DOI: 10.3901/JME.2019.06.156

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. 湖南大学机械与运载工程学院 长沙 410082)

摘要: 纵向车速和质心侧偏角是车辆主动安全控制系统的关键参考状态信号, 通常采用卡尔曼滤波算法估计。当系统噪声和测量噪声的统计特性存在不确定性时, 不仅估计精度会降低, 甚至导致估计器发散。结合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, 提出一种车辆状态自适应扩展卡尔曼滤波估计方法。基于量纲一化新息平方实现车辆状态估计有效性检测, 提出滑动窗口长度自适应调整规则; 根据新息统计特性提出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, 及基于车辆状态估计稳态误差和动态响应速度的自适应参数确定原则。数值仿真和试验证明, 所提出的车辆状态估计方法, 不仅估计精度较高, 而且实时性和易用性较强。

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

中图分类号: U461

State Estimation of Distributed Drive Electric Vehicle Based on Adaptive Extended Kalman Filter

ZHANG Zhiyong^{1,2} ZHANG Shuzhi² HUANG Caixia³ ZHANG Liuzhu² LI Bohao²

(1. Key Laboratory of Lightweight and Reliability Technology for Engineering Vehicle, Changsha 410114;

2. College of Automobile and Mechanical Engineering,

Changsha University of Science and Technology, Changsha 410114;

3. College of Mechanical and vehicle Engineering, Hunan university, Changsha 410082)

Abstract: Longitudinal velocity and sideslip angle are the key referent state signals for vehicle active safety control system, and are usually estimated by Kalman filtering algorithm. The uncertainties of the statistical characteristics of system noise and measurement noise may cause filter to deviate or even diverge. Using the characteristics of the torques and speeds of four wheels can measurement directly in a distributed drive electric vehicle, an adaptive extended Kalman filtering method for vehicle state estimation is proposed. With normalized innovation square, the validity of vehicle state estimation is detected, and an adaptive adjustment rule of sliding window length is designed. An adaptive adjustment strategy of the gain of Kalman filter and the covariance matrix of state estimation error are proposed based on the statistical characteristics of innovation. The determination principle of adaptive parameters based on the steady-state error of vehicle state estimation and the dynamic response speed is determined. The numerical simulation and experiment can prove that the proposed algorithm of vehicle state estimation not only can improve estimation accuracy, but also has advantages of high real-time and easy to implement.

Key words: electric vehicle; states estimation; extended Kalman filter; distributed drive; adaptive control

0 前言

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

* 国家自然科学基金(51675057)和湖南省教育厅(15B008, 16C0906)资助项目。20180318 收到初稿, 20181009 收到修改稿

系统最常用的参考输入信号，也是经常需要估计的状态信号。

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。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量化有困难，而且测量噪声受外界因素影响较大，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。例如李刚等^[4]在 Sage-Husa 自适应扩展卡尔曼滤波算法的基础上，通过改进自适应规则提高了估计精度；沈法鹏等^[5]利用粒子滤波算法具有解决非线性非高斯问题的能力，结合迭代扩展卡尔曼算法进行车辆状态估计，获得了较高的估计精度；BOADA 等^[6]先借助自适应神经模糊推理系统估计侧偏角，再将此估计值作为无迹卡尔曼滤波器的测量变量，通过最小化估计均方误差的方差获得精确的侧偏角。

由于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，为车辆状态的精确估计提供了基础。为此，赵治国等^[7]基于自适应无迹卡尔曼算法，通过“加速度积分-转矩矫正”实现了车轮的轮心速度估计。CHEN 等^[8]首先利用电驱动车轮动力学模型和自适应高阶滑模估计器对轮胎纵向力进行估计，然后通过第二级滤波器实现对车辆状态的估计。同时，也可以利用车轮转矩与车辆状态之间的关系，反过来对电机进行故障诊断^[9]。通过对已有研究成果的分析，如何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，提高估计精度是亟待解决的关键问题。另一方面，从工程应用的角度出发，如何提高估计算法的实时性、易用性同样至关重要^[10]。

