

DOI: 10.19650/j.cnki.cjsi.202311876

面向协作集群的鲁棒协同自定位与相对定位方法^{*}

熊 骏¹, 解相朋¹, 熊 智², 庄 园³

(1. 南京邮电大学物联网学院 南京 210023; 2. 南京航空航天大学自动化学院 南京 211106;
3. 武汉大学测绘遥感信息工程国家重点实验室 武汉 430079)

摘 要: 协同定位是卫星拒止等导航基础设施受限环境下提升载体定位精度的重要手段, 载体自定位和载体之间相对定位是其主要两项应用。然而现有方法通常将自定位与相对定位剥离开来, 仅用于估计其中一种定位状态, 不仅存在应用局限性, 也忽略了集群相对运动与个体运动之间的关联性, 导致性能损失。为解决该问题, 提出了一种适用于协作集群的鲁棒协同自定位与相对定位方法, 基于自定位、相对定位和协同量测之间的概率关系建立概率图模型, 描述了相对运动与个体运动之间的概率关系; 采用高斯置信传播传递实现图模型的边缘概率求解, 实现消息传递的高效计算; 设计了基于 Huber 损失函数的 Huber 因子, 可实现异常量测在高斯消息传递过程中的降权, 从而实现鲁棒协同估计。实验结果表明, 所提出的方法不仅能够同时进行自定位与相对定位估计, 且估计精度优于传统协同定位方法, 所设计的 Huber 因子能够有效处理异常量测, 为集群协同导航定位的融合架构提供了新思路。

关键词: 协同定位; 高斯置信传播; 自定位; 相对定位; 鲁棒估计

中图分类号: TN965 TH701 **文献标识码:** A **国家标准学科分类代码:** 510.80

Robust cooperative self-localization and relative-localization for collaborative swarms

Xiong Jun¹, Xie Xiangpeng¹, Xiong Zhi², Zhuang Yuan³

(1. School of Internet-of-Things, Nanjing University of Posts and Telecommunications, Nanjing 210023, China; 2. School of Automation, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China; 3. State Key Laboratory of Information Engineering in Surveying, Mapping and Remote Sensing, Wuhan University, Wuhan 430079, China)

Abstract: In navigation infrastructure-limited scenarios such as GNSS denied area, cooperative localization is an important approach to improve the localization accuracy. Self and relative localization are two main applications of cooperative localization. However, existing methods usually conduct self and relative localization separately, which not only limits the practical applications, but also leads to the performance loss by neglecting the motion correlations between swarm and individuals. To solve this problem, this work proposes a robust cooperative simultaneous self and relative localization (RC-SSRL) for collaborative swarm. It models the probability relationships among cooperative self-localization (CSL) and relative-localization (CRL) as well as cooperative measurements with a probability graph model, which depicts the probability relationship between relative-motion and self-motion. The marginal distributions in the graph models are calculated via the Gaussian belief propagation (GaBP), which is computationally efficient in message passing. Moreover, a Huber factor is designed based on the Huber loss function to implement the robust estimation by down-weighting the abnormal measurements in Gaussian message passing. Experimental results show that the proposed methods can estimate CSL and CRL states simultaneously, whose accuracy outperforms the traditional methods. Meanwhile, Huber factor can handle the abnormal measurements effectively to guarantee the system's robustness. The proposed RC-SSRL provides a new way for the fusion framework of swarm cooperative localization.

Keywords: cooperative localization; Gaussian belief propagation; self-localization; relative-localization; robust estimation

收稿日期: 2023-09-04 Received Date: 2023-09-04

^{*} 基金项目: 国家自然科学基金 (62203228)、南京邮电大学引进人才自然科学研究启动基金 (NY221137)、航空科学基金 (ASFC-2022Z0220X9001)、武汉大学测绘遥感信息工程国家重点实验室开放研究基金 (22P01) 项目资助

0 引 言

随着数据通信技术发展,基于数据共享的协同定位逐渐成为热点研究方向。相比于传统的单机导航系统仅依赖自身传感器进行定位解算,协同机制中每个载体可通过组网通信分享数据,通过协同估计算法可以进一步增强其导航定位性能,在导航基础设施受限(如卫星导航拒止^[1]、无线电信标不可用等^[2])条件下具备较高的应用价值。

现有的协同定位方法通常可分为两类问题,分别为协同自定位(cooperative self-localization, CSL)与协同相对定位(cooperative relative-localization, CRL)。其中 CSL 能够提供世界坐标系(如地心地固坐标系)下的位置、速度、姿态等状态,能够输出载体相对于空间固定点的绝对位姿;CRL 则用于提供两个动态载体之间的相对位置、速度、姿态等状态,用于描述载体之间的相对位姿状态。CSL 与 CRL 在精确任务执行、协同路径规划、协同编队控制等方面均起到重要支撑作用。

在 CSL 领域,卡尔曼滤波(Kalman filter, KF)作为最常见的信息融合方法最先得到了广泛运用^[3]。此类方法以 KF 框架为基础,将载体的 CSL 状态(绝对位置、速度、姿态)作为滤波器状态量构建相应的系统状态方程,将载体之间的测量作为观测建立观测方程,本质上是传统组合导航算法的简单扩展。然而受制于一阶马尔可夫过程假设, KF 类方法无法充分利用集群的历史观测与估计信息进一步提升估计性能。为解决该问题,近年来以图模型为基础的 CSL 方法受到了广泛关注,图模型能够有效描述多历元之间 CSL 状态量和协同观测的约束,可通过因子图优化(factor graph optimization, FGO)^[4-5]多次迭代降低残差或者消息传递(message passing, MP)^[6-7]求解边缘后验分布的方式求解 CSL 状态量。其中 MP 机制在协同定位领域受到广泛关注,然而传统 MP 算法计算量高、通信量大,工程适用性较差。

在 CRL 领域,以多传感器融合为核心的相对定位状态估计是目前最为主流的方法。此类方法以 KF 框架为核心,基于惯性^[8]、运动模型^[9]等建立状态方程,基于卫星^[9]、数据链^[10]、视觉^[11]等观测建立观测方程,从而实现 CRL 状态估计。文献[8]以相对惯导模型为基础建立系统方程,以视觉获得的相对视线量测建立观测方程,从而实现惯性/视觉融合的 CRL 系统。然而其系统方程依赖两个载体惯性传感器的直接输出,高速率的惯性量测信息将带来较大通信压力;基于相对惯导模型的系统方程建立也较为复杂,不利于实际应用;此外,这类 CRL 滤波器通常局限于两个载体之间的相对估计,无法同时估计多个载体之间的 CRL 状态。

综上所述,虽然现有的 CSL 与 CRL 方法可以实现相应的协同定位状态估计,但是这两种方法通常相互独立,带来了 4 方面问题:1)在实际工程应用中,单个载体通常需要运行多个估计器以获得 CSL 状态和其相对于其他多个载体的 CRL 状态,提升了协同定位的计算负载和数据处理难度;2)现有的 CRL 估计方法通常局限于两个载体之间,不适合大规模协同的场景;3)CRL 的高精度系统方程建立较为复杂,且相应数据通信的实时性、同步性、更新速率要求较高,需要两个载体的位姿传感器以高速率实时更新系统模型,从而保证相对运动模型的准确性,工程实用性较差;4)将自定位与相对定位分开处理忽略了两者的互相关性,未能充分利用无人集群中各个载体之间的几何约束与时空相关性,存在一定的性能损失。

