

DOI: 10.19951/j.cnki.1672-9331.20220419001

文章编号: 1672-9331(2023)06-0149-10

引用格式: 龙科军, 郭妍慧, 刘洋, 等. 基于全连接条件随机场的车道线检测方法[J]. 长沙理工大学学报(自然科学版), 2023, 20(6): 149-158.

Citation: LONG Kejun, GUO Yanhui, LIU Yang, et al. Lane line detection method based on Fully Connected CRFs[J]. J Changsha Univ Sci Tech (Nat Sci), 2023, 20(6): 149-158.

基于全连接条件随机场的车道线检测方法

龙科军^{1,2}, 郭妍慧¹, 刘洋¹, 桂彦^{2,3}, 王永峰⁴, 陈旺³

(1. 长沙理工大学 交通运输工程学院, 湖南 长沙 410114; 2. 长沙理工大学 智能道路与车路协同湖南省重点实验室, 湖南 长沙 410114; 3. 长沙理工大学 计算机与通信工程学院, 湖南 长沙 410114; 4. 东风悦享科技有限公司, 湖北 武汉 430058)

摘要:【目的】优化车道线检测结果中的噪声区域, 提高边缘分割精度。【方法】提出一种深度学习算法与后处理方法相结合的新方法; 引入全连接条件随机场(Fully Connected CRFs)算法对ENet-SAD算法输出的车道线概率图进行修正, 并将概率图与原图进行拟合, 得到车道线检测结果; 将新的检测算法在自建数据集及CULane数据集上进行训练及测试。【结果】在自建数据集上, 新算法在常规、强光、阴影、遮挡4种场景下的 F_1 分数分别为90.0%、73.1%、81.5%、76.6%; 在CULane数据集上, 该算法在常规场景下的 F_1 达到了91.0%。【结论】所提出的车道线检测算法能适应多类场景, 是一种有效的车道线检测算法。

关键词: 车道线检测; 自动驾驶; 全连接条件随机场; ENet-SAD算法; 自建数据集; CULane数据集

中图分类号: U495

文献标志码: A

0 引言

实时、精准的车道线检测能为智能驾驶和自动驾驶车辆^[1]提供重要基础条件, 因此车道线检测是智能驾驶和自动驾驶领域的重点研究内容。用于车道线检测的传感器类型众多, 主要包括雷达、全球定位系统设备以及视觉传感器等。相比于其他类型的传感器, 视觉传感器以其成本较低、视觉信息十分丰富的优势, 已成为目前车道线检测系统的主要传感器设备^[2-4]。采用视觉传感器进行车道线检测的方法较多, 主要可以分为3类, 即基于特征的检测^[5-7]、基于模型的检测^[8-10]、基于深度学习的检测^[11-15]。

基于深度学习的车道线检测方法主要依赖于具有强大特征提取能力的卷积神经网络(convolutional neural network, CNN), 其通过建立包含多个隐含层的神经网络, 将大量数据放入网络训练并提取车道线的本质特征, 以提升分类的

准确性^[11]。与另外两种方法相比, 深度学习检测方法虽然具有较高的检测精度和检测速度^[12], 但是车道线检测结果仍然存在细小的噪声区域以及边缘处分割精度不高的问题。

针对上述问题, 许多研究者将基于深度学习的车道线检测算法与后处理方法相结合对检测结果进行细化。KIM等^[13]将CNN与随机抽样一致性(random sample consensus, RANSAC)算法相结合, 利用RANSAC算法对深度学习算法所提取的车道线特征进行后处理, 该方法虽然减少了部分错误分类的区域, 但其精度仍不能满足要求。邓天民等^[11]提出了一种改进分割网络(segmentation network, SegNet)算法与连通域约束方法相结合的车道线检测方法, 该方法利用连通域约束方法去除分类错误的孤立区域, 得到了更为准确的车道线特征, 但是该方法需要对深度学习算法输出的二值图进行两次扫描, 实时性较差。刘彬等^[14]针对深度学习算法所获取的特征不平滑以及存在分类错误的问题, 提出了一种改进的高效神经网络

收稿日期: 2022-04-19; 修回日期: 2022-05-01; 接受日期: 2022-05-08

基金项目: 国家自然科学基金资助项目(52172313); 湖南省科技创新计划项目(2020RC4048); 长沙市科技重大专项(kh2301004)

通信作者: 龙科军(1974—)(ORCID: 0000-0002-5659-9855), 男, 教授, 主要从事交通运输规划与管理方面的研究。

E-mail: longkejun@csust.edu.cn

(efficient network, ENet)与具有噪声的基于密度的空间聚类算法(density-based spatial clustering of applications with noise, DBSCAN)相结合的方法对车道线进行检测,用改进的ENet进行车道线特征提取,用DBSCAN算法去除结果中分类错误的部分,虽然该方法能得到不错的检测结果,但计算量较大。周苏等^[15]针对这一问题提出了一种三支车道线检测算法,将自适应聚类及最小二乘法拟合作为后处理方法对深度学习算法的提取结果进行优化,去除了部分识别错误的像素点,但其自适应聚类过程的耗时占了整个算法检测时间的一半以上。

上述的后处理方法仅考虑像素点的位置信息,却忽略了像素点的颜色信息,导致检测结果仍有分类错误的区域。全连接条件随机场(Fully Connected CRFs)^[16]算法将图像中所有像素点之间的位置信息和颜色信息相结合,可以优化深度学习算法输出的分类图像中较为粗糙的边缘,并对分类错误的像素点进行修正,从而得到更加精细的边缘以及更加准确的检测结果。

ENet-SAD算法的优势在于其参数的数量较少,在训练阶段通过引入自注意蒸馏(self attention distillation, SAD)模块,在不影响算法检测速度的情况下,从算法自身学习到更好的特征。基于此,本文将ENet-SAD算法与Fully Connected CRFs算法相结合来提高车道线的检测精度。首先,使用ENet-SAD算法检测图像上的车道线,获得车道线的分类结果;然后,使用Fully Connected CRFs算法对车道线检测结果中的粗糙边缘以及分类错误的区域进行优化,获得更加细致且准确的分类结果;最后,分别在自建数据集及CULane数据集上对本文算法进行验证。

