

一种基于 MEAN-SHIFT 特征增强的车牌定位方法

谢以磊¹, 王军号¹, 颜新云^{2*}

(1. 安徽理工大学计算机科学与工程学院,安徽 淮南 232001;
2. 金陵科技学院网络与通信工程学院,江苏 南京 211169)

摘要:复杂场景下的车牌定位算法由于环境的变化导致车牌识别率低、计算效率不高。在对 Faster R-CNN 算法分析的基础上,结合 MEAN-SHIFT 聚类算法的特点,提出了一种基于 MEAN-SHIFT 特征增强的车牌定位方法。该方法采用并行计算的方式,通过增强目标区域的特征,有效提升了复杂场景下车牌定位的效率和准确度。实验表明,该方法能够在多种复杂场景下快速定位车牌照区域,准确率高,具有较好的鲁棒性。

关键词:复杂场景; Faster R-CNN; MEAN-SHIFT; 特征增强

中图分类号:TP391

文献标识码:A

文章编号:1672-755X(2020)01-0016-05

A License Plate Location Method Based on MEAN-SHIFT Feature Enhancement

XIE Yi-lei¹, WANG Jun-hao¹, YAN Xin-yun^{2*}

(1. Anhui University of Science and Technology, Huainan 232001, China;
2. Jinling Institute of Technology, Nanjing 211169, China)

Abstract: The license plate localization algorithm under complex scenarios has a low license plate recognition rate due to changes in the environment, and the calculation efficiency is not high. Based on the analysis of Faster R-CNN algorithm and the characteristics of MEAN-SHIFT clustering algorithm, this paper proposes a method of vehicle license plate positioning based on features to effectively improve the efficiency of fast and accurate positioning of license plates in complex scenes. MEAN-SHIFT feature enhancement is a method uses parallel computing to enhance the target area. The experiments show that this method can quickly locate the license plate area in a variety of complex scenarios, with high accuracy and good robustness.

Key words: complex scene; Faster R-CNN; MEAN-SHIFT; feature enhancement

近年来各种环境不同的停车场不断产生,传统的单一环境下的车牌识别算法不能适应各类特殊场景下的车牌识别^[1],而车牌识别算法中最重要的是车牌定位。通常车牌定位方法分为三类:基于车牌结构特征定位方法、基于车牌颜色特征定位方法以及基于机器学习的车牌定位方法。其中,基于车牌结构特征的定位方法一般对场景要求高,适合复杂程度低的场景。如果光照条件差、有雨雪雾霾等天气,或车身的区域纹理等特征与车牌照区域特征相近时,该方法识别率低,误检率较高^[2-3]。基于车牌颜色特征的定位方法与基于结构特征的定位方法相比要简单,但是其局限性也非常明显:当车牌照颜色与车身区域颜色相同时定位效率会很低;当光照条件不足时,车牌定位效率也会很低^[4-5]。针对上面两类方法的不足,

收稿日期:2019-12-28

基金项目:江苏省高等学校自然科学研究面上项目(19KJB510030)

作者简介:谢以磊(1994—),男,江苏响水人,硕士研究生,主要从事图形图像处理研究。

通信作者:颜新云(1989—),女,江苏泗阳人,讲师,博士研究生,主要从事人工智能、数据挖掘、图形图像处理等研究。

Abolghasemi 等提出基于车牌边缘与颜色结合的方法^[6],该方法能够在一定程度上改进单个算法的不足,但是无法真正弥补这两类算法的缺陷,依然受光照条件影响很大,而且计算量也是单个算法的数倍。

近几年来,随着人工智能的不断发展,基于机器学习的车牌定位算法取得了很大进展。目前主流的基于机器学习的车牌定位算法有 YOLO(You Only Look Once)、SSD(Single Shot MultiBox Detector)、Faster R-CNN 以及 CornerNet-Lite^[7-10]。YOLO 算法^[7]相较于 SSD 和 Faster R-CNN 两种算法,识别率低,但是时间代价较小。SSD 算法改进了 YOLO 算法的工作原理,弥补了识别率低下的不足。Faster R-CNN 算法^[11]相比上面两种算法,虽然时间代价较大,但识别率较高。CornerNet-Lite 算法虽然理论上比 YOLO 算法快且准确性高,但实验结果显示该算法的性能在复杂场景下与 YOLO 算法仍有差距。本文在充分分析相关车牌定位算法优缺点的基础上,结合复杂场景下车牌定位的复杂性,融合 Faster R-CNN 方法,提出了一种基于 MEAN-SHIFT 聚类算法^[12]进行特征增强从而快速定位车牌的方法。

