物理内嵌高斯过程模型及其在智能汽车路径跟踪控制器参数整定中的应用

赵克刚[1] 陈浩强[1] 梁志豪[2] 叶 杰[3*] 王炽军[4]
1.华南理工大学机械与汽车工程学院,广州,510641
2.广东电网有限责任公司佛山供电局,佛山,528010
3.佛山大学机电工程与自动化学院,佛山,528231
4.南方(韶关)智能网联新能源汽车试验检测中心有限公司,韶关,511200

摘要:高精度动力学模型是基于模型的强化学习框架实现智能汽车路径跟踪控制器参数自动整定的关键基础。针对物理模型因简化假设导致精度不足、数据驱动模型泛化性差的问题,提出一种物理内嵌高斯过程(PEGP)模型,将物理模型的预测状态嵌入高斯过程的特征空间,引导高斯过程学习物理模型的建模误差,实现物理信息与数据驱动的融合。实车试验结果表明,PEGP模型的预测精度和泛化性能优于物理模型与纯数据驱动模型等基准模型。在此基础上,提出一种PEGP-RL控制器参数自动整定方法,该方法仅需少量实车交互即可实现控制器参数的有效整定,中低速工况下的实车验证结果表明,其跟踪性能与人工多次整定的控制器相当。

关键词:车辆动力学;智能汽车;物理内嵌高斯过程模型;路径跟踪控制;控制器参数整定;基于模型的强化学习

中图分类号:U463.82

DOI:10.3969/j.issn.1004-132X.2026.10.020 **开放科学(资源服务)标识码(OSID)**:

Physics-embedded Gaussian Process Model and Its Application in Parameter Tuning of Intelligent Vehicle Path Tracking Controllers

ZHAO Kegang[1] CHEN Haoqiang[1] LIANG Zhihao[2] YE Jie[3*] WANG Chijun[4]
1.School of Mechanical and Automotive Engineering, South China University of Technology, Guangzhou, 510641
2.Foshan Power Supply Bureau of Guangdong Power Grid Co., Ltd., Foshan, Guangdong, 528010
3.School of Mechatronic Engineering and Automation, Foshan University, Foshan, Guangdong, 528231
4.South (Shaoguan) Intelligent Connected and New Energy Vehicle Testing & Inspection Center Co., Ltd., Shaoguan, Guangdong, 511200

Abstract: A high-fidelity vehicle dynamic model is a critical foundation for model-based reinforcement learning frameworks for automatic parameter tuning of path tracking controllers in intelligent vehicles. A PEGP model was proposed to address the limited accuracy of simplified physics-based models and the poor generalization of purely data-driven approaches. In this method, the predictive states of a physical model were embedded into the feature space of the Gaussian process. The unmodeled dynamics of the physical model were thereby learned by the Gaussian process, and physical principles were integrated with data-driven learning. Real-vehicle tests demonstrated that the proposed PEGP model achieved superior prediction accuracy and generalization performance compared with the physics-based and purely data-driven baseline models. Based on this model, a PEGP-RL automatic parameter tuning method was developed, by which the controller parameters were effectively tuned with only a small amount of real-vehicle interaction data. Real-vehicle experiments at low-to-medium speeds show that the proposed approach achieves tracking performance comparable to that of a controller tuned through multiple rounds of manual adjustment.

Key words: vehicle dynamics; intelligent vehicle; physics-embedded Gaussian process model (PEGP); path tracking control; controller parameter tuning; model-based reinforcement learning

0 引言

智能汽车是提高道路交通安全与通行效率的重要技术途径[1]。车辆路径跟踪控制作为智能汽

收稿日期:2025-09-01
基金项目:国家自然科学基金(52572474);2023年度广东省特支计划领军人才项目

车的最终执行环节，直接决定车辆行驶的安全性与舒适性，其控制效果高度依赖控制器参数的精准整定[2]。工程实践中，参数整定多依靠工程师在真实驾驶场景中反复试错调试，该方式效率低下，且难以获取最优控制参数。相比之下，基于模型的强化学习（model-based reinforcement learning，MBRL）框架在控制器参数整定任务中展现出较高的效率，其核心思想是从历史数据中学习系统的动态特性，并在此基础上开展控制参数寻优，从而避免繁琐的实车试验[3]。然而，该框架的有效实施需要实现对车辆系统的精确建模，这在实际操作中较为困难。

现有的车辆动力学模型可归纳为物理模型、纯数据驱动模型与混合模型三类。物理模型通过机理分析构建车辆动力学状态方程，精度越高的物理模型其复杂度越高。为平衡模型精度和计算效率，建模过程需进行简化假设，导致模型存在未建模动态误差[4]。此外，复杂度越高的模型往往需要更多车辆参数，而这些参数通常难以精确获取[5]，使得对车辆系统的精确建模难以实现[6-7]。

纯数据驱动建模仅依靠数据学习未知系统的动态特性，无需复杂的机理分析和精确的车辆参数。SPIELBERG等[8]采用神经网络学习赛车动力学模型并优化控制策略，实现圈速成绩的显著提高；LIANG等[9-10]通过高斯过程（Gaussian process，GP）构建车辆系统的概率模型，并将模型不确定性融入控制器优化中。需要指出的是，纯数据驱动建模方法存在固有局限性：在训练数据分布外的预测可靠性不足[11]，其“黑箱”特性导致预测结果缺乏物理可解释性[12-13]。

混合模型结合物理机理与数据驱动的优势，在车辆动力学建模领域应用逐渐广泛。CHROSNIAK等[14]提出物理约束神经网络，使用神经网络估计动力学方程中的关键物理参数，将物理模型的预测作为最终输出，使模型输出结果在物理约束范围之内。CHEN等[5]和KIM等[12]也采用类似的方式分别对轮胎和车辆横向动力学进行建模。这种混合模型结构通过数据驱动消除参数摄动带来的物理模型失配问题，并实现输出结果的可解释性，但无法消除物理模型简化带来的系统误差。HEWING等[15]和KABZAN等[16]基于GP学习车辆单轨动力学模型的残差，实时补偿物理模型误差，显著提高模型精度及模型预测控制算法的性能。然而，这种残差混合模型无法解决数据驱动模型输出缺乏可解释性的问题。

综上，现有的物理模型存在未建模动态、纯数据驱动方法存在泛化性和物理可解释性差的固有缺陷，难以满足实际应用的需求。将物理机理与数据驱动优势相结合，通过合理的结构设计实现两者深层次的融合，有助于提高模型的预测精度和物理可解释性。在此背景下，面向MBRL框架中控制器参数整定对高精度动力学模型的需求，本文提出一种物理内嵌高斯过程（PEGP）模型，创新混合模型结构，实现物理模型与高斯过程模型的深度融合，使模型具备更好的物理可解释性和预测性能。在此基础上，提出基于PEGP强化学习（PEGP reinforcement learning，PEGP-RL）的路径跟踪控制器参数自动整定方法，仅需少量的实车交互数据就能实现控制器参数整定，且整定效果与人工多次整定的控制器跟踪性能相当。

