



结合滤波与优化的无人机多传感器融合方法

代波^{1,2,3*}, 何玉庆^{1,2}, 谷丰^{1,2}, 杨丽英^{1,2}, 徐卫良⁴

1. 中国科学院沈阳自动化研究所机器人学国家重点实验室, 沈阳 110016, 中国

2. 中国科学院机器人与智能制造创新研究院, 沈阳 110016, 中国

3. 中国科学院大学, 北京 100049, 中国

4. Department of Mechanical Engineering, University of Auckland, Auckland 1010, New Zealand

* 通信作者. E-mail: daibo16@mails.ucas.edu.cn

收稿日期: 2019-10-25; 修回日期: 2019-12-6; 接受日期: 2019-12-14; 网络出版日期: 2020-10-20

国家自然科学基金 (批准号: U1508208, U1608253, 91748130) 资助项目

摘要 高精度实时状态估计是无人机安全飞行及执行各种任务的首要条件. 多传感器 (如视觉、惯性测量单元 (IMU) 和 GPS 等) 融合可提高状态估计精度, 并实现信息冗余, 当其中某些传感器出现故障时, 仍具有较好的鲁棒性. 因此, 本文提出结合滤波与优化的无人机多传感器融合方法, 从而得到局部高精度、全局无漂移的状态估计. 该方法主要分为卡尔曼 (Kalman) 滤波和全局优化两部分. 卡尔曼滤波器作为主体融合框架, 融合局部传感器 (IMU) 和全局传感器 (经优化后的视觉、GPS、磁力计和气压计) 信息得到全局位姿估计. 由于卡尔曼滤波算法计算量较小, 可以保证融合估计的实时性. 全局优化则负责将有漂移的视觉惯性里程计信息与全局传感器 (GPS, 磁力计和气压计) 融合对齐后, 得到高精度的全局视觉估计. 但优化输出会出现不连续且视觉处理存在延迟的问题. 因此, 将优化后的里程计再输入到卡尔曼滤波器中, 从而得到高精度、实时无漂移的状态估计. 最后结合具体无人机平台, 进行了实际的飞行测试与定位实验, 实验结果表明了本文方法的有效性和鲁棒性.

关键词 无人机, 传感器融合, 状态估计, 卡尔曼滤波, 全局优化

1 引言

小型无人机具有操作简单、机动性好等特点, 在应急搜救^[1]、安防巡逻和航拍摄影^[2]等军事和民事领域得到了越来越多的应用. 而在无人机飞行及执行任务过程中, 精确的状态信息估计 (如位置、速度、加速度和姿态等) 是飞行的前提条件. 这些信息可以通过多个互补的传感器分别提供 (如 GPS 提供位置, 惯性测量单元 (IMU) 提供姿态和加速度信息), 也通过多传感器融合的方式提供. 相比于直接使用传感器互补的方式, 多传感器融合可以更好地利用这些信息, 实现更高精度的状态估计. 同时, 由

引用格式: 代波, 何玉庆, 谷丰, 等. 结合滤波与优化的无人机多传感器融合方法. 中国科学: 信息科学, 2020, 50: 1919–1931, doi: 10.1360/SSI-2019-0237

Dai B, He Y Q, Gu F, et al. Multi-sensor fusion for unmanned aerial vehicles based on the combination of filtering and optimization (in Chinese). Sci Sin Inform, 2020, 50: 1919–1931, doi: 10.1360/SSI-2019-0237

于多传感器之间的冗余特性, 通过融合的方式在某个或某些传感器失效的情况下, 仍然能够获得较好的定位信息, 使得系统抗干扰能力更强.

无人机上机载传感器主要有 GPS、激光、IMU、视觉、超声波等^[3]. 这些传感器主要分为两大类, 一类是局部传感器, 例如视觉和激光. 这类传感器可以通过前后两帧或多帧数据得到位姿关系, 通过反复迭代, 不断地推测当前时刻的位姿. 常见的有视觉里程计^[4~7]和激光里程计^[8,9], 以及融合了 IMU 的视惯里程计^[10~13]等. 这些算法可以在局部区域达到很高的精度, 非常适用于不需要已知全局信息的一些任务中, 如定点悬停、手动飞行增稳等. 但是其缺点也是显而易见的. 首先这些算法估计的位姿信息是在局部坐标系下的, 即相对于初始点, 而不是全局坐标系. 当初始点发生变化时, 例如在不同的地方启动飞机, 状态估计的结果会变化. 因此, 无人机无法完成依赖全局信息的任务, 如飞往某个已知全局信息的任务点. 其次, 这些算法是通过两帧或者多帧滑窗的形式进行状态估计, 这会导致大尺度情况下, 估计信息发生漂移. 尽管可以通过视觉或者激光回环检测^[14~16]的方法消除漂移, 但是在尺度的场景中, 回环需要的计算量巨大, 无法保证实时性, 而且很可能根本不存在回环. 另一类传感器是全局传感器, 如 GPS、气压计和磁力计等. 这类传感器可以提供全局无漂移的测量值. 但是, 一般这些测量信息包含较大的噪声, 而且极易受到干扰. 例如 GPS, 容易受到遮挡、天气或者电磁辐射等因素的干扰, 导致定位精度变差. 因此, 如何融合局部传感器和全局传感器从而得到局部高精度全局无漂移的状态估计是研究热点. 对无人机来说, 在保证这两个条件的同时, 还要保证估计的实时性和在有干扰时的可靠性. 尽管基于滤波的融合方法^[17~20], 如卡尔曼滤波等, 可以将局部传感器信息融合到全局信息中, 但这需要二者之间的一个精确的变换关系, 而且假设视觉不会发生漂移. 而基于优化^[21~26]的融合方式可以利用过往状态, 实现两类传感器的融合. 但通常优化的状态估计有时会不连续, 而且较难处理传感器故障的情况.

本文提出结合滤波与优化的方法对局部传感器和全局传感器进行融合. 其中, 优化部分利用视惯里程计和全局信息 (GPS、气压计和卡尔曼滤波的姿态), 实时估计出局部坐标系与全局坐标系之间的变换关系, 从而得到优化后的全局视惯里程计. 再将全局视惯里程计与其他全局传感器信息通过卡尔曼滤波进行融合, 从而得到全局无漂移、局部高精度、实时的状态估计结果. 相比于现有多传感器融合方法, 本文研究的融合方法主要贡献如下:

- (1) 提出结合优化与滤波的多传感器融合方法, 可实现局部高精度、全局无漂移的实时状态估计;
- (2) 优化中引入姿态约束, 结合关键帧添加约束的方式, 提高优化的精度、实时性和鲁棒性;
- (3) 将上述方法应用到实际的无人机飞行中, 通过实验分析, 验证了算法的有效性.

2 相关研究

近年来, 针对多传感器融合进行状态估计问题, 得到许多学者的深入研究. 总的来说, 这些方法可以分为两大类: 基于滤波的方法和基于优化的方法.