1 RPN 原理

RPN(Region Proposal Network)通过快速有效地扫描图片中每一个位置,以判断给定区域是否需要进一步处理,一般包括 3 个步骤:

步骤 1:输入图片经卷积网络处理后得到一个后面卷积层需要的特征图。

步骤 2:在特征图上进行滑窗操作,一般生成 9 个候选框,且这 9 个候选框具有相同的中心,如图 1 所示。

步骤 3:每个候选框 anchor 经过平移和伸缩参数变换,用来提高候选框与标志框之间的重叠率,计算出精确的训练 anchor。再根据区域得分进行降序排列,选取区域得分较为靠前的区域,再经过非极大值抑制,取前 Top-N 的 anchors,最后将选取的 anchors 作为 proposals 输出,送到 RoI Pooling 层。

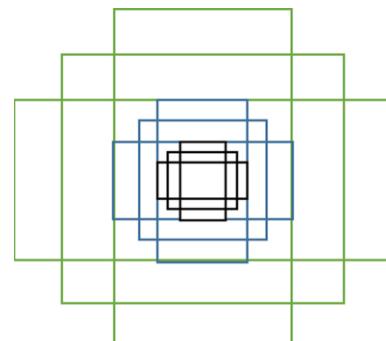


图 1 9 个候选框(anchor)

2 基于 MEAN-SHIFT 特征增强的车牌定位方法

2.1 方法框架

Faster R-CNN 算法是 Fast R-CNN 算法的增强版,其最大的创新就是采用 RPN 网络实现对候选区域的快速提取。本文在充分分析现有 Faster R-CNN 算法优缺点的基础上,结合复杂场景下 Faster R-CNN 算法定位车牌区域效率不高的情况,在原有 Faster R-CNN 算法框架基础上,引入 MEAN-SHIFT 聚类算法进行算法优化,总体算法框架如图 2 所示。

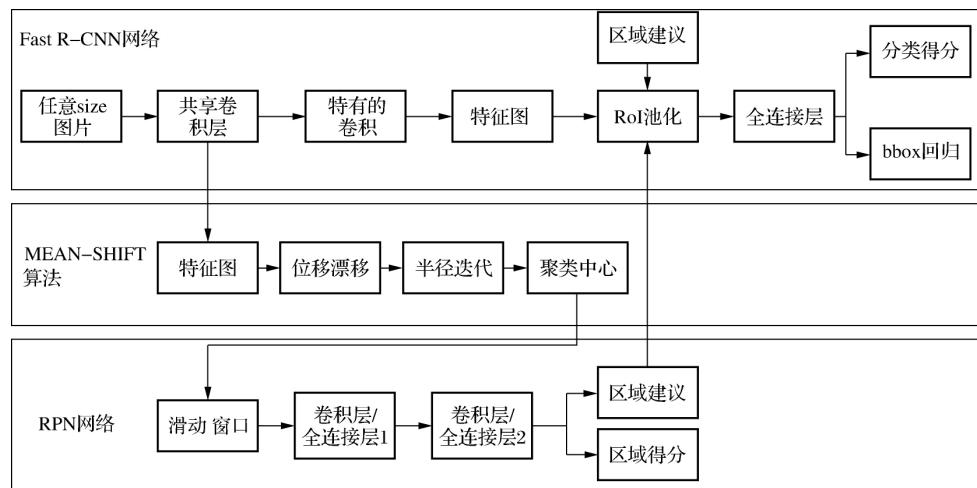


图 2 Faster R-CNN 与 MEAN-SHIFT 结合的整体框架

本文算法分为训练阶段和测试阶段。训练阶段与 Faster R-CNN 算法一致,过程如下:

步骤 1:训练一个 RPN 并根据 RPN 提取训练出 Fast R-CNN 网络。

步骤 2:根据 Fast R-CNN 网络训练出共享卷积层网络模型和特有卷积层模型。

步骤 3:迭代上述步骤,直到训练结束。

测试阶段则需要 Faster R-CNN 算法的测试阶段算法(以下步骤 1、2、4、5)与 MEAN-SHIFT 算法(以下步骤 3、4)结合使用,步骤如下:

步骤 1:输入一张任意大小的图片到 CNN 网络。

步骤 2:CNN 网络前向传播到共享的卷积层,得到一张特征图并传播到特有的卷积网络。

步骤 3:步骤 2 中的特征图再输入到 MEAN-SHIFT 算法中,通过计算事先选定的车牌照区域与 MEAN-SHIFT 算法随机选定区域内各特征点之间的相似函数,得到目标偏移量,多次迭代得到最相似特征区域。

步骤 4:将步骤 3 中得到的最相似特征区域输入 RPN 网络,通过两层卷积神经网络得到区域建议和区域得分,设置得分区域阈值为 0.7,将得分大于 300 的区域建议输送到 RoI 池化层。

步骤 5:步骤 2 中特有卷积层产生高维度特征图,与步骤 4 中的区域建议一起送到 RoI 池化层,提取对应的区域特征。

步骤 6:步骤 5 提取的区域特征,通过全连接层得到该区域的分类得分,并且对 bbox 进行回归操作。

2.2 MEAN-SHIFT 特征增强

传统的 MEAN-SHIFT 算法虽然能够快速找出特征点密集的区域,但是无法判断该区域作为车牌照区域的可能性。针对这种情况,本文改进了传统的 MEAN-SHIFT 算法,使其更加适用于车牌定位:计算一般车牌照区域的特征点与区域内每个特征点的相似函数,通过相似函数计算出每次迭代的偏移量,经过多次迭代准确寻找出与车牌照区域相似度最大的区域,并且标注出该区域的范围。具体过程如下:1)随机从区域中选择一个特征点作为圆心 x 。2)找出以 x 为圆心,先取半径 $h=5$ 的所有特征点的集合,记为集合 S 。3)计算车牌照区域的特征点与集合内每一个特征点的相似函数,通过相似函数计算出下一次目标的偏移量 M_h 。偏移量计算公式为 $M_h = \frac{1}{K} \sum_{x_i \in S_k} (x_i - x)$ 。4) $x = x + M_h$ 。即 x 沿着 M_h 的方向移动,移动的距离为 $\|M_h\|$ 。5)重复上面的步骤 2、3、4,直到 $\|M_h\|$ 的距离趋近于 0。6)当 $\|M_h\| \approx 0$ 时,计算相似特征点的数量与该区域的面积之比,用于判断适合 h 的大小。相似函数与面积比公式为 $L = \frac{\rho}{\pi h^2}$ 。7)取半径为 $h+1, h, h-1$ 三种大小,分别计算出三种半径对应的相似度比 L_{h+1}, L_h, L_{h-1} ,判断三种半径下相似函数与面积比的大小,阈值设为 7,当结果大于设定阈值时则保留,否则舍去。8)对步骤 7 进行迭代,找出所有比例大于阈值的区域,将这些区域输送到 RPN 网络中。

3 实验及结果

3.1 实验环境和数据来源

本文的实验环境为 Linux 操作系统,16 GB 内存, GPU,通过 TensorFlow 等软件对相关算法进行实验。实验总共采集 3 400 张图片,其中大部分车牌照为普通轿车牌照,少部分为新能源轿车牌照。图像选择在多种环境下采集,如中午烈日下、雨雾天气下、夜晚路灯下等。采集的地点也选择多种场景,如地下停车场、路边停车场等。采集的图片质量由于光线、天气条件、车牌照上的污渍以及拍摄角度等不同而不同,以此提升本文方法与其他方法的对比度。

3.2 算法结果分析

实验与基于形态学的方法^[2]、彩色边缘检测法^[5]、SSD 法^[8]、Faster R-CNN 法^[9]、Corner Net-Lite 法^[10]进行对比。选择的场景有光照不同、纹理相近、图像模糊等。如图 3 所示,当光照过度时,形态学的方法、彩色边缘检测法无法准确定位出车牌照区域。前者依靠对车牌照边框的检测,错误地定位到了矩形

