

基于交通环境信息的虚拟车道线拟合方法

朱冰¹, 孟鹏翔¹, 刘斌², 韩嘉懿¹, 赵健¹, 陈志成¹, 宋东鉴¹, 陶晓文¹

(1. 吉林大学汽车底盘集成与仿生全国重点实验室, 长春 130022; 2. 中国第一汽车集团有限公司, 长春 130013)

摘要: 针对车辆行驶道路中部分路段因磨损、冰雪覆盖等引发的车道线缺失问题, 提出了一种基于交通环境信息的虚拟车道线拟合方法。首先, 基于 highD 自然驾驶数据集建立了交通车辆在车道保持状态下的车道线横向偏移概率模型, 以确定虚拟车道线横向位置; 其次, 基于双向长短期记忆网络建立了交通车辆意图识别和轨迹预测模型, 以实现虚拟车道线产生条件判别和形状生成; 最后, 根据上述信息, 将满足拟合条件的交通车车道线横向偏移统计学特征转化为主车坐标系下的虚拟车道线风险场, 以实现虚拟车道线拟合。仿真和实车数据验证结果表明, 该方法能够很好地生成安全、有效的虚拟车道线, 与车道线真值误差较小, 可为主车提供参考行驶空间, 确保行车安全。

关键词: 车辆工程; 虚拟车道线; 交通环境信息; 车道线横向偏移特性; 风险场

中图分类号: U463.6 **文献标志码:** A **文章编号:** 1671-5497(2025)09-2935-11

DOI: 10.13229/j.cnki.jdxbgxb.20240526

Virtual lane lines fitting method based on traffic environment information

ZHU Bing¹, MENG Peng-xiang¹, LIU Bin², HAN Jia-yi¹, ZHAO Jian¹, CHEN Zhi-cheng¹,
SONG Dong-jian¹, TAO Xiao-wen¹

(1. National Key Laboratory of Automotive Chassis Integration and Bionics, Jilin University, Changchun 130022, China;
2. China FAW Group Co., Ltd., Changchun 130013, China)

Abstract: A method for virtual lane lines fitting based on traffic environment information was proposed to address the problem of lane lines missing caused by wear, ice and snow coverage, etc. on certain road sections during vehicle driving. Firstly, a probability model for the lateral offset of lane lines under lane-keeping conditions of traffic vehicles was established based on the highD naturalistic driving dataset to determine the lateral position of virtual lane lines. Then, a traffic vehicle intention recognition and trajectory prediction model based on bi-directional long short-term memory networks was established to realize the condition judgment and shape generation of virtual lane lines generation. Finally, based on the information of the above, the statistical characteristics of lateral lane deviation of traffic vehicles that meet

收稿日期: 2024-05-15.

基金项目: 国家自然科学基金青年基金项目(52302494); 吉林省自然科学基金面上项目(20240101116JC); 中国博士后科学基金面上项目(2023M741339).

作者简介: 朱冰(1982-), 男, 教授, 博士. 研究方向: 汽车智能化技术. E-mail: zhubing@jlu.edu.cn

通信作者: 韩嘉懿(1992-), 男, 在站博士后. 研究方向: 汽车智能化技术. E-mail: jiayi_han@jlu.edu.cn

the fitting conditions were transformed into the risk field of virtual lane lines in the main vehicle coordinate system to realize the virtual lane lines fitting. Simulation and real vehicle data validation results show that this method can generate safe and effective virtual lane lines with a small error compared to the true value of lane lines, providing a reference driving space for the main vehicle and ensuring driving safety.

Key words: vehicle engineering; virtual lane lines; traffic environment information; lateral offset characteristics of lane lines; risk field

0 引言

在自动驾驶系统中,通过传感器识别得到的车道线检测结果通常是系统的重要上层感知输入,但部分行驶路段因磨损、冰雪覆盖等导致车道线缺失,进而可能导致系统功能失效。如何充分利用已知的交通环境信息,拟合出可供自动驾驶系统应用的虚拟车道线,具有重要的现实意义。

针对车道线缺失的问题,现有文献多基于图像的车道线检测方法展开研究。蒋一国^[1]针对车道线常见的磨损、遮挡甚至缺失等情况,提出了一种基于生成对抗网络的车道线检测算法,在提取车道线特征的同时忽略了其他外界环境因素对车道线的干扰,提高了车道线检测的鲁棒性;邓天民等^[2]提出了双分支特征自适应融合的车道线检测方法,以有效应对遮挡、阴影等复杂场景下的车道线检测任务;Tabelini等^[3]在车道线遮挡、缺失或弱显示等情况下引入注意力机制整合全局信息,进而推断车道线的位置。以上方法基于摄像头输入图像的车道线检测解决了车道线部分缺失的问题,而在车道线完全消失的情况下(如车道线完全磨损或被冰雪覆盖的路面),由于摄像头传感器输入信息严重缺失,上述依赖输入图像的方法难以检测出车道线。

