

基于改进组合核函数高斯过程回归的车速预测

赵靖华^{1,2}, 闻 龙¹, 汪守丰³, 刘倩好¹, 周宇麒¹, 刘 姐¹, 解方喜²

(1. 吉林师范大学 数学与计算机学院, 吉林 四平 136000;

2. 吉林大学 汽车底盘集成与仿生全国重点实验室, 长春 130025;

3. 奇精机械股份有限公司 技术开发部, 浙江 宁波 315000)

摘要: 基于高斯过程回归技术, 提出一种新的实时车速预测方法, 在准确有效预测前车速度的同时量化了预测的不确定性. 该方法通过引入平方指数和 Matern 的组合核函数 SEM, 并改进组合核函数为 SEM*, 有效平衡了单一核函数对车速预测的优缺点, 并在超参数寻优时采用了粒子群实时求解方法. 瞬态工况下 2 s 时长车速预测的仿真分析表明: 相比于单核性能较好的径向基(SE)核函数, SEM 方法在车速 FTP75 工况下平均绝对误差(MAE)和均方根误差(RMSE)标准分别降低了 10.09% 和 7.23%, 而 SEM* 方法在两个误差指标上相比 SEM 方法分别降低 8.02% 和 8.13%; 在城市典型工况下, SEM 相比 SE 方法 MAE 和 RMSE 分别降低了 3.44% 和 4.16%, 而 SEM* 在两个误差指标上相比 SEM 核函数分别降低 3.57% 和 2.17%; 同时 SEM* 方法在 FTP75 工况单次最大计算时间上相对 SE 核函数降低 0.3 s, 城市典型工况付出的代价是相对 SE 核函数提高了 0.015 s 的最大计算时间, 但计算时间仍在 0.1 s 采样时刻以内, 具有实时性.

关键词: 组合核函数; 高斯过程; 车速预测

中图分类号: TP273 **文献标志码:** A **文章编号:** 1671-5489(2025)02-0454-11

Vehicle Speed Prediction Based on Gaussian Process Regression with Improved Combination Kernel Function

ZHAO Jinghua^{1,2}, WEN Long¹, WANG Shoufeng³, LIU Qianyu¹,

ZHOU Yuqi¹, LIU Da¹, XIE Fangxi²

(1. College of Mathematics and Computer, Jilin Normal University, Siping 136000, Jilin Province, China;

2. National Key Laboratory of Automotive, Chassis Integration and Bionics, Jilin University, Changchun 130025, China;

3. Department of Technical Development, Qijing Machinery Co., Ltd., Ningbo 315000, Zhejiang Province, China)

Abstract: We proposed a novel real-time vehicle speed prediction method based on Gaussian process regression (GPR) technology, which accurately and effectively predicted the velocity of the preceding vehicle while quantifying the uncertainty of the prediction. This method introduced a combination kernel function SEM of squared exponent (SE) and Matern, and improved the combination kernel function to SEM*. This effectively balanced the advantages and disadvantages of a single kernel function for vehicle speed prediction, and a particle swarm optimization method for real-time solution in hyperparameter optimization was adopted. The simulation analysis of 2 s vehicle speed prediction

收稿日期: 2024-04-17. 网络首发日期: 2024-12-27.

第一作者简介: 赵靖华(1980—), 男, 汉族, 博士, 教授, 从事车辆智能控制的研究, E-mail: zjh@jlnu.edu.cn. **通信作者简介:** 解方喜(1982—), 男, 汉族, 博士, 教授, 从事先进控制理论应用的研究, E-mail: xiefx2011@jlu.edu.cn.

基金项目: 国家自然科学基金面上项目(批准号: 61773009)和吉林省科技发展计划项目(批准号: 20240601034RC).

网络首发地址: <https://link.cnki.net/urlid/22.1340.O.20241225.1334.001>.

under transient operating conditions shows that under the FTP75 working condition, compared to the radial basis SE kernel function with better single kernel performance, the SEM method reduces the mean absolute error (MAE) and root mean square error (RMSE) standards by 10.09% and 7.23% respectively, while the SEM* method reduces the two error indicators by 8.02% and 8.13% respectively compared to the SEM method. Under typical urban working conditions, the SEM reduces MAE and RMSE standards by 3.44% and 4.16% respectively compared to the SE method, while the SEM* reduces the two error indicators by 3.57% and 2.17% respectively compared to the SEM method. At the same time, the SEM* method reduces the maximum single calculation time relative to the SE method by 0.3 s under the FTP75 working condition, and the cost paid under typical urban conditions is an increase in the maximum single calculation time relative to the SE method by 0.015 s, but the calculation time is still within 0.1 s of the sampling time, which has real-time performance.

Keywords: combination kernel function; Gaussian process; vehicle speed prediction

随着智能交通技术的不断发展,越来越多的车和路端都融入网络并共享信息,为车与车之间的互联通信提供了更多的可能性^[1].通过获取前车车速信息预测前车的车速状态,对本车的行驶安全性及节能减排控制都有重要意义,特别是在车辆编队跟车场景中.研究表明,利用车辆地理坐标、瞬时速度、交通等信息可预测前车的速度^[2-3].但车速是一个高度非线性的时序变量,受交通、环境、驾驶习惯等因素影响,精准预测难度较大^[4].

针对上述车速预测问题目前已有很多研究结果,主要分为基于模型和基于机器学习两种方法.文献[5]基于指数变化的模型对车速进行预测,方法简便快捷,但速度变化的单一性限制了其在不同动态工况下的适应性;文献[6]采用智能驾驶员模型预测前车速度、车距等信息,保证安全速度的同时提高了经济燃油性能.这些基于模型的车速预测方法具有实现简单、可解释性强等特点,但受车辆驾驶行为和周围不确定因素的动态变化影响,在实际应用中有一定的局限性,很难适应复杂的行驶工况.因此,基于机器学习的车速预测方法受到广泛关注.文献[7]基于人工神经网络(back propagation neural network, BPNN)模型提出了一种车速短期预测方法,该方法利用历史车速用于训练,采用时间演变模式预测车速,并基于数值优化的方法提高预测精度;文献[8]采用 MCMC(Markov chain Monte Carlo)方法,以多尺度单步形式预测当前状态下的速度序列,并采用平均滤波、二次拟合等后处理算法优化预测结果;文献[9]在 BP(back propagation)模型基础上结合 Markov 模型预测前车速度,得到了较高的预测精度.但车辆动态具有主观性和随机性,任何车速预测都存在不确定性,在准确预测前车速度的同时量化预测的不确定性是一个难题.

