Proceeding of the 14th International Forum of Automotive Traffic Safety, 2017, pp 246-259 No.ATS.2017.312

States estimation of a distributed drive electric vehicle based on adaptive extended Kalman filter

Zhiyong ZHANG^{1,2}, Shuzhi ZHANG², Caixia HUANG³, Liuzhu ZHANG², Bohao LI²

¹Key Laboratory of Lightweight and Reliability Technology for Engineering Vehicle, Changsha 410114;
²College of Automobile and Mechanical Engineering, Changsha University of Science and Technology, Changsha 410114;
3.College of Mechanical and vehicle Engineering, Hunan university, Changsha 410082
Email: zzy04@163.com

Abstract: Using the characteristics of the torques and speeds of four wheels can measurement directly in a distributed drive electric vehicle, a three degree of freedom vehicle state estimation model is established to estimate the longitudinal velocity and the side angle of central gravity. With normalized innovation square, the validity of vehicle state estimation is detected and the sliding window length is adjusted adaptively. An adaptive adjustment strategy of the gain of Kalman filter and the covariance matrix of state estimation error are then proposed based on the statistical characteristics of innovation. The influence mechanism between the adaptive parameters and the steady-state error of vehicle state estimation and the dynamic of state response speed are analyzed. The numerical simulation and experiment are proved that the proposed algorithm of vehicle state estimation based on adaptive extended Kalman filter not only can improve the estimation accuracy, and possess strong robustness to the initial value of measurement noise covariance matrix. The deployment of estimation algorithm based on the MCU of SMT32F407 verify that the proposed algorithm is strong real-time and easy to implement.

Key words: Electric vehicle; States estimation; Extended Kalman filter; Distributed drive; Adaptive control

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*

张志勇 ^{1,2}, 张淑芝²,黄彩霞³,张刘铸²,李博浩² ¹工程车辆安全性设计与可靠性技术湖南省重点实验室 长沙 410114; ²长沙理工大学汽车与机械工程学院 长沙 410114; ³湖南大学机械与载运工程学院 长沙 410082 *Email: zzy04@163.com*

摘 要:利用分布式驱动电动汽车4个车轮转矩和转速可直接测量的特点,建立三自由度车辆状态估计模型,开 展纵向车速和质心侧偏角估计研究。基于归一化新息平方实现车辆状态估计有效性检测,提出了滑动窗口长度 自适应调整策略,进而根据新息统计特性提出了卡尔曼滤波增益和状态估计误差协方差矩阵的自适应调整策略, 分析了自适应参数对车辆状态估计的稳态误差和动态响应速度的影响机理。数值仿真和实验证明,本文提出的 车辆状态自适应扩展卡尔曼滤波估计算法,不仅能提高估计精度,而且对测量噪声协方差矩阵初值具有较强的 鲁棒性。基于 SMT32F407 单片机的估计算法部署,进一步验证所提出算法具有较强的实时性和易用性。

关键词: 电动汽车; 状态估计; 扩展卡尔曼滤波; 分布式驱动; 自适应控制

1 引言

车辆主动安全控制是避免严重安全事故发生的关键技术,而准确获取车辆状态信号是实现车辆主动安全控制的必要前提。由于部分车辆状态信号通常无法直接测量,或直接测量的成本过于昂贵,无法广泛应用于汽车工业,因*国家自然科学基金资助项目(51675057),湖南省教育厅资助科研项目(15B008, 16C0906)。

此车辆状态估计成为车辆主动安全控制领域的研究热点^[1-3]。在车辆状态信号中,纵向车速和质心侧偏角是车辆主动安全控制系统最常用的输入信号,也是经常需要估计的状态信号^[4-7]。

车辆状态估计算法以最小化易测量状态实测值与估计值之间的残差为目标,实现待估计状态的最优估计。常用的估计算法包括卡尔曼滤波算法、鲁棒观测器、滑模观测器及其他非线性观测器。其中,鲁棒观测器通常与主控制器,如车辆动力学控制器集成为基于观测器的鲁棒控制策略设计问题^[2-3]。虽然通过求解优化模型可一次性得到主控制器增益和观测器增益,但这种方法容易造成优化问题过于保守而导致无解。滑模观测器以易测量状态的实测值与估计值之间的误差作为滑模平面进行观测器的设计。在控制作用下,误差在滑模面上下穿插而容易产生抖振。另外,已有关于车辆状态估计的研究一般仅通过数值仿真验证其有效性,这些方法的实时性、易用性有待进一步的实验验证^[8]。

卡尔曼滤波方法,包括基于此发展的扩展卡尔曼滤波和无迹卡尔曼滤波是最常用的车辆估计方法^(47,9-11)。在该方法中,需要对反映估计模型不确定性的过程噪声,以及信号测量过程中的测量噪声进行噪声协方差矩阵估计。在 实际工程应用中,不仅估计模型的不确定性定量化有困难,而且测量噪声受外界因素影响较大,并非恒定不变。遗 憾的是,所述噪声协方差矩阵对状态估计精度影响非常大,该缺陷严重限制了卡尔曼滤波方法及发展方法的工程应 用。为此,学者提出了噪声协方差矩阵自适应调整机制,发展出了自适应卡尔曼滤波方法^[5,10-11]。通过对已有研究 成果的分析,笔者认为,在引入自适应调整机制条件下,确保估计方法的稳定性,避免估计发散的同时,如何进一 步提高估计精度是亟待解决的关键问题。

