

基于改进 Enet 网络的车道线检测算法



刘彬 刘宏哲

北京联合大学北京市信息服务工程重点实验室 北京 100101

(xytziubin@126.com)

摘要 针对实际驾驶环境中道路场景及车道线复杂多样的问题,提出一种基于改进 Enet 网络的车道线检测算法。首先,对 Enet 网络进行剪枝和卷积优化操作,并利用改进的 Enet 网络对车道线进行像素级图像语义分割,将车道线从图像中分离出来。然后,采用 DBSCAN 算法对分割结果进行聚类处理,将相邻车道线区分开来。最后,对车道线聚类结果进行自适应拟合,得到最终的车道线检测结果。该算法在香港中文大学的 CULane 数据集上进行了训练和测试,结果表明,其标准路面检测准确率达到 96.3%,各种路面综合检测准确率为 78.9%,图像帧处理速度为 71.4fps,能够满足实际驾驶环境中的复杂路况和实时性需求。此外,该算法还在图森未来的 TuSimple 数据集和实采数据集 LD-Data 上进行了训练和测试,均取得了实时性的检测结果。

关键词: 车道线检测;图像语义分割;聚类;自适应拟合

中图法分类号 TP391.4

Lane Detection Algorithm Based on Improved Enet Network

LIU Bin and LIU Hong-zhe

Key Laboratory of Information Service Engineering, Beijing Union University, Beijing 100101, China

Abstract Aiming at the complex diversity of road scenes and lane lines in the actual driving environment, a lane-line detection algorithm based on improved Enet network was proposed. Firstly, the Enet network is pruned and convolution optimized. The improved Enet network is used to segment the lane-line image semantics and separate the lane lines from the image. Then, the DBSCAN algorithm is used to cluster the segmentation results to distinguish adjacent lane lines from each other. Finally, the lane line clustering results are adaptively fitted to obtain the final lane line detection results. The proposed algorithm was trained and tested in the CULane dataset of the Chinese University of Hong Kong. The accuracy of standard pavement detection is 96.3%, the accuracy of comprehensive pavement detection is 78.9%, and the image frame processing speed is 71.4fps, which can meet the complex road conditions and real-time requirements in actual driving environment. In addition, the proposed algorithm has been trained and tested on Tucson's future TuSimple dataset and our actual acquisition dataset LD-Data, all of which have achieved real time detection results.

Keywords Lane detection, Image semantics segmentation, Clustering, Adaptive fitting

1 引言

近年来,自动驾驶研究受到广泛关注。在自动驾驶研究中,车道线检测是关键的一步,对车辆的安全行驶具有重要意义。实际道路场景中路面状况的复杂性以及车道线线型的多

样性,使得车道线检测问题难以得到解决。基于计算机视觉的传统车道线检测方法通过利用车道线的颜色、亮度、形状等信息,并设定感兴趣区域,可以实现对车道线的快速检测。但是,这类方法并不适用于复杂道路环境下的车道线,尤其是针对模糊的、受到车辆或者阴影遮挡、雨雪等恶劣天气条件下的

到稿日期:2019-05-06 返修日期:2019-11-06 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:国家自然科学基金(61871039,61802019,61906017);北京市属高校高水平教师队伍支持计划项目(IDHT20170511);北京市自然科学基金(4184088);北京联合大学领军人才项目(BPHR2019AZ01);北京市教委项目(KM201911417001,KM201711417005);国家科技支撑计划项目(2015BAH55F03);智能驾驶大数据协同创新中心(CYXC1902)

This work was supported by the National Natural Science Foundation of China (61871039,61802019,61906017), Supporting Plan for Cultivating High Level Teachers in Colleges and Universities in Beijing (IDHT20170511), Beijing Natural Science Foundation(4184088), Premium Funding Project for Academic Human Resources Development in Beijing Union University (BPHR2019AZ01), Beijing Municipal Commission of Education Project (KM201911417001, KM201711417005), National Key Technology R&D Program (2015BAH55F03) and Big Data Collaborative Innovation Center for Intelligent Driving (CYXC1902).

通信作者:刘宏哲(liuhongzhe@buu.edu.cn)

道路,几乎检测不出车道线。然而,深度学习的快速发展,尤其是在图像语义分割上的成功应用,使得车道线检测难题有望得到解决。深度学习需要对样本进行标注,特别是对一些图像上不明显但能被人工识别的目标进行标注,通过训练学习目标特征,从而能够在测试中将目标检测出来。这对于复杂路况下的车道线检测是非常有效的。此外,对深度学习网络的压缩和优化研究,极大地提高了深度学习网络处理数据的实时性。

