

doi:10.3969/j.issn.1672-4348.2022.01.001

基于 EKF 和 RBF 的路面附着系数估计

查云飞¹, 刘鑫烨¹, 马芳武^{1,2}, 吕小龙¹

(1. 福建工程学院 福建省汽车电子与电驱动技术重点实验室, 福建 福州 350118;
2. 吉林大学 汽车仿真与控制国家重点实验室, 吉林 长春 130025)

摘要: 针对车辆行驶下的路面附着系数估计问题, 提出了扩展卡尔曼滤波算法(EKF, extended kalman filter)与径向基神经网络(RBF, radial basis function neural network)相融合。通过扩展卡尔曼滤波算法得出路面附着系数估计所需要的车辆状态参数, 结合轮速等直接数据采用径向基神经网络对路面附着系数进行估计。神经网络的训练样本通过 Carsim/Simulink 收集不同行驶工况, 并采用差值寻优的方法对径向基神经网络算法中的决定系数进行优化。基于双移线工况验证了该算法在路面附着系数估计上具有较高的精度。

关键词: 路面附着系数; 算法融合; 扩展卡尔曼滤波; 径向基神经网络; 决定系数优化

中图分类号: U463.5

文献标志码: A

文章编号: 1672-4348(2022)01-0001-06

Estimation of road adhesion coefficient based on EKF and RBF

ZHA Yunfei¹, LIU Xinye¹, MA Fangwu^{1,2}, LYV Xiaolong¹

(1. Fujian Provincial Key Laboratory of Automotive Electronics and Electric Drive Technology,
Fujian University of Technology, Fuzhou 350118, China;

2. State Key Laboratory of Automotive Simulation and Control, Jilin University, Changchun 130025, China)

Abstract: Aiming at the problem of road adhesion coefficient estimation under vehicle driving, a fusion algorithm is proposed integrating extended Kalman filter and radial basis function neural network. The vehicle state parameters needed to estimate the road adhesion coefficient were obtained by the extended Kalman filter algorithm. Combined with the direct data such as wheel speed, the road adhesion coefficient was estimated by radial basis function neural network. Training samples of neural networks were collected by Carsim/Simulink in different driving conditions, and the decision coefficients of radial basis neural network algorithm were optimized by the method of difference optimization. Finally, the accuracy of the algorithm was verified based on double lane change conditions.

Keywords: road adhesion coefficient; algorithm fusion; extended Kalman filter; radial basis function neural network; determination coefficient optimization

电子制动力分配控制、电子稳定控制系统、侧倾稳定控制, 车辆的质心侧偏角、横摆角速度、纵向速度以及路面附着系数信息都是控制程序中的重要输入信息, 实时准确获取这些信息可以显著提高车辆的安全性。由于技术和成本方面的限制, 这些

参数通常无法直接获取, 由此衍生出的基于车载传感器获得的车辆状态信息进行汽车状态参数和路面附着系数估计成为国内外研究的热点。

王少帅等^[1]基于 MATLAB 搭建无迹卡尔曼滤波算法(unscented Kalman filter, UKF)估计器、三

收稿日期: 2021-11-01

基金项目: 福建工程学院科研基金项目(GY-Z19010)

第一作者简介: 查云飞(1981—), 男, 安徽怀宁人, 副教授, 博士, 研究方向: 汽车底盘动力学及控制, 新能源汽车驱动系统设计及控制。

自由度车辆动力学模型 Dugoff 轮胎模型成功对路面附着系数进行估计。吕梦男等^[2]基于非线性三自由度车辆动力学模型和扩展卡尔曼滤波算法(extended Kalman filter, EKF)的路面附着系数估计器,并在 MATLAB 和 Prescan、Carsim 的联合仿真中,验证了估计算法和制动稳定性的有效性。王健等^[3]提出了一种在制动工况下利用车轮轮速以及制动力矩估计路面附着系数的方法,并在 MATLAB/Simulink 中实现了扩张状态观测器对路面附着系数的估计。Krisztian Enisz 等^[4]提出基于魔术轮胎公式和扩展卡尔曼滤波算法估计轮胎与路面附着系数之间的最大值以及瞬时值,在硬件在环仿真中验证了算法的有效性。J. J. Rath 等^[5]提出一种基于超扭曲算法的滑模观测器来估计路面附着系数,仿真结果表明,该估计器能够实时跟踪路面附着系数的变化。

