

基于深度学习的高铁接触网定位器检测与识别

陈东杰^{1,2}, 张文生^{1,2}, 杨阳¹

(1. 中国科学院自动化研究所, 北京 100190; 2. 中国科学院大学, 北京 101408)

摘要: 高铁接触网安全监测的主要方法是采用可见光高清相机捕捉接触网零部件的图像序列, 通过图像处理和计算机视觉技术实现对零部件的检测、识别与跟踪。在整个监测系统中, 定位器检测识别是必要的基础工作。传统的目标检测算法受限于特征描述子设计, 难以依靠人工设计出具有通用性、鲁棒性、高精度的特征描述子。于是提出基于 Faster R-CNN 模型实现高精度的接触网定位器检测, 同时采用 Hough 变换检测出定位器的骨架轮廓, 并通过滤线机制筛选出定位器的最优拟合直线段, 为定位器坡度的非接触式精准测量做好基础性工作。

关键词: 定位器; 目标检测; 深度学习; 卷积神经网络; Hough 变换

中图分类号: TP391 **文献标识码:** A doi:10.3969/j.issn.0253-2778.2017.04.006

引用格式: 陈东杰, 张文生, 杨阳. 基于深度学习的高铁接触网定位器检测与识别[J]. 中国科学技术大学学报, 2017, 47(4): 320-327.

CHEN Dongjie, ZHANG Wensheng, YANG Yang. Detection and recognition of high-speed railway catenary locator based on Deep Learning[J]. Journal of University of Science and Technology of China, 2017, 47(4): 320-327.

Detection and recognition of high-speed railway catenary locator based on Deep Learning

CHEN Dongjie^{1,2}, ZHANG Wensheng^{1,2}, YANG Yang¹

(1. Institute of Automation, Chinese Academy of Sciences, Beijing, 100190;
2. University of Chinese Academy of Sciences, Beijing, 101408)

Abstract: High-speed rail monitoring is conducted mainly by adopting image processing and computer vision technology to detect, identify and track catenary components in image sequences taken by the visible light high-definition camera. In the entire monitoring system, the detection and recognition of the locator constitutes the very basis. It is difficult to design the feature descriptor with the characteristics of versatility, robustness and high-accuracy by using traditional target detection algorithms. The detection of the high-accuracy locators based on the Faster R-CNN framework has been realized. Meanwhile, the Hough transform is used to detect the skeleton outline of the locator, and the optimal fitting straight line of the locator is extracted by the filtering mechanism, which paves the way for the non-contact precision measurement of the slope of the locators.

Key words: locator; target detection; Deep Learning; convolutional neural networks; Hough transform

收稿日期: 2016-08-28; 修回日期: 2016-12-08

基金项目: 国家自然科学基金(61432008, 61532006, 61472423) 资助。

作者简介: 陈东杰, 男, 1990年生, 硕士生, 研究方向: 机器学习与人工智能。E-mail: chendongjie2013@ia.ac.cn

通讯作者: 张文生, 博士/研究员。E-mail: zhangwenshengia@hotmail.com

0 引言

近年来我国高铁迅猛发展,积累了海量的高铁运营监测数据.高铁监测数据是交通大数据的重要组成部分,分析处理海量监测数据有助于实现高铁运营管理智能化^[1].在高铁监测数据中,弓网监测数据是主要部分,“弓”意指受电弓,“网”意指接触网,分析弓网监测数据是实现高铁智能管理的有效技术手段.目前,弓网安全监测的通用方法是采用高清相机采集受电弓、接触网以及定位器等目标的图像序列,然后对弓网目标进行检测识别、追踪甚至行为分析.如图1所示,接触网包括导线和拉索,受电弓与

导线紧密配合.定位器负责夹持导线,使导线保持固定姿态.定位器的位姿状态直接保障了接触网的正常工作,因此定位器的视频监测成为弓网安全监测的重要部分.本文通过对定位器的检测识别来达到异常预警的目的.定位器检测属于可见光图像目标检测范畴.传统的目标检测方法通常有背景建模法、帧间差分法、光流法^[2]等,目标检测的首要问题是目标表述.目标表述常用的特征算子有 SIFT^[3]、SURF^[4]、HOG^[5]等.在定位器检测领域,国内目前主要还是用图像目标的特征描述子^[6-8]来解决该问题,然而由于目标的形态、光照、背景等扰动因素使得人工设计一个鲁棒、快速、高精度的特征算子较为困难.