此外,有部分方法尝试通过交通环境信息(如道路形状、电子地图等)拟合车道线。John等^[4,5]将基于视觉的多标签深度学习框架与树回归框架相结合,根据提取的道路特征预测车道线,即使在车道线遮挡或不存在的条件下,该算法也能预测给定图像中的车道位置,从而估计缺失的车道线;Wang等^[6]利用电子地图中包含的先验知识,将从中提取的道路形状作为车道模型,提出了一种基于搜索的优化算法,实现了缺少特征下的车道线检测;Yao等^[7]提出了一种基于高精度地图和多传感器融合的车道线检测算法,实现了恶劣路况下的车道线检测。上述基于交通环境信息的方法

依赖于高成本的数据收集和强大的计算能力,且对环境变化敏感,导致实现成本较高。

因此,本文提出了一种基于交通环境信息的虚拟车道线拟合方法,充分挖掘并利用交通环境中丰富的交通车运动信息构建虚拟车道线。首先,基于highD自然驾驶数据集建立交通车辆在车道保持状态下的车道线横向偏移概率模型,以确定虚拟车道线横向位置;其次,基于双向长短期记忆网络(Bi-directional long short-term memory, Bi-LSTM)建立交通车辆意图识别与轨迹预测模型,结合交通车辆在车道保持时获得的历史和预测轨迹,实现虚拟车道线产生条件判别和形状生成;最后,根据上述信息,将满足拟合条件的交通车车道线横向偏移统计学特征转化为主车坐标系下的虚拟车道线风险场,实现虚拟车道线拟合,并进行仿真和实车数据测试验证。该方法能够在车道线短暂消失情况下,充分利用交通环境信息生成可信赖的虚拟车道线,为主车提供可参考行驶空间,使自动驾驶系统持续安全运行,确保行车安全。

1 问题定义和总体框架

本文待解决的问题为:在车道线短暂缺失情况下,如何充分利用交通环境信息,拟合主车视角下可参考和使用的虚拟车道线。本文所述的交通环境信息主要指主车周围交通车的运动学信息^[8-10]。研究的具体场景如图1所示,在单向3车道道路中,车道线存在的正常场景和车道线缺失的异常场景,两种场景中的行驶车辆按位置可划分为两侧车道车辆和中间车道车辆。当车道线缺失时,两侧车道的车辆分别以各自一侧的道路边界(如路缘石、护栏、树木等)为参考进行车道保持运动;而中间车道的车辆与左右两侧道路边界距离均较远,缺少可参考的行驶空间。这种车道线信息的缺失使自动驾驶系统功能失效,甚至面临与两侧交通车碰撞的行车风险。因此,本文将重




图1 研究场景

Fig. 1 Research scenario

点研究主车位于中间车道且左右两侧均有交通车辆场景下的虚拟车道线拟合问题。定义主车为EV,其左右两侧的交通车辆为 LV_i 和 $RV_j(i, j=1, 2, \dots, n)$ 。在 t 时刻,主车观察到的左侧 i 辆和右侧 j 辆交通车辆分别由主车坐标系中的相对运动学特征 $E_i^{(t)}$ 和 $E_j^{(t)}$ 表示,即:

$$E_i^{(t)} = (\Delta x_i^{(t)}, \Delta y_i^{(t)}, \Delta v_{x,i}^{(t)}, \Delta v_{y,i}^{(t)}) \quad (1)$$

$$E_j^{(t)} = (\Delta x_j^{(t)}, \Delta y_j^{(t)}, \Delta v_{x,j}^{(t)}, \Delta v_{y,j}^{(t)}) \quad (2)$$

式中: $\Delta x_i^{(t)}$ 、 $\Delta x_j^{(t)}$ 分别为左、右侧交通车相对纵向坐标; $\Delta y_i^{(t)}$ 、 $\Delta y_j^{(t)}$ 分别为左、右侧交通车相对侧向坐标; $\Delta v_{x,i}^{(t)}$ 、 $\Delta v_{x,j}^{(t)}$ 分别为左、右侧交通车相对纵向速度; $\Delta v_{y,i}^{(t)}$ 、 $\Delta v_{y,j}^{(t)}$ 分别为左、右侧交通车相对侧向速度。

主车从时刻1到 T_{obs} 观察到的左、右两侧交通车辆 i, j 的特征 $X_i^{(T_{\text{obs}})}$ 和 $X_j^{(T_{\text{obs}})}$,包含相对运动学特征 $E_i^{(t)}$ 和 $E_j^{(t)}$ 等,即:

$$X_i^{(T_{\text{obs}})} = [E_i^{(1)}, E_i^{(2)}, \dots, E_i^{(T_{\text{obs}})}]^T \quad (3)$$

$$X_j^{(T_{\text{obs}})} = [E_j^{(1)}, E_j^{(2)}, \dots, E_j^{(T_{\text{obs}})}]^T \quad (4)$$

通过观察 $X_i^{(T_{\text{obs}})}$ 和 $X_j^{(T_{\text{obs}})}$,虚拟车道线拟合方法将输出 T_{obs} 时刻的主车坐标系下左右侧虚拟车道线表达式,即:

$$y_l^{(T_{\text{obs}})} = c_{2,l} \cdot x^2 + c_{1,l} \cdot x + c_{0,l} \quad (5)$$

$$y_r^{(T_{\text{obs}})} = c_{2,r} \cdot x^2 + c_{1,r} \cdot x + c_{0,r} \quad (6)$$

