

DOI: 10.7652/xjtuxb202003009

室内惯性导航系统/相机拓扑测量的 因子图合作定位算法

张琳, 廉保旺

(西北工业大学电子信息学院, 710129, 西安)

摘要: 为解决合作定位算法中滤波结构不易扩展、鲁棒性差的问题,提出了一种适应于室内多用户的惯性导航系统/相机拓扑测量的因子图合作定位算法。利用目标检测识别算法,提出相机拓扑测量合作定位算法。通过构建拓扑测量、惯性导航系统因子函数,推导出基于因子图的可扩展参数优化模型。为进一步提高鲁棒性,引入综合考虑残差和检测分数的权值判断法,提出适应于相机拓扑测量的改进型开关约束算法。仿真和实测实验表明:拓扑测量观测精度的提升对位置和速度估计、算法收敛次数均有不同程度的改善;合作+改进型开关约束算法的定位精度较非合作+非鲁棒算法的提高了79.8%;改进型开关约束算法相比原开关约束算法具有较高的预测成功率,当测量遮挡时长比为0.4时,改进型开关约束算法将原开关约束算法对野值点的预测成功率由89.35%提高到了97.4%;与原开关约束算法相比,引入权值判断法的改进型开关约束算法剔除了同用户多边框的异常拓扑测量值,减小了计算开销,提高了合作定位精度和鲁棒性。

关键词: 相机拓扑测量;惯性导航系统;因子图;合作定位;鲁棒性

中图分类号: TP29;V249.3 **文献标志码:** A **文章编号:** 0253-987X(2020)03-0070-10

Inertial Navigation System/Topology Measurement Integrated Algorithm with Factor Graph for Indoor Cooperative Localization

ZHANG Lin, LIAN Baowang

(School of Electronics and Information, Northwestern Polytechnical University, Xi'an 710129, China)

Abstract: To address the deficiencies of standard filters and low robustness in cooperative localization system, a novel factor graph algorithm is proposed, which can be applied to indoor multiple users by fusing topology measurement provided by cameras with inertial navigation system. A topology measuring cooperative localization method is further presented utilizing the objects detection algorithm from the images. To derive a flexible optimization model of the navigation solution with incorporating asynchronous sensors capabilities, the topology measuring factors and inertial navigation system factors are created in solving nonlinear optimization problems. To further enhance the robustness, an improved switch constraint algorithm is developed by introducing weights decision approach considering both residuals and detection scores, and it better suits to the topology measurements. Simulations and experiments show that the rising accuracy of topology measurements improves position and velocity estimations and reduces iteration times of the navigation solutions. The positioning accuracy of non-cooperative+

收稿日期: 2019-07-01。 作者简介: 张琳(1988—),女,博士生;廉保旺(通信作者),男,教授。 基金项目: 国家自然科学基金资助项目(61771393);国家自然科学基金青年科学基金资助项目(61803310)。

网络出版时间: 2019-11-07

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1069.T.20191106.1705.004.html>

non-robust approach is 79.8% higher than that of cooperative+improved switching constraint approach. The improved switch constraint algorithm has a higher prediction success rate than that of the original switch constraint algorithm, and when the ratio of measuring occlusion duration is 0.4, the former improves the prediction success rate of the latter for outliers from 89.35% to 97.4%. Compared with the switch constraint algorithm, the improved algorithm by introducing weights decision approach removes abnormal topology measurements of the same user with multiple detected rectangles, improves cooperative positioning accuracy and robustness time consumption in computation.

Keywords: topology measurement; inertial navigation system; factor graph; cooperative localization; robust

近年来,合作定位技术作为群用户导航定位的关键技术之一,在群机器人导航、智能交通系统、无线传感器网络、无人机救援等联合作业领域有着良好的应用前景^[1-3]。当前主流的合作定位算法是基于用户间测距信息辅助的混合传感器定位。意大利都灵理工大学与 Istituto Superiore Mario Boella 高等研究院首次提出了混合全球导航卫星系统(GNSS)合作定位^[4]。法国航空实验室研究团队提出 Camera/IMU/Sonar 合作定位模型,实现了微小型飞行器编队合作定位和飞行控制^[5]。文献[6]提出了基于测距辅助的合作定位和室内构图算法,以改善网内传感器节点定位精度和节点建图的收敛速度。但是,以上这些合作定位算法都需额外安装射频测距系统,而基于特征的传统视觉定位技术易受光照等因素影响且对硬件要求高^[7],这些因素严重制约着合作定位技术在室内环境中的广泛应用。

针对融合滤波,相关学者讨论了最小二乘、卡尔曼滤波和粒子滤波等算法在合作中的定位性能^[8-9]。但是,上述算法框架结构固定,在应用环境和场景变化中无法快速扩展传感器集合和导航状态。因此,文献[10]提出了基于因子图融合模型的即插即用型算法,以解决多源传感器定位中的异步融合问题,但观测量中存在的野值点仍会影响定位性能。为了抑制野值,当前基于因子图的鲁棒性算法包括开关约束(SC)算法、动态协方差尺度(DCS)算法以及最大混合(MM)算法。文献[11]利用 SC 算法成功抑制了 GNSS 伪距和 iSAM2 算法中的观测野值。文献[12]证明了 SC 算法具有更好的性能,但是其计算量大,所需收敛次数多。DCS 算法能实时提供开关变量的闭环解,但精度略低。MM 算法^[13]更适用于高斯混合分布。

鉴于以上问题,考虑相机、监控设备等在日常生活日益普及,且深度学习在图像识别领域的快速

发展^[14],本文提出目标检测辅助的相机拓扑测量合作定位方法。该方法较传统合作定位方法无需额外射频测距系统,只需拍摄目标图像就可提取出目标相对位置的拓扑测量信息。针对传统滤波结构不易扩展、鲁棒性差的问题,提出室内惯性导航系统(INS)/相机拓扑测量的因子图模型,利用 Levenberg-Marquardt(LM)算法^[15]解决测量因子函数变化造成的矩阵奇异问题,并在 SC 算法基础上引入权值判断法,提出残差和检测分数联合判断的改进型 SC 算法。相比于 SC 算法,改进型 SC 检测拓扑测量野值点成功率更高,且提高了合作定位算法的定位精度和鲁棒性。

