

基于双渐消因子调节的自适应卡尔曼滤波器

朱文超¹, 何 飞^{2,3}

(1. 中国电子科技集团公司第三十八研究所, 安徽 合肥 230041;

2. 中国科学技术大学, 安徽 合肥 230027;

3. 中国科学院合肥智能机械研究所, 安徽 合肥 230031)

摘要:针对传统卡尔曼(Kalman)滤波器鲁棒性差,无法实时精确跟踪系统突变状态的问题,设计了一款双渐消因子调节的自适应 Kalman 滤波器。算法分析了突变状态无法精确跟踪的原因,在传统 Kalman 滤波器的基础上,引入双渐消因子,优化预测协方差,实时激活滤波增益,调节量测新息在状态估计中的贡献度。借鉴新息正交性定理,依据 Sage 开窗估计原理与加权最小二乘准则,建立了双渐消因子的函数解析式。基于滤波发散判据,分析了储备系数与量测新息协方差之间的关系,构造了函数边界条件。实例研究表明,自适应 Kalman 滤波器鲁棒性强,能够精确跟踪系统突变状态,状态收敛速度优于抗差 Kalman 滤波器,稳态精度提升了 44.76%。

关键词:双渐消因子;自适应 Kalman 滤波;突变状态;精确跟踪

中图分类号: TP391 **文献标志码:** A **文章编号:** 2095-0373(2019)04-0066-07

0 引言

卡尔曼(Kalman)滤波器具有实时性高、数据存储量小、估计精度高等优点,被广泛应用于数字信号处理、故障联合诊断、目标跟踪等领域^[1]。然而,传统 Kalman 滤波器依赖于系统状态空间模型的准确性,当状态参数发生扰动时,往往无法精确跟踪系统突变状态,甚至会引起滤波发散现象^[2]。针对这一问题,文献[3-4]以 SINS/DVL 组合导航系统为研究对象,利用 Sage-Husa 估计原理定义了量测残差及渐消因子的解算方法,实时调整预测协方差,突出量测新息的贡献度。文献[5]通过强跟踪中心差分滤波器实时估计汽车前后轴等效时变侧偏刚度,对标称模型的不精确与状态扰动等因素具有强鲁棒性。文献[6-7]在强跟踪滤波器中引入了限定记忆的思想,通过次优渐消因子修正滤波增益,增强跟踪突变状态的能力。文献[8-9]将强跟踪滤波器和 UKF 滤波器相融合,引入时变渐消因子调节卡尔曼增益,强迫输出残差序列保持正交,提取残差有效信息,提升突变状态的跟踪能力。文献[10]基于模糊控制理论模型,动态调整弱化因子与渐消因子,膨胀量测新息,降低滤波误差,成功应用于 GPS 定位解算领域。

然而,上述研究均未对状态突变程度等级进行分层,致使状态收敛速度慢。针对这一问题,本文基于滤波发散判据,梳理储备系数与量测新息协方差的关系,划分状态突变程度等级,利用双渐消因子调整预测协方差,增权量测新息,提升估计精度,实时跟踪系统突变状态。

1 Kalman 滤波简介

1.1 线性离散时间系统模型

k 历元下,线性离散时间系统状态方程和量测方程可表示为

收稿日期:2018-05-13 网络出版日期:- 责任编辑:车轩玉 DOI:10.13319/j.cnki.sjztdxxbzb.20180513001

网络出版地址: <http://kns.cnki.net/kcms/detail/13.1402.n.20191120.1354.012.html>

基金项目:国家自然科学基金(No. 61473272)

作者简介:朱文超(1989—),男,工程师,研究方向为信息获取与检测技术。E-mail:412815833@qq.com

朱文超,何飞.基于双渐消因子调节的自适应卡尔曼滤波器[J].石家庄铁道大学学报:自然科学版,2019,32(4):66-72.

$$\mathbf{X}_k = \Phi_{k,k-1} \mathbf{X}_{k-1} + \Gamma_{k,k-1} \mathbf{U}_{k-1} \Psi_{k,k-1} \mathbf{W}_{k-1} \quad (1)$$

$$\mathbf{Z}_k = \mathbf{H}_k \mathbf{X}_k + \mathbf{V}_k \quad (2)$$

式中, $\mathbf{X}_k$ 是 m 维状态向量; $\Phi_{k,k-1}$ 是 $m \times m$ 维 $k-1$ 历元至 k 历元的状态转移矩阵; $\mathbf{U}_{k-1}$ 是 p 维输入控制量; $\Gamma_{k,k-1}$ 是 $m \times p$ 维控制输入系数矩阵; $\mathbf{W}_{k-1}$ 是 q 维系统过程噪声序列; $\Psi_{k,k-1}$ 是 $m \times q$ 维过程噪声系数矩阵; $\mathbf{Z}_k$ 是 j 维量测向量; $\mathbf{H}_k$ 是 $j \times m$ 维量测系数矩阵; $\mathbf{V}_k$ 是 j 维系统量测噪声序列。

