

基于 Faster R-CNN 的车辆多属性识别

阮航,孙涵

(南京航空航天大学 计算机科学与技术学院,江苏 南京 211100)

摘要:基于 Faster R-CNN 提出一种车辆的多属性识别模型。首先利用 Faster R-CNN 对车辆数据库进行训练,得到车辆检测网络,对图像中多个车辆目标进行检测。将检测结果输入改进的车辆属性识别网络中,对检测得到的车辆进行属性推断,包括车辆颜色、品牌和姿态。为评估车辆检测精度和车辆多属性识别的准确率,采集了 8 000 张真实场景下的图片作为测试集进行测试。对于车辆检测网络,对比了 R-CNN、Fast R-CNN 等方法的检测精度;对于车辆属性识别,对比了不同网络结构、不同图片分辨率和单属性和多属性等对于识别准确率的影响。实验结果表明,基于 Faster R-CNN 的车辆多属性识别方法充分学习了不同属性间的特征,具有较高的准确率和检测精度,以及良好的通用性和鲁棒性,适用于车辆多属性分类。

关键词:Faster R-CNN;多属性识别;车辆检测;深度学习;图像分类

中文分类号:TP391

文献标识码:A

文章编号:1673-629X(2018)10-0129-06

doi:10.3969/j.issn.1673-629X.2018.10.027

Vehicle Multi-attribute Recognition Based on Faster R-CNN

RUAN Hang, SUN Han

(School of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 211100, China)

Abstract: We put forward a vehicle multi-attribute recognition model based on Faster R-CNN. First we use vehicle images to train and obtain vehicle detection network for detection of vehicle targets in image. Then we put detected results into vehicle attribute recognition network and infer attributes including color, type and view. In order to evaluate the accuracy of vehicle detection precision and vehicle multi-attributes detection, we collect 8 000 vehicle images under actual scene as test set for testing. In terms of vehicle detection network, we compare the detection precision of R-CNN and Fast R-CNN, and for vehicle attribute recognition we compare the accuracy of different network, different image definition and different number of attributes. Experiment shows that the proposed vehicle multi-attribute recognition method based on Faster R-CNN can learn more features fully with higher accuracy and precision, as well as better versatility and robustness, which can be used for vehicle multi-attribute classification.

Key words: Faster R-CNN; multi-attribute recognition; vehicle detection; deep learning; image classification

1 概述

车辆的自动识别系统对于交通监控、停车管理和公安系统有着重要的意义,其中基于计算机视觉的车辆自动识别研究受到了广泛关注。在这些研究中,车辆检测和车辆识别是自动识别系统中的重要组成部分,而由于自然道路场景下的光照变化,不同天气条件影响和拍摄图像畸变等问题,使得车辆检测和识别具有很大的挑战性。传统的图像处理方法首先提取图像特征,如文献[1]采用 Harris 特征与 SIFT 特征结合的方式实现车型识别,文献[2]采用空间金字塔结合 Ad-

aboost 分类器的方式对车辆进行检测。这些方法提取的特征为纹理、边缘、轮廓等浅层特征,无法准确区分车辆外观,而且提取到的特征易受光照、车辆姿态的影响,在车辆识别中,无法应用浅层特征进行车辆的细粒度分类。

在传统的目标检测中,DPM^[3](可变形模型部分)组件检测算法应用广泛。DPM 首先计算梯度方向直方图,然后使用 SVM 训练得到物体的梯度模型来完成分类。DPM 具有良好的鲁棒性,但由于使用滑动窗口进行特征提取和分类,使得计算量大、效率低,无法

收稿日期:2017-11-13

修回日期:2018-03-06

网络出版时间:2018-05-28

基金项目:国家自然科学基金(61203246,61375021);中央高校基本科研业务费专项资金(NS2016091);江苏省自然科学基金(SBK201322136)

