

DOI:10.3969/j.issn.1003-5060.2026.01.001

基于 LSTM 神经网络的智能汽车 轨迹跟踪混合控制策略研究

张 良, 程 浩, 卢剑伟, 雷夏阳

(合肥工业大学 汽车与交通工程学院, 安徽 合肥 230009)

摘要:针对车辆轨迹跟踪过程中实时迭代求解隐式模型预测控制(model predictive control, MPC)计算效率低且实时性较差以及显式 MPC 受限于预计算的问题, 文章提出基于长短期记忆(long short-term memory, LSTM)神经网络并结合 MPC 与线性二次型调节器(linear quadratic regulator, LQR)的混合控制策略。通过设置控制器的动态切换条件, 在低速或状态误差较小时, 采用 LQR 进行反馈控制, 以快速响应并降低计算成本; 在高速或状态误差较大时, 采用 MPC 控制提供高精度轨迹跟踪, 同时利用 LSTM 神经网络在线学习 MPC 控制行为, 逐步逼近其控制效果, 当 LSTM 学习误差满足阈值后, 系统切换至 LSTM 结合 LQR 控制模式, LSTM 生成基础控制信号, 而 LQR 负责实时反馈调整以补偿动态环境中的扰动或误差。仿真实验结果表明, 该混合控制策略在提高跟踪控制精度的同时能显著提升计算效率。

关键词:长短期记忆(LSTM)神经网络; 模型预测控制(MPC); 线性二次型调节器(LQR); 动态切换机制; 轨迹跟踪控制

中图分类号: TP181; U461.6

文献标志码: A

文章编号: 1003-5060(2026)01-0001-12

Research on hybrid control strategy of intelligent vehicle trajectory tracking based on LSTM neural network

ZHANG Liang, CHENG Hao, LU Jianwei, LEI Xiayang

(School of Automobile and Traffic Engineering, Hefei University of Technology, Hefei 230009, China)

Abstract: In order to solve the problem of low computational efficiency and poor real-time performance of iterative solution of implicit model predictive control (MPC) in the process of vehicle trajectory tracking, as well as the limitation of explicit MPC constrained by pre-computation, a hybrid control strategy based on long short-term memory (LSTM) neural network combined with MPC and linear quadratic regulator (LQR) is proposed. By setting the dynamic switching condition of the controller, LQR is used for feedback control at low speed or when the state error is small, so as to respond quickly and reduce the computational cost. At high speed or when the state error is large, MPC is used to provide high-precision trajectory tracking, and LSTM neural network is used to learn MPC control behavior online to gradually approximate its control effect. When the LSTM learning error meets the threshold, the system switches to the control mode of LSTM combined with LQR, LSTM generates the basic control signal, and LQR is responsible for real-time feedback adjustment to compensate for the disturbance or error in the dynamic environment. The simulation results show that the hybrid control strategy can improve the tracking control precision and computational efficiency significantly.

Key words: long short-term memory (LSTM) neural network; model predictive control (MPC); linear quadratic regulator (LQR); dynamic switching mechanism; trajectory tracking control

收稿日期: 2024-12-31; 修回日期: 2025-04-03

基金项目: 国家重点研发计划资助项目(2021YFE0116600)

作者简介: 张 良(1973—), 男, 安徽淮北人, 博士, 合肥工业大学副教授, 硕士生导师, 通信作者, E-mail: zhl@hfut.edu.cn;
卢剑伟(1975—), 男, 山东青州人, 博士, 合肥工业大学教授, 博士生导师。

近年来,随着无人驾驶领域的飞速发展,轨迹跟踪技术作为实现无人驾驶的核心模块,不仅直接影响车辆的行驶安全性、稳定性和舒适性,也是评估自动驾驶性能的关键指标之一。横向控制作为轨迹跟踪的关键环节,其性能对轨迹跟踪精度起着决定性作用。

传统模型预测控制(model predictive control, MPC)^[1]因能够预测未来状态并优化控制输入,被广泛应用于轨迹跟踪控制。然而,隐式 MPC 需要实时求解复杂的优化问题,计算成本高且实时性较差;显式 MPC^[2]尽管计算效率较高,但其依赖于离线预计算的特性使得普适性不足,难以适应复杂环境。文献[3]提出基于多目标优化和显式模型预测控制(multi-objective explicit MPC, MO-EMPC)的轨迹跟踪控制器,将传统 MPC 在线优化转化为显式控制律,大幅提升了控制实时性;但离线优化效率低、计算量大。文献[4]提出一种适用于隐式微分-代数方程(DAEs)系统的统一 MPC 框架,能够应对动力学建模和控制中的复杂性;但计算成本大,需要依赖精确的系统建模。文献[5]提出的显式 MPC 方法通过离线优化和在线快速查表,兼顾轨迹跟踪精度与稳定性,大幅提高了实时性;但其控制律求解耗时。文献[6]利用高斯过程回归(Gaussian process regression, GPR)实时修正车辆动力学模型的不确定性,增强了状态预测的精度;但 GPR 模型在数据稀疏或突变场景中性能可能下降。文献[7]通过变预测时域的自适应调整,显著提升了轨迹跟踪精度和横向稳定性;但其实现依赖于精确模型和数据支持,同时复杂性较高。近年来,基于深度学习的控制方法逐渐成为研究热点。文献[8]利用强化学习(reinforcement learning, RL)动态调整 MPC 权重,使控制器能根据实时场景风险调整行为;文献[9]提出一种基于在线学习的 MPC 方法,通过结合 Takagi-Sugeno 模糊模型和实时优化,实现了复杂非线性系统的高效控制,满足实时控制需求;文献[10]利用深度学习模仿 MPC 的控制行为,通过替代在线优化,实现两数量级的计算时间减少。

针对上述隐式 MPC 计算效率低且实时性较差以及使用显式 MPC 受限于预计算的问题,本文提出一种基于长短期记忆(long short-term memory, LSTM)神经网络并结合 MPC 以及线性二次型调节器(linear quadratic regulator, LQR)的混合控制策略。该方法充分利用 LSTM 神经

网络的在线学习能力,逼近 MPC 控制行为;同时,通过动态切换机制实现控制算法之间的切换并且保证切换过程的平稳性,在低速或状态误差较小时采用 LQR 控制以降低计算成本,在高速或状态误差较大时采用 MPC 以提供高精度轨迹跟踪。当 LSTM 在线学习误差达到设定阈值后,系统切换至 LSTM 结合 LQR 组合控制模式,实现计算效率与控制精度的平衡。

1 轨迹跟踪模型

1.1 车辆二自由度动力学模型

本文基于以下假设建立车辆二自由度动力学模型:① 忽略空气动力学的作用;② 忽略轮胎的非线性特性,使用理想化轮胎模型;③ 忽略轮胎侧偏刚度的变化;④ 忽略车辆结构的弯曲和变形,假设车辆是一个刚体,车辆仅作平行于地面的平面运动;⑤ 忽略轮胎的纵向力,假设车辆纵向速度恒定;⑥ 忽略转向系统,车辆模型输入为前轮转角。最终得到车辆动力学模型如图 1 所示。

图 1 中: m 为车辆质量; φ 为车辆横摆角; α_f 为前轮侧偏角; α_r 为后轮侧偏角; δ_f 为前轮转角; XOY 为大地坐标系; xoy 为车身坐标系; v_x 、 v_y 分别为车身坐标系中质心点的纵向速度和横向速度; F_{yf} 、 F_{yr} 分别为前、后轮所受侧向力; F_{xf} 、 F_{xr} 分别为前、后轮所受纵向力; l_f 、 l_r 分别为前、后轴到质心的距离。




图 1 车辆动力学模型

根据牛顿第二定律建立车辆沿 x 、 y 、 z 方向的受力平衡方程:

$$\begin{cases} m a_x = m(\dot{v}_x - v_y \dot{\varphi}) = F_{xf} \cos \delta_f - F_{yf} \sin \delta_f + F_{xr} \\ m a_y = m(\dot{v}_y - v_x \dot{\varphi}) = F_{xf} \sin \delta_f + F_{yf} \cos \delta_f + F_{yr} \\ I_z \ddot{\varphi} = l_f (F_{xf} \sin \delta_f + F_{yf} \cos \delta_f) - l_r F_{yr} \end{cases} \quad (1)$$

