

doi: 10.11835/j.issn.1000-582X.2023.111

基于高速公路场景的换道驾驶行为研究

杨崇辉¹, 郑玲¹, 左益芳¹, 王勘², 曾杰², 丁雪聪²

(1. 重庆大学机械传动国家重点实验室, 重庆 400044; 2. 招商局检测车辆技术研究院有限公司, 重庆 400067)

摘要: 深入研究人类驾驶员的驾驶行为和习性, 对于推进智能汽车的拟人化决策规划, 改善驾驶安全性具有重要意义。针对高速公路这一典型场景, 基于NGSIM (Next Generation Simulation) 数据集提取有效表征换道驾驶行为的特征参数, 分析换道驾驶行为与驾驶参数的相关性, 量化驾驶行为特性, 建立了基于高斯混合-隐马尔科夫理论 (Gaussian mixed model-hidden Markov model, GMM-HMM) 的换道意图识别模型。研究表明: 该模型识别准确率较高, 在换道点 1.0 s 之前的换道行为识别准确率达到 95.6%, 在有换道意图的时刻识别准确率超过 80%, 可应用于智能汽车换道策略的拟人化设计, 有效降低换道风险, 改善驾驶安全。

关键词: 驾驶员特性; 换道行为分析; NGSIM; 驾驶安全

中图分类号: U448.213

文献标志码: A

文章编号: 1000-582X(2024)11-037-14

Highway lane-changing behavior: a data-driven analysis of driver intentions

YANG Chonghui¹, ZHENG Ling¹, ZUO Yifang¹, WANG Kan², ZENG Jie², DING Xuecong²

(1. State Key Laboratory of Mechanical Transmissions, Chongqing University, Chongqing 400044, P. R. China;

2. China Merchants Testing Vehicle Technology Research Institute Co., Ltd., Chongqing 400067, P. R. China)

Abstract: Understanding human driving behaviors has significant implications for promoting decision-making in intelligent vehicles and improving driving safety. This study focuses on highway lane-changing behavior, using the NGSIM (Next Generation Simulation) Dataset to extract key parameters and analyze the correlation between these parameters and driving behaviors. A GMM-HMM-based model for lane-changing intention recognition was developed, achieving an accuracy of 95.6% in predicting lane changes 1.0 s before they occur, and an accuracy of over 80% in recognizing lane-changing intentions. This model can be applied to intelligent vehicle design to effectively reduce lane-changing risks and improve driving safety.

Keywords: driver characteristics; lane-changing behavior analysis; NGSIM (Next Generation Simulation); driving safety

车辆换道是驾驶过程中广泛存在的一种行为, 不当的换道行为往往会导致车辆发生追尾和碰撞事故, 严重威胁人们的生命财产安全。因此, 对车辆换道行为进行分析并准确识别车辆换道意图, 对减少交通事故、

收稿日期: 2023-02-13 网络出版日期: 2023-06-20

基金项目: 国家自然科学基金资助项目 (51875061)。

Supported by National Natural Science Foundation of China (51875061).

作者简介: 杨崇辉 (1999—), 男, 硕士研究生, 主要从事汽车主动安全技术研究, (E-mail) 20162255@cqu.edu.cn。

通信作者: 郑玲, 女, 教授, 博士生导师, (E-mail) zling@cqu.edu.cn。

提高行车效率具有极为重要的意义^[1]。Tomar等^[2]通过采集车辆位置坐标、车速等参数分析车辆换道行为,认为车辆换道轨迹与周围驾驶员的习惯和自车驾驶员对周围交通状况的评估有关。Nilsson等^[3]通过计算车辆的横纵向运动线路,基于规则设定阈值来识别换道意图。Chauhan等^[4]利用累计横向速度的绝对值来识别换道操作的时间窗口,并对车辆换道行为进行分类。Tran等^[5]将车速、加速度、方向盘转角等参数离散化,输入到隐马尔科夫模型中来识别驾驶员换道策略。Oh等^[6]建立二元逻辑回归模型来研究驾驶员换道行为。

随着机器学习和深度学习的快速发展,一些学者利用贝叶斯网络、支持向量机、深度神经网络等方法进行换道意图识别。邱小平等^[7]利用贝叶斯网络根据周围交通状况,将换道过程中的连续特征变量离散化,建立了车辆换道行为识别模型。Schlechtriemen等^[8]提出了一种基于朴素贝叶斯方法的扩展模型,实现了对换道行为的识别。Zyner等^[9]将车辆位置、航向角和速度等参数输入长短时记忆(long short term memory, LSTM)网络模型,用以识别车辆在交叉路口时驾驶员的意图。Xie等^[10]通过引入深度置信网络(deep belief network, DBN),预测车辆换道决策结果,模型精度较高,但未对影响换道决策的因素进行分析。Kim等^[11]在高级驾驶辅助系统(advanced driving assistance system, ADAS)上,通过ANN(artificial neural network)算法增强车辆状态和路面状况的信息,将增强后的信息反馈到支持向量机(support vector machine, SVM),检测了驾驶员的驾驶换道意图。Ahmed等^[12]基于NGSIM(Next Generation Simulation)数据集研究了不同拥堵水平下驾驶员的换道行为,提出了利用临界交叉时间和单位距离车道变化识别极端换道行为的方法。季学武等^[13]基于NGSIM数据集,考虑交互式信息,提出了基于LSTM网络的驾驶意图识别模型,具有较高的准确率。然而,深度学习算法在模型的可解释性和可靠性方面仍需要进一步提升。

