

DOI: 10.19650/j.cnki.cjsi.J1904702

基于相机状态方程多模增广的改进 MSCKF 算法*

齐乃新¹, 张胜修¹, 杨小冈¹, 李传祥¹, 曹立佳²

(1. 火箭军工程大学导弹工程学院 西安 710025; 2. 四川轻化工大学自动化与信息工程学院 自贡 643000)

摘要:针对基于多状态约束卡尔曼滤波(MSCKF)的视觉-惯性里程计算法中相机状态方程增广过程的误差累积问题,提出了一种相机状态方程多模增广方法。该方法首先对视觉特征跟踪状态的稳定性进行判断,然后自动地选择基于视觉图像信息优化求解相机相对位姿参数或基于惯性传感器(IMU)状态递推结果联合相机外参初始化新图像帧相机位姿参数两种途径增广相机的状态方程,解决特征跟踪状态稳定情况下IMU误差的累积问题。实验部分通过EuRoC数据和实际应用数据对算法的性能进行了验证分析,结果表明,改进后的MSCKF算法能够在特征跟踪稳定状态下有效避免IMU误差的累积,进一步融合视觉与惯性系统之间的互补优势,提高载体的定位定向精度和稳定性。

关键词:视觉-惯性里程计;多状态约束扩展卡尔曼滤波器;视觉里程计;位姿图优化

中图分类号: TP391.4 TH76 **文献标识码:** A **国家标准学科分类代码:** 520.20

An improved MSCKF algorithm based on multi-mode augmentation method for the camera state equation

Qi Naixin¹, Zhang Shengxiu¹, Yang Xiaogang¹, Li Chuanxiang¹, Cao Lijia^{2,3}

(1. College of Missile Engineering, Rocket Force University of Engineering, Xi'an 710025, China;

2. College of Automation and Information Engineering, Sichuan University of Science & Engineering, Zigong 64300, China)

Abstract: Aiming at the error accumulation problem of the visual-inertial odometry algorithm based on multi-state constraint kalman filter (MSCKF) in the augmentation process of the camera state equation, a multi-mode augmentation method of camera state equation is proposed. In this method, the stability of the visual feature tracking state is strictly judged firstly; then, two methods are automatically selected to augment the camera state equation, the first method optimally solves the relative pose parameters of the camera based on visual image information, another method is based on the recursion results of inertial measurement unit (IMU) state combining the camera-IMU external parameters to initialize the camera pose parameters for new image frame. As a result, the error accumulation problem of IMU under the stable feature tracking state is solved. In the experiment part, the performance of the proposed algorithm is verified utilizing the EuRoC dataset and practical application dataset. The experiment results show that the improved MSCKF algorithm can effectively avoid the error accumulation of IMU under the stable feature tracking state, further fuse the complementary advantages of both visual and inertial systems, and improve the localization & orientation precision and stability of the carrier.

Keywords: visual-inertial odometry; multi-state constraint EKF; visual odometry; pose graph optimization

0 引言

惯性传感器(inertial measurement unit, IMU)配备加速度计和陀螺仪,能够测量输出载体的三轴加速度和三

轴角速度。基于IMU的运动估计能够准确的输出载体短时间内的快速运动,弥补纯视觉运动估计中存在的运动模糊及特征缺失的不足^[1-2]。对于长时间的载体运动,视觉能够有效地估计其位姿参数,修正IMU测量数据中的漂移误差,解决载体慢速运动位姿估计的问题。因此,

IMU 被认为是与相机互补性较强的测量元件,在基于视觉的定位定向^[3-4]以及三维重建中得到了广泛的关注^[5]。

目前,利用相机与 IMU 数据融合实现载体位姿估计的算法称为视觉惯性里程计 (visual-inertial odometry, VIO)^[6-7],根据其实现途径,可以分为基于滤波的 VIO 算法^[8]和基于优化的 VIO 算法^[9-10]。基于滤波的方法以滤波器为基础,将视觉系统的运动参数和惯性系统的运动参数作为状态量,以相机采集的视觉信息和 IMU 输出的惯性信息为测量量,同时考虑相机和 IMU 的噪声及漂移误差,估计载体的运动参数;基于优化的方法是以图优化为框架,将相机观测到的视觉信息和 IMU 输出的惯性信息显式地规划成优化问题,然后采用通用图优化 (general graph optimization, g2o) 框架联合优化载体的运动参数^[11]。其中,基于优化的 VIO 算法精度较高,但是要处理 IMU 的高频数据,具有较大的计算量^[12]。而基于滤波的方法能够有效地处理高频数据,状态更新速度较快,具有较好的实时性,能够更好的应用于实时系统中^[13]。

基于滤波的 VIO 算法根据框架类型又可以分为松耦合 (loosely coupled)^[14]和紧耦合 (tightly coupled)^[15]。松耦合就是将视觉与惯性看成两个独立的运动估计模块,然后将两个模块的位姿估计结果进行融合解算载体的运动参数。其中,最具有代表性的就是 MSF 算法框架^[16],该框架是一个比较成熟的多传感器融合框架,能够稳定的融合视觉、激光、IMU 以及码盘等多种传感器,其最大的特点就是计算简单,复杂度较小,而由此带来的不足就是精度不高,适用于精度要求比较低的系统。紧耦合则是使用两个传感器的原始数据共同估计载体的运动参数,这类算法比较复杂,但往往具有较高的精度,比较具有代表性的算法有 Rovio^[17]和 Msckf^[18]。ROVIO 算法是以扩展卡尔曼滤波器 (extended Kalman filter, EKF) 算法为框架,基于图像块实现的一种 VIO 算法,其优点是基于图像块,具有较小的计算量,但其对参数的依赖程度较大,对应不同的设备需要调节不同的参数,并且具有累积误差,算法总体精度不够高。MSCKF 算法同样以 EKF 滤波器为框架,采用一个滑动窗口将多时刻的相机状态加入到状态方程和协方差矩阵中,有效地解决了传统 EKF-SLAM 框架中状态方程维数过大的问题,降低了算法的计算复杂度,具有较好的实时性和精度,并成功应用于谷歌 tango 中。有学者对 MSCKF 算法进行了改进,如文献 [19-20] 中将相机与 IMU 之间的标定参数一同写入到滤波器的状态方程中,增加了系统的可观测性和一致性;文献 [21] 将图像块的光度误差最小化过程融合到 EKF 测量模型中,提高了算法处理相机快速运动情况的鲁棒性和精度;文献 [22] 将 MSCKF 进行了扩展,使其能够利用双目相机实现小型飞行器的定位功能。

当相机观测到一帧新图像时,需要初始化相机的位

姿参数,增广相机状态方程,在 MSCKF 算法及其现有的改进版本中,采用 EKF 的滤波结果以及相机与 IMU 之间的标定参数计算完成,随着时间的推移,势必会累积一定的 IMU 误差,影响算法的精度。针对此问题,本文提出将基于纯视觉信息的位姿图优化过程引入到新图像帧相机位姿参数求解的过程中,根据特征点跟踪状态,构建两种不同的状态增广方式,利用光束平差 (bundle adjustment, BA) 算法的高精度估计结果修正 IMU 引入的累积误差,以 IMU 的短时高精度测量输出弥补视觉系统难以克服的运动模糊和特征缺失的不足,充分发挥视觉与惯性系统之间的互补优势。

1 多状态约束 EKF 算法的基本方程

1.1 MSCKF 算法的状态方程及 IMU 的状态预测

MSCKF 滤波器的状态误差方程包括 IMU 的状态误差方程和相机的状态误差方程两部分,其中 IMU 的状态误差方程是一个 22×1 的向量,包含 IMU 的运动参数、随机游走误差以及和相机之间的外参,如式 (1) 所示。

$$\bar{X}_{IMU} = [\delta\theta_I^T \quad \bar{b}_g^T \quad \bar{c}_{v_I}^T \quad \bar{b}_a^T \quad \bar{c}_{p_I}^T \quad \delta\theta_C^T \quad \bar{p}_C^T]^T \quad (1)$$

式中: \bar{c}_{p_I} 和 \bar{c}_{v_I} 是 IMU 在惯性坐标系下的位置误差和速度误差; \bar{b}_g 、 \bar{b}_a 为 IMU 的角速度和线加速度的随机游走误差; $\delta\theta_I^T$ 表示 IMU 在惯性坐标系 $\{G\}$ 下的转动量误差; $\delta\theta_C^T$ 和 \bar{p}_C 为相机与 IMU 之间的标定参数。