其中: a_x 、 a_y 分别为纵向加速度和侧向加速度; I_z 为绕 z 轴的转动惯量。

正常行驶工况下,车辆前轮转角 δ_f 较小, F_{xf} 可视为 0。车辆前轮转角作为模型输入,即通过前轮驱动车辆,故后轮驱动力 F_{xr} 可视为 0,又因

为本文假设车辆纵向速度恒定,所以 $\dot{v}_x = 0$ 。因此,可将式(1)改写为:

$$\begin{cases} \dot{v}_y = \frac{F_{yf} \cos \delta_f + F_{yr}}{m} - v_x \dot{\varphi}, \\ \ddot{\varphi} = \frac{l_f F_{yf} \cos \delta_f - l_r F_{yr}}{I_z} \end{cases} \quad (2)$$

由于不考虑轮胎非线性区域,前、后轮胎所受侧向力可以表示为:

$$\begin{cases} F_{yf} = C_f \alpha_f, \\ F_{yr} = C_r \alpha_r \end{cases} \quad (3)$$

其中, C_f, C_r 分别为前、后轮的侧偏刚度。轮胎侧偏角 α_f 和 α_r 在车辆正常行驶时较小,可表示为:

$$\begin{cases} \alpha_f = \frac{v_y + l_f \dot{\varphi}}{v_x} - \delta_f, \\ \alpha_r = \frac{v_y - l_r \dot{\varphi}}{v_x} \end{cases} \quad (4)$$

结合式(2)、式(3)、式(4)并整理可得完整的车辆二自由度模型,即

$$\begin{bmatrix} \dot{v}_y \\ \ddot{\varphi} \end{bmatrix} = \begin{bmatrix} -\frac{C_f + C_r}{mv_x} & -\frac{l_f C_f - l_r C_r}{mv_x} \\ -\frac{l_r C_r - l_f C_f}{I_z v_x} & -\frac{l_f^2 C_f + l_r^2 C_r}{I_z v_x} \end{bmatrix} \begin{bmatrix} v_y \\ \dot{\varphi} \end{bmatrix} + \begin{bmatrix} \frac{C_f}{m} \\ \frac{l_f C_f}{I_z} \end{bmatrix} \delta_f \quad (5)$$

若设

$$\mathbf{A} = \begin{bmatrix} -\frac{C_f + C_r}{mv_x} & -\frac{l_f C_f - l_r C_r}{mv_x} \\ -\frac{l_r C_r - l_f C_f}{I_z v_x} & -\frac{l_f^2 C_f + l_r^2 C_r}{I_z v_x} \end{bmatrix}, \mathbf{B} = \begin{bmatrix} \frac{C_f}{m} \\ \frac{l_f C_f}{I_z} \end{bmatrix},$$

可用 $\dot{\mathbf{X}} = [\dot{v}_y \quad \ddot{\varphi}]^T$ 表示状态矩阵, $u = \delta_f$ 表示控制量,则式(5)可表示为:

$$\dot{\mathbf{X}} = \mathbf{A}\mathbf{X} + \mathbf{B}u \quad (6)$$

1.2 轨迹跟踪横向误差模型

横向误差动力学模型如图 2 所示。

图 2 中:横向误差 e_d 为参考轨迹点到车辆质心的横向距离;航向误差 e_φ 为车辆当前航向与参考轨迹点切线方向之间的夹角; v_x, v_y 为车辆质心在自车坐标系中的速度分量; δ_f 为前轮转角; κ_{ref} 为参考轨迹点的曲率。

图 2 基于动力学模型描述了车辆实际行驶轨迹与参考轨迹之间的实时误差状态。由图 2 可知期望航向角速度 $\dot{\varphi}_{ref} = v_x \kappa_{ref}$, 结合车辆运动学关系,可得横向误差和航向误差的动力学公式为:

$$\dot{e}_d = v_x e_\varphi + v_y \quad (7)$$

$$\dot{e}_\varphi = \dot{\varphi} - \dot{\varphi}_{ref} \quad (8)$$

航向误差为当前航向角 φ 与匹配轨迹点处航向角 φ_r 之间的误差,可表示为:

$$e_\varphi = \varphi - \varphi_r \quad (9)$$

期望向心加速度为车辆经过对应曲率点轨迹时的横向加速度,可表示为:

$$a_{yr} = v_x^2 \kappa_{ref} = v_x \dot{\varphi}_r \quad (10)$$

由式(10)可得瞬时加速度 a_y 与期望横向加速度之间的误差表达式为:

$$\ddot{e}_d = a_y - a_{yr} = \ddot{y} + v_x (\dot{\varphi} - \dot{\varphi}_r) \quad (11)$$

假设瞬时时间段内车辆速度不变,由式(11)可得横向速度误差为:

$$\dot{e}_d = \dot{y} - v_x (\varphi - \varphi_r) \quad (12)$$

结合车辆动力学模型以及式(7)、式(8)可得:

$$\begin{aligned} \ddot{e}_d = & -\frac{C_f + C_r}{mv_x} \dot{e}_d + \frac{C_f + C_r}{mv_x} e_\varphi - \frac{l_f C_f + l_r C_r}{mv_x} \dot{e}_\varphi + \\ & \left(-\frac{l_f C_f - l_r C_r}{mv_x} - v_x \right) \dot{\varphi}_r + \frac{C_f}{m} \delta_f \end{aligned} \quad (13)$$

$$\begin{aligned} \ddot{e}_\varphi = & -\frac{l_f C_f - l_r C_r}{I_z v_x} \dot{e}_d + \frac{l_f C_f - l_r C_r}{I_z} e_\varphi - \\ & \frac{l_f^2 C_f + l_r^2 C_r}{mv_x} (\dot{e}_\varphi + \dot{\varphi}_r) + \frac{l_f C_f}{I_z} \delta_f \end{aligned} \quad (14)$$




图 2 轨迹跟踪横向误差模型

定义横向误差状态变量,即横向误差 e_d 、横向误差率 \dot{e}_d 、航向误差 e_φ 、航向误差率 \dot{e}_φ ,最终横向误差动力学模型^[11]可表示为:

$$\dot{\mathbf{e}}_{tr} = \bar{\mathbf{A}}\mathbf{e}_{tr} + \bar{\mathbf{B}}u + \bar{\mathbf{C}}\dot{\varphi}_r \quad (15)$$

其中

$$\bar{\mathbf{A}} = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & -\frac{C_f + C_r}{mv_x} & \frac{C_f + C_r}{mv_x} & -\frac{l_f C_f + l_r C_r}{mv_x} \\ 0 & 0 & 0 & 1 \\ 0 & -\frac{l_f C_f - l_r C_r}{mv_x} & \frac{l_f C_f - l_r C_r}{I_z} & -\frac{l_f^2 C_f + l_r^2 C_r}{I_z v_x} \end{bmatrix};$$

$$\bar{\mathbf{B}} = \begin{bmatrix} 0 \\ C_f \\ m \\ 0 \\ l_f C_f \\ I_z \end{bmatrix}; \bar{\mathbf{C}} = \begin{bmatrix} 0 \\ -l_f C_f + l_r C_r \\ m v_x \\ 0 \\ -l_f^2 C_f + l_r^2 C_r \\ I_z v_x \end{bmatrix};$$

$$\mathbf{e}_{rr} = [e_d \quad \dot{e}_d \quad e_\varphi \quad \dot{e}_\varphi]^T; \mathbf{u} = \delta_f.$$

2 轨迹跟踪控制器设计

2.1 MPC 控制器设计

2.1.1 预测模型建立

对基于横向误差的动力学模型采用改进欧拉法进行离散化处理以满足控制器设计,可以得到车辆离散动力学模型为:

$$\begin{cases} \boldsymbol{\chi}(k+1) = \mathbf{A}_{k,t} \boldsymbol{\chi}(k) + \mathbf{B}_{k,t} \mathbf{u}(k) + \mathbf{C}_{k,t}, \\ \boldsymbol{\Psi}(k+1) = \mathbf{D}_{k,t} \boldsymbol{\chi}(k) \end{cases} \quad (16)$$