基于滤波方法的融合一般是利用卡尔曼滤波或其变种方法, 如扩展卡尔曼滤波 (extended Kalman filter, EKF) 和无迹卡尔曼滤波 (unscented Kalman filter, UKF) 等. Weiss 等^[17,18]通过 EKF 融合 IMU, GPS 和视觉信息, 并构建了一个通用的模块化多传感器融合框架. 这两个研究中用高频的 IMU 信息作为驱动, 其他的信息与之进行对齐融合, 并且对 IMU 的漂移进行实时在线修正. 在模块化设计过程中, 考虑了传感器延迟的问题, 可实现多个不同频率的传感器的融合. 之后 Bloesch 等^[11]提出将视觉中的亮度误差引入到扩展卡尔曼滤波中, 通过与 IMU 紧耦合的方式实现视惯里程计. 由于引入了亮度误差, 使得系统的抗扰动能力更强. Shen 等^[19]提出了基于 UKF 的方法对视觉、激光和 GPS

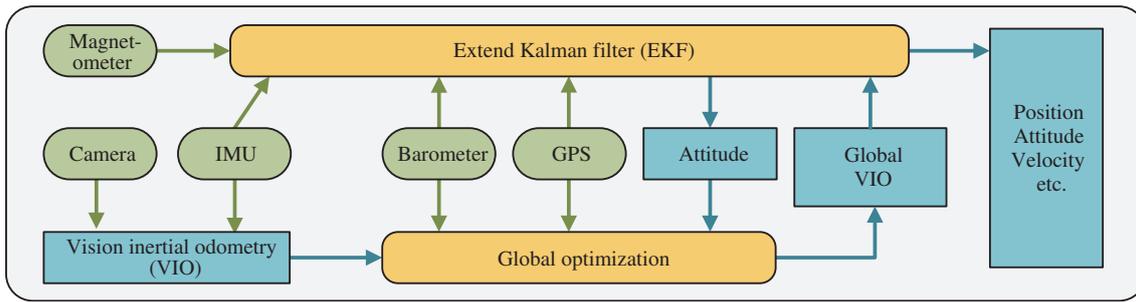


图 1 (网络版彩图) 结合滤波与优化的多传感器融合方法总框架

Figure 1 (Color online) The fusion framework for multiple sensors combining filtering and optimization method

的数据进行融合, 可以实现无人机在户内外环境的准确定位. 相比于 EKF, UKF 不需要线性化, 不要求观测方程的连续性, 而且计算量随着维度的增长是线性的. 利用滤波的方法可实现模块化设计, 处理多传感器之间的信息不同步以及延迟的问题, 而且实时性也可得到保证. 但是通常, 滤波方法是基于一阶马尔科夫 (Markov) 假设的, 并不能很好利用过往信息. 对于处理全局传感器信息时有较大优势, 而处理随着时间变化的局部传感器信息, 如里程计等, 滤波方法是一种次优估计 [27]. 相比于滤波方法, 基于优化的多传感器融合方法将状态估计问题假设为多阶马尔科夫过程. 通过利用当前及过往的测量值优化当前和过往状态. 优化方法常常用于融合视觉和 IMU 信息, 从而得到有尺度且更加鲁棒的视惯里程计信息, 如 OKVIS [10] 和 VINS [13] 等. Rehder 等 [21] 融合 GPS 和双目信息实现了全局位姿估计. 其核心思想是通过利用多帧间的匹配关系而不仅仅是双目的匹配, 提升视觉在大尺度情况下估计的精度. Merfels 等 [22] 通过滑动窗口的思想对窗口中的里程计信息和全局 GPS 信息进行优化, 并提出了相应的边缘化的方法. 相似的方法还有 Mascaro 等 [23] 提出的 GOMSF. 文献 [23] 与文献 [22] 的不同之处在于并不是从优化中直接获得最优的状态估计, 而是通过优化的方式估计局部坐标系和全局坐标系的变换关系, 从而得到较高帧率的状态估计. 而与之相似的还有文献 [24, 25], 不过该方法需要已知先验地图, 这在很多情况下是较难实现的. Qin 等 [26] 提出了一个多传感器优化融合框架 VINS-Fusion. 该方法将每个全局传感器当成一个约束因子, 理论上可以融合视惯信息和 GPS、气压计和磁力计等全局传感器信息. 基于优化的融合方法可以很好地融合局部和全局传感器信息, 并且可以给出实时的状态估计. 但这种融合方式对传感器故障较为敏感, 一旦视觉信息出现错误, 状态估计就会失效. 而且优化的状态估计输出会由于传感器噪声等原因产生跳变, 不利于无人机的实时控制.

3 基于 EKF 的主融合框架

系统的总融合框架如图 1 所示, 绿色部分表示传感器测量输入, 黄色部分表示数据融合方法, 蓝色部分表示融合后的输出信息. EKF 融合磁力计、IMU、气压计、GPS 和优化之后的全局视惯里程计信息得到局部高精度、全局无漂移的位置姿态速度等信息. 同时, EKF 将融合后的姿态信息输出给优化模块. 采用滤波和优化相结合的方法, 另一个好处是增加系统的鲁棒性. 通常情况下, 较容易受到环境影响的传感器是 GPS 和视觉. 当 GPS 因为遮挡或者电磁干扰变得不可靠时, 通过优化对齐视觉和姿态信息, 得到优化后的局部高精度视惯里程计信息, 此时视惯里程计位置有漂移但姿态无漂移, 但仍能用于无人机的控制和任务. 当视惯里程计信息出现丢失时, 依靠 GPS 和 IMU 等传感器的融合, 仍能得到全局无漂移、精度有所降低的状态估计. EKF 融合过程可分为状态预测和测量更新两部分. 下面分别介绍系统的状态描述以及如何处理不同传感器测量信息的测量模型.

3.1 状态描述

首先介绍 IMU 和磁力计的模型. 假设 IMU 和磁场测量值包含一个偏移量 b 和高斯 (Gauss) 白噪声 n [17]. 因此, 本体坐标系真实加速度 a 、角速度 ω 和地磁 m 可以表示为

$$\begin{cases} a = \tilde{a} - b_a - n_a, & \dot{b}_a = n_{ba}, \\ \omega = \tilde{\omega} - b_\omega - n_\omega, & \dot{b}_\omega = n_{b\omega}, \\ m = \tilde{m} - b_m - n_m, & \dot{b}_m = n_{bm}, \end{cases} \quad (1)$$

其中 \tilde{a} , $\tilde{\omega}$ 和 \tilde{m} 表示测量值, 偏移量 b 可假设为随机游走, 即其微分为高斯白噪声. 滤波器的状态由 IMU 在世界坐标系 (以下称全局坐标系) 中的位置 p^w 、速度 v^w 和姿态 q^w (四元数) 构成. 同时考虑到了加速度计和陀螺仪的偏移 b_a 和 b_ω . 在获得航向信息时, 需要利用地磁场信息, 因此状态量还包括地磁在全局坐标中的分量 m^w 以及在本体系中磁力计的偏移量 b_m . 因此, 滤波状态可以表示成一个 22 维的向量 x :

$$x = [p^{wT} \ v^{wT} \ q^{wT} \ b_a^T \ b_\omega^T \ b_m^T \ m^{wT}]^T. \quad (2)$$

系统的预测部分由如下的微分方程进行约束:

$$\begin{cases} \dot{p}^w = v^w, \\ \dot{v}^w = R_b^w(\tilde{a} - b_a - n_a) + g^w, \\ \dot{q}^w = 0.5\Omega(\tilde{\omega} - b_\omega - n_\omega)q^w, \end{cases} \quad \Omega(\omega) = \begin{bmatrix} -[\omega]_\times & \omega \\ -\omega^T & 0 \end{bmatrix}, \quad [\omega]_\times = \begin{bmatrix} 0 & -\omega_z & \omega_y \\ \omega_z & 0 & -\omega_x \\ -\omega_y & \omega_x & 0 \end{bmatrix}, \quad (3)$$

其中 R_b^w 表示本体到全局坐标系的旋转矩阵, g^w 表示重力加速度. 地磁场假定为随机游走过程.