作者简介:阮航(1993-),女,硕士,CCF 会员(54504G),研究方向为计算机视觉、深度学习;孙涵,教授,研究方向为计算机视觉、图像处理。

网络出版地址: <http://www.cnki.net/kcms/detail/61.1450.TP.20180525.1603.042.html>

广泛应用。随着深度学习在计算机视觉领域的突出表现,深度学习算法被广泛应用于图像检测和图像分类中,其中在物体检测领域提出了基于候选框的 R-CNN^[4]方法。该方法采用选择搜索方法(selective search)或边缘框方法(edge box)得到物体的候选框,然后送入卷积神经网络提取特征,最后通过 SVM 分类器获得最终的检测结果。R-CNN 方法将提取到的几千个候选框依次送入 CNN 网络提取特征,上千次的卷积操作带来了巨大的计算量,使得该方法效率低,计算复杂。为改进 R-CNN 方法,Fast R-CNN^[5]采用兴趣区域(ROI)池化层得到候选框,并采用多任务损失函数预测物体类别和位置信息,只需要一次卷积操作即可完成提取特征操作。与采用滑动窗口的 DPM 方法相比,上述两种基于候选框的深度学习方法,大大提升了检测效率,然而,这两种方法需要时间来提取候选框,降低了整体的检测效率。因此,在 R-CNN 和 Fast R-CNN 的基础上提出了 Faster R-CNN^[6]。Faster R-CNN 算法采用 RPN 网络(区域建议网络)提取候选

框,该方法采用共享卷积层特性来提高速度和性能,真正实现了端到端网络,是一个完整的卷积神经网络结构。Faster R-CNN 方法大大提升了物体检测精度,也大大加快了物体检测的效率。

另一个重要的和具有挑战性的研究领域是车辆属性识别,包括车辆姿态、颜色、速度、门的数量、类型和其他细粒度属性。Li 等^[7]采用矢量匹配的模板来识别车辆颜色,该方法对于图像的质量要求较高,而且只能识别车辆的颜色信息。张军等^[8]提出改进的深度学习网络实现车型的分类,该方法只对车辆大小进行分类。文献[9]通过粒子群编码,采用粒子群与云模型结合的方法实现车型识别。文献[10]采用改进的 LeNet-5 网络结构进行车牌识别,该方法对车牌图像质量要求高。上述方法只针对特定的车辆属性进行分析,然而在许多情况下多个车辆属性需要同时采集,如车辆自动驾驶领域,而且这些属性的学习存在很强的相关性。因此,在车辆自动识别系统中,车辆的多属性识别是十分重要的。

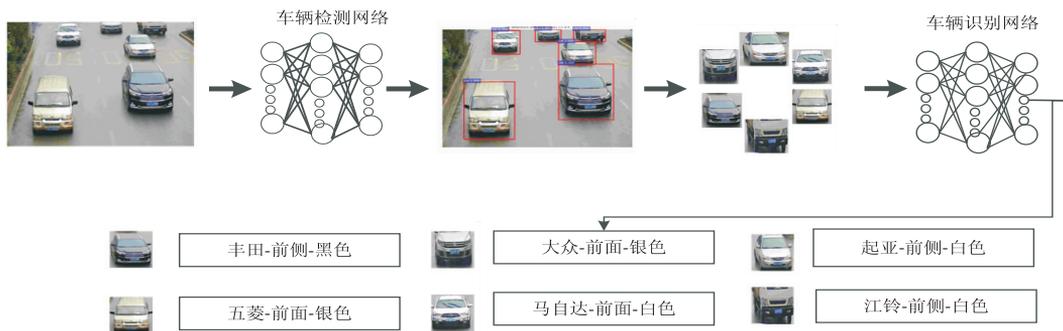


图 1 基于 Faster R-CNN 的车辆多属性识别模型

2 基于 Faster R-CNN 的车辆检测与多属性识别框架

文中提出了基于 Faster R-CNN 的车辆检测以及车辆多属性识别,其中车辆多属性识别包括车辆估计、品牌、姿态、颜色等,如图 1 所示。该检测识别模型包括两个卷积神经网络:车辆检测网络和车辆识别网络。在公路场景中,车辆检测网络旨在预测车辆的位置,然后将检测到的车辆图像输入车辆识别网络中识别车辆的多属性。