图1 接触网和定位器结构

Fig.1 The structure of catenary and locator

卷积神经网络^[9](convolutional neural networks)是一种对图像检测识别非常有效的前馈网络,通过自底向上逐层提取图像的特征来合成整个图像.在CNN具有良好分类特性的基础上,Girshick提出了基于候选区域的R-CNN^[10]算法,利用选择搜索(selective search)算法^[11]获得场景中目标可能存在的多个备选区域,并取得了较好的图像识别效果.由于尺度不同的备选区域难以输入CNN,需要统一备选区域的尺寸作为输入,导致特征提取重复严重,图像失真导致信息丢失,而且计算速度慢.SPP-net算法^[12]在一定程度上解决了R-CNN算法的上述缺点,并且证明了不同尺度的目标都能够输入深度卷积网络.Girshick借鉴SPP-net算法思想于2015年提出了Fast-RCNN算法^[13],将备选区域映射到CNN的最后一个卷积层的特征图谱上,大大提高了计算速度.同年,He等提出了Faster R-CNN^[14]算法.Faster-RCNN算法将整幅图像分割为固定大小的区域,然后把固定区域输入RPN网络,输出对备选区域的类别判断和位置修正特征图谱;然后将RPN

网络输出的备选区域特征图谱输入RoI(region of interest)池化层和多任务分类器,做更精细的分类和边界框的位置精修.

本文以高铁接触网定位器的目标检测为应用实例,提出了一种基于Faster R-CNN模型的定位器检测方法.该方法主要解决两个问题:一是基于深度学习的定位器目标检测算法的适应性问题.接触网定位器图像的复杂性包含目标尺度不同,复杂背景和遮挡等;白天和夜晚对目标持续成像,满足了光照变化的要求;简单室外背景和复杂室内(隧道、桥梁)背景下对目标成像,满足了复杂场景的要求;由于相机安装角度的偏移,捕捉不同尺度的目标出现部分遮挡,满足了遮挡要求.二是定位器骨架结构检测问题.由于机械连接松动或者突发意外导致定位器的坡度异常,就会影响导线与受电弓的配合关系,进而影响列车行车安全.因此通过Hough变换以及滤线机制检测出定位器的骨架结构,能够实时测量定位器的坡度值,有助于实现高铁接触网定位器坡度的非接触式实时测量.

1 基于深度学习的定位器检测识别

本文基于 Faster R-CNN 模型进行定位器检测识别, 目的在于实现定位器坡度的非接触式测量. 本文框架主要包括两部分内容: 第一部分是定位器区域的检测, 基于 Faster R-CNN 模型的定位器检测如图 2 所示, 第一步将整幅定位图像输入深度卷积神经网络生成特征图谱; 第二步将特征输入 RPN(region proposal networks)网络生成目标候选区域; 第三步

采用 RoI 池化层提取备选区域特征; 第四步利用一个多任务分类器做备选区域的位置回归, 目标类别的判定采用深度学习算法精确检测出定位器的边界框位置. 第二部分是定位器的骨架轮廓检测. 在检测出定位器边界框(最小包络矩形)后, 截取该边界框区域定位器的图像, 然后通过 Hough 变换以及滤线机制筛选定位器的最优拟合直线段; 最后计算定位器的坡度值.




图 2 基于 Faster R-CNN 模型的目标检测框架

Fig.2 Framework of target detection based on Faster R-CNN model

1.1 卷积神经网络(CNN)

CNN 是一种对图像检测非常有效的前馈网络, 可以精确地提取图像的视觉特征. 图 3 是典型深度卷积网络 LeNet-5^[15] 的示意图, 它通常包含若干个卷积层与采样层模块, 以实现逐层提取图像的特征.