1 跟踪控制器参数整定框架

路径跟踪控制器参数整定任务中，车辆系统的离散动力学可通过如下数学模型描述：

$$\boldsymbol{x}_{t+1}=f_{\text{real}}(\boldsymbol{x}_t,\boldsymbol{u}_t)+\boldsymbol{w}_t \tag{1}$$

式中：$f_{\text{real}}(\cdot)$为车辆动力学的状态转移方程；$\boldsymbol{w}_t\sim N(0,\Sigma_{\text{w}})$为独立分布的高斯噪声；$\boldsymbol{x}_t$、$\boldsymbol{u}_t$分别为状态量和控制量。

路径跟踪控制器可被描述为一个策略函数$\boldsymbol{\pi}_\theta:\boldsymbol{x}_t\rightarrow\boldsymbol{u}_t$，该函数取决于控制器的结构设计与控制器参数向量$\boldsymbol{\theta}$。

路径跟踪控制器参数整定的目标是在某一确定的控制器结构下寻找到最优参数向量$\boldsymbol{\theta}^*$，使被控车辆在有限时间步T内的累计代价$J(\boldsymbol{\theta})$最小，其定义如下：

$$J(\boldsymbol{\theta})=\sum_{t=0}^{T}c(\boldsymbol{x}_t,\boldsymbol{u}_t) \tag{2}$$

式中：惩罚函数$c(\cdot)$为t时刻对系统状态$\boldsymbol{x}_t$和控制量$\boldsymbol{u}_t$的惩罚。

采用基于MBRL框架设计路径跟踪控制器参数整定方法，如图1所示。具体流程分为以下

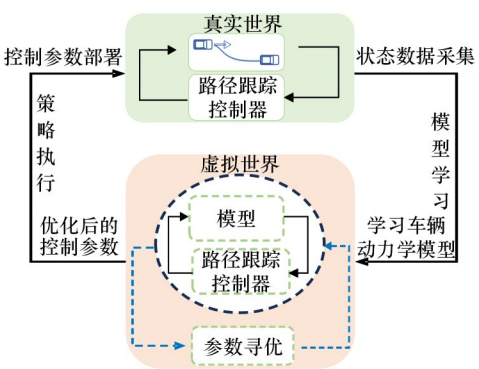

图1 路径跟踪控制器参数自动整定流程

Fig.1 The procedure of parameter auto-tuning of path tracking controller

三个环节：①模型学习，采集实车数据，选择合适的建模方法构建实车动力学模型；②参数寻优，基于模型在虚拟环境中以最小化代价为目标寻找最优参数；③策略执行，部署最优控制参数，执行控制策略。

通过学习代理模型，控制器的参数更新不再依赖实车闭环试验，可显著降低实车试验成本。需要强调的是，代理模型是MBRL算法在虚拟环境中实现有效参数寻优的关键基础，模型精度直接影响参数寻优方向与最终控制性能。

2　物理内嵌高斯过程模型建立与验证

2.1　物理模型

基于以下假设建立车辆单轨动力学模型：车辆近似为刚体；忽略车辆侧倾和悬架系统的影响；车辆沿车体坐标系x轴方向保持匀速行驶；侧向加速度限定在0.4g以下，轮胎侧偏特性处于线性区域。模型结构如图2所示，其中，纵向速度v_x、侧向速度v_y为车辆质心沿车体坐标系x、y方向的速度；r为车辆横摆角速度；l_f、l_r为车辆前轴、后轴至车辆质心的距离。

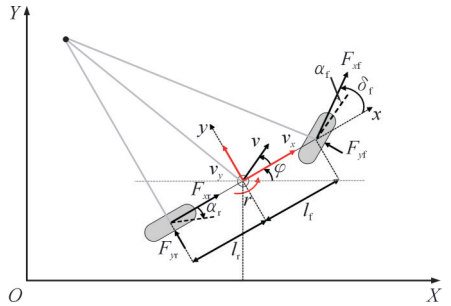

图2　单轨动力学模型

Fig.2　Single-track dynamic model

以侧向速度和横摆角速度为状态变量，前轮转角为控制输入，单轨动力学模型的离散状态方程可表示为

$$\tilde{\boldsymbol{x}}_{t+1}=f_\mathrm{p}(\boldsymbol{x}_t,\boldsymbol{u}_t)=(\boldsymbol{I}+\tau\boldsymbol{A})\boldsymbol{x}_t+\tau\boldsymbol{B}\boldsymbol{u}_t \tag{3}$$

$$\boldsymbol{A}=\begin{bmatrix}-\dfrac{C_\mathrm{f}+C_\mathrm{r}}{mv_x} & -v_x-\dfrac{l_\mathrm{f}C_\mathrm{f}-l_\mathrm{r}C_\mathrm{r}}{mv_x}\\ -\dfrac{l_\mathrm{f}C_\mathrm{f}-l_\mathrm{r}C_\mathrm{r}}{I_zv_x} & -\dfrac{l_\mathrm{f}^2C_\mathrm{f}+l_\mathrm{r}^2C_\mathrm{r}}{I_zv_x}\end{bmatrix}\quad \boldsymbol{B}=\begin{bmatrix}\dfrac{C_\mathrm{f}}{m}\\ \dfrac{l_\mathrm{f}C_\mathrm{f}}{I_z}\end{bmatrix}$$

式中：τ为离散时间步长；m为整车质量；I_z为车辆绕质心z轴的转动惯量；C_f、C_r分别为前轮、后轮的侧偏刚度。

2.2　PEGP模型结构

由于模型简化假设和模型参数的精确数值难以获取，故物理模型$f_\mathrm{p}(\cdot)$与真实系统动力学$f_\mathrm{real}(\cdot)$之间不可避免地存在误差。考虑到高斯过程具备小样本学习能力和概率输出特性，能够实现样本稀缺工况下的快速建模和预测结果的不确定量化[17]，本文采用GP对物理模型与真实系统之间的误差进行建模：

$$\boldsymbol{x}_{t+1}=f_\mathrm{p}(\boldsymbol{x}_t,\boldsymbol{u}_t)+g(\boldsymbol{z}_t)+\boldsymbol{w}_t \tag{4}$$

式中：$g(\cdot)$为误差补偿模型，用于表征物理模型的未建模动态；$\boldsymbol{z}_t$为$g(\cdot)$的特征向量。

为进一步增强$g(\cdot)$的物理可解释性，将物理模型预测状态嵌入到GP的输入特征空间中，建立GP输出与物理机理的联系。同时，通过在输入特征中引入物理先验知识，引导GP对物理模型残差的学习，从而加速模型学习效率，提高模型整体的预测精度。

