

基于驾驶人风险响应机制的人机共驾模型

何 仁¹, 赵晓聪¹, 杨奕彬², 王建强²

(1. 江苏大学汽车与交通工程学院, 江苏镇江 212013; 2. 清华大学汽车安全与节能国家重点实验室, 北京 100084)

摘要:提出了一种根据驾驶人对环境风险的实时响应进行控制权切换的智能汽车人机共驾模型。首先,从基于真实道路信息的 highD 数据集中提取出跟车和并道两类典型驾驶片段。接着,应用行车风险场理论对驾驶片段中的环境风险进行统一量化。然后,通过拟合环境风险作用与驾驶人的行驶加速度,得到安全风险响应策略曲面,并提出了基于策略偏差的人机共驾控制权柔性切换模型(FCTM)。最后,以纵向控制模型(LCM)作为辅助控制模型,在前车紧急制动和旁车切入两类危险场景中进行了人机共驾仿真实验。结果表明:本文 FCTM 模型可以通过平稳的人机控制权切换,修正驾驶人在危险场景中的驾驶操作,提高行驶安全性。

关键词:车辆工程;人机共驾;行车风险场;控制权柔性切换;风险响应策略

中图分类号:U491.25 **文献标志码:**A **文章编号:**1671-5497(2021)03-0799-11

DOI:10.13229/j.cnki.jdxbgxb20200092

Man-machine shared driving model using risk-response mechanism of human driver

HE Ren¹, ZHAO Xiao-cong¹, YANG Yi-bin², WANG Jian-qiang²

(1. School of Automotive and Traffic Engineering, Jiangsu University, Zhenjiang 212013, China; 2. State Key Laboratory of Automotive Safety and Energy, Tsinghua University, Beijing 100084, China)

Abstract: A man-machine shared driving model for the intelligent vehicle was proposed, employing human drivers' real-time response to the environmental risk. Firstly, typical driving segments, including car-following and cut-in segments, were extracted from a real-traffic-based dataset, the highD dataset. Then the driving risk field theory was employed to quantify the environmental risk in extracted driving segments. By fitting the environmental risk effect and driving acceleration, a safe risk-response strategy was obtained, following which the Flexible Control-Transition Model (FCTM) based on strategy deviation was proposed. Finally, the Longitudinal Control Model (LCM) was applied as the auxiliary control model, and the man-machine shared driving simulation was carried out in two dangerous driving scenes, namely front-vehicle emergency braking and adjacent-car cut-in. The results show that the proposed FCTM can modify driving behavior of the human driver in dangerous scenarios through smooth man-

收稿日期:2020-02-20.

基金项目:国家杰出青年科学基金项目(51625503);国家自然科学基金重点项目(61790561);江苏省研究生科研与实践创新计划项目(SJKY19_2537).

作者简介:何仁(1962-),男,教授,博士生导师.研究方向:汽车综合节能与环保技术. E-mail:heren@mail.ujs.edu.cn

通信作者:王建强(1972-),男,教授,博士.研究方向:汽车智能安全. E-mail:wjqlws@tsinghua.edu.cn

machine control transition and improve driving safety.

Key words: vehicle engineering; man-machine shared driving; driving risk field; flexible control-transition model (FCTM); risk-response strategy

0 引言

近年来,自动驾驶技术迅猛发展,但在开放道路下的纯无人驾驶仍然存在技术瓶颈。在此背景下,构建辅助驾驶系统与驾驶人协作驾驶的人机共驾模式,成为自动驾驶技术逐步发展的重要途径^[1]。人机共驾中最为核心的人机交互是驾驶控制权的切换,为了实现合理的人机驾驶控制权切换,国内外学者提出了众多理论框架。Blaschke等^[2]在2009年首次提出根据驾驶人状态对人机驾驶控制权进行柔性切换,并设计了一种基于驾驶人分心程度的横向驾驶控制权切换模型。Chen等^[3]以驾驶人疲劳状态作为驾驶控制权的分配依据,设计了一种基于横向辅助控制器的人机共驾机制。刘瑞等^[4]基于非合作模型预测控制,提出了一种考虑环境安全裕度的驾驶控制权柔性切换模型。2017年,Li等^[5,6]进一步考虑了驾驶人对驾驶控制权的掌控意图,设计了一种柔性驾驶控制权切换控制器,并讨论了驾驶人对人机协同系统的信任程度对控制器性能的影响。上述研究不同程度地考虑了人机共驾中的2个关键因素,即驾驶人状态和环境安全裕度,但均未充分考

虑两者之间的耦合关系,因此忽视了驾驶人对行车环境的响应机制。这意味着当处于危险驾驶情形时,即使驾驶人的响应方式是正确的,也依然无法获得足够的驾驶控制权。在自动驾驶技术尚不完全成熟的现阶段,如果使驾驶人对驾驶控制权的分配处于过于被动的地位,可能会带来一定的安全隐患。

针对以上问题,本文以行车风险控制为导向,将驾驶人在安全驾驶片段中对环境风险的响应策略作为安全策略,根据驾驶人在驾驶过程中的策略偏差,量化其实时的驾驶能力,并据此进行驾驶控制权的分配,形成了将“量化驾驶状态”与“分配控制权”有机统一的人机共驾机制。

1 控制权柔性切换模型设计架构

本文驾驶控制权柔性切换机制的实现方式如图1所示。美国国家公路交通安全管理局对2258起交通事故的分析结果表明,驾驶人个体因素是引发交通事故的主要原因^[7]。分析报告的作者Treat据此提出交通事故发生机理为:驾驶人在环境风险的作用下,个体风险因素被释放,从而引起

