基于鲁棒自适应UKF的分布式电动汽车状态估计

张志达, 郑玲*, 吴行, 乔旭强, 李以农

重庆大学汽车工程学院, 机械传动国家重点实验室, 重庆 400044

* E-mail: zling@cqu.edu.cn

收稿日期: 2019-09-15; 接受日期: 2019-12-20; 网络版发表日期: 2020-04-03

国家自然科学基金(批准号: 51875061)、重庆市研究生科研创新项目(编号: CYB19063)和重庆市技术创新与应用发展专项(编号: cstc2019jscx-zdztzxX0032)资助

摘要 准确的车辆状态参数是实现汽车主动安全和自动驾驶的关键。标准的无迹卡尔曼(UKF)算法, 在观测噪声较大或噪声协方差不匹配时, 会对车辆状态的估计精度产生严重影响。针对分布式电动汽车状态估计, 提出一种基于故障检测机制的鲁棒自适应UKF算法, 该算法利用观测变量的残差向量识别系统是否存在故障, 依据统计函数判断是否需要观测噪声协方差和过程噪声协方差进行自适应调整, 并基于权重因子更新协方差。设计了基于鲁棒自适应UKF的估计器, 对车辆的纵向车速、侧向车速和质心侧偏角三个重要状态变量进行估计。最后利用CarSim和MATLAB/Simulink联合仿真对算法进行了验证。结果表明, 所提出鲁棒自适应UKF算法能够明显降低三个状态变量的估计误差, 在精确性和鲁棒性上均优于标准的UKF算法, 为先进驾驶辅助系统以及自动驾驶的精确运动控制奠定了重要基础。

关键词 电动汽车, 分布式驱动, 状态估计, 鲁棒自适应UKF, 故障检测机制

1 引言

分布式电动汽车用线控系统代替机械传动结构, 可通过轮毂电机对车轮扭矩进行快速控制, 易于实现牵引控制(TC)、防抱死控制(ABS)和稳定性控制(ESC), 还可利用电机再生制动, 实现能量回收^[1-3]。由于在控制响应、主动安全和节能等方面具有明显的优势, 分布式驱动必将成为电动汽车重要的发展方向^[4]。实时准确的测量、估计车辆状态是实现分布式电动汽车主动安全控制和自动驾驶控制的关键^[5]。

由于现有传感器的成本较高, 且GPS获取的数据

难以满足车辆运动控制需求, 基于低成本车载传感器和车辆模型的状态估计方法成为研究热点^[6-8]。目前, 国内外学者多采用卡尔曼(Kalman filter, KF)、扩展卡尔曼(extended Kalman filter, EKF)、无迹卡尔曼(unscented Kalman filter, UKF)和容积卡尔曼(cubature Kalman filter, CKF)等算法对车辆状态进行估计。文献^[9]结合递推最小二乘法和KF设计了一种用于估计车辆质心侧偏角和侧倾角的估计器。文献^[10]基于全球导航卫星系统(global navigation satellite system, GNSS)设计了一种用于估计车辆纵向速度、侧向速度和横摆角速度的自适应EKF估计器。文献^[11]考虑EKF

引用格式: 张志达, 郑玲, 吴行, 等. 基于鲁棒自适应UKF的分布式电动汽车状态估计. 中国科学: 技术科学, 2020, 50: 1461-1473

Zhang Z D, Zheng L, Wu H, et al. State estimation of distributed electric vehicle based on robust adaptive UKF (in Chinese). Sci Sin Tech, 2020, 50: 1461-1473, doi: 10.1360/SST-2019-0326

估计器新息和残差的动态变化, 基于开窗法修正了观测噪声方差和过程噪声方差, 进而提出一种噪声自适应EKF算法, 并对分布式电动汽车的行驶状态进行了估计. 文献[12]考虑系统噪声和测量噪声的不确定性, 基于滑动窗口长度自适应调整规则修正卡尔曼滤波增益和状态误差协方差矩阵, 提高了EKF算法对车辆状态估计的适应性和精确性. 文献[13]结合车辆动力学模型和UKF算法对车轮滑移率和车辆质心侧偏角进行了估计. 文献[14]为减小UKF估计器的噪声干扰, 利用ANFIS观测器测量伪质心侧偏角, 提出了一种结合ANFIS和UKF的质心侧偏角估计方法. 文献[15]利用模糊规则对UKF算法的观测噪声协方差矩阵进行调整, 提出了一种基于自适应UKF的车辆状态估计算法. 文献[16]设计了平方根CKF车辆非线性状态观测器, 对分布式电动汽车的质心侧偏角和轮胎侧向力进行了估计. 文献[17]在文献[16]的基础上将噪声分为三个等级, 基于马尔可夫转移概率矩阵提出了多模CKF算法. 文献[18]针对汽车行驶过程中观测变量存在野值问题, 提出了一种抗野值鲁棒CKF估计算法, 并利用CarSim和MATLAB/Simulink联合仿真对算法的实时性进行了验证.

传统的KF算法仅适用于线性系统, 在状态估计中具有局限性. EKF算法将非线性系统一阶线性化, 在估计复杂工况下的车辆状态时, 误差累积会逐渐增大. 尽管文献[10~12]采用不同算法减小了噪声的干扰, 但是线性化过程中的误差问题仍然不能避免. CKF算法在准确性上优于UKF算法, 然而, 当涉及高维状态时, CKF存在固有的非局部采样问题[19]. 因此, 在各领域状态估计研究中, 尤其涉及高维状态时, 学者们通常选择对UKF进行改进使用. 文献[20]结合当前时刻和前一时刻残差向量的增益矩阵, 在UKF算法的基础上提出了一种鲁棒双增益UKF算法. 文献[21]结合强跟踪滤波(strong tracking filter, STF)算法和UKF算法, 提出了一种自适应主从UKF算法. 但是, 在计算增益矩阵和因子矩阵时, 文献[20,21]均将观测方程进行了线性化处理, 这样必然会降低状态预测值的精度. 文献[22]通过调整观测噪声协方差和过程噪声协方差的自适应因子, 提出了一种改进的变换UKF算法. 然而在计算自适应因子时, 文献[22]同时结合了开窗法、遗传算法和粒子滤波算法, 这会严重影响算法的计算效率. 根据对研究现状的分析, 可以看出在不影响鲁棒性和实

时性的同时, 提高UKF算法的估计精度具有重要的应用意义.

鉴于此, 本文提出一种基于故障检测机制的鲁棒自适应UKF算法, 对车辆的纵向车速、侧向车速和质心侧偏角进行估计. 该算法利用动态残差向量判断系统是否出现故障, 基于统计函数和权重因子自适应调整UKF估计器的观测噪声协方差和过程噪声协方差. 利用CarSim和MATLAB/Simulink联合仿真, 基于高低-中路面附着系数连续变化的蛇行转向工况, 验证了所提算法的精确性和鲁棒性.