基于上述混合策略，本文提出的PEGP模型结构如图3所示。PEGP模型的输入为车辆状态变量$\boldsymbol{x}_t=[v_{y,t}\ r_t]^\mathrm{T}$和控制变量$\boldsymbol{u}_t=[\delta_{f,t}]$、纵向速度$v_{x,t}$，输出为车辆下一时刻状态的预测量$\boldsymbol{x}_{t+1}$，具体预测过程如下。

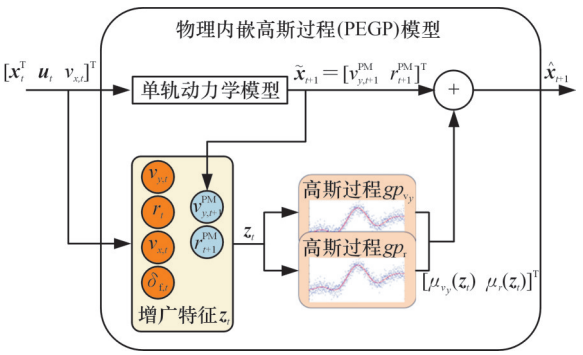

图3　PEGP模型结构

Fig.3　Structure of PEGP model

首先，将原始特征输入物理模型$f_\mathrm{p}(\cdot)$，计算得到名义预测状态：

$$\tilde{\boldsymbol{x}}_{t+1}=\left[v_{y,t+1}^\mathrm{PM}\quad r_{t+1}^\mathrm{PM}\right]^\mathrm{T}=f_\mathrm{p}(\boldsymbol{x}_t,\boldsymbol{u}_t) \tag{5}$$

然后，将名义预测状态作为具有物理意义的基准特征，与原始输入特征进行特征融合，生成新的增广特征矩阵：

$$\boldsymbol{z}_t=\left[\boldsymbol{x}_t^\mathrm{T}\quad \boldsymbol{u}_t\quad v_{x,t}\quad \tilde{\boldsymbol{x}}_{t+1}^\mathrm{T}\right]^\mathrm{T}$$

最后，将该增广矩阵输入到GP后得到物理模型残差的预测状态，将其与名义预测状态叠加即可得到最终的预测状态：

$$\hat{\boldsymbol{x}}_{t+1}=f_\mathrm{PEGP}(\boldsymbol{x}_t,\boldsymbol{u}_t)=\tilde{\boldsymbol{x}}_{t+1}+g(\boldsymbol{z}_t) \tag{6}$$

基于高斯过程建模的常用策略是为每个状态维度分别建立独立的高斯过程模型，因此，本文将侧向速度和横摆角速度的建模误差分别建模为独立的高斯过程：

$$g_d(Z)\sim\mathcal{GP}(m_d(Z),k_d(Z,Z'))\qquad d\in\{v_y,r\}$$

$$Z=\{\boldsymbol{z}_1^\mathrm{T},\boldsymbol{z}_2^\mathrm{T},\cdots,\boldsymbol{z}_n^\mathrm{T}\}$$

式中：$\mathcal{GP}(\cdot,\cdot)$为高斯过程；$m_d(\cdot)$为均值函数，反映输入点处函数值的期望；$k_d(\cdot,\cdot)$为核函数，用于度量不同输入点处函数值之间的相关性；Z为输入特征向量的集合，

$Z\in\mathrm{R}^{n\times 6}$。

假定建模误差函数向量$g_d(\cdot)$的均值函数为0，核函数选用具有自相关性确定的平方指数核函数，形式如下[18]：

$$k_d(Z_i,Z_j')=\sigma_{f,d}^2\exp\left(-\frac{1}{2}(Z_i-Z_j')^{\mathrm{T}}\boldsymbol{\Lambda}_d^{-1}(Z_i-Z_j')\right) \quad (7)$$

式中：Z_i为第i个特征向量，$i=1,2,\cdots,n$；$\sigma_{f,d}^2$为信号方差；$\boldsymbol{\Lambda}_d$为对角矩阵，$\boldsymbol{\Lambda}_d=\mathrm{diag}(l_{d,1}^2,l_{d,2}^2,\cdots,l_{d,6}^2)$。

给定训练集对应的输入特征矩阵Z，对于任意时刻的测试输入特征向量z_t，GP的预测均值μ_d和方差Σ_d可计算为

$$\mu_d(z_t)=\boldsymbol{k}_d(z_t,Z)(\boldsymbol{K}_d(Z,Z)+\sigma_{n,d}^2\boldsymbol{I})^{-1}g_d \quad (8)$$

$$\Sigma_d(z_t)=k_d(z_t,z_t)-\boldsymbol{k}_d(z_t,Z)\boldsymbol{\alpha}^{-1}\boldsymbol{k}_d^{\mathrm{T}}(z_t,Z) \quad (9)$$

$$\boldsymbol{\alpha}=\boldsymbol{K}_d(Z,Z)+\sigma_{n,d}^2\boldsymbol{I}$$

$$\boldsymbol{k}_d(z_t,Z)=[k_d(z_t,z_1)\quad k_d(z_t,z_2)\cdots k_d(z_t,z_n)]^{\mathrm{T}}$$

$$\boldsymbol{K}_d(Z,Z)=\begin{bmatrix}k_d(z_1,z_1) & k_d(z_1,z_2) & \cdots & k_d(z_1,z_n)\\ k_d(z_2,z_1) & k_d(z_2,z_2) & \cdots & k_d(z_2,z_n)\\ \vdots & \vdots & & \vdots\\ k_d(z_n,z_1) & k_d(z_n,z_2) & \cdots & k_d(z_n,z_n)\end{bmatrix}$$

式中：$\sigma_{n,d}^2$为观测噪声方差。

至此，GP模型对物理模型未建模状态的预测向量可表示为

$$g_{\mathrm{GP}}(z_t)=[\mu_{v_y}(z_t)\quad \mu_r(z_t)]^{\mathrm{T}} \quad (10)$$

高斯过程超参数为$[\sigma_{f,d}^2\quad\boldsymbol{\Lambda}_d\quad\sigma_{n,d}^2]$，可通过最大化训练数据的对数边际似然估计来确定。

2.3 数据集构建

为验证PEGP模型的预测精度与泛化性能，基于实车试验平台开展道路试验，采集实车行驶数据构建模型训练集与测试集。实车试验平台采用经过线控改装的广汽传祺GE3自动驾驶车辆，如图4所示，车辆参数如表1所示。



