

基于改进双重无迹卡尔曼滤波算法的车辆状态估计

费明哲¹,王健^{1*},于金鹏²,杨君¹,杜若飞¹,王云靖¹,邓欢¹

1. 山东交通学院汽车工程学院,山东 济南 250357;2. 青岛大学自动化学院,山东 青岛 266071

摘要:针对车辆行驶过程中的状态和参数估计问题,基于软件 MATLAB 中车辆三自由度动力学模型,分别采用无迹卡尔曼滤波(unscented Kalman filter, UKF)算法、双重无迹卡尔曼滤波(dual unscented Kalman filter, DUKF)算法及采用奇异值分解的改进双重无迹卡尔曼滤波(singular value decomposition-dual unscented Kalman filter, SVD-DUKF)算法,估计车辆在同一工况下的状态及参数。结果表明:UKF 算法能保证一定的估计精度,但需时刻输入准确的车身质量等参数,在车辆行驶过程中难以实现;DUKF 算法与 SVD-DUKF 算法有相近的估计精度,但 DUKF 算法采用 Cholesky 分解,在车辆运行过程中难以保证误差协方差矩阵为正定矩阵;SVD-DUKF 算法更适合估计车辆行驶状态及参数,估计精度较高,适用性较强。

关键词:状态估计;UKF 算法;DUKF 算法;奇异值分解

中图分类号:U463.9

文献标志码:A

文章编号:1672-0032(2023)03-0007-08

引用格式:费明哲,王健,于金鹏,等.基于改进双重无迹卡尔曼滤波算法的车辆状态估计[J].山东交通学院学报,2023,31(3):7-14.

FEI Mingzhe, WANG Jian, YU Jinpeng, et al. Vehicle state estimation based on improved dual unscented Kalman filter[J]. Journal of Shandong Jiaotong University, 2023, 31(3): 7-14.

0 引言

车辆运行时,从反馈参数中获取精确、实时的状态信息是提高车辆主动安全控制能力的重要保证,随无人驾驶技术的发展,状态估计和参数估计越来越重要,无人驾驶的最终目标是实现零人为干预,要求车辆有一定的自我校准能力。开发车辆动力学控制系统旨在提高车辆、用户及周围其他要素的安全性,采用主动控制系统防止由地形、外部因素或驾驶员输入过快而导致的不当行为,控制器性能主要取决于它们对车辆状态和参数的估计程度^[1]。车辆动力学控制系统在很大程度上依赖车辆各部分惯性矩、轮胎刚度等参数^[2],这些参数随时间变化,无法直接测量,如何得到更准确的车辆行驶状态和参数极为重要。

车辆行驶状态估计方法主要有卡尔曼滤波(Kalman filter, KF)算法^[3]及其衍生的各种相关算法,如神经网络^[4-5]、状态观测器^[6]、模糊逻辑^[7]方法等。在简单的线性动力学模型和线性平衡系统中经常采用 KF 算法,根据系统的输入和输出计算最优估计^[8]。输出数据受外界噪声干扰,在某些情况下可把系统的估计过程看作是滤波过程。KF 算法主要用于线性高斯系统,当车辆表现出复杂非线性时的估计精度较低^[9]。标准扩展卡尔曼滤波(exended Kalman filter, EKF)算法以线性最小方差估计为依据,通过递推算法对状态变量进行滤波估计,是车辆状态估计领域的经典方法,应用广泛^[10-11],若系统具有高非线性度

收稿日期:2022-10-27

基金项目:山东省交通运输厅科技计划项目(2022B107);山东省高等学校青创科技支持计划项目(2021KJ039);山东交通学院研究生科技创新项目(2022YK001)

第一作者简介:费明哲(1996—),男,内蒙古包头人,硕士研究生,主要研究方向为车辆状态参数估计,E-mail:alone_1012@163.com。

*通信作者简介:王健(1986—),男,山东潍坊人,副教授,工学博士,主要研究方向为自动驾驶及主动安全,E-mail:wangjian@sdjtu.edu.cn。

时, EKF 算法很容易在初始系统的一阶线性分析中产生严重的线性误差, 且很难计算出所需的雅可比矩阵, 同时该算法为无限增长的记忆滤波器, 计算效率和估计精度会随时间的推移而降低。文献[12]提出了一种基于限定记忆随机加权扩展卡尔曼滤波(limited memory random weighted extended Kalman filter, LMRWEKF)算法, 响应速度较快, 估计精度较高。