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规则，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。数值仿真和试验验证了本文所提出估计方法的优越性。

1 卡尔曼滤波器估计模型

1.1 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如下。

图 1 三自由度车辆动力学模型

纵向动力学方程

$$ma_x = (F_{xfl} + F_{xfr})\cos\delta - (F_{yfl} + F_{yfr})\sin\delta + F_{xrl} + F_{xrr} \quad (1)$$

横向动力学方程

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

横摆动力学方程

$$I_z\dot{\gamma} = \frac{t_w}{2}[(F_{xfl} - F_{xfr})\cos\delta + (F_{yfl} - F_{yfr})\sin\delta] + \frac{t_w}{2}(F_{xrl} - F_{xrr}) + a[-(F_{xfl} + F_{xfr})\sin\delta + (F_{yfl} + F_{yfr})\cos\delta] - b(F_{yrl} + F_{yrr}) \quad (3)$$

质心侧偏角定义为

$$\beta = \arctan(v_y / v_x) \approx v_y / v_x \quad (4)$$

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

1.2 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。对于集中式驱动车辆, 一般需要通过轮胎模型计算轮胎力^[4-5], 不仅会引入建模误差, 而且还会增加估计算法的计算负荷。由于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

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

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

$$T_{ij} = K_T I_{ij} \quad (6)$$

式中, K_T 为电机转矩常数; I_{ij} 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

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

轮胎的侧向力可通过式(8)计算

$$F_{yij} = C_{\alpha_j} \alpha_{ij} \quad (8)$$

式中, C_{α_j} 为轮胎侧偏刚度; α_{ij} 为轮胎侧偏角, 计算方法如下

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

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

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

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

另一方面, 二自由度车辆动力学模型为

$$ma_y = F_{yf} + F_{yr} \quad (13)$$

$$I_z \dot{\gamma} = aF_{yf} - bF_{yr} \quad (14)$$

式中, F_{yf} 和 F_{yr} 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

$$F_{yf} = (bma_y + I_z \dot{\gamma}) / (a + b) \quad (15)$$

$$F_{yr} = (ama_y - I_z \dot{\gamma}) / (a + b) \quad (16)$$

而前、后轴的侧向力也可表示为

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

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

由式(15)~(18)可得前、后轴轮胎的侧偏刚度

$$C_{\alpha f} = \frac{(bma_y + I_z \dot{\gamma})v_x}{2(a + b)(\delta v_x - v_y - a\gamma)} \quad (19)$$

$$C_{\alpha r} = \frac{(ama_y - I_z \dot{\gamma})v_x}{2(a + b)(b\gamma - v_y)} \quad (20)$$

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。

2 自适应扩展卡尔曼滤波算法

2.1 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

$$\mathbf{x} = (v_x, v_y, \gamma, a_x, a_y)^T \quad (21)$$

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

$$\mathbf{z} = (\gamma, a_x, a_y)^T \quad (22)$$

系统输入为

$$\mathbf{u} = (\delta, F_x, F_y)^T \quad (23)$$

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

$$\begin{cases} \mathbf{x}_k = f(\mathbf{x}_{k-1}, \mathbf{u}_k) + \mathbf{w}_{k-1} \\ \mathbf{z}_k = h(\mathbf{x}_{k-1}, \mathbf{u}_k) + \mathbf{\varepsilon}_{k-1} \end{cases} \quad (24)$$

式中, f 为状态转移函数; h 为测量函数; $\mathbf{w}_k$ 为系统过程噪声, 是均值为零, 协方差为 $\mathbf{Q}$ 的高斯白噪声; $\mathbf{\varepsilon}_k$ 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