本文摒弃传统对路面附着系数的估计方法,利用 RBF 神经网络具有强分类的能力,对路面附着系数进行估计,同时,采用插值法对 RBF 神经网络进行参数优化,提高路面附着系数估计的准确性。

1 车辆状态参数估计

1.1 整车动力学模型

在二自由度车辆动力学模型上^[6],考虑纵向车速,搭建具有横摆角速度、质心侧偏角和纵向车速的三自由度模型,如图 1 所示。

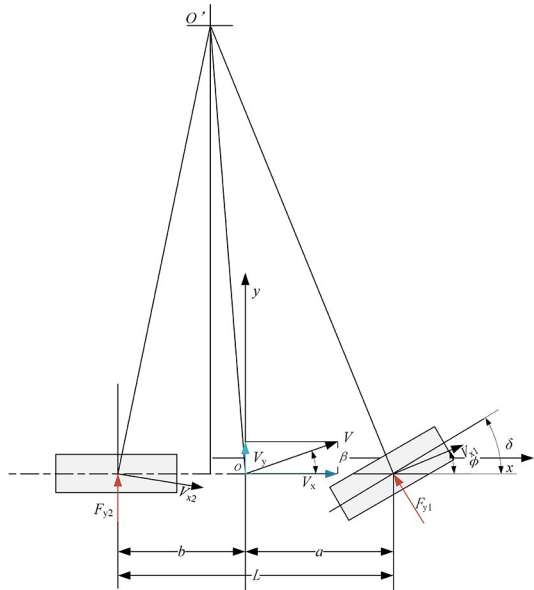


图 1 整车动力学模型

Fig.1 Vehicle dynamic model

图 1 中, F_{y1} 与 F_{y2} 分别为地面对前后轮的侧向反作用力; δ 为前轮转角, rad; β 为质心侧偏角, rad; V_x 和 V_y 分别为纵向车速与侧向车速, V 为 V_x 和 V_y 的速度, km/h; V_{x1} 和 V_{x2} 分别代表汽车前、后轴中点处的速度, km/h; a 为质心至前轴的距离, m; b 质心至后轴的距离, m; L 为前后轴距离, m。

作为车辆状态参数的估计目标, 状态方程与测量方程为:

$$\begin{aligned}\dot{\omega}_r &= \frac{a^2 k_1 + b^2 k_2}{I_z V_x} \omega_r + \frac{a k_1 - b k_2}{I_z} \beta - \frac{a k_1}{I_z} \delta \\ \dot{\beta} &= \left(\frac{a k_1 - b k_2}{m V_x^2} - 1 \right) \omega_r + \frac{k_1 + k_2}{m V_x} \beta - \frac{k_1}{m V_x} \delta \\ \dot{V}_x &= V_x \beta \omega_r + a_x\end{aligned}\quad (1)$$

$$a_y = \frac{a k_1 - b k_2}{m V_x} \omega_r + \frac{k_1 + k_2}{m} \beta - \frac{k_1}{m} \delta \quad (2)$$

式中, ω_r 为横摆角速度, rad/s; I_z 为转动惯量, $\text{kg} \cdot \text{m}^2$; k_1 为前轮的侧偏刚度, N/rad; k_2 后轴的侧偏刚度, N/rad; m 为汽车质量, kg; a_y 为侧向加速度, m/s^2 。

1.2 扩展卡尔曼滤波

EKF 的原理是通过简单的一阶 Taylor 展开, 将非线性方程简化为线性方程, 忽略状态方程的高阶项。

考虑状态噪声和观测噪声, 由式(1)和式(2)得到车辆的非线性函数。

$$x(t) = w(x(t), u(t), q(t)) \quad (3)$$

$$y(t) = z(x(t), r(t)) \quad (4)$$

式(3)、(4)中, $x(t)$ 代表系统状态变量; $y(t)$ 代表观测输出量; $u(t)$ 代表系统输入; $q(t)$ 代表状态噪声协方差矩阵, 且 $q(t) = I_{3 \times 3} \cdot 100$; $r(t)$ 代表观测噪声协方差矩阵且 $r(t) = [0.01]$ 。

通过公式(3)、(4), 求出状态方程和观测方程的偏导数, 得到雅可比矩阵:

$$W(t) = \left[\frac{\partial w(x)}{\partial x} \right]_{x=\hat{x}(t)} \quad (5)$$

$$Z(t) = \left[\frac{\partial z(x)}{\partial x} \right]_{x=\hat{x}(t)} \quad (6)$$

$$\gamma(t) = \exp(W(t)) \cdot \Delta t \approx W(t) \cdot \Delta t + 1 \quad (7)$$