图4 实车试验平台

Fig.4 Real vehicle test platform

车辆状态数据由惯导INS570D测量，包括车体坐标系下的加速度、横摆角速度和车速；转向盘转角从底盘CAN总线中读取；运算平台处理器为Intel Core i9-10900F，内存为32GB RAM。采用卡尔曼平滑方法估计车体坐标系下的纵向速度与侧向速度并减小其他测量数据噪声，从而获得更接近真实系统的高质量数据[19]。采样频率和控制频率设置为25 Hz。为保障试验安全，车辆配备安全员实时监控，在异常工况下可由安全员接管控制权或启动紧急制动系统。

表1 车辆参数

Tab.1 The parameters of vehicle

车辆参数	数值
整车质量m	1667 kg
横摆转动惯量I_z	2500 kg·m^2
质心至前轴的距离l_f	1.10 m
质心至后轴的距离l_r	1.46 m
前轮侧偏刚度C_f	−65 kN/rad
后轮侧偏刚度C_r	−65 kN/rad
转向传动比i_{sw}	17

图5所示为实车训练集的全局路径及数据分布。为验证模型在小样本条件下的预测性能，采用间隔取样的方式将训练集样本量固定为1000组。

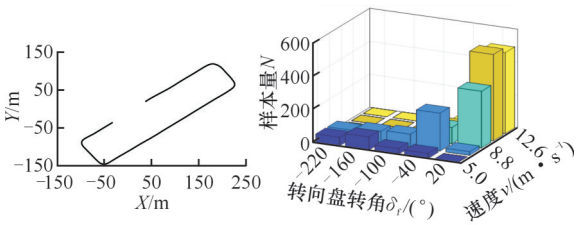

(a)全局路径 (b)数据分布

图5 实车训练集

Fig.5 Real training set

PEGP模型的实车测试包括预测精度测试与泛化性能测试，对应的测试集为实车测试集1与实车测试集2，其全局路径与数据分布分别如图6、图7所示。实车测试集1的速度范围与训练集基本一致，但转向盘转角基本相反，用于测试相似工况下模型的预测精度。实车测试集2为常见的双移线变道场景，其速度超出训练集的覆盖范围，用于评估PEGP模型在更高车速的泛化能力。

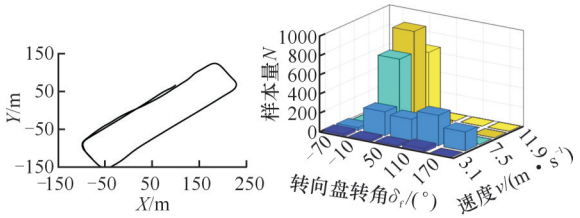

(a)全局路径 (b)数据分布

图6 实车测试集1

Fig.6 Real test set 1

2.4 基准模型与评价指标

为全面评估PEGP模型的性能，选取以下基准模型进行对比分析。

1）基于魔术轮胎公式的单轨动力学模型(magic formula based single-track model，MF-STM)：采用非线性单轨动力学模型，其轮胎力由魔术公式(MF)轮胎模型表征。基于相同的训练

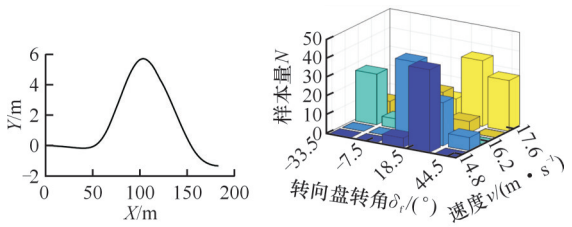

(a)全局路径　(b)数据分布

图7　实车测试集2

Fig.7　Real test set 2

集，采用遗传算法对魔术轮胎进行参数辨识[20]。

2）高斯过程模型（Gaussian process model，GPM）：将侧向速度与横摆角速度建模为独立的高斯过程，输入特征、核函数形式与超参数优化方法均与PEGP模型一致。

3）高斯过程并联混合模型（Gaussian process parallel hybrid model，GP-PHM）：基于线性单轨模型与高斯过程构建残差混合模型，模型的输入特征、GP的核函数形式与超参数优化方法均与PEGP模型一致。

采用模型开环迭代预测得到的状态序列与车辆真实状态序列之间的均方根误差（RMSE）和最大绝对误差ε_{max}作为预测精度的评价指标，分别评估模型预测结果的整体偏差与局部偏差。

2.5　模型性能分析

图8和表2所示分别为各模型在实车测试集1的状态预测结果和误差量化结果。图8结果显示，各模型预测趋势与真实状态基本一致，但GPM在大曲率工况下的表征能力略有不足，尤其是在横摆角速度的预测上，这与转向盘转角数据超出训练集范围有关。物理模型的假设在大部分测试工况范围内保持有效性，使得MF-STM表现出更优的预测性能。表2数据显示，GP-PHM和PEGP模型的RMSE值都略小于GPM和MF-STM，说明残差混合模型架构能够较好地融合物理机理与数据驱动优势，得到更优的预测性能。其中，PEGP模型的侧向速度和横摆角速度的RMSE值相较于GPM下降52.38%和40.50%。

图9和表3所示分别为各模型在实车测试集2的状态预测结果和误差量化结果。显然，PEGP模型的侧向速度和横摆角速度曲线与真实曲线更加贴合，展现出更强的泛化能力。由图9b可以看出，GPM基本无法跟踪真实的状态曲线，MF-STM在快速变道行驶过程中虽然出现明显幅值偏差，但整体上预测表现较为稳定。相比于GP-PHM，PEGP模型的预测性能提高更加明显。表3数据显示，PEGP模型在侧向速度和横摆角速度的RMSE值相较于GPM分别降低了74.79%和76.28%，相较于GP-PHM分别降低了47.53%和50.13%。这说明将物理模型的信息嵌入到GP模型的特征空间，可使GP在物理信息的指导下学习更深层次的物理机理，从而提高泛化能力。

