

doi: 10.19562/j.chinasae.qcgc.2024.07.007

基于学习的无人驾驶车辆模型预测路径跟踪控制研究*

韩陌¹, 何洪文¹, 石曼¹, 刘伟², 曹剑飞³, 吴京达⁴

(1. 北京理工大学, 高端汽车集成与控制全国重点实验室, 北京 100081; 2. 上海友道智途科技有限公司, 上海 200438;
3. 北京空间飞行器总体设计部, 北京 100094; 4. 香港理工大学, 香港 999077)

[摘要] 针对无人驾驶车辆路径跟踪控制问题中预测模型准确性与计算成本平衡制约问题, 本文提出了一种基于学习的模型预测(learning-based model predictive control, LB-MPC)路径跟踪控制策略。建立了车辆2自由度单轨动力学模型, 深入分析了其与IPG TruckMaker模型单步响应误差随车速、踏板开度及前轮转向角的变化规律, 设计了误差数据集构建和滚动更新方法, 基于高斯过程回归(Gaussian process regression, GPR)建立了误差拟合模型, 对标称单轨模型进行实时误差补偿修正。将误差修正模型作为预测模型, 设计了路径跟踪代价函数, 构建了二次规划优化问题, 提出了一种基于学习的模型预测路径跟踪控制架构。基于IPG TruckMaker & Simulink联合仿真平台与实车平台, 验证了所提GPR模型误差修正与LB-MPC路径跟踪控制策略的实时性与有效性。结果表明, 相较于传统模型预测(model predictive control, MPC)路径跟踪控制策略, 所提LB-MPC策略路径跟踪平均误差降低了23.64%。

关键词: 路径跟踪; 车辆模型误差分析; 高斯过程回归; 模型预测控制

Research on Learning-Based Model Predictive Path Tracking Control for Autonomous Vehicles

Han Mo¹, He Hongwen¹, Shi Man¹, Liu Wei², Cao Jianfei³ & Wu Jingda⁴

1. Beijing Institute of Technology, National Key Laboratory of Advanced Vehicle Integration and Control, Beijing 100081;
2. UTOPILOT, Shanghai 200438; 3. Beijing Institute of Spacecraft System Engineering, Beijing 100094;
4. The Hong Kong Polytechnic University, Hong Kong 999077

[Abstract] For the trade-off between prediction model accuracy and computational cost for path tracking control of autonomous vehicles, a learning-based model predictive control (LB-MPC) path tracking control strategy is proposed in this paper. A two-degree-of-freedom single-track vehicle dynamic model is established, and an in-depth analysis is conducted on its step response error with respect to variation in vehicle speed, pedal position, and front wheel steering angle compared to the IPG TruckMaker model. Methods for constructing error datasets and receding horizon updates are designed, and the Gaussian process regression (GPR) is employed to establish an error-fitting model for real-time error compensation and correction of the nominal single-track model. The error correction model is utilized as the prediction model, and a path tracking cost function is designed to formulate a quadratic programming optimization problem, proposing a learning-based model predictive path tracking control architecture. Through joint simulation using the IPG TruckMaker & Simulink platform and real vehicle experiments, the real-time performance and effectiveness of the proposed GPR error correction model and LB-MPC path tracking control strategy are verified. The results show that compared to the traditional model predictive control (MPC) path tracking control strategy, the proposed LB-MPC strategy reduces the average path tracking error by 23.64%.

Keywords: path tracking; vehicle model error analysis; Gaussian process regression; model predictive control

* 国家自然科学基金(52172377)资助。

原稿收到日期为2024年02月07日, 修改稿收到日期为2024年03月22日。

通信作者: 何洪文, 教授, 博士生导师, E-mail: hwhebit@bit.edu.cn。

前言

随着计算机运算能力和传感器技术的进步,基于高精度模型的无人驾驶车辆技术迅速发展,并在乘用车及商用车领域取得了长足的进步^[1]。高精度路径跟踪控制是无人驾驶车辆的关键技术问题之一^[2]。基于模型的路径跟踪控制策略因其具备处理非线性系统含约束优化问题而受到广泛应用^[3-5]。然而,基于模型的控制算法受到模型精度与算法实时性的平衡制约,且车辆在实际行驶过程中不可避免出现参数变化、测量噪声干扰等问题,严重影响无人驾驶车辆路径跟踪的准确性,威胁车辆及乘员的安全^[6-7]。因此,基于模型预测框架,提升预测模型精度、根据车辆实际行驶状态实时调整预测模型响应特性,成为无人驾驶车辆发展的关键技术^[8-10]。

基于学习的无人驾驶车辆控制算法相较于传统的基于规则、优化的方法,能够应对更加复杂、实时变化的驾驶场景^[10]。该类算法主要包括基于人类驾驶员行为数据的驾驶行为端到端学习,和针对预测模型精度提升或参数调节的学习等方面^[11]。麻省理工学院 Chong 等提出一种基于规则的神经网络模型,模拟跟踪过程和安全检测两种情况下的驾驶员行为,从车辆轨迹数据中获取驾驶员驾驶规则,基于机器学习训练神经网络模拟驾驶员行为^[12]。加州大学伯克利分校的 Lefevre 等提出了从人类示意中学习的自动驾驶框架进行车辆纵向控制,并通过在线和离线两种方式模拟驾驶员的操纵行为^[13]。南洋理工大学 Wu 等提出一种基于不确定性感知模型的强化学习方法,并通过仿真验证了所提算法的学习效率和执行性能^[14]。

上述端到端的无人驾驶控制算法较大程度上受制于计算平台的算力成本,因而更多学者面向参数调节与模型精度提升开展基于学习的模型预测(learning-based model predictive control, LB-MPC)无人驾驶控制研究。南洋理工大学的 Ji 等提出一种针对车辆驾驶极限工况的、基于人工神经网络(artificial neural network, ANN)横向控制方法,将基于李亚普诺夫稳定性理论的自适应控制机制与径向基神经网络(radial basis function neural network, RBFNN)相结合,设计了用于估计轮胎转弯刚度不确定性的 ANN 逼近器,通过学习近似非线性函数降

低非线性的不利影响^[15]。多伦多大学 Ostafew 等基于通用的先验车辆模型,提出了一种用于自主移动机器人的基于学习的非线性模型预测(learning-based model predictive control, LB-NMPC)算法以减少路径跟踪误差^[16]。同济大学 Wang 等提出了一种基于强化学习的自学习算法来提取动态交通场景的特征,对场景的风险等级进行分类,从而调整模型预测控制器的权重系数,提升路径跟踪控制的场景适应性^[17]。西班牙加泰罗尼亚政治大学 Alcalá 等提出了一种 Takagi-Sugeno(TS)模糊表示方法,通过学习输入-输出数据来替代预测模型,避免了模型预测控制(model predictive control, MPC)对预测模型建模以及参数辨识的挑战,使用 1:10 遥控模型车验证了所提方法的有效性^[18]。