式中: $y_l^{(T_{\text{obs}})}$ 、 $y_r^{(T_{\text{obs}})}$ 分别为左、右侧虚拟车道线在主车坐标系中的横坐标; x 为纵坐标; $c_{2,l}$ 、 $c_{1,l}$ 、 $c_{0,l}$ 、 $c_{2,r}$ 、 $c_{1,r}$ 和 $c_{0,r}$ 分别为左、右侧虚拟车道线拟合表达

式中的二次项系数、一次项系数和常数项系数。

为实现上述过程,需要解决若干问题。首先,虚拟车道线的产生条件取决于交通车辆的行驶意图,若两侧车辆存在换道意图并实施换道行为切入中间车道,则其换道后的相对运动学信息会影响虚拟车道线的拟合,因此需要及时识别交通车辆的行驶类别,将其从虚拟车道线拟合方法的输入中剔除。其次,对于虚拟车道线的横向位置,两侧交通车辆即使处于车道保持状态,其横向位移也会不断变化,相当于在有车道线条件下,车辆沿车道中心线发生左右偏移,因此需要通过大量数据分析统计其横向偏移特征,借助概率模型表征车辆与车道线的横向距离关系。最后,关于虚拟车道线的形状,由于其信息来源本身不确定性大,将其拟合为固定的表达式过于单一和武断;而通过风险场表征方式,使其具有一定的概率置信区间,可使其在后续决策中具有更合理的参考性。在建立风险场的过程中,通过轨迹预测的方式预测未来一段时间的交通车辆行驶轨迹,可为建立更合理的风险场提供支持。

图2为本文方法整体框架。首先,基于highD自然驾驶数据集建立交通车辆在车道保持状态下的车道线横向偏移概率模型,以确定虚拟车道线横向位置;其次,基于Bi-LSTM建立交通车辆意图识别与轨迹预测模型,以实现虚拟车道线产生条件判别与形状生成;最后,根据上述信息,将满足拟合条件的交通车车道线横向偏移统计学特征转化为主车坐标系下的虚拟车道线风险场,以实现虚拟车道线拟合。




图2 本文方法整体框架

Fig. 2 Overall framework of proposed method

2 基于统计特征的虚拟车道线横向位置分析

2.1 数据预处理

本文基于 highD 数据集对交通车辆横向偏移特征进行分析。该数据集是由德国亚琛工业大学汽车工程研究所制作的开源数据集,以鸟瞰视角在德国高速公路上选取约 420 m 的路段,从中提取车辆的轨迹特征信息。

本文筛选了该数据集中单向 3 车道两侧车道车辆的轨迹数据。为了充分体现车辆的横向偏移特性,选取行驶距离大于 400 m 且始终在单一车道做车道保持运动的车辆,提取其 bounding box 宽度(约等于车宽),计算并分析车辆边缘与道路内侧车道线的偏移距离。考虑到两侧车辆左右侧道路边界和交通车的位置反对称,且由于驾驶室位置使驾驶人视野相对左右两侧车道线距离不对称,同时道路最左侧栅栏和最右侧应急车道为车辆行驶提供了一定的限制或缓冲空间,推测以上因素可能一定程度上影响车辆与车道中心线的距离,即车辆与左右两侧车道线的距离一致性,因此有必要对左、右侧车辆分别展开研究,以确认其是否服从不同分布。由于车道中心线是虚拟的,驾驶人会根据两侧实际车道线形成的可行驶区域调整行驶轨迹,这意味着驾驶人基于车辆边缘与车道线的偏移距离进行车道保持行为^[11]。

为了提高数据的准确性,本文剔除了处于换道过程中的车辆轨迹数据,最终获得两侧交通车辆的行驶轨迹偏移数据,即车身在道路内侧方向与道路中间车道线的距离。将每条轨迹的每个采样点的相对车道线横向偏移作为一个样本,统计数据集中所有样本。

2.2 相对车道线横向偏移特性分析

考虑到车辆宽度差异对横向偏移特征的影响,将数据中的车辆宽度划分为 7 个区间,分别为 <1.8 m、1.8~1.9 m、1.9~2.0 m、2.0~2.1 m、2.1~2.2 m、2.2~2.3 m 和 >2.3 m,各个区间的样本量如表 1 所示。

对车辆宽度进行统计分析并绘制了如图 3 所示的概率密度分布,通过左右分布的形状差异推测左侧与右侧的分布不同。左侧交通车辆相对车道线的横向偏移数据接近偏态分布(韦布尔分布),其平均值和数据有向左偏移的趋势;右侧数据则左右对称,接近正态分布。采用 K-S 检验

(Kolmogorov-smirnov test)检验分布情况。K-S 检验是一种基于累计分布函数的非参数检验方法,用于检验 2 个经验分布是否不同,或一个经验分布与某个理想分布是否不同。计算结果显示,不同宽度的左右两侧交通车辆分布无显著性差异的可能性 p 值均接近于 0,远远小于显著性水平 0.05,证明两侧分布具有显著性差异,属于不同的分布。