1 结合 Fully Connected CRFs 算法的 ENet-SAD 算法

1.1 算法总体结构

针对ENet-SAD算法输出的车道线检测结果存在明显的噪声区域以及分割精度不高的问题^[17],本文首先构建车道线数据集,对ENet-SAD算法进行训练,并将测试集输入ENet-SAD算法中对车道线进行预识别,输出类别概率;然后,利用类别概率构建Fully Connected CRFs算法的一阶势函数,利用高斯核的线性组合定义Fully

Connected CRFs算法的二阶势函数,采用均值场近似算法进行求解,得到优化后的概率图,在概率图上搜寻概率最大的像素点位置,将相应的类别标签赋予该像素点,并与原图进行拟合;最后,得到最终的车道线检测结果,并对检测结果进行评价。该算法的流程如图1所示。其主要流程包括:

1) 自建数据集。利用东风悦享科技有限公司生产的自动驾驶汽车Sharing-VAN 1.0Plus前方摄像头采集的影像,生成有效像素为1 920×1 080的道路图像数据,对道路图像中的车道线进行标注,制作数据集,并将数据集划分为训练集、验证集和测试集。

2) 构建及训练ENet-SAD算法。构建ENet-SAD算法,将训练集和验证集同时输入ENet-SAD算法中进行训练,得到最优算法。

3) ENet-SAD算法预识别。将测试集作为最优算法的输入,得到车道线概率图(图1中左下角的虚线框部分)。

4) 采用Fully Connected CRFs算法对ENet-SAD算法输出的概率图进行优化。将ENet-SAD算法输出的概率图以及原图作为Fully Connected CRFs算法的输入,构造Fully Connected CRFs算法的吉布斯能量函数,并输出优化后的概率图(图1中右下角的虚线框部分)。

5) 拟合。在优化后的概率图上选取概率值最大的像素点,打上相应的类别标签,并将检测结果与原图进行拟合。

6) 精度评价。通过计算 F_1 分数,将Fully Connected CRFs算法的检测结果与其他算法进行对比分析。

1.2 自建数据集

为提高算法在真实道路场景中的泛化性及鲁棒性,需要选取尽可能多的复杂的道路场景对算法进行训练。为此,作者自制了东风园区场景数据集作为试验数据集,对本文算法进行训练及测试。

1.2.1 数据采集

采集车辆为东风悦享科技有限公司生产的自动驾驶汽车Sharing-VAN 1.0Plus,车身配备12个摄像头,每个摄像头所拍摄图像的有效像素为1 920×1 080。本文采用的是车辆前端摄像头采集的车道线数据。采集地点为武汉市东风园区,道路场景包含直道、弯道,道路上有3条车道

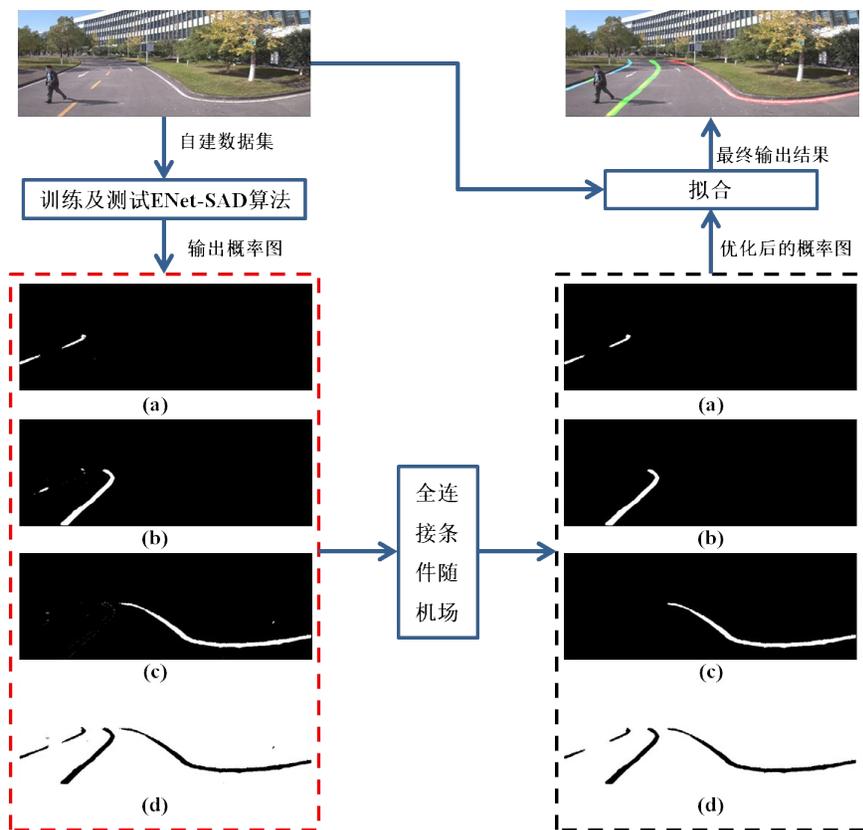


图 1 算法流程图

Fig. 1 Algorithm flow chart

线;天气包括晴天、阴天,采集时间为上午 10:00—11:00、下午 2:00—3:00,包含强光、阴影、遮挡等场景。视频的累计拍摄时长约 9 h。

算法输入的数据为图像格式,采集的数据为视频格式,因而需要对数据格式进行转换。在转换格式时,因为相邻视频帧中数据信息的相似度较大,所以采用每隔 5 帧提取一帧图像的方式。本文共选取了 5 741 幅包含不同场景且画质清晰的图像,为后续车道线数据集的构建提供支持。