针对上述 4 个问题,本文提出一种适用于协作集群的鲁棒协同自定位与相对定位(robust cooperative simultaneous self and relative localization, RC-SSRL)方法,基于概率图模型构建载体 CSL 状态与 CRL 状态之间的约束关系,采用高斯置信传播(Gaussian belief propagation, GaBP)实现定位数据边缘后验概率求解,从而实现 CSL、CRL 状态的同步解算;为保障系统鲁棒性,采用 Huber 因子对 GaBP 的消息传递过程进行重加权,通过降低故障因子的消息权重实现鲁棒估计。相比于传统集群协同定位方法, RC-SSRL:能够基于单个导航状态估计器同时进行 CSL 与 CRL 估计,简化了传统协同算法的架构;克服了传统 CRL 算法局限于两个载体之间的约束,能够同时估计当前载体相对于多个其他协同载体的 CRL 状态;数据通信要求较低,无需载体间实时高速率互传位姿传感数据;充分利用了载体之间的几何约束与时空相关性,其绝对、相对位姿精度相比于传统方法均有提升。因此,本文所提出的 SSRL 相比于传统方法在算法实现架构、数据通信量、定位精度方面均具备一定优势,在集群协同导航定位具有较高的应用潜力。

1 定位系统模型

假设一个如图 1 所示的二维协同定位系统,该协同场景由无人载体集合 $\mathcal{R}$ 与地标集合 $\mathcal{L}$ 组成,所有参与协同定位的载体均可基于网络共享自身的 CSL、CRL 状态估值和传感器测量值,以提供进一步协同解算。

载体 $i \in \mathcal{R}$ 在 t 时刻的 CSL 状态量为 $\mathbf{s}_i^{(t)} = [\mathbf{x}_i^{(t)}, \mathbf{y}_i^{(t)}, \mathbf{q}_i^{(t)}]^T$, 其中 $\mathbf{x}_i^{(t)}, \mathbf{y}_i^{(t)}$ 为二维坐标, $\mathbf{q}_i^{(t)} = [q_{i,0}^{(t)}, q_{i,1}^{(t)}, q_{i,2}^{(t)}, q_{i,3}^{(t)}]^T$ 为姿态四元数;载体 i 相对于其他载体 $j \in \mathcal{C}_i^{(t)}$ 的 CRL 状态量为 $\mathbf{r}_{ij}^{(t)} = [d_{ij}^{(t)}, \varphi_{ij}^{(t)}]^T$, 其中, $d_{ij}^{(t)}$ 是载体 i, j 之间的相对距离估计, $\varphi_{ij}^{(t)}$ 为相对角度估计,集合 $\mathcal{C}_i^{(t)}$ 包含了 t 时刻与载体 i 有量测关系的所有其他协同载体。




图 1 协同定位场景

Fig. 1 Scenario of cooperative localization

每个载体均搭载了能够获取自身运动量测 $\tilde{\mathbf{u}}_i^{(t)} = [\tilde{v}_i^{(t)}, \tilde{\omega}_i^{(t)}]^T$ 的轮式里程计,其中 $\tilde{v}_i^{(t)}$ 为载体的前向速度量测, $\tilde{\omega}_i^{(t)}$ 为机体航向旋转角速度量测,与 CSL 状态的关系为:

$$\begin{cases} \tilde{v}_i^{(t)} = f_o \sqrt{(x_i^{(t+1)} - x_i^{(t)})^2 + (y_i^{(t+1)} - y_i^{(t)})^2} + n_v \\ \tilde{\omega}_i^{(t)} = f_o [\theta(\mathbf{q}_i^{(t+1)}) - \theta(\mathbf{q}_i^{(t)})] + n_\omega \end{cases} \quad (1)$$

式中: f_o 为里程计更新频率; $\theta(\mathbf{q}_i^{(t)})$ 为姿态四元数与载体航向的转换函数; n_v 和 n_ω 为相应的量测噪声,服从零均值高斯分布。

为获得相对量测,每个载体均搭载了视觉相机,能获得相对于其他载体、地标的相对量测 $\tilde{\mathbf{z}}_{ij}^{(t)} = [\tilde{d}_{ij}^{(t)}, \tilde{\varphi}_{ij}^{(t)}]^T$,其中 $\tilde{d}_{ij}^{(t)}$ 、 $\tilde{\varphi}_{ij}^{(t)}$ 分别为载体 i j 之间的相对距离和相对角度量测,量测模型为:

$$\begin{cases} \tilde{d}_{ij}^{(t)} = \sqrt{(x_i^{(t)} - x_j^{(t)})^2 + (y_i^{(t)} - y_j^{(t)})^2} + n_d \\ \tilde{\varphi}_{ij}^{(t)} = \text{atan}\left(\frac{y_j^{(t)} - y_i^{(t)}}{x_j^{(t)} - x_i^{(t)}}\right) - \theta(\mathbf{q}_i^{(t)}) + n_\varphi \end{cases} \quad (2)$$

式中: n_d 、 n_φ 分别为相对距离和相对角度的量测噪声,服从零均值高斯分布。

2 协同自定位与相对定位图模型

基于里程计运动模型(式(1))和协同量测模型(式(2)),可建立 CSL 与 CRL 状态的条件概率分布为:

$$p(\mathbf{S}^{(1:t)}, \mathbf{R}^{(1:t)} | \tilde{\mathbf{U}}^{(1:t)}, \tilde{\mathbf{Z}}^{(1:t)}, \mathbf{S}^{(0)}) \quad (3)$$

式中:上标 $(1:t)$ 表示相应参数包含时刻 $1 \sim t$ 所有数据; $\mathbf{S}^{(1:t)} \triangleq \{\mathbf{s}_i^{(k)}, i \in \mathbb{R}, k = 1:t\}$ 为所有载体 CSL 状态集合; $\mathbf{R}^{(1:t)} \triangleq \{\mathbf{r}_{ij}^{(k)}, i \in \mathbb{R}, j \in \mathbb{C}_i^{(k)}, k = 1:t\}$ 为所有载体与其他载体之间的 CRL 状态集合, $\tilde{\mathbf{U}}^{(1:t)} \triangleq \{\tilde{\mathbf{u}}_i^{(k)}, i \in \mathbb{R}, k = 1:t\}$ 为所有载体里程计量测集合; $\tilde{\mathbf{Z}}^{(1:t)} \triangleq \{\tilde{\mathbf{z}}(k)_{ij},$


$i \in \mathbb{R}, j \in \mathbb{C}_i^{(k)} \cup \mathbb{L}_i^{(k)}, k = 1:t\}$ 为所有载体的相对量测集合,其中 $\mathbb{L}_i^{(k)}$ 包含 t 时刻与载体 i 有相对量测的全部地标。

在协同定位过程中,不同载体的量测和运动可视为相互独立,则协同定位条件概率(式(3))可进一步分解为:

$$\begin{aligned} & \prod_{i \in \mathbb{R}} p(\mathbf{s}_i^{(0)}) \prod_{i \in \mathbb{R}} \left\{ \prod_{k=1}^t p(\mathbf{s}_i^{(k)} | \mathbf{s}_i^{(k-1)}, \tilde{\mathbf{u}}_i^{(k-1)}) \times \right. \\ & \prod_{k=1}^t \prod_{j \in \mathbb{C}_i^{(k)}} p(\mathbf{r}_{ij}^{(k)} | \mathbf{s}_i^{(k)}, \mathbf{s}_j^{(k)}) \prod_{k=1}^t \prod_{j \in \mathbb{L}_i^{(k)}} p(\mathbf{s}_i^{(k)} | \tilde{\mathbf{z}}_{ij}^{(k)}) \times \\ & \left. \prod_{k=1}^t \prod_{j \in \mathbb{C}_i^{(k)}} p(\mathbf{r}_{ij}^{(k)} | \mathbf{r}_{ij}^{(k-1)}) p(\mathbf{r}_{ij}^{(k)} | \tilde{\mathbf{z}}_{ij}^{(k)}) \right\} \end{aligned} \quad (4)$$

