

• 智能汽车运动控制与先进控制算法专题 •

智能汽车轨迹跟踪 MPC-RBF-SMC 协同控制策略研究*

张良 蒋瑞洋 卢剑伟 程浩 雷夏阳

(合肥工业大学, 合肥 230009)

【摘要】针对自动驾驶车辆行驶过程中模型失配以及外部环境干扰导致车辆轨迹跟踪环节精确性不高的问题,提出了一种结合车辆运动学模型预测控制(MPC)、径向基(RBF)神经网络和滑模控制(SMC)的轨迹跟踪控制策略。通过建立车辆运动学 MPC 模型计算当前状态车辆期望横摆角速度,并将其与实际横摆角速度的偏差输入 RBF-SMC 控制器,利用 RBF 快速逼近非线性模型的特点,结合滑模控制输出前轮转角,实现车辆的横向轨迹跟踪控制。仿真结果表明,与传统的控制器相比,该方法轨迹跟踪精度显著提高,并在不同行驶工况下表现出较好的鲁棒性。

关键词: 车辆运动学模型 模型预测控制 径向基神经网络 滑模控制

中图分类号:U461.6 文献标志码:A DOI: 10.20104/j.cnki.1674-6546.20230444

Research on MPC-RBF-SMC Collaborative Control Strategy for Intelligent Vehicle Trajectory Tracking

Zhang Liang, Jiang Ruiyang, Lu Jianwei, Cheng Hao, Lei Xiayang

(Hefei University of Technology, Hefei 230009)

【Abstract】This paper proposed a trajectory tracking control strategy that combined Model Predictive Control (MPC), Radial Basis Function (RBF) neural network, and Sliding Mode Control (SMC) to address the low accuracy of vehicle trajectory tracking caused by model mismatch and external environmental interference during the driving process of autonomous vehicles. By establishing a vehicle kinematic model predictive control, the expected yaw rate of the vehicle in the current state was calculated, and the deviation value from the actual yaw rate was input to the RBF-SMC controller. By utilizing RBF's ability to quickly approach nonlinear models, combined with sliding mode control to output front wheel angles, the lateral trajectory tracking control of the vehicle was achieved. The simulation experimental results show that this method significantly improves trajectory tracking accuracy compared with traditional controllers, and exhibits good robustness under different driving conditions.

Key words: Vehicle kinematics model, Model Predictive Control (MPC), Radial Basis Function (RBF) neural network, Sliding Mode Control (SMC)

【引用格式】张良, 蒋瑞洋, 卢剑伟, 等. 智能汽车轨迹跟踪 MPC-RBF-SMC 协同控制策略研究[J]. 汽车工程师, 2024(5): 11-19.

ZHANG L, JIANG R Y, LU J W, et al. Research on MPC-RBF-SMC Collaborative Control Strategy for Intelligent Vehicle Trajectory Tracking[J]. Automotive Engineer, 2024(5): 11-19.

1 前言

近些年,汽车的智能化发展对车辆路径跟踪控

制的精度和乘坐舒适性等方面提出了更高的要求^[1]。智能车辆是一个时延、非线性系统,其模型参数具有不确定性,同时,行驶过程中的外部干扰提

*基金项目:国家重点研发计划项目(2021YFE0116600)。

高了轨迹跟踪控制器的设计难度。其中,智能车辆的横向控制是保证车辆的行驶安全性和乘坐舒适性的关键技术之一^[2]。

针对智能车辆跟踪控制问题,国内外专家提出了各种解决方案。PID控制^[3-4]和模糊控制^[5-6]因具有不需建立精确模型等优点,常用于车辆轨迹跟踪控制。文献[3]将PID控制器和模糊控制相结合,动态调整控制器参数,获得了理想的跟踪效果,但由于无法预测车辆状态变化,参数调整需要较长时间。

模型预测控制(Model Predictive Control, MPC)具有可处理多输入多输出和预测未来一段时间内状态变化的优点,可解决控制中易受状态变化影响的问题,逐渐在轨迹跟踪控制领域应用^[7-9]。其中,车辆行驶所处的环境多样,对依赖精确模型的算法的控制效果会产生较大影响,故文献[10]和文献[11]提出使用自适应模糊控制和切换控制模型的控制策略,以解决MPC在轨迹跟踪过程中因模型精确性等问题产生的不利影响。文献[12]也提出,在水下航行器的控制中,可利用SMC结合MPC以抑制外部干扰。

对于车辆轨迹跟踪控制效果受到外界干扰和模型不确定性影响的问题,有专家提出使用自适应控制^[13-14]、滑模控制(Sliding Mode Control, SMC)^[15-17]、神经网络控制^[18-19]等算法解决此类问题。其中,滑模控制用于横向控制中会产生抖振,文献[17]使用高阶滑模平抑抖振现象,提高了车辆跟踪控制的稳定性,但仍无法预测车辆的状态变化。文献[19]面对路径跟踪的复杂情况,提出了一种通过神经网络预测的智能循迹控制策略,通过采集驾驶员操作样本对控制器进行训练,取得了理想的控制效果。但此控制策略依赖大量的训练集数据,要实现较好的控制效果,所需成本较高。

为避免在车辆跟踪控制中出现的各种局限性,同时保持较高的跟踪精度,本文将RBF和SMC相结合构成下层控制器,并级联MPC构造跟踪控制器,在具备MPC优点的同时也能补偿外部环境的干扰或建模不确定性等因素对控制效果的影响,从而提高车辆轨迹跟踪控制精度。

2 车辆模型

2.1 车辆运动学模型

本文建立的车辆运动学模型如图1所示。




图1 车辆运动学模型

图1中, (X_r, Y_r) 和 (X_f, Y_f) 分别为车辆后轴中心和前轴中心在全局坐标系下的坐标, δ_f 为前轮转角, R 为后轴中心的瞬时转向半径, l 为轴距, φ 为横摆角, v 为车辆后轴中心处的速度。则可在大地坐标系中构建车辆的几何关系,并假设车辆为平面运动,忽略垂直、俯仰和侧倾运动,且车轮的滑移角均为零。