1.2.2 数据集标注

运用 Labelme 软件中的 Create Polygons 方法从左到右依次对挑选出的 5 741 幅图像中车道线的

轮廓进行标注,并将其划分为不同的车道线类别。具体操作步骤为:首先,打开 Create Polygons 进入标注状态;然后,将光标放到图像左下方的车道线底部,点击左键从下往上对整条车道线轮廓进行标注,完成后再标注目标类型,将左、中、右 3 条车道线分别设为 lane1、lane2、lane3。完成后,如果发现部分标注点的位置存在问题,点击 Edit Polygons,对标注点进行调整。车道线的标注实例如图 2 所示。

在对直道进行车道线标注时,标注点可以选取得少些;而对于弯道,由于车道线弧度较大,则标注点需要多选取些,以确保标注精准。若车道



图 2 车道线标注图

Fig. 2 Label map of lane line

线为虚线,其标注方法与实线车道线相同;对破损的车道线,也采用实线车道线的标注方法;当车道线被车辆或者行人遮挡时,则采用分段标注的方法进行标注。

1.2.3 数据预处理

每张标注完成的图像在保存后,都会形成一个 json 格式的注释文件,该文件中保存了图像的路径、每一条车道线的标签以及标记点在图像中的位置。对算法网络进行训练时不能直接使用 json 格式的数据,必须将其转换成纯坐标格式的数据。在对 json 格式数据转换的同时,须按照 CULane 数据集的文件路径,设置自制数据集的路径,并修改 Labelme 数据集中自带的 json_to_dataset 代码。将左、中、右 3 条车道线的像素值分别设为 1、2、3,将非车道线区域的像素值设为 0。生成训练所需的标注掩码图,并按照 CULane 数据集的路径格式,生成标注文件路径、原图路径以及车道线三者相互对应的 txt 格式文件。对数据集中的所有图像进行随机选择,并根据 6:2:2 的比例将

其划分为训练集、验证集及测试集。

1.3 ENet-SAD 初始网络构建

ENet-SAD 是一种轻量级的图像分割网络^[18],包含一个编码器、一个解码器和一个与解码结构并行的车道线预测分支,总体结构如图 3 所示,图中, I_1 为初始阶段,在该阶段对输入图像进行初始化操作,减小输入图像的尺寸及冗余信息,提升算法速度; $B_1 \sim B_3$ 为编码阶段,在该阶段提取图像中的车道线特征;在 I_1 以及 $B_1 \sim B_3$ 模块后添加注意力生成器 (attention generator, AT-GEN),让前层模块模仿后一层模块的注意力图; J 为解码器,可以得到 $800 \times 288 \times n$ 的概率图, n 为类别数; E_1 为车道线的预测分支,用来预测图像中的车道线。

在图 3 中, SAD 模块让前层模块模仿更深层模块的注意力图,使浅层的注意力图得以修正,从而提取到更加丰富的上下文信息。浅层学习到的更好的特征反作用于深层,从而使网络学到更好的特征。在算法训练到一半的时候加入 SAD 模块,这样在部署过程中就不会增加额外的计算成本。

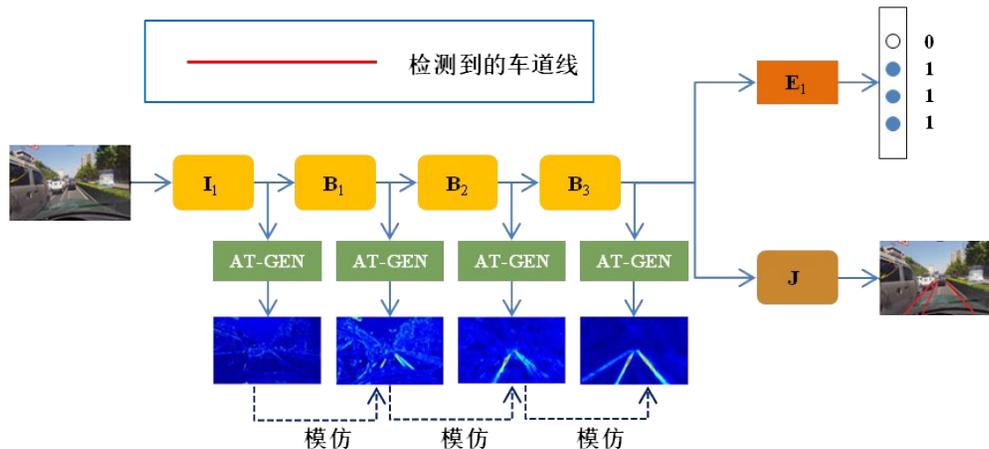


图 3 ENet-SAD 算法的总体结构

Fig. 3 ENet-SAD algorithm overall structure

1.4 训练及测试 ENet-SAD 算法

1.4.1 训练 ENet-SAD 算法

采用的图形处理器 (graphics processing unit, GPU) 为 1080Ti 计算机,基于 Opencv 库函数与 Tensorflow 框架,通过 CUDA10.0 与 CUDNN7.0 采用 Python 语言来实现 Fully Connected CRFs 算法,该算法主要调用 Python 的第三方库 pydensecrf。

参与算法训练的数据集为自建数据集以及 CULane 中的训练集和验证集。为了与 ENet-SAD 算法进行对比,根据文献[18]对本文算法的训练参数进行设置。设置迭代次数为 60 000,在迭代

次数为 40 000 时引入 SAD 模块。批处理大小为 12,基础学习率的初始值为 10^{-2} ,动量和权重衰减分别设置为 0.9 和 2×10^{-5} 。

在自建数据集上训练后得到的损失函数曲线如图 4 所示。由图 4 可知,在迭代次数小于 10 000 时,损失函数曲线迅速下降;在迭代次数达到 30 000 时,损失函数曲线趋于平缓,但波动幅度较大;在迭代次数达到 40 000 时,由于加入了 SAD 模块,损失函数曲线小幅下降,且随着迭代次数的不断增加,其波动幅度和频率都在逐渐减小;在迭代次数达到 60 000 时,损失函数的值稳定在 0.074 左右。

