

## 基于模型预测控制的人机共驾纵向跟车策略

张智<sup>a</sup>, 曲大义<sup>a,\*</sup>, 李文杰<sup>a</sup>, 韦良帅<sup>a</sup>, 战锦涛<sup>b</sup>

(青岛理工大学 a. 机械与汽车工程学院; b. 土木工程学院, 青岛 266525)

**摘要:**为降低复杂交通环境中车辆纵向行驶事故率,提升行驶安全性和稳定性,提出了基于模型预测控制(Model Predictive Control, MPC)的人机共驾车辆跟车策略。设计上层控制器,利用 MPC 求解期望加速度;根据电机扭矩特性和油门刹车标定表设计下层控制器,精确控制车辆运行状态;分析人机共驾的控制策略和性能评价指标,合理分配控制权以确保安全稳定行驶;利用 Carsim/Simulink 联合仿真,验证分析模型预测控制的人机共驾车辆跟车行为。结果表明其在跟车安全性、驾驶舒适性和操作稳定性上优于人工驾驶车辆;人机共驾模型预测控制纵向驾驶策略能更好应对突发情况,减轻复杂道路环境中的驾驶压力。

**关键词:**模型预测控制;人机共驾;驾驶权切换;纵向跟车

**中图分类号:**U491.2 **文献标志码:**A **文章编号:**1673-4602(2026)02-0108-12

**DOI:**10.3969/j.issn.1673-4602.2026.02.014

## Longitudinal following strategy for human-machine co-driving based on model predictive control

ZHANG Zhi<sup>a</sup>, QU Dayi<sup>a,\*</sup>, LI Wenjie<sup>a</sup>, WEI Liangshuai<sup>a</sup>, ZHAN Jintao<sup>b</sup>

(a. School of Mechanical and Automotive Engineering; b. School of Civil Engineering, Qingdao University of Technology, Qingdao 266525, China)

**Abstract:** To reduce the accident rate of longitudinal driving in complex traffic environments and to enhance driving safety and stability, this paper proposes a human-machine co-driving vehicle-following strategy based on model predictive control (MPC). An upper-layer controller is designed to compute the desired acceleration by using MPC. A lower-layer controller is designed based on motor torque characteristics and the throttle-brake calibration table to achieve precise vehicle motion control. The control strategy and performance evaluation metrics for human-machine co-driving are analyzed, with control authority being reasonably allocated to ensure safe and stable driving. A co-simulation platform using CarSim and Simulink is built to validate and analyze the MPC-based human-machine co-driving vehicle-following behavior. The results show that the proposed approach outperforms manual driving in terms of following safety, driving comfort and handling stability. This MPC-based longitudinal driving strategy for human-machine co-driving can better handle emergency situations and reduce driving stress in complex road environments.

收稿日期:2024-09-29

基金项目:国家自然科学基金(52272311)

作者简介:张智(1999—),男,山东淄博人。硕士,研究方向为车辆轨迹规划与控制。E-mail:zhangzhiqdlg@163.com。

\*通信作者:曲大义(1973—),男,山东青岛人。博士,教授,主要从事车路协同及安全控制方面的研究。  
E-mail:dayiqu@qut.edu.cn。

**Key words:** model predictive control (MPC); human-machine co-driving; driving authority switching; longitudinal following

随着人工智能、大数据、云计算和 5G 等技术的发展,传统汽车智能化加速发展。人工驾驶车辆与人机共驾<sup>[1]</sup>车辆形成的混合交通流逐渐成为复杂道路环境的主流。人机共驾车辆作为新型道路参与者,结合了高级辅助驾驶系统和人类的共同决策能力。然而,两者在决策机理和控制策略上的差异,导致了混合交通流中的人机共驾车辆事故频发,这一安全问题也促使学者开始广泛关注其行驶行为。

纵向跟车和控制能够有效缓解交通流压力、降低事故发生率并提高通行效率。陈秀锋等<sup>[2]</sup>运用改进的期望视觉角模型描述小扰动下的交通流演变过程,降低了跟车碰撞风险。刘浩敏等<sup>[3]</sup>从数据出发,全面分析城市快速路交通流的演化规律,保证了交通流的稳定性。考虑车辆跟驰,WEI 等<sup>[4]</sup>开发了一种车载雷达传感器和 V2V 通信的控制框架,来实现自动驾驶车辆在纵横向的跟驰行为。陈齐平等<sup>[5]</sup>提出了一种融合前馈及状态反馈的模型预测控制方法,解决智能车路径跟踪问题,结果表明此方法具有更高的跟踪精度和安全性。人机共驾行为是指在驾驶过程中,人类驾驶员与机器共同参与驾驶任务,旨在提高驾驶的安全性和效率。ZHANG 等<sup>[6]</sup>提出了驾驶权重分配模块,解决了驾驶员与自动驾驶系统的协同驾驶问题。HAN 等<sup>[7]</sup>研究了人机交互过程中不同驾驶任务的接管问题,结果表明不同接管请求对驾驶员接管性能有着显著影响。WANG 等<sup>[8]</sup>运用强化学习的车辆跟驰控制方法,获得了计算效率更高的纵向跟驰控制器。刘辉等<sup>[9]</sup>提出一种基于实轴轨迹逆最优控制的自动驾驶车辆拟人化驾驶控制方法,降低了驾驶轨迹误差。LI 等<sup>[10]</sup>提出了一种侧风条件下的人机共驾系统权限分配方法,该方法能提高车辆的行驶安全性和稳定性。

控制理论和自适应巡航相结合的车辆纵向控制已受到学者的关注,黄菊花等<sup>[11]</sup>提出了一种结合卡尔曼滤波器和模型预测控制器的自适应反馈模型,该模型在噪声存在的情况下有效提高了自适应巡航控制跟驰(ACC)系统的跟车安全性和舒适性;孔令仁等<sup>[12]</sup>提出了一种自适应模型预测控制(MPC)策略来处理约束并求得数值解;徐哲等<sup>[13]</sup>通过考虑纵向跟车的舒适性,利用模型预测控制理论建立了纵向跟车仿真模型,并通过计算期望加速度达到了较好的舒适性要求。分层控制能够通过独立控制来影响整体的控制策略,刘西等<sup>[14]</sup>建立了上层 MPC 策略和下层逆纵向动力学模型,实现了对前车的速度跟踪;音建华等<sup>[15]</sup>通过不同工况测试,验证了分层控制下车辆的运行状态;MA 等<sup>[16]</sup>提出了一种模型预测控制的分层车辆纵横向控制器来保证速度的协调,降低了纵横向行车误差;QIN 等<sup>[17]</sup>引入了一种改进的滑模控制(SMC)方法,为车辆速度跟踪和纵向控制提供了新思路。

综上所述,学者通过各种方法和模型来提高车辆在纵向运行过程中的安全性和稳定性,缓解交通压力。然而,现有研究往往只考虑单一因素,具有一定的局限性。本文分析了人机共驾车辆的纵向控制,基于 MPC 策略构建了上层控制模型,将纵向跟车问题转化为具有约束条件的在线二次规划(QP)问题。此外,设计了更精确的油门刹车标定表用于下层控制,并提出了一种人机共驾的驾驶权分配策略。研究了前车高速制动和前车切入过程的控制权切换问题,并验证了该模型的合理性。