得到车辆运动学模型为:

$$\begin{cases} \dot{X} = v \cos \varphi \\ \dot{Y} = v \sin \varphi \\ \dot{\varphi} = (v \tan \delta_f) / l \end{cases} \quad (1)$$

式中: X 、 Y 分别为车辆质心位置在全局坐标系中的横、纵坐标。

上述模型将车辆视为刚体,并只考虑了车辆运动的形状和位姿变化,没有考虑车辆的质量与车轮间的相互作用力。

2.2 考虑轮胎滑移的动力学模型

考虑轮胎受力情况构建动力学模型,受限于轮胎模型的复杂性,无法实时获得足够精确的车辆模型,故对轮胎模型进行简化,根据图2所示的不同载荷下轮胎侧向力与轮胎侧偏角的关系曲线可以看出,当轮胎侧偏角较小时,轮胎侧向力可以近似表示为轮胎侧偏角的线性函数^[20]:

$$\begin{cases} F_{yf} = C_{\alpha f} \alpha_f \\ F_{yr} = C_{\alpha r} \alpha_r \end{cases} \quad (2)$$

式中: F_{yf} 、 F_{yr} 分别为前、后轮侧向力, α_f 、 α_r 分别为前、后轮侧偏角, $C_{\alpha f}$ 、 $C_{\alpha r}$ 分别为前、后轮线性侧偏刚度。




图2 不同载荷条件下轮胎侧向力与侧偏角的关系

其中,轮胎侧偏角 α_r 和 α_f 可表示为:

$$\begin{cases} \alpha_f = \frac{v_y + l_f \dot{\varphi}}{v_x} - \delta_f \\ \alpha_r = \frac{v_y - l_r \dot{\varphi}}{v_x} \end{cases} \quad (3)$$

式中: l_f 、 l_r 分别为车辆质心到前、后轴的距离, v_x 、 v_y 分别为车体坐标系 x 轴和 y 轴方向的速度。

在车辆行驶过程中,轮胎滑移对轮胎的纵向力存在显著影响,特别是在道路摩擦因数较小的情况下,因此有必要建立考虑轮胎滑移因素的车辆动力学模型。为了进行后续探讨,本文先假设前轮偏角较小且轮胎模型为线性模型,则可建立考虑轮胎滑移的车辆动力学模型的表达式为:

$$\begin{cases} m\dot{v}_y = -m\dot{v}_x \dot{\varphi} + 2 \left[C_{af} \left(\delta_f - \frac{v_y + l_f \dot{\varphi}}{v_x} \right) + C_{ar} \frac{l_f \dot{\varphi} - v_y}{v_x} \right] \\ m\dot{v}_x = mv_y \dot{\varphi} + 2 \left[C_{rf} s_f + C_{ar} \left(\delta_f - \frac{v_y + l_f \dot{\varphi}}{v_x} \right) \delta_f + C_{lr} s_r \right] \\ I_z \ddot{\varphi} = 2 \left[l_f C_{af} \left(\delta_f - \frac{v_y + l_f \dot{\varphi}}{v_x} \right) - l_r C_{ar} \frac{l_r \dot{\varphi} - v_y}{v_x} \right] \\ \dot{Y} = v_x \sin \varphi + v_y \cos \varphi \\ \dot{X} = v_x \cos \varphi - v_y \sin \varphi \end{cases} \quad (4)$$

式中: C_{lr} 、 C_{lf} 分别为车辆前、后轮胎的纵向侧偏刚度, s_f 、 s_r 分别为前、后车轮的滑移率, I_z 为转动惯量, m 为整车质量。

在构建的车辆动力学模型中,所需考虑的因素主要是动力学约束和外部环境的干扰,如车辆行驶路面的复杂性、行驶时的风阻等。

考虑上述因素会增加模型计算维度,从而导致控制效率降低,甚至求解失败,因而没有模型能完全精确地反映外部干扰的特性。但忽略上述因素的影响会导致模型出现失配现象,即模型不能精确反映车辆的运动状态变化,对于依赖于模型的控制

器,这意味着控制精度的降低。本文针对此现象,提出新的控制策略以抑制模型失配和外部干扰。

3 控制器设计

路径跟踪控制的目标是在期望的速度下使车辆尽可能接近给定的路径。本文主要研究车辆的横向轨迹跟踪控制,并基于车辆运动学模型,提出一种由 MPC-RBF-SMC 构成的级联控制器,其控制框架如图3所示。

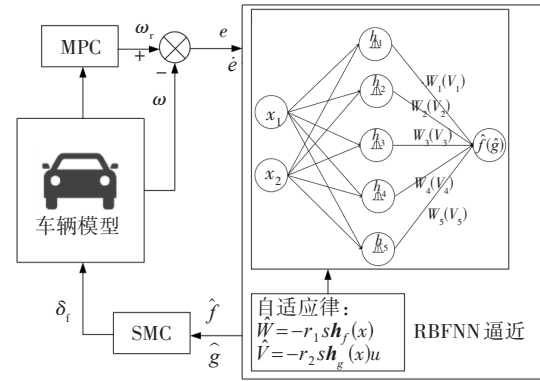


图3 控制策略流程

上层控制器由基于运动学模型的 MPC 控制器构成,通过输入的车辆轨迹状态计算出当前状态下的理想横摆角速度。下层控制器由 RBF-SMC 控制器构成,用于跟踪上层控制器输出的理想横摆角速度,最终输出前轮转角,实现车辆的轨迹跟踪。

