

# 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\*

钱立军<sup>1</sup>, 陈健<sup>1</sup>, 赵丰<sup>2</sup>, 陈欣宇<sup>1</sup>, 宣亮<sup>1</sup>

(1. 合肥工业大学汽车与交通工程学院, 合肥 230009; 2. 中国人民解放军32381部队, 北京 100070)

**[摘要]** 为解决网联汽车由于驾驶员误差存在导致的速度轨迹偏移问题, 本文提出一种实时的考虑驾驶员误差的网联混合车队生态驾驶策略。首先通过实车试验采集不同驾驶员的驾驶员误差数据, 建立基于马尔可夫链的驾驶员误差模型, 用于预测未来一段时间的驾驶员误差。然后以最小化整个车队的燃油消耗为优化目标, 将车队速度轨迹优化问题描述为一个最优控制问题, 采用快速随机模型预测控制(fast stochastic model predictive control, FSMPC)算法求解车队中网联汽车的最优速度轨迹。仿真和智能网联微缩车试验结果表明, 相比于传统的基于快速模型预测控制(fast model predictive control, FMPC)的生态驾驶策略, 本文所提出的生态驾驶策略能够有效减小车辆的速度轨迹偏移, 并降低整个车队的燃油消耗, 且满足实时性要求。

**关键词:** 网联汽车; 驾驶员误差; 快速随机模型预测控制; 混合车队

## Research on Fast Stochastic Model Predictive Control-Based Eco-Driving Strategy for Connected Mixed Platoons

Qian Lijun<sup>1</sup>, Chen Jian<sup>1</sup>, Zhao Feng<sup>2</sup>, Chen Xinyu<sup>1</sup> & Xuan Liang<sup>1</sup>

1. Department of Automotive and Traffic Engineering, Hefei University of Technology, Hefei 230009;

2. Unit 32381 of the PLA, Beijing 100070

**[Abstract]** To address the problem of speed trajectory deviation of connected vehicles (CVs) caused by human driver error, a real-time eco-driving strategy for connected mixed platoons considering human driver error is proposed in this paper. Firstly, real vehicle tests are conducted to collect human driver error data of different drivers to establish the human driver error model based on Markov chain so as to predict the human driver error for a period of time in the future. Then, with the optimization objective of minimizing the fuel consumption of the entire platoon, the platoon speed trajectory optimization problem is formulated as an optimal control problem. Fast stochastic model predictive control (FSMPC) is employed to calculate the optimal speed trajectories of the connected vehicle in the mixed platoon. Both the simulation and intelligent and connected micro-car test results indicate that, compared to the traditional eco-driving strategy based on fast model predictive control (FMPC), the proposed eco-driving strategy can effectively reduce the speed trajectory deviation and fuel consumption of the whole platoon as well as meet the real-time requirements.

**Keywords:** connected vehicle; human driver error; fast stochastic model predictive control; mixed platoon

\* 国家自然科学基金面上项目(51875149)资助。

原稿收到日期为2024年03月16日, 修改稿收到日期为2024年04月14日。

通信作者: 钱立军, 教授, 博士, E-mail: qianlijun66@163.com。

## 前言

生态驾驶(eco-driving)是一种节能减排的驾驶行为,通常来说,是指驾驶员根据交通条件选择合适的行驶路线和调整车辆的行驶速度以最小化车辆的能量消耗<sup>[1-2]</sup>。随着智能网联技术的发展,车辆之间不仅能够共享状态信息,同时也能够实现协同运动。因此,生态驾驶技术在多车场景下的应用,即车队生态驾驶,正受到越来越多的关注和研究。不同于单车场景下的生态驾驶只考虑自车的能量消耗,多车场景下的生态驾驶旨在通过不同车辆之间协同运动实现整个车队的能耗最小化。相关研究表明,相比于单车生态驾驶,车队生态驾驶可以进一步提升信号交叉口的道路容量,提高车辆的通行效率、燃油经济性和安全性<sup>[3-5]</sup>。

近几年来,许多国内外学者对基于智能网联技术的车队生态驾驶进行了研究。文献[6]中提出了一种智能网联车队生态协同自适应巡航控制(ecological cooperative adaptive cruise control, Eco-CACC)策略,该策略分别采用动态规划和PID控制实现领航车的速度轨迹规划和其他车辆的跟随控制。仿真结果表明,所提出的Eco-CACC策略相比于人工驾驶降低了车队的能量消耗。文献[7]中提出了一种基于MPC和分布式线性反馈控制(distributed linear feedback control, DLFC)的异质车队Eco-CACC方法,该方法提高了车队的燃油经济性、乘坐舒适性和通行效率。针对车车通讯丢包问题,文献[8]中设计了一种异质车队分布式 $H_\infty$ 控制器,仿真结果表明在有外部干扰和通讯丢包存在的场景下,该控制器有效提高车队的稳定性和鲁棒性。针对由智能网联汽车和传统的人类驾驶汽车混行的交通环境,文献[9]中提出了一种由人类驾驶汽车和智能网联汽车组成的混合车队协同控制方法。该方法基于最优速度模型估计人类驾驶汽车的速度轨迹,采用MPC算法优化车队中智能网联汽车的速度轨迹。仿真结果表明,所提出的协同控制方法有效提高了整个车队的燃油经济性。文献[10]中提出了“1+n”混合车队的概念,即由1辆智能网联汽车和n辆人类驾驶汽车组成的车队,基于此建立了车队的线性动力学模型,并对其开环稳定性和可控性进行理论分析。基于“1+n”混合车队模型,作者提出一种信号交叉口混合车队的最优控制方法,通过优化

智能网联汽车的速度轨迹降低了整个车队的行程时间延误和燃油消耗。文献[11]和文献[12]中提出了基于混合MPC系统的编队生态驾驶控制策略,该策略包含3个MPC控制器,分别用于车队在接近交叉口、车队拆分和通过交叉口时的速度轨迹优化。仿真结果表明,该策略有效提高了交叉口的通行效率并降低了车队的能耗和排放。然而上述研究主要针对由自动驾驶汽车组成的车队,考虑到车辆要实现完全网联自动驾驶依然需要很长一段发展时间,在车队控制中考虑驾驶员操作对车辆速度轨迹的影响目前研究较少。文献[13]中对网联汽车的生态驶入和离开(eco-approach and departure, EAD)策略进行道路测试,结果表明在有驾驶员操作误差存在的情况下,EAD策略的真实节油效果相比于仿真变差。因此,对于由驾驶员操控的混合车队控制有必要考虑驾驶员操作误差的影响。文献[14]中提出了一种考虑驾驶员误差的网联汽车生态驾驶方法,采用随机模型预测控制(stochastic model predictive control, SMPC)算法优化车辆的速度轨迹。然而文献[14]仅针对单车场景下的车辆控制进行研究,没有考虑多车场景下车辆之间的相互影响。另外,对于车队而言,随着预测时域、状态变量和控制变量的数量增加,SMPC算法的计算效率降低,难以满足实际应用的实时性要求。

为解决上述问题,针对网联汽车与人类驾驶汽车混行的交通场景,本文提出了一种实时的考虑驾驶员误差的混合车队生态驾驶策略。通过实车试验采集真实的驾驶员误差数据,建立驾驶员误差模型。基于驾驶员误差模型预测的驾驶员误差信息、交通信号配时信息以及车队中车辆的状态信息,以提高整个车队的燃油经济性为优化目标,采用FSMPC算法求解车队中网联汽车的最优速度轨迹。最后对所提出的生态驾驶策略进行仿真和智能网联微缩车试验验证。

## 1 混合车队生态驾驶方案

本文研究混合交通环境下信号交叉口场景如图1所示。在车道上同时存在网联汽车和人类驾驶汽车,两者可以组成车队行驶。本文中混合车队定义为同一车道上由网联汽车和传统的人类驾驶汽车组成(网联汽车作为领航车)且能够在相同的信号灯绿灯时期通过交叉口的的一组车辆<sup>[9-10]</sup>。为降低优化问