基于传统方法的车道线检测利用道路图像的特征(如颜色梯度、直方图或边缘)来检测车道线。可以将基于视觉的解决方案划分为两个主要的类别。1)基于特征的方法^[1-4]。此类方法依据道路的特征(如颜色、坡度或边缘)提取车道线。Chang等^[1]应用一个Canny边缘检测算子来提取车道线边界,并提出一种霍夫变换下的边缘扫描方法来检验边缘是否属于车道线。文献^[2]引入一种自适应的感兴趣区域和车道线定位的方法。Benligiray等^[3]提出一种基于快速消失点的估计算法对车道线进行检测。文献^[4]利用基于消失点的canny边缘检测算法和霍夫变换进行车道线检测。基于特征的方法是简便易行的,但是要求路面清晰且车道线与周围目标具有鲜明的色彩对比。2)基于模型的方法^[5-8]。此类方法建立了道路结构的数学模型,使用摄像机和车道线的几何坐标作为输入参数,并依赖于它们的精度。为了确定参数,将初始配置信息与从道路图像中提取的车道线的特征点合并。Li等^[5]使用扩展卡尔曼滤波器和B样条曲线模型来保证车道线检测的连续性。Tan等^[6]在基于双曲线双通道模型条件下,利用改进的河流寻点算法(Improved River Flow, IRF)与随机抽样一致性算法(Random Sample Consensus, RANSAC)来检测弯曲的车道线。Li等^[7]采用逆透视图(Inverse Perspective Mapping, IPM)模型来检测图像中的直线。Mu等^[8]通过目标分割确定车道线候选区域,采用Sober算子提取冗余边缘,并采用分段拟合线型或抛物线模型检测车道线。利用基于模型的方法检测车道线的难点在于求解数学模型,从而准确拟合出车道线;检测的准确性不仅取决于摄像机的初始输入参数或道路的形状,还取决于从捕获的道路图像中提取的特征点。

基于深度学习车道线检测主要利用卷积神经网络强大的特征提取能力。文献^[9-10]提出一种基于卷积神经网络(Convolutional Neural Network, CNN)的车道检测算法。Li等^[11]使用CNN和一个递归神经网络(Recurrent Neural Network, RNN)来检测车道线边界, CNN提供车道线结构的几何信息, RNN用该信息检测车道线。He等^[12]提出使用双视图卷积神经网络(Dual-View Convolutional Neural Network, DVCNN)框架进行车道线检测。大量研究表明,卷积神经网络作为特征提取器和分类器,能够提高车道线检测和识别的性能。Bailo等^[13]提出一种提取多个感兴趣区域的方法,合并可能属于同一类的区域,最后利用主成分分析网络(Principal Component Analysis Network, PCANet)^[14]和卷积神经网络对候选区域进行分类。Lee等^[15]提出一种基于灭点指导的多任务网络(Vanishing Point Guided Network, VPG-Net)来解决复杂天气条件下的车道线与路面标志识别和分类

问题。上述深度学习方法能够准确提取车道线特征,但是由于网络深度的影响,特征提取的实时性不足。此外,深度学习获取的车道线特征也不平滑,还需进一步拟合。

基于传统方法的车道线检测能够达到实时性检测的要求,并且算法对运行平台的要求也比较低;但是在面对复杂路况时检测鲁棒性很差,甚至检测不出车道线,这对于安全行驶决策是致命的威胁。基于深度学习车道线检测方法在特征提取上具有很大的优势,能够提取复杂路况中的车道线特征;但是由于网络深度的影响,参数量大、计算复杂,导致实时性不足,并且获取的车道线特征也不平滑。针对上述问题,本文提出一种基于改进Enet网络的车道线检测算法。该算法的流程图如图1所示,首先对输入的原始图像进行初始化,然后将其输入到网络编码器进行处理以提取图像特征,再通过解码器处理恢复图像的分辨率,接着全卷积输出网络分割结果,继而对车道线分割结果进行聚类,最后自适应拟合车道线输出结果图。

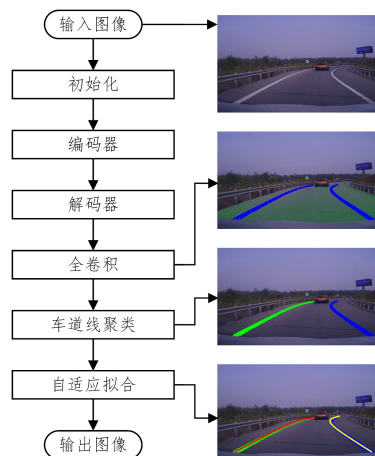


图1 算法流程图

Fig. 1 Algorithm flowchart

该算法主要具备以下优点:1)对Enet网络进行剪枝和卷积优化,使网络更加轻量化,降低了参数量和计算的复杂度,提高了网络处理的实时性;2)采用自适应拟合方法对车道线进行拟合,能够在对不同车道线线型进行准确拟合的条件下兼顾实时性。

2 基于改进 Enet 的车道线检测算法

Enet网络是由Paszke^[16]提出的一种轻量化图像语义分割网络,能够实现目标的像素级语义分割,具有参数量少、运算速度快的特点,满足车道线检测的实时性和准确性要求;同时,Enet网络还具备一定的可塑性。基于此,本文对Enet网络进行剪枝和卷积优化改进,提出一种基于改进Enet网络的车道线检测算法。