高斯过程回归(Gaussian process regression, GPR)能够仅依赖很少的先验过程知识,直接提供模型残差不确定性的度量^[19]。因而,在基于模型的预测控制策略中,GPR具备应用于学习周期性时变扰动,从而提升控制性能的潜力^[20]。苏黎世联邦理工学院的 Kabzan 等提出了一种基于学习的模型预测控制算法,应用 GPR 对车辆 2 自由度动力学模型进行误差拟合,并将其作为预测模型实现智能驾驶赛车纵横向耦合控制^[21]。帕多瓦大学的 Picotti 等提出了一个面向三轮车辆的 LB-NMPC 控制器,基于 GPR 获得加速度的连续黑盒模型,并在真实卡丁车上进行了实车实验验证^[22]。慕尼黑工业大学的 Liu 等提出了一种 LB-MPC 路径跟踪控制策略,应用 GPR 对运动学模型进行误差补偿,考虑避障作为约束条件,并通过仿真验证了直线行驶工况下所提算法的有效性,但在弯道工况的效果仍不够理想^[23]。

综上,基于神经网络的端到端无人驾驶算法对车载控制器的计算能力提出了较高要求,而现有面向模型的预测控制算法也尚未实现乘用车实车实时应用,且鲜有对车辆模型响应特性的深入分析,并依据误差发展变化规律设计训练集。为解决上述问题,进一步提升路径跟踪控制精度,本文提出了一种 LB-MPC 路径跟踪控制策略。首先,深入分析车辆 2 自由度单轨动力学模型响应误差特性,设计了满足实时运算需求的训练数据集构建方法;其次,建立基于 GPR 的误差拟合模型,考虑防侧翻防侧滑约束设计代价函数;最后,在 MPC 框架下实现随车辆实际行驶状态实时修正模型响应误差的高精度实时路径跟踪控制,完成仿真与实车实验验证。

1 车辆动力学模型

1.1 非线性单轨模型

基于以下假设建立车辆2自由度单轨模型:车辆近似看作一个刚体,忽略车辆的侧倾和悬架系统的影响、轮胎非线性特性等。考虑横向、横摆运动的车辆2自由度单轨模型能够表征车辆纵横向耦合特性。车辆单轨模型以方形盘转角为控制量,以车辆横向车速、横摆角速度为状态量及输出量,同时认为车辆在车辆坐标系 x 轴方向匀速行驶。如图1所示,以车辆质心 O 为参考点,在车辆坐标系下,描述后轴驱动车辆横向及横摆运动的2自由度非线性动力学模型表示为




图1 车辆单轨模型示意图

$$\begin{cases} m(\dot{v}_y + v_x \omega) = F_{yf} \cos \delta_f + F_{yr} \\ I_z \dot{\omega} = aF_{yf} \cos \delta_f - bF_{yr} \\ \dot{X} = v_x \cos \theta - v_y \sin \theta \\ \dot{Y} = v_x \sin \theta + v_y \cos \theta \\ \dot{\theta} = \omega \end{cases} \quad (1)$$

式中: m 为车辆满载质量,kg; v_x, v_y 分别为车辆坐标系下质心处纵向、横向车速,m/s; ω 为车辆横摆角速度,rad/s; F_i 为轮胎受到来自地面的力,下标 $i = yf, yr$ 分别表示前轮侧向、后轮侧向,N; δ_f 为前轮转向角,rad; I_z 为车辆绕车辆坐标系 z 轴的转动惯量,kg·m²; a, b 为分别车辆质心到前、后轴的距离,m; X, Y 分别为大地坐标系下车辆的横、纵位置坐标,m; θ 为大地坐标系下车辆的航向角,(°)。采用线性轮胎模型,侧向轮胎力表示为

$$F_{yf} = k_y \alpha_f \quad (2)$$

$$F_{yr} = k_y \alpha_r \quad (3)$$

式中: k_y 为轮胎侧偏刚度,N/rad; α_f, α_r 分别为前、后轴轮胎侧偏角,rad。轮胎侧偏角表示为

$$\alpha_f = \arctan\left(\frac{v_y + a\omega}{v_x}\right) - \delta_f \approx \frac{v_y + a\omega}{v_x} - \delta_f \quad (4)$$

$$\alpha_r = \arctan\left(\frac{v_y - b\omega}{v_x}\right) \approx \frac{v_y - b\omega}{v_x} \quad (5)$$

1.2 单轨模型线性化与离散化

为应用于真实车辆控制,须将非线性2自由度单轨模型作线性化、离散化处理。在该模型中,纵向车速 v_x 在一个控制周期内视为常量。将非线性车辆单轨模型表示为状态空间方程,状态量及控制量定义见表1。

表1 仿真及实车车辆参数

状态量含义	变量符号	变量表示	单位
横向车速	v_y	x_1	m/s
横摆角速度	ω	x_2	rad/s
大地坐标系横坐标位置	X	x_3	m
大地坐标系纵坐标位置	Y	x_4	m
大地坐标系航向角	θ	x_5	rad
控制量含义	变量符号	变量表示	单位
前轮转向角	δ_f	u	rad

将式(1)中的变量用状态量和控制量表示,得到2自由度单轨模型的非线性连续状态空间表达式:

$$\begin{cases} \dot{x}_1 = f_1(\mathbf{x}, u) = \frac{1}{m}(F_{yf} \cos u + F_{yr}) - v_x x_2 \\ \dot{x}_2 = f_2(\mathbf{x}, u) = \frac{1}{I_z}(aF_{yf} \cos u - bF_{yr}) \\ \dot{x}_3 = f_3(\mathbf{x}, u) = v_x \cos x_5 - x_1 \sin x_5 \\ \dot{x}_4 = f_4(\mathbf{x}, u) = v_x \sin x_5 + x_1 \cos x_5 \\ \dot{x}_5 = f_5(\mathbf{x}, u) = x_5 \end{cases} \quad (6)$$

