

·智能车辆运动规划与控制技术专题·

考虑驾驶风格的高速行驶工况自动换道决策规划研究*

张新锋^{1,2} 汪亚君¹ 张浩杰¹ 赵娟¹ 贾瑞豪¹

(1. 长安大学, 西安 710064; 2. 新疆农业大学, 乌鲁木齐 830052)

【摘要】为了解决高速行驶工况下自动驾驶车辆决策模型的车间互动性不足、规划控制匹配性差等问题,构建了基于斯塔克尔伯格(Stackelberg)博弈的闭环换道决策模型,将障碍物响应纳入自车换道决策中,同时引入驾驶风格特征优化多目标决策成本函数,并使用粒子群优化(PSO)算法求解博弈决策模型,采用考虑质心侧偏角影响下的运动学模型预测车辆状态,设计了基于动态风险势场法的非线性模型预测规划控制器。仿真结果表明,所提出的闭环换道决策模型可有效结合车间互动行为与驾驶风格特征输出正确的决策指令并完成相应的运动规划和控制。

关键词: 自动驾驶车辆 换道决策规划 驾驶风格 斯塔克尔伯格博弈

中图分类号: U461.91 **文献标志码:** A **DOI:** 10.19620/j.cnki.1000-3703.20230357

Research on High-Speed Automatic Lane Change Decision-Making and Planning Considering Driving Style

Zhang Xinfeng^{1,2}, Wang Yajun¹, Zhang Haojie¹, Zhao Juan¹, Jia Ruihao¹

(1. Chang'an University, Xi'an 710064; 2. Xinjiang Agricultural University, Urumqi 830052)

【Abstract】There are insufficient vehicle-vehicle interaction and poor matching between planning and control in the decision-making model of high-speed autonomous vehicles. In order to solve these problems, a closed-loop lane change decision model based on Stackelberg game was constructed. Faulty vehicle response was incorporated into lane changing decision while introducing driving style feature. The multi-objective decision-making cost function was optimized. Particle Swarm Optimization (PSO) algorithm was used to solve the game decision model, and the vehicle state was predicted by using a kinematic model that considers the influence of center of mass sideslip angle. A nonlinear model predictive planning controller based on dynamic risk potential field method was designed. The simulation test results show that the closed-loop lane-changing decision-making model proposed in this paper can effectively combine the interaction behavior and driving style characteristics of vehicles to make correct decision-making instructions and implement corresponding motion planning and control.

Key words: Autonomous vehicle, Lane change decision-making and planning, Driving style, Stackelberg game theory

【引用格式】张新锋,汪亚君,张浩杰,等.考虑驾驶风格的高速行驶工况自动换道决策规划研究[J].汽车技术,2024(7):17-28.

ZHANG X F, WANG Y J, ZHANG H J, et al. Research on High-Speed Automatic Lane Change Decision-Making and Planning Considering Driving Style[J]. Automobile Technology, 2024(7): 17-28.

1 前言

近年来,自动驾驶技术在提高驾驶安全性和运输效率方面表现出巨大的潜在优势,换道决策规划是其关键技术之一^[1-3]。随着支持向量机(Support Vector Machines, SVM)^[4]、极限学习机(Extreme Learning Machines, ELM)^[5]和强化学习(Reinforcement Learning,

RL)^[6]等数据驱动模型的兴起,简单场景的安全换道决策^[7-8]得以实现,而博弈论注重交通参与者的驾驶风格与互动性,博弈决策更适用于实际驾驶环境^[9]。

在考虑驾驶风格特征的博弈决策方面:Wei等^[10]通过分析驾驶风格对决策的影响,基于博弈论提出考虑车间互动性的并线决策模型,解决了高速公路匝道并线冲突问题;Lopez等^[11]基于路口环境信息,引入驾驶

*基金项目:陕西省重点研发计划项目(2022GY-303);西安市科技计划项目(2022GXFW0152)。

风格特征,提出博弈论与深度学习相结合的决策模型,增强了模型的泛化性;Zhang等^[12]根据车辆攻击性提出分层博弈决策框架,采用带图灵测试的贝叶斯博弈理论模拟决策过程,解决了车间多模态互动问题,但仅用攻击性描述自动驾驶车辆(Autonomous Vehicle, AV)并不全面。

在运动规划博弈决策方面,人工势场(Artificial Potential Field, APF)法因结构简单、便于底层精确控制得以广泛应用^[13];Wang等^[14]在APF中引入虚拟目标点以解决局部最优的缺陷,但未解决全局范围内的局部最优问题;Orozco-Rosas等^[15]通过将APF与遗传算法结合,解决自动驾驶车辆路径规划问题;Tu等^[16]将传统的引力和斥力扩展为符合车辆实际形状的椭圆形风险势场,将其运用到车辆碰撞检测算法中,但相应的算力负担大幅增加。

现有的决策规划模型虽然解决了异质交通参与者间的冲突,但仍未充分考虑异质交通参与者间的互动性,忽略了自动驾驶车辆乘员驾驶风格差异与个性化需求,且多数侧重意图识别和决策的开发,缺少规划控制的匹配性,导致规划轨迹未能完全满足预测模型的各项控制约束,控制效果难以提升。

为解决上述问题,本文将纵向速度规划融入决策环节,结合Stackelberg主从博弈理论^[17],将车间互动行为纳入自车决策中,同时引入驾驶风格特征,使模型的结果更加符合实际驾驶需求。针对规划控制部分匹配性差的问题,设计基于动态势场法的非线性模型预测规划控制器(Dynamic Potential Field-Nonlinear Model Predictive Controller, DPF-NMPC),将风险势场与控制器结合,实现实时动态规划及运动控制,同时使规划结果满足运动约束,提高规划控制部分的匹配性,保证车辆在风险最低的安全区域内行驶。最后,采用粒子群优化(Particle Swarm Optimization, PSO)算法对模型进行求解,并通过仿真测试验证其有效性。

2 闭环换道决策模型架构

常见的高速公路换道场景主要分为并线换道和自由换道,如图1所示,以典型的两车道并线换道和三车道自由换道场景为例,开展考虑驾驶风格的高速自动换道决策规划研究。

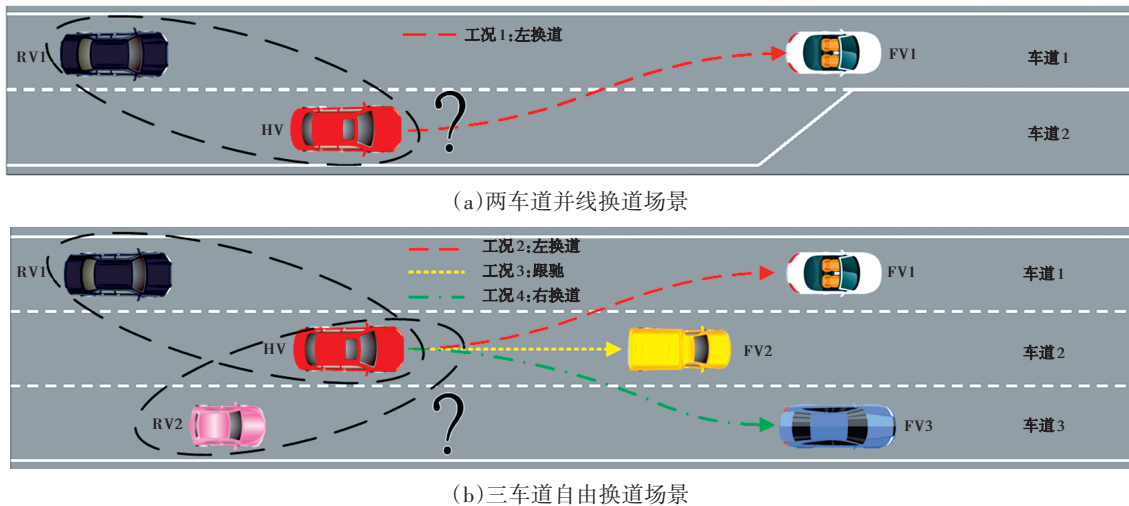


图1 高速公路换道场景示意

假定上述换道场景中的自车(Host Vehicle, HV)均为自动驾驶车辆,前车(Front Vehicle, FV)和后车(Rear Vehicle, RV)均为网联的人类驾驶车辆,车辆驾驶风格(包含激进型、正常型和保守型)的特征信息可根据运行状态进行估计和标定,并通过车联网(Vehicle to Everything, V2X)实现信息交互^[14-15]。