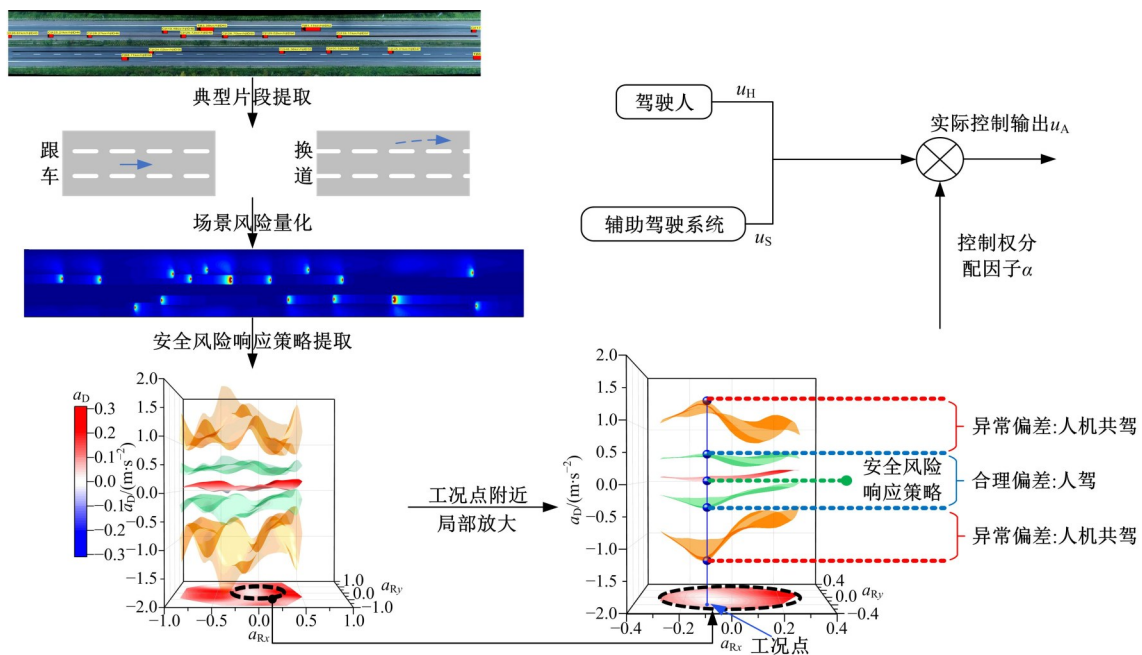


图1 控制权柔性切换模型设计架构

Fig. 1 Design structure of the flexible control-transition model

了交通事故^[7]。在驾驶过程中,将驾驶人驾驶行为的激进性定义为驾驶人内部风险因素,将环境风险定义为外部风险因素^[8]。风险平衡理论中提出,驾驶人在驾驶中需要通过调整其驾驶操作的激进性来应对时变的环境风险,从而将内部风险和外部风险总量控制在由驾驶人能力所决定的平衡边界的附近^[9]。这一结论表明,驾驶人在驾驶过程中与外部环境的交互机制在一定程度上是一种风险交互,即根据驾驶环境的风险程度调整自身的驾驶操作。本文将无事故驾驶过程中驾驶人的风险交互策略定义为安全风险响应策略(以下称为安全策略),则驾驶人在驾驶过程中维持使用安全策略的能力可以有效反映其处理当前驾驶任务的能力。当驾驶人在驾驶过程中偏离安全策略程度越大时,即越可能引发交通事故。因此,本文依据驾驶人偏离安全策略的程度表征驾驶人的实时驾驶能力,并根据此进行人机驾驶控制权的柔性切换。

2 自然驾驶数据提取

安全风险响应策略的提取需要大量的安全无事故的自然驾驶数据。本文采用了由德国亚琛工业大学汽车工程学院公开的highD自然驾驶轨迹数据集^[10]。该数据集利用如图2所示的小型无人机采集了6个地点、16.5h共计110 000辆车的行驶轨迹,车辆总行驶里程达到45 000 km。highD数据集从鸟瞰视角对每一辆车的类型及几何尺寸进行了精确记录,并基于最先进的视觉计算方法确保了分米级的定位误差^[11]。基于该数据集丰富而精准的自然驾驶数据,本文开展了驾驶人风险响应策略的分析。

2.1 换道场景提取

一次完整的换道行为包括:①换道准备阶段;




图2 highD数据记录场景

Fig. 2 Data collection scene of highD

②换道执行阶段;③换道后调整阶段。对于数据集中的换道执行阶段的数据提取,本文采用了文献[12]中的方法。首先,将换道车辆(主车)的轨迹与车道线的相交点(即跨道点)定义为换道事件发生点。然后,沿时间轴反向遍历,当连续3个采样点的车辆航向角 θ 小于阈值 $\theta_{th} = 0.02 \text{ rad}$ 时,则将第1个航向角小于阈值的采样点作为换道起点;同理,从换道事件发生点,沿时间轴正向遍历,当连续3个采样点的车辆航向角 θ 小于阈值 θ_{th} 时,将第1个航向角小于阈值的采样点作为换道终点。从换道起点到换道终点,即为换道执行阶段。最后,将换道起点的5 s前作为行为起点,从行为起点至换道起点,即为换道准备阶段;将换道终点的5 s后作为行为终点,从换道终点至行为终点,即为换道后调整阶段;将从行为起点到行为终点时间范围内的数据序列定义为一条换道行为数据。单条换道行为所包含的数据内容为:主车及主车周围(主车所在车道及相邻车道的前、后150 m范围内)其他车辆的时序的坐标、速度、加速度信息,以及上述所有车辆的驾驶环境信息(道路类型和车道信息)。本文研究中共计提取换道行为数据13 095条,其中包括6741条左向换道行为和6354条右向换道行为。

2.2 跟车片段提取

根据2.1节中定义的换道行为,当某一车辆在被数据集记录的行驶范围内未执行换道行为,且在行驶过程中,其所在车道前方50 m范围内始终有其他车辆时,则以该车为主车的驾驶片段是一条跟车片段。单条跟车片段中所包含的内容与换道片段相同,本文研究中共计提取跟车行为数据15 234条。

highD数据集的采样频率为25 Hz。由于片段数据过多,为保证计算效率,本文对两类驾驶片段的数据进行了频率为5 Hz的重采样。

3 风险量化模型

3.1 模型框架

本文采用行车风险场^[13-15](也称“行车安全场”)理论对交通环境风险进行统一量化。文献[13]对该理论框架进行了完整的阐述。highD数据集所涉及的场景均为结构化道路下的车辆交通,为了提升行车风险场模型的易用性和实用性,本文针对该场景对行车风险场模型进行了基于规

则的细化和优化,设计规则为:①交通单元*i*所产生的风险正比于其风险量 V_i ,所受到的来自其他交通单元的风险反比于其风险量 V_i ;②交通单元*j*对交通单元*i*产生的风险与两个交通单元间的距离呈反相关;③运动的交通单元*j*对交通单元*i*产生的风险受到两者相对运动状态的影响;④交通标志对交通单元产生的风险具有约束作用。以下对各条规则进行详细说明。

3.2 模型设计

3.2.1 交通单元的风险量

道路交通中的事故形式通常为交通单元间的碰撞。在发生碰撞时,交通单元的动能将通过挤压、扭曲等形式进行释放,从而造成碰撞双方的弹性和塑性形变,以及其他的连锁反应,最终导致事故的“损失”^[16]。上述过程可以通过能量传递理论^[17]进行解释,交通事故的发生是交通单元所携带的能量以非正常的途径进行了转移和释放,从而造成不良结果。因此,一个交通单元潜在可以造成的损失大小与其所携带的能量密切相关。基于上述分析,可以将交通单元的风险量 V 定义为:

$$V = T \cdot \left(m + \frac{1}{2} m v^2 \cdot \frac{2k_1}{v_{lim}^2} \right) \quad (1)$$

