

文章编号:1671-1637(2026)04-0303-16

基于动态卡尔曼多项式网络的自动驾驶车辆 轨迹跟踪控制技术

蔡英凤^{*1}, 章宇航¹, 孙晓强¹, 张晓东², 王海³, 陈龙¹

(1. 江苏大学汽车工程研究院, 江苏镇江 212013; 2. 吉利汽车研究院(宁波)有限公司, 浙江宁波 315336;
3. 江苏大学汽车与交通工程学院, 江苏镇江 212013)

摘要:为实现复杂动力学场景下自动驾驶车辆高可靠性和高精度轨迹跟踪控制,提出一种基于动态卡尔曼多项式网络的预测控制框架,该控制框架通过利用时间序列记忆能力来捕捉车辆的动态特性,融合卡尔曼滤波的自适应调整,实现对实时控制误差的优化校正;借助多项式网络的非线性特征扩展,进一步提升系统的建模能力;该方法集动态感知、误差修正与非线性建模于一体,显著增强系统对车辆动力学变化的适应性与精度。此外,还引用基于横向偏差和航向偏差的反馈控制器,旨在与预测模块协同工作,从而实现更加精确的路径跟踪误差校正。CarSim与Simulink联合仿真验证表明:预测-反馈控制器在低附路面和高速紧急换道极限工况下展现出明显的优势,其中高速紧急换道工况下与ILQR和NMPC控制器相比,路径跟踪的横向偏差均方根值分别减少了32.5%和38.4%;航向偏差的均方根值则分别减少了37.8%和40.0%。所提方法可为自动驾驶系统中高精度、高可靠性的轨迹跟踪控制提供一种创新且有效的解决方案。

关键词:汽车工程;车辆动力学控制;多项式网络拟合;卡尔曼滤波;自动驾驶;轨迹跟踪;误差实时校正

中图分类号:U461.1 文献标志码:A DOI:10.19818/j.cnki.1671-1637.2026.021

Trajectory tracking control technology for autonomous vehicles based on dynamic Kalman polynomial networks

CAI Ying-feng^{*1}, ZHANG Yu-hang¹, SUN Xiao-qiang¹, ZHANG Xiao-dong²,
WANG Hai³, CHEN Long¹

(1. Automotive Engineering Research Institute, Jiangsu University, Zhenjiang 212013, Jiangsu, China;
2. Geely Automobile Research Institute (Ningbo) Co., Ltd., Ningbo 315336, Zhejiang, China;
3. School of Automotive and Traffic Engineering, Jiangsu University, Zhenjiang 212013, Jiangsu, China)

Abstract: To achieve high-reliability and high-precision trajectory tracking control for autonomous vehicles in complex dynamic scenarios, a predictive control framework based on a dynamic Kalman polynomial network was proposed. The dynamic characteristics of vehicles were captured by utilizing time-series memory capabilities, and the adaptive adjustment of Kalman filter was integrated to achieve the optimal correction of real-time control errors. By utilizing the nonlinear

出版历程:2025-02-14 收稿,2025-07-13 修回,2025-08-25 录用

基金项目:国家自然科学基金项目(52225212,52272418,U22A20100);国家重点研发计划(2022YFB2503302)

* 作者简介:蔡英凤(1985-),女,江苏如皋人,教授,博士生导师,工学博士,E-mail:caicaixiao0304@126.com

引用格式:蔡英凤,章宇航,孙晓强,等.基于动态卡尔曼多项式网络的自动驾驶车辆轨迹跟踪控制技术[J].交通运输工程学报,2026,26(4):303-318.

Citation:CAI Ying-feng, ZHANG Yu-hang, SUN Xiao-qiang, et al. Trajectory tracking control technology for autonomous vehicles based on dynamic Kalman polynomial networks[J]. Journal of Traffic and Transportation Engineering, 2026, 26(4): 303-318.

feature extension of polynomial networks, the modeling capability of the system was further enhanced. Dynamic perception, error correction, and nonlinear modeling were integrated into the method, significantly enhancing the adaptability and precision of the system to vehicle dynamics variations. Furthermore, a feedback controller based on lateral and heading deviations was incorporated to work synergistically with the predictive module, thereby achieving more accurate path tracking error correction. The co-simulation verification of CarSim and Simulink shows that the predictive-feedback controller exhibits obvious advantages under extreme conditions of low-adhesion surfaces and high-speed emergency lane changes. Specifically, under the condition of high-speed emergency lane changes, compared with ILQR and NMPC controllers, the root mean square value of the lateral deviation of path tracking is reduced by 32.5% and 38.4%, respectively; the root mean square value of heading deviation is reduced by 37.8% and 40.0%, respectively. The proposed method can provide an innovative and effective solution for the high-precision and high-reliability trajectory tracking control in autonomous driving systems.

Keywords: automotive engineering; vehicle dynamics control; polynomial network fitting; Kalman filtering; autonomous driving; trajectory tracking; real-time error correction

Publication history: Received 2025-02-14; Received in revised form 2025-07-13; Accepted 2025-08-25

Funding: National Natural Science Foundation of China (52225212, 52272418, U22A20100); National Key R&D Program of China (2022YFB2503302)

* **Corresponding author:** CAI Ying-feng, professor, PhD, E-mail: caicaixiao0304@126.com.

0 引 言

自动驾驶汽车(Autonomous Vehicles, AV)作为替代传统人类驾驶的创新方案,展现出巨大的潜力,能够颠覆人类出行方式,并彻底改变道路交通格局^[1-3]。具体来说,自动驾驶包括环境感知^[4-5]、决策规划^[6-7]、控制执行^[8-10]3个主要技术领域,控制执行模块负责控制目标车辆遵循规划的轨迹轮廓,这是自动驾驶汽车最重要和最困难的功能之一,尤其在高速行驶、大曲率转弯、低道路附着系数等复杂工况下表现尤为突出。诚然,在高速公路等常规理想工况下,常见乘用车的小曲率循迹与车道保持等轨迹跟踪控制技术已相对成熟。这些技术已在高级驾驶辅助系统(Advanced Driver Assistance System, ADAS)中广泛商业化,展现出较高的控制精度与稳定性。然而,当车辆面临极限动态驾驶场景(如低附着路面行驶、高速紧急避障等)时,情况则远为复杂。此时,车辆动力学呈现强非线性、参数时变、轮胎力趋于饱和等特性,对控制系统的鲁棒性、自适应性和快速响应能力均提出了远超常规工况的严苛要求。

传统的轨迹跟踪控制方法在低中速、曲率变化平缓、高道路附着系数条件下已被广泛应用:纯追踪控制方法^[11-12]由于其模型简洁、原理直观、计算负担轻,在低速和高附着力的路面条件下能够提供较好

的跟踪性能,但其转向运动学模型过于理想化,难以完全反映实际情况。比例-积分-微分控制(Proportional-integral-derivative Control, PID)具有简单的结构、易于调节的参数以及较强的鲁棒性,然而它仅适用于单输入单输出的线性时变系统,对于复杂的多输入多输出或非线性时变系统,PID的控制效果往往难以满足要求^[13-14]。线性二次型调节控制(Linear Quadratic Regulator, LQR)通过基于精确模型的目标函数来优化控制策略,其控制效果依赖于模型的准确性,因此在处理高度非线性和时变的车辆系统时会遇到一定的限制。尤其是在面对高速或低附着系数的复杂场景时,LQR难以有效处理动态参数的约束,导致在这些条件下的轨迹跟踪鲁棒性较差^[15-16]。

模型预测控制(Model Predictive Control, MPC)近年来得到了广泛应用。MPC能够依据线性或非线性动态模型进行多目标优化,并处理约束问题,同时展现出强大的鲁棒性^[17-18]。然而MPC的控制效果高度依赖于精确车辆模型,在克服不确定性、非线性方面尚未得到深入研究,此外,MPC还需消耗大量计算资源,这对实时控制提出了挑战。近年来,针对高速、高曲率等复杂工况传统车辆动力学模型失配的问题,高品质车辆轨迹跟踪研究越来越成为众多学者研究的重点,Shi等^[19]针对商用车

