

基于深度加权的稳健 Kalman 滤波方法

刘也^{①②}, 唐歌实^②, 余安喜^①, 朱炬波^③, 梁甸农^①

① 国防科学技术大学电子科学与工程学院, 长沙 410073;

② 北京航天飞行控制中心航天飞行动力学技术重点实验室, 北京 100094;

③ 国防科学技术大学理学院, 长沙 410073

E-mail: liuye.cool2007@yahoo.com.cn

2012-01-16 收稿, 2012-04-28 接受

国家自然科学基金(61072115, 60901071)资助

摘要 在分析粗差对 Kalman 滤波器性能影响的基础上, 通过将滤波新息的加权方式改进为深度加权平均, 提出了一种基于 Kalman 框架的新型的稳健滤波算法. 该算法仅需引入一个样本深度及权函数的计算步骤, 无需针对测元的粗差检择, 直接调节各测元对滤波状态的贡献. 深度加权滤波扩展了传统 Kalman 滤波的最小均方误差优化准则, 充分利用了不同测元间的相关性和测元与状态的相关性, 可以有效降低含粗差数据对滤波结果的影响程度. 在稳健性分析的基础上, 数值算例验证了算法的可行性和有效性.

关键词

数据深度
加权
滤波
粗差

粗差指离群的误差, 它由某些突发性的异常因素造成, 会严重恶化滤波系统的稳健性. 可采取两类方法抑制粗差的影响, 一是设计检验统计量对含有粗差的数据进行检测并删除, 二是通过加权等方式降低含有粗差数据对滤波结果的贡献. 前者又称粗差检择算法, 根据所用信息的不同, 可以在单个测量通道内进行, 也可在融合滤波器中实现, 常用的时间序列方法^[1]、新息方法^[2]、面向状态^[3]、抗差估计^[4]和拟准检定^[5]均属此类. 检择算法的关键是检验统计量的构造, 及由此设计的检择标准与检择阈值. 其中检验统计量的合理性严重依赖于实际数据的分布特性, 限制了此类算法的通用性. 后者从信息贡献性出发, 通过合理调节各测元对融合结果的贡献, 降低粗差的影响, 其关键是融合权值的设计. 杨元喜等人^[6]在抗差估计中引入等价权的概念, 是此类方法的典型应用, 然而它仍是采用测元间的欧氏距离对质量较差测元进行定位, 易受“杠杆观测”的影响^[7]. 实际上, Kalman 滤波采用的是最小均方误差准则或极大似然准则, 这实际上是在传统欧氏距离空间上的均值加权思想, 具有稳健性差的天然缺陷. 拟准检定算

法^[5]的执行过程中引入了数据分群的思想, 一定程度上突破了欧氏距离的限制, 可以有效克服“杠杆观测”导致的粗差转移现象. 但文献中还缺少对这种数据分群特征的理论描述, 因而拟准观测数量的选取有一定的随意性.

数据分群特征表示了数据靠近中心的程度, 这与序统计量中数据深度^[8]有着类似之处. 次序统计量又称顺序统计量, 它反映了随机变量的位置信息, 不敏感于传统的距离函数, 如中值、极值、极差、中程、截尾均值等, 它们都具有良好的稳健估计性质^[9~13]. 在滤波器设计中, 一个简单的应用是用中值滤波来进行单个测量通道的数据检择. 然而, 对于复杂系统, 测量信息可能为不同种类、不同维数. 对于多维样本, 数据之间不存在自然的线性序关系, 无法按照样本的大小排序. 因此, 发展高维次序统计量, 扩展一维次序统计量的一些有用结论, 是十分重要的问题. 数据深度又称统计深度函数, 有时也称为中心度, 为高维数据提供了一种由中心向外排序的半序方法, 从而可以把一维情形中的中位数等次序统计量概念推广到高维. 数据深度可以看作是一个高维数据在相

应的概率分布或者给定样本数据集下,到底有多么靠近中心,这样就可以把数据中的隐藏信息挖掘出来.近年来,数据深度已经被广泛应用于质量控制、数据分类、多元回归、置信区域、聚类判别、异方差检验和风险度量等领域^[8,14].关于如何利用数据深度构建稳健估计方法,有学者在卫星轨道事后精密定轨中进行了初步的探索^[15].虽然次序统计量的理论研究成果很多,但如何利用次序统计量构建复杂动态系统的稳健滤波方法,还有许多问题需要深入研究.