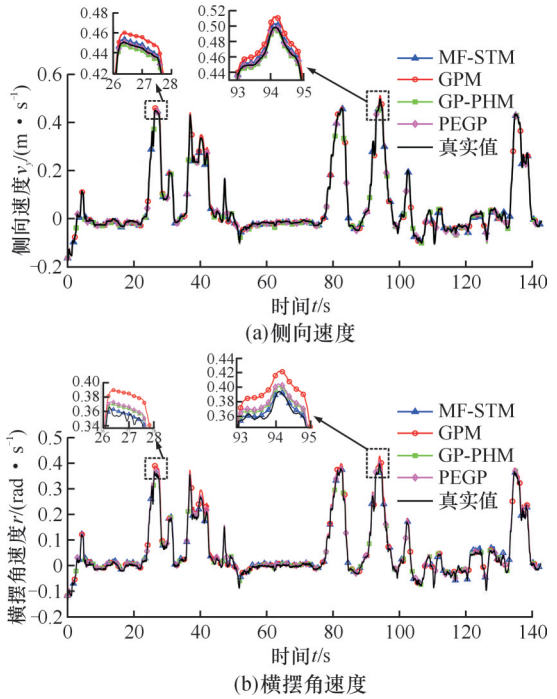

(a)侧向速度

(b)横摆角速度

图8　实车测试集1下状态预测曲线对比

Fig.8　The comparison of state predictions in real test set 1

表2　实车测试集1下预测误差对比

Tab.2　The comparison of prediction error in real test set 1

模型	v_y/(m·s^{-1})		r/(rad·s^{-1})	
	RMSE	ε_{max}	RMSE	ε_{max}
MF-STM	0.0038	0.0162	0.0076	0.0279
GPM	0.0042	0.0269	0.0121	0.0463
GP-PHM	0.0039	0.0155	0.0073	0.0266
PEGP	**0.0020**	**0.0104**	**0.0072**	**0.0272**

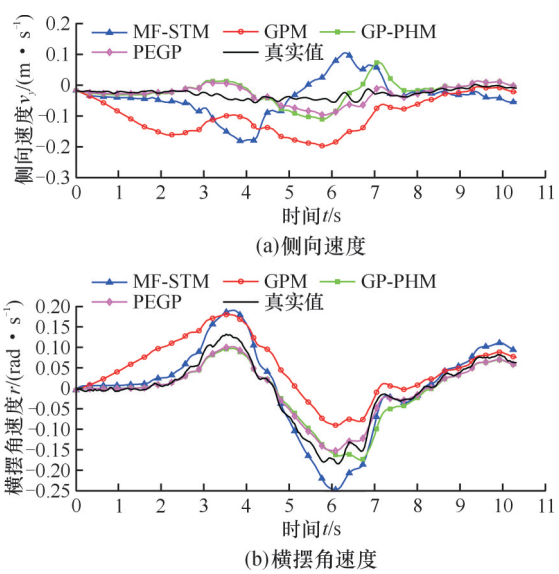

(a)侧向速度

(b)横摆角速度

图9　实车测试集2下状态预测曲线对比

Fig.9　The comparison of state predictions in real test set 2

表3 实车测试集2下预测误差对比

Tab.3 The comparison of prediction error in real test set 2

模型	v_y/(m·s^{-1})		r/(rad·s^{-1})	
	RMSE	ε_{max}	RMSE	ε_{max}
MF-STM	0.0594	0.1352	0.0322	0.0759
GPM	0.0837	0.1531	0.0586	0.1043
GP-PHM	0.0318	0.1014	0.0202	0.0746
PEGP	**0.0211**	**0.0532**	**0.0139**	**0.0372**

3 PEGP-RL方法及试验验证

3.1 PEGP-RL控制器参数整定方法

在图1所示的控制器参数整定框架的基础上，借鉴文献[10]的设计思路，进一步提出PEGP-RL路径跟踪控制器参数自动整定方法，如图10所示。该方法的核心创新在于引入所提出的PEGP模型替代原有的高斯过程模型，显著提高了模型对车辆动力学的表征精度。

1)模型学习阶段：首先，基于卡尔曼平滑算法对实车采集的原始数据进行预处理，以提高数据质量；然后，构建转向系统时滞模型补偿控制指令与执行器实际响应间的时滞[21]；最后，基于预处理后的数据集训练PEGP模型。

2)参数寻优阶段：在基于PEGP模型的虚拟环境中，通过式(8)和式(9)输出预测结果的预测均值μ_d和方差Σ_d，进一步通过粒子法和蒙特卡罗采样实现预测状态的不确定性传播，从而生成一段时间内的状态轨迹分布。在此基础上计算累计代价$J(\theta)$，并采用随机梯度下降的方法，以最小化累计代价为目标，实现控制参数迭代优化。

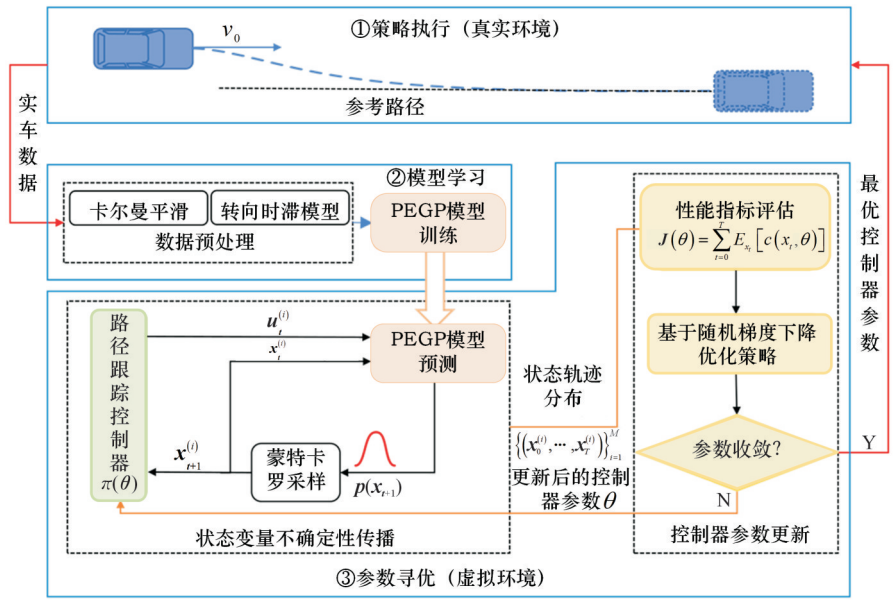

图10 PEGP-RL控制器参数自动整定方法示意图

Fig.10 Schematic diagram of the PEGP-RL controller parameter auto-tuning method

3)策略执行阶段：基于优化后的参数开展实车测试，生成新的数据集后便开始新的迭代循环，直至控制器参数收敛至最优或满足预设终止条件。

3.2 跟踪控制器及待整定参数

以当前应用较为广泛的线性二次型(LQR)横向路径跟踪控制器作为研究对象。车辆动力学跟踪误差模型的离散状态方程可表示为[22]

$$\boldsymbol{x}_{e,t+1}=(\boldsymbol{I}+\boldsymbol{A}_{e,t}\tau)\boldsymbol{x}_{e,t}+(\boldsymbol{B}_{e,t}\tau)\delta_{f,t}+(\boldsymbol{D}_{e,t}\tau)\dot{\varphi}_{des,t}$$