其中: $\boldsymbol{\chi}$ 为离散系统状态变量; $\boldsymbol{\Psi}$ 为离散系统输出量; $\mathbf{A}_{k,t}$ 为离散系统状态矩阵; $\mathbf{B}_{k,t}$ 为离散系统控制矩阵; $\mathbf{C}_{k,t}$ 为离散系统扰动矩阵。 $\mathbf{A}_{k,t}$ 、 $\mathbf{B}_{k,t}$ 、 $\mathbf{C}_{k,t}$ 表达式分别为:

$$\begin{aligned} \mathbf{A}_{k,t} &= \mathbf{I} + T\mathbf{A}_s + \frac{T^2}{2}\mathbf{A}_s^2, \\ \mathbf{B}_{k,t} &= T\mathbf{B}_s + \frac{T^2}{2}\mathbf{A}_s\mathbf{B}_s, \\ \mathbf{C}_{k,t} &= T\mathbf{C}_s + \frac{T^2}{2}\mathbf{A}_s\mathbf{C}_s. \end{aligned}$$

其中: \mathbf{A}_s 为连续系统状态矩阵; \mathbf{B}_s 为连续系统控制矩阵; \mathbf{C}_s 为连续系统扰动矩阵; T 为离散周期。

为保证控制量的稳定性、连续性,采用控制增量代替控制量,对动力学模型的状态变量进行以下转换:

$$\boldsymbol{\xi}(k|t) = [\boldsymbol{\chi}(k|t) \quad \mathbf{u}(k-1|t)]^T \quad (17)$$

可得新的状态空间表达式为:

$$\begin{cases} \boldsymbol{\xi}(k+1|t) = \tilde{\mathbf{A}}\boldsymbol{\xi}(k|t) + \tilde{\mathbf{B}}\Delta\mathbf{U}(k|t) + \tilde{\mathbf{C}}(k|t), \\ \boldsymbol{\eta}(k|t) = \tilde{\mathbf{D}}\boldsymbol{\xi}(k|t) \end{cases} \quad (18)$$

$$\text{其中: } \tilde{\mathbf{A}} = \begin{bmatrix} \mathbf{A}_{k,t} & \mathbf{B}_{k,t} \\ \mathbf{0}_{m_d \times n_d} & \mathbf{I}_{m_d} \end{bmatrix}; \tilde{\mathbf{B}} = \begin{bmatrix} \mathbf{B}_{k,t} \\ \mathbf{I}_{m_d} \end{bmatrix}; \tilde{\mathbf{C}} = \begin{bmatrix} \mathbf{C}_{k,t} \\ \mathbf{0}_{m_d} \end{bmatrix};$$

$\tilde{\mathbf{D}} = [\mathbf{D}_{k,t} \quad \mathbf{0}_{n_d}]$; m_d 为控制变量的维度; n_d 为状态变量的维度; \mathbf{I}_{m_d} 为单位矩阵。

为简化计算,定义预测时域为 N_p ,控制时域为 N_c ,并作如下假设:

$$\begin{cases} \mathbf{A}_{k,t} = \mathbf{A}_t, & k = 1, 2, \dots, t + N_p - 1; \\ \mathbf{B}_{k,t} = \mathbf{B}_t, & k = 1, 2, \dots, t + N_p - 1; \\ \mathbf{C}_{k,t} = \mathbf{C}_t, & k = 1, 2, \dots, t + N_p - 1 \end{cases} \quad (19)$$

根据式(18)推导可得,在 N_p 预测时域内系统的预测输出表达式为:

$$\begin{cases} \mathbf{X}(t) = \boldsymbol{\Psi}_t \boldsymbol{\xi}(t|t) + \boldsymbol{\Phi}_t \Delta\mathbf{U}(t|t) + \boldsymbol{\gamma}_t, \\ \mathbf{Y}(t) = \tilde{\mathbf{D}}\mathbf{X}(t) \end{cases} \quad (20)$$

其中

$$\mathbf{X}(t) = \begin{bmatrix} \boldsymbol{\xi}(t+1|t) \\ \boldsymbol{\xi}(t+2|t) \\ \boldsymbol{\xi}(t+3|t) \\ \vdots \\ \boldsymbol{\xi}(t+N_p|t) \end{bmatrix}; \mathbf{Y}(t) = \begin{bmatrix} \boldsymbol{\eta}(t+1|t) \\ \boldsymbol{\eta}(t+2|t) \\ \boldsymbol{\eta}(t+3|t) \\ \vdots \\ \boldsymbol{\eta}(t+N_p|t) \end{bmatrix};$$

$$\boldsymbol{\Phi}_t = \begin{bmatrix} \tilde{\mathbf{B}}_t & \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \\ \tilde{\mathbf{A}}_t \tilde{\mathbf{B}}_t & \tilde{\mathbf{B}}_t & \mathbf{0} & \cdots & \mathbf{0} \\ \tilde{\mathbf{A}}_t^2 \tilde{\mathbf{B}}_t & \tilde{\mathbf{A}}_t \tilde{\mathbf{B}}_t & \tilde{\mathbf{B}}_t & \cdots & \mathbf{0} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \tilde{\mathbf{A}}_t^{N_p-1} \tilde{\mathbf{B}}_t & \tilde{\mathbf{A}}_t^{N_p-2} \tilde{\mathbf{B}}_t & \tilde{\mathbf{A}}_t^{N_p-3} \tilde{\mathbf{B}}_t & \cdots & \tilde{\mathbf{B}}_t \end{bmatrix};$$

$$\boldsymbol{\gamma}_t = \begin{bmatrix} \tilde{\mathbf{C}}_t \\ \tilde{\mathbf{A}}_t \tilde{\mathbf{C}}_t + \tilde{\mathbf{C}}_t \\ \tilde{\mathbf{A}}_t^2 \tilde{\mathbf{A}}_t \tilde{\mathbf{C}}_t + \tilde{\mathbf{C}}_t \\ \vdots \\ \sum_{i=0}^{N_p-1} \tilde{\mathbf{A}}_t^i \tilde{\mathbf{C}}_t \end{bmatrix}; \Delta\mathbf{U} = \begin{bmatrix} \Delta\mathbf{u}(t|t) \\ \Delta\mathbf{u}(t+1|t) \\ \Delta\mathbf{u}(t+2|t) \\ \vdots \\ \Delta\mathbf{u}(t+N_p-1|t) \end{bmatrix};$$

$$\boldsymbol{\Psi}_t = [\tilde{\mathbf{A}}_t^1 \quad \tilde{\mathbf{A}}_t^2 \quad \tilde{\mathbf{A}}_t^3 \quad \cdots \quad \tilde{\mathbf{A}}_t^{N_p}]^T.$$

2.1.2 滚动优化

MPC 的目标是通过优化问题实现车辆轨迹跟踪性能的最优。在路径跟踪控制中,MPC 在每个采样时刻都需最小化状态偏差和控制增量,以实现最佳的轨迹跟踪性能和行驶稳定性^[12]。MPC 控制器的目标函数可设计为如下形式:

$$J(k) = \sum_{i=1}^{N_p} \|\boldsymbol{\eta}(k+i|t) - \boldsymbol{\eta}_{\text{ref}}(k+i|t)\|_{\mathbf{Q}_m}^2 + \sum_{i=1}^{N_p} \|\Delta\mathbf{U}(k+i|t)\|_{\mathbf{R}_m}^2 + \rho\epsilon^2 \quad (21)$$

其中: $J(k)$ 为 k 时刻的总代价量; \mathbf{Q}_m 、 \mathbf{R}_m 分别为 2 个优化目标的权重矩阵; $\boldsymbol{\eta}_{\text{ref}}$ 为参考轨迹变量; ρ 为权重系数; ϵ 为松弛因子,松弛因子的引入是为了防止目标函数出现无解的情况。