2.1 车辆检测模型

传统的检测方法如 DPM 使用滑动窗口方法,有很多重复的候选框,严重降低了效率,增大了计算量。基于深度学习的 R-CNN 和 Fast R-CNN 的方法结合候选框与分类网络,也会产生很多冗余的候选框,从而降低了网络效率。因此,文中选择 Faster R-CNN 物体检测算法来实现车辆检测。该算法设计 RPN 层来提取精确的候选框,大大减少了候选框的数量,并采用多任

务损失函数来回归候选框位置信息,同时将 RPN 网络与多任务分类网络相结合,真正实现端到端的网络结构,在保证速度的同时,大大提升了检测精度。Faster R-CNN 框架分为卷积层、RPN 层和坐标回归层,网络结构如图 2 所示。有 5 层卷积层用于车辆特征图提取,第 1 层卷积层(conv_1)有 96 个大小为 7 * 7 的卷积核;第 1 层卷积层(conv_2)的输入是从上一层获得的特征图,该层有 256 个大小为 5 * 5 的卷积核;conv_3、conv_4、conv_5 将上一层获得的特征图作为输入,其卷积核的个数分别为 384、384、256,大小均为 3 * 3。5 个卷积层,其卷积核大小逐层减小,这样可以保留更多有用的浅层特性并提高网络性能。

车辆检测首先将图像缩放至 224 * 224 并输入检测网络的卷积层部分,经过 5 层卷积,将卷积层获得的 256 个特征图输入区域建议网络(RPN)进行训练,以预测不同尺度、不同比例的矩形框。在 RPN 训练阶段,将特征图送入多任务损失层,损失分为两种,第一种损失是 2 分类问题,用来预测是目标还是背景。式

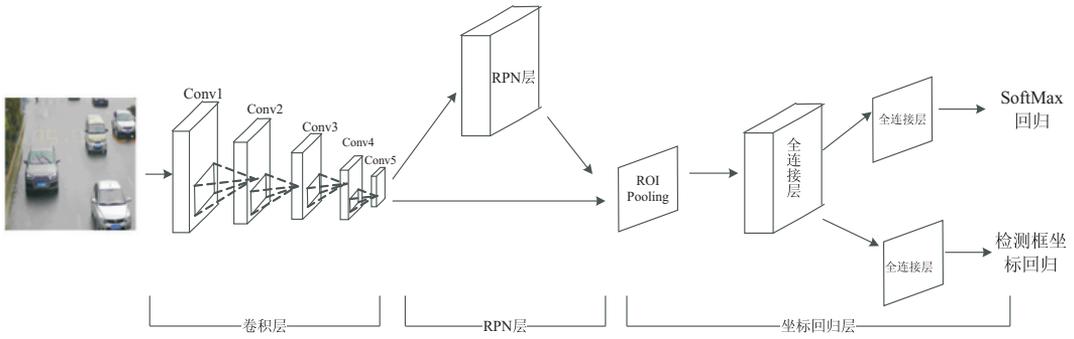


图 2 车辆检测网络结构

1 中的 L_{cls} 为两个类别 (目标和非目标) 的损失值, 损失函数采用对数损失, 其中 P_i 为 RPN 预测候选框是目标的概率, P_i^* 为真实标签, 如式 2 所示。

$$L_{cls}(P_i, P_i^*) = -P_i^* \log(P_i) \quad (1)$$

$$P_i^* = \begin{cases} 1, & \text{reference box is positive} \\ 0, & \text{reference box is negative} \end{cases} \quad (2)$$