1 室内相机拓扑测量定位

1.1 基于 Faster R-CNN 的目标用户检测

用于图像检测的 R-CNN^[16]最早由 Girshick Ross 在 CVPR2014 上提出,该算法将图像划分为多个候选区域,对每个候选区域采用卷积神经网络(CNN)提取和分类目标,并且提出在大规模数据中预训练和目标数据集中微调的训练模式,为小规模数据集提供了解决方法。其快速版 Fast R-CNN^[17]和 Faster R-CNN^[18]分别于 2015 和 2017 年被相继提出,Faster R-CNN 的运行速度是 R-CNN 的 250 倍。利用上述特点,本文采用在 PASCAL VOC 2007 通用数据集上预先训练过的 Faster R-CNN,利用其学习到的 20 个类别浅层特征,在目标用户训练数据集上微调,最终输出目标用户类别、包围框坐标与检测分数,为拓扑测量算法提供用户成像高度。

1.2 拓扑测量合作定位

图 1 为单目相机拓扑测量原理图, U 为被摄用户, U_c 为其在互补金属氧化物半导体(CMOS)平面上的成像中心, P_v 为被摄用户与光轴垂直的所在物平面, P_h 为经过光轴的平行平面, O 为透镜光心, u

为 O 到 P_v 的距离, v 为像距, l 为被摄用户中心到光轴的距离, l_{CMOS} 为成像用户中心到图像中心点的距离, l_h 和 l_v 分别为 l_{CMOS} 在 CMOS 平面上水平和垂直距离。




图1 单目相机拓扑测量原理

根据单目相机拓扑测量原理图,分别得到用户距离 d 、方位角 α_c 和俯仰角 θ_c 为

$$d^2 - \beta v^2 = \rho^2 \quad (1)$$

$$\alpha_c = \arctan(l_h/v) \quad (2)$$

$$\theta_c = \arctan(l_v/\sqrt{v^2 + l_h^2}) \quad (3)$$

式中: $\beta = (h_{\text{true}}/h_{\text{CMOS}})^2$; $\rho^2 = (l_{\text{CMOS}} h_{\text{true}}/h_{\text{CMOS}})^2$, 其中 h_{true} 为被摄用户实际高度, h_{CMOS} 为被摄用户成像高度。 l_{CMOS} 、 h_{CMOS} 的单位为米, 而目标检测中包围框边长 n_p 的单位为像素, 因此需通过 n_p/e_p 将单位由像素转换为米, e_p 为 CMOS 传感器上单位长度的像素数。同一张测量图像中多个测量用户的 v 相等, 可将 v 看作未知量, 并结合式(1)~(3), 得到多用户相机拓扑测量定位函数模型为

$$\left\{ \begin{array}{l} \| \mathbf{p}_i - \mathbf{p}_j \|^2 - \beta_{ij} v_s^2 + \sigma_{ij}^2 = \rho_{ij}^2 \\ \alpha_{ij} + \delta_{ij}^2 = \alpha_{c_{ij}} \\ \theta_{ij} + \epsilon_{ij}^2 = \theta_{c_{ij}} \end{array} \right. \quad (4)$$

式中: $\mathbf{p}_i = [e_i, n_i, u_i]^T$ 和 $\mathbf{p}_j = [e_j, n_j, u_j]^T$ 分别为用户 i 和 j 在东北天坐标系下的位置; $\alpha_{ij} = \arctan(\Delta e_{ij}/\Delta n_{ij})$ 和 $\theta_{ij} = \arcsin(\Delta u_{ij}/\|\mathbf{p}_i - \mathbf{p}_j\|_2)$ 分别为用户的方位角和仰角; v_s 为测量图像 s 中的像距; σ_{ij}^2 、 δ_{ij}^2 、 ϵ_{ij}^2 分别为距离、方位角和仰角矢量的测量方差。假设用户数为 n , 待求状态量为用户三维位置和像距, 用户间总共进行 m 次拓扑测量, 共得到 l 张图像, 每次拓扑测量可得到距离、方位角和仰角 3 个观测量, 当满足 $m \geq n + l/3$ 时, 根据式(4)拓扑测量定位函数建立的非线性方程组有唯一解。

2 惯性导航系统/相机拓扑测量合作定位

本系统结合用户间相机拓扑测量和 INS 位姿递推, 设计了易扩展、导航信息更灵活的 INS/相机拓扑测量合作定位因子图模型。

2.1 基于因子图的合作定位模型

图 2 是 INS/相机拓扑测量合作定位因子图模型。 x_{it} 表示用户 i 在时序 t 时的导航状态; f^{INS} 为 INS 因子函数, 连接前后时序导航状态, 表示用户 INS 位姿估计误差函数; f^{bias} 为 INS 偏置因子函数, 表示偏置参数估计误差函数; f^{TOP} 为相机拓扑测量因子函数, 表示可视用户间拓扑测量误差函数。每个历元时刻, 通过灵活增添外源传感器因子函数和导航状态参数, 实时更新二维因子图, 结合量测或先验信息, 求得导航状态的最大后验概率估计值。




图2 INS/相机拓扑测量合作定位因子图模型

假设共有 k 个待定位用户, 导航状态量表示为 $\mathbf{X} = [\mathbf{X}_1, \dots, \mathbf{X}_k, \mathbf{V}_s]$, $\mathbf{V}_s$ 为图像像距矩阵, $\mathbf{X}_k = [\varphi_k, v_k, p_k, b_k]^T$ 包括用户姿态 φ_k 、速度 v_k 、位置 p_k 和 INS 偏置参数 b_k 。拓扑测量观测量表示为 $\mathbf{Z} = [\mathbf{Z}_1^{\text{TOP}}, \dots, \mathbf{Z}_k^{\text{TOP}}]$ 。在本定位模型问题中, 需要根据给定的量测信息, 求得使一系列概率分布 $p_i(\mathbf{X}|\mathbf{Z})$ 最大的状态变量 $\mathbf{X}$, 表示为

$$\mathbf{X}^* = \arg \max_{\mathbf{X}} \prod_{i=1}^k p_i(\mathbf{X}_i | \mathbf{Z}_i) \quad (5)$$

