

基于视觉/惯导的无人机组导航算法研究

黄剑雄, 刘小雄, 章卫国, 高鹏程

(西北工业大学 自动化学院, 西安 710072)

摘要: 目前视觉惯性组合导航系统多采用优化紧/松耦合以及滤波紧/松耦合算法, 应用误差状态卡尔曼滤波能够将较低频率的视觉位姿信息提升到与惯性信息同步的频率; 提出一种基于自适应卡尔曼滤波的视觉惯导组合导航算法, 首先考虑到系统建模与传感器测量误差, 采用自适应渐消卡尔曼滤波进行导航解算, 通过实时计算遗忘因子, 以调节历史数据的权重, 可抑制建模误差, 提高组合导航系统性能, 然后针对视觉 SLAM 解算过程造成的视觉位姿信息滞后于惯导信息的问题, 提出一种延时补偿方法; 仿真实验表明, 采用延时补偿的自适应渐消卡尔曼滤波算法能够有效抑制建模误差, 并降低视觉位姿信息滞后带来的影响, 提高无人机组导航的解算精度, 姿态、速度、位置解算精度分别达到 5° 、 0.5m/s 、 0.4m 以内。

关键词: SLAM; 惯性导航; 卡尔曼滤波; 自适应卡尔曼滤波; 补偿延时

Research on Vision/Inertial Based Integrated Navigation Technology of UAVs

Huang Jianxiong, Liu Xiaoxiong, Zhang Weiguo, Gao Pengcheng

(College of Automation, Northwestern Polytechnical University, Xi'an 710072, China)

Abstract: At present, most of the vision inertial integrated navigation systems use optimization tight/loose coupling method based on optimize or filter. The application of error state Kalman filter can raise the frequency from visual pose to synchronized with IMU. A vision integrated navigation algorithm based on Adaptive Kalman filter is proposed. Firstly, considering the system modeling and sensor measurement error, adaptive fading Kalman filter is used to solve the navigation problem. By calculating the forgetting factor in real time, the weight of historical data can be adjusted, the modeling error can be suppressed, and the performance of integrated navigation system can be improved. In view of the problem that the visual pose information lags behind the inertial information caused by the visual SLAM solution process, a delay compensation method is proposed to solve the problem. The simulation results show that the adaptive fading Kalman filter algorithm with time delay compensation can effectively suppress the modeling error, reduce the influence of visual pose information lag, and improve the accuracy of integrated navigation of UAVs, the accuracy of attitude, velocity and position is within 5° , 0.5m/s and 0.4m respectively.

Keywords: SLAM; inertial navigation; Kalman filter; adaptive fading Kalman filter; compenstaion for time delay

0 引言

传统的无人机通常采用全球定位系统 (GPS, global position system) 与惯性测量单元 (IMU, inertial measurement unit) 进行融合^[1], 为无人机提供所需的姿态、速度以及位置等导航信息。

当 GPS 受遮挡或完全无信号时, 这将直接影响到使用 GPS 与 IMU 的传统组合导航算法, 严重的情况下, 甚至会使其完全失效, 从而引发无人机坠机事故。

针对上述问题, 许多学者将研究重点转向了同时定位与地图构建 (SLAM, simultaneous localization and mapping) 的研究, 并提出了许多优秀的开源算法。其中利用视觉传感器的 SLAM 算法, 主要分为基于特征点法的 SLAM 算法, 如 PTAM^[2]、ORB_SLAM^[3], 与基于直接法或半

直接法的 SLAM 算法, 如 DSO^[4]、SVO^[5] 等算法。其中, ORB_SLAM 是基于特征点法的 SLAM 算法中性能非常优秀的算法, 并且于 2017 年推出了同时支持单目、双目、RGBD 的 ORB_SLAM2^[6]。

但由于无人机的机载处理器性能较弱, 如在 NVIDIA JETSON TX2 平台上, ORB_SLAM2 经过 GPU 加速等优化后, 通常也只能输出 $10\sim 20\text{Hz}$ 的位姿信息。这对于无人机的导航而言, 确实有些捉襟见肘。因此, 利用误差状态卡尔曼滤波 (ErKF, error-state kalmanfilter) 松耦合方法^[7]对视觉位姿与惯导信息进行融合从而提升导航信息的输出频率是非常有效的手段之一。