在上述状态描述中, 我们用四元数表示姿态. 而在实际的使用过程中, 一般用误差四元数来描述四元数误差和它的协方差, 而不是算数误差. 参考文献 [28], 定义如下 21 维误差状态向量:

$$\delta x = [\delta p^{wT} \ \delta v^{wT} \ \delta \theta^{wT} \ \delta b_a^T \ \delta b_\omega^T \ \delta b_m^T \ \delta m^{wT}]^T. \quad (4)$$

δx 表示真实值 x_{true} 和名义量 x (不包括噪声) 之间的误差, 即 $x_{\text{true}} = x \oplus \delta x$, \oplus 表示广义加法. $\delta \theta^w$ 定义为 $q^{w-1} \otimes q_{\text{true}}^w \approx [0.5\delta \theta^{wT} \ 1]^T$, \otimes 为四元数的乘法运算. 对式 (3) 进行线性化后, 得到状态方程的雅克比 (Jacobian) 矩阵.

3.2 测量更新模型

任意传感器测量模型可描述为如下非线性形式:

$$z = h(x) + v, \quad (5)$$

其中 z 表示观测信息, v 表示观测噪声, h 表示由状态到观测的映射. 对式 (5) 线性化后, 即可得到观测方程的雅克比矩阵. 下面分别讨论不同传感器对应的观测模型.

由于不同的传感器更新频率不同和处理延迟的不同, 因此在测量模型中, 也需要考虑传感器延迟问题. 参考文献 [15], 构建先验状态的缓存队列, 在计算新息 (innovation) 时, 先验状态选用与测量值同时刻的值. 然后根据计算出的后验状态, 再重新传播到当前时刻, 得到当前时刻的先验状态. 一般测量值的延迟可以提前获得. 例如, GPS 的延迟主要是信号延迟, 而视觉则是视觉信息处理需要的时间. 而气压计和磁罗盘, 由于本身测量频率较高, 因此可不考虑二者的测量延迟. 本文涉及到多种不同的

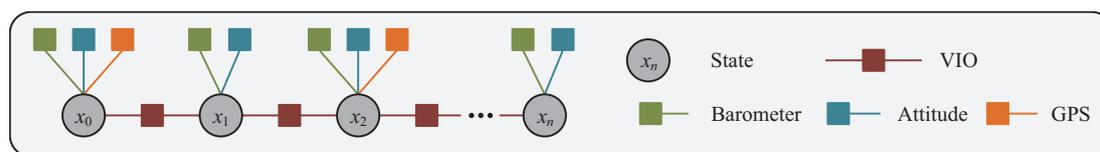


图 2 (网络版彩图) 全局优化整体框架

Figure 2 (Color online) The fusion framework of global optimization

传感器, 它们提供的测量信息不一样. 因此我们将这些传感器按照与滤波状态之间的关系分为 3 大类: 位置信息、姿态信息和地磁信息. 位置信息可由 GPS、气压计和视惯里程计提供, 测量模型如下:

$$z^p = R_b^w p_0^b + p^w + n_p, \quad (6)$$

其中 z^p 表示位置信息测量值, p_0^b 表示传感器在本地坐标系的位置, n_p 是位置测量噪声, 假设服从零均值的正态分布. 同时, 视惯里程计也可以提供姿态信息, 其对应的测量模型如下:

$$z^q = \left[q_0^{b-1} \otimes q^w \otimes q\{n_q\} \right]_{xyz}, \quad (7)$$

其中 z^q 表示姿态信息测量, q_0^b 表示传感器相对 IMU 坐标系的姿态, n_q 是角度测量噪声, $q\{\theta\}$ 表示旋转矢量 θ 对应的四元数, $[q]_{xyz}$ 表示四元数的虚部. 对磁力计来说, 由于存在地磁偏角, 而且一般较难得到其精确值, 因此不仅要考虑磁力计偏移误差, 还需要对地磁在全局坐标系的分量进行估计, 从而达到更好的估计效果, 对应的测量模型为

$$z^m = R_w^b m^w + b_m. \quad (8)$$

4 全局位姿优化

如图 1 所示, 全局优化的输入为视惯里程计 6 维位姿信息、气压计和 GPS 信息以及 EKF 滤波得到的姿态信息. 通过将视惯里程计与其他 3 种全局信息进行优化对齐, 得到最新时刻局部里程计坐标系到全局坐标系的坐标变换, 从而得到全局里程计信息.

4.1 整体优化框架

优化的整体框架如图 2 所示. 灰色圆圈表示待优化的状态变量, 矩形表示不同的观测约束. 全局信息, 如气压计约束、姿态约束和 GPS 约束作为全局因子加入到优化中, 而局部视惯里程计则约束相邻两个状态的关系, 具体我们将在下文中展开. 与文献 [26] 不同的是, 本文在考虑磁罗盘约束时, 将整个卡尔曼滤波后的姿态信息作为全局状态约束加入到优化中. 而文献 [26] 直接用地磁测量作为约束, 虽然通过查询当地的经纬度可以给出参考地磁场分量, 但实际应用中, 很难得到当地地磁在全局坐标系的真实分量. 而通过卡尔曼滤波后的姿态结果实际上已经考虑到了地磁分量的估计. 实际使用中, 为了保证优化的实时性, 图 2 中的每个状态量是视惯里程计中的关键帧在全局坐标系的状态. 即当关键帧更新时, 才向优化中添加新的变量和约束. 相比于文献 [26] 的每帧图像都添加新的状态, 这种方式可以在保证精度的情况下, 大大减少优化的状态和求解所需要的时间.