对于单个相机状态,定义其状态误差方程为:

$$\bar{X}_{C_i} = [\delta\theta_{C_i}^T \quad \bar{c}_{p_{C_i}}^T]^T \quad (2)$$

式中: $\delta\theta_{C_i}^T$ 和 $\bar{c}_{p_{C_i}}^T$ 表示相机在惯性坐标系 $\{G\}$ 的转动量误差和位置误差。整个 MSCKF 包含一个 IMU 状态向量和 N 个相机状态向量,其状态误差方程定义为:

$$\bar{X} = [\bar{X}_{IMU}^T \quad \delta\theta_{C_1}^T \quad \bar{c}_{p_{C_1}}^T \quad \cdots \quad \delta\theta_{C_N}^T \quad \bar{c}_{p_{C_N}}^T]^T \quad (3)$$

连续时间系统中,IMU 的运动模型可以描述为:

$$\begin{aligned} {}_I^G \bar{q} \cdot (t) &= \frac{1}{2} \Omega(\omega(t)) {}_I^G \bar{q} (t) \\ \dot{\bar{b}}_g(t) &= n_{wg}(t), \dot{\bar{b}}_a(t) = n_{wa}(t) \\ {}_G^C \dot{\bar{v}}_I(t) &= {}^G a(t), {}_G^C \dot{\bar{p}}_I(t) = {}^G v_I(t) \\ {}_I^G \bar{q} \cdot (t) &= \mathbf{0}_{3 \times 1}, {}_I^G \bar{p}_C(t) = \mathbf{0}_{3 \times 1} \end{aligned} \quad (4)$$

式中: ${}^G a$ 表示 IMU 在惯性坐标系中的线加速度; n_{wg} 和 n_{wa} 表示随机游走误差 \bar{b}_g 和 \bar{b}_a 的噪声; $\omega(t) = [\omega_x \quad \omega_y \quad \omega_z]^T$ 表示 IMU 的角速度; $\Omega(\omega) =$

$$\begin{bmatrix} 0 & -\omega_z & \omega_y \\ -[\omega \times] & \omega & \\ -\omega^T & \mathbf{0} & \end{bmatrix}, [\omega \times] = \begin{bmatrix} 0 & -\omega_z & \omega_y \\ \omega_z & 0 & -\omega_x \\ -\omega_y & \omega_x & 0 \end{bmatrix}。$$

考虑地球重力因素下的 IMU 角速度和线加速度的测量值可以表示为:

$$\boldsymbol{\omega}_m = \boldsymbol{\omega} + C(\overset{l}{c}\bar{\boldsymbol{q}})\boldsymbol{\omega}_G + \boldsymbol{b}_g + \boldsymbol{n}_g \quad (5)$$

$$\boldsymbol{a}_m = C(\overset{l}{c}\bar{\boldsymbol{q}})(\overset{c}{c}\boldsymbol{a} - \overset{c}{c}\boldsymbol{g} + 2[\boldsymbol{\omega}_G \times]^c \boldsymbol{v}_l + [\boldsymbol{\omega}_G \times]^{2c} \boldsymbol{p}_l) + \boldsymbol{b}_a + \boldsymbol{n}_a \quad (6)$$

式中: $C(\cdot)$ 表示单位四元数到旋转矩阵的转换; \boldsymbol{n}_g 和 \boldsymbol{n}_a 分别表示 IMU 角速度和线加速度的测量噪声, 均为零均值高斯白噪声; $\boldsymbol{\omega}_G$ 为地球重力在角速度上的分量; $\overset{c}{c}\boldsymbol{g}$ 为地球重力在线加速度上的分量。

根据式(4)~(6), IMU 观测向量的传递模型可以表示为:

$$\begin{aligned} \overset{l}{c}\hat{\boldsymbol{q}} &= \frac{1}{2}\boldsymbol{\Omega}(\hat{\boldsymbol{\omega}})\overset{l}{c}\hat{\boldsymbol{q}} \\ \dot{\hat{\boldsymbol{b}}}_g &= \mathbf{0}_{3 \times 1}, \dot{\hat{\boldsymbol{b}}}_a = \mathbf{0}_{3 \times 1} \\ \overset{c}{c}\hat{\boldsymbol{v}}_l &= \mathbf{C}_q^T \hat{\boldsymbol{a}} - 2[\boldsymbol{\omega}_G \times]^c \boldsymbol{v}_l - [\boldsymbol{\omega}_G \times]^{2c} \hat{\boldsymbol{p}}_l + \overset{c}{c}\boldsymbol{g} \\ \overset{c}{c}\hat{\boldsymbol{p}}_l &= \overset{c}{c}\hat{\boldsymbol{v}}_l, \overset{c}{c}\hat{\boldsymbol{p}}_c = \mathbf{0}_{3 \times 1}, \overset{l}{l}\hat{\boldsymbol{p}}_c = \mathbf{0}_{3 \times 1} \end{aligned} \quad (7)$$

式中: \mathbf{C}_q 是 $C(\overset{l}{c}\bar{\boldsymbol{q}})$ 的简写形式; $\hat{\boldsymbol{a}} = \boldsymbol{a}_m - \hat{\boldsymbol{b}}_a$; $\hat{\boldsymbol{\omega}} = \boldsymbol{\omega}_m - \hat{\boldsymbol{b}}_g - \mathbf{C}_q \boldsymbol{\omega}_G$ 。将 IMU 的状态误差方程线性化表示为:

$$\dot{\tilde{\boldsymbol{X}}}_{IMU} = \boldsymbol{F} \tilde{\boldsymbol{X}}_{IMU} + \boldsymbol{G} \boldsymbol{n}_{IMU} \quad (8)$$

式中: $\boldsymbol{n}_{IMU} = [\boldsymbol{n}_g^T \ \boldsymbol{n}_{ug}^T \ \boldsymbol{n}_a^T \ \boldsymbol{n}_{aa}^T]^T$ 表示 IMU 的系统噪声方程, \boldsymbol{F} 和 \boldsymbol{G} 为状态矢量和噪声矢量对应的系数矩阵。

在 MSCKF 中, 用于状态预测的 IMU 数据 $\boldsymbol{\omega}_m$ 和 \boldsymbol{a}_m 是以 Δt 为时间间隔离散获取的, 当 IMU 获取一组测量值后, 滤波器根据式(7)完成一次状态预测。同时, MSCKF 的误差方差阵也完成一次预测, 计算式为:

$$\boldsymbol{P}_{klk+1} = \begin{bmatrix} \boldsymbol{P}_{ll_{t_{k+1}}} & \boldsymbol{\Phi}_{l_{t_{k+1}}, t_k} \boldsymbol{P}_{l_{t_k}} \\ \boldsymbol{P}_{l_{t_k} c_{u_k}}^T & \boldsymbol{\Phi}_{l_{t_{k+1}}, t_k}^T \boldsymbol{P}_{l_{t_k}} \\ \boldsymbol{P}_{c_{u_k} c_{u_k}} & \boldsymbol{P}_{c_{u_k} c_{u_k}} \end{bmatrix} \quad (9)$$

式中: $\boldsymbol{P}_{ll_{t_{k+1}}}$ 为 IMU 的误差方差阵, 其维数为 21×21 ; $\boldsymbol{P}_{c_{u_k} c_{u_k}}$ 为相机的误差方差阵, 其维数为 $6N \times 6N$, N 为相机状态的个数; $\boldsymbol{P}_{l_{t_k} c_{u_k}}$ 为相机和 IMU 之间的相关误差方差阵, 其维数为 $21 \times 6N$; $\boldsymbol{\Phi}_{l_{t_{k+1}}, t_k}$ 是离散时间系统的 IMU 状态转移矩阵。

$$\boldsymbol{\Phi}_{l_{t_{k+1}}, t_k} = \exp\left(\int_{t_k}^{t_{k+1}} \boldsymbol{F}(\tau) d\tau\right) \quad (10)$$