图 3 卷积神经网络结构

Fig.3 Framework of convolution neural networks

1.2 RPN 网络

在备选区域与 CNN 分类结合的目标检测框架中, 备选区域选取的质量高低直接影响目标检测的精度. 如果能找到一种方法只提取几百个或者更少的高质量的首选窗口并且召回率很高, 不但能加快目标检测速度, 而且能提高目标检测的性能. RPN 很好地解决了上述难题. RPN 是一个全连接卷积网络^[14], 其核心思想是使用卷积网络直接产生备选区域. 如图 4 所示, RPN 网络用一个 3×3 的空间池化窗口在共享卷积层的特征图谱上滑动一遍, 然后备选区域的特征图谱输入到两个全连接层——边界框回归层和特征分类层, 最后通过锚定机制和最小化回归损失可以得到多尺度多长宽比的备选区域. 具体来说, 锚定机制生成多尺度的锚点, 然后对每一个

候选区域生成训练目标和标签, 最后对于标签大于零的边界框进行位置回归. RPN 网络和整个检测网络共享卷积部分的特征, 同时训练区域的边界和目标存在的信度.

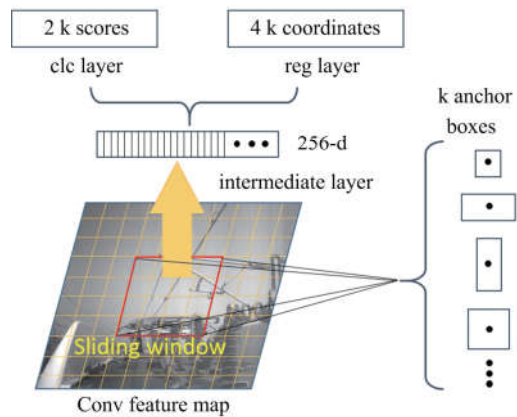


图 4 RPN 网络^[14]

Fig.4 Region proposal network

1.3 RoI 池化层

针对 R-CNN 模型计算耗时的缺点, SPP-net 模型^[16] 加快了计算速度. SPP-net 模型只需要对全局图像提取一次特征, 然后将原图的备选区域所在位置映射到特征图谱相应区域即可, 这样显著提高了检测效率. Fast R-CNN 结合 SPP-net 的思路, 设计了简化的 SPP-net——RoI 池化层. RoI 池化层是只含一个池化层的 SPP-net 结构, 区别在于 SPP-net 把备选区域池化为多个固定尺度, 而 RoI 池化层只把备选区域池化到一个固定的尺度(6×6).

1.4 基于 Faster R-CNN 模型的定位器检测识别

如图 2 所示, Faster R-CNN 模型首先将整幅图像输入深度卷积网络得到特征图谱, 然后输入 RPN 网络, 把获取的备选区域直接连接到 RoI 池化层, 池化后将特征图谱输入到全连接层, 最后利用多任务分类器做特征分类和边界框位置回归. 在整个模型框架中, Faster R-CNN 模型的多任务损失函数定义如下:

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

式中, p_i, t_i 是目标边界框和类别的预测值; p_i^*, t_i^* 是目标边界框和类别的真实值; $N_{\text{cls}}, N_{\text{reg}}$ 分别是分类项和回归项的归一化参数; λ 是平衡权重; L_{cls} 是分类 log 损失; L_{reg} 是回归损失. 分类损失 L_{cls} 的表达式如下:

$$L_{\text{cls}}(p_i, p_i^*) = -\log(p_i^* p_i + (1 - p_i^*)(1 - p_i)) \quad (2)$$

回归损失函数 L_{reg} 的表达式如下:

$$L_{\text{reg}}(t_i, t_i^*) = R(t_i - t_i^*) \quad (3)$$

式(3)中, R 是鲁棒的平滑 L_1 损失^[13], 表达式如下:

$$R(t_i - t_i^*) = \text{smooth}_{L_1}(t_i, t_i^*) \quad (4)$$

式(4)中,

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

Faster R-CNN 模型首先使用预先训练好的 RPN 网络, 输入整幅测试图像, 可以直接得到边界回归后的备选区域; 然后根据备选区域的类别得分对 RPN 网络进行排序, 并选取前 300 个窗口作为 Fast R-CNN 的输入进行目标检测. 训练 RPN 和 Fast R-CNN 时用了四阶段的训练方法^[14] 让 RPN 网络和 Fast R-CNN 网络实现卷积层的权值共享. 权值共享后的 RPN 和 Fast R-CNN 用于目标检测, 精度获得了显著提高. Faster R-CNN 算法使用端到端的一体化网络进行目标检测, 避免了以往算法多阶段训练时缓存中转数据的麻烦, 无论在速度上还是精度上都有大幅提升, 实现了鲁棒、快速、精确的目标检测.