$$\boldsymbol{A}_{e,t}=\begin{bmatrix}0 & 1 & 0 & 0\\ 0 & -\dfrac{C_f+C_r}{mv_{x,t}} & \dfrac{C_f+C_r}{m} & -\dfrac{l_fC_f-l_rC_r}{mv_{x,t}}\\ 0 & 0 & 0 & 1\\ 0 & -\dfrac{l_fC_f-l_rC_r}{I_zv_{x,t}} & \dfrac{l_fC_f-l_rC_r}{I_z} & -\dfrac{l_f^2C_f+l_r^2C_r}{I_zv_{x,t}}\end{bmatrix}$$

$$\boldsymbol{B}_{e,t}=\begin{bmatrix}0\\ \dfrac{2C_f}{m}\\ 0\\ \dfrac{2C_fl_f}{I_z}\end{bmatrix}\qquad \boldsymbol{D}_{e,t}=\begin{bmatrix}0\\ -\dfrac{l_fC_f-l_rC_r}{mv_{x,t}}-v_{x,t}\\ 0\\ -\dfrac{l_f^2C_f+l_r^2C_r}{I_zv_{x,t}}\end{bmatrix}$$

$$\boldsymbol{x}_e=\begin{bmatrix}e_y & \dot{e}_y & e_\varphi & \dot{e}_\varphi\end{bmatrix}^{\mathrm{T}}$$

式中：$\boldsymbol{x}_e$为误差状态变量；e_y为横向位置偏差；e_φ为车辆航向角与参考航向角偏差；$\dot{\varphi}_{des}$为期望横摆角速度。

横向控制的目的是精确、平滑地跟踪期望路径，其目标函数通常采用如下二次型形式：

$$J=\sum_{t=0}^{\infty}(\boldsymbol{x}_{e,t}^{\mathrm{T}}\boldsymbol{Q}\boldsymbol{x}_{e,t}+\delta_{f,t}\boldsymbol{R}\delta_{f,t})$$

式中：$\boldsymbol{Q}$、$\boldsymbol{R}$为对角权重矩阵，$\boldsymbol{Q}\in\mathbf{R}^{4\times4}$、$\boldsymbol{R}\in\mathbf{R}^{1\times1}$。

为提高LQR控制器在时变曲率路径下的跟踪精度，将LQR控制器与基于曲率补偿的前馈控

制相结合，其控制律可表述为[23]

$$\delta_{f,t}=-\boldsymbol{K}\boldsymbol{x}_{e,t}+\Delta\delta_{ff,t}$$
$$\boldsymbol{K}=-[\boldsymbol{R}+\boldsymbol{B}^{\mathrm{T}}\boldsymbol{P}\boldsymbol{B}]^{-1}\boldsymbol{B}^{\mathrm{T}}\boldsymbol{P}\boldsymbol{A}$$
$$\Delta\delta_{ff,t}=(l_f+l_r)c_{des}+k_v v_x^2 c_{des}$$

其中，$\Delta\delta_{ff,t}$为前馈项；c_{des}为参考路径曲率；前馈项系数k_v的详细推导过程见文献[23]；第一项$-\boldsymbol{K}\boldsymbol{x}_{e,t}$为反馈项，$\boldsymbol{K}$为增益矩阵，$\boldsymbol{K}=[k_1\quad k_2\quad k_3\quad k_4]$；矩阵$\boldsymbol{P}$可通过如下黎卡提方程迭代获得：

$$\boldsymbol{P}=\boldsymbol{Q}+\boldsymbol{A}^{\mathrm{T}}\boldsymbol{P}\boldsymbol{A}-\boldsymbol{A}^{\mathrm{T}}\boldsymbol{P}\boldsymbol{B}\left(\boldsymbol{R}+\boldsymbol{B}^{\mathrm{T}}\boldsymbol{P}\boldsymbol{B}\right)^{-1}\boldsymbol{B}^{\mathrm{T}}\boldsymbol{P}\boldsymbol{A}$$

可见，LQR控制器的性能表现与权重矩阵$\boldsymbol{Q}$、$\boldsymbol{R}$参数直接相关，需进行整定优化。为使优化过程中两个权重矩阵保持正定，定义矩阵$\boldsymbol{Q}$、$\boldsymbol{R}$如下：

$$\boldsymbol{Q}=\exp(\mathrm{diag}(q_1,q_2,q_3,q_4))$$
$$\boldsymbol{R}=\exp(r_1)$$

式中：q_1、q_2、q_3、q_4、r_1为待整定参数。

3.3　PEGP-RL实车试验验证

PEGP-RL算法的试验场地为一段直线道路，该道路总长约250 m，宽约10 m，如图11a的红色区域所示。在交通车辆和行人较少以及存在安全员的情况下可进行算法的实车测试。

实车试验分为LQR控制器参数整定与控制性能验证两个阶段。①参数整定阶段选取具有初始横向偏差、车速36 km/h的匀速直线跟踪场景进行测试，以实现LQR控制器参数的快速优化，试验场景图11b中红色直线为目标路径，测试车与红色直线存在1 m的初始偏差；②性能验证阶段将整定后的LQR控制器与经多轮人工调参的基于模型预测控制(MPC)的控制器进行对比，在车速为30～40 km/h且更复杂的双移线工况下评估PEGP-RL算法在控制性能与整定效率方面的有效性，试验场景图11c中红色直线为目标路径。



(a)试验场地



(b)参数整定阶段试验场景



(c)性能验证阶段试验场景

图11　PEGP-RL算法验证场景

Fig.11　Tracking performance of LQR controller under different tuning iterations

图12为实车试验的测试现场与环境。控制器控制性能的评价指标选择路径跟踪过程中横向误差与航向误差的RMSE值和ε_{max}，以及控制器的累计代价(式(2))。选择如下形式的惩罚函数对横向偏差、航向偏差与控制指令进行惩罚[10]：

$$c(x_{e,t},u_{e,t})=1-\exp\left(-\left(\frac{e_{y,t}}{0.6}\right)^2-\left(\frac{e_{\varphi,t}}{0.2}\right)^2-\left(\frac{\delta_{f,t}}{0.18}\right)^2\right)$$



图12　试验现场

Fig.12　Test Site

表4所示为相应阶段的跟踪性能对比，可以看出，所提出的PEGP-RL参数整定方法在第2次迭代后即出现明显的收敛，第3、4、5次整定所获得控制器性能相当，性能提高趋于稳定。经3次整定后，控制器的跟踪性能取得明显的提高。具体而言，在横向跟踪偏差e_y的RMSE值基本不变的情况下，航向跟踪偏差e_φ的RMSE值和ε_{max}指标分别降低了25.98%和31.28%，且跟踪过程的累计代价减小了39.75%。

表4　不同整定次数下LQR控制器的跟踪性能对比

Tab. 4　The comparison of tracking performance of LQR controller under different tuning iterations