高斯过程回归(Gaussian process regression, GPR)方法^[10]确定了连续输入空间中的每个点都与正态分布的随机变量相关联,在非线性系统建模领域得到广泛应用. GPR 方法能在给出预测结果的同时提供置信区间,即能给出具有概率意义的结果,与 BP 等机器学习方法相比,更适合较复杂的非线性系统^[11].文献[12]利用 GPR 方法预测了发动机性能,相比 BP 以及其他的线性回归方法, GPR 方法具有较高的预测精度.针对利用历史数据预测前车加速度或速度分布问题,文献[13]比较了包括 GPR 方法在内的多种参数和非参数的时间序列预测方法,并证明了 GPR 方法的有效性.

随着 GPR 方法的发展,其性能得到了广泛认可,被应用于各领域.但 GPR 方法对数据的拟合能力面临两个挑战:一是核函数的选择;二是超参数的实时优化.常用的单一核函数有径向基核函数(SE)、Matern 核函数、有理二次(RQ)核函数^[14-16].当遇到不同区域的数据突变时,采用单一核函数的 GPR 方法可能无法有效拟合^[17].同时, GPR 模型中存在超参数过多,通过优化参数提高预测精度也是一项重要且艰巨的任务.文献[18]采用梯度下降法对多个超参数进行优化,得到了更高的预测精度.文献[19]采用共轭梯度法对超参数进行了优化,但上述梯度算法都依赖超参数估计函数是可微或近似可微,限制了梯度法的通用性能.并且梯度法还对初值过分依赖,易陷入局部最优.因此,采用粒子群优化(particle swarm optimization, PSO)算法等智能算法优化超参数是一种可行的方案. PSO 迭代寻优算

法的核心是基于生物种群行为特征求解优化问题,算法中的每个粒子均是问题的一个潜在解^[20-21].

基于上述研究结果,本文提出一种新的实时车速预测 GPR 方法,通过引入 SE 和 Matern 核的改进组合核函数 SEM*,有效平衡了单一核函数对车速预测的优缺点,并在超参数寻优时采用 PSO 实时求解方法,保证了车速预测的实时性.

1 GPR 原理及 PSO 求解方法

GPR 方法是一种非参数的回归方法,其核心思想是将输入数据视为从一个多元高斯分布中抽取的样本,用于建模和预测数据. PSO 方法能解决 GPR 超参数的实时优化问题.

1.1 GPR 数学模型推导

GPR 是由随机变量集合定义的一个随机过程,其分布是所有随机变量的联合分布. 因此 GPR 是建立在连续域上的函数分布. 对给定的训练集 $D = \{X, Y\}$, n 个输入特征构成 $\mathbf{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n)^T$, $\mathbf{X} \in \mathbb{R}^{n \times d}$, 第 i 个输入特征 \mathbf{x}_i 为 d 维向量,对应的目标值 $\mathbf{Y} = (y_1, y_2, \dots, y_n)^T$, $\mathbf{Y} \in \mathbb{R}^{n \times 1}$. 考虑到一个 GPR 模型实际输出中会包含噪声,因此 GPR 问题可建模为

$$y_i = f(\mathbf{x}_i) + \varepsilon, \quad (1)$$

其中: f 为 GPR 模型; $i = 1, 2, \dots, n$; ε 为高斯噪声,服从均值为 0、方差为 σ_n^2 的高斯分布. 一个高斯过程可由均值函数 $m(\mathbf{x})$ 和协方差函数 $k(\mathbf{x}, \mathbf{x}')$ 决定:

$$\begin{aligned} m(\mathbf{x}) &= E[f(\mathbf{x})], \\ k(\mathbf{x}, \mathbf{x}') &= E[(f(\mathbf{x}) - m(\mathbf{x}))(f(\mathbf{x}') - m(\mathbf{x}'))], \end{aligned} \quad (2)$$

其中 \mathbf{x}' 为输入特征, $E(\cdot)$ 表示均值函数. 由于 0 均值先验具有泛用性,因此一般将先验均值函数设为 0,即 $m(\mathbf{x}) = 0$,则 GPR 可简化为 $y \sim \text{GP}(0, k(\mathbf{x}, \mathbf{x}'))$. 协方差函数以矩阵形式可表示为

$$\text{Cov}(\mathbf{X}, \mathbf{X}) = \mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I}, \quad (3)$$

其中 \mathbf{I} 表示 $N \times N$ 的单位矩阵, $\text{Cov}(\mathbf{X}, \mathbf{X})$ 表示 $N \times N$ 的协方差矩阵, $\mathbf{K}(\mathbf{X}, \mathbf{X})$ 表示 $N \times N$ 的核矩阵.

核函数能实现非线性映射,可以表征协方差函数,主要分为 RQ, SE 和 Matern 核函数等几种. RQ 核函数表达式为

$$k_{\text{RQ}}(\mathbf{x}, \mathbf{x}') = \sigma_{\text{RQ}}^2 \left(1 + \frac{\|\mathbf{x} - \mathbf{x}'\|^2}{2\alpha_{\text{RQ}} l_{\text{RQ}}^2} \right)^{-\alpha_{\text{RQ}}}, \quad (4)$$

其中 l_{RQ} 为信号特征长度的尺度, α_{RQ} 为正值尺度混合参数,超参数 σ_{RQ}^2 为调节协方差函数变化的垂直尺度因子, $\|\mathbf{x} - \mathbf{x}'\|^2$ 为输入向量 \mathbf{x} 和 \mathbf{x}' 之间的欧氏距离平方. 设 $\theta_{\text{RQ}} = \{\alpha_{\text{RQ}}, l_{\text{RQ}}, \sigma_{\text{RQ}}^2\}$ 为 RQ 核函数超参数集,需通过训练学习获取最优值.

SE 核函数通常用于对光滑函数的建模,在高斯过程回归中表示任意两点的协方差值,表达式为

$$k_{\text{SE}}(\mathbf{x}, \mathbf{x}') = \sigma_{\text{SE}}^2 \exp\left\{-\frac{\|\mathbf{x} - \mathbf{x}'\|^2}{2l_{\text{SE}}^2}\right\}, \quad (5)$$

其中: l_{SE} 为信号特征长度的尺度,用于描述函数的平滑程度,当它较小时,拟合函数响应特征性能较好,较大时函数趋于平滑; σ_{SE}^2 为信号的方差,用于表示拟合函数与信号均值的偏差,当它较小时,相对偏离信号均值,当它较大时,拟合函数波动会变大.