本文中, 优化的变量是关键帧在全局坐标系中的位姿. 同时, 由于卡尔曼滤波无法利用过往信息, 地磁分量估计仍有误差, 使得测量的正北和地理北极存在偏差. 而优化的方式可以利用过往信息, 通过整体的估计, 可以得到更加精确的地磁分量. 因此优化状态还包括卡尔曼估计的地磁分量和真实地

磁分量的偏角 (虽然该偏角较小, 但是随着距离的增加, 仍然可能对整体的优化有影响). 全局优化的本质, 即求解由各个观测方程构成的联合概率分布的最大似然估计. 定义优化状态如下:

$$\chi^w = \left[x_0^{wT} \ x_1^{wT} \ x_2^{wT} \ \dots \ x_n^{wT} \ \theta_0 \right]^T, \quad x_k^w = \left[p_k^{wT} \ q_k^{wT} \right]^T, \quad k \in [0, n], \quad (9)$$

其中 p_k^w 和 q_k^w 分别表示第 k 个关键帧对应的 IMU 在全局坐标系中的位置和姿态四元数. θ_0 是磁场估计的水平偏移量. 假设所有测量值之间相互独立, 且传感器测量误差符合高斯分布, 即 $p(z_k^j | \chi^w) \sim \mathcal{N}(z_k^j, \Omega_k^j)$. 优化问题建模并简化为如下形式:

$$\chi^{w*} = \arg \max_{\chi^w} \prod_{k=0}^n \prod_{j \in S} p(z_k^j | \chi^w) = \arg \min_{\chi^w} \sum_{k=0}^n \sum_{j \in S} \left\| z_k^j - h_k^j(\chi^w) \right\|_{\Omega_k^j}^2. \quad (10)$$

方程中使用马氏距离, 即 $\|r\|^2 = r^T \Omega^{-1} r$, 将观测误差按照其分布进行归一化, 噪声越大, 优化权重越小. 此时最大似然估计转化成非线性最小二乘问题, 可通过高斯-牛顿或 LM 算法进行求解.

4.2 局部视惯里程计

本文使用的局部视惯里程计是 VINS^[13], 该方法是一种 IMU 和视觉的紧耦合融合. 即将视觉残差和 IMU 的预积分残差一起优化. 在优化的过程中, 通过多帧滑窗的形式, 保证了局部的高精度. 同时, 不断地边缘化旧状态, 保证计算的实时性. 本文的优化输入不限于 VINS, 也可以是其他的视惯里程计. VINS 中的优化状态是当前滑窗中的 IMU 在局部坐标系中的状态和图像中的特征点的逆深度. 具体涉及到的所有优化状态量定义如下:

$$\chi^l = \left[x_0^{lT} \ x_1^{lT} \ \dots \ x_n^{lT} \ \lambda_0^T \ \lambda_1^T \ \dots \ \lambda_n^T \right]^T, \quad x_k^l = \left[p_k^{lT} \ v_k^{lT} \ q_k^{lT} \ b_a^{lT} \ b_\omega^{lT} \right]^T, \quad k \in [0, n], \quad (11)$$

其中 x_k 表示第 k 帧图像对应的 IMU 的位置、速度、姿态、加速度偏移和陀螺仪偏移量. λ_j 表示第 j 个像素点在第一次被观测帧中的逆深度. 最终, 可构建如下的最小二乘问题:

$$\chi^{l*} = \arg \min_{\chi^l} \left\{ \left\| r_p - H_p \chi^l \right\|^2 + \sum_{k \in B} \left\| r_B(z_{k+1}^k, \chi^l) \right\|_{P_{k+1}^k}^2 + \sum_{(i,j) \in C} \rho \left(\left\| r_C(z_i^{C_j}, \chi^l) \right\|_{P_i^{C_j}}^2 \right) \right\}, \quad (12)$$

其中 r_p, H_p 是边缘化约束项, r_B 和 r_C 分别表示预积分和视觉重投影误差约束项. $\rho(x)$ 表示鲁棒核函数^[29], 该函数在保证方程可导的基础上, 可以有效减少某些特征点状态的异常观测引入的误差. P_{k+1}^k 表示 k 与 $k+1$ 帧之间 IMU 预积分协方差, $P_m^{C_j}$ 表示第 m 个特征点在 C_j (相机第 j 帧坐标系) 中的观测噪声协方差矩阵.

VINS 的输出是 6 维位姿信息, 每当关键帧更新后, 结合上一个关键帧的位姿, 得到视觉约束残差. 视惯里程计在小范围内拥有很高的精度, 因此用来约束相邻两帧的位姿, 此时误差表示为

$$z_k^l - h_k^l(\chi^w) = z_k^l - h_k^l(x_k^w, x_{k-1}^w) = \begin{bmatrix} R_{k-1}^{l-1} (p_k^l - p_{k-1}^l) - R_{k-1}^{w-1} (p_k^w - p_{k-1}^w) \\ 2 \left[(q_{k-1}^{l-1} \otimes q_k^l)^{-1} \otimes (q_{k-1}^{w-1} \otimes q_k^w) \right]_{xyz} \end{bmatrix}, \quad (13)$$

其中上标 l 和 w 分别表示在局部坐标系和全局坐标系下的变量, 全局变量即式 (10) 中需要优化的变量. 根据优化队列最新帧, 即第 n 帧在 l 和 w 坐标系下的位姿, 得到二者的变换关系如式 (14). 局部里程计可以通过式 (14) 变换到全局坐标系, 从而得到全局里程计信息, 从而降低对优化的实时性要求.

$$T_l^w = \begin{bmatrix} R_n^w & p_n^w \\ 0 & 1 \end{bmatrix} \begin{bmatrix} R_n^l & p_n^l \\ 0 & 1 \end{bmatrix}^{-1}. \quad (14)$$

4.3 全局传感器

GPS 原始测量值为经度、纬度和高度信息. 以初始 GPS 点为原点, 建立 ENU (东北天) 坐标系. 将 GPS 测量转换到 ENU 坐标系下, 得到全局位置 GPS 位置测量值 p_k^G 以及相应的误差约束:

$$z_k^G - h(\chi^w) = p_k^G - p_k^w. \quad (15)$$

另外, 由于 GPS 的更新频率较低, 并不能保证每一个关键帧都有与之匹配的 GPS 数据, 需对 GPS 信息进行插值, 得到更加精确的 GPS 数据. 气压计直接测量的是当前高度的气压, 可以假设同一高度或海平面气压相对恒定, 则可以将气压信息转换为海平面高度信息. 此时约束的是全局位置的垂直方向:

$$z_k^B - h(\chi^w) = p_{zk}^B - [p_k^w]_z, \quad (16)$$

其中 p_{zk}^B 表示气压计测量的高度, $[p_k^w]_z$ 表示待优化的位置 z 轴分量.

由 EKF 给出的姿态信息可以提供很精准的全局姿态信息, 但仍然存在航向估计的误差, 因此需要通过优化进一步提高精度. 此时误差约束为

$$z_k^A - h(\chi^w) = 2 \left[(q_k^A)^{-1} \otimes \begin{bmatrix} \cos(\theta_0/2) \\ r \sin(\theta_0/2) \end{bmatrix} \otimes q_k^w \right]_{xyz}, \quad (17)$$

其中 q_k^A 表示 EKF 输出的姿态测量, $r = [0 \ 0 \ 1]^T$. 将约束 (13), (15)~(17) 带入式 (10) 中, 利用 Ceres 求解, 得到优化后的全局视惯里程计和过往轨迹.