在传统的使用扩展卡尔曼滤波 (EKF, extended kalmanfilter) 对 GPS 信息与惯性信息进行融合的流程中, 建模的准确与否直接影响到 EKF 的精确性。为了解决系统建

收稿日期:2020-06-13; 修回日期:2020-07-07。

基金项目:航空科学基金资助(201905053003);陕西省飞行控制与仿真技术重点实验室资助项目。

作者简介:黄剑雄(1994-),男,四川乐山人,硕士研究生,主要从事视觉惯性组合导航方向的研究。

刘小雄(1973-),男,陕西周至人,博士,副教授,主要从事飞机飞行控制、无人机导航、制导与轨迹控制方向的研究。

章卫国(1956-),男,安徽南陵人,教授,博士生导师,主要从事飞行控制与仿真、现代飞行控制方向的研究。

引用格式:黄剑雄,刘小雄,章卫国,等.基于视觉/惯导的无人机组导航算法研究[J].计算机测量与控制,2021,29(2):137-143,149.

模不准确的问题,自适应渐消卡尔曼滤波(AFKF, adaptive fading kalman filter)应运而生。AFKF 主要通过实时的计算遗忘因子,不断调整系统的协方差矩阵,从而削弱历史数据的权重,即限制了模型误差累积。国内外学者在传统 AFKF 方面做了许多研究工作,其中,AFKF 直接对协方差阵进行加权渐消处理的合理性已得到了完备的证明^[8];学者也提出了非常合理的最佳遗忘因子的求取算法^[9]。

基于上述文献的研究成果,本文提出了使用 AFKF 作为视觉位姿与惯导信息的融合算法,进一步提升滤波结果的精度。在此基础上,本文还讨论了一种由于视觉 SLAM 解算过程而引入的视觉位姿信息相对惯性信息滞后的问题,并提出了一种延时补偿方法以解决这类滞后问题,进一步改善导航解算精度。

1 ORB_SLAM2 简介及其简化工作

ORB_SLAM2 是当前基于特征点法的主流 SLAM 算法之一,前端是一个轻量级的定位模型,后端主要采用 BA 优化方法,可以实现未知环境中的定位。ORB_SLAM2 在原 ORB_SLAM 的基础上,新增了对双目以及 RGB-D 摄像头的支持,并可以实现地图重用、回环检测以及重定位等功能。

ORB_SLAM2 一共包含 3 个主要线程以及一个次要线程,分别是 Tracking 线程、Local Mapping 线程、Loop Closure 线程及全局 BA 线程,其中全局 BA 线程仅发生在回环检测成功后才执行。

本文为了保证实时性要求,对 ORB_SLAM2 框架进行了一定程度的简化,简化包括去除闭环检测以及回环修正的线程;同时,为了与惯导进行融合,增加了 Scheduler 线程,Scheduler 中主要完成 IMU 数据的采集以及基于 EKF 框架的视觉惯导融合。如图 1 所示。

本文暂且把修改后的框架称为简化 ORB_SLAM2,简化 ORB_SLAM2 共包含 3 个线程,分别是 Tracking 线程、Local Mapping 线程、Scheduler 线程。

在 Scheduler 线程中,本文将 ORB_SLAM2 与 IMU 视为相互独立的传感器,按设定频率进行数据采集与处理,并基于 EKF 框架进行融合,得到融合后的无人机位置、速度以及姿态信息,作为无人机的导航信息。

2 基于 EKF 的视觉惯导组合导航算法

2.1 EKF 预测更新

假设系统状态为 $[q, v, p, \epsilon_r, \nabla_r]^T$, 其中 q 表示无人机姿态, v 表示无人机速度, p 表示无人机位置, ϵ_r 表示角速度 bias, ∇_r 表示加速度 bias。

将陀螺仪误差与加速度计误差建模为一阶马尔科夫随机过程,可以将陀螺仪误差模型建模如下:

$$\begin{cases} \epsilon_g = \epsilon_r + w_e \\ \dot{\epsilon}_r = -\frac{1}{\tau_g} \epsilon_r + w_{er} \end{cases} \quad (1)$$




图 1 简化 ORB_SLAM2 流程框图

加计误差模型建模如下:

$$\begin{cases} \nabla_a = \nabla_r + w_{\nabla} \\ \dot{\nabla}_r = -\frac{1}{\tau_a} \nabla_r + w_{\nabla_r} \end{cases} \quad (2)$$