Matern 核函数具有参数化的灵活性,能通过调节 l_M 和 σ_M 更精细地控制模型的平滑度和波动范围,使模型能更好地适应不同的数据特性,表达式为

$$k_{\text{Matern}}(\mathbf{x}, \mathbf{x}') = \sigma_M^2 \left[\left(1 + \frac{\sqrt{5} \|\mathbf{x} - \mathbf{x}'\|}{l_M} + \frac{5 \|\mathbf{x} - \mathbf{x}'\|^2}{3l_M^2} \right) \exp\left\{-\frac{\sqrt{5} \|\mathbf{x} - \mathbf{x}'\|}{l_M}\right\} \right]. \quad (6)$$

根据 Bayes 原理,高斯过程模型在训练集 D 内建立先验函数,在测试数据 \mathbf{X}_* 上转化为后验分布,因此根据测试数据输入得到的预测结果 y_* 与训练集数据的目标值 y 形成联合高斯分布,即

$$\begin{pmatrix} y \\ y_* \end{pmatrix} \sim N\left(0, \begin{pmatrix} \mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I}_{N \times N} & \mathbf{K}(\mathbf{X}, \mathbf{X}_*) \\ \mathbf{K}(\mathbf{X}_*, \mathbf{X}) & \mathbf{K}(\mathbf{X}_*, \mathbf{X}_*) \end{pmatrix}\right), \quad (7)$$

其中 $\mathbf{K}(\mathbf{X}, \mathbf{X})$ 表示训练集输入特征的自协方差矩阵, $\mathbf{K}(\mathbf{X}_*, \mathbf{X}_*)$ 表示测试集输入特征的自协方差矩

阵, $\mathbf{K}(\mathbf{X}, \mathbf{X}_*)$ 表示训练集数据与测试集数据输入特征之间的协方差矩阵. 根据式(4)中的联合分布可计算 y_* 的边缘分布为

$$y_* \sim N(\mathbf{K}(\mathbf{X}_*, \mathbf{X})[\mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I}]^{-1} \mathbf{y}, \mathbf{K}(\mathbf{X}_*, \mathbf{X}_*) - \mathbf{K}(\mathbf{X}_*, \mathbf{X})[\mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I}]^{-1} \mathbf{K}(\mathbf{X}, \mathbf{X}_*)), \quad (8)$$

其中预测均值 $\mu(y_*)$ 和预测方差 $\sigma^2(y_*)$ 分别为

$$\begin{aligned} \mu(y_*) &= \mathbf{K}(\mathbf{X}_*, \mathbf{X})[\mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I}]^{-1} \mathbf{y}, \\ \sigma^2(y_*) &= \mathbf{K}(\mathbf{X}_*, \mathbf{X}_*) - \mathbf{K}(\mathbf{X}_*, \mathbf{X})[\mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I}]^{-1} \mathbf{K}(\mathbf{X}, \mathbf{X}_*). \end{aligned} \quad (9)$$

1.2 PSO 求解方法

本文利用 PSO 算法优化 GPR 中的超参数, 对前方车速进行预测. 粒子群优化算法的速度和位置更新公式分别为

$$v_{i,d}^{k+1} = v_{i,d}^k + c_1 \text{Rand}() (p_{i,d}^k - x_{i,d}^k) + c_2 \text{Rand}() (p_{g,d}^k - x_{i,d}^k), \quad (10)$$

$$x_{i,d}^{k+1} = x_{i,d}^k + v_{i,d}^{k+1}, \quad (11)$$

其中 c_1 和 c_2 分别为学习因子和加速常数, $\text{Rand}()$ 为 $(0, 1)$ 内的随机数, $v_{i,d}^{k+1}$ 和 $x_{i,d}^{k+1}$ 分别为粒子 i 在 k 次迭代中第 d 维的速度和位置, $P_{i,d}^k$ 为粒子 i 在第 d 维的个体极值位置, $P_{g,d}^k$ 为群体在第 d 维的全局极值位置.

2 基于改进组合核函数的车速预测

图 1 为基于 GPR 技术的前车车速预测流程.

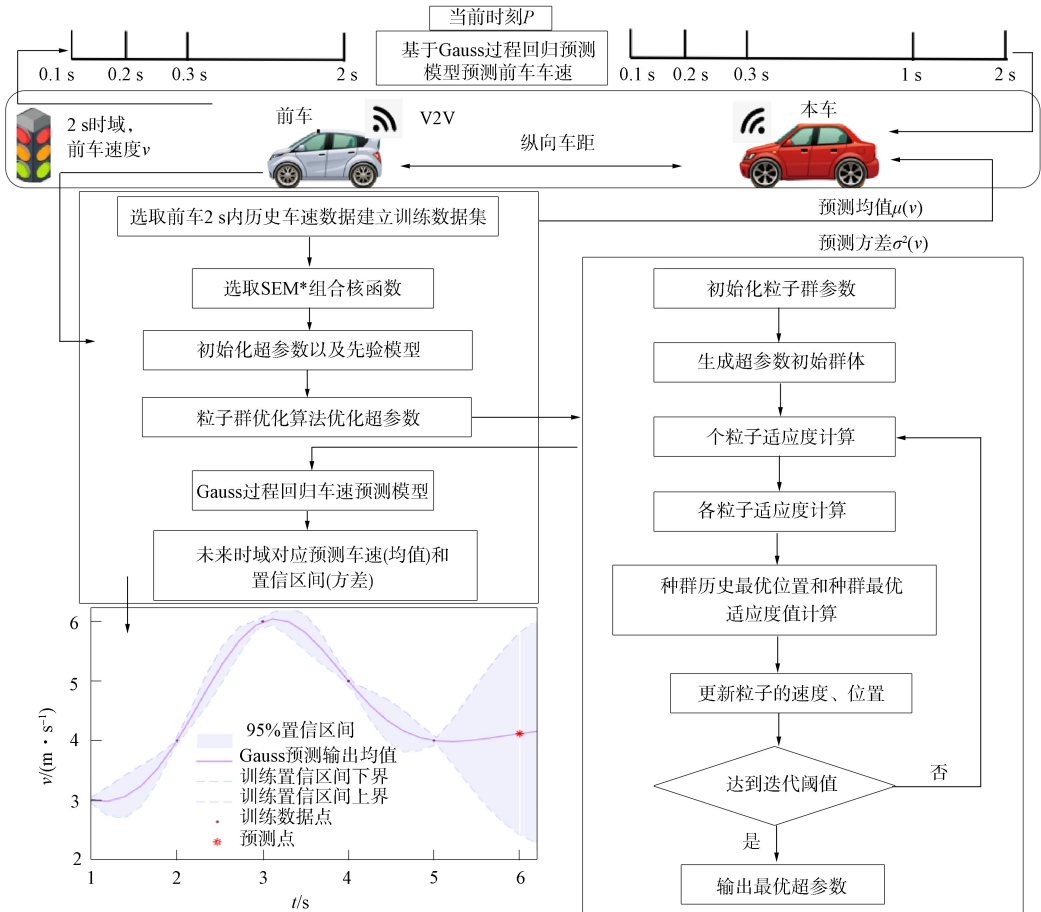


图 1 基于 GPR 技术的前车车速预测流程

Fig. 1 Flow chart of vehicle speed prediction of preceding vehicle based on GPR technology

由图 1 可见, 本车基于前车 2 s 历史车速数据, 利用 GPR 技术预测前车 0.1~2 s 内未来车速的均值和方差. GPR 技术的主要步骤如下:

- 1) 选取前车 2 s 内历史车速数据建立训练数据集;
- 2) 选取 SEM* 组合核函数;
- 3) 初始化超参数及进行先验模型;
- 4) 使用 PSO 算法对超参数进行优化;
- 5) 得到高斯过程回归车速预测模型;
- 6) 得到未来 2 s 时域预测车速的均值和方差.