式中: $W(t)$ 表示非线性函数, $w(x(t), u(t), q(t))$ 对状态变量求偏导的雅克比矩阵; $Z(t)$ 表

示非线性函数; $z(x(t), r(t))$ 对状态变量求偏导的雅克比矩阵; $\gamma(t)$ 表示状态转移矩阵; Δt 为采样时间。

$$W(t) = \begin{bmatrix} \frac{\omega_r a^2 + \beta b^2}{I_z V_x} & \frac{k_1 a - k_2 b}{I_z} \\ \frac{k_1 a - k_2 b - m v_x^2}{m V_x^2} & \frac{k_1 + k_2}{m V_x^2} \\ V_x \beta & V_x \omega_r \end{bmatrix} - \begin{bmatrix} -\frac{(k_1 a^2 + k_2 b^2)}{I_z V_x} \omega_r \\ -\frac{2 \omega_r (k_1 a - k_2 b)}{m V_x^3} - \beta \frac{(k_1 + k_2)}{m V_x^2} + \frac{\delta k_1}{m V_x^2} \\ \omega_r \beta \end{bmatrix} \quad (8)$$
$$Z(t) = \begin{bmatrix} \frac{k_1 a - k_2 b}{m V_x} \\ \frac{k_1 + k_2}{m} \\ -\frac{(k_1 a - k_2 b)}{m V_x^2} \end{bmatrix} \quad (9)$$

1.3 仿真分析

通过 Carsim 与 Matlab 进行联合仿真,利用 EKF 算法对车辆状态参数进行估计,仿真中所用的整车相关参数如表 1 所示。

表 1 仿真软件中汽车模型的相关参数

Tab.1 Relevant parameters of vehicle model in simulation software

整车各部分参数	数值
整车质量 m/kg	1 229
质心至前轴的距离 a/m	1.020
质心至后轴的距离 b/m	1.560
转动惯量 $I_z/(\text{kg} \cdot \text{m}^2)$	1 536.7
前轴侧偏刚度 $k_1/(\text{N} \cdot \text{rad}^{-1})$	-79 004
后轴侧偏刚度 $k_2/(\text{N} \cdot \text{rad}^{-1})$	-98 838
质心高度 h/m	0.54

通过 EKF 算法估计出的质心侧偏角、横摆角速度、纵向车速结果如图 2 所示。

图 2 中 EKF 线型代表由 EKF 算法所得出的估计值,ST value 线型代表由 Carsim 仿真软件直接输出的仿真实验值。从图 2(a)和图 2(c)可以看出,质心侧偏角和纵向车速的估计结果较为理想,误差整体控制在 15%以内。而从图 2(b)看出横摆角速度的估计结果较不理想,估计结果精度从 3 s 处开始漂移,估计误差较大,但 EKF 算法对

从公式(5)、(6)的雅克比矩阵可得线性化模型为:

车辆状态参数的估计仅作为后续径向基神经网络的训练样本,其结果不会对最终的路面附着系数估计产生决定性的影响。

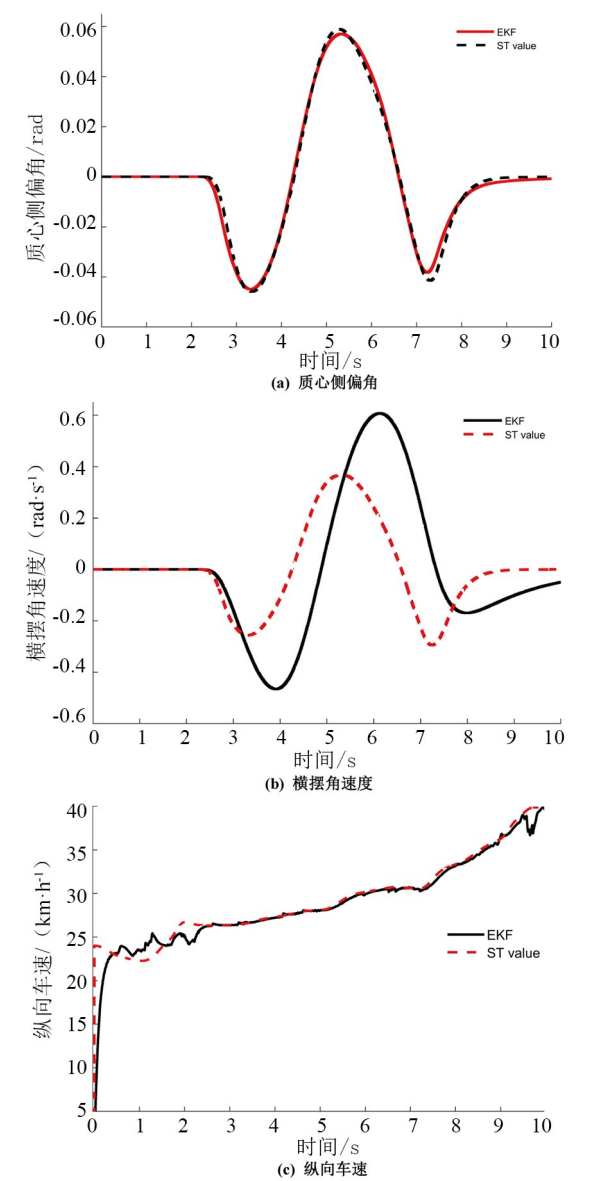


图 2 EKF 算法对车辆状态参数的估计结果

Fig.2 Estimated results of vehicle state parameters by EKF algorithm

2 双移线工况下的路面附着系数估计

结合车辆动力学模型和 Dugoff 轮胎模型,采用 Carsim/Simulink 联合仿真模拟双移线驾驶工况,采集车辆的纵向加速度、侧向加速度等参数以及通过 EKF 算法估计的质心侧偏角等数据作为径向神经网络的训练池并作为神经网络输入,将所得数据作为训练样本进行神经网络训练。

车轮工作在非线性区,结合车辆行驶时的受力分析与 Dugoff 轮胎模型,如式 (10) 所示。

$$\begin{aligned} a_y &= \frac{1}{m} \cdot [(F_{x1} + F_{x2}) \sin\delta + (F_{y1} + F_{y2}) \cos\delta + F_{y3} + F_{y4}] \\ a_x &= \frac{1}{m} \cdot [(F_{x1} + F_{x2}) \cos\delta - (F_{y1} + F_{y2}) \sin\delta + F_{x3} + F_{x4} + F_{wx}] \\ \mu_i &= \frac{2\sqrt{C_\sigma^2 \cdot \sigma_i^2 + C_\alpha^2 \cdot \tan^2 \alpha_i}}{F_{zi}(1 + \sigma_i)} \quad (i = 1, 2, 3, 4) \end{aligned} \quad (10)$$

通过建立车辆状态参数与路面附着系数之间的函数关系,得出当车辆的纵向加速度、侧向加速度、车轮转速、纵向车速、质心侧偏角、前轮转角、横摆角速度确定时,路面附着系数 μ 的方程必有解且唯一^[7],即

$$\mu = f(a_x, a_y, n_i, V_x, \beta, \delta, \omega_r)$$

式中, a_x 为纵向加速度, $\text{m} \cdot \text{s}^{-2}$; n_i 为车轮转速, $\text{r} \cdot \text{s}^{-1}$ 。

在实际车辆行驶时,车辆纵向行驶车速 V_x 、横摆角速度 ω_r 与质心侧偏角 β 无法直接由传感器获得,需要通过估计算法获得相关的状态参数并提供给神经网络,无法直接获取的状态参数由 1.2 节的 EKF 算法提供。

2.1 Dugoff 轮胎模型

Dugoff 轮胎模型公式如下^[8]:

$$F_{xi} = C_\sigma \frac{\sigma_i}{1 + \sigma_i} f(\lambda_i) \quad (11)$$

$$F_{yi} = C_\alpha \frac{\tan \alpha_i}{1 + \alpha_i} f(\lambda_i) \quad (12)$$

其中,

$$f(\lambda_i) = \begin{cases} (2 - \lambda_i) \lambda_i & \lambda_i \leq 1 \\ 1 & \lambda_i \geq 1 \end{cases} \quad (13)$$

$$\lambda_i = \frac{\mu F_{zi}(1 + \sigma_i)}{2\sqrt{C_\sigma^2 \cdot \sigma_i^2 + C_\alpha^2 \cdot \tan^2 \alpha_i}} \quad (14)$$

