

基于能耗预测的网联电动公交车 生态驾驶优化策略*

潘应久, 郝毅, 刘延森, 房文鹏, 张文珊
(长安大学汽车学院, 西安 710018)

[摘要] 电动公交车的动力系统及能耗特性与传统内燃机公交车存在显著差异,传统公交车的节能驾驶策略并不完全适用于电动公交车。本文综合考虑电动公交车经过信号交叉口时的信号配时、前车信息能耗特性和乘客舒适性,提出一种基于能耗预测的网联电动公交车生态驾驶深度强化学习模型。首先,采集纯电动公交车自然驾驶数据,考虑电动公交车的制动能量回收特性,利用车辆动力学建立能耗基本模型,构建系统辨识模型对能耗基本模型中的未知参数进行辨识和估计;其次,剖析车辆进出信号交叉口时不同信号相位对速度模式的影响,确定能够精确描述交通环境信息的状态变量,以构建的能耗模型为基础,综合考虑安全、效率、节能和舒适性构建奖励函数,基于SAC(soft actor critic)算法构建电动公交车进出信号交叉口的生态驾驶策略优化模型;最后,将本文构建的生态驾驶策略与经典交叉口通行策略GLOSA进行对比验证。结果表明,本文提出的生态驾驶策略在划分的4种交通情境下均可保证车辆的安全性,在通行时间平均仅增长7.29%的情况下,舒适性平均提高21.96%,能耗平均降低24.47%。

关键词: 生态驾驶策略;网联电动公交车;深度强化学习;乘客舒适性;能耗预测;信号交叉口

An Energy Consumption Prediction-Based Optimization Strategy for Eco-driving of Connected Electric Buses

Pan Yingjiu, Xi Yi, Liu Yansen, Fang Wenpeng & Zhang Wenshan

School of Automobile, Chang'an University, Xi'an 710018

[Abstract] The power system and energy consumption characteristics of electric buses significantly differ from those of traditional buses with internal combustion engines, and conventional eco-driving strategies cannot fully adapt to electric buses. An energy consumption prediction-based deep reinforcement learning model is proposed for eco-driving of connected electric buses, taking into account of signal timing, information from preceding vehicles, energy consumption characteristics and comfort of passengers. Firstly, natural driving data from battery electric buses is collected, and a basic energy consumption model is established using vehicle dynamics, considering the regenerative braking characteristics of electric buses. A system identification model is then constructed to identify and estimate the unknown parameters in the basic energy consumption model. Next, the impact of different signal phases on speed patterns when entering and exiting signalized intersections is analyzed, and state variables that accurately describe traffic environment information are determined. Based on the constructed energy consumption model, a reward function is developed, considering safety, efficiency, energy conservation, and comfort. An optimization model for eco-driving strategies at signalized intersections for electric buses is established using the SAC (soft actor critic) algorithm. Finally, the proposed strategy is compared with the classic intersection passage strategy

* 国家自然科学基金(52402417)、陕西省自然科学基金基础研究计划项目(2023-JC-QN-0385)和长安大学中央高校基本科研业务专项资金(300102223107)资助。

原稿收到日期为2024年10月16日,修改稿收到日期为2024年12月19日。

通信作者:张文珊,高级工程师,工学博士,E-mail: zhangwenshan@chd.edu.cn。

GLOSA. The results show that the proposed eco-driving strategy ensures vehicle safety across the four defined traffic scenarios. Despite an average increase in travel time of only 7.29%, the strategy enhances comfort by an average of 21.96% and reduces energy consumption by an average of 24.47%.

Keywords: eco-driving strategy; connected electric bus; deep reinforcement learning; passenger comfort; energy consumption prediction; signalized intersection

前言

电动公交车因其低噪声、低污染等特性逐渐成为城市公交系统的首推车型,但是电动公交车因目前电池技术导致续航里程有限,提高其能耗利用率成为该领域的研究热点。由于电动公交车的动力系统及能耗特性与传统内燃机公交车存在显著差异,传统公交车的节能驾驶策略并不完全适用于电动公交车。因此,有必要针对电动公交车节能驾驶特性和生态驾驶策略开展深入研究。

网联技术的发展为生态驾驶策略的精确控制提供了基础条件,车辆基于V2X(vehicle to everything)车联网系统可提前获取前车信息及道路交通环境信息,这为动态更新节能驾驶策略提供了有力保障^[1-2]。这种保障尤其适用于信号交叉口区域,相关学者利用V2I提供信号相位与配时(SpAT)信息,针对交叉口处的生态通行策略开展了大量研究^[3-7]。较为经典的交叉口策略应用是绿灯车速引导策略(green light optimal speed advisory, GLOSA)^[8],该策略根据信号灯SpAT和道路限速信息,通过控制车辆在红灯相位减速行驶,减少了车辆的停车次数,提高了车辆的能源利用效率。陈欣宇等^[9]提出了一种考虑时变时延的鲁棒模型预测控制方法,建立了车队的时滞离散模型,对安全性、燃油经济性和交通流畅性进行了优化。袁伟等^[10]将信号灯剩余时长区间划分为6种情境,利用运动学公式分别设计了6种情境下的电动公交车的节能行驶策略,降低了电动公交车在交叉口路段的能源消耗。钱立军等^[11]提出了一种分层生态驾驶控制方法,上层控制器以实现车队机动性、燃油经济性和舒适性为优化目标,下层控制器采用自适应等效燃油消耗最小化策略优化车辆发动机与电池的功率分配。仿真结果表明,车辆平均油耗降低了2.82%。刘显贵等^[12]以能耗、排放和通行时间为优化目标,基于遗传算法设计了生态驾驶推荐车速。钱立军等^[13]以最小化整个车队的燃油消耗为研究目标,采用快速随机模型预测控制算法求

解车队中网联汽车的最优速度轨迹,降低了整个车队的能耗。上述研究多采取基于规则与优化的策略,虽然可以有效节省车辆能耗,但仍存在不足之处,如很难考虑到周围车辆的动态变化、容易陷入局部最优解、状态与约束条件过多使模型复杂导致无法进行数值求解和因计算量庞大而导致实时性较差等。因此需要一种能满足实时性和动态性的策略。