式中: 积分初值取 $\boldsymbol{\Phi}_{l_{t_k}, t_k} = \boldsymbol{I}_{21}$ 。 $\boldsymbol{P}_{ll_{t_{k+1}}}$ 计算式为:

$$\boldsymbol{P}_{ll_{t_{k+1}}} = \boldsymbol{\Phi}_{l_{t_{k+1}}, t_k} \boldsymbol{P}_{ll_{t_k}} \boldsymbol{\Phi}_{l_{t_{k+1}}, t_k}^T + \boldsymbol{Q}_k \quad (11)$$

式中: \boldsymbol{Q}_k 表示离散时间系统中 IMU 的噪声方差阵。

$$\boldsymbol{Q}_k = \int_{t_k}^{t_{k+1}} \boldsymbol{\Phi}_{l_{t_{k+1}}, \tau} \boldsymbol{G} \boldsymbol{Q}_{IMU} \boldsymbol{G}^T \boldsymbol{\Phi}_{l_{t_{k+1}}, \tau}^T d\tau \quad (12)$$

1.2 MSCKF 算法的观测方程及观测更新

定义 VIO 系统的残差 \boldsymbol{r} 的线性表达式为:

$$\boldsymbol{r} = \boldsymbol{H} \tilde{\boldsymbol{X}} + \boldsymbol{n} \quad (13)$$

式中: \boldsymbol{H} 表示观测量的雅可比矩阵; $\tilde{\boldsymbol{X}}$ 表示系统的状态误

差; \boldsymbol{n} 表示系统的零均值白噪声矩阵。

定义地图点 f_j , 能够在连续的 M_j 帧中被相机观测到, 每个时刻相机的状态向量定义为 $(\overset{c}{c}\bar{\boldsymbol{q}}, \overset{c}{c}\boldsymbol{p}_c)$, $i \in S_j$, 则每个时刻相机对此地图点的观测模型可以定义为:

$$\boldsymbol{z}_i^{(j)} = \frac{1}{c} \begin{bmatrix} \overset{c}{c}\boldsymbol{X}_j \\ \overset{c}{c}\boldsymbol{Y}_j \\ \overset{c}{c}\boldsymbol{Z}_j \end{bmatrix} + \boldsymbol{n}_i^{(j)}, \quad i \in S_j \quad (14)$$

式中: $\boldsymbol{n}_i^{(j)}$ 表示相机传感器系统的零均值高斯白噪声, 其协方差矩阵可以定义为 $\boldsymbol{R}_i^{(j)} = \sigma_{im}^2 \boldsymbol{I}_2$ 。地图点 f_j 在每一次观测时刻相机坐标系下位置向量 $\overset{c}{c}\boldsymbol{p}_f$ 的计算公式为:

$$\overset{c}{c}\boldsymbol{p}_f = \begin{bmatrix} \overset{c}{c}\boldsymbol{X}_j \\ \overset{c}{c}\boldsymbol{Y}_j \\ \overset{c}{c}\boldsymbol{Z}_j \end{bmatrix} = C(\overset{c}{c}\bar{\boldsymbol{q}}) (\overset{c}{c}\boldsymbol{p}_f - \overset{c}{c}\boldsymbol{p}_c) \quad (15)$$

式中: $\overset{c}{c}\boldsymbol{p}_f$ 为地图点在惯性坐标系下的位置向量, 其值可以通过观测量 $\boldsymbol{z}_i^{(j)}$, $i \in S_j$ 和相机的位姿估计值进行估计求解, 记为 $\overset{c}{c}\hat{\boldsymbol{p}}_f$ 。

当得到地图点的位置向量估计值后, 系统的残差方程计算为:

$$\boldsymbol{r}_i^{(j)} = \boldsymbol{z}_i^{(j)} - \hat{\boldsymbol{z}}_i^{(j)} \quad (16)$$

式中: $\hat{\boldsymbol{z}}_i^{(j)} = \frac{1}{c} \begin{bmatrix} \overset{c}{c}\hat{\boldsymbol{X}}_j \\ \overset{c}{c}\hat{\boldsymbol{Y}}_j \\ \overset{c}{c}\hat{\boldsymbol{Z}}_j \end{bmatrix}$ 。又有:

$$\begin{bmatrix} \overset{c}{c}\hat{\boldsymbol{X}}_j \\ \overset{c}{c}\hat{\boldsymbol{Y}}_j \\ \overset{c}{c}\hat{\boldsymbol{Z}}_j \end{bmatrix} = C(\overset{c}{c}\hat{\boldsymbol{q}}) (\overset{c}{c}\hat{\boldsymbol{p}}_f - \overset{c}{c}\hat{\boldsymbol{p}}_c) \quad (17)$$

式(16)可以线性化表示为:

$$\boldsymbol{r}_i^{(j)} \approx \boldsymbol{H}_X^{(j)} \tilde{\boldsymbol{X}} + \boldsymbol{H}_f^{(j)} \overset{c}{c}\tilde{\boldsymbol{p}}_f + \boldsymbol{n}_i^{(j)} \quad (18)$$

其中, $\boldsymbol{H}_X^{(j)}$ 是 $\boldsymbol{z}_i^{(j)}$ 相对于状态误差的雅可比矩阵。

$\boldsymbol{H}_f^{(j)}$ 是 $\boldsymbol{z}_i^{(j)}$ 相对于地图点的雅可比矩阵, $\overset{c}{c}\tilde{\boldsymbol{p}}_f$ 是地图点的位置误差。将式(18)扩展到对地图点的所有观测, 即可得到该地图点的残差方程为:

$$\boldsymbol{r}^{(j)} \approx \boldsymbol{H}_X^{(j)} \tilde{\boldsymbol{X}} + \boldsymbol{H}_f^{(j)} \overset{c}{c}\tilde{\boldsymbol{p}}_f + \boldsymbol{n}^{(j)} \quad (19)$$

式中: $\boldsymbol{r}^{(j)}$ 、 $\boldsymbol{H}_X^{(j)}$ 、 $\boldsymbol{H}_f^{(j)}$ 、 $\boldsymbol{n}^{(j)}$ 是由 $\boldsymbol{r}_i^{(j)}$ 、 $\boldsymbol{H}_X^{(j)}$ 、 $\boldsymbol{H}_f^{(j)}$ 、 $\boldsymbol{n}_i^{(j)}$ 组成的块矩阵, i 取值为 $i \in S_j$ 。地图点的不同观测向量之间是相互独立的, 因此噪声 $\boldsymbol{n}^{(j)}$ 的协方差矩阵可以定义为 $\boldsymbol{R}^{(j)} = \sigma_{im}^2 \boldsymbol{I}_{2M_j}$ 。

地图点的位置向量是通过观测量 $\boldsymbol{z}_i^{(j)}$, $i \in S_j$ 以及相机的位姿估计值进行解算的, 因此, 特征点的位置误差 $\overset{c}{c}\tilde{\boldsymbol{p}}_f$ 与系统的状态误差 $\tilde{\boldsymbol{X}}$ 是相关的, 残差 $\boldsymbol{r}_i^{(j)}$ 不能线性化为式(13)的形式, 也不能直接用于 MSCKF 的观测更新。为解决这个问题, 将式(19)左乘 $\boldsymbol{H}_f^{(j)}$ 的左零空间矩阵 \boldsymbol{A} :

$$\boldsymbol{A} \boldsymbol{r}^{(j)} \approx \boldsymbol{A} \boldsymbol{H}_X^{(j)} \tilde{\boldsymbol{X}} + \boldsymbol{A} \boldsymbol{H}_f^{(j)} \overset{c}{c}\tilde{\boldsymbol{p}}_f + \boldsymbol{A} \boldsymbol{n}^{(j)} = \boldsymbol{A} \boldsymbol{H}_X^{(j)} \tilde{\boldsymbol{X}} + \boldsymbol{A} \boldsymbol{n}^{(j)} \quad (20)$$

令 $\mathbf{r}_o^{(j)} = \mathbf{A}\mathbf{r}^{(j)}$, $\mathbf{H}_o^{(j)} = \mathbf{A}\mathbf{H}_X^{(j)}$, $\mathbf{n}_o^{(j)} = \mathbf{A}\mathbf{n}^{(j)}$, 式(20)可以表述为:

$$\mathbf{r}_o^{(j)} = \mathbf{H}_o^{(j)} \tilde{\mathbf{X}}^{(j)} + \mathbf{n}_o^{(j)} \quad (21)$$