根据运动学关系,式(1)以及式(2),可得如下运动学状态方程:

$$\begin{cases} \dot{q}_t = \frac{1}{2} q_t \otimes (\omega_t) \\ \dot{v}_t = C_{b,t}^n(a_t) \\ \dot{p}_t = v_t \\ \dot{\epsilon}_r = -\frac{1}{\tau_g} \epsilon_r + w_{er} \\ \dot{\nabla}_r = -\frac{1}{\tau_a} \nabla_r + w_{\nabla_r} \end{cases} \quad (3)$$

其中:

$$\begin{cases} \omega_t = \omega_m - \epsilon_g \\ a_t = a_m - \nabla_a \end{cases} \quad (4)$$

其中: ω_m 表示陀螺仪量测值, a_m 表示加速度计量测值。

上述运动状态方程中,含有噪声项,这是我们无法在实际测量中直接去除的,因此我们需要将这些噪声项通过 EKF 估计出来之后再行消除。我们首先将上述运动方程中的噪声项去除,然后对噪声项进行建模,得到我们最终的误差状态方程:

$$\begin{cases} \dot{q} = \frac{1}{2} q \otimes (\omega_m - \epsilon_g) \\ \dot{v} = C_b^n(a_m - \nabla_r) \\ \dot{p} = \hat{v} \\ \dot{\epsilon}_r = 0 \\ \dot{\nabla}_r = 0 \end{cases} \quad (5)$$

由式(1)和式(2)描述的 IMU 误差模型可知,如果

我们将噪声项消除, 则 IMU 误差应该恒为 0, 则其倒数也为 0, 因此可以得到如上消除噪声项后的运动方程, 我们对每一个状态量求取上述两组运动方程的误差, 则可以得到我们最终的状态量为 $[\delta\theta, \delta v, \delta p, \epsilon_r, \nabla_r]^T$ 的误差状态方程如下:

$$\begin{cases} \dot{\delta\theta} = -|\omega_m - \epsilon_r| \times \delta\theta - \epsilon_r - w_\epsilon \\ \dot{\delta v} = -C_b^n |a_m - \nabla_r| \times \delta\theta - C_b^n \nabla_r - C_b^n w_{\nabla} \\ \dot{\delta p} = \delta v \\ \dot{\epsilon_r} = -\frac{1}{\tau_g} \epsilon_r + w_{\epsilon_r} \\ \dot{\nabla_r} = -\frac{1}{\tau_a} \nabla_r + w_{\nabla_r} \end{cases} \quad (6)$$

对各状态量求偏导, 可得如下预测模型的状态空间方程:

$$\dot{X}(t) = F(t)X(t) + G(t)w(t) \quad (7)$$

其具体表达形式为:

$$\begin{bmatrix} \dot{\delta\theta} \\ \dot{\delta v} \\ \dot{\delta p} \\ \dot{\epsilon_r} \\ \dot{\nabla_r} \end{bmatrix} = \begin{bmatrix} -|\omega_m - \epsilon_r| \times & 0_{3 \times 3} & 0_{3 \times 3} & -I_{3 \times 3} & 0_{3 \times 3} \\ -C_b^n |a_m - \nabla_r| \times & 0_{3 \times 3} & 0_{3 \times 3} & 0_{3 \times 3} & -C_b^n \\ 0_{3 \times 3} & I_{3 \times 3} & 0_{3 \times 3} & 0_{3 \times 3} & 0_{3 \times 3} \\ 0_{3 \times 3} & 0_{3 \times 3} & 0_{3 \times 3} & -\frac{1}{\tau_g} & 0_{3 \times 3} \\ 0_{3 \times 3} & 0_{3 \times 3} & 0_{3 \times 3} & 0_{3 \times 3} & -\frac{1}{\tau_a} \end{bmatrix} \cdot \begin{bmatrix} \delta\theta \\ \delta v \\ \delta p \\ \epsilon_r \\ \nabla_r \end{bmatrix} + \begin{bmatrix} -I_{3 \times 3} & 0_{3 \times 3} & 0_{3 \times 3} & 0_{3 \times 3} \\ 0_{3 \times 3} & -C_b^n & 0_{3 \times 3} & 0_{3 \times 3} \\ 0_{3 \times 3} & 0_{3 \times 3} & 0_{3 \times 3} & 0_{3 \times 3} \\ 0_{3 \times 3} & 0_{3 \times 3} & I_{3 \times 3} & 0_{3 \times 3} \\ 0_{3 \times 3} & 0_{3 \times 3} & 0_{3 \times 3} & I_{3 \times 3} \end{bmatrix} \begin{bmatrix} w_\epsilon \\ w_{\nabla_r} \\ w_{\epsilon_r} \\ w_{\nabla_r} \end{bmatrix} \quad (8)$$