题建模的复杂度,对研究场景做出如下假设:(1)路边单元能够通过传感技术(如雷达、摄像头等)获取人类驾驶汽车的位置和速度等信息;(2)车辆遵循先进先出的规则,不考虑换道和超车的情况;(3)V2I和V2V通信是实时准确的,不存在延时和丢包;(4)所有的网联汽车均由驾驶员操控,不考虑自动驾驶功能;(5)不考虑风阻、路面阻力系数变化以及传感器测量噪声等外界干扰的影响。




图1 信号交叉口场景

混合车队生态驾驶方案如图2所示。路边单元通过V2I通信或者传感技术获取道路上车辆的状态信息(例如位置、速度等),并将车辆或车队拆分或合并为不同的队列。车队中的网联汽车可与路边单元以及周围车辆进行实时通信,获取前方交叉口的道路交通信息和周围车辆的状态信息,同时可通过车载传感器获取自车的状态信息和驾驶员误差信息。利用上述信息,车载计算机计算车队到达交叉口的终端时间,使得车辆能够在绿灯时间窗口通过交叉口。同时,车载计算机基于驾驶员误差模型预测未来时刻的驾驶员误差,基于跟车模型预测车队中人类驾驶汽车的速度轨迹。将上述信息作为输入,以最小化整个车队的燃油消耗为优化目标,车载计算机采用FSMPC算法求解网联汽车的最优速度轨迹,并通过交互界面以建议车速的形式显示给驾驶员,驾驶员操控车辆以跟随建议车速行驶。

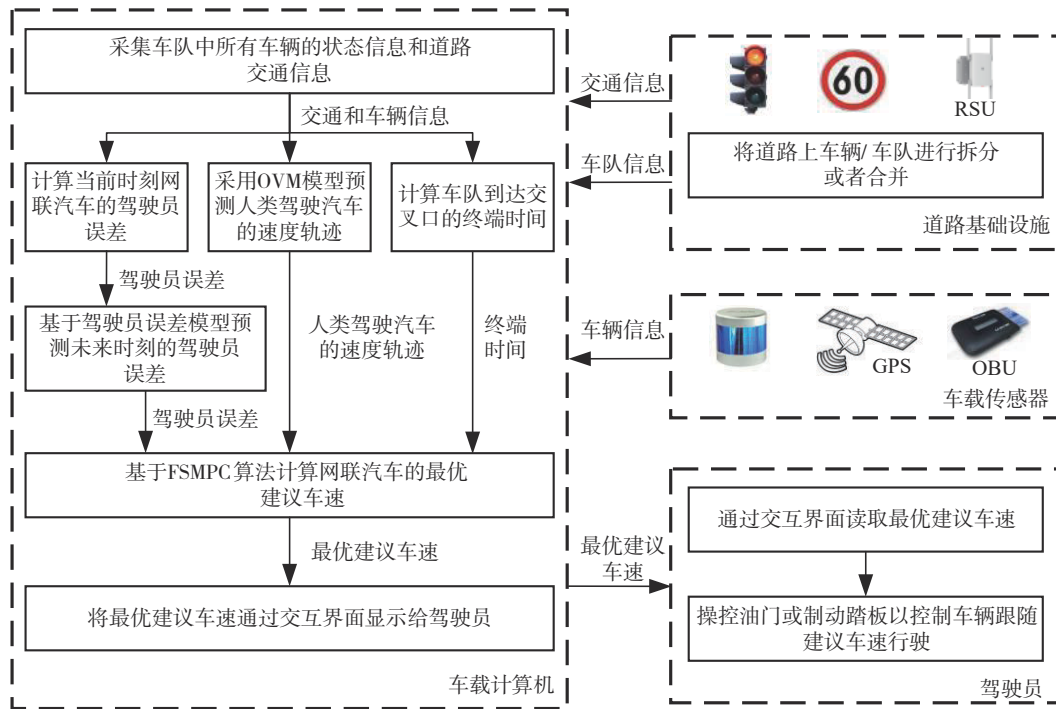


图2 混合车队生态驾驶方案

## 2 系统建模

### 2.1 最优速度模型

采用最优速度模型(optimal velocity model, OVM)<sup>[15]</sup>描述人类驾驶汽车的跟车运动。在该模型中,车辆的加速度由自身车速以及自车与前车的车

头间距决定,可通过式(1)和式(2)计算得到:

$$a_i = \kappa [V_{ov}(s_{i-1} - s_i) - v_i] \quad (1)$$

$$V_{ov} = V_1 + V_2 \tanh[C_1(s_{i-1} - s_i - l_{veh}) - C_2] \quad (2)$$

式中: $a_i$ 为车辆加速度; $s_i$ 和 $s_{i-1}$ 分别为自车与前车的位置; $v_i$ 为车辆速度; $V_{ov}$ 为最优速度,是车头间距的函数; $l_{veh}$ 为车辆长度; $\kappa$ 为驾驶员敏感系数; $V_1$ 、

$V_2$ 、 $C_1$ 和 $C_2$ 均为须通过试验数据标定的参数,无实际物理意义。OVM模型参数的选取来自文献[15],如表1所示。

表1 OVM模型参数<sup>[15]</sup>

参数	$\kappa/s^{-1}$	$V_1/(m \cdot s^{-1})$	$V_2/(m \cdot s^{-1})$	$C_1/m^{-1}$	$C_2$	$l_{veh}/m$
数值	0.85	6.75	7.91	0.13	1.57	5

## 2.2 混合车队模型

在本文中混合车队由一辆网联汽车和 $n$ 辆人类驾驶汽车组成,网联汽车作为领航车。与文献[10]类似,假设车队以预先设定的平衡车速 $v_{eq}$ 和平衡车头间距 $d_{eq}$ 通过交叉口,并满足式(3):

$$a_i = \kappa [V_{ov} d_{eq} - v_{eq}] = 0 \quad (3)$$

将跟随车辆 $i$ 当前状态 $(d_i(t), v_i(t))$ 与平衡状态 $(d_{eq}, v_{eq})$ 的差作为其状态参数:

$$\begin{cases} d'_i(t) = d_i(t) - d_{eq} \\ v'_i(t) = v_i(t) - v_{eq} \end{cases}, i = 1, 2, \dots, n \quad (4)$$

式中 $d_i(t) = s_{i-1}(t) - s_i(t)$ 为跟随车辆与前车的车头间距。将式(1)1阶泰勒展开,则跟随车辆在平衡状态 $(d_{eq}, v_{eq})$ 处的线性动力学方程如式(5)所示:

$$\begin{cases} \widehat{d}'_i(t) = v_{i-1}(t) - v_i(t) \\ \widehat{v}'_i(t) = f_1 d'_i(t) - f_2 v'_i(t) - f_3 v'_{i-1}(t) \end{cases}, i = 1, 2, \dots, n \quad (5)$$

其中: $f_1 = \kappa V_2 C_1 \{1 - \tanh^2[C_1(d_i(t) - l_{veh}) - C_2]\}$

$$f_2 = \kappa; f_3 = 0$$

考虑驾驶员误差的网联汽车非线性纵向动力学方程<sup>[14]</sup>如式(6)所示:

$$\begin{cases} \dot{s}_0(t) = v_0(t) \\ \dot{v}_0(t) = -\frac{1}{2M} C_D \rho_a A_v [v_0(t)]^2 - fg - g\theta + u_f(t) \\ u_f(t) = u(t) + e(t) \end{cases} \quad (6)$$

式中: $M$ 、 $C_D$ 、 $\rho_a$ 、 $A_v$ 、 $f$ 、 $\theta$ 分别为车辆的整备质量、空气阻力系数、空气密度、迎风面积、滚动阻力系数和路面坡度; $g$ 为重力加速度; $u_f$ 为单位质量车辆的实际驱动力或制动力; $u$ 为单位质量车辆的最优驱动力或制动力; $e$ 为驾驶员误差,驾驶员误差定义为驾驶员操控车辆跟随建议车速行驶时车辆单位质量的实际驱动力或制动力与车载计算机计算的单位质量的最优驱动力或制动力之间的差值<sup>[14]</sup>。