近年来,深度强化学习(deep reinforcement learning, DRL)等基于学习的策略在交通系统优化方面引起了广泛关注。DRL将车辆视为智能体,智能体不断与环境进行交互,最终会选择出最佳动作,以获得最大化的期望奖励,这一过程通常具备实时性,智能体可根据环境的即时反馈迅速调整其行为策略,DRL利用深度神经网络,能在高维状态空间中近似最优控制策略,有效应对各种控制任务。Shi等^[14]将二氧化碳的排放量作为奖励值,利用Q-learning算法优化车辆的CO₂排放。Q-learning算法是基于值的强化学习算法,不能在连续的状态空间下控制车辆,容易出现局部最优。Lian等^[15]提出基于深度确定性策略梯度(DDPG)算法来优化混合动力汽车(HEV)的能耗,使车辆获得了更好的能源经济性。庄伟超等^[16]使用DDPG算法,对电动汽车在信号交叉口的加速度进行训练,使车辆在单路口和多路口场景下均能提高能量效率和通行效率。Bai等^[17]提出了一种混合强化学习框架,该框架将基于规则的策略和深度强化学习相结合,该方法与最先进的基于模型的生态驾驶方法相比,可以减少12.70%的能耗,节省11.75%的旅行时间。Li等^[18]以燃油经济性、驾驶安全性、行驶效率为优化目标,设计了一种基于双延迟深度确定性策略梯度(TD3)算法的生态驾驶控制策略,在满足交通信号灯和安全规则约束的情况下,实现了油耗的显著下降。辛琪等^[19]采用TD3优化智能网联车辆接近信号交叉口的车速轨迹,实现了车辆不停车通过交叉口,显著降低了车辆的交叉口等待时间与能量消耗。Zhou等^[20]将DQN算法与DDPG算法相结合,在不增加通行时间的前提下,将能耗提升了46%。张建等^[21]利

用 GLOSA 系统产生的车辆行驶数据,基于 BCQ (batch-constrained deep Q-learning) 算法进行训练,仿真结果表明,在单交叉口与多交叉口情景中,能耗经济性可以分别提升 25.14% 和 11.49%。李捷等^[22]基于 TD3 算法提出了考虑驾驶安全、能耗经济性、舒适性和行驶效率的多目标生态驾驶策略。Wegener 等^[23]提出了一种基于 TD3 的连续控制策略,与模拟人类驾驶员和 GLOSA 算法相比,分别减少了 19% 和 11% 的能耗。

上述研究为生态驾驶优化策略提供了重要的思路以及技术支持,但仍有许多难点亟待进一步突破。首先,近年来国内外学者已开始针对电动汽车和电动公交车的生态驾驶策略展开研究,积累了一定的研究经验和研究成果^[3],但当前研究大多以仿真软件中的通用能耗模型为基础构建优化目标函数^[16,19-23],忽略了不同电动车辆的配置特征和交通条件对能耗特性的影响,较难保证优化策略的精确性;其次,大多优化模型的优化车速轨迹存在多处急减速行为,对于电动公交车而言,过多急加速/减速会导致站立乘客质心不稳甚至摔倒,虽然在部分研究^[16,19-20]中针对加速度设计了奖励函数,车辆加速度变化大多数处于较低范围内,但从车速轨迹来看,存在多处急减速行为,大大降低乘客舒适性。

为解决上述问题,本文通过实测电动公交车的自然驾驶数据,首次提出利用自车运行过程中的实际能耗数据标定能耗模型的未知参数,以标定的能耗预测模型为基础构建生态驾驶优化目标函数,由此保证能耗预测的准确性和能耗优化的可靠性;基于构建的优化目标奖励函数,重点考虑“低能耗+高舒适”耦合的优化目标,利用 SAC (soft actor critic) 算法建立电动公交车在进出信号交叉口过程中的生态驾驶优化策略,最后利用经典交叉口通行策略 GLOSA 对本文提出策略的有效性进行对比验证。

1 电动公交车能耗预测模型

精确的能耗模型是构建生态驾驶策略的基础^[24],现有的研究大多采用通用的能耗模型^[16,19-23],未充分考虑车辆个体特征带来的差异,降低了生态驾驶策略的准确性。鉴于此,本文利用自然驾驶实测数据,结合车辆动力学和系统辨识方法构建具有自适应参数学习能力的能耗预测模型。

1.1 电动公交车自然驾驶数据采集实验

本文设计实验采集了广州市 24 辆不同品牌、车

型、线路的电动公交车自然驾驶数据,包括速度、经纬度坐标、行驶里程、总电流、总电压等各种参数,数据采集精度为 6 Hz,总数据量达到 7 538 489 条,数据参数说明如表 1 所示。为保证数据的精确性,本试验同时采用两种方式采集车辆的位置和速度数据。一是利用高精度定位装置 VBOX 采集公交车的位置相关数据,如图 1 所示;二是通过访问控制局域网 (CAN) 总线获取车辆的位置、速度、电池及电机相关数据,最后利用插值和加权平均的方法对两种来源的数据进行数据对齐与融合,得到精确度较高的电动公交车自然驾驶数据集。

表 1 数据参数说明

参数	数据描述	实例
记录日期	记录日期	2022-09-07 07:39:25.472
经度	公交车所处位置的经度	113.3663
纬度	公交车所处位置的纬度	22.92088
车速/(km·h ⁻¹)	公交车实时车速	20.42857
电压/V	电池电压	596
电流/A	电池电流	18.5
CAN 里程/km	公交车累计里程	254779.3



图 1 采集设备的安装位置

1.2 基于车辆动力学的能耗基本模型

基于车辆动力学理论,电动公交车在纵向行驶过程中须克服滚动阻力、坡道阻力、加速阻力和空气阻力,计算公式为

$$F_t = F_f + F_i + F_w + F_j = \mu mg \cos \alpha + mg \sin \alpha + \frac{1}{2} \rho A C_D v^2 + \delta m a \quad (1)$$

式中: F_t 表示电动公交车纵向牵引力; F_f 表示滚动阻力; F_i 表示坡度阻力; F_w 表示空气阻力; F_j 表示线性加速阻力; m 表示公交车质量; v 表示车辆行驶速度; a 表示车辆加速度; μ 表示滚动阻力系数; α 表示道路坡度; g 表示重力加速度; C_D 表示空气阻力系数; A 表示车辆迎风面积; ρ 表示空气密度; δ 表示旋转质量的转换因子。

公交车的瞬时输出功率可以表示为

$$P_t = F_t v = \frac{v}{3600\eta_i\eta_m\eta_{ess}} \cdot (\mu mg \cos \alpha + mg \sin \alpha + \frac{1}{2} \rho AC_D v^2 + \delta ma) \quad (2)$$

式中： η_m 表示电机效率； η_i 表示机械传动效率； η_{ess} 表示逆变器传动效率。

式(2)中，公交车的速度和加速度可直接测量获得，车辆总质量、电机效率、机械传动效率、逆变器传动效率等参数与车辆配置特性有关，在进行能耗预测时难以获取。将这些难以获取的参数进行提取，可得：

$$P_t = \frac{\mu mg \cos \alpha + mg \sin \alpha}{3600\eta_i\eta_m\eta_{ess}} v + \frac{\rho AC_D}{7200\eta_i\eta_m\eta_{ess}} v^3 + \frac{\delta m}{3600\eta_i\eta_m\eta_{ess}} av \quad (3)$$