因为矩阵 $\mathbf{H}_f^{(j)}$ 的秩为 $2M_j \times 3$, 所以矩阵 \mathbf{A} 的维数为 $2M_j - 3$, 则残差 $\mathbf{r}_o^{(j)}$ 为 $(2M_j - 3) \times 1$ 的向量。式(21)定义了相机状态对地图点的线性约束, 其利用到了观测量 $\mathbf{z}_i^{(j)}$ 的所有可用信息, 并且相对于特征点是独立的, 能够直接用于观测更新得到 MSCKF 的状态最优值。噪声矢量 $\mathbf{n}_o^{(j)}$ 的协方差矩阵可以计算为:

$$\mathbf{E}\{\mathbf{n}_o^{(j)} \mathbf{n}_o^{(j)\top}\} = \sigma_{im}^2 \mathbf{A}^\top \mathbf{A} = \sigma_{im}^2 \mathbf{I}_{2M_j-3} \quad (22)$$

考虑到所有 L 个特征点, 整个 VIO 系统的残差方程可以表示为:

$$\mathbf{r}_o = \mathbf{H}_X \tilde{\mathbf{X}} + \mathbf{n}_o \quad (23)$$

式中: \mathbf{r}_o 是由 $\mathbf{r}_o^{(j)}$ 组成的块矩阵; \mathbf{n}_o 是由 $\mathbf{n}_o^{(j)}$ 组成的块矩阵; \mathbf{H}_X 是由 $\mathbf{H}_o^{(j)}$ 组成的块矩阵; j 的取值为 $j=1 \cdots L$ 。所有地图点的观测值是相互独立的, 其噪声 \mathbf{n}_o 的协方差矩阵可以表述为:

$$\mathbf{R}_o = \sigma_{im}^2 \mathbf{I}_d \quad (24)$$

式中: d 为残差 \mathbf{r}_o 的维数 $d = \sum_{j=1}^L (2M_j - 3)$, 与能够观测的地图点数量和相机的状态直接相关, 并且在实际应用中取值较大, 因此会增加 MSCKF 更新过程的计算复杂度。为解决此问题, 将测量矩阵 \mathbf{H}_X 进行正交三角(QR)分解, 得到:

$$\mathbf{H}_X = [\mathbf{Q}_1 \quad \mathbf{Q}_2] \begin{bmatrix} \mathbf{T}_H \\ \mathbf{0} \end{bmatrix} \quad (25)$$

式中: \mathbf{Q}_1 矩阵和 \mathbf{Q}_2 矩阵是唯一的, 受 \mathbf{H}_X 的零空间和秩的约束, \mathbf{T}_H 是上三角矩阵。将式(25)代入式(23)可得:

$$\mathbf{r}_o = [\mathbf{Q}_1 \quad \mathbf{Q}_2] \begin{bmatrix} \mathbf{T}_H \\ \mathbf{0} \end{bmatrix} \tilde{\mathbf{X}} + \mathbf{n}_o \quad (26)$$

左乘 $[\mathbf{Q}_1 \quad \mathbf{Q}_2]^\top$, 式(26)可以转换为:

$$\begin{bmatrix} \mathbf{Q}_1^\top \mathbf{r}_o \\ \mathbf{Q}_2^\top \mathbf{r}_o \end{bmatrix} = \begin{bmatrix} \mathbf{T}_H \\ \mathbf{0} \end{bmatrix} \tilde{\mathbf{X}} + \begin{bmatrix} \mathbf{Q}_1^\top \mathbf{n}_o \\ \mathbf{Q}_2^\top \mathbf{n}_o \end{bmatrix} \quad (27)$$

式中: $\mathbf{Q}_2^\top \mathbf{r}_o$ 只包含噪声项, 可以忽略。所以残差方程(23)可以化简为:

$$\mathbf{r}_n = \mathbf{Q}_1^\top \mathbf{r}_o = \mathbf{T}_H \tilde{\mathbf{X}} + \mathbf{n}_n \quad (28)$$

式中: $\mathbf{n}_n = \mathbf{Q}_1^\top \mathbf{n}_o$ 为噪声矢量, 其对应的协方差矩阵如式(29)。

$$\mathbf{R}_n = \mathbf{Q}_1^\top \mathbf{R}_o \mathbf{Q}_1 = \sigma_{im}^2 \mathbf{I}_r \quad (29)$$

式中: r 为 \mathbf{Q}_1 矩阵的列数。此时, MSCKF 的最优增益为:

$$\mathbf{K} = \mathbf{P}\mathbf{T}_H^\top (\mathbf{T}_H \mathbf{P}\mathbf{T}_H^\top + \mathbf{R}_n)^{-1} \quad (30)$$

状态方程的修正量为:

$$\Delta \mathbf{X} = \mathbf{K} \mathbf{r}_n \quad (31)$$

协方差矩阵的更新量为:

$$\mathbf{P}_{k+1|k+1} = (\mathbf{I}_\xi - \mathbf{K}\mathbf{T}_H) \mathbf{P}_{k+1|k} (\mathbf{I}_\xi - \mathbf{K}\mathbf{T}_H)^\top + \mathbf{K}\mathbf{R}_n \mathbf{K}^\top \quad (32)$$

式中: $\xi = 6N + 21$ 是协方差矩阵的维数。

2 相机状态方程多模增广方法

本文提出采用两种方法, 构建相机状态方程的多模增广。在图像特征跟踪稳定的状态下, 通过纯视觉信息解算新图像帧相机的位姿参数, 完成相机状态方程的增广。而在图像特征跟踪不稳定情况下仍然采用 IMU 状态递推结果和相机外参推算新图像帧相机的位姿参数, 完成相机状态方程的增广。

2.1 基于 IMU 状态递推结果和相机外参的状态增广

当相机获取一帧新图像时, 需要将其添加到状态方程中, 对当前相机的状态向量做一次增广。此时的相机姿态可以通过 IMU 的状态递推结果以及相机和 IMU 之间的标定参数进行计算:

$$\hat{\mathbf{c}}_q^c = \hat{\mathbf{c}}_q^i \otimes \hat{\mathbf{q}}^c, \quad \hat{\mathbf{p}}_c = \hat{\mathbf{p}}_i + \mathbf{C}_q^\top \hat{\mathbf{p}}_c \quad (33)$$

式中: $\hat{\mathbf{q}}^c$ 是 IMU 和相机之间的转动向量对应的四元数, $\hat{\mathbf{p}}_c$ 为 IMU 坐标系下的相机位置向量。此时, 系统的协方差矩阵增广为:

$$\mathbf{P}_{k|k} \leftarrow \begin{bmatrix} \mathbf{I}_{6N+21} \\ \mathbf{J} \end{bmatrix} \mathbf{P}_{k|k} \begin{bmatrix} \mathbf{I}_{6N+21} \\ \mathbf{J} \end{bmatrix}^\top \quad (34)$$

式中: \mathbf{J} 为相机状态方程对应的雅可比矩阵。

$$\mathbf{J} = \begin{bmatrix} \mathbf{C}(\hat{\mathbf{q}}^c) & \mathbf{0}_{3 \times 9} & \mathbf{0}_{3 \times 3} & \mathbf{I}_3 & \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 6N} \\ \lfloor \mathbf{C}_q^\top \hat{\mathbf{p}}_c \times \rfloor & \mathbf{0}_{3 \times 9} & \mathbf{I}_3 & \mathbf{0}_{3 \times 3} & \mathbf{C}(\hat{\mathbf{q}}^c)^\top & \mathbf{0}_{3 \times 6N} \end{bmatrix} \quad (35)$$

2.2 基于纯视觉信息的位姿图优化结果的状态增广

如图1所示, 已知前后两帧图像中关联好的特征点, 以及特征点对应的地图点, 可以通过 BA 优化求解的方式估计两帧之间相机的运动, 此过程称为 PnP (perspective-n-point) 求解问题。