本文引入深度加权概念,研究 Kalman 滤波的稳健性改进方法.首先,分析粗差在 Kalman 滤波器中的累积效应;其次,将 Kalman 滤波中新息对状态的修正量变换为样本矩平均形式,进而将其改进为深度加权平均,从而拓展 Kalman 滤波框架的最小均方误差准则,获得新型 Kalman 滤波算法;最后进行算法的稳健性分析和数值验证,给出文章主要结论.

1 粗差的影响分析

考虑系统

$$\begin{cases} \mathbf{x}_k = \mathbf{A}_k \mathbf{x}_{k-1} + \mathbf{v}_{k-1}, \\ \mathbf{y}_k = \mathbf{H}_k \mathbf{x}_k + \mathbf{n}_k, \end{cases} \quad (1)$$

其中 $\mathbf{x}_k$ 为 m 维系统状态向量, $\mathbf{y}_k$ 为 n 维系统观测向量, $\mathbf{A}_k$ 和 $\mathbf{H}_k$ 分别代为统的状态转移矩阵和测量矩阵,假设噪声 $\mathbf{v}_{k-1}$ 和 $\mathbf{n}_k$ 为零均值高斯白噪声,方差分别为 $\mathbf{P}_{v,k}$ 和 $\mathbf{P}_{n,k}$.若 k 时刻系统的某些测量通道出现了粗差,则测量方程为

$$\mathbf{y}_k = \mathbf{H}_k \mathbf{x}_k + \mathbf{n}_k + \boldsymbol{\delta}_k. \quad (2)$$

设 $\{\delta'_r, r \in \Omega\}$ 是 $\boldsymbol{\delta}_k$ 中非零元素集合,它在 $\mathbf{n}_k$ 中对应位置的元素集合为 $\{n'_r, r \in \Omega\}$,则根据粗差性质^[1],有 $|n'_r| \ll |\delta'_r|, r \in \Omega$.下面分析 $\boldsymbol{\delta}_k$ 对滤波结果的影响.

记 k 时刻系统状态预测值和滤波值分别为 $\bar{\mathbf{x}}_{k|k-1}$ 和 $\hat{\mathbf{x}}_{k|k}$,对应误差协方差矩阵 $\bar{\mathbf{P}}_{x,k}$ 和 $\mathbf{P}_{x,k}$,滤波增益矩阵 $\mathbf{K}_k$, $\bar{\mathbf{y}}_{k|k-1} = \mathbf{H}_k \bar{\mathbf{x}}_{k|k-1}$.若 $\boldsymbol{\delta}_k$ 已知,则根据 Kalman 滤波公式,可获得最优状态估计值和方差

$$\begin{cases} \hat{\mathbf{x}}_{k|k}^0 = \bar{\mathbf{x}}_{k|k-1} + \mathbf{K}_k (\mathbf{y}_k - \bar{\mathbf{y}}_{k|k-1}), \\ \mathbf{P}_{x,k}^0 = (\mathbf{I}_{m \times m} - \mathbf{K}_k \mathbf{H}_k) \bar{\mathbf{P}}_{x,k}, \end{cases} \quad (3)$$

