DOI: 10.3901/JME.2021.20.181

基于鲁棒自适应 SCKF 的智能汽车目标 状态跟踪研究*

张志达^{1,2} 郑玲^{1,2} 李以农^{1,2} 吴行^{1,2} 余颖弘^{1,2}

(1. 重庆大学机械与运载工程学院 重庆 400044;
2. 重庆大学机械传动国家重点实验室 重庆 400044)

摘要: 准确的自车和前车状态估计是智能汽车有效决策和控制的前提,而以往的研究通常不考虑噪声统计特性不确定的问题,导致某些情况下车辆状态估计的误差很大。为此,提出一种鲁棒自适应平方根容积卡尔曼滤波(Robust adaptive square-root cubature Kalman filter, RASCKF)算法,以降低噪声统计不确定性对估计精度的影响。首先,采用最大后验概率准则估计了过程噪声协方差和测量噪声协方差的统计值,以提高噪声稳定时状态估计的精确性。然后,基于标准化测量新息序列设计了故障检测规则,利用实时测量新息对噪声协方差进行校正处理,保证状态估计算法的鲁棒性。最后,在不同的噪声干扰工况下对 RASCKF 算法进行了仿真验证。结果表明, RASCKF 算法在估计精度和稳定性上明显优于标准 SCKF 算法,有效地解决了智能汽车目标状态跟踪过程中噪声统计特性不确定的问题。

关键词: 智能汽车; 目标状态跟踪; 平方根容积卡尔曼滤波; 鲁棒自适应

中图分类号: U461

Research on Intelligent Vehicle Target State Tracking Based on Robust Adaptive SCKF

ZHANG Zhida^{1,2} ZHENG Ling^{1,2} LI Yinong^{1,2} WU Hang^{1,2} YU Yinghong^{1,2}

(1. College of Mechanical and Vehicle Engineering, Chongqing University, Chongqing 400044;
2. State Key Lab of Mechanical Transmissions, Chongqing University, Chongqing 400044)

Abstract: Accurate estimation of the states of vehicle and front vehicle is the premise of the effective decision-making and control of the intelligent vehicle. However, previous studies usually do not consider the uncertainty of noise statistical characteristics, which leads to a large error of vehicle state estimation in some cases. Therefore, a robust adaptive square-root cubature Kalman filter (RASCKF) algorithm is proposed to reduce the influence of noise statistical uncertainty on estimation accuracy. Firstly, the statistical values of process noise covariance and measurement noise covariance are estimated by the maximum a posteriori (MAP) criterion to improve the accuracy of state estimation when the noise is stable. Secondly, the fault detection rules are designed based on the standardized measurement innovation sequence, and the real-time measurement innovation is used to correct the noise covariances for ensure the robustness of the state estimation algorithm. Finally, the RASCKF algorithm is verified by simulation under different noise interference conditions. The results show that RASCKF algorithm is superior to standard SCKF algorithm in estimation accuracy and stability, which effectively solves the problem of uncertain noise statistical characteristics in the process of intelligent vehicle target state tracking.

Key words: intelligent vehicle; target state tracking; square-root cubature Kalman filter; robust adaptive

0 前言

随着汽车保有量的不断增长和交通环境的复杂

化,驾驶员操纵车辆的负荷不断增大。因此,具有自主感知、决策和控制功能的智能汽车成为研究热点^[1-3]。智能汽车的感知功能可以获取自车状态、周围车辆状态和行人位置等信息,是有效决策和精准控制的前提^[4-5]。其中,准确实时地获得车辆行驶过程中自车和目标车辆的状态信息,是实现智能汽车

* 国家自然科学基金(51875061)、重庆市研究生科研创新(CYB19063)和重庆市技术创新与应用发展专项(cstc2019jscx-zdztzxX0032)资助项目。20200508 收到初稿,20210423 收到修改稿

高速道路自动驾驶的关键^[6-8]。

目前, 自车状态和目标车辆状态的估计问题引起了学者们的广泛关注^[9-11]。REINA 等^[12]基于扩展卡尔曼滤波(Extended Kalman filter, EKF)设计了一种用于估计车辆侧偏角和轮胎刚度的观测器。HEIDFELD 等^[13]利用无迹卡尔曼滤波(Unscented Kalman filter, UKF)算法对四轮独立驱动汽车的车辆状态和轮胎侧偏角进行了估计。宋义彤等^[14]采用 UKF 算法估计了分布式电动汽车的轮胎侧偏刚度和车辆的质量参数。ASKELAND 等^[15]基于卡尔曼滤波(Kalman filter, KF)对十字路口处目标车辆的运动状态进行了跟踪估计。XIE 等^[16]利用 UKF 对目标车辆的轨迹进行了预测估计。SCHUBERT 等^[17]基于 UKF 对比分析了常用车辆目标跟踪模型的优劣。此外, KATRINIOK 等^[18]考虑路面附着系数不确定问题, 提出了一种自适应 EKF 算法, 并用其对车辆的纵向和侧向速度进行了估计。STRANO 等^[19]考虑车辆状态变化, 提出了一种用于估计车辆侧偏角的约束 UKF 算法。

然而, 上述研究仍然存在一定的局限性。KF 可用于线性估计, 但不适合非线性系统。EKF 通过求 Jacobian 矩阵对系统一阶线性化, 可用于非线性估计, 但当系统具有强非线性时, 线性化计算会引起较大的截断误差, 严重影响估计精度^[20]。UKF 采用无迹变换对概率密度函数进行高斯逼近, 精度高于 EKF, 但对于高维非线性系统, 其精确性和稳定性会明显下降^[21]。为此, ARASARATNAM 等^[22]提出了一种高性能的非线性滤波算法, 容积卡尔曼滤波(Cubature Kalman filter, CKF), 它的估计精度和数值稳定性均优于 UKF^[23]。为了保证协方差矩阵的对称性、正(半)定性和提高 CKF 的估计精度, 文献[22]同时给出了 CKF 的平方根形式, 即 Square-root CKF (SCKF)。然而, SCKF 同 EKF、UKF 和 CKF 等一样, 都需要知道噪声协方差的先验统计值。实际应用中, 工作环境、系统模型等的不确定性和执行器、传感器等的故障问题都会导致噪声先验统计不可知或严重不匹配^[24-25]。

近年来, 针对非线性估计中存在的噪声统计特性不确定的问题, 学者们提出了一些新的方法。例如, KIANI 等^[26]结合 SCKF 和粒子滤波提出了一种自适应 SCKF 滤波算法, 该算法具有较高的估计精度, 但计算成本明显增大。SHEN 等^[27]提出了一种基于神经网络的自学习 SCKF 算法, 该

算法可以提高 SCKF 的准确性, 但在使用前需要训练一些参数, 其通用性和时效性无法得到保障。LIU 等^[28]提出了一种可以重构 SCKF 测量更新的最大相关熵 SCKF 算法, 该算法对于异常测量噪声具有较强的鲁棒性, 但不能解决异常过程噪声的干扰问题。

考虑智能汽车目标状态跟踪过程中噪声统计特性的不确定问题, 本文提出了一种鲁棒自适应 SCKF 算法。采用最大后验概率统计方法估计噪声协方差的统计值, 自适应调整过程噪声和测量噪声协方差; 利用故障检测准则实时的检测估计过程, 基于当前时刻的测量新息校正异常情况下的噪声协方差。该算法可以保证状态估计的精确性和鲁棒性, 解决智能汽车目标跟踪过程中噪声统计特性不确定的问题。