1.5 定位器骨架轮廓检测

1.5.1 Hough 变换检测直线段

霍夫变换^[17-18] (Hough transform) 是图像处理中的一种特征提取技术, Hough 变换将图像空间中

的直线检测问题转换为参数空间中对点的检测问题, 通过在参数空间进行简单的累加统计完成检测. 首先, 图像空间中共线的点对应在参数空间里相交的线; 其次, 在参数空间中相交于同一点的所有直线在图像空间里都有共线的点与之对应. 如果参数空间中使用直角坐标方程, 当图像空间直线斜率为无穷大时, 会使累加器尺寸变得很大, 从而导致计算复杂度过大, 因此 Hough 变换采用极坐标方程. 本文采用 Hough 变换检测定位器的骨架轮廓, 进而估计定位器坡度.

接触网定位架是一个由若干根定位杆用螺栓紧固而成的一个力学桁架结构, 又是支持定位器的基础部件. 定位架包括横腕臂、斜腕臂、斜拉臂、定位管、定位器, 在定位架的支持下, 定位器才能有效夹持接触网. 由于机械振动或者突发意外, 导致定位架上的紧固元件出现松动或者滑脱, 定位杆之间的夹角会发生改变, 极有可能引发定位器坡度异常.

为了保证定位器准确夹持接触网, 使得导线保持在规定的范围内, 必须实时监测定位器坡度是否出现异常, 表现在图像上就是直线段的斜率有无发生大幅改变. 如图 5 所示, Hough 变换检测出的直线段即为定位架的骨架轮廓, 该直线段代表了定位架的骨架结构. 上述方法同样适用于定位器的骨架结构检测, 但是由于定位器相较整个定位架, 尺寸较小, 通过 Hough 变换输入定位架全局图像很难检测出定位器的骨架结构, 因此本文采用的输入图像是采用基于深度学习的目标检测步骤中的定位器边界框区域, 然后截取定位器边界框图像部分, 最后通过 Hough 变换检测定位器的骨架轮廓.




图 5 Hough 变换检测直线

Fig.5 Lines detection based on Hough transform

1.5.2 定位器骨架的最优拟合直线段

本文先采用 Canny 算子^[19] 对定位器的边界框区域图像做二值化边缘检测, 然后将二值边缘图作为 Hough 变换直线检测的输入图像, 最后得到直线检测结果. 大量实验证实了该方法可以检测出多条直线段, 因此需要一个筛选方法来选出最优拟合直

线段.如图 6 所示,Hough 变换检测出若干根直线段.首先根据先验知识剔除接近水平的直线,然后统计检测出的各条直线段的端点坐标,将最左边的端点作为起始点,每隔 1°顺时针扫描终点,直到终点为最右边的端点位置,最后绘制最佳拟合直线段.




图 6 定位器骨架的最优拟合直线段

Fig.6 The optimal matching line of the locator skeleton

由于定位器的外形为细杆状,定位器的最优拟合直线段的斜率可以代表定位器的倾斜状态.从图 7 可以看出,本文提出的方法可以很好地检测出定位器的骨架轮廓.通过连续检测图像序列中的定位器,就可以实时测量出定位器的坡度值,实现定位器异常状况实时预警的目的.




图 7 基于 Hough 变换的定位器骨架检测

Fig.7 Locator framework detection based on Hough transform

2 实验结果与分析

为了验证基于 Faster-RCNN 的目标检测模型在复杂环境下的可靠性,本文采用可见光高清相机随车采集的 5 000 张接触网定位器图片为样本集.将该样本集随机分为训练集(3 000 张)和测试集(2 000 张)完成定位器目标检测与分类试验.如图 8 所示,样本集包括定位器在白天、黑夜和隧道环境以及近距离和远距离成像等几种情况.目标检测前未