由式(3)可得一个关于速度和加速度的多项式：

$$\widehat{P}_t = \theta_1 v + \theta_2 v^3 + \theta_3 av + \theta_4 \quad (4)$$

式中： θ_1 、 θ_2 、 θ_3 为待估计的多项式系数； θ_4 为常数项，表示公交车上其他电器的功率。

考虑到电动公交车的制动能量回收特性，将公交车的运行工况划分为加速、匀速和减速3种。由于本文采用的是电动公交车自然驾驶真实数据，在实际运行中很少能达到理想的匀速行驶。因此，将瞬时加速度绝对值小于 $0.15 \text{ m} \cdot \text{s}^{-2}$ 视做匀速行驶，构建的能耗基本模型如下：

$$\widehat{P}_t = \begin{cases} \theta_{11}v + \theta_{21}v^3 + \theta_{31}av + \theta_{41}, & a > 0.15 \text{ m/s}^2 \\ \theta_{12}v + \theta_{22}v^3 + \theta_{42}, & -0.15 \text{ m/s}^2 \leq a \leq 0.15 \text{ m/s}^2 \\ \theta_{13}v + \theta_{23}v^3 + \theta_{33}av + \theta_{43}, & a < -0.15 \text{ m/s}^2 \end{cases} \quad (5)$$

式中 \widehat{P}_t 表示 t 时刻瞬时功率的预测值。

1.3 基于系统辨识的能耗预测

在1.2节构建的能耗基本模型中， $\theta_{ij}(i=1, 2, 3, 4; j=1, 2, 3)$ 为未知参数，须利用实测数据对其进行估计。参考本团队的相关研究成果^[25]，利用最小二乘系统辨识法对3种工况下的模型参数进行估计。通过辨识得到的参数 $\theta_{ij}(i=1, 2, 3, 4; j=1, 2, 3)$ 标定能耗预测的未知参数，并以此对新的数据集进行预测。预测结果如图2所示，可以初步看出预测的瞬时功率曲线与实际功率曲线较接近，模型效果良好。

为更加客观地评价模型预测的准确性，采用行程累计能耗作为衡量电动公交车能耗预测精度的指标，行程累计能耗的计算方法如式(6)所示。

$$W(t) = \sum_{i=1}^T P_i \Delta t \quad (6)$$

式中： $W(t)$ 为 t 时刻车辆的累计能耗； Δt 为时间间隔； T 表示行程总时间。




图2 累计能耗预测值与真实值对比

使用平均绝对误差(MAE)、均方误差(MSE)、均方根误差(RMSE)、平均绝对百分比误差(MAPE)和决定系数(R^2)等5个常用的回归模型评价指标进一步衡量模型的预测效果，结果如表2所示。其中，MAPE达到4.962%， R^2 值为0.993，表明本文构建的能耗预测模型能够精确预测电动公交车的能量消耗。

表2 回归模型评价指标计算结果

评价指标	MSE	MAE	RMSE	MAPE	R^2
数值	4.253	1.797	2.062	4.962%	0.993

2 信号交叉口电动公交车经济性通行问题

2.1 问题描述

在智能网联条件下，电动公交车具有与交叉口的信号灯及周边车辆通信和数据传输的能力。在通信范围内，车辆获取交叉口SPaT和动态交通环境信息，利用生态驾驶策略算法优化行驶速度谱，从而实现车辆以一种低能耗、高效率的车速轨迹通过信号交叉口，最大可能地避免在信号交叉口停车等待。

本文所设定的具体场景如图3所示。假定信号交叉口通信范围为 l ，电动公交车在 t_0 时刻以车速 v_i 进入信号交叉口的通信范围，此时车辆可获取交叉口SPaT、道路限速、跟车距离、前车速度等信息，根据这些动态交通信息，利用本文提出的生态驾驶优化算法来实时计算出兼顾车辆能耗、安全、通行效率

及舒适性的最优车速轨迹,使车辆以最优驾驶模式在 t_s 时刻通过路口停车线,最终在 t_f 时刻离开交叉口。




图3 网联公交车信号交叉口生态驾驶场景

2.2 最优控制模型构建

电动公交车行驶过程中,须考虑前方信号灯约束、前方车辆约束、速度限制约束等多种约束条件。本文的研究目标是从电动公交车进入交叉口信号通信范围到车辆通过交叉口的过程中,结合信号交叉口 SPaT 和动态交通环境信息,使车辆在满足道路约

束的前提下,以能耗最低的行驶模式通过交叉口,根据最优控制原理建立如下优化模型:

$$\min J(x(t), a(t)) = T + P_b + N_{\text{light}} + N_{\text{collision}} + v_{\text{limit}} \quad (7)$$

式中: $x(t)$ 表示 t 时刻车辆的位置; $a(t)$ 表示 t 时刻车辆的加速度; T 表示通行时间; $P_b(t)$ 表示车辆的瞬时功率; N_{light} 表示闯红灯; $N_{\text{collision}}$ 表示碰撞前车; v_{limit} 表示超过速度限制。

本文拟采用深度强化学习算法求解上述问题,根据约束条件构建多目标耦合奖励函数,通过输出建议加速度来优化车辆行驶轨迹,以低能耗、高效率的方式安全、舒适地通过交叉口。此外,为简化问题,本文只考虑公交车自身纵向运动的相关因素,暂不考虑变道、超车等横向动作。

3 基于SAC算法的生态驾驶策略

针对上节描述的多目标生态驾驶优化问题,本节建立基于SAC的生态驾驶策略框架,如图4所示。当电动公交车智能体获取到周围的交通环境信息后会储存起来,不断进行学习,不断更新策略,并根据策略输出动作(加速度),达到控制车辆行驶轨迹、实现生态驾驶的目的。

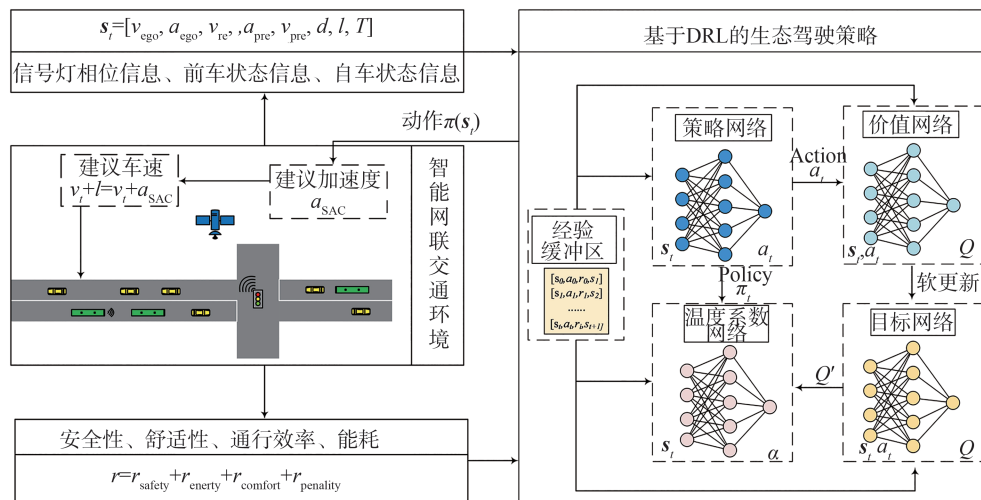


图4 基于深度强化学习的信号交叉口生态驾驶策略框架

3.1 交通环境信息

电动公交车智能体基于当前环境观测所得到的信息做出正确的决策,因此环境状态量的选择对于智能体的决策起着重要作用。本文根据电动公交车在实际行驶过程中可能会出现驾驶状态提取8个状态信息来定义状态空间,分别为本车车速 v_{ego} , 本