表 1 样本量统计

Table 1 Sample size statistics

车宽/m	左侧交通车辆样本量	右侧交通车辆样本量
<1.8	881 213	406 644
1.8~1.9	2 739 963	884 933
1.9~2.0	3 219 259	773 928
2.0~2.1	1 777 115	384 604
2.1~2.2	551 579	205 403
2.2~2.3	203 123	144 733
>2.3	138 415	5 728 230

借助最大似然估计分别拟合两类函数。对于左侧交通车辆,使用韦布尔分布进行拟合,即:

$$f(x_r|\lambda, k) = \begin{cases} \frac{k}{\lambda} \left(\frac{x_r}{\lambda}\right)^{k-1} e^{-(x_r/\lambda)^k}, & x_r \geq 0 \\ 0, & x_r < 0 \end{cases} \quad (7)$$

式中: x_r 为交通车辆相对车道线横向偏移量的随机变量,绝大多数情况下为正值; λ 为比例参数; k 为形状参数。

进一步依据拟合的两参数得出:

$$E_L = \lambda \Gamma\left(1 + \frac{1}{k}\right) \quad (8)$$

$$\text{Var}_L = \lambda^2 \left[\Gamma\left(1 + \frac{2}{k}\right) - \Gamma\left(1 + \frac{1}{k}\right)^2 \right] \quad (9)$$

式中: E_L 和 Var_L 分别为韦布尔分布的均值和方差; Γ 为伽马(gamma)函数。

Γ 在实数域上的定义为:

$$\Gamma(x) = \int_0^{+\infty} t^{x-1} e^{-t} dt, \quad x > 0 \quad (10)$$

由于韦布尔分布仅在取值大于 0 时才有意义,而本文数据中左侧交通车辆相对车道线横向偏移存在小于 0 的情况,因此先将整体数据向正方向平移 c 个位移长度,使所有数据均大于 0,拟合分布后再平移回原位,即:

$$\begin{cases} f(x_r|\lambda, k) = \frac{k}{\lambda} \left(\frac{x_r - c}{\lambda}\right)^{k-1} e^{-(x_r/\lambda)^k} \\ x_r + c \geq 0 \end{cases} \quad (11)$$

为满足式(11),要求 c 大于样本数据中的最




图3 左右侧相对车道线横向偏移概率密度分布

Fig.3 Probability density distribution of lateral deviation of left and right relative lane lines

小相对车道线横向偏移量。

相应地,分布均值为:

$$E_L = \lambda \Gamma \left(1 + \frac{1}{k} \right) - c \tag{12}$$

对于右侧交通车辆,使用正态分布进行拟

合,即:

$$f(x_r|\mu_R, \sigma_R) = \frac{1}{\sqrt{2\pi} \sigma_R} \exp \left(-\frac{(x_r - \mu_R)^2}{2\sigma_R^2} \right) \tag{13}$$

式中: μ_R 和 σ_R^2 分别为正态分布的均值和方差。

左、右侧分布参数如表2所示,所得分布参数将用于后续算法输入。

表2 分布参数

车宽/m	左侧(韦布尔分布)		右侧(正态分布)	
	均值/m	方差/m ²	均值/m	方差/m ²
<1.8	1.300 2	0.153 7	1.308 5	0.381 0
1.8~1.9	1.201 5	0.151 6	1.225 9	0.382 6
1.9~2.0	1.101 5	0.151 5	1.188 8	0.382 7
2.0~2.1	1.014 2	0.160 6	1.143 4	0.374 1
2.1~2.2	0.930 9	0.153 1	1.096 8	0.369 1
2.2~2.3	0.879 4	0.169 1	1.081 8	0.378 2
>2.3	0.795 7	0.208 8	0.955 0	0.334 2

结合图3和表2分析可知,同一车宽下,左侧交通车辆相对车道线横向偏移比右侧具有更小的均值和最小值,中位数和众数也更小,即数据更靠近中间车道的车道线。这一方面是因为驾驶室在车辆左前侧,驾驶人对左右侧视野的感知程度不同,导致其对左右侧车道线距离的判断存在差异,进而在一定程度上影响车辆左右侧偏移程度;另一方面,数据集中的单向3车道道路最左侧为护栏,存在碰撞风险,使左侧交通车辆更靠近中间车道,而最右侧为应急车道,无碰撞风险,右侧交通车辆的预期驾驶区域不受限制,因此其相对车道线横向偏移偏大。这一情况在城市道路和高速公路中也很常见,具有一定的普适性。这也印证了对两侧车辆采用不同分布描述概率密度的合理性。此外,两侧交通车辆均值随车宽而递减,这符合“车身越大,行驶时与车道线距离越近”的认知,但其与中间车道车辆的碰撞风险随之增加。

3 基于Bi-LSTM的虚拟车道线产生条件判别和形状生成

上述对两侧交通车辆相对车道线横向偏移分布参数的分析建立在其行驶意图不变的基础上,当交通车辆行驶意图发生改变,即产生换道驾驶行为时,其轨迹的横向偏移参数不再为主车提供参考依据。因此,在主车行驶过程中,有必要对交通车辆的行驶类别进行实时识别。当其行驶意图为车道