3.1 运动学MPC控制器设计

模型预测控制在路径跟踪领域得到了广泛的应用,一般情况下,根据车辆模型的不同,大致可分为基于运动学的模型预测控制(Kinematics Model Predictive Control, KMPC)和基于动力学的模型预测控制(Dynamics Model Predictive Control, DMPC)两种方法。KMPC的计算模型简单、计算效率高,但只适用于低速条件下。随着速度的提高,运动学模型的失配将导致控制效果变差,即会产生较大的跟踪误差。而动力学模型相较于运动学模型,虽然可以抑制车速提高对模型的影响,但计算效率也会随之降低。

由上节中车辆运动学模型可构建 MPC 控制器。可定义状态变量 $\chi = [x \ y \ \varphi]^T$ 和控制变量 $u = [v \ \omega]^T$, 其中 $\omega = (v \cdot \tan \delta) / l$ 为横摆角速度。则该车辆运动学模型可以转换为:

$$\begin{bmatrix} \dot{X} \\ \dot{Y} \\ \dot{\varphi} \end{bmatrix} = \begin{bmatrix} \cos \varphi \\ \sin \varphi \\ 0 \end{bmatrix} v + \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} \omega \quad (5)$$

式(5)可表示为:

$$\dot{\chi}=f(\chi, u) \quad (6)$$

假设车辆在任意时刻做直线运动或者绕某个点做圆周运动,并忽略悬架的作用,对于给定的参考轨迹,控制系统可表示为 $\dot{\chi}_r=f(\chi_r, u_r)$ 。其中 $\chi_r=[x_r \ y_r \ \varphi_r]^T$ 为参考状态, $u_r=[v_r \ \omega_r]^T$ 为参考控制输入。其中, x_r, y_r, φ_r 分别为参考X轴位置、参考Y轴位置和参考横摆角, v_r, ω_r 分别为参考速度和参考横摆角速度。

可对式(6)在参考轨迹点进行泰勒级数展开,近似得到:

$$\begin{aligned} \dot{\chi} &= f(\chi_r, u_r) + \frac{\partial f(\chi, u)}{\partial \chi} \Big|_{\chi=\chi_r} (\chi - \chi_r) \\ &+ \frac{\partial f(\chi, u)}{\partial u} \Big|_{u=u_r} (u - u_r) \end{aligned} \quad (7)$$

将式(7)与 $\dot{\chi}_r=f(\chi_r, u_r)$ 相减,令 $\dot{\tilde{\chi}}=\dot{\chi}-\dot{\chi}_r$,可得车辆轨迹误差模型:

$$\begin{aligned} \dot{\tilde{\chi}} &= \begin{bmatrix} \dot{x} - \dot{x}_r \\ \dot{y} - \dot{y}_r \\ \dot{\varphi} - \dot{\varphi}_r \end{bmatrix} = \begin{bmatrix} 0 & 0 & -v_r \sin \varphi_r \\ 0 & 0 & v_r \cos \varphi_r \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} x - x_r \\ y - y_r \\ \varphi - \varphi_r \end{bmatrix} + \\ & \begin{bmatrix} \cos \varphi_r & 0 \\ \sin \varphi_r & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} v - v_r \\ \omega - \omega_r \end{bmatrix} \end{aligned} \quad (8)$$

将该模型应用于控制器,以 $\dot{\tilde{\chi}}=A_k \tilde{\chi} + B_k \tilde{u}$ 表示式(8),并进行离散化处理。使用前向欧拉法得到离散的误差模型:

$$\tilde{\chi}(k+1) = A_{k,t} \tilde{\chi}(k) + B_{k,t} \tilde{u}(k) \quad (9)$$

$$\text{式中: } A_{k,t} = I + TA_t = \begin{bmatrix} 1 & 0 & -v_r T \sin \varphi_r \\ 0 & 1 & v_r T \cos \varphi_r \\ 0 & 0 & 1 \end{bmatrix}, B_{k,t} = TB_t =$$

$$\begin{bmatrix} T \cos \varphi_r & 0 \\ T \sin \varphi_r & 0 \\ 0 & T \end{bmatrix}, T \text{ 为采样时间。}$$

$$\text{选择一个新的状态变量 } \xi(k|t) = \begin{bmatrix} \tilde{\chi}(k|t) \\ \tilde{u}(k-1|t) \end{bmatrix},$$

对式(9)进行转换,得到新的模型:

$$\xi(k+1|t) = \bar{A}_{k,t} \xi(k|t) + \bar{B}_{k,t} \Delta u(k|t) \quad (10)$$

整理后再由 $\eta(k)$ 表示:

$$\eta(k) = \bar{C}_{k,t} \xi(k|t) \quad (11)$$

$$\text{式中: } \bar{A}_{k,t} = \begin{bmatrix} A_{k,t} & B_{k,t} \\ \mathbf{0}_{m \times n} & I_m \end{bmatrix}; \bar{B}_{k,t} = \begin{bmatrix} B_{k,t} \\ I_m \end{bmatrix}; \bar{C}_{k,t} = [I_n \ \cdots \ \mathbf{0}_{n \times m}];$$

m, n 为状态变量和控制变量的维数; $\Delta u(k|t)$ 为控制

增量,其中 k 为任意时刻,且 $k=1, 2, \dots, t+N-1$; t 为当前时刻; N 为计算所需的时域。

为了简化计算,假设系统均以当前时刻的离散状态量进行推导,即 $\bar{A}_{k,t}=\bar{A}_{t,t}, \bar{B}_{k,t}=\bar{B}_{t,t}, \bar{C}_{k,t}=\bar{C}_{t,t}$,可整理得到系统的预测输出表达式:

$$Y(t) = \Psi_t \xi(t|t) + \Theta_t \Delta U(t) \quad (12)$$

$$\text{式中: } Y(t) = \begin{bmatrix} \eta(t+1|t) \\ \eta(t+2|t) \\ \vdots \\ \eta(t+N_p|t) \end{bmatrix}, \Psi_t = \begin{bmatrix} \dot{C}_{t,t} \dot{A}_{t,t} \\ \dot{C}_{t,t} \bar{A}_{t,t}^2 \\ \vdots \\ \dot{C}_{t,t} \bar{A}_{t,t}^{N_p} \end{bmatrix}, \Theta_t =$$

$$\begin{bmatrix} \dot{C}_{t,t} \dot{A}_{t,t} & \mathbf{0} & \cdots & \mathbf{0} \\ \dot{C}_{t,t} \dot{A}_{t,t} \dot{B}_{t,t} & \dot{C}_{t,t} \dot{B}_{t,t} & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \dot{C}_{t,t} \dot{A}_{t,t}^{N_p-1} \dot{B}_{t,t} & \dot{C}_{t,t} \dot{A}_{t,t}^{N_p-2} \dot{B}_{t,t} & \cdots & \mathbf{0} \end{bmatrix} \Delta U(t) = \begin{bmatrix} \Delta u(t|t) \\ \Delta u(t+1|t) \\ \vdots \\ \Delta u(t+N_p-1|t) \end{bmatrix},$$

N_p 为预测时域, N_c 为控制时域。

定义目标函数求得最优控制量:

$$\begin{aligned} J(k) &= \sum_{i=1}^{N_p} \left\| \eta(t+i|t) - \eta_r(t+i|t) \right\|_Q^2 + \\ & \sum_{i=1}^{N_c} \left\| \Delta U(t+i|t) \right\|_R^2 + \rho \varepsilon^2 \end{aligned} \quad (13)$$

式中: ρ 为权重系数, ε 为松弛因子, η_r 为参考状态量, Q, R 为权重矩阵。

第1项反映了预测输出点与期望轨迹点之间的误差的代价,第2项反映了控制量变化的代价。为了求得最优 $\Delta U(t)$,需要总代价量 J 取得最小值, J 可以表示为:

$$J(\xi(t), u(t-1), \Delta U) = [\Delta U(t)^T \ \varepsilon]^T H \Delta U(t) + G_t [\Delta U(t)^T \ \varepsilon]^T \quad (14)$$

式中: $H_t = \Theta_t^T Q \Theta_t + R, G_t = 2E_t^T Q \Theta_t, E_t$ 为预测时域内的跟踪误差。

其约束条件表示为:

$$\Delta U_{\min} \leq \Delta U_t \leq \Delta U_{\max} \quad (15)$$

$$U_{\min} \leq A \Delta U_t + U_t \leq U_{\max} \quad (16)$$

式中: $\Delta U_{\min}, \Delta U_{\max}$ 分别为控制量的最小、最大变化量集合, U_{\min}, U_{\max} 分别为控制量的最小值、最大值集合, $U_t = [u(k-1) \ u(k-1) \ \cdots \ u(k-1)]_{N_c}^T, \Delta U_t =$

$[\Delta u(k) \ \Delta u(k) \ \cdots \ \Delta u(k)]_{N_c}^T, u(k-1)$ 为上一时刻

实际控制量, $\Delta u(k)$ 为当前时刻的控制增量, $A =$

$$\begin{bmatrix} I_m & \mathbf{0} & \cdots & \cdots & \mathbf{0} \\ I_m & I_m & \mathbf{0} & \cdots & \mathbf{0} \\ I_m & I_m & I_m & \cdots & \mathbf{0} \\ \vdots & \vdots & \vdots & \ddots & \mathbf{0} \\ I_m & I_m & \cdots & I_m & I_m \end{bmatrix}_{N_c \times N_c} \circ$$

上述推导需利用二次规划计算在最小代价条件下输入变化量的大小,再通过 $u(t)=u(t-1)+\Delta u$ 计算得到当前时刻实际控制量 $u(t)$,即理想横摆角速度,传递给下层控制器进行跟踪控制。

3.2 RBF-SMC控制器设计

基于运动学模型,通过MPC控制器得到期望的横摆角速度后,需要搭建下层控制器以实现对其期望的角速度信号跟踪控制。根据第2节的车辆动力学模型可得到车辆的横摆角速度与前轮转角存在非线性关系,可表示为:

$$\ddot{\omega}=f(\omega,\dot{\omega})+g(\omega,\dot{\omega})u+d(t) \quad (17)$$

式中: f 、 g 为未知的非线性函数; u 为控制量,即前轮转角; $d(t)$ 为外部干扰,且 $|d(t)|\leq D$ (有界干扰)。

运动学控制器给出期望的横摆角速度 ω_r ,车辆行驶的实际横摆角速度为 ω 。可定义横摆角速度的误差为:

$$e=\omega_r-\omega \quad (18)$$

本文选用滑动面 s 公式:

$$s=\dot{e}+ce \quad (19)$$

可设计控制律为:

$$u=\frac{1}{g(x)}[-f(x)+\ddot{\omega}_r+ce+\eta\operatorname{sgn}(s)] \quad (20)$$

式中: $g(x)$ 、 $f(x)$ 为非线性函数; η 为预设参数,且 $\eta\geq D$ 。

上述控制律中包含了 f 和 g 的未知部分,而控制律的实现必须具有足够精确的模型。本文采用RBF神经网络进行在线逼近,以有效解决系统的不确定性问题。

本文设计的RBF神经网络主要由输入层、隐藏层和输出层组成。为了避免 f 和 g 估计之间的相互干扰,本文使用2个独立的RBF神经网络。输入层接收上层控制器输出的理想横摆角速度与当前横摆角速度的偏差及其导数,即 $[e \ e]^T$ 。输出层输出对非线性关系的估计值,即 $[\hat{f} \ \hat{g}]^T$ 。网络结构如图4所示。