1 智能汽车目标跟踪模型

1.1 目标车辆运动学模型

为了能够给智能汽车辅助驾驶系统的决策与控制提供准确的参考信息, 本研究以前车为跟踪目标。建立包括纵向距离、横向距离、相对速度、偏航角和偏航角速度的目标车辆运动学模型, 如图 1 所示。其中, x 轴表示纵向, y 轴表示横向。

图 1 目标车辆运动学模型

恒定转率和速度模型(Constant turn rate and velocity, CTRV)假设目标车辆以固定的转弯速率和速度运动, 可以满足高速公路上的车辆状态估计^[4]。因此, 选取 CTRV 模型对目标车辆的状态进行跟踪, 其状态转移函数表示为

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

其中,

$$f(\mathbf{x}_{k-1}) = \begin{pmatrix} p_{k-1} + \frac{v_{k-1}}{\dot{\phi}} [\cos \varphi_{k-1} - \cos(\varphi_{k-1} + \dot{\phi}_{k-1}T)] \\ q_{k-1} + \frac{v_{k-1}}{\dot{\phi}} [\sin(\varphi_{k-1} + \dot{\phi}_{k-1}T) - \sin \varphi_{k-1}] \\ v_{k-1} \\ \varphi_{k-1} + \dot{\phi}_{k-1}T \\ \dot{\phi}_{k-1} \end{pmatrix} \quad (2)$$

式中, $\mathbf{x}_k = (p_k, q_k, v_k, \varphi_k, \dot{\phi}_k)^T$ 为离散时间 k 时刻的车辆状态, $f(\cdot)$ 为状态转移方程, $\mathbf{w}_{k-1}$ 为过程噪声, p_k 和 q_k 表示纵向距离和横向距离, v_k 为相对速度, φ_k 和 $\dot{\phi}_k$ 表示指偏航角和偏航角速度, T 为时间步长。当偏航角速度 $\dot{\phi}_k = 0$ 时, CTRV 模型对于距离 p_k 和 q_k 的估计会失效^[17]。考虑到目标车辆运动状态的不确定性, 将状态转移方程修正为

$$f(\mathbf{x}_{k-1}) = \begin{pmatrix} p_{k-1} + v_{k-1} \cos \varphi_{k-1}T \\ q_{k-1} + v_{k-1} \sin \varphi_{k-1}T \\ v_{k-1} \\ \varphi_{k-1} + \dot{\phi}_{k-1}T \\ \dot{\phi}_{k-1} \end{pmatrix} \quad (3)$$

在 CTRV 模型中, 假设过程噪声主要由高斯分布的纵向加速度和偏航角加速度扰动产生, 其表达式如下

$$\mathbf{w}_{k-1} = \begin{pmatrix} 1/2 \mu_a T^2 \cos \varphi_{k-1} \\ 1/2 \mu_a T^2 \sin \varphi_{k-1} \\ \mu_a T \\ 1/2 \mu_\varphi T^2 \\ \mu_\varphi T \end{pmatrix} \quad (4)$$

式中, μ_a 为随机纵向加速度, μ_φ 为随机偏航角加速度。

1.2 测量模型

毫米波雷达可以用于运动目标和障碍物的探测, 准确的获取相对距离、相对速度和方位角等信息。基于毫米波雷达的测量模型可以表示为^[29]

$$\mathbf{z}_k = h(\mathbf{x}_k) + \mathbf{v}_k \quad (5)$$

$$h(\mathbf{x}_k) = \begin{pmatrix} \sqrt{p_k^2 + q_k^2} \\ \frac{p_k v_k \cos \varphi_k + q_k v_k \sin \varphi_k}{\sqrt{p_k^2 + q_k^2}} \\ \arctan(q_k / p_k) \end{pmatrix} \quad (6)$$

式中, $\mathbf{z}_k = [\rho_k, \dot{\rho}_k, \theta_k]^T$ 为测量变量, $h(\cdot)$ 为测量方

程, $\mathbf{v}_k$ 为测量噪声, ρ_k 为目标车辆在车辆坐标系下与本车的距离, $\dot{\rho}_k$ 为距离变化率, θ_k 为目标车辆与 x 轴间的夹角。当车辆行驶工况复杂时, 恶劣的振动环境可能会使毫米波雷达的测量通道受到噪声干扰甚至出现故障。因此, 测量噪声主要由三个通道的测量误差引起, 其表达式如下

$$\mathbf{v}_k = \begin{pmatrix} v_\rho \\ v_{\dot{\rho}} \\ v_\theta \end{pmatrix} \quad (7)$$

式中, v_ρ 为距离误差, $v_{\dot{\rho}}$ 为距离变化率误差, v_θ 为角度误差。

2 鲁棒自适应 SCKF

2.1 标准 SCKF 算法

在 CKF 算法中引入协方差矩阵的平方根因子, 可以构造出 SCKF 算法。SCKF 能够保证协方差矩阵的对称性和正(半)定性, 并提高估计精度和滤波稳定性^[22]。标准 SCKF 算法的实现过程如下。

(1) 初始化。设置状态初始值 $\hat{\mathbf{x}}_{00}$ 及相应的误差协方差矩阵平方根因子 $\mathbf{S}_{00}$ 。其中, $\mathbf{S}_{00}$ 的计算式为

$$\mathbf{S}_{00} = [\text{Chol}(\mathbf{P}_{00})]^T \quad (8)$$

式中, $\mathbf{P}_{00}$ 表示误差协方差矩阵, Chol 表示 Cholesky 分解。

(2) 时间更新。计算容积点并基于状态转移方程传递

$$\begin{cases} \mathbf{x}_{k-1|k-1}^i = \hat{\mathbf{x}}_{k-1|k-1} + \mathbf{S}_{k-1|k-1} \boldsymbol{\xi}_i & i = 1, 2, \dots, 2n \\ \mathbf{x}_{k|k-1}^{i*} = f(\mathbf{x}_{k-1|k-1}^i) \end{cases} \quad (9)$$

式中, $\boldsymbol{\xi}_i$ 为容积点权重矩阵 $[\sqrt{n}\mathbf{I}_n, -\sqrt{n}\mathbf{I}_n]$ 的第 i 列, $\mathbf{I}_n$ 为 $n \times n$ 的单位矩阵, n 为状态变量的维数。

计算状态的预测值及其误差协方差矩阵的平方根因子

$$\begin{cases} \mathbf{x}_{k|k-1} = \frac{1}{2n} \sum_{i=1}^{2n} \mathbf{x}_{k|k-1}^{i*} \\ \mathbf{S}_{k|k-1} = \text{Tria}([\mathbf{X}_{k|k-1}^{i*}, \text{Chol}(\mathbf{Q}_{k-1})]) \end{cases} \quad (10)$$

加权的中心矩 $\mathbf{X}_{k|k-1}^{i*}$ 定义为

$$\mathbf{X}_{k|k-1}^{i*} = \frac{1}{\sqrt{2n}} [\mathbf{x}_{k|k-1}^{1*} - \hat{\mathbf{x}}_{k|k-1}, \mathbf{x}_{k|k-1}^{2*} - \hat{\mathbf{x}}_{k|k-1}, \dots, \mathbf{x}_{k|k-1}^{2n*} - \hat{\mathbf{x}}_{k|k-1}] \quad (11)$$

式中, $\text{Tria}(\cdot)$ 运算定义 $\mathbf{R}$ 为 $\mathbf{A}^T$ 矩阵 $\mathbf{Q}\mathbf{R}$ 分解的上三角矩阵, 则 $\mathbf{A}$ 矩阵的 $\mathbf{Q}\mathbf{R}$ 分解运算可以表示为