式中, σ_i 为轮胎滑移率; C_σ 为轮胎纵向刚度, $\text{N} \cdot \text{rad}^{-1}$; C_α 为轮胎侧偏刚度, $\text{N} \cdot \text{rad}^{-1}$; λ_i 为边界值,用来表述轮胎的非线性特性; F_{z1} , F_{zfr} , F_{zrl} , F_{zrr} 分别代表左前,右前,左后,右后车轮所受的垂直载荷。

$$\begin{aligned} F_{z1} &= \frac{mgb}{2L} + \frac{mha_x}{2L} - \frac{mbha_y}{cL} \\ F_{zfr} &= \frac{mgb}{2L} + \frac{mha_x}{2L} + \frac{mbha_y}{cL} \\ F_{zrl} &= \frac{mga}{2L} + \frac{mha_x}{2L} - \frac{maha_y}{cL} \\ F_{zrr} &= \frac{mga}{2L} + \frac{mha_x}{2L} + \frac{maha_y}{cL} \end{aligned} \quad (15)$$

式中: c 为轮距, m ; g 为重力加速度, $\text{m} \cdot \text{s}^{-2}$ 。

2.2 径向神经网络

RBF 网络学习速度快,适用于在线动态估计。本文通过 EKF 算法估计出质心侧偏角、横摆角速度、纵向车速并结合车辆纵向加速度等数据作为 RBF 神经网络的特征输入,对路面附着系数进行估计。

2.2.1 神经网络结构

RBF 网络结构分为两层:隐含径向基层和线性输出层,网络结构如图 3 所示。

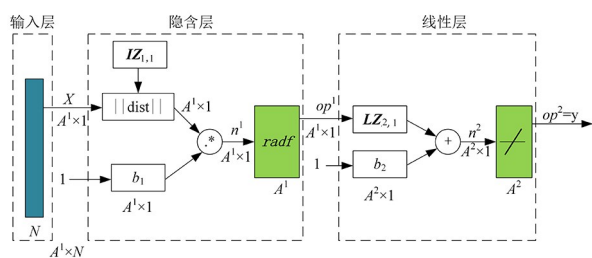


图 3 径向基神经网络结构图

Fig.3 RBF neural network structure

图 3 中, N 为输入向量中元素的个数; A^1 为隐含层神经元数目; A^2 为线性层神经元数目; $IZ_{1,1}$ 为输入权重矩阵; $LZ_{2,1}$ 为线性层权重矩阵; X 为输入样本; op^1 为径向基函数 radf ; $|| \text{dist} ||$ 为欧氏距离权函数; op^2 为线性传递函数 purelin ; b_1 、 b_2 分别为隐含层与线性层的神经元阈值; y 为最终输出结果。

$$op^1 = \text{radf}(| | IZ_{1,1} - X | | b_1)$$

$$op^2 = \text{purelin}(LZ_{2,1}op^1 - b_2)$$

在隐含层中,由 Kolmogorov 定理表明,隐含层神经元个数 S 和输入向量元素个数 N 的关系为: $S = 2N + 1$ 。因此,在纯 RBF 网络中隐含层神经元个数为 9,有 EKF 参与的 RBF 网络的隐含层神经元个数为 15。

2.2.2 神经网络样本采集

通过 Carsim 与 Simulink 联合仿真的方法,模拟不同附着系数以及不同行驶车速,采集转速 n_i 等数据作为 RBF 神经网络训练样本的输入,以路面附着系数 μ 作为输出。

仿真时间 10 s,采样频率 500 Hz,每种附着系数采集 5 000 组数据集,样本池共 15 000 份数据,同时将样本池中的数据按 3 : 2 的比例分为训练集和验证集,仿真工况如表 2 所示。

表 2 双移线驾驶工况下的样本采集情况
Tab.2 Sample collection under double lane-shifting driving conditions

附着系数	行驶车速/(km · h ⁻¹)
0.5	30
0.7	40
0.9	50

2.2.3 径向基神经网络训练及决定系数寻优

(一) 计算误差 e_j

$$e_j = d_j - f(X_j) = d_j - \sum_{i=1}^M \omega_i G(X_j, T_i) \quad (16)$$

式中: d_j 为期望输出; $f(X_j)$ 为网络估计输出; X_j 为第 j 个神经元输入; T_i 为神经元中心。

(二) 计算输出权重改变量

$$\frac{\partial E(n)}{\partial \omega_i(n)} = - \frac{1}{N} \sum_{j=1}^N e_j \exp\left(\frac{- \|X_j - T_i\|^2}{2\sigma_i^2}\right) \quad (17)$$