PSO 算法对超参数进行优化的主要步骤如下:

- 1) 初始化粒子群参数;
- 2) 生成超参数初始群体;
- 3) 计算各粒子适应度;
- 4) 计算个体最优位置;
- 5) 计算种群历史最优位置和种群最优适应度;
- 6) 更新粒子的速度和位置;
- 7) 判断是否达到迭代值, 如果未满足条件则返回步骤 3) 计算各粒子适应度;
- 8) 输出最优超参数.

本文车速误差评价采用平均绝对误差 (mean absolute error, MAE) 和均方根误差 (root-mean-square error, RMSE), 分别表示为

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |\mu(y_i) - y'_i|, \quad (12)$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\mu(y_i) - y'_i)^2}, \quad (13)$$

其中 y_i 表示车速预测输出 (为一个高斯随机变量), $\mu(y_i)$ 表示车速预测输出的均值, y'_i 表示前车车速的真实值, N 表示车速预测点总数.

单一核函数一般只针对一个类型的数据有较好的性能, 但对于复杂的非线性系统, 基于单一核函数的模型通常无法完成对数据的描述. 假设高斯过程 $f(\mathbf{x}) = f_1(\mathbf{x}) + f_2(\mathbf{x})$, 且 $f_1(\mathbf{x})$ 与 $f_2(\mathbf{x})$ 相互独立, 则有

$$k(\mathbf{x}, \mathbf{x}') = k_1(\mathbf{x}, \mathbf{x}') + k_2(\mathbf{x}, \mathbf{x}'),$$

即使核函数的特征长度不同也不会影响这种组合方式的结果. 本文利用两个单一核函数 SE 和 M 组合成核函数 SEM, 表示为

$$k_{\text{SEM}}(\mathbf{x}, \mathbf{x}') = \sigma_{\text{SE}}^2 \exp\left\{-\frac{\|\mathbf{x} - \mathbf{x}'\|^2}{2l_{\text{SE}}^2}\right\} + \sigma_M^2 \left[\left(1 + \frac{\sqrt{5} \|\mathbf{x} - \mathbf{x}'\|}{l_M} + \frac{5 \|\mathbf{x} - \mathbf{x}'\|^2}{3l_M^2}\right) \exp\left\{-\frac{\sqrt{5} \|\mathbf{x} - \mathbf{x}'\|}{l_M}\right\} \right]. \quad (14)$$

在此基础上利用两个不同核函数的特点进一步改进 SEM 组合核函数并进行分析. 将 4 种改进的 SEM 组合核函数分别标记为 SEM1, SEM2, SEM3, SEM*, 公式为

$$k_{\text{SEM1}}(\mathbf{x}, \mathbf{x}') = \sigma_{\text{SE}}^2 \exp\left\{-\frac{\|\mathbf{x} - \mathbf{x}'\|^2}{2l_{\text{SE}}^2}\right\} + \left[\left(1 + \frac{\sqrt{\theta} \|\mathbf{x} - \mathbf{x}'\|}{l_M} + \frac{\theta \|\mathbf{x} - \mathbf{x}'\|^2}{3l_M^2}\right) \exp\left\{-\frac{\sqrt{\theta} \|\mathbf{x} - \mathbf{x}'\|}{l_M}\right\} \right], \quad (15)$$

$$k_{\text{SEM2}}(\mathbf{x}, \mathbf{x}') = \exp\left\{-\frac{\|\mathbf{x} - \mathbf{x}'\|^2}{2l_{\text{SE}}^2}\right\} + \sigma_M^2 \left[\left(1 + \frac{\sqrt{5} \|\mathbf{x} - \mathbf{x}'\|}{l_M} + \frac{5 \|\mathbf{x} - \mathbf{x}'\|^2}{3l_M^2}\right) \exp\left\{-\frac{\sqrt{5} \|\mathbf{x} - \mathbf{x}'\|}{l_M}\right\} \right], \quad (16)$$

$$k_{\text{SEM3}}(\mathbf{x}, \mathbf{x}') = \exp\left\{-\frac{\theta_{\text{SE}} \|\mathbf{x} - \mathbf{x}'\|^2}{2l_{\text{SE}}^2}\right\} + \sigma_M^2 \left[\left(1 + \frac{\sqrt{5} \|\mathbf{x} - \mathbf{x}'\|}{l_M} + \frac{5 \|\mathbf{x} - \mathbf{x}'\|^2}{3l_M^2}\right) \exp\left\{-\frac{\sqrt{5} \|\mathbf{x} - \mathbf{x}'\|}{l_M}\right\} \right], \quad (17)$$

$$k_{SEM^*}(\mathbf{x}, \mathbf{x}') = \left[\left(\frac{\theta_M \|\mathbf{x} - \mathbf{x}'\|^2 + 3\sqrt{2}\theta_M l_M \|\mathbf{x} - \mathbf{x}'\| + 3l_M^2}{3l_M^2} \right) \exp\left\{ -\frac{\sqrt{2}\theta_M \|\mathbf{x} - \mathbf{x}'\|}{l_M} \right\} \right] + \sigma_{SE}^2 \exp\left\{ -\frac{\|\mathbf{x} - \mathbf{x}'\|^2}{2l_{SE}^2} \right\}. \tag{18}$$

图 2 为组合核函数对车速预测结果的敏感性分析曲线. 图 2(A) 为车速 1 s 预测效果, 图 2(B) 为车速 2 s 预测效果.