式中: $\mathbf{X}_i \subseteq \mathbf{X}$; $\mathbf{Z}_i \subseteq \mathbf{Z}$ 。假设测量误差服从高斯分布, 对式(5)取负对数, 可以得到

$$\mathbf{X}^* = \arg \min_{\mathbf{X}} \sum_{i=1}^k \| \mathbf{e}_i(\mathbf{X}_i, \mathbf{Z}_i) \|^2_{\boldsymbol{\Omega}} \quad (6)$$

式中: $\mathbf{e}_i(\mathbf{X}_i, \mathbf{Z}_i) = \mathbf{Z}_i - \mathbf{h}(\mathbf{X}_i)$, $\mathbf{h}(\cdot)$ 表示测量函数; $\| \mathbf{e} \|^2_{\boldsymbol{\Omega}} = \mathbf{e}^T \boldsymbol{\Omega}^{-1} \mathbf{e}$ 为测量协方差矩阵 $\boldsymbol{\Omega}$ 马氏距离的平方。至此, 多用户合作定位问题转化为最小二乘问题, 即求解使式(6)最小的参数最优解。

2.2 非线性优化

为了构建 INS/相机拓扑测量合作定位因子图, 需要为 INS 和相机拓扑测量建立因子函数, 从而构建多用户合作定位总体优化模型。用户的相机拓扑测量因子函数为

$$f_i^{\text{TOP}}(t) = d_1(\mathbf{Z}_i^{\text{TOP}}(t) - \mathbf{h}^{\text{TOP}}(\mathbf{x}_i(t), \mathbf{L}_i)) \quad (7)$$

式中: $d_1(\cdot) = \|\cdot\|_{\Omega}^2$; $\mathbf{h}^{\text{TOP}}$ 为拓扑测量函数; $\mathbf{x}_i(t)$ 为用户 i 导航状态矢量; $\mathbf{L}_i$ 为邻居用户位置矢量; $\mathbf{Z}_i^{\text{TOP}} = [d_i, \alpha_i, \theta_i]^T$ 为拓扑测量观测量。

INS 包含陀螺仪和加速度计,在给定量测 $\mathbf{Z}_i^{\text{INS}}$ $= [\mathbf{f}_i^b, \boldsymbol{\omega}_i^b]^T$ 时, $\mathbf{f}_i^b$ 、 $\boldsymbol{\omega}_i^b$ 分别是加速度计和陀螺仪的原始观测矢量,INS 因子函数 $\mathbf{f}_i^{\text{INS}}$ 和偏置因子函数 $\mathbf{f}_i^{\text{bias}}$ 分别为

$$\mathbf{f}_i^{\text{INS}} = d_1(\mathbf{x}_i(t+1)) - \mathbf{h}^{\text{INS}}(\mathbf{x}_i(t), \mathbf{b}(t), \mathbf{Z}_i^{\text{INS}}) \quad (8)$$

$$\mathbf{x}_i(t+1) = \mathbf{h}^{\text{INS}}(\mathbf{x}_i(t), \mathbf{b}_i(t), \mathbf{Z}_i^{\text{INS}}) \quad (9)$$

$$\mathbf{f}_i^{\text{bias}} = d_1(\mathbf{b}_i(t+1) + \mathbf{h}^{\text{bias}}(\mathbf{b}_i(t))) \quad (10)$$

$$\mathbf{b}_i(t+1) = \mathbf{h}^{\text{bias}}(\mathbf{b}_i(t)) \quad (11)$$

式中: $\mathbf{h}^{\text{INS}}$ 为 INS 位置、速度、姿态更新矢量函数; $\mathbf{h}^{\text{bias}}$ 为陀螺仪和加速度偏移矢量函数。将式(8)~(11)扩展到全体用户状态 $\mathbf{X} = [\mathbf{X}_1, \dots, \mathbf{X}_k, \mathbf{V}_s]$, 参照式(6)的形式,得到

$$\mathbf{X}^* = \arg \min_{\mathbf{X}} \left[\sum_{i=1}^k (\|\mathbf{e}_i^{\text{INS}}\|_{\Omega_{\text{INS}}}^2 + \|\mathbf{e}_i^{\text{bias}}\|_{\Omega_{\text{bias}}}^2 + \|\mathbf{e}_i^{\text{TOP}}\|_{\Omega_{\text{TOP}}}^2) \right] \quad (12)$$

上式右边记为 $\|\mathbf{e}_i\|_{\Omega}^2 = \|\mathbf{e}_i^{\text{INS}}\|_{\Omega_{\text{INS}}}^2 + \|\mathbf{e}_i^{\text{bias}}\|_{\Omega_{\text{bias}}}^2 + \|\mathbf{e}_i^{\text{TOP}}\|_{\Omega_{\text{TOP}}}^2$, 并令 $F(\mathbf{X}) = \sum_{i=1}^k \|\mathbf{e}_i\|_{\Omega}^2$, 对其中每一项 $\mathbf{e}_i(\cdot)$ 进行一阶泰勒展开,得到形如 $\mathbf{e}_i(\hat{\mathbf{x}} + \Delta \mathbf{x}) \approx \mathbf{J}_i \Delta \mathbf{x} + \mathbf{e}_i$ 的形式为

$$F(\mathbf{X} + \Delta \mathbf{X}) = \sum_{i=1}^k (\mathbf{J}_i \Delta \mathbf{X} + \mathbf{e}_i)^T \boldsymbol{\Omega}^{-1} (\mathbf{J}_i \Delta \mathbf{X} + \mathbf{e}_i) = \Delta \mathbf{X}^T \sum_{i=1}^k \mathbf{H}_i \Delta \mathbf{X} - 2 \sum_{i=1}^k \mathbf{r}_i^T \Delta \mathbf{X} + \sum_{i=1}^k \mathbf{e}_i^T \boldsymbol{\Omega}_i^{-1} \mathbf{e}_i \quad (13)$$

