

# 误差状态卡尔曼滤波的视觉惯性 自适应融合定位方法研究



王鹏<sup>1,2</sup>,王大为<sup>1</sup>,何晶晶<sup>1</sup>

1. 天津大学 精密测试技术及仪器全国重点实验室, 天津 300072

2. 航空工业洛阳电光设备研究所 光电控制重点实验室, 河南 洛阳 471000

**摘要:**头盔瞄准具(HMS)是近年来新一代战斗机飞行员的辅助瞄准设备,能够帮助飞行员增强战场态势感知能力,对敌方目标进行快速、精准打击。其能正常工作的关键是获取飞行员头部相对于运动飞机的姿态参数。本文结合头盔瞄准具这一应用场景研究了视觉组合姿态测量关键技术。视觉惯性组合定位能够实现目标位姿测量方法的优势互补,而由于标称噪声矩阵无法绝对准确预测,融合算法的鲁棒性、精度有待进一步提升。针对这一问题,本文提出一种误差状态卡尔曼滤波框架下基于变分贝叶斯推断的视觉惯性自适应融合方法。首先,对于过程噪声使用逆威沙特(Wishart)分布进行建模,之后通过引入隐变量分解一步预测协方差,并结合变分贝叶斯推断实现了对过程噪声协方差矩阵的在线估计。试验证明,在复杂运动及标称噪声协方差矩阵偏移较大的测量条件下,所提位姿测量算法具有较高的精度与鲁棒性,能够完成对靶标的快速、高精度跟踪。

**关键词:** 自适应; 误差状态卡尔曼滤波; 变分贝叶斯; 视觉惯性融合; 姿态测量

中图分类号: TP212.9

文献标识码: A

DOI: 10.19452/j.issn1007-5453.2024.04.014

准确、快速地获取运动物体的姿态在航空航天和工业制造等领域都有着极为重要的意义<sup>[1-3]</sup>。头盔瞄准具(HMS)是近年来新一代战斗机飞行员的辅助瞄准设备,其安装在飞行员头盔上,并将作战信息投射到头部显示器中。HMS能够帮助飞行员增强战场态势感知能力,是当今智能化作战中的重要装备。在目标瞄准的过程中,火控计算机根据飞行员头部的瞄准线指向控制军械部分的武器线指向,从而完成武器的快速瞄准。在这个过程中,测量飞行员头部相对于飞机坐标系的姿态角是确定瞄准线的关键<sup>[4]</sup>。为了更好地估计飞行员头部的姿态,可以通过融合来自不同传感器的数据,从而充分利用不同传感器的优势进行互补。目前常见的一种融合方案是将单目相机与惯性器件组成测量系统:视觉测量具有较高的精度以及长期的稳定性,但受视场及曝光时间等条件的限制,其跟踪范围较小且测量频率较低;而惯性器件的测量频率高且

跟踪范围广,但由于器件的硬件限制,其输出存在零偏,积分运算会使测量误差随时间不断增大。二者组成一个测量系统可以弥补相互的缺点,实现高精度、高频率、广范围的物体跟踪及位姿测量<sup>[5-8]</sup>。

对于包含惯性传感器的测量系统,误差状态卡尔曼滤波器(ESKF)是一种流行的多源数据融合算法,具有许多独特的优点<sup>[9-12]</sup>。首先,误差状态描述避免了过度参数化导致的问题。其次,由于误差状态通常较小,因此对参数的一阶线性化带来的线性化误差较小。最后,由于误差状态变化缓慢,因此滤波校正可以以较低速率进行。

在误差状态卡尔曼滤波过程中,噪声协方差矩阵的设定对滤波器性能至关重要,噪声信息的不准确会导致算法精度下降甚至发散。由于视觉测量具有长期稳定性,因此测量噪声协方差矩阵可以预设为标称值,并假定其在测量过程中不发生变化。但由于惯性测量单元(IMU)的测量

收稿日期: 2023-09-06; 退修日期: 2024-01-17; 录用日期: 2024-02-21

基金项目: 航空科学基金(201951048002)

引用格式: Wang Peng, Wang Dawei, He Jingjing. Vision inertia adaptive fusion method for attitude determination based on error state Kalman filter[J]. Aeronautical Science & Technology, 2024, 35(04): 104-111. 王鹏, 王大为, 何晶晶. 误差状态卡尔曼滤波的视觉惯性自适应融合定位方法研究[J]. 航空科学技术, 2024, 35(04): 104-111.

结果易受环境干扰,并考虑数据通信错误及传感器自身突变等特殊情况,过程噪声协方差矩阵需要根据实际情况进行自适应调整。

对噪声协方差矩阵自适应估计的传统方法大致分为相关性法、协方差匹配法、最大似然估计法和贝叶斯法<sup>[13]</sup>4类。当前也有学者使用深度学习及深度神经网络方法估计IMU的噪声参数<sup>[14-16]</sup>,该方法需要大量的标记数据进行训练并且需要更多的计算资源,相比传统卡尔曼滤波明确的数学模型和简单的递归方法,其工作机制的可理解性及模型的泛化性还有待验证。

相关法利用系统输出结果或更新值的自相关性来调整噪声协方差,主要适用于常系数线性系统,其缺点是无法保障噪声协方差矩阵的正定型并且计算量较大<sup>[17-18]</sup>。协方差匹配法使用更新值或残差序列来计算更新值或残差的协方差,并将获得的协方差与其理论值进行匹配,以估计噪声协方差,但该方法有不收敛的可能<sup>[19-20]</sup>。基于最大似然(ML)的自适应滤波器通过最大化似然函数估计协方差噪声矩阵,如期望最大化(EM)方法<sup>[13]</sup>,但该方法需要足够的先验数据才能有较好的滤波效果。贝叶斯方法是最通用和最全面的自适应噪声滤波方法<sup>[20]</sup>。Sarkka<sup>[21]</sup>为基于变分贝叶斯(VB)推理的自适应滤波奠定了基础。通过将系统状态和噪声协方差的分布近似为高斯分布和逆威沙特(IW)分布的乘积,可以推断噪声协方差以及系统状态的估算值。