## 1 车辆纵向速度控制策略

采用上下分层速度控制结构,上层控制策略使用模型预测控制设计目标函数,分析车辆行驶过程中的安全性、稳定性、行驶效率等因素,设计对应的约束条件,并且根据车辆当前状态和驾驶员期望的速度,求出相应的期望加速度。上层求出的期望加速度作用到下层建立的油门刹车标定表上,作为智能辅助驾驶系统的输出。同时,人类驾驶员根据自身判断生成另一个输出策略。在人机共驾模式下,这两个输出值合并为总的控制输出,作用于车辆。人机共驾车辆的纵向控制如图 1 所示。

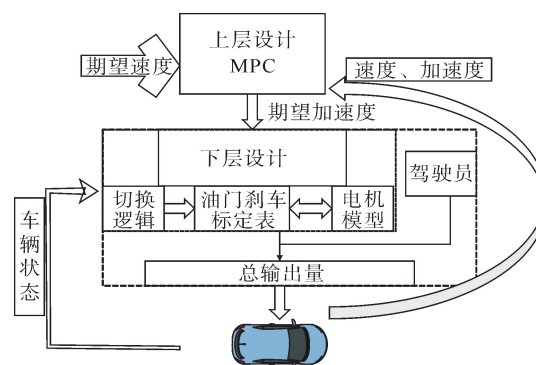


图 1 人机共驾车辆纵向控制

## 1.1 上层控制器设计

### 1.1.1 车辆间距模型建立

在人机共驾车辆跟车行驶的过程中,驾驶员可以根据自身对前车与自车间距的风险分析,结合驾驶经验来调节车辆状态。然而,驾驶员在驾驶过程中会出现疲倦和操作失误的情况,此时需要智能驾驶辅助系统的介入。在车辆行驶过程中,驾驶辅助系统能够利用激光雷达等车载传感器对周围环境进行感知,从而获取交互车辆的运动状态信息,以确保行车安全。合理分配驾驶权限可以进一步提高车辆行驶的安全性和稳定性。

安全间距是保证车辆安全行驶的前提,间距的大小也直接影响到行车安全和道路的通行效率。其计算公式如下:

$$d_{\text{des}} = \tau v + d \quad (1)$$

式中:  $d_{\text{des}}$  为期望跟车间隔;  $\tau$  为车头时距;  $v$  为自车速度;  $d$  为自车与前车之间的安全距离。

### 1.1.2 运动学模型建立

在跟车过程中,两车的速度误差和间距误差反映了跟车的性能。同时,加速度及其变化率对驾乘舒适性产生影响。综合考虑车辆及车间的纵向动力学,基于模型预测控制原理设计纵向跟车控制器,并通过图2所示的车辆运动学关系建立状态方程。




图2 车辆运动学关系

$$t_p \dot{a} = K(a_{\text{des}} - a) \quad (2)$$

式中:  $x$ 、 $v$ 、 $a$ 、 $a_{\text{des}}$  和  $\dot{a}$  分别为车距、自车速度、自车的加速度、期望加速度和加速度对时间的变化率;  $K$  为系统增益,  $K=1$ ;  $t_p$  为时间常数。

车辆的纵向控制模型采用一阶惯性时滞模型  $\dot{a} = \frac{K}{t}(a_{\text{des}} - a)$ , 其中,  $t$  为控制时间。把连续的系统模型写成状态方程可表示为

$$\dot{\mathbf{x}} = \mathbf{A}\mathbf{x} + \mathbf{B}\mathbf{u} \quad (3)$$

式中:  $\dot{\mathbf{x}}$  为系统的状态向量  $\mathbf{x}$  对时间的导数,  $\mathbf{x} = [v \ a]^T$ ;  $\mathbf{u} = a_{\text{des}}$  为系统的输入量;  $\mathbf{A}$  为状态矩阵,  $\mathbf{B}$  为输入矩阵。

为了便于计算并得到数值解,通过向前欧拉法把连续的状态方程进行离散化,得到离散的状态方程式为

$$\mathbf{x}(t+1) = \mathbf{A}_t \mathbf{x}(t) + \mathbf{B}_t \mathbf{u}(t) \quad (4)$$

式中:  $\mathbf{A}_t = \begin{bmatrix} 1 & T \\ 0 & 1 - \frac{T}{t_p} \end{bmatrix}$  为离散时间系统的状态矩阵,  $\mathbf{B}_t = \begin{bmatrix} 0 \\ \frac{KT}{t_p} \end{bmatrix}$  为离散时间系统的输入矩阵;  $t$ 、 $t+1$

分别为当前时刻和下一时刻采样点;  $T$  为采样周期。

系统的输出函数可表示为

$$y(t) = \mathbf{C}\mathbf{x}(t) \quad (5)$$

式中:  $y(t)$  为输出变量;  $\mathbf{C} = [1 \ 0]$ 。

目标函数的作用是实现更快、更稳定地安全跟车,并通过降低加速度和加速度变化率保障行车舒适性,其设计以系统状态量偏差和控制量的优化输入为核心,目标函数表示为

$$\mathbf{J}(\mathbf{x}(j), \mathbf{u}(j-1), \Delta \mathbf{u}(t)) = \sum_{i=1}^{N_p} \|\mathbf{y}_p(t+i|t) - \mathbf{y}_{\text{ref}}(t+i|t)\|_Q^2 + \sum_{i=1}^{N_c} \|\Delta \mathbf{u}(t+i)\|_R^2 \quad (6)$$

式中:  $J$  为未来预测时域内的总优化代价;  $\mathbf{u}(j-1)$  为前一时刻采样值;  $N_p$  为预测步长;  $N_c$  为控制步长;  $\mathbf{y}_p(t+i|t)$  为控制输出预测值;  $\mathbf{y}_{\text{ref}}(t+i|t)$  为控制输出参考值;  $(t+i|t)$  为通过  $t$  时刻的采样信息来预测  $t+i$  时刻的值,其中  $i=1,2,3,\dots,N_p$ ;  $\Delta\mathbf{u}(t+i)$  为  $t+i$  时刻的控制输入增量,其中  $i=0,1,2,\dots,N_c-1$ ;  $\mathbf{Q}$ 、 $\mathbf{R}$  分别为系统输出量权重矩阵和控制输入量的权重矩阵。

式(6)中右侧第一项表示跟车过程的跟随能力,第二项表示控制量误差变化的稳定性,两项求和是对整个系统跟车平稳性和高效性的体现。在系统约束条件下使整个目标函数取最小值时性能最优,此时的加速度和加速度变化率在最大值与最小值之间,即

$$\mathbf{u}_{\min} \leq \mathbf{u}(t+i) \leq \mathbf{u}_{\max}, i=0,1,2,\dots,N_c-1 \quad (7)$$

$$\Delta\mathbf{u}_{\min} \leq \Delta\mathbf{u}(t+i) \leq \Delta\mathbf{u}_{\max}, i=0,1,2,\dots,N_c-1 \quad (8)$$

式中:  $\mathbf{u}_{\min}$ 、 $\mathbf{u}_{\max}$ 、 $\Delta\mathbf{u}_{\min}$  和  $\Delta\mathbf{u}_{\max}$  分别为加速度的最小最大值和加速度变换率的最小最大值。