2 分布式电动汽车动力学模型

2.1 车辆动力学模型

为便于对分布式电动汽车的状态进行实时估计, 建立车辆动力学模型, 如图1所示. 模型忽略悬架动力学和车轮外倾的影响, 并假设道路的侧倾角和坡度角均为零. 其中, x 轴表示纵向, 以车辆行驶方向为正; y 轴表示侧向, 以左侧为正. 图中符号含义如下: δ_f 为前轮转角; v_x 为纵向车速; v_y 为侧向车速; β 为质心侧偏角; γ 为横摆角速度; B_l 为轮距; l_i 为车轴至质心距离; F_{xij} 和 F_{yij} 为轮胎纵向力和侧向力. 其中, $i=f, r$ 表示前和后; $j=l, r$ 表示左和右.

根据达朗贝尔原理, 表示纵向运动、侧向运动和横摆运动的车身动力学方程如下[23]:

$$\dot{v}_x = v_y \gamma + a_x, \quad (1)$$

$$\dot{v}_y = -v_x \gamma + a_y, \quad (2)$$

图1 (网络版彩图)分布式电动汽车动力学模型

Figure 1 (Color online) A dynamics model of the distributed electric vehicle.

$$\beta = \arctan(v_y / v_x), \quad (3)$$

$$\dot{\gamma} = \frac{1}{I_z} \left\{ \frac{B_{fl}}{2} [(F_{xfl} - F_{xfr}) \cos \delta_f + (F_{yfl} - F_{yfr}) \sin \delta_f] \right. \\ \left. + l_f [(F_{xfl} + F_{xfr}) \sin \delta_f + (F_{yfl} + F_{yfr}) \cos \delta_f] \right. \\ \left. + \frac{B_r}{2} (F_{xrr} - F_{xrl}) - l_r (F_{yrl} + F_{yrr}) \right\}, \quad (4)$$

式中, a_x 为纵向加速度; a_y 为侧向加速度; I_z 为整车绕 z 轴的转动惯量. 其中, 车辆加速度与轮胎纵向力和侧向力有如下关系:

$$a_x = \frac{1}{m} [(F_{xfl} + F_{xfr}) \cos \delta_f - (F_{yfl} + F_{yfr}) \sin \delta_f \\ + F_{xrl} + F_{xrr} - F_w], \quad (5)$$

$$a_y = \frac{1}{m} [(F_{xfl} + F_{xfr}) \sin \delta_f + (F_{yfl} + F_{yfr}) \cos \delta_f \\ + F_{yrl} + F_{yrr}], \quad (6)$$

式中, m 为整车质量; $F_w = \rho C_d A_f v_x^2 / 2$ 为空气阻力; ρ 为空气密度; C_d 为空气阻力系数; A_f 为汽车正面迎风面积.

4 个车轮旋转运动的动力学方程为

$$\dot{\omega}_{ij} = \frac{1}{J_{ij}} [T_{ij} - (F_{xij} + F_{fij}) R_e], \quad (7)$$

式中, ω_{ij} 为车轮转速; J_{ij} 为车轮转动惯量; R_e 为车轮有效半径; T_{ij} 为电机转矩; $F_{fij} = f F_{zij}$ 为滚动阻力, f 为滚动阻力系数; F_{zij} 为轮胎垂向载荷.

2.2 轮胎动力学模型

刷子轮胎模型不同于复杂的魔术公式轮胎模型, 其计算参数少, 且可以准确描述轮胎纵向力和侧向力与侧偏角、滑移率、轮胎垂向载荷和路面附着系数等的非线性关系. 纵向力和侧向力联合模型定义为^[24,25]

$$F = \begin{cases} Cs - \frac{(Cs)^2}{3\mu F_z} + \frac{(Cs)^3}{27(\mu F_z)^2}, & |s| < s_m \\ \mu F_z, & |s| \geq s_m \end{cases} \quad (8)$$

$$C = 4a^2 b k_e, \\ s_m = 3\mu F_z / C, \\ s = \sqrt{s_x^2 + s_y^2}. \quad (9)$$

轮胎的纵向力和侧向力可分别表示为

$$F_x = \frac{s_x}{s} F, \quad F_y = \frac{s_y}{s} F, \quad (10)$$

式中, a 为半接地长度; b 为半接地宽度; k_e 为胎面分布刚度; s 为总滑移率; s_x 为纵向滑移率; s_y 为侧向滑移率; F_z 为轮胎垂向载荷; μ 为路面附着系数. 其中, 各轮胎的纵向和侧向滑移率可表示为

$$s_{xij} = \frac{R_e \omega_{ij} - v_{ij}}{\max(R_e \omega_{ij}, v_{ij})}, \quad s_{yij} = \frac{v_{ij}}{R_e \omega_{ij}} \tan \alpha_{ij}, \quad (11)$$

式中, v_{ij} 为车轮中心速度; α_{ij} 为轮胎侧偏角, 计算式为

$$\begin{cases} v_{fl,r} = (v_x \mp 0.5 B_f \gamma) \cos \delta_f + (v_y + l_f \gamma) \sin \delta_f, \\ v_{rl,r} = v_x \mp 0.5 B_r \gamma, \end{cases} \quad (12)$$

$$\begin{cases} \alpha_{fl,r} = \delta_f - \arctan \left(\frac{v_y + l_f \gamma}{v_x \mp 0.5 B_f \gamma} \right), \\ \alpha_{rl,r} = -\arctan \left(\frac{v_y - l_r \gamma}{v_x \mp 0.5 B_r \gamma} \right). \end{cases} \quad (13)$$

各轮胎垂向载荷的计算式为

$$\begin{cases} F_{zfl,r} = \frac{mgl_r - m a_x h_c}{2(l_f + l_r)} \mp \frac{a_y m h_c l_r}{B_f(l_f + l_r)}, \\ F_{zrl,r} = \frac{mgl_f + m a_x h_c}{2(l_f + l_r)} \mp \frac{a_y m h_c l_f}{B_r(l_f + l_r)}, \end{cases} \quad (14)$$

式中, h_c 为车辆质心高度.

3 系统状态空间模型

为便于进行状态估计, 需先写出系统的状态空间模型, 状态方程与观测方程的形式如下:

$$\begin{cases} \dot{\mathbf{x}}(t) = \mathbf{f}[\mathbf{x}(t), \mathbf{u}(t)] + \mathbf{w}(t), \\ \mathbf{z}(t) = \mathbf{h}[\mathbf{x}(t), \mathbf{u}(t)] + \mathbf{v}(t), \end{cases} \quad (15)$$

式中, $\mathbf{x}(t)$ 为状态变量; $\mathbf{u}(t)$ 为输入变量; $\mathbf{z}(t)$ 为观测变量; $\mathbf{w}(t)$ 为过程噪声; $\mathbf{v}(t)$ 为观测噪声.