VB方法由于其估计未知噪声统计方面的效率及完备的数学基础而吸引了许多学者的兴趣,并开发了许多基于VB的滤波器<sup>[20-25]</sup>。然而系统状态和过程噪声协方差的联合后验分布的概率模型是非共轭的<sup>[23]</sup>。因此,大多数基于VB的自适应算法只能在线估计未知的测量噪声协方差,并假设过程噪声协方差是已知并且恒定的<sup>[21-24]</sup>。为了减轻不准确的过程噪声协方差的不利影响,黄玉龙等<sup>[22]</sup>提出了间接估计预测误差协方差而不是过程噪声协方差的算法。然而,在每个时间步长处利用不准确的标称过程噪声协方差,这可能导致精度下降。最近,黄玉龙等<sup>[22]</sup>提出了一种基于滑动窗口状态矢量平滑后验分布近似的自适应算法。然而由于惯性器件的输出频率远高于视觉输出频率,该方法并不适合视觉惯性组合测量系统。

目前虽然已经有许多基于变分贝叶斯理论的自适应滤波器,但它们大多是基于传统的卡尔曼滤波的框架导出的,很少有文献讨论ESKF中自适应方法的滤波性能。基于这样的研究现状,在综合考虑滤波性能和计算代价的基

础上,本文采用误差状态卡尔曼滤波器对惯性和视觉数据进行融合,推导了测量系统的ESKF过程和测量模型,并采用VB理论提高了算法的自适应性。通过引入一个隐变量对一步预测误差协方差矩阵进行分解,并利用变分贝叶斯理论将噪声协方差和误差状态矢量一起推导,实现了过程噪声协方差的直接估计,增强算法的精度及鲁棒性。

## 1 视觉惯性组合测量系统

### 1.1 测量系统组成

本文所述融合定位方法所依托的测量系统为动基座上的视觉与双惯性组合测量系统,采用两个IMU与一个视觉传感器进行组合测量,用于获得非惯性系下待测目标相对于运动基座的姿态运动信息,测量系统结构如图1所示。

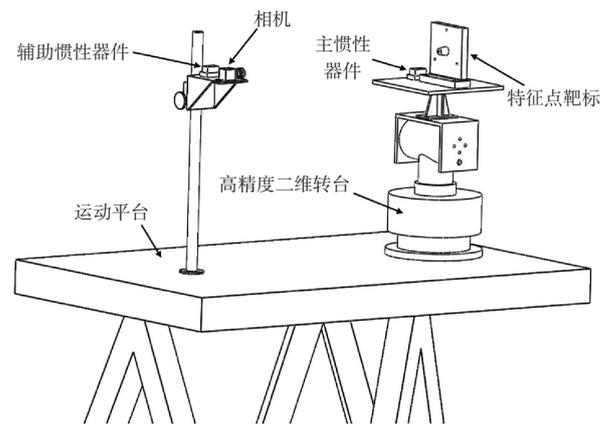


图1 姿态测量系统示意图

Fig.1 Diagram of the attitude determination system

测量系统由运动基座、高精度二维旋转台、主IMU、辅助IMU、单目视觉传感器以及红外特征点靶标组成。使用运动基座模拟载体的运动,使用高精度二维旋转台模拟目标物体的运动,主IMU用于获取目标物体在自身坐标系下的运动,辅助IMU用于获取载体在自身坐标系下的运动,单目视觉传感器是一台工业面阵相机,用于获取目标物体在视觉传感器坐标系下的运动,可以周期性地修正IMU由于零偏带来的测量误差。

本文的坐标系定义如下: $O_c X_c Y_c Z_c$ 为单目视觉传感器坐标系, $O_m X_m Y_m Z_m$ 为主IMU坐标系, $O_s X_s Y_s Z_s$ 为辅助IMU坐标系。本文使用 $C_A^B$ 表示由A坐标系转换到B坐标系的方向余弦矩阵。

### 1.2 卡尔曼滤波器状态量定义

定义标称状态矢量及误差状态矢量为

$$\mathbf{x} = [\mathbf{q}^T \quad \boldsymbol{\varepsilon}_m^T \quad \boldsymbol{\varepsilon}_s^T]^T \quad (1)$$

$$\delta \mathbf{x} = [\delta \boldsymbol{\theta}^T \quad \delta \boldsymbol{\varepsilon}_m^T \quad \delta \boldsymbol{\varepsilon}_s^T]^T \quad (2)$$

式中,  $\mathbf{q}$  为主IMU坐标系转换到辅助IMU坐标系的姿态四元数矢量;  $\boldsymbol{\varepsilon}_m$  和  $\boldsymbol{\varepsilon}_s$  为主IMU和辅助IMU零偏矩阵;  $\delta \boldsymbol{\theta}$  为姿态四元数误差  $\delta \mathbf{q}$  对应的角度值矢量,  $\delta \boldsymbol{\varepsilon}_m$  和  $\delta \boldsymbol{\varepsilon}_s$  为零偏误差矢量。

状态矢量是标称状态矢量和误差状态矢量之和, 可表示为

$$\mathbf{x}_t = \mathbf{x} \oplus \delta \mathbf{x} \quad (3)$$

式中,  $\mathbf{x}_t$  表示  $t$  时刻的系统状态矢量;  $\oplus$  表示对偏置分量的加法运算, 而对四元数的运算如式(4)所示

$$\mathbf{q}_t = \mathbf{q} \otimes \delta \mathbf{q} \quad (4)$$

式中,  $\otimes$  表示四元数乘法, 由于  $\delta \boldsymbol{\theta}$  一般很小, 可近似表示为

$$\delta \mathbf{q} = [1 \quad \delta \boldsymbol{\theta}/2]^T \quad (5)$$

### 1.3 误差状态卡尔曼滤波器模型

根据惯性器件的运动学模型, 可推导出双惯性器件误差状态转移方程为

$$\delta \mathbf{x}_k = \mathbf{F}_k \delta \mathbf{x}_{k-1} + \mathbf{W}_k \mathbf{n}_k \quad (6)$$