$\mathbf{S} = \text{Tria}(\mathbf{A}) = \mathbf{R}^T$, $\mathbf{S}$ 为下三角矩阵。

(3) 测量更新。更新容积点并基于测量方程传递

$$\begin{cases} \mathbf{x}_{k|k-1}^i = \hat{\mathbf{x}}_{k|k-1} + \mathbf{S}_{k|k-1} \xi_i \\ \mathbf{z}_{k|k-1}^i = h(\mathbf{x}_{k|k-1}^i) \end{cases} \quad (12)$$

计算测量的预测值及其新息协方差矩阵的平方根因子

$$\begin{cases} \hat{\mathbf{z}}_{k|k-1} = \frac{1}{2n} \sum_{i=1}^{2n} \mathbf{z}_{k|k-1}^i \\ \mathbf{S}_{k|k-1}^{zz} = \text{Tria}([\mathbf{Z}_{k|k-1}, \text{Chol}(\mathbf{R}_k)]) \end{cases} \quad (13)$$

加权的中心矩 $\mathbf{Z}_{k|k-1}$ 定义为

$$\mathbf{Z}_{k|k-1} = \frac{1}{\sqrt{2n}} [\mathbf{z}_{k|k-1}^1 - \hat{\mathbf{z}}_{k|k-1}, \mathbf{z}_{k|k-1}^2 - \hat{\mathbf{z}}_{k|k-1}, \dots, \mathbf{z}_{k|k-1}^{2n} - \hat{\mathbf{z}}_{k|k-1}] \quad (14)$$

计算测量协方差矩阵和互协方差矩阵

$$\begin{cases} \mathbf{P}_{k|k-1}^{zz} = \mathbf{S}_{k|k-1}^{zz} (\mathbf{S}_{k|k-1}^{zz})^T \\ \mathbf{P}_{k|k-1}^{xz} = \mathbf{X}_{k|k-1} \mathbf{Z}_{k|k-1}^T \end{cases} \quad (15)$$

加权的中心矩 $\mathbf{X}_{k|k-1}$ 定义为

$$\mathbf{X}_{k|k-1} = \frac{1}{\sqrt{2n}} [\mathbf{x}_{k|k-1}^1 - \hat{\mathbf{x}}_{k|k-1}, \mathbf{x}_{k|k-1}^2 - \hat{\mathbf{x}}_{k|k-1}, \dots, \mathbf{x}_{k|k-1}^{2n} - \hat{\mathbf{x}}_{k|k-1}] \quad (16)$$

计算 Kalman 增益矩阵

$$\mathbf{K}_k = \mathbf{P}_{k|k-1}^{xz} (\mathbf{P}_{k|k-1}^{zz})^{-1} \quad (17)$$

更新状态变量和误差协方差矩阵的平方根因子

$$\begin{cases} \hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k (\mathbf{z}_k - \hat{\mathbf{z}}_{k|k-1}) \\ \mathbf{S}_{k|k} = \text{Tria}([\mathbf{x}_{k|k-1} - \mathbf{K}_k \mathbf{z}_{k|k-1}, \mathbf{K}_k \text{Chol}(\mathbf{R}_k)]) \end{cases} \quad (18)$$

2.2 基于 MAP 的噪声协方差统计估计

标准 SCKF 算法在噪声统计特性已知的情况下具有较高的估计精度, 然而, 当噪声统计的先验统计值未知时其估计精度难以得到保障^[30]。最大后验概率(Maximum a posterior, MAP)估计是一种广泛应用的贝叶斯估计方法, 通过后验概率密度的最大化来估计参数^[31-32]。为提高标准 SCKF 算法的估计精度和自适应能力, 本文基于 MAP 估计过程噪声和

量测噪声的统计值。

假设过程噪声协方差 $\mathbf{Q}$ 、量测噪声协方差 $\mathbf{R}$ 和系统状态 $\mathbf{x}_k$ 均为未知变量。它们的 MAP 估计值可以通过最大化条件密度函数得到

$$J^* = p[\mathbf{X}_k, \mathbf{Q}, \mathbf{R} | \mathbf{Z}_k] \quad (19)$$

式中, $\mathbf{X}_k = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_k\}$, $\mathbf{Z}_k = \{\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_k\}$ 。

根据条件概率的性质, 可以得到

$$J^* = \frac{p[\mathbf{X}_k, \mathbf{Q}, \mathbf{R}, \mathbf{Z}_k]}{p[\mathbf{Z}_k]} \quad (20)$$

由于 $p[\mathbf{Z}_k]$ 与 J^* 的最大化无关, $\mathbf{Q}$, $\mathbf{R}$ 和 $\mathbf{x}_k$ 的 MAP 估计可以通过下列最大化密度函数等价得到

$$J = p[\mathbf{X}_k, \mathbf{Q}, \mathbf{R}, \mathbf{Z}_k] = p[\mathbf{Z}_k | \mathbf{X}_k, \mathbf{Q}, \mathbf{R}] \times p[\mathbf{X}_k | \mathbf{Q}, \mathbf{R}] \times p[\mathbf{Q}, \mathbf{R}] \quad (21)$$

根据概率乘法准则

$$\begin{aligned} p[\mathbf{X}_k | \mathbf{Q}, \mathbf{R}] &= p[\mathbf{x}_0] \prod_{j=1}^k p[\mathbf{x}_j | \mathbf{x}_{j-1}, \mathbf{Q}] = \\ &= \frac{1}{(2\pi)^{\frac{n}{2}} |\mathbf{P}_0|^{\frac{1}{2}}} \exp \left\{ -\frac{1}{2} \|\mathbf{x}_0 - \hat{\mathbf{x}}_0\|_{\mathbf{P}_0^{-1}}^2 \right\} \times \\ &= \prod_{j=1}^k \frac{1}{(2\pi)^{\frac{n}{2}} |\mathbf{Q}|^{\frac{1}{2}}} \exp \left\{ -\frac{1}{2} \|\mathbf{x}_j - f(\mathbf{x}_{j-1})\|_{\mathbf{Q}^{-1}}^2 \right\} = \\ &= C_1 |\mathbf{P}_0|^{\frac{1}{2}} |\mathbf{Q}|^{\frac{k}{2}} \exp \left\{ -\frac{1}{2} \left[\|\mathbf{x}_0 - \hat{\mathbf{x}}_0\|_{\mathbf{P}_0^{-1}}^2 + \right. \right. \\ &\quad \left. \left. \sum_{j=1}^k \|\mathbf{x}_j - f(\mathbf{x}_{j-1})\|_{\mathbf{Q}^{-1}}^2 \right] \right\} \end{aligned} \quad (22)$$

式中, n 为状态变量的维数, $C_1 = 1/(2\pi)^{n(k+1)/2}$ 为常数, $|\cdot|$ 表示矩阵的行列式计算, $\|\mathbf{x}\|_{\mathbf{A}}^2 = \mathbf{x}^T \mathbf{A} \mathbf{x}$ 表示求二次型。