式中: $p(\mathbf{s}_i^{(0)})$ 为 CSL 状态的起始概率分布; $p(\mathbf{s}_i^{(k)} | \mathbf{s}_i^{(k-1)}, \tilde{\mathbf{u}}_i^{(k-1)})$ 为基于里程计量测 $\tilde{\mathbf{u}}_i^{(k-1)}$ 的 CSL 状态条件概率分布; $p(\mathbf{r}_{ij}^{(k)} | \mathbf{s}_i^{(k)}, \mathbf{s}_j^{(k)})$ 为 CSL 状态和 CRL 状态之间的条件概率关系; $p(\mathbf{s}_i^{(k)} | \tilde{\mathbf{z}}_{ij}^{(k)})$ 为基于相对量测 $\tilde{\mathbf{z}}_{ij}^{(k)}$ 的 CSL 状态条件概率分布,代表载体 i 对地标 j 的相对量测过程; $p(\mathbf{r}_{ij}^{(k)} | \tilde{\mathbf{z}}_{ij}^{(k)})$ 为基于相对量测的 $\tilde{\mathbf{z}}_{ij}^{(k)}$ 的相对量测过程; $p(\mathbf{r}_{ij}^{(k)} | \mathbf{r}_{ij}^{(k-1)})$ 为 CRL 状态基于其前一时刻状态的条件概率分布,代表了相对运动状态的约束关系。

基于上述概率分解,即可构建图模型如图 2 所示,分为 CSL 与 CRL 两部分。该模型由变量节点(variable node, VN)、功能节点(function node, FN)和边(Edge)组成,其中 VN 表示载体的 CSL 或 CRL 状态, FN 表示里程计量测和相对量测,连接节点的边则表示相应两两节点之间的概率分布关系。

图 2 载体 i 的协同自定位与相对定位图模型Fig. 2 CSL & CRL graph model for vehicle i

3 基于 GaBP 的消息传递

针对图 2 图模型实现消息传递(message passing, MP)。消息传递是一种基于图模型的概率推理流程,用

于推理图模型中任意状态量的边缘概率分布,是置信传播(belief propagation, BP)算法的基础。因此,BP 可用于求解式(4)中关于 CSL、CRL 状态的边缘概率分布,从而实现协同定位。本文采用的 GaBP 是 BP 的变种算法之一^[12-13],采用高斯分布描述 BP 的消息传递过程,具备算法稳定性好、计算量低、算法实现简便的优势。

在 GaBP 中,高斯分布均采用其信息形式,由信息向量 $\boldsymbol{\eta}$ 和信息矩阵 $\mathbf{A}$ 表示:

$$\begin{cases} \mathcal{N}(\boldsymbol{\mu}, \Sigma) \propto \mathcal{N}^{-1}(\boldsymbol{\eta}, \mathbf{A}) \\ \mathbf{A} = \Sigma^{-1}; \boldsymbol{\eta} = \mathbf{A}\boldsymbol{\mu} \end{cases} \quad (5)$$

式中: $\boldsymbol{\mu}$ 和 Σ 分别为高斯分布的均值和协方差矩阵。在高斯信息形式下,高斯分布之间的乘积等价于信息向量和信息矩阵的相加,简化了 BP 计算的复杂度。基于式(5)可知, GaBP 消息传递过程中所有的消息 m 均采用高斯信息形式:

$$m \triangleq \{\boldsymbol{\eta}, \mathbf{A}\} \quad (6)$$

消息传递过程主要由消息广播和消息接收两步组成。1) 消息广播步骤中,图模型中所有的 VN 将经由边发送消息给其相连接的所有 FN,用于表征其节点自身的概率分布, FN 将储存所有来自 VN 的消息;2) 消息接收步骤中,所有的 VN 将经由边接收其相连接所有 FN 储存的消息,并更新本地置信度。迭代计算上述步骤即可获得图模型的收敛,从而基于最小均方误差(minimum mean square error, MMSE) 准则或最大后验(maximum a posteriori, MAP) 准则求解变量节点对应的状态量。“消息”通常表示为边缘概率分布,基于其流向节点的被估状态量,在 GaBP 中通过高斯分布的信息向量和信息矩阵表示^[13]。

CSL 状态 $\text{VNs}_i^{(t)}$ 的消息广播与消息接收为例说明 GaBP 实现流程如下。

3.1 消息广播

关于 $\text{VNs}_i^{(t)}$ 的简化图模型如图 3 所示,其中任意 FN 为 $\mathcal{F}$, $m_{s_i^{(t)} \rightarrow \mathcal{F}}$ 为 $\text{VNs}_i^{(t)}$ 广播至 FN $\mathcal{F}$ 的消息。当 CSL 状态 $\text{VNs}_i^{(t)}$ 要广播消息 $m_{s_i^{(t)} \rightarrow \mathcal{F}}$ 至 FN $\mathcal{F}$ 时, $m_{s_i^{(t)} \rightarrow \mathcal{F}}$ 的信息向量和信息矩阵为:

$$\boldsymbol{\eta}_{s_i^{(t)} \rightarrow \mathcal{F}} = \sum_{\nu \in \mathcal{A}_i^{(t)} \setminus \mathcal{F}} \boldsymbol{\eta}_{\nu \rightarrow s_i^{(t)}} \quad (7)$$

$$\mathbf{A}_{s_i^{(t)} \rightarrow \mathcal{F}} = \sum_{\nu \in \mathcal{A}_i^{(t)} \setminus \mathcal{F}} \mathbf{A}_{\nu \rightarrow s_i^{(t)}} \quad (8)$$

式中: $\mathcal{A}_i^{(t)}$ 代表 $\text{VNs}_i^{(t)}$ 在图模型中所连接的全部 FN 集合, $\mathcal{A}_i^{(t)} \setminus \mathcal{F}$ 代表集合 $\mathcal{A}_i^{(t)}$ 剔除 FN $\mathcal{F}$ 。

3.2 消息接收

当 CSL 状态 $\text{VNs}_i^{(t)}$ 要接收任意 FN $\mathcal{F} \in \mathcal{A}_i^{(t)}$ 的消息 $m_{\mathcal{F} \rightarrow s_i^{(t)}}$ 时(图 4),该消息需要转换为 $\text{VNs}_i^{(t)}$ 的函数,且 FN $\mathcal{F}$ 需要将其自身概率分布与储存的消息相乘(在高




图3 消息广播简化示意图

Fig. 3 Simplified diagram of message passing

斯信息形式中表现为相加)。因此,消息接收可分解为两步:1) 将 FN 转化为相应 VN 的函数;2) 需要将 FN 的概率分布与其储存的消息相乘,并针对相应 VN 进行边缘化处理。