式中: T 为交通单元的类型系数,表征了根据交通单元的外形、运载物特性等对其风险量进行的修正; m 为交通单元的质量; v 为交通单元的运动速度; v_{lim} 为道路限速与车辆极限车速之间的较小值(本文取 $v_{lim} = 120 \text{ km/h}$); $k_1 = 0.1$ 为权重修正系数。

3.2.2 基于距离的风险分布

受限于感知能力,驾驶人在评估环境中某个交通单元的风险时,最主要的考量因素是该交通单元和自车间的距离,以及距离的变化趋势,也就是相对速度^[18]。为了刻画驾驶人的风险响应策略,首先需要保证对于风险的量化与驾驶人对于风险的认知保持一致。基于距离的风险评估是人类对于风险最直观的认识。对于同一个风险源,距离风险源越远所受到的风险越弱,反之则越强(见图3(a))。因此,将基于距离的风险分布强度矢量 D_{ji}^* 定义为:

$$D_{ji}^* = \frac{1}{|r_{ji}|^\lambda} \cdot \frac{r_{ji}}{|r_{ji}|} \quad (2)$$

式中: r_{ji} 为由*j*指向*i*的距离矢量; $\lambda = 1$ 为下降梯度系数。

3.2.3 基于运动状态的风险分布

除相对距离以外,风险源相对自身的运动状态是驾驶人最为敏感的风险评估因素^[18]。文献[15]采用多普勒效应对由运动状态所引起的交通单元风险特性的改变进行了刻画。但是,该方法未能明显地体现车辆运动过程中风险在横、纵向上分布的差异性,故本文采用文献[13]中所提出的指数形式,将交通单元基于运动状态的风险分布特征系数 D_{mot} (见图3(a))表示为:

$$D_{mot,ji} = \exp[|v_r| \cdot \cos(\theta)] \quad (3)$$

式中: $v_r = v_j - v_i$ 为交通单元*j*与*i*的相对速度矢量; $\theta < 180^\circ$ 为相对速度矢量 v_r 与距离矢量 r_{ji} 的夹角。

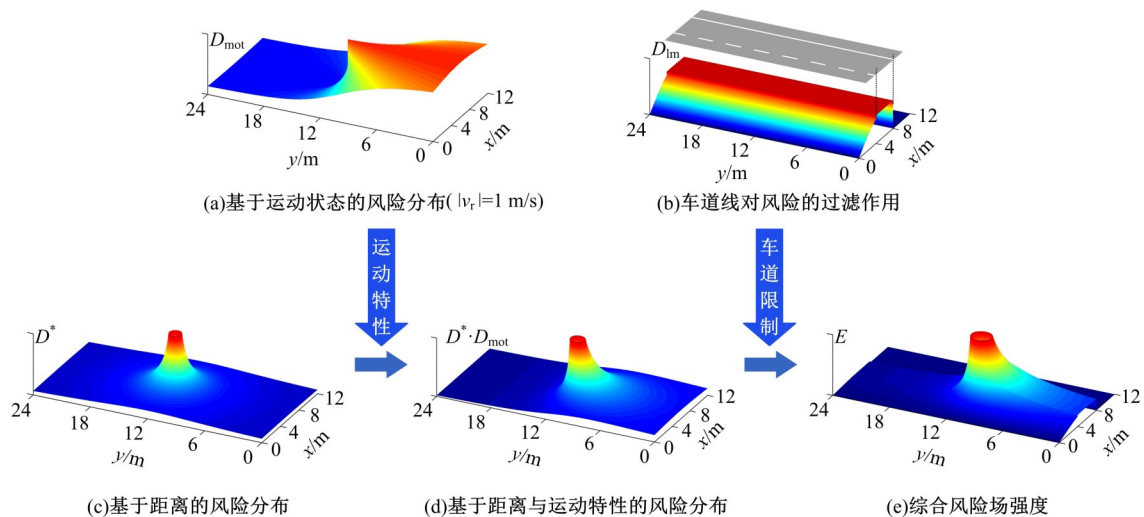


图 3 行车风险场模型

Fig. 3 Driving risk field model

3.2.4 交通规则对风险的约束

车道线等道路标记确定了结构化道路上的行驶规则。以车道线为例,如果位于相邻车道的旁车与自车间所隔的是车道虚线,可以认为旁车不会在无目的、无适当并道间距的情况下随意越过车道虚线,故旁车所引起的风险,将在一定程度上受到车道虚线的限制;而如果所隔的是车道实线,可以认为旁车不会在任何情况下越过车道实线,故旁车所引起的风险被完全限制在自车的车道外。综合上述分析,车道线实质上起到了风险过滤^[15,19]的作用(见图3(b)),将该过滤系数 D_{lm} 定义为:

$$D_{lm} = \begin{cases} T_{lm} \cdot \cos\left(|r_p| \cdot \frac{\pi}{3\omega}\right), & |r_p| > \frac{\omega}{2} \\ 1, & |r_p| \leq \frac{\omega}{2} \end{cases} \quad (4)$$

式中: T_{lm} 为车道线类型系数; r_p 为道路上一点 p 点指向车道中心线的距离矢量; ω 为车道宽度。

对于车道虚线,使用 $T_{lm} = 1$ 表征车道虚线对风险的限制作用;对于车道实线,使用 $T_{lm} = 0$ 表征车道实线对风险的截断作用。

3.2.5 多元风险作用

综合上述4点讨论,在二元风险交互中,交通单元 j 对交通单元 i 所构成的风险作用强度 $a_{R,ji}^*$ 可以表示为:

$$a_{R,ji}^* = E_{ji} \cdot V_j / V_i \quad (5)$$

式中: $E_{ji} = D_{ji}^* \cdot D_{mol,ji} \cdot D_{lm,ji}$ 为综合风险场强度函数,其分布特征如图3(e)所示。

式(5)中,交通单元 i 受到交通单元 j 的风险作用强度不仅正比于 j 的风险量,同时还反比于 i 自身的风险量。这是由于 j 在对 i 造成风险的同时还会受到 i 的风险作用,这使得风险的作用强度受到被作用单元的属性的影响,即风险作用具有交互性。同时,上述的风险交互是非对称的,由式(5)易得到:当 j 和 i 是非相同类型的交通单元时, j 对 i 造成的风险作用强度不等于 i 对 j 造成的风险作用强度。这是由于在道路交通中,低风险性交通单元中的驾驶人倾向于主动规避具有高风险性的交通单元,因而造成规避倾向的非对称现象。

