

DOI:10.16356/j.2097-6771.2026.03.010

## 车辆极限工况的谱稳定多专家 Koopman 动力学建模

陶奕然<sup>1</sup>, 宋廷伦<sup>1,2</sup>, 赵蕊<sup>1</sup>, 韩艺铭<sup>1</sup>, 崔向<sup>1</sup>

(1. 南京航空航天大学能源与动力学院, 南京 210016; 2. 奇瑞汽车股份有限公司, 芜湖 241007)

**摘要:** 针对现有数据驱动车辆动力学模型普遍缺乏物理可解释性, 限制了其在极限工况下的泛化性能, 致使模型易出现拟合失真与长时推演发散的问题, 本文构建了一种引入谱稳定性正则化的条件多专家 Koopman (Conditional multi-expert Koopman, CME-Koopman) 网络。在架构设计上, 该网络引入了一种条件感知门控机制, 根据车辆实时工况动态调度多个局部线性 Koopman 专家模型, 有效说明了车辆从线性区到非线性饱和区的动力学演化规律。针对多步预测易失稳的缺陷, 本文在损失函数中引入了基于幂迭代法的谱稳定性正则项, 显式约束 Koopman 算子特征值的模长, 从理论上保证了长时预测的有界性与渐进稳定性。在 CarSim 高保真仿真平台上的实验表明, 该方法在包含 40% 极限工况的数据集上, 长时预测误差均方根误差 (Root mean square error, RMSE) 较传统深度扩展动态模态分解 (Deep extended dynamic mode decomposition, Deep EDMD) 方法实现了大幅缩减, 并且准确还原了车辆处于失稳临界点时的渐近收敛特征。与模型预测控制器 (Model predictive control, MPC) 的闭环联合仿真, 进一步验证了该模型在极限工况下的工程潜力: 其不仅能在纵横向耦合的变工况中实现高精度的轨迹跟踪, 更能在路面附着系数骤降 ( $\mu$ -Jump) 的极端突变工况下, 为控制系统提供精准的预判, 展现出卓越的抗发散鲁棒性与极限防侧滑能力。

**关键词:** 车辆动力学; Koopman 算子; 混合专家; 谱稳定性; 模型预测控制器; 极限工况

**中图分类号:** U461 **文献标志码:** A **文章编号:** 1005-2615(2026)03-0569-11

## Spectrally Stable Multi-expert Koopman Dynamics Modeling for Vehicles Under Extreme Conditions

TAO Yiran<sup>1</sup>, SONG Tinglun<sup>1,2</sup>, ZHAO Rui<sup>1</sup>, HAN Yiming<sup>1</sup>, CUI Xiang<sup>1</sup>

(1. College of Energy and Power Engineering, Nanjing University of Aeronautics & Astronautics, Nanjing 210016, China;  
2. Chery Automobile Co., Ltd., Wuhu 241007, China)

**Abstract:** To address the lack of physical interpretability in existing data-driven vehicle dynamics models which limits their generalization performance under extreme handling conditions and makes them susceptible to fitting distortion and long-term prediction divergence, this paper proposes a conditional multi-expert Koopman (CME-Koopman) network incorporating spectral stability regularization. Architecturally, the network introduces a condition-aware gating mechanism that dynamically dispatches multiple local linear Koopman expert models based on real-time vehicle operating conditions, thereby effectively characterizing the dynamic evolution of the vehicle from the linear handling region to the nonlinear saturation region. To mitigate the inherent instability of multi-step predictions, a spectral stability regularization term based on the power iteration method is introduced into the loss function. By explicitly constraining the modulus of the Koopman operator's eigenvalues, this approach theoretically guarantees the boundedness and asymptotic stability of long-term predictions. Experiments conducted on the CarSim high-fidelity simulation platform demonstrate

**收稿日期:** 2026-03-01; **修订日期:** 2026-04-21

**通信作者:** 赵蕊, 女, 教授, 硕士生导师, E-mail: zhaorui39@nuaa.edu.cn。

**引用格式:** 陶奕然, 宋廷伦, 赵蕊, 等. 车辆极限工况的谱稳定多专家 Koopman 动力学建模[J]. 南京航空航天大学学报(自然科学版), 2026, 58(3): 569-579. TAO Yiran, SONG Tinglun, ZHAO Rui, et al. Spectrally stable multi-expert Koopman dynamics modeling for vehicles under extreme conditions[J]. Journal of Nanjing University of Aeronautics & Astronautics(Natural Science Edition), 2026, 58(3): 569-579.

that, on a dataset containing 40% extreme handling conditions, the proposed method achieves a substantial reduction in long-term prediction error, namely root mean square error (RMSE) compared to the traditional deep extended dynamic mode decomposition (Deep EDMD) baseline. Furthermore, it accurately reproduces the asymptotic convergence characteristics of the vehicle at the critical point of instability. Closed-loop co-simulation with a model predictive controller (MPC) further validates the model's engineering potential in extreme environments: It not only achieves high-precision trajectory tracking under strongly coupled longitudinal and lateral variable conditions, but also provides precise prediction of dynamics for the control system during sudden drops in road adhesion coefficient ( $\mu$ -Jump). This demonstrates its outstanding anti-divergence robustness and extreme sideslip prevention capabilities.

**Key words:** vehicle dynamics; Koopman operator; mixture of experts (MoE); spectral stability; model predictive controller (MPC); limit handling conditions

随着自动驾驶技术的快速发展<sup>[1]</sup>,行业对车辆高精度动力学建模与精确运动控制的要求日益严苛。车辆动力学建模作为自动驾驶运动控制系统的核心,其拟合精度与计算效率直接决定了模型预测控制器(Model predictive control, MPC)等闭环系统的控制性能<sup>[2]</sup>,尤其是在极限工况下的稳定性。

目前,车辆动力学建模方法主要分为基于物理机理的建模和基于数据驱动的建模两大类<sup>[3-5]</sup>。基于物理机理的模型,如二自由度自行车模型和七自由度整车模型等具有明确的物理可解释性,是目前工业界的主流选择<sup>[6]</sup>。然而,这类模型依赖于轮胎侧偏刚度、转动惯量等难以实时精确辨识的物理参数,且在描述高度耦合的非线性动力学特性时存在简化误差,难以适应复杂多变的行驶环境。相比之下,基于数据驱动的建模方法不依赖物理参数,直接从海量行驶数据中学习车辆状态演化规律,成为近年来的研究热点<sup>[7-10]</sup>。早期的研究多采用循环神经网络及其变体长短期记忆网络和门控循环单元来处理时序数据。文献[5]设计了一种基于物理信息的循环神经网络模型,利用门控机制捕捉车辆动态的时间相关性。文献[11]则结合物理信息神经网络与无迹卡尔曼滤波,在流形上实现了车辆状态的高精度估计。文献[12]提出了一种物理引导的迁移学习框架,通过将仿真模型中的物理先验知识迁移至神经网络,有效提升了车辆侧向动力学模型在噪声环境下的鲁棒性。文献[3]提出一种轻量化门控循环单元架构,在保证精度的同时降低了参数量。尽管各类深度神经网络在拟合精度上表现优异<sup>[13-14]</sup>,但这类“黑盒”模型缺乏明确的物理结构,难以利用经典控制理论分析闭环系统的稳定性,且由于缺乏对系统物理约束的表征,模型在面对未见过的极端工况时泛化能力较差,在多步迭代预测中极易产生累积误差甚至发散,限制了其在长时域控制任务中的应用。