其中:

$$F_{yf} = k_y \left(\frac{x_1 + ax_2}{v_x} - u \right) \quad (7)$$

$$F_{yr} = \frac{k_y(x_1 - bx_2)}{v_x} \quad (8)$$

采用泰勒级数线性化方法,忽略高次项,得到车辆单轨线性动力学模型:

$$\dot{\mathbf{x}} = \left(\frac{\partial \mathbf{f}}{\partial \mathbf{x}} \Big|_{\mathbf{x}_0, u_0} \right) \mathbf{x} + \left(\frac{\partial \mathbf{f}}{\partial u} \Big|_{\mathbf{x}_0, u_0} \right) u + \mathbf{f}_0 \quad (9)$$

其中:

$$\mathbf{f}_0 = \mathbf{f}(\mathbf{x}_0, u_0) - \left(\frac{\partial \mathbf{f}}{\partial \mathbf{x}} \Big|_{\mathbf{x}_0, u_0} \right) \mathbf{x}_0 - \left(\frac{\partial \mathbf{f}}{\partial u} \Big|_{\mathbf{x}_0, u_0} \right) u_0 \quad (10)$$

$$\left(\frac{\partial \mathbf{f}}{\partial \mathbf{x}} \Big|_{\mathbf{x}_0, u_0} \right)_{i,j} = \frac{\partial f_i}{\partial x_j} \Big|_{\mathbf{x}_0, u_0} \quad (11)$$

$$\left(\frac{\partial \mathbf{f}}{\partial u} \Big|_{\mathbf{x}_0, u_0} \right)_i = \frac{\partial f_i}{\partial u} \Big|_{\mathbf{x}_0, u_0} \quad (12)$$

采用前向欧拉法将线性化模型进行离散化,在 k 时刻, $\mathbf{x}_0 = \mathbf{x}(k), u_0 = u(k-1)$,则 k 时刻车辆单轨模型的准线性离散状态空间表达式为

$$\mathbf{x}(k+1) = \mathbf{A}(k)\mathbf{x}(k) + \mathbf{B}(k)u(k) + \Delta T\mathbf{f}_0 \quad (13)$$

其中:

$$\mathbf{A}(k) = \mathbf{I} + \Delta T \left. \frac{\partial \mathbf{f}}{\partial \mathbf{x}} \right|_{\mathbf{x}(k), u(k)} \quad (14)$$

$$\mathbf{B}(k) = \Delta T \left. \frac{\partial \mathbf{f}}{\partial u} \right|_{\mathbf{x}(k), u(k)} \quad (15)$$

2 模型误差分析与补偿

2自由度单轨动力学模型相比于考虑纵向、横向、横摆运动的2自由度动力学模型,其在纵向运动上认为纵向车速在每个控制周期内保持不变,因此存在纵横耦合误差。在对上述单轨模型进行线性化和离散化过程中,又分别产生了来自泰勒级数的高阶误差及前向欧拉近似离散化方法的截断误差。此外,相比于真实车辆,单轨模型设定了诸多简化条件,其本身存在模型误差。上述模型误差直接导致基于模型的路径跟踪控制精度降低。本节视IPG TruckMaker模型近似真实车辆响应,分析单轨模型与TruckMaker模型的响应误差,并基于GPR实现误差拟合。

2.1 单轨模型误差分析

受到噪声、外界干扰与建模误差等不确定性因素的影响,1.1节建立的单轨模型与实际车辆动力学之间存在着较大预测误差。这些误差主要来源于以下两个方面:

(1)非线性轮胎模型经线性化后所导致的偏差。轮胎的滑移效应和侧向力特性会随着车速的增加变得更加显著,这可能导致车辆单轨模型的准确性下降。

(2)因部分参数难以精确测量所导致的偏差。难以精确测量的参数包括转动惯量、轮胎侧偏刚度、质心位置、路面附着系数,当车辆运动状态发生变化时,上述参数会随之改变,进而导致更大的偏差。

在单轨模型误差分析中,在每个采样周期,令单轨模型与IPG TruckMaker车辆模型的初始状态量相同,即采用IPG惯性导航传感器反馈状态量作为单轨模型在该控制周期的状态量。仿真道路为水平的干燥水泥混凝土或沥青路面,车辆前轮转角限幅为 $\pm 36^\circ$,仿真步长0.001 s。车辆防侧翻防侧滑约束下,不同车速下的安全转向角约束如图2所示。




图2 不同车速下防侧翻、侧滑转向角约束

图3所示为纵向车速 $v_x = 3 \text{ m/s}$ 工况下,前轮转角 δ_f 分别为 $5^\circ \sim 35^\circ$ 时单轨模型的横向车速、横摆角速度的单步响应误差箱线图。可见,相同纵向车速下,随着前轮转角增大,车辆单轨模型的横向车速单步响应误差近似指数增加。横摆角速度单步响应误差在小角度转向时维持在较低水平;随着转向角继续增大,轮胎侧偏角进入轮胎非线性区域,横摆角速度单步误差继而大幅增加。




图3 纵向车速为3 m/s时单轨模型单步响应误差随前轮转角的变化情况

为更加全面地呈现单轨模型单步响应误差随车速和前轮转角的变化情况,选取图2中星号工况点进行模型单步误差采样,图4为横向车速误差Map图,图5为横摆角速度误差Map图。可见:在相同前轮转角输入下,单轨模型横摆角速度单步误差绝对值随纵向车速增加而增大;在相同纵向车速工况下,横摆角速度单步误差绝对值在小角度转向时变化较小,当前轮转角超过 15° 时,横摆角速度单步误差随转向角增大而显著增加。

2.2 基于GPR的单轨模型误差补偿

上述2自由度单轨模型对真实车辆系统进行了较大程度简化。为了逼近车辆系统的真实响应,建立实时更新的车辆单轨模型与实际车辆或IPG




图4 单轨模型横向车速单步响应误差 Map 图




图5 单轨模型横摆角速度单步响应误差 Map 图

TruckMaker中的车辆模型的单步响应误差数据集,将线性离散单轨模型(式(13))记为标称系统,引入待学习的误差项 $d(z_k)$ 和过程噪声项 w_k ,基于标称系统构建误差补偿模型。采用GPR对误差的概率分布进行实时拟合,其用误差项的均值和方差表征:

$$\mathbf{x}_{k+1} = \mathbf{f}(\mathbf{x}_k, \mathbf{u}_k) + \mathbf{B}_d(d(z_k) + \mathbf{w}_k) \quad (16)$$