本文旨在利用纵向加速度、侧向加速度、横摆角速度、前轮转角和车轮转速等易于获取的车辆状态信息, 估计纵向车速、侧向车速和质心侧偏角. 为了充分利用观测信息, 将观测值作为状态变量的一部分^[12,17]. 故定义状态变量为

$$\mathbf{x}(t) = [v_x, v_y, \beta, a_x, a_y, \gamma]^T, \quad (16)$$

输入变量为

$$\mathbf{u}(t) = [\delta_f, \omega_{ij}]^T, \quad (17)$$

观测变量为

$$\mathbf{z}(t) = [a_x, a_y, \gamma]^T. \quad (18)$$

进行离散化, 则系统可以表示为

$$\begin{cases} \mathbf{x}_k = f(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}) + \mathbf{w}_{k-1} \\ \mathbf{z}_k = h(\mathbf{x}_k, \mathbf{u}_k) + \mathbf{v}_k. \end{cases} \quad (19)$$

4 标准UKF算法及其鲁棒性分析

4.1 标准UKF算法

标准UKF算法^[26,27]如下.

(1) 系统参数初始化

设置初始的状态变量 $\mathbf{x}_{0|0}$ 和误差协方差 $\mathbf{P}_{0|0}$.

(2) 计算Sigma点

$$\mathbf{x}_{k-1|k-1} = [\bar{\mathbf{x}}_{k-1|k-1} \quad \bar{\mathbf{x}}_{k-1|k-1} \pm \sqrt{(n+\tau)\mathbf{P}_{k-1|k-1}}]. \quad (20)$$

(3) 状态变量和误差协方差一步预测

$$\mathbf{x}_{k|k-1}^{(i)} = f(\mathbf{x}_{k-1|k-1}^{(i)}, \mathbf{u}_{k-1}), \quad (21)$$

$$\bar{\mathbf{x}}_{k|k-1} = \sum_{i=0}^{2n} \omega_m^{(i)} \mathbf{x}_{k|k-1}^{(i)} \quad (22)$$

$$\mathbf{P}_{k|k-1} = \sum_{i=0}^{2n} \omega_c^{(i)} [\mathbf{x}_{k|k-1}^{(i)} - \bar{\mathbf{x}}_{k|k-1}] [\mathbf{x}_{k|k-1}^{(i)} - \bar{\mathbf{x}}_{k|k-1}]^T + \mathbf{Q}_{k-1}, \quad (23)$$

其中,

$$\begin{cases} \omega_m^{(0)} = \frac{\tau}{n+\tau}, \\ \omega_c^{(0)} = \frac{\tau}{n+\tau} + (1 - \alpha^2 + \beta), \\ \omega_m^{(i)} = \omega_c^{(i)} = \frac{\tau}{2(n+\tau)}, \quad i = 1, \dots, 2n, \end{cases} \quad (24)$$

$$\tau = \alpha^2(n + \kappa) - n, \quad (25)$$

式中, ω_m 为Sigma点的均值加权值, ω_c 为协方差加权值; i 为采样点顺序; $\tau = \alpha^2(n + \kappa) - n$ 为缩放系数, 决定总的预测误差; α 为尺度参数, 决定采用点分布, 取为0.001; κ 为次级缩放系数, 通常取为0; β 为权重因子, 用来合并高阶项的动差, 通常取为2.

(4) 更新Sigma点

$$\mathbf{x}_{k|k-1}^{(i)} = [\bar{\mathbf{x}}_{k|k-1} \quad \bar{\mathbf{x}}_{k|k-1} \pm \sqrt{(n+\tau)\mathbf{P}_{k|k-1}}]. \quad (26)$$

(5) 计算观测变量预测值

$$\mathbf{z}_{k|k-1}^{(i)} = h(\mathbf{x}_{k|k-1}^{(i)}, \mathbf{u}_k), \quad (27)$$

$$\bar{\mathbf{z}}_{k|k-1} = \sum_{i=0}^{2n} \omega_m^{(i)} \mathbf{z}_{k|k-1}^{(i)}. \quad (28)$$

(6) 计算观测协方差和互协方差

$$\mathbf{P}_{k|k-1}^{zz} = \sum_{i=0}^{2n} \omega_m^{(i)} [\mathbf{z}_{k|k-1}^{(i)} - \bar{\mathbf{z}}_{k|k-1}] [\mathbf{z}_{k|k-1}^{(i)} - \bar{\mathbf{z}}_{k|k-1}]^T + \mathbf{R}_k, \quad (29)$$

$$\mathbf{P}_{k|k-1}^{xz} = \sum_{i=0}^{2n} \omega_m^{(i)} [\mathbf{x}_{k|k-1}^{(i)} - \bar{\mathbf{x}}_{k|k-1}] [\mathbf{z}_{k|k-1}^{(i)} - \bar{\mathbf{z}}_{k|k-1}]^T. \quad (30)$$

(7) 计算增益矩阵

$$\mathbf{K}_k = \mathbf{P}_{k|k-1}^{xz} (\mathbf{P}_{k|k-1}^{zz})^{-1}. \quad (31)$$

(8) 更新状态变量和误差协方差

$$\bar{\mathbf{x}}_{k|k} = \bar{\mathbf{x}}_{k|k-1} + \mathbf{K}_k (\mathbf{z}_k - \bar{\mathbf{z}}_{k|k-1}), \quad (32)$$

$$\mathbf{P}_{k|k} = \mathbf{P}_{k|k-1} - \mathbf{K}_k \mathbf{P}_{k|k-1}^{zz} \mathbf{K}_k^T. \quad (33)$$

4.2 UKF鲁棒性分析

标准的UKF算法将观测噪声协方差 $\mathbf{R}$ 和过程噪声协方差 $\mathbf{Q}$ 设置为常值, 当选取的 $\mathbf{R}$ 和 $\mathbf{Q}$ 先验值与实际值不匹配时, 会增大估计器的跟踪误差, 甚至可能导致发散^[28,29]. 在工程实际中, 由于汽车行驶工况的不同, 传感器测得的数据往往会伴随着不确定的干扰噪声, 故难以获取相对准确的 $\mathbf{R}$ 和 $\mathbf{Q}$ 先验值, UKF算法也会因此而丧失鲁棒性. 为分析观测噪声对UKF鲁棒性的影响, 选取纵向车速、侧向车速和质心侧偏角等状态变量的估计误差作为评价指标. 取车速 $v_x = 50$ km/h、路面附着系数 $\mu = 0.85$ 的蛇行转向工况, 进行三种不同噪声干扰的仿真, 假定三种观测噪声 $\mathbf{Rz}$ 分别为0, $\mathbf{R}_0$ 和 $3\mathbf{R}_0$, 其中 $\mathbf{R}_0 = \text{diag}([0.02, 0.35, 0.02])$. 将误差协方差 $\mathbf{P}$ 初始值、观测噪声协方差 $\mathbf{R}$ 和过程噪声协方差 $\mathbf{Q}$ 分别设置为

$$\mathbf{P} = \text{diag}([1, 1, 1, 1, 1, 1]), \quad (34)$$

$$\mathbf{R} = \text{diag}([0.1, 0.2, 0.1]), \quad (35)$$

$$\mathbf{Q} = \text{diag}([0.02, 0.02, 0.02, 0.02, 0.02, 0.02]). \quad (36)$$

三种观测噪声下各状态变量的估计误差如图2所示, 估计误差的均方根对比如表1所示.

