

边缘场景下计及驾驶员认知处理过程的 驾驶风险场模型构建

周彬^{1,2,3} 杨志峰¹ 张峻宁¹ 董元发^{1,2,3*} 彭巍^{1,2,3}

1. 三峡大学机械与动力学院, 宜昌, 443002

2. 水电机械设备设计与维护湖北省重点实验室, 宜昌, 443002

3. 三峡大学智能制造创新技术中心, 宜昌, 443002

摘要:人-车共驾过程中, 驾驶员的情绪变化会导致认知变化, 进而改变车辆风险场, 为此构建了一种考虑驾驶员认知-情绪状态的人因风险场模型。首先通过驾驶模拟器实验收集并分析车辆行驶数据和驾驶员生理信号; 随后标定人因风险场中的驾驶员因子; 最后通过六自由度驾驶模拟器采集实验数据并对人因风险场风险指标与多传统风险指标进行对比。人因风险场模型在边缘场景下能更有效和稳定评估不同情绪驾驶员的行车风险。

关键词:行车风险场; 边缘场景; 认知处理过程; 人因行为场

中图分类号: TP182

DOI:10.3969/j.issn.1004-132X.2026.01.023

开放科学(资源服务)标识码(OSID):



Construction of Driving Risk Field Model Considering Driver Cognitive Processing in Edge Scenes

ZHOU Bin^{1,2,3} YANG Zhifeng¹ ZHANG Junning¹ DONG Yuanfa^{1,2,3*} PENG Wei^{1,2,3}

1. School of Mechanical Engineering and Power Engineering, China Three Gorges University, Yichang, Hubei, 443002

2. Hubei Key Laboratory of Design and Maintenance of Hydropower Machinery and Equipment, Yichang, Hubei, 443002

3. Intelligent Manufacturing Innovation Technology Center, China Three Gorges University, Yichang, Hubei, 443002

Abstract: During the human-vehicle co-driving processes, driver's emotional changes would lead to cognitive changes, which in turn altered the vehicle risk field. Therefore, a human factor risk field model was constructed considering driver's cognitive-emotional state. Firstly, vehicle driving data and driver physiological signals were collected and analyzed through driving simulator experiments. Then, the driver factors in the human factor risk field were calibrated. Finally, experimental data were collected through a 6-DOF driving simulator, and the risk indicators of the human factor risk field were compared with multiple traditional risk indicators. The results show that the human factor risk field model is more effective and may evaluate the driving risks of drivers stably with different emotions in edge scenarios.

Key words: driving risk field; edge scene; cognitive processing; human factor risk field

0 引言

人工驾驶与智能驾驶混行程度的日益提高加大了交通环境的交互复杂性与不确定性, 这种复杂交互环境使人-车共驾系统频繁面临边缘场景即驾驶过程中遇到的低频但复杂、多样且高危的驾驶场景的考验。智能驾驶系统因场景数据稀缺而难以有效处理边缘场景下的安全关键事件^[1],

同时, 边缘场景的动态不确定性导致系统无法具有人类驾驶员同等水平的风险感知与实时决策能力。因此, 对人-车共驾行驶过程进行风险评估变得尤为重要。

现有的驾驶风险评估主要依赖对车辆自身状态参数及周边交通参与者相对运动信息的分析^[2-4], 但此类方法未充分考虑交通环境与车辆状态的动态耦合关系。因此有学者以风险势场量化驾驶风险, 将交通环境构建为动态场域, 通过分析场域内车辆的动态交互与运动规律, 引导车辆遵循特定规则行驶。王安杰等^[5]针对自动驾驶车辆

收稿日期: 2024-12-20

基金项目: 国家自然科学基金(52075292); 湖北省自然科学基金(2022CFB798, 2023AFB1116)

侧后方的避撞问题,提出融合障碍物轨迹预测的预测风险场模型及对应的运动规划方法,并通过实验验证其避撞有效性。LI等^[6]针对自动驾驶车辆的动态驾驶风险量化问题,构建了融合车辆加速度与转向角的风险势场模型,并将势场模型用于构建协同跟驰模型,精准量化了动态风险。CHEN等^[7]针对隧道跟驰安全问题,提出融合势场、动能场、环境场的复合安全场模型,据此开发的协同车辆跟驰模型在隧道场景下可实现安全调控。人车共驾场景中,驾驶员的行为特性直接影响行驶风险。如风险场模型仅聚焦车辆与环境交互,忽视驾驶者主观风险感知及行为异质性,会限制其在实际场景中的应用准确性,因此,有研究者开展了融合驾驶员行为特征的风险场建模。WANG等^[8]提出的人-车-路协同行车风险场模型能统一描述多种耦合因素,但其参数规模较大,给实际应用中的标定带来了挑战。SONG等^[9]认为驾驶认知风险由环境客观风险与驾驶员主观特性共同驱动,基于此构建了主观驾驶风险场预测模型并证实了风险预测效能。李文博等^[10]通过定量解析驾驶员情绪对驾驶行为的动态影响,融合行驶风险场理论构建了情绪驱动型驾驶行为-风险关联模型,揭示了情绪状态与驾驶安全等级的多维映射机制。当前研究对驾驶者行为特性的分析大多局限于静态与定性层面,缺乏对其动态演变过程的量化表征,因此建立的风险场模型难以动态响应突发风险态势的适应性调控需求。

人因风险场模型的构建过程中,驾驶员的生理信号与行为特性有紧密联系。NI等^[11]融合多模态生理数据与车辆动力学参数,构建5类驾驶情绪识别模型,验证了情绪状态与生物特征-行为数据的关联。SCHMIDT等^[12]分析了同步采集的心理生理指标与驾驶行为数据,发现生理数据与驾驶员主观状态之间存在显著关联性,可作为预测主观状态的有效指标。上述研究表明,驾驶员情绪通过认知效应改变驾驶行为,诱发行驶风险的动态演变。该机制在长尾场景中表现得尤为显著,因此融合多源生理和行为数据解析情绪驱动的认知机制,并将其纳入风险场建模框架,已成为提升动态风险量化合理性和准确性的关键路径。

本文针对智能汽车主动安全决策对驾驶员状态适应性不足的问题,提出人因风险场(human factor-cognitive risk field, HF-CRF)模型。基于驾驶任务中的生理信号与车辆动力学数据,解析情绪状态对认知决策与驾驶行为的差异化影响。