5 实验结果与分析

为了验证本文提出算法的性能, 我们进行了实际的飞行及定位测试实验. 飞行实验平台以及各个传感器如图 3 所示. 飞机平台对角长度为 550 mm, 总重量为 3.35 kg. GPS 型号是 Ublox NEO-M8N 低成本定位模块, 理想定位精度为 3 m 左右, 磁力计内置于 GPS 模块中, 减少来自机体的电磁干扰. 飞控使用的是 Pixhawk 开源飞控, 其内部集成气压计和 IMU (MPU6050). 机载处理器使用的是 Nvidia Jetson TX2, 搭载在 Auvideo J120 扩展板上. TX2 处理器采用双核 Denver 2 加四核 ARM A57 组合的形式, 工作频率为 2 GHz, 内存为 8 GB. 可以看出, TX2 处理器性能并不是很好, 但其功耗仅 7.5 W, 重量仅 255 g, 非常适合无人机这种小载荷平台. 视觉使用的是 MYNT 双目相机, 而实际使用中只用到了视觉的左相机提供的图像. 为了保证视觉处理的实时性, 视觉信息采集的图片分辨率为 640×480 , 图像处理频率为 10 Hz, 该频率已经能够满足无人机控制时的实时性要求.

5.1 全局优化结果

本小节主要介绍全局优化的结果, 即从局部视惯里程计信息得到全局视惯里程计信息. 我们主要进行了 3 个类型的轨迹飞行测试. 飞行实验环境和轨迹如图 4 所示, 其中, 实验 1 (蓝色轨迹) 为短距离飞行; 实验 2 (绿色轨迹) 为中等距离飞行, 在飞行过程中, 有一段为室内飞行 (红色矩形框区域), 此区域内无 GPS 信号; 实验 3 (红色轨迹) 为较远距离飞行. 3 个轨迹均为往返, 为了衡量算法的精度, 我们将回环^[13]的结果作为真实值, 无人机以后退的方式返回来获得更多的回环结果. 通过这 3 种飞行轨迹实验结果来分析算法的准确性、鲁棒性和实时性. 实验中评估轨迹误差方法参考文献 [30].

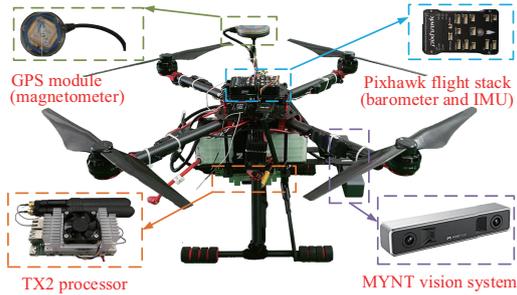


图 3 (网络版彩图) 无人机实验平台

Figure 3 (Color online) UAV platform for fusion experiments



图 4 (网络版彩图) 飞行测试实验环境及飞行轨迹

Figure 4 (Color online) Experimental environment and flight trajectories

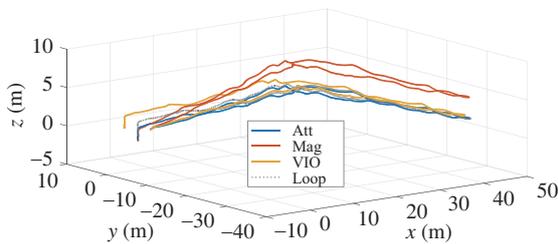


图 5 (网络版彩图) 实验 1 中各算法最终优化轨迹

Figure 5 (Color online) The flight trajectories recovered from different algorithms in experiment 1

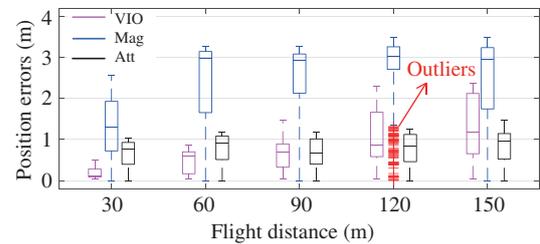


图 6 (网络版彩图) 姿态约束与磁约束误差箱线图

Figure 6 (Color online) Position error boxplots of attitude and magnetic constraints in experiment 1

首先, 通过实验 1, 我们对比本文的姿态约束优化结果与 VINS-Fusion^[26] 中的磁约束优化结果. 这两个优化方法中, 均未考虑气压计约束. 图 5 所示为姿态约束方法优化轨迹、磁约束方法优化轨迹、视惯里程计轨迹以及回环优化轨迹. 在数据处理中, 误差为各个轨迹在相同时刻下与回环结果的位置差. 图 6 所示为各个轨迹相对于回环轨迹的误差箱线图. 通过图 5 和 6, 首先可以直观看出, 视惯里程计有较大漂移, 且随着距离的增加不断增大. 对比姿态约束和磁约束轨迹, 磁约束轨迹在垂直方向有较大误差. 因为磁约束需要获得当地的磁场信息. 而实际应用中, 往往很难获得其准确的数值. 因此, 本文提出的姿态约束方式要好于磁约束. 由于引入错误的磁约束会带来优化轨迹整体的倾斜, 如图 5 所示, 因此在下面的实验中, 我们将 VINS-Fusion 中的磁约束改成本文姿态约束再进行对比.

下面我们分析轨迹 2 中存在的 GPS 信号弱甚至无 GPS 信号情况下的优化结果. 图 7 所示的分别是 GPS 的轨迹、视惯里程计轨迹、VINS-Fusion 优化轨迹、本文优化轨迹以及回环轨迹. 图中红色矩形框 1 中的轨迹为无人机进入建筑物内部的情况, 此时的 GPS 已经相当不准确, 误差在十米以上, 且跳变很大, 还会出现无 GPS 的情况. 黑色矩形框 2 中的轨迹为无人机贴近建筑物的情况, 此时 GPS 也有遮挡, 但其误差和跳变都较小, 无人机处于弱 GPS 条件. 图 8 显示了不同区时间段内的误差箱线图. 图中对应的 5 个时间段从小到大分别为: 进入区域 1 前、区域 1 内、出区域 1 到进入区域 2 前、区域 2 内以及出区域 2 后. 可以看到由于引入了视觉信息, 在 GPS 遮挡情况下 (97.8~133.7 s 及 163.8~181.9 s), 优化后仍能给出精确的位置估计. 在最后一段 (181.9~267.8 s) 的结果中, 可以看到视惯里程计存在较大的漂移, 而由于结合了 GPS 信息, 优化的结果精度更高. 本文的优化结果相比于 VINS-Fusion 的优化结果精度更高, 特别是在 GPS 信号不好的时候. 主要是本文优化时, 利用了 GPS 的噪声标准差 σ_k

