DOI: 10. 13382/j. jemi. B2104194

改进 SHAKF 算法消除 IMU 随机误差的研究*

马星河 毕文龙 朱 行 于振子2

(1.河南理工大学电气学院 焦作 454002;2.平煤神马集团煤炭开采利用研究院 平顶山 467000)

摘 要:针对 Sage-Husa 自适应卡尔曼滤波(SHAKF)算法在处理惯性测量单元(IMU)时,随机误差容易随着时间的累积而造成 滤波发散的问题,提出一种改进的 Sage-Husa 自适应鲁棒卡尔曼滤波(MSHARKF)算法。首先对 IMU 构建了合适的模型,再将 SHAKF 与自适应鲁棒卡尔曼滤波(ARKF)相结合并纳入改进的时变噪声估计器,再引入最优自适应比例因子 α_k 对量测方程迭 代更新,最后得出新的预测协方差矩阵代入原方程。实验结果表明,分别通过 Allan 方差和均方根误差(RMSE),对 MEMS-IMU 滤波前后的静/动态数据分析计算得,随机误差噪声分别减小至原数据的 1/10 000 和 1/100。与本文其他算法相比,该方法有 效地对算法滤波发散进行了抑制,进而提高了 IMU 的测量精度和长期稳定性。

Research on improving SHAKF algorithm to eliminate random error of IMU

Ma Xinghe¹ Bi Wenlong¹ Zhu Hang¹ Yu Zhenzi²

(1. School of Electrical Engineering, Henan Polytechnic University, Jiaozuo 454002, China;

2. Research Institute of Coal Mining and Utilization, Pingmei Shenma Group, Pingdingshan 467000, China)

Abstract: Aiming at the problem that when the Sage-Husa adaptive Kalman filter (SHAKF) algorithm is processing inertial measurement units (IMU), random errors are likely to accumulate over time and cause filter divergence, an improved Sage-Husa adaptive robustness Kalman filter (MSHARKF) algorithm is proposed. First, build a suitable model for IMU, then combine SHAKF with adaptive robust Kalman filter (ARKF) and incorporate it into the improved time-varying noise estimator, and then introduce the optimal adaptive scale factor (α_k) to the measurement equation Iteratively update, and finally get a new predicted covariance matrix to be substituted into the original equation. The experimental results show that through the Allan variance and root mean square error (RMSE), the static/dynamic data before and after the MEMS-IMU filtering is calculated and the random error noise is reduced to one ten thousandth and one percent of the original data, respectively. Compared with other algorithms in this paper, this method effectively suppresses the filtering divergence of the algorithm, thereby improving the measurement accuracy and long-term stability of the IMU. **Keywords**: micro-electromechanical inertial measurement unit; Allan standard deviation; adaptive robust Kalman filtering; random error; Sage-Husa adaptive Kalman filtering

0 引 言

近年来,微机电系统的惯性测量单元(MEMS-IMU) 由于其结构简单、成本低廉、体积小等优点,在航姿参考 系统(AHRS)中得到了广泛的应用。但由于其随机噪声和时变偏差较大,在高精度应用领域无法与其他传感器 竞争。此外,温度、磁场、压力和机械应力等因素也会导 致 MEMS-IMU 的动态性能降低。因此,为了提高系统性 能,需要合适的随机误差去噪算法来提高 IMU 性能^[1]。

收稿日期: 2021-04-18 Received Date: 2021-04-18

^{*}基金项目:国家自然科学基金(182300410280)项目资助

针对 IMU 的随机误差处理已有一些方法,如低通滤 波^[2]、神经网络^[34]、经验模式分解(EMD)^[5]和小波变 换^[6-7]等。以上方法虽然在消除 IMU 的白噪声(高频)有 一定优势,但在相关噪声(低频)分析、信号不实时连续 区域以及动态条件下,其处理结果并不令人满意,故上述 方法在 AHRS 系统中是不合适的^[8]。一般来说,卡尔曼 滤波(KF)在减少 IMU 的随机漂移和噪声方面有了较多 应用^[9]。假定状态空间模型及其噪声特性为高斯型,但 其建模并不十分精确,因此 KF 的性能会随着时间的推 移而下降。扩展卡尔曼滤波(EKF)与无迹卡尔曼滤波 (UKF)提高了 KF 在增益和预测调整能力,但存在计算 量大,收益小的缺点,并在实时检测信号方面,表现出较 差的性能^[10]。文献[11]在传统 KF 上,提出了一种自适 应鲁棒卡尔曼滤波(ARKF)的方法,在快速处理变化信 号的噪声,提高异常值测量和滤波收敛速度方面,效果显 著。文献[12]新息序列被用于估计协方差矩阵,要求每 个时期的新息向量的维数及其分布是相同的,这在动态 条件下很难保持。文献[13]系统和量测噪声得以实时 估计,但易造成因新息中混入误差量而导致的状态预测 方程发散,抗干扰能力弱,故精度不高。