选取多维评估指标并通过熵权法量化权重,结合眼动、脑电及心电等动态生理特征标定模型参数。最后,基于驾驶模拟实验实现风险量化评估,验证HF-CRF模型在复杂场景下的有效性。

1 实验设计

1.1 驾驶模拟实验场景设定

在自然交通流速为匀速40 km/h且车辆不变道的条件下,本文设定如下2种场景:

场景1——总路程9.1 km、限速60 km/h的双向四车道。此场景中,对向车道、相邻车道均设置行驶车辆,并要求驾驶员执行跟车驾驶任务。设置具有“边缘效应”的驾驶情景:车流汇入导致前车急刹,如图1所示。前车因车流汇入而突然减速急刹较为常见,要求驾驶员迅速反应以避免碰撞,符合边缘场景的定义。



A. t 时刻并入快速路车辆 B. t 时刻前车 C. t 时刻实验车
A'. $t+t_0$ 时刻并入快速路车辆 B'. $t+t_0$ 时刻前车 C'. $t+t_0$ 时刻实验车


图1 快速路边场景示意图

Fig.1 Expressway edge scene diagram

场景2——总路程3 km、限速30 km/h的双向两车道。在此场景中,对向车道设置行驶车辆,要求驾驶员按交通法规执行驾驶任务。设置具有“边缘效应”的驾驶情景:在公交站、房屋等视觉盲区,行人突然出现,如图2所示。场景2考验驾驶员在视线受限区域的预判能力,以及对突发情况的快速反应能力,同样符合边缘场景的定义。

1.2 驾驶情绪的分类与选择

驾驶情绪是指驾驶员在驾驶过程中的情绪状态,对驾驶员的驾驶行为及交通安全具有重大影响。目前研究将驾驶情绪划分为离散情绪和维度情绪。常见的维度模型包括环绕体模型和三维PAD情绪模型^[13],维度情绪模型能更全面评估和理解驾驶员的情绪状态,因此本文选择维度情绪



A. t 时刻行人 B. t 时刻实验车
A'. $t+\Delta t$ 时刻行人 B'. $t+\Delta t$ 时刻实验车

图2 城市道路边缘场景示意图

Fig.2 Urban road edge scene diagram

量化分析驾驶员情绪。

1.3 情绪诱导材料的选择

研究情景为通勤情景,而基于驾驶模拟器实验的情绪诱导难以诱导出高唤醒度的维度情绪,因此对实验驾驶员主要进行负性(低效价-低唤醒)、中性、正性(高效价-低唤醒)的情绪诱导。

本研究的情绪诱导材料包括图片、视频和音乐。选取材料标准:①必须符合伦理要求;②主要基于中国人的日常生活场景和事件;③诱导材料应能有效引发目标情绪,且其情绪指向明确无误。

每种情绪初步选取10张图片、5个视频、5段音乐。向参与者展示诱导材料,并采用情绪自我评估模型(self-assessment manikin, SAM)量表收集其主观情绪反馈。每种情绪最终选取诱导效果评分最佳的5张图片、2个视频、2段音乐。

1.4 实验流程

青年驾驶员具有情绪易诱导、不同情绪状态下的风险驾驶行为差异明显等特点^[14],因此选择的12名驾龄2~8年(平均驾龄4.67年,标准差2.19年)的在校大学学生(平均年龄22.92岁,标准差1.38岁)作为被试驾驶员。

采用驾驶场景搭建软件搭建各工况驾驶场景,并外接G29罗技驾驶模拟器实现驾驶员在环实验。采集设定场景下的车辆行驶数据,采用北京津发科技股份有限公司提供的ErgoLAB人机环境同步平台V3.0进行实验。采用ErgoLAB可穿戴无线生理仪器采集并记录实验驾驶员的脑电和心电信号,采用Tobii Pro Glass3眼动仪记录驾驶过程中的驾驶员眼动数据。

情绪诱导实验分为初步诱导和深度诱导,其中,情绪图片用于初步诱导,视频用于深度诱导。模拟驾驶实验设计如图3所示,具体实验流程如下:

1)主持人介绍实验内容,被试者签署知情同意书,检查并确保设备处于正常工作状态。

2)被试者进行5 min的模拟器驾驶练习,熟悉驾驶操作。练习驾驶结束后,休息2 min。

3)再次检查实验设备,为实验人员佩戴生理信号采集装置和眼动仪。数据输出正常后,驾驶员填写SAM量表,标定初始情绪,随后,要求驾驶员在一条无边缘场景的道路上进行3 km无驾驶任务的模拟驾驶,将此过程中收集到的生理信号作为基线数据。