由式(5)和式(6)可以得到整个混合车队系统的状态矩阵,如式(7)所示:

$$\dot{\mathbf{x}}(t) = [s_0(t), v_0(t), d'_1(t), v'_1(t), \dots, d'_n(t), v'_n(t)]^T \quad (7)$$

则混合车队系统的状态空间方程如式(8)所示:

$$\dot{\mathbf{x}}(t) = \mathbf{A}\mathbf{x}(t) + \mathbf{B}u(t) + \boldsymbol{\varepsilon}(t) \quad (8)$$

其中: $\mathbf{A} \in \mathbb{R}^{(2n+2) \times (2n+2)}$ ;  $\mathbf{B} \in \mathbb{R}^{(2n+2) \times 1}$

$$\mathbf{A} = \begin{bmatrix} C_1 & 0 & \dots & \dots & 0 & 0 \\ A_2 & A_1 & 0 & \dots & \dots & 0 \\ 0 & A_2 & A_1 & 0 & \dots & 0 \\ \vdots & \ddots & \ddots & \ddots & \ddots & \vdots \\ 0 & \dots & 0 & A_2 & A_1 & 0 \\ 0 & \dots & \dots & 0 & A_2 & A_1 \end{bmatrix}; \mathbf{B} = \begin{bmatrix} B_1 \\ B_2 \\ B_2 \\ \vdots \\ B_2 \\ B_2 \end{bmatrix}$$

$$A_1 = \begin{bmatrix} 0 & -1 \\ f_1 & -f_2 \end{bmatrix}; A_2 = \begin{bmatrix} 0 & 1 \\ 0 & f_3 \end{bmatrix}; B_1 = \begin{bmatrix} 0 \\ 1 \end{bmatrix}; B_2 = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

$$C_1 = \begin{bmatrix} 0 & & & & & 1 \\ 0 & -\frac{1}{2M_0} C_D \rho_a A_v v_0 - \frac{fg}{v_0} - \frac{g\theta}{v_0} & & & & \end{bmatrix}$$

式中: $\mathbf{x}$ 为状态矩阵; $u$ 为控制输入; $\boldsymbol{\varepsilon}$ 为由驾驶员误差导致的干扰。

需要说明的是,在多车场景中一个车队可能包含多辆网联汽车。为保证所建立的混合车队动力学模型能够适用于不同的车队类型,在本文所提出的生态驾驶策略中,跟随的网联汽车将采用传统的人类驾驶汽车模式<sup>[10]</sup>。

## 2.3 车辆油耗模型

车辆燃油消耗模型<sup>[16]</sup>可以由式(9)和式(10)表示:

$$\dot{m}_{fuel}(t) = \alpha + \beta_1 P_T(t) + (\beta_2 Ma(t)^2 v(t))_{a(t) > 0} \quad (9)$$

$$P_T(t) = \max\{0, d_1 v(t) + d_2 v(t)^2 + d_3 v(t)^3 + Ma(t)v(t)\} \quad (10)$$

式中: $\dot{m}_{fuel}(t)$ 为车辆燃油消耗; $P_T(t)$ 为车辆总需求功率; $\alpha$ 为怠速燃油消耗率; $\beta_1$ 、 $\beta_2$ 、 $d_1$ 、 $d_2$ 和 $d_3$ 为模型参数,参数选取来自文献[16],如表2所示。

表2 燃油消耗模型参数<sup>[16]</sup>

参数	$\alpha$	$\beta_1$	$\beta_2$	$d_1$	$d_2$	$d_3$
数值	0.666	0.072	0.034 4	0.269	0.017 1	0.000 672

## 2.4 驾驶员误差模型

驾驶员误差的变化符合随机马尔可夫过程,即下一时刻的驾驶员误差仅与当前时刻的驾驶员误差相关<sup>[14]</sup>。因此,通过建立马尔可夫链模型来模拟驾驶员误差的变化,其状态转移概率矩阵的计算过程如下。

(1)根据驾驶员误差的变化范围将其离散成为有限数量状态:

$$e \in \{e_1, e_2, e_3, \dots, e_{N_e}\} \quad (11)$$

式中:  $\{e_1, e_2, e_3, \dots, e_{N_e}\}$  为驾驶员误差的状态空间;  $N_e$  为驾驶员误差状态的数量。

(2) 对任意驾驶员误差状态  $e_i$ , 驾驶员误差从状态  $e_i$  转移到状态  $e_j$  的概率可以由式(12)计算得到:

$$\tau_{ij} = \frac{N_{ij}}{N_i} \quad (12)$$

式中:  $\tau_{ij}$  为驾驶员误差从状态  $e_i$  转移到状态  $e_j$  的概率;  $N_{ij}$  为驾驶员误差从状态  $e_i$  转移到状态  $e_j$  的次数;  $N_i$  为驾驶员误差从状态  $e_i$  转移的次数总和。

(3) 驾驶员误差的状态转移概率矩阵可以由式(13)表示:

$$T_e = \begin{bmatrix} \tau_{11} & \tau_{12} & \tau_{13} & \cdots & \tau_{1N_e} \\ \tau_{21} & \tau_{22} & \tau_{23} & \cdots & \tau_{2N_e} \\ \tau_{31} & \tau_{32} & \tau_{33} & \cdots & \tau_{3N_e} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \tau_{N_e,1} & \tau_{N_e,2} & \tau_{N_e,3} & \cdots & \tau_{N_e,N_e} \end{bmatrix} \quad (13)$$

式中  $T_e$  为状态转移概率矩阵。

## 2.5 随机模型预测控制器建模

### 2.5.1 平衡车速

平衡车速的选择旨在最大化车队在绿灯相位时间内通过交叉口的车辆数量同时减少单位距离燃油消耗。对于由一辆网联汽车和  $n$  辆人类驾驶汽车组成的混合车队, 其在绿灯相位时间内通过交叉口的

最大跟随车辆数量可由式(14)和式(15)计算得到:

$$n_{\max} = \frac{v_{\text{eq}} t_g}{d_{\text{eq}}} \quad (14)$$

$$d_{\text{eq}} = \frac{1}{C_1} \left[ \arctan \left( \frac{v_{\text{eq}} - V_1}{V_2} \right) + C_2 \right] + l_{\text{veh}} \quad (15)$$

式中:  $n_{\max}$  为最大跟随车辆数量;  $t_g$  为绿灯时间间隔。

车辆单位距离油耗  $m_{\text{fuel},s}$  可由式(16)计算得到:

$$m_{\text{fuel},s} = \frac{\dot{m}_{\text{fuel}}}{v_{\text{eq}}} = \frac{\alpha}{v_{\text{eq}}} + \beta_1 \left[ d_1 + d_2 v_{\text{eq}} + d_3 (v_{\text{eq}})^2 \right] \quad (16)$$

则最优平衡车速可通过求解如下最优化问题得到:

$$\begin{cases} v_{\text{eq}}^* = \arg \max (n - m_{\text{fuel},s}) \\ \text{subject to: } \kappa [V_{\text{ov}} d_{\text{eq}} - v_{\text{eq}}] = 0 \end{cases} \quad (17)$$

式中  $v_{\text{eq}}^*$  为最优平衡车速。

图3为不同平衡车速下车队的平衡车头间距、最大跟随车辆数量以及单位距离油耗仿真结果。从图3可以看出, 平衡车头间距随着平衡车速的增加而增大, 跟随车辆数量则是先增大后减少, 当平衡车速为 12 m/s 时, 跟随车辆数量达到最大值。另外, 车辆单位距离油耗随着平衡车速的增加而逐渐减小, 然而随着平衡车速的增加, 油耗的降低幅度变得不明显。综合考虑车辆的通行效率和燃油经济性, 本文最优平衡车速选取为 12 m/s。