MPC 策略是在满足约束条件的前提下,求目标函数性能最优的解,转化成利用二次规划问题来求解目标函数的最小值,即

$$\min J(\mathbf{x}(t), \mathbf{u}(t-1), \Delta\mathbf{u}(t)) \quad (9)$$

### 1.1.3 滚动优化求解

将约束条件和目标函数转换为带约束的二次规划问题,求解每个时刻的控制量,并将第一分量作为实际控制输入,进行滚动优化,实现 MPC 策略的动态调整。

首先对离散化的状态空间方程构建新的状态向量  $\zeta(t|j) = [\mathbf{x}(t) \quad \mathbf{u}(t-1)]^T$ , 得到一个新的状态空间表达式:

$$\begin{aligned} \zeta(t+1) &= \hat{\mathbf{A}}_t \zeta(t) + \hat{\mathbf{B}}_t \Delta\mathbf{u}(t) \\ \boldsymbol{\eta}(t) &= \hat{\mathbf{C}} \zeta(t) \end{aligned} \quad (10)$$

式中:  $\hat{\mathbf{A}}_t = \begin{bmatrix} \mathbf{A}_t & \mathbf{B}_t \\ \mathbf{0}_{m \times n} & \mathbf{I}_m \end{bmatrix}$ ,  $\hat{\mathbf{B}}_t = \begin{bmatrix} \mathbf{B}_t \\ \mathbf{I}_m \end{bmatrix}$ ,  $\hat{\mathbf{C}} = [\mathbf{C} \quad \mathbf{0}]$  以及  $\mathbf{I}_m$  均为  $m$  维的单位矩阵,这里  $m=1$ ,  $n=2$ 。对

式(10)进行状态预测和推导可得新状态空间方程系统的状态输出量为

$$\begin{aligned} \zeta(t+1) &= \hat{\mathbf{A}}_t \zeta(t) + \hat{\mathbf{B}}_t \Delta\mathbf{u}(t) & \boldsymbol{\eta}(t) &= \hat{\mathbf{C}} \zeta(t) \\ \zeta(t+2) &= \hat{\mathbf{A}}_t^2 \zeta(t) + \hat{\mathbf{A}}_t \hat{\mathbf{B}}_t \Delta\mathbf{u}(t) + \hat{\mathbf{B}}_t \Delta\mathbf{u}(t+1) & \boldsymbol{\eta}(t+1) &= \hat{\mathbf{C}} \hat{\mathbf{A}}_t \zeta(t) + \hat{\mathbf{C}} \hat{\mathbf{B}}_t \Delta\mathbf{u}(t) \\ & \vdots & & \vdots \\ \zeta(t+N_p) &= \hat{\mathbf{A}}_t^{N_p} \zeta(t) + \hat{\mathbf{A}}_t^{N_p-1} \hat{\mathbf{B}}_t \Delta\mathbf{u}(t) + \hat{\mathbf{A}}_t^{N_p-2} \hat{\mathbf{B}}_t \Delta\mathbf{u}(t+1) + \dots + \hat{\mathbf{B}}_t \Delta\mathbf{u}(t+N_p-1) & \boldsymbol{\eta}(t+N_p) &= \hat{\mathbf{C}} \hat{\mathbf{A}}_t^{N_p} \zeta(t) + \hat{\mathbf{C}} \hat{\mathbf{A}}_t^{N_p-1} \hat{\mathbf{B}}_t \Delta\mathbf{u}(t) + \dots + \hat{\mathbf{C}} \hat{\mathbf{B}}_t \Delta\mathbf{u}(t+N_p-1) \end{aligned} \quad (11)$$

通过对比复杂的关系式发现可以对其进行简化,利用矩阵的形式来表示系统未来的输出:

$$\mathbf{Y} = \boldsymbol{\Phi} \zeta(t) + \boldsymbol{\Upsilon} \Delta\mathbf{U} \quad (12)$$

其中,

$$\mathbf{Y} = \begin{bmatrix} \boldsymbol{\eta}(t+1) \\ \boldsymbol{\eta}(t+2) \\ \vdots \\ \boldsymbol{\eta}(t+N_c) \\ \vdots \\ \boldsymbol{\eta}(t+N_p) \end{bmatrix}, \boldsymbol{\Phi} = \begin{bmatrix} \hat{\mathbf{C}} \hat{\mathbf{A}}_t \\ \hat{\mathbf{C}} \hat{\mathbf{A}}_t^2 \\ \vdots \\ \hat{\mathbf{C}} \hat{\mathbf{A}}_t^{N_c} \\ \vdots \\ \hat{\mathbf{C}} \hat{\mathbf{A}}_t^{N_p} \end{bmatrix}, \Delta\mathbf{U} = \begin{bmatrix} \Delta\mathbf{u}(t) \\ \Delta\mathbf{u}(t+1) \\ \vdots \\ \Delta\mathbf{u}(t+N_c-1) \\ \vdots \\ \Delta\mathbf{u}(t+N_p-1) \end{bmatrix},$$

$$\mathbf{T} = \begin{bmatrix} \widehat{\mathbf{C}}\mathbf{B}_t & 0 & 0 & 0 & 0 \\ \widehat{\mathbf{C}}\mathbf{A}_t\mathbf{B}_t & \widehat{\mathbf{C}}\mathbf{B}_t & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \widehat{\mathbf{C}}\mathbf{A}_t^{N_c-1}\mathbf{B}_t & \widehat{\mathbf{C}}\mathbf{A}_t^{N_c-2}\mathbf{B}_t & \widehat{\mathbf{C}}\mathbf{A}_t^{N_c-3}\mathbf{B}_t & \cdots & \widehat{\mathbf{C}}\mathbf{B}_t \\ \widehat{\mathbf{C}}\mathbf{A}_t^{N_c}\mathbf{B}_t & \widehat{\mathbf{C}}\mathbf{A}_t^{N_c-1}\mathbf{B}_t & \widehat{\mathbf{C}}\mathbf{A}_t^{N_c-2}\mathbf{B}_t & \cdots & \widehat{\mathbf{C}}\mathbf{A}_t\mathbf{B}_t \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \widehat{\mathbf{C}}\mathbf{A}_t^{N_p-1}\mathbf{B} & \widehat{\mathbf{C}}\mathbf{A}_t^{N_p-2}\mathbf{B} & \widehat{\mathbf{C}}\mathbf{A}_t^{N_p-3}\mathbf{B} & \cdots & \widehat{\mathbf{C}}\mathbf{A}_t^{N_p-N_c-1}\mathbf{B} \end{bmatrix}$$

由式(12)可知,在预测时域内的状态变量和输出变量可以通过系统当前的状态变量  $\zeta(t)$  和控制变量  $\Delta U$  计算求出,这正体现了模型预测控制里的“预测”功能。

设定参考输出量为  $\mathbf{Y}_{\text{ref}}(k) = [\boldsymbol{\eta}_{\text{ref}}(k+1), \dots, \boldsymbol{\eta}_{\text{ref}}(k+N_p)]^T$ , 令  $\mathbf{E} = \boldsymbol{\Phi}\zeta(t)$ , 将式(12)与优化目标函数联合求解可得

$$\begin{aligned} J &= (\mathbf{Y} - \mathbf{Y}_{\text{ref}})^T \mathbf{Q}_Q (\mathbf{Y} - \mathbf{Y}_{\text{ref}}) + (\Delta U)^T \mathbf{R}_R \Delta U \\ &= [\boldsymbol{\Phi}\zeta(t) + \mathbf{T} \Delta U - \mathbf{Y}_{\text{ref}}]^T \mathbf{Q}_Q [\boldsymbol{\Phi}\zeta(t) + \mathbf{T} \Delta U - \mathbf{Y}_{\text{ref}}] + \Delta U^T \mathbf{R}_R \Delta U \\ &= \Delta U^T (\mathbf{T}^T \mathbf{Q}_Q \mathbf{T} + \mathbf{R}_R) \Delta U + 2(\mathbf{E}^T \mathbf{Q}_Q \mathbf{T} - \mathbf{Y}_{\text{ref}}^T \mathbf{Q}_Q \mathbf{T}) \Delta U + \mathbf{E}^T \mathbf{Q}_Q \mathbf{E} + \mathbf{Y}_{\text{ref}}^T \mathbf{Q}_Q \mathbf{Y}_{\text{ref}} - 2\mathbf{Y}_{\text{ref}}^T \mathbf{Q}_Q \mathbf{E} \end{aligned} \quad (13)$$