分布式驱动电动汽车具有结构紧凑、动力传动链短、控制响应快、车轮转矩分配灵活等优点,已成为电动汽车 的重要发展方向。分布式驱动电动汽车在不增加传感器的情况下,可通过驱动电机准确获得车轮转矩和转速,信息 的感知范围相对于传统车辆有较大程度的拓展,为车辆状态估计提供了更大应用空间⁽⁷⁾。本文提出一种新的自适应 扩展卡尔曼滤波方法。在其中,不仅改进了滑动窗口长度的自适应调整方法,而且提出了卡尔曼滤波增益和估计噪 声协方差矩阵的自适应调整方法。前者提高了算法的实时性和易用性,使得自适应估计方法更适合单片机实现;后 者使得提出的自适应方法,比传统的直接更新过程噪声协方差矩阵和测量噪声协方差矩阵的自适应方法更稳定,精 度更高。数值仿真和实验验证了本文所提出估计方法的优越性。

2 卡尔曼滤波器估计模型

2.1 三自由度车辆动力学模型

如图 1 所示的车辆动力学模型包括纵向、侧向、横摆三个自由度,用于描述易测量状态和待估计状态的内 在联系,并实现状态预测。三自由度车辆动力学模型的控制方程为:



Figure 1. 3-DOF vehicle dynamic model 图 1 三自由度车辆动力学模型

纵向动力学方程:

$$ma_{x} = \left(F_{xfl} + F_{xfr}\right)\cos\delta - \left(F_{yfl} + F_{yfr}\right)\sin\delta + F_{xrl} + F_{xrr}$$
(1)

横向动力学方程:

$$ma_{y} = (F_{xfl} + F_{xfr})\sin\delta + (F_{yfl} + F_{yfr})\cos\delta + F_{yrl} + F_{yrr}$$
(2)

横摆动力学方程:

$$M = \frac{t_{w}}{2} [(F_{xfl} - F_{xfr})\cos\delta + (F_{yfl} - F_{yfr})\sin\delta] + \frac{t_{w}}{2}(F_{xrl} - F_{xrr}) + a[-(F_{xfl} + F_{xfr})\sin\delta + (F_{yfl} + F_{yfr})\cos\delta] - b(F_{yrl} + F_{yrr})$$
(3)

质心侧偏角定义为:

$$\beta = \arctan\left(v_y / v_x\right) \approx v_y / v_x \tag{4}$$

式中: *m*为整车质量; a_x 为纵向加速度, $\exists a_x = \dot{v}_x - v_y \gamma$, 其中 v_x 为纵向速度; a_y 为侧向加速度, $\exists a_y = \dot{v}_y + v_x \gamma$, 其中 v_y 为侧向速度; γ 为横摆角速度; $F_{xij} \approx F_{yij} \beta$ 别为轮胎纵向力和侧向力, 其中i = f, r, 分别表示前和后。 $j = l, r \beta$ 别表示左和右; I_z 为整车绕 z 轴的转动惯量; $a \approx b \beta$ 别为质心到前、后轴的距离; t_w 为轮距; δ 为前轮转角。

2.2 轮胎力计算模型

由三自由度车辆动力学模型可知,进行车辆状态预测时,需要已知轮胎的纵向力和侧向力。分布式驱动电动汽车的4个车轮直接由电机驱动,转矩和转速容易测量,因此可利用车轮动力学模型计算轮胎纵向力。车轮动力学模型为:

$$J_w \dot{\omega}_{ij} = T_{ij} - R_w F_{xij} \tag{5}$$

式中: R_w 为轮胎滚动半径; J_w 为轮胎转动惯量; ω_{ij} 为车轮旋转角速度; T_{ij} 为电机转矩, 驱动为正, 制动为负, 计算方法如下:

$$T_{ij} = K_T I_{ij} \tag{6}$$

式中: K_T为电机转矩常数; I_{ii}为电机线电流。

在已知车轮转矩和旋转角速度的前提下,轮胎纵向力可表示为:

$$F_{xij} = \left(T_{ij} - J_w \dot{\omega}_{ij}\right) / R_w \tag{7}$$

轮胎的侧向力可通过下式计算:

$$F_{yij} = C_{\alpha j} \alpha_{ij} \tag{8}$$

式中: $C_{\alpha i}$ 为轮胎侧偏刚度; α_{ii} 为轮胎侧偏角,计算方法如下^[2]:

$$\alpha_{lf} = \delta - \arctan\left(\frac{v_y + a\gamma}{v_x + (t_w/2)\gamma}\right)$$
(9)

$$\alpha_{rf} = \delta - \arctan\left(\frac{v_y + a\gamma}{v_x - (t_w/2)\gamma}\right)$$
(10)

$$\alpha_{lr} = \arctan\left(\frac{-v_y + b\gamma}{v_x + (t_w/2)\gamma}\right)$$
(11)

$$\alpha_{rr} = \arctan\left(\frac{-v_y + b\gamma}{v_x - (t_w/2)\gamma}\right)$$
(12)