4)被试者观看情绪诱导材料并被要求回想特定情绪相关的往事,研究人员使用SAM量表对其情绪状态进行评分,以检验情绪诱导操作的有效性。

5)完成驾驶任务后,研究人员回放实验录像,要求被试者根据特定时间点(边缘场景触发前后)的自身体验,再次填写SAM量表进行情绪状态评估。

重复步骤1)~5),直至每名驾驶员完成实验。最后,收集实验数据,结束实验。

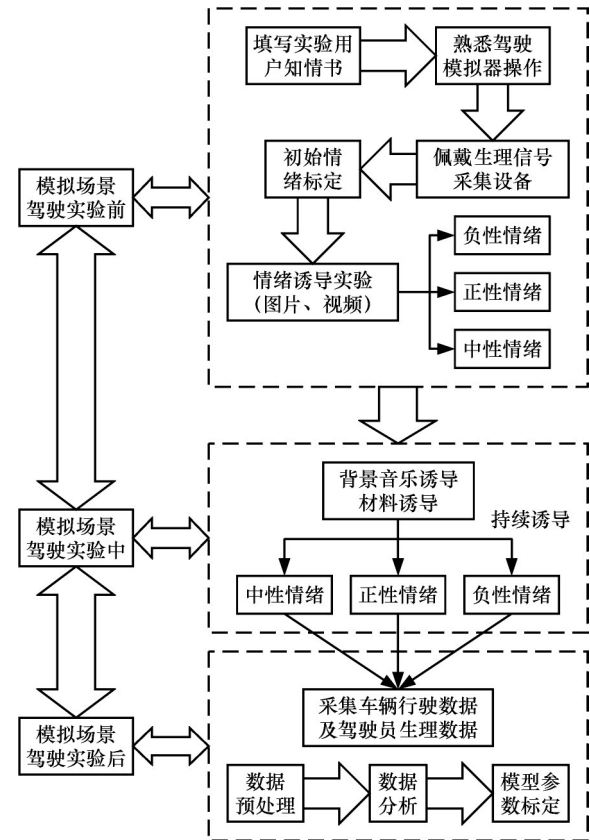


图3 模拟驾驶实验设计

Fig.3 Experimental design for simulated driving

1.5 情绪诱导成功及持续性验证

借鉴已有研究^[11],本研究将SAM量表与心电指标作为检验依据,通过对比分析每次情绪诱

导后及驾驶全程结束后的数据来判定目标情绪的诱导是否成功。12名被试者中,中性情绪的效价维度得分从诱导后的5.46下降至驾驶结束后的4.91,唤醒度则从2.89上升至3.77,这表明驾驶任务本身可引发轻微压力反应,但被试者情绪仍在中性情绪区间。正性情绪的效价维度得分从诱导后的8.14下降至驾驶结束后的7.86,唤醒度从3.02下降至2.84,这表明愉悦情绪的持续性较好。负性情绪的效价维度得分从诱导后的3.42下降至驾驶结束后的2.17,唤醒度从3.69上升至3.93,这反映驾驶过程中负面情绪加重,但仍保持在低唤醒度区间。由此可知,情绪诱导效果贯穿驾驶全过程。

2 模型构建

2.1 风险场模型的组成

边缘场景的动态风险特性要求综合风险场模型应结合动态环境场与静态环境场,同时考虑驾驶人因素对风险势场的调节效应。本文提出的综合风险场模型包括综合环境场和人因行为场:

$$E_a = E_c + E_b \quad (1)$$

式中: E_a 、 E_c 、 E_b 分别为综合风险场、环境场和行为场的场强。

2.2 综合环境场

综合环境场由静态环境场和动态环境场组成:

$$E_c = E_v + E_s \quad (2)$$

式中: E_v 、 E_s 分别为动态环境场和静态环境场的场强。

静态环境场源于道路上具有约束的设施,如车道线、道路边界。不同车道线对应不同的风险势场强度,研究场景中的道路标线包含白色虚线、黄色虚线、黄色双实线。

车道线风险场采用类高斯函数模型描述:

$$E_1 = \sum_{i=1}^I \sum_{j=1}^J A_i \exp\left(-\frac{|d_{Aj}|^2}{2\sigma^2}\right) \frac{d_{Aj}}{|d_{Aj}|} \quad (3)$$

$$d_{Aj} = y_j - y_A \quad (4)$$

式中: I 为车道线的种类数; J 为车道线的条数; A_i 第*i*类车道线的场强系数; y_A 为目标车质心纵坐标;车道线*j*的*Y*轴坐标为 y_j ; d_{Aj} 为车辆与第*j*条车道线的距离; σ 为未定参数,决定势场增减的速度。

与车道线类似,道路边界同样构成风险势场,其场强随车辆靠近而急剧增大。道路边界场模型可表示为

$$E_r = \frac{\eta}{2} \left(\frac{d_{r_1}}{|d_{r_1}|^3} + \frac{d_{r_2}}{|d_{r_2}|^3} \right) \quad (5)$$

$$d_{r_l} = y_{r_l} - y_B \quad l = 1, 2 \quad (6)$$

式中: η 为道路边界势场系数; r_1 、 r_2 分别表示两个道路边界; B 为目标车; y_{r_l} 为第*l*个道路边界的*Y*轴位置坐标; y_B 为目标车辆的*Y*轴位置坐标; d_{r_l} 为目标车到第*l*个道路边界 r_l 的距离。

动态环境场是动态障碍物的运动状态变化引起的驾驶情景改变,其场强向量由移动目标定义的属性、运动状态决定。基于WANG等^[8]的研究,将运动中的车辆质量定义成虚拟质量:

$$M_c = m_c (1.566 \times 10^{-14} v_c^{6.687} + 0.3345) \quad (7)$$

式中: M_c 、 m_c 分别为物体的虚拟质量和实际质量; t 、 v_c 为物体的速度,m/s。

风险场的车距通常设为车辆质心间的距离,这导致没有考虑车辆轮廓与障碍物方向对车辆周围风险分布的影响。因此,本文引入伪距离概念,将实际距离修正为伪距离:

$$|d_k| = \sqrt{[(x - x_k)d_x / \exp(\mu v)]^2 + [(y - y_k)d_y]^2} \quad (8)$$

式中: d_k 为车辆*k*与风险产生对象之间的伪距离; d_x 、 d_y 分别为纵向和横向的安全距离阈值; μ 为与速度相关的待定参数; (x, y) 为道路上风险产生对象的质心坐标; (x_k, y_k) 为车辆*k*的质心坐标。

本研究引入安全裕度

$$D_{SM} = 1 - \frac{0.15v_k}{D} + \frac{v_k^2 - v_{k-1}^2}{1.5gD} \quad (9)$$

$$v_k t / D \leq D_{SM} \quad (10)$$

式中: D 为第*k*-1和第*k*辆车之间的距离; v_{k-1} 、 v_k 分别为第*k*-1和第*k*辆车的速度; g 为重力加速度。

来确定纵向安全距离的阈值^[9]。通过式(9)、式(10)得到纵向安全距离的阈值:

$$d_x = D_{\min} = (0.15 + t_0)v_k + \frac{v_k^2 - v_{k-1}^2}{1.5g} \quad (11)$$

横向的安全阈值 d_y 设为车道的宽度3.5 m。因此,动态环境场的场强为

$$E_v = \frac{M_c R d_k}{K_2 |d_k|^2} \exp(-K_1 a \cos \theta) \quad (12)$$

式中: R 为道路环境影响因子, $R=1$; K_1 、 K_2 为待标定的权重系数,分别表征加速度与相对距离对场强的影响程度; d_k 为车辆*k*与风险对象之间的距离; a 为车辆的加速度; θ 表示车辆加速度*a*的方向与车辆*k*和风险对象之间连线方向的夹角。

2.3 人因行为场

动态环境场中,驾驶员的情绪、认知和驾驶技能对行驶风险具有显著影响。为量化这些难以直接观测的驾驶员特性,本文通过融合车辆行驶状态参数与驾驶员生理信号参数,构建综合性的驾驶员因子,并将该因子引入行为场建模。人因行为场的场强为

$$E_b = F_b E_v \quad (13)$$

$$F_b = \eta_1 F_{\text{cognition}} + \eta_2 F_{\text{skill}} + \eta_3 F_{\text{laws}} \quad (14)$$