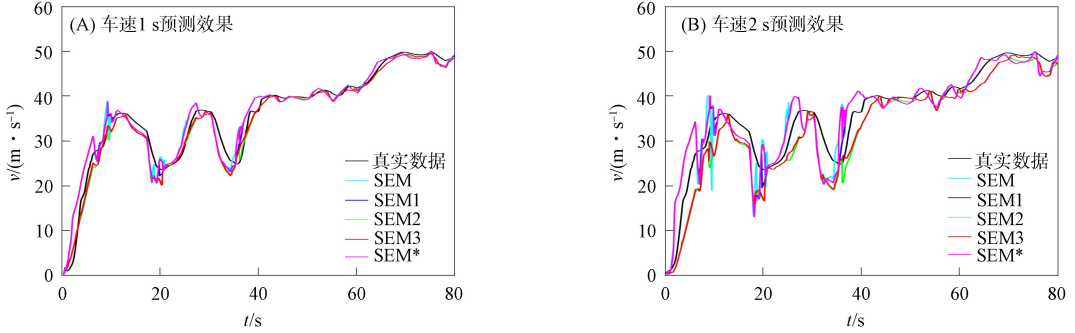


图 2 组合核函数对车速预测效果的敏感性分析曲线

Fig. 2 Sensitivity analysis curves of combined kernel function on vehicle speed prediction effect

表 1 列出了不同核函数 GPR 方法车速预测 2 s 的误差对比结果. 由表 1 可见, SEM* 组合核函数方法的 MAE 和 RMSE 指标都是最低的. 敏感性分析结果表明, SEM* 方法不仅具有 SE 核函数对高维数据集建模的优势, 而且也具有 M 核函数更精细的模型平滑尺度.

表 1 不同核函数 GPR 方法车速预测 2 s 的误差对比结果

Table 1 Comparison results of speed prediction errors for 2 s by different kernel function GPR methods

| 核函数 | MAE | RMSE | 核函数 | MAE | RMSE |
|------|------|------|------|------|------|
| SEM | 1.83 | 2.85 | SEM3 | 2.90 | 4.38 |
| SEM1 | 1.76 | 2.79 | SEM* | 1.72 | 2.75 |
| SEM2 | 2.80 | 4.25 | | | |

3 不同核函数的 GPR 方法车速仿真分析

为验证不同核函数对车速的预测效果, 本文分别在 FTP75 工况和城市典型工况下进行仿真测试. 使用 MATLAB 工具箱 RQ 核函数方法作为预测基准, 其他核函数的超参数为 PSO 实时优化. 当前时刻下控制器以 0.1 s 时刻为采样间隔获取历史车速 2 s 数据作为训练数据集, 分别对未来 1 s 和 2 s 时域车速进行预测, 其中预测步长为 0.1 s.

3.1 FTP75 工况下的 5 种核函数 GPR 方法车速预测效果对比

图 3 和图 4 分别为未来 1 s 和 2 s 时, 5 种核函数在 FTP75 工况下的车速预测对比结果. 其中(A) 为 5 种核函数 GPR 方法下的车速预测效果, (B)和(C)为部分工况下预测对比局部放大图, (D)为(B) 的 95%置信区间(confidence interval, CI), (E)为(C)的 95%CI.

表 2 列出了 5 种核函数 GPR 方法车速预测 1 s 和 2 s 的误差对比. 由表 2 可见: 当车速进行 1 s 预测时, SEM 组合核函数相比于 M 核函数和 SE 核函数方法, MAE 指标分别下降 11.76%, 15.09%, RMSE 指标分别下降 7.79%, 11.80%; SEM* 组合核函数相比于 SEM, MAE 和 RMSE 指标分别下降 17.77%和 11.26%; 对车速进行 2 s 预测时, SEM 组合核函数相比于 M 核函数和 SE 核函数方法, MAE 指标分别下降 9.66%, 10.09%, RMSE 指标分别下降 6.94%, 7.23%; SEM* 组合核函数相比于 SEM, MAE 和 RMSE 指标分别下降 8.02%和 8.13%. 图 5 为 FTP75 工况下 4 种核函数超参数实时优化算法的运行时间. 4 种核函数方法的单次最大运行时间均在 0.1 s 以内, SE 核函数为 0.09 s, M 核函数为 0.04 s, SEM 核函数为 0.082 s, SEM* 核函数为 0.035 s. 结果表明, 上述 GPR 车速预测方法都具有实时性.

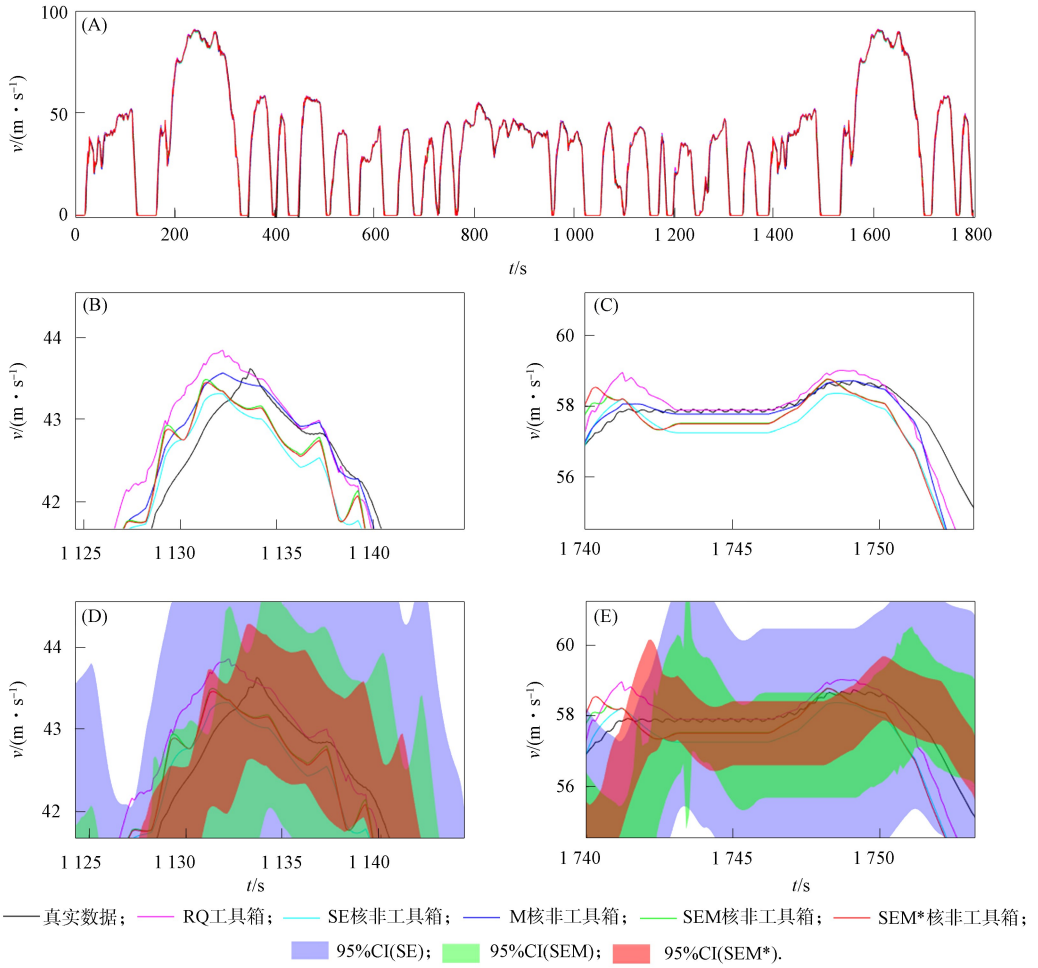


图 3 FTP75 工况下 5 种核函数 GPR 方法车速 1 s 预测效果对比

Fig. 3 Comparison of 1 s prediction effect of five kernel function GPR methods for vehicle speed under FTP75 working conditions