式中, N 为总输入样本个数。

(三) 计算隐含层神经元中心改变量

$$\frac{\partial E(n)}{\partial T_i(n)} = - \frac{\omega_i}{N\sigma_i^3} \sum_{j=1}^N e_j \exp\left(\frac{- \|X_j - T_i\|^2}{2\sigma_i^2}\right) (X_j - T_i)^2 \quad (18)$$

调整中心为:

$$T_i(n + 1) = T_i(n) - \eta_2 \frac{\partial E(n)}{\partial T_i(n)} \quad (19)$$

式中, η_2 为中心改变量调整时的学习速率。

(四) 计算输出权重改变量

$$\frac{\partial E(n)}{\partial T_i(n)} = - \frac{\omega_i}{N\sigma_i^3} \sum_{j=1}^N e_j \exp\left(\frac{- \|X_j - T_i\|^2}{2\sigma_i^2}\right) (X_j - T_i)^2 \quad (20)$$

调整宽度为:

$$\sigma_i(n + 1) = \sigma_i - \eta_3 \frac{\partial E(n)}{\partial \sigma_i(n)} \quad (21)$$

式中, η_3 为中心宽度调整时的学习速率。

(五) 计算总误差值

$$E = \frac{1}{2N} \sum_{j=1}^N e_j^2 \quad (22)$$

训练结果用决定系数 R^2 来表示,系数值越接近 1,则样本在 RBF 网络下的输出值与目标值相关性越高,体现网络训练效果越好。在 Matlab 中不同扩展速度的设置会最终影响决定系数 R^2 ,因此通过寻优算法对区间内的扩展速度值进行查找,使决定系数尽可能接近 1。假设寻优区间为 (a, b) ,采用差值二分法进行寻优,对区间内取 $a, b, (a + b)/2$ 作为扩展速度并通过 RBF 得出所对应的决定系数 $R^2(i)$, (i 为 $a, b, (a + b)/2$),利用差值得到:

$$e_1 = R^2(a) - R^2((a + b)/2)$$

$$e_2 = R^2(b) - R^2((a + b)/2)$$

若 $e_1 > e_2$,则说明优值处于区间 $((a + b)/2, b)$ 内,继续循环直至找到适合训练样本的扩展速度优值。扩展速度值越大神经网络激活函数越平滑,将会导致网络学习能力减弱,因此寻优区间设置 $(0, 100)$ 。

在单纯使用 RBF 算法进行路面附着系数估计时,其输入特征值为轮速、侧向加速度、纵向加速度和前轮转角。通过差值二分法寻优后,得到扩展速度结果值为 19,对应的决定系数 R^2 寻优值为 0.577。

采用 EKF+RBF 算法时,神经网络的参数输入发生了变化,增加质心侧偏角、横摆角速度和纵向车速 3 个特征值输入。采用上述相同的寻优方法,针对 EKF+RBF 算法下的决定系数进行寻优,得到的扩展速度结果值 57,对应的决定系数 R^2 寻优值为 0.847。

2.3 路面附着系数估计

考虑仿真工况不与训练样本重合,设置路面附着系数为 0.85、车速为 20~40 km/h,采用双移

线工况进行路面附着系数估计。同时,为了验证 EKF 算法在 RBF 神经网络估计路面附着系数中的重要性,将单纯使用 RBF 神经网络估计附着系数的结果作为对照组。

4 个车轮的估计结果及对比如图 4~图 7 所示,其中添加 N-EKF 前缀的代表直接单纯 RBF 算法估计结果,无添加 N-EKF 前缀的代表通过 EKF+RBF 相融合算法估计结果。

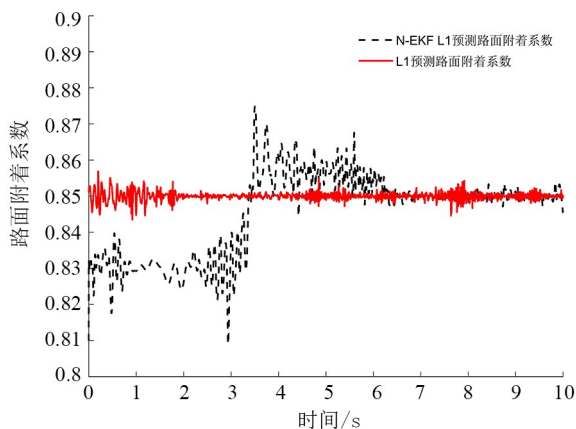


图 4 左前轮路面附着系数估计结果对比

Fig.4 Comparison of estimation results of road adhesion coefficient of left front wheel

