

车道保持模型预测控制中车辆模型简化推导及仿真分析

罗悦齐 魏强 岳凯

(上海汽车集团股份有限公司, 上海 201804)

【摘要】为提高车道保持控制中算法的计算效率,构建了模型预测控制(MPC)算法,基于刚体动力学推导出单轨车辆模型,并考虑横、纵向轮胎作用力特性作为标准车辆模型,在此基础上,忽略偏滑角和轮胎滑移率,推导出了简化车辆模型,该模型用线性方程表达车辆航向角变化率,省去轮胎模型,从而降低了MPC约束方程的复杂度。综合考虑跟踪误差、控制量及其变化率的代价项作为目标函数,对标准车辆模型和简化车辆模型的控制效果进行了仿真对比分析,结果表明,简化车辆模型在车道保持模型预测控制中取得了与标准车辆模型相近的控制效果,同时避免了车速接近0时无法求解轮胎模型的问题,且显著缩短了MPC优化求解耗时。

关键词:模型预测控制 车辆模型 车道保持

中图分类号:U461.1*91

文献标志码:A

DOI: 10.20104/j.cnki.1674-6546.20230149

Simplified Derivation of Vehicle Models for Lane-Keeping Model Predictive Control and Simulation Analysis

Luo Yueqi, Wei Qiang, Yue Kai

(SAIC Motor Corporation Limited, Shanghai 201804)

【Abstract】To improve calculation efficiency of lane-keep control algorithm, a Model Predictive Control (MPC) algorithm for lane-keeping was constructed. A single-rail vehicle model was derived based on rigid body dynamics. The standard vehicle model was based on rigid body dynamics and considered lateral and longitudinal tire force characteristic. Based on that, a simplified vehicle model was derived by assuming zero slip angle and slip ratio. The simplified model formulated yaw rate using linear equations and eliminated the tire model, thereby reducing the complexity of the constraint equations in the MPC. Considering the tracking error, control input, and the cost item of its change rate as the objective function, the control effect of standard vehicle model and simplified vehicle model were compared and analyzed. The results show that the simplified vehicle model achieves similar control performances to the standard model in lane-keeping MPC and avoids the problem of being unable to solve the tire model when the vehicle speed is close to zero. Additionally, the simplified model significantly reduces the computational time required for MPC optimization.

Key words: Model Predictive Control (MPC), Vehicle model, Lane-keeping

【引用格式】罗悦齐,魏强,岳凯.车道保持模型预测控制中车辆模型简化推导及仿真分析[J].汽车工程师,2024(5):26-32.

LUO Y Q, WEI Q, YUE K. Simplified Derivation of Vehicle Models for Lane-Keeping Model Predictive Control and Simulation Analysis[J]. Automotive Engineer, 2024(5): 26-32.

1 前言

随着辅助驾驶控制算法智能化程度和复杂程度的提升,算法的计算资源需求和整车成本相应提高^[1-3]。相较于传统的反馈控制算法,模型预测控制(Model Predictive Control, MPC)^[4-5]在辅助驾驶控制中能够获得更加平顺的控制效果,并降低系统的整

体复杂性^[6],但如何兼顾车辆模型精确度与计算效率仍有待深入研究^[7]。

Falcone等^[8]分别使用非线性车辆模型和实时线性化的车辆模型来实施模型预测控制,并基于冰雪路面对比测试了两种方案的计算复杂度和性能。Ji等^[9]定义了三维危险势能场,并生成实时无碰撞轨迹,基于横向位置、偏航率和偏滑角的状态

约束以及转向盘转角的输入约束构建了MPC算法。Lee等^[10]尝试采用显式MPC,使用多参数二次规划技术降低了计算负载。Babu等^[11]构建了基于交替极小化优化算法的MPC策略,发现在车辆模型中考虑执行器动力学可以改善自动驾驶的控制效果。Gao等^[12]提出了一种基于MPC的横向控制方案,通过小角度近似将车辆模型线性化,同时可保障控制的鲁棒性和精度。Yakub等^[13]对比研究了MPC和线性二次控制在路径跟踪中的效果,验证了MPC在轨迹跟踪和车辆稳定性方面表现更优秀。Dixit等^[14]介绍了一种用于在高速结构化环境中针对自主超车场景的轨迹规划框架,提出了表征道路安全区域的场函数作为MPC算法的边界条件,规避了碰撞避免等非凸约束的限制,满足了实时性要求。