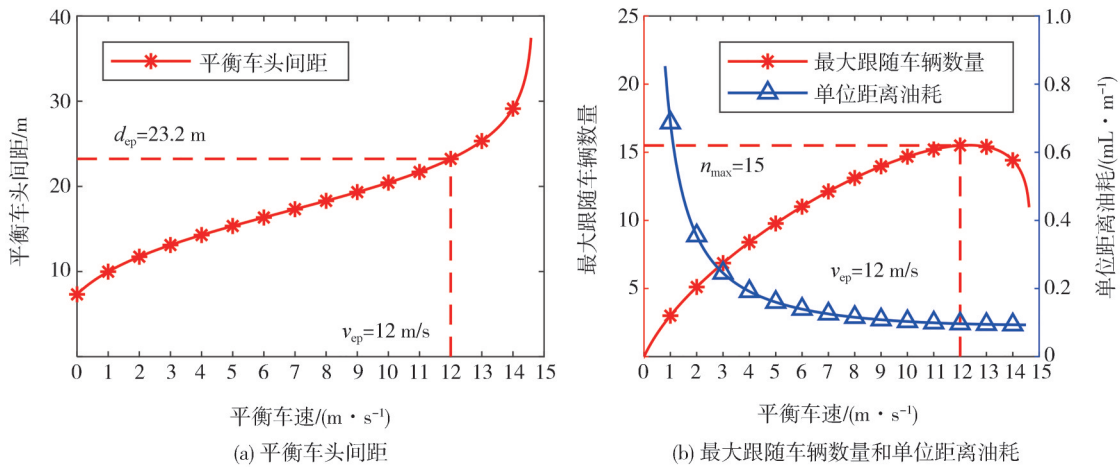


图3 不同平衡车速下平衡车头间距、最大跟随车辆数量以及单位距离油耗仿真结果

### 2.5.2 成本函数设计

已知当前时刻的驾驶员误差状态, 利用转移概率矩阵可以估计下一时刻驾驶员误差状态出现的概率, 例如假设当前时刻驾驶员误差状态为  $e_i$ , 则下一

时刻其转移到状态  $e_j$  的概率为  $\tau_{ij}$ 。图4为一个场景树例子, 假设驾驶员误差状态的数量为3, 分别为  $e_1$ 、 $e_2$  和  $e_3$ , 预测时域从  $t_0$  到  $t_4$ 。定义从初始时刻的驾驶员误差状态到经过一段预测时域后驾驶员误差状态

为一条路径(如图4红色箭头所示),则路径出现的概率为不同时刻下驾驶员误差状态转移概率的乘积,即 $p = \tau_{21} \times \tau_{13} \times \tau_{32} \times \tau_{22}$ 。通过场景树模型可以计算所有路径出现的概率值。




图4 场景树

考虑到驾驶员误差的不确定性,本文采用SMPC算法求解车队中网联汽车的最优速度轨迹。SMPC的优化目标为使车队在绿灯时间窗口到达交叉口停车线且以最优平衡车速通过交叉口。其成本函数定义为领航车位置和目标位置差的平方、领航车单位质量的驱动力或制动力和目标驱动力差的平方以及全部车辆速度和最优平衡车速差的平方的期望之和,如下式所示:

$$J = \sum_{s=1}^{N_{sp}} p_s \sum_{t=k}^{k+T-1} [\omega_1 (s_0(t) - s_{tar}(t))^2 + \omega_2 \sum_{i=0}^n (v_i(t) - v_{eq}^*)^2 + \omega_3 (u(t) - e_s(t) - u_{tar}(t))^2] \quad (18)$$

$$s_{tar}(t) = s_{if} - (t_f - t) v_{eq}^* \quad (19)$$

$$u_{tar}(t) = \frac{1}{2M} C_D \rho_a A_v [v_0(t)]^2 + fg + g\theta \quad (20)$$

式中: $\omega_1$ 、 $\omega_2$ 和 $\omega_3$ 为权重系数; $s_{tar}$ 为车辆目标位置; $s_{if}$ 为停车线位置; $t_f$ 为终端时间; $u_{tar}$ 为目标驱动力,文中目标驱动力为单位质量车辆的空气阻力、滚动阻力和坡度阻力之和; $N_{sp}$ 为路径数量; $p_s$ 为路径出现的概率; $e_s$ 为路径上不同时刻驾驶员误差状态的集合; $T$ 为预测步长。

终端时间 $t_f$ 可由式(21)计算得到:

$$t_f = \max(t_{min}, t_{f,pre} + t_h) \quad (21)$$

$$t_{min} = \begin{cases} K_w t_c - t_g, & \text{红灯} \\ \frac{d_s}{v_{eq}} + t, & \text{绿灯且 } \frac{d_s}{K_w t_c - t} \leq v_{eq}^* \\ K_w t_c + t_r, & \text{绿灯且 } \frac{d_{i,s}}{K_w t_c - t} > v_{eq}^* \end{cases} \quad (22)$$

$$\text{信号灯状态} = \begin{cases} \text{红灯}, & 0 \leq \text{mod}\left(\frac{t}{t_c}\right) < t_r \\ \text{绿灯}, & t_r \leq \text{mod}\left(\frac{t}{t_c}\right) \leq t_c \end{cases} \quad (23)$$

式中: $t_{min}$ 为领航车能够在信号灯绿灯时期通过交叉口的最早时间; $t_{f,pre}$ 为前车的终端时间; $t_h$ 为前后车辆之间的安全车头时距; $d_s$ 为车辆到停车线的距离; $t_r$ 和 $t_g$ 分别为信号灯红灯和绿灯的持续时间; $t_c$ 为信号灯一个循环的持续时间; $K_w$ 为描述信号灯循环次数的整数。

### 2.5.3 约束条件

约束条件考虑车辆的运动学约束以及安全约束,如式(24)~式(26)所示:

$$v_{min} \leq v_i(t) \leq v_{max} \quad (24)$$

$$u_{min} \leq u(t) \leq u_{max} \quad (25)$$

$$s_j(t) - s_i(t) - l_{veh} \geq d_{safe} \quad (26)$$

式中: $v_{min}$ 和 $v_{max}$ 分别为道路最小和最大允许车速; $u_{min}$ 和 $u_{max}$ 分别为单位质量车辆的最小和最大驱动力或制动力; $s_j$ 为前车位置; $d_{safe}$ 为前后车辆的安全距离。

### 2.5.4 最优控制问题描述

基于上述成本函数和约束条件,混合车队速度轨迹优化的最优控制问题可由式(27)描述:

$$\begin{cases} \arg \min_{u(t)} J = \sum_{s=1}^{N_{sp}} p_s \sum_{t=k}^{k+T-1} [\omega_1 (s_0(t) - s_{tar}(t))^2 + \omega_2 \sum_{i=0}^n (v_i(t) - v_{eq}^*)^2 + \omega_3 (u(t) - e_s(t) - u_{tar}(t))^2] \\ \text{subject to: 式(24), 式(25), 式(26)} \end{cases} \quad (27)$$

## 3 随机模型预测控制快速求解

为提高算法的实时性,本文采用快速随机模型预测控制方法<sup>[17-18]</sup>来求解最优控制问题。

由于未来时刻的驾驶员误差状态只与当前时刻驾驶员误差状态有关,因此由驾驶员误差导致的干扰 $\boldsymbol{\varepsilon}(t)$ 与时间无关,本文采用当前时刻和未来时刻预测的干扰的平均值 $\bar{\boldsymbol{\varepsilon}}$ 替代 $\boldsymbol{\varepsilon}(t)$ 以简化混合车队系统的状态空间方程,如式(28)所示:

$$\dot{\boldsymbol{x}}(t) = \boldsymbol{A}\boldsymbol{x}(t) + \boldsymbol{B}u(t) + \bar{\boldsymbol{\varepsilon}} \quad (28)$$