式(21)中等号右边第 1 项反映了系统对参考路径的跟踪能力,第 2 项反映了系统对控制量平稳变化的要求。

控制量和控制增量的约束表达式为:

$$\begin{cases} u_{\min}(t+k) \leq u(t+k) \leq u_{\max}(t+k), \\ \Delta u_{\min}(t+k) \leq \Delta u(t+k) \leq \Delta u_{\max}(t+k) \end{cases} \quad (22)$$

其中, $k=0, 1, \dots, N_c-1$ 。

将约束条件中的变量统一,以方便后续优化求解,可将式(22)转换为以下形式:

$$\begin{cases} (\mathbf{U}_{\min})_i \leq (\mathbf{A}_t \Delta \mathbf{U}_t + \mathbf{U}_t)_i \leq (\mathbf{U}_{\max})_i, \\ (\Delta \mathbf{U}_{\min})_i \leq (\Delta \mathbf{U}_t)_i \leq (\Delta \mathbf{U}_{\max})_i \end{cases} \quad (23)$$

其中: $\mathbf{U}_t = \mathbf{I}_{N_c} \otimes \mathbf{u}(k+1)$, \mathbf{I}_{N_c} 表示行数为 N_c 的列向量, $\mathbf{u}(k+1)$ 为上一时刻的控制量; \mathbf{U}_{\min} 、 \mathbf{U}_{\max} 分别表示控制量下界向量和上界向量集合; $\Delta \mathbf{U}_{\min}$ 、 $\Delta \mathbf{U}_{\max}$ 分别为控制增量下界向量和上界向量集合; \mathbf{A}_t 为 $N_c \times N_c$ 的单位下三角矩阵。

结合式(21)的目标函数以及式(23)的约束条件,进一步将 MPC 最优控制求解问题转换为标准二次规划问题:

$$\begin{aligned} \min J(\xi(t), \mathbf{u}(t-1), \Delta \mathbf{U}(t)) &= [\Delta \mathbf{U}(t)^T \quad \epsilon]^T \times \\ &\quad \mathbf{H}_t [\Delta \mathbf{U}(t)^T \quad \epsilon] + \mathbf{G}_t [\Delta \mathbf{U}(t)^T \quad \epsilon]; \\ \text{s. t.} \quad (\mathbf{U}_{\min})_i &\leq (\mathbf{A} \Delta \mathbf{U}_t + \mathbf{U}_t)_i \leq (\mathbf{U}_{\max})_i, \\ (\Delta \mathbf{U}_{\min})_i &\leq (\Delta \mathbf{U}_t)_i \leq (\Delta \mathbf{U}_{\max})_i \end{aligned} \quad (24)$$

其中

$$\mathbf{H}_t = \begin{bmatrix} \Phi_t^T \mathbf{Q}_m \Phi_t + \mathbf{R}_m & \mathbf{0} \\ \mathbf{0} & \rho \end{bmatrix}; \mathbf{G}_t = [\mathbf{2E}_t \mathbf{Q}_m \Phi \quad \mathbf{0}].$$

2.2 LQR 控制器设计

LQR 控制器的设计目的不仅是减小车辆的路径跟踪误差,还要同时保持车辆的稳定性并提升舒适性。可定义如下目标函数:

$$J = \sum_{i=0}^{\infty} (\mathbf{X}^T \mathbf{Q}_1 \mathbf{X} + \mathbf{u}^T \mathbf{R}_1 \mathbf{u}) \quad (25)$$

其中: \mathbf{Q}_1 、 \mathbf{R}_1 分别为状态量权重矩阵和控制量权重矩阵; \mathbf{X} 为系统状态量; \mathbf{u} 为系统控制量。

在 2.1 节 MPC 控制器设计中已经给出式(16)车辆离散的动力学模型,基于此模型构建路径跟踪二次型目标函数^[13]如下:

$$J(k) = \sum_{j=0}^{\infty} [\chi(k+j|t)^T \mathbf{Q}_1 \chi(k+j|t) + \mathbf{u}(k+j-1|t)^T \mathbf{R}_1 \mathbf{u}(k+j-1|t)] \quad (26)$$

式(26)中目标函数第 1 项反映车辆的跟踪精度,第 2 项反映控制量的变化约束情况。

假设 LQR 控制器的控制律为:

$$\mathbf{u} = -\mathbf{KX} \quad (27)$$

其中, \mathbf{K} 为状态反馈矩阵, $\mathbf{K} = [k_1 \quad k_2 \quad k_3 \quad k_4]$ 。

将式(27)代入式(25),可得:

$$J = \sum_{i=0}^{\infty} \mathbf{X}^T (\mathbf{Q}_1 + \mathbf{K}^T \mathbf{R}_1 \mathbf{K}) \mathbf{X} \quad (28)$$

假设存在常量对称矩阵 \mathbf{P} 使系统趋于稳定,可得:

$$\mathbf{K} = (\mathbf{R}_1 + \mathbf{B}^T \mathbf{P} \mathbf{B})^{-1} \mathbf{B}^T \mathbf{P} \mathbf{A} \quad (29)$$

其中,矩阵 \mathbf{P} 为 Riccati 方程解,即

$$\mathbf{P} = -\mathbf{A}^T \mathbf{P} \mathbf{B} (\mathbf{R}_1 + \mathbf{B}^T \mathbf{P} \mathbf{B})^{-1} \mathbf{B}^T \mathbf{P} \mathbf{A} + \mathbf{A}^T \mathbf{P} \mathbf{A} + \mathbf{Q}_1 \quad (30)$$

2.3 LSTM 控制器设计

LSTM 神经网络是一种特殊的递归神经网络(recursive neural network, RNN),其结构适合处理时序数据或依赖于历史信息的问题。本文中 LSTM 神经网络被用于学习 MPC 控制行为^[14-15],从而在车辆轨迹跟踪中逐步替代 MPC 控制器,实现控制的普适性和在线优化。

2.3.1 LSTM 在线学习模型

LSTM 神经网络模型的训练目标是最小化损失函数 E_{LSTM} ,从而使模型的预测 $\mathbf{u}_{\text{LSTM},i}$ 尽可能接近目标输出 $\mathbf{u}_{\text{MPC},i}$,以准确模拟 MPC 控制器的行为,在线学习流程图如图 3 所示。




图 3 LSTM 神经网络在线学习流程图

损失函数选用均方误差(mean square error, MSE)表示模型预测与目标值之间的偏差:

$$E_{\text{LSTM}} = \frac{1}{N} \sum_{i=1}^N \|\mathbf{u}_{\text{LSTM},i} - \mathbf{u}_{\text{MPC},i}\|_2^2 \quad (31)$$

其中: E_{LSTM} 为损失值,用以衡量 LSTM 模型输出与目标值之间的偏差程度; $\mathbf{u}_{\text{LSTM},i}$ 为 LSTM 模型的预测值; $\mathbf{u}_{\text{MPC},i}$ 为目标值,即 MPC 控制器的期望输出; N 为样本数量,表示用于训练的批量样本的总数。

梯度的计算用于确定每个参数的方向和步长,假设参数向量 θ , LSTM 模型使用梯度下降法来更新参数 θ ,以最小化损失函数:

$$\theta \leftarrow \theta - \eta \nabla_{\theta} E_{\text{LSTM}} \quad (32)$$

其中: θ 为 LSTM 模型的参数向量,包括输入权重、隐状态权重和偏置项; η 为学习率,表示控制每次迭代中参数的更新步长,学习率 η 动态调整以确保模型能快速收敛但不陷入局部最优; $\nabla_{\theta} E_{\text{LSTM}}$ 为损失函数对模型参数的梯度。

利用反向传播算法,将损失对模型各层参数的梯度传递回网络,即

$$\mathbf{W} \leftarrow \mathbf{W} - \eta \nabla_{\mathbf{W}} E_{\text{LSTM}} \quad (33)$$

其中, \mathbf{W} 包含输入权重矩阵 \mathbf{W}_{sh} 、隐状态下自反馈权重矩阵 \mathbf{W}_{hh} 和输出权重矩阵 \mathbf{W}_{hy} 。前向传播中