由此可见,要计算轮胎侧向力,首先要进行轮胎侧偏刚度的估计。另一方面,二自由度车辆动力学模型可表示为:

$$ma_{v} = F_{vf} + F_{vr} \tag{13}$$

$$I_z \dot{\gamma} = a F_{yf} - b F_{yr} \tag{14}$$

式中: F_{vf} 和 F_{vr} 分别为前、后轴的轮胎侧向力。

由式(13)和式(14)可得到前、后轴的侧向力为:

$$F_{vf} = \left(bma_v + I_z\dot{\gamma}\right) / \left(a + b\right) \tag{15}$$

$$F_{yr} = \left(ama_{y} - I_{z}\dot{\gamma}\right) / \left(a + b\right)$$
(16)

而前、后轴的侧向力也可表示为[2]:

$$F_{yf} = 2C_{\alpha f} \left(\delta - \beta - a\gamma / v_x \right) \tag{17}$$

$$F_{yr} = 2C_{\alpha r} \left(-\beta + b\gamma / v_x \right) \tag{18}$$

由(15)-(18)可得前、后轴轮胎的侧偏刚度为:

$$C_{\alpha f} = \frac{\left(bma_{y} + I_{z}\dot{\gamma}\right)v_{x}}{2(a+b)\left(\delta v_{x} - v_{y} - a\gamma\right)}$$
(19)

$$C_{\alpha r} = \frac{\left(ama_{y} - I_{z}\dot{\gamma}\right)v_{x}}{2\left(a+b\right)\left(b\gamma - v_{y}\right)}$$
(20)

综上所述,轮胎力计算模型利用电机转矩、车轮角加速度计算轮胎纵向力;利用当前的车辆状态信号,如纵向 车速、侧向速度、侧向加速度、横摆角速度等信号实时估计前、后轴轮胎的侧偏刚度,进而计算出轮胎的侧向力。

3 自适应扩展卡尔曼滤波 3.1 扩展卡尔曼滤波算法

针对三自由度车辆动力学模型,定义状态变量为:

$$x = \left(v_x, v_y, \gamma, a_x, a_y\right)^{\mathrm{T}}$$
(21)

在状态变量中,车辆横摆角速度、纵向加速度和侧向加速度属于易测量状态,纵向速度和侧向速度属于待估计 状态,质心侧偏角由两者根据式(4)计算。定义测量变量为:

$$z = \left(\gamma, a_x, a_y\right)^{\mathrm{T}} \tag{22}$$

系统输入为:

$$u = \left(\delta, F_x, F_y\right)^{\mathrm{T}}$$
(23)

式中: $F_x 和 F_y 分别为4 个轮胎的纵向力、侧向力。$

经离散后,三自由度车辆动力学模型可写成如下形式:

$$\begin{cases} x_{k} = f(x_{k-1}, u_{k}) + w_{k-1} \\ z_{k} = h(x_{k-1}, u_{k}) + \varepsilon_{k-1} \end{cases}$$
(24)

式中: f 为状态转移函数; h 为测量函数; w_k 为系统过程噪声,是均值为零,协方差为Q 的高斯白噪声; ε_k 为测 量噪声,是均值为零,协方差为 \mathbf{R} 的高斯白噪声。

标准扩展卡尔曼滤波算法计算步骤如下:

1) 状态预测:

$$\overline{x_k} = f\left(x_{k-1}, u_k\right) \tag{25}$$

2) 误差协方差预测

$$P_k^- = \Phi_k P_{k-1} \Phi_k^{\mathrm{T}} + Q_k \tag{26}$$

其中:

$$=I+T_{\rm s}F\tag{27}$$

式中: I 为合适维数的单位矩阵; T_s 为采样时间; F 为状态转移函数的雅克比矩阵,通过求状态转移函数关

 Φ_{i}

INFATS Conference in Changsha, December 1-3, 2017

于自变量的偏导数得到,即 $F=\partial f / \partial x$ 。

3) 计算卡尔曼滤波增益:

$$K_{k} = P_{k}^{-} H_{k}^{\mathrm{T}} \left(H_{k} P_{k}^{-} H_{k}^{\mathrm{T}} + R_{k} \right)^{-1}$$
(28)

4) 更新状态变量,即计算状态变量估计值:

$$x_{k} = x_{k}^{-} + K_{k} \left(y_{k} - h \left(x_{k}^{-}, u_{k} \right) \right)$$
(29)

5) 更新状态估计误差协方差矩阵:

$$P_k = \left(I - K_k H_k\right) P_k^- \tag{30}$$

3.2 噪声协方差矩阵自适应调整策略

卡尔曼滤波算法基于递推最小方差估计原理,对线性系统的状态进行最优估计,而扩展卡尔曼滤波算法将该功能推广到了非线性系统。由于扩展卡尔曼滤波算法通过一阶泰勒展开式进行模型的线性化,较大的建模误差使得该方法只适用于弱非线性系统,对于强非线性系统该方法估计误差较大,甚至导致滤波发散[6]。注意到,建模误差是估计模型的过程噪声重要组成部分,如果能根据新息对过程噪声的协方差矩阵进行自适应调整,可以减小估计误差和滤波发散的可能性。新息受到建模误差和初始条件的影响,因此可以根据新息进行噪声协方差矩阵的估计。新息定义为测量变量的实际值与预测值之间的误差,即:

$$v_k = z_k - H_k x_k^- \tag{31}$$

式中: H_k 为测量方程的雅克比矩阵,通过求测量函数关于自变量的偏导数得到,即 $H_k = \partial h / \partial x$; x_k^- 为状态预测值。