保持时,可为主车提供参考交通信息;当其将要切入换道时,主车应提前识别并结束对其交通信息的参考。在此基础上,两侧交通车辆在车道保持行为下的行驶轨迹与实际车道线存在一定的映射关系,因此其历史轨迹可用于构建虚拟车道线的形状;同时,其未来轨迹与未来车道线同样存在一定的映射关系,通过交通车辆轨迹预测方法获得的预测轨迹同样可用于构建虚拟车道线的形状。本文基于Bi-LSTM实现交通车辆的行驶意图识别(即时间序列分类)和行驶轨迹预测(即时间序列预测),从而建立交通车辆意图识别和轨迹预测模型,最终完成虚拟车道线产生条件判别和形状生成。

Bi-LSTM神经网络结构模型分为2个独立的LSTM网络。输入序列(即交通车辆在不同时间点的位置、速度等时序信息)分别以正序和逆序输入至2个LSTM神经网络进行特征提取,以捕捉从当前时刻向未来和向过去的运动趋势和模式;随后将2个网络输出的特征向量拼接,形成更全面的特征表示。由于Bi-LSTM同时考虑过去和未来的信息,其特征提取效率和性能要优于传统LSTM结构模型。

Bi-LSTM的行驶意图识别神经网络结构和行驶轨迹预测神经网络结构如图4所示。




图4 Bi-LSTM神经网络结构图

Fig. 4 Bi-LSTM neural network structure diagram

图4中,两侧交通车辆的历史运动学信息经归一化层处理后,进入Bi-LSTM网络层和全连接层计算;对于行驶意图识别网络,数据经过Softmax层处理后,通过分类输出层输出行驶意图结果,本文将左侧和右侧交通车辆的行驶意图

统一描述为车道保持行为和切入行为,结果分别为0和1;对于行驶轨迹预测网络,数据经过回归输出层处理后,对输出结果进行反归一化,即可获得预测位置坐标。

网络结构训练的数据同样提取自highD数据集,筛选行驶时长大于10 s的道路中心车辆,且其前方两侧车道存在交通车辆的轨迹对。其中,交通车辆发生切入行为的轨迹对记为切入轨迹对,进行车道保持行为的轨迹对记为车道保持轨迹对。在切入轨迹对中,交通车辆在时刻 t 处于车道ID变换点(记为换道点),若提取的轨迹片段最后一个时间节点落在 $[t-3.2, t+3.2]$ 内,则该轨迹片段记为切入片段,否则为车道保持片段;将车道保持片段与前述切入轨迹对混合,最终形成了交通车辆切入片段和车道保持片段。原数据集采样频率为25 Hz(0.04 s),经间隔采样后为5 Hz(0.2 s);取2 s为一个片段,通过滑动窗口的方式以0.4 s时间步移动来最大限度利用数据。由于行驶轨迹预测是为虚拟车道线拟合提供参考,因此只需采用车道保持片段的数据进行训练以预测车道保持轨迹中的未来位置,取3.2 s为一个片段,将前2 s的数据作为历史轨迹数据,后1.2 s的数据作为未来轨迹数据。

测试结果表明,车道保持、切入和总体的识别准确率分别为98.73%、97.72%、98.19%;左、右侧交通的行驶轨迹预测均方根误差(Root mean square error, RMSE)分别为0.183 5和0.196 1。本文只需识别车道保持结果即可用于虚拟车道线拟合。可以看出,车道保持识别的准确率为98.73%,实现了较高的交通车辆识别,用于虚拟车道线产生条件判别;行驶轨迹预测的RMSE较小,由于交通车辆处于车道保持行驶状态,预测位置点大致围绕其行驶轨迹分布,用于后续虚拟车道线拟合的形状生成。

4 基于风险场的虚拟车道线拟合

获得虚拟车道线的产生条件判别、横向位置和形状后,本节进一步基于风险场拟合虚拟车道线^[12-16]。主车在道路中间车道行驶过程中,当某一侧有交通车辆时,根据其历史行驶轨迹的相对运动学信息,通过虚拟车道线产生条件判别模块识别其驾驶行为为车道保持行为后,结合其车道方向和车宽,借助横向位置拟合模块输出对应的相对车道线横向偏移分布。该分布沿交通车辆与

主车接近的车身边缘向主车延伸,虚拟车道线形状生成模块将交通车辆行驶轨迹预测的未来轨迹和历史轨迹的各个横向位置点组成一个序列,建立轨迹高斯分布,即:

$$\Delta Y = (\Delta y_i^{(t-k)}, \dots, \Delta y_i^{(t)}, \dots, \Delta y_i^{(t+m)}) \quad (14)$$

其分布为:

$$f(\Delta y_L | E_{\Delta y_L}, \sigma_{\Delta y_L}) = \frac{1}{\sqrt{2\pi} \sigma_{\Delta y_L}} \exp\left(-\frac{(\Delta y_L - E_{\Delta y_L})^2}{2\sigma_{\Delta y_L}^2}\right) \quad (15)$$

$$f(\Delta y_R | E_{\Delta y_R}, \sigma_{\Delta y_R}) = \frac{1}{\sqrt{2\pi} \sigma_{\Delta y_R}} \exp\left(-\frac{(\Delta y_R - E_{\Delta y_R})^2}{2\sigma_{\Delta y_R}^2}\right) \quad (16)$$