两车道并线换道场景中,为保证车辆换道安全的同时满足乘员的个性化需求,需结合HV与RV1的互动决策结果,选择不同的换道方式。三车道自由换道场景中,当HV产生换道意图时,FV和RV统称为障碍车(Obstacle Vehicle, OV),其中,FV包括FV1、FV2和FV3,

RV包括RV1和RV2。此时,FV1、FV3与HV行驶状态相对稳定且具备换道空间,HV的换道行为决策主要取决于RV的驾驶风格:若RV1的驾驶风格为正常型或保守型,RV2为偏好加速行驶的激进型,则HV更倾向于工况2,反之,则HV更倾向于工况4;若RV1和RV2同为激进型,均偏好加速行驶,则HV不具备换道条件,只能选择工况3,反之,HV换道不受影响。

上述换道决策过程属于典型的Stackelberg主从博弈,当HV产生换道意图,OV获得信息后作出相应的行为决策,HV根据OV的响应修正决策,经过多轮博弈最终达到平衡,即得到最优换道决策。鉴于HV决策过程

中能够融合OV决策并进行实时信息互动,因此,将决策、规划和控制构成闭环,构建基于Stackelberg博弈的闭环换道决策模型架构,如图2所示。

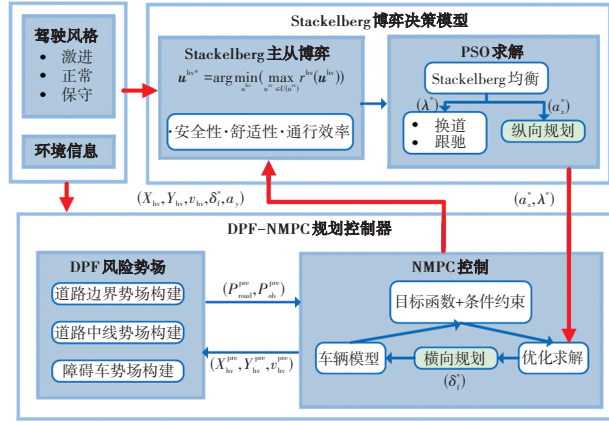


图2 基于Stackelberg博弈的闭环换道决策模型架构

该模型主要由输入信息模块、Stackelberg博弈决策模型和DPF-NMPC规划控制器组成。输入信息模块将V2X接收的各周期驾驶风格和环境信息(OV状态和道路特征)传递给其他模块;Stackelberg博弈决策模型构建基于安全性、舒适性及通行效率的决策成本函数,建立车间Stackelberg主从博弈关系,通过优化求解得到最优换道指令 λ^* 和最优纵向加速度 a_x^* ,并输出给规划控制器;DPF-NMPC将基于动态风险势场(Dynamic Potential Field, DPF)与车辆预测状态信息所建立的道路、各车风险势场、博弈结果作为非线性模型预测控制(Nonlinear Model Predictive Control, NMPC)的输入,结合车辆运动学模型建立控制目标优化函数,求解得到最优前轮转角 δ_r^* ,并将车辆实时状态反馈给决策模型,以此构成闭环的决策控制过程。

3 Stackelberg博弈决策模型构建

本文研究的高速换道场景中,相邻车道仅存在1辆RV,即该换道决策问题可视为博弈对象仅为HV和RV 2个参与者的Stackelberg主从博弈,建立对应的Stackelberg博弈决策模型为:

$$\mathbf{u}^{hv*} = \arg \min_{\mathbf{u}^{hv}} \left(\max_{\mathbf{u}^{rv} \in U(\mathbf{u}^{rv})} r^{hv}(\mathbf{u}^{hv}) \right) \quad (1)$$

$$U(\mathbf{u}^{rv}) = \begin{cases} \tau \in \Theta: r^{rv}(\tau) \\ \leq r^{rv}(\mathbf{u}^{rv}), \forall \mathbf{u}^{rv} \in \Theta \end{cases} \quad (2)$$

式中: \mathbf{u}^{hv} 、 \mathbf{u}^{rv} 分别为HV和RV的决策变量, \mathbf{u}^{hv*} 为HV的最优决策变量, $r^{hv}(\mathbf{u}^{hv})$ 、 $r^{rv}(\mathbf{u}^{rv})$ 分别为HV和RV根据对方决策的响应决策成本, $U(\mathbf{u}^{rv})$ 为RV根据HV的决策作出的最优决策行为集合, τ 为该最优决策行为集合中的任意元素; Θ 为RV的决策行为集合。

由于Stackelberg博弈决策模型以HV和RV的决策成本函数为博弈依据,故需要对决策成本函数进行优化设计。

3.1 决策成本函数设计

高速场景的行驶过程中不仅要考虑驾驶安全性与舒适性,通行效率也十分重要。

3.1.1 驾驶安全性

驾驶安全性可分为纵向安全性和横向安全性^[18-19],HV安全性成本 r_{sa}^{hv} 可表示为:

$$r_{sa}^{hv} = ||\lambda| - 1| r_{salog}^{hv} + |\lambda| r_{salat}^{hv} \quad (3)$$

式中: λ 为换道指令,可取值为-1、0和1,分别代表向右换道、跟驰行驶和向左换道; r_{salog}^{hv} 、 r_{salat}^{hv} 分别为纵向和横向的安全成本。

通常, r_{salog}^{hv} 为纵向相对距离 $\Delta s_{x,\delta}^{hv}$ 和纵向相对车速 $\Delta v_{x,\delta}^{hv}$ 的函数,当车辆运动状态发生变化时, λ 随之改变以满足博弈期望。若HV安全性成本 r_{sa}^{hv} 、HV舒适性成本 r_{com}^{hv} 和HV通行效率成本 r_{ct}^{hv} 之间相差过大,车辆运动状态发生变化时, λ 保持不变或发生错误的改变均满足博弈期望,导致决策失误。为解决此问题,采用 $\Delta s_{x,\delta}^{hv}$ 和 $\Delta v_{x,\delta}^{hv}$ 的累计误差描述安全性成本,则 r_{salog}^{hv} 可表示为:

$$r_{salog}^{hv} = k_{vlog}^{hv} \beta_{\delta}^{hv} \int_0^T \Delta v_{x,\delta}^{hv} dt + \frac{k_{slog}^{hv}}{\int_0^T \Delta s_{x,\delta}^{hv} dt + \varepsilon} \quad (4)$$

$$\begin{cases} \Delta v_{x,\delta}^{hv} = v_{x,\delta}^{fv} - v_{x,\delta}^{hv} \\ \Delta s_{x,\delta}^{hv} = X_{x,\delta}^{fv} - X_{x,\delta}^{hv} \end{cases} \quad (5)$$

$$\beta_{\delta}^{hv} = \begin{cases} 1, \Delta v_{x,\delta}^{hv} < 0 \\ 0, \Delta v_{x,\delta}^{hv} \geq 0 \end{cases} \quad (6)$$