2.1 Enet 网络架构

Enet网络采用的是当前通用的编码器-解码器网络结构。这是一种轻量化的网络结构,在模型大小和参数量上都具有巨大的优势,专门为低延迟操作任务而设计。Enet网络改变了之前的编码器-解码器的对称性结构,在解码器中减少了卷积操作,从而很大程度地加快了处理速度。Enet网络对输入图像有一个初始化操作(Initial),如图2所示,其主要目的是生

成特征图,将池化和卷积操作生成的特征图进行融合。卷积操作共有 13 个 3×3 的滤波器,滑动步长为 2,共获得 13 张特征图,最大值池化(MaxPooling)是一个非覆盖的 2×2 的滑动窗口,得到 3 张特征图,最后经过融合一共获得 16 张特征图。




图 2 初始化操作

Fig. 2 Initialization operation

此外,Enet 网络中还采用了一种 Bottleneck 的卷积结构,本文称之为封装卷积模块,该模块贯穿 Enet 网络的始终。其主要应用在编码器-解码器中,具体结构如图 3 所示,每个封装卷积模块包含 3 个卷积层,图 3 中自上而下为 1 个 1×1 的投影映射(用于减少维度)、1 个主卷积层和 1 个 1×1 的升维;并且在卷积层之间进行归一化^[17]和 PReLU 激活^[18]操作。封装卷积模块并不是一成不变的,会根据具体的操作进行相应的变化。如果是下采样的封装卷积模块, 1×1 的投影映射被核大小为 2×2 、步长为 2 的 MaxPooling 层替代,并且用 0 进行填充,以匹配特征图的大小。Conv 是一个 3×3 的常规卷积、扩张卷积或者全卷积,有时也会使用 1×5 和 5×1 的非对称卷积进行替换。正则化(Regularier)采用的是文献^[19]中的 Spatial Dropout,以解决模型过拟合的问题。




图 3 Bottleneck 卷积结构

Fig. 3 Bottleneck convolution structure

Enet 的总体架构如表 1 所列。在初始化和最后全卷积(Full Convolution, Fullconv)之间,还包含 5 个部分。第一部分,有 1 个降采样的封装卷积模块,后跟 4 个普通卷积的封装卷积模块。第二部分,首先是最大值池化的封装卷积模块,后面依次接 8 个不同的封装卷积模块:普通的封装卷积模块;1 个主卷积扩张率为 2 的扩张的封装卷积模块;非对称封装卷积模块;1 个主卷积扩张率为 4 的封装卷积模块;4 个依次重复除了最大值池化操作外的封装卷积模块,并且扩张率依次扩大 2 倍,即扩张率依次为 2, 4, 8, 16。第三部分,重复第二部分除了最大值池化封装卷积操作外的所有操作。第四部分,有 1 个上采样的封装卷积,后跟 2 个普通的封装卷积。由于之前的操作已经提取到了足够的特征信息,这里需要将图像的分辨率恢复到原来的尺寸后输出即可。因此,第五部分直接是 1 个上采样的封装卷积后跟 1 个普通卷的封装卷积模

块。最后,全卷积输出图像语义分割的最终结果。第四、第五部分之所以没有采用扩张卷积模块,是因为前 3 部分的编码模块已经对图像分割完全,不需要扩大视野来提取特征信息,解码结构的作用主要是恢复图像的分辨率,同时提高网络模型运行的效率。

表 1 Enet 网络结构

Table1 Framework of Enet network

Name	Type	Output size
Initial		$16 \times 256 \times 256$
Bottleneck	Downsampling	$64 \times 128 \times 128$
$4 \times$ Bottleneck 1. x		$64 \times 128 \times 128$
Bottleneck 2.0	Downsampling	$128 \times 64 \times 64$
Bottleneck 2.1		$128 \times 64 \times 64$
Bottleneck 2.2	Dilated 2	$128 \times 64 \times 64$
Bottleneck 2.3	Asymmetric 5	$128 \times 64 \times 64$
Bottleneck 2.4	Dilated 2	$128 \times 64 \times 64$
Bottleneck 2.5		$128 \times 64 \times 64$
Bottleneck 2.6	Dilated 2	$128 \times 64 \times 64$
Bottleneck 2.7	Asymmetric 5	$128 \times 64 \times 64$
Bottleneck 2.8	Dilated 16	$128 \times 64 \times 64$
Repeatsection 2, without bottleneck 2. 0		
Bottleneck 4.0	Upsampling	$64 \times 128 \times 128$
Bottleneck 4.1		$64 \times 128 \times 128$
Bottleneck 4.2		$64 \times 128 \times 128$
Bottleneck 5.0	Upsampling	$16 \times 256 \times 256$
Bottleneck 5.1	Upsampling	$16 \times 256 \times 256$
Fullconv		$C \times 512 \times 512$

2.2 Enet 网络改进分析

车道线检测对实时性和准确率要求都很高。因此,在选择深度学习网络架构时,要特别考虑实时性和准确率要求。Enet 网络正是这样一种轻量化、低复杂度和低计算力的网络结构,非常符合车道线检测的相关要求。通过分析认为,可以对 Enet 网络进行改进来使其适应车道线检测问题。具体改进主要体现在以下两个方面:

- (1) 压缩网络结构,进一步加快图像处理的速度,保证实时性;
- (2) 卷积核替换,确保能够提取到足够多的特征信息,从而保证检测精度。

改进后的 Enet 网络如图 4 所示。

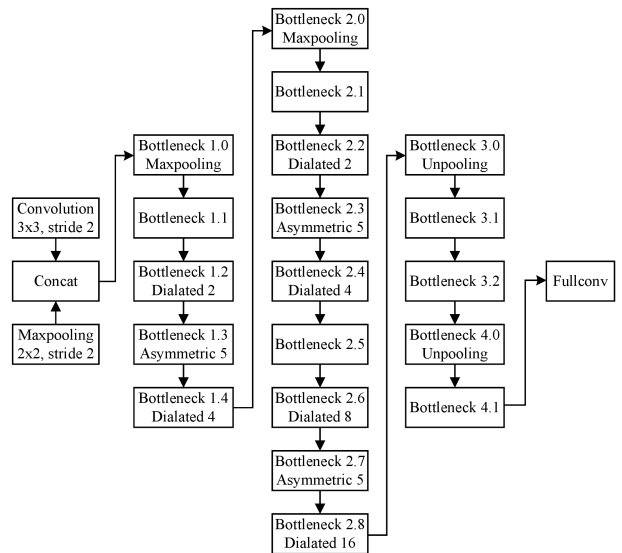


图 4 改进 Enet 网络示意图

Fig. 4 Improved Enet network diagram

2.2.1 Enet 网络压缩

虽然 Enet 网络是一种轻量化的网络架构,但是通过表 1 可以看出,Enet 网络中的第二部分与第三部分的卷积操作是在同一尺度上的重复操作,这会产生信息冗余问题。一般来说,重复的卷积操作会重复性地提取特征信息,从而造成一定的信息冗余,而这可能不会对结果产生影响或者产生的影响非常小。因此,本文对 Enet 网络进行进一步压缩,将重复卷积操作的第三部分剪除,以加快运算速度,进一步提高网络处理的实时性,以满足智能驾驶的实时性需求。这里将剪除后的 Enet 网络命名为 C-Enet(Compressed Enet)。

2.2.2 Enet 卷积替换

Enet 网络中包含多种卷积类型。其中第一部分,降采样封装卷积后跟 4 个普通的封装卷积模块。降采样封装卷积的作用是降低图像的分辨率,加快图像处理的速度,同时降低信息的冗余。当前,相机采集的图像分辨率普遍较高,但对于具体的分类任务来说,分辨率并不是越高越好,尤其是对于实时性要求较高的任务,诸如车道线检测任务。分辨率高固然可以提高目标分类的准确率,使得提取的特征信息足够丰富。然而,当图像分辨过高时,并不能一直提高分类精度,分辨率过高,冗余信息也是相应增加的,这既会降低图像处理的速度,也会对分类的准确率产生一定的影响。对于重复的 4 个封装卷积模块,可以进行相关的改进。普通的卷积模块在信息提取方面具有泛化的能力,对任务特殊性的提高能力有限。本文参照第二部分的卷积安排形式,在不引入新的计算量的情况下对第一部分的卷积形式和卷积结构进行相应的替换。具体替换如下:将第一部分最后的 3 个普通的封装卷积结构分别替换为扩张率为 2 的扩张封装卷积模块、非对称封装卷积模块和扩张率为 4 的扩张封装卷积模块。扩张的卷积能够增大感受野,提取到更多的特征信息;非对称卷积操作能够降低运算的复杂度,加快运算速度。卷积是进行等数量替换,不会影响算法的速度。文中在 C-Enet 的基础上对卷积进行替换。对于改进后的网络,本文称之为 CR-Enet(Compressed and Replaced Bottleneck Enet)。

2.3 基于改进 Enet 网络的分割结果

图 5 给出了应用本文提出的改进 Enet 网络输出的分割结果,其中包括匝道弯道、高速路上坡路、逆光、夜晚、干扰线、阴影、雨天以及雪天情况。




图 5 分割结果图

Fig. 5 Segmentation result graph

从分割效果图来看,改进的 Enet 网络具有很好的分类能力,并能够适应复杂的路面条件,特别是在逆光、夜晚、干扰线、有阴影的条件下依然有着良好的表现。实验结果表明,本文所提网络的特征提取能力很强,能够适应车道线检测的各种复杂路面环境。

2.4 车道线分割结果聚类

为了更好地对车道线进行拟合,在拟合前需要对分割结果进行聚类,将同一条车道线的特征点进行聚类连接,从而形成聚类点。本文采用的基于密度的聚类算法 DBSCAN,可以通过样本分布的紧密程度决定聚类情况。同一类别的样本之间是紧密相连的,该类别中任意样本周围不远处一定存在同类别的样本。

DBSCAN 的车道线聚类算法流程如算法 1 所示。

算法 1 DBSCAN 聚类算法

输入:分割特征点图集 D ,邻域参数 $(\epsilon, \text{MinPts})$,其中, ϵ 表示一个点周围邻近区域的半径, MinPts 表示邻近区域内至少包含的点的个数。通过实际聚类效果比较,实验中设置 $\epsilon=3, \text{MinPts}=3$ 。