类似于式(22), 可以得到

$$\begin{aligned} p[\mathbf{Z}_k | \mathbf{X}_k, \mathbf{Q}, \mathbf{R}] &= \prod_{j=1}^k p[\mathbf{z}_j | \mathbf{x}_j, \mathbf{R}] = \\ &= \prod_{j=1}^k \frac{1}{(2\pi)^{\frac{m}{2}} |\mathbf{R}|^{\frac{1}{2}}} \exp \left\{ -\frac{1}{2} \|\mathbf{z}_j - h(\mathbf{x}_j)\|_{\mathbf{R}^{-1}}^2 \right\} = \\ &= C_2 |\mathbf{R}|^{\frac{k}{2}} \exp \left\{ -\frac{1}{2} \sum_{j=1}^k \|\mathbf{z}_j - h(\mathbf{x}_j)\|_{\mathbf{R}^{-1}}^2 \right\} \end{aligned} \quad (23)$$

式中, m 为测量变量的维数, $C_2 = 1/(2\pi)^{mk/2}$ 为常数。

将式(22)和式(23)代入式(21)中, 可得

$$J = C_1 C_2 |P_0|^{-\frac{1}{2}} |Q|^{-\frac{k}{2}} |R|^{-\frac{k}{2}} p(Q, R) \times \exp \left\{ -\frac{1}{2} \left[\|x_0 - \hat{x}_0\|_{P_0^{-1}}^2 + \sum_{j=1}^k \|x_j - f(x_{j-1})\|_{Q^{-1}}^2 + \sum_{j=1}^k \|z_j - h(x_j)\|_{R^{-1}}^2 \right] \right\} =$$

$$C |Q|^{-\frac{k}{2}} |R|^{-\frac{k}{2}} \exp \left\{ -\frac{1}{2} \left[\sum_{j=1}^k \|x_j - f(x_{j-1})\|_{Q^{-1}}^2 + \sum_{j=1}^k \|z_j - h(x_j)\|_{R^{-1}}^2 \right] \right\} \quad (24)$$

$$C = C_1 C_2 |P_0|^{-\frac{1}{2}} p(Q, R) \times \exp \left\{ -\frac{1}{2} \|x_0 - \hat{x}_0\|_{P_0^{-1}}^2 \right\} \quad (25)$$

因为对数运算并不会改变函数的极值点, 所以 J 和 $\ln J$ 具有相同的最大值。对式(24)两边做取对数运算, 可以得到

$$\ln J = -\frac{k}{2} \ln |Q| - \frac{k}{2} \ln |R| - \frac{1}{2} \sum_{j=1}^k \|x_j - f(x_{j-1})\|_{Q^{-1}}^2 - \frac{1}{2} \sum_{j=1}^k \|z_j - h(x_j)\|_{R^{-1}}^2 + \ln C \quad (26)$$

假设 $\hat{x}_{j-1/k}$ 和 $\hat{x}_{j/k}$ 已知, 取 $\ln J$ 关于 Q 和 R 的偏导数, 有如下关系

$$\frac{\partial \ln J}{\partial Q} \bigg|_{Q=\hat{Q}_{k-1}}^{x_{j-1}=\hat{x}_{j-1/k}, x_j=\hat{x}_{j/k}} = 0 \quad \frac{\partial \ln J}{\partial R} \bigg|_{R=\hat{R}_k}^{x_j=\hat{x}_{j/k}} = 0 \quad (27)$$

此时, 噪声协方差 Q_{k-1} 和 R_k 的 MAP 估计为

$$\hat{Q}_{k-1} = \frac{1}{k} \sum_{j=1}^k \{ [\hat{x}_{j/k} - f(x_{j-1})|_{x_{j-1}=\hat{x}_{j-1/k}}] \times [\hat{x}_{j/k} - f(x_{j-1})|_{x_{j-1}=\hat{x}_{j-1/k}}]^T \} \quad (28)$$

$$\hat{R}_k = \frac{1}{k} \sum_{j=1}^k \{ [z_j - h(x_j)|_{x_j=\hat{x}_{j/k}}] \times [z_j - h(x_j)|_{x_j=\hat{x}_{j/k}}]^T \} \quad (29)$$

对于实时的动态系统而言, 无法知道某一时刻之后的信息。因此, 平滑估计 $\hat{x}_{j-1/k}$ 和 $\hat{x}_{j/k}$ 通常无法得到。可以用状态估计 $\hat{x}_{j-1|j}$, $\hat{x}_{j|j}$ 或者状态预测 $\hat{x}_{j|j-1}$ 代替它们^[30, 32], 将噪声协方差 Q_{k-1} 和 R_k 的次优估计值表示为

$$\hat{Q}_{k-1} = \frac{1}{k} \sum_{j=1}^k \{ [\hat{x}_{j|j} - f(\hat{x}_{j|j-1})] \times [\hat{x}_{j|j} - f(\hat{x}_{j|j-1})]^T \} \quad (30)$$

$$\hat{R}_k = \frac{1}{k} \sum_{j=1}^k \{ [z_j - h(\hat{x}_{j|j-1})] [z_j - h(\hat{x}_{j|j-1})]^T \} \quad (31)$$

定义测量新息为

$$\mu_k = z_k - \hat{z}_{k|k-1} \quad (32)$$

则有如下关系

$$\begin{cases} E[\mu_k] = E[z_k - \hat{z}_{k|k-1}] = 0 \\ E[\mu_k \mu_k^T] = E[(z_k - \hat{z}_{k|k-1})(z_k - \hat{z}_{k|k-1})^T] = P_{k|k-1}^{zz} \end{cases} \quad (33)$$

结合式(18)和式(32), 可得

$$\hat{x}_{j|j} - \hat{x}_{j|j-1} = K_j (z_j - \hat{z}_{j|j-1}) = K_j \mu_j \quad (34)$$

已知 $P_{j|j} = S_{j|j} S_{j|j}^T$, 根据标准 CKF 算法^[22]及式(30)和式(31)可知噪声协方差 Q_{k-1} 和 R_k 的期望为

$$\begin{aligned} E[\hat{Q}_{k-1}] &= \frac{1}{k} \sum_{j=1}^k E\{[\hat{x}_{j|j} - f(\hat{x}_{j-1})] \times [\hat{x}_{j|j} - f(\hat{x}_{j-1})]^T\} = \\ &= \frac{1}{k} \sum_{j=1}^k E[K_j \mu_j \mu_j^T K_j^T] = \frac{1}{k} \sum_{j=1}^k [P_{j|j-1} - P_{j|j}] = \\ &= \frac{1}{k} \sum_{j=1}^k [P_{j|j-1}^{xx*} - P_{j|j} + Q_{j-1}] \neq Q_{k-1} \end{aligned} \quad (35)$$

$$\begin{aligned} E[\hat{R}_k] &= \frac{1}{k} \sum_{j=1}^k E\{[z_j - h(\hat{x}_{j|j-1})] [z_j - h(\hat{x}_{j|j-1})]^T\} = \\ &= \frac{1}{k} \sum_{j=1}^k E[\mu_j \mu_j^T] = \frac{1}{k} \sum_{j=1}^k [P_{j|j-1}^{zz*} + R_j] \neq R_k \end{aligned} \quad (36)$$

$$P_{j|j-1}^{xx*} = \frac{1}{2n} \sum_{i=1}^{2n} \{ [x_{j|j-1}^i - \hat{x}_{j|j-1}] [x_{j|j-1}^i - \hat{x}_{j|j-1}]^T \} \quad (37)$$

$$P_{j|j-1}^{zz*} = \frac{1}{2n} \sum_{i=1}^{2n} \{ [z_{j|j-1}^i - \hat{z}_{j|j-1}] [z_{j|j-1}^i - \hat{z}_{j|j-1}]^T \} \quad (38)$$