为了兼顾数据驱动模型的高精度与控制理论所需的线性结构,Koopman算子理论引起了广泛关注<sup>[15-16]</sup>。该理论通过寻找观测函数将有限维非线性系统映射到无限维Hilbert空间,从而实现全局线性化描述。文献[17]提出一种基于深度扩展动态模态分解(Deep extended dynamic mode decomposition, Deep EDMD)的车辆建模方法,利用自动编码器自动学习观测函数,验证了其在MPC中的计算效率优势;文献[18]进一步提出随机模型预测控制框架,引入随机约束处理侧向动力学的不确定性;文献[19]将Koopman算子应用于磁流变阻尼器控制系统,验证了该理论在车辆底盘执行器控制中的工程潜力;文献[20]探索了物理信息自适应Deep Koopman模型,通过在线迭代更新系统矩阵以应对动力学参数的时变特性;文献[21]则通过设计切换区间观测器,有效解决了车辆侧向动力学中的参数不确定性与状态估计问题。

上述研究虽然验证了Koopman理论在控制上的优势,但其闭环性能始终受限于底层模型的拟合精度与稳定性。现有Deep Koopman方法虽然在车辆建模方面取得了一定进展,却依然难以解决极限工况下非线性特征捕捉与长时推演发散的核心问题。现有架构大多假设存在单一的全局线性算子来描述全工况动力学,然而车辆在轮胎力饱和区表现出强烈的非线性特征,单一算子在兼顾线性区的高效拟合的同时难以捕捉饱和区的非线性特征。此外,现有研究多以最小化多步预测误差为目标,缺乏对算子谱属性的显式约束,容易导致算子特征值模长大于1,违背了物理系统的能量耗散特性,从而在长时域滚动推演中引发数值发散。

针对上述问题,本文提出一种带有谱稳定性正则化的条件多专家Koopman(Conditional multi-expert Koopman, CME-Koopman)网络。该方法首先设计条件感知门控机制,根据车辆实时工况动态融合多个局部线性Koopman专家模型,精

准表示了车辆从线性区到非线性饱和区的动力学演化机理。其次,在损失函数中引入基于幂迭代法的谱稳定性正则项,显式约束特征值模长,从理论上保证长时预测的有界性与渐进稳定性。最后,通过CarSim高保真仿真及MPC闭环控制实验验证了所提方法的有效性。

## 1 车辆动力学Koopman建模基础

### 1.1 车辆动力学问题描述

自动驾驶车辆的运动状态变化遵循复杂的物理规律,但在离散时间域内,其状态演化可被描述为一个非线性动力学系统。设 $k$ 时刻系统的状态向量为 $\mathbf{x}_k \in \mathbf{R}^n$ ,控制输入向量为 $\mathbf{u}_k \in \mathbf{R}^m$ 。在本研究中,选取车辆纵向速度 $v_x$ 、侧向速度 $v_y$ 及横摆角速度 $\dot{\phi}$ 构建状态向量 $\mathbf{x}_k = [v_x, v_y, \dot{\phi}]^T$ ,选取前轮转角 $\zeta$ 与油门输入 $\eta$ 构建控制向量 $\mathbf{u}_k = [\zeta, \eta]^T$ 。车辆动力学演化遵循非线性映射 $f: \mathbf{R}^n \times \mathbf{R}^m \rightarrow \mathbf{R}^n$ ,即

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

在本文中,“极限工况”特指车辆在高速大曲率转向、紧急避障或路面附着系数突变等场景下,由于轮胎侧偏角急剧增大或地面附着边界急剧收缩,导致轮胎侧向力进入非线性饱和区甚至逼近附着椭圆边界的物理临界失稳状态。由于车辆在极限工况下轮胎侧偏特性呈现强非线性,若直接将非线性模型用于MPC控制器设计,构建的优化问题通常是非凸的,难以保证求解效率。因此,寻求一种既能保留非线性动力学特征,又具备线性系统计算优势的建模方法,是实现极限工况高效控制的关键。

### 1.2 Koopman算子理论与局限性

针对上述非线性控制难题,Koopman算子理论提供了一种全局线性化的解决方法。不同于基于Jacobi矩阵的局部线性化方法,该理论将有限维非线性系统提升至无限维Hilbert空间,使其在提升空间内表现为线性特征。定义观测函数集 $\psi: \mathbf{R}^n \rightarrow \mathbf{R}^N$ ,将原始状态 $\mathbf{x}_k$ 映射为高维潜在状态 $\mathbf{z}_k = \psi(\mathbf{x}_k)$ 在此空间中,非线性演化可近似由Koopman矩阵 $\mathbf{K}$ 、控制矩阵 $\mathbf{B}$ 和解码矩阵 $\mathbf{C}$ 描述的线性系统代替

$$\begin{cases} \mathbf{z}_{k+1} \approx \mathbf{K}\mathbf{z}_k + \mathbf{B}\mathbf{u}_k \\ \mathbf{x}_{k+1} \approx \mathbf{C}\mathbf{z}_{k+1} \end{cases} \quad (2)$$

传统的Deep EDMD方法试图用单一的全局矩阵 $\mathbf{K}$ 描述全工况动力学。然而,如图1所示,车辆轮胎侧向力在侧偏角较大( $>6^\circ$ )时进入饱和区,呈现出显著的非线性特征。此时,单一线性算子产生的拟合误差急剧增大,且缺乏对算子谱半径的约束,极易导致长时预测发散。




图1 轮胎非线性特性与线性拟合误差

Fig.1 Nonlinear tire characteristics and linear fitting errors

由于车辆动力学在极限工况下表现出显著的非线性与时变特征,传统Deep EDMD所用的全局线性算子已无法满足全状态空间的高精度逼近需求。因此,需要引入一种能够根据当前工况自适应调整演化算子的动态建模机制。

## 2 条件多专家Koopman网络架构

### 2.1 网络整体架构

由于车辆在极限工况下表现出的强非线性与时变特性,单一的全局线性Koopman算子难以满足全状态空间的拟合精度要求,且易在长时推演过程中产生累积误差。为此本文构建了一种CME-Koopman网络架构,旨在通过构建局部线性专家模型库并感知实时工况进行动态加权融合,从而在保留Koopman算子线性形式优势的同时,实现对车辆复杂非线性动力学特性的精准拟合。

该网络采用端到端学习范式,整体架构如图2所示,主要由残差编码器、条件多专家算子模块及解码器3部分组成。具体而言,残差编码器负责学习最优观测函数,将低维非线性物理状态映射至高维潜在空间。条件多专家算子模块用门控网络生成的动态权重,对专家矩阵进行线性组合以推演潜在状态的时间演化轨迹。解码器则负责执行逆映射操作,将演化后的潜在状态重构回物理空间,从而完成从当前时刻状态到下一时刻状态的闭环预测。