式中: $v_{x,\delta}^{fv}$ 、 $\Delta v_{x,\delta}^{hv}$ 分别为FV和HV的速度,并线场景中, $v_{x,\delta}^{fv} = 0$; k_{vlog}^{hv} 、 k_{slog}^{hv} 分别为速度和距离的权重系数; β_{δ}^{hv} 为调节参数; $X_{x,\delta}^{fv}$ 、 $X_{x,\delta}^{hv}$ 分别为FV和HV的纵向位置,并线场景中, $X_{x,\delta}^{hv}$ 为前方障碍物位置; δ 为车道编号,其值为1、2和3,分别表示左、中、右车道; ε 为避免分母为零而设置的极小值; T 为车辆预测状态的采样周期。

同理, r_{salat}^{hv} 可表示为:

$$r_{salat}^{hv} = k_{vlat}^{hv} \beta_{\delta+\lambda}^{hv} \int_0^T \Delta v_{x,\delta+\lambda}^{hv} dt + \frac{k_{slat}^{hv}}{\int_0^T \Delta s_{x,\delta+\lambda}^{hv} dt + \varepsilon} \quad (7)$$

$$\begin{cases} \Delta v_{x,\delta+\lambda}^{hv} = v_{x,\delta+\lambda}^{hv} - v_{x,\delta+\lambda}^{rv} \\ \Delta s_{x,\delta+\lambda}^{hv} = X_{x,\delta+\lambda}^{hv} - X_{x,\delta+\lambda}^{rv} \end{cases} \quad (8)$$

$$\beta_{\delta+\lambda}^{hv} = \begin{cases} 1, \Delta v_{x,\delta+\lambda}^{hv} < 0 \\ 0, \Delta v_{x,\delta+\lambda}^{hv} \geq 0 \end{cases} \quad (9)$$

式中: k_{vlat}^{hv} 、 k_{slat}^{hv} 分别为速度和距离的权重系数, $\Delta v_{x,\delta+\lambda}^{hv}$ 、 $\Delta s_{x,\delta+\lambda}^{hv}$ 分别为HV与RV的相对速度和相对距离, $v_{x,\delta+\lambda}^{rv}$ 、

$v_{x,\delta}^{hv}$ 分别为RV和HV的速度, $X_{x,\delta+\lambda}^{rv}$ 、 $X_{x,\delta}^{hv}$ 分别为RV和HV的纵向位置, $\beta_{\delta+\lambda}^{hv}$ 为调节参数。

3.1.2 车辆舒适性

车辆舒适性评价中常用加速度衡量车辆行驶时的舒适程度,舒适性成本 r_{com}^{hv} 可表示为:

$$r_{com}^{hv} = k_{log}^{hv} \left(\int_0^T \mathbf{a}_{x,\delta}^{hv} dt \right)^2 + |\lambda| k_{lat}^{hv} \left(\int_0^T \mathbf{a}_{y,\delta}^{hv} dt \right)^2 \quad (10)$$

式中: k_{lat}^{hv} 、 k_{log}^{hv} 分别为横、纵向舒适性权重系数, $\mathbf{a}_{x,\delta}^{hv}$ 、 $\mathbf{a}_{y,\delta}^{hv}$ 分别为HV横、纵向加速度。

3.1.3 通行效率

通行效率主要与通行时间、行驶速度相关,因此,通行效率成本 r_{ef}^{hv} 可表示为:

$$r_{ef}^{hv} = [v_{x,\delta}^{hv} - \min(v_{x,\delta}^{max} - v_{x,\delta}^{fv})]^2 \quad (11)$$

式中: $v_{x,\delta}^{max}$ 为车道 δ 允许的最大行驶车速。

3.1.4 决策总成本

为了满足自动驾驶车辆乘员的个性化需求,对各成本分配不同的权重系数来模拟不同的驾驶风格,HV决策总成本 r^{hv} 表示为:

$$r^{hv} = \omega_{sa} r_{sa}^{hv} + \omega_{com} r_{com}^{hv} + \omega_{ef} r_{ef}^{hv} \quad (12)$$

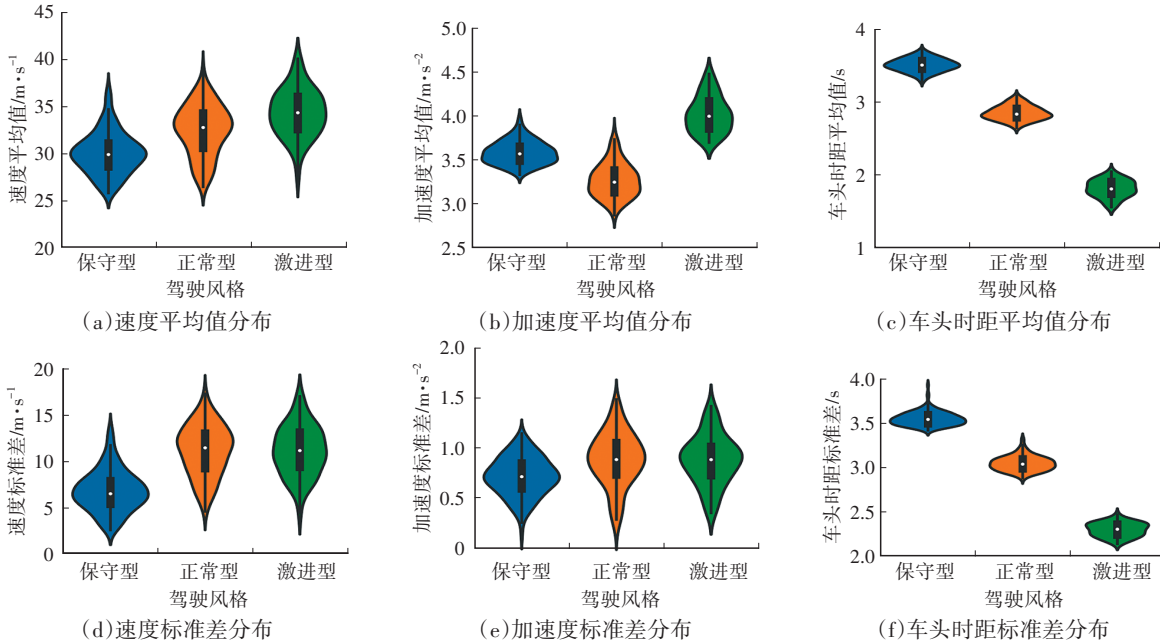


图3 各驾驶风格及其行驶特征分布

由图3a、图3d可知,激进型驾驶风格速度最高,保守型驾驶风格速度最低,这表明激进型驾驶风格对通行效率要求最高;由图3b、图3e可知,激进型驾驶风格加速度最大,保守型驾驶风格次之,正常型驾驶风格加速度最小,这表明正常型驾驶风格相比其余驾驶风格更注重舒适性;由图3c、图3f可知,保守型、正常型和激进型驾驶风格的车头时距依次减小,这表明三者对安全性的重视程度依次减轻。

式中: ω_{sa} 、 ω_{com} 、 ω_{ef} 分别为安全性、舒适性和通行效率的权重系数。

同理,RV的决策总成本函数 r^{rv} 为:

$$r^{rv} = \omega_{sa} r_{sa}^{rv} + \omega_{com} r_{com}^{rv} + \omega_{ef} r_{ef}^{rv} \quad (13)$$