1.2 传统 Kalman 滤波特性

在系统状态空间模型及滤波初值已知的前提下, Kalman 滤波可实时处理量测数据, 获取系统状态的最优估计值。它是一种线性、无偏且误差方差最小的随机系统最优估计算法^[11]。

然而, 传统 Kalman 滤波器鲁棒性较差, 无法精准跟踪系统突变状态。究其原因, 主要有 2 点: ①状态扰动下的先验预测偏差较大; ②当系统处于稳态环境时, 定量滤波增益无法实时增权量测新息。假设状态扰动(系统控制方式改变、噪声特性变化等)于 k 历元加载至稳态系统, 其真实状态将发生突变, 突变信息首先表现于量测新息, 作用于状态方程中的系数矩阵, 如扰动方程(3)中 $\Delta\Phi_{k,k-1}$ 、 $\Delta\Gamma_{k,k-1}$ 、 $\Delta\Psi_{k,k-1}$ 所示。此时, 若仍依靠旧状态方程进行先验预测, 必然产生较大的偏差。然而, 定量滤波增益无法实时增权量测新息, 则最优估计将逐渐偏离真实值, 最终致使滤波器发散。

$$\mathbf{X}_k = (\Phi_{k,k-1} + \Delta\Phi_{k,k-1}) \mathbf{X}_{k-1} + (\Gamma_{k,k-1} + \Delta\Gamma_{k,k-1}) \mathbf{U}_{k-1} + (\Psi_{k,k-1} + \Delta\Psi_{k,k-1}) \mathbf{W}_{k-1} \quad (3)$$

精确跟踪系统突变状态, 避免滤波器发散的方法有 2 种: ①依据状态扰动的统计特性建立精确的数学模型, 修正原始状态方程, 获取准确先验预测。②寻找激活滤波增益的方法, 当状态扰动来临时, 实时增权测量新息。

然而, 状态扰动种类繁多, 统计特性复杂, 难以准确建立数学模型, 故在分析状态突变程度的基础上, 利用不同的渐消因子优化预测协方差, 激活滤波增益, 采用实时调整量测新息在最优估计中贡献度的策略, 精确跟踪系统突变状态。

2 自适应 Kalman 滤波

2.1 自适应 Kalman 滤波设计

在传统 Kalman 滤波的基础上, 引入渐消因子、优化预测协方差, 结合线性离散时间系统状态模型, 获取自适应 Kalman 滤波递推公式。

状态预测:

状态一步预测

$$\hat{\mathbf{X}}_{k,k-1} = \Phi_{k,k-1} \hat{\mathbf{X}}_{k-1} + \Gamma_{k,k-1} \mathbf{U}_{k-1} \quad (4)$$

一步预测协方差

$$\bar{\mathbf{P}}_{k,k-1} = \lambda_k \bar{\mathbf{P}}_{k-1} \quad (5)$$

$$\bar{\mathbf{P}}_{k,k-1} = \gamma_k \Phi_{k,k-1} \bar{\mathbf{P}}_{k-1} \Phi_{k,k-1}^T + \Psi_{k,k-1} \mathbf{Q}_{k-1} \Psi_{k,k-1}^T \quad (6)$$

观测更新:

量测新息

$$\mathbf{Y}_k = \mathbf{Z}_k - \mathbf{H}_k \hat{\mathbf{X}}_{k,k-1} \quad (7)$$

滤波增益

$$\bar{\mathbf{K}}_k = \bar{\mathbf{P}}_{k,k-1} \mathbf{H}_k^T [\mathbf{H}_k \bar{\mathbf{P}}_{k,k-1} \mathbf{H}_k^T + \mathbf{R}_k]^{-1} \quad (8)$$

最优估计

$$\hat{\mathbf{X}}_k = \hat{\mathbf{X}}_{k,k-1} + \bar{\mathbf{K}}_k \cdot \mathbf{Y}_k \quad (9)$$