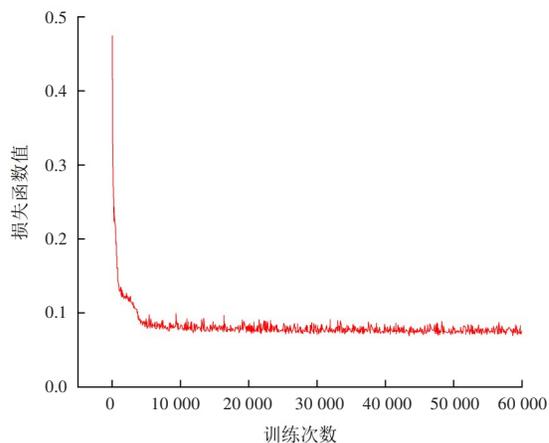


图4 损失函数曲线

Fig. 4 Loss function graph

1.4.2 测试ENet-SAD算法

将自建数据集中的测试集输入到训练好的ENet-SAD算法中,对ENet-SAD算法进行预识别。ENet-SAD算法输出的概率图见图1中左下方的虚线框部分,该虚线框中的图(a)~(c)分别为左、中、右侧车道线的类别概率图,图(d)为背景的类别概率图。每张概率图上的白色像素点表示这类像素点与其所在概率图是同一个类别,黑色像素点则表示其不属于这一概率图类别。

虽然ENet-SAD算法可以独立完成车道线的检测,但从图1中左下方虚线框内的概率图可以看出,在ENet-SAD算法输出的概率图中存在许多分类错误的区域,如图1中左下方虚线框中的图(b)将原本属于左侧车道线的像素点错误地归类为中间车道线的像素点。

$$\varphi_p(x_i, x_j) = \mu(x_i, x_j) \left[\omega_1 \exp\left(-\frac{|p_i - p_j|^2}{2\theta_\alpha^2} - \frac{|I_i - I_j|^2}{2\theta_\beta^2}\right) + \omega_2 \exp\left(-\frac{|p_i - p_j|^2}{2\theta_\gamma^2}\right) \right] \quad (3)$$

式中: $\mu(x_i, x_j)$ 为标签一致性因子,对标记成不同类型标签的邻近相似像素点进行惩罚,当类别标签 $x_i \neq x_j$ 时, $\mu(x_i, x_j) = 1$,当类别标签 $x_i = x_j$ 时, $\mu(x_i, x_j) = 0$; ω_1 、 ω_2 为线性组合的权重; p_i 、 p_j 为像素点 i 、 j 的位置信息; I_i 、 I_j 为像素点 i 、 j 的颜色信息; θ_α 、 θ_β 、 θ_γ 为超参数,其中, θ_α 、 θ_β 用于控制位置信息的尺度, θ_γ 用于控制颜色相似度的尺度。式(3)中中括号内的第一项为双边核,与像素点之间的位置以及颜色差异有关,第二项为高斯核,仅与像素点之间的位置有关。

运用均值场近似算法快速求解上述能量函数^[16],得到优化后的概率图,如图1中右下方的虚

1.5 基于Fully Connected CRFs算法的概率图优化

针对ENet-SAD算法输出的概率图存在噪声区域的问题,本文引入了Fully Connected CRFs算法,对ENet-SAD算法输出的概率图进行优化。Fully Connected CRFs是一种概率图模型,可以用来描述某一个像素与其他像素之间的关系,能够有效解决分类错误的问题。该方法将图像中像素点的所有特征进行归一化,从而求得最优解。

本文采用Fully Connected CRFs算法对ENet-SAD算法输出的概率图进行后处理,将概率图的优化问题转换为多标签分类问题^[16]。该方法为每一个像素点 i 分配一个类别标签 x_i ,图像中所有像素点的类别标签 $X = \{x_i\}$ 可通过最小化吉布斯能量函数得到。

图像像素点的类别标签 X 所对应的吉布斯能量函数可表示为:

$$E(X) = \sum_i \varphi_u(x_i) + \sum_{i < j} \varphi_p(x_i, x_j) \quad (1)$$

式中: $\varphi_u(x_i)$ 为一阶势函数,由该函数可以得到每个像素点的类别概率,其表达式为:

$$\varphi_u(x_i) = -\ln P(x_i) \quad (2)$$

式中: $P(x_i)$ 为ENet-SAD算法预识别结果中像素点 i 属于某类别的概率。

式(1)中 $\varphi_p(x_i, x_j)$ 为二阶势函数,用来描述图像中每一个像素点与其他像素点的位置、颜色关系,可用高斯核函数的线性组合来定义:

线框所示,该虚线框中的图(a)~(c)分别为优化后的左、中、右侧车道线类别概率图,图(d)为优化后的背景类别概率图,由该虚线框中的图(a)~(d)可以明显看出,优化后的概率图中已没有分类错误的区域。

2 试验及结果分析

为了测试引入Fully Connected CRFs的ENet-SAD算法的车道线检测方法的效果,分别在自建数据集及CULane数据集上对该算法进行训练及测试。在自建数据集上进行测试时,将测试集分

为常规、强光、阴影、遮挡4种场景,在这4种场景下对本文算法、ENet-SAD算法以及空间卷积神经网络算法^[19](spatial convolutional neural network algorithm, SCNN)进行测试;在公开数据集 CULane 的常规、拥挤、夜间、阴影、弯道以及强光这6种场景下对本文所提算法进行测试,并与其他当前的代表性算法进行对比;最后,计算各算法的 F_1 分数,对各算法的检测结果进行量化对比。

2.1 算法评价指标

将车道线预测结果与车道线标签之间的交并比^[20](intersection over union, IOU)作为阈值,当 IOU 大于 0.5 时,认为预测的车道线为真正例 T_p 。