为了提升MPC算法的计算效率和准确性,一些研究提出了离散化搜索算法与连续优化方法相结合的方法^[15-16]。对于非凸问题,首先通过离散搜索方法获得MPC的初始条件与边界条件,进而确保获得全局最优解。在模型本身的优化方面,Spielberg等^[17]开发了一套基于深度网络的车辆动力学模型,基于干燥路面和雨雪路面的组合数据对该深度网络模型进行了训练,测试结果显示,其对不同极端工况的预测能力有所提升。

针对车道保持控制中控制精度与计算效率难以兼顾的问题,本文构建车辆模型,并基于车道保持功能的核心控制目标对模型进行简化推导。最后,分别以简化前、后的车辆模型为基础,构建MPC算法并仿真分析两种模型的控制效果。

2 模型构建

2.1 车辆模型构建与简化推导

2.1.1 单轨车辆动力学模型

基于动力学的车辆模型包含了相对较多的参数,包括前、后车轮的作用力,以更准确地表达车辆的状态。如图1所示,将整车视为刚体,其运动遵循刚体动力学。




图1 车辆刚体动力学模型示意

本文将模型简化为二维平面运动,可描述为:

$$\begin{cases} m\ddot{x} = m\dot{y}\dot{\varphi} + F_x \\ m\ddot{y} = -m\dot{x}\dot{\varphi} + F_y \\ I_z\ddot{\varphi} = M_z \end{cases} \quad (1)$$

式中: x 、 y 分别为惯性坐标系下的横、纵坐标, φ 为车辆在惯性系下的航向角, m 为车辆质量, I_z 为车辆的转动惯量, F_x 、 F_y 分别为作用于整车的纵向力、横向力, M_z 为整车受到的转矩。

如图2所示,在直角惯性坐标系下将式(1)展开,并考虑轮胎模型,可得:

$$\begin{cases} \dot{X} = v_x \cos \varphi - v_y \sin \varphi \\ \dot{Y} = v_x \sin \varphi + v_y \cos \varphi \\ \dot{\varphi} = \omega \\ \dot{v}_x = \frac{1}{m} (F_{r,x} - F_{t,y} \sin \delta + m v_y \omega) \\ \dot{v}_y = \frac{1}{m} (F_{r,y} - F_{t,y} \cos \delta + m v_x \omega) \\ \dot{\omega} = \frac{1}{I_z} (F_{t,y} l_f \cos \delta - F_{r,y} l_r) \end{cases} \quad (2)$$

式中: X 、 Y 分别为自车在惯性系下的横、纵坐标, v_x 、 v_y 分别为车辆在自车坐标系下的纵向和横向速度分量, ω 为车辆航向角变化率, $F_{f,x}$ 、 $F_{r,x}$ 分别为前、后轮胎受到的纵向作用力, $F_{f,y}$ 、 $F_{r,y}$ 分别为前、后轮胎受到的横向作用力, δ 为前轮转角, l_f 、 l_r 分别为质心到前、后轴的距离。




图2 惯性直角坐标系示意

上述方程中的轮胎作用力由轮胎模型描述。由于本文采用了单轨车辆模型,轮胎作用力的计算分为前轮和后轮:

$$F_{t,y} = D_t \sin(C_t \arctan(B_t \alpha_t)) \quad (3)$$

$$\alpha_t = -\arctan[(\omega l_t + v_y)/v_x + \delta] \quad (4)$$

$$F_{r,y} = D_r \sin(C_r \arctan(B_r \alpha_r)) \quad (5)$$

$$\alpha_r = \arctan[(\omega l_r + v_y)/v_x] \quad (6)$$

$$F_{r,x} = (C_{m1} - C_{m2} v_x) d - C_{r0} - C_{rd} v_x^2 \quad (7)$$

式中: B_t 、 C_t 、 D_t 为前轮轮胎模型的参数, B_r 、 C_r 、 D_r 为后轮轮胎模型的参数,上述参数通常通过试验测定; α_f 、 α_r 分别为前、后轮偏滑角,即车轮轴向与车轮行