图4 消息接收简化示意图

Fig. 4 Simplified diagram of message receiving

由 FN 对相应 VN 的线性化处理实现^[12]过程以 CSL 状态 $\text{VNs}_i^{(t)}$ 接收来自 FN $\mathcal{F}$ 的消息 $m_{\mathcal{F} \rightarrow s_i^{(t)}}$ 为例, FN $\mathcal{F}$ 关于 $s_i^{(t)}$ 的信息向量与信息矩阵为:

$$\boldsymbol{\eta}_{\mathcal{F} | s_i^{(t)}} = \mathbf{J}^T \boldsymbol{\Sigma}_z^{-1} [\mathbf{J} \tilde{\mathbf{s}}_i^{(t)} + \tilde{\mathbf{z}}_i^{(t)} - h(\tilde{\mathbf{s}}_i^{(t)})] \quad (9)$$

$$\mathbf{A}_{\mathcal{F} | s_i^{(t)}} = \mathbf{J}^T \boldsymbol{\Sigma}_z^{-1} \mathbf{J} \quad (10)$$

式中: $\mathbf{J}$ 为量测 $\tilde{\mathbf{z}}_i^{(t)}$ 关于 $s_i^{(t)}$ 的雅各比矩阵; $\boldsymbol{\Sigma}_z$ 为量测协方差; $\tilde{\mathbf{s}}_i^{(t)}$ 为 $s_i^{(t)}$ 的初始估值; $h(\cdot)$ 代表量测 $\tilde{\mathbf{z}}_i^{(t)}$ 的模型。此处 $\tilde{\mathbf{z}}_i^{(t)}$ 即对应图 2 的里程计量测、相对量测、相对运动约束和邻机 CSL 值。

将 FN $\mathcal{F}$ 与其储存的消息相乘并边缘化处理过程在 GaBP 中以信息形式相加与舒尔补^[12]实现,则 $m_{\mathcal{F} \rightarrow s_i^{(t)}}$ 的信息形式为:

$$\boldsymbol{\eta}_{\mathcal{F} \rightarrow s_i^{(t)}} = \boldsymbol{\eta}_{\mathcal{F} | s_i^{(t)}} - \mathbf{A}_{\mathcal{F} | s_i^{(t)}, X} \times (\mathbf{A}_{\mathcal{F} | X} + \mathbf{A}_{X \rightarrow \mathcal{F}})^{-1} \times (\boldsymbol{\eta}_{\mathcal{F} | X} + \boldsymbol{\eta}_{X \rightarrow \mathcal{F}}) \quad (11)$$

$$\mathbf{A}_{\mathcal{F} \rightarrow s_i^{(t)}} = \mathbf{A}_{\mathcal{F} | s_i^{(t)}} - \mathbf{A}_{\mathcal{F} | s_i^{(t)}, X} \times (\mathbf{A}_{\mathcal{F} | X} + \mathbf{A}_{X \rightarrow \mathcal{F}})^{-1} \times \mathbf{A}_{\mathcal{F} | X, s_i^{(t)}} \quad (12)$$

式中: $\mathbf{X} \in \mathbb{F} \setminus \mathbf{s}_i^{(t)}$, $\mathbb{F}$ 是与 FN $\mathcal{F}$ 相连的所有 VN 集合, $\mathbb{F} \setminus \mathbf{s}_i^{(t)}$ 代表集合 $\mathbb{F}$ 剔除 $\text{VNs}_i^{(t)}$; 信息向量 $\boldsymbol{\eta}_{\mathcal{F}|_{\mathbf{x}}}$ 、信息矩阵 $\mathbf{A}_{\mathcal{F}|_{\mathbf{s}_i^{(t)}, \mathbf{x}}}$ 、 $\mathbf{A}_{\mathcal{F}|_{\mathbf{x}}}$ 、 $\mathbf{A}_{\mathcal{F}|_{\mathbf{x}, \mathbf{s}_i^{(t)}}}$ 由式(9)、(10) 得到; 信息向量 $\boldsymbol{\eta}_{\mathbf{x} \rightarrow \mathcal{F}}$ 、信息矩阵 $\mathbf{A}_{\mathbf{x} \rightarrow \mathcal{F}}$ 由式(7)、(8) 得到。

3.3 VN 置信度更新

当消息传递达到收敛后,图模型中任意 VN 的置信度将达到收敛。在 GaBP 中置信度同样以高斯信息形式表示,以 CSL 状态 $\text{VNs}_i^{(t)}$ 为例,其置信度为:

$$\boldsymbol{\eta}_{\mathbf{s}_i^{(t)}} = \sum_{\nu \in \mathbf{A}_i^{(t)}} \boldsymbol{\eta}_{\nu \rightarrow \mathbf{s}_i^{(t)}} \quad (13)$$

$$\mathbf{A}_{\mathbf{s}_i^{(t)}} = \sum_{\nu \in \mathbf{A}_i^{(t)}} \mathbf{A}_{\nu \rightarrow \mathbf{s}_i^{(t)}} \quad (14)$$

基于式(5) 即可得 $\mathbf{s}_i^{(t)}$ 的均值与协方差,完成图 2 的 CSL 状态协同解算。CRL 状态的解算方式形如式(6)~(13),此处不再赘述。

4 变量节点与函数节点构建

协同定位图模型(图 2)由 CSL/CRL 状态的 VN 和各类量测/约束的 FN 构成,基于式(4) 构建 RC-SSRL 中的 VN 与 FN。

4.1 VN 构建

以载体 i 在 t 时刻的 CSL 状态量 $\mathbf{s}_i^{(t)}$ 为例, $\text{VNs}_i^{(t)}$ 的表示方式与式(6) 中消息传递的信息形式相同:

$$\mathbf{s}_i^{(t)} \triangleq \{\boldsymbol{\eta}_{\mathbf{s}_i^{(t)}}, \mathbf{A}_{\mathbf{s}_i^{(t)}}\} \quad (15)$$

类似的,载体 i, j 之间的 CRL 状态量 $\mathbf{r}_{ij}^{(t)}$ 对应的 VN 表示为:

$$\mathbf{r}_{ij}^{(t)} \triangleq \{\boldsymbol{\eta}_{\mathbf{r}_{ij}^{(t)}}, \mathbf{A}_{\mathbf{r}_{ij}^{(t)}}\} \quad (16)$$

该 VN 表示方法符合式(5) 的高斯信息形式,与传统的均值/方差形式等价。

4.2 FN 构建

FN 是连接 VN 的纽带,代表了不同 VN 基于相应 FN 的条件概率关系,因此可以用于描述式(4) 中的协同定位条件概率分布。FN 基于相应的量测信息、量测协方差、VN 状态量组成,由式(9)、(10) 得到,针对式(4) 分解出的各项构建 FN 过程如下。

本文采用图优化中因子^[9]的数学表达式来表示 FN,其合理性在于图优化与 GaBP 均基于高斯假设。

1) CSL 状态起始 FN

该 FN 基于概率 $p(\mathbf{s}_i^{(0)})$, 用于表征载体 i 在 0 时刻的 CSL 状态:

$$\mathcal{F}_I \propto \exp\left(-\frac{1}{2} \|\tilde{\mathbf{s}}_i^{(0)} - \mathbf{s}_i^{(0)}\|_{\boldsymbol{\Omega}_0}^2\right) \quad (17)$$

式中: $\tilde{\mathbf{s}}_i^{(0)}$ 为量测,代表载体起始 CSL 状态的初始化值;

$\boldsymbol{\Omega}_0$ 为相应的协方差。

2) 里程计 FN

该 FN 基于概率 $p(\mathbf{s}_i^{(t)} | \mathbf{s}_i^{(t-1)}, \tilde{\mathbf{u}}_i^{(t-1)})$, 用于表征 CSL 状态量 $\mathbf{s}_i^{(t)}$ 、 $\mathbf{s}_i^{(t-1)}$ 基于里程计量测 $\tilde{\mathbf{u}}_i^{(t-1)}$ 的概率关系:

$$\mathcal{F}_O \propto \exp\left(-\frac{1}{2} \|h_o(\mathbf{s}_i^{(t)}, \mathbf{s}_i^{(t-1)}) - \tilde{\mathbf{u}}_i^{(t-1)}\|_{\boldsymbol{\Omega}_o}^2\right) \quad (18)$$