$$\mathbf{x}_k^- = f(\mathbf{x}_{k-1}, \mathbf{u}_k) \quad (25)$$

(2) 误差协方差预测

$$\mathbf{P}_k^- = \Phi_k \mathbf{P}_{k-1} \Phi_k^T + \mathbf{Q}_k \quad (26)$$

$$\Phi_k = \mathbf{I} + T_s \mathbf{F} \quad (27)$$

式中, $\mathbf{I}$ 为合适维数的单位矩阵; T_s 为采样时间; $\mathbf{F}$ 为状态转移函数的雅可比矩阵, 通过求状态转移函

数关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

$$K_k = P_k^- H_k^T (H_k P_k^- H_k^T + R_k)^{-1} \quad (28)$$

(4) 更新状态变量, 即计算状态变量估计值

$$x_k = x_k^- + K_k (y_k - h(x_k^-, u_k)) \quad (29)$$

(5) 更新状态估计误差协方差矩阵

$$P_k = (I - K_k H_k) P_k^- \quad (30)$$

2.2 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^[7]。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

$$v_k = z_k - H_k x_k^- \quad (31)$$

式中, H_k 为测量方程的雅可比矩阵, 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

$$C_k = E[v_k v_k^T] = H_k P_k H_k^T + R_k \quad (32)$$

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。新息的实际协方差矩阵计算方法如下

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

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^[11]

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

相对于文献[12-13]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

$$K_k = P_k^- H_k^T (H_k P_k^- H_k^T + \alpha_k R_k)^{-1} \quad (35)$$

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^[14]。因此状态估计误差协方差矩阵的自适应调整方法为

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

式中, κ 过程噪声协方差矩阵调整增倍数。

2.3 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 $\hat{C}_k$, 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^[15]。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。

$$\begin{cases} M = M_{\min} & d \geq \alpha_{\max} \\ M = M_{\max} & d \leq \alpha_{\min} \\ M = \text{int} \left(\frac{(d - \alpha_{\min})(M_{\max} - M_{\min})}{\alpha_{\max} - \alpha_{\min}} \right) + M_{\min} & \alpha_{\min} < d < \alpha_{\max} \end{cases} \quad (37)$$

式中, d 为调整因子; $\alpha_{\max}$ 和 $\alpha_{\min}$ 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; $\text{int}(\cdot)$ 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[16]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[16]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[16]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。

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, 常用量纲一化新息平方(Normalized innovation square, NIS)进行目标对象的机动检测^[17-18]。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,最终导致新息及其量纲一化平方增大。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,量纲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,当量纲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。调整因子定义为量纲一化新息平方,即

$$d = \mathbf{v}_k^T \mathbf{C}_k^{-1} \mathbf{v}_k \quad (38)$$

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。

图2 自适应扩展卡尔曼滤波估计流程

3 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: $m=1\,230\text{ kg}$, $a=1.15\text{ m}$, $b=1.36\text{ m}$, $t_w=1.5\text{ m}$, $I_z=4\,607\text{ kg}\cdot\text{m}^2$ 。另外,车速为80 km/h,路面附着系数 μ 为0.85, $T_s=0.01\text{ s}$, $\kappa=100$, $\alpha_{\min}=2$, $\alpha_{\max}=10$, $M_{\min}=1$, $M_{\max}=100$ 。

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)^[4]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。

3.1 估计精度分析

设定状态估计误差协方差矩阵的初值为 $\mathbf{P}_0 = \text{eye}(5) \times 1$,过程噪声协方差矩阵的初值 $\mathbf{Q}_0 = \text{eye}(3) \times 0.01$ 。图4的左右图分别为测量噪声协方差矩阵初值 $\mathbf{R}_0 = \text{eye}(5) \times 0.01$ 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。

图4 状态估计对比($\mathbf{R}_0 = \text{eye}(3) \times 0.01$)

当 $R_0 = \text{eye}(5) \times 2$ 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 s 后存在较大的稳态误差。

图 5 状态估计对比($R_0 = \text{eye}(3) \times 2$)

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方均根值, 定义为

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

式中, y_i 和 $\hat{y}_i$ 分析信号的真实值和估计值。

表 1 状态的估计误差分析

车辆状态	方法	R 的初值	
		$\text{eye}(3) \times 0.01$	$\text{eye}(3) \times 2$
纵向车速	EKF	0.020	0.801
	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 $R_0 = \text{eye}(3) \times 0.01$ 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 $R_0 = \text{eye}(3) \times 2$ 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。