$\mathbf{I}_{m \times m}$ 是 m 阶单位矩阵.假设 $\boldsymbol{\delta}_k$ 未知,根据 Kalman 滤波公式,粗差不影响滤波器中各协方差矩阵的计算,因此可获得有偏的状态估计结果

$$\begin{cases} \hat{\mathbf{x}}_{k|k}^1 = \bar{\mathbf{x}}_{k|k-1} + \mathbf{K}_k (\mathbf{y}_k - \bar{\mathbf{y}}_{k|k-1}) \\ = \hat{\mathbf{x}}_{k|k}^0 + \mathbf{K}_k \boldsymbol{\delta}_k \\ \triangleq \hat{\mathbf{x}}_{k|k}^0 + \Delta \mathbf{x}_k, \\ \mathbf{P}_{x,k}^1 = (\mathbf{I}_{m \times m} - \mathbf{K}_k \mathbf{H}_k) \bar{\mathbf{P}}_{x,k} = \mathbf{P}_{x,k}^0 \end{cases} \quad (4)$$

中 $\Delta \mathbf{x}_k$ 是 k 时刻系统状态估计偏差.

假设 $k+1$ 时刻各测量通道内均无系统误差,则类上可得 $\boldsymbol{\delta}_k$ 已知和未知时的状态估计值分别为

$$\hat{\mathbf{x}}_{k+1|k+1}^0 = \mathbf{A}_{k+1} \hat{\mathbf{x}}_{k|k}^0 + \mathbf{K}_{k+1} (\mathbf{y}_{k+1} - \mathbf{H}_{k+1} \mathbf{A}_{k+1} \hat{\mathbf{x}}_{k|k}^0), \quad (5)$$

$$\hat{\mathbf{x}}_{k+1|k+1}^1 = \mathbf{A}_{k+1} \hat{\mathbf{x}}_{k|k}^1 + \mathbf{K}_{k+1} (\mathbf{y}_{k+1} - \mathbf{H}_{k+1} \mathbf{A}_{k+1} \hat{\mathbf{x}}_{k|k}^1). \quad (6)$$

将(4)和(5)式代入(6)式可得

$$\begin{aligned} \hat{\mathbf{x}}_{k+1|k+1}^1 &= \mathbf{A}_{k+1} (\hat{\mathbf{x}}_{k|k}^0 + \Delta \mathbf{x}_k) \\ &\quad + \mathbf{K}_{k+1} [\mathbf{y}_{k+1} - \mathbf{H}_{k+1} \mathbf{A}_{k+1} (\hat{\mathbf{x}}_{k|k}^0 + \Delta \mathbf{x}_k)] \\ &= \mathbf{A}_{k+1} \hat{\mathbf{x}}_{k|k}^0 + \mathbf{K}_{k+1} (\mathbf{y}_{k+1} - \mathbf{H}_{k+1} \mathbf{A}_{k+1} \hat{\mathbf{x}}_{k|k}^0) \\ &\quad + \mathbf{A}_{k+1} \Delta \mathbf{x}_k - \mathbf{K}_{k+1} \mathbf{H}_{k+1} \mathbf{A}_{k+1} \Delta \mathbf{x}_k \\ &= \hat{\mathbf{x}}_{k+1|k+1}^0 + (\mathbf{I}_{m \times m} - \mathbf{K}_{k+1} \mathbf{H}_{k+1}) \mathbf{A}_{k+1} \Delta \mathbf{x}_k. \end{aligned} \quad (7)$$

由此,可得状态偏差的递推公式

$$\Delta \mathbf{x}_{k+1} = (\mathbf{I}_{m \times m} - \mathbf{K}_{k+1} \mathbf{H}_{k+1}) \mathbf{A}_{k+1} \Delta \mathbf{x}_k \triangleq \mathbf{D}_k \Delta \mathbf{x}_k. \quad (8)$$

由上可见,某个时刻观测出现粗差时,其影响将以 $\mathbf{D}_k$ 的倍数叠加到以后的状态估值上,使滤波器产生偏差.当 $\|\mathbf{D}_k\|$ 始终大于 1 时,系统会因误差累积而发散;否则,系统会逐渐收敛,但其收敛过程中的精度会明显低于无粗差测量的情形.通常,滤波器收敛过程满足 $\|\mathbf{I}_{m \times m} - \mathbf{K}_{k+1} \mathbf{H}_{k+1}\| < 1$,但为保证滤波器的收敛性,还需合理设计增益矩阵,抑制状态预测过程中 $\mathbf{A}_{k+1}$ 对粗差影响的放大作用.以上分析了单个时刻存在粗差(孤立粗差)对滤波结果的影响,当存在成片粗差或粗差相隔较近时,滤波结果的恶化程度将更加显著.