式中: r_{sa}^{rv} 、 r_{com}^{rv} 、 r_{ef}^{rv} 分别为RV的安全性成本、舒适性成本、通行效率成本。

由于HV和RV的横向安全性是由彼此决定的,则RV横向安全成本 $r_{salat}^{rv} = r_{salat}^{hv}$,纵向安全成本与HV类似。假设RV不产生换道行为,只采取加减速操作,其舒适性成本为 $r_{com}^{rv} = k_{log}^{rv} \left(\int_0^T \mathbf{a}_{x,\delta+\lambda}^{rv} dt \right)^2$,其中 $\mathbf{a}_{x,\delta+\lambda}^{rv}$ 为RV纵向加速度, k_{log}^{rv} 为纵向舒适性权重系数。通行效率成本也与HV类似,仅考虑纵向相对车速即可。

驾驶风格是影响车间互动决策的重要因素,本文使用美国联邦公路管理局的公开轨迹数据集NGSIM,该数据集包括US101、I-80等道路上的所有车辆在一定时间内的车辆行驶状况,采用K-均值(K-Means)聚类算法对其聚类分析,各驾驶风格及行驶特征如图3所示。

鉴于不同驾驶风格对通行效率、舒适性和安全性具有相应的倾向性,可结合行驶特征分布情况,通过设置不同的权重系数 ω_{sa} 、 ω_{com} 和 ω_{ef} 模拟考虑不同驾驶风格的博弈决策行为。正常型驾驶风格的行驶特征中加速度分布较为离散,车头时距分布较为集中,即正常型驾驶风格个体对舒适性的选择具有较大差异性,对安全性的选择更为统一,因此,可适当增加正常型驾驶风格中的安全性权重比例,具体权重系数如表1所示^[20-21]。

表1 驾驶风格权重系数

权重系数	激进型	正常型	保守型
ω_{sa}	0.2	0.5	0.7
ω_{com}	0.1	0.3	0.2
ω_{ef}	0.7	0.2	0.1

3.2 博弈决策模型的求解

选取 $\mathbf{a}_{x,\delta}^{hv}$ 、 $\mathbf{a}_{x,\delta+\lambda}^{rv}$ 和 λ 为博弈求解变量,则 $\mathbf{u}^{hv} = [\mathbf{a}_{x,\delta}^{hv}, \lambda]$, $\mathbf{u}^{rv} = [\mathbf{a}_{x,\delta+\lambda}^{rv}]$, 博弈决策模型可转化为:

$$\begin{aligned} \mathbf{u}^{hv*} &= \arg \min_{\mathbf{a}_{x,\delta}^{hv}, \lambda} (\max_{\mathbf{a}_{x,\delta+\lambda}^{rv} \in U(\mathbf{a}_{x,\delta+\lambda}^{rv})} r^{hv}(\mathbf{u}^{hv})) \\ \text{s.t.} & \begin{cases} U(\mathbf{a}_{x,\delta+\lambda}^{rv}) = \left\{ \begin{array}{l} \tau \in \Theta: r^{rv}(\tau) \\ \leq r^{rv}(\mathbf{a}_{x,\delta+\lambda}^{rv}), \forall \mathbf{a}_{x,\delta+\lambda}^{rv} \in \Theta \end{array} \right\} \\ \lambda(\lambda+1)(\lambda-1) = 0 \\ \mathbf{v}_{x,\delta} \in [0, |\mathbf{v}_{x,\delta}^{\max}|] \\ \mathbf{a}_{x,\delta} \in [|\mathbf{a}_{x,\delta}^{\min}|, |\mathbf{a}_{x,\delta}^{\max}|] \end{cases} \end{aligned} \quad (14)$$

式中: $\mathbf{a}_{x,\delta}^{hv*}$ 、 λ^* 分别为 HV 最优纵向加速度和最优换道指令, $U(\mathbf{a}_{x,\delta+\lambda}^{rv})$ 为 RV 的最优决策行为集合, $r^{hv}(\mathbf{a}_{x,\delta}^{hv}, \lambda)$ 、 $r^{rv}(\mathbf{a}_{x,\delta+\lambda}^{rv})$ 分别为 HV 和 RV 的决策总成本函数, $\mathbf{a}_{x,\delta}^{\min}$ 、 $\mathbf{a}_{x,\delta}^{\max}$ 分别为车道 δ 纵向加速度的最小值和最大值。

鉴于 PSO 算法具有精度高、收敛快且易实现等特点, 采用 PSO 算法求解博弈决策模型, 具体求解流程如图 4 所示。

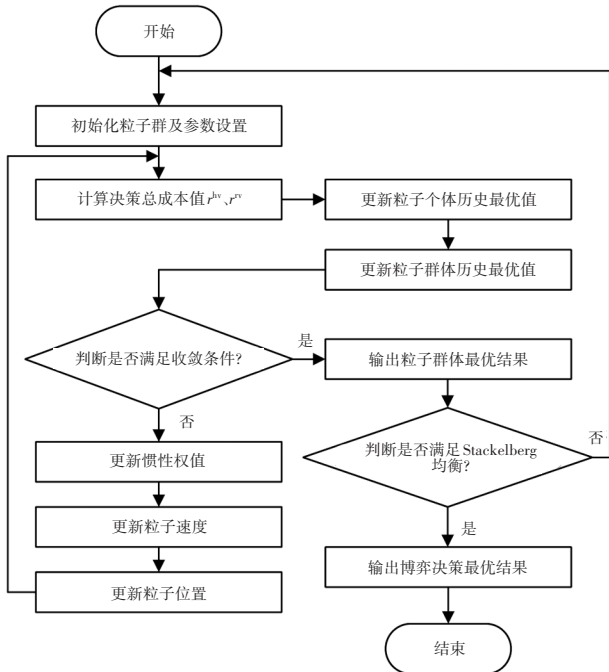


图4 博弈决策模型求解流程

4 规划控制器设计

由式(1)~式(14)可知, 求解上述决策及纵向规划问题, 需要控制部分在跟踪规划目标时获得车辆运动学

参数。因此, 本文设计动态势场法的非线性模型预测规划控制器, 将横、纵向换道加速度规划与控制环节相互耦合, 同时在规划中考虑车辆预测模型的运动学约束, 实现实时动态规划和运动控制。

4.1 风险势场函数

DPF 法可在动态场景中改善陷入局部最优的缺陷, 因而广泛用于 AV 的避障规划中^[22]。DPF 总风险势场 P_{xy} 包括 OV 动态风险势场和道路标线风险势场, 可表示为:

$$P_{xy} = e_{xy} + r_{xy} \quad (15)$$

式中: e_{xy} 为 OV 对 HV 产生的动态风险势场, r_{xy} 为道路标线对 HV 产生的风险势场。

4.1.1 OV 动态风险势场

根据道路几何特征及车辆的运动特性分析, OV 横向风险势场随着车间横向距离变化, 而纵向风险势场与纵向相对距离及相对速度有关, 故使用不同函数描述各方向的风险势场。

以车辆尾部中心为坐标原点 o 建立坐标系, 令行驶方向为 x 轴正向, 左侧为 y 轴正向, 垂直向上方向为 z 轴正向, 得到 OV 风险势场范围如图 5 所示。其中, L 为 OV 车长, S 为安全距离。OV 的风险势场范围以纵向为主, 向横、纵两个方向延伸, 可分为 α 、 β 和 γ 区域^[22], 可用分段函数描述:

$$A_{car} = \begin{cases} U_{car}, & P \in \beta \cup \gamma \\ U_{car} \cdot \exp[-(K_r - S)/v_r], & (P \in \alpha) \cap (v_r > 0) \\ 0, & (P \in \alpha) \cap (v_r \leq 0) \end{cases} \quad (16)$$