采用 F_1 分数作为算法性能的评价指标^[19]。 F_1 分数为精确率 P 与召回率 R 的调和平均值,由式(4)进行计算:

$$F = \frac{2 \times P \times R}{P + R} \quad (4)$$

精确率与召回率分别由式(5)~(6)计算:

$$P = \frac{T_p}{T_p + F_p} \quad (5)$$

$$R = \frac{T_p}{T_p + F_n} \quad (6)$$

式(5)~(6)中: T_p 为真正例,表示真实值为车道线,且被预测为车道线的样本; F_p 为假正例,表示真实值为非车道线,但被预测为车道线的样本; F_n 为假负例,表示真实值为车道线,但被预测为非车道线的样本。

2.2 试验结果

2.2.1 自建数据集的试验结果

将自建数据集中的测试集分为常规、强光、阴影、遮挡4种场景,其分别占测试集总量的41.4%、13.6%、11.5%和33.5%。在这4种场景下,分别对本文算法、ENet-SAD算法及SCNN算法进行量化分析,计算这4种场景下各算法的 F_1 分数,结果见表1。

在常规场景下,本文算法的 F_1 分数相对于 ENet-SAD 算法、SCNN 算法的分别提升了 0.9%、0.7%;在强光场景下,本文算法的 F_1 分数较 ENet-SAD 算法、SCNN 算法的分别提升了 0.3%、2.7%;在阴影场景下,本文算法的 F_1 分数较 ENet-SAD 算法、SCNN 算法分别提升了 1.4%、0.5%;在遮挡场景下,本文算法的 F_1 分数较 ENet-SAD 算法、SCNN 算法分别提升了 0.1%、0.8%。由此可知,在这4种场景下,本文算法的 F_1 分数较 ENet-SAD 算法、

SCNN 算法的均有不同程度的提升,证明了本文方法的有效性。

表1 各算法在自建数据集上的 F_1 分数

Table 1 F_1 -score of each algorithm in the self-built dataset %

场景	ENet-SAD	SCNN	本文算法
常规	89.2	89.4	90.0
强光	72.9	71.2	73.1
阴影	80.4	81.1	81.5
遮挡	76.5	76.0	76.6

2.2.2 CULane 数据集的试验结果

为进一步验证本文算法的有效性,选取常规、拥挤、夜间、阴影、弯道、强光这6种有车道线的场景,对本文算法在公开数据集 CULane 上进行训练及测试,并与 ENet-SAD 算法、SCNN 算法以及超快的车道线检测 (ultra fast lane detection, UFLD) 算法^[21]进行对比。

各算法在 CULane 数据集上的检测结果的 F_1 分数见表2。由表2可以看出,在这6种场景下,本文算法的 F_1 分数较 ENet-SAD 算法、SCNN 算法的 F_1 分数均有所提升;在常规、拥挤、夜间以及强光场景下,较 UFLD 算法的 F_1 分数有所提升。

表2 各算法在 CULane 数据集上的 F_1 分数

Table 2 F_1 -score of each algorithm in the CULane dataset %

场景	SCNN ^[19]	UFLD ^[21]	ENet-SAD ^[18]	本文算法
常规	90.6	90.7	90.1	91.0
拥挤	69.7	70.2	68.8	70.4
夜间	66.1	66.7	66.0	66.9
阴影	66.9	69.3	65.9	67.1
弯道	64.4	69.5	65.7	66.3
强光	58.5	59.5	60.2	61.3

3 讨论

为方便讨论,将各算法在自建数据集上的检测结果与原图进行拟合,并将拟合结果可视化。其中,在各算法输出的4通道概率图中,当车道线的预测概率大于0.5时,在对应通道的概率图上搜索概率最大像素点的位置,将相应的类别标签赋予这些像素点,并与原图进行拟合,得到车道线检测结果。为方便表述,从左到右将每张图像上检测到的属于3条车道线的像素点分别用三角形、正

方形、圆形表示,如图5~8所示。

图5~8分别为常规、强光、阴影、遮挡4种场景下车道线检测的可视化结果。其中,(a)、(b)、(c)分别为ENet-SAD算法、本文算法(Fully Connected CRFs+ENet-SAD)及SCNN算法拟合的车道线结果。因为本文算法对局部区域以及车道线边缘进行了优化,所以在可视化图中将局部区域进行放大,便于对结果进行展示,见图5~8中引出的白色框部分。

从图5~8可以看出,ENet-SAD算法以及SCNN算法的检测结果在车道线边缘处和非车道线区域内存在明显的分类错误区域(噪声区域);而本文算法得到了更加细致的车道线边缘,仅存在较少的分类错误区域,得到了精确度更高的车道线检测结果。在图5所示的常规场景下,ENet-SAD算法、SCNN算法把车道上的指示标记检测为车道线,ENet-SAD算法将非车道区域停靠车辆的部分像素点检测为车道线,而本文算法没有类似错误。

与另外两种算法相比,本文算法的 F_1 分数在这4种场景下均有所提升,但是在遮挡场景下的检测效果稍差,在被遮挡的区域容易出现检测错误的点^[22-23],今后需要针对遮挡场景对算法进行进一步调整。