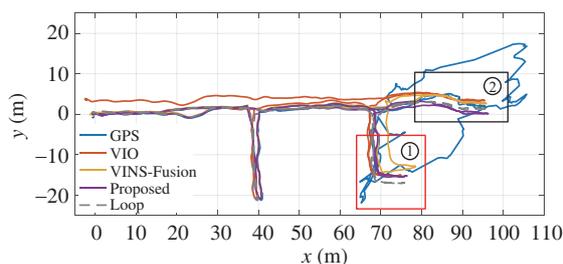


图 7 (网络版彩图) 弱或无 GPS 信号条件下 (实验 2) 各优化轨迹图

Figure 7 (Color online) The flight trajectories of different algorithms in the weak-GPS case (experiment 2)

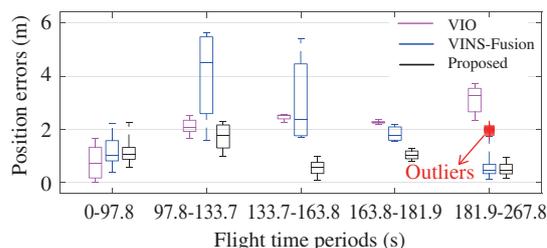


图 8 (网络版彩图) 弱或无 GPS 条件下 (实验 2) 各个时间段对应的误差箱线图

Figure 8 (Color online) Position error boxplots of different algorithms in the weak-GPS case (experiment 2)

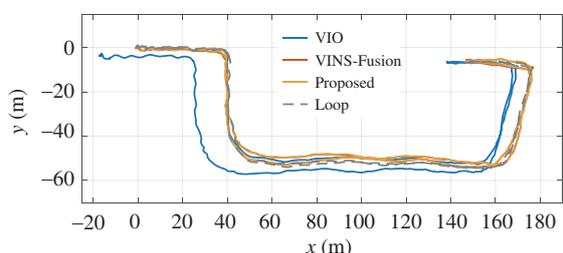


图 9 (网络版彩图) 较远距离飞行 (实验 3) 各算法轨迹图

Figure 9 (Color online) The flight trajectories of different algorithms in the long-range case (experiment 3)

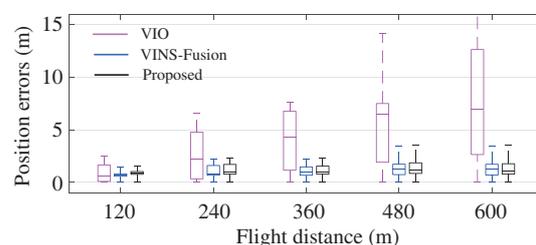


图 10 (网络版彩图) 较远距离飞行 (实验 3) 各算法误差箱线图

Figure 10 (Color online) Position error boxplots of different algorithms in the long-range case (experiment 3)

和其微分对 GPS 信号的好坏进行评估, 具体条件如下:

- (1) 由好状态判断为坏状态条件 ($\sigma_k > 4$ 且 $\dot{\sigma}_k > 0.2$) 或 $\sigma_k > 5$;
- (2) 由坏状态判断为好状态条件 ($\sigma_k < 5$ 且 $\dot{\sigma}_k < -0.2$) 或 $\sigma_k < 4$.

当判断为坏时, 优化便不再添加 GPS 约束, 只利用气压计、视觉和姿态约束进行优化. 轨迹 2 的实验结果说明本文的方法在 GPS 信号无或者弱的情况下具有很好的鲁棒性.

下面根据较长距离的轨迹 3 结果分析所提出方法的实时性. 图 9 所示的是轨迹 3 情况下视惯里程计轨迹、VINS-Fusion 轨迹、本文优化轨迹和回环轨迹. 图 10 为各个轨迹相对于回环的绝对位置误差箱线图. 从这两个图中可以看出视惯里程计的漂移随着距离的增长不断变大, 而引入优化后, 不管是 VINS-Fusion 还是本文算法都能获得无漂移且准确的全局位置估计. 图 11 所示分别为 VINS-Fusion、回环与本文提出算法在优化时需要的时间随距离变化的曲线. 可以发现, 本文方法优化需要时间小于 VINS-Fusion 方法, 这是因为本文在添加优化约束时基于关键帧, 总的优化约束因子数量比 VINS-Fusion 要少. 而回环优化需要的时间随着尺度的增加急剧上升, 因此回环的方式不适用于大尺度场景. 为了保证优化的实时性, 当总的约束因子数量大于某个阈值时, 固定最开始的一些状态, 采用滑窗的形式进行优化, 保证需要优化的因子总数恒定, 从而保证优化算法的实时性. 如图 11 所示, 本文方法的每次优化所需时间最终稳定在 0.3 s 左右, 满足无人机对实时性的要求. 图 12 所示的是磁场估计水平偏移角度随着距离的变化曲线, 可以看到最终估计值稳定在 0.89° . 该结果同时也说明使用 EKF 输出的姿态信息本身的精度是相对准确的, 因为我们在滤波器中引入了地磁场估计.

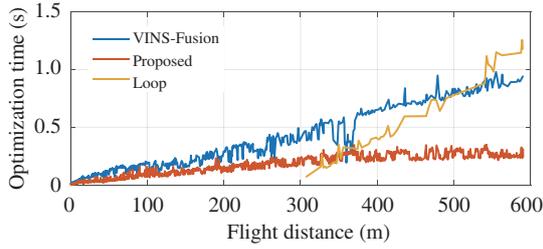


图 11 (网络版彩图) 实验 3 中各算法优化需要时间随距离变化曲线图

Figure 11 (Color online) Optimization times of different algorithms in experiment 3

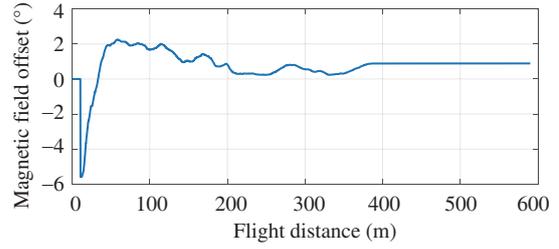


图 12 (网络版彩图) 磁场估计水平偏移角优化结果

Figure 12 (Color online) The optimization result of magnetic field estimation offset

表 1 3 个实验中各个方法的 RMSE (m) 结果

Table 1 The RMSE (m) results of different algorithms in all three experiments

Flight distance (m)	RMSE of experiment 1					RMSE of experiment 2					RMSE of experiment 3				
	158.6	128.9	157.5	159.5	146.6	293.9	284.7	301.2	325.1	294.0	579.4	552.8	607.4	585.9	585.1
VIO	0.41	0.86	0.70	0.75	1.49	1.90	1.78	1.72	1.66	2.62	8.87	15.20	12.98	12.66	14.09
VINS-Fusion	0.60	0.75	0.71	0.51	1.33	2.08	3.75	3.55	4.20	2.70	1.96	4.51	1.39	2.59	2.07
Proposed	0.59	0.70	0.62	0.52	1.06	1.06	0.80	1.04	1.43	1.15	1.33	2.39	1.34	2.15	1.87

