

基于目标检测的城市路口车辆加塞的行为识别研究

杨倩会¹, 张长伦^{1,2}, 何强¹, 王恒友¹, 黎铭亮¹, 阳光¹

¹北京建筑大学, 理学院, 北京

²北京建筑大学, 北京未来城市设计高精尖创新中心, 北京

收稿日期: 2021年9月8日; 录用日期: 2021年10月13日; 发布日期: 2021年10月20日

摘要

针对城市交通路口常见的车辆加塞行为, 建立一个基于目标检测算法的车辆加塞行为识别模型。首先对城市路口图像进行目标检测, 并对检测结果进行目标类别筛选, 保留加塞行为的目标类别; 其次对目标中心点进行Hough变换, 在图像中拟合多条直线; 然后对Hough变换的结果进行非极大值抑制、非车道方向抑制等后处理, 得到输入图像中车道方向直线; 最后通过计算目标中心点与车道方向直线的距离判定目标是否具有加塞行为。本文采用Hough变换对基于深度学习的目标检测结果进行处理, 通过拟合图像中车道方向直线, 判断车辆与车道方向直线的距离, 可有效检测路口车辆的加塞行为。

关键词

目标检测, 车辆加塞行为, Hough变换

Research on Recognition of Vehicle Cut in Lion Behavior at Urban Intersections Based on Object Detection

Qianhui Yang¹, Changlun Zhang^{1,2}, Qiang He¹, Hengyou Wang¹, Mingliang Li¹, Guang Yang¹

¹Science School, Beijing University of Civil Engineering and Architecture, Beijing

²Beijing Advanced Innovation Center for Future Urban Design, Beijing University of Civil Engineering and Architecture, Beijing

Received: Sep. 8th, 2021; accepted: Oct. 13th, 2021; published: Oct. 20th, 2021

文章引用: 杨倩会, 张长伦, 何强, 王恒友, 黎铭亮, 阳光. 基于目标检测的城市路口车辆加塞的行为识别研究[J]. 图像与信号处理, 2021, 10(4): 176-183. DOI: 10.12677/jisp.2021.104019

Abstract

Aiming at the common vehicle cut in line behavior at urban traffic intersections, a vehicle cut in line behavior recognition model based on the object detection is established. First, perform object detection on the urban intersections image, and perform object category screening on the detection results to retain the traffic categories which may cut in line behavior. Secondly, perform Hough transform on the traffic object center points to fit multiple straight lines in the image. Then perform Non-Maximum Suppression, Non-Lane direction Suppression and other post processing on Hough transform result to obtain the lane direction lines in the image. Finally, by calculating the distance between the object center point and the lane direction line to determine whether the object has cut in line behavior. In this paper, Hough transform is used to process the object detection results based on deep learning. By fitting the lane direction lines in the urban intersections image, judging the distance between the vehicle and the lane direction line, it can effectively detect the traffic cut in line behavior of the intersection.

Keywords

Object Detection, Vehicle Cut in Line Behavior, Hough Transform

Copyright © 2021 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着科技的发展以及人民生活水平的不断提高,汽车走进了千家万户。据统计,2021年上半年全国机动车保有量达3.84亿辆,其中汽车保有量达2.92亿辆[1]。但是飞速增长的机动车保有量与城市建设、交通道路整改力度等往往不是同步的,因此在现实中常见如车辆加塞等违法行为。虽然近年来交警部门通过无人机航拍、电子警察抓拍以及路面查处等方式查处多起车辆加塞行为,但是目前尚无完善的检测车辆加塞的设备与方法,且上述查处方式对人力以及财力的消耗是巨大的。

在技术领域,进行车辆加塞行为识别时,主流的方法是依托监控视频流的信息:通过传统图像处理方法对整幅图像进行处理,提取出相应车辆信息,进而预测车辆行驶轨迹。但此类方法在提取车辆信息时计算量大,严重依赖传统算法对图像的信息提取能力,且车辆信息提取的好坏直接影响预测结果。