车加速度 a_{ego} , 建议车速 v_{ref} , 前车车速 v_{pre} , 前车加速度 a_{pre} , 跟车距离 d , 车辆距离交叉口停止线的距离 l , 和交通相位信息 T 。状态空间 s_t 可表示为

$$s_t = [v_{\text{ego}}, a_{\text{ego}}, v_{\text{ref}}, v_{\text{pre}}, a_{\text{pre}}, d, l, T] \quad (8)$$

交通相位信息 T 须说明当前信号灯的相位以及剩余时间,因此 T 可表示为

$$T = \begin{cases} t_{\text{rem}}, & \text{绿灯} \\ -t_{\text{rem}} - t_{\text{red}}, & \text{黄灯} \\ -t_{\text{rem}}, & \text{红灯} \end{cases} \quad (9)$$

式中: t_{rem} 为当前相位剩余时间; t_{red} 为红灯相位时长。将黄灯视为不可通行相位,当信号灯为可通行相位时, T 的值为正,信号灯为不可通行相位时, T 的值为负。

建议车速 v_{ref} 由两部分构成,首先应使车辆避免碰撞前车,根据 Krauss 跟驰模型^[28],跟驰车辆应满足:

$$L(V_f) + V_f\tau < L(V_p) + D \quad (10)$$

式中: V_f 和 V_p 分别表示当前公交车和前车的车速; τ 为驾驶员反应时间; D 为两车的间距; $L(V_f)$ 和 $L(V_p)$ 分别为当前公交车和前车的制动距离。

根据式(10)可以计算得出车辆的安全跟驰车速:

$$v_{\text{cf}} = (a^2\tau^2 + V_p^2 + 2aD)^{1/2} - a\tau \quad (11)$$

信号灯不停车建议通过车速 v_{light} 应使车辆避免在交叉口反复停车。为避免车速剧烈变化,将 v_{light} 车速设计为变化较为缓和的速度轨迹。当交通信号为红灯相位时,车辆首先须判断,若红灯剩余时间较短,车辆匀速通过交叉口的速度大于车辆最高速度 v_{max} ,此时 v_{light} 取值为 v_{max} 。若红灯剩余时间较长,车辆匀速通过交叉口的速度小于 v_{max} ,车辆需要减速以避免闯红灯。根据运动学基本公式 $v_t^2 - v_0^2 = 2ax$,在车辆刚进入信号范围时,记录初始车速 v_{mit} ,将最终车速设为0,从而计算得出减速度 a 。根据 v_{mit} 和 a 实时计算车速 v_t ,并将此车速与能不停车匀速通过信号交叉口的车速($v_{\text{con}} = -l/T$)进行比较,选取两者间较大值作为 v_{light} 的取值,为车辆提供一条较为缓和的减速行驶速度轨迹。

当交通信号为绿灯相位时,与红灯时的情况相反。若剩余时间较长,车辆匀速通过交叉口的速度小于 v_{max} , v_{light} 取值为 v_{max} ;若剩余时间较短,车辆匀速通过交叉口的速度大于车辆最高速度 v_{max} ,车辆需要减速,在下一个绿灯相位通过交叉口,减速方式与红灯相位减速轨迹类似。根据上述分析, v_{light} 可表示为

$$v_{\text{light}} = \begin{cases} \max(v_t - at, \min(v_{\text{max}}, (-l/T))), & T < 0 \\ v_{\text{max}}, & 0 < llv_{\text{max}} < T \\ \max(v_t - at, ll(T + t_{\text{red}})), & 0 < T < llv_{\text{max}} \end{cases} \quad (12)$$

建议车速 v_{ref} 的值为安全跟驰车速 v_{cf} 和信号灯不停车建议通过速度 v_{light} 中的较小者:

$$v_{\text{ref}} = \min(v_{\text{cf}}, v_{\text{light}}) \quad (13)$$

为控制车辆的速度变化,选择加速度作为智能体的动作变量输出。因此,速度可以表示为

$$v_{\text{DRL}} = v_{\text{ego}} + a_{\text{DRL}} \quad (14)$$

式中 a_{DRL} 为计算得到的车辆加速度。为保证乘客舒适性, a_{DRL} 取值范围为 $[-2.5, 2.5] \text{m} \cdot \text{s}^{-2[26]}$ 。

3.2 奖励函数构建

本文从以下4个方面构建奖励函数。

(1) 驾驶安全性奖励函数

为了使公交车能在绿灯相位通过交叉口,并且能避免与前车发生碰撞,本文对公交车行驶速度设计奖励函数 r_{safe} 。当速度与 v_{ref} 相差较大时,将给予负向奖励;当车速大于建议速度时,有可能与前车相撞或闯红灯,因此给予额外的负向奖励;为鼓励车辆高效通过信号交叉口,车速在 v_{ref} 附近范围内时,给予鼓励。安全奖励函数可表示为

$$r_{\text{safety}} = \begin{cases} f_1(v_{\text{ego}} - v_{\text{ref}})^2, & v_{\text{ego}} < f_v v_{\text{ref}} \\ f_2 v_{\text{ego}}, & f_v v_{\text{ref}} \leq v_{\text{ego}} \leq v_{\text{ref}} \\ f_3(v_{\text{ego}} - v_{\text{ref}})^2 + \beta_1, & v_{\text{ref}} < v_{\text{ego}} \end{cases} \quad (15)$$

(2) 车辆能耗奖励函数

奖励函数的设置以车辆从初始位置到达目标位置整段路程的能量消耗最小为目标。根据第一节构建的电动公交车能耗预测模型,车辆能耗的奖励函数可表示为

$$r_{\text{energy}} = -\int_{t_0}^{t_f} P_t dt \quad (16)$$

(3) 乘坐舒适奖励函数

相比高振幅和较短持续时间的车速变动,低振幅和较长持续时间的车速变动更舒适,则针对车辆的绝对加速度的奖励函数可表示为

$$r_{\text{comfort}} = -a_{\text{ego}}^2 \quad (17)$$

(4) 惩罚函数

为避免车辆的一些不当行为,须额外设置一些惩罚函数来避免违规行为的发生。本文构建的惩罚函数综合考虑碰撞前车、闯红灯,表示为

$$r_{\text{penalty}} = \begin{cases} \beta_2, & \text{闯红灯} \\ \beta_3, & \text{碰撞前车} \end{cases} \quad (18)$$

综合以上构建的各部分奖励函数,本文的综合奖励函数可表示为

$$r = \alpha_1 r_{\text{safe}} + \alpha_2 r_{\text{energy}} + \alpha_3 r_{\text{comfort}} + \alpha_4 r_{\text{penalty}} \quad (19)$$

3.3 基于SAC的生态驾驶策略求解

采用SAC算法构建生态驾驶深度强化学习模

型,算法网络结构如图5所示。SAC是一种 off-policy 的随机策略算法,通过引入熵正则化项鼓励算法探索最优策略,可以探索更广阔的状态-动作空间。在面对观测干扰和噪声时表现出较高的稳定性和鲁棒性。