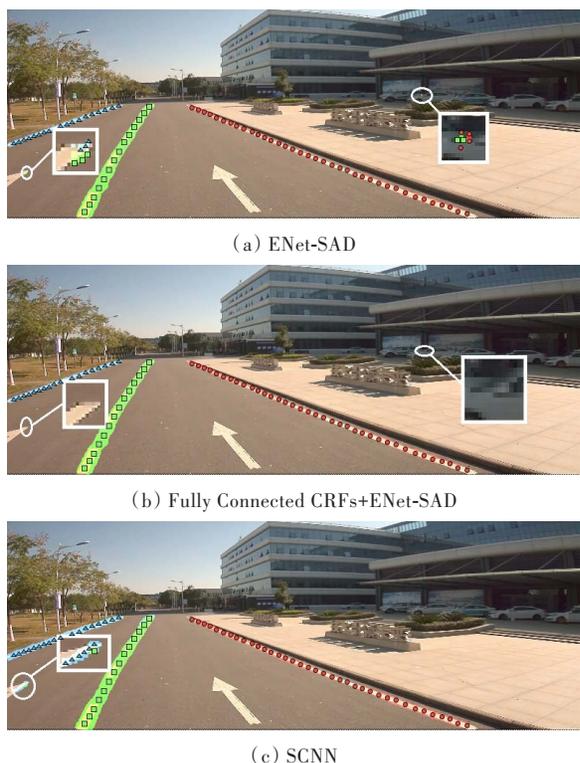


图5 常规路况检测结果
Fig. 5 Normal road condition test results

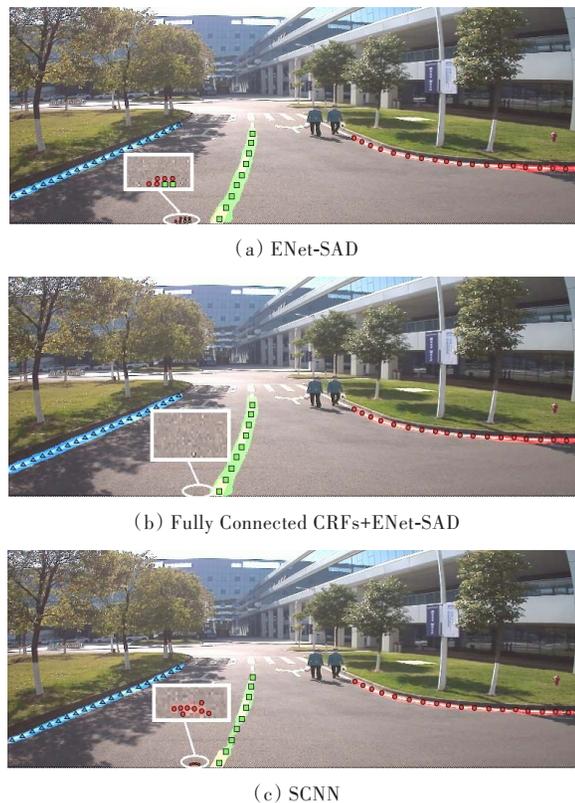


图6 强光路况检测结果
Fig. 6 Dazzle light road condition test results

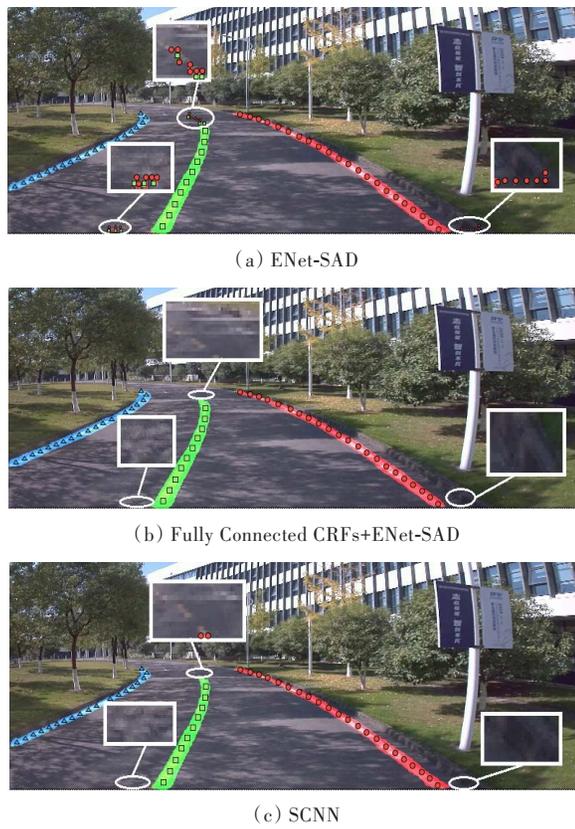


图7 阴影路况检测结果
Fig. 7 Shadow road condition test results

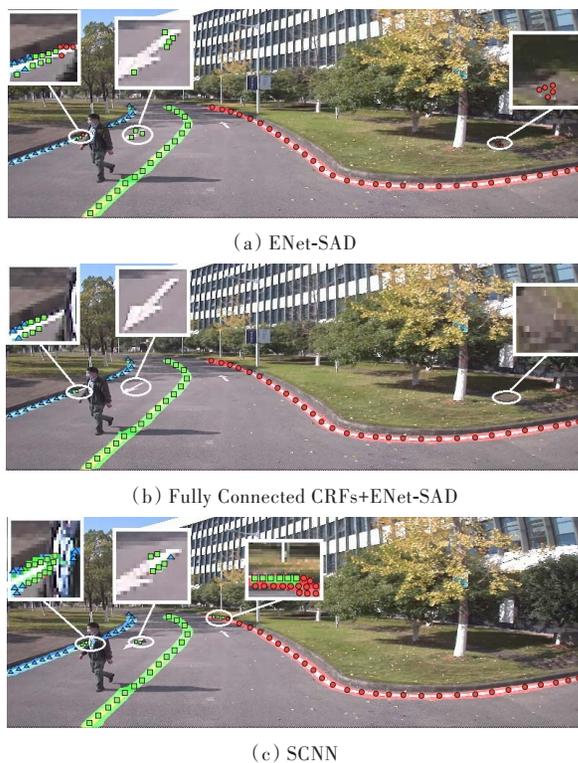


图8 遮挡路况检测结果

Fig. 8 Occlusion road condition test results

4 结论

针对车道线检测算法存在噪声区域和边缘分割精度不高等问题,本文构建了基于城市道路的车道线数据集,提出了ENet-SAD算法与Fully Connected CRFs算法相结合的车道线检测方法。首先,利用ENet-SAD算法提取车道线特征,得到车道线概率图。然后,利用Fully Connected CRFs算法对输出的概率图进行后处理。最后,分别在自建数据集以及CULane数据集上进行验证。试验结果显示,在自建数据集上,本文算法在常规、强光、阴影、遮挡这4种场景下的 F_1 分数分别为90.0%、73.1%、81.5%、76.6%;在CULane数据集上,本文算法在常规场景下的 F_1 分数达到了91.0%。本文算法的 F_1 分数较其他算法的 F_1 分数在大多数场景下都有所提升,说明本文算法是一种有效的车道线检测方法。

[参考文献]

[1] 黄中祥,覃定明,况爱武.考虑无人驾驶车辆影响的道路网络容量模型[J].长沙理工大学学报(自然科学版),2018,15(4):45-51. DOI:10.3969/j.issn.1672-9331.2018.04.007.