底盘在恶劣、复杂工况和多种未知扰动下控制效果差的情况,设计了一种耦合自抗扰控制器,以提高紧急避障中路径跟踪的鲁棒性。Hang等^[20]利用 μ 综合方法设计了路径跟踪控制器,考虑了四轮独立驱动/四轮独立转向(Four-wheel Independent Drive/Steering, 4WID/4WIS)模型参数的不确定性和未建模动力学,并验证了集成底盘控制算法的鲁棒性能。随着深度学习的快速发展,数据驱动建模已成为一种备受关注的技术路径。该方法能够直接从数据中学习系统的动态关系,尤其擅长处理复杂的非线性和时变问题。在车辆轨迹跟踪控制中,数据驱动建模不仅能以较低的成本构建模型,还具有较强的适应性,能够为自动驾驶车辆在各种环境下实现高精度和高鲁棒性的控制。Spielberg等^[21]在前馈-反馈控制架构中应用了神经网络车辆模型,实现了复杂驾驶环境中的轨迹跟踪精度和控制性能。Da等^[22]使用前馈神经网络来建模并优化车辆的纵向动力学,从而提高了模型的精度和实时控制能力。

尽管如此,目前基于数据驱动的方法依然面临着一些挑战。绝大多数研究都依赖于离线数据集进行训练,这些数据的采集与标注成本较高,尤其是在复杂路况和极端条件下,数据集可能无法覆盖所有潜在的场景。此外,离线训练的模型难以动态地适应车辆在实际运行过程中遇到的环境变化,比如路面摩擦因数的变化、轮胎性能的退化或者突发障碍物的出现,这使得模型的泛化能力受到限制,进而影响了轨迹跟踪的可靠性。为了应对这些挑战,在线学习方法应运而生。它能够在车辆运行过程中持续更新模型,实时地适应环境变化,从而提高系统的实时性和适应性。Beckers等^[23]针对车辆轨迹跟踪控制过程中存在的外部干扰、部分内部动态未知以及建模耗时等问题,提出了一种基于在线学习的轨迹控制律,用于欠驱动刚体动力学,并使用一个预测器来预测未知的动力学,所提出的方法保证了在高概率下具有有界的跟踪误差。然而高斯过程虽然在处理不确定性和非线性问题时表现出色,但其计算复杂度较高,这进而影响了系统的实时性和效率。近些年来,卡尔曼滤波在车辆状态估计和轨迹跟踪控制中得到了广泛应用,如无迹卡尔曼滤波^[24]、扩展卡尔曼滤波^[25]、自适应卡尔曼滤波^[26]等技术的应用均在一定程度上改善了滤波性能。然而,这些方法大多集中于单一滤波框架内对滤波器参数的自适应调整或扰动补偿,往往缺乏对系统非线性特征的充分捕捉以及对时间序列数据的深度挖掘。

为有效应对上述极限动态驾驶场景带来的挑战,本文提出了一种全新的动态卡尔曼多项式网络方法,该方法的核心优势在于其独特的结构与机制:①多项式网络的非线性特征扩展能力。通过构建输入状态和控制量的高次多项式组合,动态卡尔曼多项式网络能够比传统线性模型或简化的非线性模型更精确地逼近车辆在极限工况下(如轮胎力饱和、大侧偏角)的复杂非线性动态行为,这为其提供了强大的先验非线性建模基础。②卡尔曼滤波的动态自适应权重校正机制。这不仅用于传统的状态估计,更关键的是它在线、实时地调整多项式网络的内部权重参数,这使得整个预测模型能够快速适应如路面附着系数突变、轮胎特性变化等时变不确定性因素,这种由数据驱动的实时模型参数优化能力,是传统固定参数模型或主要依赖离线训练的模型难以企及的。通过这两者的有机结合,最终构建一种预测-反馈协同控制架构。在此架构中,多项式网络以其显式、透明的数学形式精确捕捉车辆的非线性动态,避免了传统神经网络的“黑盒”特性造成的不可解释性以及高斯过程进行大规模矩阵运算带来的计算负担;而卡尔曼滤波则以其计算高效、快速自适应的特点,不仅仅是处理系统噪声,更是主动地在线优化多项式网络的参数,赋予了整个动态卡尔曼多项式网络模型动态演化的能力。进一步地,协同控制架构中基于跟踪偏差的反馈控制增强了系统的鲁棒性与动态响应能力。这种集成了结构化非线性建模、在线参数自适应学习以及鲁棒反馈校正的协同设计,使得控制器能够在高速紧急变道、低附着路面等传统方法因模型失配或适应性不足而面临瓶颈的工况下,实现高品质的轨迹跟踪控制。

本文的主要贡献包括:①提出了一种将非线性建模与在线自适应校正深度结合的全新预测控制架构,结合了时间序列记忆特性、卡尔曼滤波的自适应优化机制以及非线性特征扩展的表达能力,充分发挥各方法的协同增益效应。②预测-反馈控制器的协同作用,使系统在保持预测控制高效性的同时,实现了在复杂极限动力学特性下更为精准和稳定的路径跟踪。所提出的控制方案不仅为车辆动态系统的建模与轨迹跟踪控制提供了全新的理论范式,同时为高维非线性系统的精准预测与鲁棒控制奠定了坚实基础,展现出广泛的学术前景和应用潜力。

1 车辆非线性动力学模型

本文考虑从横向和横摆2个自由度建立车辆动

力学模型,如图1所示,其中: G 为车辆的质心; l_f 和 l_r 分别为前后轴距。




图1 车辆动力学模型

Fig. 1 Vehicle dynamics model

根据力学分析和牛顿第二定律,可以得到车辆的横向速度变化率 \dot{v}_y 和横摆角速度变化率 $\dot{\omega}$ ^[27]分别为

$$\begin{cases} \dot{v}_y = \frac{1}{m} [F_{xf} \sin(\delta_f) + F_{yf} \cos(\delta_f) + F_{yr}] - v_x \omega \\ \dot{\omega} = \frac{1}{I_z} \{ [F_{xf} \sin(\delta_f) + F_{yf} \cos(\delta_f)] l_f - F_{yr} l_r \} \end{cases} \quad (1)$$

式中: m 为车辆质量; I_z 为车辆绕质心的转动惯量; v_x 和 v_y 分别为车辆的纵向速度和横向速度; δ_f 为前轮转角; ω 为横摆角速度; F_{xf} 、 F_{yf} 、 F_{xr} 、 F_{yr} 分别为前轮和后轮的纵向力以及横向力,这些力受到车辆轮胎特性、路面条件以及转向角的影响。

系统还存在高度的非线性特性和参数时变性,使得基于模型的控制策略难以适应复杂动态条件对路径跟踪性能的影响^[28-29]。为应对这一挑战,本文基于车辆的非线性映射关系 $\dot{\mathbf{X}} = f(\mathbf{X}, \mathbf{u})$ 构建车辆动力学模型。其中 \mathbf{X} 表示车辆系统的状态向量,包含了车辆横向速度 v_y 和横摆角速度 ω ,而 \mathbf{u} 则表示控制输入,即前轮转角 δ_f 。为了更好地描述这种非线性关系,本文引入了一种多项式网络来捕捉系统的动力学特性,通过学习车辆的历史数据,系统能够基于当前的状态和控制输入预测未来的车辆状态。多项式网络通过构造高次多项式来拟合系统输入和输出之间的关系,不同于传统的线性回归,其具有更强的非线性映射能力,能够更好地适应复杂的动态系统。多项式网络的结构可以表示为以下形式

$$\begin{cases} \hat{v}_{y,t+1} = \mathbf{W}_{vy}^T \boldsymbol{\phi}_t(\mathbf{X}_t, \mathbf{u}_t) \\ \hat{\omega}_{t+1} = \mathbf{W}_{\omega}^T \boldsymbol{\phi}_t(\mathbf{X}_t, \mathbf{u}_t) \end{cases} \quad (2)$$

式中: $\hat{v}_{y,t+1}$ 和 $\hat{\omega}_{t+1}$ 为对 $t+1$ 时刻车辆横向速度和横

摆角速度的预测值; \mathbf{X}_t 为 t 时刻的状态量; \mathbf{u}_t 为该时刻的转角输入;特征向量 $\boldsymbol{\phi}_t(\mathbf{X}_t, \mathbf{u}_t)$ 通过非线性函数从状态和输入中提取高维特征,用以刻画系统的非线性动态特性; \mathbf{W}_{vy} 和 \mathbf{W}_{ω} 分别为横向速度和横摆角速度的权重向量,通过在线学习过程逐步更新,以适应车辆的非线性动态行为。

