

DOI: 10.7652/xjtuxb201910015

基于深度学习的高铁受电装置 安全状态快速检测方法

冯勇¹, 宋天源², 钱学明²

(1. 中车青岛四方车辆研究所有限公司电气事业本部, 266000, 山东青岛;

2. 西安交通大学电子与信息工程学院, 710049, 西安)

摘要: 针对因受电弓形变、脱离而影响高铁运行安全的问题,提出了一种快速而且准确的检测高铁受电弓的方法,能够对高铁受电弓严重形变、脱离等情况进行及时预警。该方法首先利用在高铁受电弓前的摄像头捕捉到的 10 000 余张图片作为训练样本,并利用这些训练样本对自定义的深度学习卷积神经网络进行离线训练,生成预测模型,然后在高铁运行过程中利用训练好的模型和改进后的 YOLOv2 算法对摄像头的实时监控图像进行在线检测,最后检测程序将返回检测结果,对受电弓缺失、严重形变等现象进行预警。采用该方法在 CPU 平台以 55 帧/s 的检测速度对受电弓进行实时检测,平均准确率达到 93.1%。

关键词: 高铁;受电弓;安全状态;深度学习;目标检测

中图分类号: TN953 **文献标志码:** A **文章编号:** 0253-987X(2019)10-0109-06

A Fast Detection Method for Safety States of Power Receiving Device on High-Speed Rail Based on Deep Learning

FENG Yong¹, SONG Tianyuan², QIAN Xueming²

(1. Electric Business Headquarter, CRRC Qingdao Sifang Rolling Stock Research Institute Co. Ltd., Qingdao, Shandong 26600, China; 2. School of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: A fast and accurate method to detect and locate pantographs is proposed to solve the safety problem of railways caused by pantograph missing or serious deformation. The deep learning based method firstly uses 10,000 images captured by the camera in front of the high-speed rail pantograph as training samples to perform offline training and to generate a CNN prediction model. Then the model and the improved YOLOv2 are used to implement online testing to the pantograph through the image captured by the camera. Test results are finally returned by a program and an early warning of phenomenons of pantograph loss or severe deformation is provided. Results show that the proposed method detects the pantograph in real time with a detection speed of 55 frames per second on a CPU platform while the average accurate rate is 93.1%.

Keywords: high speed railway; pantograph; safety state; deep learning; detection

在铁路运输进入高速智能化的时代,高铁、地铁 等电气化机车在我国交通系统中起到重要作用。目

收稿日期: 2019-01-10。 作者简介: 冯勇(1981—),男,工程师;钱学明(通信作者),男,教授,博士生导师。 基金项目: 国家自然科学基金资助项目(61772407,61732008);中车研究基金资助项目(F15-11-1)。

网络出版时间: 2019-08-01

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1069.T.20190801.1117.006.html>

前,高铁以平均 300 km/h 的速度稳定运行,运行中需要通过受电装置获取动力,这种在机车电力设备和运营电网之间衔接的取电设备称为受电弓^[1]。受电弓图像如图 1 所示,受电弓正常工作时与顶部电线接触使列车获取动力,受电弓是列车受电装置的核心部分。



图1 受电弓正常工作场景

受电弓是高速铁路牵引供电安全监测系统(6C系统)的一部分,对高铁获取电力保证正常运行有着重要作用。根据铁道部运输局资料显示,牵引供电系统故障造成的铁路事故在 2008、2009、2010 年分别占到了当年事故总数的 28.8%、40.4%、29.6%^[2]。受电弓的故障状态如图 2 所示,图 2a 为受电弓受到异物撞击而断裂,图 2b 为受电弓因电弧打火而脱离高压线使高铁失去动力。为了保障行车安全,需要对受电弓进行快速高效的检测^[3]。受电弓检测原理如下:首先提取大量处于正常状态下的受电弓图像样本,建立受电弓检测模型;然后在线检测运行中的受电弓,若受电弓发生形变或者不处于正常区域,检测程序便会因为无法检测到正常形态的受电弓而及时预警,工作人员就会在第一时间获知受电弓故障信息。