因为机载处理器只能以离散化的计算形式对导航数据进行处理, 因此需要将式 (7) 进行离散化处理。具体离散化流程可参考文献 [10], 本文采用泰勒展开的方式, 并且仅取二阶项, 如式 (9) 所示:

$$\Phi_{k+1,k} = e^{\int_{t_k}^{t_{k+1}} F(\tau) d\tau} = I + TF_k + \frac{T^2}{2!}(F_k)^2 + \dots \quad (9)$$

其中: $\Phi_{k+1,k} = \Phi(t_{k+1}, t_k)$, $F_k = F(t_k)$, $T = t_{k+1} - t_k$ 。根据系统状态转移矩阵 Φ 以及噪声矩阵 G , 可以求得系统的噪声协方差矩阵 Q_k 的离散化形式, 如式 (10):

$$Q_k = \int_{t_k}^{t_{k+1}} \Phi(t_{k+1}, \tau) G Q_c G^T (\Phi(t_{k+1}, \tau))^T d\tau \quad (10)$$

其中: Q_c 为系统噪声的协方差矩阵, 利用式 (9), 式 (10) 求得的状态转移矩阵与离散过程噪声协方差矩阵, 则可计算 $k+1$ 时刻的状态协方差矩阵:

$$P_{k+1,k} = \Phi_{k+1,k} P_k \Phi_{k+1,k}^T + Q_k \quad (11)$$

以及完成状态量的预测过程:

$$\hat{x}_{k+1,k} = \Phi_{k+1,k} \hat{x}_k \quad (12)$$

2.2 EKF 量测更新

量测更新采用视觉 SLAM 解算的位姿信息, 由于视觉输出位姿信息是离散形式的, 因此本文的量测方程可以直接离散化形式表示为:

$$Z_{k+1} = H_{k+1} X_{k+1} + V_{k+1} \quad (13)$$

其中:

$$Z_{k+1} = \begin{bmatrix} \varphi - \hat{\varphi} \\ \theta - \hat{\theta} \\ \phi - \hat{\phi} \\ X_n - \hat{p}_x \\ Y_n - \hat{p}_y \\ Z_n - \hat{p}_z \end{bmatrix} \quad (14)$$

其中: $[X_n, Y_n, Z_n]^T$ 为转换到本文所定义的导航坐标系下的轨迹对应的三维坐标值。

根据视觉 SLAM 的特性, 量测噪声 V_{k+1} 可以表示为:

$$V_{k+1} = [n_\theta \ n_p]^T, n_\theta \sim N(0, \sigma_{n_\theta}^2), n_p \sim N(0, \sigma_{n_p}^2) \quad (15)$$

其中: $n_p \in R^{3 \times 1}$ 为位置量测值所含白噪声, $n_\theta \in R^{3 \times 1}$ 为姿态量测值所含白噪声。

不难知道:

$$p + n_p = \begin{bmatrix} X_n \\ Y_n \\ Z_n \end{bmatrix} \quad (16)$$

则有:

$$\begin{bmatrix} X_n - \hat{p}_x \\ Y_n - \hat{p}_y \\ Z_n - \hat{p}_z \end{bmatrix} = \delta p + n_p \quad (17)$$

假设 $H = [H_\theta \ H_p]^T$, 上式对预测模型状态量求偏导, 则有:

$$H_p = [0_{3 \times 6} \ I_{3 \times 3} \ 0_{3 \times 6}] \quad (18)$$

同理可得:

$$H_\theta = [I_{3 \times 3} \ 0_{3 \times 12}] \quad (19)$$

根据上述量测更新模型, 可以计算 $k+1$ 时刻的增益矩阵:

$$K_{k+1} = P_{k+1,k} H_{k+1}^T (H_{k+1} P_{k+1,k} H_{k+1}^T + R_{k+1})^{-1} \quad (20)$$