整定次数	e_y/m		e_φ/(°)		累计代价
	RMSE	ε_{max}	RMSE	ε_{max}	
0	0.30	1.00	2.81	9.27	35.85
1	0.31	1.00	2.03	5.96	22.04
2	0.31	1.00	2.06	6.15	21.81
3	0.31	1.00	2.08	6.37	**21.60**
4	0.31	1.00	2.08	6.39	21.61
5	0.31	1.00	2.07	6.35	21.76
提高	−3.33%		25.98%	31.28%	39.75%

图13所示为不同整定次数下LQR控制器跟踪控制效果的演变过程。相比于初始控制器，整定后的控制器能够实现较好的路径跟踪效果，在转向平滑度方面也得到了明显的改善。需要指出的是，一次实车闭环跟踪控制试验的交互时间为6 s，而完成LQR控制器的参数整定所需要的3次参数整定对应的实车交互时间仅为18 s(对应450组数据，控制频率为25 Hz)。上述结果验证了PEGP-RL控制器参数自动整定方法在实车环境的适用性与数据高效性。

为进一步验证经自动化整定方法优化的LQR控制器的跟踪性能，在30～40 km/h的双移线工况下，将经过3次参数整定的LQR控制器与基于MPC的路径跟踪控制器进行对比研究。考虑到该车速相对较低，采用基于车辆运动学模型的MPC控制器即可实现高精度路径跟踪，具体设

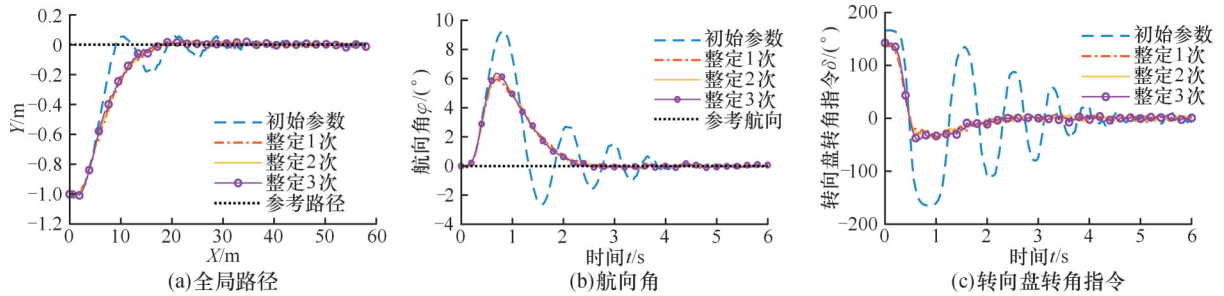

图13 不同整定次数下LQR控制器的跟踪效果

Fig.13 Tracking performance of LQR controller under different tuning iterations

计与实现见文献[24]。MPC的控制性能受预测时域、控制时域及目标函数权重系数的影响，采用试错法对MPC控制器进行人工整定。表5所示为不同整定次数下MPC跟踪性能的演变过程。由表5可以看出，即使经过5次人工整定，MPC控制器的跟踪性能仍略逊于自动化方法整定的LQR控制器。两者在横向跟踪偏差e_y的RMSE指标上相当，但LQR航向跟踪偏差e_φ的RMSE值相较于最优人工整定的MPC减小了29.55%。

图14所示为经5次人工整定的MPC与自动化整定LQR在双移线工况下的跟踪性能。结果显示，两种控制器均能有效跟踪参考路径，且LQR输出的转向盘转角指令平滑度接近MPC水平。

上述对比分析表明，在工程实践中，仅通过有限的几次实车调试即获得性能优异的MPC控制器具有较大挑战性。该结果进一步佐证了所提出的PEGP-RL控制器参数自动整定方法在参数整定效率与控制性能方面相较于传统人工方法的显著优势。

表5 不同控制器在双移线工况下的跟踪性能对比

Tab.5 The comparison of tracking performance of different controllers in double-lane change maneuver

控制器类型	整定次数	e_y/m		e_φ/(°)	
		RMSE	ε_{max}	RMSE	ε_{max}
MPC	1	0.06	0.18	0.66	2.00
	2	0.06	0.17	0.57	1.63
	3	0.06	0.15	0.47	1.51
	4	0.06	0.16	0.48	1.34
	5	**0.05**	**0.13**	**0.44**	**1.24**
LQR	3	**0.05**	**0.11**	**0.31**	**0.71**

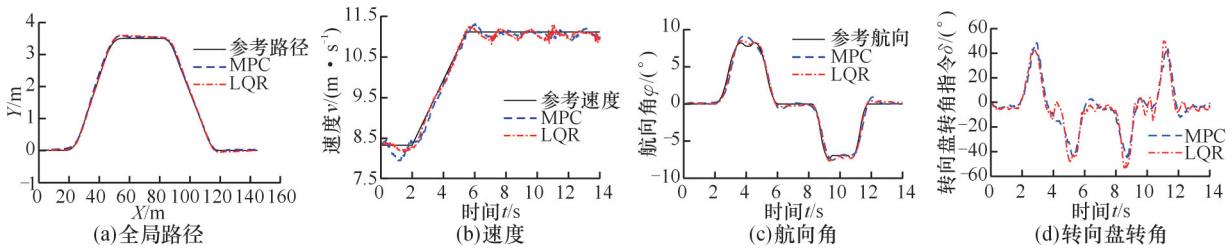

图14 不同控制器在双移线工况下的跟踪性能对比

Fig.14 The comparison of tracking performance of different controllers in double-lane change maneuver

4 结论

本文提出了一种物理内嵌高斯过程模型来实现车辆动力学的精确表征。该模型通过将物理模型预测信息嵌入高斯过程的特征空间，由物理先验知识引导高斯过程的数据学习过程，从而实现高斯过程对物理模型未建模动态的实时补偿，提高模型的预测精度和泛化性能。实车试验结果表明，PEGP模型的预测精度优于非线性模型、高斯过程模型和基于高斯过程的残差模型，尤其是在训练数据分布外的工况下展现出良好的泛化性能。

基于上述研究，本文进一步提出PEGP-RL控制器参数整定方法。在直线路径跟踪试验中，PEGP-RL仅与实车环境交互3次就能快速完成控制器参数整定。实车试验结果表明，在中低速工况下，整定后的控制器跟踪精度与经过多次人工整定的控制器相当，体现了该算法在实车环境中的适用性和数据高效性。未来可考虑研究PEGP-RL算法在多场景下的泛化能力。

参考文献：

[1] 熊璐，杨兴，卓桂荣，等. 无人驾驶车辆的运动控制发展现状综述[J]. 机械工程学报，2020，56(10)：127-143.
XIONG Lu，YANG Xing，ZHUO Guirong，et al. Review on Motion Control of Autonomous Vehicles[J]. Journal of Mechanical Engineering，2020，56(10)：127-143.