进方向之间的夹角; $d \in [-1, 1]$ 为动力总成系统的控制指令,1表示最大加速度,-1表示最大减速度,因本文模型仅针对上层控制量进行优化,故将 d 作为直接控制量,在实际应用中, d 通过底层控制器转换为电机转矩输出和制动力输出; C_{m1} 、 C_{m2} 为驱动力系数; C_m 为滚动摩擦系数; C_d 为空气阻力系数。

为了简化计算,纵向力的计算与横向力模型解耦。纵向力 F_{ix} 和 F_{rx} 包含了电机驱动力、滚动摩擦力和空气阻力。基于后轮驱动的设置,驱动力施加在后轮上。模型中的横、纵向力计算都忽略了轮胎滑移率。

2.1.2 车辆模型的简化

为了进一步降低模型预测控制的计算负载,本文基于一定的假设条件构建简化的单轨车辆模型,主要假设包括忽略轮胎作用力模型,忽略前、后轮偏滑角和滑移率,直接基于车辆的几何参数计算其运动状态,如图3所示。该简化模型的主要优势在于减少了模型参数,简化了非线性控制方程,从而提高计算效率。其潜在问题在于降低了模型精度,对较复杂工况可能无法准确预测,因此需要进一步评估其效果。




图3 简化车辆模型推导原理示意

本文所构建的简化车辆模型可表示为:

$$\begin{cases} \dot{X} = v \cdot \cos \varphi \\ \dot{Y} = v \cdot \sin \varphi \\ \dot{\varphi} = \frac{v \cdot \delta}{L} \\ \dot{v} = a \end{cases} \quad (8)$$

式中: v 为车速, L 为轴距, a 为加速度。

该简化模型的核心是航向角变化率的推导。结合图3的示意,首先假设前、后轮的轮胎偏滑角为0,轮胎滑移率为0,则前轮轴心速度 v 与前轮径向方向一致,进而可基于前轮转角 δ 计算前轮轴心横向速度 $v_{y_front} = v \cdot \sin \delta$,后轴中心(Center of Rear axle, CoR)的速度方向与后轮径向方向一致,而考虑到后

轮转角通常为0,可得后轮轴心横向速度为 $v_{y_rear} = v_{rear} \cdot \sin(0) = 0$,其中 v_{rear} 为CoR的速度。基于前轴中心(Center of Front axle, CoF)和CoR的横向线速度,CoR的角速度为:

$$\omega_r = (v_{y_front} - v_{y_rear}) / L = (v \cdot \sin \delta) / L \quad (9)$$

进一步,由于 δ 较小,可假设 $\sin \delta = \delta$ 。基于刚体运动的基本假设,有 $\omega = \omega_r$,可得出航向角变化率。

2.2 MPC 车道保持控制设计

2.2.1 控制目标

将车道保持系统的控制目标定义为:

$$J_t(X, U) = J_{\text{track_err}_t} + J_{U_t} + J_{\Delta U_t} \quad (10)$$

其中:

$$J_{\text{track_err}_t} = w_{e_{\text{ref}_t}} \|e_{\text{ref}_t}\|^2 + w_{e_{\varphi_t}} \|e_{\varphi_t}\|^2 + w_{e_{v_t}} \|e_{v_t}\|^2 \quad (11)$$

$$J_{U_t} = w_{\delta} \|\delta_t\|^2 + w_{\kappa} \|\kappa_t\|^2 \quad (12)$$

$$J_{\Delta U_t} = w_{\text{deriv}_\delta} \|\delta_t - \delta_{t-1}\|^2 + w_{\text{deriv}_\kappa} \|\kappa_t - \kappa_{t-1}\|^2 \quad (13)$$