式中: h_o 为式(1) 中的里程计观测模型; $\boldsymbol{\Omega}_o$ 为里程计观测的协方差矩阵。

3) 邻机自定位 FN

该 FN 基于概率 $p(\mathbf{r}_{ij}^{(k)} | \mathbf{s}_i^{(k)}, \mathbf{s}_j^{(k)})$, 用于表征 CSL、CRL 状态之间的概率关系,此处邻机 $j \in \mathcal{C}_i^{(t)}$ 的 CSL 状态 $\mathbf{s}_j^{(k)}$ 为量测:

$$\mathcal{F}_N \propto \exp\left(-\frac{1}{2} \|h_N(\mathbf{s}_i^{(t)}, \mathbf{r}_{ij}^{(t)}) - \mathbf{s}_j^{(t)}\|_{\boldsymbol{\Omega}_N}^2\right) \quad (19)$$

式中: h_N 为式(2) 中相对量测模型的变形,将其转换为 $\mathbf{s}_j^{(t)} = h_N(\mathbf{s}_i^{(t)}, \mathbf{r}_{ij}^{(t)})$ 的形式; $\boldsymbol{\Omega}_N$ 为邻机 j 的 CSL 状态协方差矩阵。

4) 载体-地标相对量测 FN

该 FN 基于概率 $p(\mathbf{s}_i^{(t)} | \tilde{\mathbf{z}}_{ij}^{(t)})$, 代表载体获得地标相对测距、测角量测值:

$$\mathcal{F}_L \propto \exp\left(-\frac{1}{2} \|h_L(\mathbf{s}_i^{(t)}) - \tilde{\mathbf{z}}_{ij}^{(t)}\|_{\boldsymbol{\Omega}_L}^2\right) \quad (20)$$

式中: h_L 为式(2) 中的相对量测模型; $\boldsymbol{\Omega}_L$ 为测距、测角量测的协方差矩阵。

5) 载体-载体相对量测 FN

该 FN 基于概率 $p(\mathbf{r}_{ij}^{(t)} | \tilde{\mathbf{z}}_{ij}^{(t)})$, 代表相对量测与 CRL 状态之间的概率关系,由于本文所采用模型中相对量测 $\tilde{\mathbf{z}}_{ij}^{(t)}$ 可以直接提供 CRL 状态观测(基于式(2) 可知, $\tilde{\mathbf{z}}_{ij}^{(t)} = \mathbf{r}_{ij}^{(t)} + n$), 因此相应 FN 为:

$$\mathcal{F}_R \propto \exp\left(-\frac{1}{2} \|\mathbf{r}_{ij}^{(t)} - \tilde{\mathbf{z}}_{ij}^{(t)}\|_{\boldsymbol{\Omega}_R}^2\right) \quad (21)$$

式中: $\boldsymbol{\Omega}_R = \boldsymbol{\Omega}_L$, 为相对测距、测角量测协方差矩阵。

6) 相对运动约束 FN

该 FN 基于概率 $p(\mathbf{r}_{ij}^{(k)} | \mathbf{r}_{ij}^{(k-1)})$, 用于表征前后时刻 CRL 状态之间的相对运动约束关系,本文采用了载体最大相对移动速度和载体旋转速度为约束:

$$\mathcal{F}_C \propto \exp\left(-\frac{1}{2} \|\mathbf{r}_{ij}^{(t)} - \mathbf{r}_{ij}^{(t-1)}\|_{\boldsymbol{\Omega}_{\text{VMAX}}}^2\right) \quad (22)$$

式中: $\boldsymbol{\Omega}_{\text{VMAX}}$ 为约束协方差矩阵,由载体最大移速和旋转速度设定,表明 CRL 状态 $\mathbf{r}_{ij}^{(t)}$ 在 t 时刻的分布被一个均值为 $\mathbf{r}_{ij}^{(t-1)}$ 协方差为 $\boldsymbol{\Omega}_{\text{VMAX}}$ 的高斯分布包络涵盖在内。

5 基于 Huber 因子的鲁棒函数节点设计

实际协同定位过程中传感器量测误差可能偏离假设的高斯分布,因此需要采取容错处理手段以保障估计器

的鲁棒性。Huber M 估计是一种广泛应用于 KF 的鲁棒估计技术^[14],能够动态调整量测的权重以保障估计过程的鲁棒性。本文基于 GaBP 的消息传递特性,设计了基于 Huber 因子的鲁棒 FN,通过降低故障量测的权重以保障系统的稳定性。

定义一个 FN $\mathcal{F}$ 的量测为 $\mathbf{z}$, 与 VN 状态 $\mathbf{X}$ 的量测关系为 $\mathbf{z} = h(\mathbf{X})$, 量测协方差矩阵为 $\mathbf{\Omega}$, 则该 FN 的最小二乘约束度 $M_{\mathcal{F}}$ 为:

$$M_{\mathcal{F}} = \sqrt{\|\mathbf{z} - h(\mathbf{X})\|_{\mathbf{\Omega}}^2} \quad (23)$$

式中: $M_{\mathcal{F}}$ 是一种典型的马氏距离^[15], 可用于表示量测 $\mathbf{z}$ 与系统估计量测 $h(\mathbf{X})$ 的偏离程度。将其用于 Huber 损失函数^[14], 可定义如下基于最小二乘约束度 $M_{\mathcal{F}}$ 的 Huber 损失函数:

$$\mathcal{F} \propto \begin{cases} K \exp\left(-\frac{1}{2}M_{\mathcal{F}}^2\right), & M_{\mathcal{F}} < N_{\mathcal{F}} \\ K \exp\left(\frac{1}{2}N_{\mathcal{F}}^2 - N_{\mathcal{F}}M_{\mathcal{F}}\right), & M_{\mathcal{F}} \geq N_{\mathcal{F}} \end{cases} \quad (24)$$

式中: $N_{\mathcal{F}}$ 为相应的检测阈值。式(24)中, 检测阈值通常用于切换 Huber M 估计的工作状态。当 $M_{\mathcal{F}} < N_{\mathcal{F}}$ 时, 可认为相应最小二乘的残差服从预设分布; $M_{\mathcal{F}} \geq N_{\mathcal{F}}$ 时, 则认为相应的残差偏离了预设分布。在量测噪声服从高斯分布的预设条件下, 偏离预设分布的故障量测将导致实际噪声呈现长尾分布, 此时将 Huber 损失函数的 $N_{\mathcal{F}}$ 定义为 1.345 可获得 95% 的渐进相对效率, 达到估计精度与鲁棒性的平衡。 $N_{\mathcal{F}}$ 值将根据所采用的损失函数不同、噪声假设不同发生变化, 具体原理请参考文献[16]。由于本文量测噪声采用高斯分布假设, 并采用 Huber 损失函数, 因此将 $N_{\mathcal{F}}$ 定义为 1.345^[14]。

