

基于分子力场的网联自主车辆驾驶风险量化方法

陈意成,曲大义,崔善柠,王 韬,邵德栋

(青岛理工大学 智慧交通与运载学院,山东 青岛 266520)

摘 要:网联自主车辆面临着人、车、路、环境等多维交通要素的约束,精确量化车辆在复杂交通场景的运行状态、驾驶风险程度,对提高网联自主驾驶效率与安全至关重要。针对网联自主车辆感知周围环境进行驾驶决策的自驱动粒子特性,将车车交互行为类比为分子间相互作用,运用分子间莫尔斯势能模型与车辆动力学理论,考虑驾驶安全裕度与驾驶风格的特异性,采用多层解码器-编码器长短期记忆网络进行车辆运行轨迹预测,建立车车交互行为风险量化模型;使用 SUMO 软件建立了跟驰、换道、让行三个典型驾驶行为场景,对比分析了所提方法与现有风险量化方法的后侵入时间、避免碰撞的减速率、修正碰撞时间、安全势场指标。评估结果表明,风险场量化方法具有连续量化风险的优势,能弥补传统风险指标在冲突点消失情况下评估结果间断的不足,且在半衰期参数取值合理的情况下表现出更稳定的评估性能;从分子力场角度量化评估复杂交通环境人机共驾和网联驾驶面临的风险是精确且稳定的,可为网联自主车群在混合交通流环境下的驾驶风险动态均衡控制提供理论依据。

关键词:车车交互;驾驶风险;量化方法;分子力场;网联自主车辆;混合交通流

中图分类号:U491.2

文献标志码:A

Quantification method of driving risks for networked autonomous vehicles based on molecular potential fields

CHEN Yicheng, QU Dayi, CUI Shanning, WANG Tao, SHAO Dedong

(School of Intelligent Transportation and Vehicle, Qingdao University of Technology, Qingdao 266520, China)

Abstract: Networked autonomous vehicles encounter various constraints from multidimensional traffic elements like human behavior, vehicle dynamics, and environmental factors. Precisely quantifying a vehicle's operational state in complex traffic scenarios and assessing the level of driving risk are crucial for enhancing the efficiency and safety of networked autonomous driving. In view of the self-driven particle characteristics governing the perception of surrounding environments in networked autonomous vehicles for driving decisions, an analogy is drawn between vehicle-to-vehicle interactions and molecular interactions. This involves applying a molecular Morse potential model alongside vehicle dynamics theory, considering the specificity of driving safety margins and styles. Utilizing a multi-layer decoder-encoder long and short-term memory network, vehicle trajectories are predicted and a model for quantifying risks in vehicle-to-vehicle interactions. Using SUMO software, typical driving behavior scenarios such as car-following, lane-changing, and yielding are simulated to compare and analyze the risk potential field quantification method against the existing risk quantification metrics like post encroachment time, deceleration rate to avoid crash, modified time to collision, and safety potential fields. Evaluation results show that the risk potential field quantification method provides continuous risk quantification, overcoming discontinuity issues in traditional risk metrics when conflict points disappear, and demonstrates a more stable evaluation performance when reasonable values for the half-life parameter are considered. Quantifying

收稿日期:2024-01-21

基金项目:国家自然科学基金项目(52272311)

作者简介:陈意成(1999—),男,山东东营人,博士研究生,研究方向为车路协同与安全控制。

曲大义(1973—),男,山东青岛人,教授,博士,研究方向为车路协同与安全控制,本文通信作者。

E-mail:dayiqu@qut.edu.cn

and the risks faced by human-machine co-driving and networked driving in complex traffic environments from a molecular potential field perspective is accurate and stable. This theoretical framework can provide a basis for dynamically balancing and controlling driving risks for networked autonomous vehicle fleets within mixed traffic flow environments.