2 基于深度加权的 Kalman 滤波

2.1 滤波算法

根据 Kalman 滤波公式(3),滤波器的估计值由系统预测状态信息和测量信息综合后获得,算法的关键是从模型误差和测量误差构造滤波增益 $\mathbf{K}_k$.记 $\tilde{\mathbf{y}}_k = [\tilde{\mathbf{y}}_k^1, \tilde{\mathbf{y}}_k^2, \dots, \tilde{\mathbf{y}}_k^n]^T$,将 $\mathbf{K}_k$ 写成行向量组合 $\mathbf{K}_k = [\mathbf{K}_k^1, \mathbf{K}_k^2, \dots, \mathbf{K}_k^n]$,则

$$\hat{\mathbf{x}}_{k|k} = \bar{\mathbf{x}}_{k|k-1} + \sum_{i=1}^n (\mathbf{K}_k^i \tilde{\mathbf{y}}_k^i). \quad (9)$$

上式第2项可以写作样本矩的平均加权形式

$$\sum_{i=1}^n K_k^i \tilde{y}_k^i = \frac{1}{n} \sum_{i=1}^n (n K_k^i \tilde{y}_k^i) \triangleq \frac{1}{n} \sum_{i=1}^n (z_k^i). \quad (10)$$

然而, 样本矩对数据的扰动比较敏感, 特别是 $\tilde{y}_k$ 中的粗差会严重恶化滤波结果. 有文章提出了随机变量深度加权平均^[16]的稳健估计方法, 还有人等将其初步应用于卫星事后精密轨道确定^[15]. 深度加权方法对于靠近数据集中心的数据赋予较大的权重, 有利于降低含粗差数据对估计结果的影响, 因此, 下面考虑将 Kalman 滤波中的样本矩均值计算式(10)改进为深度加权平均, 以提高滤波估计的稳健性.

数据深度定义很多, 其应用效果视具体问题而定. 下面采用随机变量的投影深度加权均值^[16]构造 Kalman 滤波器, 基于其他数据深度的 Kalman 滤波器类似可得. 具有分布 F 的随机向量 S 的投影深度 $D(S, F)$ 定义为

$$\begin{cases} D(S, F) = \frac{1}{(1 + O(S, F))}, \\ O(S, F) = \sup_{\|u\|=1} \left\{ \frac{|u^T S - \text{Med}(F_u)|}{\text{MAD}(F_u)} \right\}, \end{cases} \quad (11)$$

其中 F_u 是 $u^T S$ 的分布函数, $\text{Med}(F_u)$ 是 F_u 的中位数, $\text{MAD}(F_u)$ 是 $|u^T S - \text{Med}(F_u)|$ 的中位数. 特别地, 若 $\text{MAD}(F_u)=0$, 则定义 $O(S, F)=0$. 根据随机变量深度加权平均思想, 随机向量 $z_k^i, i=1, \dots, n$ 在数据深度 $D(S, F)$ 下的加权平均为

$$E_D(z^1, \dots, z^n) = \frac{\sum_{i=1}^n \{\varphi[D(z^i)] \cdot z^i\}}{\sum_{i=1}^n \varphi[D(z^i)]}. \quad (12)$$

其中 $\varphi(r)$ 为加权函数, 其计算方法为, 若 $r > \beta \text{Med}(D(z, F))$, 则 $\varphi(r)=1$, 否则

$$\varphi(r) = \frac{\exp\left\{-\gamma \left[1 - \frac{r^t}{\text{Med}^t(D(z, F))}\right]^2\right\} - \exp(-\gamma)}{1 - \exp(-\gamma)}, \quad (13)$$