式中: \mathbf{f} 表示标称车辆模型; d 表示引入的待学习模型。车辆单轨动力学模型见式(13),在GPR问题中表示为

$$\hat{\mathbf{x}}_{k+1} = \mathbf{f}(\mathbf{x}_k, \mathbf{u}_k) \quad (17)$$

如图6所示构建GPR实时训练数据集 \mathcal{D} :训练输入变量 \mathbf{Z} ,包括车辆当前时刻控制量(前轮转向角)、实车或IPG传感器反馈运动状态(纵向车速、横向车速、横摆角速度);训练输出变量 \mathbf{E} ,相同控制量作用下,在一个控制周期过后车辆单轨模型与车辆真实响应的状态量误差(横向车速单步误差、横摆角速度单步误差)。

假设待学习模型与过程噪声部分仅影响与车辆横向运动状态对应的 \mathbf{B}_d 所覆盖的子空间,并依赖于从 $\mathbf{x}_k, \mathbf{u}_k$ 中提取的与回归相关的一组输入变量 z_k 。基于2.1节的单轨模型误差分析结果,对横向车速、横摆角速度两个状态量进行误差学习及补偿校正,

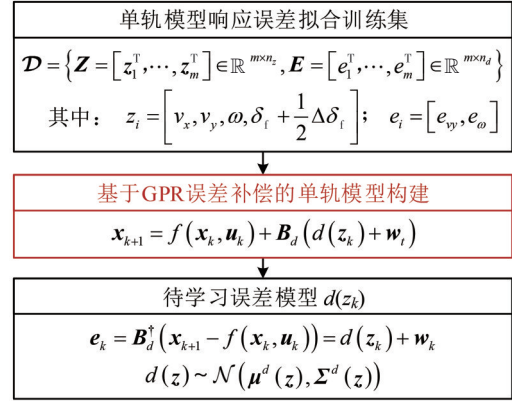


图6 GPR训练数据集构成

设定:

$$\mathbf{B}_d = \begin{pmatrix} 1 & & & & \\ & 1 & & & \\ & & 0 & & \\ & & & 0 & \\ & & & & 0 \end{pmatrix} \quad (18)$$

为了降低学习问题的维数,进一步通过选择回归输入变量来假设模型误差与车辆的位置坐标、航向角无关,仅与纵横向车速、横摆角速度相关:

$$\mathbf{z} = \left[v_x, v_y, \omega, \delta_i + \frac{1}{2} \Delta \delta_i \right] \quad (19)$$

式中,修正前轮转向角命令来解释输入控制量的动态变化,即用控制量在两个相邻控制周期内的均值来表示该周期内的实际控制量。训练数据 \mathbf{e}_k 由真实车辆或TruckMaker中车辆的惯性导航传感器测量值 \mathbf{x}_{k+1} 与标称模型预测值之间的差值生成:

$$\mathbf{e}_k = \mathbf{B}_d^\dagger(\mathbf{x}_{k+1} - \mathbf{f}(\mathbf{x}_k, \mathbf{u}_k)) = d(z_k) + \mathbf{w}_k \quad (20)$$

式中 \mathbf{B}_d^\dagger 为Moore-Penrose广义逆矩阵。给定训练数据集,采用径向基核函数,由GPR可得随机估计:

$$d(z_k) \sim \mathcal{N}(\boldsymbol{\mu}^d(z_k), \boldsymbol{\Sigma}^d(z_k)) \quad (21)$$

GPR的一个重要步骤是在核函数公式中选择超参数。由于文中假设模型误差的一般特征在车辆运行期间保持不变,因此使用基于历史数据的最大似然优化来确定运行前一周的超参数和噪声水平,并在行驶过程中对其进行实时修正。

3 LB-MPC路径跟踪控制

第2节基于GPR对标称单轨模型进行了误差拟合修正,本节将上述误差修正单轨模型与预测模型、滚动优化和反馈校正的传统MPC框架融合,将GPR误差修正模型用作MPC路径跟踪控制策略的预测

模型,提出LB-MPC路径跟踪控制策略架构,通过提升预测模型精度实现路径跟踪精度提升。

3.1 LB-MPC路径跟踪控制架构

融合GPR模型误差拟合修正与MPC控制框架的LB-MPC路径跟踪控制策略架构如图7所示。不同于传统MPC采用固定参数的时变预测模型,基于标称单轨模型与GPR误差拟合修正的预测模型能够基于实时更新的误差数据集实时完成模型响应修正,从而适应车辆实际行驶中的模型参数变化及道路工况变化^[24]。在 k 时刻,选取当前时刻前 N 个采样周期的标称模型与真实车辆单步响应误差作为当前 k 时刻的训练数据集 $\mathcal{D}(k) = \{\mathbf{Z}(k), \mathbf{E}(k)\}$, $\mathbf{Z}(k) \in \mathbb{R}^{4 \times N}$, $\mathbf{E}(k) \in \mathbb{R}^{2 \times N}$,其中 $\mathbf{Z}(k)$ 表示 N 个采样周期内的训练输入集合,包括车辆纵横向车速、横摆角速度、历史前轮转向角指令; $\mathbf{E}(k)$ 表示 N 个采样周期内的标称模型单步响应误差集合,包括车辆纵向车速与横摆角速度。该训练集跟随运行时刻滚动更新。采用GPR对当前 k 时刻的车辆误差数据集进行学习,对标称模型误差补偿修正,根据模型的残差不确定性和过程噪声求出随机分布,并在时间上向前传播。

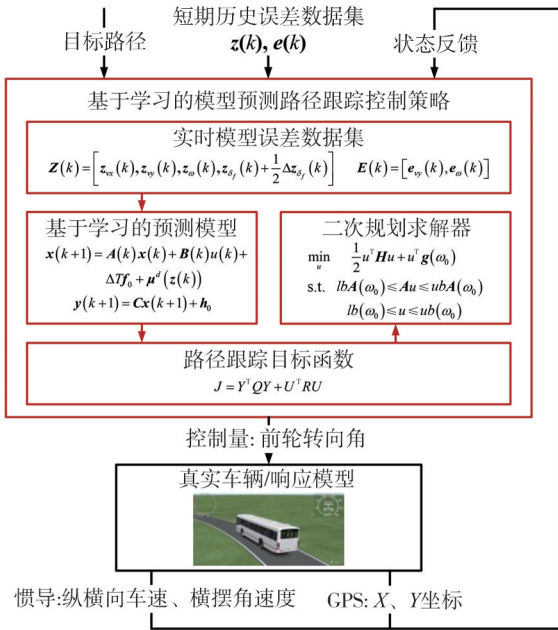


图7 LB-MPC路径跟踪控制架构

如图7所示,路径跟踪控制策略的输入为车辆状态反馈变量 $v_x(k)$, $v_y(k)$, $\omega(k)$ 、短期历史误差数据集和目标路径 \mathbf{Y}_{ref} ;LB-MPC路径跟踪控制策略以提升车辆路径跟踪精度为目标设计代价函数,构造二次规划优化问题,实时优化求解当前 k 时刻前轮