式中: $E_{\Delta y_L}$ 、 $E_{\Delta y_R}$ 分别为左、右侧轨迹高斯分布的均值; $\sigma_{\Delta y_L}^2$ 、 $\sigma_{\Delta y_R}^2$ 分别为左、右侧轨迹高斯分布的方差。

在上述相对车道线左、右侧横向偏移分布的均值中心处,取左右一定范围的 r_L 和 r_R ,形成车道带。为避免车道带宽度过大或过小而失去意义,取方差倍数和设定值的最大值为车道带值,即:

$$r_L = \max(3\sigma_{\Delta y_L}, 0.2) \quad (17)$$

$$r_R = \max(3\sigma_{\Delta y_R}, 0.2) \quad (18)$$

将左、右侧交通车坐标系下相对车道线横向偏移分布分别转换为主车坐标系下对应车道线分布,并引入场强系数,建立虚拟车道线风险场。此时交通车的横向距离取值为 $\Delta y_i^{(t)}$,由几何距离关系可得:

$$y_{E,1}^{(t)} + w_i/2 + x_r = \Delta y_i^{(t)} \quad (19)$$

式中: $y_{E,1}^{(t)}$ 为主车左侧虚拟车道线风险场的横坐标; w_i 为交通车的宽度。

变换式(19)可得:

$$x_r = -y_{E,1}^{(t)} + \Delta y_i^{(t)} - \frac{w_i}{2} \quad (20)$$

结合前述统计结果可得:

$$f(x_r | \mu_R, \sigma_R) = \frac{1}{\sqrt{2\pi} \sigma_R} \exp\left(-\frac{(x_r - \mu_R)^2}{2\sigma_R^2}\right) \quad (21)$$

将式(20)代入式(21)可得:

$$f(-y_{E,1}^{(t)} + \Delta y_i^{(t)} - \frac{w_i}{2}) = \frac{1}{\sqrt{2\pi} \sigma_R} \exp\left(-\frac{\left(-y_{E,1}^{(t)} + \Delta y_i^{(t)} - \frac{w_i}{2} - \mu_R\right)^2}{2\sigma_R^2}\right) \quad (22)$$

进一步整理得:

$$f(y_{E,1}^{(t)} - \Delta y_i^{(t)} + w_i/2) = \frac{1}{\sqrt{2\pi} \sigma_R} \exp\left(-\frac{(y_{E,1}^{(t)} - \Delta y_i^{(t)} + w_i/2 - \mu_R)^2}{2\sigma_R^2}\right) \quad (23)$$

引入场强系数并沿主车前进方向 x 轴延展,最终可得:

$$E(x_{E,1}^{(t)}, y_{E,1}^{(t)}) = \frac{E_K}{\sqrt{2\pi} \sigma_R} \exp\left(-\frac{(y_{E,1}^{(t)} - \Delta y_i^{(t)} + w_i/2 - \mu_R)^2}{2\sigma_R^2}\right) \quad (24)$$

式中: E_K 为虚拟车道线风险场场强系数。

以上为主车对应的左侧虚拟车道线风险场。同理,对于主车对应的右侧虚拟车道线风险场,由几何距离关系可得:

$$y_{E,r}^{(t)} + \frac{w_i}{2} + x_r = \Delta y_i^{(t)} \quad (25)$$

变换式(25)可得:

$$x_r = -y_{E,r}^{(t)} + \Delta y_i^{(t)} - \frac{w_i}{2} \quad (26)$$

结合前述统计结果可得:

$$\begin{cases} f(-y_{E,r}^{(t)} + \Delta y_i^{(t)} - \frac{w_i}{2} - c | \lambda, k) = \\ \frac{k}{\lambda} \left(\frac{-y_{E,r}^{(t)} + \Delta y_i^{(t)} - \frac{w_i}{2} - c}{\lambda} \right)^{k-1} \cdot \\ e^{-\left(-y_{E,r}^{(t)} + \Delta y_i^{(t)} - \frac{w_i}{2}\right) \frac{c}{\lambda}} \\ -y_{E,r}^{(t)} + \Delta y_i^{(t)} - \frac{w_i}{2} + c \geq 0 \end{cases} \quad (27)$$

整理式(27)并引入场强系数可得:

$$\begin{cases} E(x_{E,r}^{(t)}, y_{E,r}^{(t)}) = \frac{E_K \cdot k}{\lambda} \left(\frac{y_{E,r}^{(t)} + \Delta y_i^{(t)} - \frac{w_i}{2} - c}{\lambda} \right)^{k-1} \cdot \\ e^{-\left(y_{E,r}^{(t)} + \Delta y_i^{(t)} - \frac{w_i}{2}\right) \frac{c}{\lambda}} \\ y_{E,r}^{(t)} \leq \Delta y_i^{(t)} - w_i/2 + c \end{cases} \quad (28)$$