### 2.2 条件感知门控机制

为精准捕捉车辆动力学的多模态切换特征,在演化模块前引入条件感知门控机制。如图3所示,该机制首先将车辆当前的物理状态 $\mathbf{x}_k$ 与控制输入 $\mathbf{u}_k$ 进行拼接,作为描述当前行驶工况的先验条件。随后,将拼接向量输入至由全连接层构成的轻量级多层感知机(Multilayer perceptron, MLP)中,提取隐含的工况特征向量 $\mathbf{c}_k$ 。最后,特征向量经由Softmax激活函数处理,输出一组归一化的动态概率权重 $\alpha$ ,第 $i$ 个权重的计算公式为

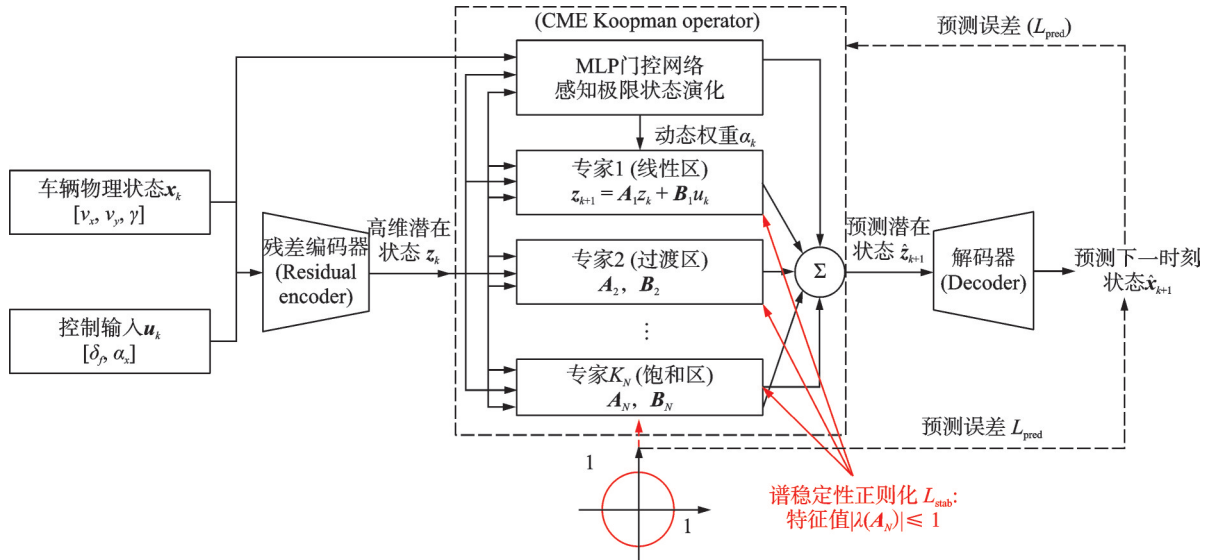


图2 谱正则化 CME-Koopman 网络总体架构

Fig.2 Overall architecture of the spectral-regularized CME-Koopman network

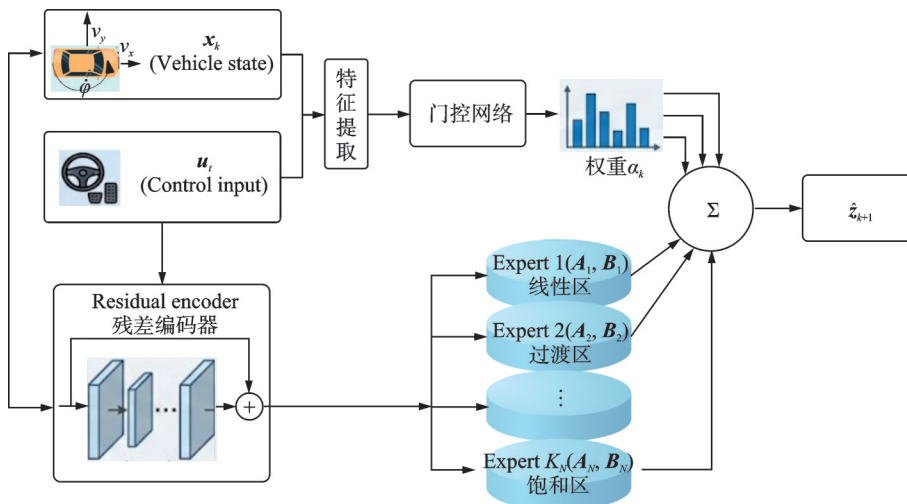


图3 条件感知门控机制与权重生成网络

Fig.3 Condition-aware gating mechanism and weight generation network

$$\alpha_i(x_k, u_k) = \frac{\exp(W_i c_k + b_i)}{\sum_{j=1}^N \exp(W_j c_k + b_j)} \quad (3)$$

式中:  $\alpha_i(x_k, u_k)$  表示第  $i$  个动力学模态在  $k$  时刻的激活程度, 物理上对应于车辆处于线性区、过渡区或饱和区的概率;  $W_i$  与  $b_i$  代表门控网络输出层的权重与偏置参数。

### 2.3 基于动态权重的多专家线性演化

针对 1.2 节所述单一全局算子难以兼顾极限工况拟合精度的局限性, 本节提出了条件多专家演化架构。考虑到车辆在极限工况下的非线性行为主要受轮胎侧偏力主导, 且动力学演化具有明显的阶段性, 本网络构建了包含  $N$  个局部线性演化矩阵的 Koopman 专家算子库  $\{A_1, A_2, \dots, A_N\}$ 。关于专家数量  $N$  的选取, 与车辆轮胎底层物理特性有

关。典型的轮胎侧偏特性在物理上可自然划分为线性区、非线性过渡区与极限饱和区。当  $N=1$  时, 模型退化为传统方法, 难以覆盖轮胎力饱和区的非线性特征。当  $N \geq 4$  时, 则缺乏明确的物理对应关系且会引入计算冗余。因此, 本文选取  $N=3$ , 使各个局部专家分别隐式对应上述 3 个典型的动力学区间。基于多专家策略的车辆非线性动力学区域划分如图 4 所示, 通过门控机制的调度, 模型能够针对不同工况自动匹配最合适的专家算子。

在引入控制输入后, 高维潜在空间中的 Koopman 演化可被解析为状态转移与控制作用两部分。在状态推演时, 模型并不依赖单一算子, 而是根据门控网络输出的动态权重, 将模型库中的多个局部专家状态转移矩阵  $K$ , 进行加权融合, 生成全局状




图4 基于多专家策略车辆非线性动力学区域划分

Fig.4 Region division of vehicle nonlinear dynamics based on multi-expert strategy

态转移矩阵  $A$ , 并结合全局控制输入矩阵  $B$ , 实现潜在状态的线性演化

$$A = \sum_{i=1}^N \alpha_i(x_k, u_k) K_i \quad (4)$$

$$z_{k+1} = A z_k + B u_k \quad (5)$$

式中:  $K_i$  为第  $i$  个局部专家的状态转移矩阵;  $A$  为加权融合后的全局状态转移矩阵;  $B$  为控制输入矩阵, 用于表征控制量  $u_k$  对高维状态的线性驱动作用;  $z_k$  和  $z_{k+1}$  分别为当前时刻与下一时刻的高维观测状态。