式中,  $\delta \mathbf{x}_k$  是当前时刻误差状态矢量,  $\delta \mathbf{x}_{k-1}$  是上一时刻误差状态矢量,  $\mathbf{W}_k$  为噪声驱动矩阵,  $\mathbf{n}_k$  是均值为零的高斯过程噪声, 它的协方差矩阵为  $\mathbf{Q}_k$ ,  $\mathbf{F}_k$  是状态转移矩阵, 表示为

$$\mathbf{F}_k = \begin{bmatrix} \mathbf{C} \{ \boldsymbol{\omega}_{sm,k-1}^m \Delta t \}^T & -\Delta t \mathbf{I}_{3 \times 3} & \mathbf{C}_s^m \Delta t \\ 0 & \mathbf{I}_{3 \times 3} & 0 \\ 0 & 0 & \mathbf{I}_{3 \times 3} \end{bmatrix} \quad (7)$$

式中,  $\boldsymbol{\omega}_{sm,k-1}^m$  为两个陀螺仪相对角速度, 先验误差的协方差矩阵通过式(8)传播

$$\mathbf{P}_{k|k-1} = \mathbf{F}_k \mathbf{P}_{k-1|k-1} \mathbf{F}_k^T + \mathbf{W}_k \mathbf{Q}_k \mathbf{W}_k^T \quad (8)$$

式中,  $\mathbf{P}_{k-1|k-1}$  是  $k-1$  时刻后验误差状态估计量  $\delta \hat{\mathbf{x}}_{k-1|k-1}$  的误差协方差。

相机观测模型为

$$\mathbf{z}_k = \mathbf{H}_x \mathbf{x}_k + \mathbf{r}_k \quad (9)$$

式中,  $\mathbf{z}_k$  是相机测量的姿态四元数  $\mathbf{z}_k^q$  中的矢量部分,  $\mathbf{r}_k$  是测量噪声, 它的协方差矩阵为  $\mathbf{R}_k$ ,  $\mathbf{H}_x$  是观测函数, 可表示为

$$\mathbf{H}_x = [0_{3 \times 1} \quad \mathbf{I}_{3 \times 3} \quad 0_{6 \times 6}] \quad (10)$$

测量模型相对于误差状态的雅克比矩阵可由式(11)

计算

$$\mathbf{H}_k = \frac{\partial \mathbf{z}_k}{\partial \mathbf{x}_k} \frac{\partial \mathbf{x}_t}{\partial \delta \mathbf{x}} = \mathbf{H}_x \frac{\partial \mathbf{x}_t}{\partial \delta \mathbf{x}} \quad (11)$$

误差状态及误差协方差通过式(12)、式(13)更新

$$\delta \hat{\mathbf{x}}_{k|k} = \mathbf{K}_k (\mathbf{z}_k - \mathbf{H}_x \hat{\mathbf{x}}_{k|k-1}) \quad (12)$$

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_{k|k-1} \quad (13)$$

式中,  $\hat{\mathbf{x}}_{k|k-1}$  是预测状态量;  $\mathbf{K}_k$  是卡尔曼增益, 可表示为

$$\mathbf{K}_k = \mathbf{P}_{k|k-1} \mathbf{H}_k^T (\mathbf{H}_k \mathbf{P}_{k|k-1} \mathbf{H}_k^T + \mathbf{R}_k)^{-1} \quad (14)$$

## 2 自适应误差状态卡尔曼滤波

### 2.1 变分贝叶斯推断

VB推断是一种用于近似推断后验概率密度函数中隐变量的方法。其通过将后验分布近似为如高斯分布或指数族分布的简单形式, 并最小化KL散度来提高两个分布之间的近似程度, 从而获得隐变量的后验估计。隐变量的后验分布可以表示为

$$p(\boldsymbol{\theta}_{1,k}, \boldsymbol{\theta}_{2,k}, \dots, \boldsymbol{\theta}_{m,k} | \mathbf{z}_{1:k}) \approx q_1(\boldsymbol{\theta}_{1,k}) q_2(\boldsymbol{\theta}_{2,k}) \cdots q_m(\boldsymbol{\theta}_{m,k}) \quad (15)$$

式中,  $\mathbf{z}_{1:k}$  是观测量,  $\boldsymbol{\theta}_{1,k}, \boldsymbol{\theta}_{2,k}, \dots, \boldsymbol{\theta}_{m,k}$  是不可观测的隐变量。令  $\mathbf{X} = \{\boldsymbol{\theta}_{1,k}, \boldsymbol{\theta}_{2,k}, \dots, \boldsymbol{\theta}_{m,k}\}$  表示为隐变量合集,  $\mathbf{Z} = \{\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_k\}$  为观测量合集, 则隐变量的后验分布可表示为

$$p(\mathbf{X} | \mathbf{Z}) \approx q(\mathbf{X}) \quad (16)$$

根据贝叶斯理论, 可得

$$\begin{cases} \ln p(\mathbf{Z}) = \mathcal{L}(q) + \text{KL}(q \| p) \\ \mathcal{L}(q) = \int q(\mathbf{X}) \ln \left\{ \frac{p(\mathbf{X}, \mathbf{Z})}{q(\mathbf{X})} \right\} d\mathbf{X} \\ \text{KL}(q \| p) = - \int q(\mathbf{X}) \ln \left\{ \frac{p(\mathbf{X}, \mathbf{Z})}{q(\mathbf{X})} \right\} d\mathbf{X} \end{cases} \quad (17)$$