其中,  $\mathbf{Q}_Q = \mathbf{I}_{N_p} \otimes \mathbf{Q}$ ,  $\mathbf{R}_R = \mathbf{I}_{N_p} \otimes \mathbf{R}$ ,  $\otimes$  为克罗内克积。因此  $\mathbf{E}^T \mathbf{Q}_Q \mathbf{E} + \mathbf{Y}_{\text{ref}}^T \mathbf{Q}_Q \mathbf{Y}_{\text{ref}} - 2\mathbf{Y}_{\text{ref}}^T \mathbf{Q}_Q \mathbf{E}$  是一个常数,在优化过程中不影响结果,故忽略不计。性能函数的表达式可以表示为

$$J = \Delta U^T (\mathbf{T}^T \mathbf{Q}_Q \mathbf{T} + \mathbf{R}_R) \Delta U + 2(\mathbf{E}^T \mathbf{Q}_Q \mathbf{T} - \mathbf{Y}_{\text{ref}}^T \mathbf{Q}_Q \mathbf{T}) \Delta U \quad (14)$$

令  $\mathbf{H} = \mathbf{T}^T \mathbf{Q}_Q \mathbf{T} + \mathbf{R}_R$ ,  $\mathbf{h} = \mathbf{E}^T \mathbf{Q}_Q \mathbf{T} - \mathbf{Y}_{\text{ref}}^T \mathbf{Q}_Q \mathbf{T}$ , 把上式改写成:

$$J = 2\left(\frac{1}{2} \Delta U^T \mathbf{H} \Delta U + \mathbf{h}^T \Delta U\right) \quad (15)$$

在优化求解过程中,可知控制量与控制增量存在如下关系式:

$$\mathbf{u}(t+i) = \mathbf{u}(t+i-1) + \Delta \mathbf{u}(t) \quad (16)$$

并结合式(7)、式(8)的约束条件,进行控制量和控制增量的变量统一化处理:

$$\mathbf{U}_{\min} \leq \mathbf{A}_k \Delta \mathbf{U} + \mathbf{U}_j \leq \mathbf{U}_{\max} \quad (17)$$

$$\Delta \mathbf{U}_{\min} \leq \Delta \mathbf{U}_j \leq \Delta \mathbf{U}_{\max} \quad (18)$$

式中:  $\mathbf{U}_j = \mathbf{I}_{N_c} \otimes \mathbf{u}(t-1)$ ,  $\mathbf{I}_{N_c}$  为有  $N_c$  行的列向量,  $\mathbf{u}(t-1)$  为前一时刻实际控制量;  $\mathbf{U}_{\min}$ 、 $\mathbf{U}_{\max}$  分别为控制时域内控制量的最小最大值集合;  $\Delta \mathbf{U}_{\min}$ 、 $\Delta \mathbf{U}_{\max}$  分别为控制时域内控制增量的最小最大值集合;  $\mathbf{A}_k$  为一个  $N_c \times N_c$  的单位下三角矩阵。

通过一系列的转化,把模型控制预测的优化求解问题转换成了一个标准二次型规划问题:

$$\begin{aligned} \min_{\Delta \mathbf{U}} \quad & \frac{1}{2} \Delta \mathbf{U}^T \mathbf{H} \Delta \mathbf{U} + \mathbf{h}^T \Delta \mathbf{U} \\ \text{s. t.} \quad & \Delta \mathbf{U}_{\min} \leq \Delta \mathbf{U} \leq \Delta \mathbf{U}_{\max} \\ & \mathbf{U}_{\min} \leq \mathbf{A}_k \Delta \mathbf{U} + \mathbf{U}_j \leq \mathbf{U}_{\max} \end{aligned} \quad (19)$$

针对此二次型规划问题,可使用 MATLAB 里的 quadprog 函数进行求解,得到控制时域中一系列控制输入增量:

$$\Delta \mathbf{U}^* = [\Delta \mathbf{u}^*(t) \quad \Delta \mathbf{u}^*(t+1) \quad \cdots \quad \Delta \mathbf{u}^*(N_c-1)]^T \quad (20)$$

将得到的控制序列第 1 个元素  $\Delta \mathbf{u}^*(t)$  作为实际的控制输入增量作用到系统,得到

$$\mathbf{u}(t) = \mathbf{u}(t+1) + \Delta \mathbf{u}^*(t) \quad (21)$$

系统完成当前时刻控制量计算后,进入下一周期以求得新的控制量增量。这样,系统可以逐步得到下一时刻的控制量,并依次循环,最终获得控制时域内的所有控制量,从而完成整个控制过程。

## 1.2 下层控制器设计

通过上层控制器获得期望加速度,并将其作为输入用于下层控制器的设计。在车辆纵向控制中,油门

踏板压力对节气门开度的影响以及制动踏板压力对制动力的影响都是重要因素。油门和制动踏板的控制策略常采用比例积分微分控制(PID)、MPC、线性二次型调节器(LQR)及其改进算法,以实现更精确、平稳的控制输出。部分学者<sup>[18]</sup>利用纵向运动学和动力学方程建立制动和驱动模型,标定参数以制定切换规则,从而求出制动和驱动控制输入并应用于车辆平台,以获取速度和加速度指标。同时,油门刹车标定表通过大量数据的计算和拟合,实现更精确的跟踪控制效果,该过程依赖于丰富的实验数据。

### 1.2.1 制动、驱动切换逻辑

车辆通过调节驱动力和制动力来保持正常跟车行驶。当车距较大时,通过对驱动踏板施加压力来提速;当车距较小时,采取制动来保证跟车的安全性。避免同时或频繁踩油门和刹车,以防控制紊乱、性能下降以及刹车片和轮胎的过度磨损。合理的制动驱动切换逻辑能提升安全性、舒适性和经济性。

用  $\theta$  表示车辆油门和刹车标定表输出值,  $\theta$  的正负代表驱动力和制动力,切换过程如式(22)所示:

$$\alpha = \begin{cases} \theta, & \theta \geq 0 \\ 0, & \theta < 0 \end{cases}, \quad b = \begin{cases} 0, & \theta \geq 0 \\ -\theta, & \theta < 0 \end{cases} \quad (22)$$