式中: A_{car} 为风险势场范围系数; U_{car} 为 OV 风险势场的最大值; K_r 、 v_r 分别为 HV 与 OV 的纵向相对距离、相对车速, 同向运动时, 若 HV 的速度大于 OV 的速度, $v_r > 0$, 反之, $v_r < 0$; $S = v_r \Delta T + S_{min}$ 为安全影响因子, 与最小安全距离和系统延迟有关, 以防止 HV 与 OV 相撞; ΔT 为由传感器传输特性带来的时间延迟; S_{min} 为最小安全距离; P 为势场中的点。




图5 OV 风险势场函数分区图

当 HV 位于 α 区域 P_1 点时,若 $v_r > 0$,则 $A_{car} = U_{car} \cdot \exp[-(K_r - S)/v_r]$,若 $v_r \leq 0$,则 $A_{car} = 0$,表明风险势场与 K_r 呈负相关,与 v_r 呈正相关。因此,OV 动态风险势场可表示为:

$$e_{xy} = A_{car} \cdot \exp(-D^2/2\sigma_r) \quad (17)$$

式中: σ_r 为收敛系数,主要决定 OV 风险势场的侧向作用范围; D 为等效距离,主要决定 OV 风险势场的纵向作用范围,当 HV 位于 α 区域 P_1 点时,则 $D=d_1$,当 HV 位于 β 区域 P_2 点时,则 $D=d_2$,当 HV 位于 γ 区域 P_3 点时,则 $D=d_3$; d_1 为 HV 坐标点到 OV 车身方向中心轴线的垂直距离; d_2 为 HV 坐标点到 OV 风险势场边界的垂直距离; d_3 为 HV 坐标点到 OV 车身侧边线的垂直距离。

4.1.2 道路标线风险势场

车辆在行驶过程中,需保证在车行道边缘线之内,当满足换道条件时,可控制车辆跨越车行道分界线到达相邻车道行驶。建立以车道 1 和车道 2 分界线观测点为坐标原点 o_r ,行驶方向为 x_r 轴正向,左侧为 y_r 轴正向,垂直向上方向为 z_r 轴正向的道路坐标系,如图 6 所示。




图6 道路坐标系示意

道路标线风险势场可表示为:

$$r_{xy} = \begin{cases} r_{xyline} = U_{line} \cdot \exp(-d_{line,i}^2/2\sigma_r^2) \\ r_{xyroad} = \exp[-(-d_{road,l} + d_c + b/2) \cdot h_i] \end{cases} \quad (18)$$

式中: r_{xyline} 、 r_{xyroad} 分别为车行道分界线、边缘线的风险势场, U_{line} 为道路风险势场的最大值, $d_{line,i}$ 、 $d_{road,l}$ 分别为 HV 至车行道分界线和边缘线的距离, $i \in [i_1, i_2]$, $l \in [l_1, l_2]$, l_1 、 l_2 分别为左、右道路边界线位置, i_1 、 i_2 为车道边界线位置, d_c 为边界距离安全阈值, b 为车辆宽度, h_i 为风险势场调节系数。

综上所述,当 HV 位于道路不同位置时,会同时受到道路上 OV 的动态风险势场和道路标线的风险势场作用。将行驶过程中 HV 的总风险势场 P_{xy} 实时传递给 NMPC 控制部分作为系统输出量,令控制部分的目标函数以此为依据求解最优控制量,可避免 HV 在行驶过程中发生碰撞。

4.2 NMPC 控制部分设计

NMPC 控制部分接收到 λ^* 和 $\alpha_{x,\delta}^{hv*}$ 后,结合总风险势场 P_{xy} 进行横向规划和运动控制,采用单轨运动学模型

作为车辆预测模型:

$$f[\mathbf{X}(t), \mathbf{u}(t)] = \begin{bmatrix} \dot{v}_{x,\delta}^{hv} \\ \dot{\varphi}_{\delta}^{hv} \\ \dot{X}_{\delta}^{hv} \\ \dot{Y}_{\delta}^{hv} \end{bmatrix} = \mathbf{v}_{x,\delta}^j \begin{bmatrix} \alpha_{x,\delta}^{hv}/v_{x,\delta}^{hv} \\ \tan \beta/l_r \\ \cos \theta / \cos \beta \\ \sin \theta / \cos \beta \end{bmatrix} \quad (19)$$

$$\beta = \arctan \frac{l_r \cdot \tan \delta_f}{l_r + l_f} \quad (20)$$

$$\theta = \varphi_{\delta}^{hv} + \beta \quad (21)$$

式中: l_r 、 l_f 分别为 HV 质心到前、后轴的距离, β 、 θ 分别为 HV 的质心侧偏角和航向角, $\mathbf{X} = (v_{x,\delta}^{hv}, \varphi_{\delta}^{hv}, X_{\delta}^{hv}, Y_{\delta}^{hv})^T$ 为状态向量, $v_{x,\delta}^{hv}$ 、 φ_{δ}^{hv} 、 X_{δ}^{hv} 、 Y_{δ}^{hv} 分别为 HV 的纵向速度、横摆角、纵向位移、横向位移, $\mathbf{u} = [\delta_f]$ 为控制向量, δ_f 为前轮转角。

实际上,对控制目标的求解已包含车辆横向换道轨迹的规划。

根据模型预测控制理论^[22],可将基于 DPF 的 MPC 控制问题转化为求凸函数的带约束非线性规划问题:

$$\begin{aligned} \min J(k) &= \mathbf{P}_{xy}^T(k) \mathbf{Q}_1 \mathbf{P}_{xy}(k) + \Delta \mathbf{M}^T(k) \mathbf{Q}_2 \Delta \mathbf{M}(k) + \\ &\quad \Delta \mathbf{v}^T(k) \mathbf{Q}_3 \Delta \mathbf{v}(k) + \Delta \mathbf{u}^T(k) \mathbf{R} \Delta \mathbf{u}(k) \\ \text{s.t.} &\begin{cases} 0 \leq v_{x,\delta} \leq v_{x,\delta}^{\max} \\ \mathbf{u}_{\min} \leq \mathbf{u}(k+i-1|k) \leq \mathbf{u}_{\max} \\ \Delta \mathbf{u}(k) = \mathbf{u}(k) - \mathbf{u}(k-1), k = 1, 2, \dots, N_p \\ \Delta \mathbf{M}(k) = \mathbf{Y}_{\delta}^{hv}(k) - \mathbf{Y}_{\delta}(k) \\ \Delta \mathbf{v}(k) = \mathbf{v}(k) - \mathbf{v}(k-1) \end{cases} \end{aligned} \quad (22)$$

式中: N_p 为预测时域; $\mathbf{Y}_{\delta}^{hv}(k)$ 、 $\mathbf{Y}_{\delta}(k)$ 分别为 HV 在 k 时刻的横向位置序列和对应的道路中心线横向位置; $\mathbf{v}(k)$ 为 HV 在 k 时刻的速度序列; $\mathbf{P}_{xy}(k)$ 为风险势场序列; $\Delta \mathbf{M}(k)$ 为道路中心线偏差序列; $\Delta \mathbf{v}(k)$ 为速度增量序列; $\Delta \mathbf{u}(k)$ 为控制增量序列; \mathbf{Q}_1 、 \mathbf{Q}_2 、 \mathbf{Q}_3 、 \mathbf{R} 分别为 $\mathbf{P}_{xy}(k)$ 、 $\Delta \mathbf{M}(k)$ 、 $\Delta \mathbf{v}(k)$ 、 $\Delta \mathbf{u}(k)$ 的权重矩阵; \mathbf{u}_{\max} 、 \mathbf{u}_{\min} 分别为最大和最小的控制量序列。