输出:车道线聚类点集 C_1, C_i 表示第 i 条车道线。

1. 初始化核心对象集 $\Omega = \emptyset$, 聚类簇数 $k=0$, 未访问样本集合 $\Gamma = D$, 簇划分 $C = \emptyset$ 。
2. 对于 $j=1, 2, \dots, n$, 按下面的步骤找出所有的核心对象:
 - (1) 通过距离度量方式, 找到样本 x_j 的 ϵ -邻域子样本集 $|N_\epsilon(x_j)|$;
 - (2) 如果子样本集中样本的个数满足 $|N_\epsilon(x_j)| \geq \text{MinPts}$, 则将样本 x_j 加入核心对象样本集合: $\Omega = \Omega \cup \{x_j\}$ 。
3. 如果核心对象集合 $\Omega = \emptyset$, 则算法结束, 否则转入步骤 4。
4. 在核心对象集合 Ω 中, 随机选择一个核心对象 o , 初始化当前簇核心对象队列 $\Omega_{\text{cur}} = \{o\}$, 类别序号 $k = k + 1$, 当前簇样本集合 $C_k = \{o\}$, 更新未访问样本集合 $\Gamma = \Gamma - \{o\}$ 。
5. 如果当前簇核心对象队列 $\Omega_{\text{cur}} = \{o\}$, 则当前聚类簇 C_k 生成完毕, 更新簇划分 $C = \{C_1, C_2, \dots, C_k\}$ 和核心对象集合 $\Omega = \Omega - C_k$, 转入步骤 3。否则更新核心对象集合 $\Omega = \Omega - C_k$ 。
6. 在当前簇核心对象队列 Ω 中取出一个核心对象 o' , 通过邻域距离阈值 ϵ 找出所有的 ϵ -邻域子样本集 $N_\epsilon(o')$, 令 $\Delta = N_\epsilon(o') \cap \Gamma$, 更新当前簇样本集合 $C_k = C_k \cup \Delta$, 未访问样本集合 $\Gamma = \Gamma - \Delta$ 和 $\Omega_{\text{cur}} = \Omega_{\text{cur}} \cup (\Delta \cap \Omega) - o'$, 转入步骤 5。

车道线聚类结果如图 6 所示, DBSCAN 聚类算法成功将车道线区分开。



图 6 车道线聚类结果

Fig. 6 Lane line clustering results

对于图 6 中不连续的车道线, 根据近车端部分车道线拟合

结果探测的方式,若其在拟合延长线上,则归为同一条车道线。

2.5 自适应拟合

实际路况下,车道线线型多样。直线拟合固然速度很快,但是遇到弯道时拟合结果将会变得非常不准确。二次曲线可以满足一般弯道的拟合情况,但是对于曲率较大的弯道,拟合过程也存在着极大的误差。三次曲线拟合的速度慢,对于不连续的车道线,其结果存在非常大的误差,极易造成拟合不匹配的现象;同时也会造成拟合结果向下、向上延续性差的问题,在向上、向下延续的过程中极易产生弯曲和偏离实际路况的问题。针对这种情况,本文提出一种车道线自适应的拟合算法,即对车道线特征点集进行自适应拟合,自动选取拟合线型,以保证拟合的准确性。

自适应拟合算法的依据:对于一系列离散的点集 $P(x_i, y_i)$ (其中 $i=1,2,3,\dots,n, n$ 为自然常数),不管通过哪种线型公式进行拟合,必然能够得到一条拟合线,有尽可能多的点在拟合线上,或者均匀分布在拟合线的周围并且距离越小越好;或者说是真值 y_i 和预测值 \bar{y}_i 之间的差值 d 越小越好。对于差值 d ,可能存在有正有负的情况,这里对其进行平方,如式(1)所示,以便后续进行计算和比较,同时也可以对其进行客观评价。

$$d^2 = \sum_{i=1}^n (y_i - \bar{y}_i)^2 \quad (1)$$

如果是单纯的差值,可能存在正负相互抵消的情况,不能正确、客观地表现出拟合点在拟合线周围分布的离散程度,可能会存在极大的评价误差;通过对其求平方,保证了距离为正就可以准确表达这种离散程度。但是, d^2 会随着拟合点数 n 的增加而逐渐向上累加,最后达到一种无法估计和衡量的情况。针对这种情况,对其进行均值化,同时进行开平方,以便在确保它始终为一个正值的同时避免因为它的持续累加而无法进行估量的情况。开平方可以将其限定在一个更小的阈值范围内,这也符合拟合点在拟合线周围离散程度越小越好的原则。具体计算如式(2)所示:

$$d = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (2)$$

自适应拟合算法首先以基于最小二乘法的直线拟合作为探测依据,通过直线拟合求得 d 的大小,并以此决定拟合是否需要采用二次或者三次曲线。

自适应拟合算法的整体流程如算法 2 所示。

算法 2 自适应拟合算法

输入:车道线特征点集 $I(x, y)$

输出:车道线拟合结果

1. 提取车道线控制点集 $I'(x', y')$ 。
2. 首先采用直线进行拟合,判断 d^2 是否在阈值 t_1 内。若 $d^2 \leq t_1$, 则拟合下一条车道线;若 $t_2 \geq d^2 > t_1$, 则选择采用二次曲线拟合;若 $t_3 \geq d^2 > t_2$, 则直接采用三次曲线进行拟合;若 $d^2 > t_3$, 则不进行拟合。
3. 最终评价指标也以 d^2 最小为原则,输出车道线拟合结果。