转向角指令。

3.2 基于GPR误差修正的单轨预测模型

以1.2小节中推导的线性离散单轨模型作为标称模型式(式(13)),采用GPR对其单步响应误差的概率分布进行拟合,得到基于学习的预测模型(式(16))。为减轻控制策略计算成本,采用误差概率分布的均值作为标称模型的加性误差补偿量。由车辆运动几何关系,LB-MPC路径跟踪控制策略的预测模型表示为

$$\begin{cases} \mathbf{x}(k+1) = \mathbf{A}(k)\mathbf{x}(k) + \mathbf{B}(k)u(k) + \\ \quad \Delta T \mathbf{f}_0 + \boldsymbol{\mu}^a(\mathbf{z}(k)) \\ \mathbf{y}(k+1) = \mathbf{C}(k)\mathbf{x}(k) + \mathbf{h}_0 \end{cases} \quad (22)$$

其中,输出方程的输出矩阵形同矩阵 \mathbf{B}_j ,常数项 \mathbf{h}_0 的推导与 \mathbf{f}_0 相同。第 $a \in \{1, 2\}$ 维预测误差输出的均值 $\boldsymbol{\mu}^a(\mathbf{z}(k))$ 如下式计算:

$$\boldsymbol{\mu}^a(\mathbf{z}) = \mathbf{k}_{z,z}^a (\mathbf{K}_{z,z}^a + \mathbf{I}\sigma_a^2)^{-1} [\mathbf{E}]_{:,a} \quad (23)$$

式中: $[\mathbf{E}]_{:,a}$ 表示输出量 \mathbf{E} 的第 a 列; $\mathbf{K}_{z,z}^a$ 、 $\mathbf{k}_{z,z}^a$ 、 $\mathbf{k}_{z,z}^a$ 分别是相关向量的核函数结果,分别为

$$[\mathbf{K}_{z,z}^a]_{i,j} = k^a(\mathbf{z}_i, \mathbf{z}_j) \quad (24)$$

$$\mathbf{k}_{z,z}^a = (\mathbf{k}_{z,z}^a)^T \in \mathbb{R}^4 \quad (25)$$

$$[\mathbf{k}_{z,z}^a]_j = k^a(\mathbf{z}_j, \mathbf{z}) \in \mathbb{R} \quad (26)$$

核函数为径向基核函数,超参数 \mathbf{L}^a 为正定的对角长度尺度矩阵,用于将不同输入变量进行归一化,超参数 $\sigma_{r,a}$ 为信号方差:

$$k^a(\mathbf{z}_j, \mathbf{z}) = \sigma_{r,a}^2 \exp\left(-(\mathbf{z}_j - \mathbf{z})^T \mathbf{L}^a (\mathbf{z}_j - \mathbf{z})\right) \quad (27)$$

3.3 LB-MPC路径跟踪代价函数

考虑路径跟随精度与乘坐舒适性,设计LB-MPC路径跟踪控制策略的代价函数。跟踪精度体现为GPR误差修正模型的预测车辆位移与目标路径在大地坐标系下的横纵坐标的差的平方和最小;舒适性体现为前轮转向角控制量的绝对值尽量取最小,即以最小幅度的转向实现路径跟踪误差最小。代价函数具体推导为:在 k 时刻时,LB-MPC预测时域为从 k 时刻开始向后 N_p 个控制周期;定义目标函数为路径跟踪误差和控制变量绝对值的组合。

$$\mathbf{J} = \mathbf{Y}^T \mathbf{Q} \mathbf{Y} + \mathbf{U}^T \mathbf{R} \mathbf{U} \quad (28)$$

式中 \mathbf{Q} 和 \mathbf{R} 矩阵为自定义权重矩阵,用于描述MPC不同预测步长处的代价函数权重,以及路径跟踪精度与控制量之间的权重。本文中, \mathbf{Q} 和 \mathbf{R} 矩阵分别定义为

$$\mathbf{Q} = a\mathbf{I}; \mathbf{R} = b\mathbf{I} \quad (29)$$

式中: I 为单位矩阵;本文中,令系数 $a = 10, b = 1$ 。式(28)中,描述车辆路径跟踪精度的向量 Y 与待求解控制量序列 U 表示为

$$Y = Y - Y_{\text{ref}} = \begin{pmatrix} y(k+1) - y_{\text{ref}}(k+1) \\ y(k+2) - y_{\text{ref}}(k+2) \\ y(k+3) - y_{\text{ref}}(k+3) \\ \dots \\ y(k+N_p) - y_{\text{ref}}(k+N_p) \end{pmatrix} \quad (30)$$

$$U(k) = \begin{pmatrix} u(k) \\ u(k+1) \\ u(k+2) \\ \dots \\ u(k+N_p-1) \end{pmatrix} \quad (31)$$

优化问题的约束条件由转向系统机械特性和车辆行驶安全性决定。转向盘转向角限值为 $[-800^\circ, 800^\circ]$,其在相邻控制周期内的变化率不超过 30° ,则对应的前轮转角限值和相邻控制周期变化量限值均可以通过转向系统传动比计算获得。在任意车速工况下,根据车辆防侧翻防侧滑安全约束,前轮转向角限值是附着系数、纵向车速的函数,可依据图2查表获得。

3.4 二次规划问题求解

3.3小节中,设计了考虑路径跟踪精度与乘坐舒适性的LB-MPC路径跟踪问题代价函数(式(28))。为便于实现该代价函数的实时求解,将其表示为二次规划形式,使用一种在线有效集策略qpOASES实时求解二次规划问题^[25]。有效集法是求解带不等式约束的二次规划问题的经典算法之一,其特点是迭代点循着约束边界进行快速寻优。有效集法的基本思路是在每次迭代中,将原不等式约束二次规划问题转换成更容易求得的等式约束问题。该有效集策略的最优有效集在相邻二次规划之间不会有太大的变化,因车辆的状态量和控制量在相邻控制周期内不会出现大幅变化,因而qpOASES适合用于基于MPC的无人驾驶车辆路径跟踪控制问题。在本文LB-MPC路径跟踪控制问题中,GPR对于预测模型的修正采用预测均值加性补偿的方式进行,因而仍可利用qpOASES工具包求解描述为二次规划问题的路径跟踪控制问题:

$$\begin{cases} \min_u & \frac{1}{2} U^T H U + U^T g \\ \text{s. t.} & l_{\min} \leq A U \leq l_{\max} \\ & L_{\min} \leq U \leq L_{\max} \end{cases} \quad (32)$$