根据文献[33], 当噪声统计为常数或变化较小时, 可以认为 $Q_{k-1} = Q_{j-1}$ 和 $R_k = R_j$ 。对式(35)和式(36)重新改写, 可以得到

$$\begin{aligned} E[\hat{Q}_{k-1}] &= \frac{1}{k} \sum_{j=1}^k E[K_j \mu_j \mu_j^T K_j^T] = \\ &= \frac{1}{k} \sum_{j=1}^k [P_{j|j-1}^{xx*} - P_{j|j}] + Q_{k-1} \end{aligned} \quad (39)$$

$$E[\hat{R}_k] = \frac{1}{k} \sum_{j=1}^k E[\mu_j \mu_j^T] = \frac{1}{k} \sum_{j=1}^k P_{j|j-1}^{zz*} + R_k \quad (40)$$

因此, 可得噪声协方差 Q_{k-1} 和 R_k 的统计估计为

$$\hat{Q}_{k-1} = \frac{1}{k} \sum_{j=1}^k \{ K_j \mu_j \mu_j^T K_j^T - P_{j|j-1}^{xx*} + P_{j|j} \} \quad (41)$$

$$\hat{R}_k = \frac{1}{k} \sum_{j=1}^k \{ \mu_j \mu_j^T - P_{j|j-1}^{zz*} \} \quad (42)$$

2.3 基于故障检测的噪声协方差校正

当过程噪声和测量噪声相对稳定时, 利用式(41)和式(42)可以根据测量新息的统计值自适应调整噪

声协方差 $\mathbf{Q}_{k-1}$ 和 $\mathbf{R}_k$ 。然而,当过程噪声和测量噪声由于模型不确定、系统状态变化、执行器或传感器间歇性故障而突然变大时,利用测量新息的统计值很难准确的估计噪声协方差 $\mathbf{Q}_{k-1}$ 和 $\mathbf{R}_k$ [34-35]。此时,基于 MAP 的噪声协方差统计估计值并不能保证 SCKF 估计的准确性和鲁棒性。为了避免这一问题,当系统或测量出现异常时,需要对此刻的噪声协方差 $\mathbf{Q}_{k-1}$ 和 $\mathbf{R}_k$ 进行校正处理。为此,本文提出一种故障检测方法来判断估计过程是否异常。

假设测量新息 μ_k 的每个元素都是独立的高斯分布 $N(0, \mathbf{P}_{k|k-1}^{zz})$, 则标准化后的测量新息序列 $\bar{\mu}_k = (\mathbf{P}_{k|k-1}^{zz})^{-1/2} \mu_k$ 服从高斯正态分布 $N(0, 1)$ 。为检测故障,将维度为 m 的测量新息序列转化为 m 个 1 维的标准化新息序列 $\bar{\mu}_k^{(i)} (i = 1, 2, \dots, m)$ 。考虑到高斯正态分布数据集 99.73% 的数据都在 3 个标准差 (3σ) 之内 [36], 可以选取检测因子为

$$\lambda_k = \max(|\bar{\mu}_k^{(i)}|) \quad (43)$$

若定义检测阈值为 $\lambda_0 = 3\sigma$ (对于标准高斯正态分布 $\sigma = 1$), 则检测规则为

$$\begin{cases} \text{若 } \lambda_k > \lambda_0 & \text{有故障} \\ \text{若 } \lambda_k \leq \lambda_0 & \text{无故障} \end{cases} \quad (44)$$

当检测到存在过程噪声或测量噪声异常时,认为估计过程存在故障。此时,基于式(41)和式(42)得到的噪声协方差统计值 $\hat{\mathbf{Q}}_{k-1}$ 和 $\hat{\mathbf{R}}_k$ 将与真实的噪声协方差 $\mathbf{Q}_{k-1}$ 和 $\mathbf{R}_k$ 严重不匹配。这时不能再利用 $1 \sim k$ 时刻的信息进行统计估计。可以利用当前时刻的测量新息对噪声协方差进行校正估计。因此,当检测到 $\lambda_k > \lambda_0$ 时,即检测出估计过程中存在故障,仅利用式(41)和式(42)中 $j=k$ 时刻的信息,将相应的噪声协方差估计值校正为

$$\hat{\mathbf{Q}}_{k-1}^* = \mathbf{K}_k \mu_k \mu_k^T \mathbf{K}_k^T - \mathbf{P}_{k|k-1}^{xx*} + \mathbf{P}_{k|k} \quad (45)$$

$$\hat{\mathbf{R}}_k^* = \mu_k \mu_k^T - \mathbf{P}_{k|k-1}^{zz*} \quad (46)$$

通过观察噪声协方差的统计估计值 $\hat{\mathbf{Q}}_{k-1}$ 和 $\hat{\mathbf{R}}_k$ 及校正估计值 $\hat{\mathbf{Q}}_{k-1}^*$ 和 $\hat{\mathbf{R}}_k^*$, 可以发现它们可能是非正定的。为了避免估计过程中会因非正定问题而导致算法失效,在编程时对统计估计值和校正估计值的对角线元素均做取绝对值处理 [35, 37]。

综上所述,本文提出的用于智能汽车目标状态跟踪的鲁棒自适应 SCKF 算法如图 2 所示。当所提出的鲁棒自适应 SCKF 算法接收到测量数据后,先基于标准的 SCKF 计算测量新息 μ_k 和检测因子 λ_k 。然后,利用式(44)进行故障检测。当 $\lambda_k \leq \lambda_0$ 时,无

故障出现,利用式(41)和式(42)中的 $\hat{\mathbf{Q}}_{k-1}$ 和 $\hat{\mathbf{R}}_k$ 自适应调整噪声协方差;当 $\lambda_k > \lambda_0$ 时,有故障出现,利用式(45)和式(46)中的 $\hat{\mathbf{Q}}_{k-1}^*$ 和 $\hat{\mathbf{R}}_k^*$ 对噪声协方差进行校正处理。接着,再次执行式(10)~(17),并重新计算相应的 Kalman 增益 $\mathbf{K}_k$ 。最后,更新状态估计值 $\hat{\mathbf{x}}_{k|k}$ 和误差协方差的平方根因子 $\mathbf{S}_{k|k}$, 并进入下一步运算。需要说明的是:当 k 时刻无故障而在此之前的某些时刻存在故障时,为了保证算法的鲁棒性,在利用式(41)和式(42)编程求取 k 时刻的噪声协方差统计值 $\hat{\mathbf{Q}}_{k-1}$ 和 $\hat{\mathbf{R}}_k$ 时,需要剔除相应时刻的故障数据。

图 2 鲁棒自适应 SCKF 算法框图

结合算法框图可以看出,所提出的 RASCKF 算法在过程噪声和测量噪声稳定时,即没有检测到估计过程存在故障,可以利用基于 MAP 的统计估计值 $\hat{\mathbf{Q}}_{k-1}$ 和 $\hat{\mathbf{R}}_k$ 自适应调整过程噪声和测量噪声,提高智能汽车目标跟踪的精确性和适应性。当过程噪声和测量噪声出现异常时, RASCKF 算法中的故障检测规则也能够将其识别出,并且可以利用当前测量新息计算出噪声协方差的校正估计值 $\hat{\mathbf{Q}}_{k-1}^*$ 和 $\hat{\mathbf{R}}_k^*$, 从而保证目标跟踪的鲁棒性。