式中,  $\mathcal{L}$  为  $q(\mathbf{X})$  下  $\ln p(\mathbf{Z})$  的下界, KL为散度。对KL散度进行最小化可转化为将下界  $\mathcal{L}$  最大化。下界与各因式分布的关系如下

$$\begin{cases} \mathcal{L}(q) = -\text{KL}(q_j \| \tilde{p}(\boldsymbol{\theta}_{j,k}, \mathbf{Z})) + c \\ \ln \tilde{p}(\boldsymbol{\theta}_{j,k}, \mathbf{Z}) = E_{i \neq j} [\ln p(\mathbf{X}, \mathbf{Z})] + c \\ E_{i \neq j} [\ln p(\mathbf{X}, \mathbf{Z})] = \int \ln p(\mathbf{X}, \mathbf{Z}) \prod_{i \neq j} q_i d\boldsymbol{\theta}_{i,k} \end{cases} \quad (18)$$

式中,  $c$  为常数;  $E_{i \neq j}[\cdot]$  是对分布  $q_1, \dots, q_{m+1}$  的期望。由式(18)得, 当  $q_j(\boldsymbol{\theta}_{j,k}) = \tilde{p}(\boldsymbol{\theta}_{j,k}, \mathbf{Z})$  时, KL散度为零, 因此第  $j$  个隐变量的近似分布最优估计为  $\tilde{p}(\boldsymbol{\theta}_{j,k}, \mathbf{Z})$ 。

### 2.2 VB优化的误差状态卡尔曼滤波

为了实现过程噪声协方差的直接估计, 引入隐变量  $\mathbf{m}_k$  对先验误差协方差  $\mathbf{P}_{k|k-1}$  进行分解

$$\mathbb{N}(\delta \mathbf{x}_k | \delta \mathbf{x}_{k|k-1}, \mathbf{P}_{k|k-1}) = \int \mathbb{N}(\delta \mathbf{x}_k | \mathbf{m}_k, \mathbf{A}_k) \times \mathbb{N}(\mathbf{m}_k | \delta \mathbf{x}_{k|k-1}, \mathbf{W}_k \mathbf{Q}_k \mathbf{W}_k^T) d\mathbf{m}_k \quad (19)$$

式中,  $\mathbf{A}_k = \mathbf{F}_k \mathbf{P}_{k-1} \mathbf{F}_k^T$ 。

误差状态、过程噪声协方差矩阵和隐变量的联合后验分布可表示为

$$p(\delta \mathbf{x}_k, \mathbf{Q}_k, \mathbf{m}_k | \mathbf{z}_{1:k}) \approx q(\delta \mathbf{x}_k) q(\mathbf{Q}_k) q(\mathbf{m}_k) \quad (20)$$

根据VB理论,式(20)中各分布最优解满足

$$\begin{aligned} \ln q(\mathbf{m}_k) &= E_{\mathbf{Q}_k} [\ln p(\delta \mathbf{x}_k, \mathbf{Q}_k, \mathbf{m}_k, \mathbf{z}_{1:k})] + c \\ \ln q(\delta \mathbf{x}_k) &= E_{\mathbf{Q}_k} [\ln p(\delta \mathbf{x}_k, \mathbf{Q}_k, \mathbf{m}_k, \mathbf{z}_{1:k})] + c \\ \ln q(\mathbf{Q}_k) &= E_{\delta \mathbf{x}_k} [\ln p(\delta \mathbf{x}_k, \mathbf{Q}_k, \mathbf{m}_k, \mathbf{z}_{1:k})] + c \end{aligned} \quad (21)$$

式中,  $c$  为常数。根据贝叶斯理论,联合分布可分解为

$$\begin{aligned} p(\delta \mathbf{x}_k, \mathbf{Q}_k, \mathbf{m}_k, \mathbf{z}_{1:k}) &= p(\mathbf{z}_k | \delta \mathbf{x}_k, \mathbf{m}_k) \times \\ p(\delta \mathbf{x}_k | \mathbf{z}_{1:k-1}, \mathbf{m}_k) &\times p(\mathbf{m}_k | \mathbf{z}_{1:k-1}, \mathbf{Q}_k) \times p(\mathbf{z}_{1:k-1}) = \\ \mathbb{N}(\mathbf{z}_k | \mathbf{H}_x \mathbf{x}_k) &\times \mathbb{N}(\delta \mathbf{x}_k | \mathbf{m}_k, \mathbf{A}_k) \times \mathbb{N}(\mathbf{m}_k | \delta \mathbf{x}_{k|k-1}, \mathbf{W}_k \mathbf{Q}_k \mathbf{W}_k^T) \times \\ \mathbf{IW}(\mathbf{Q}_k; \hat{\mathbf{t}}_{k|k-1}, \hat{\mathbf{T}}_{k|k-1}) &\times p(\mathbf{z}_{1:k-1}) \end{aligned} \quad (22)$$

式中,过程噪声协方差  $\mathbf{Q}_k$  建模为逆威沙特分布,其中  $\hat{\mathbf{t}}_{k|k-1}$  为自由度;  $\hat{\mathbf{T}}_{k|k-1}$  为逆尺度矩阵。将式(22)代入式(21)可得

$$\begin{aligned} q(\mathbf{m}_k) &\propto \mathbb{N}(E[\delta \mathbf{x}_k] | \mathbf{m}_k, \mathbf{A}_k) \cdot \mathbb{N}(\mathbf{m}_k | \delta \mathbf{x}_{k|k-1}, (\mathbf{W}_k \mathbf{Q}_k \mathbf{W}_k^T + \mathbf{A}_k)^{-1}) \\ q(\delta \mathbf{x}_k) &\propto \mathbb{N}(\delta \mathbf{x}_k; E[\mathbf{m}_k], \mathbf{A}_k) \cdot \mathbb{N}(\mathbf{z}_k; \mathbf{H}_x \mathbf{x}_k) \end{aligned} \quad (23)$$

由式(22)、式(23)可见  $\mathbf{m}_k$  的后验分布仍是正态分布,则其测量更新过程为

$$\begin{cases} \hat{\mathbf{m}}_k = \delta \mathbf{x}_{k|k-1} + \mathbf{K}_{m,k} (E[\delta \mathbf{x}_k] - \delta \mathbf{x}_{k|k-1}) \\ \mathbf{K}_{m,k} = \mathbf{W}_k \mathbf{Q}_k \mathbf{W}_k^T (\mathbf{W}_k \mathbf{Q}_k \mathbf{W}_k^T + \mathbf{A}_k)^{-1} \\ \mathbf{P}_{m,k} = (\mathbf{I} - \mathbf{K}_{m,k}) \mathbf{W}_k \mathbf{Q}_k \mathbf{W}_k^T \end{cases} \quad (24)$$