随着大数据时代的到来以及深度学习的兴起,基于深度学习的目标检测算法飞速发展。目标检测可分为两阶段目标检测算法[2]-[8]和一阶段目标检测算法[9]-[14],是一类用来检测图片或视频中物体的位置以及类别的算法。虽然该算法可以有效检测道路上的车辆,却不能实现加塞车辆的检测。

基于上述分析,本文提出基于目标检测的城市路口车辆加塞行为的识别研究。以目标检测算法为基础,对算法检测到的城市交通路口的目标车辆进行建模,通过模型分析,有效检测加塞行为的车辆。在现实场景中可对其进行抓拍上传网络,有利于减轻民警负担,同时该方法不需要购买设备,减轻相关部门财政开销。

2. 相关知识

2.1. Faster R-CNN 网络结构

Faster R-CNN 以 Fast R-CNN 为基础,提出了区域选取网络(RPN):通过在特征图上设置的大量锚框

并对其进行分类和回归，得到目标候选区域。RPN 代替了 Fast R-CNN 以及 R-CNN 中使用的传统特征聚合方法 Selective Search，使得 Faster R-CNN 成为第一个真正意义上的端到端的目标检测网络，并被广泛应用于工业界中。

Faster R-CNN 首先将输入网络的图片进行裁剪，使其符合网络输入尺寸，接着使用 13 个卷积激活层和 4 个池化层组成的卷积神经网络对其进行特征提取。生成的特征图输入 RPN 进行检测，得到目标存在的大概位置，为最后的分类和回归提供一次预选。将 RPN 得到的候选区域坐标映射到特征图上获取对应特征，再经过 RoI Pooling 将每一个候选区域的特征映射成相同大小，然后输入下游网络进行分类和回归。

2.2. Hough 变换原理

Hough 变换于 1962 年由 P.V.C. Hough 首次提出[15]，用于对气泡室照片进行机器分析。1972 年，Richard Duda 和 Peter Hart 对其进行改进，提出广义 Hough 变换[16]，通过检测图像中的特征来识别形状，如直线、圆形、椭圆形等。

Hough 变换将原始空间中的曲线(包括直线)通过参数化表示，映射到参数空间，通过统计参数空间中的投票结果，确定可以准确描述原始空间中曲线的参数，从而得到准确描述原始空间曲线的方程。

如图 1 所示，给出一个二维图像，以图像中心为坐标原点建立直角坐标系，直线 l 可以被法向量角度 θ_l 和原点到直线 l 的距离 r_l 参数化表示。在 θ 和 r 参数平面中，直线 l 的参数方程如公式(1)所示，可以看出，图像坐标下的一个点在参数空间中表示为一条曲线，参数系中多条曲线的交点即为平面直角坐标系中共线的点的所在直线方程参数。

$$r = x \cos \theta + y \sin \theta \quad (1)$$

参数空间中的投票结果计算过程如下：首先建立一个二维投票数组 $V(r, \theta)$ ，初始化为 0，其中第一个维度是 r 的取值范围，第二个维度是 θ 的取值范围。然后对于图像坐标中每一个点 (x_i, y_i) ，将参数空间中每一个角度 θ 代入，得到对应的 r ，每计算出一组 (r, θ) ，将投票数组 $V(r, \theta)$ 的对应位置加 1，以此类推。计算结束则投票结束，票数最高位置对应的 r 和 θ 为最大峰值，该参数即为原图像中共线点数目最多的直线方程的参数。接下来还可继续寻找次峰值以及第三峰值、第四峰值等，分别对应原图像中共线点数目逐渐减少的直线。




Figure 1. Schematic diagram of parameters in Hough transform
图 1. Hough 变换中参数示意图

3. 基于目标检测的城市路口车辆加塞行为的识别研究

本文将目标检测算法与 Hough 变换相结合，进行城市交通路口车辆加塞行为的识别。首先利用目标检测算法检测图片中的目标，得到它们的位置以及类别信息；其次将可能会发生加塞行为的目标类别挑