(a)受电弓断裂



(b)受电弓脱离输电线

图2 受电弓的异常情况

当前的受电弓检测技术主要有接触式检测方式和非接触式检测方式^[4]。传统的受电弓检测大都是基于人工登车或利用综合检测车进行检测,这类接触式检测方法极大地提高了检测精度,但主要的缺点是人工检测或利用综合检测车进行接触式检测需要占用线路,干扰正常行车。近年来,非接触式图像检测以其行车干扰小、通用性好、便于安装使用等优点成为受电弓检测领域中的研究热点。当前在基于图像的受电弓状态监测和预警方面,常用边缘检测结合经验阈值的判断方法。姚兰等提出采用边缘检测、霍夫变换分析检测受电弓图像,间接判断接触网是否有故障可能的方法^[5],该方法将传统方法较好的利用在受电弓检测任务中,但是只用到了图像的外观特征而造成复杂场景下的检测精度较低。蒲文旭等也提出过基于紫外光的受电弓电弧检测算法,使用紫外光辅助来对弓网进行检测^[6],但基于紫外光检测的方法需要在原有设备基础上加装紫外设备而带来成本增加。曾攀等人提出通过图像预处理和边缘提取的方法进行受电弓区域检测^[7],通过对别受电弓上下边缘的距离来自动判读受电弓的磨损情况,该方法可以大致估算出受电弓的位置和磨损情况,但同样存在传统图像算法的精度较低的问题。同样基于边缘的检测方法还有张辉等人提出的利用小波变换的边缘检测方法^[8],该方法相比于传统图像算法有更好的抗干扰能力,但实验表明对于复杂图像的处理时效果不及基于深度学习的图像处理方法。

由于受电弓在线监测系统安装在户外,采集的图像图片质量受光线、环境、天气等条件影响很大,相同的受电弓在不同时刻获取的图片光线、阴影、色相和背景物都不一样,使得在各种环境下基于图像检测受电弓变得十分困难。

受电弓检测算法就是要从复杂多变的图片中把受电弓实体完整地提取出来,保证图像分析的结果和整个系统的精度、稳定性不受环境变化的影响。在实际运用中,图像目标和背景之间并不具备截然不同的灰度,随着自然光照射角度的不同,目标和背景的亮度均要发生变化。当前的边缘检测结合经验阈值的检测方法受限于传统图像算法,在长时间实时监测和安全报警的任务中会存在检测精度低的问题。现有方法基于深度学习,能够相比于传统方法更好的提取图像的深度特征,在检测时精度更高,提供更多安全保障。

深度学习近年来飞速发展,一系列基于深度学习的目标检测算法因其良好的鲁棒性使其检测性能

远远超过传统检测方法。基于深度学习的目标检测算法能够轻松地完成对数十种甚至更多物体的检测,但目前来看检测速度慢是该类算法的一大弊端,为了满足实时性要求,本文使用了速度最快的 YOLO 系列算法的第 2 版作为基础算法,并在原有 YOLO 算法的基础上对特征提取网络和检测网络进行改进使其进一步提速,很好地解决了传统方法对复杂场景、长持续时间的受电弓检测性能不佳的问题,在保证检测精度的前提下最大限度地提升了检测速度。本方法可以在 CPU 上达到 55 帧/s 的检测速度,同时保持 93.1% 的平均准确率(AP)。

1 受电弓拉弧检测方法描述

本文中所提出的浅层 CNN 及 YOLOv2 算法的受电弓检测方法包括在线检测和离线训练两大环节,接下来分别对在线和离线系统中所采用的相关方法进行详细介绍。

1.1 YOLOv2 算法介绍

YOLO 算法是由 Redmon 等人近年发布的一种高速目标检测算法^[9]。YOLO 算法一共进行了 3 次改进,又被称为 YOLOv1、YOLOv2 和 YOLOv3。YOLO 系列算法与以 Faster R-CNN^[10]为代表的另一类基于深度学习的目标检测算法不同,Faster R-CNN 系列算法追求高准确率,在很多领域的监控视频中有着很好的性能,如 MPNET 算法^[11]中对监控视频中的行人进行检测。YOLO 系列算法则是追求更快的速度,没有使用先提取区域再对区域分类的整体框架,而是直接对预测框的位置和类别参数进行回归,通过网络直接得到最终的预测结果,这使得 YOLO 系列算法在速度上表现出更大的优势。与 YOLO 算法类似的还有 SSD 算法^[12],但考虑到 SSD 算法所用框架依赖多、移植难等问题,本文最终选用了 YOLO 算法。