第二种损失是位置回归层, 用以修正候选框位置, 坐标首先归一化到 0 ~ 1 之间, 如式 3 和式 4 所示。

$$t_x = (x - x_a) / w_a, t_y = (y - y_a) / h_a \quad (3)$$

$$t_w = \log(w / w_a), t_h = \log(h / h_a)$$

$$t_x^* = (x^* - x_a) / w_a, t_y^* = (y^* - y_a) / h_a \quad (4)$$

$$t_w^* = \log(w^* / w_a), t_h^* = \log(h^* / h_a)$$

其中, 位置信息由 x, y, w, h 表示, x 和 y 为候选框左上角的坐标, w 和 h 为长和宽, t_i 为预测候选框的坐标信息, t_i^* 为真实位置信息。

该损失采用 Smooth L1 函数, 如式 5 所示, 作为坐标回归的损失函数。位置回归层的损失函数如式 6 所示。

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

$$L_{reg}(t_i, t_i^*) = \sum_{k \in \{x, y, w, h\}} \text{smooth}_{L_1}(t_{i,k} - t_{i,k}^*) \quad (6)$$

RPN 在训练阶段的多任务损失函数由 2 分类损失函数和位置回归损失函数构成, 如式 7 所示。

$$L(p_i, t_i) = \frac{1}{N_{cls}} \sum_i L_{cls}(p_i, p_i^*) + \lambda \frac{1}{N_{reg}} \sum_i p_i^* L_{reg}(t_i, t_i^*) \quad (7)$$

其中, N_{cls} 为训练批处理数据的图片个数; N_{reg} 为 RPN 层预测的候选框的数量。这两个参数是将损失值做了归一化处理。

2.2 车辆属性识别模型

在车辆识别领域有很多研究, 如车辆类型识别和车辆颜色分类, 然而大多都是将车辆属性进行独立研究的, 由于未考虑多个属性间的特征关系导致识别准确率下降, 万丹数据文中提出车辆识别网络实现车辆多

属性分类。车辆识别网络选择 GoogLeNet^[11] 作为基本的网络模型, 该网络有 22 层, 相比于 5 层的 Alexnet^[12] 和 16 层的 VGG, 文中选择深层网络结构的原因是由于车辆识别属于细粒度的分类问题, 深层结构可以获得更具代表性的深层语义特征。修改了 GoogLeNet 网络结构获得车辆识别网络, 在 GoogLeNet 网络的基础上, 将全连接层改为多个, 每个全连接层对应一个损失层, 从而实现多属性分类。修改后的网络结构如图 3 所示。

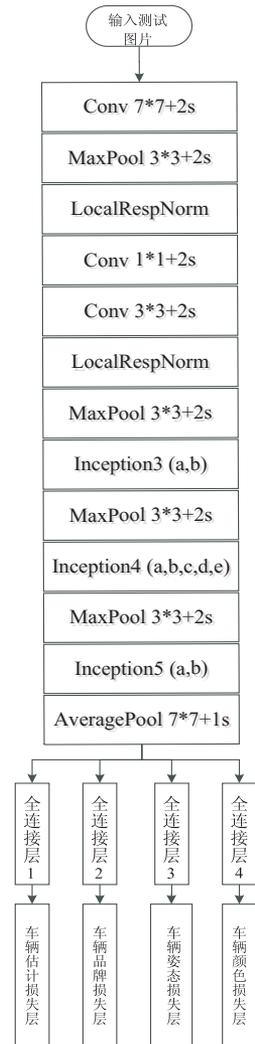


图 3 车辆属性识别网络结构

车辆识别网络的网络稀疏结构大大减小了计算量,提升了网络性能,其多个损失层又能够更好地利用车辆属性特征之间的关联,提高分类的准确率。在车辆识别阶段,图像具有 4 个属性标签: E 、 M 、 V 、 C , 分别代表估计、品牌、姿态、颜色。如果 E 为 0, 表示目标不是车辆, 则其他四个属性设置为 0, 表示这些属性在训练阶段无贡献。属性 E 的损失函数如式 8 所示。

$$L(P^E) = \frac{1}{N_{\text{estimate}}} \sum_i iL_{\text{estimate}}(p_i^E, p_i^*) \quad (8)$$