在实际道路交通中,交通单元间的交互往往是多元的,即一个交通单元会受到多个周围交通单元共同的风险作用,本文采用矢量和的形式表

达多元交互下的风险作用强度:

$$a_{R,i}^* = \sum_{j=1}^{N_u} a_{R,ji}^* \quad (6)$$

式中: $a_{R,i}^*$ 为多元交互下交通单元 i 所受到的风险作用强度; N_u 为环境中与交通单元 i 发生风险交互的交通单元的总数。

需要说明的是,本文假设一个交通单元仅与其所在车道以及相邻车道内的交通单元发生风险交互,纵向交互范围为自身所在位置的前、后150m内。

4 控制权柔性切换模型

4.1 风险作用强度的预处理

利用第3节中提出的风险量化模型,可以将每一帧驾驶场景中主车所受到其他周围车辆的风险作用强度进行量化。同时,将主车在该时刻的行驶加速度作为驾驶人响应,即可得到驾驶人在不同强度和方向的风险作用下的驾驶响应。考虑到驾驶人对于风险的响应具有一定的迟滞效应^[20],即某一时刻的驾驶响应是当前时刻风险及过去一段时间内风险共同的作用结果。此处采用半汉宁窗对风险作用强度 $a_{R,i}^*$ 进行卷积处理,从而增加对历史风险作用的考虑,即交通单元所受到的综合风险作用强度 a_R 为:

$$a_R = a_{R,i}^* \otimes H(n) \quad (7)$$

式中: $H(n)$ 为长度为 n 的半汉宁窗函数。

本文研究中,取 $n = 25$ 时,数据集中驾驶人的行驶加速度 a_D 与风险作用强度 a_R 可以取得最高平均相关性。由于数据采样频率 f 为5 Hz,故该窗函数可以实现对过去5 s内风险作用的综合考虑。

4.2 安全风险响应策略

通过提取各帧驾驶数据中驾驶人的行驶加速度 a_D 和对应帧中主车所受的综合风险作用强度 a_R ,即可获得驾驶人在不同驾驶场景中的风险响应策略,以下分别为跟车和换道驾驶片段中的安全风险响应策略曲面的拟合结果。

4.2.1 跟车场景

图4为跟车场景中驾驶人的风险响应策略。其中,周向坐标表征了车辆坐标系下风险作用的来向,径向坐标表征了风险作用的强度,图面颜色则表征了在不同风险工况下驾驶人的行驶加速度大小,红色表征加速,蓝色表征减速。

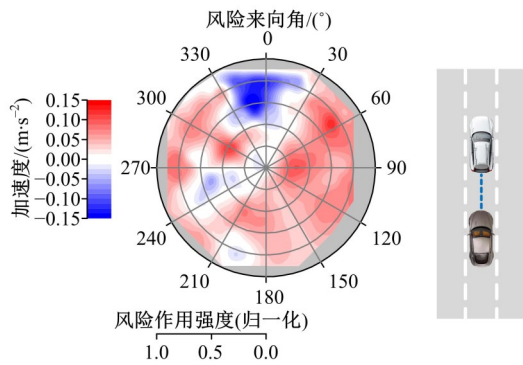


图 4 跟车场景风险响应策略

Fig. 4 Risk-response strategy in the car-following scenarios

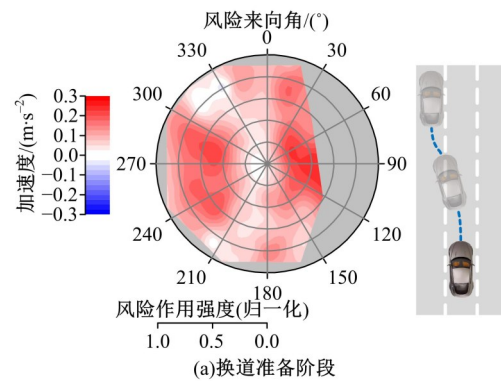
由图 4 可知,对于来自前方的风险作用,尤其是风险来向为 0° 附近的前方风险作用,驾驶人在风险作用提高时,会采取明显的减速避让行为。但是,当风险作用来自车辆后方时,即使风险作用强度较高时驾驶人也不会通过加速的方式来规避这种风险作用。并且,当来自后方的风险作用的强度变化时,驾驶人的平均行驶加速度并无明显变化。这在一定程度上说明驾驶人在跟车过程中,对行驶方向后方的风险作用并不敏感。

4.2.2 换道场景

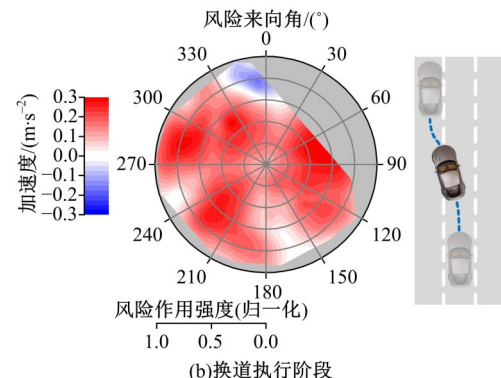
highD 数据集的道路场景中,车辆前进方向的左侧车道为高速车道、右侧车道为低速车道^[21],因此驾驶人在左向换道和右向换道时需要采取不同的驾驶策略,故以下将对两个方向的换道行为中的风险响应策略分别进行分析。

(1)左向换道过程中,驾驶人需要通过加速来汇入相对较为高速的车流。但是,在换道准备阶段中(见图 5(a)),当目标车道的前方(风险来向角 330° 附近)和目标车道的后方(风险来向角 200° 附近)存在风险作用时,驾驶人趋向于放弃加速。这是由于驾驶人在换道前,需要对目标车道的可通行性进行判断。对于目标车道前方存在风险作用的情况,实际驾驶场景为:主车的目标车道的前方存在车辆,且速度低于主车,因此驾驶人为了汇入该车道,需要将车速调整至接近目标车道中的前车。而对于目标车道的后方存在风险作用的情况,实际驾驶场景为:目标车道后方存在车辆正在接近。此时驾驶人应优先保证该接近车辆的通行,因此暂缓变道行为。

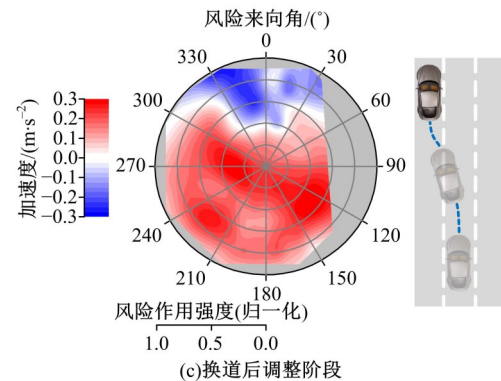
在换道执行阶段中,驾驶人已经确认了换道的可行性并开始执行换道。由图 5(b)可知,在该阶段中,驾驶人着重考虑目标车道中的前车,因此



(a)换道准备阶段



(b)换道执行阶段



(c)换道后调整阶段

图 5 左向换道风险响应策略

Fig. 5 Risk-response strategy in left lane changes

仅当风险作用来自目标车道的前方时(风险来向角 355° 附近),进行明显的制动。而在风险作用来自其他方向时,则仍进行加速,换入高速车道。

在换道完成后的调整阶段,驾驶人通常需要重新回到跟车状态。由图 5(c)可知,该阶段中驾驶人的风险响应策略在纵向上对前方风险作用更为敏感,当来自前方的风险作用强度较大时,即执行制动。