上述研究表明,传统的基于规则的换道驾驶策略大多通过人为定义车辆运行状态参数来表征换道行为,并未深入分析各参数对换道行为的影响规律,导致换道行为识别模型的准确率不高,换道驾驶策略体验较差,影响驾驶安全性。

针对现有基于规则的换道行为识别模型存在的问题,笔者在深入分析驾驶员换道行为基础上,提出一种基于高斯混合-隐马尔科夫理论(Gaussian mixed model-hidden Markov model, GMM-HMM)的换道行为识别模型,以左换道、保持车道、右换道3种行为作为不可观测的隐状态,将驾驶行为表征参数如车辆横向位置偏移和侧向速度作为模型观测层输入参数,采用最大期望算法优化模型参数,考虑驾驶行为的不确定性,利用NGSIM数据集对换道行为识别模型进行验证,为智能汽车换道驾驶策略的研究和开发奠定理论基础和技术支撑。

1 换道场景定义

自动驾驶车辆在多车道道路上行驶时,通过一系列操作从当前车道变更到目标车道的决策行为即属于换道行为。换道行为涉及到多车之间的相互作用,参与的车辆将会对换道意图产生影响,图1为典型的换道场景示意图。对单向双车道而言,目标车道上存在着前车FV(front vehicle)和后车RV(rear vehicle),当前车道上行驶着前车PV(preceding vehicle)以及换道车辆LV(lane-changing vehicle)^[14]。LV在行驶过程中受到前方PV的速度约束,产生换道意图,在换道过程中有一定概率与RV发生碰撞而放弃换道。此类换道行为即是本文的研究对象。




图1 换道场景

Fig. 1 Lane-changing scene

2 数据预处理与特征提取

2.1 数据来源

使用的数据集来源于NGSIM的US-101数据库和I-80数据库^[15](图2),NGSIM数据集是美国联邦公路局为推进微观交通建模方面的研究,在高层建筑上设置多台同步摄像头采集所得,数据采集频率为10 Hz,通过图像处理技术获得车辆位置、速度、加速度等数据信息,2个数据库包括6个15 min采集轨迹子库。为了验证模型在时间和空间上的泛化性,将一个数据库作为训练集,另一个数据库作为测试集。

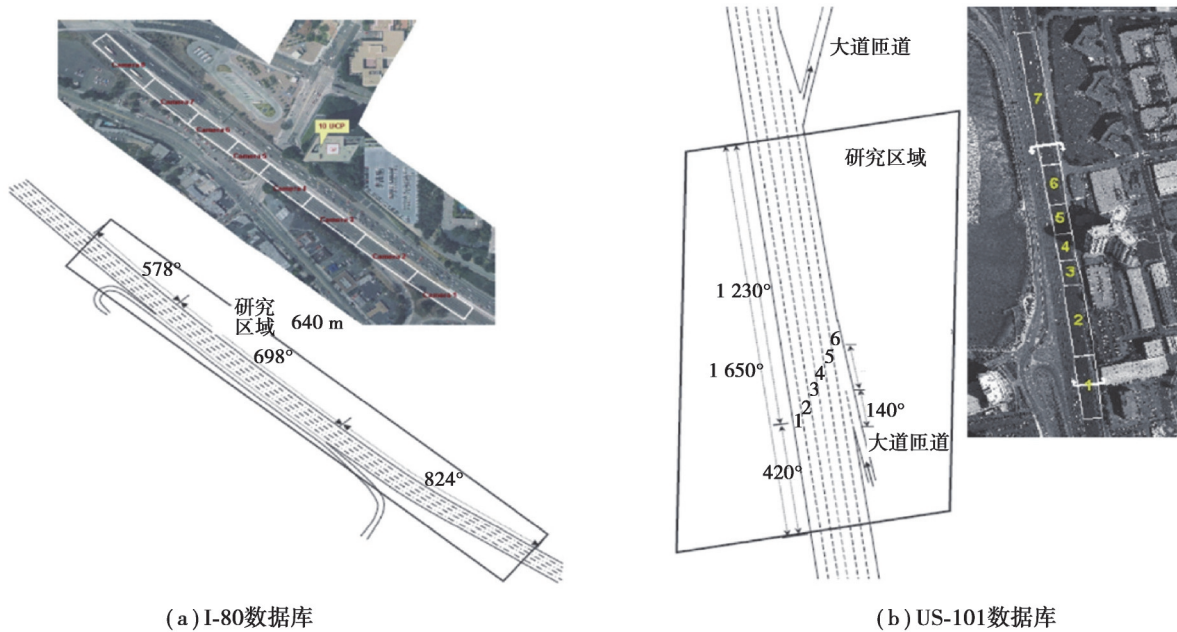


图2 NGSIM数据集^[15]
Fig. 2 NGSIM Dataset^[15]

2.2 数据预处理

由于NGSIM数据集中的数据是通过拍摄视频的方式采集的,并非由车辆传感器直接采集获得,因此,表征车辆运行状态的数据不可避免地出现一定的误差。为了修正原始数据中不符合运动学规律的车辆位置、速度、加速度等相关数据,需要对其进行预处理。