图 2 (网络版彩图)三种观测噪声下的估计误差对比。(a) 纵向车速误差; (b) 侧向车速误差; (c) 质心侧偏角误差

Figure 2 (Color online) Comparison of estimation errors under three observation noises. (a) Longitudinal speed error; (b) lateral speed error; (c) sideslip angle error.

表 1 不同噪声下的估计误差对比

Table 1 Comparison of estimation errors under different noises

观测噪声	状态变量估计误差均方根值 ($\times 10^{-3}$)		
	纵向车速	侧向车速	质心侧偏角
0	0.5191	1.5000	0.0971
R_o	9.1256	5.1723	0.4239
$3R_o$	11.0847	13.9447	1.0302

由图2可知, 不同的观测噪声干扰会使UKF估计器的估计误差存在较大差异. 随着观测噪声的增大, 纵向车速、侧向车速和质心侧偏角三个状态变量的估计误差均变大, 且波动幅度亦变大. 分析表1可知, 观测噪声为 R_o 时, 三个状态变量估计误差的均方根值相对无观测噪声时分别增大了16.58倍、2.45倍和3.37倍; 当观测噪声为 $3R_o$ 时, 各状态变量估计误差的均方根值相对无观测噪声时分别增大了20.35倍、8.30倍和9.61倍. 通过对比可知: 当 R 和 Q 取为常值时, 观测噪声的增大会造成估计误差的明显增大, 从而使得UKF算法的鲁棒性变差. 可见, 当车载传感器受到较大的噪声干扰时, UKF估计器的输出结果可能会严重失真, 尤其从图2(a)中可以看出, 随着估计器工作时间的增加, 各状

态变量的估计误差甚至会出现累积现象. 因此, 想要保障UKF估计器在各行驶工况下均能准确地估计车辆状态信息, 应当使得UKF算法中的 R 和 Q 值可根据实时噪声自适应调整.

5 鲁棒自适应UKF算法

5.1 系统故障检测机制

当观测噪声较小时, 适当的协方差 R 和 Q 值可使得UKF算法具有较好的精度. 然而, 当观测噪声过大或选取的 R 和 Q 先验值不合适时, 就会导致UKF算法失效, 从而造成估计器的输出结果不准确^[30]. 为此, 本文提出了一种鲁棒自适应UKF算法. 该算法可根据观测噪声残差向量的变化判断系统是否出现故障, 并对协方差矩阵 R 和 Q 值进行自适应调整. 故障检测机制原理如下.

对噪声协方差矩阵 R 和 Q 更新之前, 需要判断其必要性, 即检测系统是否存在故障, 采用如下统计函数判断^[31,32].

$$\lambda_k = \mathbf{e}_k^T [\mathbf{P}_{k|k}^{zz}]^{-1} \mathbf{e}_k, \quad (37)$$

式中, λ_k 服从一个自由度为 s 的 χ^2 分布; s 为残差向量 $\mathbf{e}_k$ 的

维数. 如果用确定概率 ρ 检测系统是否存在故障, 则检测阈值 $\chi_{\rho,s}^2$ 可由 λ_k 的 χ^2 分布确定:

$$P(\lambda_k > \chi_{\rho,s}^2) = \rho, \quad (38)$$

式中, ρ 为能够检测到系统故障的概率, 表示统计值 λ_k 大于阈值 $\chi_{\rho,s}^2$ 的可信度. 当 $\lambda_k > \chi_{\rho,s}^2$ 被误检为 $\lambda_k \leq \chi_{\rho,s}^2$ 时, 其概率为 $P(\lambda_k \leq \chi_{\rho,s}^2) = 1 - \rho$, 表示用概率值 ρ 计算相应的故障检测阈值 $\chi_{\rho,s}^2$ 时, 统计值 $\lambda_k > \chi_{\rho,s}^2$ 存在 $1 - \rho$ 的不可信度.

5.2 观测噪声协方差R自适应

定义状态估计器的残差向量 $\mathbf{e}_k$ 为观测变量实际值与其估计值的误差, 根据式(19)可得

$$\mathbf{e}_k = \mathbf{z}_k - h(\hat{\mathbf{x}}_{k|k}, \mathbf{u}_k). \quad (39)$$

参考标准UKF算法, 结合式(29)和(39), 观测噪声协方差的估计值可表示为

$$\hat{\mathbf{R}}_k = E[\mathbf{e}_k \mathbf{e}_k^T] - \mathbf{S}_{k|k-1}^{zz}, \quad (40)$$

其中,

$$\begin{aligned} \mathbf{S}_{k|k-1}^{zz} = & \sum_{i=0}^{2n} \omega_m^{(i)} \left[h(\mathbf{x}_{k|k-1}^{(i)}, \mathbf{u}_k) - \bar{\mathbf{z}}_{k|k-1} \right] \\ & \times \left[h(\mathbf{x}_{k|k-1}^{(i)}, \mathbf{u}_k) - \bar{\mathbf{z}}_{k|k-1} \right]^T. \end{aligned} \quad (41)$$

根据文献[33]分析, 协方差矩阵 $\hat{\mathbf{R}}_k$ 应该是正定的, 而式(40)中存在两项相减, 故并不能保证其绝对正定. 因此, 参考文献[34,35]中的分析, 可以将观测噪声协方差矩阵表示为

$$\hat{\mathbf{R}}_k = \text{cov}(\mathbf{v}_k) = E[\mathbf{e}_k \mathbf{e}_k^T] + \mathbf{S}_{k|k}^{zz}, \quad (42)$$

其中,

$$\begin{aligned} \mathbf{S}_{k|k}^{zz} = & \sum_{i=0}^{2n} \omega_m^{(i)} \left[h(\mathbf{x}_{k|k}^{(i)}, \mathbf{u}_k) - \bar{\mathbf{z}}_{k|k} \right] \\ & \times \left[h(\mathbf{x}_{k|k}^{(i)}, \mathbf{u}_k) - \bar{\mathbf{z}}_{k|k} \right]^T, \end{aligned} \quad (43)$$

$$\bar{\mathbf{z}}_{k|k} = \sum_{i=0}^{2n} \omega_m^{(i)} h(\mathbf{x}_{k|k}^{(i)}, \mathbf{u}_k). \quad (44)$$

观测噪声协方差 $\mathbf{R}_k$ 的自适应调整是基于权重因子 p 平衡噪声协方差与当前的估计值. 当 λ_k 超过阈值 $\chi_{\rho,s}^2$ 时, $\mathbf{R}_k$ 进行自适应更新. 因此, 可将观测噪声协方差矩阵更新为

$$\mathbf{R}_k = (1 - p)\mathbf{R}_k + p(\mathbf{e}_k \mathbf{e}_k^T + \mathbf{S}_{k|k}^{zz}), \quad (45)$$

其中,

$$p = \max\{p_o, (\lambda_k - \chi_{\rho,s}^2) / \lambda_k\}, \quad (46)$$

式中, p_o 为权重因子极限值. 为确保观测噪声协方差矩阵具有一定更新强度, 且不影响算法的估计精度, 取极限值 $p_o \in (0, 1)$.