式中,  $\mathbf{K}_{m,k}$  为卡尔曼增益;  $\hat{\mathbf{m}}_k$  和  $\mathbf{P}_{m,k}$  分别为隐变量的后验估计和误差协方差。同理可得误差状态  $\delta \hat{\mathbf{x}}$  的测量更新过程为

$$\begin{cases} \delta \hat{\mathbf{x}}_k = E[\mathbf{m}_k] + \mathbf{K}_{x,k} \boldsymbol{\eta}_m \\ \mathbf{K}_{x,k} = \mathbf{A}_k \mathbf{J}_k^T \mathbf{S}_k^{-1} \\ \mathbf{P}_{x,k} = (\mathbf{I} - \mathbf{K}_{x,k} \mathbf{J}_k) \mathbf{A}_k \end{cases} \quad (25)$$

式中,  $\boldsymbol{\eta}_m$  为测量噪声与误差状态的残差,运算符合四元数加法与乘法。  $\mathbf{K}_{x,k}$  和  $\mathbf{P}_{x,k}$  分别为卡尔曼增益和后验误差协方差。同样的,过程噪声协方差  $\mathbf{Q}_k$  近似后验分布为

$$q(\mathbf{Q}_k) \propto \exp \left\{ -0.5(n + \hat{\mathbf{t}}_{k|k-1} + 2) \times \log |\mathbf{Q}_k| - 0.5 \text{tr}(\mathbf{A}_k (\mathbf{W}_k \mathbf{Q}_k \mathbf{W}_k^T)^{-1}) - 0.5 \text{tr}(\hat{\mathbf{T}}_{k|k-1} \mathbf{Q}_k^{-1}) \right\} \quad (26)$$

式中,  $\mathbf{A}_k = \mathbf{P}_{m,k} + \hat{\mathbf{m}}_k \hat{\mathbf{m}}_k^T$ 。观察发现  $\mathbf{Q}_k$  的后验分布仍为逆威沙特分布,其自由度及逆尺度矩阵更新为

$$\begin{cases} \hat{\mathbf{t}}_k = \hat{\mathbf{t}}_{k|k-1} + 1 \\ \hat{\mathbf{T}}_k = \mathbf{D}_k^{-1} \mathbf{A}_k \mathbf{D}_k^{-T} + \hat{\mathbf{T}}_{k|k-1} \end{cases} \quad (27)$$

后验估计噪声协方差  $\hat{\mathbf{Q}}_k$  可根据逆威沙特分布的性质推导

$$\hat{\mathbf{Q}}_k = \text{diag} \left\{ \frac{\hat{\mathbf{T}}_k}{(\hat{\mathbf{t}}_k - m - 1)} \right\} \quad (28)$$

式中,  $m$  为测量矢量维度,在本文中  $m=3$ 。在滤波过程中,  $\delta \mathbf{x}_k$ 、 $\mathbf{m}_k$  和  $\mathbf{Q}_k$  的更新相互耦合,交替优化,直到误差状态矢量满足如下关系

$$\frac{\|\delta \hat{\mathbf{x}}_k^t - \delta \hat{\mathbf{x}}_k^{t-1}\|_2^2}{\|\delta \hat{\mathbf{x}}_k^{t-1}\|_2^2} < \lambda \quad (29)$$

式中,  $\lambda$  为收敛阈值。

### 3 试验结果及分析

#### 3.1 试验系统及测试条件

为了验证本文研究的误差状态卡尔曼滤波的视觉惯性自适应融合定位方法的性能,按图1结构搭建了动基座视觉惯性组合测量系统。使用的惯性器件的型号为Xsens-MTi-100,零偏稳定性为  $10(^{\circ})/h$ ,噪声密度为  $0.01(^{\circ})/(s/\sqrt{Hz})$ 。工业相机采用海康威视的面阵相机MV-CS050-10UM,像元尺寸为  $3.45\mu m \times 3.45\mu m$ ,相机分辨率为  $2448 \times 2048$ 。使用Computar的镜头,其焦距为8mm。被测靶标由4个非共面的红外LED特征点组成,其相对位置关系如图2所示。采用二维转台模拟靶标的自身运动,采用运动平台模拟载体的运动。试验数据处理平台为Intel(R) Core(TM) i7-10700 CPU。

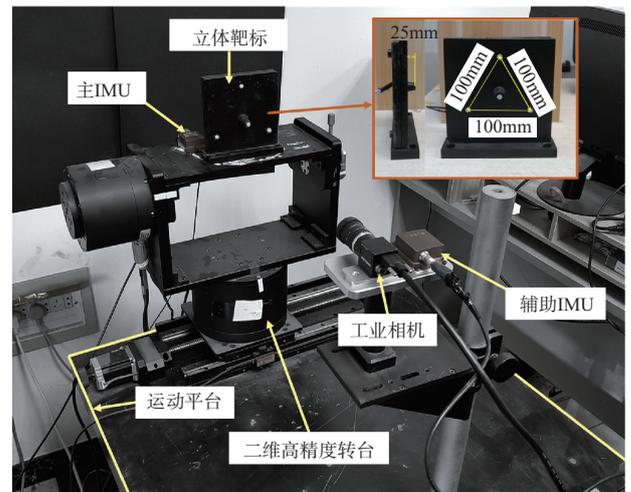


图2 动基座视觉惯性组合测量系统图

Fig.2 Dynamic base visual-inertial combination measurement system

在物体位姿测量试验中,二维转台进行多轴旋转来模拟物体自身的运动,其运动轨迹如图3和图4所示。运动平台的三个轴均以幅值为  $10^{\circ}$ 、周期为25s的正弦轨迹进行运动。