式中: $\mathbf{H}_i = \mathbf{J}_i^T \boldsymbol{\Omega}_i^{-1} \mathbf{J}_i$; $\mathbf{r}_i^T = -\mathbf{e}_i^T \boldsymbol{\Omega}_i^{-1} \mathbf{J}_i$, $\mathbf{J}_i$ 为雅可比矩阵,具体的各类因子节点 $\mathbf{J}_i$ 可参见附录。

当 $\partial F(\mathbf{X} + \Delta \mathbf{X}) / \partial \Delta \mathbf{X} = 0$ 时,使得 $\Delta \mathbf{X}$ 取最小值,可得满足 $\Delta \mathbf{X}$ 最小的条件为

$$\sum_{i=1}^k \mathbf{H}_i \Delta \mathbf{X} = \sum_{i=1}^k \mathbf{r}_i^T \quad (14)$$

通过式(14)可以看出,当有新的相机拓扑测量因子需要扩展时,只需叠加新的 $\mathbf{H}_i$ 和 $\mathbf{r}_i^T$,求得使 $F(\mathbf{X} + \Delta \mathbf{X})$ 达到最小的迭代更新值 $\Delta \mathbf{X}$ 。

解决非线性最小二乘问题常用的算法有牛顿迭代、高斯牛顿迭代和 LM 算法。在本文中,考虑到相机拓扑测量观测视域受限,可视邻居用户几何结构较差,且扩展的雅可比矩阵会发生实时变化,易造成 $\mathbf{H}_i$ 矩阵奇异、病态,不满足牛顿迭代求解的条件。因此,采用能够克服上述限制的 LM 算法求解最优化问题,将式(14)改进为

$$\left(\sum_{i=1}^k \mathbf{H}_i + \lambda \mathbf{I} \right) \Delta \mathbf{X} = \sum_{i=1}^k \mathbf{r}_i^T \quad (15)$$

式(15)通过阻尼迭代参数 λ 自适应控制 $\Delta \mathbf{X}$ 的收敛步伐,从而使 LM 算法类似于高斯牛顿迭代或梯度下降算法。对式(15)求解得到 $\Delta \mathbf{X}$,得到导航状态迭代解为 $\mathbf{X}^* = \mathbf{X} + \Delta \mathbf{X}$,当达到收敛条件时,当前的迭代解为最终优化解。

3 改进型鲁棒性因子图算法

在多传感器融合框架中,应用能够抑制观测野值点的鲁棒性算法可以进一步提高定位精度和可用性。SC 算法的主要思想是在测量因子函数中引入开关变量,利用该变量的调节作用,让优化器根据观测噪声自主决定开关变量。当测量噪声偏大时,开关变量函数 $\Psi(s_i)$ 接近于 0,从而抑制观测量对导航状态的校正;当测量噪声偏小时, $\Psi(s_i)$ 接近于 1。为此,将式(12)修正为

$$\mathbf{X}_{\text{sc}}^*, \mathbf{S}^* = \arg \min_{\mathbf{X}, \mathbf{S}} \left[\sum_{i=1}^k (\|\mathbf{e}_i^{\text{INS}}\|_{\Omega_{\text{INS}}}^2 + \|\mathbf{e}_i^{\text{bias}}\|_{\Omega_{\text{bias}}}^2 + \|\Psi(s_i) \mathbf{e}_i^{\text{TOP}}\|_{\Omega_{\text{TOP}}}^2 + \|1 - s_i\|_{\Omega_{\text{sc}}}^2) \right] \quad (16)$$

式中: $\mathbf{e}_i^{\text{TOP}} = \Psi(s_i) \mathbf{e}_i^{\text{TOP}}$; 开关函数 $\Psi(s_i)$ 描述为

$$\Psi(s_i) = \begin{cases} 1, & s_i > a \\ s_i/a, & 0 \leq s_i \leq a \\ 0, & s_i < 0 \end{cases} \quad (17)$$

其中 $a=1$ 为经验参数^[12]。定义 $e_i^{\text{sc}} = 1 - s_i$ 。根据 SC 算法,为优化参数而扩展开关变量会增加计算开销,故文献[12]提出实时求取开关变量的 DCS 算法,本文将 DCS 算法引用到式(12)中并修正为

$$\mathbf{X}_{\text{DCS}}^* = \arg \min_{\mathbf{X}} \left[\sum_{i=1}^k (\|\mathbf{e}_i^{\text{INS}}\|_{\Omega_{\text{INS}}}^2 + \|\mathbf{e}_i^{\text{bias}}\|_{\Omega_{\text{bias}}}^2 + \|s_i \mathbf{e}_i^{\text{TOP}}\|_{\Omega_{\text{TOP}}}^2) \right] \quad (18)$$

式中 $\mathbf{e}_i^{\text{DTP}} = s_i \mathbf{e}_i^{\text{TOP}}$, 开关变量 s_i ^[12] 为

$$s_i = \min \left(1, \frac{2\phi_i}{\phi_i + \|\mathbf{e}_i\|_{\Omega_i}^2} \right) \quad (19)$$

其中 ϕ_i 为 1×1 矩阵 $\boldsymbol{\Omega}_{\text{sc}}^{-1}$ 中的元素。


为了减少计算,通常可以通过设置残差阈值 e_{th} 作为启动鲁棒性算法的判断条件。当 $\mathbf{e}_i^{\text{TOP}}$ 中的最大元素 $e_{i,\text{max}}^{\text{TOP}}$ 满足 $e_{i,\text{max}}^{\text{TOP}} > e_{\text{th}}$ 时,启动鲁棒性算法,否则,仍按照常规误差函数进行参数优化。

然而,设置残差阈值的方法仍无法解决本文拓扑测量合作定位算法中同一个用户在同一帧观测到多个拓扑测量值的异常情况。图 3 是同用户多边框异常测量情况示意图,根据检测出的边框提取出相应的拓扑测量值,图中 g_i 为检测分数。在图 3a 中,通过残差法能够剔除出用户 A 的异常值,此时用户 A 的测量残差大于阈值。在图 3b 中由于预测出用