其中 t, β 和 γ 是常值参数, 用于调节需要区分的具有不同投影深度的点的数量, $\text{Med}(D(z, F))$ 是所有采样点深度的中位数. 将(12)和(13)式应用于(10)式的修改, 即获得深度加权的 Kalman 滤波算法

$$\begin{aligned} \hat{x}_{k|k} &= \bar{x}_{k|k-1} + \frac{\sum_{i=1}^n \{\varphi[D(n K_k^i \tilde{y}_k^i)] \cdot (n K_k^i \tilde{y}_k^i)\}}{\sum_{i=1}^n \varphi[D(n K_k^i \tilde{y}_k^i)]} \\ &\triangleq \bar{x}_{k|k-1} + \Phi(K_k, \tilde{y}_k). \end{aligned} \quad (14)$$

类似地, 可得滤波状态误差协方差的估计. 计算方法是: 首先, 将 $\bar{P}_{y,k}$ 写作列向量, 获得矩阵 $A = K_k \bar{P}_{y,k}$ 的深度加权估计; 然后, 将 A 写作行向量形式, 可得 $B = A K_k^T$ 的深度加权估计; 最后, 将 B 带入(3)式可得滤波状态误差协方差的深度加权估计. 这里仅需在原算法基础上增加一个分量的深度及权函数计算步骤, 实现简单, 且在 EKF 和 UKF 等常见的实时滤波算法中均适用.

如果采用通常 Kalman 滤波中的变量高斯分布假设, 可以认为 z_i 是高斯随机过程, 均值为零, 方差为 $\bar{P}_{x,k}$. 则此时深度函数可简化为

$$D(S, F) = \inf_{\|u\|=1} \left\{ \frac{\text{Med}(|u^T S|)}{|u^T S| + \text{Med}(|u^T S|)} \right\}. \quad (15)$$

对比传统粗差检择算法和本文深度加权方法的实现过程, 可以发现两者的显著区别. 在传统粗差检择方法中, 对含粗差测元的抑制是通过两步实现的: 即首先通过粗差检择技术识别含粗差测元, 并对其取舍或加权; 然后, 通过增益矩阵引入测元与状态的相关性, 修正滤波状态. 本文的深度加权滤波方法则无需测元级的粗差检择, 并且绕过了增益矩阵, 直接调节各测元对滤波状态的贡献, 实现了测元间相关性及其与状态相关性的同时利用. 实际上, 深度加权通过对各测元距“中心”远近的刻画, 隐含了滤波稳健性指标, 改变了滤波优化函数, 可以看作是对传统 Kalman 滤波的最小均方误差优化准则的扩展.

2.2 稳健性分析

假设 k 时刻测元 y_k^s 含有粗差, 则由粗差的分群特性^[5], 对任意满足 $1 \leq i \leq n$ 且 $i \neq s$ 的测元 y_k^i , 有

$$|u^T z_k^s - \text{Med}(F_u)| \gg |u^T z_k^i - \text{Med}(F_u)|, \|u\|=1. \quad (16)$$

由深度加权的定义, 各测元投影深度满足

$$D(z_k^s) \ll D(z_k^i), \quad 1 \leq i \leq n, \quad i \neq s. \quad (17)$$

可见, 测元 y_k^s 在滤波器计算中的加权函数远小于其它测元. 实际上, 由式(13)的加权函数定义, 测元距数据中心越远, 则其对滤波器的贡献就越小. 因此, 只要同一时刻参与滤波的测元中含粗差的测元个数与正常的测元个数相比足够小, 使得数据中心点位于合理数据范围内, 则深度加权的稳健性就可以保证滤波器对含粗差测元的抑制作用. 当然, 系统最大可允许多少测元含有粗差, 还需根据实际测量结构

进行具体分析.