对图像作增强处理;采集图像序列中包含了全局目标和部分目标被遮挡两种场景.本文选用的深度 CNN 网络为 CaffeNet^[20],其网络结构如图 9 所示,包含 5 个卷积与降采样模块,1 个备选区域采样层和 2 个全连接层.CaffeNet 是一种清晰而高效的深度学习框架,运算速度快且架构简单,能够运行复杂的模型和海量的数据^[21];CaffeNet 具有模块化功能,方便扩展到新的任务和设置上,是一个纯粹的 C++/CUDA 架构,可以在 CPU 和 GPU 之间无缝切换.为了加速网络运算,本文中 Faster R-CNN 模型在 GPU 并行平台上完成,模型运行环境为 Intel Core i7-4790 和 NVIDIA GeForce GTX 960.




图 8 接触网定位器目标样例

Fig.8 Locator object samples




图 9 CaffeNet 网络结构图^[20]

Fig.9 The network structure of CaffeNet

2.1 基于 Faster R-CNN 模型的定位器检测精度

为了验证基于 Faster R-CNN 的定位器检测模型的性能,本文选用 DPM 模型^[22](基于 HOG 特征)作为基准模型进行对比.此外我们还选用背景建模法、帧间差分法、光流法以及基于 SVM^[23]分类原理实现目标检测作为对比试验.由于定位器形状的特殊性,采用现有的背景建模法、帧间差分法、光流法的检测精度很差;甚至采用 SVM 分类方法检测精度也差强人意.如表 1 所示,对于不同成像距离的定位器,基于 Faster R-CNN 模型的检测精度远远高于 DPM 模型.定位器成像距离为近距离时,基于 Faster R-CNN 模型的检测精度达到 99%,即使定位器成像距离为远距离时,检测精度也能达到 95%以上.测试结果表明,DPM 模型难以实现高精度的定位器检测,而基于 Faster R-CNN 模型实现了高精度检测.

表 1 Faster R-CNN 模型检测精度对比

Tab.1 The comparison of Faster R-CNN locator detection precision

| 模型 | 近距离 | 远距离 | 平均 |
|--------------|------|------|------|
| SVM | 0.42 | 0.46 | 0.44 |
| DPM | 0.81 | 0.73 | 0.77 |
| Faster R-CNN | 0.99 | 0.95 | 0.97 |

除了具有高精度检测指标外,定位器检测的实时性也是高铁接触网安全监测的重要指标.经过实验验证,基于 Faster R-CNN 模型的定位器检测在 GPU 并行平台上运算,检测每幅图片内全部定位器的平均时长为 0.2 s,可以满足高铁行车时对场景目标的实时检测要求.随着硬件性能的提升,并且针对特定任务加入先验知识加速目标检测,算法的运行时间会进一步的缩短,足以满足实时检测的需求.




图 10 不同尺度的定位器检测

Fig.10 Locator detection from different scales

图 10 和图 11 展示了本文模型对于正反两种定位器在不同尺度下的检测精度.从图 11 的统计结果

可以看出,定位器的检测精度随着成像物距的增大而下降.在近距离检测目标时,定位器目标在图像中清晰显著,模型的检测精度为 99%.在远距离检测目标时,模型的检测精度略有降低,但是仍然可以达到平均 95%以上.大量图像序列试验表明,Faster R-CNN 模型可以准确地找到测试图像中的全部定位器.无论定位器处于正定位还是反定位状态,基于 Faster R-CNN 模型的定位器检测都可以达到一个很高的精度,该模型检测出全部定位器的平均精度为 98%.




图 11 不同成像距离的检测精度

Fig.11 Locator detection precision of different distances

2.2 不同尺度下的定位器多目标检测精度

目标距离的远近与图像中目标尺度的大小及分辨率的高低相关.图 12 给出了定位器不同尺度多目标检测与分类的效果.从图 12 可以看出,对于近距离的目标,Faster R-CNN 模型可以准确地对多个定位器进行检测分类,而且受背景干扰较小;对于远距离的目标,该模型对多目标检测分类的精确度略有降低,但检测精度仍然可达 95%.从表 2 可以看出,从检测定位器数量的角度分析,本文提出的基于 Faster R-CNN 模型的检测精度随着定位器成像物距的增加