权重向量 \mathbf{W}_{vy} 和 \mathbf{W}_{ω} 为该多项式网络的核心参数,它们通过在线学习过程不断自适应调整。

2 控制器设计

本文提出的整体控制框架包括基于动态卡尔曼多项式网络的预测控制器以及基于横向偏差与航向偏差的反馈控制器(图2),其中:动态卡尔曼多项式网络输入包含车辆当前预测状态(横向速度 $\hat{v}_{y,t}$ 、横摆角速度 $\hat{\omega}_t$),控制输入(前轮转角 $\delta_{f,t}$)及纵向车速 $v_{x,t}$ 组成的特征向量,输出则为对下一时刻车辆状态的预测结果 $\hat{v}_{y,t+1}$ 和 $\hat{\omega}_{t+1}$,最终基于 $t+1$ 时刻规划的横向速度 $v_{y,t+1}^p$ 、横摆角速度 ω_{t+1}^p 以及前轮转角物理限定条件进行最优控制输出预测转角 $\delta_{p,t+1}$,基于预测结果,控制器生成前馈转角指令,实现对车辆未来状态的前瞻性控制。同时本文引入了基于横向偏差和航向偏差的反馈机制,以实现路径跟踪误差的实时修正,具体来说,基于预瞄误差 e_{LA} 、车辆实时的航向角 Ψ 以及横向位置 y 生成反馈转角 $\delta_{fb,t+1}$ 。最终基于预测转角和反馈转角生成总的前轮转角 $\delta_{t,t+1}$ 实现对车辆的控制输入。下文将具体介绍动态卡尔曼多项式网络预测控制器和反馈控制器的设计。

2.1 基于动态卡尔曼多项式网络的预测控制器设计

多项式网络是一种基于特征组合的非线性建模方法,本文基于动态卡尔曼多项式网络的预测示意图如图3所示。动态卡尔曼多项式网络构建了包含车辆当前预测状态(横向速度 $\hat{v}_{y,t}$ 、横摆角速度 $\hat{\omega}_t$)、控制输入(前轮转角 $\delta_{f,t}$)及纵向车速 $v_{x,t}$ 的特征向量,随后经多项式组合映射为高维特征空间 $\boldsymbol{\epsilon}_t$ 。这种特征扩展机制能够有效表征车辆状态间复杂的交互与耦合作用,并凭借其强大的非线性拟合能力,在一定程度上学习和逼近由简化基础模型(如前述二自由度模型)所忽略的高阶动态或参数时变特性,从而近似模拟系统的非线性映射关系 $\mathbf{X}_{t+1} = f(\mathbf{X}_t, \mathbf{u}_t)$,因此多项式网络能够更好地表征高曲率路段、低附着系数等复杂工况下的车辆非线性行为,有效提升预测精度与建模适应性。

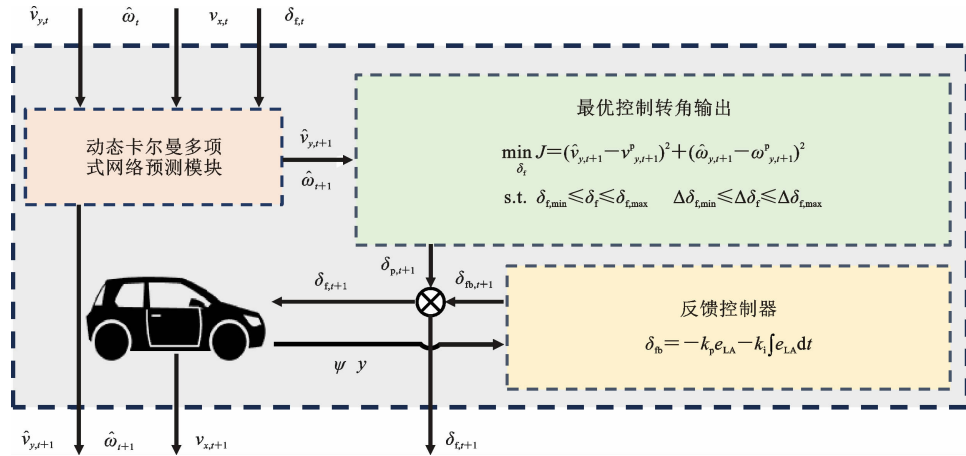


图 2 控制框架

Fig. 2 Control framework

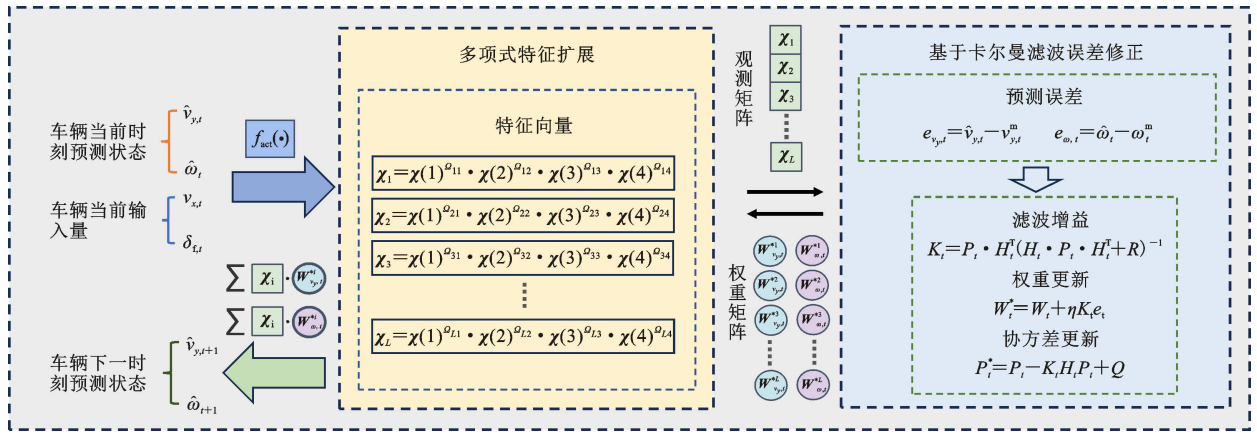


图 3 动态卡尔曼多项式网络预测模块

Fig. 3 Diagram of the dynamic Kalman polynomial network prediction module

在每个时间步,网络接收上一时刻对状态量的预测值 $\hat{v}_{y,t}$ 、 $\hat{\omega}_t$,当前时刻的纵向车速 $v_{x,t}$ 以及系统当前的控制输入 $\delta_{f,t}$,这些输入的特征量统一表示为 χ 并通过双曲正切激活函数进行归一化处理,以确保所有数据在统一的数值范围内,从而避免不稳定性 and 增强网络的收敛性。具体激活函数定义为^[30]

$$\begin{cases} f_{act}(\hat{v}_{y,t}) = \tanh(\hat{v}_{y,t}) \\ f_{act}(\hat{\omega}_t) = \tanh(\hat{\omega}_t) \\ f_{act}(v_{x,t}) = \tanh(v_{x,t}) \\ f_{act}(\delta_{f,t}) = \tanh(\delta_{f,t}) \end{cases} \quad (3)$$

这些特征可以稳定网络的输出,并增强系统对复杂动态关系的表达能力。在对输入变量进行激活后,通过构建矩阵 Ω 生成激活后输入变量的多项式组合,最终通过不同的指数组合来构造一个高维特征向量 ϵ_t 。具体来说,特征多项式 $\epsilon_{t,i}$ 表示 t 时刻第 i 个基函数,它是由激活后状态变量 $v_{x,t}$ 、 $\hat{v}_{y,t}$ 、 $\hat{\omega}_t$ 和前轮转角 $\delta_{f,t}$ 构成的多项式

$$\epsilon_{t,i} = [f_{act}(v_{x,t})]^{\Omega_{i,1}} \cdot [f_{act}(\hat{v}_{y,t})]^{\Omega_{i,2}} \cdot$$

$$[f_{act}(\hat{\omega}_t)]^{\Omega_{i,3}} \cdot [f_{act}(\delta_{f,t})]^{\Omega_{i,4}} \quad (4)$$

式中: $\Omega_{i,j}$ 为对应矩阵 Ω 的第 i 行第 j 列 ($j=1,2,3,4$),本研究将网络中的基函数数量设定为 15,即 $i \in \{1,2,3,\dots,15\}$,通过不同特征多项式的组合最终得到 t 时刻的特征向量 ϵ_t 。

值得注意的是,矩阵 Ω 的构造具有明确的组合依据,本文输入变量为 4 个激活变量: $f_{act}(v_{x,t})$ 、 $f_{act}(\hat{v}_{y,t})$ 、 $f_{act}(\hat{\omega}_t)$ 、 $f_{act}(\delta_{f,t})$,为了刻画其所有可能的非线性交互作用,考虑这 4 个变量是否参与组合(每个变量指数为 0 或 1),可构造 16 种组合,去除无动态意义的常数项(所有指数为 0),共形成 15 个具有实际动态意义的组合项,对应 15 个特征多项式基函数(即 15 层)。这种构造确保了输入特征空间的完备性,避免结构设计的随意性。 Ω 表示为

$$\Omega = \begin{bmatrix} 1 & 0 & 0 & 0 & 1 & 1 & 1 & 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 \\ 0 & 1 & 0 & 0 & 1 & 0 & 0 & 1 & 1 & 0 & 1 & 0 & 1 & 1 & 1 \\ 0 & 0 & 1 & 0 & 0 & 1 & 0 & 1 & 0 & 1 & 1 & 1 & 0 & 1 & 1 \\ 0 & 0 & 0 & 1 & 0 & 0 & 1 & 0 & 1 & 1 & 1 & 1 & 1 & 0 & 1 \end{bmatrix}^T \quad (5)$$