LSTM 的每个时刻 t 的隐状态 \mathbf{h}_t 输出 $\hat{\mathbf{y}}_t$ 通过以下公式计算:

$$\begin{aligned} \mathbf{h}_t &= f(\mathbf{W}_{\text{sh}}\mathbf{x}_t + \mathbf{W}_{\text{hh}}\mathbf{h}_{t-1} + \mathbf{b}_h), \\ \hat{\mathbf{y}}_t &= \mathbf{W}_{\text{hy}}\mathbf{h}_t + \mathbf{b}_y \end{aligned} \quad (34)$$

其中: \mathbf{b}_h 、 \mathbf{b}_y 为偏置向量; \mathbf{h}_t 为 LSTM 的隐状态, 表示对前一时刻和当前输入的记忆; $\hat{\mathbf{y}}_t$ 为 LSTM 在时刻 t 的输出预测; \mathbf{x}_t 为 LSTM 在时刻 t 的输入。梯度计算还用于确定模型输出与目标值之间的偏差, 以便在反向传播过程中更新模型的各个参数, 对每个 $\hat{\mathbf{y}}_t$ 计算损失的梯度为:

$$\nabla_{\hat{\mathbf{y}}_t} E_{\text{LSTM}} = \frac{\partial E_{\text{LSTM}}}{\partial \hat{\mathbf{y}}_t} = \frac{2}{n} (\hat{\mathbf{y}}_t - \mathbf{y}_t) \quad (35)$$

其中, \mathbf{y}_t 为时刻 t 的目标值。为防止梯度爆炸, 确保在线学习的稳定性, 设置梯度裁剪阈值 γ 。若

$$\|\nabla_{\theta} E_{\text{LSTM}}\| > \gamma, \text{ 则 } \nabla_{\theta} E_{\text{LSTM}} \leftarrow \gamma \frac{\nabla_{\theta} E_{\text{LSTM}}}{\|\nabla_{\theta} E_{\text{LSTM}}\|}.$$

2.3.2 LSTM 控制器输出

为了应对车辆行驶中的微小扰动或偏差并提高混合控制中 LQR 控制器的利用效率, 使用 LQR 作为辅助反馈控制器, 对 LSTM 生成的基础控制信号进行实时调整, 以提高系统的鲁棒性和控制精度。

LSTM 生成基础控制信号 \mathbf{u}_{LSTM} , LQR 补偿控制信号为 $\mathbf{u}_{\text{LQR}} = -\mathbf{K}_{\text{LQR}}\mathbf{e}_s$, \mathbf{e}_s 为实时状态误差, \mathbf{K}_{LQR} 为 LSTM 模型输入中提取的 LQR 增益矩阵。

定义状态误差的欧几里得范数 $\|\mathbf{e}_s\|$, 计算公式如下:

$$\|\mathbf{e}_s\| = \sqrt{4 \sum_i e_{s,i}^2} \quad (36)$$

定义权重系数 α , 用于平衡 LQR 和 LSTM 控制量, 范围为 $(0, 1]$, 计算公式如下:

$$\alpha = e^{-0.5 \|\mathbf{e}_s\|} \quad (37)$$

可得组合控制信号为:

$$\mathbf{u}_{\text{COM}} = (1 - \alpha)\mathbf{u}_{\text{LSTM}} + \alpha\mathbf{u}_{\text{LQR}} \quad (38)$$

为避免系统过激或失控并且提升系统鲁棒性, 使用 \tanh 函数对控制信号进行非线性激活处理, 使得控制信号限制在 $(-1, 1)$ 范围内:

$$\mathbf{u}_{\text{non}} = \tanh(\mathbf{u}_{\text{COM}}) \quad (39)$$

其中, \mathbf{u}_{non} 为非线性处理后的信号。

使用 FIFO 模式对缓冲区进行更新, 缓冲区更新公式为:

$$\mathbf{I}_{\text{buffer}} = (\mathbf{u}_2, \mathbf{u}_3, \dots, \mathbf{u}_n, \mathbf{u}_{\text{new}}) \quad (40)$$

其中, $\mathbf{I}_{\text{buffer}}$ 为缓冲区。

对缓冲区的历史信号和当前信号 \mathbf{u}_{non} 进行加权平均, 使用平滑因子 β_1 调整历史值与当前值的

权重分配:

$$\mathbf{u}_{\text{final}} = \beta_1 \frac{1}{M} \sum_{i=1}^M \mathbf{u}_i + (1 - \beta_1) \mathbf{u}_{\text{non}} \quad (41)$$

其中: $\mathbf{u}_{\text{final}}$ 为经过平滑因子 β_1 处理过后的输出最终控制信号; \mathbf{u}_i 为 $\mathbf{I}_{\text{buffer}}$ 缓冲区历史控制信号; M 为缓冲区长度。

2.4 前馈控制

为消除式(15)最后一项扰动矩阵所带来的稳态误差影响, 需要加入前馈控制使系统误差收敛至 0。定义前馈控制补偿转角为 δ_{ff} , 控制量为 $\bar{u} = -\mathbf{K}\mathbf{e}_{\text{rr}} + \delta_{\text{ff}}$, 假设添加前馈控制系统趋于稳定, 即 $\dot{\mathbf{e}}_{\text{rr}} = 0$, 经过计算可得前馈控制量为:

$$\delta_{\text{ff}} = \frac{\dot{C}_r}{v} \left[l_f + l_r - l_r k_3 - \frac{mv^2}{l_f + l_r} \left(\frac{l_r}{C_f} + \frac{l_f}{C_r} k_3 - \frac{l_f}{C_r} \right) \right] \quad (42)$$

其中, k_3 为状态反馈矩阵第 3 项。

MPC 控制器 k_3 未知, 对式(42)进一步推导可得:

$$\delta_{\text{ff}} = \frac{v^2}{R} \left(\frac{ml_r}{LC_f} - \frac{ml_f}{LC_r} \right) + k_3 e_{\varphi} + \frac{L}{R} \quad (43)$$

其中: R 为参考轨迹点的曲率半径; L 为车辆轴距。又前馈控制中忽略反馈项 $k_3 e_{\varphi}$, 因此 MPC 控制器前馈控制量可表示为:

$$\delta_{\text{ff}} = \frac{v^2}{R} \left(\frac{ml_r}{LC_f} - \frac{ml_f}{LC_r} \right) + \frac{L}{R} \quad (44)$$

3 混合控制策略实现

3.1 混合控制策略

本文设计混合控制策略, 通过动态切换机制和在线学习提高了轨迹跟踪的求解效率和跟踪精度。

混合控制框图如图 4 所示。




图 4 混合控制框图

在车辆处于高速运行阶段时, 控制系统采用 MPC 进行高精度轨迹跟踪, MPC 输出的控制信号作为系统的初始基准, 为后续在线学习提供数据支持; 当车辆从高速状态转为低速状态或状态误差在可接受的范围内时, 系统切换至 LQR 控

制模式;在 MPC 控制阶段,LSTM 神经网络通过学习 MPC 控制行为并逐步逼近 MPC 控制的效果,当损失值 E_{LSTM} 在给定误差范围内时,则用 LSTM 神经网络控制完全代替 MPC 控制,同时通过 LQR 反馈信号对当前状态误差提供反馈调整,补偿外部扰动或模型误差。

3.2 动态切换机制

3.2.1 LSTM 神经网络控制与 MPC 控制切换

在 MPC 控制阶段,LSTM 神经网络模型通过学习 MPC 控制行为以逐步逼近 MPC 控制的效果,若损失值 E_{LSTM} 在给定误差范围内,则用 LSTM 控制完全代替 MPC 控制,动态切换框图如图 5 所示。




图 5 LSTM 神经网络控制与 MPC 控制动态切换框图

定义 LSTM 神经网络控制与 MPC 控制条件切换阈值^[16]为 Q_{LSTM} ,当损失值 E_{LSTM} 在切换阈值 Q_{LSTM} 范围之内,表示 LSTM 控制满足误差要求可以代替 MPC 控制,否则使用 MPC 控制,LSTM 控制继续逼近 MPC 控制直至满足切换条件。切换阈值的选取既要避免阈值范围过大,导致损失值 E_{LSTM} 较大使 LSTM 控制无法精准逼近 MPC 控制行为,又要避免阈值范围过小,导致 LSTM 在线学习时间过长从而影响整个控制器效率,因此本文通过不同大小阈值的试验最终确定切换阈值 Q_{LSTM} 的范围为 $[0, 0.005]$,在该范围内 LSTM 控制既能较好地逼近 MPC 控制行为,又能避免在线学习过长。