其中, P^E 为预测的类别; p_i^* 为真实类别, 如式 9 所示, 1 表示车辆, 0 表示背景; N_{estimate} 为训练批处理数据的图片个数, 其损失函数 L_{estimate} 的选取为式 2 中的对数损失。

$$p_i^* = \begin{cases} 1, & \text{object is vehicle} \\ 0, & \text{object is background} \end{cases} \quad (9)$$

其他四个属性 M 、 T 、 V 、 C 的损失函数为 Softmax 损失, 表示预测为某一类别的概率大小。以属性 M 的损失函数为例, 如式 10 所示。

$$L(P^M) = \frac{1}{N_{\text{make}}} \sum_i p_i^* L_{\text{make}}(p_i^M) \quad (10)$$

其中, p_i^M 为第 i 张图片属于某个品牌的概率; p_i^* 为真实品牌类别; L_{make} 为式 11 中的 Softmax 损失函数; N_{make} 为训练批处理数据的图片个数用来做归一化处理。

$$L = -\log(z) z = \frac{e^p}{\sum_i ie^p} \quad (11)$$

车辆多属性识别网络的损失函数如式 12 所示, 由估计、品牌、颜色、姿态这四个损失构成。

$$L_{\text{VRN}}(P_E, P_M, P_C, P_V) = L(P_E) + \lambda L(P_M) + \lambda L(P_C) + \lambda L(P_V) \quad (12)$$

其中, $L(P_E)$ 表示车辆估计的损失值, 表示预测图像为目标或背景, 如果预测为目标, 则 λ 固定为 1, 否则 λ 为 0。

2.3 训练网络

由于要实现车辆的多目标检测和细粒度的分类问题, 因此需要数据集有充足训练数据和丰富的种类, 因此选用大规模数据集“Compars”^[13] 作为训练数据。

该数据集有 130 000 幅车辆图像, 标定了坐标信息和车辆属性, 包括品牌、车辆类型、车辆姿态等, 具有 163 种品牌, 12 种类型, 如 MPV、SUV、掀背车、轿车、面包车等, 5 种姿态: 前面(F)、后面(R)、侧面(S)、前侧(FS)和后侧(RS)。

对于训练数据, 选用所有 163 种汽车品牌, 5 种车辆姿态。此外, 标注了 50 000 张常见车辆类型的图像, 标注了 4 种车辆颜色属性, 包括黑色、白色、银色、红色, 作为训练数据集。

对于训练数据集首先缩放图片到 $224 * 224$, 采用镜像数据和裁剪的方式扩增数据集, 对数据集图像进行去均值处理, 使得图像的均值为零。对于车辆检测网络, 采用车辆的坐标信息作为回归参数, 以 0.001 为初始学习率, 权重衰减系数 0.9, 全部训练数据迭代训练 30 次, 得到车辆检测网络; 对于车辆分类网络, 采用 ImageNet^[14] 预训练好的 GoogLeNet 模型来初始化权值参数, 修改网络的损失层为车辆品牌损失层、车辆姿态损失层和车辆颜色损失层, 学习率调整为 0.001 来训练网络, 采用随机梯度下降的方式更新权重, 全部训练数据迭代 30 次, 得到车辆识别网络。

3 实验结果与分析

采集了真实道路场景下不同时间、不同分辨率的 5 000 幅图像作为测试集 Test1 来评估车辆检测网络和车辆识别网络。为比较图像对框架的影响, 又从测试集 Test1 中选取 2 000 幅光照正常, 图像内车辆目标个数在 3~4 个的图像作为测试集 Test2, 以对比图像对框架的影响。该实验基于 Caffe^[15] 平台, 在 GeForce1080 上测试完成。