混合车队系统的状态和控制约束式(24)~式(26)可以写成如下矩阵形式:

$$\boldsymbol{F}_x \boldsymbol{x}(t) \leq \boldsymbol{f}_x \quad (29)$$

$$\boldsymbol{F}_u u(t) \leq \boldsymbol{f}_u \quad (30)$$

其中: $\boldsymbol{F}_x \in \mathbb{R}^{(2n+3) \times (2n+2)}$ ;  $\boldsymbol{f}_x \in \mathbb{R}^{(2n+3) \times 1}$

$$F_u = \begin{bmatrix} 1 \\ -1 \end{bmatrix}; f_u = \begin{bmatrix} u_{\max} \\ u_{\min} \end{bmatrix}$$

$$F_x = \begin{bmatrix} 1 & 0 & 0 & 0 & \cdots & 0 & 0 \\ 0 & 1 & 0 & 0 & \cdots & 0 & 0 \\ 0 & -1 & 0 & 0 & \cdots & 0 & 0 \\ 0 & 0 & 1 & 0 & \cdots & 0 & 0 \\ 0 & 0 & 0 & 1 & \cdots & 0 & 0 \\ 0 & 0 & 0 & -1 & \cdots & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & \cdots & 1 & 0 \\ 0 & 0 & 0 & 0 & \cdots & 0 & 1 \\ 0 & 0 & 0 & 0 & \cdots & 0 & -1 \end{bmatrix}$$

$$f_x = \begin{bmatrix} s_j(t) - l_{\text{veh}} - d_{\text{safe}} \\ v_{\max} \\ v_{\min} \\ d_{\text{eq}}^* + l_{\text{veh}} + d_{\text{safe}} \\ v_{\max} \\ v_{\min} \\ \vdots \\ d_{\text{eq}}^* + l_{\text{veh}} + d_{\text{safe}} \\ v_{\max} \\ v_{\min} \end{bmatrix}$$

首先,将最优控制问题的成本函数式(18)改写为如下形式:

$$J = \sum_{s=1}^{N_p} p_s \sum_{t=k}^{k+T-1} [\omega_1 (s_0(t) - s_{\text{tar}}(t))^2 + \omega_2 \sum_{i=0}^n (v_i(t) - v_{\text{eq}})^2 + \omega_3 (u(t) - e_s(t) - u_{\text{tar}}(t))^2] =$$

$$\sum_{t=k}^{k+T-1} [\varphi_1 (s_0(t) - s_{\text{tar}}(t))^2 + \varphi_2 \sum_{i=0}^n (v_i(t) - v_{\text{eq}})^2 + \varphi_3 \left( u(t) - u_{\text{tar}}(t) - \frac{\sum_{s=1}^{N_p} p_s e_s(t)}{\sum_{s=1}^{N_p} p_s} \right)^2] + C_1 =$$

$$\sum_{t=k}^{k+T-1} [\phi(\mathbf{x}(t), u(t)) + C_1] \tag{31}$$

$$\phi(\mathbf{x}, u) = \begin{bmatrix} \mathbf{x}(t) - \mathbf{x}_{\text{tar}}(t) \\ u(t) - u_{\text{des}}(t) \end{bmatrix}^T \begin{bmatrix} \mathbf{Q} & \mathbf{S} \\ \mathbf{S}^T & \mathbf{R} \end{bmatrix} \begin{bmatrix} \mathbf{x}(t) - \mathbf{x}_{\text{tar}}(t) \\ u(t) - u_{\text{des}}(t) \end{bmatrix} \tag{32}$$

$$u_{\text{des}}(t) = u_{\text{tar}}(t) + \frac{\sum_{s=1}^{N_p} p_s e_s(t)}{\sum_{s=1}^{N_p} p_s} \tag{33}$$

其中:  $\mathbf{Q} \in \mathbb{R}^{(2n+2) \times (2n+2)}$ ;  $\mathbf{S} \in \mathbb{R}^{(2n+2) \times 1}$ ;  $\mathbf{R} = [\varphi_3]$

$$\mathbf{Q} = \begin{bmatrix} \varphi_1 & 0 & 0 & \cdots & 0 & 0 & 0 \\ 0 & \varphi_2 & 0 & \cdots & 0 & 0 & 0 \\ 0 & 0 & 0 & \cdots & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & \cdots & \varphi_2 & 0 & 0 \\ 0 & 0 & 0 & \cdots & 0 & 0 & 0 \\ 0 & 0 & 0 & \cdots & 0 & 0 & \varphi_2 \end{bmatrix}$$

$$\mathbf{S} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ \vdots \\ 0 \\ 0 \\ 0 \end{bmatrix}$$

式中:  $\mathbf{x}_{\text{tar}}$  和  $u_{\text{des}}$  为目标状态和期望控制输入;  $C_1$  为

常数。

定义优化变量  $z$ , 如式(34)所示:

$$z = [u(t), \mathbf{x}(t+1), u(t+1), \dots, \mathbf{x}(t+T-1), u(t+T-1), \mathbf{x}(t+T)]^T \tag{34}$$

最优控制问题式(27)可以改写为如下二次规划问题,如式(35)所示:

$$\arg \min_z \left[ \frac{1}{2} (z - z_{\text{tar}})^T \mathbf{H} (z - z_{\text{tar}}) \right] \tag{35}$$

subject to:

$$\mathbf{P}z \leq \mathbf{h} \tag{36}$$

$$\mathbf{C}z = \mathbf{b} \tag{37}$$

其中:

$$z_{\text{tar}} = [u_{\text{des}}(t), \mathbf{x}_{\text{tar}}(t+1), u_{\text{des}}(t+1), \dots, \mathbf{x}_{\text{tar}}(t+T-1), u_{\text{des}}(t+T-1), \mathbf{x}_{\text{tar}}(t+T)]^T$$

$$\mathbf{H} = \begin{bmatrix} \mathbf{R} & 0 & 0 & \cdots & 0 & 0 & 0 \\ 0 & \mathbf{Q} & \mathbf{S} & \cdots & 0 & 0 & 0 \\ 0 & \mathbf{S}^T & \mathbf{R} & \cdots & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & \cdots & \mathbf{Q} & \mathbf{S} & 0 \\ 0 & 0 & 0 & \cdots & \mathbf{S}^T & \mathbf{R} & 0 \\ 0 & 0 & 0 & \cdots & 0 & 0 & \mathbf{Q} \end{bmatrix}$$

$$C = \begin{bmatrix} -B & I & 0 & 0 & \cdots & 0 & 0 & 0 \\ 0 & -A & -B & I & \cdots & 0 & 0 & 0 \\ 0 & 0 & 0 & -A & \cdots & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & \cdots & I & 0 & 0 \\ 0 & 0 & 0 & 0 & \cdots & -A & -B & I \end{bmatrix}$$

$$P = \begin{bmatrix} F_u & 0 & 0 & \cdots & 0 & 0 & 0 \\ 0 & F_x & 0 & \cdots & 0 & 0 & 0 \\ 0 & 0 & F_u & \cdots & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & \cdots & F_x & 0 & 0 \\ 0 & 0 & 0 & \cdots & 0 & F_u & 0 \\ 0 & 0 & 0 & \cdots & 0 & 0 & F_x \end{bmatrix}$$

$$b = \begin{bmatrix} Ax + \bar{\varepsilon} \\ \bar{\varepsilon} \\ \bar{\varepsilon} \\ \vdots \\ \bar{\varepsilon} \\ \bar{\varepsilon} \end{bmatrix}; h = \begin{bmatrix} f_u \\ f_x \\ f_u \\ \vdots \\ f_x \\ f_u \\ f_x \end{bmatrix}$$

式中: $H$ 为对角矩阵; $z_{tar}$ 为目标状态; $P$ 、 $h$ 、 $C$ 和 $b$ 为包含所有等式和不等式约束的系数矩阵。

上述二次规划问题可采用拉格朗日法求解,通过引入拉格朗日乘子,将约束条件转化到拉格朗日方程中,拉格朗日方程如式(38)所示:

$$L(z, \lambda, \delta) = \frac{1}{2}(z - z_{tar})^T H(z - z_{tar}) + \lambda(Cz - b) + \delta(Pz + s_l - h) \quad (38)$$