3 仿真试验

为验证所提出鲁棒自适应 SCKF(RASCKF)算法的有效性和优越性,利用 Matlab/Simulink 仿真平台搭建智能汽车目标状态跟踪模型,与标准

SCKF 算法和文献[28]所提出的最大相关熵 SCKF (MCSCKF)算法进行对比分析。假设主车前面有一辆频繁换道行驶的车辆, 需要根据毫米波雷达的测量数据估计前车的运动状态, 为主车的决策和控制提供准确的参考信息。车辆目标跟踪过程中, 由于未知的系统噪声和测量噪声干扰, 可能会出现不同类型的故障。为此, 选取稳定噪声干扰、异常过程噪声干扰、异常测量噪声干扰和异常复合噪声干扰的四种工况进行了分析。假设四种工况下前车的运动轨迹相同, 如图 3 所示, 相对速度均为 10 m/s。在仿真试验中, 各算法的初始参数设置相同, 均为

$$\begin{cases} \hat{\mathbf{x}}_{0|0} = (5, 0, 10, 0, 0)^T \\ \mathbf{P}_{0|0} = 10^{-4} \cdot \text{diag}(1, 1, 1, 1, 1) \\ \mathbf{Q}_0 = 10^{-4} \cdot \text{diag}(1, 1, 1, 1, 1) \\ \mathbf{R}_1 = 10^{-6} \cdot \text{diag}(1, 1, 1) \end{cases} \quad (47)$$

图 3 前车的相对运动轨迹

3.1 稳定噪声干扰工况

在该仿真试验中, 假设系统噪声和测量噪声都是稳定的零均值高斯白噪声, 式(4)和式(7)中取值为

$$\begin{cases} \mu_a \sim N(0, (0.35 \text{ m/s}^2)^2) \\ \mu_\varphi \sim N(0, (0.05 \text{ rad/s}^2)^2) \\ \nu_\rho \sim N(0, (0.5 \text{ m})^2) \\ \nu_{\dot{\rho}} \sim N(0, (0.02 \text{ m/s})^2) \\ \nu_\theta \sim N(0, (0.005 \text{ rad})^2) \end{cases} \quad (48)$$

为评估所提 RASCKF 算法对目标状态的跟踪效果, 选取前车纵向距离、横向距离、相对速度和偏航角的估计结果作为分析指标。稳定噪声干扰工况下的仿真结果如图 4 所示, 各指标误差的均方根和最大值对比分别如表 1 和图 5 所示。本文估计误差最大值对比中, 各指标处对应的三种算法自左向右分别为 SCKF、MCSCKF 和 RASCKF。

(a) 纵向距离估计结果

(b) 横向距离估计结果

(c) 相对速度估计结果

(d) 偏航角估计结果

图 4 稳定噪声干扰工况估计结果对比

由图 4 可见, 在稳定噪声干扰工况下, 各算法均能较为准确地估计目标车辆的状态信息。然而, 所提出的 RASCKF 算法的估计精度要高于 SCKF 和

MCCKF。特别是对于相对速度和偏航角的估计，RASCKF 可以准确稳定地跟踪真实值，而 SCKF 和 MCCKF 的估计结果却在真实值附近有一定幅度的波动。

表 1 稳定噪声干扰工况误差均方根值对比

算法	纵向距离 p/m	横向距离 q/m	相对速度 $v/(\text{m/s})$	偏航角 φ/rad
SCKF	0.542 5	0.143 8	0.216 5	0.032 5
MCCKF	0.505 8	0.113 5	0.127 8	0.022 2
RASCKF	0.487 0	0.094 3	0.002 4	0.018 7

图 5 不同算法估计误差最大值对比

由表 1 可见，相对 SCKF，RASCKF 可以明显减小各指标的估计误差均方根值，而 MCCKF 只能小幅减小 SCKF 的估计误差均方根值。由图 5 可见，基于 RASCKF 算法的各指标误差最大值都明显小于基于 SCKF 和 MCCKF 算法的误差最大值。尤其从相对速度估计结果对比可以看出，对于 10 m/s 的真实值，SCKF 和 MCCKF 的估计误差相对过大。整体而言，所提出的 RASCKF 在估计精度上要优于 SCKF 和 MCCKF。

3.2 异常过程噪声干扰工况

在该仿真试验中，假设过程噪声和测量噪声如试验 1，但是在 8~12 s 系统出现异常，不确定加速度噪声增大为 $\mu_a \sim N(0, (3.5 \text{ m/s}^2)^2)$ 。仿真结果如图 6 所示，各指标误差的均方根和最大值对比分别如表 2 和图 7 所示。

(a) 纵向距离估计结果

(b) 横向距离估计结果

(c) 相对速度估计结果

(d) 偏航角估计结果

图 6 异常过程噪声干扰工况估计结果对比

由图 6 可见，在异常过程噪声干扰工况下，各算法仍然能较为准确地估计目标车辆的纵向距离。但是，SCKF 和 MCCKF 对横向距离、相对速度和偏航角的估计效果不如所提出的 RASCKF。尤其在 8 s 至 12 s 过程噪声突然增大时，SCKF 和 MCCKF 的鲁棒性明显变差，估计结果严重偏离真实值，而 RASCKF 的估计值仍然可以很好地跟随车辆状态的真实值。

表 2 异常过程噪声干扰工况误差均方根值对比

算法	纵向距离 p/m	横向距离 q/m	相对速度 $v/(\text{m/s})$	偏航角 φ/rad
SCKF	0.546 9	0.542 3	0.868 5	0.244 7
MCCKF	0.516 7	0.293 4	0.247 7	0.165 9
RASCKF	0.497 6	0.094 3	0.004 3	0.038 9

图 7 不同算法估计误差最大值对比

由表 2 和图 7 可见，当目标跟踪过程中受到异常的过程噪声干扰时，采用所提出 RASCKF 算法的误差均方根值和最大值均最小。对比表 1 和图 5 可以看出，当受到异常过程噪声干扰时，SCKF 和 MCSCKF 的估计误差方均根值和最大值会大幅度增加，而 RASCKF 的估计误差变化相对较小。可见，在有异常过程噪声干扰的情况下，RASCKF 的性能仍然要优于 SCKF 和 MCSCKF。

3.3 异常测量噪声干扰工况

在该仿真试验中，假设在 8 s 至 12 s 测量出现异常，不确定距离噪声增大为 $\mu_p \sim N(0, (2 \text{ m})^2)$ 。仿真结果如图 8 所示，各指标误差的方均根和最大值对比分别如表 3 和图 9 所示。

(a) 纵向距离估计结果

(b) 横向距离估计结果

(c) 相对速度估计结果

(d) 偏航角估计结果

图 8 异常测量噪声干扰工况估计结果对比

由图 8 可见，在异常测量噪声干扰工况下，所提出的 RASCKF 可以较为准确地估计目标车辆的状态信息。然而，SCKF 和 MCSCKF 的整体估计效果明显变差，不但在 8 s 至 12 s 测量噪声异常时估计误差增大，在 12 s 之后的估计效果也会受到不同程度的影响。

表 3 异常测量噪声干扰工况误差均方根值对比

算法	纵向距离 p/m	横向距离 q/m	相对速度 $v/(\text{m/s})$	偏航角 φ/rad
SCKF	1.062 9	0.413 7	1.167 5	0.130 2
MCSCKF	0.527 5	0.150 1	0.236 5	0.033 4
RASCKF	0.460 2	0.094 2	0.010 5	0.021 0