[2] 赵克刚，区伟麟，张政，等. 一种循迹控制参数调节器及其训练集构建方法[J]. 汽车工程，2025，47(2)：248-258.

ZHAO Kegang, OU Weilin, ZHANG Zheng, et al. A Tuner of Trajectory Control Parameters and the Construction Method of Its Training Set[J]. Automotive Engineering, 2025, 47(2): 248-258.

[3] AMADIO F, DALLA LIBERA A, ANTONELLO R, et al. Model-based Policy Search Using Monte Carlo Gradient Estimation with Real Systems Application[J]. IEEE Transactions on Robotics, 2022, 38(6): 3879-3898.

[4] 王秋，曲婷，陈虹. 基于随机模型预测控制的自主车辆转向控制[J]. 信息与控制，2015，44(4)：499-506.
WANG Qiu, QU Ting, CHEN Hong. Steering Control of Autonomous Vehicles Based on Stochastic Model Predictive Control[J]. Information and Control, 2015, 44(4): 499-506.

[5] CHEN J, YU C, WANG Y, et al. Hybrid Modeling for Vehicle Lateral Dynamics via AGRU with a Dual-attention Mechanism under Limited Data[J]. Control Engineering Practice, 2024, 151: 106015.

[6] ZHOU Z, WANG Y, ZHOU G, et al. Vehicle Lateral Dynamics-inspired Hybrid Model Using Neural Network for Parameter Identification and Error Characterization[J]. IEEE Transactions on Vehicular Technology, 2024, 73(11): 16173-16186.

[7] 方培俊，蔡英凤，陈龙，等. 基于车辆动力学混合模型的智能汽车轨迹跟踪控制方法[J]. 汽车工程，2022，44(10)：1469-1483.
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): 1469-1483.

[8] 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.

[9] LIANG Z, ZHAO K, XIE J, et al. Ultra-fast Tuning of Neural Network Controllers with Application in Path Tracking of Autonomous Vehicle[J]. ISA Transactions, 2024, 149: 394-408.

[10] LIANG Z, ZHAO K, ZHANG Z, et al. Improvement of a Learning-based Tuning Approach for Trajectory Tracking Controller[J]. IEEE Transactions on Vehicular Technology, 2025, 74(3): 4033-4047.

[11] GRÄBER T, LUPBERGER S, UNTERREINER M, et al. A Hybrid Approach to Side-slip Angle Estimation with Recurrent Neural Networks and Kinematic Vehicle Models[J]. IEEE Transactions on Intelligent Vehicles, 2019, 4(1): 39-47.

[12] KIM T, LEE H, LEE W. Physics Embedded Neural Network Vehicle Model and Applications in Risk-aware Autonomous Driving Using Latent Features[C]//2022 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Kyoto, 2022: 4182-4189.

[13] JIANG Y, CHEN J, ZHOU H, et al. Residual Learning of the Dynamics Model for Feeding System Modelling Based on Dynamic Nonlinear Correlate Factor Analysis[J]. Applied Intelligence, 2021, 51(7): 5067-5080.

[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] HEWING L, LINIGER A, ZEILINGER M N. Cautious NMPC with Gaussian Process Dynamics for Autonomous Miniature Race Cars[C]//2018 European Control Conference (ECC). Limassol, 2018: 1341-1348.

[16] KABZAN J, HEWING L, LINIGER A, et al. Learning-based Model Predictive Control for Autonomous Racing[J]. IEEE Robotics and Automation Letters, 2019, 4(4): 3363-3370.

[17] LIU H, ONG Y S, SHEN X, et al. When Gaussian Process Meets Big Data: a Review of Scalable GPs[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 31(11): 4405-4423.

[18] RASMUSSEN C E, WILLIAMS C K I. Gaussian Processes for Machine Learning[M]. Cambridge, MA: The MIT Press, 2005.

[19] van der LAAN N, COHEN M, ARSENAULT J, et al. The Invariant Rauch-tung-Striebel Smoother[J]. IEEE Robotics and Automation Letters, 2020, 5(4): 5067-5074.

[20] 边伟，龚佳慧，文爱民，等. 基于遗传算法的魔术公式轮胎模型参数两级辨识[J]. 重庆交通大学学报(自然科学版)，2017，36(5)：115-120.
BIAN Wei, GONG Jiahui, WEN Aimin, et al. Two Levels of Parameter Identification of Magic Formula Tire Model Based on Genetic Algorithm[J]. Journal of Chongqing Jiaotong University (Natural Sciences), 2017, 36(5): 115-120.

[21] XU S, PENG H, TANG Y. Preview Path Tracking Control with Delay Compensation for Autonomous Vehicles[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 22(5): 2979-2989.

[22] 张涛，赵奉奎，张涌，等. 基于遗传算法的无人驾驶卡车路径跟踪控制研究[J]. 南京信息工程大学学报，2024，16(6)：791-800.
ZHANG Tao, ZHAO Fengkui, ZHANG Yong, et al. Path Tracking Control of Unmanned Truck Based on Genetic Algorithm[J]. Journal of Nanjing University of Information Science & Technology, 2024, 16(6): 791-800.

[23] 王姝，张海川，赵轩，等. 融合稳定性的分布式驱动电动汽车路径跟踪控制策略研究[J]. 中国机械工程，2023，34(9)：1035-1044.
WANG Shu, ZHANG Haichuan, ZHAO Xuan, et al. Research on Path Tracking Control Method of Distributed Drive Electric Vehicles with Integrated Stability[J]. China Mechanical Engineering, 2023, 34(9): 1035-1044.

[24] ZHAO K, WANG C, XIAO G, et al. Research for Nonlinear Model Predictive Controls to Laterally Control Unmanned Vehicle Trajectory Tracking[J]. Applied Sciences, 2020, 10(17): 6034.

（编辑　袁兴玲）

作者简介：赵克刚，男，1977年生，副教授。研究方向为先进传动系统的设计与控制、混合动力汽车的能量管理策略、智能网联汽车的控制与规划。叶　杰*（通信作者），男，1991年生，讲师。研究方向为自动驾驶规划与控制。E-mail: yejie@fosu.edu.cn。

本文引用格式：

赵克刚，陈浩强，梁志豪，等. 物理内嵌高斯过程模型及其在智能汽车路径跟踪控制器参数整定中的应用[J]. 中国机械工程，2026，37(10)：2577-2585.

ZHAO Kegang, CHEN Haoqiang, LIANG Zhihao, et al. Physics-embedded Gaussian Process Model and Its Application in Parameter Tuning of Intelligent Vehicle Path Tracking Controllers[J]. China Mechanical Engineering, 2026, 37(10): 2577-2585.