为了减少滤波器发散问题,增强滤波算法的鲁棒性。 本文基于自适应鲁棒估计理论,提出了一种改进的 Sage-Husa 自适应鲁棒卡尔曼算法(MSHARKF)。首先确定了 合适的 MEMS-IMU 传感器的状态空间误差模型,其次引 入三段法和更新统计法来确定最优自适应因子 α_k,并控 制状态预测误差方程的干扰^[14]。然后验证了 MSHARKF 算法的收敛性。最后实验室中分别在 IMU 静态和动态 条件下,将 MSHARKF 算法的性能与其他现有算法进行 了比较。计算结果证明,该算法在静态和动态条件下的 随机噪声和漂移误差去噪效果最优。

1 Allan 方差分析与误差模型

1.1 Allan 方差

目前, MIMU 随机误差建模估计方法, 诸如自回归 (AR)、移动平均(MA)和自回归移动平均模型之类的时 间序列模型已经被开发用于构建 IMU 传感器的随机误 差。但在静态条件下的时域和频域中, 分析识别 IMU 随 机误差特征, Allan 方差是首选方法^[15], 如图 1 所示。

在时域分析中, Allan 方差在聚类分析的基础上进行,其中惯性测量单元的原始数据被划分为指定长度的集群(即 M_{AV} 样本)。集群的数量为 K_{AV} ,总数据长度为 N_{AV} ,每个集群都有 M_{AV} 个样本,每个集群的平均值计算如下:

$$\bar{\omega}_{k}(M_{AV}) = \frac{1}{M_{AV}} \sum_{i=1}^{M_{AV}} \omega_{(k-1)M_{AV}+i}$$
(1)



slope and random error

式中: $\hat{\omega}_{k}(M_{AV})$ 是时间步长测量的平均值, $k = 1, 2, \cdots$, K_{AV} 。Allan 方差是根据指定两个相关时间的连续聚类平 均值计算的:

$$\sigma^{2}(\tau) = \frac{\sum_{k=1}^{K_{AV}-1} (\bar{\omega}_{k+1}(M_{AV}) - \bar{\omega}_{k}(M_{AV}))^{2}}{2(K_{AV}-1)}$$
(2)

式中: $\tau = \frac{M_{AV}}{f_s}$ 是相关时间; $\sigma^2(\tau_{M_{AV}})$ 是量化噪声的 Allan 方差; f_s 是采样频率。

1.2 IMU 噪声模型

MEMS-IMU本身存在偏差,其固定步长积分误差会被累积,造成AHRS的位置和速度输出的显著漂移。因此,需要开发出新的惯性测量单元传感器噪声模型,提升导航精度。

一般来说,角度随机游走(ARW)和偏差不稳定性 (BI)是两种主要的随机噪声^[16],其标准噪声模型可表 示为:

$$y_{\text{arw}}(k) = y_{\text{arw}}(k-1) + \frac{ARW}{\sqrt{(\Delta T)}}u_{\text{arw}}$$
(3)

$$y_{bi}(k) = (1 - \zeta \Delta T) y_{arw}(k - 1) + \beta \sqrt{\Delta T} \cdot BI \cdot u_{bi}$$

$$k = 1, 2, \dots, N$$
(4)

式中: β 为噪声相关系数。系统状态空间模型可以用噪 声模型表示如下:

$$z_{k} = \begin{bmatrix} 1 & 1 \end{bmatrix} \begin{bmatrix} y_{are}(k-1) \\ y_{bi}(k-1) \end{bmatrix} + \begin{bmatrix} 1 & 1 \end{bmatrix} \begin{bmatrix} u_{are}(k-1) \\ u_{bi}(k-1) \end{bmatrix}$$
(5)

$$\mathbf{x}_{k} = \begin{bmatrix} y_{arw}(k) \\ y_{bi}(k) \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ (1 - \beta \Delta T) & 0 \end{bmatrix} \begin{bmatrix} y_{arw}(k - 1)) \\ y_{bi}(k - 1) \end{bmatrix} + \begin{bmatrix} \frac{ARW}{\sqrt{(\Delta T)}} & 0 \\ 0 & \beta \sqrt{\Delta T} \cdot BI \end{bmatrix} \begin{bmatrix} u_{arw}(k - 1)) \\ u_{bi}(k - 1) \end{bmatrix}$$
(6)