若正常情况下载感器量测噪声以高斯分布表示, 则基于高斯分布假设的估计器可实现较好的估计效果。一旦出现故障量测, 相应的长尾非高斯分布将导致估计器工作在显著的有偏状态。为消除长尾非高斯分布带来的影响, 可采用一个协方差更大的新高斯分布来^[17] 涵盖故障量测导致的长尾分布。将该原理应用于 Huber 损失函数(式(24)), 则是要令新分布等价于 Huber 损失函数线性区域的分布, 即:

$$-\frac{1}{2}M_{\mathcal{F}}^2 = \frac{1}{2}N_{\mathcal{F}}^2 - N_{\mathcal{F}}M_{\mathcal{F}} \quad (25)$$

式中: $M_{\mathcal{F}}^*$ 为新分布的约束度。则新分布与旧分布的比值为:

$$K_{\mathcal{F}} = \frac{M_{\mathcal{F}}^2}{M_{\mathcal{F}}^2} = \frac{2N_{\mathcal{F}}M_{\mathcal{F}} - N_{\mathcal{F}}^2}{M_{\mathcal{F}}^2} \quad (26)$$

本文将该比值定义为 Huber 因子, 代表了消息传递过程中故障量测 FN 应当削弱的比值。

若 $M_{\mathcal{F}} < N_{\mathcal{F}}$, 则说明当前 FN 的分布处于式(23)的高斯区域, 相应的消息传递可基于式(6)~(13)得到; 若

$M_{\mathcal{F}} \geq N_{\mathcal{F}}$ 则说明当前 FN 的分布偏离了预设高斯分布, 处于式(23)的线性区域, 因此需要削弱该 FN 在消息传递过程中的权重。以式(9)、(10)为例, FN 对应的信息向量与信息矩阵需要乘以 Huber 因子以削弱权重:

$$\begin{cases} \boldsymbol{\eta}_{\mathcal{F}|s_i^{(t)}}^* = K_{\mathcal{F}} \boldsymbol{\eta}_{\mathcal{F}|s_i^{(t)}} \\ \mathbf{A}_{\mathcal{F}|s_i^{(t)}}^* = K_{\mathcal{F}} \mathbf{A}_{\mathcal{F}|s_i^{(t)}} \end{cases} \quad (27)$$

新生成的信息向量 $\boldsymbol{\eta}_{\mathcal{F}|s_i^{(t)}}^*$ 和信息矩阵 $\mathbf{A}_{\mathcal{F}|s_i^{(t)}}^*$ 将替代原始值参与计算, 从而实现故障量测在消息传递过程中的降权。

6 仿真结果及分析

采用仿真数据对本文所提出的 RC-SSRL 进行验证。仿真环境由 5 台可移动的机器人和 30 个已知位置的地标组成, 相应的仿真环境与机器人轨迹如图 5 所示。基于本文的轮式里程计模型(模型 1)和视觉量测模型(模型 2), 所有机器人均可测量相对于地标和其他相邻机器人的量测信息。为验证算法在不同动态环境下的效果, 机器人的移动速度由正弦函数控制而呈现周期变化, 最大移速为 15 m/s, 速度变化周期为 20 s。为验证本文所提出鲁棒函数节点具体的有效性, 仿真中随机添加了测距、测角故障。具体仿真参数配置如表 1 所示。




图5 协同定位仿真场景

Fig. 5 Simulated cooperative localization scenario

表1 协同定位仿真场景配置参数

Table 1 Configurations of the simulated cooperative localization scenario

配置参数项	参数值
里程计前向速度/旋转角速度标准差	0.1 m/s、3°/s
视觉测距/测角标准差	0.2 m、2°
视觉感知范围/角度	200 m、±60°
随机故障最大值(测距/测角)	1.5 m、5°
随机故障总时长	30 s(随机添加至量测)
机器人最大移速/变化周期	15 m/s、20 s
轨迹时长	600 s

由于 RC-SSRL 可以同步估计机器人的 CSL 与 CRL 状态,而传统方法想要实现 CSL 或 CRL 需要分别运行多个估计器,因此实验结果将分别从机器人的 CSL 性能和 CRL 性能两方面入手,分析对比 RC-SSRL 与传统方法的性能差异。

6.1 CSL 仿真性能对比

对比 RC-SSRL 与其他传统方法在仿真中的 CSL 性能,为保障对比公平,非本文所提出的算法均采用 Huber 技术进行鲁棒处理,所采用的对照组如下。

1) CP-EKF-Huber,以 EKF 为基础框架的协同定位算法^[18],并采用 Huber M 估计实现鲁棒估计^[19],其系统方程基于里程计模型(式(1)),观测方程基于测距、测角量测(式(2)),融合来自地标和相邻机器人的测距和测角观测进行协同自定位解算。

2) GaBP-Huber,基于 GaBP 采用传统图模型的协同定位算法,并采用本文所提出的 Huber 因子进行容错处理,GaBP 图模型中仅对 CSL 状态进行建模^[12],无 CRL 状态、相对运动约束 FN,载体间量测 FN 建模与载体-地标量测 FN(式(19))相同。

3) SSRL,本文所提出的协同自定位与相对定位方法,去除了第 5 节所提出的 Huber 因子,此处提取其 CSL 估计结果进行对比。

4) RC-SSRL,本文所提出协同自定位与相对定位方法,并采用 Huber 因子进行鲁棒估计,此处提取其 CSL 估计结果进行对比。

所采用的评价指标为位置误差与航向误差,位置误差定义为 $Err_s = \sqrt{Err_x^2 + Err_y^2}$,其中 Err_x 、 Err_y 分别为机器人在世界系 X 、 Y 方向的误差。

图 6 和 7 所示为以集群中一台示例机器人为例,对比了多种算法在仿真环境下的 CSL 性能,性能指标为 CSL 位置误差和 CSL 航向角误差,以及相应的均方根误差 (root-mean-square-error, RMSE) 曲线。所提出的 RC-SSRL 在位置和航向角方面的估计精度均优于其他方法,以航向角的最终 RMSE 为例,RC-SSRL 的值为 0.86° ,优于 CP-EKF-Huber 的 1.11° 、GaBP-Huber 的 1.08° 、SSRL 的 0.91° 。结果表明,基于协同自定位与相对定位过程建模的图模型能够有效对协同估计过程进行描述,相应的估计框架在精度方面具备一定优势。此外,由于 Huber 因子的存在,RC-SSRL 的精度高于采样同样图模型的 SSRL,以位置误差的最终 RMSE 为例,RC-SSRL 为 0.32 m ,优于 SSRL 的 0.39 m ,证明了 Huber 因子的鲁棒处理有效性。

6.2 CRL 仿真性能对比

对比 RC-SSRL 与其他传统方法在仿真条件下的 CRL 性能,所采用的对照组如下。




图 6 CSL 位置误差及其均方根误差对比

Fig. 6 Positioning errors & positioning RMSE comparisons of CSL




图 7 CSL 航向角度误差及其均方根误差对比

Fig. 7 Heading angle errors & angle RMSE comparisons of CSL

1) 原始量测,机器人得到的测距与测角量测值。

2) VIS/ODO,采用 EKF 为算法框架融合里程计、视觉测距、视觉测角,并采用 Huber 技术保障估计鲁棒性,系统方程基于常加速度模型,观测方程基于测距、测角和 CP-EKF-Huber 估计结果^[9]。

3) RC-SSRL,本文所提出协同自定位与相对定位方法,并采用 Huber 因子进行鲁棒估计,此处提取其 CRL 估计结果进行对比。

由于 UTIAS 数据集中机器人随机移动,导致它们无法长期出现在彼此的相机视场角内,因此不同机器人之间的相对定位过程通常随时间断续。为对比不同对照组的性能,收集了所有机器人在所有时刻的相对定位数据进行误差累计分布 (cumulative distribution function, CDF) 曲线对比,可从整体上对比不同方法的性能。