式中: $J_t(X, U)$ 为目标函数,表征了 t 时刻的总价值; X 为状态量向量; U 为控制量向量; $J_{\text{track_err}_t}$ 为 t 时刻的跟踪误差; e_{ref_t} 为 t 时刻轨迹跟踪误差,即自车轨迹点与参考线的横向偏差,如图4所示; $w_{e_{\text{ref}_t}}$ 为轨迹跟踪误差代价项的权重系数; e_{φ_t} 为 t 时刻参考线航向角跟踪误差,即自车轨迹点航向角与参考线航向角的偏差; $w_{e_{\varphi_t}}$ 为航向角跟踪误差对应的权重系数; e_{v_t} 为 t 时刻目标速度跟踪误差,表征车辆纵向速度与目标速度的偏差; $w_{e_{v_t}}$ 为目标速度跟踪误差对应的权重系数; J_{U_t} 为 t 时刻的控制量代价项,其目标是优化 t 时刻的横向控制量 δ_t 和纵向控制量 κ_t ,避免过大幅度的操作; w_{δ} 、 w_{κ} 分别为横、纵向控制量的权重系数; $J_{\Delta U_t}$ 为 t 时刻的控制量变化率代价项,其目标是降低控制量的波动程度,进而使控制效果更加平滑; w_{deriv_δ} 、 w_{deriv_κ} 分别为横向控制量变化率、纵向控制量变化率的权重系数。




图4 跟踪误差示意

目标函数 $J_t(X, U)$ 与模型的状态向量和控制量向量相关,状态向量和控制量向量在2个车辆模型中有所不同。

e_{ref_t} 和 e_{φ_t} 在基于2个不同车辆模型所构建的MPC算法中物理意义是相同的,表达式分别为:

$$e_{\text{ref}_t} = y_{\text{ref}_t} - y_t \quad (14)$$

$$e_{\varphi_t} = \varphi_t - \varphi_{\text{ref}_t} \quad (15)$$

式中: y_{ref_t} 、 y_t 分别为 t 时刻参考线、模型预测轨迹的横坐标, φ_{ref_t} 、 φ_t 分别为 t 时刻参考线、模型预测轨迹的航向角。

2.2.2 基于标准车辆模型的模型预测控制

基于标准车辆模型,其预测控制算法可表达为如下优化问题:

$$\begin{aligned} \min_U \quad & \sum_{t=1}^N J_t(\mathbf{X}, \mathbf{U}) \\ \text{s.t.} \quad & \mathbf{X}_0 = \mathbf{X}(0) \\ & \mathbf{E}_0 = \mathbf{E}(0) \\ & \mathbf{X}_{t+1} = f_{\text{dyn}}(\mathbf{X}_t, \mathbf{U}_t) \\ & \mathbf{E}_{t+1} = f_{\text{dyn_err}}(\mathbf{X}_t, \mathbf{U}_t) \\ & \mathbf{U}_{\min} \leq \mathbf{U}_t \leq \mathbf{U}_{\max} \end{aligned} \quad (16)$$

式中: $\mathbf{X} = [X, Y, \varphi, v_x, v_y, \omega]^T$, $\mathbf{U} = [\delta, d]^T$, $\mathbf{E} = [e_{\text{ref}}, e_{\varphi}]^T$ 为偏差值向量, e_{ref} 、 e_{φ} 分别为轨迹跟踪误差和航向角跟踪误差, t 为预测步, N 为总预测步数, \mathbf{X}_0 、 \mathbf{E}_0 分别为初始时间步的状态量向量和偏差值向量, $\mathbf{X}(0)$ 、 $\mathbf{E}(0)$ 分别为状态量向量和偏差值向量的初始约束值, \mathbf{X}_t 、 \mathbf{E}_t 分别为 t 时间步的状态量向量和偏差值向量, \mathbf{U}_t 为 t 时间步的控制量向量, f_{dyn} 、 $f_{\text{dyn_err}}$ 分别为基于标准车辆模型的状态约束方程、偏差值约束方程, \mathbf{U}_{\min} 、 \mathbf{U}_{\max} 分别为控制量向量的下限和上限。

关于该优化问题中约束的构建,在每一个优化求解周期的初始时刻,需对状态向量和偏差向量进行初始化,用于初始条件约束。

具体而言,首先在方程推导中,车辆状态中采用的位置坐标 X 、 Y 和航向角 φ 是基于固定的直角惯性系推导获得的。但在实际的模型预测控制中,每一周期的求解初始化时,都将 X 、 Y 和 φ 重置为 0,即在每个求解周期的初始时刻,始终将惯性系重置到自车坐标系上,这主要是由于在计算跟踪偏差时采用的参考线通常是基于自车坐标系定义的,见图 4。因此,上述处理方法可使各周期内每个预测步的偏差值计算都在同一坐标系下,避免了反复进行坐标转换的操作。尽管在每个周期的初始预测步中统一了固定惯性系和车辆坐系统,但式(2)中的 X 、 Y 与 v_x 、 v_y 的关系将在预测窗口内的后续时间步中成立,这是推算预测轨迹所直接依赖的约束,见图 4。对于自车横、纵向速度与航向角变化率的初始步约束,则以当前时刻从车辆仿真器返回的实时状态数据为基础。偏差值的初始步约束以初始的状态值