5.3 过程噪声协方差Q自适应

根据式(19), 可以将UKF估计器状态变量的噪声估计值表示为

$$\hat{\mathbf{w}}_{k-1} = \hat{\mathbf{x}}_k - f(\hat{\mathbf{x}}_{k-1|k-1}, \mathbf{u}_{k-1}). \quad (47)$$

结合式(21)与(22), 有

$$\hat{\mathbf{x}}_{k|k-1} \approx f(\hat{\mathbf{x}}_{k-1|k-1}, \mathbf{u}_{k-1}). \quad (48)$$

由式(32)可得

$$\hat{\mathbf{w}}_{k-1} \approx \hat{\mathbf{x}}_k - \hat{\mathbf{x}}_{k|k-1} = \mathbf{K}_k(\mathbf{z}_k - \bar{\mathbf{z}}_{k|k-1}) = \mathbf{K}_k \delta_k. \quad (49)$$

为提高估计器的计算效率, 避免再次进行UT变换, 将式(49)中的观测变量预测值表示为

$$\bar{\mathbf{z}}_{k|k-1} \approx h(\hat{\mathbf{x}}_{k|k-1}, \mathbf{u}_k). \quad (50)$$

可以得到过程噪声协方差矩阵 $\mathbf{Q}_{k-1}$ 的估计值为

$$\hat{\mathbf{Q}}_{k-1} = \text{cov}(\hat{\mathbf{w}}_{k-1}) = \mathbf{K}_k E[\delta_k \delta_k^T] \mathbf{K}_k^T. \quad (51)$$

因此, 可将过程噪声协方差矩阵更新为

$$\mathbf{Q}_{k-1} = (1 - q)\mathbf{Q}_{k-1} + q(\mathbf{K}_k \delta_k \delta_k^T \mathbf{K}_k^T), \quad (52)$$

其中,

$$q = \max\{q_o, (\lambda_k - \chi_{\rho,s}^2) / \lambda_k\}, \quad (53)$$

式中, q 为权重因子; q_o 为权重因子极限值, 取值范围同 p_o .

5.4 鲁棒自适应UKF工作流程

基于故障检测机制, 对观测噪声协方差和过程噪声协方差进行自适应更新, 并将二者与标准的UKF滤波算法结合, 便可得到所提出的鲁棒自适应UKF算法, 其工作流程如图3所示. 对车辆状态估计分析时, 以方向盘转角(可根据比例系数化为前轮转角)、各车轮转速作为输入量, 以可利用低成本传感器获得的纵向加

图3 (网络版彩图) 鲁棒自适应UKF估计器工作流程

Figure 3 (Color online) Workflow of the robust adaptive UKF estimator.

速度、侧向加速度和横摆角速度作为输出量,即估计器的观测变量^[12,36]。同时,用随机白噪声信号模拟传感器受到的噪声干扰^[31~33]。汽车行驶过程中,测量信号实时输入到估计器中,估计器首先根据观测信息和UKF主程序计算系统的残差向量 $\mathbf{e}_k$,接着基于统计函数 λ_k 对系统进行故障检测,然后利用式(45)和(52)对噪声协方差 $\mathbf{R}$ 和 $\mathbf{Q}$ 进行自适应更新,最后将状态估计值 $\hat{\mathbf{x}}_{k|k}$ 和误差协方差 $\mathbf{P}_{k|k}$ 反馈给UKF主程序,作为下一时刻的初始值。

当检测到系统存在故障,即判断出统计函数 λ_k 大于检测阈值 $\chi_{\rho,s}^2$ 时,噪声协方差 $\mathbf{R}$ 和 $\mathbf{Q}$ 进行自适应更新,否则,仅依据权重因子极限值 p_o 和 q_o 对 $\mathbf{R}$ 和 $\mathbf{Q}$ 进行较小强度的更新。根据式(46)和(53),噪声协方差 $\mathbf{R}$ 和 $\mathbf{Q}$ 的自适应强度主要由检测阈值 $\chi_{\rho,s}^2$ 与权重因子极限值 p_o 和 q_o 确定。其中,检测阈值 $\chi_{\rho,s}^2$ 可根据检测概率 ρ 和观测变量维度查阅表2确定。设置权重因子极限值 p_o 和 q_o 是为

表2 检测阈值 $\chi_{\rho,s}^2$ 的概率分布表^[37]Table 2 Probability distribution of detection threshold $\chi_{\rho,s}^2$ [37]

检测概率 ρ	检测阈值 $\chi_{\rho,s}^2$					
	1维	2维	3维	4维	5维	6维
0.99	0.00	0.02	0.11	0.30	0.55	0.87
0.95	0.00	0.10	0.35	0.71	1.15	1.64
0.90	0.02	0.21	0.58	1.06	1.61	2.20
0.75	0.10	0.58	1.21	1.92	2.67	3.45
0.50	0.45	1.39	2.37	3.36	4.35	5.35
0.25	1.32	2.77	4.11	5.39	6.63	7.84

了保证当统计函数 $\lambda_k > \chi_{\rho,s}^2$ 被误检为 $\lambda_k \leq \chi_{\rho,s}^2$ 时和 λ_k 略大于 $\chi_{\rho,s}^2$ 时,噪声协方差 $\mathbf{R}$ 和 $\mathbf{Q}$ 的更新强度。为充分发挥式(46)和(53)对于权重因子 p 和 q 的调节作用,权重因子极限值 p_o 和 q_o 应选取为较小的数值。由于算法中检测概率 ρ 表示 $\lambda_k > \chi_{\rho,s}^2$ 的可信度,主要由检测系统的可靠性决定。权重因子极限值 p_o 和 q_o 是基于一定更新强度限定对 $\lambda_k > \chi_{\rho,s}^2$ 不可信度的补充,可取 $p_o = q_o = 1 - \rho$ 。

假定鲁棒自适应UKF估计器以概率0.90检测系统故障,由于观测变量的维度为3,式(38)中的阈值 $\chi_{\rho,s}^2$ 为0.58,式(46)和(53)中的权重因子极限值 $p_o = q_o = 0.1$ 。基于两种测量噪声(噪声1连续,噪声2在噪声1的基础上有两处突变)干扰,测试该算法检测系统故障的能力,仿真设置同下一节,检测结果如图4所示。由图可见,该算法可实时检测系统是否出现故障,并判断观测噪声的强度。由图4(b)中可知,准确检测出了两处观测噪声的突变。因此,所提出的算法具有噪声自适应能力,能够提高UKF算法的鲁棒性。

6 仿真实验

根据文献[38,39]的研究,CarSim仿真平台与MATLAB/Simulink的联合可对估计算法进行有效验证,且与实验结果能很好地吻合。为验证所提出的鲁棒自适应UKF(RAUKF)算法的精确性和鲁棒性,基于CarSim平台搭建分布式电动汽车模型,并设置路面附着系数为高-低-中连续变化,利用MATLAB/Simulink设计估计器。由于本文主要研究RAUKF估计算法,具体

图 4 (网络版彩图)故障检测结果. (a) 噪声1干扰; (b) 噪声2干扰
Figure 4 (Color online) Fault detection results. (a) Noise 1 interference; (b) noise 2 interference.