新息的理论协方差矩阵为:

$$C_k = E[\nu_k v_k^{\mathrm{T}}] = H_k P_k H_k^{\mathrm{T}} + R_k$$
(32)

由于受到建模误差和测量噪声的影响,新息协方差矩阵实际值往往偏离理论值。一般通过下式计算新息的实际 协方差矩阵。

$$\hat{C}_{k} = \frac{1}{M} \sum_{i=1}^{M} v_{k-i} v_{k-i}^{\mathrm{T}}$$
(33)

式中: M 为滑动窗口的长度。

通过比较新息的实际协方差矩阵 \hat{C}_k 和理论协方差矩阵 C_k 大小,实现对 R_k 的调整。当 $C_k > \hat{C}_k$ 时减小 R_k ;当 $C_k < \hat{C}_k$ 时,理论上应增加 R_k ,但为了避免滤波器发散,可保持 R_k 不变。定义的 R_k 调整因子为[12]:

$$\alpha_k = \max\left(1, \frac{trace(\hat{C}_k)}{trace(C_k)}\right)$$
(34)

相对于文献^[10-11]直接更新 Q 和 R 不同,本文提出的自适应协方差矩阵调整策略不更新 Q 和 R,只是在计算卡尔曼滤波增益和状态估计误差协方差矩阵时给出 Q 和 R 修正量。在更新卡尔曼滤波器增益时,自适应调整方法如下:

$$K_{k} = P_{k}^{-} H_{k}^{\mathrm{T}} \left(H_{k} P_{k}^{-} H_{k}^{\mathrm{T}} + \alpha_{k} R_{k} \right)^{-1}$$
(35)

为了提高卡尔曼滤波算法的估计精度,测量噪声协方差矩阵与过程噪声协方差矩阵一般作反向调整^[13]。因此状态估计误差协方差矩阵的自适应调整方法为:

$$P_k^{-} = \Phi_k P_{k-1} \Phi_k^{\mathrm{T}} + \kappa Q_{k-1} / \alpha_k$$
(36)

3.3 滑动窗口长度自适应调整策略

车辆在匀速直线或匀加速,以及匀速转弯行驶时,纵向车速和质心横摆侧偏角不变或变化缓慢;在高速急转弯, 或车辆发生严重侧滑的情况下,纵向车速,特别是质心侧偏角会发生突然变化。如果式(33)的滑动窗口长度采用固 定值计算新息的协方差矩阵 Ĉ_k,不能权衡稳态误差和动态响应两方面,因此如何选择合适的窗口长度是难点^[14]。 为此,本文提出如下的滑动窗口长度自适应调整策略,兼顾稳态误差和动态响应两方面。

$$\begin{cases}
M = M_{\min}, & d \ge \alpha_{\max} \\
M = M_{\max}, & d \le \alpha_{\min} \\
M = \operatorname{int}\left(\frac{(d - \alpha_{\min})(M_{\max} - M_{\min})}{\alpha_{\max} - \alpha_{\min}}\right) \\
+M_{\min}, & \alpha_{\min} < d < \alpha_{\max}
\end{cases}$$
(37)

式中: d 为调整因子; α_{max} 和 α_{min} 分别是设定的上、下阈值; M_{min} 和 M_{max} 分别为滑动窗口的最小值和最大值; int(·) 为取整函数。本文提出的滑动窗口长度自适应调整策略相较于文献[15]的调整策略而言,更适合在单片机中编程实现。如果第三条规则采用如同文献[15]的规则,即 $M = k \times \eta^{d-\mu_{max}}$,则需要保存每个计算步的新息数据。随着计算步数的增加,新息数据量也随之增加,对于内存空间有限的单片机而言显然不现实;另外,在第三条规则中,本文应用简单的滑动窗口长度线性扩展方法代替文献[15]的指数窗口,减小了计算量,有望提高实时性。滑动窗口长度自适应调整策略中的参数对估计精度的影响,后续将作详细阐述。