直线拟合与自适应拟合的结果分别如图 7 和图 8 所示。在曲线路面下,直线拟合显然是不准确的,而自适应拟合通过对路面线型的自适应实现了对车道线的准确拟合。



图 7 直线拟合

Fig. 7 Straight line fitting




图 8 自适应拟合

Fig. 8 Adaptive fitting

3 实验及结果分析

3.1 实验数据集

目前专门用于车道线检测的公开数据集,主要有香港中文大学提出的 CULane 数据集和图森未来提出的 TuSimple 数据集,大多数研究者都是基于以上数据集进行相关的研究和实验。本文不仅在 CULane 数据集和 TuSimple 数据集上进行了相关实验,还在基于北京和天津的实际路面环境采集的 LD-Data 数据集上进行了实验。

3.1.1 CULane 数据集

CULane 数据集由香港中文大学提出,由 6 辆车于不同时间在北京录制,55 个多小时共收集了 133 235 张图片。实验将数据集中的 88 880 张图片作为训练集,9 675 张图片作为验证集,34 680 张图片作为测试集。数据集内包括城市、农村和高速公路等场景。该数据集样本标注示例如图 9 所示,道路中的车道线用粗实线进行标注。



图 9 CULane 标注示例

Fig. 9 CULane annotation example

3.1.2 TuSimple 数据集

TuSimple 数据集是图森未来专门为自动驾驶算法研发测试建立的数据集。该数据集包含大量时长为 1s 的视频,通过分帧将 1s 视频数据转换成 20 张图片,形成图像数据集,并且仅对最后一张图片进行车道线标注。该数据集中,训练集包含 72 520 张图像(其中 3 626 张标注图像),测试集包含 55 640 张图像(其中 2 782 张标注图像)。此外,该数据集主要是国外高速场景下的道路图像,属于结构化道路场景。该数

据集标注示例如图 10 所示,车道线采用中心打点的方式进行标注,这样就可以通过向两侧等距扩展获得车道线的轮廓。




图 10 TuSimple 标注示例

Fig. 10 TuSimple annotation example

3.1.3 LD-Data 数据集

LD-Data 数据集依托于北京联合大学智能驾驶平台采集整理,共包含北京市和天津市各种路况下的 100 383 张样本,其分布如表 2 所列。

表 2 LD-data 数据集分布

Table 2 LD-data dataset distribution

路况	样本数量	路况	样本数量
阴影	9 925	雨	13 290
损坏	11 343	雪渍	8 424
较少曝光	6 243	夜晚	7 789
过度曝光	15 343	常规道路	18 356
雾	9 561	总计	100 343

该数据集样本标注示例如图 11 所示,采用了全轮廓标注的方式,标注结果更加准确。



图 11 LD-Data 标注示例

Fig. 11 LD-Data annotation example

3.2 评价标准

自动驾驶不仅要求能够避障和感知道路交通信息,还需要遵守交通规则,对车道线检测的要求比较高。很多交通规则的设计使得行人和车辆必须依照一定的规则进行移动,这些规则的参考标准除了交通信号灯外,就是道路车道线,通过

检测车道线可以进一步检测地面指示标志,进行前碰撞预警策略的设计等。

为了判断是否能成功检测车道线,将车道线视为宽度为 30 px 的线,并计算出车道线真值 T 与预测值 H 之间的重叠部分占真值的百分比 (IoU)。若 IoU 大于某个阈值的预测,则被视为准确检测到了车道线。本文以 IoU 大于或等于 0.5 作为检测标准。 IoU 的计算如式(3)所示:

$$IoU = \frac{H}{T} \times 100\% \quad (3)$$

3.3 实验设置

本实验在 Ubuntu16.04 环境下基于 Python3.5, Tensorflow-gpu-1.10.0, 以及依赖函数库 Easydict-1.6, Opencv-python-3.4.1.15, Glog-0.3.1, Numpy-1.13.1, Matplotlib-2.0.2, Scikit-learn-0.19.1 完成。将样本训练集和验证集送入 Enet 网络与本文改进的 Enet 网络中进行训练和验证。参照文献 [20] 中 SCNN 模型,使用标准梯度下降法训练模型,参数设置:批处理量为 12,基础学习率为 0.01,学习动量为 0.9,权重衰减为 0.0001,迭代次数设置为 60 000。