采用Thiemann等^[16]提出的对称指数移动平均滤波算法(symmetric exponential moving average filter, sEMA)对原始数据进行滤波预处理。sEMA是对简单移动平均法的改进,通过将权重函数调整为“人”字形的对称指数函数,距离修正点越近的值权重越大,滤波效果较好。根据Thiemann对平滑宽度的分析,得出平滑位置时取 $T = 0.5\text{ s}$ 、平滑速度时取 $T = 1.0\text{ s}$ 、平滑加速度时取 $T = 4.0\text{ s}$,可实现噪声衰减和原始数据高频部分之间的最佳折中。sEMA算法公式如下:

$$\tilde{y}_j(t_i) = \frac{\sum_{k=i-D}^{i+D} y_j(t_k) e^{-\frac{|i-k|}{\Delta}}}{\sum_{k=i-D}^{i+D} e^{-\frac{|i-k|}{\Delta}}} \quad (1)$$

式中: $i = 1, 2, \dots, N_j$, N_j 是车辆 j 的数据长度; Δ 是平滑宽度, $\Delta = T/dt$, $dt = 0.1\text{ s}$, T 根据拟合参数不同,取值不同; D 是平滑窗口,取值为 $\min\{3\Delta, i-1, N_j-i\}$; $\tilde{y}_j(t_i)$ 是车辆 j 在第 i 个时刻拟合后的新数据; $y_j(t_k)$ 是车辆 j 在第 k 个时刻的原始数据。以US-101中的98号车辆轨迹数据为例,其滤波效果如图3所示。由图3可知,对称指数移动平均滤波能够有效减小加速度中白噪声的影响,使加速度变化更平滑,同时保留了反映驾驶行为的数据特征,并对速度进行了小幅度修正,但对位移数据几乎没有影响,这与用图像采集技术数据的误差特征

相符。

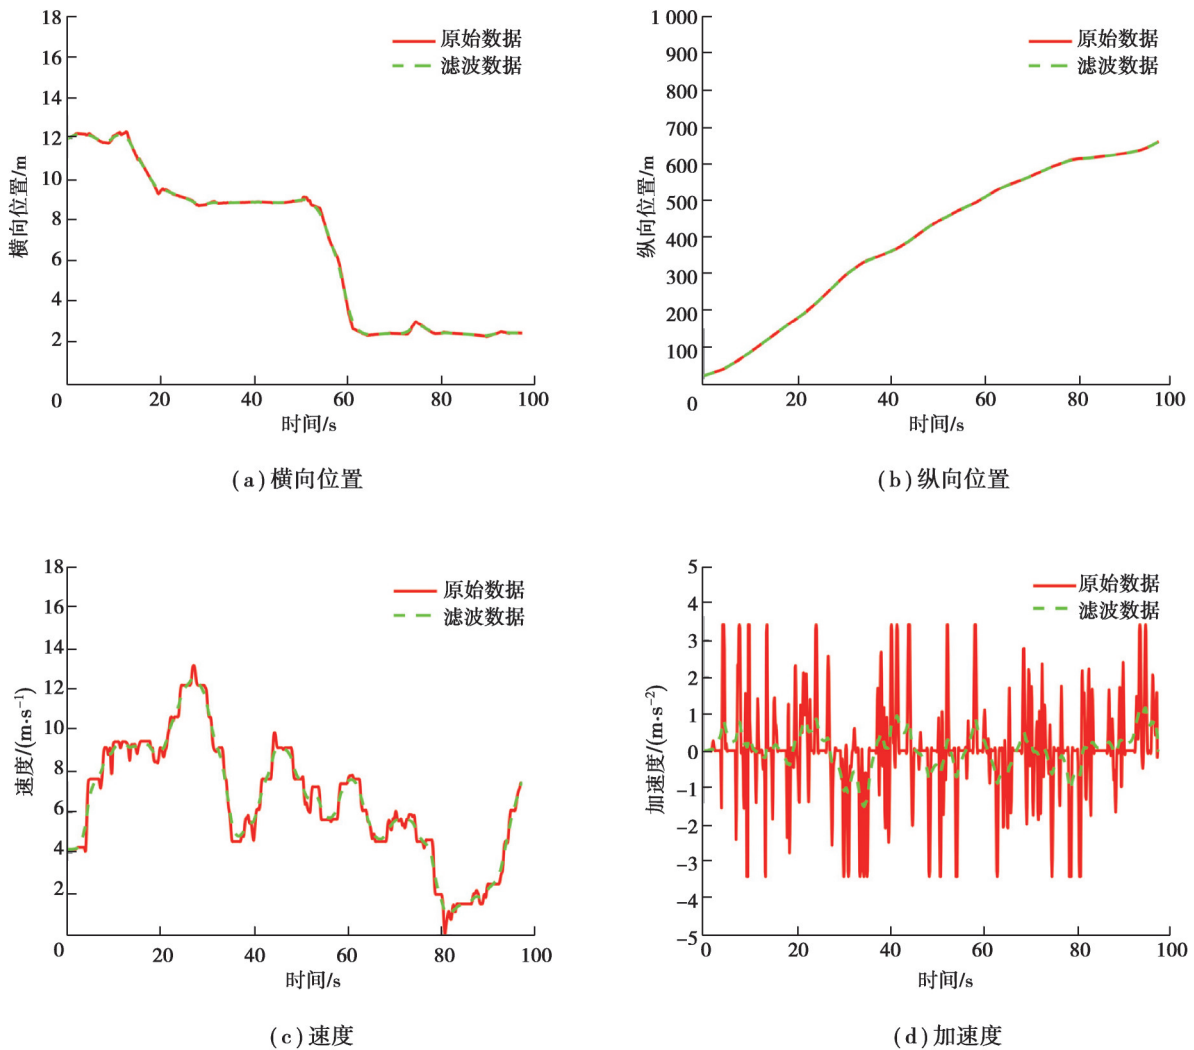


图3 对称指数移动平均滤波效果图

Fig. 3 The filtering results of sEMA

2.3 换道数据提取

对原始数据进行滤波处理后,需要从数据集中提取出具有换道行为且车辆前方有行驶车辆的样本数据。NGSIM数据集的车辆轨迹信息较全面,包含了车辆类型、尺寸等特征信息,以及车辆位置、速度、加速度等动态信息,还提供了周围车辆所处车道和前后车辆的信息,包含乘用车、卡车和摩托车的样本数据。因为卡车和摩托车样本数据较少且换道方式与乘用车不同,所以本研究中仅将乘用车作为研究对象。