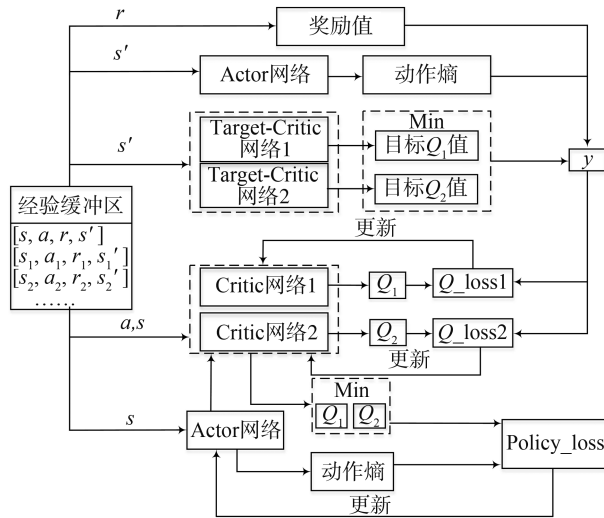


图5 算法网络结构

传统强化学习的目标是最大化期望奖励,而SAC的目标是同时最大化期望奖励和熵,即

$$\pi^* = \arg \max_{\pi} \sum_{t=0}^T E_{(s_t, a_t) \sim \pi} [r(s_t, a_t) + \alpha H(\pi(\cdot | s_t))] \quad (20)$$

式中: $H(\pi(\cdot | s_{t+1}))$ 表示动作熵; α 为温度系数,在训练过程中自动调整。 α 的值表示策略探索中随机性的强度。

在SAC算法框架中包含一个Actor网络、两个Critic网络和两个Target-Critic网络,假设采样到的一条数据为 $[s, a, r, s']$,首先通过2个Target-Critic网络输出的两个目标Q值,取其中的最小值、Actor网络输出的动作熵和奖励值计算目标y值:

$$y = r + \gamma (\min_{i=1,2} Q_{\phi_i}(s', a') - \alpha \log \pi_{\theta}(a' | s')) \quad (21)$$

式中: s 为当前状态; a 为执行动作; r 为奖励; s' 为下一状态; ϕ' 为Target-Critic网络参数; ϕ 为Critic网络参数; θ 为Actor网络参数; a' 下一个时间步的估计动作; $\log \pi_{\theta}(a' | s')$ 为动作熵。两个Critic网络计算与目标y值的差距,即损失函数,来更新Critic网络,其损失函数可以表示为

$$L(\phi_i) = E[(Q_{\phi_i}(s, a) - y)^2] \quad (22)$$

Critic网络不断迭代更新后,将状态向量输入Actor网络中采样得到动作 \tilde{a} ,取两个Critic网络输出

的两个估计Q值中的最小值,通过最大化未来奖励值来更新策略网络,其损失函数可以表示为

$$L_{\pi} = \max [\min_{i=1,2} Q_{\phi_i}(s, \tilde{a}) - \alpha \log \pi_{\theta}(\tilde{a} | s)] \quad (23)$$

4 实验结果与分析

4.1 实验仿真场景与参数设置

从参与实车测试的公交车中,选取一辆某品牌10 m纯电动公交车作为研究对象进行模型的仿真结果与分析。首先,利用该公交车的实测数据,利用构建的能耗模型在线估计能耗模型参数;然后,使用SUMO搭建仿真环境,以Python作为算法编程语言,通过SUMO的Traci接口来实现对车辆的控制。本文所涉及的车辆选型等参数如表3所示。

表3 主要仿真参数

参数	含义	取值
$E_{\max}/(\text{W} \cdot \text{h})$	最大电池容量	48 300
m/kg	车辆质量	12 400
$v_{\max}/(\text{km} \cdot \text{h}^{-1})$	最高车速	40
$a_{\max}/(\text{m} \cdot \text{s}^{-2})$	最大加速度	2.5
$d_{\max}/(\text{m} \cdot \text{s}^{-2})$	最大减速度	2.5
l/m	交叉口信号范围	300
t_{open}	通行信号相位持续时间比	0.466 7
t_{cycle}	交通信号灯周期时长	90
D/s	仿真步长	1

为模拟信号交叉口的随机性,控制车辆以随机车速在随机时刻进入信号交叉口的通信范围内,信号交叉口的交通量为1 000车/h,构建的生态驾驶算法参数及模型结构如表4所示。

表4 生态驾驶算法相关参数

主要参数	数值
学习率	0.000 3
折现系数	0.99
重放缓冲区容量	100 000
样本批次大小	256
Actor网络层数	4
Critic网络层数	4
隐藏层神经元数量	256
$f_1, f_2, f_3, f_4, \beta_1, \beta_2, \beta_3, \alpha_1, \alpha_2, \alpha_3, \alpha_4$	-1, 1, -1, 0.8, -100, -100, -100, 1, 0.5, 3, 1

4.2 不同情境下生态驾驶策略优化结果分析

根据电动公交车到达交叉口通信范围时的信号控制状态,将交叉口划分为4种情境:(1)绿灯剩余时间较短,车辆无法在本次绿灯相位通过;(2)绿灯

时间充足,车辆可在本次绿灯剩余时长内通过;(3)红灯剩余时间过短无须减速;(4)红灯剩余时间较长,需要车辆减速停车,信号控制状态信息如表5所示。为探究本文所构建的生态驾驶策略在不同情境下的优化性能,将提出的策略部署在SUMO当中,同时以经典算法GLOSA作为基准算法,对比在4种不同的交通情境下电动公交车的节能效果、通行效率和舒适性。

4种交通情境下两种策略的行驶轨迹和速度轨迹对比情况分别如图6和图7所示。由图6可以看出,4种情境中,两种策略均能控制车辆满足交通信号灯规则约束,在绿灯时段通过信号交叉口。由图

表5 4种交通情境信息

交通情境	信号控制状态	剩余时间/s	初始车速/($\text{km} \cdot \text{h}^{-1}$)
交通情境1	绿灯	15	34.54
交通情境2	绿灯	35	30.87
交通情境3	红灯	23	33.06
交通情境4	红灯	33	30.32

7可以看出,车辆在当前相位无法通过时,本文方法控制的车辆按照预期策略做持续的减速行驶,最终不停车通过交叉口。GLOSA策略虽然能控制车辆在红灯相位时进行减速行驶,但由于受前方车辆排队的影响最终仍需要停车等待。