无迹卡尔曼滤波(unscented Kalman filter, UKF)算法未采用 KF 和 EKF 的方法, 即将系统的非线性函数线性化, 而是在卡尔曼估计结构中通过无迹变换(unscented transform, UT)方法, 调整均值和方差的连续方程进行预测^[13-14]。UKF 算法无需运算雅可比矩阵, 也无需忽略函数中的高阶元素, 减小了估计误差, 具有测量非线性分布的高精度计算能力^[15]。文献[16]在 UKF 算法中加入遗忘因子进行车辆参数估计, 提高了算法对噪声的抑制能力。文献[17]提出一种改进的迭代无迹卡尔曼滤波(improved iterated unscented Kalman filter, IIUKF)算法, 在系统方程处于非常严重的非线性状态时, 该算法具有较高的估计精度。文献[18]提出了一种基于蚁群优化算法的 UKF 状态估计自适应滤波算法, 运用蚁群算法的寻优能力, 提高了算法的鲁棒性和估计精度。

本文基于车辆三自由度动力学模型, 分别采用 UKF 算法、双重无迹卡尔曼滤波算法(dual unscented Kalman filter, DUKF)和采用奇异值分解的改进双重无迹卡尔曼滤波算法(singular value decomposition-dual unscented Kalman filter, SVD-DUKF)估计车辆行驶状态及车辆参数, 评估 3 种算法在车辆一定行驶工况下的状态及参数估计能力。

1 车辆三自由度动力学模型

1.1 车辆模型

只考虑各轮胎的平面运动, 忽略滚动和俯仰运动, 建立包含纵向、侧向、横摆的车辆三自由度动力学非线性灰箱模型, 如图 1 所示。

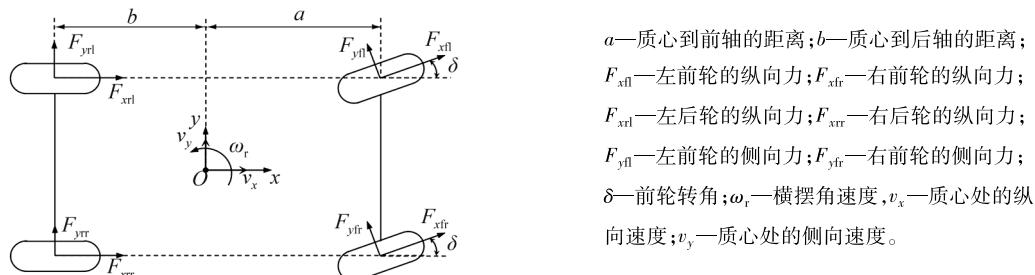


图 1 车辆三自由度动力学非线性灰箱模型

不考虑空气阻力, 车辆三自由度动力学模型方程包括纵向、侧向和横摆方向的动力学方程。纵向的动力学方程为:

$$\begin{cases} ma_x = (F_{xfl} + F_{xfr}) \cos \delta - (F_{yfl} + F_{yfr}) \sin \delta + F_{xrl} + F_{xrr}, \\ \dot{v}_x = a_x + \omega_r v_y \end{cases},$$

式中: m 为整车质量, a_x 为车辆纵向加速度, \dot{v}_x 为质心处的纵向加速度。

侧向的动力学方程为:

$$\begin{cases} ma_y = (F_{xfl} + F_{xfr}) \sin \delta + (F_{yfl} + F_{yfr}) \cos \delta + F_{yrl} + F_{yrr}, \\ \dot{v}_y = a_y - \omega_r v_x \end{cases},$$

式中: a_y 为车辆侧向加速度, \dot{v}_y 为质心处的侧向加速度。

横摆方向的动力学方程为:

$$I_z \dot{\omega}_r = a(F_{xfl} + F_{xfr}) \sin \delta + a(F_{yfl} + F_{yfr}) \cos \delta - b(F_{yrl} + F_{yrr}),$$

式中: I_z 为车辆绕 z 轴的转动惯量, $\dot{\omega}_r$ 为横摆角加速度。

1.2 轮胎模型

轮胎支承车辆自重传递驱动和制动力矩,轮胎模型直接影响整车动力学模型的仿真结果^[19]。轮胎模型为:

$$F_{xf} = C_x s_f, F_{xr} = C_x s_r, F_{yf} = C_y \alpha_f, F_{yr} = C_y \alpha_r,$$

式中: F_{xf}, F_{xr} 分别为前轴轮胎、后轴轮胎的纵向力; F_{yf}, F_{yr} 分别为前轴轮胎、后轴轮胎的侧向力; C_x, C_y 分别为轮胎的纵向、侧向刚度,设轮胎的刚度相同; s_f, s_r 分别为前轴轮胎、后轴轮胎的滑移率; α_f, α_r 分别为前轴轮胎、后轴轮胎的滑移角,其中 $\alpha_f = \delta - \arctan[(v_y + a\omega_r)/v_x]$, $\alpha_r = -\arctan[(v_y - b\omega_r)/v_x]$ 。