Key words: vehicle-to-vehicle interaction; driving risk; quantification method; molecular potential field; networked autonomous vehicles; mixed traffic flow

交通安全始终是交通系统的重中之重。在制定防止车辆碰撞的各种对策前,需要准确评估车辆周围的潜在风险,不仅可以大大减少事故的发生,还可以提高道路的效率。一般来说,道路潜在风险评估是根据交通风险指标实现的,传统驾驶风险指标可分为三类:基于时间的风险指标、基于距离的风险指标和基于减速的指标。在实际应用中,基于时间的风险指标应用最为广泛,如碰撞时间^[1]、危险暴露时间^[2]、修正碰撞时间(modified time to collision, MTTC)^[3]等。基于距离的风险指标,如车头时距^[4]等,主要用于计算防止碰撞时的安全距离。基于减速的指标在紧急情况下根据减速率评估行驶风险,如冲突速度^[5]等。但是,此类指标仅考虑车辆的突然制动情况,无法用于评估车辆在其他驾驶条件下面临的风险,且大多基于传统驾驶环境,未被广泛使用。

近年来,基于场论的车辆交互模型因其客观性、通用性、灵活性及可解释性倍受关注。Li 等^[6]提出一种基于人工势场的简化刺激-响应汽车跟随模型,并利用 NGSIM(next generation simulation)数据集进行了验证,该模型为复杂交通环境下兼顾行车安全性的车辆控制问题提供了新的解决方向。Liu 等^[7]对车道线和联网车辆等交通因素进行建模,构建自动驾驶汽车控制模型并验证了有效性。Li 等^[8]建立了基于驾驶风险场模型理论的汽车跟踪模型,通过数值模拟验证了有效性,并据此提出一种风险感知预警策略,以降低联网自主车辆的驾驶风险。Wang 等^[9]提出一个驾驶安全电位场,用来表征驾驶员、联网车辆和道路的综合风险。秦严严等^[10]研究了网联辅助设备对混合交通流通行效率的影响。贾彦峰等^[11]结合 Lennard-Jones 势函数与安全势场,引入加速度参数,考虑车道线与道路边界的综合影响,构建了网联环境下优化的安全势场汽车跟随模型,利用上海自然驾驶实验数据集验证了模型的有效性。曲大义等^[12]从分子力场的角度,引入速度协同项,提出系统分析网联异质车群协同关系和安全态势演化规律的新思路。

现有研究,有些未在智能网联环境下进行,其模型物理性质的合理性有待进一步验证;有些研究虽然建立在智能网联环境下,但是缺乏对车辆动力学特性以及多车辆间相互作用影响的考虑。本研究基于莫尔斯分子力场理论,分析目标车辆与相邻车辆的相互作用机理,引入风险场概念,考虑不同车辆在位置、速度、加速度等因素影响下的时间、空间风险场叠加效应,提出一种针对网联混合车流环境下的可视化风险量化方法,对复杂交通环境人机共驾面临的风险进行稳定、精确评估。

1 分子力场描述与建模

分子力是指分子间的吸引力和排斥力,当分子间距小于平衡间距时分子表现出排斥力,当分子间距大于平衡间距时分子表现出吸引力,当分子间距大于逃逸间距时表现出自由状态。两车之间的交互关系与分子行为类似。物理学家菲利普-莫尔斯^[13]于 1929 年提出一种用于描述原子或分子间相互作用的势能函数,即莫尔斯(Morse)势,被广泛应用于分子光谱和分子动力学,以及分子能级的计算等领域,可表示为:

$$U(r) = D \{ [1 - \exp[-p(r - r_0)]]^2 - 1 \} \quad (1)$$

式中: $U(r)$ 为莫尔斯力场的强度, p 为可变参数, r 为分子间距离, r_0 为分子间平衡距离, D 为分子间解离能。

势函数有类似于谐振子势的双势阱形状,分子间距离一旦超过平衡距离后,势能衰减速度加快,从而能更准确地描述分子的振动现象。莫尔斯力场强随 p 与 r_0 的变化如图 1 所示。

如果车辆之间的距离达到一定值,会具有类似分子间距离的特性,且在智能网联环境下,具有获取车辆速度差、速度和加速度差等参数的条件。基于此,引入车辆间平衡距离 l_0 对应分子间平衡距离 r_0 ,使用莫尔斯势描述车辆交互风险力场,

$$l_0 = \lambda_0 (\lambda_1 - \lambda_2 \Delta v - \lambda_3 \Delta a) v_n \quad (2)$$