的建模过程参见文献[7,15,40], 轮毂电机模型假设参见文献[12,41]. 联合仿真时, 用CarSim车辆模型输出的纵向加速度、侧向加速度和横摆角速度与相应随机白噪声信号的叠加模拟传感器测到的观测变量, 即将其作为估计器的输入. 车辆主要参数如表3所示.

设置仿真车速为50 km/h, 前轮转角为幅值4°的蛇行转向输入, 路面附着系数为0.9-0.3-0.6连续变化, 前轮转角和路面附着系数随时间变化具体如图5和6所示. 利用随机白噪声信号模拟各传感器受到的噪声干扰, 将观测噪声设置为 $Rz=diag([0.02, 0.5, 0.03])$, 则估计器含噪声的观测变量纵向加速度、侧向加速度和横摆角速度与CarSim车辆模型的输出结果对比如图7所示.

为体现本文所提出RAUKF算法的优越性, 选取标

表 3 车辆模型主要参数

Table 3 Main parameters of the vehicle model

名称	数值
车辆质量 m (kg)	1530
绕 z 轴的转动惯量 I_z ($kg \cdot m^2$)	2315.3
质心至前轴距离 l_f (m)	1.135
质心至后轴距离 l_r (m)	1.645
前后轴距 l (m)	2.78
质心高度 h_c (m)	0.52
前轮轮距 B_f (m)	1.55
后轮轮距 B_r (m)	1.55
车轮转动惯量 J ($kg \cdot m^2$)	0.9
车轮有效半径 R_e (m)	0.325
胎面分布刚度 k_e ($N \cdot m^{-2}$)	2.6×10^7
汽车迎风面积 A_f (m^2)	2.3
空气密度 ρ ($kg \cdot m^{-3}$)	1.206
空气阻力系数 C_d	0.3

图 5 (网络版彩图)前轮转角输入
Figure 5 (Color online) Steering angle input of the front wheel.

图 6 (网络版彩图)路面附着系数的变化
Figure 6 (Color online) Variation of road adhesion coefficient.

准的UKF算法和文献[42]提出的鲁棒无迹卡尔曼 (PRUKF)算法作为参照, 进行对比分析. 三个估计器的误差协方差 P 、观测噪声协方差 R 和过程噪声协方差 Q 初始值设置均同式(34)~(36). RAUKF估计器参数设置为 $\rho=0.9$, $p_0=q_0=0.1$. 基于联合仿真, RAUKF估计器的故障检测结果如图8所示. 三个估计器对纵向车速、侧向车速和质心侧偏角的估计结果与CarSim车辆系

图7 (网络版彩图)估计器观测变量与CarSim输出结果. (a) 纵向加速度; (b) 侧向加速度; (c) 横摆角速度

Figure 7 (Color online) Estimator observe variables and CarSim output results. (a) Longitudinal acceleration; (b) lateral acceleration; (c) yaw rate.

图8 (网络版彩图)基于统计函数的故障检测结果

Figure 8 (Color online) Fault detection result based on statistical function.

统输出值的对比如图9所示. 各状态变量的估计误差对比如图10所示, 状态估计误差的均方根对比如表4和5所示.

由图8可知, RAUKF估计器判断出了观测噪声的实时变化和噪声水平, 表明结合统计函数与检测阈值, 可以自适应更新噪声协方差的权重因子. 由图9可知, 车辆在附着系数为连续变化的路面上进行蛇行转向时, RAUKF估计器对纵向车速、侧向车速和质心侧偏角等三个状态变量的估计结果均能与CarSim模型输

出值较好地吻合, 而UKF估计器和PRUKF估计器的整体估计精度相对较差, 尤其对于纵向车速的估计出现了漂移.

由图10和表4可知, RAUKF估计器各状态变量的估计误差明显小于UKF估计器和PRUKF估计器的估计误差. 表4中的数据显示, 全程中RAUKF算法使纵向车速、侧向车速和质心侧偏角等各状态变量的估计误差相对于UKF算法分别降低了77.50%, 12.49%和12.84%; PRUKF算法仅使纵向车速的估计误差降低了39.09%, 侧向车速和质心侧偏角的估计误差反而分别增加了24.97%和24.30%. 可见所提出的RAUKF算法在估计精度上要优于UKF算法和PRAUKF算法.

从图10中还可以看出, RAUKF算法可以使各状态变量的估计误差随工作时间逐渐收敛, 表明随着对观测噪声协方差 $\mathbf{R}$ 和过程噪声协方差 $\mathbf{Q}$ 的自适应调整, RAUKF算法的鲁棒性会不断提高. 基于UKF算法和PRUKF算法的估计器对各状态变量的估计并不稳定, 估计误差无收敛趋势. 且随着路面附着系数的改变, 各状态变量的估计误差出现了较大幅度的波动, 甚至使得纵向车速的估计误差不断累积. 结合表5可知, 虽然PRUKF算法使三个状态变量在0~20 s的估计误差均有所减小, 但当路面状况改变时, 各状态变量的估计误差

图9 (网络版彩图)三种算法估计结果对比。(a) 纵向车速; (b) 侧向车速; (c) 质心侧偏角

Figure 9 (Color online) Comparison of estimation results of three algorithms. (a) Longitudinal speed; (b) lateral speed; (c) sideslip angle.

图10 (网络版彩图)三种算法估计误差对比。(a) 纵向车速误差; (b) 侧向车速误差; (c) 质心侧偏角误差

Figure 10 (Color online) Comparison of estimation results of three algorithms. (a) Longitudinal speed error; (b) lateral speed error; (c) sideslip angle error.