(2)右向换道中,驾驶人的风险响应相较于左向换道具有一定的对称性。在换道准备阶段(见图 6(a)),右向换道时驾驶人对目标车道中前侧(风险来向角 30° 附近)和后侧(风险来向角 150° 附近)的风险作用最为敏感。但右向换道时,驾驶

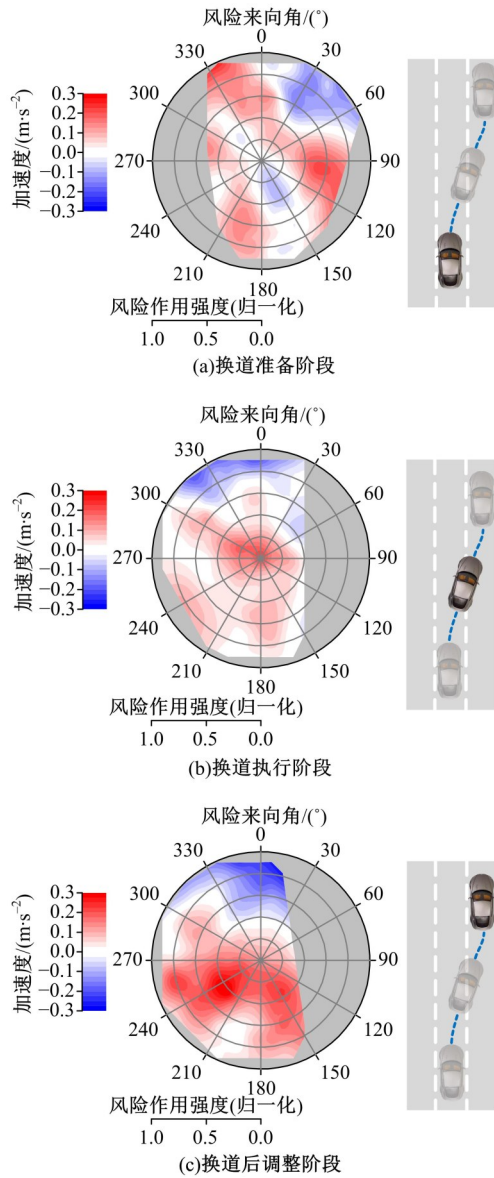


图 6 右向换道风险响应策略

Fig. 6 Risk-response strategy in right lane changes

人在换道准备阶段的平均加速度(0.04 m/s²),相较于左向换道(0.11 m/s²)较小。

在右向换道的执行阶段(见图 6(b))和后调整阶段(见图 6(c)),驾驶人的风险响应策略均与跟车场景类似,即仅对行驶方向前方的风险作用变化有明显的响应。

4.3 基于策略偏差的控制权柔性切换模型

在获得安全驾驶片段中的风险响应策略后,就可以在驾驶过程中对驾驶人实时的风险响应的合理性进行评估。将驾驶人在某种风险作用下的行驶加速度记为一个策略点 $s = (a_R, a_D)$; 对于 t 时刻某一特定策略点 $s(t) = (a_R(t), a_D(t))$, 将 $\Delta s(t) = |a_D(t) - a_D^*|$ 记为策略偏差, 其中 a_D^* 为安

全风险响应曲面上的策略点在风险作用 $a_R(t)$ 下的行驶加速度。

以左向预换道阶段为例, 将图 5(a) 中的风险响应策略热力图映射至三维笛卡尔坐标系中得到图 7。图 7 中, 中间层曲面为安全风险响应策略曲面 Ω^* ; 绿色曲面为策略偏差不大于 1 倍标准差的策略点包络面 ($\Omega_{1-\sigma^+}$ 和 $\Omega_{1-\sigma^-}$), 并将处于该包络范围内的所有策略点的集合记为安全策略集 $S^{1-\sigma}$; 橙色曲面为策略偏差不大于 3 倍标准差的策略点包络面 ($\Omega_{3-\sigma^+}$ 和 $\Omega_{3-\sigma^-}$), 并将处于该包络范围内, 但不属于 $S^{1-\sigma}$ 的所有策略点的集合记为过渡策略集 $S^{3-\sigma}$ 。对于任一策略点 $s(t) \in S^{1-\sigma}$ 满足: 在风险作用 $a_R(t)$ 下, 该策略点的策略偏差 $\Delta s(t)$ 不超过安全驾驶片段中驾驶人团体所采用的行驶加速度的标准差 $\sigma_{a_D}(a_R(t))$, 即:

$$\Delta s(t) \leq \sigma_{a_D}(a_R(t)) \quad (8)$$

同理, 任一策略点 $s(t) \in S^{3-\sigma}$ 满足: 在风险作用 $a_R(t)$ 下, 该策略点的策略偏差 $\Delta s(t)$ 不超过安全驾驶片段中驾驶人团体所采用的行驶加速度标准差 $\sigma_{a_D}(a_R(t))$ 的 3 倍, 即:

$$\sigma_{a_D}(a_R(t)) < \Delta s(t) \leq 3\sigma_{a_D}(a_R(t)) \quad (9)$$

单帧策略点仅能反映驾驶人在某一时刻的响应策略, 如果依据单帧数据中的策略偏移量来分配驾驶控制权, 将有可能因为控制权的跳变而导致驾驶人的不适应, 从而影响行驶安全。

因此, 本文采用动态时间窗内的平均策略偏差 δ 量化风险响应策略的偏差程度:

$$\delta(t) = \frac{1}{N(t) \cdot f} \sum_{k=T_1}^{T_N} \Delta s(k) \quad (10)$$

式中: f 为采样频率; T_1 、 T_N 分别为动态时间窗的时间起点和时间终点, 且满足当前时刻 $t = T_N$, 即时间窗覆盖范围的终点为当前时刻; $N(t)$ 为动态时间窗的窗长度:

$$N(t) = \begin{cases} \exp\left(-\frac{\sigma_{a_R}(N(t-1))}{\mu_{a_R}(N(t-1))}\right), & t \neq t_0 \\ 1, & t = t_0 \end{cases} \quad (11)$$

式中: t_0 为驾驶过程的时间起点; $\sigma_{a_R}(N(t-1))$ 、 $\mu_{a_R}(N(t-1))$ 分别为在 $t-1$ 时刻的时间窗范围内, 主车所受的综合风险作用强度 a_R 的标准差和平均值。