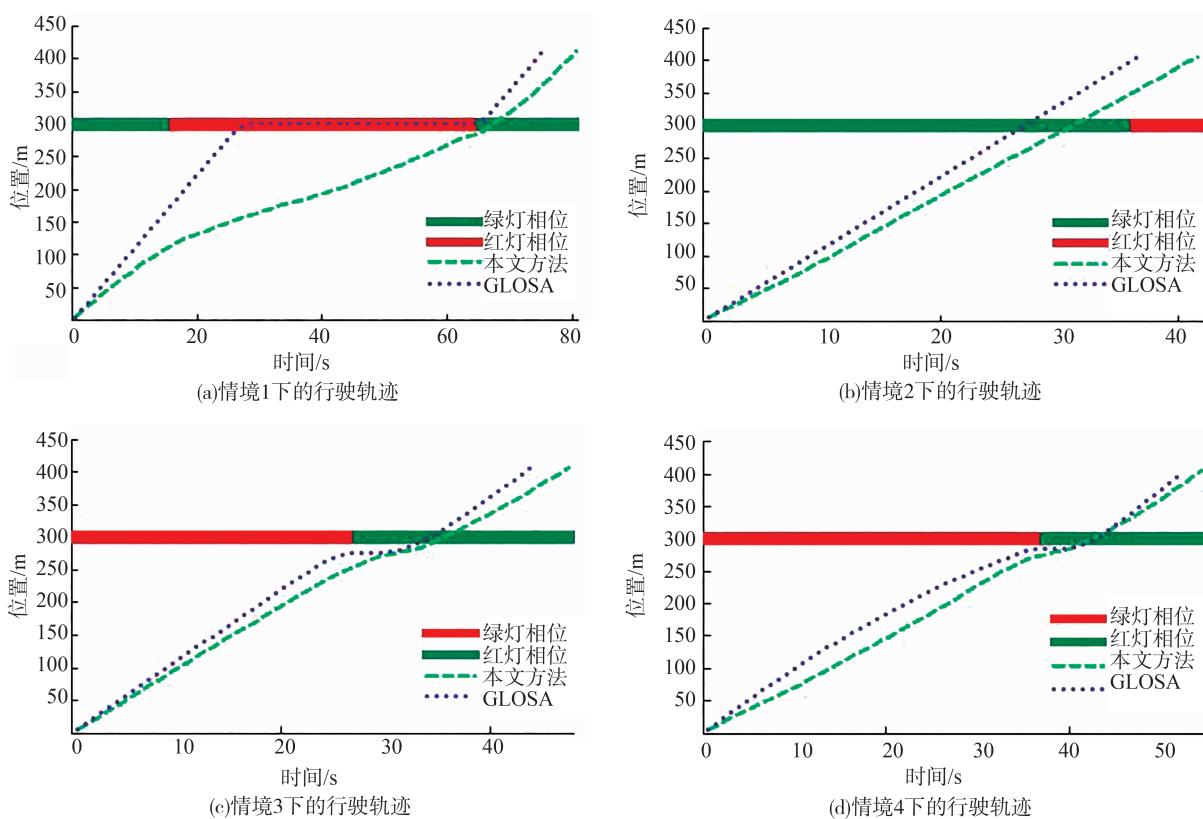


图6 4种情境下行驶轨迹对比

本文设置的仿真实境动态模拟真实交通环境,在被控公交车的周围可能存在其他行驶车辆。4种情境下两种策略的电动公交车与前车的距离变化信息如图8所示。由图8可以看出,在两种策略的控制下,被控电动公交车与前车的距离始终大于零,表明在4种情境中均未发生碰撞事故。这说明本文所构建的生态驾驶策略能控制车辆在复杂的交通环境中安全行驶。

相关研究表明,非紧急制动减速度应不大于 $0.15g^{[27]}$,否则会使轮胎剧烈磨损、乘客感到不舒服

或发生危险。本文设计的奖励函数中考虑到电动公交车的加速度,并建议车速轨迹变化较缓和,所以利用本文方法输出的动作多为较小的加速度值。4种情境下两种策略的电动公交车加速度轨迹如图9所示。由图9可以看出,本文方法的加速度大多集中在 $[-0.5, 0.5] \text{m} \cdot \text{s}^{-2}$ 区间内,且在4种情境中最大减速度为 $1.35 \text{m} \cdot \text{s}^{-2}$,未出现使乘客感到不适的急减速情况。相比之下,GLOSA策略控制的车辆则倾向于使用较高的加速度调整车速,而后匀速行驶。




图7 4种情境下速度轨迹对比

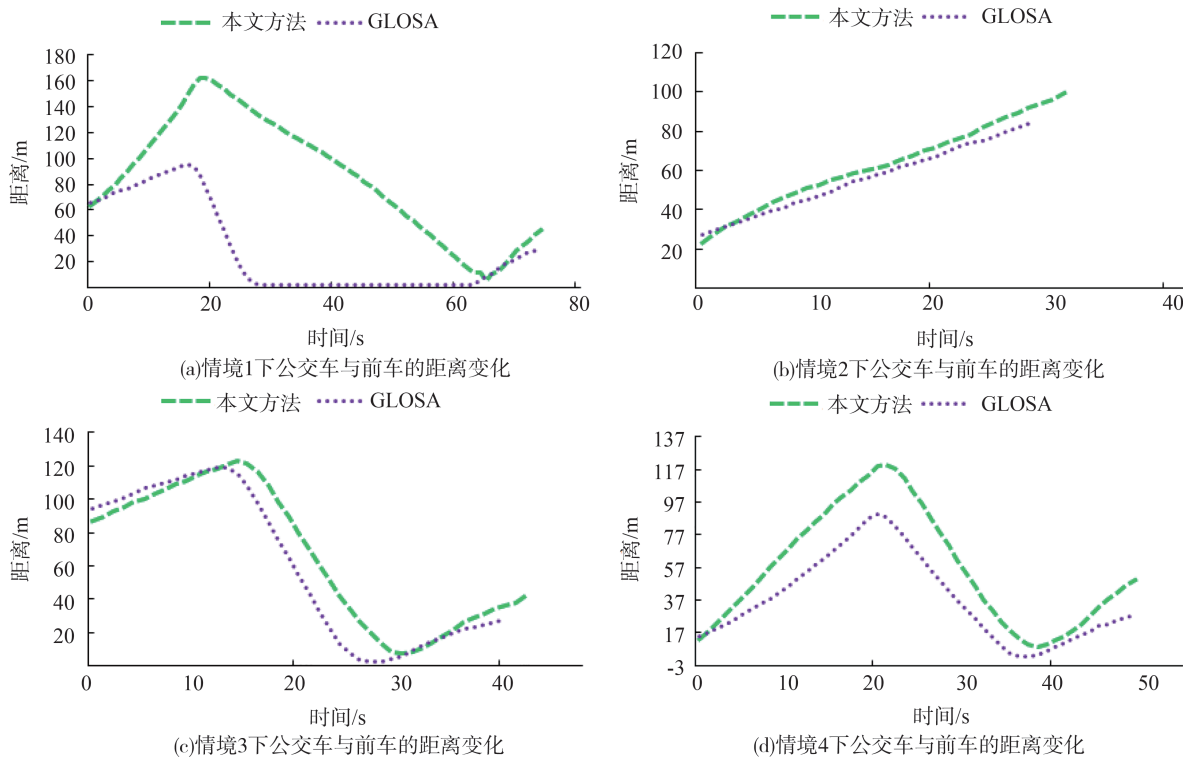


图8 4种情境下公交车与前车的距离变化信息




图9 4种情境下加速度轨迹对比

生态驾驶策略的对比结果如表6所示。

表6 生态驾驶算法对比结果

参数	控制策略	交通情境			
		情境1	情境2	情境3	情境4
前车最小距离/m	本文方法	5.33	23.63	7.31	8.73
	GLOSA	2.50	27.49	2.50	2.50
加速度绝对值 平均值/($\text{m}\cdot\text{s}^{-2}$)	本文方法	0.24	0.08	0.31	0.29
	GLOSA	0.31	0.07	0.54	0.46
能源消耗率/ ($\text{kW}\cdot\text{h}\cdot\text{km}^{-1}$)	本文方法	0.95	0.50	0.81	0.89
	GLOSA	1.35	0.61	1.24	1.05
通行时间/s	本文方法	81	42	48	55
	GLOSA	77	37	45	53
节能率/%	本文方法对比 GLOSA	29.63	18.33	34.68	15.24