选出来，比如汽车、公交车、卡车；然后利用 Hough 变换拟合路口每一车道排队的直线，计算每一车辆到最近车道直线的距离，并设置阈值区间；最后通过判断车辆到车道方向直线的距离判断车辆是否具有加塞行为：距离小于阈值下限的即可认为该车在车道内；距离大于阈值上限的即可认为该车位于别的车道且该车道车辆过少或者是逆向车道，不参与加塞行为的识别；距离位于阈值范围内的即可认为该车有可能偏离车道进行加塞行为。

3.1. 车辆加塞行为识别模型构建

本文使用 Hough 变换对路口车辆进行直线检测，是因为在路口直行、左转弯、右转弯以及掉头车道较窄，同一车道的车辆几乎位于一条直线上，那么该车道的车辆的中心也几乎位于同一条直线上，进行加塞行为的车辆会偏离该车道的直线，即为寻找的可能发生加塞行为的车辆。同时因为道路上车辆大小不等，但是车辆在路口排队时，中心点偏差微小，因此为了避免尺寸对拟合准确性带来的影响，使用检测目标的中心点进行 Hough 变换。

首先使用目标检测算法 Faster R-CNN 对城市路口交通图像进行检测，检测结果为图像中各个目标的类别以及位置信息，可视化如图 2 所示。

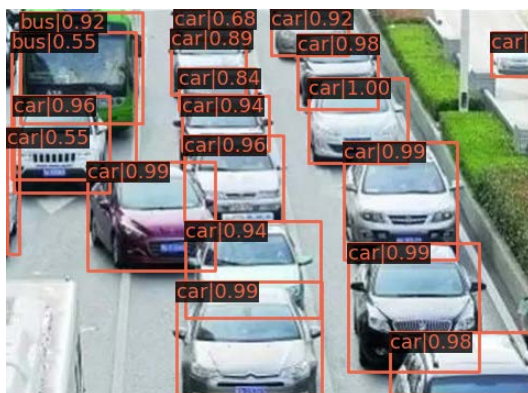


Figure 2. The urban traffic intersections image detection result by object detection

图 2. 目标检测算法对城市交通路口图像检测结果

然后对检测结果通过类别信息进行过滤，仅保留可能会发生加塞行为目标的信息，如汽车、公交车、卡车，绘制保留的目标的中心点分布如图 3 所示。




Figure 3. Schematic diagram of vehicle target distribution

图 3. 车辆目标分布示意图

接下来对图 3 进行 Hough 变换, 检测车道内车辆所在直线, 得到各个点在 Hough 空间的分布如图 4 所示, 其中图 3 中的一个点对应 Hough 空间的一条曲线。




Figure 4. The result of Hough transform
图 4. Hough 变换结果

对 Hough 变换的结果进行非极大值抑制、非车道线方向直线抑制等操作, 获得最终车道方向直线如图 5 所示。



Figure 5. Lane direction straight lines
图 5. 车道方向直线

经过 Hough 变换得到车道方向的直线之后, 计算每一个目标中心点与每一条直线的距离。设置距离阈值区间, 距离小于阈值下限的判定目标在车道内; 距离大于阈值上限的判定该目标位于别的车道且该车道车辆过少或者是逆向车道, 不参与加塞行为的识别; 距离位于阈值范围内的判定该车有可能偏离车道进行加塞行为。由于每一目标距离不同车道会有不同的距离值, 距离最小值为车辆与所在车道的直线的距离, 因此用最小距离对其进行距离判别, 若是位于区间内, 则将该目标框选出来, 并标注“warning”, 识别结果如图 6 所示。