求解上述有约束的非线性规划问题,当前 k 时刻的最优控制增量为 $\Delta \mathbf{u}^*(k|k)$,则最优控制量 $\mathbf{u}^*(k|k)$ 为:

$$\mathbf{u}^*(k|k) = \mathbf{u}(k-1|k-1) + \Delta \mathbf{u}^*(k|k) \quad (23)$$

在 $(k+1)$ 时刻,重复 NMPC 的预测、优化和求解过程,不断更新车辆状态,从而完成实时决策控制。

5 模型验证分析

使用 MATLAB 平台对基于 Stackelberg 博弈的闭环换道决策模型进行仿真测试。为了简化测试方案,将图 1 所示的 4 种工况中的 FV 均设置为匀速行驶, HV 和 RV 的驾驶风格均按照第 3.1 节的决策成本函数及表 1 执行,以式 (14) 构建博弈决策模型,车道宽度设置为 4 m,仿真参数及车辆初始状态分别如表 2 和表 3 所示。其中, x_0 为初始

纵向位移, y_0 为初始横向位移。


表2 仿真参数

参数	参数值	参数	参数值	参数	参数值
k_{vlog}^{hv}	0.4	T/s	0.2	$v_{x,\delta}^{max}/m \cdot s^{-1}$	30
k_{slog}^{hv}	0.4	σ_r	0.5	Q_1	$100 \times I_{10 \times 10}$
k_{valt}^{hv}	0.6	U_{car}	15	Q_2	$10 \times I_{10 \times 10}$
k_{slat}^{hv}	0.6	U_{line}	15	Q_3	$0.1 \times I_{10 \times 10}$
k_{log}^{hv}	0.5	h_i	0.8	R	$0.5 \times I_{1 \times 1}$
k_{lat}^{hv}	0.5	$\Delta T/s$	0.4		
k_{log}^{rv}	0.5	S_{min}/m	3		


表3 4种工况下车辆初始状态

车辆类别	初始状态	工况1	工况2	工况3	工况4
HV	x_0/m	20	20	20	20
	y_0/m	-2	-2	-2	-2
	$v_0/m \cdot s^{-1}$	22	22	22	22
FV1	x_0/m	55	70	70	70
	y_0/m	2	2	2	2
	$v_0/m \cdot s^{-1}$	25	30	25	30
FV2	x_0/m		50	50	50
	y_0/m		-2	-2	-2
	$v_0/m \cdot s^{-1}$		15	18	15
FV3	x_0/m		70	70	70
	y_0/m		-6	-6	-6
	$v_0/m \cdot s^{-1}$		24	25	30
RV1	x_0/m	10	10	10	10
	y_0/m	2	2	2	2
	$v_0/m \cdot s^{-1}$	20	18	18	18
RV2	x_0/m		15	15	15
	y_0/m		-6	-6	-6
	$v_0/m \cdot s^{-1}$		20	20	20

为验证所设风险势场的合理性,根据第4.1节建立相对速度为10 m/s时障碍车动态风险势场和道路标线风险势场,如图7所示。



(a)障碍车




(b)道路标线

图7 障碍车和道路标线风险势场分布情况


当HV处于道路不同位置时,所受OV动态风险势场的大小随横、纵向位置变化,且纵向势场受相对车速影响而变化趋势更平缓,这使得车辆换道更加顺畅,不会因所受势场变化而发生换道抖动现象或直接导致换道失败。道路标线势场中,道路中心线位置势场最小,车行道边缘线势场远大于分界线,HV始终不会驶出车行道边缘,且能顺利换道至相邻车道并保持在道路中心线上行驶。因此,该风险势场可用于本文高速换道场景模型验证研究。

5.1 基于HV不同驾驶风格的并线场景验证

针对图1a中的工况1,假设RV1驾驶风格为正常型,并将工况1的车辆初始状态输入Stackelberg博弈决策模型和规划控制器中,仿真结果如图8~图10所示。




(a)HV轨迹和换道指令




(b)各车纵向加速度

图8 基于HV不同驾驶风格的并线决策结果



(a)各车纵向速度



(b)HV横向加速度

图9 并线时各车纵向速度及HV横向加速度

图8a中,此场景下3种驾驶风格的HV博弈决策模型的初始输出结果均为 $\lambda^*=1$ 。图8、图9表明,可用到达




图10 HV并线时空轨迹


由于保守型驾驶风格注重安全性,激进型驾驶风格注重行驶效率,正常型驾驶风格居于二者之间,该场景下,3种驾驶风格中保守型HV最先换道,其次是正常型,激进型换道最迟。同时,考虑到前方路况,过大的纵向加速度会增加决策成本,此时,激进型HV纵向加速度远小于其他驾驶风格,在博弈决策过程中也会降低输出的纵向加速度。由3种驾驶风格换道速度变化情况可知,为了与RV1保持安全距离,HV均会先缓慢地加速,其中,正常型与激进型前期加速情况高度相同。若该路况下激进型HV采取更高的加速度,则难以保证与RV1的安全距离,极易产生碰撞。因此,需确保安全换道后再加速,从而提高通行效率。

5.2 基于RV保守型驾驶风格的左换道场景验证


针对图1b中的工况2,假设HV驾驶风格为正常型,RV1和RV2驾驶风格均为保守型,并将工况2的车辆初始状态输入Stackelberg博弈决策模型和规划控制器,仿真结果如图11~图13所示。

如图11a可知,博弈决策模型在该工况下初始输出结果为 $\lambda^*=1$ 。由于FV2速度过低,HV行驶一段时间后未减速或换道将会发生碰撞,此时决策部分评估左、右车道行车情况,发现左、右侧RV均无明显加速意图,即均具备换道条件,但左侧RV1速度更低,且与HV距离更远,因此,HV需选择向左侧加速换道。在换道过程中,HV换道后的轨迹与道路中心线的最大误差为0.128 m,纵向加速度最大值为2.00 m/s²,回正横向加速度最大值为1.73 m/s²,均满足换道舒适性和跟踪误差要求。换道过程耗时6.3 s,HV在换道完成后7.7 s时,跟踪至与FV1保持相同速度行驶,满足高速工况下通行效率的要求,由图13可知,HV在左换道过程中未与周围车辆发生碰撞。

车行道分界线的位置反映不同驾驶风格在HV换道过程中的差异。保守型、正常型和激进型HV到达车行道分界线的纵向位移分别为50.30 m、62.55 m和70.41 m,激进型HV横向误差最大,为0.071 m,正常型和保守型HV误差分别为0.055 m和0.045 m,均满足通行效率和跟踪误差要求。并线过程中,激进型、正常型和保守型HV最大纵向加速度分别为0.49 m/s²、0.28 m/s²和0.24 m/s²,满足行驶舒适性要求。由图10可知,此场景下,3种驾驶风格的HV均会选择向左侧加速换道,且并线过程中均未与周围车辆和前方道路终止处发生碰撞。