由表6可知,前车最小距离表示车辆的行驶安全性。4种情境下,本文方法的前车距离分别为5.33、23.63、7.31、8.73 m,除情境2,其他均大于由GLOSA策略控制的车辆,保证了车辆的行驶安全性;加速度绝对值平均值表示车辆在行驶过程中的行驶平稳性,表征乘客的舒适性。4种情境下,本文方法控制的车辆加速度绝对值平均值分别为0.24、0.08、0.31、0.29 m/s^2 ,除情境2中高于GLOSA策略0.01 m/s^2 外,其余均小于GLOSA策略,3种情境下舒

适性分别提高22.58%、42.59%、36.96%。能源消耗率表示车辆的节能特性,本文方法控制的车辆在4种情境下的能源消耗率分别为0.95、0.50、0.81和0.89 $\text{kW}\cdot\text{h}\cdot\text{km}^{-1}$,相比于GLOSA策略,能源消耗率分别降低了29.63%、18.33%、34.68%和15.24%。通行时间用于表征车辆的通行效率,本文方法控制的车辆在4种情境下通过交叉口的时间分别为81、42、48和55 s,相较于GLOSA策略通行效率有所下降,通行时间分别增加了5.19%、13.51%、6.67%和3.77%,说明节能性和舒适性的提高须适当损失通行效率,但损失较小,在可接受范围内。

由上述分析可知,本文提出的生态驾驶策略在保证行车安全且几乎不损失通行效率的情况下,能够有效降低电动公交车在信号交叉口处的能源消耗,且在一定程度上提高乘客的乘坐舒适性。主要原因是本文构建的奖励函数充分考虑了电动公交车的个体能耗特性,构建的生态驾驶策略在经过大量的训练后,不断优化速度轨迹以避免反复启停等高能耗行为,有效提高了公交车能耗效率。

5 结论

(1)利用自然驾驶数据,结合车辆动力学和最小

二乘系统辨识方法构建了可适应不同车辆个体配置的能耗预测模型。结果表明,模型的平均绝对百分比误差为4.962%,决定系数 R^2 达到0.993。

(2)首次提出利用自车运行过程中的实际能耗数据标定能耗模型的未知参数,以标定的能耗预测模型为基础构建生态驾驶优化目标函数,保证了能耗预测的准确性和能耗优化的可靠性。

(3)为减速工况设计了较为缓和的建议速度轨迹,加速度绝对值在情境1、3、4中平均分别降低了22.58%、42.59%、36.96%,车辆的最大减速度为 $1.35 \text{ m} \cdot \text{s}^{-2}$,车辆未出现急减速行为。

(4)提出了基于SAC深度强化学习的网联电动公交车信号交叉口生态驾驶策略,相较于经典的GLOSA策略,4种典型情境下能源消耗率分别降低了29.63%、18.33%、34.68%、15.24%,且同时保证了行驶的安全性、舒适性和通行效率。

(5)为进一步研究电动公交车在行驶路线上的生态驾驶策略,本文只针对单个交叉口区域内的电动公交车进行生态驾驶策略优化研究,下一步还须考虑“连续信号交叉口+公交站点”的协同优化控制策略,这是公交车区别于传统车辆的典型特征,也是未来进一步研究工作的重点。

参考文献

- [1] 付锐,张雅丽,袁伟.生态驾驶研究现状及展望[J].中国公路学报,2019,32(3):1-12.
FU R, ZHANG Y L, YUAN W. Progress and prospect in research on eco-driving[J]. China Journal of Highway and Transport, 2019, 32(3): 1-12.
- [2] 胡永辉,金旭峰,王亦兵,等.智能网联混合动力异构交通流生态驾驶[J].中国公路学报,2022,35(3):15-27.
HU Y H, JIN X F, WANG Y B, et al. Eco-driving of connected and automated vehicles in mixed and power-heterogeneous traffic flow[J]. China Journal of Highway and Transport, 2022, 35(3): 15-27.
- [3] ZHAI C, CHEN C, YANG X, et al. Ecological driving for connected and automated vehicles at unsaturated intersections considering queue effects[J]. IEEE Transactions on Vehicular Technology, 2022, 71(12): 1-13.
- [4] YU M, LONG J. An eco-driving strategy for partially connected automated vehicles at a signalized intersection[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(9): 15780-15793.
- [5] HAN J, VAHIDI A, SCARRETTA A. Fundamentals of energy efficient driving for combustion engine and electric vehicles: an optimal control perspective[J]. Automatica (Oxford), 2019, 103: 558-572.
- [6] 孟竹,邱志军.节能导向的信号交叉口生态驾驶策略研究[J].交通信息与安全,2018,36(2):76-84,92.
MENG Z, QIU Z J. A study of eco-driving strategy at signalized intersections[J]. Journal of Transport Information and Safety, 2018, 36(2): 76-84, 92.
- [7] FENG Y, YU C, LIU H X. Spatiotemporal intersection control in a connected and automated vehicle environment[J]. Transportation Research Part C: Emerging Technologies, 2018, 89: 364-383.
- [8] STAHLMANN R, MOELLER M, BRAUER A, et al. Exploring GLOSA systems in the field: technical evaluation and results[J]. Computer Communications, 2018, 120: 112-124.
- [9] 陈欣宇,钱立军,王其东.考虑时延的信号交叉口生态驾驶控制[J].汽车工程,2022,44(7):960-968.
CHEN X Y, QIAN L J, WANG Q D. Eco-driving control at signalized intersections with consideration of time delay[J]. Automotive Engineering, 2022, 44(7): 960-968.
- [10] 袁伟,张雅丽,王虹霞,等.纯电动公交车交叉口节能驾驶策略[J].中国公路学报,2021,34(7):54-66.
YUAN W, ZHANG Y L, WANG H X, et al. Energy-saving driving technique for pure electric buses in intersection[J]. China Journal of Highway and Transport, 2021, 34(7): 54-66.
- [11] 钱立军,陈健,吴冰,等.考虑驾驶员操作误差的混合动力汽车队列生态驾驶控制[J].汽车工程,2021,43(7):1037-1045.
QIAN L J, CHEN J, WU B, et al. Eco-driving control for hybrid electric vehicle platoon with consideration of driver operation error[J]. Automotive Engineering, 2021, 43(7): 1037-1045.
- [12] 刘显贵,王晖年,洪经纬,等.网联环境下信号交叉口车速控制策略及优化[J].交通运输系统工程与信息,2021,21(2):82-90.
LIU X G, WANG H N, HONG J W, et al. Speed control strategy and optimization of signalized intersection in network environment[J]. Journal of Transportation Systems Engineering and Information Technology, 2021, 21(2): 82-90.
- [13] 钱立军,陈健,赵丰,等.基于快速随机模型预测控制的网联混合车队生态驾驶策略研究[J].汽车工程,2024,46(9):1587-1599.
QIAN L J, CHEN J, ZHAO F, et al. Research on fast stochastic model predictive control-based eco-driving strategy for connected mixed platoons[J]. Automotive Engineering, 2024, 46(9): 1587-1599.
- [14] SHI J, QIAO F, LI Q, et al. Application and evaluation of the reinforcement learning approach to eco-driving at intersections under infrastructure-to-vehicle communications[J]. Transportation Research Record, 2018, 2672(25): 89-98.
- [15] LIAN R, PENG J, WU Y, et al. Rule-interposing deep reinforcement learning based energy management strategy for power-split hybrid electric vehicle[J]. Energy, 2020, 197: 117297.
- [16] 庄伟超,丁昊楠,董昊轩,等.信号交叉口网联电动汽车自适应学习生态驾驶策略[J].吉林大学学报(工学版),2023,53(1):82-93.