表 2 FTP75 工况下 5 种核函数 GPR 方法 1 s 和 2 s 的车速预测误差

Table 2 Prediction errors of 1 s and 2 s of five kernel function GPR methods for vehicle speed under FTP75 working conditions

| 预测时间/s | 核函数 | MAE | RMSE | 预测时间/s | 核函数 | MAE | RMSE |
|--------|------------|------|------|--------|------------|------|------|
| 1 | RQ 工具箱 | 0.90 | 1.42 | 2 | RQ 工具箱 | 1.85 | 2.91 |
| 1 | M 核非工具箱 | 1.02 | 1.54 | 2 | M 核非工具箱 | 2.07 | 3.17 |
| 1 | SE 核非工具箱 | 1.06 | 1.61 | 2 | SE 核非工具箱 | 2.08 | 3.18 |
| 1 | SEM 核非工具箱 | 0.90 | 1.42 | 2 | SEM 核非工具箱 | 1.87 | 2.95 |
| 1 | SEM* 核非工具箱 | 0.74 | 1.26 | 2 | SEM* 核非工具箱 | 1.72 | 2.71 |

3.2 城市典型工况下 5 种核函数 GPR 方法车速预测效果的对比

下面进一步验证本文提出的 SEM* 组合核函数方法预测车速的可行性和准确性。图 6 和图 7 分别为未来 1 s 和 2 s 时 5 种核函数 GPR 方法在城市典型工况下的车速预测对比结果。表 3 列出了城市工况下 5 种核函数 GPR 方法车速预测 1 s 和 2 s 的误差对比数据。由表 3 可见：对车速进行 1 s 预测时，SEM 核函数组合相比于 M 核函数和 SE 核函数方法 MAE 指标分别下降 9.09%，6.25%，RMSE 指标分别下降 7.40%，5.66%；SEM* 组合核函数相比于 SEM 方法，MAE 和 RMSE 指标分别下降 3.33%，4.0%；对车速进行 2 s 预测时，SEM 核函数组合相比于 M 核函数和 SE 核函数方法，MAE 指标分别下降 8.19%，3.44%，RMSE 指标分别下降 5.15%，4.16%；SEM* 组合核函数相比于 SEM 方法，MAE 和 RMSE 指标分别下降 3.57%，2.17%。图 8 为 4 种核函数超参数实时优化算法的运行时间。4 种核函数 GPR 方法的单次最大运行时间均在 0.1 s 以内，SE 核函数为 0.075 s，M 核函数为 0.029 s，SEM 核函数为 0.029 s，SEM* 核函数为 0.09 s。结果表明，上述 GPR 车速预测方法都具有

实时性.

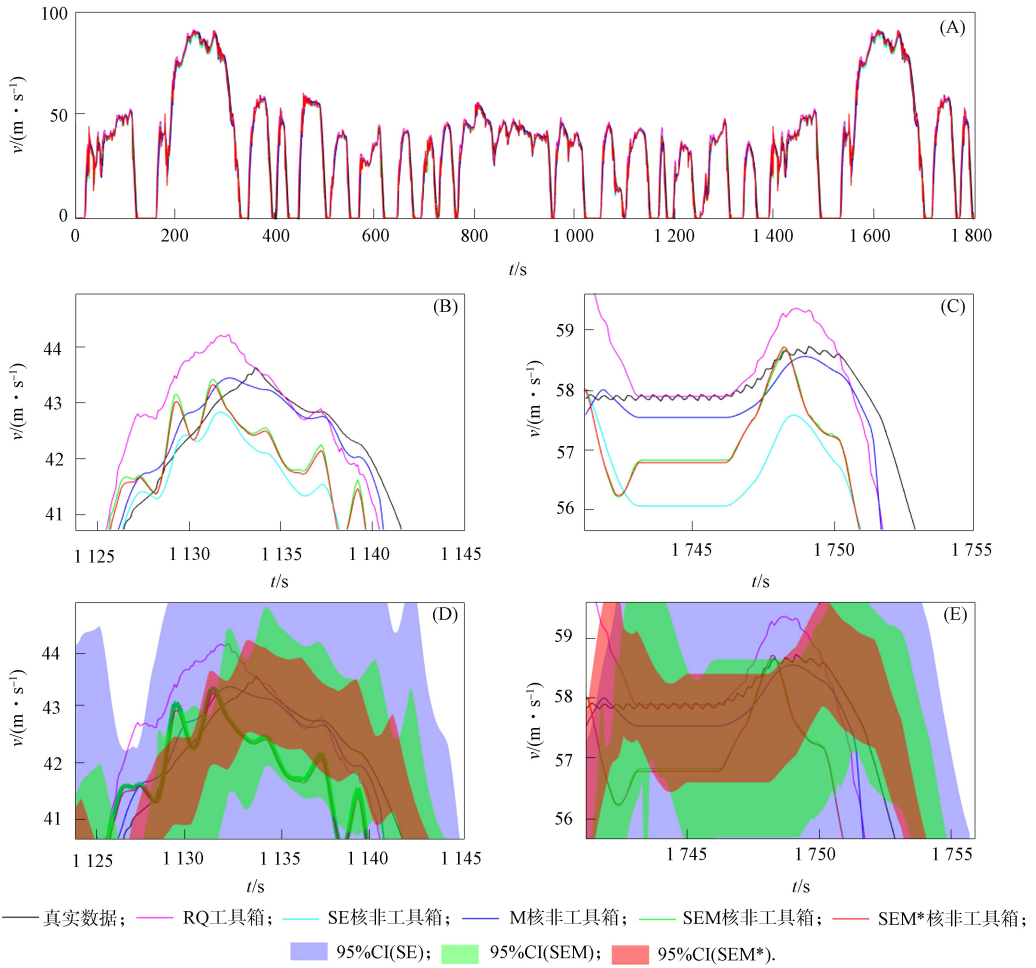


图 4 FTP75 工况下 5 种核函数 GPR 方法车速 2 s 预测效果对比

Fig. 4 Comparison of 2 s prediction effect of five kernel function GPR methods for vehicle speed under FTP75 working conditions