2 车辆状态估计算法

2.1 UKF 算法

UKF 算法在卡尔曼估计结构中通过 UT 变换调整均值和方差的连续方程进行估计,估计精度较高,在强非线性系统中具有一定的鲁棒性。

根据构建的车辆三自由度力学模型,定义系统在时刻 t 的状态向量 $\mathbf{x}(t) = [v_{x0} \ v_{y0} \ \omega_{r0}]^T$,对应的 Sigma 点集向量 $\mathbf{X}(t) = [v_x \ v_y \ \omega_r]^T$,非线性系统状态空间方程为:

$$\begin{cases} \mathbf{X}(t+1) = f(\mathbf{x}(t), \mathbf{W}(t)) \\ \mathbf{Z}(t) = h(\mathbf{x}(t), \mathbf{V}(t)) \end{cases}, \quad (1)$$

式中: $\mathbf{Z}(t)$ 为考虑噪声的系统观测矩阵, $f(\cdot)$ 为非线性状态方程函数, $h(\cdot)$ 为非线性观测方程函数, $\mathbf{W}(t)$ 为系统估计过程中的高斯白噪声, $\mathbf{V}(t)$ 为系统测量高斯白噪声。

UKF 算法通过 UT 变换得到 $\mathbf{X}(t)$ 的统计特征,即选取 $2n+1$ 个采样点,公式为:

$$\mathbf{X}^{(i)} = \begin{cases} \bar{\mathbf{X}}, i=0 \\ \bar{\mathbf{X}} + (\sqrt{(n+\lambda)\mathbf{P}})_i, i=1 \sim n \\ \bar{\mathbf{X}} - (\sqrt{(n+\lambda)\mathbf{P}})_i, i=(n+1) \sim 2n \end{cases}, \quad (2)$$

式中: $\mathbf{X}^{(i)}$ 为第 i 个采样点; \mathbf{P} 为 \mathbf{x} 的协方差矩阵; λ 为缩放比例系数, $\lambda = d^2(n+\kappa) - n$,其中 d 为系数, d 的选取控制采样点的分布状态, κ 为待选参数,其取值没有界限,但通常应确保矩阵 $(n+\lambda)\mathbf{P}$ 为半正定矩阵。

计算采样点的权值,公式为:

$$\begin{cases} \omega_m^{(0)} = \lambda / (n+\lambda) \\ \omega_c^{(0)} = \lambda / (n+\lambda) + (1-d^2+\beta) \\ \omega_m^{(i)} = \omega_c^{(i)} = \lambda / 2(n+\lambda), i=1 \sim 2n \end{cases}, \quad (3)$$

式中: $\omega_m^{(i)}$ 为第 i 个采样点的均值的权值; $\omega_c^{(i)}$ 为第 i 个采样点的协方差的权值; β 为非负权系数, $\beta=2$ 。

UKF 算法基本步骤有以下 8 步。

1) 根据式(2)获取 1 组采样点(即 Sigma 点集)

$$\mathbf{X}^{(i)}(t|t) = [\hat{\mathbf{X}}(t|t) \ \hat{\mathbf{X}}(t|t) + \sqrt{(n+\lambda) P(t|t)} \ \hat{\mathbf{X}}(t|t) - \sqrt{(n+\lambda) P(t|t)}]^T,$$

式中 $\hat{\mathbf{X}}(t|t)$ 为 t 时刻 Sigma 点集的预测值。

2) 计算 Sigma 点集的一步预测

$$\mathbf{X}^{(i)}(t+1|t) = f[t, \mathbf{X}^{(i)}(t|t)]. \quad (4)$$

3) 将式(4)加权求和得到系统状态量的一步预测 $\hat{\mathbf{X}}(t+1|t) = \sum_{i=0}^{2n} \omega_m^{(i)} \mathbf{X}^{(i)}(t+1|t)$,一步预测的协方差矩阵

$$\mathbf{P}(t+1|t) = \sum_{i=0}^{2n} \omega_c^{(i)} [\hat{\mathbf{X}}(t+1|t) - \mathbf{X}^{(i)}(t+1|t)] [\hat{\mathbf{X}}(t+1|t) - \mathbf{X}^{(i)}(t+1|t)]^T + \mathbf{Q}, \quad (5)$$

式中 \mathbf{Q} 为系统过程噪声协方差矩阵。

4) 对式(5)再次进行 UT 变换,产生新的 Sigma 点集

$$\mathbf{X}^{(i)}(t+1|t) = [\hat{\mathbf{X}}(t+1|t) \quad \hat{\mathbf{X}}(t+1|t) + \sqrt{(n+\lambda)} \mathbf{P}(t+1|t) \quad \hat{\mathbf{X}}(t+1|t) - \sqrt{(n+\lambda)} \mathbf{P}(t+1|t)]。 \quad (6)$$