 Figure 2. Estimation process of adaptive extended Kalman filtering

 图 2 自适应扩展卡尔曼滤波估计流程

在滑动窗口长度自适应调整策略中,调整因子 d 需要正确反映车辆状态变量变化的快慢。在目标定位与跟踪的 相关研究中,常用归一化新息平方(Normalized Innovation Square, NIS)进行目标对象的机动检测^[16-17]。当目标对象发 生机动时,状态变量会发生较大改变,目标对象的定位或跟踪难度会增加,表现为定位或跟踪的误差增加,最终导 致新息及其归一化平方增大。如果此时通过调整系统噪声协方差矩阵的方法,实现滤波结果的实时修正,有望提高 定位或跟踪精度。由此可见,归一化新息平方实质上是估计器的有效性检验,判断当前的估计结果是否有效。本文 借鉴这一思想,当归一化新息平方大于某一阈值时,认为车辆发生了较大的状态改变,类似于目标对象的"机动", 进而可根据车辆状态改变快慢的程度自适应调整滑动窗口的长度。调整因子定义为归一化新息平方,即:

$$d = v_k^{\mathrm{T}} C_k^{-1} v_k \tag{38}$$

综上所述,本文提出的分布式驱动电动汽车状态的自适应扩展卡尔曼滤波估计方法如图 2 所示。在系统输入计 算模块中,根据驾驶员的方向盘转角输入,由车辆动力学模型得到前轮转角、四轮转矩和四轮转速,再经轮胎力估 计模型计算得到 4 个车轮的纵向力和横向力。与此同时,车辆动力学模型输出横摆角速度、纵向加速度和横向加速 度 3 个测量变量。车辆状态估计过程中采用式(37)实现滑动窗口长度自适应调整,进而通过式(34)计算协方差矩阵 自适应调整因子,实现卡尔曼滤波增益和状态估计协方差矩阵的自适应调整。

4 估计精度与参数影响分析

为了验证本文提出的自适应扩展卡尔曼滤波方法在分布式驱动电动汽车状态估计方面的效果,基于 CarSim 和 Matlab/ Simulink 进行车辆动力学的联合仿真,分析纵向车速和质心侧偏角的估计精度。数值仿真时,方向盘转角 为双鱼钩阶跃输入,前轮转角如图 3 所示。车辆参数如下:m=1230kg, a=1.15m, b=1.36m, $t_w=1.5m$, $I_z=4607$ kg m²。另外,车速为 80km/h,路面附着系数 μ 为 0.85, Ts=0.01, $\kappa=100$, $\alpha_{min}=2$, $\alpha_{max}=10$, Mmin=1, Mmax=100。



图 3 前轮转角

为体现本文提出的自适应扩展卡尔曼滤波方法(PAEKF)的优越性,同时进行改进 Sage-Husa 自适应扩展卡尔曼 滤波方法(SHAEKF)[8]和标准扩展卡尔曼滤波方法(EKF)的车辆状态估计仿真,并将三者进行对比分析。在分析过 程中,以 CarSim 输出的车辆状态作为真实值。

4.1 估计精度分析

设定状态估计误差协方差矩阵的初值为 P_0 =eye(5)×1,过程噪声协方差矩阵的初值 Q_0 =eye(3)×0.01。图 4 的左 右图分别为测量噪声协方差矩阵初值 R_0 =eye(5)×0.01 时,纵向车速和质心侧偏角估计精度对比。由图可知,三种 方法中,PAEKF 的状态估计值最接近真实值,且 EKF 比 SHAEKF 的估计精度高。但总体而言,三种方法对于纵 向车速和质心侧偏角的估计精度处于相同水平,可认为此时的测量噪声协方差矩阵的初值非常接近真实的统计特 性。





当 *R*₀ =eye(5)×2 时,三种方法对纵向车速和质心侧偏角的估计精度对比如图 5 的左右两图所示。由图可知,测量噪声协方差矩阵初值偏离真实值时,EKF 对纵向车速和质心侧偏角的估计精度高明显下降,已严重偏离真实值。而 SHAEKF 通过自适应策略保证其具有较好的估计精度。但相比 PAEKF 方法,SHAEKF 的估计精度仍具有差距,特别是质心侧偏角在 27 秒后存在较大的稳态误差。



Figure 5. Comparison of state estimation $(R_0=eye(3)\times 2)$

图 5 状态估计对比 (R₀=eye(3)×2)

表1为估计误差的定量分析结果。评价的指标是估计误差的均方根值,定义为:

$$e_{\rm RMS} = \sqrt{\frac{1}{k} \sum_{i=1}^{k} (y_i - \hat{y}_i)^2}$$
(39)

式中: ^yi和^ŷi分析信号的真实值和估计值。

Table 1. State estimation errors 表 1. 状态估计误差分析

	_	R的初值	
		eye(3)×0.01	$eye(3) \times 2$
	EKF	0.020	0.801
纵向车速	SHAEKF	0.091	0.276
	PAEKF	0.015	0.050
质心侧偏角	EKF	0.002	0.081
	SHAEKF	0.005	0.012
	PAEKF	0.001	0.003

由表 1 可知,当测量噪声协方差矩阵初值为 R_0 =eye(3)×0.01 时,对纵向车速的估计,PAEKF的估计精度分别 比 EKF 和 SHAEKF 提高了 25% 和 84%;对质心侧偏角的估计,PAEKF 的估计精度分别比 EKF 和 SHAEKF 提高 了 50% 和 80%。当测量噪声协方差矩阵初值设置 R_0 =eye(3)×2 时,对纵向车速的估计,PAEKF 的估计精度分别比