#### 3.2 算法效果评估

为了充分验证算法的滤波性能,使用不同的标称噪声协方差矩阵对误差状态卡尔曼滤波(ESKF)、容积卡尔曼滤波(CKF)、自适应误差状态卡尔曼滤波(AESKF)、基于期望最大化的自适应误差状态卡尔曼滤波(AESKF-EM)、基于变分贝叶斯推断的自适应误差状态卡尔曼滤波(AESKF-

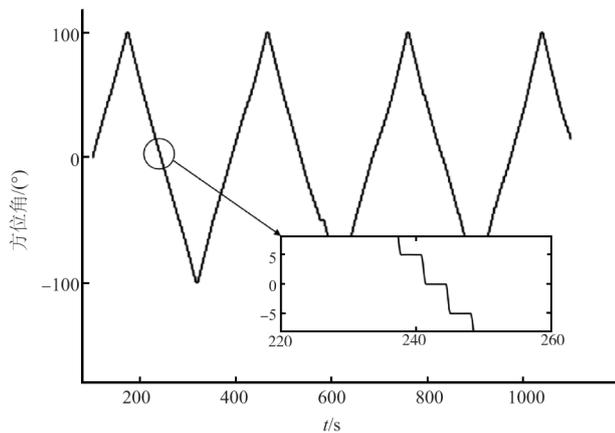


图3 多轴运动方位角轨迹

Fig.3 Multi-axis motion attitude angle trajectory

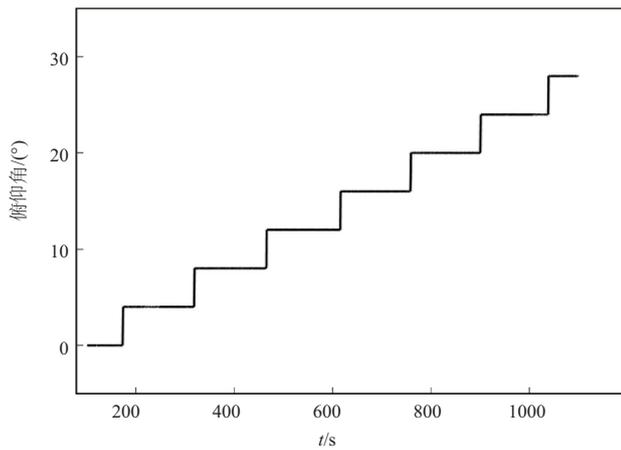
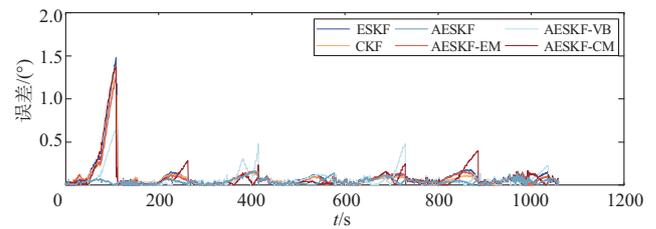


图4 多轴运动俯仰角轨迹

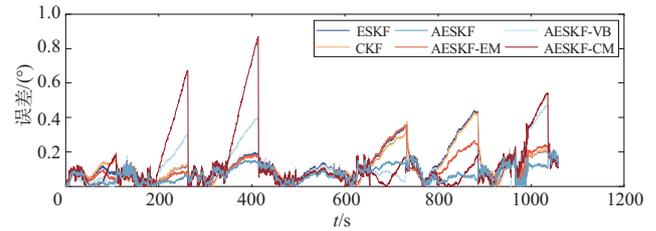
Fig.4 Multi-axis motion pitch angle trajectory

VB)和基于协方差匹配的自适应误差状态卡尔曼滤波(AESKF-CM)进行测试验证,考虑以下三种应用场景。场景1:标称过程噪声协方差矩阵远大于参考过程噪声协方差矩阵: $\bar{\mathbf{Q}}_k = 100\hat{\mathbf{Q}}_k$ 。场景2:标称过程噪声协方差矩阵等于参考过程噪声协方差矩阵: $\bar{\mathbf{Q}}_k = \hat{\mathbf{Q}}_k$ 。场景3:标称过程噪声协方差矩阵远小于参考过程噪声协方差矩阵: $\bar{\mathbf{Q}}_k = 0.01\hat{\mathbf{Q}}_k$ 。

测试结果如图5~图7所示。姿态估算结果误差的均方根误差(RMSE)见表1。在场景1和场景3中,由于标称过程噪声协方差矩阵与参考过程噪声协方差矩阵相差极大,而ESKF和CKF算法无自适应调节功能,因此其滤波效果远比AESKF的滤波效果差。由于 $\bar{\mathbf{Q}}_k$ 和 $\hat{\mathbf{Q}}_k$ 相差极大,AESKF-CM未必能够正确收敛;而AESKF-EM和AESKF-VB需要依赖标称值进行一步预测,所以其预测精度也并不高。相比之下,在该场景中本文提出的滤波算法



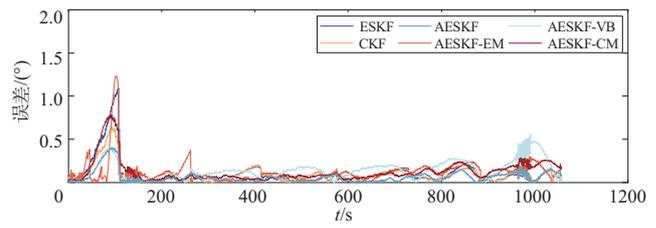
(a) 俯仰角误差



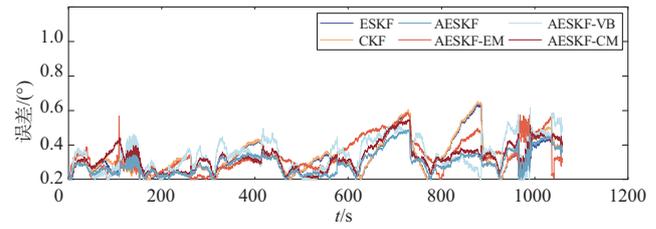
(b) 方位角误差

图5 场景1下的滤波误差绝对值曲线

Fig.5 Absolute value curve of filtering error under scene 1



(a) 俯仰角误差(°)