5) 将式(6)代入式(1),得到预测的系统观测量

$$\mathbf{Z}^{(i)}(t+1|t) = h(\mathbf{X}^{(i)}(t+1|t))。 \quad (7)$$

6) 结合式(7)计算系统预测的均值 $\bar{\mathbf{Z}}(t+1|t) = \sum_{i=0}^{2n} \omega^{(i)} \mathbf{Z}^{(i)}(t+1|t)$, 观测协方差、协方差分别为:

$$\mathbf{P}_{z_{\tilde{z}_t}} = \sum_{i=0}^{2n} \omega^{(i)} [\mathbf{Z}^{(i)}(t+1|t) - \bar{\mathbf{Z}}(t+1|t)] [\mathbf{Z}^{(i)}(t+1|t) - \bar{\mathbf{Z}}(t+1|t)]^T + \mathbf{R}。$$

$$\mathbf{P}_{x_{\tilde{x}_t}} = \sum_{i=0}^{2n} \omega^{(i)} [\mathbf{X}^{(i)}(t+1|t) - \bar{\mathbf{Z}}(t+1|t)] [\mathbf{Z}^{(i)}(t+1|t) - \bar{\mathbf{Z}}(t+1|t)]^T,$$

式中 \mathbf{R} 为测量噪声协方差矩阵。

7) 计算卡尔曼增益矩阵 $\mathbf{K}(t+1) = \mathbf{P}_{x_{\tilde{x}_t}} \mathbf{P}_{z_{\tilde{z}_t}}^{-1}$ 。

8) 计算系统的状态更新,公式为: $\hat{\mathbf{X}}(t+1|t+1) = \hat{\mathbf{X}}(t+1|t) + \mathbf{K}(t+1) [Z(t+1) - \hat{\mathbf{Z}}(t+1|t)]$, 计算协方差矩阵更新,公式为: $\mathbf{P}(t+1|t+1) = \mathbf{P}(t+1|t) - \mathbf{K}(t+1) \mathbf{P}_{z_{\tilde{z}_t}} \mathbf{K}^T(t+1)$ 。

2.2 DUKF 算法

DUKF 算法由 2 个单独的无迹卡尔曼滤波器并行运行^[20]。连接 2 个平行的无迹卡尔曼滤波器,将输入量 u 输入参数滤波器中,参数滤波器将预测估计值 $\hat{\mathbf{X}}_{pt}^-$ 传至状态滤波器,与 u 一起估计车辆的状态信息,将得到的状态预测信息 $\hat{\mathbf{X}}_{st}^-$ 与由观测方程得到的状态观测量 z_s 一起进行状态修正,得到修正后的状态信息 $\hat{\mathbf{X}}_{st}$,同时将 $\hat{\mathbf{X}}_{st}^-$ 传回参数估计器,与 $\hat{\mathbf{X}}_{pt}^-$ 和参数观测量 z_p 一起修正预测参数,得到修正值 $\hat{\mathbf{X}}_{pt}$,2 个无迹卡尔曼滤波器根据 $\hat{\mathbf{X}}_{st}$ 、 $\hat{\mathbf{X}}_{pt}$ 再次进行估计预测,最后按照该过程迭代更新。DUKF 算法运行框架如图 2 所示,其中 y 为车辆根据 u 得到的输出量, σ 为噪声。

2.3 SVD-DUKF 算法

车辆动力学系统的非线性程度较高时,UKF 算法的估计精度下降甚至发散。分析 UKF 算法的运行过程可知,UT 变换过程中,生成 Sigma 点集时使用 Cholesky 分解运算误差协方差矩阵,需保证其是非负定矩阵,但在车辆运行过程中,系统协方差矩阵易受噪声影响,导致其成为奇异矩阵而无法处理,从而结束滤波过程,使滤波结果精度下降甚至发散。本文在 UT 变换中引入奇异值分解(singular value decomposition, SVD)替代 Cholesky 分解,使算法具有更强的鲁棒性。

SVD 算法在机器学习领域应用广泛。假设任意矩阵 $\mathbf{A}_{m \times n}$ 的 SVD 过程可表示为:

$$\mathbf{A}_{m \times n} = \mathbf{U}_{m \times m} \boldsymbol{\Sigma}_{m \times n} \mathbf{V}_{n \times n}^T,$$

式中: \mathbf{U} 为正交矩阵,即满足 $\mathbf{U}^T \mathbf{U} = \mathbf{I}_{m \times m}$,且 $\mathbf{U} \in \mathbf{R}^{m \times m}$; $\boldsymbol{\Sigma}$ 除主对角线外的元素都为 0,主对角线上的每个元素称为奇异值; \mathbf{V} 为正交矩阵,即满足 $\mathbf{V}^T \mathbf{V} = \mathbf{I}_{n \times n}$,且 $\mathbf{V} \in \mathbf{R}^{n \times n}$ 。

