] 戴陈卡,李毅. 基于 Faster RCNN 以及多部件结合的机场场面静态飞机检测[J]. 计算机应用,2017,37(增刊2):85-88.

[8] 周俊鹏,李焱. 模糊自整定 PID 控制器在光电伺服设备中的应用[J]. 电气传动,2015,45(9):62-65.

[9] REN S, GIRSHICK R, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on PatternAnalysis & Machine Intelligence, 2017, 39(6):1137-1149.

[10] 崔明月. 复杂环境下不确定轮式移动机器人运动控制的研究[D]. 重庆:重庆大学,2012.

[11] EVERINGHAM M, WINN J. The PASCAL visual object classes challenge 2007 (VOC2007) development kit[J]. International Journal of Computer Vision, 2006, 111(1):98-136.

作者简介:

彭盖伦 男,(1992-),硕士研究生.研究方向为电力巡检机器人技术.

彭道刚(通讯作者) 男,(1977-),博士后,教授.研究方向为智能发电自动化、新能源微电网与能源互联网、电力智能巡检机器人等. E-mail: pengdaogang@126.com.

张浩 男,(1962-),博士.研究方向为能源互联网、电力巡检机器人.

夏飞 男,(1971-),博士.研究方向为故障诊断、图像处理与分析.