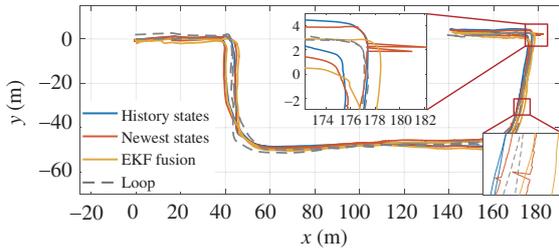


图 13 (网络版彩图) 飞行轨迹优化结果与滤波器融合结果

Figure 13 (Color online) The flight trajectories of optimization and EKF fusion

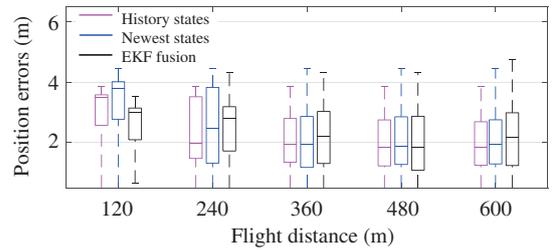


图 14 (网络版彩图) 历史状态、最新状态以及 EKF 融合状态误差箱线图

Figure 14 (Color online) Position error boxplots of history states, newest states and EKF fusion states

实际实验中, 每种轨迹我们飞行了 5 次. 表 1 列出了所有轨迹中各方法的均方根误差 (root mean square error, RMSE). 可以看到本文方法相比于其他方法, 精度提升明显.

5.2 滤波融合结果

5.1 小节中的分析是针对本文的优化方法, 主要分析的是优化后的轨迹, 即历史状态估计. 该轨迹和无人机实时使用的信息并不是同一个. 由于视觉、GPS 和气压计等多个信息的约束, 在优化过程中可能会出现信息的跳变, 该跳变在历史状态轨迹中会被优化掉, 但是会出现在实时优化轨迹中. 如图 13 所示轨迹分别是历史状态轨迹 (除了当前最新状态的历史状态构成的轨迹)、最新状态优化轨迹 (即每次优化后的最新的状态构成的轨迹)、融合实时优化轨迹的 EKF 输出 (EKF 融合轨迹) 与回环轨迹. 无人机在飞行时, 一般只考虑当前最新的状态, 用于无人机的定位. 图 14 所示的是上述估计对

应的误差箱线图随着距离的变化关系. 从图 14 中可以看到, 三者之间的精度几乎差不多. 但从图 13 中可以看到, 红色矩形框中最新状态轨迹出现了几次跳变, 而通过滤波融合后的 EKF 融合轨迹中, 跳变消失. 因此, EKF 起到两个作用: 为优化提供精准的姿态约束以及为无人机提供平滑的状态估计.

6 结论与讨论

本文提出了一种结合滤波与优化的多传感器融合方法. 优化部分通过利用 EKF 给出的姿态信息构建姿态约束, 结合视惯里程计、GPS 和气压计信息, 得到全局无漂移、局部高精度的全局视惯里程计信息. 优化后的全局里程计信息又输入到 EKF 中, 从而消除优化中可能存在的跳变信息, 得到实时平滑的位姿估计. 同时, 在优化时, 通过关键帧来减少需要优化的状态量, 从而提高优化的实时性. 最终, 通过对无人机在不同场景下的实际飞行轨迹分析, 证明了本文的算法在精度、鲁棒性和实时性上都有显著提升. 但是, 本文算法并没有考虑到尺度约束, 因此不能很好地应对里程计尺度发生漂移的情况, 这将作为我们下一步的研究内容.

参考文献

- 1 Qi J, Song D, Shang H, et al. Search and rescue rotary-wing UAV and its application to the Lushan Ms 7.0 earthquake. *J Field Robot*, 2016, 33: 290–321
- 2 Cao W R, Zhu L L, Han J D. An iterable multi-directional auto-correlation approach for aerial power line image enhancement. *Robot*, 2015, 37: 738–747
- 3 Liu Y, Wang Q, Hu H, et al. A novel real-time moving target tracking and path planning system for a quadrotor UAV in unknown unstructured outdoor scenes. *IEEE Trans Syst Man Cybern Syst*, 2019, 49: 2362–2372
- 4 Klein G, Murray D. Parallel tracking and mapping for small AR workspaces. In: *Proceedings of the 6th IEEE and ACM International Symposium on Mixed and Augmented Reality*, 2007. 1–10
- 5 Engel J, Schops T, Cremers D. LSD-SLAM: large-scale direct monocular SLAM. In: *Proceedings of European Conference on Computer Vision*, 2014. 834–849
- 6 Mur-Artal R, Montiel J M M, Tardos J D. ORB-SLAM: a versatile and accurate monocular SLAM system. *IEEE Trans Robot*, 2015, 31: 1147–1163
- 7 Engel J, Koltun V, Cremers D. Direct sparse odometry. *IEEE Trans Pattern Anal Mach Intell*, 2018, 40: 611–625
- 8 Zhang J, Singh S. LOAM: Lidar odometry and mapping in real-time. In: *Proceedings of Robotics: Science and Systems*, 2014
- 9 Zhang J, Singh S. Visual-lidar odometry and mapping: low-drift, robust, and fast. In: *Proceedings of IEEE International Conference on Robotics and Automation*, 2015. 2174–2181
- 10 Leutenegger S, Lynen S, Bosse M, et al. Keyframe-based visual-inertial odometry using nonlinear optimization. *Int J Robotics Res*, 2015, 34: 314–334
- 11 Bloesch M, Omari S, Hutter M, et al. Robust visual inertial odometry using a direct EKF-based approach. In: *Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems*, 2015. 298–304
- 12 Forster C, Carlone L, Dellaert F, et al. On-manifold preintegration for real-time visual-inertial odometry. *IEEE Trans Robot*, 2017, 33: 1–21
- 13 Qin T, Li P, Shen S. VINS-Mono: a robust and versatile monocular visual-inertial state estimator. *IEEE Trans Robot*, 2018, 34: 1004–1020
- 14 Angeli A, Doncieux S, Meyer J A, et al. Real-time visual loop-closure detection. In: *Proceedings of IEEE International Conference on Robotics and Automation*, 2008. 1842–1847
- 15 Hess W, Kohler D, Rapp H, et al. Real-time loop closure in 2D LIDAR SLAM. In: *Proceedings of IEEE International Conference on Robotics and Automation*, 2016. 1271–1278