在 UKF 算法中采用 SVD 替代 Cholesky 分解时,滤波过程的主体过程不变,仅改变产生 Sigma 点集的过程。对协方差矩阵 \mathbf{P}_t 的 SVD 过程为:

$$\mathbf{P}_t = \mathbf{U} \boldsymbol{\Sigma} \mathbf{V}^T,$$

$$\mathbf{X}^{(i)} = \begin{cases} \bar{\mathbf{X}}, i = 0 \\ \bar{\mathbf{X}} + (\sqrt{(n+\lambda)} \mathbf{U} \sqrt{\boldsymbol{\Sigma}})_i, i = 1 \sim n \\ \bar{\mathbf{X}} - (\sqrt{(n+\lambda)} \mathbf{U} \sqrt{\boldsymbol{\Sigma}})_i, i = (n+1) \sim 2n \end{cases}.$$

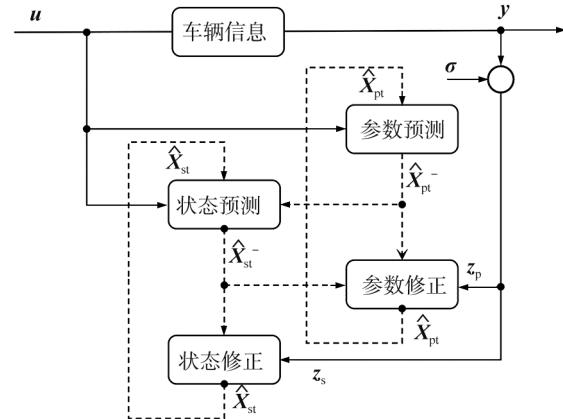


图 2 DUKF 算法运行框架

3 仿真结果对比

以 MATLAB 内置的高刚度轮胎模拟数据为仿真输入数据,前轮的滑移输入为具有恒定偏移的正弦曲线, ω_r 输入也是正弦曲线,但振幅和频率与滑移输入不同。采用 UKF 算法估计车辆状态时,因无法估计车辆参数,视正确参数为已知进行仿真。运行仿真时,设每秒迭代 10 次,仿真结果见图 3,误差见图 4。