通过这样的特征扩展,网络可以更好地拟合复杂的车辆动力学模型,提升模型的精度和最终控制效果。在上面特征向量求解过程中,纵向车速 $v_{x,t}$ 也设置为特征量,虽然在本文研究对象为车辆的横向运动控制,而且纵向车速默认作为已知的外部输入,但是车辆的横向动力学通常与纵向速度密切相关,通过将纵向速度作为输入之一,它能帮助表征更复杂的耦合关系,从而做出更准确的预测和控制。

卡尔曼滤波的设计则将传感器观测值与模型预测值进行融合,通过更新预测协方差矩阵 \mathbf{P}_t 并结合测量噪声协方差 \mathbf{R} 来计算滤波增益 \mathbf{K}_t ,从而以最小均方误差准则优化状态估计。本文中卡尔曼滤波不仅作为状态估计器有效抑制传感器噪声和动态扰动,还作为多项式网络的调节器,引导模型权重更新向更优解收敛,体现了融合滤波与学习的协同优势。

系统的观测取横向速度和横摆角速度,使得车辆控制和路径跟踪可以专注于横向动态。通过特征向量的转置即 $\boldsymbol{\varepsilon}_t^T$ 来构建观测矩阵 $\mathbf{H}_{v_y,t}$ 和 $\mathbf{H}_{\omega,t}$,即

$$\mathbf{H}_{v_y,t} = \mathbf{H}_{\omega,t} = \boldsymbol{\varepsilon}_t^T \quad (6)$$

该方法能够有效降低计算复杂度,同时通过多项式扩展增加了系统的可观性和滤波效果。这种处理方式既符合卡尔曼滤波的线性观测假设,又增强了非线性表达能力,适用于该实时车辆状态估计。滤波增益是卡尔曼滤波的核心参数,用于平衡系统预测值与实际测量值之间的关系,从而对系统的状态估计进行优化。卡尔曼滤波器的更新步骤如下^[31-32]

$$\begin{cases} \mathbf{K}_{v_y,t} = \mathbf{P}_{v_y,t} \cdot \mathbf{H}_{v_y,t}^T (\mathbf{H}_{v_y,t} \cdot \mathbf{P}_{v_y,t} \cdot \mathbf{H}_{v_y,t}^T + \mathbf{R})^{-1} \\ \mathbf{K}_{\omega,t} = \mathbf{P}_{\omega,t} \cdot \mathbf{H}_{\omega,t}^T (\mathbf{H}_{\omega,t} \cdot \mathbf{P}_{\omega,t} \cdot \mathbf{H}_{\omega,t}^T + \mathbf{R})^{-1} \end{cases} \quad (7)$$

式中: $\mathbf{P}_{v_y,t}$ 和 $\mathbf{P}_{\omega,t}$ 分别为横向速度、横摆角速度的协方差矩阵; \mathbf{R} 为测量噪声协方差; $\mathbf{K}_{v_y,t}$ 和 $\mathbf{K}_{\omega,t}$ 为滤波增益。

滤波增益使得系统能够在测量噪声和过程不确定性下优化估计精度。下面通过构造估计误差 $e_{v_y,t}$ 和 $e_{\omega,t}$ 作为反馈信号,用于自适应调整系统网络的权重

$$\begin{cases} e_{v_y,t} = \hat{v}_{y,t} - v_{y,t}^m \\ e_{\omega,t} = \hat{\omega}_t - \omega_t^m \end{cases} \quad (8)$$

式中: $v_{y,t}^m$ 和 ω_t^m 分别为当前传感器得到的状态量测量值。

最后基于得到的估计误差 $e_{v_y,t}$ 、 $e_{\omega,t}$ 以及滤波增益 $\mathbf{K}_{v_y,t}$ 、 $\mathbf{K}_{\omega,t}$, 引入更新系数进行网络的权重更新

$$\begin{cases} \mathbf{W}_{v_y,t}^* = \mathbf{W}_{v_y,t} + \eta \mathbf{K}_{v_y,t} e_{v_y,t} \\ \mathbf{W}_{\omega,t}^* = \mathbf{W}_{\omega,t} + \eta \mathbf{K}_{\omega,t} e_{\omega,t} \end{cases} \quad (9)$$

式中: η 为更新系数,控制了每一步更新的幅度; $\mathbf{W}_{v_y,t}^*$ 和 $\mathbf{W}_{\omega,t}^*$ 分别为更新后的权重矩阵。

式(9)是动态卡尔曼多项式网络实现其自适应性的核心环节,滤波增益 $\mathbf{K}_{v_y,t}$ 和 $\mathbf{K}_{\omega,t}$ 决定了模型根据当前预测误差 $e_{v_y,t}$ 及 $e_{\omega,t}$ 对多项式网络权重 \mathbf{W} 的调整幅度。当车辆动态特性发生变化(例如驶入低附着路面)或存在未建模动态时,预测误差会增大,卡尔曼滤波机制会通过调整增益 \mathbf{K} 并驱动权重 \mathbf{W} 的更新,从而使多项式网络模型迅速适应新的动态特性。这种在线的、由数据驱动的权重调整能力,是本方法能够有效应对复杂和时变工况的关键所在,使其区别于权重固定或仅依赖离线训练的传统多项式回归或神经网络模型。与此同时,协方差递归更新也反映了系统对状态估计的不确定性逐步减少的过程,具体如式(10)所示

$$\begin{cases} \mathbf{P}_{v_y,t}^* = \mathbf{P}_{v_y,t} - \mathbf{K}_{v_y,t} \mathbf{H}_{v_y,t}^T \mathbf{P}_{v_y,t} + \mathbf{Q} \\ \mathbf{P}_{\omega,t}^* = \mathbf{P}_{\omega,t} - \mathbf{K}_{\omega,t} \mathbf{H}_{\omega,t}^T \mathbf{P}_{\omega,t} + \mathbf{Q} \end{cases} \quad (10)$$

式中: $\mathbf{P}_{v_y,t}^*$ 和 $\mathbf{P}_{\omega,t}^*$ 分别为更新后的横向速度、横摆角速度的协方差矩阵; \mathbf{Q} 为过程噪声协方差矩阵。

最终完成对系统状态量估计的更新

$$\begin{cases} \hat{v}_{y,t+1} = \mathbf{W}_{v_y,t}^* \boldsymbol{\varepsilon}_t \\ \hat{\omega}_{t+1} = \mathbf{W}_{\omega,t}^* \boldsymbol{\varepsilon}_t \end{cases} \quad (11)$$

值得注意的是,与传统滤波方法不同,本文进一步将滤波误差反馈引入多项式网络的参数更新过程中,网络权重 \mathbf{W} 依据估计误差进行自适应调整,实现了状态估计与模型训练的耦合优化。该机制使得模型不仅能够存在观测噪声时保持稳定输出,还能在面对外部扰动、路况突变等动态变化时自动调整建模策略,从而增强了系统的自适应能力与泛化能力。

在车辆动力学的轨迹跟踪控制中,系统的目标是确保车辆的状态能够尽可能接近预定的理想轨迹。为实现这一目标,本文定义了一个代价函数 J , 用于度量当前时刻的车辆状态预测值与目标状态之间的误差。通过最小化代价函数,可以找到最优的控制输入,从而使车辆在下一时刻尽可能接近目标轨迹。代价函数 J 构建如下

$$J = (\hat{v}_{y,t+1} - v_{y,t+1}^p)^2 + (\hat{\omega}_{t+1} - \omega_{t+1}^p)^2 \quad (12)$$