式中： F_b 为驾驶员因子； $F_{\text{cognition}}$ 、 F_{skill} 、 F_{law} 分别为驾驶员的认知风险因子、驾驶能力因子和交规因子； $\eta_1 \sim \eta_3$ 为因子权重系数。

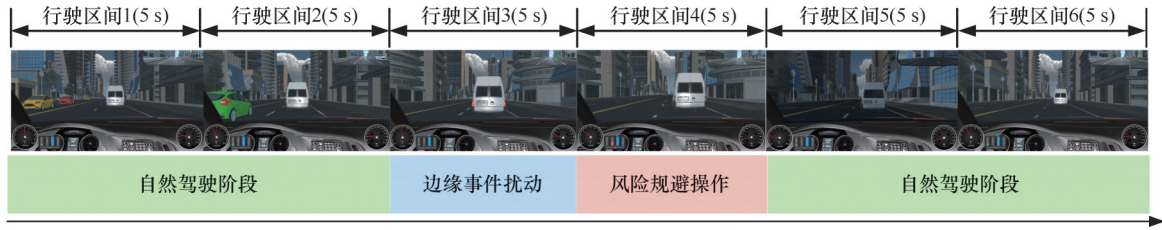


图4 行驶区间划分

Fig.4 Driving range division

2.4.1 风险场参数标定

驾驶风险场力表示道路使用者与风险场之间的短程相互作用，其大小与危险程度成正比。针对后车减速场景构建的跟驰模型^[15]与本文研究的边缘场景相符，且模型结构清晰，便于标定参数，故本文借鉴该模型。

实验使用的计算机处理器为 i5-13600KF，显卡为 RTX 3060 Ti，内存为 32GB。使用驾驶模拟实验采集车辆的行驶数据，利用灰狼算法标定模型参数，设置最大迭代次数为 300，灰狼种群规模为 30，收敛条件为连续 10 次迭代的均方根误差 (root mean square error, RMSE) 变化小于 10^{-6} 。RMSE 的表达式为

$$R_{\text{rmse}} = \sqrt{\frac{1}{M} \sum_{m=1}^M |a_m^{\text{real}} - a_m^{\text{sim}}|} \quad (15)$$

式中： a_m^{real} 、 a_m^{sim} 分别为第 m 辆跟随车辆的真实加速度和预测加速度； M 为样本量，本文样本量为 240。

上述基于灰狼算法的参数标定方法具有良好的普适性，可适用于其他工况下的风险场建模^[16]。模型参数经标定后所得结果如表 1 所示。

表1 风险场模型参数标定结果

Tab.1 Calibration results of risk field model parameters

参数	μ	K_1	K_2	RMSE
标定结果	0.0379	-0.0390	0.6741	0.5762

2.4.2 驾驶员认知因子

驾驶过程中，驾驶员依赖视觉观察路况，获取关键的环境风险信息。驾驶过程中，驾驶员平均注视时间延长或平均瞳孔直径显著增大是大脑对周围环境风险信息进行深度加工和评估的外在表现，因此采用驾驶员在不同情绪下的平均注视时间

$$\bar{t} = \frac{1}{Q} \sum_{q=1}^Q t_{F,q}$$

和平均瞳孔直径 $\bar{D} = (D_l + D_r) / 2$ 表征驾驶员的风险认知能力，其中， $t_{F,q}$ 为单位时间内第 q 次注视的持续时间， Q 为单位时间内的注视

2.4 模型参数标定

本研究将边缘场景分为 3 个主要区间，每个主要区间 (10 s) 分为 2 个子行驶区 (5 s)，如图 4 所示。

总次数， D_l 、 D_r 分别为左右瞳孔的直径。

由图 5 可知，负性情绪引发视觉隧道效应，注视点集中在前车区域，忽视对周围环境的观察与感知；正性情绪驾驶员的注视点较为分散，虽增加了信息广度，但增大分心的风险；中性情绪具有更理想的注意力分配模式。边缘事件发生后，中性情绪驾驶员的注意力波动较小，能继续保持稳定的观察与判断；正性情绪驾驶员能迅速将注意力转向关键区域（前车、行人）；负性情绪驾驶员对边缘事件发生的应对反应相对迟缓。

对驾驶员的注视特性指标进行分析，结果如图 6 所示。正性情绪驾驶员的注视时长较短且分布均匀，能快速获取风险信息，视觉认知负荷低，边缘事件发生后能迅速关注关键信息，决策能力稳定。中性情绪驾驶员注视时长适中，能合理分配观察时间，眼动特性和认知负荷平衡，突发事件后的反应同样较为稳定。负性情绪驾驶员在突发场景前呈现高认知负荷，表现为瞳孔扩大、注视时长延长，边缘事件发生后的认知负荷偏高，易导致认知过载，影响决策及时性和准确性。

脑电信号能有效反映驾驶员在不同情绪下的风险认知能力。图 7、图 8 分别为不同情绪状态下驾驶员的脑区图及各频率脑波功率。由图 8 可知，负性情绪的各频率脑电信号的功率显著高于中性和正性情绪。经历边缘场景时，驾驶员的应激反应导致脑波功率明显上升。负性情绪下，边缘场景前后的脑波功率维持高水平，表明风险认知负荷持续增大；正性情绪下，经历边缘场景后的脑波功率迅速恢复至正常水平甚至更低，说明正性情绪驾驶员能有效调整风险认知，有利于应对突发情况。中性情绪下，驾驶员的脑波功率较为稳定，反映出适中的风险认知能力。