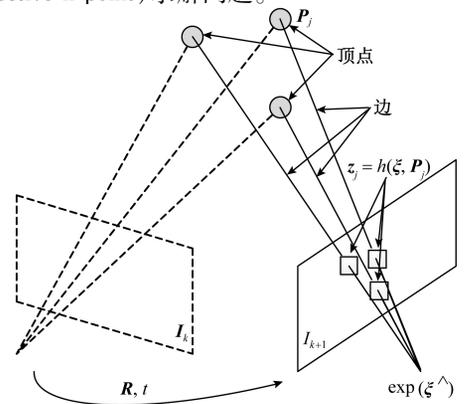


图1 BA 优化求解 PnP 问题的过程表示

Fig.1 The process of using BA method to optimize and solve the PnP problem

图 1 过程的实质就是最小二乘问题, 优化函数为:

$$\xi^* = \arg \min_{\xi} \frac{1}{2} \sum_{i=1}^n \left\| \mathbf{u}_i - \frac{1}{s_i} \mathbf{K} \exp(\xi^\wedge) \mathbf{P}_i \right\|_2^2 \quad (36)$$

式中: \mathbf{K} 为相机的内参数矩阵; \mathbf{P}_i 为地图点的位置坐标; \mathbf{u}_i 为特征点的像素坐标; n 为地图点的数量; ξ 表示相机的姿态; s_i 为尺度因子。

此问题构建的图优化框架以第 2 个相机的位姿节点 ξ 以及所有地图点的位置 \mathbf{P}_i 为节点, 以每个地图点在第 2 帧图像中的像素坐标 $\mathbf{z}_j = \mathbf{h}(\xi, \mathbf{P}_j)$, 即观测方程, 为二元边, 误差函数为:

$$\boldsymbol{\varepsilon}_i = \mathbf{z}_i - \mathbf{h}(\xi, \mathbf{P}_i) \quad (37)$$

然后通过一定的迭代次数使得函数 (36) 取得最优解。在优化的过程中, 将第 1 帧相机的位姿固定为 0, 则优化的结果既是两帧之间相机的相对位姿, 用 ${}_{c_1}^c \hat{\mathbf{q}}$ 和 ${}_{c_1}^c \hat{\mathbf{p}}_{c_2}$ 表示。

当获取的新图像中能够稳定跟踪上的特征点数量较多时, BA 优化求解的相机位姿参数精度较高, 可以用于增广当前时刻相机的状态向量, 避免 IMU 误差的累积, 计算式为:

$${}_{c_1}^c \hat{\mathbf{q}} = {}_{c_1}^c \hat{\mathbf{q}} \otimes {}_{c_1}^c \hat{\mathbf{q}} \quad {}_{c_1}^c \hat{\mathbf{p}}_{c_2} = {}_{c_1}^c \hat{\mathbf{p}}_{c_2} + \mathbf{C}({}_{c_1}^c \hat{\mathbf{q}}) {}_{c_1}^c \hat{\mathbf{p}}_{c_1} \quad (38)$$

式中: ${}_{c_1}^c \hat{\mathbf{q}}$ 和 ${}_{c_1}^c \hat{\mathbf{q}}$ 分别表示前一帧和当前帧相机对应的姿态四元数; ${}_{c_1}^c \hat{\mathbf{q}}$ 表示 BA 方法解算的前后两帧之间相机的转动量; ${}_{c_1}^c \hat{\mathbf{p}}_{c_1}$ 和 ${}_{c_1}^c \hat{\mathbf{p}}_{c_2}$ 分别表示前一帧和当前帧相机的位置向量; ${}_{c_1}^c \hat{\mathbf{p}}_{c_2}$ 为 BA 方法解算的前后两帧之间相机的位移向量。此时, 系统的协方差矩阵增广为:

$$\mathbf{P}_{klk} \leftarrow \begin{bmatrix} \mathbf{I}_{6, N+21} \\ \mathbf{J} \end{bmatrix} \mathbf{P}_{klk} \begin{bmatrix} \mathbf{I}_{6, N+21} \\ \mathbf{J} \end{bmatrix}^T \quad (39)$$

式中: \mathbf{J} 为相机状态方程对应的雅可比矩阵。

$$\mathbf{J} = \begin{bmatrix} \mathbf{0}_{3 \times (21+6(N-1))} & \mathbf{I}_3 & \mathbf{0}_{3 \times 3} \\ \mathbf{0}_{3 \times (21+6(N-1))} & \mathbf{0}_{3 \times 3} & \mathbf{C}({}_{c_1}^c \hat{\mathbf{q}}) \end{bmatrix} \quad (40)$$

2.3 本文 VIO 算法结构流程

本文改进的 MSCKF 算法框架流程如图 2 所示, 包括滤波器初始化、IMU 状态递推、图像数据处理、相机状态增广以及滤波器观测更新等环节。

1) 滤波器初始化, 包括相机和 IMU 等传感器的参数设置、MSCKF 滤波器的参数设置和初始化过程。

2) 图像数据处理, 当相机获取一帧新图像时, 需要调用图像处理类获取相关的图像数据, 主要包括图像滤波、特征点的跟踪、新特征点的提取。其中图像滤波采用高斯滤波器完成; 特征点的跟踪采用多尺度 LK 光流算法; 特征提取采用加速分割测试特征 (features from accelerated segment test, FAST) 算法。

3) 相机状态增广, 当相机采集的一帧新图像时, 需要将此时的相机位姿参数初始化成状态向量增广到相机

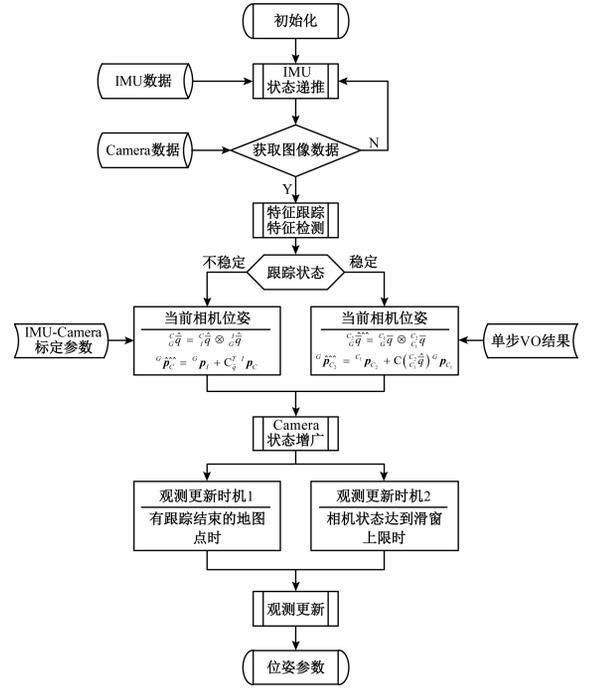


图 2 本文 VIO 算法流程

Fig.2 The flowchart of the proposed VIO algorithm

的状态方程中。本文算法首先对此时的图像特征跟踪过程进行判断: 特征跟踪不稳定时, 根据 IMU 和相机之间的标定参数以及 IMU 状态递推结果计算相机的位姿参数, 增广相机的状态向量和协方差矩阵, 计算过程如式 (33) ~ (35) 所示; 特征跟踪不稳定时, 利用纯视觉信息, 根据 BA 算法估计得到的前后两帧之间相机的相对转动量和平移量递推当前时刻相机的位姿参数, 增广相机的状态向量和协方差矩阵, 计算过程如式 (38) ~ (40) 所示。前者采用的是 IMU 和标定信息完成的增广, 随着 IMU 累积误差的增加会引入相应的误差。而后者采用的是纯视觉信息完成的增广, 能够有效地避免 IMU 误差的累积。

4) 滤波器观测更新, 在 MSCKF 中, 滤波器的更新有两种时机。一是随着相机的运动以及视角的变化, 一些特征点会因为移除相机的视场或跟踪丢失而结束跟踪的过程, 而这些特征点已经被连续跟踪数帧, 具有较强的极线约束, 可以为更新过程提供了较为丰富的先验信息, 计算得到较为准确的雅可比矩阵, 提高系统的鲁棒性。筛选出跟踪结束的特征点后, 通过三角化解算出对应的地图点位置坐标, 然后根据式 (28) ~ (32) 完成滤波器的更新。另外一种情况是随着新图像帧的获取, 相机的状态向量数量在不断地增加, 算法计算的复杂度也在不断的增加。为保证实时性, 算法中采用滑动窗口的方式对相机状态向量的数量设置了阈值上限, 在达到阈值上限后对相机的状态向量进行管理, 删除已经观测不到当前地