HUANG Zhongxiang, QIN Dingming, KUANG Aiwu. Capacity model of road network considering the impact of the autonomous vehicles [J]. Journal of Changsha University of Science & Technology (Natural Science), 2018, 15 (4) : 45-51. DOI: 10.3969/j.issn.1672-9331.2018.04.007.

[2] 吴一全,刘莉.基于视觉的车道线检测方法研究进展[J].仪器仪表学报,2019,40(12):92-109. DOI: 10.19650/j.cnki.cjsi.J1905719.

WU Yiquan, LIU Li. Research and development of the vision-based lane detection methods [J]. Chinese Journal of Scientific Instrument, 2019, 40(12) : 92-109. DOI: 10.19650/j.cnki.cjsi.J1905719.

[3] 刘力源,荣亚鹏,李硕,等.美国加州自动驾驶汽车路测数据分析[J].公路与汽运,2021(5):40-44. DOI: 10.3969/j.issn.1671-2668.2021.05.011.

LIU Liyuan, RONG Yapeng, LI Shuo, et al. Analysis of road test data of California self-driving cars [J]. Highways & Automotive Applications, 2021 (5) : 40-44. DOI: 10.3969/j.issn.1671-2668.2021.05.011.

[4] HARIS M, GLOWACZ A. Lane line detection based on object feature distillation [J]. Electronics, 2021, 10 (9) : 1102. DOI: 10.3390/electronics10091102.

[5] 罗康,韩军.全景鸟瞰图像中车道线颜色识别方法[J].电子测量技术,2019,42(13):80-85. DOI: 10.19651/j.cnki.emt.1902602.

LUO Kang, HAN Jun. Lane line color recognition in panoramic bird view images [J]. Electronic Measurement Technology, 2019, 42(13) : 80-85. DOI: 10.19651/j.cnki.emt.1902602.

[6] 罗胜,赵丽,王慕抽.基于道路特征信息的车道结构化解析[J].北京航空航天大学学报,2020,46(9):1643-1649. DOI: 10.13700/j.bh.1001-5965.2020.0079.

LUO Sheng, ZHAO Li, WANG Muchou. Lane semantic analysis based on road feature information [J]. Journal of Beijing University of Aeronautics and Astronautics, 2020, 46(9) : 1643-1649. DOI: 10.13700/j.bh.1001-5965.2020.0079.

[7] 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,2019,33(8):166-172. DOI: 10.13382/j.jemi.B1801845.

FU Lijun, LAN Fangpeng. Lane detection algorithm based on edge information coupling improved Hough transforms [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33 (8) : 166-172. DOI: 10.13382/j.jemi.B1801845.

[8] 王宝锋,齐志权,马国成,等.基于动态区域规划的双模型车道线识别方法[J].北京理工大学学报,2014,34(5):485-489. DOI: 10.15918/j.tb11001-0645.2014.05.010.