根据驾驶员经历边缘场景前后的初始眼动、脑电特征变化标定驾驶员的认知因子。定义认知

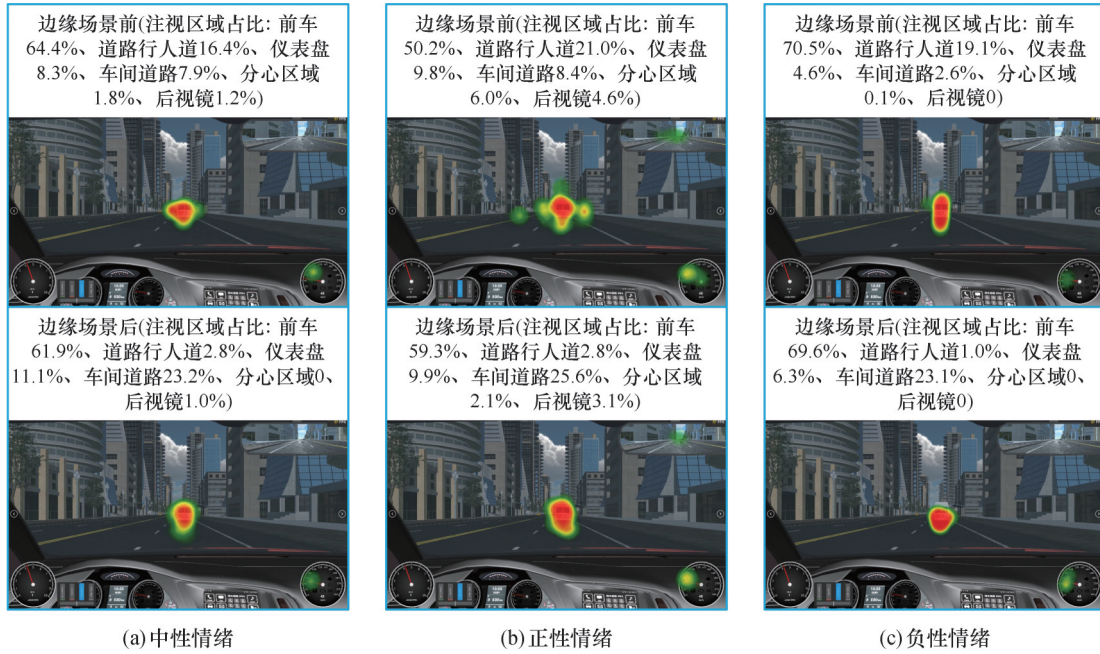


图5 不同情绪状态下驾驶员注视区热力图

Fig.5 Heat maps of the driver's gaze area under different emotional states




图6 不同情绪状态下驾驶员注视特性指标变化趋势图

Fig.6 Trend chart of driver's gaze characteristics index changes under different emotional states

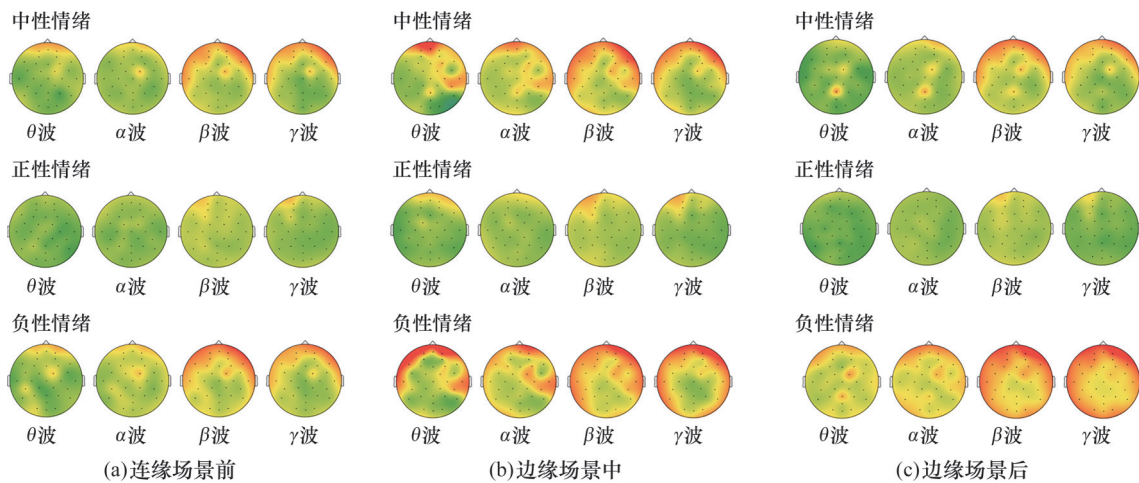


图7 不同情绪状态下驾驶员脑区图

Fig.7 Brain region maps of drivers in different emotional states

风险因子:

$$F_{\text{cognition}} = \epsilon_1 I_{\theta}^* + \epsilon_2 I_{\alpha}^* + \epsilon_3 I_{\beta}^* + \epsilon_4 I_{\gamma}^* + \epsilon_5 I_D^* + \epsilon_6 I_T^* \quad (16)$$

式中: $\epsilon_1 \sim \epsilon_6$ 为指标权重系数; I_{θ} 、 I_{α} 、 I_{β} 、 I_{γ} 分别为 θ 波、 α 波、 β 波和 γ 波的总功率; I_D 为瞳孔直径; I_T 为持续注视时间; I_w^*

为认知风险因子指标 I_w 标准化后的指标, $w = \alpha, \beta, \gamma, \theta, D, T$ 。

熵权法利用信息熵原理衡量各评价指标的离散程度, 进而确定其权重。根据熵权法获得的权重标定结果如表 2 所示。

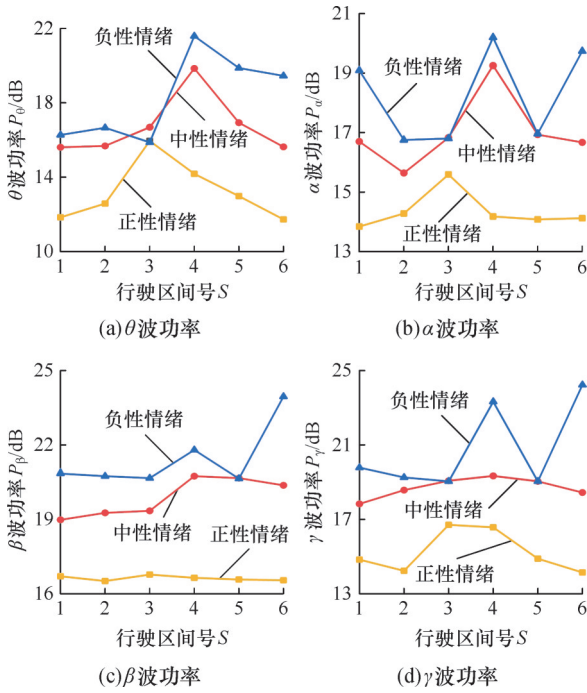


图8 不同情绪状态下驾驶员各频率脑波功率

Fig.8 The power of brain waves at different frequencies of drivers under various emotional states