却会大幅度的增加, 尤其侧向车速和质心侧偏角在20~60 s的估计误差要明显大于UKF算法的估计误差。而RAUKF算法使三个状态变量的估计误差均逐渐减小。可见, 所提出的RAUKF算法在精确性和鲁棒性上均优于标准UKF算法和PRUKF算法。

7 结论

本文建立了分布式电动汽车的动力学模型, 分析了标准UKF算法的鲁棒性, 进而提出一种基于故障检测机制的鲁棒自适应UKF算法, 并设计了基于鲁棒自

表 4 三种算法全程估计误差对比

Table 4 Comparison of estimation errors of three algorithms in whole process

估计算法	状态变量估计误差均方根值 ($\times 10^{-3}$)		
	纵向车速	侧向车速	质心侧偏角
UKF	8.4033	6.6800	0.4825
PRUKF	5.1181	8.3478	0.5998
RAUKF	1.8908	5.8459	0.4206

适应UKF的车辆状态估计器,最后利用CarSim和MATLAB/Simulink联合仿真对所提出算法的精确性和鲁棒性进行了验证。

(1) 利用标准UKF算法对不同噪声环境下的车辆状态进行估计,发现较大的观测噪声会使估计器的误差增大、鲁棒性变差,有必要对车辆行驶过程中的噪声协方差进行自适应更新。

(2) 基于故障检测机制提出了一种噪声协方差自适应调整的鲁棒自适应UKF算法,该算法可利用残差向量判断系统是否存在故障,并根据统计函数和权重因子实时调整、更新估计器的观测噪声协方差和过程噪声协方差。

(3) 通过在附着系数高-低-中连续变化的路面进行蛇行转向工况仿真,证明所提出的鲁棒自适应UKF

表 5 三种算法不同时间段估计误差对比

Table 5 Comparison of estimation errors of three algorithms in different time

时间段	估计算法	状态变量估计误差均方根值 ($\times 10^{-3}$)		
		纵向车速	侧向车速	质心侧偏角
0~20 s	UKF	5.1207	8.3883	0.6304
	PRUKF	1.9518	7.4005	0.5320
	RAUKF	2.4367	8.2851	0.6095
20~40 s	UKF	7.9077	4.8330	0.4074
	PRUKF	3.8538	8.0218	0.5813
	RAUKF	1.3029	4.7297	0.3401
40~60 s	UKF	11.0947	6.3360	0.3677
	PRUKF	7.7410	9.4836	0.6771
	RAUKF	1.7581	2.8560	0.2085

算法能够实时判断观测噪声的水平,明显提高了标准UKF算法估计的精确性和鲁棒性,可用来对分布式电动汽车进行状态估计。

本文研究主要解决UKF算法在车辆状态估计中的噪声协方差自适应问题,后续将探究基于该算法的路面附着系数估计问题,同时将根据项目进展,结合智能汽车的主动循迹与避撞控制研究进行相应的实车实验。

参考文献

- Guo J, Luo Y, Li K. Adaptive non-linear trajectory tracking control for lane change of autonomous four-wheel independently drive electric vehicles. *IET Intell Transp Syst*, 2018, 12: 712–720
- Ivanov V, Savitski D, Shyrokau B. A survey of traction control and antilock braking systems of full electric vehicles with individually controlled electric motors. *IEEE Trans Veh Technol*, 2015, 64: 3878–3896
- Du R H, Mi S Y, Hu L, et al. Simulation on control strategy for torque distribution of compound brake system in a distributed drive electric vehicle (in Chinese). *Autom Eng*, 2019, 41: 327–333 [杜荣华, 米思雨, 胡林, 等. 分布式驱动电动汽车复合制动系统转矩分配控制策略仿真. *汽车工程*, 2019, 41: 327–333]
- Chen Y, Stout C, Joshi A, et al. Driver-assistance lateral motion control for in-wheel-motor-driven electric ground vehicles subject to small torque variation. *IEEE Trans Veh Technol*, 2018, 67: 6838–6850
- Naets F, van Aalst S, Boulkroune B, et al. Design and experimental validation of a stable two-stage estimator for automotive sideslip angle and tire parameters. *IEEE Trans Veh Technol*, 2017, 66: 9727–9742
- Hannes H, Martin S, Roland K. UKF-based State and tire slip estimation for a 4WD electric vehicle. *Vehicle System Dynamics*, 2019, doi: 10.1080/00423114.2019.1648836
- Zhao Z G, Zhu Q, Zhou L J, et al. Vehicle speed estimation in driving case based on distributed self-adaptive unscented Kalman filter for 4WD hybrid electric car (in Chinese). *Sci Sin Tech*, 2016, 46: 481–492 [赵治国, 朱强, 周良杰, 等. 分布式驱动HEV自适应无迹卡尔曼车速估计. *中国科学: 技术科学*, 2016, 46: 481–492]
- Chen T, Xu X, Chen L, et al. Estimation of longitudinal force, lateral vehicle speed and yaw rate for four-wheel independent driven electric