YOLO 系列算法的整体思想就是将输入图片划分成一个个网格,然后每个网格预测一组检测框

及其所属的类别,最终取得分最高的检测框和类别作为最终的结果,YOLO 系列算法检测示意图如图 3 所示。YOLO 算法有 3 次改进:YOLOv1 算法通过全连接层直接预测出所有需要的参数如检测框的长宽、检测框的位置以及检测框内物体的类别;YOLOv2 算法^[13]去掉了全连接层,而在检测层加入了锚框(anchorbox),其作用是利用不同尺寸的锚框在各个网格处滑动,遍历所有网格和锚框之后找到得分最高的框作为最终的检测结果,这一方法更好的利用了位置信息,且网络只需要预测出锚框与实际位置的偏差而不是全部参数,使得预测的参数更准确也更容易收敛,因此 YOLOv2 算法相比 YOLOv1 算法对于预测框的准确度上有了很大提高;YOLOv3 算法^[14]则是在 YOLOv2 算法的基础上更换了基础网络,并加入了多分辨率下的预测,使得 YOLOv3 算法对小物体的预测更加准确。

本文最终选择了 YOLOv2 算法来完成受电弓检测任务,主要是因为 YOLO 系列算法速度最快,最能接近 CPU 上实时检测这一目标。同时,YOLOv1 算法对于框的检测精准度较差,而 YOLOv3 算法的网络过于复杂,对于这一简单的检测任务并不需要过多的参数和多分辨率下的预测使最终检测速度变慢。

1.2 受电弓样本提取、标注和训练

本文方法中训练用的图片全部提取于架设在受电弓旁的摄像机所记录的受电弓监控视频。共提取受电弓图片 10 300 张,其中包含 1 080×720、1 920×1 080 和 2 048×1 536 像素 3 种不同分辨率的摄像头拍摄的样本。每张受电弓图片中包含受电弓目标 1 个,即一共包含 10 300 个受电弓目标。在 10 300 张图片中选取 8 300 张作为训练集,其余 2 000 张为测试集。为了保证在全部光线条件下都对受电弓进行准确的预测,受电弓样本中需要包含高铁绝大多数运行场景和背景条件下的图片,根据实际情况把白天和黑天的样本比例大概控制在 3:1 左右。无论是




图 3 YOLO 系列算法检测示意图

白天还是黑天的样本,都需要考虑到背景和光线变化带来的影响,因此白天和黑天的样本中都包含了晴天、雨雪天气、阴天、雾天和进出站时提取的图片。

然后,手动对样本图片进行标注,标注时框出受电弓所在位置,并最终制作成训练集。

最后,对训练集进行训练,训练时共迭代 40 000 次,取初始学习率为 0.000 5,随着训练进行将初始学习率逐渐减小。

1.3 网络结构设计

目前,由于目标检测任务中检测物体种类多,且物体形态特征等变化较大,因而基于深度学习的目标检测多采用 VGG16^[15]、Resnet^[16] 等深层网络来进行特征提取。虽然深层网络的检测性能较好,但是过度依赖于 GPU 的强大计算能力,速度较慢。此外,一些轻量级网络如 MobileNet^[17]、ShuffleNet^[18] 等也因为参数少、速度快而被人们在一些情况下使用。

考虑到检测的目标只有受电弓一类,而且受电弓作为刚体,其形态不会随时间产生变化,同时摄像头与受电弓角度关系相对固定,仅仅采用简单的浅层网络便可以很好地完成对受电弓的检测,因此本文没有采用上文中提到的各种复杂网络,而是采用了重新设计的神经网络,使得算法在保证检测性能没有过多下降的同时,速度大幅加快,仅依赖 CPU 也可以完成实时检测的任务。

网络由特征提取层和最终的检测层组成。网络特征提取层类似于 TINY-YOLO 的网络结构,但使用了更低的输入图片分辨率和更少的卷积核数量来提升检测速度。同时,在检测层的锚框长宽比设计上采用了更贴近受电弓真实长宽比的 4:1,并根据受电弓形态基本不会变化的特点,将锚框数量由 5 个减少为 1 个,也就是仅使用长宽比为 4:1 的锚框来逐个网格滑动对图像进行预测,减少预测层的计算量,进一步提升了检测速度。

本文设计的受电弓检测这种神经网络结构示意图如图 4 所示。图中卷积指图像卷积操作,即将卷积核在原图中滑动,与卷积核中的参数相乘再相加得到新的图片的过程;池化指的是将图像相邻像素点取最大值得到新的图片的像素的过程。图 4 中的所有池化操作都是在图片中取相邻的 4 个像素点中的最大值作为输出图片在该位置的最大值。图 4 中卷积 1 的参数为 $3 \times 3 \times 4$,其中 3×3 表示卷积核的宽与高,4 指的是卷积滤波器的数量。同理,卷积 2 的参数为 $3 \times 3 \times 8$,卷积 3 的参数为 $3 \times 3 \times 16$,卷积