上面仅是对单个测元含粗差时的简单定性分析. 下面引入 Kalman 滤波器的稳健性分析方法^[17], 简要分析多测元的综合影响. 系统滤波后, 测量残差为

$$\begin{aligned} V_k &= y_k - \hat{y}_k \\ &= H_k x_k - \Delta_k - H_k \hat{x}_k \\ &= -(\mathbf{I}_{n \times n} - H_k K_k) H_{k+1} \tilde{x}_{k+1|k-1} \\ &\quad - (\mathbf{I}_{n \times n} - H_k K_k) \Delta_k, \end{aligned} \quad (18)$$

其中 Δ_{k+1} 为测量真误差, $\tilde{x}_{k+1|k}$ 为预报误差, 误差系数 $R_{k+1} = \mathbf{I}_{n \times n} - H_{k+1} K_{r,k+1}$ 为可靠性矩阵. 在深度加权滤波中, 上式变为

$$\begin{aligned} V_k &= -H_k \tilde{x}_{k|k-1} + H_k \Phi(K_k, H_k \tilde{x}_{k|k-1}) \\ &\quad - \Delta_k + H_k \Phi(K_k, \Delta_k), \end{aligned} \quad (19)$$

可见, 一方面, 合理设计权函数, 则粗差仅会对自身所在通道产生影响; 另一方面, 深度权函数还会影响滤波器的预测能力, 如果过往数据中不含粗差, 则 $\Phi(K_k, H_k \tilde{x}_{k|k-1})$ 会降低滤波器的预测精度, 如果测量通道内含有成片粗差, 则 $\Phi(K_k, H_k \tilde{x}_{k|k-1})$ 通过累积会进一步抑制该粗差的影响.

3 数值验证

本节选取一段典型弹道目标的飞行轨迹为研究对象, 进行算法性能验证.

首先, 按典型布站几何配置 6 台测速雷达, 测速随机误差 0.03 m/s. 该弹道处于平稳段落, 采用动力学模型^[18]和简化 UKF 算法^[19,20]跟踪弹道. 在前 3 个

测量通道的 60~80 s 内加入了 3 个孤立粗差, 第 1 个测量通道 120 和 145 s 附近分别加入了连续 10 个点的幅度为常值和随机大小的粗差. 通道 1 和 2 的测量误差如图 1 所示, 图 2 给出了粗差注入前后弹道估计误差曲线. 由图可见, 含粗差时刻弹道估计误差突然增大, 成片粗差的影响尤其显著. 图中粗差量级较大, 故粗差注入后, 滤波器虽然未出现发散, 但误差累积效应使其精度一直低于无粗差的情形. 图 2 还给出了面向状态粗差检择和深度加权 UKF 的跟踪结果, 深度加权方法的参数选取为 $t=0.8$, $\beta=3$ 和 $\gamma=0.01$. 可见, 两种方法均达到了抑制粗差影响的目的, 其中深度加权方法的估计曲线尤其平滑, 特别是对末端成片粗差的抑制, 显示了其良好的滤波稳健性. 然而在无粗差的初始段落, 深度加权方法在提高稳健性的同时也造成了一定的精度损失, 估计误差的累积使其整体精度低于面向状态的方法. 这与 2.2 节的分析结论是一致的.

其次, 为综合考察算法性能, 图 3 和 4 给出了两组更加符合实际的弹道跟踪数据处理结果, 它们分处于目标的不同飞行段落. 这里的测量数据引入了弹道建模误差、测量系统误差和复杂粗差的综合影响, 其中测量误差的产生参考了一些实际弹道目标测量数据的误差分布特性. 图中的数据进行了归一化处理, 由其变化趋势可见, 在复杂测量条件下, 深度加权方法有更光滑的误差曲线和更高的估计精度, 其滤波性能明显优于传统粗差检择算法.

综上, 系统测量条件较好时, 面向状态的粗差检择算法的估计精度优于深度加权方法, 随着系统观




图 1 存在测量粗差时的测元残差




图 2 测量信息中存在粗差时不同算法的弹道误差




图 3 测量信息中存在复杂系统误差时不同算法的弹道误差(段落 1)




图 4 测量信息中存在复杂系统误差时不同算法的弹道误差(段落 2)

测变复杂,深度加权方法的稳健性优势逐渐体现,总体性能优于估计面向状态方法.因此,根据测量数据质量合理设计滤波器结构和参数,综合利用深度加权和原始样本矩平均思想,应该是实现滤波器稳健性和估计精度折中的有效手段.