图4 RBF神经网络结构

RBF神经网络在输入层有2个输入神经元,在输出层有5个隐藏层神经元和1个输出神经元。输入层的输入信号 $x=[x_1 \ x_2]^T$ 传输到隐藏层的每个神经元,隐藏层由5个具有高斯核的节点组成,每个节点具有预先定义的中心和偏置宽度,高斯函数描述为^[21]:

$$h_j=\exp\left(-\frac{\|x-c_j\|^2}{2b_j^2}\right) \quad (21)$$

式中: $h_j(j=1,2,3,\dots,n)$ 为每个神经元计算的高斯函数,形成高斯函数的输出向量 $h=[h_j]^T$; n 为神经元数量; $c_j=[c_{1j} \ c_{2j}]^T$ 为隐藏层第 j 个节点的高斯函数中心的坐标向量,隐藏层所有节点的高斯函数中心点的坐标向量由 $c=\begin{bmatrix} c_{11} & \dots & c_{1n} \\ c_{21} & \dots & c_{2n} \end{bmatrix}$ 表示; b_j 为隐藏层第 j 个节点的高斯函数的宽度,隐藏层所有节点的高斯函数的宽度由 $b=[b_1 \ \dots \ b_n]^T$ 表示。

所以,RBF的输出可以表示为:

$$f=W^T h_f(x)+\varepsilon_f \quad (22)$$

$$g=V^T h_g(x)+\varepsilon_g \quad (23)$$

式中: W^* 、 V^* 为网络理想权值; $h_f(x)$ 、 $h_g(x)$ 分别为RBF神经网络所逼近的高斯函数; ε_f 、 ε_g 为网络的逼近误差,均为有界误差。

因此,所提出的RBF神经网络的输出可重写为:

$$\hat{f}(x)=\hat{W}^T h_f(x) \quad (24)$$

$$\hat{g}(x)=\hat{V}^T h_g(x) \quad (25)$$

式中: \hat{W} 、 \hat{V} 为估计向量。

则式(21)的控制律可改写为:

$$u=\frac{1}{\hat{g}(x)}[-\hat{f}(x)+\ddot{\omega}_r+ce+\eta\operatorname{sgn}(s)] \quad (26)$$

并设计自适应律为^[22]:

$$\dot{\hat{W}}=-\gamma_1 s h_f(x) \quad (27)$$

$$\dot{\hat{V}}=-\gamma_2 s h_g(x) u \quad (28)$$

式中: $\gamma_1>0$ 、 $\gamma_2>0$ 。

4 仿真分析

4.1 仿真环境搭建

基于MATLAB/Simulink和CarSim仿真平台设计搭建了KMPC-RBF-SMC车辆路径跟踪控制器。车辆主要参数参考CarSim中C级掀背式汽车(C-Class Hatchback)的预设数据,如表1所示。轮胎型号选择215/55 R17,仿真中路面上附着系数设为0.8。

表1 车辆主要参数

| 参数名称 | 数值 |
|--|----------|
| 整车质量 m/kg | 1 416 |
| 转动惯量 $I/\text{kg}\cdot\text{m}^2$ | 1 536.7 |
| 质心到前轴的距离 l_f/m | 1.015 |
| 质心到后轴的距离 l_r/m | 1.895 |
| 轴距 l/m | 2.91 |
| 前轮侧偏刚度 $C_{lf}/\text{N}\cdot\text{rad}^{-1}$ | -112 600 |
| 后轮侧偏刚度 $C_{lr}/\text{N}\cdot\text{rad}^{-1}$ | -94 548 |

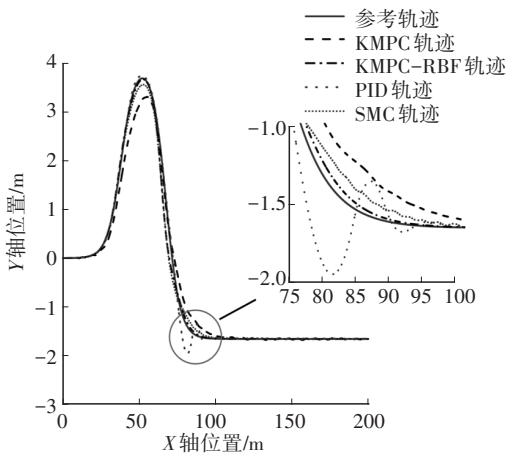
4.2 多种控制器仿真对比

双移线轨迹道路曲率变化较大,可更好地表现出各控制器对车辆行驶稳定性和跟踪精确性的影响,故本文选用双移线轨迹作为跟踪参考轨迹:


$$\begin{cases} Y_r(X) = \frac{d_{y1}}{2} [1 + \tanh(z_1)] - \frac{d_{y2}}{2} [1 + \tanh(z_2)] \\ \varphi_r(X) = \arctan \left[d_{y1} \left(\frac{1}{\cosh(z_1)} \right)^2 \left(\frac{1.2}{d_{x1}} \right) - d_{y2} \left(\frac{1}{\cosh(z_2)} \right)^2 \left(\frac{1.2}{d_{x2}} \right) \right] \end{cases} \quad (29)$$

式中: $d_{x1}=25, d_{x2}=21.95, d_{y1}=4.05, d_{y2}=5.7, z_1=2.4(X-27.19)/d_{x1}-1.2, z_2=2.4(X-56.46)/d_{x2}-1.2$ 。

为了分析控制器的轨迹跟踪控制精确性,通过对PID控制、多点预瞄SMC、DMPC、KMPC与本文提出的控制策略(KMPC-RBF)分别进行仿真验证,得到车辆在36 km/h和72 km/h车速下的行驶轨迹,结果如图5所示。



(a)36 km/h



(b)72 km/h

图5 不同车速下各控制器的跟踪轨迹

设置评价指标为:

$$e_{\max} = \max(|\hat{y}_i - y_i|) \quad (30)$$

$$e_{\text{RMS}} = \sqrt{\frac{1}{p} \sum_{i=1}^p (\hat{y}_i - y_i)^2} \quad (31)$$