3.4 实验对比分析

在 CULane, TuSimple, LD-Data 数据集上,分别对 Enet 网络、压缩后的 C-Enet 网络、加入扩张卷积和非对称卷积的 CR-Enet 进行实验,并与目前 3 种数据集上效果最好的方法 SCNN 进行比较。表 3—表 5 分别列出了几种算法在 CULane, TuSimple, LD-Data 数据集上的实验结果对比。

从表 3 中的实验结果可以看出,Enet 网络的特征提取能力和检测结果的准确率高于 SCNN 网络;Enet 经过压缩以后得到 C-Enet,去掉了编码器中部分重复卷积,检测结果的准确率有所下降,但是仍然优于 SCNN;C-Enet 用扩张卷积和非对称卷积替换部分常规卷积操作后得到的 CR-Enet,表现出了优越的性能。压缩的 C-Enet 网络的准确率之所以下降,是因为去掉部分重复卷积之后,特征提取的能力有所下降,但由于是重复的卷积操作,信息提取存在一定的冗余,因此准确率下降得并不是非常严重,而且这在一定程度上能够提高运算的效率。CR-Enet 网络之所以表现出了优越的性能,主要是因为替换卷积后增强了特征提取的能力,扩张的卷积增大了特征提取的感受野,使得提取的特征信息更加丰富。但是,CR-Enet 由于网络结构比较浅,并且轻量化,其在夜间、强光以及没有车道线的非结构化路面上的特征信息提取能力稍弱,因此没有达到最好的效果。

表 3 CULane 不同场景下车道线检测的准确率比较

Table 3 Accuracy comparison of lane line detection in different scenes of CULane

(单位:%)

方法	常规	拥堵	夜间	非结构化	阴影	箭头	强光	弯道	路口	总计
SCNN ^[20]	90.6	69.7	66.1	43.4	66.9	84.1	58.5	64.4	53.2	71.6
Enet	92.1	70.8	71.4	56.3	69.7	85.0	63.5	74.6	59.1	74.2
C-Enet	91.4	69.5	70.3	54.5	68.3	84.6	62.3	72.5	62.7	73.1
CR-Enet	96.3	76.9	66.3	45.7	74.6	87.3	58.1	78.1	63.5	78.9

由于 TuSimple 数据集主要是高速公路场景,因此实验过程中没有对场景进行细分,这里只对检测的准确率进行比较分析。由表 4 可以看到,CR-Enet 网络表现最好;SCNN 由于

网络结构较深,并且采用行列卷积的形式,因此特征提取能力较强,也取得了不错的效果;Enet 网络及 C-Enet 网络在 TuSimple 数据集上的表现也相当不错,说明对于这种单一场

景,在样本数量足够多的情况下,Enet 的网络能够更好地学习特征,提高检测识别能力和精度。

表 4 TuSimple 车道线检测的准确率比较

Table 4 Accuracy comparison of TuSimple lane line detection

方法	准确率/%
SCNN	96.53
Enet	95.74
C-Enet	93.22
CR-Enet	97.35

本文将 LD-Data 数据集场景划分为阴影、损坏、曝光不足、曝光过度、雨、雾、雪、夜和常规路况 9 种情况。在训练验

表 5 LD-Data 车道线检测的准确率比较

Table 5 Accuracy comparison of LD-Data lane line detection

方法	阴影	损坏	曝光不足	曝光过度	雾	雨	雪	夜	常规	总计
SCNN	81.5	80.7	71.2	69.1	45.3	62.1	56.1	69.3	88.1	73.3
Enet	88.1	87.6	76.5	75.1	51.9	67.8	61.2	66.0	93.6	78.4
C-Enet	86.4	83.1	75.3	72.9	49.1	65.3	58.7	63.5	91.2	76.2
CR-Enet	91.5	89.2	78.4	77.6	54.6	71.2	63.7	68.1	96.4	81.5

(单位:%)

SCNN,Enet,C-Enet 和 CR-Enet 模型检测速度的比较如表 6 所列。可以看出,4 种模型的处理速度是依次递增的,这是符合理论情况的。首先,SCNN 的网络结构最复杂,深度较大,所以速度最慢。Enet 网络本身是一种轻量化的网络结构,因此处理的速度快于 SCNN 网络。C-Enet 网络是在 Enet 基础上进行剪枝操作,因此处理速度快于 Enet 网络。而 CR-Enet 网络是在 C-Enet 网络基础上增加了非对称卷积操作,可以有效降低运算量和参数量,同时提高特征提取能力,因此

CR-Enet 网络表现出了最好的速度性能。

表 6 各网络模型检测速度的比较

Table 6 Comparison of detection speed of various network models

方法	单帧速度/ms	速度/fps
SCNN	42	23.8
Enet	19	52.6
C-Enet	16	62.5
CR-Enet	14	71.4

车道线检测结果如图 12 所示。




图 12 车道线检测效果图

Fig. 12 Lane line detection effect map

结束语 本文提出的基于改进 Enet 网络的车道线检测算法,能够满足实际驾驶环境中复杂路况和实时性的需求。文中采用改进 Enet 网络将道路图像中的车道线分割出来,利用 DBSCAN 聚类算法对分割结果进行聚类,将相邻车道线区分开来。最后,利用自适应拟合算法对不同曲率的车道线进行自适应拟合,以获得更加准确的车道线检测结果。未来,将在加强网络特征学习和迁移学习方面进行研究。加强网络特征学习可以提高对特征的识别能力,应对更加复杂的道路状况;迁移学习可以有效利用已有学习经验提高网络学习的效