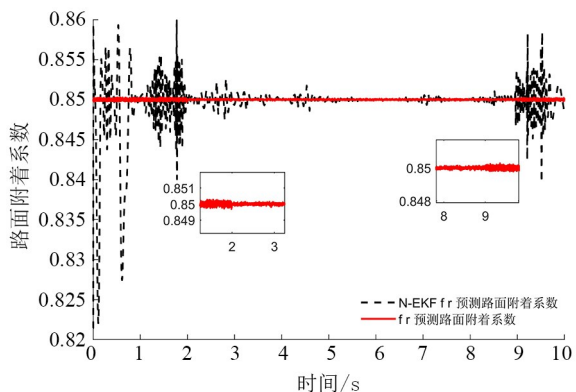


图 5 右前轮路面附着系数估计结果对比

Fig.5 Comparison of estimation results of road adhesion coefficient of right front wheel

从图 4~图 7 可看出,在路面附着系数估计上采用 EKF+RBF 相融合估计算法的结果比单纯 RBF 算法估计结果具有更高的精度,且最大相对误差均保持在 2% 内,而 N-EKF 下路面附着系数估计的最大相对误差分别达到 4.7%、3.31%、3.36%、4.7%。这是由于通过 EKF 所获得的质心侧偏角等状态特征值输入为 RBF 算法对路面附

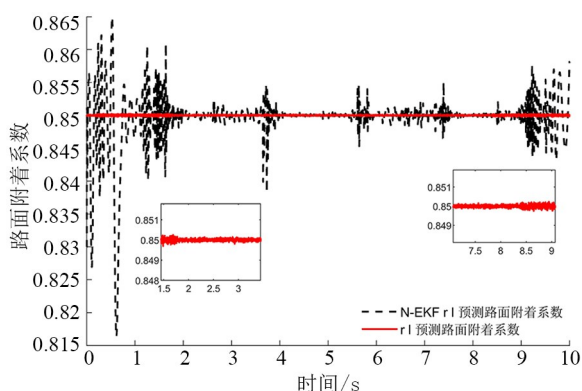


图 6 左后轮路面附着系数估计结果对比

Fig.6 Comparison of estimation results of road adhesion coefficient of left rear wheel

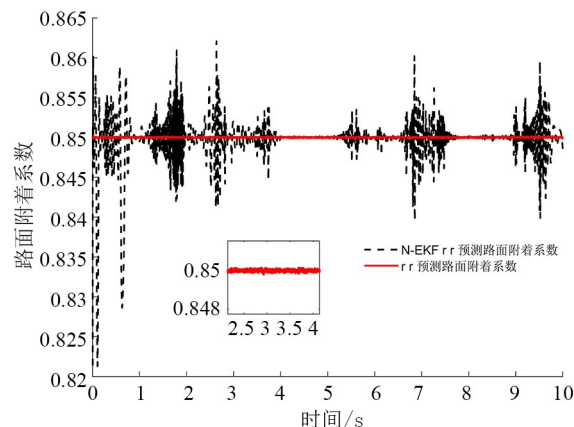


图 7 右后轮路面附着系数估计结果对比

Fig.7 Comparison of estimation results of road adhesion coefficient of right rear wheel

着系数估计提供了更多的样本特征。

从图 4~图 6 还可以看出,EKF+RBF 算法估计中,在 1~2 s 和 9~10 s 行驶时,估计结果有较大波动,原因在于采取寻优算法后,与之匹配的部分训练样本特征不明显。但从放大图中可以看出,波动的误差控制在 1% 左右,不会对估计结果产生过大的影响。从图 7 可以看出,在双移线驾驶时,RBF 网络对右后轮路面附着系数的估计结果相较于其他车轮路面附着系数的估计精度有所提升,且没有产生较大波动,估计结果优秀,相对误差控制在 1% 之内。从图 4~图 7 对比可看出,左前轮路面附着系数估计结果最差,右后轮估计结果最好,原因是车辆在双移线工况下行驶时,后轮没有转向的影响,训练样本的数据连贯性好,

(下转第 34 页)