式中: \hat{y}_i 为车辆在第*i*点的横向位置, y_i 为第*i*点处的参考路径横向位置, e_{\max} 为最大横向偏差, e_{RMS} 为横向偏差的均方根, p 为轨迹点的总量。

表2所示为各控制器在2种速度下的最大横向偏差和横向均方根偏差的对比结果。

表2 不同车速下各控制器控制结果

| 控制器 | 36 km/h | | 72 km/h | |
|----------|------------|------------------|------------|------------------|
| | e_{\max} | e_{RMS} | e_{\max} | e_{RMS} |
| KMPC | 0.591 4 | 0.034 2 | 0.668 7 | 0.047 9 |
| KMPC-RBF | 0.034 2 | 0.008 3 | 0.193 8 | 0.001 6 |
| PID | 0.595 0 | 0.011 2 | 0.804 4 | 0.055 6 |
| SMC | 0.745 8 | 0.021 8 | 0.594 1 | 0.044 2 |

4.3 KMPC-RBF控制器横向精确性分析

在36 km/h车速条件下,结合图5a和表2可知:KMPC、PID、SMC的控制精度相差不多,但PID控制在曲率变化较大处存在剧烈抖动,SMC控制也存在微小的抖振现象,KMPC则表现出平缓的控制效果;在行驶平顺性方面,KMPC的效果优于PID和SMC;KMPC-RBF的最大偏差和偏差的均方根均小于其他控制器,且控制平缓,优于其余控制器。

在72 km/h车速条件下,KMPC控制器明显无法跟踪轨迹,不具备参考性,这也表明了运动学模型不适用于高速环境。为了验证出现这种现象的原因,增加DMPC控制器。结合图5b和表2可知,DMPC控制器控制效果远优于KMPC。对比分析可

知,运动学模型在高速环境下出现模型失配现象。

同时,72 km/h车速下PID控制器 e_{\max} 和 e_{RMS} 均高于其余控制器,表明其控制精度最差。与36 km/h车速下的数据相比,SMC控制器的 e_{\max} 降低了0.1517 m,但 e_{RMS} 提高了0.0224 m,表明SMC可抑制车速提高对控制精度带来的影响,但随着车辆的提高也出现误差变化不稳定的现象,且在轨迹图中也显示出抖振现象的加剧。DMPC的 e_{\max} 和 e_{RMS} 与SMC的数据对比,结果相差不大,但轨迹图中未出现抖振现象。综上可知,PID和SMC在行驶平顺性方面的控制效果较DMPC和KMPC-RBF差。

在双移线轨迹下,各控制器的横向偏差和横摆角偏差数据对比如图6所示。




图6 72 km/h车速下各控制器的控制性能

根据图6分析可知,DMPC综合控制效果优于PID控制器和SMC控制器,但明显较KMPC-RBF差。KMPC-RBF相较于DMPC,横向偏差最大值减小了0.475 m,横摆角偏差减小了0.611°,提升效果明显,证明KMPC-RBF在高速条件下,仍能保持较好的控制精度。

4.4 KMPC-RBF控制器的车速鲁棒性分析

车辆行驶过程中,纵向速度对车辆的横向稳定

性有重要影响。为了验证设计控制器的鲁棒性,本文通过仿真进行分析。

在36 km/h、54 km/h和72 km/h 3种恒定车速下仿真获得横向偏差、横摆角、横向速度和前轮转角与时间的关系,分析控制器鲁棒性和路径跟踪性能。其中KMPC-RBF在3种速度下的控制参数相同,仿真结果如图7所示。

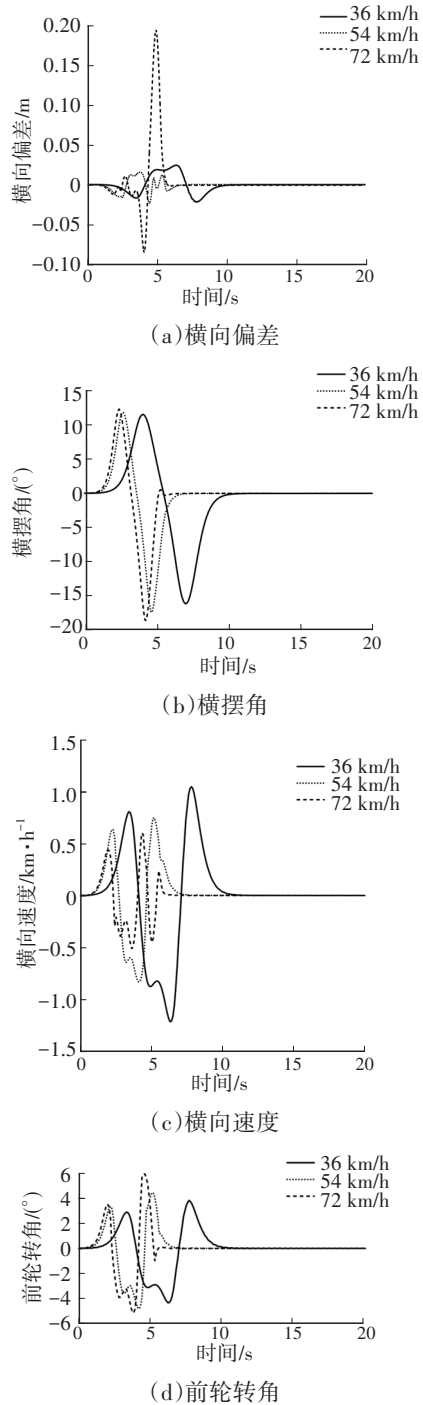


图7 不同速度下的KMPC-RBF控制性能

由图7a、图7b可知,所设计的控制器可在3种

不同车速下产生预期的控制信号。横摆角信号有着相同的变化趋势,且在道路曲率变化较大的双移线轨迹下横向偏差均小于0.2 m。这表明设计控制器在车速变化时具有较好的鲁棒性。在72 km/h的速度下,路径的跟踪精度也较高,通过图7c可以看出,纵向速度越低,横向速度越小,且横向速度控制在 ± 1.25 m/s范围内。这反映设计的控制器安全行驶范围在80 km/h左右。由图7d可以看出,前轮转角没有抖振情况,也表明控制器能够有效抑制抖振现象。