式(24)(28)形成了两侧虚拟车道线风险场,场强最高处为虚拟车道线的唯一值,由车道带值向两侧延展形成虚拟车道带,可提高虚拟车道线拟合的容错性。

当一侧车道有多辆交通车辆时,对于相对车道线的横向偏移,为了尽可能保证安全,采取较为保守的策略选取,即通过计算位移点减去车宽的

距离,取最小值对应的车宽分布作为虚拟车道线横向偏移分布,即:


$$n = \arg \min (\Delta y_i^{(i)} - w_i) \quad (29)$$

$$i = 1, 2, 3, \dots, n$$


式中: n 为最终选取的交通车辆编号 ID。

当一侧车道无交通车辆时,该侧的车道线可由另一侧虚拟车道线位置减去车道宽度得到。车道宽度可以通过主车在该路段车道线存在的场景下行驶时通过传感器输出结果计算,也可根据道路车道宽度标准,取标准值 3.75 m。

通过以上步骤,将交通车坐标系下的相对车道线横向偏移统计学特征转换为主车坐标系下的虚拟车道线风险场。图 5 为某交通场景示意图和对应的虚拟车道线风险场 3D 图,从图 5 中可以直观看出,主车基于左、右两侧交通车拟合出了虚拟车道线风险场,其范围基本覆盖了真实车道线,为主车提供了安全、有效的行车参考空间。



(a) 交通场景示意图



(b) 风险场 3D 图

图 5 风险场示意图


Fig. 5 Risk field diagram

5 仿真与实车数据验证


5.1 仿真试验验证

本文分别通过仿真试验和实车数据验证所提算法的可行性。在仿真试验中,本文随机选取了数据集中某次工况进行测试验证,如图 6 所示,分别包括交通场景轨迹、纵侧向相对位移算法的中间输出结果和最终输出结果。


在该工况中,主车位于道路中间车道进行车道保持行驶,其前方左、右侧各有一辆交通车分别




(a) 交通场景轨迹




(b) 纵向相对位移




(c) 侧向相对位移




(d) 意图识别结果



(e) 轨迹预测结果



(f) 试验结果



(g) 某时刻试验结果

图 6 仿真试验

Fig. 6 Simulation experiment

沿道路边界行驶。以一定时间步长提取当前时刻及历史时段交通车相较于主车的相对运动学信息,输入算法模块后,输出此时主车周围的虚拟车道线风险场信息,并拟合虚拟车道线,最后将测试结果与真实车道线结果进行比较。

由图6可以看出,主车及两侧交通车均做车道保持运动,且两侧交通车无换道意图。在没有车道线信息输入的情况下,虚拟车道线拟合算法模块有效地预测了两侧交通车的车道保持意图和侧向相对位移轨迹,最终结合其相对运动学信息和车道偏离统计学信息,拟合出虚拟车道线风险场,输出虚拟车道线及虚拟车道线带。相较于真实车道线,虚拟车道线平均误差为0.189 0 m,虚拟车道线带平均误差为0.081 4 m,虚拟车道线最大误差为0.398 8 m,虚拟车道线带最大误差为0.216 7 m,在一定误差允许范围内符合要求,构成了主车可参考行驶空间,确保了行车安全。

5.2 实车数据验证

在实车数据验证试验中,本文搭建的实车试验平台架构如图7所示。主车上搭载了地平线摄像头及其控制器、基于dSPACE平台的MicroAutoBox和对应的2台上位机,通过2辆交通车及车道线缺失的3车道路面构建试验场景。试验原理简述如下:通过上位机1,将基于Matlab/Simulink编写的虚拟车道线拟合算法编译为SDF文件,并下载到原型控制器MicroAutoBox中;上位机1与MicroAutoBox通过Ethernet网线连接,地平线摄像头将输入图像通过Ethernet网线输入至上位机2进行观察和保存,同时将识别图像输出的交通车运动学信息通过CAN线传入MicroAu-




图7 实车试验平台架构

Fig. 7 Real vehicle testing platform architecture

toBox中,作为虚拟车道线拟合算法的输入;虚拟车道线拟合算法在MicroAutoBox中实时运行并生成输出结果,显示并实时保存在上位机1中;结合上位机1的算法输出结果与上位机2的图像进行分析,判断算法的准确性。

试验场景如图8所示,在车道线缺失的3车道路路上,主车在道路中心行驶,两辆交通车分别在道路左右两侧行驶,主车与交通车保持5~50 m的同向行驶距离,允许主车方向盘与主车横向位移、交通车方向盘与交通车横向位移有一定抖动,车辆同向行驶50~100 m。由于道路中车道线磨损导致缺少车道线真值,因此以道路宽度三等分值作为车道线真值。参考车道线真值,以时间作为横坐标,绘制主车与交通车的相对位移关系和试验数据结果,进而观察、记录和分析虚拟车道线拟合算法输出的结果及误差。由于实车数据验证在车道线缺失的实际道路上进行,车道线完全消失且不可见,可以预测基于图像车道线检测方法在此场景下将无法有效识别车道线。为此,本文采用基于交通环境信息中道路形状拟合车道线的方法,将传感器获得的道路信息按照已知道路宽度进行平移,作为拟合车道线结果,与本文方法进行对比。



(a)试验场景实车图



(b)试验场景示意图

图8 试验场景

Fig. 8 Experimental scenario

实车数据验证结果如图9所示,与车道线真值相比,车道线平均误差为0.216 0 m,虚拟车道线带平均误差为0.093 1 m,虚拟车道线最大误差为




图9 实车数据验证结果

Fig. 9 Validation results of real vehicle data

0.398 8 m, 虚拟车道线带最大误差为 0.278 5 m。上述误差均小于工程应用中车道线拟合常参考的最大误差 0.4 m, 在误差允许范围内, 且优于已有方法, 为主车构建了可参考的行驶空间。