户 B 两个边框较接近,无法仅从测量残差中剔除。因此,本文在原 SC 算法中引入权值判断法,综合衡量测量值的检测分数和残差,当权值 $w_i < w_{th}$ 时启动鲁棒性算法,并将权值最高的同类别测量值保留。定义权值 w_i 为

$$w_i = \frac{g_i}{\max(\epsilon, e_{i, \max}^{TOP})} \tag{20}$$

式中 ϵ 为很小的正数,引入 ϵ 是为了防止由 $e_{i, \max}^{TOP}$ 过小导致的 w_i 过大问题。



(a)用户 A 的异常情况 (b)用户 B 的异常情况

图 3 同用户多边框异常测量

基于第 3 节鲁棒性算法的分析,建立多用户 INS/相机拓扑测量鲁棒性因子图合作定位算法,并根据权值判断法启动鲁棒性算法,整体算法流程如图 4 所示。




图 4 整体算法流程

4 实验测试及分析

4.1 仿真实验


为了测试算法在不同参数情况下的导航性能,设计了 INS/拓扑测量的合作/非合作定位仿真系统。在仿真系统中,用户 A 在二维平面移动,用户 B 和拓扑测量点 C 、 D 均处于静止状态,并设计了非合作定位与合作定位算法用做比较实验。非合作定位算法 (INS/NTOP) 中,拓扑测量观测量表示为 $Z^{NTOP} = [Z_{AC}^{TOP}, Z_{AD}^{TOP}, Z_{BC}^{TOP}, Z_{BD}^{TOP}]^T$,合作定位算法 (INS/CTOP) 中,拓扑测量观测量表示为 $Z^{CTOP} = [Z_{AC}^{TOP}, Z_{AD}^{TOP}, Z_{BC}^{TOP}, Z_{BD}^{TOP}, Z_{AB}^{TOP}]^T$,仿真系统中生成的每一个拓扑测量矢量 Z^{TOP} 均包括对用户测距和测角的观测值。系统仿真参数和 INS 各参数设定如表 1 所示,用户 A 仅配备 INS, B 和拓扑测量点 C 与 D 仅提供拓扑测量观测量。

表 1 仿真实验参数设置


导航源	参数	数值
INS	频率/Hz	30
	陀螺仪偏置/((°)·h ⁻¹)	0.1
	加速度计偏置	10 ⁻⁵ g
	角度随机游走/((°)·h ^{-1/2})	0.001
	速度随机游走/h ^{-1/2}	0.2×10 ⁻⁶ g
拓扑测量	频率/Hz	1
	测距误差/m	0.2~0.6
	俯仰误差/(°)	1~5
	航向误差/(°)	1~5

图 5 是不同测距和测角精度下,用户位置、速度、姿态误差的累积分布函数。测距精度 δ_d 分别设为 0.2、0.4、0.6 m,测角精度 δ_a 分别为 1°、3°、5°。从图 5a、5b、5d、5e 可知,拓扑测量的测距与测角精度越高,得到的位置和速度估计就越准确。从图 5c 和 5f 可知,测距和测角精度对姿态估算的影响不大,这是由于相机拓扑测量观测量仅包含对用户位置的修正信息,所以位置和速度的估计精度得到了明显提升。图 6 是测距和测角精度与收敛次数的关系,可以看出,测距和测角精度与算法收敛次数相关,精度越高,LM 算法所需的收敛次数越少。

仿真合作定位不同测距和测角精度与非合作定位的对比实验,合作定位测距和测角精度指拓扑测量 Z_{AB}^{TOP} 的测量精度。图 7 展示了合作定位与非合作定位对位置估计的影响,合作定位测距精度分别为 0.1、0.3、0.6 m,测角精度分别为 1°、2°和 3°。从图



(a)不同测距精度下的位置误差累积分布函数 (b)不同测距精度下的速度误差累积分布函数 (c)不同测距精度下的姿态误差累积分布函数



(d)不同测角精度下的位置误差累积分布函数 (e)不同测角精度下的速度误差累积分布函数 (f)不同测角精度下的姿态误差累积分布函数

图 5 不同测距和测角精度下的位置、速度、姿态误差累积分布函数




图 6 测距和测角精度与收敛次数的关系

7 可以看出, $\mathbf{Z}_{AB}^{TOP}$ 对位置解算有着明显的改善。这是因为 $\mathbf{Z}_{AB}^{TOP}$ 对待定位用户间进行位置约束, 当 $\delta_d = 0.6\text{ m}$ 、 $\delta_a = 3^\circ$ 时, 非合作定位算法中大于 10 m 的位置误差达 40%, 而合作定位算法将此部分位置误差全部降低到了 5~9 m, 因此较非合作定位算法而言, 合作定位算法的总体位置估计精度有较大程度提升。

4.2 实测实验

为了进一步测试算法在实测环境中的性能, 在西北工业大学电子信息学院搭建了实试验验证系统。由于前期需要建立 Faster R-CNN, 为此在尺寸为




图 7 合作与非合作定位的总体位置误差

15 m×7 m 的室内测试场景下随机采集实验人员、小推车、无人机和安装相机的三脚架(静态用户)的图像 400 幅, 记录目标高度, 并在图像上分别标记类。训练数据集中, 测试、训练和验证集分别为 200、120 和 80 幅图像, 采用已在 PASCAL VOC2007 通用数据集上训练过的基于 ZF 网络的 Faster R-CNN 作为实验初始训练网络。

4.2.1 拓扑测量精度验证 在实测场地中每隔 2 m 对所要识别的实验人员拍照 20 张, 应用训练过的 Faster R-CNN 完成目标检测, 拓扑测量观测误差与物距的关系如图 8 所示。可以看出: 随着物距的增加, 测距和测角误差呈上升趋势; 物距 10 m 之内的测距误差小于 1 m, 测角误差小于 1.5°; 当物距达到 15 m 时, 测距和测角误差分别达到 3 m 和 2°。




图 8 测距误差和测角误差与物距的关系

为分析不同尺寸目标对测量精度和检测成功率的影响, 在物距 10 m 情况下采集行人(高度×正面长度×侧面长度: 162 cm×38 cm×17 cm)、小推车(高度×长度×宽度: 81 cm×71 cm×41 cm)和无人机(高度×长度×宽度: 22 cm×45 cm×45 cm)图像各 50 张, 测距、测角误差和检测成功率如图 9 所示, 为方便比较, 将此处测角误差转换为弧长, 单位为 m。从图 9 中可以看出: 尺寸最小的无人机测距误差最大, 体积近似的行人和小推车测距误差相差较