5 结束语

本文以智能车辆作为研究对象,针对轨迹跟踪控制存在的精确度问题,提出了一种基于车辆经典运动学模型构建的MPC-RBF-SMC控制策略。以双移线轨迹为参考线进行仿真验证,结果表明,相较于PID控制、SMC和MPC策略,本文提出的控制策略在具备MPC算法优点的同时,控制精度得到了提高。

仿真结果同样表明,在不同车速下,本文所提出的控制策略的横向偏差、横摆角偏差等均控制在较小范围内,整体跟踪效果平滑,验证了MPC-RBF-SMC控制策略控制效果优于传统控制策略,且具有较好的鲁棒性。

参 考 文 献

- [1] XING B, XU E, WEI J, et al. Recurrent Neural Network Non-Singular Terminal Sliding Mode Control for Path Following of Autonomous Ground Vehicles with Parametric Uncertainties[J]. IET Intelligent Transport Systems, 2022(5): 616-629.
- [2] MING X, MINOR M A. Variable Structure Backstepping Control via a Hierarchical Manifold Set for Graceful Ground Vehicle Path Following[C]// 2013 IEEE International Conference on Robotics and Automation (ICRA). Karlsruhe, Germany: IEEE, 2013.
- [3] 戚志锦, 杨志刚, 黄燕. 基于模糊PID的智能4WS车辆换道路径跟踪控制[J]. 汽车工程学报, 2012, 2(5): 379-384.
- [4] QI Z J, YANG Z G, HUANG Y. Intelligent 4WS Vehicle Lane Changing Path Tracking Control Based on Fuzzy PID[J]. Journal of Automotive Engineering, 2012, 2(5): 379-384.
- [5] 李欢欢, 刘辉, 盖江涛, 等. 基于粒子群优化算法PID参数优化的双电机耦合驱动履带车辆转向控制研究[J]. 兵工学报, 2023(2): 1-8.
- [6] LI H H, LIU H, GAI J T, et al. Research on Steering Control of Dual Motor Coupled Drive Tracked Vehicles Based on Particle Swarm Optimization Algorithm PID Parameter Optimization[J]. Journal of Ordnance Engineering, 2023(2): 1-8.
- [7] 刁勤晴, 张雅妮, 朱凌云. 双预瞄点智能车大曲率路径的横纵向模糊控制[J]. 中国机械工程, 2019, 30(12): 1445-1452.
- [8] DIAO Q Q, ZHANG Y, ZHU L Y. Horizontal and Vertical Fuzzy Control of High Curvature Path for Dual Preview Intelligent Vehicles[J]. China Mechanical Engineering, 2019, 30(12): 1445-1452.
- [9] 王红岩, 秦大同, 张伯英, 等. 无级变速汽车自动驾驶系统模糊控制策略[J]. 汽车工程, 2000(6): 397-402.
- [10] WANG H Y, QIN D T, ZHANG B Y, et al. Fuzzy Control Strategy of Continuously Variable Transmission Vehicle Auto Drive System[J]. Automotive Engineering, 2000(6): 397-402.
- [11] AMER N H, HAIRI Z, et al. Modelling and Control Strategies in Path Tracking Control for Autonomous Ground Vehicles: A Review of State of the Art and Challenges[J]. Journal of Intelligent and Robotic Systems, 2017, 86: 225-254.
- [12] MING T, DENG W, ZHANG S, et al. MPC-Based Trajectory Tracking Control for Intelligent Vehicles[C]// SAE 2016 World Congress and Exhibition. Detroit, USA: SAE, 2016.
- [13] 李春, 王少峰, 刘明春, 等. 基于多目标优化的自动驾驶车辆轨迹跟踪控制[J]. 汽车技术, 2022(4): 8-15.
- [14] LI C, WANG S F, LIU M C, et al. Autonomous Vehicle Trajectory Tracking Control Based on Multi-Objective Optimization[J]. Automotive Technology, 2022(4): 8-15.
- [15] WANG H Y, LIU B, PING X Y, et al. Path Tracking Control for Autonomous Vehicles Based on an Improved MPC[J]. IEEE Access, 2019, 7: 161064-161073.
- [16] SUN C, ZHANG X, ZHOU Q, et al. A Model Predictive Controller with Switched Tracking Error for Autonomous Vehicle Path Tracking[J]. IEEE Access, 2019, 7: 53103-53114.
- [17] YAO X L, WANG X W, WANG F. Path Following Based on Waypoints and Real-Time Obstacle Avoidance Control of an Autonomous Underwater Vehicle[J]. Sensors, 2020, 20(3): 795.
- [18] TIAN Y, YAO Q Q, HANG P, et al. Adaptive Coordinated Path Tracking Control Strategy for Autonomous Vehicles with Direct Yaw Moment Control[J]. Chinese Journal of Mechanical Engineering, 2022, 35(1): 234-248.
- [19] 姚文龙, 庞震, 池荣虎, 等. 环卫车辆轨迹跟踪系统的无