在提取换道轨迹时,为了排除辅助车道和坡道的车道变化影响,需要过滤掉匝道入口和出口的车辆轨迹。将车辆轨迹与车道线的交点定义为换道点,根据 Tijerina 等^[17]的研究成果,平均 5 s 就可以实现完整的换道过程,且连续变道与单次换道的微观特性不同,本研究中仅考虑单次换道行为,不考虑多次换道行为,即要求提取轨迹片段在换道前 15 s 和换道后 10 s 时间内均处于相应的固定车道。

Wang 等^[18]认为应将车辆侧向速度大于 0.2 m/s 的时间点作为车辆换道行为意图发生时刻。为了避免车辆瞬时抖动干扰,本研究中以车辆起始点和后面连续的 5 个时间点的车辆侧向速度均大于 0.2 m/s 的时间点作为产生换道意图的起点,换道结束也是如此。

为了方便地研究换道行为,还必须对数据进行归一化处理,将不同车道的换道行为统一到相对位置上,将换道轨迹与车道线的交点作为换道点,换道点的横向位置和纵向位置为 0,对每条车辆轨迹的每个采样

点的横纵向位置进行处理,并将数据单位英尺(feet)转换为国际单位米(m),得到车辆换道轨迹如图4所示。




图4 换道轨迹图

Fig. 4 Lane-changing trajectories

3 换道行为分析

提取NGSIM的US-101路段交通数据库的换道轨迹作为训练集,分析换道行为阶段车辆运行状态参数,明确表征驾驶行为的特征指标,为后续换道行为识别模型的建立提供运动状态特征参数。

3.1 驾驶员换道行为特征分析

在车辆换道过程中,车辆的横纵向驾驶表现指标均呈现出一定的变化差异。首先,对不同驾驶阶段的横纵向驾驶指标及其标准差进行分析,研究驾驶表现指标的分布规律。采样间隔时间为0.1s,1.0s为一个时窗,对驾驶表现指标的标准差进行统计。

3.1.1 纵向运动状态表征分析

针对车辆换道时的纵向运动状态,选择车速、纵向加速度、相对前车距离和车头时距作为纵向驾驶表现指标。

1)车速。车速统计结果如图5所示,可以看出保持车道阶段会出现车速为0的情况,这是由于数据采集时间点正处于早高峰阶段。换道阶段的车速标准差比保持车道阶段大,车速稳定性较差。左右换道阶段车速和标准差均无明显的差别,说明车速不能作为有效表征驾驶人换道行为的车辆状态参数。




图5 不同阶段车速及其标准差箱型图

Fig. 5 Speed and its standard deviation at different stages

2)纵向加速度。纵向加速度统计结果如图6所示,可以看出不同阶段的纵向加速度并没有明显的统计规律,换道阶段的纵向加速度中位数和均值相对于保持车道阶段稍大一些,表明换道阶段发生急加速急减速行为的几率更高,左换道和右换道并没有显著区别,说明纵向加速度不能作为有效表征驾驶人换道行为的车辆状态参数。




图6 不同阶段纵向加速度及其标准差箱型图

Fig. 6 Longitudinal acceleration and its standard deviation at different stages

3)相对前车距离。相对前车距离统计结果如图7所示。从图7(a)看出右换道相对前车距离的均值和波动范围较大,是因为右车道为慢车道,自车需要降速,而其他车道车速无明显变化,导致换道后相对前车距离增大。图7(b)中换道阶段相对前车距离的标准差比保持车道阶段大,是因为换道后前方车辆发生变化,相对于前车的距离会发生突变,但左换道和右换道阶段并无明显差异,说明相对前车距离不能作为有效表征驾驶人换道行为的车辆状态参数。




图7 不同阶段相对前车距离及其标准差箱型图

Fig. 7 Relative front vehicle distance and its standard deviation at different stages

4)车头时距。车头时距统计结果如图8所示,从图中可以看出换道阶段车头时距比保持车道阶段小,而在换道阶段车头时距标准差比保持车道阶段大,符合换道时自车与前车的变化关系,换道时车头时距波动值越大,处于危险环境的几率越高。但左换道和右换道阶段车头时距及其标准差的变化没有显著区别。因此,车头时距不能作为有效表征驾驶人换道行为的车辆状态参数。




图 8 不同阶段车头时距及其标准差箱型图

Fig. 8 Headway and its standard deviation at different stages

3.1.2 横向运动状态表征分析

针对车辆换道时的横向运动状态,选择车辆横向位置偏移、侧向速度和侧向加速度作为横向驾驶表现指标。

1)横向位置偏移。横向位置统计结果如图 9 所示,车辆处于左换道阶段时,横向位置偏移为负数,右换道阶段横向位置偏移为正数,换道阶段的横向位置偏移标准差比保持车道阶段大。给定显著性水平 0.05,3 种行为的横向位置偏移之间的伴随概率为 0,说明均存在显著差异性。因此,横向位置偏移可以作为有效表征驾驶人换道行为的车辆状态参数。