表2 认知风险因子指标权重标定

Tab.2 Cognitive risk factor index weight calibration

指标	I_θ	I_α	I_β	I_γ	I_D	I_T
权重	0.0689	0.1659	0.1389	0.2436	0.1934	0.1893

12名驾驶员不同情绪下的认知因子如图9所示,驾驶员在正性情绪下有最低的认知风险,中性情绪次之,负性情绪下的驾驶员由于过高的认知负荷,对行驶过程中潜在风险的感知能力下降。

将各情绪下的平均认知风险因子作为最终的标定结果,中性、正性和负性情绪下驾驶员的认知风险因子分别为0.5129、0.4458和0.7351。

2.4.3 驾驶员驾驶能力因子

驾驶员的驾驶能力决定了遭遇突发边缘场景




图10 不同情绪状态下驾驶员心电图指标对比

Fig.10 Comparison of ECG indexes of drivers under different emotional states

正性和中性情绪下,驾驶员的RMSSD差异不显著,因此选取制动踏板行程标准差 I_{Tstd} 、速度




图9 不同情绪状态下驾驶员认知因子图

Fig.9 Cognitive factor map of drivers under different emotional states

时,能否作出正确的安全驾驶决策,直接影响行车风险。本研究选取心率均值(average heart rate, AVHR)、正常窦律RR间期的标准差(standard deviation of all normal to normal RR intervals, SDNN)、相邻RR间期差值的均方根(root mean square of successive differences between adjacent RR intervals, RMSSD)作为心电信号分析指标。

由图10可知,驾驶员在中性情绪下经历突发边缘场景前后的AVHR变化小,并能调整心率至正常范围。正性情绪下驾驶员的AVHR及其波动幅度大于中性情绪,但其心率调节能力更佳。负性情绪驾驶员在边缘场景后出现AVHR剧增且波动大的情况,表明其调节能力差,紧张程度高。具体而言,AVHR峰值在中性与正性情绪下出现于行车区间3和4,在负性情绪下延迟至区间5。同时,在区间3和4,正性与中性情绪的SDNN和RMSSD均显著大于负性情绪。这意味着中性和正性情绪下驾驶员的自主神经系统的调节功能更佳,灵活性更高,有利于降低心率和生理负荷,增强对边缘场景的适应与应对能力。

标准差 I_{std} 、加速度标准差 I_{astd} 、心率均值 I_{AVHR} 和心率变异性标准差 I_{SDNN} 作为驾驶能力指标。定义驾

驶能力因子如下：

$$F_{skill} = \sigma_1 I_{Tstd}^* + \sigma_2 I_{vstd}^* + \sigma_3 I_{astd}^* + \sigma_4 I_{AVHR}^* + \sigma_5 I_{SDNN}^* \quad (17)$$

式中： σ_s 为指标权重系数， $s=1, 2, \dots, 5$ ； I_w^* 为驾驶能力评价指标 I_w 标准化后的指标， $w=Tstd, vstd, astd, AVHR, SDNN$ 。

将能力指标进行标准化处理后，通过熵权法标定5个驾驶能力指标的权重， I_{Tstd} 、 I_{vstd} 、 I_{astd} 、 I_{AVHR} 和 I_{SDNN} 的权重分别为 0.2660、0.1011、0.1485、0.3147 和 0.169。根据驾驶能力因子分析驾驶员在不同情绪下的驾驶能力，结果如图 11 所示。中性情绪驾驶员在边缘事件触发后的驾驶能力有所下降且低于正性情绪驾驶员，但在边缘事件前后的阶段(区间 1、2、5、6)，中性情绪驾驶员的驾驶能力因子高于其他情绪状态，并在边缘事件结束后恢复至基准驾驶水平，有着最稳定的驾驶能力。




图 11 不同情绪状态下各驾驶区间驾驶员驾驶能力图
Fig.11 Driving ability of drivers in different driving ranges under different emotional states

将不同情绪下的平均驾驶能力因子作为最终的标定结果，通过综合指标计算，中性、正性和负性情绪下驾驶员的驾驶能力因子分别为 0.7586、0.6716 和 0.3843。

2.4.4 驾驶员守规因子

驾驶员对交通规则的遵守程度是决定驾驶风险的一个重要因素。本研究设定合规车速为小于等于 60 km/h，根据道路交通安全法，超速 10%~20% 给予警告，超速 20% 以上进行处罚。因此本文将超速分为轻微超速和严重超速。

由表 3 可知，3 种情绪状态下，驾驶员均因执行跟车任务而出现超速驾驶。驾驶员情绪为中性时，超速驾驶的频率为最低水平，且未出现严重超速。

驾驶员处于正性情绪时，超速频率比中性情绪时有所增加。驾驶员处于负性情绪时，超速的发生显著增多，且伴随严重超速的频繁出现。

本研究设定的驾驶员守规因子为

$$F_{laws} = 1 - (\rho_{light} + 2\rho_{serious}) \quad (18)$$

式中： ρ_{light} 为轻微超速占比； $\rho_{serious}$ 为严重超速占比。

表 3 不同情绪状态下驾驶员超速行为频数和占比

Tab.3 The frequency and proportion of speeding behavior of drivers under different emotional states

情绪状态	合规车速驾驶		轻微超速驾驶		严重超速驾驶	
	频数	占比/%	频数	占比/%	频数	占比/%
中性情绪	2893	96.40	60	2.00	48	1.60
正性情绪	2794	93.54	135	4.52	58	1.94
负性情绪	2428	82.00	448	14.93	92	3.07%