式中:  $\alpha$  为踩油门操作;  $b$  为踩刹车操作。

### 1.2.2 建立电机模型

随着新能源汽车的兴起,电机相比燃油机具有启动扭矩大、低速响应快、能源利用效率高、维修成本低和控制方便的优势。本文以某款电机为例进行建模。电机运行分为恒功率和恒扭矩两部分,两者的切换点对系统性能和效率至关重要。此切换点的转速可通过电机最大扭矩与最大功率之比来确定。公式如下:

$$\hat{\omega} = \frac{M_{\max}}{P_{\max}} \quad (23)$$

式中:  $\hat{\omega}$  为恒功率与恒扭矩切换时的转速;  $M_{\max}$  为最大扭矩;  $P_{\max}$  为最大功率。

图 3 展示了该款纯电动汽车电机的外特性曲线。为了在不同速度下保持良好的动力性和效率,电机需在恒功率与恒扭矩之间切换。在恒扭矩阶段,电机转速增加,扭矩保持恒定,确保车辆在低速时也能迅速提升车速。达到一定速度后,为避免过载,系统将从恒扭矩模式切换到恒功率模式,此时扭矩随着转速增加而减小,以维持恒功率输出。

车辆输出扭矩的大小可以通过电机转速在电机外特性曲线上确定,电机转速的高低根据踩油门操作来衡量。所以电机输出的扭矩与踩油门操作和电机转速的关系式如下:




图 3 电机外特性曲线

$$M = \begin{cases} t \cdot M_{\max} & , \omega \leq \hat{\omega} \\ \frac{\hat{\omega} \cdot t \cdot M_{\max}}{\omega} & , \omega > \hat{\omega} \end{cases} \quad (24)$$

式中:  $M$  为此刻输出扭矩;  $\omega$  为此刻电机转速。

### 1.2.3 油门刹车标定表的制作

1) 油门标定表的制作。根据 Carsim 提供的车辆参数,从车速为 0 的情况开始,通过油门踏板的压力来调节节气门开度大小。节气门从闭合到完全打开的过程中,可以得到车速和加速度的变化曲线,在合并拟合处理后就可以得到图 4(a)所示车辆的油门标定表。

2) 刹车标定表的制作。刹车标定表的制作过程与油门标定表的制作过程相仿,但车辆制动需要在一定初速度下进行。在一定车速的情况下开始制动,直到车辆速度为 0 完成测试,车辆在停车后继续施加制动力不会对车辆的状态产生影响。根据采集到的刹车速度和加速度,进行数据处理后得到刹车标定表如

图4(b)所示。

3) 油门刹车标定表的合并。在车辆控制系统中,为了优化油门和刹车的控制连续性,合并生成油门与刹车的标定表是有效的方法。单独生成的油门和刹车表,可能导致数据不匹配和过渡不畅。通过数据拟合和插值处理,可以平滑油门和刹车之间的过渡,提高系统的平顺性和整体性能。通过 Carsim/Simulink 联合仿真,根据制动驱动切换逻辑以及电机外特性曲线制定的油门刹车合并标定表如图4(c)所示。




图4 油门刹车标定表的制作

## 2 纵向控制器模型验证分析

纵向跟车控制模型由上层 MPC 策略模块和下层油门刹车标定表构成,为验证所建跟车控制模型的控制性能,从车辆加速工况和跟车行驶两方面进行分析验证。

1) 加速工况测试。在 Carsim/Simulink 联合仿真中,设置车辆初速度为 0,加速过程保持最大油门,仿真时间为 25 s,得到车辆速度和加速度分别如图5(a)(b)所示。通过对速度和加速度的分析,所建模型能够在规定的时间内达到最高车速并稳定运行。加速度初期波动较大是由于从恒扭矩模式切换到恒功率模式所致,之后的加速度曲线与电机转速扭矩曲线趋势一致。

2) 跟车行驶测试。在跟车过程中,人类驾驶员依据前方车辆的速度和距离调整油门和刹车,而驾驶辅助系统通过传感器和激光雷达获取运动状态信息,进行分析和控制修正,以实现期望的速度和加速度。对比所建模型的实际速度和加速度,如图5(c)(d)所示,可以分析系统的性能和准确性。

由图5(c)(d)可知,车辆速度跟踪更加平稳,波动较小,油门和刹车切换过程符合逻辑,没有出现油门与刹车同时踩下的情况;期望加速度与实际加速度差异较小,表明控制器模型能够较好地跟踪期望加速度。总体而言,上层 MPC 控制策略与下层油门刹车标定表的配合效果良好,实现了平稳的期望速度跟踪和加速度跟踪。

## 3 人机共驾控制策略

传统人工驾驶车辆的运动状态完全由驾驶员决定,应对突发状况的处理能力较强,但疲劳驾驶、操作失误等状况难以避免。因此,设计驾驶辅助系统以提高行车安全性和稳定性。

将车辆驾驶权进行合理分配,提出驾驶权切换策略,如式(25)所示:

$$\varphi = \mu\varphi_1 + (1 - \mu)\varphi_2 \quad (25)$$

式中: $\varphi$  为输出的驾驶策略; $\varphi_1$  为驾驶员做出的驾驶策略; $\varphi_2$  为智能驾驶辅助系统做出的驾驶策略; $\mu$  为人机共驾切换系数,当 $\mu$  趋近于 0 时智能驾驶辅助系统逐渐接管控制权,处理潜在危险,当 $\mu$  趋近于 1 时驾驶权返回给人类驾驶员,系统支持人类驾驶员应对车辆运行问题。

为全面评估智能驾驶系统的综合表现,本部分从行车过程中的核心需求出发,选取跟车安全性、驾驶舒适性与操作稳定性 3 个关键维度构建性能评价指标体系,各指标的具体计算与衡量方式如下。