图 9 不同阶段横向位置及其标准差箱型图

Fig. 9 Horizontal position and its standard deviation at different stages

2)车辆侧向速度。车辆侧向速度统计结果如图 10 所示。从图 10(a)看出当车辆左换道时,侧向速度为负值,车辆右换道时,侧向速度为正值,保持车道时侧向速度较小,处于 0 附近。图 10(b)表示换道阶段的侧向速度标准差大于保持车道阶段。给定显著性水平为 0.05,3 种行为的侧向速度之间的伴随概率均为 0,即均存在显著差异性。因此,统计分析结果表明侧向速度可以作为有效表征驾驶人换道行为的车辆状态参数。

3)车辆侧向加速度。车辆侧向加速度统计结果如图 11 所示。换道阶段的侧向加速度及其标准差显著大于保持车道阶段,但是左右换道阶段无明显差别。给定显著性水平为 0.05,左换道和保持车道之间侧向加速度的伴随概率为 0.289 5,右换道和保持车道之间的伴随概率为 0.515 0,左换道和右换道之间的伴随概率

为0.418 6,表明3种行为之间在侧向加速度上没有显著差异,因此,侧向加速度不可以作为有效表征驾驶人换道行为的车辆状态参数。




图 10 不同阶段侧向速度及其标准差箱型图

Fig. 10 Lateral velocity and its standard deviation at different stages




图 11 不同阶段侧向加速度及其标准差箱型图

Fig. 11 Lateral acceleration and its standard deviation at different stages

通过以上分析可知,横向驾驶表征指标横向位置偏移和侧向速度可作为车辆换道行为的特征指标。

3.2 换道持续时间分析

进一步对换道持续时间进行分析,利用2.3节提出的换道产生的时刻作为换道持续时间的起始点,以0.5 s为时间间隔统计,换道持续时间直方图如图12所示。可以看出换道持续时间主要集中在6~8 s之间,这与定义的换道起止点和该数据时间段位于上班早高峰相关。

为更好地理解换道持续时间与车辆运行状态参数之间的关系,将提取出来的换道阶段的车辆状态参数与换道持续时间进行斯皮尔曼和皮尔逊相关性分析。斯皮尔曼和皮尔逊相关系数是统计学中常用来衡量变量之间相关性的指标,统计结果如表1所示。统计发现,换道时间的长短与换道阶段内的侧向速度绝对值的均值的相关系数最大,斯皮尔曼相关系数达到-0.78,皮尔逊相关系数达到-0.81。

设置置信度为0.05,对换道时间与侧向速度绝对值均值进行拟合得到如下线性关系:

$$t_x = -9.274 4 \text{ mean}(|v_x|) + 11.393 7. \quad (2)$$

式中: $\text{mean}(|v_x|)$ 表示侧向速度绝对值的均值; t_x 表示换道持续时间。从图13可以看出,拟合的线性关系可

以很好地反映换道时间随侧向速度绝对值的均值的变化趋势。




图 12 换道持续时间分布直方图

Fig. 12 Lane-changing duration distribution

表 1 驾驶表现参数与换道持续时间的相关系数

Table 1 Correlation coefficients between driving performance parameters and lane-changing duration

驾驶表现参数	斯皮尔曼相关系数	皮尔逊相关系数
最大纵向速度	-0.008 1	-0.020 9
纵向速度均值	-0.042 1	-0.070 7
横向位置波动范围	0.242 4	0.261 3
横向位置偏移标准差	0.233 7	0.249 4
最小侧向速度绝对值	-0.271 3	-0.267 4
侧向速度绝对值均值	-0.784 8	-0.811 9
侧向速度标准差	0.024 8	0.049 7
侧向加速度均值	0.527 8	0.326 4
侧向加速度标准差	-0.461 3	-0.504 2
相对前车距离均值	-0.017 8	0.035 6
相对前车距离标准差	-0.011 4	-0.041 4
车头时距均值	0.060 2	0.067 2
车头时距标准差	0.008 2	0.076 8




图 13 换道持续时间与侧向速度绝对值均值拟合关系

Fig. 13 Line fitting relationship between the lane-changing duration and the mean value of absolute lateral velocity

将左换道和右换道阶段的侧向速度绝对值均值划分为4个范围进行统计,结果如图14和表2所示。图中纵轴为侧向速度绝对值在相应区间内各个时间占总体时间的比例,以图14(a)为例,图中展示了统计样本中左右换道侧向速度绝对值在 $0\sim 0.3\text{ m}\cdot\text{s}^{-1}$ 区间各个时间出现次数占样本总体的比例。换道阶段的侧向速度绝对值的均值越大,换道持续时间的峰值向时间少的方向移动。