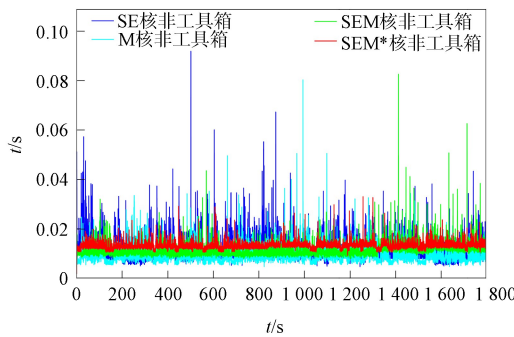


图 5 FTP75 工况下 4 种核函数实时运行时间

Fig. 5 Real-time running time of four kernel functions under FTP75 working conditions

表 3 城市典型工况下 5 种核函数 GPR 方法 1 s 和 2 s 车速预测结果

Table 3 Prediction results of 1 s and 2 s of five kernel function GPR methods for vehicle speed under typical urban working conditions

| 预测时间/s | 核函数 | MAE | RMSE | 预测时间/s | 核函数 | MAE | RMSE |
|--------|------------|------|------|--------|------------|------|------|
| 1 | RQ 工具箱 | 0.25 | 0.43 | 2 | RQ 工具箱 | 0.50 | 0.83 |
| 1 | M 核非工具箱 | 0.33 | 0.54 | 2 | M 核非工具箱 | 0.61 | 0.97 |
| 1 | SE 核非工具箱 | 0.32 | 0.53 | 2 | SE 核非工具箱 | 0.58 | 0.96 |
| 1 | SEM 核非工具箱 | 0.30 | 0.50 | 2 | SEM 核非工具箱 | 0.56 | 0.92 |
| 1 | SEM* 核非工具箱 | 0.29 | 0.48 | 2 | SEM* 核非工具箱 | 0.54 | 0.90 |

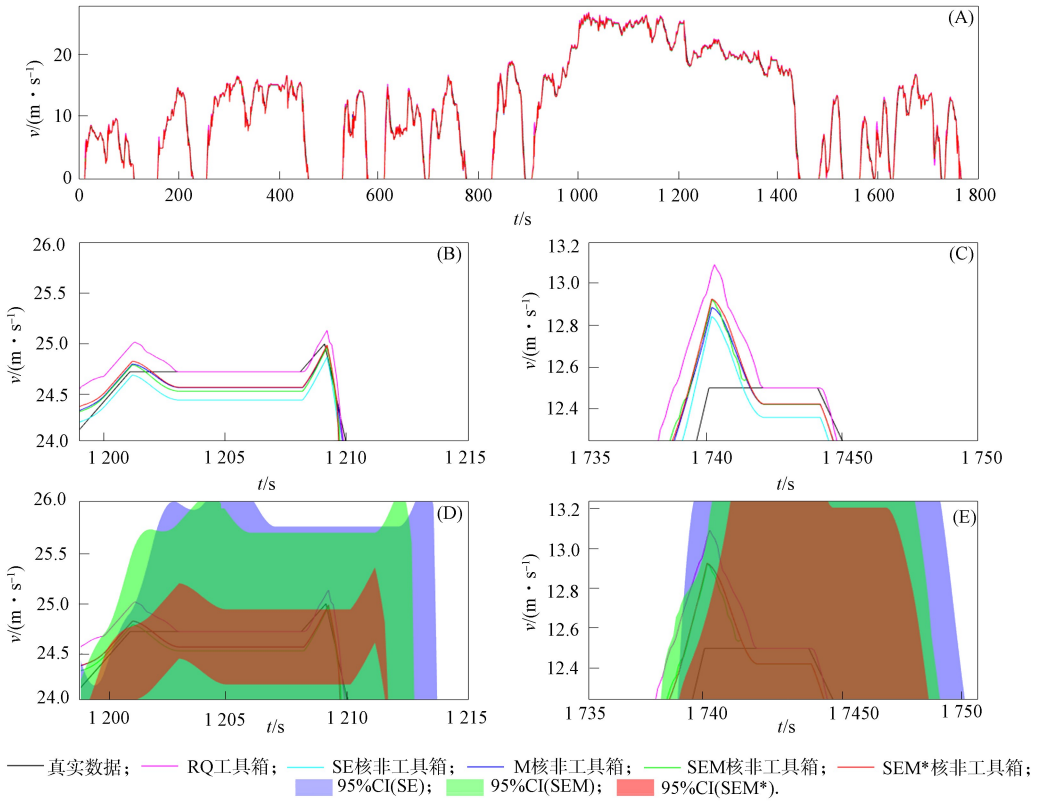


图 6 城市典型工况下 5 种核函数 GPR 方法车速 1 s 的预测效果对比

Fig. 6 Comparison of 1 s prediction effect of five kernel function GPR methods for vehicle speed under typical urban working conditions




图 7 城市典型工况下 5 种核函数 GPR 方法车速 2 s 的预测效果对比

Fig. 7 Comparison of 2 s prediction effect of five kernel function GPR methods for vehicle speed under typical urban working conditions

图 9 为 FTP75 工况下和城市典型工况下, 0.1~2 s 不同预测时域下 4 种核函数实时 GPR 方法车速预测误差对比结果. 由图 9 可见, 随着预测时域增大, 各种核函数方法实时车速预测误差 MAE 和 RMSE 指标都会增大. 整体上看, SEM 组合核函数方法在各预测时域下误差指标都低于 SE 和 M 核函数方法; SEM* 核函数方法的误差指标都低于 SEM 组合核函数方法.

综上所述, 针对目前有效预测前车速度的同时量化不确定性的问题, 本文基于高斯过程回归技术, 提出了一种新的实时车速预测方法. 该方法引入 SE 和 M 的组合核函数 SEM 方法, 并改进了组合核函数方法为 SEM*, 有效地平衡了单一核函数方法对车速预测的优缺点, 并在超参数寻优时采用了粒子群实时求解方法. 瞬态工况下 2 s 时长车速预测的仿真分析表明: 相比于单核性能较好的 SE 核函数, SEM 方法在车速 FTP75 工况下误差 MAE 和 RMSE 标准分别降低了 10.09% 和 7.23%, 而 SEM* 方法在两个误差指标中相比 SEM 方法分别降低了 8.02% 和 8.13%; 在城市典型工况下, SEM 相比 SE 误差 MAE 和 RMSE 分别降低了 3.44% 和 4.16%, 而 SEM* 在两个误差指标中相比 SEM 核函数分别降低 3.57% 和 2.17%. 并且改进核函数 SEM* 在 FTP75 工况单次最大计算时间上相对 SE 核函数降低 0.3 s, 城市典型工况付出的代价是相对 SE 核函数提高了 0.015 s 的最大计算时间, 但计算时间仍在 0.1 s 采样时刻以内, 具有实时性.