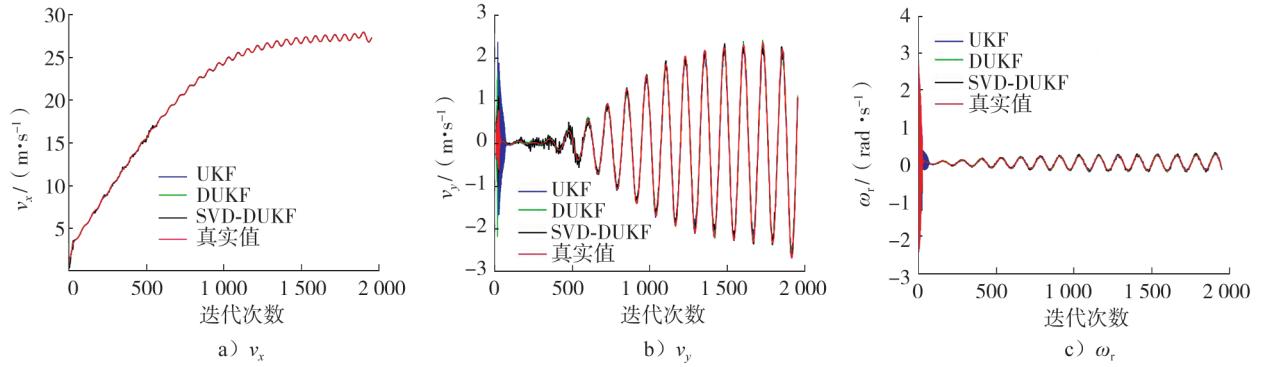


图 3 不同算法下车辆状态估计结果

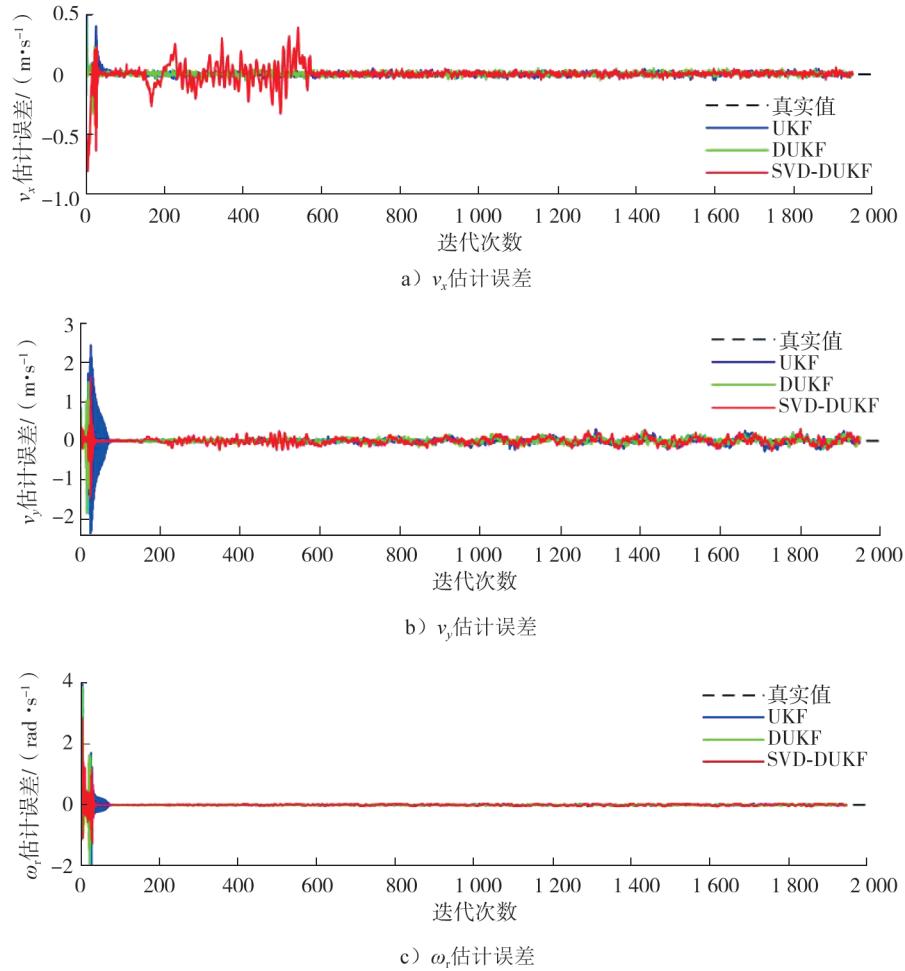


图 4 不同算法下车辆状态估计误差

为进一步分析仿真结果,用均方根误差衡量不同算法的估计性能,均方根误差

$$E_{\text{RMS}} = \sqrt{\frac{1}{N} \sum_{k=1}^N (x_k - \hat{x}_k)^2}, \quad (8)$$

式中: N 为迭代总次数, \hat{x}_k 为第 k 次迭代的状态估计值, x_k 为真实值。

根据式(8),得到不同算法下车辆状态估计的 E_{RMS} ,如表1所示。由图3、4及表1可知:3种算法的估计结果均较好,但UKF算法中将 m 等参数列为已知项,与实际情况不符;DUKF算法可同时估计车辆的状态和车辆参数,但在UT变换进行Cholesky分解时,要求协方差为非负定矩阵,有一定限制;SVD-DUKF算法的鲁棒性更强,更适合汽车强非线性系统。

表1 不同算法下车辆状态估计的 E_{RMS}

算法	E_{RMS}		
	$v_x / (\text{m} \cdot \text{s}^{-1})$	$v_y / (\text{m} \cdot \text{s}^{-1})$	$\omega_r / (\text{rad} \cdot \text{s}^{-1})$
UKF	0.120 0	0.286 0	0.159 4
DUKF	0.114 5	0.233 7	0.154 9
SVD-DUKF	0.190 3	0.265 3	0.153 6

在该车辆动力学模型中,已知 $m=1700\text{ kg}$, $C_x=1.5\times 10^5\text{ N/rad}$, $C_y=5.0\times 10^4\text{ N/rad}$ 。DUKF算法和SVD-DUKF算法对车辆参数估计结果如图5所示。由图5可知:估计 m 和 C_x 时,DUKF算法的波动较小,SVD-DUKF算法的误差随仿真进程逐渐减小,最后与DUKF算法均收敛至真实值附近;估计 C_y 时,SVD-DUKF算法能较快地收敛至真实值并在附近波动,DUKF算法比DUKF算法的适用性更高。