### 3.1 跟车安全性

跟车安全性通过车辆的跟车碰撞时间来进行衡量,跟车碰撞时间越长,说明碰撞风险越小,为保证与

其他性能评价指标量纲一致,计算时需采取归一化处理。

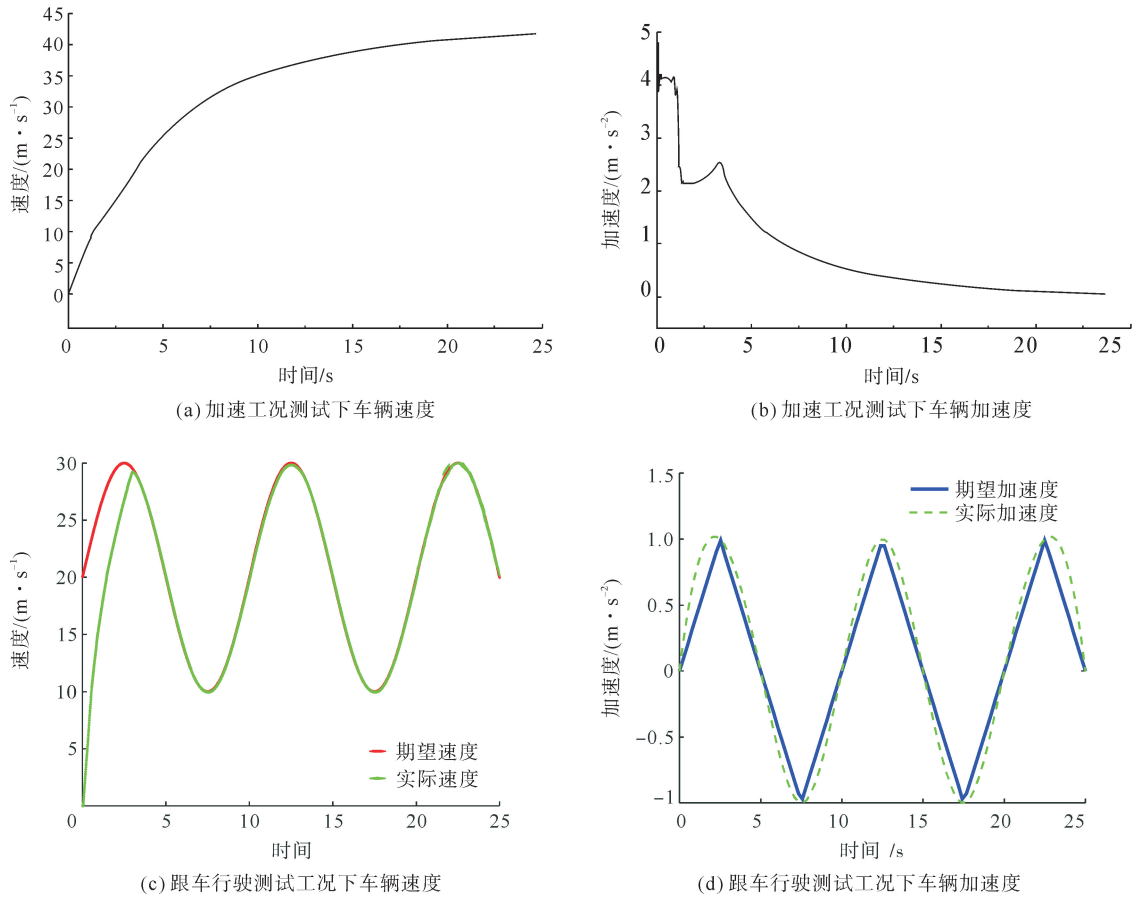


图 5 两种工况的车速、加速度

$$G_{tc} = \frac{x}{v_1 - v}, P_s = \max \frac{G_{tc}}{G_{P_s}} \tag{26}$$

式中:  $G_{tc}$  为跟车碰撞时间;  $x$  为两车之间的实际距离;  $v_1$  为前车的速度;  $v$  为后车速度;  $P_s$  为跟车安全性指标;  $G_{P_s}$  为安全性指标的归一化系数,取值为  $1 \text{ s}^{-1}$ 。

### 3.2 驾驶舒适性

舒适性是行车过程中驾乘人员比较关注的指标之一,这里采用加速度的二次幂来进行舒适性的衡量。加速度的平方越小,车辆运行越平稳,说明加速或减速过程中舒适性越好。

$$P_c = \left(\frac{a}{G_{P_c}}\right)^2 \tag{27}$$

式中:  $P_c$  为舒适性指标;  $G_{P_c}$  为舒适性指标的归一化系数,取值为  $1 \text{ m/s}^2$ 。

### 3.3 操作稳定性

驾驶员的操作稳定性影响智能驾驶辅助系统的决策,驾驶风格稳定的驾驶员与系统的交互更为高效。通过油门、刹车踩踏来衡量驾驶员的操作稳定性,在整个驾驶周期内,对油门、刹车操作之和进行积分,值越小说明驾驶操作指标越稳定。

$$P_f = \int_0^t (P_a + P_b) dt \tag{28}$$

式中:  $P_f$  为操作稳定性指标;  $P_a$ 、 $P_b$  分别为油门和刹车操作指标;  $t$  为车辆行驶时间。

## 4 仿真实验与分析

基于 MATLAB/Simulink, 依托 Carsim 平台, 使用驾驶模拟器采集车辆数据。在同一驾驶员的操作下, 人驾车辆和人机共驾车辆分别进行多次数据采集, 并求取均值作为最终数据。这种方法既能保证驾驶风格的一致性, 又能确保数据的可靠性和有效性。为确保测试结果的准确性, 驾驶员需具备至少 3 年的驾驶经验, 并熟悉驾驶模拟器的操作。此外, 驾驶员应具备较强的应变能力, 能够在遇到前车紧急制动和切入状况时迅速做出反应, 从而在模拟测试中有效体现真实的驾驶情境。在突发工况的选取上, 本研究关注前车高速制动和前车切入两种情况。前车高速制动模拟真实交通环境中驾驶员需迅速反应以避免碰撞的情景; 而前车切入则模拟其他车辆突然变道的情况, 以测试驾驶员及人机共驾系统的应变能力和决策速度。这两种突发工况的选择将有助于全面评估人机共驾车辆与传统人工驾驶车辆在紧急情况下的处理能力。利用以上 3 个性能评价指标, 对比分析人机共驾车辆和传统人工驾驶车辆在面临前车高速制动和前车切入两种突发状况时的处理能力。

### 4.1 前车高速制动工况

仿真参数设定为前车和自车初速度均为 15 m/s, 两车间距 58 m, 前车约以  $2 \text{ m/s}^2$  的减速度制动直至停车。在整个制动过程中, 人驾车辆完全凭借驾驶员的经验行驶, 而人机共驾车辆则结合驾驶员的控制量和智能辅助系统基于传感器数据的控制量, 通过驾驶权切换系数确保车辆安全、稳定运行。图 6(a)(b)(c) 展示了前车制动至停止过程中后车的速度、加速度、与前车的车间距的对比情况, 图 6(d) 为驾驶权切换系数的变化情况。