(b) 方位角误差(°)

图6 场景2下的滤波误差绝对值曲线

Fig.6 Absolute value curve of filtering error under scene 2

在降低RMSE方面表现效果十分显著。这证明当过程噪声协方差矩阵与真值相差十分大时,本文所提出的滤波算法十分有效。

在场景2中,标称过程噪声协方差矩阵与参考过程噪声协方差矩阵相同,6种滤波算法的估计误差都有所降低。其中滤波效果提升最多的是AESKF-VB,因为其在估计噪声协方差矩阵时,仍要用到标称值。尽管如此,AESKF算法仍与其精度持平,有效地降低了姿态估计误差,这从RMSE结果可以得知。

在实际测量中,过程噪声协方差矩阵精确值往往不能事先精确得知,将其设定为固定值会降低姿态估计精度。

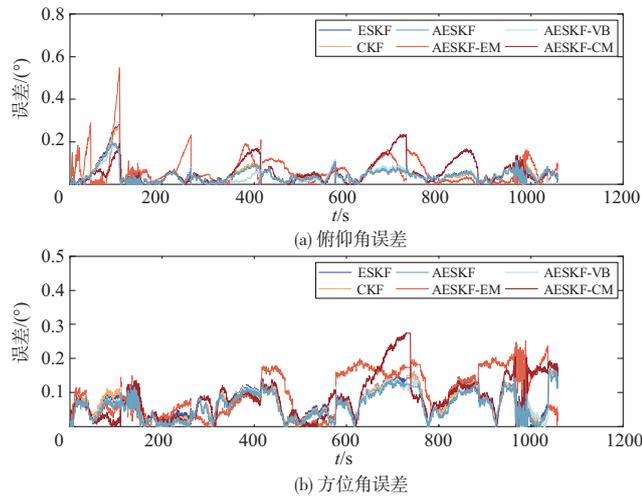


图7 场景3下的滤波误差绝对值曲线

Fig.7 Absolute value curve of filtering error under scene 3

表1 滤波算法姿态估计的RMSE结果

Table 1 RMSE results of filtering algorithm attitude estimation

滤波器	场景1		场景2		场景3	
	俯仰轴	方位轴	俯仰轴	方位轴	俯仰轴	方位轴
ESKF	0.1729	0.1562	0.0712	0.0826	0.1648	0.1398
CKF	0.1416	0.1297	0.0597	0.0851	0.1365	0.1426
AESKF	0.0620	0.0873	0.0524	0.0714	0.0841	0.1066
AESKF-EM	0.1677	0.1362	0.0924	0.1069	0.1788	0.1468
AESKF-VB	0.1031	0.1612	0.0513	0.0749	0.1685	0.1542
AESKF-CM	0.1884	0.2048	0.0857	0.1006	0.1681	0.1344

综上,本文提出的滤波算法在多种场景下均能实现良好的滤波效果,具有较好的普适性。

## 4 结论

本文提出了一种基于误差状态卡尔曼滤波框架的视觉惯性自适应融合算法,通过引入隐变量并结合贝叶斯推断的方法实现了过程噪声协方差的在线估计,从而实现更精确的位姿估计。算法无须提前获得较精确的过程噪声协方差矩阵,具有更高的鲁棒性与测量环境普适性。经过试验测试,本文算法实现了在标称过程噪声协方差矩阵过大、过小及适中的全测量场景下的高精度姿态测量。尤其是在标称过程噪声协方差偏离真值较大的测量条件下,所提算法能够显著改善测量效果。综上所述,本文提出的算法具有较高的精度及鲁棒性,可以实现视觉惯性自适应融合的物体位姿精准估计。

AST

## 参考文献

- [1] Ekenhoff K, Geneva P, Huang G Q. MIMC-VINS: A versatile and resilient multi-imu multi-camera visual-inertial navigation system[J]. IEEE Transactions on Robotics, 2021, 37(5): 1360-1380.
- [2] 阎峰,刘震. 基于立体视觉的无人机位姿测量方法[J]. 航空科学技术, 2023, 34(4): 72-78.  
Yan Feng, Liu Zhen. UAV pose measurement method based on stereo vision[J]. Aeronautical Science & Technology, 2023, 34(4): 72-78.(in Chinese)
- [3] 张西林,何亚坤,张格易,等. 面向自主空中加油任务的目标检测技术研究[J]. 航空科学技术, 2023, 34(2): 64-71.  
Zhang Xilin, He Yakun, Zhang Keyi, et al. Object detection technology for autonomous air to air refueling[J]. Aeronautical Science & Technology, 2023, 34(2): 64-71.(in Chinese)
- [4] 张立民,姜杰,方伟,等. 头位瞄准技术应用与研究[J]. 舰船电子工程, 2021, 41(8): 93-96.  
Zhang Limin, Jiang Jie, Fang Wei, et al. Application and research of head position aiming technology[J]. Ship Electronic Engineering, 2021, 41(8): 93-96.(in Chinese)
- [5] Assa A, Janabi-Sharifi F. A Kalman filter-based framework for enhanced sensor fusion[J]. IEEE Sensors, 2015, 15(6): 3281-3292.
- [6] Ekenhoff K, Geneva P, Bloecker J, et al. Multi-camera visual-inertial navigation with online intrinsic and extrinsic calibration [C]. 2019 International Conference on Robotics and Automation (ICRA), 2019.
- [7] Guo Xiaoting, Sun Changku, Wang Peng, et al. Vision sensor and dual MEMS gyroscope integrated system for attitude determination on moving base [J]. Review of Scientific Instruments, 2018, 89(1): 015002.
- [8] Gao Xitian, Li Baoquan, Shi Wuxi, et al. Visual-inertial odometry system with simultaneous extrinsic parameters optimization[C]. 2020 IEEE/ASME International Conference on Advanced Intelligent Mechatronics(AIM), 2020: 1977-1982.
- [9] 崔晓珍,周琪,武东杰,等. 可融合里程计的INS/GNSS组合导航系统设计与试验分析[J]. 航空科学技术, 2022, 33(2): 84-89.  
Cui Xiaozhen, Zhou Qi, Wu Dongjie, et al. Design and experimental analysis of INS/GNSS integrated navigation system