- ZHUANG W C, DING H N, DONG H X, et al. Learning based eco-driving strategy of connected electric vehicle at signalized intersection[J]. *Journal of Jilin University (Engineering and Technology Edition)*, 2023, 53(1):82-93.
- [17] BAI Z, HAO P, SHANGGUAN W, et al. Hybrid reinforcement learning-based eco-driving strategy for connected and automated vehicles at signalized intersections[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(9): 15850-15863.
- [18] LI J, WU X, XU M, et al. Deep reinforcement learning and reward shaping based eco-driving control for automated HEVs among signalized intersections[J]. *Energy*, 2022, 251: 123924.
- [19] 辛琪,王嘉琪,杨文科,等. 信控路段混行交通生态驾驶深度强化学习模型[J]. *交通运输系统工程与信息*, 2024, 24(3): 127-139.
- XIN Q, WANG J Q, YANG W K, et al. Eco-driving under mixed autonomy at signalized intersection: a deep reinforcement learning model[J]. *Journal of Transportation Systems Engineering and Information Technology*, 2024, 24(3): 127-139.
- [20] ZHOU M, YU Y, QU X. Development of an efficient driving strategy for connected and automated vehicles at signalized intersections: a reinforcement learning approach[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2020, 21(1): 433-443.
- [21] 张健,姜夏,史晓宇,等. 基于离线强化学习的交叉口生态驾驶控制[J]. *东南大学学报(自然科学版)*, 2022, 52(4): 762-769.
- ZHANG J, JIANG X, SHI X Y, et al. Offline reinforcement learning for eco-driving control at signalized intersections [J]. *Journal of Southeast University(Natural Science Edition)*, 2022, 52(4): 762-769.
- [22] 李捷,吴晓东,许敏,等. 基于强化学习的城市场景多目标生态驾驶策略[J]. *汽车工程*, 2023, 45(10): 1791-1802.
- LI J, WU X D, XU M, et al. Reinforcement learning based multi-objective eco-driving strategy in urban scenarios[J]. *Automotive Engineering*, 2023, 45(10): 1791-1802.
- [23] WEGENER M, KOCH L, EISENBARTH M, et al. Automated eco-driving in urban scenarios using deep reinforcement learning [J]. *Transportation Research Part C: Emerging Technologies*, 2021, 126.
- [24] FIORI C, MONTANINO M, NIELSEN S, et al. Microscopic energy consumption modelling of electric buses: model development, calibration, and validation [J]. *Transportation Research Part D: Transport and Environment*, 2021, 98.
- [25] PAN Y J, FANG W P, GE Z Z, et al. A hybrid on-line approach for predicting the energy consumption of electric buses based on vehicle dynamics and system identification [J]. *Energy*, 2024, 290.
- [26] KYONGSU Y, JINTAI C. Nonlinear brake control for vehicle CW/CA systems [J]. *IEEE/ASME Transactions on Mechatronics*, 2001, 6(1): 17-25.
- [27] 徐哲,刘豪,党威,等. 汽车制动舒适性控制研究综述[J]. *科学技术与工程*, 2022, 22(17): 6790-6801.
- XU Z, LIU H, DANG W, et al. Review on automotive braking comfort control[J]. *Science Technology and Engineering*, 2022, 22(17):6790-6801.
- [28] KRAUSS S, WAGNER P, GAWRON C. Metastable states in a microscopic model of traffic flow [J]. *Physical Review E*, 1997, 55(5): 5597-5602.

(上接第828页)

- [13] DEOLASEE S, LIN Q, LI J, et al. Spatio-temporal motion planning for autonomous vehicles with trapezoidal prism corridors and Bézier curves [C]. 2023 American Control Conference (ACC). IEEE, 2023: 3207-3214.
- [14] DE GROOT O, FERRANTI L, GAVRILA D M, et al. Topology-driven parallel trajectory optimization in dynamic environments [J]. *IEEE Transactions on Robotics*, 2024.
- [15] SADAT A, REN M, POKROVSKY A, et al. Jointly learnable behavior and trajectory planning for self-driving vehicles [C]. 2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2019: 3949-3956.
- [16] ZIEGLER J, STILLER C. Spatiotemporal state lattices for fast trajectory planning in dynamic on-road driving scenarios [C]. 2009 IEEE/RSJ International Conference on Intelligent Robots and Systems. IEEE, 2009: 1879-1884.
- [17] DIXIT S, MONTANARO U, DIANATI M, et al. Trajectory planning for autonomous high-speed overtaking in structured environments using robust MPC [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2019, 21(6): 2310-2323.
- [18] LI B, OUYANG Y, LI L, et al. Autonomous driving on curvy roads without reliance on frenet frame: a cartesian-based trajectory planning method [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(9): 15729-15741.
- [19] ZIEGLER J, BENDER P, DANG T, et al. Trajectory planning for Bertha—a local, continuous method [C]. 2014 IEEE Intelligent Vehicles Symposium Proceedings. IEEE, 2014: 450-457.
- [20] MICHELI F, BERSANI M, ARRIGONI S, et al. NMPC trajectory planner for urban autonomous driving [J]. *Vehicle System Dynamics*, 2023, 61(5): 1387-1409.
- [21] MCNAUGHTON M, URMSON C, DOLAN J M, et al. Motion planning for autonomous driving with a conformal spatiotemporal lattice [C]. 2011 IEEE International Conference on Robotics and Automation. IEEE, 2011: 4889-4895.