- 模型自适应迭代学习控制[J]. 控制理论与应用, 2022, 39(1): 101-108.
- YAO W L, PANG Z, CHI R H, et al. Model Free Adaptive Iterative Learning Control for Environmental Sanitation Vehicle Trajectory Tracking System[J]. Control Theory and Application, 2022, 39(1): 101-108.
- [15] WANG S, JIANG J, YU C J. Adaptive Backstepping Sliding Mode Control of Air-Breathing Hypersonic Vehicles[J]. International Journal of Aerospace Engineering, 2020.
- [16] ZHOU Q, WANG F Y, LI L. Robust Sliding Mode Control of 4WS Vehicles for Automatic Path Tracking[C]// IEEE Intelligent Vehicles Symposium. Las Vegas, NV, USA: IEEE, 2005.
- [17] TAGNE G, TALJ R, CHARARA A. Higher-Order Sliding Mode Control for Lateral Dynamics of Autonomous Vehicles, with Experimental Validation[J]. 2013 IEEE Intelligent Vehicles Symposium (IV). Gold Coast, QLD, Australia: IEEE, 2013.
- [18] LEONESSA A, VAN ZWIETEN T, MOREL Y. Neural Network Model Reference Adaptive Control of Marine Vehicles[M]// MENINI L, ZACCARIAN L, ABDALLAH C T. Current Trends in Nonlinear Systems and Control. Boston, MA, USA: Birkhäuser Boston, 2006: 421-440.
- [19] 张琨, 崔胜民, 王剑锋. 基于模糊神经网络的智能车辆循迹控制[J]. 汽车工程, 2015, 37(1): 38-42+77.
- ZHANG K, CUI S M, WANG J F. Intelligent Vehicle Tracking Control Based on Fuzzy Neural Network[J]. Automotive Engineering, 2015, 37(1): 38-42+77.
- [20] TANG L Q, YAN F W, ZOU B, et al. An Improved Kinematic Model Predictive Control for High-Speed Path Tracking of Autonomous Vehicles[J]. IEEE Access, 2020, 8: 51400-51413.
- [21] WANG H, FEI J T. Nonsingular Terminal Sliding Mode Control for Active Power Filter Using Recurrent Neural Network[J]. IEEE Access, 2018, 6: 67819-67829.
- [22] ROSSOMANDO F G, SORIA C, CARELLI R. Autonomous Mobile Robots Navigation Using RBF Neural Compensator [J]. Control Engineering Practice, 2011, 19(3): 215-222.
- (责任编辑 斛 畔)
- 修改稿收到日期为2023年10月13日。

《汽车文摘》征文

《汽车文摘》(月刊)于1963年7月3日创刊,由国有资产监督管理委员会主管、中国第一汽车集团有限公司主办,为中国汽车工程学会会刊。《汽车文摘》以“览全球汽车技术文献,指中国汽车技术之道”为使命,以打造“中国汽车前沿与创新技术传播与交流的重要平台”为愿景,致力于成为汽车领域最具影响力的综述类期刊。

目前,《汽车文摘》复合影响因子达1.187,并首次入选RCCSE中国核心学术期刊(A-),这反映出《汽车文摘》自2019年启动转型升级以来,期刊学术影响力稳步提升。

《汽车文摘》坚信“他山之石,可以攻玉”,深耕电动化、智能化、网联化、共享化和智能制造5大方向和10大领域,聚焦新能源与混合动力汽车、智能网联汽车、燃料电池、低碳与氢等零碳燃料、汽车安全、健康与舒适、碳达峰与碳中和、生命周期评价(LCA)与技术经济分析、智能制造、材料轻量化与一体化压铸、飞行汽车前沿与创新技术综述论文,揭示相关领域的新动态、新趋势、新技术和新进展,为广大科研和工程技术人员进一步发展这一领域提供新突破口、新出发点和新基准。

欢迎高等院校师生、研发工程技术人员、技术管理人员,充分发挥专业领域优势,深度挖掘国内外高影响力学术期刊与其他文献,形成某个技术领域的前沿综述。

《汽车文摘》选题范围:

电动化:混合动力关键技术;动力电池关键技术;先进充电技术;电驱动系统及电力电子技术;底盘及子系统线控关键技术;燃料电池动力系统设计与优化

智能化:新型电子电气架构;自动驾驶感知、决策与运动控制;智能新能源汽车测试评价方法与工具链;车辆智能安全技术

网联化:智能网联云控技术;车路通信及网络技术;车路协同技术;汽车人因、人机交互与智慧座舱;信息安全与功能安全;车网融合(V2G)及应用

低碳化:汽车节能与排放技术;清洁能源动力系统技术;碳达峰、碳中和;氢燃料制储运及安全管控技术;生命周期评价(LCA)、标准法规与技术经济分析;低碳与氢等零碳燃料

轻量化:新能源汽车新材料技术;混合材料轻量化设计;一体化压铸

共享化:区块链技术与移动出行;车辆大数据挖掘方法与应用案例

燃料电池:电池堆、电池系统与基础设施

智能制造:机器人与自动化控制、四大工艺、物流技术、设计-制造-服务

颠覆式出行:飞行汽车;未来低空智能交通体系及其关键技术

汽车安全:主被动安全与融合、智能安全、健康与舒适

《汽车文摘》发表论文的独特优势:

《汽车文摘》是国家级刊物、中国汽车工程学会的会刊、汽车领域唯一的综述期刊。《汽车文摘》不收版面费,4个月内即可发稿。

投稿要求:

- 综述篇幅在10 000~15 000字(6~10页),图文并茂,图、表和公式非原创要求引用;
- 请按科技论文要求撰写文章摘要,摘要中文字数在200±10字;
- 文章必须附有公开发表的、体现本领域最新研究成果的、高影响力出版物作为参考文献,一般要求参考文献在20篇以上,一半左右为外文参考文献,且在文中标注文献引用出处;
- 来稿保密审查工作由作者单位负责,确保署名无争议,文责自负;
- 切勿一稿多投。

《汽车文摘》投稿网址: <http://www.qcwz.cbpt.cnki.net>

邮箱: autodigest@faw.com.cn

《汽车文摘》编辑部