(a)HV轨迹和换道指令




(b)各车纵向加速度

图11 基于RV保守型驾驶风格的左换道决策结果



(a)各车纵向速度



(b)HV横向加速度

图12 左换道时各车纵向速度和HV横向加速度





图13 HV左换道时空轨迹

由于RV1和RV2的驾驶风格为保守型,更加注重安全性,即HV加速换道时,RV1和RV2不会以加速行为阻碍HV换道,仅为提高通行效率而缓慢加速以跟踪前车车速。FV1车速(30 m/s)与FV3车速(24 m/s)均大于后方车辆,使得后方车辆具备加速条件,因此初始阶段位于FV1后方的RV1纵向加速度会大于位于FV3后方的RV2。随着RV2的加速,与前车FV3的车速不断接近,RV2的纵向加速度会逐渐减小;RV1初始时跟踪前车FV1的车速,当HV换道至车道1后,RV1转为跟踪HV的车速,并且与HV不断博弈以达到两车整体运行情况最优,由于HV在博弈过程中需要跟踪FV1的车速,且HV车速小于FV1车速,因此导致RV1的纵向加速度在HV换道成功后出现减小,随后缓慢变化的情况。HV在换道起始阶段为纵向加速阶段,决策部分发出换道指令后,HV加速为周围车辆提供换道信号,同时为保证换道安全,需与相邻车道的车辆保持一定距离。随着HV车速不断提高,HV与FV2的距离也随之接近,HV受决策部分纵向安全性成本函数的限制,会出现加速度再度减小的情况,随后,HV则以决策出的最优纵向加速度完成换道过程。

5.3 基于RV激进型驾驶风格的跟驰场景验证

针对图1b中的工况3,假设HV的驾驶风格为正常型,RV1和RV2均为激进型,并将工况3的车辆初始状态输入Stackelberg博弈决策模型和规划控制器,仿真结果如图14~图16所示。



(a)HV轨迹和换道指令






图16 HV跟驰时空轨迹

由于RV1和RV2驾驶风格均为激进型,加速意图比工况2中的保守型更为明显,所以RV1和RV2的起始纵向加速度均大于工况2的起始纵向加速度。HV在行




(b)各车纵向加速度

图14 基于RV激进型驾驶风格的跟驰决策结果



(a)各车纵向速度



(b)HV横向加速度


图15 跟驰时各车纵向速度和HV横向加速度

由图14a可知,博弈决策模型在该工况下初始输出结果 $\lambda^*=0$ 。HV发出换道信号时,激进型的RV1和RV2均会以加速行为阻碍HV换道,且RV1和RV2的车速和位置均与HV相近,强行换道极易发生碰撞,因此,HV减速跟驰行驶。在跟驰过程中,HV沿道路中心线安全行驶,纵向加速度在 2.00 m/s^2 以内,横向加速度最大值为 $0.68 \times 10^{-5} \text{ m/s}^2$,均满足舒适性要求。HV在跟驰过程中由 22 m/s 减速至与FV2的速度 18 m/s 相同,耗时 6.0 s ,两车间最短距离为 14.86 m ,满足驾驶安全性要求,由图16可知,HV在跟驰过程中未与周围车辆发生碰撞。


通行效率, HV 会选择缓慢加速, 当 HV 与 FV2 距离达到跟驰阈值时, 会接受决策部分的跟驰指令, 使得 HV 开始减速直至与 FV2 车速保持一致。

5.4 基于 RV 不同驾驶风格的右换道场景验证

针对图 1b 中的工况 4, 假设 HV、RV1 和 RV2 驾驶风格分别为正常型、激进型和保守型, 且将工况 4 的车辆初始状态输入 Stackelberg 博弈决策模型和规划控制器, 仿真结果如图 17~图 19 所示。




(a) HV 轨迹和换道指令



(b) 各车纵向加速度

图 17 基于 RV 不同驾驶风格的右换道决策结果



(a) 各车纵向速度





图 19 HV 右换道时空轨迹

5.5 仿真测试结果分析

由测试结果可知, 本文模型在上述换道场景下均能够结合车间互动行为及驾驶风格特征作出最优决策, 并实施相应的运动控制。为了验证本文提出的 DPF-NMPC 控制效果, 将采用第 4.2 节运动学模型与文献[19]中的运动学模型的结果进行对比分析, 如表 4 所示。

本文采用的运动学模型以车辆质心为原点, 考虑



(b) HV 横向加速度

图 18 右换道时各车纵向速度和 HV 横向加速度

由图 17a 可知, 博弈决策模型在该工况下初始输出结果 $\lambda^* = -1$, 若此时 RV1 与 RV2 为同种驾驶风格, 根据起始车速和位置判断, HV 向左换道更为有利。但此时 RV1 为激进型驾驶风格, 在 HV 准备向左换道时, RV1 将为保证己车速度和可行空间而加速, 阻碍 HV 成功换道, 而保守型的 RV2 会更加注重安全性, 进而放弃加速, 为 HV 让行。因此, HV 可以选择向右侧加速换道。在换道过程中, HV 换道后的轨迹与道路中心线的最大误差为 0.128 m, 纵向加速度最大值为 2.00 m/s^2 , HV 回正横向加速度最大值为 1.74 m/s^2 , 均满足换道舒适性和跟踪误差要求。整个换道过程耗时 5.6 s, HV 在换道完成后 9.4 s 时, 跟踪至与 FV3 保持相同速度行驶, 满足通行效率的需求, 由图 19 可知, HV 在右换道过程中未与周围车辆发生碰撞。

由于 RV1 的驾驶风格为激进型且跟踪 FV1 的起始纵向加速度达到 2.35 m/s^2 , 以此阻碍 HV 向左侧换道。工况 4 中 RV2 起始纵向加速度与工况 2 的 RV1 相同, 但后续过程中纵向加速度明显较工况 2 低, 两种工况下 RV 的前车速度均为 30 m/s , 而工况 4 中 RV2 起始速度高于工况 2 的 RV1, 且起始位置更靠近 HV。因此, 当 HV 向 RV2 所在车道换道时, 由于二者的速度、位置相较于工况 2 更为接近, 为了保证安全性, RV2 在博弈中降低纵向加速度的输出。

了轮胎侧偏等因素对质心侧偏的影响, 对横向加速度的限制更为充分。因此, 该模型相较于文献[19]的运动学模型, 虽在跟踪精度上并无显著差异, 但横向稳定性方面表现良好, 表明本文提出的规划控制器合理有效。

为了进一步验证 3.2 节提出的博弈决策模型的求解算法效率, 仿真验证在中央处理器 (Central Processing

Unit, CPU)为 Core i5 的计算环境下,将 4 种工况的博弈决策模型使用 PSO 算法的平均求解耗时与内点法 (Interior Point Method, IPM) 进行对比,如图 20 所示。IPM 算法的平均求解耗时为 0.153 s, PSO 算法仅为 0.042 s,对于实时性要求较高的高速自动换道场景而言,采用 PSO 算法明显占优。

表 4 两类运动学模型下 HV 控制效果对比

工况	控制表现	本文模型	文献[19]模型	
工况 1	保守型	最大纵向加速度/ $m \cdot s^{-2}$	0.24	0.22
		最大回正横向加速度/ $m \cdot s^{-2}$	1.72	2.00
		最大道路中心线误差/m	0.045	0.016
	正常型	最大纵向加速度/ $m \cdot s^{-2}$	0.28	0.27
		最大回正横向加速度/ $m \cdot s^{-2}$	1.67	2.00
		最大道路中心线误差/m	0.055	0.016
	激进型	最大纵向加速度/ $m \cdot s^{-2}$	0.49	0.47
		最大回正横向加速度/ $m \cdot s^{-2}$	1.66	2.00
		最大道路中心线误差/m	0.071	0.040
工况 2	最大纵向加速度/ $m \cdot s^{-2}$	2.00	1.95	
	最大回正横向加速度/ $m \cdot s^{-2}$	1.73	2.00	
	最大道路中心线误差/m	0.128	0.025	
工况 3	最大纵向加速度/ $m \cdot s^{-2}$	2.00	2.00	
	最大回正横向加速度/ $m \cdot s^{-2}$			
	最大道路中心线误差/m			
工况 4	最大纵向加速度/ $m \cdot s^{-2}$	2.00	1.94	
	最大回正横向加速度/ $m \cdot s^{-2}$	1.74	2.00	
	最大道路中心线误差/m	0.128	0.024	