ARW 与 BI 的噪声相关性和方差如下:

$$\begin{cases} E[u_{are}] = E[u_{bi}] = 0\\ E\left[\begin{bmatrix}u_{are}\\u_{bi}\end{bmatrix}[u_{are}&u_{bi}\end{bmatrix}^{\mathrm{T}}\right] = \begin{bmatrix}\sigma_{are}^{2}(\tau) & 0\\ 0 & \sigma_{bi}^{2}(\tau)\end{bmatrix}\delta_{kl} \end{cases}$$
(7)

式中:ARW 与 BI 噪声为高斯白噪声并且在统计上彼此 独立。 ΔT 是采样时间, $\sigma_{arw}^2(\tau)$ 和 $\sigma_{bi}^2(\tau)$ 分别是 ARW 和 BI 的方差, δ_{kl} 为具有筛选意义的克罗内克德尔塔 函数。

$$\delta_{kl} = \begin{cases} 1, & k = l \\ 0, & k \neq l \end{cases}$$
(8)

2 理论分析

2.1 改进 Sage-Husa 自适应卡尔曼滤波(SHAKF)

针对状态和测量噪声的统计特性未知的情况,采用 Sage-Husa 自适应卡尔曼滤波,加入时变噪声估计器,将 解算得到的当前时刻的状态值、误差方差、增益值等作为 下一时刻的初始值,不断进行迭代。本文在时变噪声估 计器中,采用指数加权平均多重遗忘因子来观测噪声协 方差。与单一衰落因子相比,多因子的调谐能力更有效 率^[17],其数学模型为:

$$\begin{aligned} \boldsymbol{X}_{k} &= \boldsymbol{A}\boldsymbol{X}_{k-1} + \boldsymbol{W}_{k-1} \\ \boldsymbol{Z} &= \boldsymbol{H}\boldsymbol{X} + \boldsymbol{V} \end{aligned} \tag{9}$$

式中: W_{k-1} 和 V_k 分别为状态噪声矩阵和测量噪声矩阵。 时变噪声统计递归估计器为:

$$\hat{\boldsymbol{r}}_{k+1} = (1 - d_k)\hat{\boldsymbol{r}}_k + d_k(\boldsymbol{z}_k - \boldsymbol{H}\hat{\boldsymbol{x}}_k)$$

$$\hat{\boldsymbol{R}}_{k+1} = (1 - d_k)\hat{\boldsymbol{R}}_k + d_k(\boldsymbol{v}_k\boldsymbol{v}_k^{\mathrm{T}} - \boldsymbol{H}\hat{\boldsymbol{P}}_k\boldsymbol{H}^{\mathrm{T}})$$

$$\hat{\boldsymbol{q}}_{k+1} = (1 - d_k)\hat{\boldsymbol{q}}_k + d_k(\boldsymbol{x}_k - \boldsymbol{A}_k)$$
(10)
$$\hat{\boldsymbol{Q}}_{k+1} = (1 - d_k)\hat{\boldsymbol{Q}}_k + d_k(\boldsymbol{K}_k\boldsymbol{v}_k\boldsymbol{v}_k^{\mathrm{T}}\boldsymbol{K}_k^{\mathrm{T}} + \hat{\boldsymbol{P}}_k - \hat{\boldsymbol{A}}\hat{\boldsymbol{P}}_k\boldsymbol{A}^{\mathrm{T}})$$

式中: $\hat{\mathbf{r}}_{k+1}$ 和 $\hat{\mathbf{q}}_{k+1}$ 分别是对测量误差和系统误差的数学期 望的估计; $\hat{\mathbf{R}}_{k+1}$ 和 $\hat{\mathbf{Q}}_{k+1}$ 是测量误差和系统误差方差的估 计值; d_k 为加权系数。

$$d_{k} = (1 - b) / (1 - b^{(k+1)}) \in (0, 1)$$
(11)

从优化滤波器性能的角度来考虑,采用指数加权平均算法选择遗忘因子 b,旧数据利用率以 b 的指数次方衰弱^[18]:

$$\begin{cases} b^{0} + b^{1} + \dots + b^{k} = \frac{1 - b^{k+1}}{1 - b} \\ (b^{0} + b^{1} + \dots + b^{k}) \frac{1 - b}{1 - b^{k+1}} = 1 \end{cases}$$
(12)