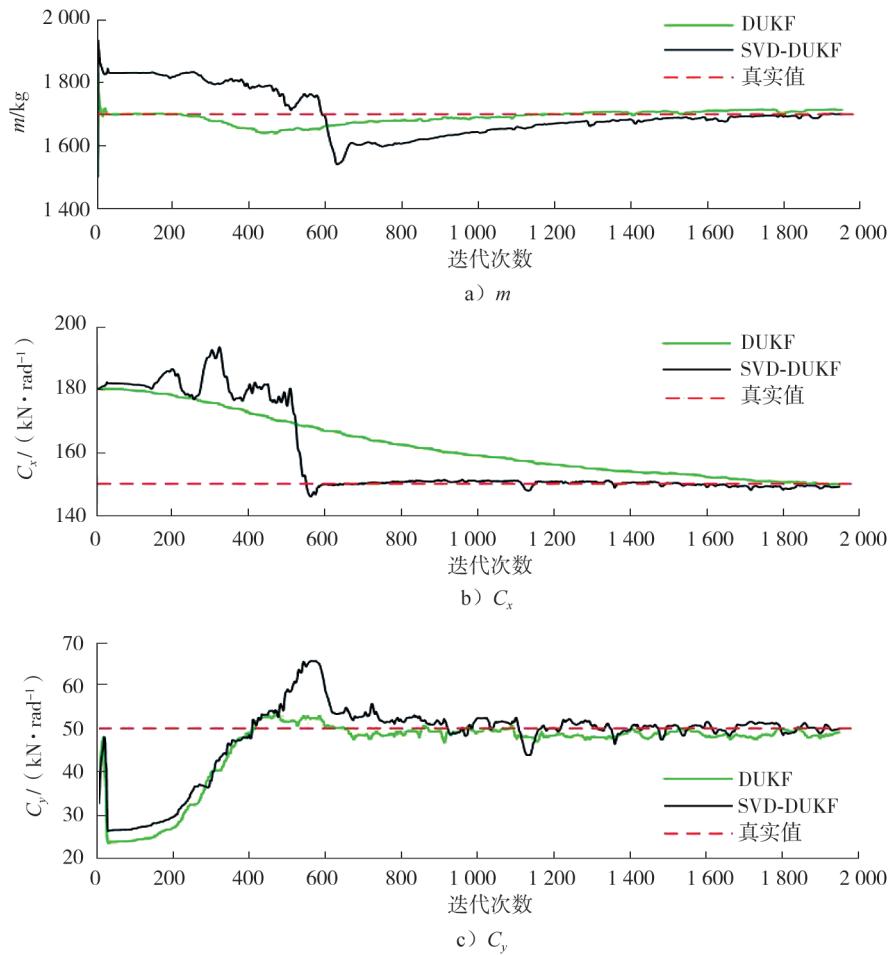


图5 不同算法下车辆参数估计结果

4 结论

基于车辆三自由度动力学模型,分别采用 UKF、DUKF、SVD-DUKF 3 种算法估计车辆运行状态及车辆参数,在同一工况下采用 MATLAB 仿真进行比较分析。UKF 算法估计车辆状态时需输入车身质量等参数,且随乘客及货物的改变,在车辆实际行驶过程中很难获取正确参数,难以单独在实车中应用算法; DUKF 算法通过 UT 变换获取 Sigma 采样点集时需进行 Cholesky 分解,此时需保证协方差为非负定矩阵,否则会导致估计结果不准确甚至发散;通过引入奇异值分解改进 DUKF 算法,在保证估计精度的同时,算法的适用范围更广,鲁棒性更强。

参考文献:

- [1] 章仁燮,熊璐,余卓平.智能汽车转向轮转角主动控制[J].机械工程学报,2017,53(14):106-113.
ZHANG Renxie, XIONG Lu, YU Zhuoping. Activesteering angle control for intelligent vehicle[J]. Journal of Mechanical Engineering, 2017, 53(14): 106-113.
- [2] 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[J]. Mechanical Systems and Signal Processing, 2018, 101:377-388.
- [3] 黄小平,王岩.卡尔曼滤波原理及应用:MATLAB 仿真[M].北京:电子工业出版社, 2015.
- [4] 张小龙,李亮,李红志,等.基于改进 RBF 网的汽车侧偏角估计方法试验研究[J].机械工程学报, 2010, 46(22):105-110.
ZHANG Xiaolong, LI Liang, LI Hongzhi, et al. Experimentalresearch on vehicle sideslip angle estimation based on improved RBF neural networks[J]. Journal of Mechanical Engineering, 2010, 46(22):105-110.
- [5] MELZI S, SABBIONI E. On the vehicle sideslip angle estimation through neural networks: numerical and experimental results[J]. Mechanical Systems and Signal Processing, 2011, 25(6):2005-2019.
- [6] CHWLI F, MELIZ S, SABBIONI E. An adaptive observer for sideslip angle estimation:comparison with experimental results [C]//Proceedings of the ASME 2007 International Design Engineering Technical Conferences and Computers and Information in Engineering Conference. Las Vegas, Nevada, USA:ASME, 2007:1193-1199.
- [7] 施树明, LUPKER H, BREMMER P, 等. 基于模糊逻辑的车辆侧偏角估计方法[J]. 汽车工程, 2005, 27(4):426-430.
SHI Shuming, LUPKER H, BREMMER P, et al. Estimation of vehicle side slip angle based on fuzzy logic[J]. Automotive Engineering, 2005, 27(4):426-430.
- [8] MANASINA R, MORREL K, KURT K, et al. Optimum design of a steer by wire system using systematic system engineering approach[J]. SAE International Journal of Passenger Cars-Electronic and Electrical Systems, 2008, 1(1):553-556.
- [9] REINA G, MESSINA A. Vehicle dynamics estimation via augmented extended Kalman filtering[J]. Measurement, 2019, 133:383-395.
- [10] 刘飞,熊璐,邬肖鹏,等.车辆质心侧偏角估计算法设计与对比分析[J].同济大学学报(自然科学版), 2015, 43(3):448-455.
LIU Fei, XIONG Lu, WU Xiaopeng, et al. Vehiclesideslip angle estimation and contrastive analysis[J]. Journal of Tongji University(Natural Science), 2015, 43(3):448-455.
- [11] 柴华溢.基于卡尔曼滤波的匀速直线运动目标跟踪研究[D].太原:山西师范大学, 2020.
CHAI Huayi. Research on tracking uniform linear moving target based on Kalman filter [D]. Taiyuan: Shanxi Normal University, 2020.
- [12] 胡敬宇,汪䶮,严永俊,等. 基于限定记忆随机加权扩展卡尔曼滤波的车辆状态估计[J]. 东南大学学报(自然科学版), 2022, 52(2):387-393.
HU Jingyu, WANG Yan, YAN Yongjun, et al. Vehicle state estimation based on limited memory random weighted extended Kalman filter[J]. Journal of Southeast University(Natural Science Edition), 2022, 52(2):387-393.
- [13] JAFARZADEH S, LASCU C, FADALI M S. Stateestimation of induction motor drives using the unscented Kalman filter