和参考线数据为基础。

约束方程中 $\mathbf{X}_{t+1} = f_{\text{dyn}}(\mathbf{X}_t, \mathbf{U}_t)$ 是基于标准车辆模型的约束,其物理意义是基于车辆动力学特性限定所预测轨迹上的相邻状态点的关联。其具体的定义是式(2)的一阶展开形式:

$$\begin{bmatrix} X_{t+1} \\ Y_{t+1} \\ \varphi_{t+1} \\ v_{x_{t+1}} \\ v_{y_{t+1}} \\ \omega_{t+1} \end{bmatrix} = \begin{bmatrix} X_t + v_x \cos \varphi - v_y \sin \varphi \, dt \\ Y_t + v_x \sin \varphi + v_y \cos \varphi \, dt \\ \varphi_t + \omega \, dt \\ v_{x_t} + \frac{1}{m} (F_{r,x} - F_{f,y} \sin \delta + m v_y \omega) \, dt \\ v_{y_t} + \frac{1}{m} (F_{r,y} - F_{f,y} \cos \delta + m v_x \omega) \, dt \\ \omega_t + \frac{1}{I_z} (F_{f,y} l_f \cos \delta - F_{r,y} l_r) \, dt \end{bmatrix} \quad (17)$$

约束方程中 $\mathbf{E}_{t+1} = f_{\text{dyn_err}}(\mathbf{X}_t, \mathbf{U}_t)$ 是偏差值的约束,根据式(14)、式(15)的定义,其在标准车辆模型中的具体展开形式为:

$$\begin{bmatrix} e_{\text{ref}_{t+1}} \\ e_{\varphi_{t+1}} \end{bmatrix} = \begin{bmatrix} P(x_{t+1}) - (y_t + v_{y,t} dt) \\ \varphi_{t+1} - \arctan(\dot{P}(x_{t+1})) \end{bmatrix} \quad (18)$$

式中: P 为参考线多项式,其一阶导数的反正切值表征了参考线上各点的参考航向,将其与自车预测轨迹的航向角之差作为航向角偏差; x_{t+1} 为 $(t+1)$ 时刻参考线在自车坐标系下的纵向位置坐标; $v_{y,t}$ 为 t 时刻的自车横向速度。

约束方程中 $\mathbf{U}_{\min} \leq \mathbf{U}_t \leq \mathbf{U}_{\max}$ 是对控制量的约束,即控制量中的前轮转向角和纵向驱动请求都被约束在符合实际的范围内。除在式(16)中体现的约束外,其他状态值仅初始时刻存在约束,在后续预测步中均没有对状态值的直接约束。

2.2.3 基于简化车辆模型的模型预测控制

基于简化车辆模型的 MPC 车道保持控制的具体优化方程为:

$$\begin{aligned} \min_U \quad & \sum_{t=1}^N J_t(\mathbf{X}, \mathbf{U}) \\ \text{s.t.} \quad & \mathbf{X}_0 = \mathbf{X}(0) \\ & \mathbf{E}_0 = \mathbf{E}(0) \\ & \mathbf{X}_{t+1} = f_{\text{kin}}(\mathbf{X}_t, \mathbf{U}_t) \\ & \mathbf{E}_{t+1} = f_{\text{kin_err}}(\mathbf{X}_t, \mathbf{U}_t) \\ & \mathbf{U}_{\min} \leq \mathbf{U}_t \leq \mathbf{U}_{\max} \end{aligned} \quad (19)$$

式中: f_{kin} 、 $f_{\text{kin_err}}$ 分别为基于简化车辆模型的状态约束方程、偏差值约束方程。

其中,代价方程与基于标准车辆模型的控制算法是相同的。基于简化模型的控制中,状态向量为

$X=[X, Y, \varphi, v]^T$, 控制量向量为 $U=[\delta, a]^T$, 偏差值向量为 $E=[e_{ref}, e_{\varphi}]^T$ 。