通过最小化 J , 利用内点法进行优化过程,获得预测控制量 $\delta_{p,t+1}$, 以使车辆状态尽可能逼近目标轨迹。同时为了进一步确保系统在真实行驶中的稳定性和安全性,求解过程中对控制量前轮转角进行限制,保证其在合理区间,即

$$\delta_{i,\min} \leq \delta_p \leq \delta_{i,\max} \quad (13)$$

式中: $\delta_{i,\min}$ 和 $\delta_{i,\max}$ 分别为系统允许的最小和最大前轮转角。

2.2 反馈控制器设计

预测控制器通过在线学习实时捕捉车辆的非线性动态特性,并利用车辆状态量的反馈信号生成稳态转角,该方法的优势在于能够适应复杂环境中的系统动态变化,并通过动态调整控制策略应对不同的驾驶条件。然而,仅依赖单一的预测控制器并不能在所有情境下保证车辆路径跟踪的精度和鲁棒性,预测控制器可能无法充分修正轨迹误差,导致控制性能下降。为此,引入一种基于横向偏差和航向偏差反馈的控制器,建立前瞻误差模型,之前已有学者证明该方法有效^[33],具体如图4所示,其中偏差 e_{LA} 的计算式为

$$e_{LA} = e + x_{LA} \Delta \Psi \quad (14)$$

式中: e 为车辆质心与参考路径的横向偏差; $\Delta \Psi$ 为车辆当前航向与参考航向的差值;预瞄距离 x_{LA} 反映了控制器对路径前方偏移趋势的预测能力。




图4 车辆预瞄误差模型

Fig. 4 Vehicle preview error model

为实现前瞻误差的快速衰减并消除可能存在的稳态跟踪误差,设计了基于横向偏差和航向偏差的比例-积分反馈控制器。其反馈控制律定义为

$$\delta_{fb,t+1} = -k_p e_{LA} - k_i \int e_{LA} dt \quad (15)$$

式中: k_p 和 k_i 分别为比例和积分调节参数。

最终,预测控制量 $\delta_{p,t+1}$ 作为前馈项,与 $\delta_{fb,t+1}$ 叠加,形成控制输入 $\delta_{i,t+1}$

$$\delta_{i,t+1} = \delta_{p,t+1} + \delta_{fb,t+1} \quad (16)$$

这种经典的前馈-反馈结构能够结合预测控制的前瞻性和反馈控制的实时纠错能力,其中反馈控

制器的积分作用旨在消除潜在的稳态跟踪误差,从而进一步提高系统的鲁棒性和跟踪精度。

3 试验仿真

为了评估本文所提出的预测-反馈控制器的轨迹跟踪实用性、有效性和可行性,本文进行了CarSim&Simulink联合仿真测试以及硬件在环(HIL)测试。仿真测试中CarSim的车辆参数规格如表1所示,车辆采用后轮驱动以及前轮转向模式,在3种不同的场景下进行了双车道变换操作的模拟。同时,为了更好地验证本文控制策略相对于传统控制策略的性能提升,选取2种在自动驾驶控制领域具有代表性且应用广泛的传统控制方法——非线性模型预测控制(Nonlinear Model Predictive Control, NMPC)与迭代线性二次调节控制(Iterative Linear Quadratic Regulator, ILQR)作为对比对象,设计并开展了多组典型驾驶工况下的仿真试验,以全面评估各控制方法在复杂动态环境中的实际控制效果与适应能力。预测-反馈控制器中的详细参数如表2所示。同时为了定量评价不同控制器轨迹跟踪控制效果,选取车辆实际横向输出与参考横向输出之间的最大误差 $e_{\max} = \max(Y - Y_{\text{ref}})$ 和误差均方根 $(\sum e^2/n)^{\frac{1}{2}}$ 进行评价,同时也计算了航向角实际值和参考值的最大误差以及误差均方根。

表1 车辆参数

Table 1 Vehicle parameters

参数	数值
车身质量 m/kg	1 525
前轴距 l_f/m	1.111
后轴距 l_r/m	1.756
车身转动惯量 $I_z/(\text{kg} \cdot \text{m}^2)$	2 315
轮胎滚动半径 r/m	0.325
轮距 b/m	1.55

表2 控制器参数

Table 2 Controller parameters

参数	数值
k_p	0.065
k_i	0.01
γ	0.05
R	0.1
Q	$0.01I_{15}$

3.1 仿真场景 I

在该仿真场景中,车辆以恒定 $60 \text{ km} \cdot \text{h}^{-1}$ 执行换道操作,道路附着系数 $\mu = 0.85$,各控制器在此工

况下的控制误差对比如表 3 所示,其中可以看出:在该高附仿真环境下,尽管本文提出的预测-反馈控制器在航向偏差的均方根误差方面略优于 NMPC,但在横向偏差方面却整体处于劣势,且其控制精度未能显著优于基线对比方法。图 5、6 分别展示了不同控制策略下的横向位移、航向角随时间变化的趋势,3 种控制器的动态响应曲线几乎重合,变化平稳,且均能在较短时间内完成换道任务。图 7 预测和反馈转角变化趋势上也很好地印证了这一点。此外,图 8~10 进一步反映了各控制器在控制输入下车身的稳定性的指标变化,包括横摆角速度、质心侧偏角、侧向加速度,可以看出车身稳定性控制效果均相差不多。在该高附换道场景下,由于轮胎具有良好的抓地性能,整个换道操纵过程中,车辆的侧向加速度和横摆角速度等关键动态参数均保持在较小范围内,表明车辆的整体动态响应相对平稳且易于预测。因此,各种控制策略均能取得较好的控制效果,本文提出的预测-反馈控制器中动态卡尔曼多项式网络的在线学习和非线性建模能力虽然持续运作,但相较于传统方法的优势在这种动态变化相对温和的工况下未能充分突显,其自适应学习和非线性建模的潜力在更为严苛的动态条件下将更为关键。

表 3 场景 I 控制目标误差

Table 3 Errors of control targets in case I

参数	方法	最大误差	均方根误差
横向偏差/m	ILQR 控制器	0.174 1	0.076 5
	NMPC 控制器	0.184 9	0.092 0
	预测-反馈控制器	0.192 6	0.095 7
航向偏差/rad	ILQR 控制器	0.026 1	0.012 6
	NMPC 控制器	0.029 2	0.015 4
	预测-反馈控制器	0.031 5	0.014 0

3.2 仿真场景 II

仿真场景 II 中,重点评估了不同控制策略在低附着力道路条件下的轨迹跟踪性能。该场景设定车辆以恒定车速 $60 \text{ km} \cdot \text{h}^{-1}$ 行驶,路面附着系数 $\mu = 0.45$,这种条件显著改变了轮胎力学特性,对依赖精确模型的传统控制器构成了严峻考验,有效增加了轨迹跟踪控制的复杂性与挑战性。横向位移与航向角随时间变化的动态响应结果如图 11、12 所示。可见:在曲率变化较大的弯道路段,本文提出的基于在线学习的预测-反馈控制策略相较于基线 ILQR 和 NMPC 算法展现出更优的跟踪性能。这一优势主要归因于动态卡尔曼多项式网络的在线学习和自适应能力。具体而言,当轮胎能够产生的有效侧向力




图 5 场景 I 横向位置对比

Fig. 5 Comparison of lateral positions in scenario I




图 6 场景 I 航向角对比

Fig. 6 Comparison of heading angles in scenario I




图 7 场景 I 预测反馈转角

Fig. 7 Predicted feedback steering angle in scenario I

减小,导致车辆对于相同的转向输入会产生更大的横向位移和横摆角速度变化时,多项式网络的在线学习机制能够实时捕捉这些动态变化。其网络模块




图 8 场景 I 横摆角速度对比

Fig. 8 Comparison of yaw rates in scenario I




图 9 场景 I 质心侧偏角对比

Fig. 9 Comparison of centroid side-slip angles in scenario I




图 10 场景 I 侧向加速度对比

Fig. 10 Comparison of lateral accelerations in scenario I

能够拟合轮胎在低附着条件下的非线性行为,而卡尔曼滤波模块则根据预测误差不断调整网络权重,从而更有效地适应因轮胎-路面交互变化而导致的




图 11 场景 II 横向位置对比

Fig. 11 Comparison of lateral positions in scenario II




图 12 场景 II 航向角对比

Fig. 12 Comparison of heading angles in scenario II

车辆非线性响应。传统基于固定或缓变模型参数的控制策略难以实时、准确地捕捉这种由于路面附着变化引起的车辆动态特性的剧烈改变。NMPC 虽具备一定预测能力,但其性能高度依赖预设模型精度及约束条件,在轮胎特性显著偏离标称状态时,其性能受到限制。动态卡尔曼多项式网络的这种自适应性使其能够更精确地预测和补偿控制误差,尤其是在横向加速度和横摆角速度波动较大的弯道路段。

预测转角 δ_p 与反馈转角 δ_f 动态变化如图 13 所示,其进一步验证了该策略的响应能力:动态卡尔曼多项式网络驱动预测模块能够合理、准确地预测道路曲率变化趋势,及时生成合理转角指令,而反馈转角则有效修正实际偏差,二者协同作用保障了轨迹跟踪的准确性与稳定性。横摆角速度与质心侧偏角的动态响应结果如图 14、15 所示,其中,在 $T = 3 \sim 4$ s 时间段,车辆质心侧偏角出现显著增大,车辆与预定轨迹偏差增大,而本文提出的预测-反馈控制