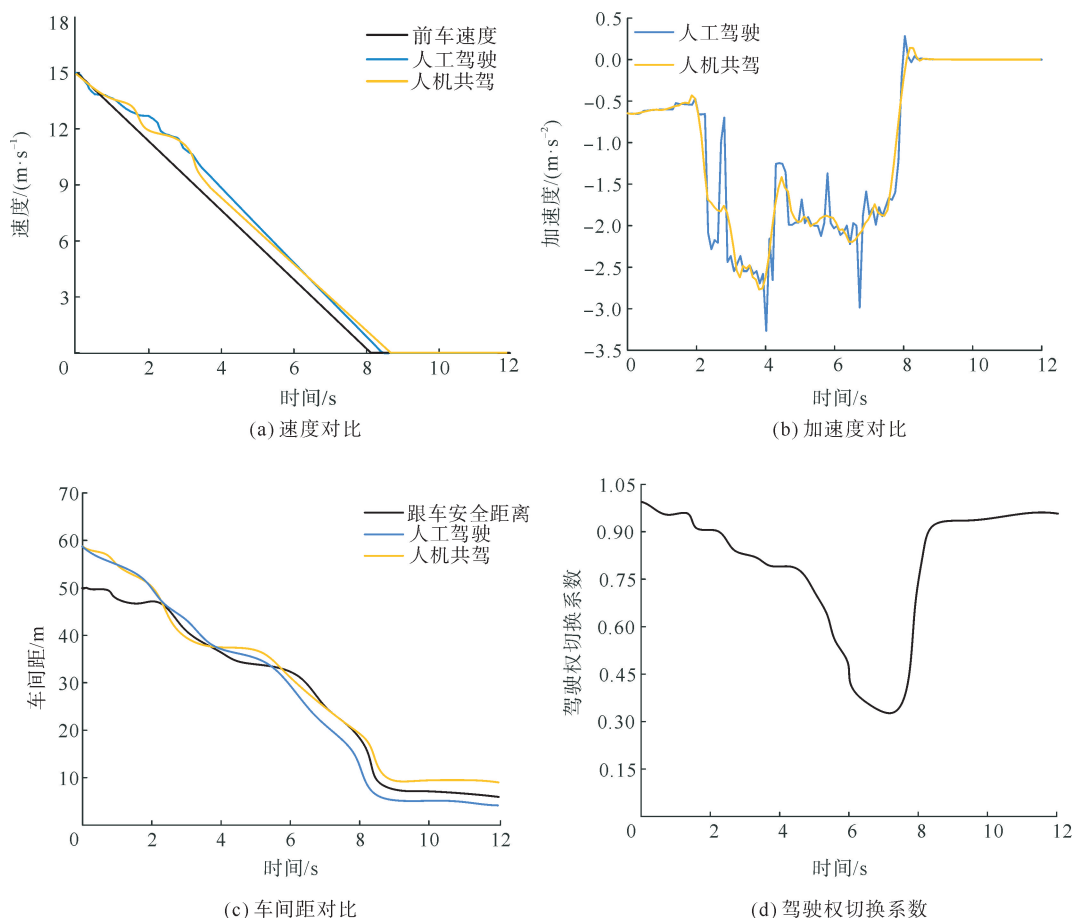


图6 前车制动工况

表 1 列出了先归一化处理后再求解的人机共驾模式和人工驾驶模式下的跟车安全性、驾驶舒适性和操作稳定性的性能评价指标。

分析图 6 和表 1 可知,图 6(a)中,前车匀减速至停车的过程中,人工驾驶车辆开始制动滞后于前车,由于力度把控不精确使得车速骤减,然后松刹车进行调整,4 s 后几乎趋于平稳,最终减速到 0。相比之下,人机共驾车辆在前车减速初期迅速响应,经过短暂调整后稳步减速,操作稳定性更优。从图 6(b)中可以看出在减速过程中人工驾驶车辆的加速度波动更加剧烈,舒适性较差。图 6(c)显示,人工驾驶车辆在跟车初期车速较高时保持较大安全距离,经过适应后车间距持续小于安全距离,反映出驾驶员风格较为激进。相比之下,人机共驾系统为了保证安全,车间距始终在安全范围内波动,并在停车阶段保持了较大的车间距。

当后车为人工驾驶车辆时,若前车准备减速且初始车间距大于安全距离,前车制动后,驾驶员凭借驾驶经验轻踩刹车,此时后车速度仍高于前车,车间距逐步缩小至安全范围。但驾驶员频繁切换油门与刹车操作,会导致车辆加速度大幅波动,不仅加剧行驶顿挫感、降低驾乘舒适性,还会增加驾驶员操作负荷。随着制动过程持续,车间距最终逐渐小于安全距离,直至两车完全停止。相较之下,若后车为人机共驾车辆,其智能驾驶辅助系统可提前识别前车减速意图并启动制动程序,使车间距始终在 2~6 s 对应的安全距离区间内小幅波动。人机共驾车辆在整个驾驶过程中,加速度变化更小且平滑,确保了更好的舒适性;在车辆完全停止后,与前车的间距也大于正常跟车安全距离,体现了人机共驾对驾乘人员安全性的优先考量。即便在图 6(d)的特殊场景中,驾驶员的操作策略与智能辅助驾驶系统的控制策略出现冲突,双方均无法取得决策主导权时,系统判定驾驶员与智能辅助系统处于犹豫不决、无法达成统一决策的状态,行车安全性与操纵稳定性的风险随之显著提升,此时人机共驾系统的安全兜底机制迅速启动,驾驶权切换系数迅速降至 0.33,车辆主要控制权被智能驾驶辅助系统接管。为从根本上规避碰撞风险,系统接管后立即主动拉大车间距,直至车辆平稳停止,充分彰显了人机共驾技术在复杂工况下的安全保障能力。

当后车为人工驾驶车辆时,若前车准备减速且初始车间距大于安全距离,前车制动后,驾驶员凭借驾驶经验轻踩刹车,此时后车速度仍高于前车,车间距逐步缩小至安全范围。但驾驶员频繁切换油门与刹车操作,会导致车辆加速度大幅波动,不仅加剧行驶顿挫感、降低驾乘舒适性,还会增加驾驶员操作负荷。随着制动过程持续,车间距最终逐渐小于安全距离,直至两车完全停止。相较之下,若后车为人机共驾车辆,其智能驾驶辅助系统可提前识别前车减速意图并启动制动程序,使车间距始终在 2~6 s 对应的安全距离区间内小幅波动。人机共驾车辆在整个驾驶过程中,加速度变化更小且平滑,确保了更好的舒适性;在车辆完全停止后,与前车的间距也大于正常跟车安全距离,体现了人机共驾对驾乘人员安全性的优先考量。即便在图 6(d)的特殊场景中,驾驶员的操作策略与智能辅助驾驶系统的控制策略出现冲突,双方均无法取得决策主导权时,系统判定驾驶员与智能辅助系统处于犹豫不决、无法达成统一决策的状态,行车安全性与操纵稳定性的风险随之显著提升,此时人机共驾系统的安全兜底机制迅速启动,驾驶权切换系数迅速降至 0.33,车辆主要控制权被智能驾驶辅助系统接管。为从根本上规避碰撞风险,系统接管后立即主动拉大车间距,直至车辆平稳停止,充分彰显了人机共驾技术在复杂工况下的安全保障能力。


#### 4.2 前车切入工况

针对前车切入工况,仿真参数设定为自车以 20 m/s 定速巡航,相邻车道前车以 16 m/s 匀速行驶,且两车间距 76 m。在 5 s 时,前车开始变道切入自车车道,8 s 时前车完成变道,在这个行车过程中,驾驶员按照自己的驾驶习惯进行驾驶,人机共驾车辆按照驾驶权分配后输出的控制量进行驾驶。图 7(a)(b)(c)分别为前车切入过程中人机共驾车辆和人工驾驶车辆的速度、加速度、与前车的车间距情况,图 7(d)是人机共驾车辆的驾驶权切换系数变化情况。


表 2 列出了先归一化处理后再求解的前车切入工况下,人机共驾模式和人工驾驶模式下的跟车安全性、驾驶舒适性和操作稳定性的性能评价指标。

表 1 人机共驾模式和传统人工驾驶模式性能评价

性能评价指标	人机共驾	人工驾驶
跟车安全性	28.57	26.08
驾驶舒适性	1.82	3.06
操作稳定性	17.76	30.24



(a) 速度对比



(b) 加速度对比




图7 前车切入工况

通过图7和表2可知,在前5s内,自车前方无车,人工驾驶车辆以20 m/s的速度巡航行驶;人机共驾车辆没有识别到风险,驾驶权切换系数为1。第5s以后,旁车道的前车开始切入自车车道,人工驾驶车辆驾驶员做出的判断迟于人机共驾车辆。驾驶员以自身驾驶习惯与切入车辆保持

了较危险的跟车距离,直到车速趋于相对平衡继续行驶;人机共驾车辆识别出了跟车风险正在急剧提高,驾驶权分配系数也从1直接降到0。在自动驾驶系统迅速接管驾驶权并将车速降至安全范围维持正常跟车距离后,跟车风险得到有效消除,随后,驾驶权会逐步恢复给驾驶员。与人工驾驶车辆相比,人机共驾车辆在前车切入情况下,做出响应的速度更快,加速度波动更小,并保持了较大跟车安全距离。总体而言,人机共驾车辆的安全性、舒适性和操作稳定性均更优。