得出的新息序列协方差为:

$$\hat{\boldsymbol{D}}_{0,k+1} = d_k \boldsymbol{\gamma}_k \boldsymbol{\gamma}_k^{\mathrm{T}} + (1 - d_k) d_{k-1} \sum_{k}^{i=1} \cdot b^{k-1-i} \boldsymbol{\gamma}_i \boldsymbol{\gamma}_i^{\mathrm{T}} (13)$$

$$\mathbf{I}(10) \sim (13) \text{ } \underline{\mathbf{1}} \mathbf{\mathbf{6}} \mathbf{\mathbf{6}} \mathbf{\mathbf{6}} \mathbf{\mathbf{7}} \mathbf{\mathbf{1}} \mathbf{\mathbf{1}} \mathbf{\mathbf{7}} \mathbf{\mathbf{7}}$$

子改进的 SHAKF 算法,其输出为:

$$\hat{\boldsymbol{x}}_{k} = \hat{\boldsymbol{x}}_{k-1} + \boldsymbol{K}_{k}\boldsymbol{v}_{k}$$

$$\hat{\boldsymbol{x}}_{k}^{-} = \boldsymbol{A}\hat{\boldsymbol{x}}_{k} + \hat{\boldsymbol{q}}_{k}$$

$$\boldsymbol{e}_{k} = \boldsymbol{z}_{k} - \boldsymbol{H}\hat{\boldsymbol{x}}_{k}^{-} - \hat{\boldsymbol{r}}_{k}$$

$$\boldsymbol{K}_{k} = \hat{\boldsymbol{P}}_{k}^{-}\boldsymbol{H}^{\mathrm{T}} [\boldsymbol{H}\hat{\boldsymbol{P}}_{k}^{-}\boldsymbol{H}^{\mathrm{T}} + \hat{\boldsymbol{R}}_{k}]^{-1}$$

$$\hat{\boldsymbol{P}}_{k}^{-} = \boldsymbol{A}\hat{\boldsymbol{P}}_{k}^{-}\boldsymbol{A}^{\mathrm{T}} + \hat{\boldsymbol{Q}}_{k}$$

$$\hat{\boldsymbol{P}}_{k} = (\boldsymbol{I} - \boldsymbol{K}_{k}\boldsymbol{H})\hat{\boldsymbol{P}}_{k}^{-} \qquad (14)$$

初始状态及其误差协方差矩阵分别为 \hat{x}_0 和 P_0, K_k 是自适应卡尔曼的增益。

2.2 ARKF

一般来说, ARKF 用于减少白噪声和有色噪声, 以抑制来自高斯分布数据的观测误差的影响^[19]。引入自适应因子 α_k 用于来调整滤波算法,更新测量方程为:

$$\boldsymbol{K}_{k} = \frac{1}{\alpha_{k}} \hat{\boldsymbol{P}}_{k}^{-} \boldsymbol{H}^{\mathrm{T}} \left[\frac{1}{\alpha_{k}} \boldsymbol{H} \hat{\boldsymbol{P}}_{k}^{-} \boldsymbol{H}^{\mathrm{T}} + \hat{\boldsymbol{R}}_{k} \right]^{-1}$$

$$\hat{\boldsymbol{x}}_{k} = \hat{\boldsymbol{x}}_{k}^{-} + \boldsymbol{K}_{k} (\boldsymbol{z}_{k} - \boldsymbol{H} \hat{\boldsymbol{k}}^{-}) \qquad (15)$$

$$\hat{\boldsymbol{P}}_{k} = \frac{1}{\alpha_{k}} (\boldsymbol{I} - \boldsymbol{K}_{k} \boldsymbol{H}) \hat{\boldsymbol{P}}_{k}^{-}$$

3 MSHARKF

本文基于改进的 SHARKF 与 ARKF,提出改进的 Sage-Husa 自适应鲁棒卡尔曼滤波。引入"遗忘因子"来 减轻累积模型误差对系统稳定性的影响。引入"自适应 比例因子"来估计和校正实际系统中的未知时变噪声。 在所提出的算法中,自适应因子 α_k 使用三段法来选择最 优自适应比例因子,并对选择阈值进行统计更新。

3.1 选择自适应比例因子

三段法来选择最佳自适应比例因子 α_k ,使得预测方程、量测方程的理论值几乎等于滤波器的实际估计输出。 此外, α_k 还能控制由异常值测量引起的预测状态误差方程的干扰^[20]。 α_k 选择如下:

$$\alpha_{k} = \begin{cases} 1, & |\Delta \widetilde{X}_{0}| \leq c_{0} \\ \frac{c_{0}}{|\Delta \overline{X}_{k}|} \left(\frac{c_{1} - |\Delta \widetilde{X}_{k}|}{|\Delta \widetilde{X}_{k}|} \right), & c_{0} \leq |\Delta \widetilde{X}_{0}| \leq c_{1} \\ 0, & |\Delta \widetilde{X}_{k}| \geq c_{1} \end{cases}$$

$$(16)$$

式中: $\Delta X_k = \hat{x}_k - \hat{x}_k^-$ 是预测状态向量的残差向量; $1 \le C_0 \le 1.5 \ \pi \ 3 \le C_1 \le 4.5 \ E两个设计常数的取值范围。状态 预测误差模型的更新统计 <math>|\Delta X_k|$ 表示为:

$$|\Delta \widetilde{X}_{k}| = \frac{\|\overline{V}_{k}\|}{\sqrt{C_{v_{k}}}}$$
(17)