EKF 和 SHAEKF 提高了 94% 和 82%;对质心侧偏角的估计,PAEKF 的估计精度分别比 EKF 和 SHAEKF 提高了 93% 和 75%。综上所述,本文提出的 PAEKF 在估计精度方面具有非常明显的优势。对比 EKF 在两种初值条件下的 车辆状态估计误差均方根值,当测量噪声偏离真实统计特性时,估计误差增加到原来的 40 倍,估计精度严重恶化。 说明 EKF 对测量噪声协方差矩阵初值非常敏感,这也是造成 EKF 在实际应用中很难保证估计精度的原因。

4.2 窗口调整因子阈值对窗口长度的影响

在本文所提出的滑动窗口长度自适应调整策略中,以归一化新息平方作为判断车辆是否发生"机动"的依据, 设定的上、下阈值影响车辆进入"机动"和退出"机动"的时机,从而影响滑动窗口长度自适应调整时刻。图 6 为 车辆做单个鱼钩阶跃转向时的归一化新息平方。对比前轮转角曲线可发现,在前轮转角发生变化的 1~7 秒之间,归 一化新息平方都比较大,特别是在前轮转角变化最激烈的 1 秒和 2.2 秒处,归一化新息平方出现了两个非常大的波 峰。由此可见,用归一化新息平方进行目标对象的机动检测切实可行。本文设定 *a*_{min} = 2,即认为归一化新息平方 小于 2 时,认为车辆状态未发生激烈变化,处于非"机动"的稳定行驶状态,调整滑动窗口长度为最大值,以便减 小估计稳态误差;设定 *a*_{max} =10,即当归一化新息平方大于 10 时,认为车辆状态发生激烈变化而处于"机动"状 态,调整滑动窗口长度为最小值,提高估计器的快速跟踪性;在归一化新息平方大于 2 而小于 10 的区间,滑动窗 口长度在最小值到最大值之间按比例进行线性扩展。由此可见,本文提出的滑动窗口长度自适应调整策略仅需保存 M_{max}个新息数据,有利于单片机实现估计算法。</sub>



图 7 为所提出自适应扩展卡尔曼滤波方法,在 R₀ =eye(3)×0.01, M_{min}=1, M_{max}=100 条件下,进行车辆状态估 计时的滑动窗口长度变化情况。由图可知,在前轮转角为 0 的 0~1 秒,以及 6.6~10 之间,滑动窗口的长度保持在 100,自适应策略通过增加滑动窗口长度来提高估计算法的稳态精度;在 1~2.6 秒之间,方向盘转角发生较快速变 化,滑动窗口发生震荡,但仍可看出长度为 1 的情况占绝对多数。说明在车辆状态激烈变化时,自适应策略通过减 小滑动窗口长度来提高估计算法的动态响应速度;在 2.6~6.6 秒之间,方向盘转角变化较缓慢,滑动窗口长度在最 大值和最小值之间平滑过渡。

4.3 滑动窗口长度极值对估计精度的影响

为了分析最小滑动窗口长度 M_{min} 和最大滑动窗口长度 M_{max} 对估计精度的影响,在 R₀ =eye(3)×2 时,分别改变 M_{min} 和 M_{max} 的情况下,分析 PAEKF 的估计精度。图 8 为 M_{max}=100, M_{min}=1、5、10、15 时的车辆状态估计值与 真实值的对比。由图可知,随着最小滑动窗口长度 Mmin 的增加, PAEKF 估计的动态跟踪速度降低,状态变量突 变处的估计精度降低明显。因此,设置较小的最小滑动窗口长度,相当于利用最新的新息调整噪声的协方差矩阵, 有利于提高状态估计的动态响应速度。



Figure 8. The influence of M_{\min} on estimation accuracy 图 8 M_{\min} 对估计精度的影响

由式(37)描述的窗口长度自适应调整规则可知,当归一化新息平方较小时,即车辆行驶状态稳定的情况下,窗



Figure 9. Influence of M_{max} on estimation accuracy 图 9 M_{max} 对估计精度的影响

口长度调整为最大滑动窗口长度 M_{max},因此最大滑动窗口长度 M_{max} 主要影响的是状态估计的稳态误差。图 9 为 M_{min}=1, M_{max}=50、100、150、200 时的车辆状态估计值与真实值的对比。由图可知,增加最大滑动窗口长度 M_{max} 有利于增加车辆非"机动"状态时的估计精度。

5 实验验证

为了进一步验证所提出车辆状态估计算法的优越性,本文开展了实验验证研究。实验用车为课题组开发的"云

INFATS Conference in Changsha, December 1-3, 2017

影一号"四轮毂电机独立驱动电动汽车,如图 10 所示。实验过程中,利用方向盘力角测量仪采集方向盘的转角信号,如图 11(a)所示;利用课题组开发的实验程序实现 STM32F407 单片机对六轴传感器 MPU6050 的信号采集,获得车辆纵向加速度、侧向加速度、横摆角速度信号,如图 11(b)所示。与此同时,利用 STM32F407 单片机对 4 个轮毂电机霍尔传感器的脉冲信号进行测频,获得 4 个车轮的转速信号;采集控制器电池端的电流传感器,获得 4 个轮毂电机的线电流,如图 11(c)所示。