小;目标尺寸对测角误差的影响较小,3个尺寸目标的测角误差较接近;小尺寸目标对识别算法的检测成功率造成了轻微影响,行人检测成功率为98%,无人机检测成功率降低到了92%。




图9 不同尺寸目标的测量精度和检测成功率

4.2.2 定位精度和鲁棒性能验证 与仿真系统中用户和拓扑测量点设置一致,移动人员携带一个消费级6自由度惯性传感器MPU9250作为用户A,在室内测试场地做8字形轨迹移动,安装数码相机的三脚架作为静态用户B,另外设置两个处于视野开阔位置的定点相机作为C和D,以便实时采集用户A和B的图像,实验场景如图10所示。INS和相机的采样频率分别为30 Hz和10 Hz。本实验参考轨迹的真实位置,由用户运动至提前布设的30个已知地标处采集后获得,采用的所有算法均在配置为Intel Core i5-7300U CPU、主频2.6 GHz、16 GB RAM笔记本上以后处理方式完成解算。开始处理前,对各拓扑测量起始数据段进行自相关运算,以确定起始同步图像帧,按照INS/CTOP组合方案,运用非鲁棒、DCS、SC和本文提出的改进型SC算法进行合作和非合作定位解算。




图10 实验场景配置

图11为运行两圈轨迹总体位置误差概率分布,可以看出:非鲁棒性的合作与非合作定位算法在所有算法中效果最差;合作定位算法均优于采用同一鲁棒性算法的非合作定位算法;合作定位+改进型SC算法较非合作定位+非鲁棒性算法的精度提升

了79.8%。






图11 总体位置误差概率分布

INS/CTOP位置误差统计如图12所示,在该实验方案中,SC算法和DCS算法的 $\Omega_{SC}=[1]$ 。由图12可以看出:非鲁棒算法野值点较多;DCS算法效果稍差于SC算法,但因为采用闭环解算,迭代次数和所需运行时间最短;SC算法因需要扩展开关变量为优化参数,故所需的时间最长;改进后的SC算法因为引入权值判断法,剔除了同用户多边框的异常拓扑测量值,进一步抑制了野值点数,提高了鲁棒性和定位精度,且减小了SC算法中未剔除的同用户多边框情况下的额外开销。各算法的性能对比结果如表2所示,其中精度提升量是指各算法均方根误差相对于非合作+非鲁棒算法的提升的百分点,预测成功率是在开关变量判断阈值 $b_{th}=0.01$ 时获得的。



(a)非鲁棒算法



(b)DCS算法





图 12 INS/CTOP 位置误差统计




图 13 SC 算法预测成功率




图 14 改进型 SC 算法预测成功率

表 2 各算法性能对比

算法	时间 /s	迭代 次数	均方根 误差/m	精度提 升量/%	预测成 功率/%
非合作+非鲁棒	8.12	10	0.94		
非合作+DCS	6.80	8	0.38	59.6	
非合作+SC	8.61	10	0.36	61.7	89.0
非合作+改进型 SC	8.10	9	0.20	78.7	97.0
合作+非鲁棒	8.09	9	0.66	29.8	
合作+DCS	6.60	8	0.32	65.9	
合作+SC	8.19	9	0.31	75.0	89.4
合作+改进型 SC	7.90	9	0.19	79.8	97.4

注:表中加粗数据为最优值。

不同开关变量判断阈值 b_{th} 下,SC 算法和其改进型算法的预测成功率与测量遮挡时长的关系如图 13 和图 14 所示,障碍物设置在 AC 视距段。可以看出:随着测量遮挡时长的增加,野值点的预测成功率均略有下降,但改进型 SC 算法较 SC 算法的拓扑测量野值点预测成功率更高;当测量遮挡时长比为 0.4 时,改进型 SC 算法将 SC 算法的预测成功率由 89.35% 提高到了 97.4%。由本实验可知,改进型 SC 算法缩短了 SC 算法的计算时间,而且对拓扑测量野值点具有较好的鲁棒性和预测准确性。

5 结 论

在合作定位算法研究中,良好的测距性能和融合算法的强鲁棒性是在室内环境中确保获得高可靠位姿估计的关键。传统合作定位算法需要依赖射频测距系统,且融合算法滤波结构固定,缺少能够有效抑制野值点的鲁棒性算法。本文提出一种基于 Faster R-CNN 辅助的相机拓扑测量合作定位方法。该方法无需额外射频测距系统,根据拍摄目标的图像就可提取出目标相对位置的拓扑测量信息。在此基础上,提出一种改进型 SC 算法,通过引入权值判断法,提高了合作定位精度和鲁棒性。本文得出的主要结论有:

- (1)拓扑测量精度的提高对位置和速度估计、收敛次数均有不同程度的改善,物距的增加和目标尺寸的减小均影响测距和测角的测量精度以及检测算法的成功率;
- (2)在定位精度方面,本文所提合作定位算法均优于采用同一鲁棒性算法的非合作定位算法,合作定位+改进型 SC 算法较非合作定位+非鲁棒型定位精度提升了 79.8%;
- (3)在鲁棒性方面,与原 SC 算法相比,改进后的 SC 算法抑制野值点效果最好,且减少了计算消

耗,在测量遮挡时间比例增加的情况下,对野值点仍具有较高的预测成功率。

未来可进行的研究方向如下:①研究不确定时延对系统定位影响,以提高算法实时运行性能;②考虑融合更丰富的测量数据类型,提高系统错误检测的能力,获得精度更高、鲁棒性更强的位姿结果;③提高识别算法对小尺寸、远距离目标的识别能力。

参考文献:

- [1] 张佳龙, 闫建国, 张普, 等. 基于一致性算法的无人机协同编队避障研究 [J]. 西安交通大学学报, 2018, 52(9): 168-174.
ZHANG Jialong, YAN Jianguo, ZHANG Pu, et al. Collision avoidance of unmanned aerial vehicle formation based on consensus control algorithm [J]. Journal of Xi'an Jiaotong University, 2018, 52(9): 168-174.
- [2] KONG S H, JUN S Y. Cooperative positioning technique with decentralized malicious vehicle detection [J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 19(3): 826-838.
- [3] 魏全瑞, 刘俊, 韩九强. 改进的无线传感器网络无偏距离估计与节点定位算法 [J]. 西安交通大学学报, 2014, 48(6): 1-6.
WEI Quanrui, LIU Jun, HAN Jiueqiang. An improved DV-hop node localization algorithm based on unbiased estimation for wireless sensor networks [J]. Journal of Xi'an Jiaotong University, 2014, 48(6): 1-6.
- [4] SOTTILE F, CACERES M A, SPIRITO M A. A simulation tool for hybrid-cooperative positioning [C] // Proceedings of International Conference on Localization and GNSS. Piscataway, NJ, USA: IEEE, 2011: 64-70.
- [5] PIASCO N, MARZAT J, SANFOURCHE M. Collaborative localization and formation flying using distributed stereo-vision [C] // Proceedings of IEEE International Conference on Robotics and Automation. Piscataway, NJ, USA: IEEE, 2016: 1202-1207.
- [6] NASERI H, KOIVUNEN V. Cooperative simultaneous localization and mapping by exploiting multipath propagation [J]. IEEE Transactions on Signal Processing, 2017, 65(1): 200-211.
- [7] 邸凯昌, 王文辉, 赵红颖, 等. 视觉 SLAM 技术的进展与应用 [J]. 测绘学报, 2018, 47(6): 770-779.
DI Kaichang, WAN Wenhui, ZHAO Hongying, et al. Progress and applications of visual SLAM [J]. Acta Geodaetica et Cartographica Sinica, 2018, 47(6): 770-779.
- [8] MINETTO A, CRISTODARO C, DOVIS F. A collaborative method for positioning based on GNSS inter agent range estimation [C] // Proceedings of 25th European Signal Processing Conference. Piscataway, NJ, USA: IEEE, 2017: 2714-2718.
- [9] STANCOVICI A, MICEA M V, CRETU V. Cooperative positioning system for indoor surveillance applications [C] // Proceedings of International Conference on Indoor Positioning and Indoor Navigation. Piscataway, NJ, USA: IEEE, 2016: 1-7.
- [10] ZENG Q H, CHEN W N, LIU J Y, et al. An improved multi-sensor fusion navigation algorithm based on the factor graph [J]. Sensors, 2017, 17(3): 641.
- [11] SUNDERHAUF N, OBST M, LANGE S, et al. Switchable constraints and incremental smoothing for online mitigation of non-line-of-sight and multipath effects [C] // Proceedings of IEEE Intelligent Vehicles Symposium. Piscataway, NJ, USA: IEEE, 2013: 262-268.
- [12] PFEIFER T, WEISSIG P, LANGE S, et al. Robust factor graph optimization: a comparison for sensor fusion applications [C] // Proceedings of IEEE 21st International Conference on Emerging Technologies and Factory Automation. Piscataway, NJ, USA: IEEE, 2016: 1-4.
- [13] OZOG P, EUSTICE R M. Large-scale model-assisted bundle adjustment using Gaussian max-mixtures [C] // Proceedings of IEEE International Conference on Robotics and Automation. Piscataway, NJ, USA: IEEE, 2016: 5576-5581.
- [14] 崔云博, 杜友田, 王航. 面向图像的有效目标区域提取方法 [J]. 西安交通大学学报, 2019, 53(5): 52-57.
CUI Yunbo, DU Youtian, WANG Hang. Extraction method for key object region in images [J]. Journal of Xi'an Jiaotong University, 2019, 53(5): 52-57.
- [15] BELLAVIA S, GRATTON S, RICCIETTI E. A Levenberg-Marquardt method for large nonlinear least-squares problems with dynamic accuracy in functions and gradients [J]. Numerische Mathematik, 2018, 140(3): 791-825.
- [16] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C] // Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2014: 580-587.
- [17] GIRSHICK R. Fast R-CNN [C] // Proceedings of IEEE International Conference on Computer Vision. Piscataway, NJ, USA: IEEE, 2015: 1440-1448.

- [18] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.

(编辑 陶晴)

附录 A

对文中涉及到的所有因子节点的雅可比矩阵具体形式给出详细求导公式。假设待优化的用户导航状态表示为 $\hat{\mathbf{x}} = [\mathbf{x}_1, \mathbf{b}_1, s_1, \dots, \mathbf{x}_k, \mathbf{b}_k, s_k]$, $\mathbf{x}_k$ 表示用户 k 的位姿状态(包括位置、速度和姿态), $\mathbf{b}_k$ 表示 INS 偏置向量, s_k 表示开关变量, 文中公式涉及的相关因子函数的雅可比矩阵 $\mathbf{J}_i$ 为

$$\mathbf{J}_{\text{INS}, \mathbf{x}_i(t)} = \frac{\partial \mathbf{e}_i^{\text{INS}}}{\partial \mathbf{x}_i(t)} = \frac{\partial (\mathbf{x}_i(t+1) - \mathbf{h}_i^{\text{INS}}(\mathbf{x}_i(t), \mathbf{h}_i(t), \mathbf{Z}_i^{\text{INS}}))}{\partial \mathbf{x}_i(t)} \quad (\text{A1})$$

$$\mathbf{J}_{\text{INS}, \mathbf{x}_i(t+1)} = \frac{\partial \mathbf{e}_i^{\text{INS}}}{\partial \mathbf{x}_i(t+1)} = \frac{\partial (\mathbf{x}_i(t+1) - \mathbf{h}_i^{\text{INS}}(\mathbf{x}_i(t), \mathbf{h}_i(t), \mathbf{Z}_i^{\text{INS}}))}{\partial \mathbf{x}_i(t+1)} \quad (\text{A2})$$