式(11)表明, 时间窗的长度受到主车所受风险作用强度的波动情况影响。当风险作用强度波

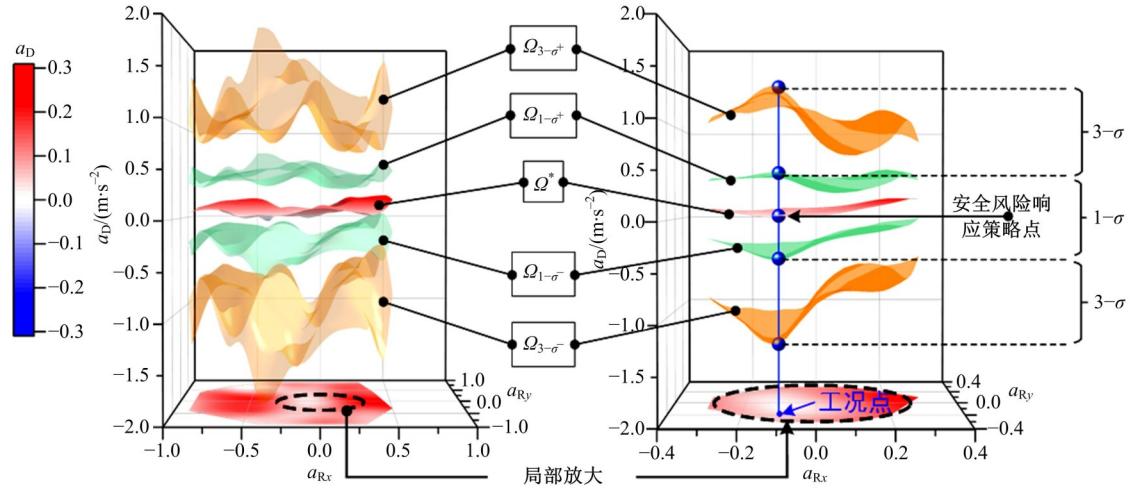


图 7 基于策略偏差的控制权分配

Fig. 7 Control authority allocation based on strategy deviation

动剧烈时,时间窗长度较短,此时更关注驾驶人在短期内的风险响应策略;反之,当风险作用强度较为平稳时,则关注驾驶人更长期的风险响应策略。

根据驾驶人在动态时间窗内的平均策略偏差 $\delta(t)$ 分配控制权,可以有效保证控制权切换的平稳性。根据式(8),当 $\delta(t) \leq \sigma_{a_D}(a_R(t))$ 时,驾驶人所采取的风险响应策略属于安全策略集,故驾驶人行为符合安全风险响应策略,此时驾驶人掌握全部驾驶控制权;再根据式(9),当 $\sigma_{a_D}(a_R(t)) < \delta(t) \leq 3\sigma_{a_D}(a_R(t))$ 时,驾驶人所采取的风险响应策略属于过渡策略集,此时驾驶人已经偏离安全响应策略,应当由辅助驾驶系统接管一部分驾驶控制权,两个驾驶主体(驾驶人和辅助驾驶系统)的控制权分配因子 $\alpha(t)$ 由驾驶人当前策略偏差 $\delta(t)$ 确定(见式(13));当驾驶人所采取的风险响应策略不属于上述两种策略集合时,认为驾驶人的驾驶操作已经完全偏离安全风险响应策略,此时应当由辅助驾驶系统进行紧急接管。综上,基于策略偏差的柔性控制权切换模型(Flexible control-transition model, FCTM)可以表述为:

$$\mathbf{u}_A = (1 - \alpha) \cdot \mathbf{u}_H + \alpha \cdot \mathbf{u}_S \quad (12)$$

$$\alpha(t) = \begin{cases} 0, & \delta(t) \leq \sigma_{a_D}(a_R(t)) \\ \frac{\delta(t) - \sigma_{a_D}(a_R(t))}{2\sigma_{a_D}(a_R(t))}, & \sigma_{a_D}(a_R(t)) < \delta(t) \leq 3\sigma_{a_D}(a_R(t)) \\ 1, & \delta(t) > 3\sigma_{a_D}(a_R(t)) \end{cases} \quad (13)$$

式中: \mathbf{u}_A 为实际生效的控制量; \mathbf{u}_H 和 \mathbf{u}_S 分别为驾

驶人和辅助系统拟执行的控制量; $\alpha = \alpha(t)$ 为时变控制权分配因子。

5 实验分析及讨论

为验证本文人机共驾模型 FCTM 的有效性,采用纵向控制模型^[22](Longitudinal control model, LCM)作为辅助驾驶控制算法,进行了人机共驾仿真实验。LCM 模型是一种驾驶人模型,其跟车效果具有优异的拟人化特性,且驾驶风格可以通过模型参数进行显式调整。LCM 可以表达为:

$$a(t) = A \left[1 - \left(\frac{v(t)}{\tilde{v}} \right) - e^{-1 - \frac{s(t)}{\tilde{s}(t)}} \right] \quad (14)$$

式中: $a(t)$ 为 LCM 模型输出的自车行驶加速度; A 为最大起步加速度; $v(t)$ 为自车行驶速度; \tilde{v} 为自车的期望行驶速度; $s(t)$ 为自车与前车的车头间距; $\tilde{s}(t)$ 为期望车头间距:

$$\tilde{s}(t) = \frac{v(t)}{2b} - \frac{v_f(t)}{2B} + \tilde{v} \cdot \tau + l \quad (15)$$

式中: b 为自车驾驶人认为自己在紧急情况所能给出的最大制动减速度; B 为自车驾驶人认为的前车可能执行的最大制动减速度; $v_f(t)$ 为前车的行驶速度; τ 为驾驶人的反应时间; l 为有效车长。

本文通过调整 LCM 模型中与驾驶风格有关的模型参数 (\tilde{v} , b 和 B), 构造了保守型、平衡型和激进型 3 种不同驾驶风格的辅助驾驶控制模型, 并分别记为 LCM^{con}、LCM^{bal} 和 LCM^{agg}。3 个模型中, A 设置为 4 m/s^2 ; τ 设置为 0.11 s ; l 设置为 6 m ; \tilde{v} 依次设置为 $80, 100$ 和 110 km/h ; b 依次设置为 $3, 4$ 和 5 m/s^2 ; B 依次设置为 $5, 4$ 和 4 m/s^2 。

5.1 实验结果

图 8 为前车紧急制动情况下的人机共驾和驾驶人手动驾驶时的驾驶过程。由图 8(a)可知, LCM^{con} 共驾模式下,行驶速度较手动驾驶有明显下降,且该模式下辅助驾驶系统接管驾驶控制的时间明显长于其他两种模式(见图 8(c))。由图 8(b)可知,相较于手动驾驶,LCM^{con} 模式可以有效提高前车紧急制动后的车头间距;而 LCM^{agg} 模式则进一步提高了驾驶的激进性,该模式下最小车头间距小于手动驾驶模式。