式中: l_0 为车辆间平衡距离, Δv 为目标车辆与待交互车辆的速度差, Δa 为目标车辆与交互车辆的加速度差, v_n 为目标车辆速度, λ_1 、 λ_2 、 λ_3 和 λ_0 分别为速度、速度差、加速度差和综合影响参数。综合式(1)和式(2),构造车辆交互场为:

$$U(l) = l_m \{ [1 - \exp[-\beta l + \lambda_0 v_n (\lambda_1 - \lambda_2 \Delta v - \lambda_3 \Delta a)]]^2 - 1 \}. \quad (3)$$

式中: l_m 为车辆最大交互距离, l 为车辆间距离, β 为场参数。

在此基础上使用梯度下降法得到目标车辆受力函数为:

$$F(l) = -\frac{dU(l)}{dl} = -2\beta l_m \{ 1 - \exp[-\beta(l-l_0)] \} \exp[-\beta(l-l_0)]. \quad (4)$$

进一步可得出目标车辆由交互力场产生的加速度为:

$$a = \frac{2\beta l_m \{ \exp[-\beta(l-l_0)] - 1 \} \exp[-\beta(l-l_0)]}{M}. \quad (5)$$

式中, M 为目标车辆质量。根据车辆交互力场推导出车辆交互潜在风险场为:

$$U_V = l_m \{ [1 - \exp[-\beta l + \lambda_0 v_n (\lambda_1 - \lambda_2 \Delta v - \lambda_3 \Delta a)]]^2 - 1 \} \cdot \omega \cdot \exp(\cos \theta). \quad (6)$$

式中: θ 为车辆速度方向与道路中心线夹角, ω 为场参数。

为融合空间与时间风险,并区分未来不同时间对于风险场的影响,引入折扣函数 $\gamma(t)$ 。折扣函数遵循半衰期原则,其函数值随着未来时间单位的变化呈指数衰减,

$$\gamma(t) = 0.5^{t/t_{0.5}}. \quad (7)$$

式中: $t_{0.5}$ 为半衰期,表示驾驶人对未来风险的重视程度,其值越大,风险场在空间范围内衰减得越慢,驾驶人越重视未来长时间的风险; t 为未来时间变量。

由式(6)和式(7)可得出车辆交互潜在时空风险场为:

$$U_r = l_m \{ [1 - \exp[-\beta l + \lambda_0 v_n (\lambda_1 - \lambda_2 \Delta v - \lambda_3 \Delta a)]]^2 - 1 \} \cdot \omega \cdot \exp(\cos \theta) \cdot (0.5)^{t/t_{0.5}}. \quad (8)$$

为更加准确地描述风险场,需要考虑每辆车的实际占用面积。如图2所示,实际占用面积不仅指车辆在道路上的物理占用面积,还包括其安全裕度范围。

Nilsson^[14]将安全裕度描述为“令驾驶员感到威胁的距离”,用于表示驾驶人感知到的车辆尺寸,其为车辆赋予的额外空间

可使驾驶人在驾驶过程中感到更加安全舒适,且能在一定程度上补偿车载、路测传感器在测量上的误差,有助于作出更加保守的风险预测。目标车辆与交互车辆的安全裕度(l_{SM})表示为:

$$l_{SM} = V_R \cdot (\tau_1 + \tau_2) + \frac{V_R^2}{2a_R} - \frac{V_F^2}{2a_F} - D_R. \quad (9)$$

式中: V_R 为目标车辆的速度, V_F 为交互车辆的速度, τ_1 为驾驶人响应时间, τ_2 为制动系统响应时间, a_R 为目标车辆的加速度, a_F 为交互车辆的加速度, D_R 为两辆车之间的相对距离。

车辆的不同运动状态以及与其他车辆的交互都会对某一时刻风险场的分布产生影响,可分三种典型场景:当车辆以一定速度自由行驶时,风险场在其安全裕度范围内达到峰值,且随着距离的增大而逐渐减小,如图3所示;当车辆处于跟驰状态时,风险势呈鞍状分布,且两车中间区域的风险场明显高于前车前方与后车后方部分,如图4所示;当车辆处于换道状态时,风险场沿着车辆前进方向叠加,但依然分别在其安