后验协方差

$$\bar{\mathbf{P}}_k = \bar{\mathbf{P}}_{k,k-1} - \bar{\mathbf{K}}_k \mathbf{H}_k \bar{\mathbf{P}}_{k,k-1} \quad (10)$$

式中, $\mathbf{Q}_{k-1}$ 、 $\mathbf{R}_k$ 分别为过程噪声 $\mathbf{W}_{k-1}$ 与量测噪声 $\mathbf{V}_k$ 的协方差矩阵。

2.2 双渐消因子的求解

线性最优 Kalman 滤波最重要的一个特点是:当滤波增益最优时,量测新息序列 $Y(k)$ 处处正交,其正交方程可用自相关函数表示为^[12]

$$E[Y_{k+j} Y_k^T] = P_{k,k-1}^{\text{opt}} \cdot H_k^T - K_k^{\text{opt}} C_k^{\text{opt}} = 0 \quad (11)$$

式中, C_k 为量测新息协方差矩阵,上标 opt 代表最优矩阵。

依据最优 Kalman 估计原理,化简式(11),结果如式(12)所示

$$C_k^{\text{opt}} = R_k + H_k P_{k,k-1}^{\text{opt}} H_k^T \quad (12)$$

若系统状态未发生突变,则传统 Kalman 滤波器的预测协方差 $P_{k,k-1}^{\text{base}}$ 可满足正交方程

$$C_k^{\text{base}} = R_k + H_k P_{k,k-1}^{\text{base}} H_k^T \quad (13)$$

$$P_{k,k-1}^{\text{base}} = \Phi_{k,k-1} P_{k-1}^{\text{base}} \Phi_{k,k-1}^T + \Psi_{k,k-1} Q_{k-1} \Psi_{k,k-1}^T \quad (14)$$

式中,上标 base 代表传统 Kalman 滤波器产生的协方差矩阵。

然而,随着滤波过程的推进,系统趋于稳态,滤波增益及后验误差协方差的取值固定。倘若此时系统状态发生突变,则需重新激活滤波增益,利用优化预测协方差 $\bar{P}_{k,k-1}$ 满足正交方程,式(12)可化为

$$C_k^{\text{opt}} = R_k + H_k \bar{P}_{k,k-1} H_k^T \quad (15)$$

根据 Sage 开窗估计法^[13],由量测新息获取 C_k^{opt} 在 k 历元下的估计值 $\bar{C}_k$,即

$$\bar{C}_k = \frac{1}{k-1} \sum_{i=1}^k Y_i Y_i^T \quad (16)$$

状态扰动下的突变信息将首先表现于量测新息即量测新息协方差矩阵。故将 $\bar{C}_k$ 与 C_k^{base} 作为突变感应元素。同时,根据滤波发散判据^[14],引入储备系数 μ_0 ,将其作为突变程度的标尺。依据三者的关系构造 λ_k 、 γ_k 的边界条件。

当状态突变程度较浅时,即 $C_k^{\text{base}} < \bar{C}_k < \mu_0 C_k^{\text{base}}$,系统仅利用 λ_k 膨胀量测新息,此时 $\bar{P}_{k,k-1} = P_{k,k-1}^{\text{base}}$ 且 $\bar{P}_{k,k-1} = \lambda_k P_{k,k-1}^{\text{base}}$ 。

联立式(13)、式(15)、式(16)进行矩阵的迹运算,获取 λ_k 的函数解析式

$$\lambda_k = \frac{\text{tr}[\bar{C}_k - R_k]}{\text{tr}[C_k^{\text{base}} - R_k]} \quad (17)$$

需要说明的是,更新 λ_{k+1} 时,需将 k 历元下的后验方差 $\bar{P}_k$ 作为 P_{k+1}^{base} ,代入式(13)与式(14),求解 C_{k+1}^{base} ,判断其与 $\bar{C}_{k+1}$ 的关系,构造边界条件,再进入 $k+1$ 历元的迭代估计阶段。

当状态突变程度较深时,即 $\bar{C}_k > \mu_0 C_k^{\text{base}}$,状态估计对量测新息的需求程度增强。此时,系统持续利用式(17)更新 λ_k ,在此基础上,启动因子 γ_k 进一步增权量测新息。