为避免长期依赖学习模型 LSTM 导致的误差积累或锁定,设置定时器机制,确保系统能够周期性使用 MPC 控制模式以校准控制信号。

通过设置动态调整以及指数平滑算法以确保模式动态切换时的平稳性。定义误差即损失值 E_{LSTM} 的变化率 ΔE_{LSTM} 、误差变化率阈值 $Q_{\Delta E_{LSTM}}$ 以及切换平滑系数 α_{LSTM} 。

利用误差变化率 ΔE_{LSTM} 动态调整切换平滑系数 α_{LSTM} ,即

$$\alpha_{LSTM} = \begin{cases} \min(\alpha_{max}, \alpha_{LSTM} + 0.05), \Delta E_{LSTM} > Q_{\Delta E_{LSTM}}; \\ \max(\alpha_{min}, \alpha_{LSTM} - 0.05), \Delta E_{LSTM} \leq Q_{\Delta E_{LSTM}} \end{cases} \quad (45)$$

其中, $\Delta E_{LSTM} = |E_{LSTM} - E_{LSTM}^{last}|$ 。

采用指数平滑算法进行信号切换的平滑过渡:

$$s_k^{final} = \alpha_{LSTM} s_{k-1}^{smh} + (1 - \alpha_{LSTM}) s_k \quad (46)$$

其中: s_k 为当前控制模式信号, MPC 模式为 1, LSTM 模式为 -1; s_k^{smh} 为平滑处理后的控制模式信号。根据平滑后的信号 s_k^{smh} , 生成最终的二值控制模式 s_k^{final} 为:

$$s_k^{final} = \begin{cases} +1, & s_k^{smh} \geq 0.5; \\ -1, & s_k^{smh} < 0.5 \end{cases} \quad (47)$$

其中: $s_k^{final} = +1$, 表示控制系统处于 MPC 模式; $s_k^{final} = -1$, 表示控制系统处于 LSTM 模式。

3.2.2 MPC 控制与 LQR 控制切换

车辆处于低速或状态误差较小的状态时,系统从 MPC 切换至 LQR 控制。LQR 适用于低动态需求的场景,通过反馈调整快速响应,从而降低计算资源的使用。MPC 控制与 LQR 控制动态切换框图如图 6 所示。




图 6 MPC 控制与 LQR 控制动态切换框图

横向误差阈值 Q_{ed} 反映车辆实际行驶轨迹与参考轨迹之间的横向偏差是否足够小;航向误差阈值 Q_{ep} 用于判断车辆航向与目标航向之间的偏差;速度阈值 Q_v 用于判断车速是否较小。本文通过敏感性分析,根据车辆动力学模型以及控制量,在不同阈值条件下进行试验,经过分析 MPC 控制和 LQR 控制器对横向误差、航向误差和车速变化的敏感程度,最终确定 MPC 控制与 LQR 控制切换阈值的范围。在该范围内车辆状态基本稳定,动态需求较低,适合采用计算量小、响应快的 LQR 控制;而在该范围外车辆动态需求较高,则需要 MPC 控制以确保轨迹跟踪的高精度。定义 MPC 控制与 LQR 控制的切换阈值条件,见表 1 所列。

表 1 MPC 控制与 LQR 控制切换阈值参数

参数	名称	取值范围
Q_{ed}/m	横向误差阈值	$[-0.1, 0.1]$
Q_{ep}/rad	航向误差阈值	$[-0.05, 0.05]$
$Q_v/(m/s)$	速度阈值	$[0, 5]$

若在速度阈值或状态误差阈值范围内可切换为 LQR 控制,否则采用 MPC 控制通过 LSTM 进

行在线学习;当满足在线学习阈值 Q_{LSTM} ,由 LSTM 控制代替 MPC 控制。

类似于 LSTM 神经网络控制与 MPC 控制模式切换,LQR 控制与 MPC 控制模式切换同样设置动态调整以及指数平滑算法,以确保模式动态切换时的平稳性,此处不再重复叙述。

4 仿真实验

4.1 整车参数及仿真环境搭建

为验证混合控制策略的效果,本文通过 MATLAB/Simulink 与 CarSim 联合仿真验证控制算法的有效性,整车参数见表 2 所列。

表 2 整车参数

参数	名称	数值
m/kg	整车质量	1 412
C_f	前轮侧偏刚度	-55 801
C_r	后轮侧偏刚度	-81 284
$I_z/(\text{kg} \cdot \text{m}^2)$	转动惯量	1 536.7
l_f/m	质心到前轴距离	1.015
l_r/m	质心到后轴距离	1.895
L/m	轮距	1.675

4.2 仿真结果分析

本文选用双移线和蛇形轨迹作为目标轨迹,双移线工况能更好地反映车辆行驶的稳定性 and 精

确性,而蛇形工况下能反映车辆在连续弯道行驶时的操控稳定性。

分别在低速 36 km/h 和高速 72 km/h 下对 2 种轨迹进行轨迹跟踪仿真。为验证 LSTM 神经网络混合控制器的求解效率以及控制精度,对 LQR 控制器、MPC 控制器以及混合控制器 3 种不同控制模式下的轨迹跟踪效果、航向角、横向误差、航向误差、求解时间进行对比验证。

4.2.1 双移线工况仿真结果分析

双移线工况下,LQR 控制器、MPC 控制器以及混合控制器 3 种不同控制模式下的参考路径与跟踪路径、航向角、横向偏差、航向偏差测试结果如图 7 和图 8 所示。

由图 7 可知,双移线工况下,无论在 36 km/h 还是在 72 km/h 车速下,混合控制器的跟踪控制效果要优于单独使用 LQR 控制器和 MPC 控制器,且相较于 LQR 控制器有较大的提升,而且能够稳定跟踪目标位置与目标航向角。