作为检验估计精度的对标信号,通过姿态方位组合导航系统产生,如图 11(d)所示。该系统基于多传感器数据 融合技术将卫星定位与惯性测量相结合,实现车速、横摆角等车辆状态及车辆行驶轨迹的准确测量。但由于该类型 仪器价格昂贵,且受到 GPS 卫星信号的限制,暂不适合作为控制器传感器在普通汽车上广泛使用。本文开展的实 验场地处于开阔的地带,系统能连接到足够的卫星数量,确保测量精度较高。



Figure 10. Experimental vehicle 图 10 实验用车



(c) 轮毂电机电流传感器

(d) 姿态方位组合导航系统

Figure 11. Signal acquisition system 图 11 信号采集系统

根据本文所提出车辆状态自适应扩展卡尔曼滤波估计算法,估计器的输入信号包括方向盘转角、4个轮毂电机的线电流、4个车轮的转速、车辆纵向加速度、车辆侧向加速度,以及车身横摆角速度。通过实验,采集的估计器输入信号如图12所示。



Figure 12. Input signals of vehicle state estimation algorithm 图 12 车辆状态估计算法的输入信号

采用离线方式进行车辆状态估计,即利用已采集的输入信号,通过估计器计算待估计的车辆状态。其中,估计 器通过 STM32F407 运行本文提出的车辆状态估自适应扩展卡尔曼滤波算法实现。在实验中,利用姿态方位组合导 航系统检测到的车辆东向车速和北向车速求出车辆的前进车速。要得到车辆纵向车速和横向车速,必须先求出车辆 质心侧偏角,计算方法如下:

$$\beta = \varphi - \psi \tag{40}$$

式中: φ 为车辆航向角,定义为车辆速度方向与正北方向的夹角,即 $\varphi = \operatorname{atan}(V_E/V_N)$,其中 V_E 为车辆东向车速, V_N 为车辆北向车速; ψ 为车辆的横摆角,定义为车辆纵轴与正北方向之间的夹角。需要说明的是,纵向车速和质心侧偏角由姿态方位组合导航系统检测的信号直接计算得到,本文定义为车辆状态的实测值。

自适应扩展卡尔曼滤波算法估计的车辆状态为车辆的纵向车速和侧向车速,但可以根据这两个车速计算车辆的车速,以及根据式(4)计算车辆的质心侧偏角。车辆状态估计值与实测值对比如图 13 所示,其中估计值 1、估计值 2 和估计值 3 分别表示测量噪声协方差矩阵初值为 R₀ =eye(3)×0.01、R₀ =eye(3)×2 和 R₀ =eye(3)×4 的情况。



· 图 13 状态量估计值与实测值对比

自适应扩展卡尔曼滤波算法估计的车辆状态为车辆的纵向车速和侧向车速,但可以根据这两个车速计算车辆的

车速,以及根据式(4)计算车辆的质心侧偏角。车辆状态估计值与实测值对比如图 13 所示,其中估计值 1、估计值 2 和估计值 3 分别表示测量噪声协方差矩阵初值为 R_0 =eye(3)×0.01、 R_0 =eye(3)×2 和 R_0 =eye(3)×4 的情况。

由图可知, 在测量噪声协方差矩阵取值范围较大的情况下,估计值都能准确跟踪实测值,说明本文提出的估计 算法不仅估计精度高,而且鲁棒性也较强。纵向车速和质心侧偏角的估计误差均方根值,如表 2 所示。对比 3 种测 量噪声协方差矩阵初值条件下的估计误差均方根值,估计精度始终处于相近水平,进一步验证了本文提出估计算法 的鲁棒性。

Table 2. State estimation errors 表 2. 状态估计的误差估计

	R 的初值		
	eye(3)×0.01	$eye(3) \times 2$	eye(3)×4
纵向车速	0.421	0.407	0.412
质心侧偏角	0.107	0.094	0.097

为了准确获取自适应扩展卡尔曼滤波算法的计算负荷,在算法开始处首先启动定时器,然后在算法结束处停止 定时器,最后根据定时器中断次数和计数器当前值计算出算法每次的运行时间。图 14 为算法其中 100 次的计算负 荷。由图可知,算法计算负荷与窗口长度直接相关,当窗口长度最小时,算法运行时间也最短;当窗口长度最大时, 算法运行时间也最大;最小窗口长度到最大窗口长度的过渡区间,运行时间与窗口长度呈线性关系。通过数据查看 可知,当 M=1 时,估计算法运行一次的时间为 190±2 μs; M=100 时,估计算法运行一次的时间为 625±5 μs。后者 需要更长的时间,是因为 M=100 时,需要循环计算新息的平方和 100 次。从估计算法的整体计算负荷来看,都没 有超过 1ms,完全满足计算步长 0.01s 的要求,即满足实时性要求。且能够通过单片机简单编程实现本文提出的估 计算法,说明满足易用要求。



6 结论

本文提出了一种新的车辆状态自适应扩展卡尔曼滤波估计算法,并通过数值仿真和实验进行了优越性验证,得 出的结论如下:

(1) 提出的卡尔曼滤波增益和估计噪声协方差矩阵自适应调整策略,能确保车辆状态估计的稳定性,避免估计 发散。

(2) 基于新息的滑动窗口长度自适应调整策略,在车辆非"机动"时采用最大窗口长度,能减小状态估计的稳态误差;在"机动"时,采用最小窗口长度,能提高状态估计的动态响应速度。