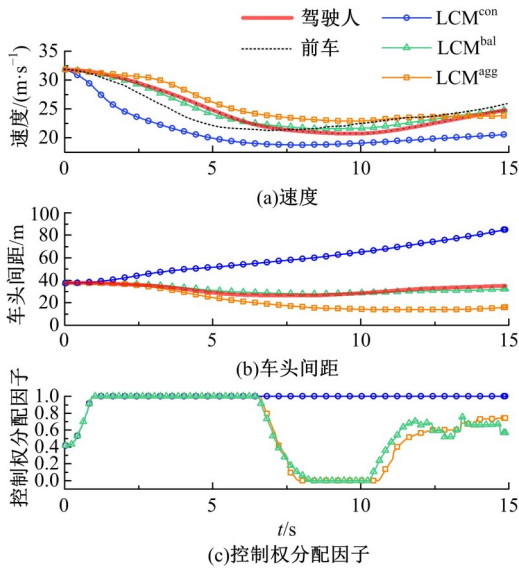


图 8 前车紧急制动下的人机共驾

Fig. 8 Man-machine shared driving process in front-car emergency braking scenarios

图 9 为 746 个紧急制动场景中,采用人机共驾和手动驾驶下的最小车头间距的统计结果。Mann-Whitney 检验表明:相较于手动驾驶,在 LCM^{con} 和 LCM^{bal} 模式下进行人机共驾时,最小车头间距的增大均具有显著性($p < 0.01$)。

图 10 为旁车切入情况下的人机共驾和驾驶人手动驾驶时的驾驶过程。由图 10(a)可知,旁车约在 2.5 s 处开始切入主车的车道,并在 7 s 左右完成切入。但是,无论是手动驾驶还是 3 种人机共驾模式,在旁车切入过程中行驶速度均没有明显的区别。注意到,在图 10(c)中,在旁车开始切入时(2.5 s 左右)驾驶控制权的分配出现波动,即驾驶人的驾驶操作一定程度上偏离了安全策略,因此将一部分驾驶控制权分配给了辅助系统,但是由于辅助系统本身拟执行的驾驶控制亦不满足安全策略,因此人机共驾模式对于驾驶人操作的修正并不明显。

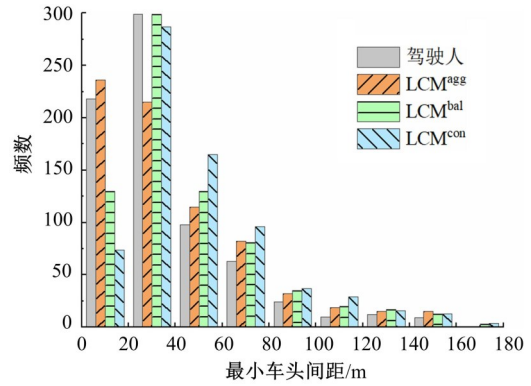


图 9 前车紧急制动下的最小车头间距

Fig. 9 Minimum headway in front-car emergency braking scenarios

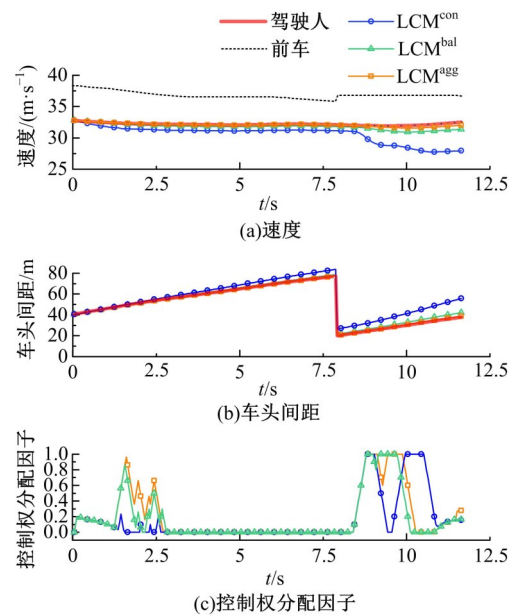


图 10 旁车切入情况下的人机共驾

Fig. 10 Man-machine shared driving process in adjacent-car cut-in scenarios

由图 10(b)可知,相较于手动驾驶,与 3 种 LCM 进行人机共驾均能在一定程度上提高车头间距。但是,如图 11 所示,1141 个旁车切入片段中,仅在 LCM^{con} 模式下进行人机共驾时,最小车头间距的增大具有显著性($p < 0.01$)。

5.2 分析及讨论

上述实验结果表明,与纵向辅助模型进行人机共驾时,可以有效提高前车紧急制动场景中的安全性。但是对于旁车切入这类横向运动导致的风险,纵向辅助模型在人机共驾时提供的辅助效果较为有限。这是由于 LCM 此类纵向驾驶人模型的设计主要面向的是纵向行驶的场景,模型本身并不具备应对横向风险的能力。因此,当驾驶

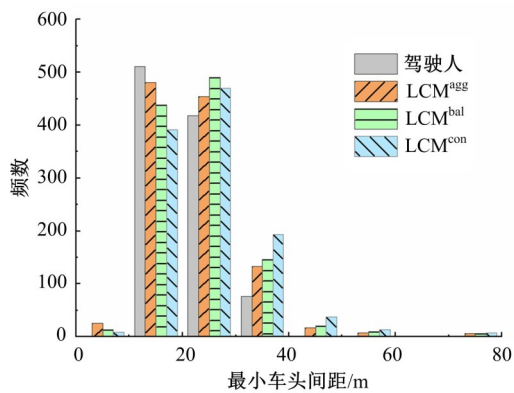


图 11 旁车切入情况下的最小车头间距

Fig. 11 Minimum headway in the adjacent-car cut-in scenarios

人面对横向风险出现策略偏差时,即使将一部分控制权分配给辅助控制模型,也不能显著提高驾驶的安全性。但是,本文所提出的FCTM对人机共驾所使用的“机驾”模型并没有选择性。这意味着,FCTM所构建的基于策略偏差的驾驶控制权柔性切换机制对人机共驾的作用是具有成长性的。随着驾驶辅助系统对驾驶任务的应对能力不断加强,FCTM所构建的人机共驾机制对驾驶人策略偏差的修正能力也不断提升。

同时,由于现阶段车载驾驶系统的驾驶能力尚不完备,本文中仅对驾驶人的驾驶操作进行了策略偏差分析,其分析结果实质上是驾驶人应当掌握的驾驶控制权的最大值,即实现驾驶人控制权的最大化。当驾驶系统由“辅助驾驶”向“自动驾驶”不断迭代发展,直至驾驶系统具备与人类一样应对完备驾驶任务的能力时,同样可以对高智能等级的辅助驾驶系统的驾驶策略进行策略偏差分析,从而综合考虑驾驶人和驾驶系统两者的策略偏差,实现更为安全的人机共驾。