3.2 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, 以量纲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量纲一化新息平方。对比前轮转角曲线可发现, 在前轮转角发生变化的 1~7 s, 量纲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 s 和 2.2 s 处, 量纲一化新息平方出现了两个非常大的波峰。由此可见, 用量纲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 $\alpha_{\min} = 2$, 即认为量纲一化新息平方小于 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 $\alpha_{\max} = 10$, 即当量纲一化新息平方大于 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; 在量纲一化新息平方大于 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要保存 $M_{\max}$ 个新息数据, 有利于单片机实现估计算法。

图 6 量纲一化新息平方

图 7 为所提出自适应扩展卡尔曼滤波方法, 在 $R_0 \leq \text{eye}(3) \times 0.01$, $M_{\min} = 1$, $M_{\max} = 100$ 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 7 可知, 在前轮转角为 0 rad 的 0~1 s, 以及 6.6~10 s 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 s, 转向盘转角发生较快速变化, 滑动窗口发生振荡, 但仍可看出长度为 1 的情况占绝大多数。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 s, 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。

图7 滑动窗口长度变化

3.3 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 $R_0 = \text{eye}(3) \times 2$ 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 $M_{\min}$ 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。

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, 当量纲一化新息平方较小时, 即车辆行驶状态稳定的情况下, 窗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。

图9 $M_{\max}$ 对估计精度的影响

4 试验验证

为了进一步验证所提出车辆状态估计算法的优越性, 本文开展了试验验证研究。试验用车为课题组开发的“云影一号”四轮电机独立驱动电动汽车, 如图 10 所示。试验过程中, 利用转向盘力角测量仪采集转向盘的转角信号; 利用课题组开发的试验程序实现 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。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。

图10 试验用车

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。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。本文开展的试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。

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。通过试验,采集的估计器输入信号如图11所示。

图11 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计自适应扩展卡尔曼滤波算法实现。在试验中,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

$$\beta = \varphi - \psi \quad (40)$$

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 $\varphi = \text{atan}(V_E / V_N)$, 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12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 $R_0 = \text{eye}(3) \times 0.01$ 、 $R_0 = \text{eye}(3) \times 2$ 和 $R_0 = \text{eye}(3) \times 4$ 的情况。

图12 状态量估计值与实测值对比

由图12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。

表2 状态的估计误差分析

车辆状态	R 的初值		
	$\text{eye}(3) \times 0.01$	$\text{eye}(3) \times 2$	$\text{eye}(3) \times 4$
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13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 $190 \pm 2 \mu\text{s}$; $M=100$ 时,估计算法运行一次的时间为 $625 \pm 5 \mu\text{s}$ 。后者需要更长的时间,这是因为 $M=100$

图13 PAEKF 的计算负荷

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 0.01 s 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。

5 结 论

(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) 单片机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) 数值仿真和试验的结果证明, 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