图1 莫尔斯力场变化趋势

Fig. 1 Trends in Morse potential field




图2 车辆运行安全裕度辐射范围

Fig. 2 Radiation range of safety margin for vehicle operation

全裕度范围内达到峰值,如图 5 所示。




图 3 车辆自由行驶风险场分布

Fig. 3 Distribution of risk fields for vehicle free travel




图 4 车辆跟驰驾驶风险场分布

Fig. 4 Distribution of risk fields for vehicle-following driving




图 5 车辆换道行为风险场分布

Fig. 5 Distribution of risk fields for vehicle lane-changing behavior

2 车辆运行轨迹预测模型

前文描述了风险场的理论作用机理,考虑到驾驶员异质性对风险场的影响,应用深度学习神经网络预测车辆的短期未来位置,综合多维度因素构建车辆轨迹风险场。

2.1 输入与输出

预测模型的输入和输出分别为 X 与 Y ,如式(10)所示, T_h 和 τ 分别表示输入的观测时间与输出的预测时间范围。在输入过程中,以步长为 0.1 s 记录车辆的位置、速度、加速度、转向角等参数,直到观测时间 T_h 停止;在预测过程中,依然以步长为 0.1 s 预测车辆行驶参数,直到预测时间 τ 停止。

$$\begin{cases} X = X_{t-T_h}, X_{t-T_h+1}, \dots, X_t; \\ Y = Y_{t+j}, j = 1, 2, \dots, \tau; \end{cases} \quad (10)$$

$$\begin{cases} X_t = [x_{t-p}^k, y_{t-p}^k], k \in [1, 2, \dots, N], p \in [0, 1, 2, \dots, T_h]; \\ Y_{t+j} = [x_{t+q}^k, y_{t+q}^k], k \in [1, 2, \dots, N], q \in [0, 1, 2, \dots, \tau]. \end{cases} \quad (11)$$

式中: X_t 表示输入范围及其维度,即 $T_h \times 2 \times N$ (T_h 个步长 $\times xy$ 坐标维数 $\times$ 车辆数量), Y_{t+j} 表示输出范围及其维度,即 $\tau \times 2 \times N$ (τ 个步长 $\times xy$ 坐标维数 $\times$ 车辆数量)。

2.2 深度学习 EDLN 模型

多层解码器-编码器长短期记忆网络(encoder-decoder long short-term memory network, EDLN)作为一种长短期记忆神经网络(long short-term memory neural network, LSTM)的变体,Ettinger 等^[15]已经证明可有效提取复杂场景中的轨迹特征。因此选择 EDLN 作为预测模型的基础,主要分为三部分:编码器、解码器和混合密度层,如图 6 所示。EDLN 的编码器和解码器由具有相同结构和权重的 LSTM 堆栈组成,编码器先将历史轨迹数据转换为桥接向量,储存交互车辆的行为特征,解码器然后通过桥接向量的编码特征输出车辆的 x 、 y 坐标向量,最后由混合密度层输出车辆的预测分布。




图 6 深度学习预测模型流程图

Fig. 6 Flowchart of deep learning predictive modeling

考虑到预测性能,模型使用两层 LTSM,共 512 个神经元,初始学习率设置为 0.001,混合密度层内高斯分布种类设置为 6。由于评估预测模型对于确定其有效性和可靠性至关重要,当验证损失在 5 个时期内没有改善时,将学习率降低一半。为了防止过度拟合,当验证损失在 10 个周期内没有改善时,停止训练,保存训练后的模型。

3 数据处理与仿真实验设置

实验采用美国中佛罗里达大学智能交通安全实验室的 CitySim 数据集^[16],经过车辆轨迹可视化分析后发现,Expressway A 城市快速路交织区段数据具有车辆跟驰、车辆换等驾驶行为集中分布的特点。为使本方法有效量化处于复杂交通环境下车辆的多种交互行为风险,选择该区段数据用于验证轨迹预测模型的准确性和风险量化方法的有效性。考虑到设备的运算能力,将输入观测时间 T_h 设置为 1 s,预测时