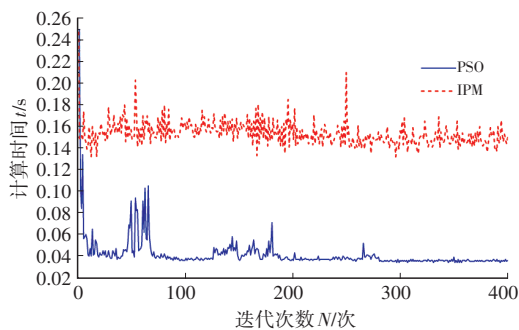


图 20 PSO 和 IPM 算法耗时

6 结束语

本文针对高速换道决策时车间互动性不足、规划控制间匹配性差等问题,基于 Stackelberg 主从博弈理论,综合分析驾驶风格特征和博弈双方的动态交互行为因素,对高速场景下的自动换道决策规划问题进行了研究,根据提出的 Stackelberg 博弈决策模型,将车间互动

行为纳入自车决策,考虑交通参与者间的互动性与个性差异,更加贴合真实场景,并设计基于动态势场法的非线性模型规划控制器,利用风险势场评估换道风险,将横向运动规划与控制问题整合到同一优化系统中,通过质心侧偏的运动学模型预测车辆状态,实时反馈车辆状态,共同完成规划控制任务,大幅提高规划控制部分的匹配性,使规划结果更加可靠,控制效果显著提升。

仿真结果表明,随着相对速度及场景的变化,本文提出的模型可结合车间互动性及各车驾驶风格作出正确的决策,较好地完成相应的运动控制。当前决策主要针对仅存在 1 辆 RV 的简单高速公路场景,未来,将开展多车间交互的 HV 博弈决策模型研究,使决策更加具备实用性。

参 考 文 献

- [1] ZHU X, GU Z Q, WANG Z. Ethical Challenges and Countermeasures of Autonomous Vehicles[J]. E3S Web of Conferences, 2021, 233(2).
- [2] CLAUSSMANN L, REVILLOUD M, GRUYER D, et al. A Review of Motion Planning for Highway Autonomous Driving [J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(5): 1826-1848.
- [3] SU J T, LOU J P, JIANG X L. Overview of Intelligent Vehicle Core Technology and Development[J]. IOP Conference Series: Earth and Environmental Science, 2021, 769(4).
- [4] 谷新平, 韩云鹏, 于俊甫. 基于决策机理与支持向量机的车辆换道决策模型[J]. 哈尔滨工业大学学报, 2020, 52(7): 111-121.
GU X P, HAN Y P, YU J F. Vehicle Lane-Changing Decision Model Based on Decision Mechanism and Support Vector Machine[J]. Journal of Harbin Institute of Technology, 2020, 52(7): 111-121.
- [5] CHENG S L, XU Y, ZONG R X, et al. A Fast Decision Making Method for Mandatory Lane Change Using Kernel Extreme Learning Machine[J]. International Journal of Machine Learning and Cybernetics, 2019, 10(12): 3363-3369.
- [6] WU J, HUANG W, DE BOER N, et al. Safe Decision-Making for Lane-Change of Autonomous Vehicles via Human Demonstration-Aided Reinforcement Learning[C]// 2022 IEEE 25th International Conference on Intelligent Transportation Systems (ITSC). Macau, China: IEEE, 2022: 1228-1233.
- [7] LIU Q, LI X Y, YUAN S H, et al. Decision-Making Technology for Autonomous Vehicles: Learning-Based Methods, Applications and Future Outlook[C]// 2021 IEEE International Intelligent Transportation Systems Conference

- (ITSC). Indianapolis, IN, USA: IEEE, 2021: 30–37.
- [8] ESKANDARIAN A, WU C X, SUN C Y. Research Advances and Challenges of Autonomous and Connected Ground Vehicles[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 22(2): 683–711.
- [9] JI A, LEVINSON D. A Review of Game Theory Models of Lane Changing[J]. Transportmetrica A: Transport Science, 2020, 16(3): 1628–1647.
- [10] WEI C, HE Y H, TIAN H Q, et al. Game Theoretic Merging Behavior Control for Autonomous Vehicle at Highway On-Ramp[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(11): 21127–21136.
- [11] LOPEZ V G, LEWIS F L, LIU M S, et al. Game-Theoretic Lane-Changing Decision Making and Payoff Learning for Autonomous Vehicles[J]. IEEE Transactions on Vehicular Technology, 2022, 71(4): 3609–3620.
- [12] ZHANG Y R, HANG P, HUANG C, et al. Human-Like Interactive Behavior Generation for Autonomous Vehicles: A Bayesian Game-Theoretic Approach with Turing Test[J]. Advanced Intelligent Systems, 2022, 4(5).
- [13] 张殿富, 刘福. 基于人工势场法的路径规划方法研究及展望[J]. 计算机工程与科学, 2013, 35(6): 88–95.
ZHANG D F, LIU F. Research and Development Trend of Path Planning Based on Artificial Potential Field Method [J]. Computer Engineering & Science, 2013, 35(6): 88–95.
- [14] WANG P W, GAO S, LI L, et al. Obstacle Avoidance Path Planning Design for Autonomous Driving Vehicles Based on an Improved Artificial Potential Field Algorithm[J]. Energies, 2019, 12(12): 2342.
- [15] OROZCO-ROSAS U, MONTIEL O, SEPULVEDA R. Mobile Robot Path Planning Using Membrane Evolutionary Artificial Potential Field[J]. Applied Soft Computing Journal, 2019, 77: 236–251.
- [16] TU Q, CHEN H, LI J C. A Potential Field Based Lateral Planning Method for Autonomous Vehicles[J]. SAE International Journal of Passenger Cars–Electronic and Electrical Systems, 2016, 10(1): 24–34.
- [17] VON STACKELBERG H. Market Structure and Equilibrium[M]. Springer Science & Business Media, 2010.
- [18] HANG P, LV C, HUANG C, et al. Cooperative Decision Making of Lane-Change for Automated Vehicles Considering Human-Like Driving Characteristics[C]// 2021 40th Chinese Control Conference (CCC). Shanghai, China: IEEE, 2021: 6106–6111.
- [19] JI K, ORSAG M, HAN K. Lane-Merging Strategy for a Self-Driving Car in Dense Traffic Using the Stackelberg Game Approach[J]. Electronics, 2021, 10(8): 894.
- [20] LV C, HU X S, SANGIOVANNI-VINCENTELLI A, et al. Driving-Style-Based Codesign Optimization of An Automated Electric Vehicle: A Cyber-Physical System Approach[J]. IEEE Transactions on Industrial Electronics, 2019, 66(4): 2965–2975.
- [21] MARTINEZ C M, HEUCKE M, WANG F Y, et al. Driving Style Recognition for Intelligent Vehicle Control and Advanced Driver Assistance: A Survey[J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 19(3): 666–676.
- [22] 皇甫淑云, 唐守锋, 童紫原, 等. 自主移动机器人路径规划方法研究综述[J]. 软件导刊, 2018, 17(10): 1–5.
HUANGFU S Y, TANG S F, TONG Z Y, et al. A Survey of Path Planning Methods for Autonomous Mobile Robots[J]. Software Guide, 2018, 17(10): 1–5.
- [22] WU Y L, LI S M, ZHANG Q J, et al. Route Planning and Tracking Control of An Intelligent Automatic Unmanned Transportation System Based on Dynamic Nonlinear Model Predictive Control[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(9): 16576–16589.

(责任编辑 瑞 秋)

修改稿收到日期为2023年8月16日。