式中: $\|\overline{V}_{k}\|$ 和 $C_{v_{k}}$ 分别是新息向量的范数和协方差矩 阵。算法的预测更新方程和量测更新方程为:

$$\hat{\boldsymbol{x}}_{k}^{-} = \boldsymbol{A}\hat{\boldsymbol{x}}_{k-1} + \hat{\boldsymbol{q}}_{k}$$

$$\hat{\boldsymbol{P}}_{k}^{-} = \boldsymbol{A}\hat{\boldsymbol{P}}_{k-1}^{-}\boldsymbol{A}^{\mathrm{T}} + \hat{\boldsymbol{Q}}_{k}$$

$$\boldsymbol{K}_{k} = \frac{1}{\alpha_{k}}\hat{\boldsymbol{P}}_{k}^{-}\boldsymbol{H}^{\mathrm{T}}\left[\frac{1}{\alpha_{k}}\boldsymbol{H}\hat{\boldsymbol{P}}_{k}^{-}\boldsymbol{H}^{\mathrm{T}} + \hat{\boldsymbol{R}}_{k}\right]^{-1}$$

$$\hat{\boldsymbol{x}}_{k} = \left[\boldsymbol{A}^{\mathrm{T}}\hat{\boldsymbol{P}}_{k}^{-}\boldsymbol{A} + \alpha_{k}\hat{\boldsymbol{P}}_{k}^{-}\right]^{-1}(\boldsymbol{A}^{\mathrm{T}}\hat{\boldsymbol{P}}_{k}^{-}\boldsymbol{z}_{k} + \alpha_{k}\hat{\boldsymbol{P}}_{k}^{-}\hat{\boldsymbol{x}}_{k}^{-})$$

$$\boldsymbol{e}_{k} = \boldsymbol{z}_{k} - \boldsymbol{H}\hat{\boldsymbol{x}}_{k}^{-} - \hat{\boldsymbol{r}}_{k}$$

$$\hat{\boldsymbol{P}}_{k} = \frac{1}{\alpha_{k}}(\boldsymbol{I} - \boldsymbol{K}_{k}\boldsymbol{H})\hat{\boldsymbol{P}}_{k}^{-} \qquad (18)$$

式中: \hat{R}_{k} 为式(10)评估更新的估计测量噪声协方差矩阵。提出的算法的完整流程如图 2 所示。 α_{k} 在每次迭代中被缩放和更新到卡尔曼增益和预测误差协方差方程中。



图 2 MSHARKF 算法流程 Fig. 2 MSHARKF algorithm flow chart

3.2 MSHARKF 收敛性分析

MSHARKF 的状态空间方程如式(9),推导如下。 1)系统矩阵 F_k 对于所有 k 都是非奇异的(可逆的)。 2)假设的初始协方差如下:

$$\widetilde{X}_{0}^{\mathsf{T}} \boldsymbol{P}_{0}^{-1} \widetilde{X}_{0} \leq \boldsymbol{v}_{0} \widetilde{X}_{0}^{2}$$

$$\tag{19}$$

3) 对于所有 k, 状态误差协方差矩阵满足如下不等式:

$$\widetilde{\boldsymbol{X}}_{k}^{\mathrm{T}}\boldsymbol{P}_{k}^{-1}\widetilde{\boldsymbol{X}}_{k} \geq \boldsymbol{\eta}_{k}\widetilde{\boldsymbol{X}}_{k}^{2}$$

$$(20)$$

4) 假设的过程和测量噪声协方差矩阵有如下限制;

$$\boldsymbol{Q}_{k-1} \geq E[\boldsymbol{w}_{k-1}\boldsymbol{w}_{k-1}^{\mathrm{T}}]$$
(21)

$$\mathbf{R}_{k-1} \geq E[\mathbf{v}_{k-1}\mathbf{v}_{k-1}^{\mathrm{T}}]$$

那么通过下式,可以得出,估计误差的期望值在均方 误差范围内的概率为1,故滤波器收敛。

$$E\widetilde{X}_{k}^{2} \leq \frac{v_{0}}{\eta_{k}} E\widetilde{X}_{k}^{2} \prod_{k=1}^{i=0} (1 - \alpha_{i}) + \frac{1}{\eta_{k}} \sum_{k=1}^{i=0} \left[\prod_{i=1}^{j=1} (1 - \alpha_{k-j}) \right]$$