Figure 6. Vehicle cut in line test results
图 6. 车辆加塞检测结果

3.2. 模型具体实施过程

根据模型构建的描述，具体描述模型实施过程流程图如图 7 所示，详细步骤描述如下：

步骤一，读取城市路口监控图像。目标检测算法的输入为图像，本文将城市路口的监控图像作为目标检测的输入。

步骤二，目标检测算法对步骤一中的图像进行检测。目标检测的输出结果是图像中目标的位置信息、置信度以及类别标签。

步骤三，获取目标检测结果中交通类目标信息。本文使用的是已经训练完成的目标检测算法，可有效检测多种类别的目标。由于使用目标中心点进行 Hough 变换拟合车道方向直线时，只需交通类目标，且在检测加塞行为时，只需对交通类目标进行识别，因此非交通类目标在该模型中属于噪声点。但是重新标注只含有交通类目标的数据集并进行训练工作量繁琐且耗时费力，因此在原有检测结果上对类别进行筛选，只保留交通类目标的信息，如汽车、卡车、公交车。

步骤四，对上述类别目标的中心点进行 Hough 变换。根据目标检测结果中目标的位置信息计算目标的中心点坐标。由于交通图像中车道线的数量不止一条，对交通图像中拟合车道线所在直线不能使用常用的最小二乘法、梯度下降法等。因此对目标的中心点进行 Hough 变换，并绘制其在参数坐标系下对应曲线所示，并计算对应参数的投票矩阵。

步骤五，对 Hough 变换的结果进行非极大值抑制，抑制一条直线周边相近直线，更新投票结果。由于相近的直线会得到相近的票数，因此在将 Hough 变换的结果绘制到原图时，在同一车道位置将得到多条直线。对其进行非极大值抑制，分别给参数设置相似范围，范围内只保留得票最高的一对参数，其余参数对的票数归零，更新参数坐标系下对应参数的投票矩阵。

步骤六，选出投票结果中得票最高的 K 对极值，并计算相应直角坐标下的 K 个表达式。对于投票结果，有许多票数低的参数对表示的直线并不符合预期，因此对此类直线进行硬阈值操作，票数低于某阈值的直线，其对应的参数对的投票结果归零，更新参数坐标系下投票矩阵。

步骤七，对 K 条直线进行非车道方向抑制，删除不符合车道线方向的直线，得到符合车道线方向的 k 条直线，绘制到输入图像如图 4 所示。由于车道的整齐性以及车辆在车道排队的规整性，Hough 变换会产生方向不同于车道的直线，比如垂直车道线方向的直线。为了抑制此类直线，对结果进行非车道方向抑制，通过对交通场景的图像及视频的观察，注意到符合车道方向直线上的相邻点距较小，不符合车道方向的直线上的相邻点距较大，因此通过计算每条直线上相邻点距的平均值判断直线抑制与否，直线上相邻点平均点距高于阈值则判定为不符合车道线方向，对其进行抑制。

步骤八，计算每个目标到 k 条直线的距离，判断每一目标的 k 个距离中最小距离是否处于距离区间内，若处于距离区间内，则判定该目标正在发生加塞行为。计算每个目标与 k 条直线的距离，距离大于距离区间的上界则说明计算的是该目标到别的车道的距离，距离小于距离区间的下界则说明是该目标到本车道的距离，处于距离区间内则说明该目标正在进行加塞行为，则将该目标框选出来，并标注“warning”。




Figure 7. Operation flow chart of vehicle cut in line model
图 7. 车辆加塞模型操作流程

3.3. 结果分析

本文构建城市路口车辆加塞行为识别模型，首先利用基于深度学习的目标检测算法有效检测交通图像中的车辆，然后通过类别筛选保留所需交通类目标信息，再通过对交通类目标信息的中心点进行 Hough 变换进行车道方向直线拟合，再通过非极大值抑制等后处理抑制错误直线，得到准确的车道方向直线，并通过对目标到车道线方向直线的距离可准确检测车辆与车道之间的位置关系，从而判定目标是否具有加塞行为。如图 6 所示，本文构建的模型可有效检测城市路口的车辆加塞。通过可视化信息处理结果可以看出，本文构建的模型可准确拟合车道方向直线，可有效识别加塞车辆，证明了模型的有效性。