图 12 定位器多目标检测

Fig.12 Multiple locators detection

而降低;从检测定位器类型的角度分析,正定位和反定位的检测精度基本一致,采用 Faster R-CNN模型检测定位器可以达到平均 98%的高精度。

表 2 定位器多目标检测精度对比

Tab.2 The comparison of multiple locator detection precision

| Faster R-CNN | 近距离 | 远距离 | 平均 |
|--------------|-------|-------|------|
| 单目标 | 0.99 | 0.95 | 0.97 |
| 多目标 | 0.97 | 0.95 | 0.96 |
| 正定位 | 0.99 | 0.97 | 0.98 |
| 反定位 | 0.995 | 0.985 | 0.99 |

Faster R-CNN 模型为端到端的快速一体化模型,可以同时检测出目标的位置与类别.从实验结果可以看出目标检测、分类的精度随着目标物距的增大而略有下降,对于近距离的目标分类,多个定位器均能做到精确识别,而检测远距离定位器的精度虽略有降低,但仍然达到了较高的检测精度.上述结果表明,本文引入的 Faster R-CNN 模型具有很强的适应性,无论是单目标检测还是多目标检测都可以得到一个很好的检测精度,实现了高精度多定位器检测识别。

2.3 基于 Hough 变换的定位器骨架轮廓检测

基于 Faster R-CNN 模型检测出定位器的最小包络矩形后,截取该矩形区域;将矩形区域作为输入,通过 Hough 变换检测出定位器骨架的最优拟合直线段.定位器界限框区域检测已经在 2.1 和 2.2 小节完成,本小节着重介绍基于 Hough 变换的定位器骨架轮廓检测效果。

为了便于监测系统的一体化设计,本文将定位器轮廓检测模块融入基于 Faster R-CNN 模型的定位器检测框架中,实现了端到端的定位器位置、类别以及骨架结构检测.如图 13 和 14 所示,本文的方法




图 13 定位器实时检测(白天)

Fig.13 Locator online detection (day)

无论在白天等简单背景,还是在黑暗、隧道内等复杂背景下均可以实现定位器的高精度检测.尤其是在隧道环境下,基于深度学习的定位器检测体现出了其他方法不可比拟的高精度优势.并且算法加载高性能 GPU(GTX960)后可以实现每秒 50 帧的处理速度,实现了与高铁高速行车同步、实时的高精度的接触网安全监测。

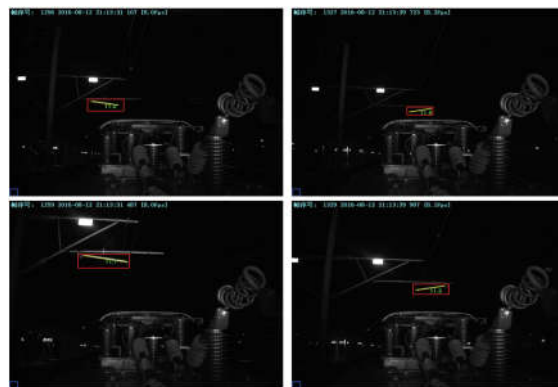


图 14 定位器实时检测(夜晚)

Fig.14 Locator online detection (night)

3 结论

高铁接触网定位器检测算法要求具有实时性、鲁棒性和高精度等特性.鉴于传统目标检测方法的局限性,本文引入了基于 Faster R-CNN 模型进行定位器检测,展现出鲁棒、实时、高精度检测的优良性能,满足了高铁接触网定位器检测的技术指标.本文将深度学习理论应用在高铁接触网定位器的检测识别中,基于深度学习技术实现了对高铁接触网定位器的实时、高精度检测识别,具有很高的工程应用价值.分析三维空间中世界坐标系与相机坐标系的相对位置可知,本文提出的基于 Hough 变换检测定位器的坡度值只是一个工程近似方法,文中的重点在于精确检测定位器位置与轮廓.最后,定位器坡度的精准计算还需要通过单目视觉框架,如基于先验知识进行三维空间的位姿校正以及在特定应用环境下单目相机内外参数标定等,都有待进一步研究。

参考文献(References)

- [1] 张红,王晓明,曹洁,等.基于大数据的智能交通体系架构[J].兰州理工大学学报,2015,41(2):112-115.
ZHANG Hong, WANG Xiaoming, CAO Jie, et al. Architecture of intelligent traffic systems based on big data [J]. Journal of Lanzhou University of Technology, 2015, 41(2): 112-115.