进一步可以更新 $k+1$ 时刻的状态协方差矩阵:

$$P_{k+1} = (I - K_{k+1} H_{k+1}) P_{k+1,k} (I - K_{k+1} H_{k+1})^T + K_{k+1} R K_{k+1}^T \quad (21)$$

并完成对系统状态量的更新:

$$\hat{x}_{k+1} = \hat{x}_{k+1,k} + K_{k+1} (Z_{k+1} - H_{k+1} \hat{x}_{k+1,k}) \quad (22)$$

3 自适应渐消卡尔曼滤波

由于在建立 EKF 的系统模型的过程中, 通常会对其在合理的范围内进行近似或简化, 以提高解算效率, 但这些简化把不可避免的会使 EKF 的估计误差不断增大, 甚至严重影响滤波效果。因此, 本文采用了自适应卡尔曼滤波的方式来进一步提高视觉惯导融合的精度。

3.1 基本原理

为了减小在建模时由于模型近似或简化带来的估计误差, 可以在时间更新中求取当前时刻状态预测协方差矩阵时, 乘上相应的遗忘因子^[12], 即:

$$P_{k+1/k} = \lambda_{k+1} \Phi_{k+1/k} P_k \Phi_{k+1/k}^T + Q_k \quad (23)$$

其余更新流程与式 (12), 式 (20) ~ (22) 一致, 通

过分析可知,当估计误差增大时,会导致遗忘因子 λ_{k+1} 增大,从而状态预测协方差矩阵 $\mathbf{P}_{k+1,k}$ 也会相应增大, $\mathbf{P}_{k+1,k}$ 增大会使增益 $\mathbf{K}_{k+1}$ 增大,因此在计算经过测量更新得到的当前状态预测值时,会更多的信任量测信息,从而抑制历史状态信息带来的影响,即可减小由于建模时模型近似或简化带来的估计误差。从 λ_{k+1} 的物理意义可知,通常有:

$$\lambda_{k+1} \geq 1 \quad (24)$$

3.2 遗忘因子的求取方式

由于通过求取最优的遗忘因子,应当使自适应渐消卡尔曼滤波成为最优滤波器,因此遗忘因子在求取过程中,首先应该满足最优滤波器的性质。由文献 [9] 可知,最终可将最优滤波器的性质转化为如下等价条件:

$$\mathbf{P}_{k/k-1} \mathbf{H}_k^T - \mathbf{K}_k \mathbf{C}_{0k} = 0 \quad (25)$$

其中: $\mathbf{C}_{0k}$ 为残差的协方差,如下:

$$\mathbf{C}_{0k} = E[\mathbf{z}_k \mathbf{z}_k^T] = \mathbf{H}_k \mathbf{P}_{k/k-1} \mathbf{H}_k^T + \mathbf{R}_k \quad (26)$$

其中: $\mathbf{z}_k$ 为残差,是一个白噪声序列:

$$\mathbf{z}_k = \mathbf{Z}_k - \mathbf{H}_k \mathbf{X}_k \quad (27)$$

通过联立式 (25) 与式 (20), 可以将式 (25) 展开得到:

$$\mathbf{P}_{k,k-1} \mathbf{H}_k^T \{ \mathbf{I} - [\mathbf{H}_k \mathbf{P}_{k,k-1} \mathbf{H}_k^T + \mathbf{R}_k]^{-1} \mathbf{C}_{0k} \} = 0 \quad (28)$$

假设 $\mathbf{Q}_k, \mathbf{R}_k, \mathbf{P}_0$ 均正定, 且 $\mathbf{H}_k$ 满秩, 则将式 (28) 化简并将式 (23) 代入, 可展开得到:

$$\lambda_k \mathbf{M}_k = \mathbf{N}_k \quad (29)$$

其中:

$$\mathbf{M}_k = \mathbf{H}_k \Phi_{k,k-1} \mathbf{P}_{k-1} \Phi_{k,k-1}^T \mathbf{H}_k^T \quad (30)$$

$$\mathbf{N}_k = \mathbf{C}_{0k} - \mathbf{H}_k \mathbf{G}_{k-1} \mathbf{Q}_{k-1} \mathbf{G}_{k-1}^T \mathbf{H}_k^T - \mathbf{R}_k \quad (31)$$