$X_0=X(0)$ 和 $E_0=E(0)$ 分别为状态向量和偏差值向量的初始化约束, $X_{t+1}=f_{kin}(X_t, U_t)$ 为基于简化车辆模型对车辆状态值的约束。具体而言,其是基于简化车辆模型的微分方程组,即式(8)的一阶展开形式:

$$\begin{bmatrix} X_{t+1} \\ Y_{t+1} \\ \varphi_{t+1} \\ v_{t+1} \end{bmatrix} = \begin{bmatrix} X_t + v_t \cdot \cos(\varphi_t) dt \\ Y_t + v_t \cdot \sin(\varphi_t) dt \\ \varphi_t + \frac{v_t \cdot \delta_t}{L} dt \\ v_t + a_t dt \end{bmatrix} \quad (20)$$

对比基于标准模型的约束方程可知,简化模型减少了状态参数数量和约束方程数量,同时消除了高度非线性的轮胎模型计算项。

约束方程中 $E_{t+1}=f_{kin_err}(X_t, U_t)$ 是偏差值的约束,其在运动学模型下的具体展开形式为:

$$\begin{bmatrix} e_{ref_t+1} \\ e_{\varphi_t+1} \end{bmatrix} = \begin{bmatrix} P(x_{t+1}) - v_t \cdot \sin(e_{\varphi_t}) dt \\ \varphi_{t+1} - \arctan(\dot{P}(x_{t+1})) \end{bmatrix} \quad (21)$$

该方程与基于标准车辆模型的偏差值约束方程略有差异,其中与参考线的偏差量采用了近似计算结果。

2.2.4 模型优化求解方法

本文构建的2个MPC算法本质是对式(16)和式(19)所描述的非线性优化问题进行求解。预测窗口的采样时间步长为50 ms,预测步数 $N=20$,即预测时长为1 s,采用基于内点方法的非线性求解器(Interior Point OPTimizer, IPOPT)^[18]。在求解器的配置中,选择Exact计算海塞(Hessian)矩阵。具体而言,这种优化算法即是直接基于对应优化问题的目标函数和约束方程的二阶导数解析表达式来计算Hessian矩阵。类似地,对于雅可比(Jacobian)矩阵,也采用了相同的配置,即直接采用目标函数和约束方程的一阶导数表达Jacobian矩阵。这一配置在处理大型问题时计算成本较高,但求解精度更高。本文所求解的MPC问题规模不大且二阶导数较易获得,故采用上述求解器配置。另一方面,对于本文的MPC优化问题,由于其目标函数和约束方程基于一般物理特性构建,其Hessian矩阵和Jacobian矩阵通常是稀疏的^[19]。因此,在求解器配置中采用了稀疏矩阵表达,从而可以显著降低矩阵操作所需的内存,提高计算效率。最后,该优化问题的初始估计值选取需注意,对于标准车辆模

型,由于偏滑角的计算需求,车速的初始估计值不可取0。

3 仿真实验

3.1 仿真方法

为了对比分析基于不同复杂程度车辆模型的车道保持控制算法的控制效果,本文构建了闭环仿真环境^[20]。定位、感知等输入信息主要基于OpenStreetMap构建的道路模型进行模拟。通过解析地图道路拓扑,首先构建了导航路径。进一步,基于定位和导航信息及地图车道数据,规划了用于车辆控制的参考线。对于车辆运动状态数据的仿真,本文仿真环境中集成了10自由度的车动力学仿真模型^[21],该模型能够以足够的精度响应MPC控制器输出的控制量,并向控制器实时返回车辆状态信息,从而实现控制闭环。

3.2 车道跟踪效果对比

图5所示为基于标准车辆模型和简化车辆模型的车道保持行驶轨迹及车速分布情况。分别针对图示路口的3个不同行驶方向进行了测试,包含左转和右转场景,目标车速设定为10 m/s。




图5 采用不同车辆模型控制时的车道保持行驶轨迹

从图5中可以看出,基于简化车辆模型和标准模型的车道保持控制效果相近,在转向过程中均能保持居中,且控制轨迹平顺。采用标准车辆模型和简化车辆模型控制时车辆偏离车道中心线的最大