6 结束语

本文提出了一种基于交通环境信息的虚拟车道线拟合方法, 通过充分挖掘和利用交通环境中丰富的交通车运动信息构建虚拟车道线。其中, 虚拟车道线的横向位置基于建立的车道线横向偏移概率模型确定, 产生条件判别和形状生成则通过交通车辆意图识别与轨迹预测模型, 结合交通

车辆在车道保持时的历史与预测轨迹实现, 最终表达式的拟合融入了风险场理论。试验结果表明, 本文方法在车道线短暂消失情况下, 能够充分利用交通环境信息生成可信赖的虚拟车道线, 为主车提供可参考行驶空间, 使自动驾驶系统持续安全运行, 确保行车安全。

参考文献:

- [1] 蒋一国. 基于 GAN 的车道线检测算法研究[D]. 长春: 吉林大学计算机科学与技术学院, 2020.
Jiang Yi-guo. Research on lane detection based on GAN[D]. Changchun: College of Computer Science and Technology, Jilin University, 2020.
- [2] 邓天民, 谢鹏飞, 余洋, 等. 双分支特征自适应融合的车道线检测方法[J/OL]. [2024-05-03]. <https://doi.org/10.13229/j.cnki.jdxbgxb.20240397>
Deng Tian-min, Xie Peng-fei, Yu Yang, et al. Method of lane detection based on adaptive fusion of double branch features[J/OL]. [2024-05-03]. <https://doi.org/10.13229/j.cnki.jdxbgxb.20240397>
- [3] Tabelini L, Berriel R, Paixao T M, et al. Keep your eyes on the lane: Real-time attention-guided lane detection[J/OL]. [2024-05-03] <https://doi.org/10.1109/CVPR46437.2021.00036>
- [4] John V, Karunakaran N M, Guo C Z, et al. Free space, visible and missing lane marker estimation using the PsiNet and extra trees regression[C]//2018 24th International Conference on Pattern Recognition, Beijing, China, 2018: 189-194.
- [5] John V, Liu Z, Guo C Z, et al. Real-time lane estimation using deep features and extra trees regression[M]. Cham: Springer International Publishing, 2015.
- [6] Wang X L, Qian Y Q, Wang C X, et al. Map-enhanced ego-lane detection in the missing feature scenarios[J]. IEEE Access, 2020, 8: 107958-107968.
- [7] Yao H C, Chen C, Liu S D, et al. Lane marking detection algorithm based on high-precision map and multisensor fusion[J]. Concurrency and Computation: Practice and Experience, 2022, 34(8): No. e5797.
- [8] 齐春阳. 融合交通环境信息的混合动力汽车能量管理策略研究[D]. 长春: 吉林大学汽车工程学院, 2023.
Qi Chun-yang. Research on energy management strategy for hybrid electric vehicle with incorporation of traffic information[D]. Changchun: College of Automotive Engineering, Jilin University, 2023.
- [9] 王如月. 基于交通信息的汽车制动动力学研究[D].

- 北京:清华大学车辆与运载学院, 2021.
- Wang Ru-yue. Research on vehicle braking dynamics based on traffic information[D]. Beijing: School of Vehicle and Mobility, Tsinghua University, 2021.
- [10] Zhang Y, Zhang G. Research on the cooperative car-following behavior based on traffic information iteration[J]. International Journal of Modern Physics C, 2023, 34(1): 1-12.
- [11] Ding J Y, Wang J Q, Liu C C, et al. Driver steering behavior model based on lane-keeping characteristics analysis[C]//17th international IEEE conference on intelligent transportation systems (ITSC), Qingdao, China, 2014: 623-628.
- [12] Tian Y, Pei H X, Yang J X, et al. An improved model of driving risk field for connected and automated vehicles[C]//2021 IEEE International Intelligent Transportation Systems Conference (ITSC), Indianapolis, USA, 2021: 285-291.
- [13] 何仁, 赵晓聪, 杨奕彬, 等. 基于驾驶人风险响应机制的人机共驾模型[J]. 吉林大学学报: 工学版, 2021, 51(3): 799-809.
- He Ren, Zhao Xiao-cong, Yang Yi-bin, et al. Man-machine shared driving model using risk-response[J]. Journal of Jilin University (Engineering and Technology Edition), 2021, 51(3): 799-809.
- [14] Song X, Sun Y, Tao P. A dynamic Bayesian network model for real-time risk propagation of secondary rear-end collision accident using driving risk field [J]. IEEE Access, 2022, 10: 72429-72443.
- [15] Ma Y L, Dong F Q, Yin B Q, et al. Real-time risk assessment model for multi-vehicle interaction of connected and autonomous vehicles in weaving area based on risk potential field[J]. Physica A, 2023, 620: No. 128725.
- [16] Li L H, Gan J, Yi Z, et al. Risk perception and the warning strategy based on safety potential field theory [J]. Accident Analysis and Prevention, 2020, 148: No. 105805.