(3) 基于 STM32F407 的自适应扩展卡尔曼滤波车辆状态估计算法实现,证明算法的实时性和易用性得到了保证。

(4) 数值仿真和实验的结果证明,本文提出的自适应扩展卡尔曼滤波不仅能提高车辆状态估计精度,而且对测

量噪声协方差矩阵初值具有较强的鲁棒性。

参考文献 (References)

- ZHANG Renxie, XIONG Lu, YU Zhuoping. Active steering angle control for intelligent vehicle[J]. Journal of Mechanical Engineering, 2017, 53(14): 106-113.
- 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.
- [2] ZHANG Z, ZHANG N, HUANG C, et al. Observer-based H∞ control for vehicle handling and stability subject to parameter uncertainties[J]. Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering, 2013, 227(9): 704-717.
- [3] DAHMANI H, PAGÈS O, El HAJJAJI A EI. Observer-based state feedback control for vehicle chassis stability in critical situations[J]. IEEE Transactions on Control Systems Technology, 2016, 24(2): 636-643.
- [4] SONG C, XIAO F, LIU S. State estimation of electric vehicle with in-wheel motors based on UKF[J]. Journal of Jiling University(Engineering and Technology Edition), 2016, 46(2): 333-339.
 - 宋传学,肖峰,刘思含,等.基于无迹卡尔曼滤波的轮毂电机驱动车辆状态观测[J].吉林大学学报(工学版),2016,46(2):333-339.
- [5] LI Gang, ZHAO Deyang, XIE Ruichun, et al. Vehicle state estimation based on improved Sage-Husa adaptive extended Kalman filtering[J]. Automotive Engineering, 2015, 37(12): 1426-1432.
- 李刚,赵德阳,解瑞春,等.基于改进的 Sage-Husa 自适应扩展卡尔曼滤波的车辆状态估计[J]. 汽车工程, 2015, 37(12): 1426-1432.
- [6] ZHAO Zhiguo, ZHU Qiang, ZHOU Liangjie, et al. Vehicle speed estimation in driving case based on distributed self-adaptive unscented Kalman filter for 4WD hybrid electric car[J]. Scientia Sinica Technologica, 2016, 46(5): 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[J]. 中国科学: 技术科学, 2016, 46(5): 481-492. [7] CHU Wenbo, LUO Yugong, CHEN Long. Vehicle state estimation by unscented particle filter in distributed electric vehicle[J]. Journal of Mechanical Engineering, 2013, 49(24): 117-127.
- 褚文博, 罗禹贡, 陈龙, 等. 分布式电驱动车辆的无味粒子滤波状态参数联合观测[J]. 机械工程学报, 2013, 49(24): 117-127.
- [8] YU Zhuoping, GAO Xiaojie. Review of vehicle state estimation problem under driving situation[J]. Journal of Mechanical Engineering, 2009, 45(5): 20-33.
- 余卓平, 高晓杰. 车辆行驶过程中的状态估计问题综述[J]. 机械工程学报, 2009, 45(5): 20-33.
- [9] WANG Z, DONG M, QIN Y, et al. Suspension system state estimation using adaptive Kalman filtering based on road classification[J]. Vehicle System Dynamics, 2017, 55(3): 371-398.
- [10] MOHAMED A H, SCHWARZ K P. Adaptive Kalman filtering for INS/GPS[J]. Journal of geodesy, 1999, 73(4): 193-203.
- [11] XIONG R, GONG X, MI C C, et al. A robust state-of-charge estimator for multiple types of lithium-ion batteries using adaptive extended Kalman filter[J]. Journal of Power Sources, 2013, 243: 805-816.
- [12] KIM K H, LEE J G, PARK C G. Adaptive two-stage extended Kalman filter for a fault-tolerant INS-GPSloosely coupled system[J]. IEEE Transactions on Aerospace and Electronic Systems, 2009, 45(1): 125-137.
- [13] WANG X, YOU Z, ZHAO K. Inertial/celestial-based fuzzy adaptive unscented Kalman filter with Covariance Intersection algorithm for satellite attitude determination[J]. Aerospace Science and Technology, 2016, 48: 214-222.
- [14] JIANG J, ZHANG Y. A novel variable-length sliding window blockwise least-squares algorithm for on-line estimation of time-varying parameters[J]. International journal of adaptive control and signal processing, 2004, 18(6): 505-521.
- [15] HAO Y, GUO Z, SUN F, et al. Adaptive extended Kalman filtering for SINS/GPS integrated navigation systems[C]// IEEE International Joint Conference on Computational Sciences and Optimization, 2009.
- [16] MAKSAROV D, DURRANT-WHYTE H. Mobile vehicle navigation in unknown environments: a multiple hypothesis approach[J]. IEE Proceedings-Control Theory and Applications, 1995, 142(4): 385-400.
- [17] CALISKAN F, AYKAN R, HAJIYEV C. Aircraft icing detection, identification, and reconfigurable control based on Kalman filtering and neural networks[J]. Journal of Aerospace Engineering, 2008, 21(2): 51-60.