图 8 和 9 所示为 3 组方法的 CRL 性能,性能指标为 CRL 相对距离、相对角度的 CDF 分布曲线,相应曲线越

陡峭、越靠近0(误差值),则说明误差分布越靠近0、性能越好。所提出的 RC-SSRL 在相对距离和相对角度方面均具备最佳性能。CRL 相对角度误差(图9)的所有对照组相对角度误差低于 2° 的比例分别为原始量测(70.33%)、VIS/ODO(77.62%)、SSRL(82.31%)。由于将历史量测、定位状态考虑在内,RC-SSRL 融合框架相比于传统 KF 架构的 VIS/ODO 具备更好的估计性能。此外,图模型(图2)中的里程计 FN 也间接起到了机器人相对运动的建模效果,从而进一步提升了 CRL 性能。结果表明,所提出的融合框架不仅能够同步输出 CRL 估计结果,且在估计精度上优于传统基于 KF 框架。





图10 UTIAS 协同定位与构图数据集

Fig. 10 Cooperative localization and mapping dataset of UTIAS


7.1 CSL 实验性能对比

对比 RC-SSRL 与其他传统方法的 CSL 性能,所采用的对照组与仿真数据一致(6.1节)。

图11和12所示分别对比了协同机器人集群中一架示例机器人在不同算法条件下的 CSL 位置误差和 CSL 航向角误差,并对比了相应 RMSE 曲线,所提出的 RC-SSRL 具备最佳的 CSL 性能。位置误差(图11)中,RC-SSRL 的最终 RMSE 为 0.13 m,优于 CP-EKF-Huber 的 0.28 m、GaBP-Huber 的 0.17 m、SSRL 的 0.2 m。由于 RC-SSRL 在图模型中充分考虑了 CSL 状态和 CRL 状态之间的关系,并且采用 Huber 因子实现异常量测的鲁棒处理,其估计精度和稳定性显著优于其他控制组,证明了本文协同估计框架在算法精度方面的优势。对于未采用 Huber 因子的 SSRL,由于缺乏针对异常量测噪声的鲁棒处理手段,其位置误差存在明显的跳变现象(图11中 210 s 附近),证明了 Huber 因子对于消息传递类算法的鲁棒处理有效性。



(a) 位置误差
(a) Position errors



(b) 位置均方根误差
(b) Position RMSE

图11 CSL 位置误差及其均方根误差对比

Fig. 11 Positioning errors & positioning RMSE comparisons of CSL




图8 CRL 相对距离误差累计分布曲线对比

Fig. 8 CDF comparison for relative distance errors of CRL




图9 CRL 相对角度误差累计分布曲线对比

Fig. 9 CDF comparison for relative angle errors of CRL

7 实验结果及分析

为进一步验证算法性能,基于多伦多航空航天研究所(UTIAS)的开源实验数据集对所提出的 RC-SSRL 进行验证,如图10所示。该数据集为二维多机器人集群协同定位与构图数据集^[20],基于实际协同定位实验采集而成,包含5台机器人和15个已知位置的地标,每台机器人均搭载轮式里程计和视觉相机以获得量测信息。

轮式里程计可以获得机器人运动量测(式(1)),输出前向速度量测和机体旋转角度速度量测;视觉相机可以获得本机相对于其他机器人、地标的测距量测和测角量测(式(2))。




图 12 CSL 航向角度误差及其均方根误差对比
Fig. 12 Heading angle errors & angle RMSE comparisons of CSL

为充分分析不同算法在协同定位中的总体性能,图 13 和 14 所示为所有机器人的 CSL 位置误差和 CSL 航向角误差进行 CDF 分布曲线对比。图 13、14 表明,RC-SSRL 的 CDF 曲线分布最为陡峭,可见其在 CSL 方面具备最佳性能。对于传统基于 CSL 图模型的 GaBP-Huber,尽管该算法无法利用 CSL 和 CRL 状态之间的约束关系以提升估计,在采用本文所提出的 Huber 因子后仍然可获得与 SSRL 同级别的性能。传统的 CP-EKF-Huber 受制于 KF 架构的一阶马尔可夫过程限制,无法充分利用 CSL 状态、CRL 状态和量测之间的约束关系,因此其性能低于所有其他对照组。航向角度误差的 CDF 曲线(图 14)的所有对照组航向角度误差低于 1° 的百分比分别为 18.67% (CP-EKF-Huber)、26.68% (GaBP-Huber)、26.65% (SSRL)、30.82% (RC-SSRL)。




图 13 CSL 位置误差累计分布曲线对比
Fig. 13 CDF comparison for positioning errors of CSL

7.2 协同相对定位 (CRL) 实验性能对比

对比 RC-SSRL 与其他传统方法的 CRL 性能,所采用的对照组与仿真数据(6.2 节)一致。




图 14 CSL 航向角度误差累计分布曲线对比
Fig. 14 CDF comparison for heading angle errors of CSL

图 15 和 16 所示分别对比了 CRL 相对距离误差和 CRL 相对角度误差,所提出的 RC-SSRL 比其他对照组具备最佳性能。CRL 相对距离误差(图 15)的所有对照组相对距离误差低于 0.05 m 的百分比分别为 15.87% (原始观测)、28.86% (VIS/ODO)、33.53% (RC-SSRL)。由于 RC-SSRL 在图模型中对机器人里程计运动模型进行了建模,因此相比于传统的 VIS/ODO 可以更为准确的描述机器人间的相对运动状态,此外相对运动约束 FN 也提供了进一步约束了 CRL 状态的概率空间,从而提升了 CRL 估计精度。传统基于 KF 框架的 VIS/ODO 在 CRL 性能方面虽然优于原始量测值,但是其精度低于 RC-SSRL。结果表明,基于 KF 框架的 CRL 方法虽然能够有效融合里程计和视觉量测,但是其信息融合精度低于 RC-SSRL 框架。




图 15 CRL 相对距离误差累计分布曲线对比
Fig. 15 CDF comparison for relative distance errors of CRL

7.3 计算效能对比

为分析 RC-SSRL 的计算负载程度,对比了 CP-EKF、GaBP-Huber 与 RC-SSRL 在 UTIAS 数据集上的计算效能,结果如图 17 所示。由于 CP-EKF 和 GaBP-Huber 仅支持 CSL 状态估计,因此采用 CSL 位置误差作为对比对象,对应每历元数据计算时间由 MATLAB 的 tic、toc 函数记录。计算效能对比了估计误差于相应的数据处理时




图 16 CRL 相对角度误差累计分布曲线对比
Fig. 16 CDF comparison for relative angle errors of CRL

间,可全面描述算法在集群定位环境中是否具备较好的“性价比”。高效能算法应当在较低的计算处理时延条件下获得较低的估计误差。由于 SSRL 与 RC-SSRL 的区别在于鲁棒因子计算,两者计算负载基本一致,因此图 17 并不包含 SSRL 的结果。




图 17 计算效能对比(CSL 位置误差 vs. 每历元处理时间)
Fig. 17 Efficiency comparison (CSL positioning error vs. processing time per epoch)