图 13 场景 II 预测反馈转角

Fig. 13 Predicted feedback steering angle in scenario II




图 14 场景 II 横摆角速度对比

Fig. 14 Comparison of yaw rates in scenario II




图 15 场景 II 质心侧偏角对比

Fig. 15 Comparison of centroid side-slip angles in scenario II
策略, 凭借网络的快速自适应调整能力, 仍能较好地抑制偏差进一步扩大, 有效提升车身姿态稳定性。此外, 图 16 中的侧向加速度对比结果表明, 预测-反




图 16 场景 II 侧向加速度对比

Fig. 16 Comparison of lateral accelerations in scenario II

馈控制策略在曲率急剧变化处, 较 ILQR 与 NMPC 控制策略在一定程度上降低了车辆发生失稳的风险, 保障了车辆行驶的平顺性与安全性。

各方法轨迹跟踪的误差对比进一步证明了本文方法在低附着路面条件下的优越性, 如表 4 所示。表 4 中: 在最大横向偏差方面, 预测-反馈控制策略相较 ILQR 和 NMPC 分别降低了 4.2% 和 7.1%; 在横向偏差均方根值上, 分别降低了 5.1% 和 7.4%。其最大值相较 ILQR 和 NMPC 分别减少了 17.7% 和 8.5%。由此可见, 基于动态卡尔曼多项式网络的在线学习特性, 使得预测-反馈控制策略在低附着力复杂工况下, 凭借其精准的实时预测与有效的反馈调节能力, 能够有效克服传统控制算法对模型依赖性强、适应性不足的限制, 展现出更为优异的轨迹跟踪与姿态控制性能。

表 4 场景 II 控制目标误差

Table 4 Errors of control targets in case II

参数	方法	最大误差	均方根误差
横向偏差/m	ILQR 控制器	0.249 6	0.127 2
	NMPC 控制器	0.257 3	0.130 3
	预测-反馈控制器	0.239 1	0.120 7
航向偏差/rad	ILQR 控制器	0.053 6	0.021 7
	NMPC 控制器	0.048 2	0.019 8
	预测-反馈控制器	0.044 1	0.020 7

3.3 仿真场景 III

仿真场景 III 模拟了一种高速行驶过程中车辆执行双车道变换的紧急避障工况。在该场景中, 车辆以恒定速度 $90 \text{ km} \cdot \text{h}^{-1}$ 行驶, 路面附着系数为 $\mu = 0.85$, 代表高速的极端驾驶条件。此类工况下, 车辆的非线性动力学响应更为剧烈, 对控制系统的快速

性、精确性和稳定性均提出了极高要求,是检验控制器极限性能的关键场景。该场景下定量误差指标对比如表 5 所示。可见,预测-反馈控制器在最大横向偏差与最大航向偏差方面均优于 ILQR 和 NMPC 控制器。具体而言:最大横向偏差相较于 ILQR 与 NMPC 分别减少了 29.0%与 32.3%,最大航向偏差则分别减少了 39.0%与 44.9%。误差均方根值方面,横向偏差 RMSE 分别降低了 32.5%与 38.4%,航向偏差 RMSE 分别减少了 37.8%与 40.0%。这一系列定量结果清晰地反映了预测-反馈控制器在高速紧急变道情境中的突出控制能力。

表 5 场景 III 控制目标误差

Table 5 Errors of control targets in case III

参数	方法	最大误差	均方根误差
横向偏差/m	ILQR 控制器	2.425 3	0.739 2
	NMPC 控制器	2.541 0	0.810 7
	预测-反馈控制器	1.721 2	0.499 3
航向偏差/rad	ILQR 控制器	0.219 6	0.069 1
	NMPC 控制器	0.242 8	0.071 7
	预测-反馈控制器	0.133 9	0.043 0

车辆横向位置和航向位置随时间变化的轨迹对比曲线如图 17、18 所示,其中:在 $T=2$ s 后,ILQR 与 NMPC 控制器在复杂路径段出现明显偏离,且回归参考轨迹的响应速度滞后,表明其对快速变化路径曲率的响应能力不足,相比之下,预测-反馈控制器虽然在道路大曲率变化处也出现了一定偏离,但其核心的动态卡尔曼多项式网络通过其非线性多项式网络结构能够更准确地捕捉高速下的车辆动态特性,同时其卡尔曼滤波机制快速调整模型参数以适应剧烈的动态变化,从而能够在高车速下快速适应道路曲率变化,实现平稳、精准的轨迹跟踪。图 19 进一步揭示了前馈预测模块与反馈控制模块生成的转向角输入随时间的变化趋势,尽管在某些时刻存在轻微波动,但总体过渡平稳。在车辆姿态稳定性方面,横摆角速度、质心侧偏角与侧向加速度对比结果如图 20~22 所示,其中:采用动态卡尔曼多项式网络的预测-反馈控制器在高速避障过程中表现出更优的姿态控制能力。其对横摆角速度的峰值抑制效果明显优于 ILQR 与 NMPC 控制器,这表明所提控制器能更有效地管理车辆在极限工况下的横向动力学响应,显著降低了车辆出现剧烈横向运动的风险。ILQR 与 NMPC 控制器在动态变化剧烈时段出现较大的质心侧偏角和更高的横摆角速度及侧向加速度峰值,显示其在高动态、强非线性条件下的适

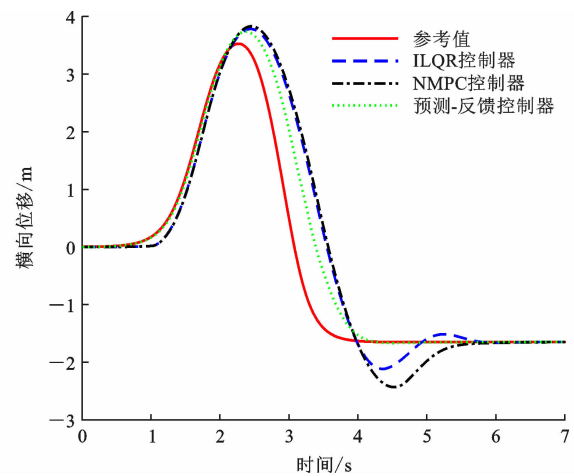


图 17 场景 III 横向位置对比

Fig. 17 Comparison of lateral positions in scenario III




图 18 场景 III 航向角对比

Fig. 18 Comparison of heading angles in scenario III




图 19 场景 III 预测反馈转角

Fig. 19 Predicted feedback steering angle in scenario III

应性和稳定性控制能力受限,存在姿态失稳的潜在风险。本文方法通过在线学习捕捉这种极端工况下车辆的高度非线性动态特性,并通过预测模块与反




图 20 场景Ⅲ横摆角速度对比

Fig. 20 Comparison of yaw rates in scenario III




图 21 场景Ⅲ质心侧偏角对比

Fig. 21 Comparison of centroid side-slip angles in scenario III




图 22 场景Ⅲ侧向加速度对比

Fig. 22 Comparison of lateral accelerations in scenario III

馈模块协同作用,实现了对关键动态参数(横摆角速度、侧向加速度)的精确控制,从而保障了车辆的行驶稳定性。

综上所述,仿真场景Ⅲ验证了本文所提出的预测-反馈控制策略在高速紧急避障工况下的绝对控制优势。通过引入动态卡尔曼多项式网络的在线学习机制与前馈-反馈协同结构,该控制器能够有效应对高动态环境下的复杂非线性系统特性,显著提升了路径跟踪精度与车辆姿态稳定性,尤其适用于高速行驶、急变路径等传统控制器难以应对的极端工况下的自动驾驶控制需求。