式中: U 为待求解控制量,即预测时域内第 k 时刻至 N_p-1 时刻的前轮转向角; $l_{\min}, l_{\max}, L_{\min}, L_{\max} \in \mathbb{R}^n$, A 为线

性约束矩阵。

$$l_{\min} = \begin{pmatrix} \delta_{f\min} \\ \delta_{f\min} \\ \vdots \\ \delta_{f\min} \end{pmatrix}; l_{\max} = \begin{pmatrix} \delta_{f\max} \\ \delta_{f\max} \\ \vdots \\ \delta_{f\max} \end{pmatrix} \quad (33)$$

$$L_{\min} = \begin{pmatrix} \Delta\delta_{f\min} + u(k-1) \\ \Delta\delta_{f\min} \\ \vdots \\ \Delta\delta_{f\min} \end{pmatrix} \quad (34)$$

$$L_{\max} = \begin{pmatrix} \Delta\delta_{f\max} + u(k-1) \\ \Delta\delta_{f\max} \\ \vdots \\ \Delta\delta_{f\max} \end{pmatrix}$$

$$A = \begin{pmatrix} 1 & 0 & 0 & 0 \\ -1 & 1 & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & -1 & 1 \end{pmatrix} \quad (35)$$

式中: $\delta_{f\min}$ 和 $\delta_{f\max}$ 分别表示前轮转向角的最小和最大限值,rad; $\Delta\delta_{f\min}$ 和 $\Delta\delta_{f\max}$ 分别表示前轮转向角在一个控制周期内的最大变化量限值,rad。海森矩阵 H 为时变矩阵:

$$H = 2(G^T Q G + R), g = 2G^T Q(K - Y_{\text{ref}}) \quad (36)$$

$$G = \begin{pmatrix} CB & 0 & \dots & 0 \\ CAB & CB & \dots & 0 \\ CA^2 B & CAB & \ddots & 0 \\ \vdots & \vdots & \vdots & \vdots \\ CA^{N_p-1} B & CA^{N_p-2} B & \dots & CB \end{pmatrix} \quad (37)$$

$$K = \begin{pmatrix} CA \\ CA^2 \\ \vdots \\ CA^{N_p} \end{pmatrix} x(k) + T \begin{pmatrix} C \\ C + CA \\ \vdots \\ C + CA + \dots + CA^{N_p} \end{pmatrix} f_0 + \begin{pmatrix} h_0 \\ h_0 \\ \vdots \\ h_0 \end{pmatrix} + \begin{pmatrix} C \\ C + CA \\ \vdots \\ C + CA + \dots + CA^{N_p} \end{pmatrix} \mu^d(z(k)) \quad (38)$$

式中 $Y_{\text{ref}} \in \mathbb{R}^{N_p \times 2}$ 为目标路径在预测时域内的横、纵坐标构成的矩阵。矩阵 G, K 、式(37)和式(38)中的矩阵 A, B, C 均为时变矩阵。

4 仿真与实车实验验证

4.1 仿真与实车验证平台

为验证所提GPR模型误差修正算法以及基于GPR误差修正预测模型的LB-MPC路径跟踪控制策略,基于IPG TruckMaker & Simulink搭建联合仿真

平台、搭建无人驾驶车辆实车测试平台,实车控制器采用工控机。仿真测试中,采样周期为1 ms,实车采样周期为10 ms;GPR训练数据集更新周期与MPC控制周期相同,即为50 ms;GPR运行周期为100 ms。仿真及实车实验平台示意图如图8所示。仿真及实车车辆参数见表2。

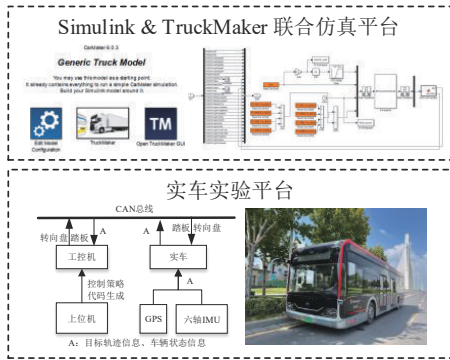


图8 仿真平台与实车实验平台

表2 仿真及实车车辆参数

参数	数值	参数	数值
整备质量/kg	10 850	迎风面积/m ²	6.375
满载质量/kg	16 500	转向系统传动比	22.15
风阻系数	0.4	轮胎滚阻系数	0.009 8
车辆长度/m	10.5	轮距/m	2.078
转向盘转角限值/(°)	±800	轮胎侧偏刚度/(N·rad ⁻¹)	252 670
车轮滚动半径/m	0.5	z轴转动惯量/(kg·m ²)	12 800

在相同控制量输入下,对比标称单轨模型(式(13))与GPR修正模型(式(16))、IPG TruckMaker车辆模型的响应差异,验证所提GPR误差拟合方法的性能。在无人驾驶客车实验平台应用LB-MPC路径跟踪控制策略,在实车实验中实时下载目标路径作为策略的输入,由惯性导航传感器实时获取车辆位姿信息,包括纵横向车速、横摆角速度;由GPS实时采集车辆在大地坐标系下的X、Y位移、航向角。

4.2 单轨模型GPR误差补偿仿真验证

第2节建立了基于2自由度单轨模型的GPR误差拟合修正模型,本节对误差修正模型的准确性进行仿真验证。比较IPG TruckMaker模型、标称单轨模型与误差补偿模型在相同控制量输入下的状态响应,选取图2中纵横向耦合工况进行验证。以目标车速为5 m/s,前轮转角由0°增大至5°的纵侧向耦合工况为例进行分析。每一控制周期中,令输入TruckMaker与标称单轨模型的前轮转角控制量相等。训练集维度为10,即选取当前时刻前10个采样

周期的模型响应误差数据训练高斯过程误差模型 $d(z_k)$ 。预测集维度为1,即预测当前时刻的车辆状态。踏板开度及转向盘转角如图9所示。






图9 纵横向耦合工况下的控制量输入

相同前轮转角控制量输入下,TruckMaker模型、标称单轨模型与GPR误差修正模型的响应结果如图10所示。以TruckMaker模型的响应结果为实际响应,在恒定车速下,标称单轨模型响应误差随着前轮转向角的增大出现明显误差。而采用GPR误差拟合修正后的单轨模型能够逼近TruckMaker模型的响应结果。