的门窗位置;后者依靠图片的 HSV 色度进行识别,错把路边的植被当成车牌照区域。SSD 法因为只需要一层卷积神经网络,识别率不高。Faster R-CNN 法定位区域基本上符合车牌照要求。Corner Net-Lite 法没有将另外一辆车的车牌照区域定位出来。本文方法成功将两辆车的车牌照区域定位出来,并且范围较为完整。

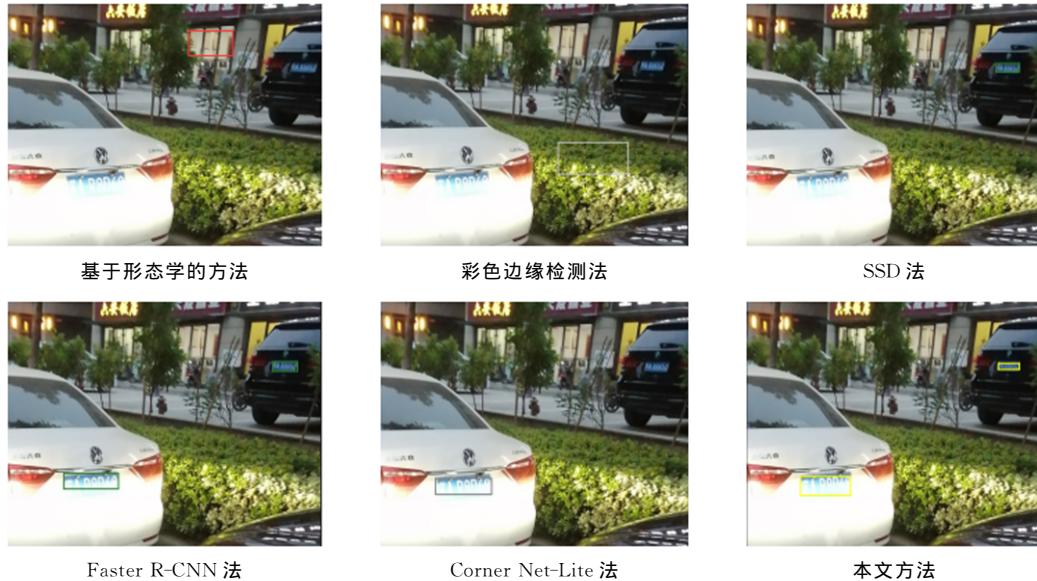


图 3 车牌照区域光照过度情况下 6 种方法的比较

如图 4 所示,当车牌区域与车身纹理颜色相近时,基于形态学的方法定位失败,标志区域与真实的车牌区域完全不符合。彩色边缘检测法车牌定位的框过小不能用于车牌识别。SSD 法、Faster R-CNN 法、Corner Net-Lite 法以及本文方法都能够将车牌照区域完全识别出来。



图 4 车牌照区域纹理颜色与车身相近时 6 种方法的比较

如图 5 所示,当图像模糊情况下,基于形态学的方法直接定位到车窗位置。彩色边缘检测法虽然图像模糊,但是根据颜色对比还是能够大概地得到车牌照区域。SSD 法无法定位出车牌照区域。Faster R-CNN 法定位位置不够精确。Corner Net-Lite 法没有定位出车牌照区域。本文使用的方法定位效果在此种情况下表现得比其他方法要好。