为定量评估本文所提出的控制器中各核心模块对整体性能提升的独立贡献,在该挑战性工况下设计并实施了一项消融试验。对比了3种控制器变体:①固定权重多项式网络预测-反馈控制器,该变体禁用了卡尔曼滤波的在线权重更新功能,旨在评估在线学习机制的贡献;②动态卡尔曼多项式网络预测器(无反馈),该变体移除了PI反馈控制器,旨在评估反馈校正环节的贡献;③完整方案,即本文提出的完整预测-反馈控制器,作为性能基准。各控制器变体在场景Ⅲ下的性能误差对比如表6所示。通过对比方案①与方案②,发现引入在线学习后,最大横向偏差从2.9155 m降至2.6530 m,其均方根误差也从1.0542 m降至0.8815 m(降低16.4%),航向偏差同样有所降低。这表明动态卡尔曼多项式网络的在线自适应能力是提升模型预测精度的关键,即使在没有反馈校正的情况下,也能优于静态模型。其次,通过对比方案②与方案③,在引入PI反馈后,横向偏差的均方根值从0.8815 m进一步大幅降至0.4993 m(降低43.4%),航向偏差的均方根值也从0.0823 rad降至0.0430 rad(降低47.8%)。这表明在高性能预测器的基础上,PI反馈控制器能有效消除残余误差,对确保最终的跟踪精度和鲁棒性至关重要。综上所述,消融试验清晰地揭示了本文方法性能提升的来源,其性能的飞跃源于两大关键模块的协同作用。动态卡尔曼多项式网络作为先进的前馈预测器,通过非线性建模与在线学习的深度融合,极大提升了系统对复杂动态的适应性和预测精度,为高精度控制奠定了坚实基础;PI反馈控制器则作为高效的反馈校正器,在此基础上提供了必要的误差补偿,保证了系统最终的高精度和稳态性能。这一“预测-反馈”的协同机制,充分证明了本文所提控制框架的有效性与完整性。

3.4 HIL 测试

为了对本文提出的预测-反馈控制策略进行全面的性能评估与可行性验证,并有效规避道路测试所固有的潜在风险与高昂成本,本研究搭建了HIL

表 6 各控制器变体在场景 III 下的性能误差对比
Table 6 Performance error comparison of controller variants in case III

参数	方法	最大误差	均方根误差
横向偏差/m	固定权重多项式网络预测-反馈控制器	2.915 5	1.054 2
	动态卡尔曼多项式网络预测器(无反馈)	2.653 0	0.881 5
	动态卡尔曼多项式网络预测-反馈控制器(完整方案)	1.721 2	0.499 3
航向偏差/rad	固定权重多项式网络预测-反馈控制器	0.296 4	0.099 7
	动态卡尔曼多项式网络预测器(无反馈)	0.261 0	0.082 3
	动态卡尔曼多项式网络预测-反馈控制器(完整方案)	0.133 9	0.043 0

测试平台,如图 23 所示,该平台的核心架构主要由被测的车辆控制单元(Vehicle Control Unit, VCU)、NI 实时仿真器以及用于控制策略编译与车辆模型部署的上位机系统构成。具体而言,基于 MATLAB/Simulink 环境开发的控制策略,经由专用软件编译后下载至 VCU 控制器;与此同时,通过 CarSim 软件构建的精细化车辆动力学模型及虚拟道路环境部署于 NI 实时仿真器中。VCU 控制器与 NI 实时仿真器之间通过物理线束实现信号交互,构成关键的测试闭环:NI 实时仿真器负责模拟真实的车辆运行状态(如车速、传感器数据等)并将其输入至 VCU 控制器,VCU 控制器则根据接收到的状态信息实时运行内部的控制算法,并将计算得到的控制指令反馈给 NI 实时仿真器,进而驱动虚拟车辆模型作出相应动态响应。这种实时闭环的测试方式,使得控制算法能够在实验室环境下进行系统化、可重复的严格测试与迭代优化,为后续的实车应用奠定坚实基础。




图 23 硬件在环测试平台

Fig. 23 Hardware-in-the-loop test platform

测试工况设定为双移线避障,车辆以恒定速度 $70 \text{ km} \cdot \text{h}^{-1}$ 行驶,通过系统性地改变路面附着系数 ($\mu=1.0, 0.8, 0.6, 0.4$),以考察控制器在不同轮胎-路面附着条件下的动态响应特性和鲁棒性。不同附着系数下,车辆横向位置与航向位置对参考轨迹的跟随情况如图 24、25 所示,其中:在高附着系数 ($\mu=1.0, 0.8$) 条件下,车辆能够精确地跟踪预设路径,横向位置误差与航向角偏差均较小,表明控制器在此理想工况下具备良好的跟踪精度,当附着系数降至 $\mu=0.6$ 时,控制器仍能维持有效的轨迹跟踪和车辆基本稳定,质心侧偏角变化如图 26 所示,也均在合理范围内。




图 24 HIL 测试横向位置变化

Fig. 24 HIL test: Lateral position variation

在极端低附着系数 $\mu=0.4$ 时,车辆执行双移线避障所需的侧向力已明显超越了轮胎与路面间的物理附着极限,车辆的横向位置(如图 24、27 所示)已经严重偏离参考轨迹,横摆角速度也未能收敛至零点,表明车辆已进入不可控的失稳状态。在这一极

限工况下,控制器已无法维持车辆的稳定性,因此分析的重点不再是轨迹跟踪精度本身,而是考察控制




图 25 HIL 测试航向角变化

Fig. 25 HIL test: Heading angle variation




图 28 HIL 测试预测转角变化

Fig. 28 HIL test: Predicted steering angle variation




图 26 HIL 测试质心侧偏角变化

Fig. 26 HIL test: Centroid side-slip angle variation




图 29 HIL 测试反馈转角变化

Fig. 29 HIL test: Feedback steering angle variation




图 27 HIL 测试横摆角速度变化

Fig. 27 HIL test: Yaw rate variation

器在系统失控背景下的响应机制。

预测转角和反馈转角变化如图 28、29 所示,其中,控制器输出的剧烈转角变化,表现出控制算法对巨大且持续增长的跟踪误差的一种确定性的、符合

其设计逻辑的响应。具体而言,该输出是预测与反馈协同作用的结果:动态卡尔曼多项式网络的在线学习机制在持续尝试拟合急剧变化的车辆动态,而反馈模块则对观测到的巨大误差生成了高幅值的补偿。表明即使在物理系统完全失稳的极端条件下,本文所提出的控制算法其内部计算流程并未崩溃,其输出也未出现饱和或无意义的振荡。控制器仍在依据其内在的数学模型和校正规则持续运作,其输出行为是可预测的。然而,由于车辆动态已超出物理可控范围,这些转向指令无法阻止失稳发生,只能反映出控制器在极端条件下依然尝试工作的特征。

综上所述,HIL 测试结果进一步验证了本文所提控制策略的有效性:在高、中附着条件下,控制器能实现精确、稳定的轨迹跟踪;在极端低附着条件下,尽管车辆因物理极限失稳失控,控制器仍通过预测-反馈相结合的补偿机制表现出一定的响应能力。

这一现象与仿真结果一致,为所提算法在实际车辆上的应用提供了有价值的参考依据。

4 结 语

(1)本文提出了一种基于动态卡尔曼多项式网络的预测-反馈控制器,旨在提升自动驾驶车辆在高速紧急变道、低附着路面等极限动态场景下的轨迹跟踪性能。该控制器的核心是一种创新的预测模块,其优势在于:首先,多项式网络通过构建高维非线性特征,能够精确逼近车辆在极限工况下的复杂动态行为,为高精度预测提供了强大的非线性建模基础;其次,也是更为关键的一点,框架中融入的卡尔曼滤波机制实现了对多项式网络权重的在线自适应更新,赋予了预测模型实时应对路面变化等不确定性的能力。仿真与硬件在环测试结果充分验证了该方法的有效性与可行性,与传统基于模型的控制方法相比,本文所提策略在极限工况下的轨迹跟踪精度显著提升。最后,消融试验清晰地揭示了其卓越性能源于非线性预测与在线自适应校正的深度协同,证实了该集成设计的优越性。

(2)然而,本研究亦认识到,控制器内部采用的预测模型基于简化的二自由度车辆动力学,在极端高速、大转向角等工况下,可能无法完全捕捉由车辆悬架系统等复杂因素引入的全部动态特性。后续研究应致力于将更精细的车辆动力学模型(如非线性悬架模型、详细轮胎模型等)显式地融入动态卡尔曼多项式网络框架,以增强系统在强耦合动态环境下的泛化能力与控制精度。

参 考 文 献 :

References :