式中: $\lambda$ 和 $\delta$ 为拉格朗日乘子; $s_l$ 为松弛变量。

通过求解拉格朗日方程的1阶KKT最优化条件可得到二次规划问题的最优解,其1阶KKT最优化条件如式(39)所示:

$$F(z, \lambda, \delta) = \begin{bmatrix} H(z - z_{tar}) + C^T \lambda + P^T \delta \\ Cz - b \\ Pz + s_l - h \\ \gamma S_l I \end{bmatrix} = 0 \quad (39)$$

式中: $\gamma = \text{diag}(\delta)$ 和 $S_l = \text{diag}(s_l)$ 为对角矩阵; $I$ 为单位向量。

为实现快速收敛,本文采用牛顿迭代法求解1阶KKT最优化条件,牛顿迭代方程为

$$\begin{bmatrix} z(q+1) \\ \lambda(q+1) \\ \delta(q+1) \\ s_l(q+1) \end{bmatrix} = \begin{bmatrix} z(q) \\ \lambda(q) \\ \delta(q) \\ s_l(q) \end{bmatrix} + \alpha(q) \begin{bmatrix} \Delta z(q) \\ \Delta \lambda(q) \\ \Delta \delta(q) \\ \Delta s_l(q) \end{bmatrix} \quad (40)$$

其牛顿更新方向 $\Delta z$ 、 $\Delta \lambda$ 、 $\Delta \delta$ 可通过求解下式计算得到:

$$\begin{bmatrix} H & C^T & P^T & 0 \\ C & 0 & 0 & 0 \\ P & 0 & 0 & I \\ 0 & 0 & S_l & \gamma \end{bmatrix} \begin{bmatrix} \Delta z(q) \\ \Delta \lambda(q) \\ \Delta \delta(q) \\ \Delta s_l(q) \end{bmatrix} = \begin{bmatrix} r_z \\ r_\lambda \\ r_\delta \\ r_{s_l} \end{bmatrix} \quad (41)$$

式中: $r_z$ 、 $r_\lambda$ 、 $r_\delta$ 和 $r_{s_l}$ 为式(39)的残留项; $q$ 为迭代系数。

令 $\Delta s_l = -P\Delta z - r_\delta$ ,  $W^T W = \gamma^{-1} S_l$ ,则式(41)可以简化为

$$\begin{bmatrix} H + P^T W^{-2} P & C^T \\ C & 0 \end{bmatrix} \begin{bmatrix} \Delta z \\ \Delta \lambda \end{bmatrix} = \begin{bmatrix} r_z + P^T W^{-2}(r_\delta - \gamma^{-1} r_{s_l}) \\ r_\lambda \end{bmatrix} \quad (42)$$

更新方向 $\Delta z$ 和 $\Delta \lambda$ 可以通过求解式(42)得到,将 $\Delta z$ 和 $\Delta \lambda$ 代入牛顿迭代方程可以得到最优控制问题的解。

## 4 结果与分析

### 4.1 驾驶员误差数据采集与计算

为模拟真实驾驶员的驾驶行为,基于智能网联试验车,通过实车场地试验分别采集4名不同驾驶员的驾驶数据。信号灯红灯间隔时间设置为45 s,绿灯间隔时间设置为25 s。测试道路总长为300 m,最大允许车速为35 km/h。为模拟车辆进入交叉口的不同场景,分别在整个信号灯周期的不同时刻(例如间隔5 s)进行场地试验,每次试验分别记录车辆的速度和位置信息。试验过程如下:

(1)车载计算机通过车载传感器(例如GPS)获取当前时刻车辆的位置和速度信息,通过V2I通信(例如DSRC)获取交叉口的交通信号配时信息;

(2)基于车辆状态信息以及交通信号配时信息,车载计算机运行内置的生态驾驶策略并计算车辆的最优速度轨迹;

(3)车载计算机将最优速度轨迹以建议车速的形式通过交互界面(如图5所示)显示给驾驶员,驾驶员操纵车辆加减速来跟随建议车速行驶。

基于采集的驾驶数据可以计算得到不同时刻的驾驶员误差,统计发现驾驶员误差数据变化范围基本在-0.4~0.4之间。因此,将驾驶员误差状态划分为9级来近似表示实际驾驶员误差:-0.4, -0.3, -0.2, -0.1, 0, 0.1, 0.2, 0.3, 0.4,由式(11)~式(13)

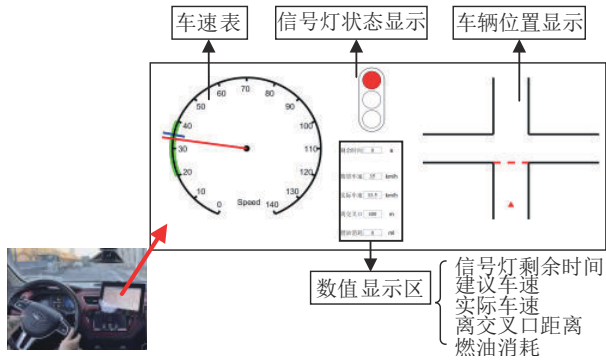


图5 交互界面

可以计算驾驶员误差的状态转移概率矩阵,其中一名驾驶员的状态转移概率矩阵如式(43)所示,其三维图像如图6所示。从式(43)中可以看出,转移概率矩阵的对角元素为所在行所有元素的最大值,说

$$T_c = \begin{bmatrix} 0.48 & 0.30 & 0.16 & 0.03 & 0.03 & 0 & 0 & 0 & 0 \\ 0.09 & 0.40 & 0.35 & 0.16 & 0 & 0 & 0 & 0 & 0 \\ 0.02 & 0.09 & 0.49 & 0.31 & 0.06 & 0.02 & 0.01 & 0 & 0 \\ 0.01 & 0.02 & 0.10 & 0.63 & 0.20 & 0.04 & 0 & 0 & 0 \\ 0 & 0 & 0.02 & 0.22 & 0.60 & 0.13 & 0.03 & 0 & 0 \\ 0 & 0 & 0 & 0.08 & 0.26 & 0.52 & 0.14 & 0 & 0 \\ 0 & 0 & 0 & 0.06 & 0.13 & 0.36 & 0.35 & 0.07 & 0.03 \\ 0 & 0 & 0 & 0 & 0.11 & 0.18 & 0.29 & 0.31 & 0.11 \\ 0 & 0 & 0 & 0 & 0.03 & 0.05 & 0.08 & 0.24 & 0.60 \end{bmatrix} \quad (43)$$

#### 4.2 实时性验证

在不同的预测时域、时间步长和场景树路径数量下对所提出的生态驾驶策略进行仿真。仿真软件为 MATLAB2017b, 计算机配置为 CPU Intel i5-7300HQ, RAM 8 GB。混合车队由 1 辆网联汽车和 3 辆人类驾驶汽车组成,领航车的位置和速度在 0-500 m 和 5-13.98 m/s 范围内按照均匀分布随机生成,车队跟随车辆的位置则在与前车保持 20-25 m 车头间距的范围内随机选取,速度则与领航车速度保持一致。仿真重复进行 500 次。选取算法的计算时间和终端成本作为评价性能指标,终端成本定义为在终端时间  $t_f$  车队车辆的状态与目标状态差的平方的加权之和,如式(44)所示:

$$J' = \omega_1 (s_0(t_f) - s_{tar}(t_f))^2 + \omega_2 \sum_{i=0}^n (v_i(t_f) - v_{eq})^2 + \omega_3 (u(t_f) - u_{des}(t_f))^2 \quad (44)$$

图7为不同预测时域和时间步长下算法的平均计算时间和终端成本仿真结果。从图7(a)可以看出,随着预测时域的增大和时间步长的减小,算法的计算时间增加。当时间步长为 0.2 s, 预测时域大于