需要说明的是, 动态权重  $\alpha$  的数值由神经网络自主计算得出。在模型训练阶段, 生成权重的门控网络与底层的专家算子库会进行同步优化, 网络通过大量的数据, 自动学习车辆当前行驶状态与各个局部专家模型之间的对应关系。在实时预测阶段, 前文提到的 Softmax 激活函数发挥了关键作用。由于该函数具有连续可导的数学特性, 当车辆的输入状态发生微小且连续的变化时, 网络输出的权重  $\alpha$  也会随之发生平滑的过渡。因为全局系统矩阵  $K$  是由各个专家矩阵按权重叠加而成的, 所以权重的平滑过渡直接带动了全局矩阵及其特征值的平稳变化。这种网络固有的连续映射机制, 使得模型在跨越线性区、过渡区和饱和区等不同行驶工况时, 能够实现动力学特性的无缝衔接, 从而保证了拟合过程的高效与稳定。

#### 2.4 状态重构解码器

由多专家演化策略获取下一时刻的潜在状态  $z_{k+1}$  后, 需将其逆映射回低维物理空间以实现车辆动力学状态的闭环预测。为此, 本节设计了状态重构解码器  $\phi^{-1}: \mathbf{R}^L \rightarrow \mathbf{R}^n$ 。为了在降低维度的同时保留关键动力学特征, 该解码器采用 MLP 架构, 其网络层级结构设定为 [32, 16, 3], 即通过维数逐层递减的全连接层剔除潜在空间中的冗余高频信息并重构物理流形。解码过程可表示为

$$\hat{x}_{k+1} = \phi^{-1}(\hat{z}_{k+1}; \theta_{\text{dec}}) \quad (6)$$

$$\hat{x}_{k+1} = S(W_{\text{out}} \cdot \sigma(\sigma(W_i z_{k+1} + b_i)) + b_{\text{out}}) \quad (7)$$

式中:  $\theta_{\text{dec}}$  为解码器可学习参数集;  $\sigma(\cdot)$  为隐藏层的 ReLU 激活函数;  $W_i$  与  $b_i$  分别为第  $i$  层的权重矩阵与偏置向量;  $W_{\text{out}}$  与  $b_{\text{out}}$  分别为第  $i$  层的权重矩阵与偏置向量。为确保输出状态具有明确的物理意义及数值边界, 输出层引入 Sigmoid 激活函数  $S(\cdot)$ , 将预测值  $\hat{x}_{k+1}$  约束在归一化区间  $[-1, 1]$  内, 最后通过反归一化恢复为实际物理量。

### 3 谱稳定性正则化与模型训练

CME-Koopman 网络虽然通过多专家策略提升了对非线性特征的拟合能力, 但若将其直接应用于 MPC 等长时域推演场景, 动力学模型的数值稳定性至关重要。

#### 3.1 离散线性系统的谱稳定性判据

根据离散时间线性系统理论, 对于离散时间系统  $z_{k+1} = A z_k$ , 根据李雅普诺夫稳定性理论, 系统的渐进稳定性取决于全局状态转移矩阵  $A$  的谱半径  $\rho(A)$ , 即其特征值的最大模长。若  $\rho(A) > 1$ , 系统能量将随时间步呈指数级增长, 导致预测轨迹发散。

由于全局矩阵  $A$  是各专家矩阵的线性凸组合 ( $\sum \alpha_i = 1$  且  $\alpha_i \geq 0$ ), 根据矩阵分析中的凸组合性质, 若每个局部专家矩阵  $K_i$  的谱半径均满足  $\rho(K_i) \leq 1$ , 则融合后的全局矩阵  $A$  亦能满足稳定性要求。因此, 为确保闭环控制系统的数值稳定性与预测收敛性, 必须在训练过程中对算子库中每个专家矩阵  $K_i$  的特征值施加硬性约束。

#### 3.2 基于幂迭代法的谱半径估计

传统的深度学习训练通常仅以最小化有限时域内的均方误差 (Mean-square error, MSE) 为目标, 缺乏对算子谱属性的显式约束。为在保证高精度拟合的同时赋予模型物理稳定性, 本文提出引入谱稳定性正则化策略。考虑到在反向传播过程中对高维矩阵进行全特征值分解计算复杂度过高且易导致梯度不稳定, 本文采用幂迭代法对每个  $K_i$  最大特征值进行快速估计。对于任意专家矩阵, 引入随机初始化向量  $v$ , 经  $q$  次迭代后, 利用 Rayleigh 商近似计算其谱半径

$$\hat{\rho}(K_i) \approx \frac{\|A_i^q v\|_2}{\|A_i^{q-1} v\|_2} \quad (8)$$

基于得到的谱半径  $\hat{\rho}(K_i)$ , 本文构建了一个基于 Hinge Loss 形式的谱稳定性正则项

$$L_{\text{stab}} = \sum_{i=1}^N \max(0, \hat{\rho}(K_i) - (1 - \epsilon)) \quad (9)$$

式中  $\epsilon$  为预设的安全裕度常数, 在本文中设定为 0.01。

从系统演化角度看,  $\epsilon$  决定了算子特征值趋近单位圆的物理边界, 实质是调节瞬态拟合精度与长时预测稳定性的折中关系。较小的  $\epsilon$  允许特征值贴近稳定性临界点, 有利于捕获强非线性瞬态响应, 但会增加多步推演的发散风险; 而过大的  $\epsilon$  虽能提升系统稳健性, 却会过度约束模型的动态表征能力。经敏感性分析验证, 本文取  $\epsilon = 0.01$ , 以在确保系统严格收敛的前提下, 最大限度保留模型对极限工况的拟合精度。

### 3.3 复合损失函数

为实现模型精度、线性一致性与稳定性的多目标优化, 本文设计了复合损失函数为

$$L = \lambda_1 L_{\text{rec}} + \lambda_2 L_{\text{pred}} + \lambda_3 L_{\text{lin}} + \lambda_4 L_{\text{stab}} \quad (10)$$

式中:  $L_{\text{rec}}$  为重构损失, 保证潜在空间能准确表征物理状态;  $L_{\text{pred}}$  为多步预测损失, 提升模型的长时外推能力;  $L_{\text{lin}}$  为线性一致性损失, 约束高维空间满足线性演化规律;  $L_{\text{stab}}$  为上述谱稳定性正则项。为在潜在空间的重构精度、长时推演能力与数值稳定性之间取得最优平衡, 本文在模型训练中将各损失项的权重系数分别设定为:  $\lambda_1 = 1.0, \lambda_2 = 2.0, \lambda_3 = 0.5, \lambda_4 = 0.1$ 。其中, 赋予多步预测损失  $L_{\text{pred}}$  较大的权重, 旨在强制网络优先优化长时外推能力; 而为谱稳定性正则项  $L_{\text{stab}}$  分配较小的权重, 则是将其作为一种软约束, 以避免过度的正则化惩罚抑制模型对高度非线性瞬态特征的捕获能力。

## 4 试验验证

### 4.1 实验设置

#### 4.1.1 仿真平台与车辆模型

本研究依托 CarSim 高保真动力学仿真平台开展实验。为充分激发车辆在极限工况下的非线性动力学响应, 本文选用一款 C 级前轮驱动 (Front-wheel drive, FWD) 轿车作为对象进行仿真建模, 该模型配置了非线性悬架系统及 Pacejka 5.2 魔术公式轮胎模型, 能够真实反映车辆在高速大侧偏角下的侧滑失稳行为。为保证仿真模型的物理保真度, 本文基于 CarSim 平台搭建了高保真整车动力学模型。考虑到极限工况下跌宕起伏的载荷转移效应, 本研究设定车辆处于标准满载荷况, 其核心动力学参数与尺寸如表 1 所示。