3.1 评估车辆检测网络

首先用数据集“Compars”作为训练集来训练车辆检测网络, 然后分别将测试集 Test1 和 Test2 送入车辆检测网络进行测试, 在车辆检测网络中测试图片经过 RPN 层给出候选框, 然后通过损失层计算输出最终的车辆位置。为了评估检测精度, 采用相同的训练集“Compars”训练不同的模型, 包括 R-CNN 和 Fast R-CNN, 并对比了 VGG 网络结构的 Faster R-CNN 模型, 在测试集 Test1 和 Test2 上对比了这几种模型的检测精度。对于检测准确性的判别, 采用 IoU (交并比) 方法来验证候选框是否为车辆位置, 计算结果如下:

$$\text{IoU} = \frac{A \cap B}{A \cup B} = \frac{S_I}{S_A + S_B - S_I} \quad (13)$$

其中, A 为候选框; B 为真实矩形框; IoU 为矩形 A 和矩形 B 的交集占矩形 A 和矩形 B 的并集的比率; S_I 为矩形 A 和矩形 B 的交集面积; $S_A + S_B - S_I$ 为矩形 A 和矩形 B 的并集面积。

选取准确率与召回率作为评估算法的检测精度指标。准确率和召回率的定义如下:

$$P = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (14)$$

$$R = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (15)$$

其中, P 表示准确率; R 表示召回率。

分类结果的混淆矩阵见表 1。车辆检测网络的车辆检测结果见表 2。

表 1 分类结果混淆矩阵

真实情况	预测结果	
	正例	反例
正例	TP(真正例)	FN(假反例)
反例	FP(假正例)	TN(真反例)

表 2 测试集 Test1 和 Test2 的检测精度对比 %

方法	Test1	Test1	Test2	Test2
	准确率	召回率	准确率	召回率
文中	84.5	90.7	98.1	97.2
R-CNN	61.3	70.3	74.5	70.0
Faster R-CNN	67.3	77.9	82.0	76.8

由表 2 可知,测试集 Test1 的准确率达 85%,测试集 Test2 的准确率达 98%。在测试集 Test1 上,召回率较高而准确率相对下降,说明在测试集 Test1 上检测错误情况较多,主要原因是 Test1 的图像车辆目标多,可达 5~6 个,图像内部有树木、行人、摩托车等干扰对准确率也有影响。而测试集 Test2 的图像比较清晰,车辆目标为 1~2 个,车辆目标明显,图像内部干扰较少,因此准确率高,说明车辆检测网络对车辆检测的效果较好,具有良好的有效性。

	车辆品牌	车辆姿态-前面	车辆姿态-后面	车辆姿态-侧面	车辆姿态-前侧	车辆姿态-后侧	车辆颜色
单属性与多属性的分类结果							
单属性	96.3%	73.5%	72.3%	66.2%	60.5%	56.7%	77.2%
多属性	98.1%	73.0%	74.4%	65.8%	61.3%	59.9%	80.1%
不同分辨率图像的分类结果							
512*512	97.2%	73.2%	74.5%	60.9%	62.3%	56.9%	73.4%
224*224	98.1%	73.0%	74.4%	65.8%	61.3%	59.9%	80.1%
112*112	96.2%	69.9%	70.5%	63.2%	60.0%	56.7%	82.1%
56*56	96.0%	68.1%	69.4%	60.7%	57.1%	55.5%	66.9%
不同网络结构的分类结果							
车辆识别网络(22层)	98.1%	73.0%	74.4%	65.8%	61.3%	59.9%	80.1%
AlexNet(5层)	90.2%	67.1%	63.2%	58.4%	45.3%	40.0%	69.7%
VGG16(16层)	94.5%	69.6%	66.9%	64.5%	50.3%	49.6%	74.9%