由图 8 可知,双移线工况下混合控制器产生的横向偏差和航向偏差均小于单独使用 LQR 控制器或 MPC 控制器时的横向偏差和航向偏差。

车速 36、72 km/h 下 3 种不同控制器的横向误差和航向误差的平均值及最大值见表 3~表 6 所列。

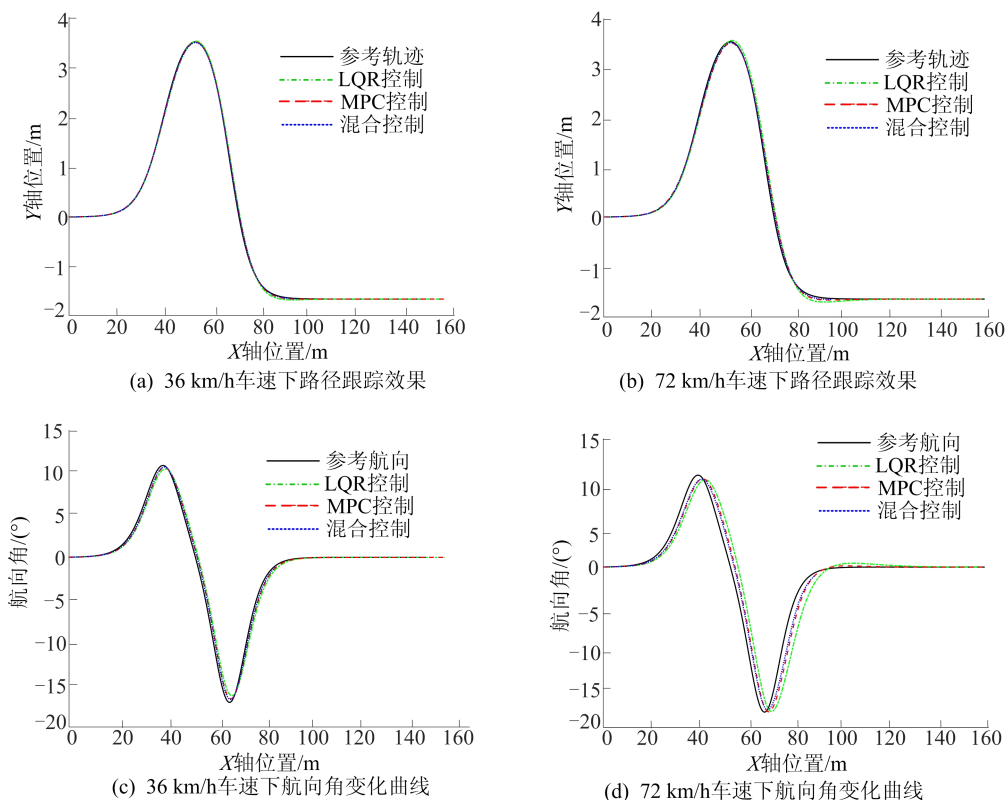


图 7 双移线工况下 3 种不同控制器的轨迹跟踪效果对比




图 8 双移线工况下 3 种不同控制器的误差变化曲线

表 3 36 km/h 车速下的横向误差平均值及最大值 单位:m

参数	LQR 控制器	MPC 控制器	混合控制器
平均横向误差	0.017 09	0.010 44	0.009 09
最大横向误差	0.095 07	0.065 86	0.058 52

表 4 36 km/h 车速下的航向误差平均值及最大值 单位:(°)

参数	LQR 控制器	MPC 控制器	混合控制器
平均航向误差	0.431 44	0.291 06	0.237 95
最大航向误差	2.097 03	1.493 70	1.289 73

由表 3 和表 4 可知在 36 km/h 车速下:相较于 LQR 控制器,混合控制器的平均横向误差和最大横向误差分别降低 46.8%和 38.4%,平均航向误差和最大航向误差分别降低 44.8%和 38.5%;相较于 MPC 控制器,混合控制器的平均横向误差和最大横向误差分别降低 12.9%和 11.1%,平均航向误差和最大航向误差分别降低 18.2%和 13.7%。

由表 5 和表 6 可知在 72 km/h 车速下:相较于 LQR 控制器,混合控制器的平均横向误差和最大横向误差分别降低 48.3%和 45.6%,平均航向误差和最大航向误差分别降低 53.8%和 42.0%;相较于 MPC 控制器,混合控制器的平均

横向误差和最大横向误差分别降低 6.8%和 12.6%,平均航向误差和最大航向误差分别降低 11.5%和 11.4%。

表 5 72 km/h 车速下的横向误差平均值及最大值 单位:m

参数	LQR 控制器	MPC 控制器	混合控制器
平均横向误差	0.052 43	0.029 07	0.027 09
最大横向误差	0.267 05	0.166 18	0.145 17

表 6 72 km/h 车速下的航向误差平均值及最大值 单位:(°)

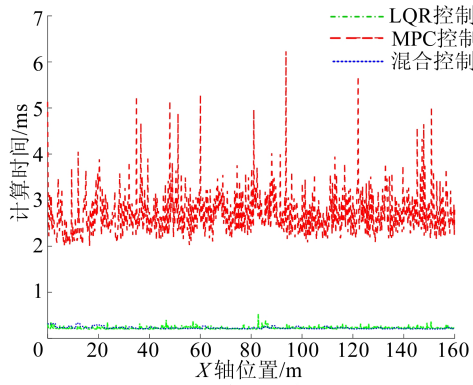
参数	LQR 控制器	MPC 控制器	混合控制器
平均航向误差	1.409 48	0.736 25	0.650 98
最大航向误差	5.562 27	3.640 00	3.225 25

因此,双移线工况下,无论是在低速还是在高速情况下,混合控制器的跟踪控制效果都优于 LQR 控制器和 MPC 控制器,并且通过设计的动态切换机制,保证了控制器在切换过程中车辆行使的稳定性。

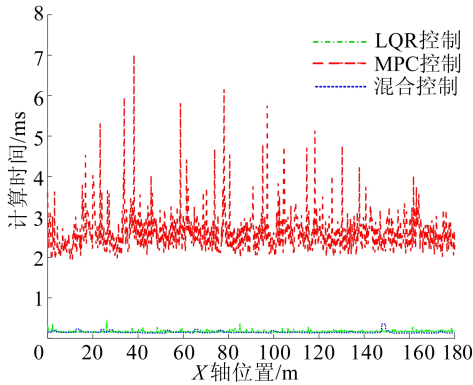
双移线工况下 LQR 控制器、MPC 控制器以及混合控制器的计算时间如图 9 所示。

由图 9 可知,无论是低速还是高速情况下,混合控制器相较于 MPC 控制器计算时间显著缩短

且求解效率大大提高。



(a) 36 km/h车速下求解时间对比



(b) 72 km/h车速下求解时间对比

图 9 双移线工况下 3 种不同控制器的计算时间对比

3 种不同控制器的计算时间见表 7、表 8 所列。

表 7 36 km/h 车速下 3 种控制器的计算时间 单位: ms

参数	LQR 控制器	MPC 控制器	混合控制器
平均计算时间	0.23	2.74	0.22
最大计算时间	0.53	6.23	0.32


表 8 72 km/h 车速下 3 种控制器的计算时间 单位: ms

参数	LQR 控制器	MPC 控制器	混合控制器
平均计算时间	0.17	2.59	0.21
最大计算时间	0.44	7.01	0.35


由表 7、表 8 可知:相较于 MPC 控制器,混合控制器在 LSTM 通过在线学习适应 MPC 后求解效率大幅度提高,混合控制器的平均计算时间降低 92.0%,最大计算时间降低 94.9%;相较于 LQR 控制器,混合控制器计算时间与其接近。

4.2.2 蛇形工况仿真结果分析

蛇形工况下,LQR 控制器、MPC 控制器以及混合控制器 3 种不同控制模式下的参考路径与跟踪路径、横向误差、航向误差测试结果如图 10 和图 11 所示。




(a) 36 km/h车速下路径跟踪效果图




(b) 72 km/h车速下路径跟踪效果图

图 10 蛇形工况下 3 种不同控制器的轨迹跟踪效果对比



(a) 36 km/h车速下横向误差变化曲线



(b) 72 km/h车速下横向误差变化曲线

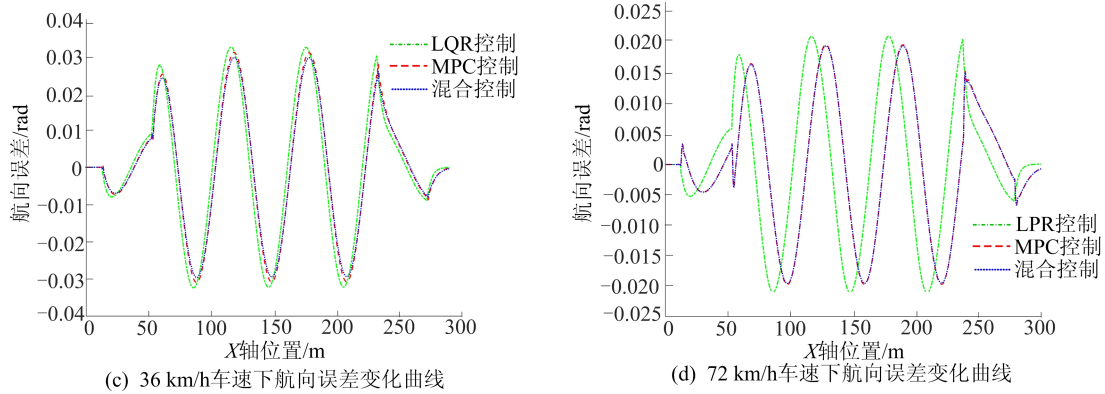


图 11 蛇形工况下 3 种不同控制器的误差变化曲线

从图 10 可以看出,无论车速为 36 km/h 还是 72 km/h,混合控制器的跟踪效果均优于 LQR 和 MPC 控制器,且较 LQR 控制器有显著提升。

由图 11 可知,蛇形工况下混合控制器产生的横向误差和航向误差同样小于单独使用 LQR 控制器或 MPC 控制器时的横向误差和航向误差。

车速 36、72 km/h 下 3 种不同控制器的横向误差平均值及最大值见表 9、表 10 所列。

由表 9 和表 10 可知:在车速 36 km/h 下,混合控制器的平均横向误差和最大横向误差比 LQR 控制器分别降低 46.4% 和 46.2%,比 MPC 控制器分别降低 13.5% 和 13.4%;而在车速 72 km/h 下,混合控制器的平均横向误差和最大横向误差比 LQR 控制器分别降低 47.3% 和 47.2%,比 MPC 控制器分别降低 14.3% 和 14.2%。