间范围 τ 设置为 6 s, 风险场半衰期 $t_{0.5}$ 设置为 0.5 s。

3.1 数据处理

由于原始的 CitySim 数据集中存在噪声数据(速度与加速度的突变),如图 7 中灰色区域,可能导致异常的车辆轨迹,故在数据处理过程中过滤掉超出加速度阈值的异常加速度数据。当原始数据加速度超过阈值时,使用线形插值对两个相邻的数据点进行去噪处理,并采用持续时间为 0.5 s 的移动平均滤波器来减轻随机噪声的影响。经过去噪处理的数据如图 7 中虚线所示。




图 7 原始数据与去噪数据比较分析

Fig. 7 Comparative analysis of raw data and denoised data

3.2 仿真实验设置

为明确实验对象与实验范围,建立一个至多由 7 辆车组成的参考坐标系,目标车辆坐标为(0,0),交互车辆选取范围为:车辆中心点位于 $X(-10,10)$, $Y(-20,80)$ 组成的矩形内。目标车辆标记为 SV,前车标记为 L,后方车辆标记为 F,目标车辆所在车道标记为 1,左侧车道标记为 0,右侧车道标记为 2。以目标车辆为参考点,周围至多 6 辆交互车辆组成的系统,每隔 0.1 s 的位置记录,定义为一次观测,并且过滤非交互车辆的观测值。

在对 CitySim 数据集 Expressway A 部分区段进行 10 min 的连续记录后,选取 12 284 个观测数据记录,经过处理后将其分为两组,其中 80% 作为训练集用于训练深度学习轨迹预测模型,20% 作为测试集。

在设置测试场景过程中,使用 SUMO 软件建立跟驰、换道 2 个典型场景以评价所提风险量化模型的适用性。在跟驰场景中,如图 8(a) 所示,目标车辆位于交互车辆后方,且保持同车道行驶,存在纵向冲突风险;在换道场景中,如图 8(b) 所示,目标车辆位于交互车辆前方相邻车道,自本车道驶向交互车辆所在车道,同时存在横向冲突与纵向冲突风险。




图 8 SUMO 测试场景

Fig. 8 SUMO Test Scenarios

4 风险量化方法评估

使用莫尔斯势风险量化模型,对不同驾驶场景中交互车辆风险场强度(morse risk field, MRF)进行固定间隔的连续计算。由于篇幅原因,选取其中1次涉及目标车辆与其他6辆交互车辆的6 s换道场景作详细展示,如图9所示。在整个过程中,目标车辆从左侧车道移动到中间车道(图9(b)),并与其他6辆交互车辆产生冲突(图9(c)),当目标车辆完成换道操作后,进入跟驰状态(图9(d))。图9(a)描述了各车辆风险场强度的变化过程,为了清楚地展示并区分每辆车的风险场,在图9(b)~9(d)展示了交互车辆前方区域的风险场与目标车辆前后区域的风险场,并对风险强度较高的区域着重标注。




图9 预测范围内目标车辆与交互车风险场变化对比分析

Fig. 9 Comparative analysis of target vehicle and interacting vehicle risk field changes in the forecast horizon

现有的风险量化指标主要针对具有冲突点的单一驾驶情况进行评估,对于风险由目标车辆与两辆或多辆交互车辆共同形成的情况,传统的风险量化指标未能对其进行有效评估。因此,本研究将 MRF 与基于冲突点的传统风险量化指标后侵入时间(post encroachment time, PET)、修正碰撞时间(MTTC)、避免碰撞的减速率(deceleration rate to avoid crash, DRAC),以及同样基于场论的安全势场(safety potential field, SPF)进行对比分析,结果如图10所示。

如图10(a)所示,当目标车辆在1 s时开始变道,其 MRF 开始逐渐提高,并且在前方与交互车辆(L0、L1、L2)形成冲突点之前可以连续量化相关风险。目标车辆在1~4 s换道过程中 MRF 未出现较大的变化,在第4 s换道完成后进入跟驰状态。由于目标车辆与 L1 发生纵向碰撞的风险较大, MRF 仍然保持在较高水平。