距离分别为 -0.51 m 和 -0.60 m 。基于2个模型的预测控制,均表现出了在入弯曲率变化时自动减速的效果。这是由于所构建的目标函数中综合考虑了循线位置偏差和车速偏差的代价项,当经过车道曲率变化较大位置时,降低了车速以获得更好的车道保持效果。相比于标准车辆模型,基于简化模型的控制中减速幅度略小,这主要是由于简化模型用线性方程表征了车速与航向角变化率的关联,相比于标准车辆模型,简化模型在一定程度上弱化了纵向速度对横向控制的影响,故其入弯时减速幅度较小。考虑到所测试场景为城区道路的路口工况,平均车速较低,故采用2种模型控制时的减速度差异对控制的安全性并无影响。

3.3 求解效率对比

图6所示为分别基于2个不同复杂程度车辆模型的MPC车道保持控制求解时间。从图6中可以看出,基于简化的车辆模型,优化求解耗时明显缩短:基于标准模型时的求解耗时平均值为 0.0192 s ,中位数为 0.0185 s ;基于简化模型时的求解耗时平均值缩短至 0.013 s ,中位数缩短至 0.014 s 。简化模型的求解效率提升,主要是由于运动学模型中忽略了轮胎作用力的计算,转而通过简化推导,直接建立了航向角变化率与车速及车辆转角的线性关系。这一简化,一方面避免了非线性轮胎模型的计算,另一方面减少了模型中约束方程的数量,从而实现了求解效率的提升。




图6 采用不同车辆模型控制时的求解时间对比

4 结束语

本文首先基于刚体动力学原理推导了单轨车辆模型并构建了轮胎模型,描述了通过前、后轮作用于车辆的横、纵向力,然后基于忽略偏滑角和轮胎滑移率的假设,推导了简化车辆模型,用线性方

程表达了车辆航向角变化率,减少了模型参数和方程数量,并考虑了跟踪误差、控制量和控制量变化率的代价项,基于不同复杂度的车辆模型分别设计了车道保持模型预测控制算法,最后,构建了闭环仿真环境,测试分析了2种模型的控制效果。研究结果表明,在车道保持模型预测控制中,简化车辆模型能够取得与标准模型相近的控制效果,且规避了标准模型中在车速接近0时无法求解轮胎模型的问题。同时,简化模型能够显著缩短MPC求解耗时,更有利于在实际工程应用中实现实时性的需求。

参考文献

- [1] YURTSEVER E, LAMBERT J, CARBALLO A, et al. A Survey of Autonomous Driving: Common Practices and Emerging Technologies[J]. IEEE Access, 2020, 8: 58443–58469.
- [2] DUARTE F. Self-Driving Cars: A City Perspective[J]. Science Robotics, 2019, 4(28).
- [3] LITMAN T. Autonomous Vehicle Implementation Predictions: Implications for Transport Planning[R]. Victoria, British Columbia Canada: Victoria Transport Policy Institute, 2020.
- [4] SORIA E, SCHIANO F, FLOREANO D. Predictive Control of Aerial Swarms in Cluttered Environments[J]. Nature Machine Intelligence, 2021, 3(6): 545–554.
- [5] MAYNE D Q. Model Predictive Control: Recent Developments and Future Promise[J]. Automatica, 2014, 50(12): 2967–2986.
- [6] GAO Y. Model Predictive Control for Autonomous and Semiautonomous Vehicles[D]. Berkeley, USA: University of California, Berkeley, 2014.
- [7] MUSA A, PIPICELLI M, SPANO M, et al. A Review of Model Predictive Controls Applied to Advanced Driver-Assistance Systems[J]. Energies, 2021, 14(23).
- [8] FALCONE P, BORRELLI F, ASGARI J, et al. Predictive Active Steering Control for Autonomous Vehicle Systems[J]. IEEE Transactions on Control Systems Technology, 2007, 15(3): 566–580.
- [9] 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, 2016, 66(2): 952–964.
- [10] LEE J, CHANG H J. Analysis of Explicit Model Predictive Control for Path-Following Control[J]. PloS ONE, 2018, 13(3).
- [11] BABU M, THEERTHALA R R, SINGH A K, et al. Model