表 9 36 km/h 车速下的横向误差平均值及最大值 单位:m

参数	LQR 控制器	MPC 控制器	混合控制器
平均横向误差	0.014 99	0.009 30	0.008 04
最大横向误差	0.035 68	0.022 16	0.019 18

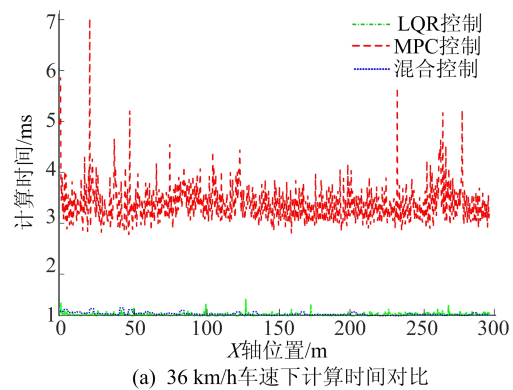
表 10 72 km/h 车速下的横向误差平均值及最大值 单位:m

参数	LQR 控制器	MPC 控制器	混合控制器
平均横向误差	0.032 85	0.020 20	0.017 32
最大横向误差	0.075 82	0.046 67	0.040 05

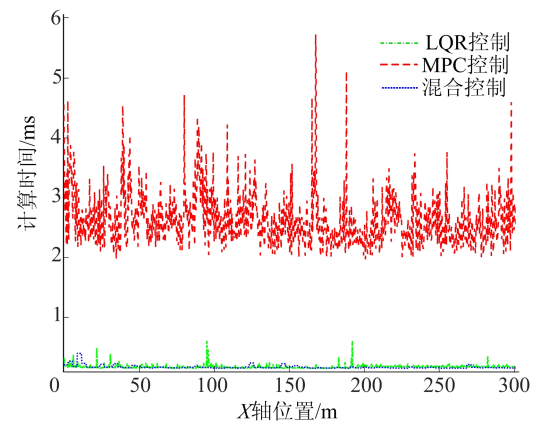
蛇形工况下,LQR 控制器、MPC 控制器以及混合控制器的计算时间如图 12 所示。

由图 12 同样可知,无论是低速还是高速情况下,相较于 MPC 控制器,混合控制器的计算时间显著缩短且求解效率大大提高。

3 种不同控制器的计算时间见表 11、表 12 所列。



(a) 36 km/h 车速下计算时间对比



(b) 72 km/h 车速下计算时间对比

图 12 蛇形工况下 3 种不同控制器的计算时间对比

表 11 36 km/h 车速下 3 种控制器的计算时间 单位:ms

参数	LQR 控制器	MPC 控制器	混合控制器
平均计算时间	0.21	2.35	0.24
最大计算时间	0.51	6.02	0.33

表 12 72 km/h 车速下 3 种控制器的计算时间 单位:ms

参数	LQR 控制器	MPC 控制器	混合控制器
平均计算时间	0.27	2.59	0.23
最大计算时间	0.61	7.01	0.40

4.2.3 仿真结果总结

综合以上双移线和蛇形工况下的仿真结果可

知,混合控制器不仅具有优于 LQR 控制器和 MPC 控制器的轨迹跟踪精度,还能大幅度提高 MPC 控制器的求解效率,解决了传统单一 LQR 控制器控制精度低以及单一 MPC 控制器计算成本高、求解效率低的问题,并且能够保证控制器切换的平稳性和车辆行驶的稳定性。

5 结 论

本文针对传统隐式 MPC 控制器计算成本高、求解效率低以及显示 MPC 受限于预计算的问题,设计了一种基于 LSTM 神经网络并结合 LQR 控制器与 MPC 控制器的混合控制策略。依据车速、车辆状态误差以及 LSTM 神经网络在线学习损失值,实现不同工况下不同控制算法的选择,在低速或者状态误差较小时采用 LQR 算法,在高速或者状态误差较大时采用 MPC 算法,并利用 LSTM 神经网络对 MPC 控制行为进行在线学习,当在线学习损失值小于给定阈值时,将由 LSTM 控制完全取代 MPC 控制进行跟踪控制,并通过 LQR 反馈调整以补偿动态环境中的扰动或误差。在此基础上,设计动态切换机制来确保不同控制器之间切换的稳定性。

MATLAB/Simulink 和 CarSim 联合仿真实验结果表明,本文设计的混合控制策略可实现不同控制算法的平稳切换,并且在保证控制精度的同时大幅度提高求解效率。

[参 考 文 献]

- [1] 关龙新,顾祖飞,张超,等.考虑系统复杂扰动的智能车模型预测路径跟踪控制[J].汽车工程,2022,44(12):1844-1855.
- [2] YAAKOUBI H,HAGGEGE J,REZK H,et al. Explicit hybrid MPC for the lateral stabilization of electric vehicle system[J]. Energy Reports,2024,11:1100-1111.
- [3] 赵树恩,王盛,冷姚.智能汽车轨迹跟踪多目标显式模型预测控制[J].汽车工程,2024,46(5):784-794.
- [4] YANG J Z,PENG H J,WU S N,et al. Differential-algebraic equation-based model predictive control for trajectory tracking of spacecraft-mounted continuum manipulators[J]. Aerospace Science and Technology,2024,155(P2):109615.
- [5] 冷姚,赵树恩.智能车辆横向轨迹跟踪的显式模型预测控制方法[J].系统仿真学报,2021,33(5):1177-1187.
- [6] 刘聪,刘辉,韩立金,等.基于学习型滑模预测控制的无人驾驶车辆非结构化环境轨迹跟踪及稳定性控制[J].机械工程学报,2024,60(10):399-412.
- [7] 杜荣华,胡鸿飞,高凯,等.基于变预测时域 MPC 的自动驾驶汽车轨迹跟踪控制研究[J].机械工程学报,2022,58(24):275-288.
- [8] WANG L W,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(3):315-325.
- [9] EUGENIO A,IURY B,VICENC P,et al. MPC using an online TS fuzzy learning approach with application to autonomous driving[J]. Applied Soft Computing Journal,2022,130:109698.
- [10] ARMIN N,SAEID S,DAVID G,et al. Deep learning based model predictive control for compression ignition engines[J]. Control Engineering Practice,2022,127:105299.
- [11] 潘世举,李华,苏致远,等.基于跟踪误差模型的智能车辆轨迹跟踪方法[J].汽车工程,2019,41(9):1021-1027.
- [12] 龚建伟.无人驾驶车辆模型预测控制[M].2版.北京:北京理工大学出版社,2020.
- [13] QIAN Y,WANG Z Q,LIANG W,et al. Research on automatic parking system based on linear quadratic regulator[J]. Engineering Computations,2021,39(3):1161-1179.
- [14] MIRZA H A,KERPICCI M,KOZAT S S. Efficient online learning with improved LSTM neural networks[J]. Digital Signal Processing,2019,86:12-21.
- [15] HUANG Z,WANG J,PI L,et al. LSTM based trajectory prediction model for cyclist utilizing multiple interactions with environment[J]. Pattern Recognition,2021,112:10780.
- [16] XU Z Y,WANG R J,CAO Y,et al. High-emitter identification for heavy-duty vehicles by temporal optimization LSTM and an adaptive dynamic threshold[J]. Frontiers of Information Technology & Electronic Engineering,2023,24(11):1633-1646.

(责任编辑 胡亚敏)