图点以及一些老的相机状态。为充分利用这些待删除相机状态中包含的大量可用信息,在删除之前完成一次滤波器的更新。

3 实验及结果分析

采用 EuRoC 数据集^[23]和实际场景采集数据对提出的 VIO 算法进行性能分析,实验所用硬件平台:笔记本电脑(Intel(R) Core(TM) i7-8550U CPU @ 1.8 GHz 2.4 GHz, 8.00 GB RAM),软件平台:64 位 Ubuntu16.04 系统,OpenCV 3.0,C++语言。对比算法分别采用 MSCKF 算法(记为 MSCKF 1.0)^[18]和 MSCKF 2.0 算法^[20]。

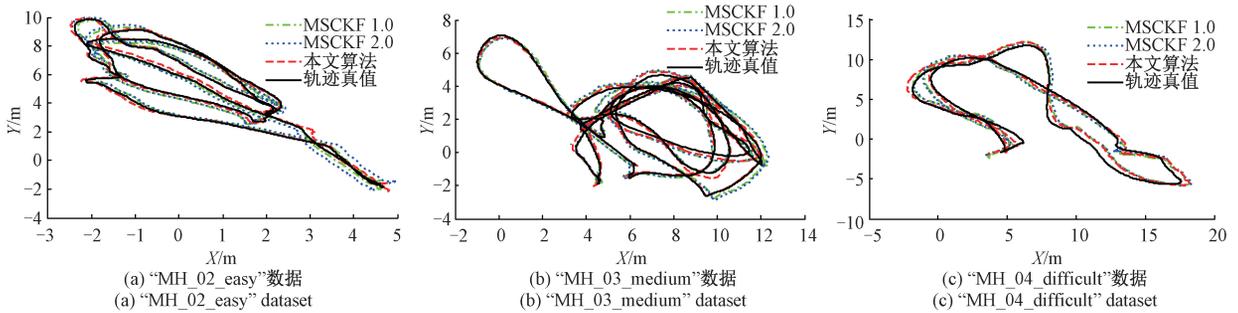


图3 EuRoC 实验数据的三维轨迹解算结果

Fig.3 The solution results of the 3D trajectory for the EuRoC experiment dataset

表1 轨迹误差统计结果

Table 1 Statistic results of the trajectory errors

数据集	算法	ATE/m				RPE/m			
		RMSE	Mean	Median	Std	RMSE	Mean	Median	Std
MH_02_easy	MSCKF 1.0	0.259	0.249	0.236	0.073	0.380	0.336	0.336	0.177
	MSCKF 2.0	0.307	0.293	0.272	0.091	0.432	0.371	0.375	0.222
	本文算法	0.164	0.138	0.115	0.089	0.241	0.195	0.154	0.141
MH_03_medium	MSCKF 1.0	0.237	0.213	0.197	0.104	0.376	0.328	0.295	0.184
	MSCKF 2.0	0.252	0.224	0.211	0.116	0.390	0.341	0.311	0.189
	本文算法	0.183	0.152	0.128	0.102	0.349	0.313	0.291	0.155
MH_04_difficult	MSCKF 1.0	0.690	0.657	0.646	0.213	1.042	0.902	0.924	0.522
	MSCKF 2.0	0.692	0.642	0.673	0.259	1.014	0.875	0.859	0.511
	本文算法	0.577	0.537	0.511	0.211	0.876	0.759	0.712	0.437

为定量分析算法的定位精度和系统漂移误差,表1分别对估计结果的绝对轨迹误差(absolute trajectory error, ATE)和相对位置误差(relative pose error, RPE)^[24]进行了统计计算,绝对轨迹误差和相对位置误差中又分别包含了均方根误差(RMSE)、均值误差(Mean)、中值误差(Median)以及标准差(Std)。分析实验结果可知,对于“MH_02_easy”和“MH_03_medium”

3.1 EuRoC 数据实验

此实验部分采用 EuRoC 数据集 Machine Hall 数据中的“MH_02_easy”、“MH_03_medium”和“MH_04_difficult”数据检验算法的性能,这3组数据对应着3个不同的难度系数。“MH_02_easy”数据对应的难度系数较小,场景中具有良好的光照和丰富的特征,飞行器的飞行速度比较缓慢,运动模糊的情况比较少;“MH_03_medium”数据对应的难度系数适中,场景中增加了一定的光照变化,同时也增加了飞行器的运动速度,存在一定的运动模糊;“MH_04_difficult”数据对应的难度系数较大,其场景中存在较大的光照变化,飞行器的运动速度比较剧烈,同时还存在部分特征稀疏的图像。实验结果如图3和表1所示。

数据,场景特征比较丰富,同时也具有较好的光度条件,3种算法对载体的位姿估计结果比较理性,误差较小。而“MH_04_difficult”数据中,场景的光度较低,影响了LK光流算法的特征跟踪性能,进而影响了算法的精度,3种算法的估计误差大于前两组数据。但是具体分析每一组数据的实验结果可知,本文算法的估计轨迹与真实轨迹贴合度更好,精度更高。表1将各

误差指标的最小值用加黑字体进行了标注, 从标注结果来看, 绝大多数都在本文算法的结果数据中, 由此从全局角度定量的说明了本文算法提高了载体的定位精度。

为从细节上分析算法的性能, 实验以具有代表性的“MH_03_medium”数据为例, 分别从 X 、 Y 、 Z 三个方向的

定位精度以及俯仰、滚动、航向三个姿态角进行分析和误差统计, 结果如图 4、5 和表 2 所示。图 4 为载体在 X 、 Y 、 Z 三个方向的运动轨迹和误差曲线, 图 5 为载体的三个姿态角及其对应的误差曲线。表 2 分别统计了载体在 X 、 Y 、 Z 三个轴上的运动轨迹和姿态角的 RMSE 误差, 并对各组误差最小值用黑粗体进行了标注。

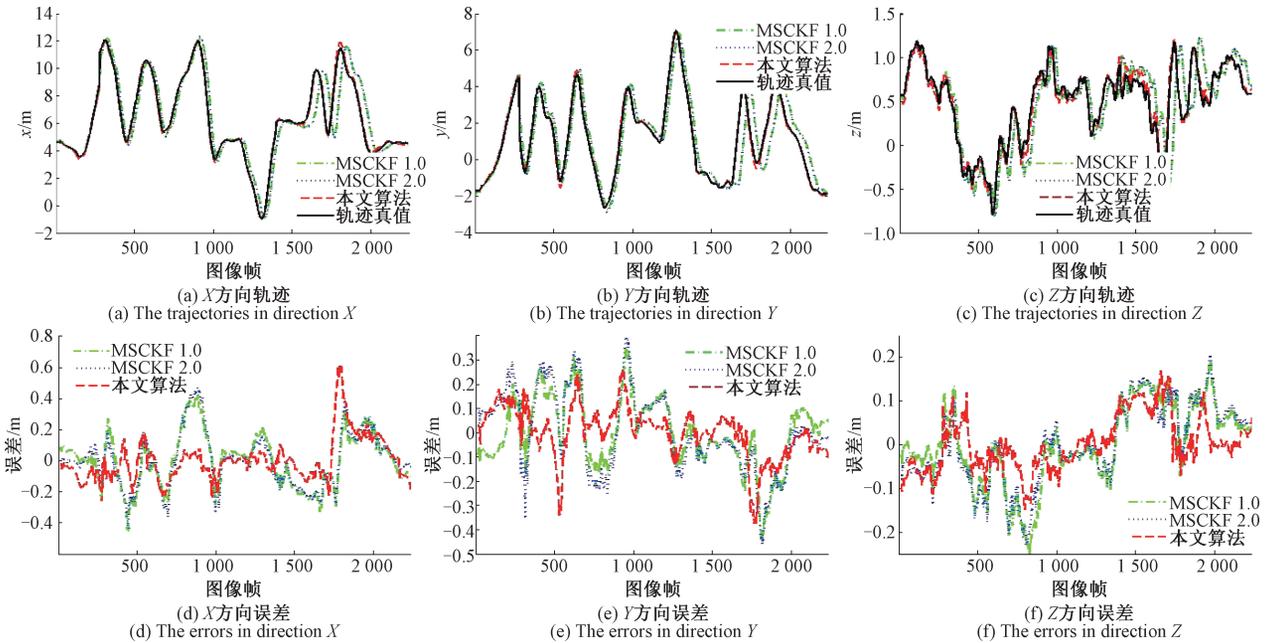


图 4 “MH_03_medium”数据的 X 、 Y 、 Z 三轴分解轨迹结果及误差

Fig.4 Trajectories and errors of the X 、 Y 、 Z three direction decomposition for the “MH_03_medium” dataset