图 9 不同算法估计误差最大值对比

由表 3 和图 9 可见,当目标跟踪过程中受到异常的测量噪声干扰时,RASCKF 的估计误差及误差最大值仍然最小。对比表 1 和图 5 可以看出,当测量噪声异常时,标准 SCKF 估计的精确性和鲁棒性都会受到严重影响,MCSCKF 和 RASCKF 受到的影响相对较小。从整体看来,所提出 RASCKF 的性能仍然要优于 SCKF 和 MCSCKF。

3.4 异常复合噪声干扰工况

在该仿真试验中,假设出现了异常的复合噪声:在 8 s 至 9 s 系统出现异常,不确定加速度噪声如试验 2;12 s 至 13 s 测量出现异常,不确定距离噪声如试验 3。仿真结果如图 10 所示,各指标误差的均方根和最大值对比分别如表 4 和图 11 所示。

(a) 纵向距离估计结果

(b) 横向距离估计结果

(c) 相对速度估计结果

(d) 偏航角估计结果

图 10 异常复合噪声干扰工况估计结果对比

由图 10 可见,在异常的复合噪声干扰工况下,所提出的 RASCKF 依然能够准确地估计目标车辆的状态信息。相对而言,SCKF 和 MCSCKF 在该工况下的估计精度会明显降低。尽管过程噪声和测量噪声出现异常的时段都仅有 1 s,但其对 SCKF 和 MCSCKF 两种算法估计效果的影响仍然很大。

表 4 异常复合噪声干扰工况误差方均根值对比

算法	纵向距离 p/m	横向距离 q/m	相对速度 $v/(m/s)$	偏航角 φ/rad
SCKF	0.705 5	0.626 1	0.948 2	0.178 7
MCSCKF	0.527 6	0.253 7	0.239 2	0.113 6
RASCKF	0.479 1	0.093 3	0.006 6	0.030 5

图 11 不同算法估计误差最大值对比

由表 4 和图 11 可见,当目标跟踪过程同时受到异常过程噪声和异常测量噪声干扰时,RASCKF 算法的估计效果仍然是最好的,并且其估计误差明显小于其他两种算法的估计误差。可以看出,所提出的 RASCKF 算法抵抗异常复合噪声干扰的能力要明显优于 MCSCKF 和 RASCKF 两种算法。

通过不同噪声干扰工况下仿真试验结果的对比,可以看出,所提出的 RASCKF 可以准确地跟踪

目标车辆的状态信息。在受到异常的过程噪声、测量噪声和复合噪声干扰时, RASCKF 算法仍然可以保持很好的跟踪性能, 其估计效果明显优于 SCKF 算法和 MCSCKF 算法。

4 结论

(1) 本文针对智能汽车目标状态跟踪中过程噪声和测量噪声的不确定问题, 提出一种 RASCKF 算法。在稳定噪声干扰情况下, RASCKF 可以基于 MAP 估计对过程噪声协方差和测量噪声协方差进行自适应调整。当过程噪声和测量噪声异常时, RASCKF 可以自动识别并对噪声协方差进行校正处理。

(2) 为验证提出 RASCKF 算法的有效性, 进行了不同噪声干扰工况下的仿真试验。结果表明 RASCKF 算法可以降低各状态变量的估计误差, 提高 SCKF 的估计精度。在过程噪声和测量噪声异常的情况下, RASCKF 仍然具有很好的鲁棒性。所提出的 RASCKF 几乎不受异常噪声扰动的影响, 其整体性能明显优于 SCKF 算法。

(3) 所提出的 RASCKF 算法可实时检测估计过程, 能够诊断出由于状态突变、模型不确定及执行器和传感器失效等造成的噪声异常, 保障目标状态跟踪的准确性和鲁棒性, 对提高智能汽车感知系统性能具有重要的意义。

参 考 文 献

- [1] KIM M H, SON J. On-road assessment of in-vehicle driving workload for older drivers: design guidelines for intelligent vehicles[J]. International Journal of Automotive Technology, 2011, 12(2): 265-272.
- [2] SHLADOVER S E. Connected and automated vehicle systems: Introduction and overview[J]. Journal of Intelligent Transportation Systems, 2018, 22(3): 190-200.
- [3] 谢有浩, 魏振亚, 赵林峰, 等. 基于 μ 综合方法的智能车辆人机共驾的鲁棒横向控制[J]. 机械工程学报, 2020, 56(4): 104-114.
XIE Youhao, WEI Zhenya, ZHAO Linfeng, et al. Robust lateral control of intelligent vehicle in the human-machine sharing based on μ -synthesis[J]. Journal of Mechanical Engineering, 2020, 56(4): 104-114.
- [4] SCHUBERT R, RICHTER E, WANIELIK G. Comparison and evaluation of advanced motion models for vehicle tracking[C]// Information Fusion, 2008 11th International Conference on. IEEE, 2008: 730-735.
- [5] 任玥, 郑玲, 张巍, 等. 基于模型预测控制的智能车辆主动避撞控制研究[J]. 汽车工程, 2019, 41(4): 404-410.
REN Yue, ZHENG Ling, ZHANG Wei, et al. A study on active collision avoidance control of autonomous vehicles based on model predictive control[J]. Automotive Engineering, 2019, 41(4): 404-410.
- [6] REN D B, ZHANG J Y, ZHANG J M, et al. Trajectory planning and yaw rate tracking control for lane changing of intelligent vehicle on curved road[J]. Science China (Technological Sciences), 2011, 54(3): 630-642.
- [7] DAVINS V J, PLESTAN F, MOUSSAOUI S, et al. Design and optimization of nonlinear observers for road curvature and state estimation in automated vehicles[J]. IEEE Transactions on Intelligent Transportation Systems, 2017, 18(12), 3315-3327.
- [8] ANANDALLI M, BALIGAR V P. A novel approach in real-time vehicle detection and tracking using Raspberry Pi[J]. Alexandria Engineering Journal, 2018, 57(3): 1597-1607.
- [9] 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[J]. 机械工程学报, 2019, 55(6): 156-165.
ZHANG Zhiyong, ZHANG Shuzhi, HUANG Caixia, et al. State estimation of distributed drive electric vehicle based on adaptive extended Kalman filter[J]. Journal of Mechanical Engineering, 2019, 55(6): 156-165.
- [10] 汪葵, 殷国栋, 耿可可, 等. 基于 NACKF 的分布式驱动电动汽车轮胎侧向力与质心侧偏角估计[J]. 机械工程学报, 2019, 55(22): 103-112.
WANG Yan, YIN Guodong, GENG Keke, et al. Tire lateral forces and sideslip angle estimation for distributed drive electric vehicle using noise adaptive cubature Kalman filter[J]. Journal of Mechanical Engineering, 2019, 55(22): 103-112.
- [11] SCHUBERT R, WANIELIK G. A unified bayesian approach for object and situation assessment[J]. IEEE Intelligent Transportation Systems Magazine, 2011, 3(2): 6-19.
- [12] REINA G, MESSINA A. Vehicle dynamics estimation via augmented extended Kalman filtering[J]. Measurement, 2019, 133: 383-395.
- [13] HEIDFELD H, MARTIN S, KASPER R. UKF-based state and tire slip estimation for a 4WD electric vehicle[J]. Vehicle System Dynamics, 2019, 57(11): 1-18.