$$\mathbf{J}_{\text{INS}, \mathbf{b}_i(t)} = \frac{\partial \mathbf{e}_i^{\text{INS}}}{\partial \mathbf{b}_i(t)} = \frac{\partial (\mathbf{x}_i(t+1) - \mathbf{h}_i^{\text{INS}}(\mathbf{x}_i(t), \mathbf{b}_i(t), \mathbf{Z}_i^{\text{INS}}))}{\partial \mathbf{b}_i(t)} \quad (\text{A3})$$

$$\mathbf{J}_{\text{bias}, \mathbf{b}_i(t)} = \frac{\partial \mathbf{e}_i^{\text{bias}}}{\partial \mathbf{b}_i(t)} = \frac{\partial (\mathbf{b}_i(t+1) - \mathbf{h}_i^{\text{bias}}(\mathbf{b}_i(t)))}{\partial \mathbf{b}_i(t)} \quad (\text{A4})$$

$$\mathbf{J}_{\text{bias}, \mathbf{b}_i(t+1)} = \frac{\partial \mathbf{e}_i^{\text{bias}}}{\partial \mathbf{b}_i(t+1)} = \frac{\partial (\mathbf{b}_i(t+1) - \mathbf{h}_i^{\text{bias}}(\mathbf{b}_i(t)))}{\partial \mathbf{b}_i(t+1)} \quad (\text{A5})$$

$$\mathbf{J}_{\text{TOP}, \mathbf{x}_i(t)} = \frac{\partial \mathbf{e}_i^{\text{TOP}}}{\partial \mathbf{x}_i(t)} = \frac{\partial (\mathbf{Z}_i^{\text{TOP}}(t) - \mathbf{h}_i^{\text{TOP}}(\mathbf{x}_i(t), \mathbf{L}_i))}{\partial \mathbf{x}_i(t)} \quad (\text{A6})$$

$$\mathbf{J}_{\text{STOP}, \mathbf{x}_i(t)} = \frac{\partial \mathbf{e}_i^{\text{STOP}}}{\partial \mathbf{x}_i(t)} = \frac{\partial (\Psi(s_i)(\mathbf{Z}_i^{\text{TOP}}(t) - \mathbf{h}_i^{\text{TOP}}(\mathbf{x}_i(t), \mathbf{L}_i)))}{\partial \mathbf{x}_i(t)} \quad (\text{A7})$$

$$\mathbf{J}_{\text{STOP}, s_i(t)} = \frac{\partial \mathbf{e}_i^{\text{STOP}}}{\partial s_i} = \frac{\partial (\Psi(s_i)(\mathbf{Z}_i^{\text{TOP}}(t) - \mathbf{h}_i^{\text{TOP}}(\mathbf{x}_i(t), \mathbf{L}_i)))}{\partial s_i} \quad (\text{A8})$$

$$\mathbf{J}_{\text{SC}, s_i(t)} = \frac{\partial \mathbf{e}_i^{\text{SC}}}{\partial s_i} = \frac{\partial (1 - s_i)}{\partial s_i} \quad (\text{A9})$$

$$\mathbf{J}_{\text{DTOP}, \mathbf{x}_i(t)} = \frac{\partial \mathbf{e}_i^{\text{DTOP}}}{\partial \mathbf{x}_i} = \frac{\partial (s_i(\mathbf{Z}_i^{\text{TOP}}(t) - \mathbf{h}_i^{\text{TOP}}(\mathbf{x}_i(t), \mathbf{L}_i)))}{\partial \mathbf{x}_i} \quad (\text{A10})$$

$$\mathbf{J}_{\text{DTOP}, s_i(t)} = \frac{\partial \mathbf{e}_i^{\text{DTOP}}}{\partial s_i} = \frac{\partial (s_i(\mathbf{Z}_i^{\text{TOP}}(t) - \mathbf{h}_i^{\text{TOP}}(\mathbf{x}_i(t), \mathbf{L}_i)))}{\partial s_i} \quad (\text{A11})$$

式(A1)中 $\mathbf{J}_{\text{INS}, \mathbf{x}_i(t)}$ 表示 INS 因子函数对 $\mathbf{x}_i(t)$ 的偏导数, 其余 $\mathbf{J}_i$ 以此类推。

以式(16)列出的采用 SC 算法的合作定位总体误差函数为例, 构建前后两个连续导航时刻的全局雅可比矩阵为

$$\mathbf{J}(\hat{\mathbf{x}}(t), \hat{\mathbf{x}}(t+1)) = \begin{bmatrix} \mathbf{J}_{\text{INS}, \mathbf{x}_1(t)} & \mathbf{J}_{\text{INS}, \mathbf{b}_1(t)} & & & & & & & & & \\ & \mathbf{J}_{\text{bias}, \mathbf{b}_1(t)} & & & & & & & & & \\ \mathbf{J}_{\text{STOP}, \mathbf{x}_1(t)} & & \mathbf{J}_{\text{STOP}, s_1(t)} & & & & & & & & \\ & & \mathbf{J}_{\text{SC}, s_1(t)} & & & & & & & & \\ & & & \ddots & & & & & & & \\ & & & & \mathbf{J}_{\text{INS}, \mathbf{x}_k(t)} & \mathbf{J}_{\text{INS}, \mathbf{b}_k(t)} & & & & & \\ & & & & & \mathbf{J}_{\text{bias}, \mathbf{b}_k(t)} & & & & & \\ & & & & & & \mathbf{J}_{\text{TOP}, \mathbf{x}_k(t)} & & & & \\ & & & & & & & \mathbf{J}_{\text{SC}, s_k(t)} & & & \end{bmatrix} \begin{bmatrix} \mathbf{J}_{\text{INS}, \mathbf{x}_1(t+1)} & & & & & & & & & & \\ & \mathbf{J}_{\text{bias}, \mathbf{b}_1(t+1)} & & & & & & & & & \\ & & \ddots & & & & & & & & \\ & & & \mathbf{J}_{\text{INS}, \mathbf{x}_k(t+1)} & & & & & & & \\ & & & & \mathbf{J}_{\text{bias}, \mathbf{b}_k(t+1)} & & & & & & \end{bmatrix} \quad (\text{A12})$$

式中 STOP 与 INS 的采样频率之比为 1:2。