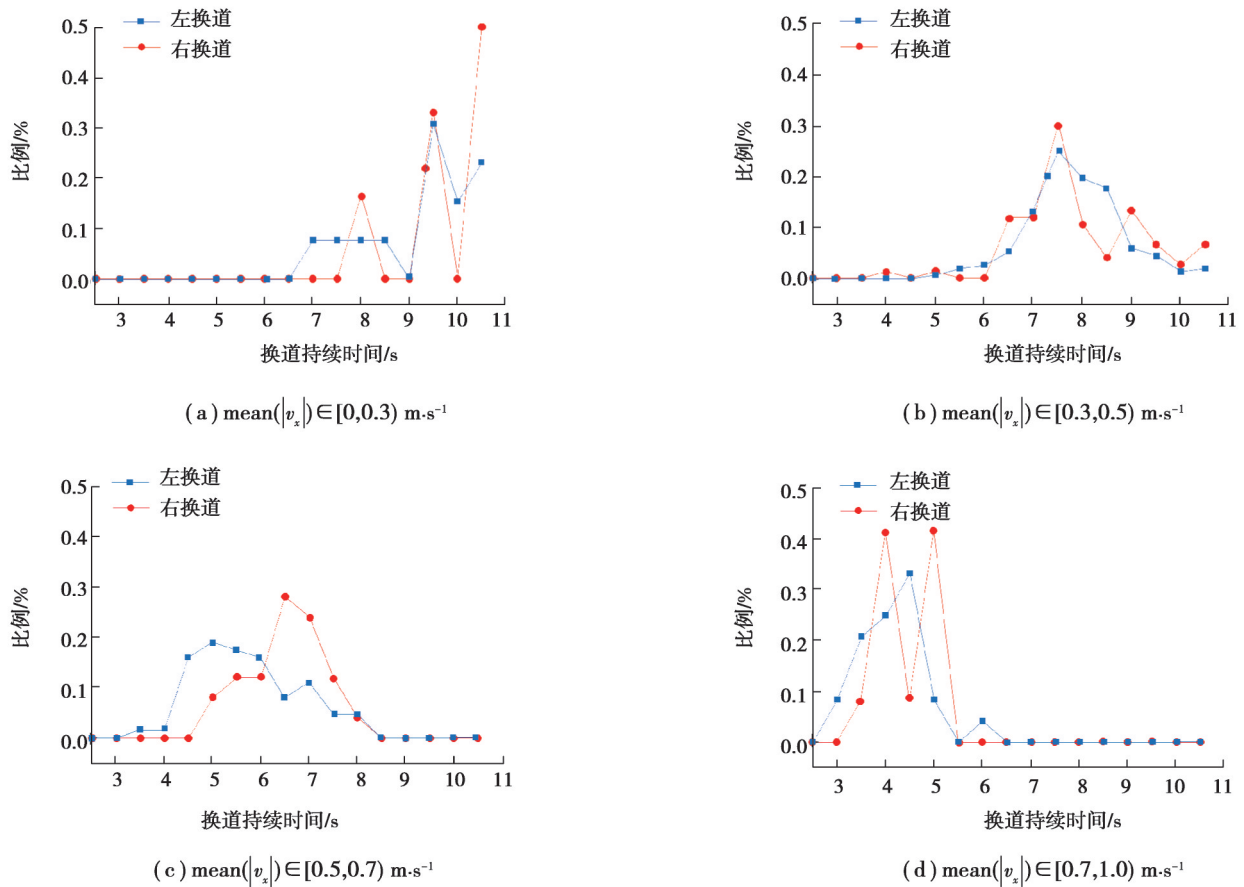


图14 不同侧向速度波动范围的换道持续时间分布统计图

Fig. 14 Lane-changing duration distribution for different lateral velocity fluctuation ranges

表2 4个侧向速度波动范围的换道持续时间统计

Table 2 Statistics of lane-changing duration of four lateral velocity fluctuation ranges

换道类型	$\text{mean}(v_x)/(\text{m}\cdot\text{s}^{-1})$	换道持续时间均值/s	换道持续时间标准差/s	换道持续时间中位数/s
左换道	$[0, 0.3)$	8.954	1.092	9.10
	$[0.3, 0.5)$	7.509	0.979	7.50
	$[0.5, 0.7)$	5.442	1.086	5.30
	$[0.7, 1.0)$	3.875	0.662	3.75
右换道	$[0, 0.3)$	9.417	0.943	9.75
	$[0.3, 0.5)$	7.616	1.245	7.30
	$[0.5, 0.7)$	6.172	0.819	6.20
	$[0.7, 1.0)$	4.225	0.528	4.15

4 换道行为识别模型

将车辆横向位置偏移和车辆侧向速度作为驾驶人换道行为对应的可观测信息,以不同驾驶行为作为隐状态,建立基于GMM-HMM的驾驶行为识别模型。利用最大期望算法对模型参数进行优化整定,考虑驾驶

行为的不确定性,用前向后向算法来对车辆处于各类行为的概率进行估计,并用NGSIM中I-80路段数据进行模型验证。驾驶人换道行为识别的流程如图15所示。从US-101数据库中,提取驾驶人的左换道、保持车道和右换道3种行为的特征参数,建立符合GMM-HMM训练要求的样本库,再采用Baum-Welch算法对HMM中的初始状态概率分布 π 和状态转移矩阵 A 的值进行训练,GMM拟合每个隐藏状态的输出观测概率分布,确定行为识别模型的架构和模型参数,采用前后向算法进行迭代求解,识别当前驾驶人的行为。