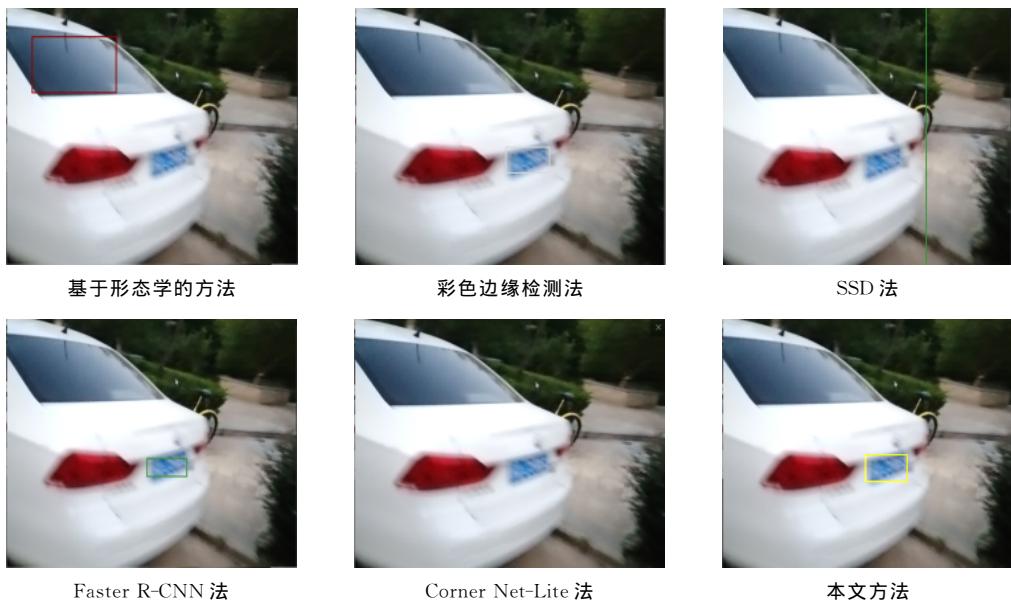


图 5 图像模糊情况下 6 种方法的比较

综上,在多数场景下本文方法略优于基于形态学的方法、彩色边缘检测法、SSD 法、Corner Net-Lite 法,与 Faster R-CNN 法效果几乎一致。当拍摄环境较为复杂时,本文算法要优于 Faster R-CNN 法。

4 结语

针对复杂场景下车牌准确率低等问题,本文提出了 Faster R-CNN 与 MEAN-SHIFT 相结合的方法。首先通过 Fast R-CNN 共享卷积层得到特征图,其次将特征图传入 MEAN-SHIFT 算法中定位出大概区域,再将大概区域通过两层神经网络得出区域得分,通过区域得分再将区域建议送入到 RoI 池化层,最后根据多次迭代回归得到准确的车牌照区域。通过与其他方法的实验对比可知,本文提出的方法对于复杂场景下的车牌定位效率有较好的提升。

参考文献:

- [1] Ross G, Jeff D, Trevor D, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]. Columbus:CVPR IEEE, 2014:581-587
- [2] 周唯,吴成东. 视网膜图像中的黄斑中心检测[J]. 中国图象图形学报,2018(3):442-449
- [3] 付利军,兰方鹏. 边缘信息耦合改进的 Hough 变换的车道线实时检测算法[J]. 电子测量与仪器学报,2019(8):166-172
- [4] 景星烁,邹卫军,夏婷,等. 基于差异颜色特性的自适应互补学习目标跟踪[J]. 计算机辅助设计与图形学学报,2018(12):2253-2261
- [5] 朱晓临,陈嫂,李雪艳,等. 结合形态学变形虫和复合颜色空间的彩色图像边缘检测模型[J]. 计算机辅助设计与图形学学报,2014(7):1060-1066
- [6] Vahid A, Alireza A. An edge-based color-aided method for license plate detection[J]. Image and Vision Computing, 2009, 27(8):1134-1142
- [7] 王忠民,段娜,范琳. 融合 YOLO 检测与均值漂移的目标跟踪算法[J]. 计算机工程与应用,2018(12):186-192
- [8] Liu W, Anguelov D, Erhan D, et al. SSD: Single shot multibox detector[C]. Berlin: Springer, 2016:21-37
- [9] 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
- [10] Hei L, Yun T, Olga R, et al. CornerNet-Lite: efficient keypoint based object detection[C]. CoRR, 2019, abs/1904.08900
- [11] 黄继鹏,史颖欢,高阳. 面向小目标的多尺度 Faster R-CNN 检测算法[J]. 计算机研究与发展,2019(2):319-327
- [12] 朱浩楠,许明敏,沈瑛. 基于 Mean Shift 的多视频车辆跟踪研究[J]. 计算机科学,2018(6):220-226

(责任编辑:湛江)