- 16 Dong Q L, Gu Z P, Hu Z Y. Automatic real-time SLAM relocalization based on a hierarchical bipartite graph model. *Sci China Inf Sci*, 2012, 55: 2841–2848
- 17 Weiss S, Achtelik M W, Chli M, et al. Versatile distributed pose estimation and sensor self-calibration for an autonomous MAV. In: *Proceedings of International Conference on Robotics and Automation*, 2012. 31–38
- 18 Lynen S, Achtelik M W, Weiss S, et al. A robust and modular multi-sensor fusion approach applied to MAV navigation. In: *Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems*, 2013. 3923–3929
- 19 Shen S, Mulgaonkar Y, Michael N, et al. Multi-sensor fusion for robust autonomous flight in indoor and outdoor environments with a rotorcraft MAV. In: *Proceedings of IEEE International Conference on Robotics and Automation*, 2014. 4974–4981
- 20 Wang L, Wan J W, Liu Y H, et al. Multiple robots collaborative localization based on PE-EKF. *Sci China Ser F-Inf Sci*, 2007, 37: 1544–1555 [王玲, 万建伟, 刘云辉, 等. 基于 PF-EKF 的多机器人合作定位方法. *中国科学: 信息科学*, 2007, 37: 1544–1555]
- 21 Rehder J, Gupta K, Nuske S, et al. Global pose estimation with limited GPS and long range visual odometry. In: *Proceedings of IEEE International Conference on Robotics and Automation*, 2012. 627–633
- 22 Merfels C, Stachniss C. Pose fusion with chain pose graphs for automated driving. In: *Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems*, 2016. 3116–3123
- 23 Mascaro R, Teixeira L, Hinzmann T, et al. GOMSF: graph-optimization based multi-sensor fusion for robust UAV pose estimation. In: *Proceedings of International Conference on Robotics and Automation*, 2018. 1421–1428
- 24 Surber J, Teixeira L, Chli M. Robust visual-inertial localization with weak GPS priors for repetitive UAV flights. In: *Proceedings of IEEE International Conference on Robotics and Automation (ICRA)*, 2017. 6300–6306
- 25 Oleynikova H, Burri M, Lynen S, et al. Real-time visual-inertial localization for aerial and ground robots. In: *Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 2015. 3079–3085
- 26 Qin T, Cao S, Pan J, et al. A general optimization-based framework for global pose estimation with multiple sensors. 2019. ArXiv: 1901.03642
- 27 Strasdat H, Montiel J M M, Davison A J. Visual SLAM: why filter? *Image Vision Comput*, 2012, 30: 65–77
- 28 Sola J. Quaternion kinematics for the error-state Kalman filter. 2017. arXiv:1711.02508
- 29 Huber P J. Robust estimation of a location parameter. *Ann Math Statist*, 1964, 35: 73–101
- 30 Grupp M. evo: Python package for the evaluation of odometry and SLAM. 2017. <https://github.com/MichaelGrupp/evo>

Multi-sensor fusion for unmanned aerial vehicles based on the combination of filtering and optimization

Bo DAI^{1,2,3*}, Yuqing HE^{1,2}, Feng GU^{1,2}, Liying YANG^{1,2} & Weiliang XU⁴

1. *State Key Laboratory of Robotics, Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang 110016, China;*

2. *Institutes for Robotics and Intelligent Manufacturing, Chinese Academy of Sciences, Shenyang 110016, China;*

3. *University of Chinese Academy of Sciences, Beijing 100049, China;*

4. *Department of Mechanical Engineering, University of Auckland, Auckland 1010, New Zealand*

* Corresponding author. E-mail: daibo16@mails.ucas.edu.cn

Abstract Accurate and real-time state estimation is the first step to realize safe flight and operation of unmanned aerial vehicles (UAVs). Multi-sensor fusion, e.g., vision, IMU, and GPS, can improve the accuracy of state estimation and even make it work when some sensor is unavailable. Thus, this paper proposes a multi-sensor fusion method based on the combination of filtering and optimization to achieve locally accurate and globally drift-free state estimation. The proposed method has two components, i.e., the Kalman filter and global optimization. The Kalman filter is considered the main structure of the fusion framework, which fuses a local sensor (IMU) and global sensors (aligned global visual inertial odometry, GPS, magnetometer, and barometer sensors) to obtain global state estimation in real time. Global optimization estimates the transformation between local base frame of the visual inertial odometry and global base frame to obtain an accurate global visual estimation. However, given discontinuity of optimization and odometry delay, the aligned visual odometry is then input into the Kalman filter to achieve accurate and drift-free state estimation in real time. Finally, flight and localization tests on a practical UAV were conducted. The experimental results demonstrate the effectiveness and robustness of the proposed multi-sensor fusion method.

Keywords unmanned aerial vehicles, multi-sensor fusion, state estimation, Kalman filter, global optimization



Bo DAI was born in 1993. He received his B.S. degree in automation from the University of Science and Technology Beijing, Beijing, China in 2014. He is currently working toward a Ph.D. degree in pattern recognition and intelligent system at Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang, China and University of the Chinese Academy of Sciences, Beijing, China. His main research interests include UAV control and localization.

Bo DAI was born in 1993. He received his B.S. degree in automation from the University of Science and Technology Beijing, Beijing, China in 2014. He is currently working toward a Ph.D. degree in pattern recognition and intelligent system at Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang, China and University of the Chinese Academy of Sciences, Beijing, China. His main research interests include UAV control and localization.



Yuqing HE was born in 1980. He received his B.S. degree in engineering and automation from Northeastern University, Qinhuangdao, China in 2002 and his Ph.D. degree in pattern recognition and intelligent system from Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang, China in 2008. He is currently a professor at the State Key Laboratory of Robotics, Shenyang Institute of Automation, Chinese Academy of Sciences. His main research interests include nonlinear estimation, control, and cooperation of multiple robots.

Yuqing HE was born in 1980. He received his B.S. degree in engineering and automation from Northeastern University, Qinhuangdao, China in 2002 and his Ph.D. degree in pattern recognition and intelligent system from Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang, China in 2008. He is currently a professor at the State Key Laboratory of Robotics, Shenyang Institute of Automation, Chinese Academy of Sciences. His main research interests include nonlinear estimation, control, and cooperation of multiple robots.



Feng GU was born in 1982. He received his B.S. and M.S. degrees in system engineering from Nanjing University of Science and Technology, Nanjing, China in 2005 and 2007, respectively, and his Ph.D. degree in pattern recognition and intelligent systems from Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang, China in 2011. He is currently an associate professor at Shenyang Institute of Automation, Chinese Academy of Sciences. His current research interests include set theory-based estimation and control, and multi-robot cooperation.

Feng GU was born in 1982. He received his B.S. and M.S. degrees in system engineering from Nanjing University of Science and Technology, Nanjing, China in 2005 and 2007, respectively, and his Ph.D. degree in pattern recognition and intelligent systems from Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang, China in 2011. He is currently an associate professor at Shenyang Institute of Automation, Chinese Academy of Sciences. His current research interests include set theory-based estimation and control, and multi-robot cooperation.



Liying YANG was born in 1979. She received her B.S. and M.S. degrees in automatic control engineering from Shenyang Jianzhu University, Shenyang, China in 2002 and 2005, respectively, and her Ph.D. degree in pattern recognition and intelligent system from Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang, China in 2011. She is currently an associate professor at the State Key Laboratory of Robotics, Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang. Her current research interests include path planning for aerial vehicles.

Liying YANG was born in 1979. She received her B.S. and M.S. degrees in automatic control engineering from Shenyang Jianzhu University, Shenyang, China in 2002 and 2005, respectively, and her Ph.D. degree in pattern recognition and intelligent system from Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang, China in 2011. She is currently an associate professor at the State Key Laboratory of Robotics, Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang. Her current research interests include path planning for aerial vehicles.