#### 4.1.2 数据集与预处理

为覆盖车辆从线性区到非线性饱和区的全动力学特性, 选取不同路面附着系数 ( $\mu \in [0.3, 0.85]$ ) 下的正弦扫描及双移线 (Double lane change, DLC) 等作为测试工况。针对常规数据分布中常规样本冗余而极限样本较少的问题, 采用加

表 1 车辆模型关键动力学参数

参数	数值
整车质量 $m/\text{kg}$	1 412
绕 Z 轴转动惯量 $I_z/(\text{kg}\cdot\text{m}^2)$	1 536.7
质心至前轴距离 $l_f/\text{m}$	1.015
质心至后轴距离 $l_r/\text{m}$	1.895
轮胎侧偏刚度 $C_{af}/(\text{kN}\cdot\text{rad}^{-1})$	65
轮胎侧偏刚度 $C_{ar}/(\text{kN}\cdot\text{rad}^{-1})$	61
静态前轴荷载分配比例 $W_f/\%$	55.1
静态后轴荷载分配比例 $W_r/\%$	44.9

权混合采样策略, 使涉及轮胎力饱和的强非线性数据占比提升至 40%。采样频率设定为 100 Hz, 累计采集有效样本点约 3 000 000 个, 该数据集剔除了常规直线巡航等低价值样本, 专注于高频激发的极限动态工况, 其所包含的非线性特征信息密度远高于数小时的常规道路驾驶数据。

为模拟真实车载传感器测量的不确定性, 缩小仿真环境与真实物理情景的差距, 在采集的理想状态量中叠加高斯白噪声。具体而言,  $v_x$  和  $v_y$  叠加标准差  $\sigma_v = 0.02 \text{ m/s}$  的噪声,  $\dot{\phi}$  叠加标准差  $\sigma_{\dot{\phi}} = 0.005 \text{ m/s}$  的噪声。

在模型输入前, 对所有状态变量  $x$  与控制输入  $u$  进行 Min-Max 归一化处理, 将其映射至  $[-1, 1]$  区间。随后, 将数据集按 7:1:2 的比例划分为训练集、验证集和测试集。其中, 测试集选用完全独立于训练样本的完整轨迹序列, 以严格验证模型在未知工况下的长时推演与泛化能力。

### 4.2 模型训练与消融实验分析

#### 4.2.1 网络超参数与训练环境

由于车辆的物理状态与控制输入均为低维向量, 本文的残差编码器与解码器均采用基于全连接层的残差多层感知机架构。每一个残差块包含两个全连接层, 并在输入与输出之间引入跳跃连接以缓解梯度消失问题。门控网络则采用轻量级的标准 MLP。各模块的具体层级、神经元数量及激活函数如表 2 所示。

在训练环境方面, 实验基于 PyTorch 深度学习框架, 在 NVIDIA RTX 3090 GPU 平台上进行训练。网络权重初始化采用 Xavier 均匀分布, 网络优化器选用 Adam, 初始学习率设为  $1 \times 10^{-3}$ , 批次大小为 256, 训练周期为 200 epochs。为定量评估模型性能, 采用均方根误差 (Root mean square error, RMSE) 作为精度指标, 并统计单步推理耗时以评估实时性。

#### 4.2.2 模块有效性消融分析

为验证本文提出的多专家架构与谱稳定性正则化的必要性, 本节在保持训练数据集、超参数设

表 2 CME-Koopman 网络核心模块参数设置

Table 2 Parameter settings of core modules in CME-Koopman network

网络模块	层级名称	神经元数量	输出维度
残差编码器(Encoder)	输入层		$n_x$
	残差块 1	64, 64	64
	残差块 2	64, 64	64
	输出映射层	128	$n_z$
条件门控网络(Gating)	拼接输入层		$n_x + n_z$
	隐藏层 1	32	32
	输出层	3	$N$
解码器(Decoder)	输入层		$n_z$
	隐藏层 1	64	64
	隐藏层 2	64	64
	输出层	$n_x$	$n_x$

置及网络基础维度完全一致的前提下,构建了两组对比模型进行消融实验。对比基准包括:传统 Deep EDMD 方法(基线 1)、仅引入混合专家(Mixture of experts, MoE)机制但未施加谱约束的中间模型(基线 2)以及本文提出的完整 CME-Koopman 模型。

为了重点考察模型的长时推演能力,实验选取测试集中所有样本的未来 30 步状态轨迹作为预测对象。采用 RMSE 作为精度评价指标,并统计预测轨迹在相平面上的发散率以评估数值稳定性。各模型在包含 40% 极限工况的测试集上的性能指标统计如表 3 所示。

为了进一步直观评估模型在不同测试样本上的误差分布特性与鲁棒性,图 5 展示了 3 组模型在长时预测任务中的 RMSE 分布箱线图。图 5 中箱体的高度反映了模型预测性能的离散程度,而箱上方的离群点则直观揭示了模型在少数极端样本下的失效风险。

从表 3 的量化对比可见,传统的 Deep EDMD 模型由于采用单一全局算子,难以兼顾极限工况下

表 3 不同模型架构的性能消融试验对比

Table 3 Performance ablation experiment comparison of different model architectures

模型架构	谱半径	RMSE ( $v_y$ )/ ( $m \cdot s^{-1}$ )	RMSE ( $\dot{\phi}$ )/ ( $rad \cdot s^{-1}$ )	单步推理 耗时/ms
Deep EDMD (基线 1)	1.042	0.045	0.038	0.82
无谱正则 MoE Spec-Reg (基线 2)	1.015	0.018	0.012	0.94
CME-Koopman (本文方法)	0.998	0.009	0.007	0.95

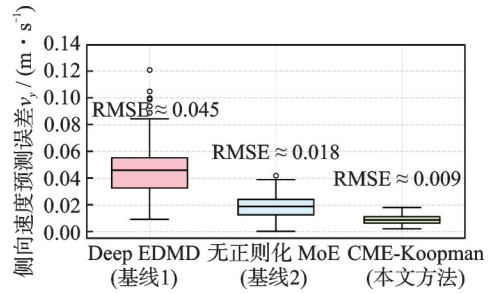


图 5 预测误差分布箱线图

Fig.5 Boxplot of prediction error distribution

的强非线性特征,导致 RMSE 处于较高水平。更为关键的是,其算子最大特征值模长  $\rho(A)$  达到 1.042 ( $> 1$ ),这在动力学上意味着系统能量将随时间呈指数级增长,存在显著的数值发散风险。在引入 MoE 机制后(基线 2),凭借条件多专家机制对不同动力学工况下局部特征的精细化表征能力,模型对  $v_y$  和  $\dot{\phi}$  的拟合精度相比 Deep EDMD 提升了约 60%;然而,在缺乏谱正则化约束的情况下,其谱半径  $\rho(A)$  仍为 1.015,表明模型虽然精确度较高,但在数值上依然处于弱不稳定状态,长时推演仍无法保证有界性。相比之下,本文提出的 CME-Koopman 方法通过联合优化,在保持最低预测误差的同时,成功将谱半径严格约束在单位圆内 ( $\rho = 0.998 < 1$ ),这表明谱稳定性正则项成功地将物理系统的耗散特性嵌入了神经网络,实现了精度与稳定性的双重最优。