其中: $\mathbf{C}_{0k}$ 由实际数据计算得到, 而非式 (26) 所示的理想化表达式得到, 则最佳遗忘因子计算方法如下:

$$\lambda_k = \max\{1, \text{tr}(\mathbf{N}_k) / \text{tr}(\mathbf{M}_k)\} \quad (32)$$

4 视觉信息滞后的补偿方法

4.1 问题描述

通过 AFKF 的方法, 能够得到精确的无人机姿态、速度以及位置信息。但由于实时的视觉 SLAM 求解位姿的过程根据具体运算平台以及算法的不同, 往往需要 30 ~ 200 ms 甚至更长的运算时间, 这将会导致视觉位姿信息滞后于惯导信息。




图 2 延时示意图

如图 2 所示, 由于视觉 SLAM 求解位姿需要一定的处理时间, 通常, 在 t_1 时刻获得的图像信息, 要在 t_2 时刻才能求解出相应的 SLAM 位姿结果, 并传递到组合导航流程与惯性信息融合, t_2 时刻获得的图像信息同理, 要在 t_3 时刻才能够解算出相应的位姿结果, 这不可避免的导致了视觉

位姿滞后于惯导信息, 即在 t_3 时刻对视觉位姿以及惯性信息进行融合时, 视觉位姿缺失了 t_2 时刻至 t_3 时刻的运动信息。因此, 我们需要对视觉位姿进行补偿, 以减缓甚至消除这类延时对系统带来的影响。

通常在简化 ORB_SLAM2 实时运行时:

$$t_2 - t_1 \neq t_3 - t_2 \quad (33)$$

也可以理解为, 通常连续两组位姿之间的惯导数据的数量并不相同, 即:

$$m \neq n \quad (34)$$

如图 2 所示, 假设 IMU 采样周期为 T , 则有:

$$\begin{cases} t_2 = t_1 + mT \\ t_3 = t_2 + kT \end{cases} \quad (35)$$

本文着重针对图 2 中, t_2 至 t_3 时刻的延时处理做详细说明, 其余时刻同理。

4.2 补偿姿态延时

由于视觉位姿的姿态信息包含了从初始参考帧一直到 t_2 时刻的姿态信息, 因此, 只需要补偿 t_3 时刻相对于 t_2 时刻的旋转量即可。可令 t_2 时刻为参考时刻, 即 t_2 时刻对应的旋转四元数为单位四元数 $[1, 0, 0, 0]^T$ 。

假设, IMU 采样周期为 T , $t_2 + T$ 时刻得到的陀螺仪在机体坐标系下的原始量测值为 $\omega_{t_2+T}^b$, 可得到 t_2 时刻到 $t_2 + T$ 时刻的等效旋转矢量为:

$$\Phi_{t_2+T} = \omega_{t_2+T}^b T = [\Delta \theta_x, \Delta \theta_y, \Delta \theta_z]^T |_{t_2+T} \quad (36)$$

$t_2 + T$ 时刻的四元数增量为:

$$q_{t_2+T}(t) = \left[\cos \frac{\Delta \theta}{2}, \frac{\Delta \theta_x}{\Delta \theta} \sin \frac{\Delta \theta}{2}, \frac{\Delta \theta_y}{\Delta \theta} \sin \frac{\Delta \theta}{2}, \frac{\Delta \theta_z}{\Delta \theta} \sin \frac{\Delta \theta}{2} \right]^T |_{t_2+T} \quad (37)$$

进而可得到, $t_2 + T$ 时刻对应的旋转四元数为:

$$Q(t_2 + T) = Q(t_2) \otimes q_{t_2+T}(t) \quad (38)$$

经过 k 次迭代后, 可以得到表示由 t_2 时刻到 t_3 时刻, 机体坐标系旋转量的四元数 $Q(t_3)$ 。

t_3 时刻由视觉信息得到的机体坐标系为 B 坐标系, 经过延时补偿后的机体坐标系为 B_- 坐标系, 则通过四元数与旋转矩阵间的转换关系^[11], 可得到表示由 B_- 坐标系旋转到 B 坐标系的旋转矩阵 $\mathbf{C}_{b_-}^b$, 由于在 t_3 时刻传入组合导航系统的视觉姿态量测信息, 表示的是 B 坐标系旋转到导航坐标系的旋转四元数, 即 $\mathbf{C}_b^c$, 则 t_3 时刻对应的真实旋转矩阵应该为:

$$\mathbf{C}_{b_-}^c = \mathbf{C}_b^c \mathbf{C}_{b_-}^b \quad (39)$$

进而通过旋转矩阵与欧拉角间的转换关系^[11], 可求出 t_3 时刻对应的真实姿态角, 从而完成姿态延时的补偿。

4.3 补偿位置延时

由于视觉位姿的姿态信息包含了从初始参考帧一直到 t_2 时刻的位置信息, 因此, 只需要补偿 t_3 时刻相对于 t_2 时刻的平移量即可, 也即是, 认为 t_2 时刻为参考时刻, 即 t_2 时刻对应的相对位置为:

$$p_{t_2} = [0, 0, 0]^T \quad (40)$$

其对应的初始速度可以由组合导航算法在 t_2 时刻输出的速度量得到, 则 t_2 时刻对应的速度为:

$$v_{t_2} = [v_x, v_y, v_z]^T |_{t_2} \quad (41)$$

假设 $t_2 + T$ 时刻 IMU 采集到的机体坐标系下的原始加速度值为:

$$a_{t_2+T} = [a_x, a_y, a_z]^T |_{t_2+T} \quad (42)$$

则通过运动学公式, 可以得到 $t_2 + T$ 时刻对应的速度为:

$$v_{t_2+T} = v_{t_2} + a_{t_2+T}T \quad (43)$$

同理, 通过运动学公式, 可以得到 $t_2 + T$ 对应的相对位置为:

$$p_{t_2+T} = \frac{1}{2}(v_{t_2} + v_{t_2+T})T \quad (44)$$

经过 k 次迭代, 最终可以得到 B_- 坐标系相对于 B 坐标系在导航坐标系下的相对位移:

$$p_{t_3} = [p_x, p_y, p_z]^T |_{t_3} \quad (45)$$

由于在时刻 t_3 传入组合导航系统的视觉位置量测信息, 表示的是 B 坐标系在导航坐标系下的位置信息 P_{t_3} , 则 t_3 时刻对应的真实位置信息应该为:

$$P_{t_3} = P_{t_3} + p_{t_3} \quad (46)$$

5 实验结果分析

本文将采用 EuRoC 数据集集中的 V2_02_medium 序列来对本文算法进行验证, 首先是基于该序列验证本文的 AFKF 算法, 由此分析 AFKF 的相对于传统 EKF 在视觉惯导组合导航中的优越性; 其次, 本文将基于简化 ORB_SLAM2 从 V2_02_medium 序列解算得到的视觉位姿信息, 人工模拟 200 ms 的延时, 并采用本文的延时补偿方法对延时进行处理, 并分析本文算法的有效性。

5.1 AFKF 仿真结果

本文首先基于简化 ORB_SLAM2 对 V2_02_medium 图像序列进行视觉位姿解算, 得到相应的视觉位姿, 并在数学仿真平台上完成视觉位姿与 V2_02_medium 序列中相应的惯导数据进行坐标系统一, 最终对得到的数据分别通过传统 EKF 算法与 AFKF 算法进行导航解算, 并作相应比较, 初始化数据如下所示:

$$P = \text{diag}([(0.5 * \pi/180)^2, (0.5 * \pi/180)^2, (0.5 * \pi/180)^2, (0.5)^2, (0.5)^2, (0.5)^2, (0.4)^2, (0.4)^2, (0.4)^2, (0.5 * \pi/180/3600)^2, (0.5 * \pi/180/3600)^2, (0.5 * \pi/180/3600)^2, (5E-4)^2, (5E-4)^2, (5E-4)^2]) \quad (47)$$

$$q = \text{diag}([(2 * \pi/180)^2, (2 * \pi/180)^2, (2 * \pi/180)^2, (5E-3)^2, (5E-3)^2, (5E-3)^2, (5E-2)^2, (5E-2)^2, (5E-2)^2, (0.5 * \pi/180)^2, (0.5 * \pi/180)^2, (0.5 * \pi/180)^2, (5E-3)^2, (5E-3)^2, (5E-3)^2]) \quad (48)$$

$$R = \text{diag}([(0.5 * \pi/180)^2, (0.5 * \pi/180)^2, (0.5 * \pi/180)^2, (0.5)^2, (0.5)^2, (0.5)^2]) \quad (49)$$