在图10(b)~10(d)中,使用标记点表示车辆轨迹冲突点出现时刻与消失时刻,由于传统基于冲突点




图 10 各风险量化指标分析结果

Fig. 10 Analysis results of quantitative indicators for each risk

的风险量化指标只有在车辆预测轨迹出现冲突点时才能正常地评估风险,在前车速度高于后车的情况下,传统风险量化指标不能对整个车辆行驶过程进行连续的风险评估。如图 10(b)所示,在目标车辆完成换道操作之前,PET 仅能评估与位于原始车道上的两辆交互车辆(L0、F0)有关的风险值,在目标车辆完成换道操作后,其仅能评估与位于目标车道上的两辆交互车辆(L1、F1)有关的风险值。

当前车速度高于后车速度时,如图 10(c)~10(d)所示,MTTC 与 DRAC 指标同样也存在缺陷。在跟驰情况下,两辆车之间的车头间距与速度差可能同时较小,如果前车突然减速,后车将没有机会通过减速或者换道来规避碰撞风险。因此,在上述情况下,基于场论的莫尔斯场风险量化方法具有连续量化风险的优势,弥补基于冲突点的传统风险指标存在的不足。

将本方法与同样基于场论的安全势场进行对比,如图 10(a)与图 10(e),SPF 整体变化趋势与 MRF

基本一致,但 SPF 在第 3 s(目标车辆换道过程中)、第 4 s(换道状态与跟驰状态切换时)出现两个较大的波动。前者可能是由于其考虑了车道线的影响,目标车辆在跨越车道线前后的风险存在一定的差异;后者可能是由于 SPF 仅探究了空间距离对于场的影响,未考虑到场随着时间衰减的过程。而莫尔斯场风险量化方法引入半衰期参量($t_{0.5}$),使其可以结合时间和空间两个维度,让风险量化结果更符合客观实际。

半衰期参量表示驾驶人对未来风险的重视程度,其取值的合理性十分重要,取值过小可能导致对于交互车辆产生风险场的敏感度降低,而取值过大会导致风险场大面积地分布在道路上,增加了程序运算负担,但又未对风险量化精度产生明显的提高。图 11 对比了两种半衰期参数取值下的风险场情况。




图 11 半衰期参数对于风险势场的影响

Fig. 11 Effect of half-life parameters on the risk potential field

如图 11(a)所示,在 $t_{0.5} = 0.25$ s 时,风险场的评估范围仅覆盖目标车辆前后共计约 30 m 范围,此时驾驶风格较为激进的驾驶人可能由于与前车缺乏足够的停车距离而陷入较为危险的状况。相比之下,当 $t_{0.5} = 0.50$ s 时,如图 11(b)所示,车辆的风险场范围明显大于上一种情况,且冲突风险场的覆盖范围、强度也较前者更广、更强,偏向更加保守的驾驶风格。

5 结论

运用莫尔斯分子力场理论,分析了目标车辆与相邻车辆的相互作用关系及内在机理,引入风险场概念,考虑不同车辆在位置、速度、加速度等因素影响下的时间、空间风险场叠加效应,提出一种针对网联混合车流环境下的可视化风险量化方法。

1) 提出的风险量化方法可用于同车道、跨车道车辆的各种交互行为(跟驰与换道等),并通过连续的驾驶风险评估,确保风险评估结果在驾驶行为切换的起始与末尾柔性变化,实时评估目标车辆面临的危险。

2) 定量计算及可视化分析目标车辆与交互车辆产生的风险场,将提出的 MRF 指标与 PET、MTTC、DRAC、SPF 进行对比分析发现,该指标可以弥补传统风险量化指标在冲突点缺失情况下量化结果中断的不足,且引入了半衰期参数,可以在较为保守和较为激进的驾驶风格间切换,动态评估不同风格驾驶人的驾驶风险。

3) 考虑本方法在更加复杂的交通场景下的适用性,以及道路宽度、曲率、坡度等造成的影响,可建立一个系统性、多维度、全方面的驾驶风险量化体系,为智能网联混合流中的网联自主车辆提供更加安全可靠的驾驶行驶环境。

参考文献:

- [1] 鲍志强, 邹岚, 翟伟. 平面交叉口右转车与行人时空布局优化研究[J]. 森林工程, 2022, 38(6): 156-163.
BAO Zhiqiang, WU Lan, ZHAI Wei. Research on space-time layout optimization of right-turning vehicles and pedestrians at level intersection[J]. Forest Engineering, 2022, 38(6): 156-163.
- [2] MINDERHOUD M M, BOVY P H L. Extended time-to-collision measures for road traffic safety assessment[J]. Accident Analysis and Prevention, 2001, 33(1): 89-97.
- [3] ZHENG L, SAYED T, ESSA M. Validating the bivariate extreme value modeling approach for road safety estimation with different traffic conflict indicators[J]. Accident Analysis and Prevention, 2019, 123: 314-323.
- [4] MICHAEL P G, LEEMING F C, DWYER W O. Headway on urban streets: Observational data and an intervention to decrease tailgating[J]. Transportation Research Part F: Traffic Psychology and Behaviour, 2000, 3(2): 55-64.
- [5] 牟瑞芳, 王春勤. 基于云理论的人车冲突严重度研究[J]. 长安大学学报(自然科学版), 2019, 39(6): 99-107.
MOU Ruifang, WANG Chunqin. Study on pedestrian-vehicle conflict severity grade based on cloud theory[J]. Journal of Chang'an University (Natural Science Edition), 2019, 39(6): 99-107.
- [6] LI C G, JIANG X B, WANG W B, et al. A simplified car-following model based on the artificial potential field[J]. Procedia Engineering, 2016, 137: 13-20.
- [7] LIU W, LI Z H. Comprehensive predictive control method for automated vehicles in dynamic traffic circumstances[J]. IET Intelligent Transport Systems, 2018, 12(10): 1455-1463.
- [8] LI L H, JING G, JI X K, 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, 2020, 23(1): 122-141.
- [9] WANG J Q, 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.
- [10] 秦严严, 唐鸿辉, 李淑庆, 等. 考虑网联辅助驾驶设备影响的混合交通流通行能力分析[J]. 山东科技大学学报(自然科学版), 2023, 42(3): 120-128.
QIN Yanyan, TANG Honghui, LI Shuqing, et al. Capacity analysis of mixed traffic flow considering the influence of connected auxiliary driving equipment[J]. Journal of Shandong University of Science and Technology(Natural Science), 2023, 42(3): 120-128.
- [11] 贾彦峰, 曲大义, 赵梓旭, 等. 基于安全势场的网联自主车辆跟驰行为决策及模型[J]. 交通运输系统工程与信息, 2022, 22(1): 85-97.
JIA Yanfeng, QU Dayi, ZHAO Zixu, et al. Car-following decision-making and model for connected and autonomous vehicles based on safety potential field[J]. Journal of Transportation Systems Engineering and Information Technology, 2022, 22(1): 85-97.
- [12] 曲大义, 孟奕名, 王韬, 等. 基于分子力场的网联自主车辆跟驰安全特性及模型[J]. 交通运输系统工程与信息, 2023, 23(6): 33-41.
QU Dayi, MENG Yiming, WANG Tao, et al. Car-following model and safety characteristics of connected autonomous vehicle based on molecular force field[J]. Journal of Transportation Systems Engineering and Information Technology, 2023, 23(6): 33-41.
- [13] MORSE P M. Diatomic molecules according to the wave mechanics. II. Vibrational levels[J]. Physical Review, 1929, 34(1): 57-64.
- [14] NILSSON R. Safety margins in the driver[D]. Uppsala: Uppsala University, 2001.
- [15] ETTINGER S, CHENG S Y, CAINE B, et al. Large scale interactive motion forecasting for autonomous driving: The Waymo open motion dataset[C]//Proceedings of the IEEE International Conference on Computer Vision. IEEE Computer Society, 2021: 9690-9699.
- [16] ZHENG O, ABDEL-ATY M, YUE L, et al. CitySim: A drone-based vehicle trajectory dataset for safety-oriented research and digital twins[J]. Transportation Research Record, 2024, 2678(4): 606-621.

(责任编辑: 齐敏华)