图6 转移概率矩阵

明下一时刻的驾驶员误差有较大概率与当前时刻的驾驶员误差所处的状态相同。

4 s 时,算法的计算时间超过一个时间步长,无法满足实时性要求,而在其他情况下算法的实时性均可以得到保证。从图7(b)可以看出,随着预测时域的增大,终端成本先降后升,而时间步长的减小则可以降低终端成本。综合考虑算法的计算时间和终端成本,在后续仿真中算法的预测时域和时间步长分别设置为 3 和 0.5 s。

图8为不同场景树路径数量下算法的平均计算时间和终端成本仿真结果。从图8可以看出,随着路径数量的增大,算法的计算时间略有增加但是仍然在一个时间步长内。终端成本则随着场景树路径数量的增大而逐渐降低,当路径数量大于 400 时,如图中箭头所示,终端成本的变化趋于平缓。因此,在后续仿真中路径数量设置为 400。随机模型预测控制的参数设置如表 3 所示。

#### 4.3 仿真实验

以由 1 辆网联汽车 (connected vehicle, CV) 和 3 辆人类驾驶汽车 (human-driven vehicle, HDV) 组成的车队为仿真对象,对所提出的混合车队生态驾驶策略的有效性进行仿真实验,并与不考虑驾驶员误




图7 不同预测时域和时间步长下算法的计算时间和终端成本




图8 不同场景树路径数量下算法的计算时间和终端成本

表3 随机模型预测控制参数

参数	数值
采样时间/s	0.5
预测时域/s	3
路径数量	400
权重系数 $\omega_1$	20
权重系数 $\omega_2$	5 000
权重系数 $\omega_3$	500

差的混合车队生态驾驶策略进行比较。不考虑驾驶员误差的混合车队生态驾驶策略采用FMPC算法求解网联汽车的最优速度轨迹。仿真设置交叉口长度为500 m,信号灯红灯和绿灯时间间隔分别为45和30 s。仿真中驾驶员误差根据状态转移概率矩阵随机生成。车辆动力学模型参数如表4所示。

表4 车辆动力学模型参数

参数	数值
整备质量/kg	1 680
迎风面积/m <sup>2</sup>	2.25
空气阻力系数	0.3
滚动阻力系数	0.01
最高车速/(m·s <sup>-1</sup> )	13.89
最低车速/(m·s <sup>-1</sup> )	0
最大加速度/(m·s <sup>-2</sup> )	3
最大减速度/(m·s <sup>-2</sup> )	-6

图9和图10分别为两种策略下车辆的位置和速度轨迹仿真结果。对比两种策略下车辆的速度轨迹可以看出,在有驾驶员误差存在的情况下,由于FMPC算法不考虑驾驶员误差对车辆速度轨迹的影响,该算法下车辆的速度轨迹发生明显的波动,使得车队偏离最优平衡车速行驶,如图9(b)中箭头所示。与之相反,FSMPC算法下车辆的速度轨迹更加平稳,在同样的驾驶员误差下,车队能够较好地跟随最优平衡车速行驶。相比于不考虑驾驶员误差的混合车队生态驾驶策略,本文所提出的考虑驾驶员误差的混合车队生态驾驶策略可以有效降低驾驶员误差对车辆速度轨迹的偏移影响。表5为两种策略下车辆的百公里油耗对比。从表5中可以看出,相比于不考虑驾驶员误差的混合车队生态驾驶策略,本文所提出的生态驾驶策略有效降低了整个车队的燃油消耗,降低比例达4.76%。

#### 4.4 智能网联微缩车试验验证

为进一步验证所提出的混合车队生态驾驶策略在实际应用中的效果,基于智能网联微缩车试验平台分别对上述两种生态驾驶策略进行测试。智能网联微缩车试验平台如图11所示,主要由信号灯、智能网联微缩车、UWB定位基站、路由器、路边单元(笔记本电脑)和环形橡胶跑道组成。测试场景设计为由3辆车组成的车队连续通过多个交叉口。试验平台相关参数如表6所示。为便于描述,对3辆智能网联微缩车进行标号,从领航车到最后一辆车分别记为车辆1、车辆2和车辆3。

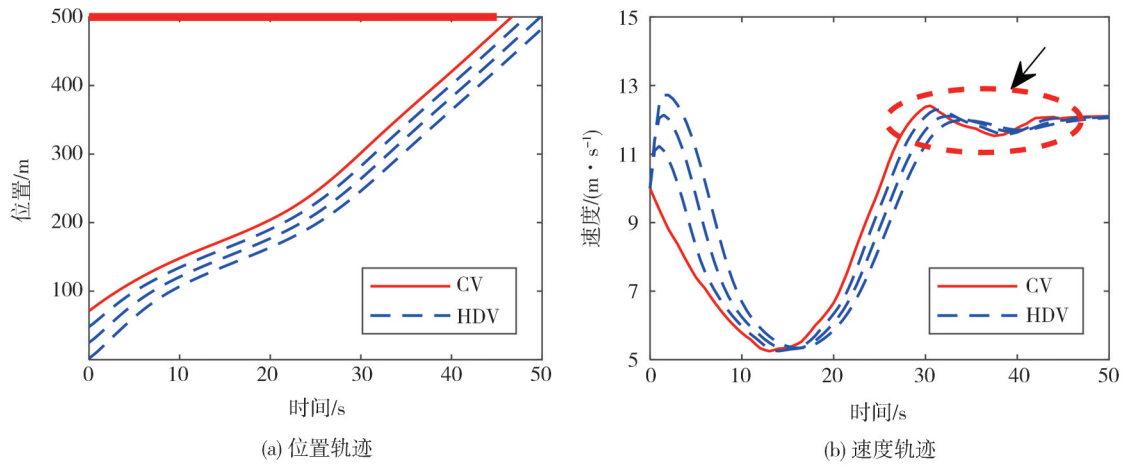


图9 不考虑驾驶员误差的车队生态驾驶策略(FMPC)下车辆的位置和速度轨迹

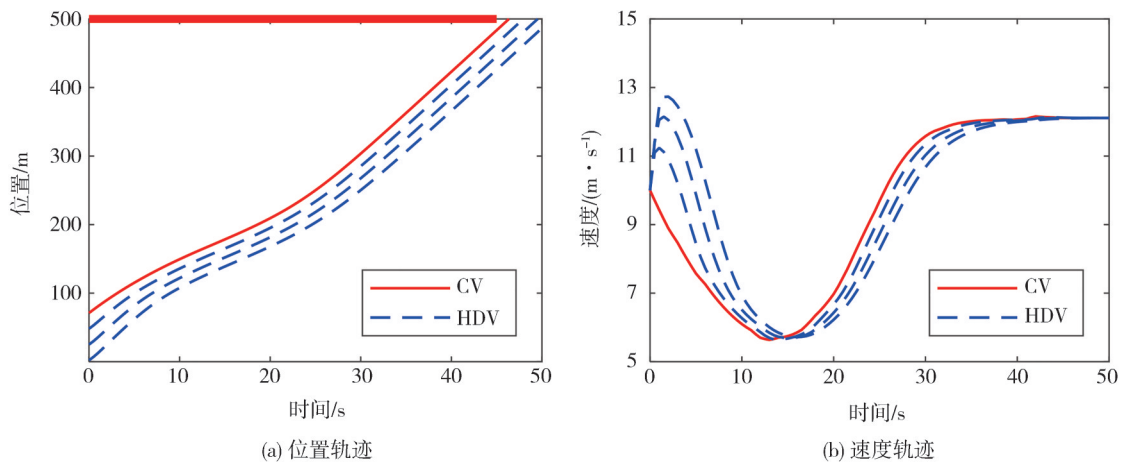


图10 考虑驾驶员误差的车队生态驾驶策略(FSMPC)下车辆的位置和速度轨迹

表5 车辆的百公里油耗对比 L/100 km

车辆序号	FMPC	FSMPC
车辆1	5.82	5.43
车辆2	6.45	6.10
车辆3	7.04	6.76
车辆4	7.56	7.33
平均值	6.72	6.40