基于加权最小二乘准则,在 $k-1$ 历元最小二乘估计 $\hat{X}_{k-1}^{\text{LSW}}$ 的基础上,引入 k 历元的量测新息,计算当前历元的后验协方差 P_k^{LSW} ,如式(18)所示,利用 P_k^{LSW} 更新因子 γ_k ,调整预测协方差。

$$P_k^{\text{LSW}} = P_{k-1}^{\text{LSW}} - P_{k-1}^{\text{LSW}} H_k^T [H_k P_{k-1}^{\text{LSW}} H_k^T + R_k]^{-1} H_k P_{k-1}^{\text{LSW}} \quad (18)$$

综合式(6)、式(14)、式(18)进行矩阵的迹运算,得到 γ_k 函数解析式

$$\gamma_k = \frac{\text{tr}[P_k^{\text{LSW}} - Q_{k-1}]}{\text{tr}[P_{k,k-1}^{\text{base}} - Q_{k-1}]} \quad (19)$$

综合式(17)~式(19),获得因子 λ_k 与 γ_k 的终解,即

$$\lambda_k = \begin{cases} 1, & \bar{C}_k \leq C_k^{\text{base}} \\ \frac{\text{tr}[\bar{C}_k - R_k]}{\text{tr}[C_k^{\text{base}} - R_k]}, & \bar{C}_k > C_k^{\text{base}} \end{cases} \quad \gamma_k = \begin{cases} 1, & \bar{C}_k \leq \mu_0 C_k^{\text{base}} \\ \frac{\text{tr}[P_k^{\text{LSW}} - Q_{k-1}]}{\text{tr}[P_{k,k-1}^{\text{base}} - Q_{k-1}]}, & \bar{C}_k > \mu_0 C_k^{\text{base}} \end{cases} \quad (20)$$

3 试验验证

本节以中科院智能机械研究所自行研制的双 E 型弹性体六维力传感器为研究对象,于静态标定环境下,研究传统 Kalman 滤波器(SKF)、抗差 Kalman 滤波器^[15](RKF)、自适应 Kalman 滤波器(AKF)的鲁棒特性。

六维力传感器标定实验台如图1所示。依次从 F_z 方向标定数据库中抽取3组量测值进行分析。其中,第一组为恒载输出电压(理想值 25 mV);第二组为卸载输出电压(理想值 10 mV);第三组为加载输出电压(理想值 60 mV)。假设前 47 历元,传感器持续进行恒载输出。第 48 历元时,分别进行异量级的卸载或加载操作,则系统状态将发生不同程度等级的突变,理想突变趋势如图2所示。由于系统状态突变的原因为传感器载荷变化,即输入控制发生变化,故 k 历元下的状态方程(1)可化为式(21),扰动方程(3)可化为式(22) 分别利用 SKF、RKF、AKF 对量测值进行滤波处理,结果如图3~图10所示。

$$\mathbf{X}_k = \mathbf{X}_{k-1} + \mathbf{U}_{k-1} + \mathbf{W}_{k-1} \quad (21)$$

$$\mathbf{X}_k = \mathbf{X}_{k-1} + (\mathbf{U}_{k-1} + \Delta \mathbf{U}_{k-1}) + \mathbf{W}_{k-1} \quad (22)$$




图1 六维力传感器标定实验台




图2 传感器阶跃输出信号

图3~图5反映了传感器输出由恒载向卸载转变时,3种算法的滤波效果。从图4中可以看出,前47历元,即系统状态未突变前,量测新息序列满足正交性要求,故AKF与RKF均退化为SKF。3种算法状态收敛速度相同,滤波精度亦相同。




图3 卸载前后3种算法跟踪效果




图4 卸载前3种算法跟踪效果

然而,当系统状态在第48历元发生突变时,如图3所示,SKF算法未更新滤波增益,逐渐偏离真实状态,估计误差无限增大。反观AKF与RKF,两者均能有效地跟踪系统突变状态。然而,由于状态突变程度较浅,AKF退化为RKF,两者滤波精度相同,如图5所示。

图6反映了状态突变前后渐消因子的时变趋势。不难发现,因子 γ_k 处于冷却状态,AKF仅用因子 λ_k 进行状态调节。 λ_k 的时变趋势分为5个阶段。

(1)阶段1(47历元至48历元)。状态于此阶段突变,突变信息作用于量测新息协方差,致使估计值 $\bar{C}_k$ 骤然变大, λ_k 由冷却骤变为激活态。

(2)阶段2(48历元至49历元)。该阶段的先验估计涵盖了量测新息,其效果优于阶段1。然而,依据图5所示,跟踪初期的后验误差大于突变前的稳态误差。故 $\bar{C}_k$ 减小, C_k^{base} 增大, λ_k 处于急速下降状态。