- with odometer[J]. *Aeronautical Science & Technology*, 2022, 33(2): 84-89.(in Chinese)
- [10] Vitali R V, McGinnis R S, Perkins N C. Robust error-state Kalman filter for estimating IMU orientation[J]. *IEEE Sensors Journal*, 2020, 21(3): 3561-3569.
- [11] Roumeliotis S I, Sukhatme G S, Bekey G A. Circumventing dynamic modeling: Evaluation of the error-state kalman filter applied to mobile robot localization[C]//*Proceedings of 1999 IEEE International Conference on Robotics and Automation*. IEEE, 1999.
- [12] Del Rosario M B, Khamis H, Ngo P, et al. Computationally efficient adaptive error-state Kalman filter for attitude estimation[J]. *IEEE Sensors Journal*, 2018, 18(22): 9332-9342.
- [13] Dunik J, Straka O, Kost O, et al. Noise covariance matrices in state - space models: A survey and comparison of estimation methods: Part I[J]. *International Journal of Adaptive Control and Signal Processing*, 2017, 31(11): 1505-1543.
- [14] Brossard M, Barrau A, Bonnabel S. AI-IMU dead-reckoning [J]. *IEEE Transactions on Intelligent Vehicles*, 2020, 5(4): 585-595.
- [15] Brossard M, Barrau A, Bonnabel S. RINS-W: Robust inertial navigation system on wheels[C]. *IEEE/RSJ International Conference on Intelligent Robots and Systems(IROS)*, 2019: 2068-2075.
- [16] 兰德智. 基于DNN-Kalman滤波算法的移动机器人轨迹估计 [D]. 哈尔滨: 哈尔滨工业大学, 2022.  
Lan Dezhi. Mobile robot trajectory estimation based on DNN-Kalman filtering algorithm[D]. Harbin: Harbin Institute of Technology, 2022.(in Chinese)
- [17] Mehra R. On the identification of variances and adaptive Kalman filtering[J]. *IEEE Transactions on Automatic Control*, 1970, 15(2): 175-184.
- [18] Davari N, Gholami A. Variational Bayesian adaptive Kalman filter for asynchronous multirate multi-sensor integrated navigation system[J]. *Ocean Engineering*, 2019, 174: 108-116.
- [19] Liu Yahui, Fan Xiaoqian, Lyu Chen, et al. An innovative information fusion method with adaptive Kalman filter for integrated INS/GPS navigation of autonomous vehicles[J]. *Mechanical Systems and Signal Processing*, 2018, 100: 605-616.
- [20] Huang Yulong, Zhang Yonggang, Wu Zhemin, et al. A novel adaptive Kalman filter with inaccurate process and measurement noise covariance matrices[J]. *IEEE Transactions on Automatic Control*, 2017, 63(2): 594-601.
- [21] Sarkka S, Nummenmaa A. Recursive noise adaptive Kalman filtering by variational Bayesian approximations[J]. *IEEE Transactions on Automatic Control*, 2009, 54(3): 596-600.
- [22] Huang Yulong, Zhang Yonggang, Xu Bo, et al. A new adaptive extended Kalman filter for cooperative localization[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2017, 54(1): 353-368.
- [23] Xu Hong, Duan Keqing, Yuan Huadong, et al. Black box variational inference to adaptive kalman filter with unknown process noise covariance matrix[J]. *Signal Processing*, 2020, 169: 107413.
- [24] Huang Yulong, Zhang Yonggang, Li Ning, et al. A robust Gaussian approximate filter for nonlinear systems with heavy tailed measurement noises[C]. *2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2016: 4209-4213.
- [25] He Jingjing, Sun Changku, Zhang Baoshang, et al. Variational Bayesian-based maximum correntropy cubature Kalman filter with both adaptivity and robustness[J]. *IEEE Sensors Journal*, 2020, 21(2): 1982-1992.

## Vision Inertia Adaptive Fusion Method for Attitude Determination Based on Error State Kalman Filter

Wang Peng<sup>1,2</sup>, Wang Dawei<sup>1</sup>, He Jingjing<sup>1</sup>

1. State Key Lab of Precision Measuring Technology & Instruments, Tianjin University, Tianjin 300072, China

2. Key Laboratory of Electro-Optical Control Technology, Luoyang Institute of Electrooptic Equipment, Luoyang 471000, China

**Abstract:** Helmet Mounted Sights(HMS) are auxiliary sighting equipment for new generation fighter pilots in recent years. They can help pilots enhance battlefield situational awareness and conduct rapid and precise strikes against enemy targets. The key to its normal operation is to obtain the attitude parameter of the pilot's head relative to the moving aircraft helmet-mounted sight. This paper investigates the key techniques for visual fusion and posture measurement in the context of helmet mounted sight. The visual inertial fusion method can realize the complementary advantages of these two target position measurement methods. However, the robustness and accuracy of the fusion algorithm need to be further improved, because the nominal noise matrix cannot be predicted absolutely and accurately. To address this problem, this paper proposes a visual inertial adaptive fusion method based on variational Bayesian inference in the error-state Kalman filter framework. First, the process noise is modeled using the inverse Wishart distribution. Then, the covariance is predicted in one step by introducing a latent variable, and the online estimation of the process noise covariance matrix is achieved by combining the variational Bayesian inference. Experimental findings unequivocally demonstrate that the proposed pose measurement algorithm exhibits remarkable accuracy and robustness in the face of complex motion and substantial deviations in the nominal noise covariance matrix. The proposed algorithm can complete fast and high-precision tracking of the target.

**Key Words:** adaptive; Error-State Kalman filter (ESKF); Variational Bayesian (VB); vision inertia fusion; attitude measurement