GPR拟合的误差模型响应结果如图11所示,阴影区域为 2σ 置信区间。本节中,用于表征实车特性



(a) 横向车速




(b) 横摆角速度

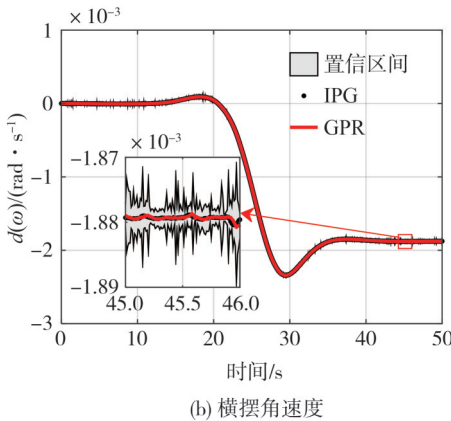
图10 纵横向耦合工况3种模型的状态量响应

的IPG TruckMaker模型的传感器测量噪声协方差较小,因此误差模型的响应数据分布也较为密集。可见,均值和残差不确定性与模型误差吻合较好。

在仿真验证中,基于i7-7700HQ CPU 2.8 GHz测试平台,GPR在每个运行周期内的计算时长如图12所示。可见,在仿真平台硬件条件下,GPR计算时长远低于运行周期100 ms,则所提LB-MPC路径跟踪控制策略完全能够满足计算实时性需求。



(a) 横向车速



(b) 横摆角速度

图11 纵横向耦合工况单轨模型GPR误差修正




图12 仿真验证中GPR在单步运行周期内的计算时长

为量化GPR误差拟合修正模型的性能,表3比较了车速5 m/s、前轮转角为5°工况下标称单轨模型

与误差补偿模型状态量的最大误差、平均误差与均方误差。可见,GPR误差拟合修正模型的横向车速最大误差为标称单轨模型误差的5.89%,平均误差为标称单轨模型的1.80%。可见,模型响应误差基本消除。图2中标记的其余工况具有类似结果,高斯回归模型均表现良好。

表3 标称单轨模型与GPR误差修正模型对比

变量	模型	最大误差/ ($\text{m}\cdot\text{s}^{-1}$)	平均误差/ ($\text{m}\cdot\text{s}^{-1}$)	标准误差/ ($\text{m}\cdot\text{s}^{-1}$)
Δv_y	误差补偿模型	8.96×10^{-6}	1.25×10^{-6}	2.73×10^{-6}
	标称单轨模型	6.18×10^{-3}	3.05×10^{-3}	4.17×10^{-3}
$\Delta\omega$	误差补偿模型	4.27×10^{-6}	5.94×10^{-7}	1.19×10^{-6}
	标称单轨模型	2.34×10^{-3}	1.09×10^{-3}	1.43×10^{-3}

4.3 LB-MPC 路径跟踪控制策略实车验证

为了验证所提LB-MPC路径跟踪控制策略的有效性和实时性,在某封闭测试路段进行了实车测试实验,测试路段坐标如图13所示,车辆纵向车速为定速15 km/h。




图13 封闭测试道路坐标

选取直角转弯路段进行实验验证。在实车实验中,高斯过程回归的计算时长为80 ms。车辆实际跟踪行驶路径与参考路径如图14所示,黑色实线表示参考路径,蓝色点划线表示基于标称单轨模型的MPC路径跟踪路径,红色虚线表示所提LB-MPC路径跟踪路径。尽管给定目标轨迹存在不连续点,车辆实际跟随控制考虑乘坐舒适性,跟踪路径均较为平滑。基于所提LB-MPC策略,车辆能够准确跟踪目标路径,而传统基于标称单轨模型的MPC策略跟踪路径在转弯过程中出现较大跟踪误差。

路径跟随过程中横向位移误差如图15所示。




图14 参考路径与跟踪路径对比

所提LB-MPC路径跟踪控制策略能够显著降低路径跟随误差。在由直角转弯进入直道阶段,传统MPC策略跟踪误差达到峰值,而所提LB-MPC策略能够快速跟随目标路径。值得注意的是,对于LB-MPC策略,较大的误差波动均出现在目标路径不规则处,其余部分的跟踪误差不超过20 cm。




图15 直角转弯道路路径跟踪误差对比

直角转弯道路路径跟随过程中转向盘转角指令如图16所示。随着目标轨迹从直线段进入转弯阶段,目标轨迹的曲率变化率提升,路径跟踪控制器输出的转向盘转角随之增大。在转向盘转角达到峰值前后,两种策略表现出超过20 cm的跟踪误差,其余




图16 转向盘转角指令对比

曲率变化较为平缓的路段,所提LB-MPC策略的跟踪误差保持在20 cm以内。

在实车实验中,两种路径跟踪控制策略直角转

弯路段测试结果见表4。可见,在直角转弯过程中,在满足策略实时性的前提下,相比于传统MPC路径跟踪控制策略,所提LB-MPC路径跟踪控制策略的平均跟踪误差降低了23.64%。

表4 路径跟踪策略实车实验跟踪误差对比

路径跟踪策略	平均误差/m	最大误差/m	起始误差/m	误差均方根	控制量均方根
MPC	0.101 4	0.629 2	0.171 4	0.153 9	0.015 0
LB-MPC	0.132 8	1.278 8	0.146 3	0.230 5	0.012 3

5 结论

为提升无人驾驶车辆路径跟踪控制的准确性与乘坐舒适性,本文提出了一种基于学习的模型预测控制策略。主要研究内容如下:(1)建立了车辆2自由度单轨动力学模型,并深入分析了单轨模型与IPG TruckMaker车辆模型的单步响应误差随车速、踏板开度与前轮转向角的变化特性。(2)基于误差分布规律,设计了用于GPR在线学习的误差数据集构建和更新方法,利用径向基核函数实时预测标称单轨模型的响应误差分布,建立了基于GPR的横向及横摆运动响应误差拟合修正模型。(3)将基于GPR修正的单轨模型作为预测模型,设计了考虑跟踪精度与乘坐舒适性的路径跟踪控制代价函数,构建了便于实时优化求解的二次规划优化问题,提出了一种基于学习的模型预测路径跟踪控制架构。

为验证所提GPR模型误差补偿方法与基于GPR模型修正的LB-MPC路径跟踪控制策略的实时性与有效性,搭建了IPG TruckMaker & Simulink联合仿真平台与无人驾驶客车实车验证平台并进行了仿真及实车实验验证。结果表明:在车速5 m/s,前轮转角为5°工况下,误差补偿模型的纵侧向车速最大误差为车辆单轨模型误差的5.89%,平均误差为单轨模型的1.80%。在直角转弯过程中,相比于传统MPC路径跟踪控制策略,所提LB-MPC路径跟踪控制策略的平均跟踪误差降低了23.64%。