通过仿真可以得到姿态曲线, 以及与姿态真值之间姿态误差曲线, 如图 3 和图 4 所示。




图3 EKF、AFKF 姿态曲线




图4 EKF、AFKF 与真值的姿态误差曲线

如图 3 和图 4 所示, 传统 EKF 方法与 AFKF 方法, 均能较好地跟踪姿态真值, 其误差在 5° 以内, 并且, AFKF 相对于传统 EKF 而言, 在一定程度上可以降低姿态误差, 以获得更高精度的姿态解算值。

速度曲线, 以及与速度真值之间的速度误差曲线分别如图 5 和图 6 所示。相对于传统 EKF 而言, 通过 AFKF 可以有效降低与真值之间的速度误差, 并误差在 0.2 m/s 以内, 相对于传统 EKF 算法, 性能提升了约 30% 左右。

位置曲线, 以及与位置真值之间的位置误差曲线分别如图 7~图 8 所示。通过 AFKF 方法, 可以使通过组合导航解算得到的位置、速度以及姿态信息的精度进一步提高, 从而提高滤波器性能。

5.2 延时补偿仿真结果

本小节在前一小节的基础上, 对得到的视觉位姿人工添加了相对于 V2_02_medium 序列中惯导信息的 200 ms 的滞后, 并在数学仿真平台上分别采用了未加延时补偿的 AFKF 算法与添加了延时补偿的 AFKF 进行了数据融合, 本小节的仿真初始化数据与式 (47)~(49) 一致。




图 5 EKF、AFKF 速度曲线




图 6 EKF、AFKF 与真值的速度误差曲线




图 7 EKF、AFKF 位置曲线

图 9、10 分别为姿态曲线，以及未采用延时补偿方法和采用延时补偿方法时，通过 AFKF 得到的姿态与真值之间的姿态误差曲线。




图 8 EKF、AFKF 与真值的位置误差曲线

如图 9 和图 10 所示，采用本文的延时补偿方法后，不仅显著地降低了姿态误差，使跟踪性能得到了非常大的提升，并且始终将姿态误差维持在 5° 以内，基本与未加入 200 ms 人工延时的估计精度一致。




图 9 采用与未采用延时补偿的 AFKF 姿态曲线




图 10 采用与未采用延时补偿的 AFKF 姿态与真值的姿态误差曲线

图 11~12 分别为速度曲线, 以及未采用延时补偿方法和采用延时补偿方法时, 通过 AFKF 得到的姿态与真值之间的速度误差曲线。

如图 11 和图 12 所示, 通过本文的延时补偿方法, 速度误差显著降低, 有效缓解了人工延时带来的误差, 相对于未采用延时补偿的情况, 对真值的跟踪更加精确。




图 11 采用与未采用延时补偿的 AFKF 速度曲线




图 12 采用与未采用延时补偿的 AFKF 速度与真值的速度误差曲线

图 13 和图 14 分别为位置曲线, 以及未采用延时补偿方法和采用延时补偿方法时, 通过 AFKF 得到的姿态与真值之间的位置误差曲线。

如图 13 和图 14 所示, 采用本文的延时补偿方法后, 有效地降低了由人工延时带来的位置误差, 并且基本维持了未加入人工延时时的位置解算精度, 误差维持在 0.4 m 内。

6 结束语

通过实验证明, 本文的算法通过引入自适应算法与延时补偿算法, 有效提高组合导航系统的解算精度, 提高滤




图 13 采用与未采用延时补偿的 AFKF 位置曲线




图 14 采用与未采用延时补偿的 AFKF 位置与真值的位置误差曲线

波器性能, 能够在保证视觉位姿解算精度的前提下, 得到 200 Hz 的导航解算结果, 非常适合无人机等需要高频率导航信息, 且硬件算力有限的平台^[13-14]。

参考文献:

- [1] Abdelkrim N, Aouf N, Tsourdos A, et al. Robust nonlinear filtering for INS/GPS UAV localization [A]. 2008 Mediterranean Conference on Control and Automation [C]. 2008: 695-702.
- [2] Klein G, Murray D W. Parallel tracking and mapping for small AR workspaces [A]. Sixth IEEE/ACM International Symposium on Mixed and Augmented Reality, ISMAR 2007 [C]. Nara, Japan, 2007: 225-234.
- [3] Raul M A, et al. Orb-slam: a versatile and accurate monocular slam system [J]. IEEE Transactions on Robotics, 2015, 31(5): 1147-1163.

(下转第 149 页)