- [14] 宋义彤, 舒红宇, 陈仙宝, 等. 分布式电动汽车状态与参数无迹卡尔曼滤波估计[J]. 机械工程学报, 2020, 56(16): 204-213.
SONG Yitong, SHU Hongyu, CHEN Xianbao, et al. State and parameters estimation for distributed drive electric vehicle based on unscented Kalman filter[J]. Journal of Mechanical Engineering, 2020, 56(16): 204-213.
- [15] ASKELAND S A, EKMAN T. Tracking with a high-resolution 2D spectral estimation based automotive radar[J]. IEEE Transactions on Intelligent Transportation Systems, 2015, 16(5): 2418-2423.
- [16] XIE G, GAO H, QIAN L, et al. Vehicle trajectory prediction by integrating physics- and maneuver-based approaches using interactive multiple models[J]. IEEE Transactions on Industrial Electronics, 2018, 65(7): 5999-6008.
- [17] SCHUBERT R, ADAM C, OBST M, et al. Empirical evaluation of vehicular models for ego motion estimation[C]// 2011 IEEE Intelligent Vehicles Symposium (IV). IEEE, 2011: 534-539.
- [18] KATRINIOK A, ABEL D. Adaptive EKF-based vehicle state estimation with online assessment of local observability[J]. IEEE Transactions on Control Systems Technology, 2016, 24(4): 1368-1381.
- [19] STRANO S, TERZO M. Constrained nonlinear filter for vehicle sideslip angle estimation with no a priori knowledge of tyre characteristics[J]. Control Engineering Practice, 2017, 71: 10-17.
- [20] GUSTAFSSON F, HENDEBY G. Some relations between extended and unscented Kalman filters[J]. Signal Processing, IEEE Transactions on, 2012, 60(2): 545-555.
- [21] CHANG L, HU B, LI A, et al. Transformed unscented Kalman filter[J]. IEEE Transactions on Automatic Control, 2013, 58(1): 252-257.
- [22] ARASARATNAM I, HAYKIN S. Cubature Kalman filters[J]. IEEE Transactions on Automatic Control, 2009, 54(6): 1254-1269.
- [23] AFSHARI H H, GADSDEN S A, HABIBI S. Gaussian filters for parameter and state estimation: a general review of theory and recent trends[J]. Signal processing, 2017, 135 (6): 218-238.
- [24] BISHT S S, SINGH M P. An adaptive unscented Kalman filter for tracking sudden stiffness changes[J]. Mechanical Systems & Signal Processing, 2014, 49: 181-195.
- [25] 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[J]. 中国科学:技术科学, 2020, 50 (11): 1461-1473.
ZHANG Zhida, ZHENG Ling, WU Hang, et al. State estimation of distributed electric vehicle based on robust adaptive UKF [J]. Science China (Technological Sciences), 2020, 50 (11): 1461-1473.
- [26] KIANI M, POURTAKDOUST S H. Adaptive square-root cubature-quadrature Kalman particle filter for satellite attitude determination using vector observations[J]. Acta Astronautica, 2014, 105(1): 109-116.
- [27] SHEN C, ZHANG Y, GUO X T, et al. Seamless GPS/inertial navigation system based on self-learning square-root cubature Kalman filter[J]. IEEE Transactions on Industrial Electronics, 2021, 68(1): 499-508.
- [28] LIU X, QU H, ZHAO J, et al. Maximum correntropy square-root cubature Kalman filter with application to SINS/GPS integrated systems[J]. ISA Transactions, 2018, 80(9): 195-202.
- [29] 赵望宇, 李必军, 单云霄, 等. 融合毫米波雷达与单目视觉的前车检测与跟踪[J]. 武汉大学学报, 2019, 44(12): 1832-1840.
ZHAO Wangyu, LI Bijun, SHAN Yunxiao, et al. Vehicle detection and tracking based on fusion of millimeter wave radar and monocular vision[J]. Journal of Wuhan University, 2019, 44(12): 1832-1840.
- [30] ZHAO L, WANG J, YU T, et al. Design of adaptive robust square-root cubature Kalman filter with noise statistic estimator[J]. Applied Mathematics and Computation, 2015, 256: 352-367.
- [31] REZA M A, YASHAR S, SILVIO S, et al. Adaptive square-root unscented Kalman filter: An experimental study of hydraulic actuator state estimation[J]. Mechanical Systems & Signal Processing, 2019, 132: 670-691.
- [32] GAO Z, MU D, GAO S, et al. Adaptive unscented Kalman filter based on maximum posterior and random weighting[J]. Aerospace Science & Technology, 2017, 71: 12-24.
- [33] GAO S, HU G, ZHONG Y. Windowing and random weighting-based adaptive unscented Kalman filter[J]. International Journal of Adaptive Control & Signal Processing, 2015, 29(2): 201-223.
- [34] SOKEN H E, HAJIYEV C. Pico satellite attitude estimation via robust unscented Kalman filter in the

- presence of measurement faults[J]. ISA Transactions, 2010, 49(3): 249-256.
- [35] HAJIYEV C, SOKEN H E. Robust adaptive unscented Kalman filter for attitude estimation of pico satellites[J]. International Journal of Adaptive Control and Signal Processing, 2014, 28(2): 107-120.
- [36] RAHIMI A, KUMAR K D, ALIGHANBARI H. Fault estimation of satellite reaction wheels using covariance based adaptive unscented Kalman filter[J]. Acta astronautica, 2017, 134(5): 159-169.
- [37] MENF Y, GAO S, ZHONG Y, et al. Covariance matching

based adaptive unscented Kalman filter for direct filtering in INS/GNSS integration[J]. Acta Astronautica, 2016, 120: 171-181.

作者简介: 张志达, 男, 1990 年出生, 博士研究生。主要研究方向为智能汽车状态估计与循迹控制。

E-mail: zhangzhida_edu@163.com

郑玲(通信作者), 女, 1963 年出生, 博士, 教授, 博士研究生导师。主要研究方向为智能汽车的环境感知、决策与动力学控制。

E-mail: zling@cqu.edu.cn

李以农, 男, 1961 年出生, 博士, 教授, 博士研究生导师。主要研究方向为车辆系统动力学与控制、振动噪声控制。

E-mail: ynlili@cqu.edu.cn

(上接第 180 页)

- WANG Zheng, LI Tian, ZHANG Jiye. Research on aerodynamic performance of high-speed train subjected to different types of crosswind[J]. Journal of Mechanical Engineering, 2018, 54(2): 203-211.
- [20] CHOI E C C. Wind-drive rain and driving rain coefficient during thunderstorms and non-thunderstorms[J]. Journal of Wind Engineering and Industrial Aerodynamics, 2001, 89(3): 293-308.
- [21] 张在中, 周丹. 不同头部外形高速列车气动性能风洞试验研究[J]. 中南大学学报, 2013, 44(6): 2603-2608.
- ZHANG Zaizhong, ZHOU Dan. Wind tunnel experiment on aerodynamic characteristic of streamline head of high-speed train with different head shapes[J]. Journal of Central South University, 2013, 44(6): 2603-2608.
- [22] YU M G, JIANG R C, ZHANG Q, et al. Crosswind

stability evaluation of high-speed train using different wind models[J]. Chinese Journal of Mechanical Engineering, 2019, 32: 40.

- [23] 于梦阁. 基于可靠性的高速列车风致安全研究[D]. 成都: 西南交通大学, 2014.

YU Mengge. Study on the wind-induced safety of the high-speed train based on the reliability[D]. Chengdu: Southwest Jiaotong University, 2014.

作者简介: 于梦阁, 女, 1985 年出生, 博士, 副教授。主要研究方向为车辆空气动力学, 车辆系统动力学。

Email: yumengge0627@163.com

刘加利(通信作者), 男, 1985 年出生, 博士, 高级工程师。主要研究方向为列车空气动力学。

Email: liujiali0612@163.com