为模拟驾驶员操作,车载计算机通过驾驶员误差模型随机产生驾驶员误差,驾驶员误差模型的状态转移概率矩阵如式(43)所示,驾驶员误差状态值则进行缩减(例如缩减为原来的1/50)。车载上位机发送给电机控制器的实际速度为算法计算的最优速度和驾驶员误差导致的速度偏差之和。假设参与试验的3辆微缩车依次为1辆网联汽车(领航车)和2辆人类驾驶汽车(跟随车)。作为人类驾驶汽车的微

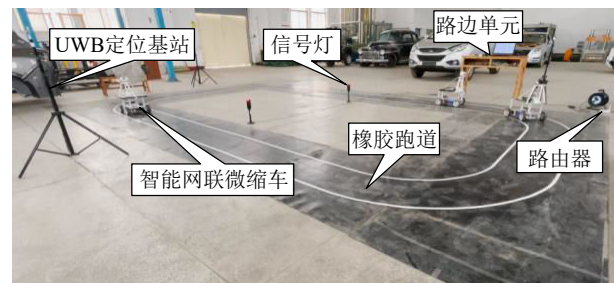


图11 智能网联微缩车试验平台

缩车的速度轨迹采用OVM模型计算。试验假设车队以相同的速度和车头间距进入交叉口,车辆的初始速度设置为0.19 m/s,初始位置分别设置为0、0.6和1.2 m。需要说明的是,为模拟车队在不同的交通条件下进入交叉口,每个交叉口的交通信号配时方案是随机生成的,即信号灯开始时间是随机选取

表6 试验平台参数

参数	数值
道路总长度/m	19
信号灯周期/s	70
信号灯红灯时间/s	45
信号灯绿灯时间/s	25
车辆最高车速/(m·s <sup>-1</sup> )	0.26
车辆最低车速/(m·s <sup>-1</sup> )	0
车辆最大加速度/(m·s <sup>-2</sup> )	0.06
车辆最大减速度/(m·s <sup>-2</sup> )	-0.12

的。最优平衡车速和平衡车头间距分别设置为 0.24 m/s 和 0.6 m。试验流程如下：

(1) 路边单元通过 UWB 定位基站获取 3 辆微缩车的实时位置信息, 通过 UDP 通信获取 3 辆微缩车的实时速度信息, 并将交通信号配时信息和车辆的状态信息等发送给车辆 1。

(2) 车辆 1 接收路边单元发送的信息后, 将交通信号配时信息和自车的状态信息通过 UDP 通信发送给车辆 2, 同时车载上位机运行内置的混合车队生态驾驶策略, 计算车辆的最优车速。为模拟驾驶员操作, 车载计算机通过驾驶员误差模型随机生成驾驶员误差, 并计算增加了驾驶员误差后的实际车速, 然后发送给电机控制器, 电机控制器通过调节电机转速控制车辆跟随该车速。

(3) 车辆 2 接收车辆 1 发送的信息后, 将交通信号配时信息和前车、自车的状态信息通过 UDP 通信

发送给车辆 3, 同时车载上位机运行内置的 OVM 模型, 计算跟车速度并发送给电机控制器以控制车辆跟随该车速。

(4) 车辆 3 接收车辆 2 发送的信息后, 将 3 辆车的状态信息通过 UDP 通信发送给路边单元, 同时车载上位机运行内置的 OVM 模型, 计算跟车速度并发送给电机控制器以控制车辆跟随该车速。

图 12 为两种策略下智能网联微缩车的位置轨迹试验结果。从图 12(a) 中可以看出, 在有驾驶员误差存在的情况下, 不考虑驾驶员误差的车队生态驾驶策略下车队的第 3 辆车发生减速停车的情况, 而本文所提出的生态驾驶策略下车队所有车辆均在绿灯时间窗口通过交叉口。图 13 为两种策略下车辆的速度轨迹试验结果对比。从图 13 可以看出, 不考虑驾驶员误差的车队生态驾驶策略下车辆 1 的速度轨迹在驾驶员误差影响下明显偏离最优平衡车速, 如图 13(a) 中箭头所示, 这也导致后续跟随车辆的速度轨迹发生偏移, 使得车队最后一辆车无法在绿灯时间窗口通过交叉口。与之相反, 本文所提出的生态驾驶策略下车辆的速度轨迹更加平稳, 且更贴合最优平衡车速。表 7 给出两种策略下智能网联微缩车的耗电量。从表 7 中可以看出, 相比于不考虑驾驶员误差的车队生态驾驶策略, 本文所提出的生态驾驶策略进一步降低了整个车队的电量消耗。此外, 在微缩车试验中, 本文所提出的 FSMPC 算法运行一次的平均计算时间为 0.052 s, 可以满足实时性要求。






图 12 两种生态驾驶策略下车辆的位置轨迹试验结果

表7 两种生态驾驶策略下车辆耗电量  $\times 10^{-2} \text{ kW} \cdot \text{h}$ 


车辆序号	FMPC	FSMPC
车辆1	2.372 8	2.369 4
车辆2	2.384 1	2.380 7
车辆3	2.455 6	2.391 2
平均值	2.404 2	2.380 4



(a) 车辆1



(b) 车辆2



(c) 车辆3

图13 两种生态驾驶策略下车辆的速度轨迹试验结果对比

## 5 结论

本文提出一种实时的考虑驾驶员误差的混合车队生态驾驶策略。首先,通过实车试验采集真实驾驶员的驾驶数据,建立基于马尔可夫链的驾驶员误差模型。然后,基于驾驶员误差模型预测未来时刻的驾驶员误差,采用快速随机模型预测控制算法求解混合车队中网联汽车的最优速度轨迹。仿真和智能网联微缩车试验结果表明:

(1)相比于传统的不考虑驾驶员误差的混合车队生态驾驶策略,本文所提出的生态驾驶策略可以有效减少由驾驶员误差导致的车辆速度轨迹偏移,从而降低整个车队的燃油消耗。

(2)在智能网联微缩车试验中,本文所提出的FSMPC算法平均计算时间为0.052 s,可以满足实际应用时的实时性要求。

(3)受试验条件限制,本文仅通过智能网联微缩车试验对所提出的生态驾驶策略的有效性进行验证,后续工作将对生态驾驶策略进行实车试验。

(4)本文所提出的混合车队生态驾驶策略主要针对均质车队,然而在实际交通场景中,车辆的类型和动力学参数往往多样化,后续工作将对异质车队生态驾驶策略进行研究。

## 参考文献

- [1] FAFOUTELLIS P, MANTOUKA E G, VLAHOGIANNI E I. Eco-driving and its impacts on fuel efficiency: an overview of technologies and data-driven methods[J]. Sustainability, 2021, 13(1): 1-17.
- [2] NAEEM H M Y, BUTT Y A, AHMED Q, et al. Optimal-control-based eco-driving solution for connected battery electric vehicle on a signalized route[J]. Automotive Innovation, 2023, 6: 586-596.
- [3] LIORIS J, PEDARSANI R, TASICARA OGLU F Y, et al. Doubling throughput in urban roads by platooning[J]. IFAC - Papers Online, 2016, 49(3): 49-54.
- [4] GONCALVES T R, VARMA V S, ELAYOUBI S E. Vehicle platooning schemes considering V2V communications: a joint communication/control approach[C]. 2020 IEEE Wireless Communications and Networking Conference (WCNC), 2020: 1-6.
- [5] 杨澜, 赵祥模, 吴国垣, 等. 智能网联汽车协同生态驾驶策略综述[J]. 交通运输工程学报, 2020, 20(5): 58-72.  
YANG L, ZHAO X M, WU G Y, et al. Review of cooperative eco-driving strategies based on connected and automated vehicles[J]. Journal of Traffic and Transportation Engineering, 2020, 20(5): 58-72.

(下转第1607页)