参考文献

[1] 国务院. 国务院关于印发“十四五”现代综合交通运输体系发展规划的通知[R]. 中华人民共和国国务院公报, 2022(4): 8-28.
The State Council. Notice of the state council on issuing the development plan for modern comprehensive transportation system during the 14th Five Year Plan Period[R]. The Bulletin of the State

- Council of the People's Republic of China, 2022(4): 8–28.
- [2] 方培俊, 蔡英凤, 陈龙, 等. 基于车辆动力学混合模型的智能汽车轨迹跟踪控制方法[J]. 汽车工程, 2022, 44(10): 1469–1483, 1510.
- FANG P, CAI Y, CHEN L, et al. Trajectory tracking control method based on vehicle dynamics hybrid model for intelligent vehicle[J]. *Automotive Engineering*, 2022, 44(10): 1469–1483, 1510.
- [3] 陈慧岩, 陈舒平, 龚建伟. 智能汽车横向控制方法研究综述[J]. 兵工学报, 2017, 38(6): 1203–1214.
- CHEN H, CHEN S, GONG J. A review on the research of lateral control for intelligent vehicles[J]. *Acta Armamentarii*, 2017, 38(6): 1203–1214.
- [4] 陈慧岩, 熊光明, 龚建伟. 无人驾驶汽车概论[M]. 北京: 北京理工大学出版社, 2014.
- CHEN H, XIONG G, GONG J. Introduction to self-driving car [M]. Beijing: Beijing Institute of Technology Press, 2014.
- [5] 龚建伟, 龚乘, 林云龙, 等. 智能车辆规划与控制策略学习方法综述[J]. 北京理工大学学报, 2022, 42(7): 665–674.
- GONG J, GONG S, LIN Y, et al. Review on machine learning methods for motion planning and control policy of intelligent vehicles[J]. *Transactions of Beijing Institute of Technology*, 2022, 42(7): 665–674.
- [6] MAYNE D Q. Model predictive control: recent developments and future promise[J]. *Automatica*, 2014, 50(12): 2967–2986.
- [7] VEGAMOOR V K, DARBHA S, RAJAGOPAL K R. A review of automatic vehicle following systems[J]. *Journal of the Indian Institute of Science*, 2019, 99(4): 567–587.
- [8] AMER N H, ZAMZURI H, HUDHA K, 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 & Robotic Systems*, 2017, 86(2): 225–254.
- [9] 熊璐, 杨兴, 卓桂荣, 等. 无人驾驶车辆的运动控制发展现状综述[J]. 机械工程学报, 2020, 56(10): 127–143.
- XIONG L, YANG X, ZHUO G, et al. Review on motion control of autonomous vehicles [J]. *Journal of Mechanical Engineering*, 2020, 56(10): 127–143.
- [10] ZHANG K, WANG J, XIN X, et al. A survey on learning-based model predictive control: toward path tracking control of mobile platforms[J]. *Applied Sciences*, 2022, 12(4): 1995.
- [11] JI J, KHAJEPOUR A, MELEK W W, et al. Path planning and tracking for vehicle collision avoidance based on model predictive control with multiconstraints[J]. *IEEE Transactions on Vehicular Technology*, 2017, 66(2): 952–964.
- [12] CHONG L, ABBAS M M, MEDINA FLINTSCH A, et al. A rule-based neural network approach to model driver naturalistic behavior in traffic[J]. *Transportation Research Part C: Emerging Technologies*, 2013, 32: 207–223.
- [13] LEFEVRE S, CARVALHO A, BORRELLI F. A learning-based framework for velocity control in autonomous driving [J]. *IEEE Transactions on Automation Science and Engineering*, 2016, 13(1): 32–42.
- [14] WU J, HUANG Z, LV C. Uncertainty-aware model-based reinforcement learning: methodology and application in autonomous driving [J]. *IEEE Transactions on Intelligent Vehicles*, 2023, 8(1): 194–203.
- [15] JI X, HE X, LV C, et al. Adaptive-neural-network-based robust lateral motion control for autonomous vehicle at driving limits [J]. *Control Engineering Practice*, 2018, 76: 41–53.
- [16] OSTAFEW C J, SCHOELLIG A P, BARFOOT T D. Robust constrained learning-based NMPC enabling reliable mobile robot path tracking [J]. *The International Journal of Robotics Research*, 2016, 35(13): 1547–1563.
- [17] WANG L, YANG S, YUAN K, et al. A combined reinforcement learning and model predictive control for car-following maneuver of autonomous vehicles [J]. *Chinese Journal of Mechanical Engineering*, 2023, 36(1): 80.
- [18] ALCALÁ E, BESSA I, PUIG V, et al. MPC using an on-line TS fuzzy learning approach with application to autonomous driving [J]. *Applied Soft Computing*, 2022, 130: 109698.
- [19] HEWING L, KABZAN J, ZEILINGER M N. Cautious model predictive control using gaussian process regression [J]. *IEEE Transactions on Control Systems Technology*, 2020, 28(6): 2736–2743.
- [20] OSTAFEW C J, SCHOELLIG A P, BARFOOT T D, et al. Learning-based nonlinear model predictive control to improve vision-based mobile robot path tracking [J]. *Journal of Field Robotics*, 2016, 33(1): 133–152.
- [21] KABZAN J, HEWING L, LINIGER A, et al. Learning-based model predictive control for autonomous racing [J]. *IEEE Robotics and Automation Letters*, 2019, 4(4): 3363–3370.
- [22] PICOTTI E, MION E, LIBERA A D, et al. A learning-based nonlinear model predictive controller for a real go-kart based on black-box dynamics modeling through gaussian processes [J]. *IEEE Transactions on Control Systems Technology*, 2023, 31(5): 2055–2065.
- [23] LIU W, LIU C, CHEN G, et al. Gaussian process based model predictive control for overtaking in autonomous driving [J]. *Frontiers in Neurorobotics*, 2021, 15: 723049.
- [24] HAN M, HE H, CAO J, et al. MPC-based lateral control algorithm for bus path following control [R]. Volume 9: Sustainable Energy Solutions for Changing the World: Part I, 2021.
- [25] HE H, HAN M, LIU W, et al. MPC-based longitudinal control strategy considering energy consumption for a dual-motor electric vehicle [J]. *Energy*, 2022, 253: 124004.