4. 结语

本文针对现实场景中城市交通路口常见的车辆加塞行为，构建一种基于目标检测的城市路口车辆加塞行为识别模型。利用 Hough 变换对目标检测算法检测出的交通类目标进行拟合，经过非极大值抑制等后处理，得到车道方向直线。通过计算每一交通类目标与每一车道方向直线的距离，判断出车辆与车道之间的状态，进而判断出车辆是否具有加塞行为。本文构建的模型简单有效，即插即用，具有一定的实用价值。

基金项目

国家自然科学基金(No. 62072024); 北京建筑大学北京未来城市设计高精尖创新中心资助项目(UDC2017033322, UDC2019033324); 北京建筑大学市属高校基本科研业务费专项资金资助(No. X20084, ZF17061)。

参考文献

- [1] 产业信息网 (2021). <https://www.chyxx.com/industry/202107/963617.html>
- [2] Girshick, R., Donahue, J., Darrell, T., *et al.* (2014) Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation. *IEEE Conference on Computer Vision and Pattern Recognition*, Columbus, 23-28 June 2014, 580-587. <https://doi.org/10.1109/CVPR.2014.81>
- [3] Girshick, R. (2015) Fast R-CNN. *IEEE International Conference on Computer Vision (ICCV)*, Santiago, 7-13 December 2015, 1440-1448. <https://doi.org/10.1109/ICCV.2015.169>
- [4] Ren, S., He, K., Girshick, R., *et al.* (2015) Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **39**, 1137-1149. <https://doi.org/10.1109/TPAMI.2016.2577031>
- [5] Cai, Z.W. and Vasconcelos, N. (2017) Cascade R-CNN: Delving into High Quality Object Detection. 2018 *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 18-23 June 2018, 6154-6162.
- [6] He, K.M., Georgia, G., Piotr, D., *et al.* (2018) Mask R-CNN. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, **42**, 386-397.
- [7] Gidaris, S., Komodakis, N., *et al.* (2019) Object Detection via a Multi-Region & Semantic Segmentation-Aware CNN Model. *IEEE Access*, **7**, 57120-57128. <https://doi.org/10.1109/ACCESS.2019.2913882>
- [8] Sun, P., Zhang, R.F., Jiang, Y., *et al.* (2021) Sparse R-CNN: End-to-End Object Detection with Learnable Proposals.
- [9] Redmon, J., Divvala, S., Girshick, R., *et al.* (2016) You Only Look Once: Unified, Real-Time Object Detection. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, 27-30 June 2016, 779-788. <https://doi.org/10.1109/CVPR.2016.91>
- [10] Redmon, J. and Farhadi, A. (2016) YOLO9000: Better, Faster, Stronger. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, 27-30 June 2016, 6517-6525. <https://doi.org/10.1109/CVPR.2017.690>
- [11] Redmon, J. and Farhadi, A. (2018) YOLOv3: An Incremental Improvement.
- [12] Bochkovskiy, A., *et al.* (2020) YOLOv4: Optimal Speed and Accuracy of Object Detection.
- [13] Liu, W., Anguelov, D., Erhan, D., *et al.* (2016) SSD: Single Shot Multi-Box Detector. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, 27-30 June 2016, 21-37. https://doi.org/10.1007/978-3-319-46448-0_2
- [14] Fu, C.Y., Liu, W., Ranga, A., *et al.* (2017) DSSD: Deconvolutional Single Shot Detector.
- [15] Hough, P.V.C. (1962) Method and Means for Recognizing Complex Patterns. US Patent No. 30696541962.
- [16] Duda, R.O. and Hart, P.E. (1972) Use of the Hough Transformation to Detect Lines and Curves in Pictures. *Communications of the ACM*, **15**, 11-15. <https://doi.org/10.1145/361237.361242>