- vehicles. *Mech Syst Signal Process*, 2018, 101: 377–388
- 9 Nam K, Oh S, Fujimoto H, et al. Estimation of sideslip and roll angles of electric vehicles using lateral tire force sensors through RLS and Kalman filter approaches. *IEEE Trans Ind Electron*, 2013, 60: 988–1000
  - 10 Katriniok A, Abel D. Adaptive EKF-based vehicle state estimation with online assessment of local observability. *IEEE Trans Contr Syst Technol*, 2016, 24: 1368–1381
  - 11 Geng G Q, Wei B Y, Jiang H B, et al. A research on driving state estimation for distributed drive electric vehicle based on NA-EKF (in Chinese). *Autom Eng*, 2019, 41: 327–333 [耿国庆, 韦斌源, 江浩斌, 等. 基于NA-EKF的分布式驱动电动汽车行驶状态估计研究. *汽车工程*, 2018, 40: 770–776]
  - 12 Zhang Z Y, Zhang S Z, Huang C X, et al. State estimation of distributed drive electric vehicle based on adaptive extended Kalman filter (in Chinese). *J Mech Eng*, 2019, 55: 156–165 [张志勇, 张淑芝, 黄彩霞, 等. 基于自适应扩展卡尔曼滤波的分布式驱动电动汽车状态估计. *机械工程学报*, 2019, 55: 156–165]
  - 13 Antonov S, Fehn A, Kugi A. Unscented Kalman filter for vehicle state estimation. *Vehicle Syst Dyn*, 2011, 49: 1497–1520
  - 14 Boada B L, Boada M J L, Diaz V. Vehicle sideslip angle measurement based on sensor data fusion using an integrated ANFIS and an unscented Kalman filter algorithm. *Mech Syst Signal Processing*, 2016, 72–73: 832–845
  - 15 Wang Z P, Xue X, Wang Y C. State parameter estimation of distributed drive electric vehicle based on adaptive unscented Kalman filter (in Chinese). *Trans Beijing Inst Tech*, 2018, 38: 698–702 [王震坡, 薛雪, 王亚超. 基于自适应无迹卡尔曼滤波的分布式驱动电动汽车车辆状态参数估计. *北京理工大学学报*, 2018, 38: 698–702]
  - 16 Jin X J, Yin G D, Chen N, et al. State observation of distributed drive electric vehicle using square root cubature Kalman filter (in Chinese). *J Southeast Univ (Nat Sci Ed)*, 2016, 46: 992–996 [金贤建, 殷国栋, 陈南, 等. 分布式驱动电动汽车的平方根容积卡尔曼滤波状态观测. *东南大学学报(自然科学版)*, 2016, 46: 992–996]
  - 17 Zhang J X, Li J. Vehicle state estimation based on interactive multiple model and cubature Kalman filter (in Chinese). *Autom Eng*, 2017, 39: 977–983 [张家旭, 李静. 基于交互式多模型和容积卡尔曼滤波的汽车状态估计. *汽车工程*, 2017, 39: 977–983]
  - 18 Li G, Wang Y, Zong C F. Driving state estimation of electric vehicle with four-wheel-hub-motors (in Chinese). *Autom Eng*, 2018, 40: 150–155 [李刚, 王野, 宗长富. 四轮轮毂电机电动汽车行驶状态估计. *汽车工程*, 2018, 40: 150–155]
  - 19 Chang L, Hu B, Li A, et al. Transformed unscented Kalman filter. *IEEE Trans Automat Contr*, 2013, 58: 252–257
  - 20 Cao L, Yang W, Li H, et al. Robust double gain unscented Kalman filter for small satellite attitude estimation. *Adv Space Res*, 2017, 60: 499–512
  - 21 Muñoz J P, Magaña M E, Cotilla-Sanchez E. Adaptive master-slave unscented Kalman filter for grid voltage frequency estimation. *IET Signal Process*, 2018, 12: 496–505
  - 22 Lin M, Yang C, Li D. An improved transformed unscented FastSLAM with adaptive genetic resampling. *IEEE Trans Ind Electron*, 2019, 66: 3583–3594
  - 23 Guo H, Chen H, Xu F, et al. Implementation of EKF for vehicle velocities estimation on FPGA. *IEEE Trans Ind Electron*, 2013, 60: 3823–3835
  - 24 Liu Y H, Li T, Yang Y Y, et al. Estimation of tire-road friction coefficient based on combined APF-IEKF and iteration algorithm. *Mech Syst Signal Process*, 2017, 88: 25–35
  - 25 Aligia D A, Magallan G A, De Angelo C H. EV traction control based on nonlinear observers considering longitudinal and lateral tire forces. *IEEE Trans Intell Transp Syst*, 2018, 19: 2558–2571
  - 26 Doumiati M, Victorino A, Lechner D, et al. Observers for vehicle tyre/road forces estimation: experimental validation. *Vehicle Syst Dyn*, 2010, 48: 1345–1378
  - 27 Julier S J, Uhlmann J K. Unscented filtering and nonlinear estimation. *Proc IEEE*, 2004, 92: 401–422
  - 28 Li W, Jia Y. H-infinity filtering for a class of nonlinear discrete-time systems based on unscented transform. *Signal Process*, 2010, 90: 3301–3307
  - 29 Zarei-Jalalabadi M, Malaek S M B. Modification of unscented Kalman filter using a set of scaling parameters. *IET Signal Process*, 2018, 12: 471–480
  - 30 Menegaz H M T, Ishihara J Y, Kussaba H T M. Unscented Kalman filters for Riemannian state-space systems. *IEEE Trans Automat Contr*, 2019, 64: 1487–1502
  - 31 Zheng B, Fu P, Li B, et al. A robust adaptive unscented Kalman filter for nonlinear estimation with uncertain noise covariance. *Sensors*, 2018, 18: 808–822
  - 32 Hajiyeve C, Soken H E. Robust adaptive unscented Kalman filter for attitude estimation of Pico satellites. *Int J Adapt Control Signal Process*,

- 2014, 28: 107–120
- 33 Gao S, Hu G, Zhong Y. Windowing and random weighting-based adaptive unscented Kalman filter. *Int J Adapt Control Signal Process*, 2015, 29: 201–223
  - 34 Mohamed A H, Schwarz K P. Adaptive Kalman filtering for INS/GPS. *J Geodesy*, 1999, 73: 193–203
  - 35 Zhou J, Knedlik S, Loffeld O. INS/GPS tightly-coupled integration using adaptive unscented particle filter. *J Navigation*, 2010, 63: 491–511
  - 36 Hashemi E, Khosravani S, Khajepour A, et al. Longitudinal vehicle state estimation using nonlinear and parameter-varying observers. *Mechatronics*, 2017, 43: 28–39
  - 37 Liu Q S, Zhong B, Rong T Z, et al. Probability Theory and Mathematical Statistics (in Chinese). Beijing: Higher Education Press, 2013. 8 [刘琼荪, 钟波, 荣腾中, 等. 概率论与数理统计. 北京: 高等教育出版社, 2013. 8]
  - 38 Hashemi E, Kasaiezadeh A, Khosravani S, et al. Estimation of longitudinal speed robust to road conditions for ground vehicles. *Vehicle Syst Dyn*, 2016, 54: 1120–1146
  - 39 Hashemi E, Pirani M, Khajepour A, et al. Opinion dynamics-based vehicle velocity estimation and diagnosis. *IEEE Trans Intell Transp Syst*, 2018, 19: 2142–2148
  - 40 Liu Z Q, Liu G. Simulation and test of stability control for distributed drive electric vehicles (in Chinese). *Autom Eng*, 2019, 41: 792–799 [刘志强, 刘广. 分布式驱动电动汽车稳定性控制仿真与试验. 汽车工程, 2019, 41: 792–799]
  - 41 Huang C X, Lei F, Hu L, et al. Lateral stability control based on regional pole placement of in-wheel-motored electric vehicle (in Chinese). *Autom Eng*, 2019, 41: 905–914 [黄彩霞, 雷飞, 胡林, 等. 轮毂电机驱动汽车区域极点配置横向稳定性控制. 汽车工程, 2019, 41: 905–914]
  - 42 Li W, Sun S, Jia Y, et al. Robust unscented Kalman filter with adaptation of process and measurement noise covariances. *Digital Signal Process*, 2016, 48: 93–103

State estimation of distributed electric vehicle based on robust adaptive UKF

ZHANG ZhiDa, ZHENG Ling, WU Hang, QIAO XuQiang & LI YiNong

State Key Lab of Mechanical Transmissions, School of Automotive Engineering, Chongqing University, Chongqing 400044, China

The key to achieving active safety and automatic driving is accurate parameters of the vehicle state. The unscented Kalman filter (UKF) algorithm will seriously affect the vehicle state's estimation accuracy if the noise of measurement is high or the covariance of noise does not suit. A robust adaptive UKF algorithm based on fault detection mechanism is proposed to estimate the state of distributed drive electric vehicle. The algorithm uses the residual vector of observation noise to identify whether there is a fault in the system, determines whether the observation noise covariance and the process noise covariance need to be adjusted adaptively according to the statistical function, and updates the covariance based on the weight factors. A robust adaptive UKF estimator is designed to estimate three important state variables: longitudinal speed, lateral speed, and sideslip angle. The algorithm is eventually tested based on the co-simulation of CarSim and MATLAB/Simulink. The results showed that the proposed robust adaptive UKF algorithm can significantly reduce the estimation error of three state variables, and is better than the standard accuracy and robustness of the UKF algorithm. This lays an important foundation for advanced driving assistance systems and precise automatic driving movement control.

electric vehicle, distributed drive, states estimation, robust adaptive UKF, fault detection mechanism

doi: [10.1360/SST-2019-0326](https://doi.org/10.1360/SST-2019-0326)