率,以实现更加复杂和未知驾驶环境下的车道线检测。

参考文献

- [1] CHANG C Y, LIN C H. An Efficient Method for Lane-mark Extraction in Complex Conditions[C]// 2012 9th International Conference on Ubiquitous Intelligence and Computing and 9th International Conference on Autonomic and Trusted Computing. IEEE, 2012:330-336.
- [2] LEE C, DING D. An Adaptive Road ROI Determination Algo-

- rithm for Lane Detection[J]. Journal of the Institute of Electronics and Information Engineers, 2014, 51(1): 116-125.
- [3] BENLIGIRAY B, TOPAL C, AKINLAR C. Video-Based Lane Detection Using a Fast Vanishing Point Estimation Method [C]//IEEE International Symposium on Multimedia. IEEE, 2012; 348-351.
- [4] WANG J Y, DUAN J M. Lane Detection Algorithm Using Vanishing Point [C]// 2013 International Conference on Machine Learning and Cybernetics. IEEE, 2013, 2: 735-740.
- [5] LI W, GONG X, WANG Y, et al. A Lane Marking Detection and Tracking Algorithm Based on Sub-Regions [C]// Proceedings 2014 International Conference on Informative and Cybernetics for Computational Social Systems (ICCSS). IEEE, 2014; 68-73.
- [6] TAN H, ZHOU Y, ZHU Y, et al. A novel curve lane detection based on Improved River Flow and RANSA [C]// 17th International IEEE Conference on Intelligent Transportation Systems (ITSC). IEEE, 2014; 133-138.
- [7] LI H, FENG M, WANG X. Inverse Perspective Mapping Based Urban Road Markings Detection [C]// 2012 IEEE 2nd International Conference on Cloud Computing and Intelligence Systems. IEEE, 2012; 1178-1182.
- [8] MU C, MA X. Lane Detection Based on Object Segmentation and Piecewise Fitting [J]. Telkomnika Indonesian Journal of Electrical Engineering, 2014, 12(5): 3491-3500.
- [9] KIM J, LEE M. Robust Lane Detection Based on Convolutional Neural Network and Random Sample Consensus [C]// International Conference on Neural Information Processing. Cham: Springer, 2014; 454-461.
- [10] HUVAL B, WANG T, TANDON S, et al. An Empirical Evaluation of Deep Learning on Highway Driving [J]. arXiv: 1504. 01716.
- [11] LI J, MEI X, PROKHOROV D, et al. Deep Neural Network for Structural Prediction and Lane Detection in Traffic Scene [J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(3): 690-703.
- [12] HE B, AI R, YAN Y, et al. Accurate and Robust Lane Detection Based on Dual-View Convolutional Neural Network [C]// 2016 IEEE Intelligent Vehicles Symposium (IV). IEEE, 2016; 1041-1046.
- [13] BAILO O, LEE S, RAMEAU F, et al. Robust Road Marking Detection and Recognition Using Density-based Grouping and Machine Learning Techniques [C]// 2017 IEEE Winter Conference on Applications of Computer Vision (WACV). IEEE, 2017; 760-768.
- [14] CHAN T H, JIA K, GAO S, et al. PCANet: A Simple Deep Learning Baseline for Image Classification? [J]. IEEE Transactions on Image Processing, 2015, 24(12): 5017-5032.
- [15] LEE S, KIM J, YOON J S, et al. VPGNet: Vanishing Point Guided Network for Lane and Road Marking Detection and Recognition [J]. arXiv: 1710. 06288, 2017.
- [16] PASZKE A, CHAURASIA A, KIM S, et al. ENet: A Deep Neural Network Architecture for Real-Time Semantic Segmentation [J]. arXiv: 1606. 02147, 2016.
- [17] IOFFE S, SZEGEDY C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift [C]// International Conference on International Conference on Machine Learning. JMLR. org, 2015; 1-11.
- [18] HE K, ZHANG X, REN S, et al. Delving Deep into Rectifiers: Surpassing Human-level Performance on Imagenet Classification [C]// Proceedings of the IEEE International Conference on Computer Vision. 2015; 1026-1034.
- [19] TOMPSON J, GOROSHIN R, JAIN A, et al. Efficient Object Localization Using Convolutional Networks [C]// IEEE Conference on Computer Vision and Pattern Recognition. 2015; 648-656.
- [20] PAN X, SHI J, LUO P, et al. Spatial As Deep: Spatial CNN for Traffic Scene Understanding [C]// IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2017; 1-8.



LIU Bin, born in 1991, postgraduate. His main research interests include digital image processing and deep learning.



LIU Hong-zhe, born in 1971, Ph.D, professor, Ph.D supervisor, is a member of China Computer Federation. Her main research interests include visual computing and deep learning.