(3)阶段3(49历元至71历元)。该阶段状态后验误差开始减小,估计精度开始提升,则 $\bar{C}_k$ 与 C_k^{base} 均开始减小, λ_k 的下降速率减缓。

(4)阶段4(71历元至76历元)。该阶段状态后验误差缓慢减小,估计精度缓慢提升,则 $\bar{C}_k$ 与 C_k^{base} 均

缓慢减小, λ_k 的下降速率进一步减缓。

(5)阶段 5(76 历元至 100 历元)。该阶段后验误差稳定, 则 λ_k 仅在稳态值范围进行微调。




图 5 卸载后 3 种算法跟踪效果




图 6 卸载后 AKF 渐消因子时变趋势

图 7~图 8 反映了传感器输出由恒载向加载转变时, 3 种算法的滤波效果。当系统状态在第 48 历元发生突变时, SKF 滤波发散。RKF 仅利用因子 λ_k 调节滤波增益, 增权量测新息, 能够有效跟踪突变状态。然而, AKF 的总体滤波效果优于 RKF。尤其在第 72 历元至第 100 历元阶段, AKF 状态收敛速度优于 RKF。




图 7 加载前后 3 种算法跟踪效果




图 8 加载后 3 种算法跟踪效果

从图 9~图 10 可以看出, 状态突变后, AKF 持续激活双渐消因子 λ_k 与 γ_k , 能够更深层地利用量测新息纠正估计值。加载环境下, γ_k 的时变趋势分为 4 个阶段; λ_k 的时变趋势分为 6 个阶段。

γ_k 的时变趋势解析:

(1)阶段 1(47 历元至 48 历元)。状态于此阶段突变, 突变信息体现于量测数据, 致使后验协方差 P_{48}^{LSW} 骤然变大, γ_k 由冷却骤变为激活态。

(2)阶段 2(48 历元至 49 历元)。该阶段的先验估计涵盖了量测新息, 先验误差 $\mathbf{P}_{48,48}^{base}$ 的精度回升, 则相较于阶段 1, γ_k 处于急速下降状态。

(3)阶段 3(49 历元至 72 历元)。该阶段后验误差开始减小, 先验估计精度稳步提升, 则相较于阶段 2, γ_k 的下降速率减缓。

(4)阶段 4(72 历元至 100 历元)。该阶段状态后验误差继续减小, 第 72 历元, $\bar{\mathbf{C}}_k$ 与 $\mathbf{C}_k^{base}$ 之间的关系到达临界条件, γ_k 由激活变为冷却态。

λ_k 的时变趋势解析:

(1)阶段 1、阶段 2、阶段 3 的趋势分析同卸载环境 λ_k 。

(2)阶段 4(72 历元至 81 历元)。该阶段 γ_k 处于冷却状态, 则 $\mathbf{C}_k^{base}$ 的衰减速率变慢。相较于阶段 3, λ_k 的下降速率加快。

(3)阶段5(81 历元至 94 历元)。该阶段后验误差缓慢减小,估计精度缓慢提升, $\bar{C}_k$ 与 C_k^{base} 均缓慢减小,相较于阶段4, λ_k 的下降速率有所减缓。

(4)阶段6(94 历元至 100 历元)。该阶段后验误差稳定,则 λ_k 仅在稳态值范围进行微调。




图9 加载后 AKF 因子 λ_k 时变趋势




图10 加载后 AKF 因子 γ_k 时变趋势

通过式(23)解算 72 历元至第 100 历元 3 种算法估计结果的均方根误差 $\bar{X}_k^{RMSE}$, 详见表 1。不难看出,SKF 误差较大,处于发散状态。相较于 RKF,AKF 稳态精度提升了 44.76%。

$$\bar{X}_k^{RMSE} = \sqrt{\frac{\sum_{k=72}^{100} (X_k - \hat{X}_k)^2}{29}} \quad (23)$$

表1 滤波算法性能对比

滤波算法	突变后误差	精度提升/%
SKF	18.869 4	—
RKF	2.839 2	—
AKF	1.568 4	44.76

4 结论

为解决传统 Kalman 滤波无法精确跟踪系统突变状态的问题,设计了自适应 Kalman 滤波器,依据不同的状态突变程度等级,采用不同的渐消因子组合,实时调节预测协方差,激活滤波增益,增权量测新息。实验表明,自适应 Kalman 滤波器能够运用于六维力传感器静态标定领域,具有较强的鲁棒性,稳定精度优于抗差 Kalman 滤波。然而,目前仅分析了标量渐消因子的求解方法,对于多维渐消因子,还有待于进一步深入研究。