本文研究中并未对驾驶人类型进行有目的的选择,故所获得的安全风险响应策略所代表的仅是人类驾驶的平均水平。理想的无人驾驶应当能够模拟甚至超越优秀驾驶人的驾驶水平。因此,遴选优秀驾驶人,提取优秀驾驶人群体的风险响应策略,可以为未来无人驾驶系统提供一种驾驶策略优越性评价准则。

6 结 论

(1) 驾驶人对行车风险的响应模式根据其驾驶场景和行为决策结果的不同具有显著区别:①跟车过程中,仅对行驶方向前方的风险作用的

变化做出明显响应;②产生换道行为决策时,对目标车道内前、后方的风险作用的响应最为明显;③换道过程中,对目标车道前方的风险作用最为敏感。

(2) 根据驾驶人行为合理性进行驾驶控制权分配时,人机共驾的综合驾驶表现在一定程度上取决于驾驶系统本身对驾驶场景的应对能力。应用纵向控制模型作为“机驾”模型时,驾驶系统对驾驶人危险行为的修正在纵向风险场景中(例如前车紧急制动)相较于在横向风险场景中(例如旁车切入)更为有效。

(3) 应用无事故驾驶片段中驾驶人的风险响应策略作为风险响应策略的安全基准,并基于策略偏差进行人机驾驶控制权柔性切换的FCTM,可以实现:①识别驾驶人的危险驾驶操作,并在其操作偏离安全响应策略时,依据策略偏离程度将一部分控制权平稳切换至辅助驾驶系统;②当与保守型纵向辅助驾驶系统进行人机共驾时,可以有效提高前车紧急制动和旁车切入场景中的行驶安全性。

参考文献:

- [1] Walch M, Colley M, Weber M. Driving-task-related human-machine interaction in automated driving: towards a bigger picture[C]//11th International Conference on Automotive User Interfaces and Interactive Vehicular Applications: Adjunct Proceedings—AutomotiveUI'19, Utrecht, Netherlands, 2019:427-433.
- [2] Blaschke C, Breyer F, Färber B, et al. Driver distraction based lane-keeping assistance[J]. Transportation Research Part F: Traffic Psychology and Behaviour, 2009, 12(4):288-299.
- [3] Chen L, Yang C. Control authority determination of a vehicle lane keeping assist controller[C] //2009 IEEE Intelligent Vehicles Symposium, Xi'an, China, 2009:1383-1388.
- [4] 刘瑞,朱西产,刘霖,等.基于非合作模型预测控制的人机共驾策略[J]. 同济大学学报:自然科学版, 2019, 47(7):1037-1045.
Liu Rui, Zhu Xi-chan, Liu Lin, et al. Cooperative driving strategy based on non-cooperative model predictive control[J]. Journal of Tongji University: Natural Science, 2019, 47(7):1037-1045.
- [5] Li R, Li Y, Li S E, et al. Driver-automation indirect shared control of highly automated vehicles with intention-aware authority transition[C]//2017 IEEE Intelli-

- gent Vehicles Symposium, Los Angeles, CA, USA, 2017:26-32.
- [6] Li R, Li S, Gao H, et al. Effects of human adaptation and trust on shared control for driver-automation cooperative driving[C]//SAE Technical Paper, 2017-01-1987.
- [7] Treat J R, Tumbas N S, McDonald S T, et al. Tri-level study of the causes of traffic accidents: final report[R]. Washington DC, USA: National Highway Traffic Safety Administration, 1979.
- [8] Wilde G J S. The theory of risk homeostasis: Implications for safety and health[J]. Risk Analysis, 1982, 2(4):209-225.
- [9] 把余韬. 基于行为和生理指标的驾驶风险分析与模式识别研究[D]. 北京:清华大学机械工程学院, 2015.
- Ba Yu-tao. Risk factors identification during driving based on behavioral and physiological measures[D]. Beijing:Department of Industrial Engineering, Tsinghua University, 2015.
- [10] Krajewski R, Bock J, Kloeker L, et al. HighD dataset[EB/OL]. [2020-05-10]. <https://arxiv.org/ftp/arxiv/papers/1810/1810.05642.pdf>
- [11] Krajewski R, Bock J, Kloeker L, et al. The highD dataset: a drone dataset of naturalistic vehicle trajectories on German highways for validation of highly automated driving systems[C]//IEEE International Conference on Intelligent Transportation Systems (ITSC), Maui, HI, USA, 2018:2118-2125.
- [12] 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 Xue-wu, Fei Cong, He Xiang-kun, et al. Intention recognition and trajectory prediction for vehicles using LSTM network[J]. China Journal of Highway and Transport, 2019, 32(6):34-42.
- [13] 王建强, 吴剑, 李洋. 基于人-车-路协同的行车风险场概念、原理及建模[J]. 中国公路学报, 2016, 29(1):105-114.
- Wang Jian-qiang, Wu Jian, Li Yang. Concept, principle and modeling of driving risk field based on driver-vehicle-road interaction[J]. China Journal of Highway and Transport, 2016, 29(1):105-114.
- [14] Wang J, Wu J, Li Y. The driving safety field based on driver-vehicle-road interactions[J]. IEEE Transactions on Intelligent Transportation Systems, 2015, 16(4):2203-2214.
- [15] Wang J, Wu J, Zheng X, et al. Driving safety field theory modeling and its application in pre-collision warning system[J]. Transportation Research Part C: Emerging Technologies, 2016, 72:306-324.
- [16] Zheng X, Zhang D, Gao H, et al. A novel framework for road traffic risk assessment with HMM-based prediction model[J]. Sensors, 2018, 18(12):4313.
- [17] 傅贵. 安全管理学:事故预防的行为控制方法[M]. 北京:科学出版社, 2013.
- [18] Macadam C C. Understanding and modeling the human driver[J]. Vehicle System Dynamics, 2003, 40(1-3):101-134.
- [19] 许洪国, 张慧永, 宗芳. 交通事故致因分析的贝叶斯网络建模[J]. 吉林大学学报:工学版, 2011, 41(增刊1):89-94.
- Xu Hong-guo, Zhang Hui-yong, Zong Fang. Bayesian network modeling for causation analysis of traffic accident[J]. Journal of Jilin University (Engineering and Technology Edition), 2011, 41(Sup. 1):89-94.
- [20] Wetton M A, Hill A, Horswill M S. The development and validation of a hazard perception test for use in driver licensing[J]. Accident Analysis & Prevention, 2011, 43(5):1759-1770.
- [21] Driving in Germany—travel guide at Wikivoyage[EB/OL]. [2020-05-10]. https://en.wikivoyage.org/wiki/Driving_in_Germany
- [22] Ni D, Leonard J D, Jia C, et al. Vehicle longitudinal control and traffic stream modeling[J]. Transportation Science, 2016, 50(3):1016-1031.