- WANG Baofeng, QI Zhiqian, MA Guocheng, et al. Lane detection system based on region dynamically planning and dual model fitting [J]. Transactions of Beijing Institute of Technology, 2014, 34(5): 485-489. DOI: 10.15918/j.tbit1001-0645.2014.05.010.
- [9] 王科, 黄智, 钟志华. 基于不定Bezier变形模板的城市道路检测算法[J]. 机械工程学报, 2013, 49(8): 143-150. DOI: 10.3901/JME.2013.08.143.
- WANG Ke, HUANG Zhi, ZHONG Zhihua. Algorithm for urban road detection based on uncertain bezier deformable template [J]. Journal of Mechanical Engineering, 2013, 49(8): 143-150. DOI: 10.3901/JME.2013.08.143.
- [10] JANG H J, BAEK S H, PARK S Y. Curved lane detection using robust feature extraction [C]//The Proceedings of 2014 2nd International Conference on Systems and Informatics (ICSAI 2014). Shanghai: IEEE, 2015: 109-112. DOI: 10.1109/ICSAI. 2014. 7009269.
- [11] 邓天民, 王琳, 杨其芝, 等. 基于改进SegNet算法的车道线检测方法[J]. 科学技术与工程, 2020, 20(36): 14988-14993.
- DENG Tianmin, WANG Lin, YANG Qizhi, et al. Lane line detection method based on improved SegNet algorithm [J]. Science Technology and Engineering, 2020, 20(36): 14988-14993.
- [12] NEVEN D, DE BRABANDERE B, GEORGOULIS S, et al. Towards end-to-end lane detection: an instance segmentation approach [C]//The Proceedings of 2018 IEEE Intelligent Vehicles Symposium (IV). Changshu: IEEE, 2018: 286-291. DOI: 10.1109/IVS. 2018. 8500547.
- [13] KIM J, LEE M. Robust lane detection based on convolutional neural network and random sample consensus [M]//Neural Information Processing. Cham: Springer International Publishing, 2014: 454-461. DOI: 10.1007/978-3-319-12637-1_57.
- [14] 刘彬, 刘宏哲. 基于改进ENet网络的车道线检测算法[J]. 计算机科学, 2020, 47(4): 142-149. DOI: 10.11896/j.sjcx.190500021.
- LIU Bin, LIU Hongzhe. Lane detection algorithm based on improved ENet network [J]. Computer Science, 2020, 47(4): 142-149. DOI: 10.11896/j.sjcx.190500021.
- [15] 周苏, 吴迪, 金杰. 基于卷积神经网络的车道线实例分割算法[J]. 激光与光电子学进展, 2021, 58(8): 381-388.
- ZHOU Su, WU Di, JIN Jie. Lane instance segmentation algorithm based on convolutional neural network [J]. Laser & Optoelectronics Progress, 2021, 58(8): 381-388.
- [16] 桂彦, 郭林, 曾光. 单幅图像训练深度神经网络的编辑传播方法[J]. 计算机辅助设计与图形学学报, 2019, 31(8): 1391-1402. DOI: 10.3724/SP. J. 1089. 2019.17558.
- GUI Yan, GUO Lin, ZENG Guang. Edit propagation using deep neural network from a single image [J]. Journal of Computer-Aided Design & Computer Graphics, 2019, 31(8): 1391-1402. DOI: 10.3724/SP.J.1089.2019.17558.
- [17] 陈立潮, 徐秀芝, 曹建芳, 等. 引入辅助损失的多场景车道线检测[J]. 中国图象图形学报, 2020, 25(9): 1882-1893.
- CHEN Lichao, XU Xiuzhi, CAO Jianfang, et al. Multi-scenario lane line detection with auxiliary loss [J]. Journal of Image and Graphics, 2020, 25(9): 1882-1893.
- [18] HOU Y N, MA Z, LIU C X, et al. Learning lightweight lane detection CNNs by self attention distillation [C]//The Proceedings of 2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul: IEEE, 2020: 1013-1021. DOI: 10.1109/ICCV.2019.00110.
- [19] PAN X G, SHI J P, LUO P, et al. Spatial as deep: spatial CNN for traffic scene understanding [J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2018, 32(1): 1-8. DOI: 10.1609/aaai.v32i1.12301.
- [20] 黄福蓉. 用于实时道路场景的语义分割算法CBRENet [J]. 中国电子科学研究院学报, 2021, 16(3): 277-284. DOI: 10.3969/j.issn.1673-5692.2021.03.011.
- HUANG Furong. Semantic segmentation network CBRENet for real-time road scenes [J]. Journal of China Academy of Electronics and Information Technology, 2021, 16(3): 277-284. DOI: 10.3969/j.issn.1673-5692.2021.03.011.
- [21] QIN Z Q, WANG H Y, LI X. Ultra fast structure-aware deep lane detection [M]//Computer Vision-ECCV 2020. Cham: Springer International Publishing, 2020: 276-291. DOI: 10.1007/978-3-030-58586-0_17.
- [22] 曹宇, 何赏璐, 陈新. 面向人车路环境的视频检测技术应用研究[J]. 交通科学与工程, 2023, 39(3): 98-109. DOI: 10.16544/j.cnki.cn43-1494/u.20210907003.
- CAO Yu, HE Shanglu, CHEN Xin. Human-vehicle-road-environment-oriented study on the application of video detection technology [J]. Journal of Transport Science and Engineering, 2023, 39(3): 98-109. DOI: 10.16544/j.cnki.cn43-1494/u.20210907003.
- [23] 武和全, 刘瑾, 龚创业, 等. 自动驾驶汽车的碰撞安全性研究综述[J]. 长沙理工大学学报(自然科学版), 2023, 20(2): 35-44. DOI: 10.19951/j.cnki.1672-9331.20230115001.
- WU Hequan, LIU Jin, GONG Chuangye, et al. A review of crash safety research on self-driving cars [J].

Lane line detection method based on Fully Connected CRFs

LONG Kejun^{1,2}, GUO Yanhui¹, LIU Yang¹, GUI Yan^{2,3}, WANG Yongfeng⁴, CHEN Wang³

(1. School of Traffic and Transportation Engineering, Changsha University of Science & Technology, Changsha 410114, China; 2. Hunan Key Laboratory of Smart Roadway and Cooperative Vehicle-Infrastructure Systems, Changsha University of Science & Technology, Changsha 410114, China; 3. School of Computer and Communication Engineering, Changsha University of Science & Technology, Changsha 410114, China; 4. Dongfeng USharing Technology Co., Ltd., Wuhan 430058, China)

Abstract: [Purposes] Optimizing the noise area and rough edges in the lane line detection results based on deep learning. [Methods] A new method combining deep learning algorithm and post-processing is proposed. The fully connected conditional random fields (Fully Connected CRFs) is introduced to modify the lane line probability map output by the ENet-SAD algorithm, fit the probability map with the original image to get the lane line detection result. The algorithm in this paper is trained and tested on the self-built data set and the CULane data set. [Findings] The results show that on the self-built data set, the F_1 -score of the algorithm in this paper in four scenarios of normal, strong light, shadow and occlusion were 90.0%, 73.1%, 81.5%, and 76.6%, respectively. On the CULane dataset, the F_1 -score of the algorithm in this paper in conventional scenarios reached 91.0%. [Conclusions] The lane detection algorithm proposed herein demonstrates adaptability to various environmental scenarios, and it is an effective lane line detection algorithm.

Key words: lane line detection; autonomous vehicle; Fully Connected CRFs; ENet-SAD algorithm; self-built dataset; CULane dataset

Manuscript received: 2022-04-19; **revised:** 2022-05-01; **accepted:** 2022-05-08

Foundation item: Project (52172313) supported by the National Natural Science Foundation of China; Project (2020RC4048) supported by Science and Technology Innovation Program of Hunan Province; Project (kh2301004) supported by Major Science and Technology Program of Changsha City

Corresponding author: LONG Kejun (1974—) (ORCID: 0000-0002-5659-9855), male, professor, research interest: transportation planning and management. E-mail: longkejun@csust.edu.cn

(责任编辑:石月珍;校对:刘平;英文编辑:刘至真)