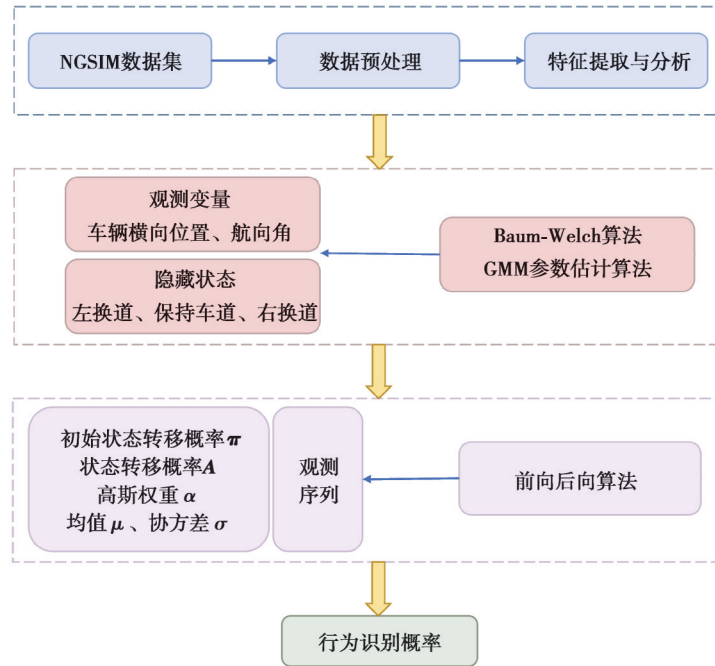


图 15 驾驶人换道行为识别流程

Fig. 15 Identification process of driver behavior for lane change

换道行为识别模型的观测层输入参数为车辆横向位置偏移 Δx 和车辆侧向速度 v_x 。

观测序列以向量 $O = \{\Delta x, v_x\}$ 的形式进行描述。该模型包含了3种隐状态:左换道行为、保持车道行为和右换道行为。用Baum-Welch算法对初始状态转移矩阵 π 和状态转移矩阵 A 的值进行训练,采取均匀取值对 π 和 A 进行初始化,通常认为驾驶人的3种隐状态在左换道和右换道之间不会进行切换,因此状态转移矩阵 A 中的 a_{13} 和 a_{31} 的初值设为0。

初始状态转移矩阵为

$$\pi = \begin{bmatrix} \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \end{bmatrix} \quad (3)$$

状态转移矩阵为

$$A = \begin{bmatrix} \frac{1}{7} & \frac{1}{7} & 0 \\ \frac{1}{7} & \frac{1}{7} & \frac{1}{7} \\ 0 & \frac{1}{7} & \frac{1}{7} \end{bmatrix} \quad (4)$$

用GMM来拟合每个隐藏状态下的输出观测概率分布,用最大期望算法估计GMM的参数 $\theta = (\alpha_m, \mu_m, \sigma_m)$ 。这里 α_m 为第 m 个高斯分布权重; μ_m 为第 m 个分模型高斯分布密度; σ_m 为第 m 个高斯分布协方差, $m = 1, 2, \dots, M$ 。 M 为GMM的高斯分布个数,由贝叶斯信息准则(Bayesian information criterion, BIC)估计得到,综合考虑训练数据的特点和实际的识别效果,设 $M=3$ 。

$$BIC(M) = M \ln(n) - 2 \log P(O, \gamma | \theta), \quad (5)$$

式中： n 是观测序列样本数； $P(\mathbf{O}, \gamma | \theta)$ 为概率分布模型； $\log P(\mathbf{O}, \gamma | \theta)$ 是对数似然值。

通过GMM-HMM方法训练,得到了驾驶人换道行为识别模型各参数,利用NGSIM数据集中的I-80路段的数据作为测试集,从测试结果中随机选取识别出左换道意图与右换道意图的车辆,以下午4:00—4:15时间段的604号车和44号车为例分别说明左换道与右换道行为识别的结果。

如图16所示,当车辆的轨迹比较平滑时,驾驶人的行动意图比较明确,意图行为的概率很快接近于1,其他行为的概率会很快等于0,行为识别算法能迅速准确地判断出车辆行为。根据3.2.2节换道意图发生的起始点的定义,604号车的换道意图起始点是在换道点前1.9 s(3.2 s处),此时的侧向速度是 -0.2211 m/s,距离车道线右侧1.286 m,左换道行为概率为0.537,保持车道的概率为0.463,此时左换道行为识别的概率值大于0.500,所以604号车辆在换道意图发生时模型就预测到左换道行为的发生。在8.1 s处,识别到换道行为结束,此时左换道行为概率为0.275,保持车道的概率为0.725,距离车道线左侧2.101 m,侧向速度是 -0.352 m/s,比保持车道意图起始点提前0.9 s预测到左换道行为的结束。




图16 左换道行为识别结果示意图

Fig. 16 Schematic diagram of left lane-changing behavior recognition result

如图17所示,44号车的换道意图起始点是在换道点前1.6 s,此时的侧向速度是0.263 m/s,距离车道线左侧1.410 m,右换道行为概率为0.542,保持车道的概率为0.458,此时右换道行为识别的概率值大于0.500,所以44号车辆在换道意图发生时模型就预测到右换道行为的发生。在9.2 s处,识别到换道行为结束,此时右换道行为概率为0.495,保持车道的概率为0.505,距离车道线右侧1.412 m,侧向速度是0.172 m/s,比保持车道意图起始点提前了0.1 s预测到右换道行为的结束。

为进一步评估模型的性能,选取支持向量机(support vector machines, SVM)与所提出的GMM-HMM模型进行对比。为确保SVM模型训练时的复杂度满足要求,对数据进行归一化处理,采用高斯径向基函数作为核函数进行SVM建模,并采用网格搜索算法对惩罚因子等参数进行寻优,得到最优参数来进行换道意图识别,SVM和GMM-HMM的识别准确率如图18所示。

由图18可以看出,与传统的基于SVM的换道行为识别模型相比,基于GMM-HMM的模型在测试集数据中的行为识别准确率提高了7.8%,在换道点1.0 s之前的换道行为识别准确率达95.6%,表明该模型在用于预测高速公路上的车辆换道行为时具有较高的精度。