- [1] JU Z Y, ZHANG H, LI X, et al. A survey on attack detection and resilience for connected and automated vehicles: From vehicle dynamics and control perspective[J]. IEEE Transactions on Intelligent Vehicles, 2022, 7(4): 815-837.
- [2] CHENG S, WANG Z, YANG B, et al. Convolutional neural network-based lane-change strategy via motion image representation for automated and connected vehicles [J]. IEEE Transactions on Neural Networks and Learning Systems, 2024, 35(9): 12953-12964.
- [3] 赵祥模国家重点研发计划(2021YFB2501200)团队. 自动驾驶测试与评价技术研究进展[J]. 交通运输工程学报, 2023, 23(6):10-77.
ZHAO Xiang-mo's team supported by the National Key Research and Development Program of China(2021YFB2501200). Research progress in testing and evaluation technologies for autonomous driving[J]. Journal of Traffic and Transportation Engineering, 2023, 23(6): 10-77.
- [4] 李 杰,张洛维,王晓燕,等. 基于视锥距离和自适应权重卡尔曼滤波的多传感器融合算法[J]. 中国公路学报, 2024, 37(3): 194-203.
LI Jie, ZHANG Luo-wei, WANG Xiao-yan, et al. A multi-sensor fusion algorithm based on view-cone distance and adaptive weighted Kalman filter[J]. China Journal of Highway and Transport, 2024, 37(3): 194-203.
- [5] ZHAO Y Y, WANG L, YUN X Y, et al. Enhanced scene understanding and situation awareness for autonomous vehicles based on semantic segmentation[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2024, 54(11): 6537-6549.
- [6] HE X K, YANG H L, HU Z X, et al. Robust lane change decision making for autonomous vehicles: An observation adversarial reinforcement learning approach[J]. IEEE Transactions on Intelligent Vehicles, 2023, 8(1): 184-193.
- [7] 李胜琴,丁雪梅. 基于五次多项式的智能车辆轨迹规划[J]. 江苏大学学报(自然科学版), 2023, 44(4): 392-398.
LI Sheng-qin, DING Xue-mei. Trajectory planning of intelligent vehicle based on quintic polynomial[J]. Journal of Jiangsu University (Natural Science Edition), 2023, 44(4): 392-398.
- [8] SHI X Y, WANG H, CHEN L, et al. A distributed driving six-wheel steering commercial vehicle chassis stability domain criterion for coordination of multiple subsystems[J]. IEEE Transactions on Vehicular Technology, 2024, 73(12): 18512-18526.
- [9] 赵 轩,王 妹,马 建,等. 分布式驱动电动汽车底盘集成控制技术综述[J]. 中国公路学报, 2023, 36(4): 221-248.
ZHAO Xuan, WANG Shu, MA Jian, et al. Review of chassis integrated control technology for distributed drive electric vehicles[J]. China Journal of Highway and Transport, 2023, 36(4): 221-248.
- [10] 黄益绍,庄 迪. 基于干扰观测器与终端滑模的车辆纵向控制[J]. 江苏大学学报(自然科学版), 2024, 45(5): 513-520.
HUANG Yi-shao, ZHUANG Di. Vehicle longitudinal control based on disturbance observer and terminal sliding mode[J]. Journal of Jiangsu University (Natural Science Edition), 2024, 45(5): 513-520.
- [11] 潘世举,李永乐,李子先,等. 基于改进纯跟踪的智能车路径跟随方法[J]. 汽车工程, 2023, 45(1): 1-8, 19.
PAN Shi-ju, LI Yong-le, LI Zi-xian, et al. Path following method of intelligent vehicles based on improved pure tracking[J]. Automotive Engineering, 2023, 45(1): 1-8, 19.
- [12] 白国星,孟 宇,刘 立,等. 无人驾驶车辆路径跟踪控制研究现状[J]. 工程科学学报, 2021, 43(4): 475-485.
BAI Guo-xing, MENG Yu, LIU Li, et al. Current status of path tracking control of unmanned driving vehicles [J]. Chinese Journal of Engineering, 2021, 43(4): 475-485.
- [13] MARINO R, SCALZI S, NETTO M. Nested PID steering control for lane keeping in autonomous vehicles[J]. Control

- Engineering Practice, 2011, 19(12): 1459-1467.
- [14] CHU D F, LI H R, ZHAO C Y, et al. Trajectory tracking of autonomous vehicle based on model predictive control with PID feedback[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(2): 2239-2250.
- [15] HU C, WANG R R, YAN F J, et al. Output constraint control on path following of four-wheel independently actuated autonomous ground vehicles[J]. IEEE Transactions on Vehicular Technology, 2016, 65(6): 4033-4043.
- [16] JUNG H, JUNG D, CHOI S B. LQR control of an all-wheel drive vehicle considering variable input constraint[J]. IEEE Transactions on Control Systems Technology, 2022, 30(1): 85-96.
- [17] NAM H, CHOI W, AHN C. Model predictive control for evasive steering of an autonomous vehicle[J]. International Journal of Automotive Technology, 2019, 20(5): 1033-1042.
- [18] ZHAI L, WANG C P, HOU Y H, et al. MPC-based integrated control of trajectory tracking and handling stability for intelligent driving vehicle driven by four hub motor[J]. IEEE Transactions on Vehicular Technology, 2022, 71(3): 2668-2680.
- [19] SHI X Y, WANG H, CHEN L, et al. Robust path tracking control of distributed driving six-wheel steering commercial vehicle based on coupled active disturbance rejection [J]. IEEE Transactions on Vehicular Technology, 2023, 72(11): 13940-13952.
- [20] HANG P, CHEN X B. Integrated chassis control algorithm design for path tracking based on four-wheel steering and direct yaw-moment control[J]. Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering, 2019, 233(6): 625-641.
- [21] SPIELBERG N A, BROWN M, KAPANIA N R, et al. Neural network vehicle models for high-performance automated driving [J]. Science Robotics, 2019, 4(28): eaaw1975.
- [22] DA LIO M, BORTOLUZZI D, PAPINI G P R. Modelling longitudinal vehicle dynamics with neural networks[J]. Vehicle System Dynamics, 2020, 58(11): 1675-1693.
- [23] BECKERS T, COLOMBO L J, HIRCHE S, et al. Online learning-based trajectory tracking for underactuated vehicles with uncertain dynamics[J]. IEEE Control Systems Letters, 2021, 6: 2090-2095.
- [24] YU H X, DUAN J M, TAHERI S, et al. A model predictive control approach combined unscented Kalman filter vehicle state estimation in intelligent vehicle trajectory tracking[J]. Advances in Mechanical Engineering, 2015, 7(5): 1-14.
- [25] LI L, WANG T Q, XIA Y Q, et al. Trajectory tracking control for wheeled mobile robots based on nonlinear disturbance observer with extended Kalman filter[J]. Journal of the Franklin Institute, 2020, 357(13): 8491-8507.
- [26] ZHANG Q, BHATTARAIN, CHEN H, et al. Vehicle trajectory tracking using adaptive Kalman filter from roadside lidar[J]. Journal of Transportation Engineering, Part A: Systems, 2023, 149(6): 04023043.
- [27] 陈 特,陈 龙,徐 兴,等.分布式驱动无人车路径跟踪与稳定性协调控制[J]. 汽车工程,2019,41(10):1109-1116.
CHEN Te, CHEN Long, XU Xing, et al. Integrated control of unmanned distributed driven vehicles path tracking and stability[J]. Automotive Engineering, 2019, 41(10): 1109-1116.
- [28] SHI X Y, WANG H, CHEN L, et al. Hybrid trigger cooperative control of six-wheeled commercial vehicles with multiple sub-systems based on sub-regional linearization model[J]. Simulation Modelling Practice and Theory, 2024, 135: 102973.
- [29] HOU R F, ZHAI L, SUN T M, et al. Steering stability control of a four in-wheel motor drive electric vehicle on a road with varying adhesion coefficient [J]. IEEE Access, 2019, 7: 32617-32627.
- [30] 马永杰,程时升,马芸婷,等.卷积神经网络及其在智能交通系统中的应用综述[J]. 交通运输工程学报,2021,21(4):48-71.
MA Yong-jie, CHENG Shi-sheng, MA Yun-ting, et al. Review of convolutional neural network and its application in intelligent transportation system[J]. Journal of Traffic and Transportation Engineering, 2021, 21(4): 48-71.
- [31] 吴 骁,史文库,陈志勇.基于交互式多模型卡尔曼滤波的主动悬架控制[J]. 汽车工程,2023,45(7):1200-1211,1253.
WU Xiao, SHI Wen-ku, CHEN Zhi-yong. Active suspension control based on interacting multiple model Kalman filter[J]. Automotive Engineering, 2023, 45(7): 1200-1211, 1253.
- [32] 胡敬宇,汪 葵,严永俊,等.基于限定记忆随机加权扩展卡尔曼滤波的车辆状态估计[J]. 东南大学学报(自然科学版), 2022,52(2):387-393.
HU Jing-yu, WANG Yan, YAN Yong-jun, et al. Vehicle state estimation based on limited memory random weighted extended Kalman filter[J]. Journal of Southeast University (Natural Science Edition), 2022, 52(2): 387-393.
- [33] KAPANIA N R, GERDES J C. Design of a feedback-feedforward steering controller for accurate path tracking and stability at the limits of handling [J]. Vehicle System Dynamics, 2015, 53(12): 1687-1704.