图 4 单属性和多属性、不同分辨率、不同网络结构的分类结果

由图 4 可以看出,多属性联合训练,车辆识别网络在车辆品牌、车辆姿态和车辆颜色方面的分类效果优于单属性训练,虽然单属性分类结果在车辆姿态上有一定的优势,但是多属性联合训练的效率和准确率都相对优于单属性分类。而不同分辨率的图像对于分类结果的影响,从总体表现来说是分辨率越高分类效果越好,但是由于 512 * 512 大小的图像在训练时的效率低,耗时长,其准确率也与 224 * 224 大小的图像相差不多,因此选择 224 * 224 大小的图像效果更好。从网络深度来看,22 层的车辆识别网络多属性分类结果明显优于其他深度网络,由于多属性分类属于细粒度

3.2 评估车辆识别网络模型

为评估车辆识别网络模型,实验中测试车辆的 4 个属性包括:车辆估计、车辆品牌、车辆颜色和车辆姿态,进行以下几组实验,包括单属性和多属性、不同图像分辨率、不同网络深度等对分类结果的影响。

基于 GoogLeNet 网络结构,对比了多属性和单属性的分类结果,可以看出在多属性的分类结果一直优于单属性分类,说明多属性联合训练可以充分利用各个属性特征之间的联系,有较好的分类效果。由于真实道路场景下摄像头拍摄的图像信息通常是不同分辨率的,距离摄像头不同远近其捕捉到的图像细节也不同,尽管在车辆识别网络中图像被归一化到 224 * 224,但是不同分辨率的图像归一化到相同大小其细节信息是不同的,故对比了不同分辨率图像对分类的影响。由于不同网络深度提取到的特征的细节程度不同,浅层提取到边缘、纹理等特征,深层提取到轮廓、语义等特征,因此分别对比了不同深度的网络结果对分类结果的影响,包括: AlexNet, VGG16, 车辆识别网络。

分类结果如图 4 所示。

的分类问题,网络结构越深,其提取的特征越丰富,分类准确率就越高。

4 结束语

提出了一种基于 Faster R-CNN 的车辆多属性识别方法。首先针对真实道路场景下的图像,采用车辆数据库训练 Faster R-CNN 网络得到车辆检测网络,该检测网络检测精度较高,检测效果好,适用于真实道路场景图像。然后,对 GoogLeNet 网络结构进行改进,将全连接层连接多个损失层实现车辆的多属性识别,包括车辆的品牌、姿态、颜色等,利用车辆属性识别网络

将多个属性之间的特征联合训练,有效提升了属性分类的准确率。采集了两种不同的数据集对基于 Faster R-CNN 的车辆多属性识别方法进行了测试,实验结果表明,该方法在不同道路场景下均具有较高的检测精度,满足了使用要求,而且可以识别出车辆的品牌、姿态、颜色等信息,具有较高的分类准确率和良好的适用性和鲁棒性。同时,该方法需要完善的方面还有很多,如车辆的其他重要属性(车辆类型、车内人数等)更加细粒度的属性分类问题的研究和建立更加全面丰富的车辆数据集以提升车辆检测精度等。

参考文献:

- [1] 康维新,曹宇亭,盛卓,等.车辆的 Harris 与 SIFT 特征及车型识别[J].哈尔滨理工大学学报,2012,17(3):69-73.
 - [2] 曹晓明.基于多图像特征金字塔的车辆检测[D].北京:北京交通大学,2016.
 - [3] FELZENSZWALB P,MCALLESTER D,RAMANAN D. A discriminatively trained, multiscale, deformable part model[C]//IEEE conference on computer vision and pattern recognition. Anchorage, AK, USA: IEEE, 2008: 1-8.
 - [4] 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. [s. l.]: IEEE, 2014: 580-587.
 - [5] GIRSHICK R. Fast r-cnn[C]//Proceedings of the IEEE international conference on computer vision. Santiago, Chile: IEEE, 2015: 1440-1448.
 - [6] REN Shaoqing, HE Kaiming, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2015, 39(6): 1137-1149.
 - [7] LI Xiuzhi, ZHANG Guanming, FANG Jing, et al. Vehicle color recognition using vector matching of template[C]//Third international symposium on electronic commerce and security. Guangzhou, China: IEEE, 2010: 189-193.
 - [8] 张军,张婷,杨正瓴,等.深度卷积神经网络的汽车车型识别方法[J].传感器与微系统,2016,35(11):19-22.
 - [9] 唐朝霞,俞扬信,张粤.基于粒子群算法和云模型的车型识别[J].微电子学与计算机,2013,30(11):80-83.
 - [10] 赵志宏,杨绍普,马增强.基于卷积神经网络 LeNet-5 的车牌字符识别研究[J].系统仿真学报,2010,22(3):638-641.
 - [11] SZEGEDY C, LIU Wei, JIA Yangqing, et al. Going deeper with convolutions[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Boston, MA, USA: IEEE, 2015: 1-9.
 - [12] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[C]//Proceedings of the 25th international conference on neural information processing systems. Lake Tahoe, Nevada: Curran Associates Inc., 2012: 1097-1105.
 - [13] YANG Linjie, LUO Ping, LOY C C, et al. A large-scale car dataset for fine-grained categorization and verification[C]//IEEE conference on computer vision and pattern recognition. Boston, MA, USA: IEEE, 2015: 3973-3981.
 - [14] RUSSAKOVSKY O, DENG J, SU H, et al. ImageNet large scale visual recognition challenge[J]. International Journal of Computer Vision, 2014, 115(3): 211-252.
 - [15] JIA Yangqing, SHELHAMER E, DONAHUE J, et al. Caffe: convolutional architecture for fast feature embedding[C]//Proceedings of the 22nd ACM international conference on multimedia. Orlando, Florida, USA: ACM, 2014: 675-678.
-
- (上接第 87 页)
- formation stabilization and fault tolerance: a state-varying switched system approach[J]. Systems and Control Letters, 2013, 62(9): 715-722.
 - [7] 李慧,崔成玲,李新宏.柔性制造系统中 CNC 机床故障诊断机理研究[J].计算机应用研究,2009,26(8):2982-2984.
 - [8] CABASINO M P, GIUA A. Diagnosability of discrete event systems using labeled Petri nets[J]. IEEE Transactions on Automation Science and Engineering, 2014, 11(1): 144-153.
 - [9] 罗继亮. Petri 网的一类禁止状态问题的混合型监控器算法设计[J].计算机学报,2008,31(2):291-298.
 - [10] SIMONA B, JAVIER C, JOSE M. Timing-failure risk assessment of UML design using time Petri net bound techniques[J]. IEEE Transactions on Industrial Informatics, 2011, 7(1): 90-104.
 - [11] LEFEBVRE D. On-line fault diagnosis with partially observed petri nets[J]. Transaction on Automatic Control, 2014, 59(7): 1919-1924.
 - [12] 叶丹丹,罗继亮.部分可观 Petri 网结构信息在故障诊断中的应用[J].控制理论与应用,2015,32(3):366-373.
 - [13] CABASINO M P, LAFORTUNE S, SEATZU C. Optimal sensor selection for ensuring diagnosability in labeled petri nets[J]. Automatica, 2013, 49(8): 2373-2383.
 - [14] LIME D, ROUX O H. Model checking of time petri nets using the state class timed automaton[J]. Discrete Event Dynamic Systems, 2006, 16(2): 179-205.
 - [15] 陈哲,刘久富,王正谦.基于正态 Petri 网的模型参数识别研究[J].计算机技术与发展,2014,24(5):20-22.
 - [16] CHEN Yufeng, LI Zhiwu, KHALGUI M, et al. Design of a maximally permissive liveness-enforcing Petri net supervisor for flexible manufacturing systems[J]. IEEE Transactions on Automation Science and Engineering, 2011, 8(2): 374-393.