- [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. Active steering angle control for intelligent vehicle[J]. Journal of Mechanical Engineering, 2017, 53(14): 106-113.
- [2] MOUSAVINEJAD E, HAN Q L, YANG F, et al. Integrated control of ground vehicles dynamics via advanced terminal sliding mode control[J]. Vehicle System Dynamics, 2017, 55(2): 268-294.
- [3] DAHMANI H, PAGÈS O, HAJJAJI A E. 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] 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.
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.
- [5] 沈法鹏, 赵又群, 孙秋云, 等. 基于 IEKF-APF 算法的汽车状态估计[J]. 机械工程学报, 2014, 50(22): 136-141.
SHEN Fapeng, ZHAO Youqun, SUN Qiuyun, et al. Ehicler state estimation based on IEKF-APF[J]. Journal of Mechanical Engineering, 2014, 50(22): 136-141.
- [6] 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[J]. Mechanical Systems and Signal Processing, 2016, 72: 832-845.
- [7] 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.
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.
- [8] 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.
- [9] ZHOU H, LIU Z, YANG X. Motor torque fault diagnosis for four wheel independent motor-drive vehicle based on unscented Kalman filter[J]. IEEE Transactions on Vehicular Technology, 2018, 67(3): 1969-1976.
- [10] 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.
YU Zhuoping, GAO Xiaojie. Review of vehicle state estimation problem under driving situation[J]. Journal of Mechanical Engineering, 2009, 45(5): 20-33.
- [11] KIM K H, LEE J G, PARK C G. Adaptive two-stage extended Kalman filter for a fault-tolerant INS-GPS loosely coupled system[J]. IEEE Transactions on Aerospace and Electronic Systems, 2009, 45(1): 125-137.
- [12] MOHAMED A H, SCHWARZ K P. Adaptive Kalman filtering for INS/GPS[J]. Journal of Geodesy, 1999, 73(4): 193-203.
- [13] 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.
- [14] 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.
- [15] 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.
- [16] HAO Y L, GUO Z, SUN F, et al. Adaptive extended Kalman filtering for SINS/GPS integrated navigation systems[C]// International Joint Conference on Computational Sciences and Optimization. Sanya: IEEE Computer Society, 2009: 192-194.
- [17] MAK SAROV 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.
- [18] 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.
- 作者简介: 张志勇(通信作者), 男, 1976 年出生, 博士, 副教授。主要研究方向为电动汽车技术, 车辆动力学及控制。
E-mail: zzy04@163.com
张淑芝, 女, 1993 年出生。主要研究方向为电动汽车技术。
E-mail: 1049889005@qq.com

第 8 届上银优秀机械博士论文奖——特别奖

激光温喷丸强化航空轻质合金的振动模态及疲劳延寿机理

作者: 孟宪凯

毕业学校: 江苏大学

指导教师: 周建忠

面向航空关键零部件的振动疲劳失效, 本文以 2024-T351 铝合金为对象, 探索激光温喷丸技术(Warm laser peening, WLP)诱导的微观组织演变及其对残余应力和模态参数的影响规律, 研究 WLP 的振动疲劳延寿机制。主要内容有:

(1) 残余压应力的生成及释放机制: 分析了 WLP 诱导的残余应力分布规律, 推导了 WLP 诱导残余压应力峰值及塑性变形深度的理论分析模型。研究了 WLP 过程中的应力应变本构模型, 建立了残余应力场的数值分析方法; 分析了残余压应力的释放过程, 获得了 WLP 强化试样残余压应力释放的规律。

(2) 动态析出、位错演变及动态再结晶过程: 研究了 WLP 诱导的晶粒、析出相、位错和亚晶界形态, 分析了 WLP 过程中的位错演变规律, 并提出了动态再结晶机制。构建了 Al-Cu 分子动力学模型, 分析了 WLP 对材料中冲击波传播、位错形态及密度的影响规律。

(3) 固有频率及材料阻尼的增益机制: 测量了 WLP 诱导的弹性模量, 推导了弹性模量与固有频率的量化模型。测量了 WLP 诱导的阻尼比, 分析了动态析出相及位错形态对材料阻尼的影响机理; 建立了阻尼比与残余压应力作用下的振动应力估算模型, 模拟研究了阻尼对动态应力的影响规律。

(4) 振动疲劳寿命的估算及裂纹起始与扩展寿命的表征: 针对裂纹起始与扩展阶段建立了振动疲劳寿命的数学模型。使用固有频率对振动疲劳损伤和损伤速率进行表征, 研究了 WLP 诱导的裂纹起始寿命和裂纹扩展寿命, 建立了振动疲劳寿命的数字化预测方法。

(5) 疲劳断口形貌分析: 研究了振动疲劳断口的组成及各阶段特征。分析了 WLP 对振动疲劳断口形貌的影响规律, 阐述了 WLP 强化航空轻质合金的振动疲劳断裂机制。

结果表明, WLP 技术在优化铝合金微观组织状态、提高残余应力稳定性、改善零部件结构在振动疲劳下的服役寿命及延缓失效方面优势显著, 有望成为航空轻质合金零件振动疲劳延寿的潜在且革新的工艺方法。