- Predictive Control for Autonomous Driving Considering Actuator Dynamics[C]// 2019 American Control Conference (ACC), Philadelphia, PA, USA: IEEE, 2019: 1983-1989.
- [12] GAO H B, KAN Z, LI K Q. Robust Lateral Trajectory Following Control of Unmanned Vehicle Based on Model Predictive Control[J]. IEEE/ASME Transactions on Mechatronics, 2021, 27(3): 1278-1287.
- [13] YAKUB F, MORI Y. Comparative Study of Autonomous Path-Following Vehicle Control via Model Predictive Control and Linear Quadratic Control[J]. Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering, 2015, 229(12): 1695-1714.
- [14] DIXIT S, MONTANARO U, DIANATI M, et al. Trajectory Planning for Autonomous High-Speed Overtaking in Structured Environments Using Robust MPC[J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 21(6): 2310-2323.
- [15] CHUNG Y, YANG Y P. Hardware-in-the-Loop Simulation of Self-Driving Electric Vehicles by Dynamic Path Planning and Model Predictive Control[J]. Electronics, 2021, 10(19).
- [16] XIONG L, FU Z Q, ZENG D Q, et al. An Optimized Trajectory Planner and Motion Controller Framework for Autonomous Driving in Unstructured Environments[J]. Sensors, 2021, 21(13).
- [17] 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).
- [18] WÄCHTER A, BIEGLER L T. On the Implementation of an Interior-Point Filter Line-Search Algorithm for Large-Scale Nonlinear Programming[J]. Mathematical Programming, 2006, 106: 25-57.
- [19] RAKOVIC S V, LEVINE W S. Handbook of Model Predictive Control[M]. Cham, Switzerland: Birkhäuser Cham, 2018.
- [20] 周干, 张嵩, 罗悦齐. 自动驾驶汽车仿真测试与评价方法进展[J]. 汽车文摘, 2019(4): 48-51.
ZHOU G, ZHANG S, LUO Y Q. Progress in Virtual Test and Evaluation of Autonomous Vehicle[J]. Automotive Digest, 2019(4): 48-51.
- [21] POLACK P. Consistency and Stability of Hierarchical Planning and Control Systems for Autonomous Driving[D]. Paris, France: PSL Research University, 2018.

(责任编辑 斛 畔)

修改稿收到日期为2024年1月7日。

《汽车技术》征稿启事

《汽车技术》杂志是中国第一汽车集团有限公司主办的国内外公开发行的汽车前瞻与应用技术类月刊,为我国高质量科技期刊分级目录入选期刊、中国科学引文数据库(CSCD)来源期刊、中文核心期刊、中国科技核心期刊、RCCSE中国核心学术期刊(A)、俄罗斯《文摘杂志》(AJ)收录期刊。

《汽车技术》杂志以报道汽车整车及其零部件设计、研究、试验等方面的前瞻与应用技术为主,并兼有理论研究内容,是中国汽车行业核心学术和知识传播与共享的平台。

《汽车技术》将在国家提出的“创新、协调、绿色、开放、共享”发展理念的指引下,把握《节能与新能源汽车技术路线图》和“低碳化、信息化、智能化”的汽车技术主流发展趋势,努力在传统内燃机汽车高效动力系统、轻量化、低阻力领域,新能源汽车和互联智能汽车技术领域,大力吸收优质稿源,为广大科研和工程技术人员服务,为我国汽车工程技术创新能力提升贡献力量。

《汽车技术》欢迎高等院校师生、研发工程技术人员、技术管理人员及相关人员不吝赐稿,反映国家重点扶持项目、自然科学基金项目和其他重点项目等研究成果的稿件将被优先选择刊登。

投稿要求:

1. 文章字数最好控制在6 000~8 000字范围之内;
2. 请按科技论文要求撰写文章摘要,摘要中文字数控制在180字左右;
3. 文章必须附有公开发表的、体现本领域最新研究成果的参考文献,且在文中应标注文献引用处;
4. 文章主要作者应提供其简介,包括出生年、性别、职称、学历、研究方向及技术成果等;
5. 来稿的保密审查工作由作者单位负责,确保署名无争议,文责自负;
6. 请勿一稿多投;

7. 本刊使用网站投稿,请先登陆网站注册成功后投稿,详细投稿要求见本刊网站中“下载中心”栏目的“作者指南”,网址:<http://qej.s.cbpt.cnki.net>。

《汽车技术》编辑部