- [5] LI X N, HOU S, HAN L Z, et al. Analysis of cracking causes of P91 welding seam of high pressure steam guide pipe of supercritical unit[J]. Journal of Physics: Conference Series, 2021, 1820(1): 012036.
- [6] KUMAR Y, DASH M K, MOITRA A, et al. Experimental investigation of creep crack growth behavior in the heat affected zone of boron added modified 9Cr-1Mo steel weld[J]. Materials Science and Engineering: A, 2021, 814: 141180.
- [7] 毕涛, 邓德安, 刘晓占, 等. 固态相变对 P91 钢焊接残余应力的影响[J]. 焊接学报, 2015, 36(9): 55-59, 116.
- [8] 郭庆虎, 胥国祥, 陈东高, 等. P91 钢多层多道同质补焊残余应力的数值模拟[J]. 焊接, 2020(9): 12-18, 61.
- [9] 胡泽训, 赵建平. 马氏体相变对 P91 多道焊残余应力的影响[J]. 热加工工艺, 2019, 48(17): 142-146, 149.
- [10] YAGHI A H, HYDE T H, BECKER A A, et al. A comparison between measured and modeled residual stresses in a circumferentially butt-welded P91 steel pipe[J]. Journal of Pressure Vessel Technology, 2010, 132(1): 011206.
- [11] 张彦斌. 9Cr-1Mo 钢焊接残余应力的数值模拟与实验验证[D]. 重庆: 重庆大学, 2017.
- [12] 杜博睿, 郭绍庆, 李能, 等. 超高强度不锈钢厚板多道 TIG 焊温度场和应力场数值模拟[J]. 焊接, 2014(12): 37-41, 66.
- [13] 吴振, 王发展, 安高灵, 等. 基于热循环曲线的分段移动组合型焊接热源研究[J]. 热加工工艺, 2015, 44(11): 211-216.
- [14] 王学, 胡磊, 陈东旭, 等. 马氏体相变对 9%Cr 热强钢管道多道焊接接头残余应力演化的影响[J]. 金属学报, 2017, 53(7): 888-896.

(责任编辑: 陈雯)

(上接第 6 页)

不会出现较大波动, 导致训练出来的径向基神经网络对后轮路面附着系数估计效果好。

3 结论

本文基于 Carsim/Simulink, 通过将 EKF 算法和 RBF 神经网络算法进行融合, 设计出路面附着系数估计算法, 并与单纯 RBF 神经网络估计结果

进行对比, 验证了该融合算法能有效提升路面附着系数估计的精度。同时, 在 RBF 神经网络算法中通过差值二分法对当前样本下的决定系数进行寻优, 尽可能发挥 RBF 神经网络优势, 准确估计路面附着系数。从双移线工况下的仿真结果可以得到, 采用 EKF+RBF 相融合的路面附着系数估计精度高于单纯 RBF 的估计精度。

参考文献:

- [1] 王少帅, 李登峰. 基于无迹卡尔曼滤波的路面附着系数估计[J]. 电子设计工程, 2020, 28(1): 27-31.
- [2] 吕梦男, 孙涛, 李洁. 基于扩展卡尔曼滤波的车辆状态参数估计[J]. 农业装备与车辆工程, 2018, 56(5): 77-80.
- [3] 王健, 杨君, 于蓬, 等. 不同路况下路面附着系数实时估计[J]. 河北科技大学学报, 2020, 41(2): 172-180.
- [4] ENISZ K, SZALAY I, KOHLRUSZ G, et al. Tyre-road friction coefficient estimation based on the discrete-time extended Kalman filter[J]. Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering, 2015, 229(9): 1158-1168.
- [5] RATH J J, VELUVOLU K C, ZHANG D, et al. Estimation of road adhesion coefficient using higher-order sliding mode observer for torsional tyre model[C]//Intelligent Robotics and Applications, 2013: 202-213.
- [6] 余志生. 汽车理论[M]. 5 版. 北京: 机械工业出版社, 2009: 108-109.
- [7] 宋涛. 轮毂驱动电动车的路面附着系数估计方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2017.
- [8] 周磊, 张向文. 基于 Dugoff 轮胎模型的爆胎车辆运动学仿真[J]. 计算机仿真, 2012, 29(6): 308-311, 385.
- [9] 樊旭, 黄颖, 冷文楠, 等. 基于径向基神经网络的地基微波辐射计反演算法研究[J]. 气象与环境学报, 2020, 36(2): 62-69.

(责任编辑: 陈雯)