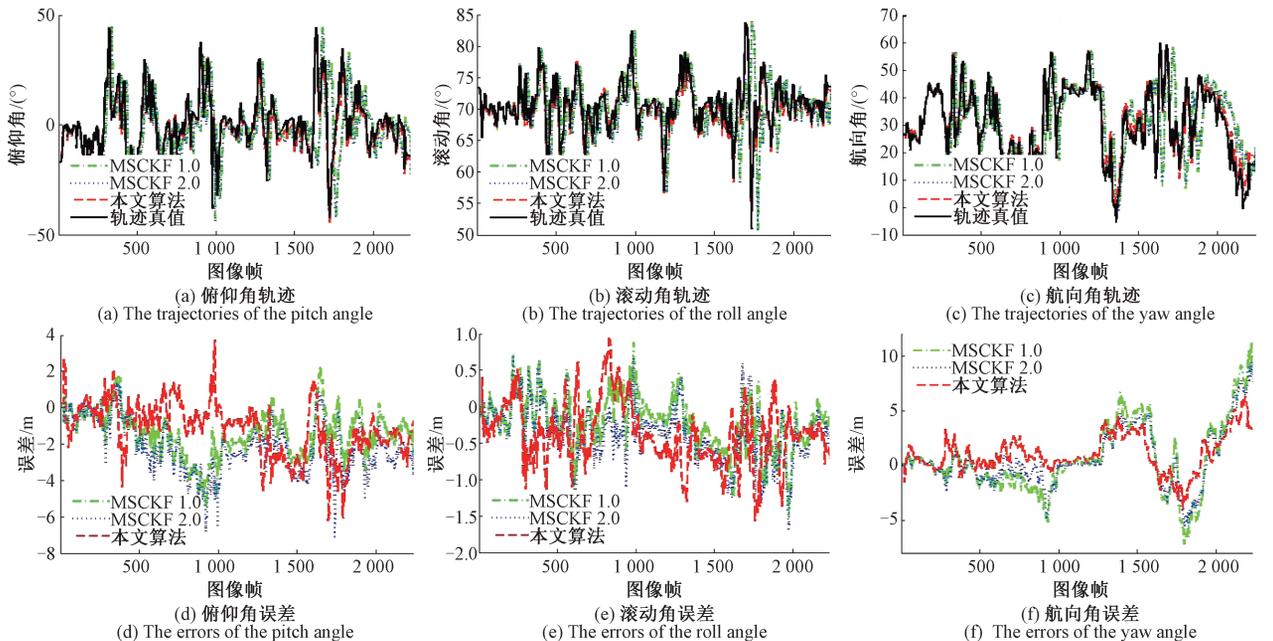


图 5 “MH_03_medium”数据的 X 、 Y 、 Z 三轴姿态角结果及误差

Fig.5 The attitude angles and errors of the X 、 Y 、 Z three directions for the “MH_03_medium” dataset

表2 “MH_03_medium”数据的误差统计结果

Table 2 The error statistic results of the “MH_03_medium” dataset

算法	位置误差/m			姿态角误差/(°)		
	X轴	Y轴	Z轴	俯仰角	滚动角	航向角
MSCKF 1.0	0.168	0.141	0.090	1.879	0.419	3.396
MSCKF 2.0	0.170	0.163	0.090	2.610	0.527	2.815
本文算法	0.136	0.105	0.062	1.893	0.567	2.023

“MH_03_medium”是难度系数适中的数据集,场景中有丰富的特征可以用于跟踪,光度条件较好,飞行器处于快速运动模式,存在一定的运动模糊。从实验结果来看,3种算法在X、Y、Z各方向上的RMSE误差均值分别为0.133 m (MSCKF 1.0)、0.141 m (MSCKF 2.0)和0.101 m (本文算法),姿态角的RMSE误差均值分别为1.898°(MSCKF 1.0)、1.984°(MSCKF 2.0)和1.494°(本文算法)。此实验结果可以说明本文算法较另外两种对比算法具有更高的定位精度和姿态角估计精度。

3.2 实际应用数据实验

为从实际应用方面进一步检验本文提出算法的有效性,采用同时配备相机和IMU的“MYNT EYE Depth”设备搭建了实验平台,如图6所示。



图6 实验所用数据采集设备

Fig.6 The data acquisition equipment used in the experiment

图6中相机的帧频为20 Hz、分辨率为1 280×720 pixels、视角为50°、焦距为3.9 mm,IMU的帧频为200 Hz、自由度为6轴,相机和IMU之间采用硬触发方式同步采集时间,同步精度小于1 ms。数据采集场景路线如图7所示,轨迹长度为222 m。实验结果如图8、9和表3所示。

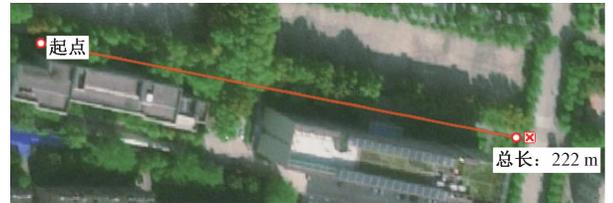


图7 实验场景路线

Fig.7 The trajectory in experiment scene

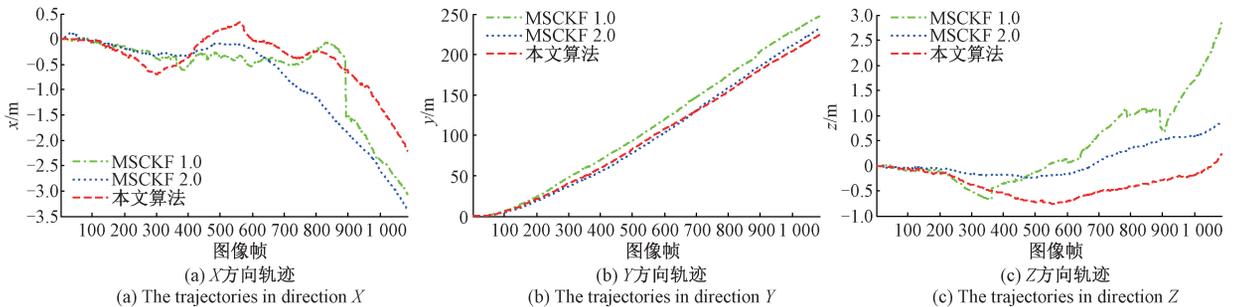


图8 实际应用数据的轨迹估计结果

Fig.8 The trajectory estimation results for the practical application dataset

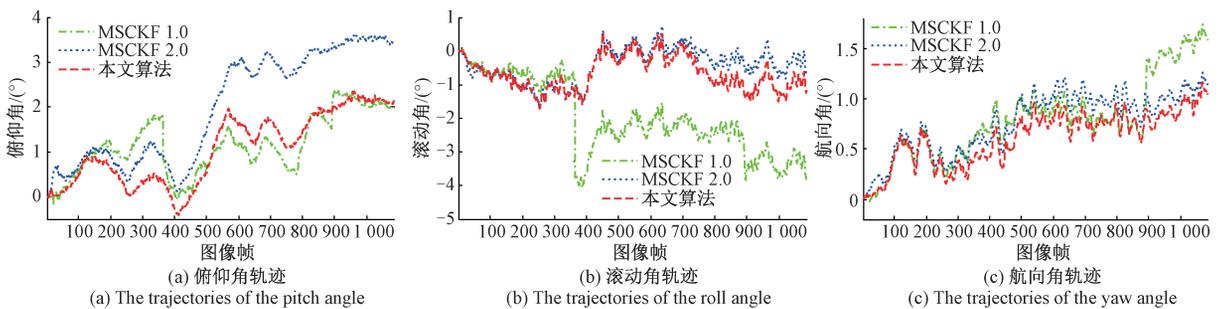


图9 实际应用数据的姿态角估计结果

Fig.9 The attitude angle estimation results of for the practical application dataset