通过分析总样本中不同情绪状态下驾驶员各等级超速频数，计算得到中性、正性和负性情绪下的守规因子分别为 0.9100、0.8648 和 0.7871。

3 模型验证

3.1 综合风险场

认知风险因子与驾驶风险正相关，守规因子、驾驶能力因子与驾驶风险负相关。由于不研究各因子间的相互影响，因此设定各因子对驾驶风险的影响相同，即因子权重 $\eta_1 = \eta_2 = \eta_3 = 1$ ，同时为体现守规因子与驾驶能力因子对风险的负向影响，模型中对这两个因子进行了 $(1-F)$ 的数学变换，使其数值减小对应风险增大。将式(16)~式(18)代入式(12)、式(13)，可得不同情绪下的人因行为场：

$$E_{neutral} = 0.8443E_v \quad (19)$$

$$E_{positive} = 0.9094E_v \quad (20)$$

$$E_{negative} = 1.5637E_v \quad (21)$$

则构建的综合风险场为

$$E_a = E_b + E_s + E_v = (1 + F_b)E_v + E_s = (1 + F_b)m_c R d_i \cdot \frac{(1.566 \times 10^{-14} \sigma_c^{6.687} + 0.3345) \exp(-K_1 a \cos \theta)}{K_2 |d_i|^2} + \frac{\eta}{2} \left(\frac{d_{r_1}}{|d_{r_1}|^3} + \frac{d_{r_2}}{|d_{r_2}|^3} \right) + \sum_{i=1}^n A_i \sum_{j=1}^n \frac{d_{A_j}}{|d_{A_j}|} \exp\left(-\frac{|d_{A_j}|^2}{2\sigma^2}\right)$$

$$F_b = \begin{cases} 0.8443 & \text{中性情绪} \\ 0.9094 & \text{正性情绪} \\ 1.5637 & \text{负性情绪} \end{cases} \quad (22)$$

3.2 HF-CRF 模型有效性验证

驾驶员在不同情绪下采取的不同驾驶策略导致车辆动力学反馈指标不同。分析驾驶员在 3 种情绪状态、3 种驾驶场景下的实验数据，人因风险场能有效适配不同的驾驶员情绪状态。如图 12 所示，由于驾驶员因子的融入，中性情绪下的行驶风险范围及程度低于正性情绪与负性情绪。本文构建的 HF-CRF 模型通过综合考虑驾驶员的风险认知水平、驾驶操作能力和驾驶守规能力三个维度，可量化评估其在特定情绪下遭遇边缘场景时所面临的风险水平，从而为风险预警提供更精准的判别依据。

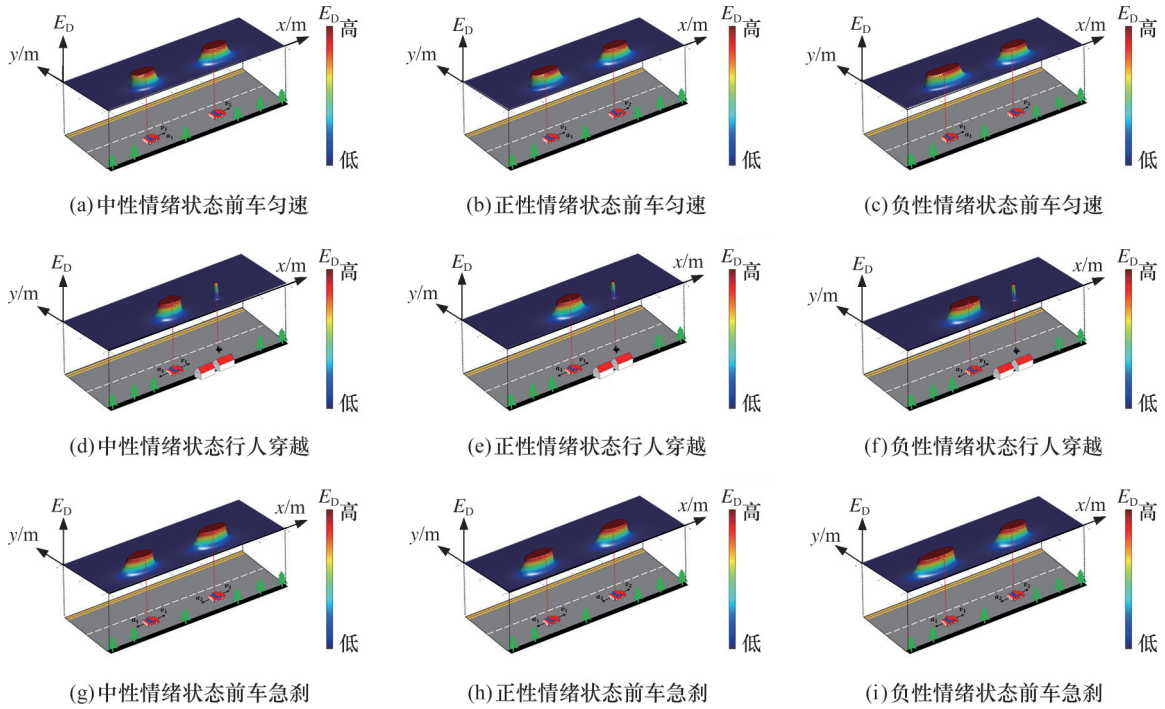

 图 12 不同情绪下 HF-CRF 三维示意图(E_D 为人因行为场场强)

 Fig.12 Three-dimensional diagram of HF-CRF under different emotions (E_D represents the field strength of the human behavior field)

负性情绪下的驾驶员有更高的认知负荷、更差的反应能力,行车风险程度更高,风险辐射范围更广。HF-CRF 模型在驾驶员处于负性情绪时,对车距减小的场强敏感性最高。行车风险超过风险阈值时,系统能缩短预警响应时间,为应对突发边缘场景时的人机交互提供更充裕的决策时间。

为验证 HF-CRF 指标在实际驾驶过程中的有效性,采用高保真六自由度驾驶模拟平台进行实验,并设计了城市道路场景下的跟驰场景,场景中前车会触发 4 次急降速的边缘事件以模拟真实风险。

汽车主动安全决策中,选取自动紧急刹车(autonomous emergency braking, AEB)系统最常用的剩余碰撞时间^[4](time to collision, TTC)、适用于跟驰安全性评估的跟车时距^[5](time headway, THW)、碰撞减速度^[6](deceleration rate to avoid a crash, DRAC)和潜在碰撞能量^[7](potential collision energy, PCE)作为对比指标。

TTC 指标的表达式为

$$I_{TTC} = -D_V / (v_k - v_{k-1}) \quad (23)$$

式中: D_V 为两车车距; v_k 为前车速度; v_{k-1} 为主车速度。跟随车与前车速度相同时,TTC 趋于无穷大。TTC 越大表示安全性越高,本文将其倒数作为风险度量指标。