从图 5 可见,Deep EDMD 等基准模型在极限工况下存在显著的误差波动与离群点发散现象。而引入谱正则化后,本文模型展现出紧凑的误差分布与极低的离群率,成功抑制了长时推演中的累积误差。此外,0.95 ms 的单步推理耗时远小于 10 ms 控制步长,说明该方法在实车嵌入式计算平台中部署的可行性。

### 4.3 极限工况长时预测性能

在完成模型训练验证后,进一步在极限工况下评估模型的长时开环预测能力。长时预测的累积误差是检验动力学模型是否掌握物理规律的核心指标。

#### 4.3.1 低附着路面正弦转向工况

选取路面附着系数  $\mu = 0.4$  的低附着路面进行高频正弦转向测试,车速恒定为 72 km/h。该工况通过施加大幅度的正弦方向盘转角输入,能够迅速激发车辆的瞬态侧偏响应并进入非线性饱和区。图 6 展示了 DeepEDMD 与本文方法在未来 300 步内的预测轨迹对比。从图 6 可见,随着预测步长的增加,Deep EDMD 的预测轨迹逐




图6 低附着路面正弦转向工况下的预测轨迹对比

Fig.6 Comparison of predicted trajectories under sinusoidal steering conditions on low-adhesion roads

渐偏离真值,表现出明显的发散趋势;而 CME-Koopman 凭借条件门控机制,能够精准感知车辆大幅度转向过程中的侧偏状态变化,其预测轨迹始终较好地贴合原曲线,体现了优异的长时推演稳定性。

#### 4.3.2 动力学相平面分析

为了说明模型对车辆非线性稳定边界的刻画能力,图7绘制了侧向速度-横摆角速度( $v_y-\dot{\phi}$ )相平面图。相轨迹的收敛性直接反映了车辆系统的稳定性。

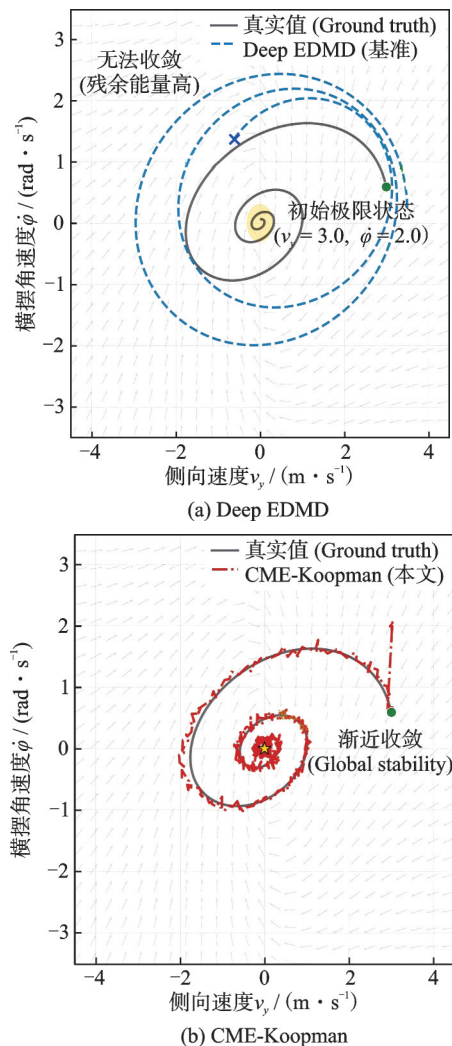


图7 相平面图轨迹对比

Fig.7 Phase plane trajectory comparison

从图7可见,在极限转向过程中,车辆真实的相轨迹呈现出典型的螺旋收敛特征。Deep EDMD 预测的相轨迹在大幅值区域出现向外扩散的现象,表明其未能正确学习到车辆的阻尼耗散特性。相比之下,CME-Koopman 预测的相轨迹不仅在形态上与真值高度重合,且准确复现了车辆从失稳边缘回到稳定平衡点的收敛过程。这表明本文提出的谱正则化策略有效地赋予了神经网络符合物理规律的耗散特性,避免了非物理的能量增长。

#### 4.4 复杂变工况与极端突变工况闭环控制验证

构建高精度动力学模型的最终目的是与高性能控制器 MPC 进行联合仿真。为全面验证 CME-Koopman 模型在处理纵横向耦合、非线性饱和以及极度未知扰动下的控制效能,本节设计了两种极具挑战性的闭环测试场景,并从跟踪精度、控制平滑性及抗扰鲁棒性3个维度进行综合评估。

##### 4.4.1 控制器设计与测试场景设置

基于上文训练得到的 CME-Koopman 动力学模型,构建线性模型预测控制器。利用 Koopman 算子的全局线性形式,原本复杂的非线性优化问题可转化为标准的凸二次规划(Quadratic programming, QP)问题求解。控制器的优化目标函数设计为

$$J = \sum_{i=1}^{N_p} (\|z_{k+i|k} - z_{ref,k+i|k}\|_Q^2 + \sum_{i=0}^{N_c-1} \|\Delta u_{k+i|k}\|_R^2) \quad (11)$$

式中:预测时域  $N_p = 20$ ,控制时域  $N_c = 5$ ;状态权重矩阵  $Q = \text{diag}[10, 1, 5]$ ,分别以此强化对  $v_x$ 、 $v_y$  及  $\dot{\phi}$  的跟踪精度;输入权重矩阵  $R = \text{diag}[0.1, 0.1]$ ,用于抑制控制输入的剧烈抖动; $\Delta u$  为控制增量。

在闭环联合仿真平台的工程部署方面,本文实现了深度学习框架与传统控制求解器的高效跨平台交互。具体而言,在离线训练完成后,3个 Koopman 专家模型的状态转移矩阵( $A_1, A_2, A_3$ )与控制矩阵( $B_1, B_2, B_3$ )作为常数矩阵被提取并存储。而包含非线性激活函数的门控网络与观测器模块,则通过 ONNX 格式导出,并利用 MATLAB 的 Deep Learning Toolbox 部署至 Simulink 环境中。在每个控制周期内,Simulink 将当前时刻的车辆物理状态  $x_k$  输入至门控网络,实时计算出各专家的动态调度权重  $\alpha_i$ ,进而在极短时间内加权组装出当前时刻的全局线性演化算子  $A_k$  与  $B_k$ ,并将其作为时变参数传入 MPC 控制器进行滚动优化,从而实现了完整闭环数据流。

为了全方位检验该闭环系统的性能边界,本文设定了以下两个层递式的极限测试场景。

场景 I (纵横向强耦合变工况):如图 8(a)所示,车辆首先从静止加速至 80 km/h,随后以该速度通过大曲率弯道,最后进行线性制动。该场景旨在考察模型在纵向变速与横向转向强耦合下的精准跟踪能力。