- [2] 张娟, 毛晓波, 陈铁军. 运动目标跟踪算法研究综述[J]. 计算机应用研究, 2009, 26(12): 4407-4410.
ZHANG Juan, MAO Xiaobo, CHEN Tiejun. Survey of moving object tracking algorithm [J]. Computer Application Research, 2009, 26(12): 4407-4410.
- [3] LOWE D G. Distinctive image features from scale-invariant key points [J]. International Journal of Computer Vision, 2004, 60(2): 91-110.
- [4] BAY H, TUYTELAARS T, GOOL L V. SURF: Speeded up robust features [J]. Computer Vision & Image Understanding, 2006, 110(3): 404-417.
- [5] DALAL N, TRIGGS B. Histograms of oriented gradients for human detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. San Diego, USA: IEEE Computer Society, 2005, 1: 886-893.
- [6] 范虎伟, 卞春华, 朱挺, 等. 非接触式接触网定位器坡度自动检测技术[J]. 计算机应用, 2010, 30: 102-103.
FAN H W, BIAN C H, ZHU T, et al. Automatic detection of positioning line in contactless overhead contact system[J]. Journal of Computer Applications, 2010, 30: 102-103.
- [7] 顾会建. 基于视频图片的接触网定位器识别方法研究[D]. 成都: 西南交通大学, 2014.
- [8] 李莹, 叶培建, 彭兢, 等. 火星探测出舱机构的识别定位与坡度测量[J]. 宇航学报, 2016, 37(2): 169-174.
LI Ying, YE Peijian, PENG Jing, et al. Egress mechanism recognition and slope measurement for mars exploration [J]. Journal of Astronautics, 2016, 37(2): 169-174.
- [9] JADERBERG M, SIMONYAN K, VEDALDI A, et al. Reading text in the wild with convolutional neural networks [J]. International Journal of Computer Vision, 2014, 116(1): 1-20.
- [10] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Columbus, USA: IEEE Computer Society, 2014: 580-587.
- [11] UIJLINGS J R R, VAN DE SANDE K E A, GEVERS T, et al. Selective search for object recognition [J]. International Journal of Computer Vision, 2013, 104(2): 154-171.
- [12] HE K M, ZHANG X, REN S Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [C]// Proceedings of the 13th European Conference on Computer Vision. Zurich, Switzerland: ACM Press, 2014: 346-361.
- [13] GIRSHICK R. Fast R-CNN[C]// Proceedings of the IEEE International Conference on Computer Vision. Santiago, USA: IEEE Press, 2015: 1440-1448.
- [14] REN S Q, HE K M, 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, arXiv: 1506.01497.
- [15] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [16] HE K M, ZHANG X Y, REN S Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904-1916.
- [17] HOUGH V, PAUL C. Method and means for recognizing complex patterns, 3069654, US1771560A [P]. 1962.
- [18] DUDA R O, HART P E. Use of the Hough transformation to detect lines and curves in pictures [J]. Communications of the ACM, 1972, 15(1): 11-15.
- [19] DING L J, GOSHTASBY A. On the canny edge detector [J]. Pattern Recognition, 2001, 34(3): 721-725.
- [20] JIA Y Q, SHELHAMER E, DONAHUE J, et al. Caffe: Convolutional architecture for fast feature embedding [C]// Proceedings of the 22nd ACM International Conference on Multimedia. Orlando, USA: ACM Press, 2014: 675-678.
- [21] Caffe: 清晰高效的深度学习 (Deep Learning) 框架 [J/OL]. http://blog.csdn.net/ycheng_sjtu/article/details/39693655.
- [22] FELZENSZWALB P F, GIRSHICK R B, MCALLESTER D, et al. Object detection with discriminatively trained part-based models [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(9): 1627-1645.
- [23] OSUNA E, FREUND R, GIROSI F. Training support vector machines: An application to face detection [J/OL]. <http://doi.ieeecomputersociety.org/10.1109/CVPR.1997.609310>, 2016.06.28.