4 结束语

本文分析了粗差通过状态预测机制在滤波器中的累积效应,指出在含粗差测元参与滤波计算时,这种误差累积会在一段时间内降低滤波器精度,而滤波器的收敛性则取决于增益矩阵对这种误差累积效果的抑制能力.通过分析,认为 Kalman 滤波器中新息对状态的修正量是一种样本矩平均,进而,引入数

据深度思想改进滤波新息的加权方法,提出了基于深度加权的 Kalman 滤波算法.在稳健性分析的基础上,以弹道目标实时跟踪为应用背景,进行了算法的数值验证.该算法舍弃了针对测元的粗差检择步骤,仅需在 Kalman 滤波框架下增加一个样本深度及权函数的计算步骤,根据相对中心的“远近”,直接调节各测量数据对滤波状态的贡献.这种做法充分利用了同一时刻测元的相关性,以及测元与状态间的相关性,可以有效改善滤波器的稳健性.算法从滤波优化准则和新息加权策略上都体现了对传统 Kalman 滤波实现方法的拓展,具有广泛的应用前景.鉴于序统计量的稳健性,后续研究工作将集中于加强算法的实用性开发和其他序统计量的应用.

参考文献

- 1 王正明,易东云.测量数据建模与参数估计.长沙:国防科技大学出版社,1996
- 2 肖艳军,李建勋.抗野值多速率模型及交互式多传感器状态融合.自然科学进展,2005,15: 1106-1112
- 3 刘也,朱炬波,梁甸农.递推样条滤波的工程化应用研究.宇航学报,2010,31: 2794-2800
- 4 Huber P J. Robust Statistics. New York: John Wiley & Sons, 1981
- 5 欧吉坤.一种检测粗差的新方法——拟准检定法.科学通报,1999,44: 1777-1781
- 6 杨元喜,文援兰.卫星精密轨道综合自适应抗差滤波技术.中国科学 D 辑: 地球科学,2003,33: 1112-1119
- 7 Ting J, Theodorou E, Schaal S. A Kalman filter for robust outlier detection. In: The Proceedings of AeroSense: the 11th International Symposium on Aerospace/Defense Sensing, Simulation and Controls., 2007. 1514-1519
- 8 Zuo Y J, Cui H J. Statistical depth functions and some applications. Adv Math, 2004, 33: 1-25
- 9 Martin R D, Yohai V J. Influence functional for time series. Anal Stat, 1986, 14: 781-819
- 10 Barner K E, Aysal T C. Polynomial weighted median filtering. IEEE T Signal Process, 2006, 54: 636-650
- 11 Lee H, Roberts S J. On-line novelty detection using the Kalman filter and extreme value theory. In: The 19th International Conference on Pattern Recognition. 2008. 1-4
- 12 Atanassov R, Bose P, Couture M, et al. Algorithms for optimal outlier removal. J Discrete Algorithms, 2009, 7: 239-248
- 13 Maiz C S, Miguez J, Djuric P M. Particle filtering in the presence of outliers. In: IEEE/SP 15th Workshop on Statistical Signal Processing, de Madrid, Leganes, Spain, 2009. 33-36
- 14 Sara L P, Juan R. Depth-based inference for functional data. Comput Stat Data Anal, 2007, 51: 4957-4968
- 15 潘晓刚,周海银.卫星轨道确定模型误差的深度加权核估计方法.天文学报,2009,50: 85-97
- 16 Zuo Y J, Cui H J, He X M. On the stahel-Donoho estimator and depth-weighted means of multivariate data. Anal Stat, 2004, 32: 483-499
- 17 刘也,余安喜,朱炬波,等.基于相差拟准检定的实时滤波.科学报通,2012,57: 1074-1080
- 18 Li X R, Jilkov V P. A survey of maneuvering target tracking—Part II: Ballistic target models. In: Proceeding of the 2001 SPIE Conference on Signal and Data Processing of Small Targets. 2001. 559-581
- 19 Julier S J, Uhlmann J K. Reduced sigma point filters for the propagation of means and covariances through nonlinear transformations. In: Proceedings of the 2002 American Control Conference. 2002. 887-892
- 20 Liu Y, Yu A X, Zhu J B, et al. Unscented Kalman filtering in the additive noise case. Sci China: Tech Sci, 2010, 53: 929-941