4 的参数为 $3 \times 3 \times 32$,卷积 5 的参数为 $3 \times 3 \times 64$,卷积 6 的参数为 $3 \times 3 \times 128$,卷积 7 的参数为 $3 \times 3 \times 256$,卷积 8 的参数为 $3 \times 3 \times 256$ 。上述所有卷积层的激活函数均为 Leaky Relu 函数。最后的卷积 9 参数为 $3 \times 3 \times 6$,主要目的是将输出通道数变为 6,激活函数采用线性激活函数。




图 4 受电弓检测神经网络结构示意图

2 实验结果与分析

2.1 测试数据集

为了测试本文中所提出受电弓检测方法的有效性,选取了训练集外的受电弓监控视频中每隔抽帧得到的受电弓图片 2 000 张作为测试集,测试集包括 3 种视频分辨率的图像,并且涵盖晴天、雨天、雾天、黑夜、进洞、车站停靠等各种光线条件下的图片。

2.2 性能度量指标

为了客观度量受电弓拉弧检测的性能,采用平均准确率(即平均精度)来检测算法的性能。平均精度(R_{AP})是一种检测中最常用到的统计指标,反映了检测的查准率和查全率的平均性能,其计算公式如下

$$R_{AP} = \frac{1}{11} \sum_{r \in \{0.0, 0.1, 0.2, \dots, 1\}} \hat{P}(r) \quad (1)$$

$$\hat{P}(r) = \max_{\bar{r} \geq r} P(\bar{r})$$

式中: r 表示召回率的阈值; $\bar{r}$ 表示当前的召回率; $\hat{P}$ 表示当前召回率大于阈值的情况下所能取到的最大准确率; P 表示在当前召回率下对应的准确率,判定正负样本的 IOU 阈值选为 0.5。

在统计过程中,召回率 R 和准确率 P 的统计方法如下式

$$R = \frac{T_p}{N} \quad (2)$$

$$P = \frac{T_p}{M} \quad (3)$$

式中: T_p 表示正确预测的数量; N 为全部图像数量,

即测试集的数量,为 2 000; M 为检测出的全部图像数,包含了正确检测和错误检测的全部情况。

此外,算法在 Intel Core I5-4590 CPU 下每秒处理图片的数量(F ,单位为帧/s)作为检测速度的度量。 F 越大,表明处理速度越快。

2.3 受电弓检测性能

表 1 中给出了本文方法、经典的 HOG+SVM 检测方法、Faster R-CNN(VGG-16 网络)检测算法、原版的 YOLOv2(tiny-yolov2 网络)检测算法和 YOLOv3(tiny-yolov3 网络)检测算法这 5 种方法在 2 000 张测试图像上的检测性能对比。

从表 1 中对比可以发现:本文基于深度学习的方法在平均准确率方面优于传统的 HOG+SVM 方法;本文方法与 Faster R-CNN 和 YOLOv3 算法相比,平均准确率低 2%左右,与原版 YOLOv2 算法相比,平均准确率基本持平;同时,速度是 Faster R-CNN 算法的近 1 000 倍,是原版 YOLOv2 算法(原版 tiny-yolov2 网络)的 50 倍,是 YOLOv3 算法的 4.3 倍。

表 1 5 种算法的受电弓检测性能对比

算法	平均精度/%	$F/\text{帧} \cdot \text{s}^{-1}$
HOG+SVM	85.6	3.0
Faster R-CNN	95.2	0.05
原版 YOLOv2	93.5	1.10
YOLOv3	95.0	12.8
本文	93.1	55.0

2.4 检测性能分析

图 5 给出了本文所提出的受电弓检测方法在受电弓不同尺度、背景下的检测性能展示。由图 5 可以看出,在不同环境和背景下,本文方法都能准确地定位出受电弓的位置。




图 5 检测结果展示

个别场景下,会有较低概率产生误检和漏检,误检场景如图 6 和图 7 所示。

在受电弓异常如断裂、降落的情况发生时,系统



图 6 受电弓误检示意图



图 7 受电弓漏检示意图

会因为检测不到正常受电弓而产生警告,如图 8a 与 8b 所示。



(a)受电弓断裂预警



(b)受电弓降落预警

图 8 异常情况预警

3 结束语

本文提出了一种采用浅层 CNN 和 YOLOv2 检测算法来实现对电力机车受电弓快速检测的检测方法。该方法以精简的浅层 CNN 网络为基础网络,并利用 YOLOv2 检测算法对摄像头的实时监控图像进行在线检测,在保证检测准确度的同时大幅提