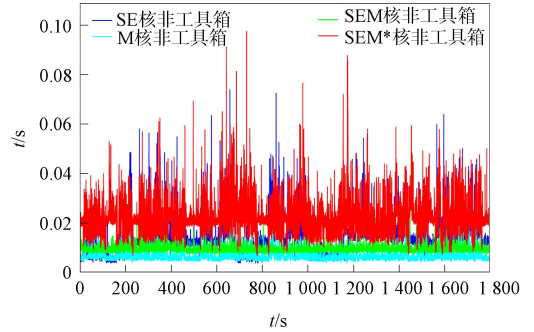


图 8 城市典型工况下 4 种核函数 GPR 方法实时运行时间
Fig. 8 Real-time running time of four kernel function GPR methods under typical urban working conditions




图 9 FTP75 工况和城市典型工况下不同时域的 GPR 方法车速预测误差对比结果

Fig. 9 Comparison results of prediction errors of GPR methods for vehicle speed in different time domains under FTP75 and typical urban working conditions

参 考 文 献

[1] 张子岩. 面向混动能量管理的自适应在线车速预测算法研究 [D]. 杭州: 浙江大学, 2023. (ZHANG Z Y. Research on Adaptive Online Vehicle Speed Prediction Algorithm for Hybrid Energy Management [D]. Hangzhou: Zhejiang University, 2023.)

[2] RAMADAN H S, BECHERIF M, CLAUDE F. Energy Management Improvement of Hybrid Electric Vehicles via Combined GPS/Rule-Based Methodology [J]. IEEE Transactions on Automation Science and Engineering, 2017, 14(2): 586-597.

[3] WANG P Y, LI J K, YU Y B, et al. Energy Management of Plug-in Hybrid Electric Vehicle Based on Trip Characteristic Prediction [J]. Journal of Automobile Engineering, 2020, 234(8): 2239-2259.

[4] 王昱昊. 网联汽车随机预测巡航控制及参数自学习方法研究 [D]. 长春: 吉林大学, 2022. (WANG Y H. Research on Stochastic Predictive Cruise Control and Parameter Self-learning Method for Networked Vehicles [D]. Changchun: Jilin University, 2022.)

[5] ZHANG S, XIONG R, SUN F C. Model Predictive Control for Power Management in a Plug-in Hybrid Electric

- Vehicle with a Hybrid Energy Storage System [J]. *Applied Energy*, 2017, 185: 1654-1662.
- [6] JING J B, KURT A, OZATAY E, et al. Vehicle Speed Prediction in a Convoy Using V2V Communication [C]//2015 IEEE 18th International Conference on Intelligent Transportation Systems. Piscataway, NJ: IEEE, 2015: 2861-2868.
- [7] MOZAFFARI L, MOZAFFARI A, AZAD N L. Vehicle Speed Prediction via a Sliding-Window Time Series Analysis and an Evolutionary Least Learning Machine: A Case Study on San Francisco Urban Roads [J]. *Engineering Science and Technology, an International Journal*, 2015, 18(2): 150-162.
- [8] XIE S S, HE H W, PENG J K. An Energy Management Strategy Based on Stochastic Model Predictive Control for Plug-in Hybrid Electric Buses [J]. *Applied Energy*, 2017, 196: 279-288.
- [9] WANG L H, CUI Y H, ZHANG F Q, et al. Stochastic Speed Prediction for Connected Vehicles Using Improved Bayesian Networks with Back Propagation [J]. *Science China Technological Sciences*, 2022, 65(7): 1524-1536.
- [10] SEEGER M. Gaussian Processes for Machine Learning [J]. *International Journal of Neural Systems*, 2004, 14(2): 69-106.
- [11] 张宇. 基于高斯过程回归的高铁制动过程速度预测 [D]. 北京: 北京交通大学, 2020. (ZHANG Y. Velocity Prediction of High-Speed Railway Braking Process Based on Gaussian Process Regression [D]. Beijing: Beijing Jiaotong University, 2020.)
- [12] SHI X Y, JIANG D G, QIAN W W, et al. Application of the Gaussian Process Regression Method Based on a Combined Kernel Function in Engine Performance Prediction [J]. *ACS Omega*, 2022, 7(45): 41732-41743.
- [13] LEFEVRE S, SUN C, BAJCSY R, et al. Comparison of Parametric and Non-parametric Approaches for Vehicle Speed Prediction [C]//2014 American Control Conference. Piscataway, NJ: IEEE, 2014: 3494-3499.
- [14] PAN Y, ZENG X K, XU H X, et al. Evaluation of Gaussian Process Regression Kernel Functions for Improving Groundwater Prediction [J]. *Journal of Hydrology*, 2021, 603: 126960-1-126960-15.
- [15] DEND T Q, YE D S, MA R, et al. Low-Rank Local Tangent Space Embedding for Subspace Clustering [J]. *Information Sciences*, 2020, 508: 1-21.
- [16] YANG X H, JIANG X Y, TIAN C X, et al. Inverse Projection Group Sparse Representation for Tumor Classification: A Low Rank Variation Dictionary Approach [J]. *Knowledge-Based Systems*, 2020, 196: 105768-1-105768-16.
- [17] SI S, HSIEH C J, DHILLON I S. Memory Efficient Kernel Approximation [J]. *Journal of Machine Learning Research*, 2017, 18(20): 1-32.
- [18] 曹通, 白艳萍. 基于梯度下降优化的 LSTM 对空气质量预测研究 [J]. *陕西科技大学学报*, 2020, 38(6): 159-164. (CAO T, BAI Y P. Prediction of Air Quality by LSTM Based on Gradient Descent Optimization [J]. *Journal of Shaanxi University of Science and Technology*, 2020, 38(6): 159-164.)
- [19] ARTEMVC A, BURT D R, VAN DER WILK M. Tighter Bounds on the Log Marginal Likelihood of Gaussian Process Regression Using Conjugate Gradients [C]//International Conference on Machine Learning. [S. l.]: PMLR, 2021: 362-372.
- [20] 于子望, 郑天琪, 程钰翔. 基于 PSO-XGB 混合优化技术的浅层地下温度预测——以长春市为例 [J]. *吉林大学学报(地球科学版)*, 2023, 53(6): 1907-1916. (YU Z W, ZHEGN T Q, CHENG Y X. Shallow Underground Temperature Prediction Based on PSO-XGB Hybrid Optimization Technology: A Case Study of Changchun City [J]. *Journal of Jilin University (Earth Science Edition)*, 2023, 53(6): 1907-1916.)
- [21] 王力, 贾欣雨. 基于 PSO-PF-SVM 的模拟电路故障诊断 [J]. *江苏大学学报(自然科学版)*, 2023, 44(2): 221-228. (WANG L, JIA X Y. Fault Diagnosis of Analog Circuits Based on PSO-PF-SVM [J]. *Journal of Jiangsu University (Natural Science Edition)*, 2019, 44(2): 221-228.)

(责任编辑: 韩 啸)