图 17 右换道行为识别结果示意图

Fig. 17 Schematic diagram of right lane-changing behavior recognition results




图 18 行为识别准确率

Fig. 18 Accuracy of behavior recognition

5 结 论

为了准确识别车辆换道意图,基于NGSIM数据集,建立了换道数据提取规则,将车辆驾驶行为分为向左换道、向右换道和直线行驶3类,并标注换道意图数据;基于统计学方法分析了换道状态下横纵向运动学参数分布差异,采用斯皮尔曼系数和皮尔曼系数量化,得出换道持续时间与侧向速度绝对值均值相关性最大的结论,确定了横向位置偏移和侧向速度2个换道行为特征指标;建立了基于GMM-HMM的换道意图识别模型,并与传统的基于SVM的方法进行了性能对比。结果表明,GMM-HMM模型整体识别准确率高,在换道点1.0 s之前的换道行为识别准确率达到95.6%,比SVM提升了7.8%;在意图发生的时刻左右的识别准确率为80%以上。换道意图模型识别精度的提升能够对车辆实际换道行为意图提供更准确的判断,进而使车辆合理规划自身路线,实现车道级别的决策,降低换道风险,提升交通安全。

参考文献

- [1] Dou Y L, Yan F J, Feng D W. Lane changing prediction at highway lane drops using support vector machine and artificial neural network classifiers[C]//2016 IEEE International Conference on Advanced Intelligent Mechatronics (AIM), July 12-15, 2016, Banff, AB, Canada. IEEE, 2016: 901-906.
- [2] Tomar R S, Verma S. Safety of lane change maneuver through a priori prediction of trajectory using neural networks[J]. Network Protocols and Algorithms, 2012, 4(1): 4-21.
- [3] Nilsson J, Fredriksson J, Coelingh E. Rule-based highway maneuver intention recognition[C]//2015 IEEE 18th International Conference on Intelligent Transportation Systems, September 15-18, 2015, Gran Canaria, Spain. IEEE, 2015: 950-955.
- [4] Chauhan P, Kanagaraj V, Asaithambi G. Understanding the mechanism of lane changing process and dynamics using microscopic traffic data[J]. Physica A: Statistical Mechanics and Its Applications, 2022, 593: 126981.
- [5] Tran D, Du J H, Sheng W H, et al. A human-vehicle collaborative driving framework for driver assistance[J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 20(9): 3470-3485.
- [6] Oh C, Choi J, Park S. In-depth understanding of lane changing interactions for in-vehicle driving assistance systems[J]. International Journal of Automotive Technology, 2017, 18(2): 357-363.
- [7] 邱小平, 刘亚龙, 马丽娜, 等. 基于贝叶斯网络的车辆换道模型[J]. 交通运输系统工程与信息, 2015, 15(5): 67-73, 95.
Qiu X P, Liu Y L, Ma L N, et al. A lane change model based on Bayesian networks[J]. Journal of Transportation Systems Engineering and Information Technology, 2015, 15(5): 67-73, 95. (in Chinese)
- [8] Schlechtriemen J, Wedel A, Hillenbrand J, et al. A lane change detection approach using feature ranking with maximized predictive power[C]//2014 IEEE Intelligent Vehicles Symposium Proceedings, June 8-11, 2014, Dearborn, MI, USA. IEEE, 2014: 108-114.
- [9] Zyner A, Worrall S, Ward J, et al. Long short term memory for driver intent prediction[C]//2017 IEEE Intelligent Vehicles Symposium (IV), June 11-14, 2017, Los Angeles, CA, USA. IEEE, 2017: 1484-1489.
- [10] Xie D F, Fang Z Z, Jia B, et al. A data-driven lane-changing model based on deep learning[J]. Transportation Research Part C: Emerging Technologies, 2019, 106: 41-60.
- [11] Kim I H, Bong J H, Park J, et al. Prediction of driver's intention of lane change by augmenting sensor information using machine learning techniques[J]. Sensors, 2017, 17(6): 1350.
- [12] Ahmed I, Karr A F, Roupail N M, et al. Characterizing lane changing behavior and identifying extreme lane changing traits[J]. Transportation Letters, 2023, 15(5): 450-464.
- [13] 季学武, 费聪, 何祥坤, 等. 基于 LSTM 网络的驾驶意图识别及车辆轨迹预测[J]. 中国公路学报, 2019, 32(6): 34-42.
Ji X W, Fei C, He X K, et al. Intention recognition and trajectory prediction for vehicles using LSTM network[J]. China Journal of Highway and Transport, 2019, 32(6): 34-42. (in Chinese)
- [14] Panichpapiboon S, Leakkaw P. Lane change detection with smartphones: a steering wheel-based approach[J]. IEEE Access, 2020, 8: 91076-91088.
- [15] Alexiadis V, Colyar J, Halkias J, et al. The next generation simulation program[J]. ITE Journal, 2004, 74(8): 22-26.
- [16] Thiemann C, Treiber M, Kesting A. Estimating acceleration and lane-changing dynamics from next generation simulation trajectory data[J]. Transportation Research Record: Journal of the Transportation Research Board, 2008, 2088(1): 90-101.
- [17] Tijerina L, Garrett W R, Stoltzfus D, et al. Eye glance behavior of van and passenger car drivers during lane change decision phase[J]. Transportation Research Record: Journal of the Transportation Research Board, 2005, 1937(1): 37-43.
- [18] Wang Q, Li Z H, Li L. Investigation of discretionary lane-change characteristics using next-generation simulation data sets[J]. Journal of Intelligent Transportation Systems, 2014, 18(3): 246-253.

(编辑 罗 敏)