升了检测速度。实验结果验证了本文方法的有效性。

参考文献:

- [1] 杨东军, 钱学明. 采用分类学习的电气化机车受电弓拉弧检测方法 [J]. 西安交通大学学报, 2017, 51(2): 79-83.
YANG Dongjun, QIAN Xueming, An Arc detection approach for pantograph of electric locomotive using classification learning [J]. Journal of Xi'an Jiaotong University, 2017, 51(2): 79-83.
- [2] 袁欢, 林建辉, 李艳萍. 基于图像处理的受电弓拉弧目标提取 [J]. 信息通信, 2016, 159(3): 36-37.
YUAN Huan, LIN Jianhui, LI Yanping. Image processing based pantograph arc object extraction [J]. Information & Communication, 2016, 159(3): 36-37.
- [3] 马莉, 王泽勇, 高晓蓉, 等. 图像处理技术在受电弓滑板检测中的应用 [J]. 机车电传动, 2009(5): 48-52.
MA Li, WANG Zeyong, GAO Xiaorong, et al. Application of image processing in detecting the pantograph sliding [J]. Electric Drive for Locomotives, 2009(5): 48-52.
- [4] 韩志伟, 刘志刚, 张桂南, 等. 非接触式弓网图像检测技术研究综述 [J]. 铁道学报, 2013, 35(6): 40-47.
HAN Zhiwei, LIU Zhigang, ZHANG Guinan, et al. Overview of non-contact image detection technology for pantograph-catenary monitoring [J]. Journal of the China Railway Society, 2013, 35(6): 40-47.
- [5] 姚兰, 肖建. 基于模糊熵和 Hough 变换的受电弓滑板裂纹检测方法 [J]. 铁道学报, 2014, 35(5): 58-63.
YAO Lan, XIAO Jian. Pantograph slide cracks detection method based on fuzzy entropy and Hough transform [J]. Journal of the China Railway Society, 2014, 35(5): 58-63.
- [6] 蒲文旭, 陈唐龙, 刘宝轩, 等. 基于紫外光的弓网电弧检测系统研究 [J]. 仪表技术与传感器, 2014(7): 64-67.
PU Wenxu, CHEN Tanglong, LIU Baoxuan, et al. Study of pantograph and catenary arc detection system based on ultraviolet light [J]. Instrument Technique and Sensor, 2014(7): 64-67.
- [7] 曾攀, 王俊玮, 邓久强, 等. 基于计算机视觉的受电弓滑板磨损图像的识别 [J]. 无线互联科技, 2016, 7(4): 104-106.
ZENG Pan, WANG Junwei, DENG Jiuqiang, et al. Image recognition of slide abrasion for locomotive pantograph [J]. Wireless Internet Technology, 2016, 7(4): 104-106.
- [8] 张辉, 罗林, 王黎, 等. 基于改进多尺度小波的受电弓滑板边缘检测 [J]. 信息技术, 2015(3): 190-192.
ZHANG Hui, LUO Lin, WANG Li, et al. Improved multi-scale wavelet in pantograph slide edge detection [J]. Information Technology, 2015(3): 190-193.
- [9] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2016: 779-788.
- [10] 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, 2016, 39(6): 1137-1149.
- [11] WANG H, WANG P, QIAN X. MPNET: an end-to-end deep neural network for object detection in surveillance video [J]. IEEE Access, 2018, 6: 30296-30308.
- [12] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector [EB/OL]. [2018-12-25]. https://link.springer.com/chapter/10.1007/978-3-319-46448-0_2.
- [13] REDMON J, FARHADI A. YOLO9000: better, faster, stronger [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2017: 7263-7271.
- [14] REDMON J, FARHADI A. Yolov3: an incremental improvement [EB/OL]. (2018-04-02)[2018-12-01]. <https://arxiv.org/abs/1804.02767>.
- [15] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [EB/OL]. (2014-09-15)[2018-12-01]. <https://arxiv.org/abs/1409.1556>.
- [16] 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. Piscataway, NJ, USA: IEEE, 2016: 770-778.
- [17] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications [EB/OL]. (2017-04-04)[2018-12-02]. <https://arxiv.org/abs/1704.04861?context=cs>.
- [18] ZHANG X, ZHOU X, LIN M, et al. Shufflenet: an extremely efficient convolutional neural network for mobile devices [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2018: 6848-6856.

(编辑 刘杨)