$$(22)$$

其中时变参数 α_k 由式(16)给出。

4 实验验证与分析

为了验证本文提出的 MSHARKF 的有效性,使用了 Xsens MTi 10 系列微机电系统惯性测量单元器件,该器 件由三轴 MEMS 陀螺仪和加速度计组成。对预热之后的 传感器以 100 Hz 为采样频率,采样 1 h,将采集到的数据 通过串口传送到 PC,如图 3 所示。图 4 和 5 所示为采集 的 IMU 输出的部分原始静态数据。



图 3 惯性测量单元数据采集 Fig. 3 IMU data acquisition





图 5 MEMS 三轴加速度计原始信号

Fig. 5 MEMS three-axis accelerometer raw signal

4.1 静态性能测试分析

在进行 Allan 方差分析之前,从惯性测量单元原始测量值中去除信号的平均值。具有白噪声特征的 ARW 噪声和内部电子元件的沉降和传感器的外部干扰产生的 BI 是 MEMS-IMU 原始数据中的最主要的噪声。使用 Allan 分析,对 MEMS-IMU 传感器主要的噪声进行识别和量化,并与各个算法 Allan 方差分析得出数值结果进行对比,如表1 所示。所有算法的对比与 Allan 方差分析如图 6~11 所示。

在 MSHARKF 算法中,采取经验法与试错法相结合,确定初始值为过程噪声 *R* 和量测 *Q* 噪声分别取为 0.098 和 0.000 1。初始预测状态 *X*。和它的误差协方差 *P*。分

表 1 静态条件下 MEMS 陀螺仪、加速度计 *X*、*Y*、*Z* 三轴的 Allan 标准差分析结果 Table 1 Allan standard deviation analysis results of MEMS gyroscope and accelerometer *X*, *Y*,











Fig. 7 MEMS gyroscope Y-axis signal filtering comparison chart and Allan variance chart







图 9 MEMS 加速度计 X 轴信号滤波对比和 Allan 方差图

Fig. 9 MEMS accelerometer X-axis signal filtering comparison chart and Allan variance chart



图 10 MEMS 加速度计 Y 轴信号滤波对比和 Allan 方差图

Fig. 10 MEMS accelerometer Y-axis signal filtering comparison chart and Allan variance chart

别选作 0 和 1。每次迭代都更新量测协方差矩阵 R 和自适应比例因子 α_k ,以预测信号中的新息量。为了能够滤波平滑,设置最优算法所需的两个常数 $C_0 = 1.2, C_1 = 4.5$ 。从 Allan 图分析来看, MSHARKF 算法的性能与其他现有算法 SHAKF 和 ARKF 算法在滤波前后的性能进行了比较。

Allan标准差计算主要噪声 ARW 和 BI 结果如表 1 所示,对比表 1 中 MEMS 陀螺仪三轴在各个算法得出的 标准差,对陀螺仪输出滤波后得到的 IMU 三轴姿态误差 的均值和标准差均优于未滤波前获取的结果,在使用 MSHARKF 算法时,标准差最小,减少至原始数据的 1/100,说明随机误差消除的效果最好。

4.2 动态性能测试分析

Allan 标准差得到的误差项拟合结果对相关时间非 常敏感,往往是微小的时间变化而造成拟合误差变大,故 可靠性差。均方根误差(RMSE)相当于 L2 范数,对异常 值更为敏感,即如果预测值与实际值相差较大,RMSE 值 会很大,因此适用于动态条件下的 IMU 数据分析。

将 MEMS-IMU(Xsens MTi 10 系列)安装在无人机系统上。记录无人机跟踪轨迹时的体固定角速度和线性加





速度。在动态数据中,本文从 Sage-Husa 自适应卡尔曼、 鲁棒卡尔曼和提出的 MSHARKF 中获得噪声和去噪声的 信号。并采用 RMSE 用作评估标准,以测试动态条件下 的滤波器性能。计算结果如表 2 所示。从表 2 可以看 出,MSHARKF 算法反应更加灵敏,结果也更为平稳,而 且有效的降低了 IMU 中的零偏不稳定性与角度随机 游走。



Fig. 13 MEMS accelerometer linear acceleration

表 2 MEMS-IMU 传感器的均方根误差 Table 2 Root mean square error of MEMS-IMU sensor

	陀螺仪 RMSE/(°/s)	加速度计 RMSE/(m·s ⁻²)
原始数据	5.40×10 ⁻²	6.50×10 ⁻²
SHAKF	1.34×10^{-2}	1.30×10^{-2}
ARKF	2. 10×10^{-3}	4.30×10 ⁻³
MSHARKF	1.50×10^{-3}	3. 10×10^{-3}