- [J]. IEEE Transactions on Industrial Electronics, 2012, 59(11):4207–4216.
- [14] 陈林, 施树明, 李远方. 车辆操纵稳定性状态估计算法比较研究[J]. 交通信息与安全, 2011, 29(5):36–40.
CHEN Lin, SHI Shuming, LI Yuanfang. Comparativestudy of some estimation algorithms for vehicle stability state [J]. Journal of Transport Information and Safety, 2011, 29(5):36–40.
- [15] 李敏, 王松艳, 张迎春, 等. 改进的强跟踪平方根 UKF 在卫星导航中应用[J]. 系统工程与电子技术, 2015, 37(8): 1858–1865.
LI Min, WANG Songyan, ZHANG Yingchun, et al. Satellite autonomous navigation filtering algorithm based on improved strong tracking square-root UKF [J]. Systems Engineering and Electronics, 2015, 37(8):1858–1865.
- [16] 冯亦奇, 陈勇. 基于遗忘因子的 UKF 车辆状态参数估计算法[J]. 合肥工业大学学报(自然科学版), 2020, 43(11): 1450–1455.
FENG Yiqi, CHEN Yong. Unscented Kalman filter for vehicle state parameter estimation based on forgetting factor [J]. Journal of Hefei University of Technology(Natural Science), 2020, 43(11):1450–1455.
- [17] 陈波. 一种改进的迭代无迹卡尔曼滤波算法[J]. 计算机应用与软件, 2019, 36(10):274–278.
CHEN Bo. Animproved iterated unscented Kalman filter algorithm [J]. Computer Applications and Software, 2019, 36(10):274–278.
- [18] 张凤娇, 魏民祥, 赵万忠. 基于蚁群优化 UKF 算法的汽车状态估计[J]. 中国机械工程, 2015, 26(22):3046–3050.
ZHANG Fengjiao, WEI Minxiang, ZHAO Wanzhong. Vehiclestate estimation based on ant colony optimization algorithm [J]. China Mechanical Engineering, 2015, 26(22):3046–3050.
- [19] 余志生. 汽车理论[M]. 6 版. 北京: 机械工业出版社, 2020.
- [20] WAN E A, MERWE R V D, NELSON A T. Dual estimation and the unscented transformation[C]//Proceedings of the 12th International Conference on Neural Information Processing Systems. Denver, Colorado, USA:NIPS, 1999:666–672.

Vehicle state estimation based on improved dual unscented Kalman filter

FEI Mingzhe¹, WANG Jian^{1}, YU Jinpeng², YANG Jun¹, DU Ruofei¹,
WANG Yunjing¹, DENG Huan¹*

1. School of Automotive Engineering, Shandong Jiaotong University, Jinan 250357, China

2. School of Automation, Qingdao University, Qingdao 266071, China

Abstract: Based on the 3-DOF dynamics model of the vehicle in MATLAB software, the unscented Kalman filter (UKF), the dual unscented Kalman filter (DUKF) and the improved dual unscented Kalman filter (SVD-DUKF) with singular value decomposition are used to estimate the state and parameters of the vehicle under the same operating conditions respectively. The results show that the UKF algorithm can achieve high estimation accuracy, but the premise is to input accurate parameters such as body mass at all times, which is difficult to reach during the operation of vehicle. The estimation accuracy of DUKF algorithm is similar to SVD-DUKF algorithm, but the former is difficult to guarantee that the error covariance matrix is a positive definite matrix during the operation of vehicle because it uses Cholesky decomposition. The latter with higher estimation accuracy and applicability is more suitable for estimating the driving state and parameters of a vehicle.

Keywords: state estimation; UKF algorithm; DUKF algorithm; singular value decomposition

(责任编辑:郭守真)