Research on robust Kalman filter based on depth-weighted

LIU Ye^{1,2}, TANG GeShi², YU AnXi¹, ZHU JuBo³ & LIANG DianNong¹¹ College of Electronic Science and Engineering, National University of Defense Technology, Changsha 410073, China;² Science and Technology on Aerospace Flight Dynamics Laboratory, Beijing Aerospace Control Center, Beijing 100094, China;³ Science College, National University of Defense Technology, Changsha 410073, China

After the analysis of cumulative effect on filter results of gross errors, a new robust filter under the Kalman framework is proposed by improving the weighted mode of the innovation with the depth-weighted algorithm. For the introduction of the calculation of data depth and weighted coefficients, the filter can straightforwardly adjust the contribution of the observations to the filter states without any gross error detections. The depth-weighted step can be viewed as an extension of the optimal criterion (the minimum mean square error, MMSE) in the Kalman filter. By utilizing of the relativity of different observations as well as the relativity between the observations and the states, the new filter can effectively release the disadvantage effect on the filter results of gross errors. Based on the robustness analysis, the feasibility and the efficiency of the new filter are validated by numerical examples finally.

data depth, weighted, filter, gross error

doi: 10.1360/972011-1701

· 动态 ·

私有云用户访问公有云的一轮认证协议

云计算是通过网络为用户提供计算、存储数据、软件、平台等服务的一种计算模式。用户不需要购买相应的基础设施与计算设备等硬件和软件,就可以通过网络从云计算中心获得所需要的服务。但用户在获取云服务之前需要与云计算中心通过双向认证。最近,由杭州师范大学谢琪教授、吴吉义博士等人合作提出的一种云计算认证协议,在云计算应用中具有重要的价值。相关文章《云计算中基于可转换代理签密的可证安全的认证协议》发表于《中国科学:信息科学》2012年第42卷第3期上。

分布在不同地方的不同的公有云能够为用户提供不同的服务。为了安全和支付费用的需要,只有用户与提供服务的公有云之间实现双向认证之后,用户才能接受公有云提供的服务并支付相应的费用。为了解决这个问题,已有的做法有两类:

第一类是用户到不同的公有云中注册,然后在需要服务的时候进行双向认证。其不足是:用户必须记住不同公有云中注册的口令、而公有云则需要维护注册用户的信息,这既不方便,又增加了各种管理成本,同时也为攻击者提供了注册表偷窃攻击的可能,降低了安全性。

第二类是基于代理签名的云计算认证协议,用户只需要到自己所属的私有云中注册,然后在私有云的帮助下,可以实现与公有云的双向认证。其不足:(1)为了保护用户的隐私,每次认证时私有云需要更新用户的公钥;(2)当同一个私有云中的许多用户需要同时登录不同的公有云时,私有云会遇到网络堵塞;(3)因为用户要实现与公有云的双向认证,需要私有云的帮助,这样,私有云与公有云需要预先共享秘密;(4)方案需要多轮认证。

为安全高效地解决这个问题,该研究首先提出了保护用户隐私的、可证明安全的可转换代理签密方案,然后基于该方案设计了可证明安全的云计算认证协议。提出的方案具有以下优点:用户只要到自己的私有云中注册,在不需要私有云的帮助下实现用户与公有云的一轮双向认证;具有保护用户隐私性;抗抵赖性;不需要更新用户的公钥;私有云与公有云不需要预先共享秘密;在随机预言机模型下是可证安全的。

(本刊讯)