5 结 论

本文提出了一种改进的 MSHARKF,采用新的惯性

测量单元传感器噪声模型,确定了以ARW噪声和BI噪声为MEMS-IMU原始数据中的两种主要随机噪声。引入加权平均多重遗忘因子与可更新的自适应比例因子,对噪声进行削弱与控制。在实验中,SHAKF、ARKF与MSHARKF算法对比,在静态条件下,从Allan标准差中得到ARW噪声源减少为原来的1/100,BI噪声减少为原来的1/10。在动态条件下,传感器在MSHARKF算法下的均方根误差最小,预测精度最高。从以上结果中得出结论,本文所提出的MSHARKF算法在静态和动态条件下,均具有良好的性能,减小了传IMU传感器随机误差,大大提升了IMU的精度。

参考文献

 [1] 孙伟,文剑,张远,等. MEMS 陀螺仪随机误差的辨识 与降噪方法研究[J]. 电子测量与仪器学报,2017, 31(1):15-20.

SUN W, WEN J, ZHANG Y, et al. Research on random error identification and noise reduction method of MEMS gyroscope [J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(1):15-20.

 [2] 王磊,吴殿昊,张永德,等.基于磁电编码器 MEMS 陀 螺标定及高阶滤波的动态滞后补偿方法研究[J].仪 器仪表学报,2020,41(8):110-119.

> WANG L, WU D H, ZHANG Y D, et al. Research on dynamic lag compensation method based on magnetoelectric encoder MEMS gyroscope calibration and high-order filtering [J]. Chinese Journal of Scientific Instrument, 2020, 41(8): 110-119.

[3] 李荣冰,鄢俊胜,刘刚,等. 基于 LSTM 深度神经网络的 MEMS-IMU 误差模型及标定方法[J]. 中国惯性技术 学报,2020,28(2):165-171.

> LI R B, YAN J SH, LIU G, et al. MEMS-IMU error model and calibration method based on LSTM deep neural network [J]. Journal of Chinese Inertial Technology, 2020,28(2):165-171.

[4] 乔文超,王红雨,王鸿东. 基于 BP 神经网络的无人机

IMU 多传感器冗余的补偿算法[J]. 电子测量与仪器 学报,2020,34(12):19-28.

QIAO W CH, WANG H Y, WANG H D. Compensation algorithm for UAV IMU multi-sensor redundancy based on BP neural network [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34 (12): 19-28.

[5] 杨菊花,刘洋,陈光武,等. 基于改进 EMD 的微机械陀 螺随机误差建模方法[J]. 仪器仪表学报, 2019, 40(12):196-204.

YANG J H, LIU Y, CHEN G W, et al. Random error modeling method of micromechanical gyroscope based on improved EMD [J]. Chinese Journal of Scientific Instrument, 2019, 40(12): 196-204.

[6] 刘菲,任章,李清东.基于小波方差的 MEMS IMU 随机 误差模型间接估计方法[J].中国惯性技术学报, 2016,24(1):77-82.

> LIU F, REN ZH, LI Q D. Indirect estimation method of MEMS IMU random error model based on wavelet variance [J]. Journal of Chinese Inertial Technology, 2016,24(1):77-82.

 [7] 刘春,刘滔,张海燕,等.小波变换法在姿态解算中的应用[J].电子测量与仪器学报,2021,35(1): 183-190.

> LIU CH, LIU T, ZH H Y, et al. Application of wavelet transform method in attitude calculation [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(1): 183-190.

- [8] WDESILVA C. A systematic approach for instrumentation of a mechatronic system [J]. Instrumentation, 2019, 6(1):116-136.
- [9] 严恭敏,邓瑀. 传统组合导航中的实用 Kalman 滤波技术评述[J]. 导航定位与授时,2020,7(2):50-64.
 YAN G M, DENG Y. A review of practical Kalman filtering technology in traditional integrated navigation [J].
 Navigation Positioning and Timing, 2020, 7(2): 50-64.
- [10] 班朝,任国营,王斌锐,等. 基于 IMU 的机器人姿态自 适应 EKF 测量算法研究[J]. 仪器仪表学报,2020, 41(2):33-39.

BAN CH, REN G Y, WANG B R, et al. Research on robot attitude adaptive EKF measurement algorithm based on IMU[J]. Chinese Journal of Scientific Instrument, 2020, 41(2): 33-39.