表3 实际应用数据的定位结果

Table 3 The localization results of the practical application dataset

	X/m	Y/m	Z/m
MSCKF 1.0	-3.07	247.67	2.86
MSCKF 2.0	-3.37	232.27	0.88
本文算法	-2.21	224.39	0.23

从图8中可以直观的看出,本文改进后的算法对载体运动地估计结果更加稳定,具有更小的误差。结合表3以及图7中实验场景的真实路线可知,本文算法对运动路线长度的估计误差为2.39 m,MSCKF 1.0算法的估计误差为25.67 m,MSCKF 2.0算法的估计误差为10.27 m。由此可以分析出本文算法具有更高的定位精度。

4 结 论

在MSCKF算法中,相机状态方程的增广采用IMU的状态递推结果和相机-IMU之间的标定参数计算完成,此过程存在IMU误差的累积问题。而在特征跟踪稳定阶段,采用图优化框架,通过BA方法优化求解相邻两帧相机之间的位姿,利用纯视觉信息增广相机的状态方程,修正IMU的累积误差,提高算法的精度。在上述理论的基础上,本文构建了一种相机状态方程的多模增广方法,对MSCKF算法进行了改进。改进后的算法能够有效地解决特征跟踪稳定状态下IMU误差的累积问题,提高算法的精度和稳定性。

参考文献

[1] 齐乃新, 杨小冈, 李小峰, 等. 基于ORB特征和LK光流的视觉里程计算法[J]. 仪器仪表学报, 2018, 39(12): 216-227.
 QI N X, YANG X G, LI X F, et al. Visual odometry algorithm based on ORB features and LK optical flow[J]. Chinese Journal of Scientific Instrument, 2018, 39(12): 216-227.

[2] 冉峰, 李天, 季渊, 等. 基于改进SURF算法的单目视觉里程计[J]. 电子测量技术, 2017, 40(5): 185-188.
 RAN F, LI T, JI Y, et al. Monocular visual odometry based on the improved SURF algorithm[J]. Electronic Measurement Technology, 2017, 40(5): 185-188.

[3] 吴玉香, 王超, 洗颖宪, 等. 基于稀疏直接法和图优化的移动机器人SLAM[J]. 仪器仪表学报, 2018, 39(4): 257-263.
 WU Y X, WANG CH, XIAN Y X, et al. SLAM based on sparse direct method and graph optimization for mobile

robot[J]. Chinese Journal of Scientific Instrument, 2018, 39(4): 257-263.

[4] 付朋, 陈新度, 吴磊. 基于角点的双目视觉绝对定位研究[J]. 电子测量与仪器学报, 2018, 32(3): 1-8.
 FU P, CHEN X D, WU L. Research on absolute positioning of binocular vision based on corner[J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(3): 1-8.

[5] TKOCZ M, JANSCHKE K. Towards consistent state and covariance initialization for monocular SLAM filters[J]. Journal of Intelligent & Robotic Systems, 2015, 80(3-4): 475-489.

[6] GUI J, GU D, WANG S, et al. A review of visual inertial odometry from filtering and optimisation perspectives[J]. Advanced Robotics, 2015, 29(20): 1289-1301.

[7] 姚二亮, 张合新, 张国良, 等. 基于Vision-IMU的机器人同时定位与地图创建算法[J]. 仪器仪表学报, 2018, 39(4): 230-238.
 YAO E L, ZHANG H X, ZHANG G L, et al. Robot simultaneous localization and mapping algorithm based on vision and IMU[J]. Chinese Journal of Scientific Instrument, 2018, 39(4): 230-238.

[8] MARTINELLI A. Closed-form solution of visual-inertial structure from motion[J]. International Journal of Computer Vision, 2014, 106(2): 138-152.

[9] MUR-ARTAL R, TARDÓS J D. Visual-inertial monocular SLAM with map reuse[J]. IEEE Robotics and Automation Letters, 2017, 2(2): 796-803.

[10] USENKO V, ENGEL J, STUCKLER J, et al. Direct visual-inertial odometry with stereo cameras[C]. 2016 IEEE International Conference on Robotics and Automation, 2016: 1885-1892.

[11] FORSTER C, CARLONE L, DELLAERT F, et al. On-manifold pre-integration for real-time visual-inertial odometry[J]. IEEE Transactions on Robotics, 2017, 33(1): 1-21.

[12] YANG Z, SHEN S. Monocular visual-inertial state estimation with online initialization and camera-imu extrinsic calibration[J]. IEEE Transactions on Automation Science and Engineering, 2017, 14(1): 39-51.

[13] CHEN C, ZHU H, LI M, et al. A review of visual-inertial simultaneous localization and mapping from filtering-based and optimization-based perspectives[J]. Robotics, 2018, 7(3): 45.

[14] FAESSLER M, FONTANA F, FORSTER C, et al. Autonomous, vision-based flight and live dense 3d

- mapping with a quadrotor micro aerial vehicle[J]. Journal of Field Robotics, 2016, 33(4): 431-450.
- [15] BLOESCH M, BURRI M, OMARI S, et al. Iterated extended Kalman filter based visual-inertial odometry using direct photometric feedback [J]. International Journal of Robotics Research, 2017, 36 (10): 1053-1072.
- [16] LYNNEN S, ACHELTELIK M W, WEISS S, et al. A robust and modular multi-sensor fusion approach applied to MAV navigation [C]. IEEE/RSJ International Conference on Intelligent Robots and Systems, 2013; 3923-3929.
- [17] BLOESCH M, OMARI S, HUTTER M, et al. Robust visual inertial odometry using a direct EKF-based approach [C]. IEEE/RSJ International Conference on Intelligent Robots and Systems, 2015; 298-304.
- [18] MOURIKIS A I, ROUMELIOTIS S I. A multi-state constraint Kalman filter for vision-aided inertial navigation[C]. 2007 IEEE International Conference on Robotics and Automation, 2007; 3565-3572.
- [19] LI M, MOURIKIS A I. Improving the accuracy of EKF-based visual-inertial odometry [C]. IEEE International Conference on Robotics and Automation, 2012; 828-835.
- [20] LI M, MOURIKIS A I. High-precision, consistent EKF-based visual-inertial odometry [J]. The International Journal of Robotics Research, 2013, 32(6): 690-711.
- [21] TANSKANEN P, NAEGELI T, POLLEFEYS M, et al. Semi-direct EKF-based monocular visual-inertial odometry[C]. IEEE/RSJ International Conference on Intelligent Robots and Systems, 2015; 6073-6078.
- [22] SUN K, MOHTA K, PFROMMER B, et al. Robust stereo visual inertial odometry for fast autonomous flight[J]. IEEE Robotics and Automation Letters, 2018, 3(2): 965-972.
- [23] BURRI M, NIKOLIC J, GOHL P, et al. The EuRoC micro aerial vehicle datasets[J]. International Journal of Robotics Research, 2016, 35(10): 1157-1163.
- [24] STURM J, ENGELHARD N, ENDRES F, et al. A benchmark for the evaluation of RGB-D SLAM systems[C]. IEEE/RSJ International Conference on Intelligent Robots and Systems, 2012; 573-580.

作者简介



齐乃新, 分别于 2012 年、2014 年于第二炮兵工程大学获得学士学位和硕士学位, 现为火箭军工程大学博士研究生, 主要研究方向为视觉导航, V-SLAM, 视觉测量。

E-mail: qinaixin2015@sina.com

Qi Naixin received his B. Sc. and M. Sc. degrees both from the Second Artillery University of Engineering in 2012 and 2014, respectively. Now he is a Ph. D. candidate in Rocket Force University of Engineering. His main research interests include visual navigation, V-SLAM and visual measurement.



曹立佳(通信作者), 分别于 2005 年、2008 年于第二炮兵工程学院获得学士学位和硕士学位, 2012 年于第二炮兵工程大学获博士学位, 现为四川理工学院自动化系主任, 主要研究方向为导航、制导与控制。

E-mail: caolijia82@163.com

Cao Lijia received his B. Sc. and M. Sc. degrees both from Second Artillery College of Engineering in 2005 and 2008, respectively, and Ph. D. degree from the Second Artillery University of Engineering in 2012. Now he is the director of Department of Automation Engineering, Sichuan University of Science & Engineering. His main research interests include navigation, guidance and control.