参 考 文 献

- [1]朱枫,张葆等,基于强跟踪卡尔曼滤波的陀螺信号处理[J]. 吉林大学学报:工学版,2017,47(6):1869-1875.
- [2]Chang G B, Liu M. M-estimator-based robust Kalman filter for systems with process modeling errors and rank deficient measurement models [J]. Nonlinear Dynamics, 2015, 80(3): 1431-1449.
- [3]Chingiz H, Halil E S. Robust adaptive Kalman filter for estimation of UAV dynamics in the presence of sensor/actuator faults[J]. Aerospace Science and Technology, 2013,28: 376-383.
- [4]Gao W, Li J C. Adaptive Kalman filtering for the integrated SINS/DVL system [J]. Journal of Computational Information Systems, 2013,9(16): 6443-6450.
- [5]李静,张家旭,张艳华,等. 采用强跟踪中心差分滤波器的汽车状态和参数估计[J]. 吉林大学学报:工学版,2017,47(5): 1329-1335.
- [6]朱文超. 一种限定记忆的自适应扩展 Kalman 滤波器[J]. 井冈山大学学报:自然科学版,2015,36(4):49-54.

- [7]高伟,李敬春,奔粤阳,等.基于多重渐消因子的自适应卡尔曼滤波器[J].系统工程与电子技术,2014,36(7):1405-1409.
- [8]杨新欣,邓联文,陈鸿飞,等.基于强跟踪 UKF 的视频目标跟踪算法[J].中国电子测量技术,2016,39(10):95-99.
- [9]胡高歌,刘逸涵,高社生,等.改进的强跟踪 UKF 算法及其在 INS/GPS 组合导航中的应用[J].中国惯性技术学报,2014,22(5):635-639.
- [10]Chang G B, Liu M. An adaptive fading Kalman filter based on Mahalanobis distance[J]. Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering, 2015, 229(6): 1114-1123.
- [11]朱文超,许德章.双 E 型弹性体六维力传感器矩形梁 Kalman 滤波研究[J].机械科学与技术,2014,33(6):909-912.
- [12]薛海建,郭晓松,周召发.基于自适应多重渐消因子卡尔曼滤波的 SINS 初始对准方法[J].系统工程与电子技术,2017,39(3):620-625.
- [13]宋会杰,董绍武,屈俐俐,等.基于 Sage 窗的自适应 Kalman 滤波用于钟差预报研究[J].仪器仪表学报,2017,38(7):1809-1816.
- [14]付梦印,邓志红,张继伟. Kalman 滤波理论及其在导航系统中的应用[M].北京:科学出版社,2003.
- [15]王琰,张传定,胡小工,等.卫星分群的抗差 Kalman 滤波在 GPS/BDS 融合精密单点定位中的应用[J].中国惯性技术学报,2016,24(6):769-774.

Adaptive Kalman Filtering Based on Two Fading Component Adjustment

Zhu Wenchao¹, He Fei^{2,3}

(1. The 38th Research Institute of China Electronics Technology Group Corporation, Hefei 230041, China;

2. Department of Electronic Engineering and Information Science,

University of Science and Technology of China, Hefei 230027, China;

3. Institute of Intelligent Machines, Chinese Academy of Science, Hefei 230031, China;)

Abstract: According to poor robustness of traditional Kalman filtering and bad behavior of accurate tracking breaking state of the system, double fading factors were designed to regulate Adaptive Kalman filtering. About the algorithm, this paper first analyzed the reason of bad behavior of accurate tracking in the breaking state, based on traditional Kalman filtering, then double fading factors were introduced, detection covariance was optimized, filtering gain was activated in real-time, regulating variable measure contribution degree of innovation in the state estimation. It is worth to use orthogonality theorem of innovation for reference, based of fenestration estimation principle and weighted least squares, functional analytic formula of double fading factors was constructed. Using criterion of filtering divergence, this paper analyzed the relationship between reserve coefficient and measuring covariance of innovation, function boundary condition was constructed. The case study shows strong robustness of adaptive Kalman filtering, it can get accurate tracking breaking state of the system, convergence rate is superior to the other rate of anti-Error Kalman filtering, steady precision was improved to 44.76percent.

Key words: double fading factors; adaptive Kalman filtering; breaking state; accurate tracking