- [11] KANG Y Y, ZHAO L, CHENG J H, et al. A novel grid SINS/DVL integrated navigation algorithm for marine application[J]. Sensors, 2018, doi:10.3390/s18020364.
- [12] 郭士荦,吴苗,许江宁,等. 自适应渐消卡尔曼滤波及 其在 SINS 初始对准中的应用[J]. 武汉大学学报(信

息科学版),2018,43(11):1667-1672,1680.

GUO SH L, WU M, XU J N, et al. Adaptive fading Kalman filter and its application in SINS initial alignment[J]. Journal of Wuhan University (Information Science Edition), 2018, 43(11): 1667-1672,1680.

[13] 傅军,韩洪祥.改进的 MEMS 陀螺随机噪声自适应 Kalman 实时滤波方法[J].光子学报,2019,48(12): 183-191.

> FU J, HAN H X. Improved MEMS gyroscope random noise adaptive Kalman real-time filtering method [J]. Acta Photonica Sinica, 2019, 48(12): 183-191.

[14] 张旭,崔乃刚,王小刚,等. 一种鲁棒自适应容积卡尔 曼滤波方法及其在相对导航中的应用[J]. 兵工学报, 2018,39(1):94-100.

ZHANG X, CUI N G, WANG X G, et al. A robust adaptive volume Kalman filter method and its application in relative navigation [J]. Acta Armamentarii, 2018, 39(1):94-100.

 [15] 王可东,武雨霞. 一种 MEMS 陀螺随机漂移的高精度 建模方法[J]. 北京航空航天大学学报,2016,42(8): 1584-1592.

WANG K D, WU Y X . A high-precision modeling method for MEMS gyroscope random drift [J]. Journal of Beijing University of Aeronautics and Astronautics, 2016, 42(8):1584-1592.

- [16] 史露强,何怡刚,罗旗舞,等. 基于传感器数据融合的 倾斜角度测量方法研究[J]. 仪器仪表学报,2017, 38(7):1683-1689.
 SHILQ, HEYG, LUOQW, et al. Research on tilt angle measurement method based on sensor data fusion [J]. Chinese Journal of Scientific Instrument, 2017, 38(7): 1683-1689.
- [17] ZHA F, GUO S L, LI F. An improved nonlinear filter based on adaptive fading factor applied in alignment of SINS[J]. Optik, 2019, 184 : 165-176.
- [18] 刘树聃.基于多重渐消因子强跟踪非线性滤波的故障参数联合估计[J].电子测量与仪器学报,2019,33(1):164-170.
 LIU SH Y. Joint estimation of fault parameters based on strong tracking nonlinear filtering with multiple fading factors [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(1): 164-170.
- [19] XU S, ZHOU H, WANG J, et al. SINS/CNS/GNSS integrated navigation based on an improved federated Sage-Husa adaptive filter [J]. Sensors, 2019, 19(17):3812.
- [20] 彭美康,郭蕴华,汪敬东,等.基于鲁棒容积卡尔曼滤 波的自适应目标跟踪算法[J].控制理论与应用,

2020,37(4):793-800.

PENG M K, GUO Y H, WANG J D, et al. Adaptive target tracking algorithm based on robust volume Kalman filter[J]. Control Theory and Applications, 2020, 37(4): 793-800.

作者简介



马星河,2000年于焦作工学院获得学 士学位,2004年于河南理工大学获得硕士 学位,2007年于中国矿业大学获得博士学 位,现为河南理工大学副教授,主要研究方 向为传感技术与自动化检测技术。 E-mail:maxinghe@hpu.edu.cn

Ma Xinghe received his B. Sc. degree from Jiaozuo Institute of Technology in 2000, M. Sc. degree from Henan University of Technology in 2004, and Ph. D. degree from China University of Mining and Technology in 2007, respectively. Now he is an associate professor at Henan University of Technology. His main research interests include sensor technology and automated

detection technology.



毕文龙,2019 年于河南理工大学获得 学士学位,现为河南理工大学硕士研究生, 主要研究方向为传感设备在线监控。 E-mail:871629983@qq.com

Bi Wenlong received his B. Sc. degree from Henan University of Technology in 2019.

Now he is a M. Sc. candidate at Henan University of Technology. His main research interest includes online monitoring of sensor equipment.



朱行,2019年于河南理工大学获得学 士学位,现为河南理工大学硕士研究生,主 要研究方向为传感器数据融合。

 $\operatorname{E-mail:} 3304887235@ \ \mathrm{qq.} \ \mathrm{com}$

Zhu Hang received his B. Sc. degree from Henan University of Technology in 2019.

Now he is a M. Sc. candidate at Henan University of Technology. His main research interest includes sensor data fusion.