场景 II (附着系数跃变极端工况):如图 8(b)车辆以 100 km/h 的极高边缘速度过弯,在  $t=4$  s 时刻路面附着系数突然由干燥柏油路 ( $\mu=0.8$ ) 跌至冰雪路面 ( $\mu=0.3$ )。该场景旨在考察模型在面临超越常规操作极限的环境突变时,多专家门控机制的瞬态响应与抗发散鲁棒性。

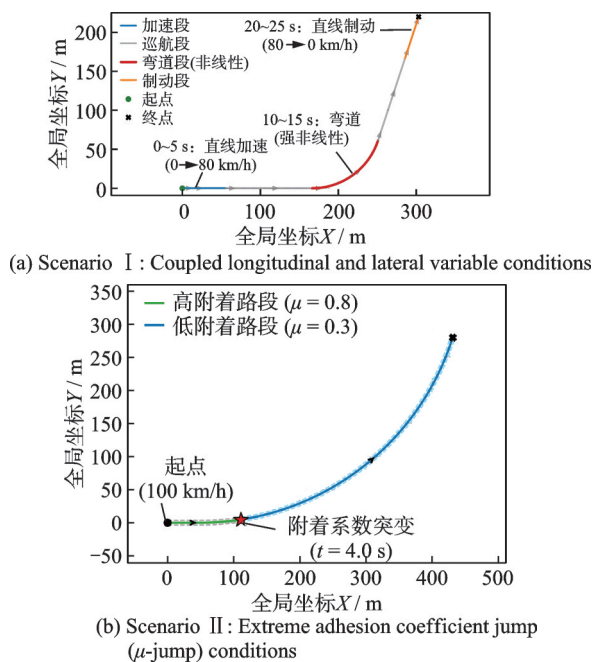


图 8 闭环控制双测试场景参考轨迹与工况设定  
Fig.8 Schematic of reference trajectories and scenario settings for dual closed-loop control test scenarios

#### 4.4.2 纵横向强耦合工况跟踪性能分析

在场景 I 的测试中,图 9 展示了两种不同模型 (Deep EDMD-MPC 与本文 CME-MPC) 的闭环空间轨迹跟踪表现。从图 9 可见,在早期的直线加速段,两种模型表现相当。但在 10~15 s 的非线性大曲率弯道区域,Deep EDMD-MPC (蓝线) 不仅产生了显著的向外漂移,更呈现出明显的震荡轨迹。左上角的局部放大图清晰地展示了这一失稳现象,表明单一算子基准模型已无法维持高速过弯时的稳定控制。相比之下,CME-MPC (红线) 在整个过弯过程中轨迹平滑且高度贴合参考路径,证明了多专家融合策略在非线工况下的闭环准确性。

在验证了宏观层面的轨迹跟踪能力后,为了进一步探究控制器在微观状态维持与执行器动作层面的具体表现,图 10 展示了该场景下微观状态与执行器动作的响应细节。图 10(a) 的侧向速度跟踪效

果表明,Deep EDMD-MPC 受限于全局线性假设,在弯道区域无法准确描述轮胎饱和特性,导致模型预测与实际动力学严重失配。而 CME-MPC 则能紧跟目标侧向动态,且图 10(b) 显示其输出的归一化控制输入更加平稳,有效避免了高频的转向抖动,保证了执行器的寿命与乘坐舒适性。




图 9 场景 I 下的闭环轨迹跟踪对比  
Fig.9 Comparison of closed-loop trajectory tracking under Scenario I

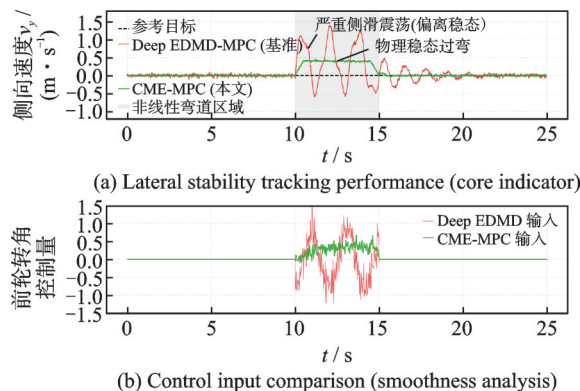


图 10 场景 I 下的车辆微观状态与控制输入对比  
Fig.10 Comparison of vehicle states and control inputs under Scenario I

#### 4.4.3 附着系数突变 ( $\mu$ -Jump) 极端工况鲁棒性分析

在验证了系统于场景 I 中的变工况跟踪精度后,本节重点针对场景 II 展开极端抗扰鲁棒性分析。

从轮胎动力学机理来看,车辆在高速过弯时遭遇附着系数的断崖式跌落,会导致轮胎侧偏刚度与极限侧向力瞬间坍塌,车辆的可用附着椭圆急剧收缩。若预测模型无法在极短的控制周期内感知到该物理边界的剧变,MPC 控制器将因预测失配而输出过量的转向指令,导致车辆彻底失控。图 11 详细展示了两种模型在该极端扰动下的闭环响应过程。

结合图 11(a) 的全局闭环轨迹与图 11(b) 的横向跟踪误差演化可以清晰地观察到:在前 4.0 s 的高附着阶段,两种模型均能维持稳定的弯道跟踪。然而,在突变触发后,传统 Deep EDMD-MPC (蓝线) 由于全局单一算子的局限性,其内部模型仍按高附着状态进行线性推演,导致控制指令与实际物理规律严重脱节。车辆随即发生剧烈的侧滑甩尾,




图 11 场景 II (附着系数跃变极端工况) 闭环鲁棒性测试结果

Fig.11 Closed-loop robustness test results under Scenario II (extreme  $\mu$ -jump conditions)

其横向误差在仿真末端误差已突破 30 m, 车辆完全脱离有效赛道。相比之下, 本文提出的 CME-MPC (红线) 展现出了卓越的极限救车能力。在遭遇  $\mu$ -Jump 瞬间, 车辆虽不可避免地产生了约 1 m 的瞬态侧偏; 但得益于非线性演化预判的迅速修正, 车辆轨迹呈现渐近收敛特征。在后续长达 16 s 的低附着弯道推演中, 车辆被平稳拉回参考路径, 横向误差重新收敛至零域附近。

CME-MPC 能够实现上述极限防侧滑控制, 其核心在于底层物理状态感知与专家算子的毫秒级重

构。图 11(c) 揭示了门控机制在全周期内的动态调度规律: 线性巡航期 ( $t < 1.8$  s): 车辆处于直线段, 状态变量处于线性区间, 网络主要激活专家 1; 常规过弯期 ( $1.8 \text{ s} \leq t < 4.0$  s): 车辆进入大曲率弯道, 轮胎侧偏角增大, 门控网络平滑切换至主导非线性过渡区的专家 2; 突变饱和期 ( $t \geq 4$  s): 在路面冰雪突变的瞬间, 门控机制凭借高敏的条件感知能力, 在不到 0.05 s 内敏锐捕捉到了状态空间  $x_k$  的剧变, 将表征极限饱和特征的专家 3 权重瞬间拉升至 0.9 以上。

这种契合车辆动力学物理机理的专家调度, 使得模型在环境剧变时瞬间抛弃失效的线性假设, 为 MPC 提供了精准的预判。该结果证实了引入谱稳定性正则化的条件多专家架构在应对极端未知扰动时的不可替代性与长时推演稳定性。