表2 人机共驾模式和传统人工驾驶模式性能评价

性能评价指标	人机共驾	人工驾驶
跟车安全性	7.69	4.87
驾驶舒适性	0.44	0.51
操作稳定性	16.77	31.23

## 5 结论

在基于模型预测控制的人机共驾车辆纵向跟车研究中,上层利用MPC策略计算期望加速度,下层通过油门和刹车标定表分析驱动与制动的切换逻辑,并在加速工况和跟车工况下验证了所建模型的准确性。提出的驾驶权分配策略综合考虑了跟车的安全性、驾驶舒适性和操作稳定性3项性能指标。Carsim/Simulink联合仿真结果显示,人机共驾车辆在前车高速制动和切入情况下,相较于人工驾驶车辆,各项性能指标均表现更优,能够更好地应对突发情况,提高车辆的安全性和稳定性,并在复杂道路环境中减轻驾驶压力。然而,本研究只考虑了前车切入和前车制动两种工况,未涵盖更多复杂工况(如急转弯、坡道等)对人机共驾车辆的影响,也未考虑恶劣天气条件对车辆跟车性能的影响,这可能导致在实际道路环境中的表现与仿真结果存在差异。因此,在未来的研究中,可以考虑更复杂的环境条件,以进一步提高人机共驾系统的可靠性和安全性。

### 参考文献(References):

- [1] 宗长富,代昌华,张东. 智能汽车的人机共驾技术研究现状和发展趋势[J]. 中国公路学报,2021,34(6):214-237.  
ZONG Changfu, DAI Changhua, ZHANG Dong. Human-machine interaction technology of intelligent vehicles: Current development trends and future directions[J]. China Journal of Highway and Transport, 2021, 34(6): 214-237.
- [2] 陈秀锋,赵凤阳,王成鑫,等. 考虑期望视觉角的车辆跟驰建模与分析[J]. 复杂系统与复杂性科学,2025,22(3):122-128.  
CHEN Xiufeng, ZHAO Fengyang, WANG Chengxin, et al. Car-following modeling and analysis considering expected visual angle[J]. Complex Systems and Complexity Science, 2025, 22(3): 122-128.
- [3] 刘浩敏,曲大义,宋慧,等. 快速路交通流状态突变边界提取及其演化规律[J]. 复杂系统与复杂性科学,2023,20(3):74-81.  
LIU Haomin, QU Dayi, SONG Hui, et al. Extraction of catastrophe boundary and evolution of expressway traffic flow state[J]. Complex Systems and Complexity Science, 2023, 20(3): 74-81.

- [4] WEI S R, ZOU Y, ZHANG X D, et al. An integrated longitudinal and lateral vehicle following control system with radar and vehicle-to-vehicle communication[J]. *IEEE Transactions on Vehicular Technology*, 2019, 68(2):1116-1127.
- [5] 陈齐平, 曹天恒, 黄少堂, 等. 融合前馈及状态反馈的智能汽车模型预测控制[J]. *湖南大学学报(自然科学版)*, 2024, 51(8):165-175.  
CHEN Qiping, CAO Tianheng, HUANG Shaotang, et al. Model predictive control for intelligent vehicles fusing Feed-forward and state feedback[J]. *Journal of Hunan University(Natural Sciences)*, 2024, 51(8):165-175.
- [6] ZHANG X R, XU Q N, GONG X L, et al. Shared control for human-machine co-driving vehicles based on constraint-following approach[J]. *Journal of Vibration and Control*, 2024, 30(21/22):5132-5148.
- [7] HAN Y X, WANG T, SHI D, et al. The effect of multifactor interaction on the quality of human-machine co-driving vehicle take-over[J]. *Sustainability*, 2023, 15(6):5131.
- [8] WANG Z L, YU S Y, ZHANG Y J, et al. Learning-based predictive control for vehicle following problems[C]//2023 23rd International Conference on Control, Automation and Systems (ICCAS). IEEE. Yeosu, 2023:1364-1369.
- [9] 刘辉, 张发旺, 聂士达, 等. 基于逆模型预测控制的拟人驾驶控制[J]. *汽车工程*, 2024, 46(4):596-604.  
LIU Hui, ZHANG Fawang, NIE Shida, et al. Human-like driving control based on inverse model predictive control[J]. *Automotive Engineering*, 2024, 46(4):596-604.
- [10] LI X Y, WANG Y P, SU C Q, et al. Authority allocation approach for the human-machine co-driving system in crosswinds[J]. *Transportation Research Record*, 2024, 2678(11):1949-1971.
- [11] 黄菊花, 邹汉鹏, 刘明春. 考虑测量噪声的车辆自适应巡航控制系统纵向跟车研究[J]. *北京理工大学学报*, 2020, 40(3):254-261.  
HUANG Juhua, ZOU Hanpeng, LIU Mingchun. Research on the longitudinal tracking of adaptive cruise control system for vehicles considering of measurement noise[J]. *Transactions of Beijing Institute of Technology*, 2020, 40(3):254-261.
- [12] 孔令仁, 亓庆源. 含参数不确定及时滞的线性系统自适应模型预测控制[J]. *复杂系统与复杂性科学*, 2024, 21(3):136-143.  
KONG Lingren, QI Qingyuan. Adaptive model predictive control for linear systems with parametric uncertainties and time delay[J]. *Complex Systems and Complexity Science*, 2024, 21(3):136-143.
- [13] 徐哲, 胡趁义, 龙永文, 等. 车辆纵向跟车舒适性模型预测控制算法研究[J]. *重庆理工大学学报(自然科学)*, 2022, 36(12):9-17.  
XU Zhe, HU Chenyi, LONG Yongwen, et al. Research on the model predictive control algorithm of comfortable longitudinal car following[J]. *Journal of Chongqing University of Technology(Natural Science)*, 2022, 36(12):9-17.
- [14] 刘西, 明朗, 胡远志. 基于 MPC 算法的车辆自适应巡航系统分层控制研究[J]. *重庆理工大学学报(自然科学)*, 2021, 35(3):53-60.  
LIU Xi, MING Lang, HU Yuanzhi. Research on hierarchical control of vehicle adaptive cruise system based on MPC Algorithm[J]. *Journal of Chongqing University of Technology(Natural Science)*, 2021, 35(3):53-60.
- [15] 音建华, 牛礼民, 张义奇, 等. 基于 MPC 分层控制的自适应巡航策略[J]. *安徽工业大学学报(自然科学版)*, 2025, 42(1):36-45.  
YIN Jianhua, NIU Limin, ZHANG Yiqi, et al. Research on adaptive cruise strategy based on MPC hierarchical control[J]. *Journal of Anhui University of Technology(Natural Science)*, 2025, 42(1):36-45.
- [16] MA S, XU Y W, LI D W, et al. Dual-level control strategy for vehicle lateral and longitudinal path following based on model predictive control[C]//2024 IEEE Intelligent Vehicles Symposium (IV). IEEE. Jeju Island, 2024:2717-2722.
- [17] QIN Z B, JING H D, CHEN L, et al. Longitudinal vehicle stability control based on modified sliding mode control[J]. *Automotive Innovation*, 2024, 7(2):335-348.
- [18] 王和荣. 无人驾驶机器人车辆纵向动力学特性学习与控制研究[D]. 南京:南京理工大学, 2020.  
WANG Herong. Research on the learning of longitudinal dynamics characteristic and the control for unmanned driving robot vehicle[D]. Nanjing: Nanjing University of Science & Technology, 2020.

(责任编辑 张晓靖;英文校审 程文华)