THW 越大表示行驶安全性越高,因此将

THW 指标的倒数作为对比指标:

$$I_{THWI} = \frac{v_{k-1}}{D_V} \quad (24)$$

DRAC、PCE 指标越大,行驶风险越高,指标表达式分别为

$$ID_{DRAC} = \frac{(v_{k-1} - v_k)^2}{2(D_V - L)} \quad (25)$$

$$I_{PCE} = \begin{cases} (m_k v_k^2 - m_{k-1} v_{k-1}^2) / 2 & m_k v_k^2 - m_{k-1} v_{k-1}^2 > 0 \\ m_k v_k^2 / 2 & m_k v_k^2 - m_{k-1} v_{k-1}^2 \leq 0 \end{cases} \quad (26)$$

式中: L 为前车的车长, $L=4.8$ m; m_k, m_{k-1} 分别为主车和前车质量, $m_i = m_{i-1} = 1400$ kg。

驾驶过程中的上述指标变化如图 13 所示。3 种情绪状态下,主车的 HF-CRF 场强与传统风险指标的变化趋势基本一致,这验证了 HF-CRF 模型能有效反映主车在边缘场景下的行车风险及行驶状态。此外,传统风险指标在行驶全程中会出现剧烈波动或数值骤降为零的情况,而 HF-CRF 指标的变化曲线更为连续且平滑,过渡更加自然,并且在不同情绪状态下,HF-CRF 指标对风险的敏感程度存在差异,表现出更强的驾驶员适应性。

4 结论

针对人车交互中主动安全策略对驾驶员状态适应性不足的问题,构建了融合驾驶员主观因素的人因行为场模型。通过分析边缘驾驶场景下驾驶员的脑电、心电、眼动等生理信号及车辆运行数




图13 HF-CRF与各常用风险量化指标

Fig.13 HF-CRF and commonly used risk quantification indicators

据,发现驾驶过程中的不同情绪状态会引发生理指标与驾驶行为的显著差异。基于此,综合评估了驾驶员的认知能力、操作技能及交通规则遵守能力,并以此为基础,完成了对模型参数的标定。

为验证模型的有效性,利用六自由度驾驶模拟器采集了不同情绪状态下的生理与车辆数据。与多种传统风险指标相比, HF-CRF模型能更好地量化不同情绪的相关行驶风险。相较于现有的行车风险场模型, HF-CRF充分考虑了驾驶员情绪状态的个体差异性,体现出良好的情绪适应性。该模型可为智能汽车预警系统提供动态阈值设定依据,优化人车交互时机,从而减小误交互概率。

本研究在此阶段主要面向青年驾驶者,后续研究将扩展至更多年龄和职业的群体。驾驶员对车辆间的交互具有重大影响,因此实现车-车交互风险的有效预警对提升行驶安全性具有重要意义。后续研究将聚焦智能网联环境下的车-车风险场交互机制与预警系统设计,以进一步提高智能驾驶系统与混流交通系统的安全性和可靠性。

参考文献:

- [1] LIU H X, FENG Shuo. Curse of Rarity for Autonomous Vehicles[J]. Nature Communications, 2024, 15: 4808.
- [2] 杨超, 杨帆, 王伟达, 等. 基于时空风险的智能驾驶车辆避险决策规划[J]. 汽车工程, 2024, 46(6): 975-984. YANG Chao, YANG Fan, WANG Weida, et al. Risk Avoidance Decision Planning for Intelligent Driving Vehicles Based on Spatiotemporal Risk[J]. Automotive Engineering, 2024, 46(6): 975-984.
- [3] 任文浩, 赵晓华, 陈晨, 等. 网联碰撞预警信息系统对雾天高速公路驾驶行为的影响[J]. 华南理工大学学报(自然科学版), 2025, 53(2): 27-37. REN Wenhao, ZHAO Xiaohua, CHEN Chen, et al. Impact of Connected Collision Warning Information System on Freeway Driving Behavior in Foggy Conditions [J]. Journal of South China University of Technology (Natural Science Edition), 2025, 53(2): 27-37.
- [4] CHEN Di, LI Hao, JIN Zhicheng, et al. Risk-anticipatory Autonomous Driving Strategies Considering Vehicles' Weights Based on Hierarchical Deep Reinforcement Learning[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(12): 19605-19618.
- [5] 王安杰, 郑玲, 李以农, 等. 基于预测风险场的智能汽车主动避撞运动规划[J]. 汽车工程, 2021, 43(7): 1096-1104. WANG Anjie, ZHENG Ling, LI Yinong, et al. Motion Planning for Active Collision Avoidance of Intelligent Vehicles Based on Predictive Risk Field[J]. Automotive Engineering, 2021, 43(7): 1096-1104.
- [6] LI Linheng, GAN Jing, JI Xinkai, et al. Dynamic Driving Risk Potential Field Model under the Connected and Automated Vehicles Environment and Its Application in Car-following Modeling[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(1): 122-141.
- [7] CHEN Zheng, WEN Huiying. Modeling a Car-following Model with Comprehensive Safety Field in Freeway Tunnels[J]. Journal of Transportation Engineering, Part A: Systems, 2022, 148(7): 04022040.
- [8] WANG Jianqiang, WU Jian, LI Yang. The Driving Safety Field Based on Driver - Vehicle - Road Interactions[J]. IEEE Transactions on Intelligent Transportation Systems, 2015, 16(4): 2203-2214.
- [9] SONG Dongjian, ZHAO Jian, ZHU Bing, et al. Subjective Driving Risk Prediction Based on Spatiotemporal Distribution Features of Human Driver's Cognitive Risk[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(11): 16687-16703.
- [10] 李文博, 刘羽婧, 张峻铖, 等. 驾驶员情绪-驾驶风险机理分析[J]. 机械工程学报, 2022, 58(22): 379-394. LI Wenbo, LIU Yujing, ZHANG Juncheng, et al. Analysis of the Influence Mechanism of Driver's Emotion on Driving Risk [J]. Journal of Mechanical Engineering, 2022, 58(22): 379-394.
- [11] NI Jie, XIE Wanying, LIU Yiping, et al. Driver Emotion Recognition Involving Multimodal Signals: Electrophysiological Response, Nasal-tip Temperature, and Vehicle Behavior[J]. Journal of Transportation Engineering, Part A: Systems, 2024, 150: 04023125.
- [12] SCHMIDT E, DECKE R, RASSHOFER R. Correlation between Subjective Driver State Measures and Psychophysiological and Vehicular Data in Simulated Driving[C]//2016 IEEE Intelligent Vehicles Symposium (IV). Gotenburg, 2016: 1380-1385.

(下转第242页)