## 5 结 论

本文针对车辆极限工况下动力学建模精度与长时稳定性不足的问题, 提出了一种引入谱稳定性正则化的 CME-Koopman 建模方法, 并通过 Car-Sim 仿真与闭环控制实验验证了该方法的有效性。主要结论如下:

(1) 提出了一种基于条件感知门控的多专家 Koopman 网络架构。针对全局线性算子难以表征轮胎力饱和特性的问题, 设计了条件门控机制, 实现了对线性区、过渡区及饱和区动力学特征的自适应拟合。实验表明, 该方法在包含 40% 极限工况的数据集上有效解决了非线性拟合失真问题, 显著提升了泛化精度。

(2) 构建了基于谱分析的 Koopman 算子稳定性约束范式。针对长时递归推演易发散的难题, 引入基于幂迭代法的谱稳定性正则项, 将算子特征值模长严格约束在单位圆内。相平面分析证实, 该方法成功复现了物理系统的渐进收敛特性, 从底层理论上有效消除了长时预测的发散隐患, 赋予了数据驱动模型严格的有界性, 保证了全局数值稳定性。

(3) 验证了所提模型在复合工况与瞬态极端扰动下的闭环鲁棒性。将 CME-Koopman 应用于线性 MPC 框架, 不仅在纵横向强耦合的变工况 (大曲率过弯制动) 中实现了高精度轨迹跟踪与平滑的控制输出; 更在附着系数骤降 ( $\mu$ -Jump) 的极端突变工况中, 展现了极其敏锐的预判。实验结果表明, 该模型有效突破了传统基准方法在物理边界突变时的性能瓶颈, 具备极高的工程适用价值。

## 参考文献:

- [1] 纪苏宁, 曹景胜, 刘世江, 等. 基于改进人工势场法的避障路径规划研究[J]. 现代电子技术, 2025, 48(1): 117-122.  
JI Suning, CAO Jingsheng, LIU Shijiang, et al. Re-

- search on obstacle avoidance path planning based on improved artificial potential field method[J]. *Modern Electronics Technique*, 2025, 48(1): 117-122.
- [2] CHEN X, WANG L, ZHAO W. Trajectory tracking control of autonomous vehicles based on improved MPC[J]. *Transactions of Nanjing University of Aeronautics and Astronautics*, 2024, 41(2): 185-194.
- [3] ODDO G, NUCA R, PARSANI M. VeMo: A lightweight data-driven approach to model vehicle dynamics [J]. arXiv preprint arXiv:2310.07447, 2023.
- [4] SPIELBERG N A, BROWN M, KAPANIA N R, et al. Neural network vehicle models for high-performance automated driving[J]. *Science Robotics*, 2019, 28(4): eaaw1975.
- [5] ZHANG J, FENG T, ZHENG Z, et al. A physics-informed recurrent neural network for vehicle dynamics modeling[C]//*Proceedings of the 2023 IEEE International Conference on Robotics and Automation (ICRA)*. London, UK: IEEE, 2023: 3105-3111.
- [6] 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): 1470-1483.  
FANG Peijun, CAI Yingfeng, CHEN Long, et al. Trajectory tracking control method based on vehicle dynamics hybrid model for intelligent vehicle[J]. *Automotive Engineering*, 2022, 44(10): 1470-1483.
- [7] 沈甜雨, 陶子锐, 王飞跃, 等. 具身智能研究的关键问题: 自主感知、行动与进化[J]. *自动化学报*, 2025, 51(1): 43-71.  
SHEN Tianyu, TAO Zirui, WANG Feiyue, et al. Key problems of embodied intelligence research: Autonomous perception, action, and evolution[J]. *Acta Automatica Sinica*, 2025, 51(1): 43-71.
- [8] KALE C. Autonomous vehicles: Applications of deep reinforcement learning in perception and decision making[J]. *International Journal for Multidisciplinary Research*, 2024, 6(1): 1-12.
- [9] AUDINYS R, ŠLIKAS Ž, RADKEVIČIUS J, et al. Deep reinforcement learning for a self-driving vehicle operating solely on visual information using vision transformers[J]. *Electronics*, 2025, 14(5): 825.
- [10] 黄昭彦, 杨烁, 吴建华, 等. 基于信息融合的智能网联汽车安全交互决策[J]. *自动化学报*, 2025, 51(9): 1883-1898.  
HUANG Zhaoyan, YANG Shuo, WU Jianhua, et al. Safety interactive decision-making for intelligent connected vehicles based on information fusion[J]. *Acta Automatica Sinica*, 2025, 51(9): 1883-1898.
- [11] TAN Chenkai, CAI Yingfeng, WANG Hai, et al. Vehicle state estimation combining physics-informed neural network and unscented Kalman filtering on manifolds[J]. *Sensors*, 2023, 23(3): 1234.
- [12] GUTOWSKI N. Physics-guided approach with transfer learning in vehicle lateral dynamics[J]. *Proceedings of Machine Learning Research*, 2025, 230: 1-15.
- [13] CHENG Shuo, HU Binbin, WEI Henglai, et al. Deep learning-based hybrid dynamic modeling and improved handling stability assessment for autonomous vehicles at driving limits[J]. *IEEE Transactions on Vehicular Technology*, 2025, 74(4): 5582-5593.
- [14] CHROSNIAK J, NING J, BEHL M. Deep dynamics: Vehicle dynamics modeling with a physics-constrained neural network for autonomous racing[J]. *IEEE Robotics and Automation Letters*, 2024, 9(6): 5292-5297.
- [15] BRUDER D, FU X, VASUDEVAN R. Advantages of bilinear Koopman realizations for the modeling and control of systems with unknown dynamics[J]. *IEEE Robotics and Automation Letters*, 2021, 6(3): 4369-4376.
- [16] BEVANDA P, SOSNOWSKI S, HIRCHE S. Koopman operator theory for nonlinear dynamic systems: A review[J]. *IEEE Access*, 2021, 9: 7529-7565.
- [17] XIAO Yongqian, ZHANG Xinlong, XU Xin, et al. Deep neural networks with Koopman operators for modeling and control of autonomous vehicles[J]. *IEEE Transactions on Intelligent Vehicles*, 2023, 8(1): 135-146.
- [18] KIM J, QUAN Y S, CHUNG C C. K-SMPC: Koopman operator-based stochastic model predictive control for enhanced lateral control of autonomous vehicles [J]. *IEEE Transactions on Industrial Electronics*, 2025, 72(5): 1-10.
- [19] 徐新泽. 基于Koopman算子的磁流变阻尼器力跟踪控制研究[D]. 长春: 吉林大学, 2024.  
XU Xinze. Research on force tracking control of magneto-rheological damper based on Koopman operator [D]. Changchun: Jilin University, 2024.
- [20] ZHANG Jianhua, HE Yansong, CHEN Hao. Physics-informed adaptive deep Koopman operator modeling for autonomous vehicle dynamics[J]. arXiv preprint arXiv:2503.23396, 2025.
- [21] IFQIR S, ICHALAL D, AÏT OUFROUKH N, et al. A new switched interval observer design for vehicle lateral dynamics estimation[C]//*Proceedings of the 2024 American Control Conference*. Toronto, Canada: IEEE, 2024: 614-619.