由于 RC-SSRL 图模型在建模时同步考虑了 CSL 和 CRL 状态,其图模型相较于传统 CSL 方法稍大,因此将引入一定的计算负载。如图 17 所示,所提出 RC-SSRL (平均 0.048 s)的计算负载略高于仅对 CSL 状态建模的 GaBP-Huber 算法(平均 0.043 s)。对于传统 CP-EKF,该方法基于一阶马尔可夫过程假设,无需考虑多历元数据,因此具备最佳的实时性(平均 0.002 s)。然而 CP-EKF 的 CSL 精度低于所提出 RC-SSRL,其平均位置误差为 0.23 m,显著高于 RC-SSRL 的 0.12 m。可见,本文所提出 RC-SSRL 在可接受的计算负载条件下获得了最佳估计性能,达成了实时性与性能的平衡。

仿真结果与实验结果表明,本文所提出的 RC-SSRL 不仅可以同时进行协作集群的 CSL 和 CRL 估计,其估计精度和效能也优于传统的协同定位方法,为集群定位提供了一种全新的通用融合架构思路。

8 结 论

为克服传统协同定位方法将自定位与相对定位剥离开的缺陷,本文提出了一种 RC-SSRL 方法,能够同步进行集群中各个载体的 CSL 状态与 CRL 状态估计,简化了协同定位系统算法架构,并设计 Huber 因子以实现异常量测的鲁棒处理。实验结果表明,RC-SSRL 充分利用了集群中 CSL 状态与 CRL 状态之间的概率约束关系,其估计精度优于多种传统协同定位方法。RC-SSRL 兼具协作集群的 CSL 和 CRL 估计能力,精度优于传统方法,且系统模型简单易实现,在集群协作集群导航定位方面具有较高的应用潜力。

参考文献

[1] OUYANG X, ZENG F, LYU D, et al. Cooperative navigation of UAVs in GNSS-denied area with colored RSSI measurements [J]. IEEE Sensors Journal, 2020, 21(2):2194-2210.

[2] NOH Y, YAMAGUCHI, LEE U. Infrastructure-free collaborative indoor positioning scheme for time-critical team operations [J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2016, 48(3):418-432.

[3] HUANG Y, ZHANG Y, XU B, et al. A new adaptive extended Kalman filter for cooperative localization [J]. IEEE Transactions on Aerospace and Electronic Systems, 2017, 54(1):353-368.

[4] 陈明星,熊智,刘建业,等. 基于因子图的无人机集群分布式协同导航方法[J]. 中国惯性技术学报, 2020, 28(4):456-461.

CHENG M X, XIONG ZH, LIU J Y, et al. Distributed cooperative navigation for UAV swarm based on the factor graph [J]. Journal of Chinese Inertial of Technology, 2020, 28(4):456-461.

[5] 朱建良,王栋,徐旋孜. 一种基于图优化的行人协同定位方法[J]. 仪器仪表学报, 2023, (6):126-134.

ZHU J L, WANG D, XU X Z. A pedestrian cooperative localization method based on graph optimization [J]. Chinese Journal of Scientific Instrument, 2023, (6):126-134.

[6] WYMEERSCH H, LIEN J, WIN M Z. Cooperative localization in wireless networks [J]. Proceedings of the IEEE, 2009, 97(2):427-450.

[7] XIONG J, XIONG Z, DING Y M, et al. Multi-hypothesis Gaussian belief propagation for radio ranging-based localization and mapping [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71:1-13.

[8] 王小刚. 非线性滤波方法在无人机相对导航上的应用

- 研究[D]. 哈尔滨:哈尔滨工业大学, 2010.
- WANG X G. Nonlinear filtering for UAV relative navigation applications[D]. Harbin: Harbin Institute of Technology, 2010.
- [9] 熊骏,熊智,于永军,等. 超宽带测距辅助的无人机近距离相对导航方法[J]. 中国惯性技术学报, 2018, 26(3):346-351.
- XIONG J, XIONG ZH, YU Y J, et al. Close relative navigation algorithm for unmanned aerial vehicle aided by UWB relative measurement[J]. Journal of Chinese Inertial of Technology, 2018, 26(3):346-351.
- [10] DE PONTE MULLER F. Survey on ranging sensors and cooperative techniques for relative positioning of vehicles[J]. Sensors, 2017, 17(2):271.
- [11] XU H, WANG L, ZHANG Y, et al. Decentralized visual-inertial-UWB fusion for relative state estimation of aerial swarm[C]. 2020 IEEE International Conference on Robotics and Automation (ICRA), 2020: 8776-8782.
- [12] ORTIZ J, EVANS T, DAVISON A J. A visual introduction to gaussian belief propagation[J]. Computer Science, 2021, DOI:10.48550/arXiv.2107.02308.
- [13] DAVISON A J, ORTIZ J. FutureMapping 2: Gaussian belief propagation for spatial AI[J]. Computer Science, 2019, DOI:10.48550/arXiv.1910.14139.
- [14] SUN Q, ZHOU W X, FAN J. Adaptive huber regression[J]. Journal of the American Statistical Association, 2020, 115(529):254-265.
- [15] GHORBANI H. Mahalanobis distance and its application for detecting multivariate outliers[J]. Facta Universitatis, Series: Mathematics and Informatics, 2019, 34(3):583-595.
- [16] BICKEL P J. One-step Huber estimates in the linear model[J]. Journal of the American Statistical Association, 1975, 70(350):428-434.
- [17] AGARWAL P, TIPALDI G D, SPINELLO L, et al. Robust map optimization using dynamic covariance scaling[C]. Proceedings of the IEEE International Conference on Robotics and Automation (ICRA), 2012.
- [18] BAI M, HUANG Y, ZHANG Y, et al. A novel heavy-tailed mixture distribution based robust Kalman filter for cooperative localization[J]. IEEE Transactions on Industrial Informatics, 2020, 17(5):3671-3681.
- [19] 孙伟,刘经洲. 基于 Huber 鲁棒容积裂变粒子滤波的协同导航方法[J]. 仪器仪表学报, 2022, 43(2):167-175.
- SUN W, LIU J ZH. Cooperative navigation method based on the Huber robust cubature fission particle filter[J]. Chinese Journal of Scientific Instrument, 2022, 43(2):167-175.

- [20] LEUNG K Y, HALPERN Y, BARFOOT T D, et al. The UTIAS multi-robot cooperative localization and mapping dataset[J]. The International Journal of Robotics Research, 2011, 30(8):969-974.

作者简介



E-mail:xiongjun@njupt.edu.cn

Xiong Jun (Corresponding author) received his B. Sc. degree from Nanjing University of Posts & Telecommunications in 2013, M. Sc. degree and Ph. D. degree both from Nanjing University of Aeronautics & Astronautics in 2017 and 2021, respectively. He is currently an associate professor at Nanjing University of Posts & Telecommunications. His main research interests include swarm navigation and perception, cooperative multi-sensor fusion, integrated navigation.



Xie Xiangpeng received his Ph. D. degree from the Northeastern University in 2010. He is currently a professor at Institute of Advanced Technology, Nanjing University of Posts & Telecommunications. His main research interests include fuzzy modeling and control synthesis, state estimation, optimization in process industries and intelligent optimization algorithms.



Xiong Zhi received his Ph. D. degree from Nanjing University of Aeronautics & Astronautics in 2004. He is currently a professor at Nanjing University of Aeronautics & Astronautics. His main research interests include inertial navigation and integrated navigation system.



Zhuang Yuan received his Ph. D. degree from the University of Calgary in 2015. He is currently a professor at Wuhan University. His main research interests include multi-sensors integration, real-time location system, Internet of Things localization.

熊骏(通信作者),2013 年于南京邮电大学获得学士学位,2017 年于南京航空航天大学获得硕士学位,2021 年于南京航空航天大学获得博士学位,现为南京邮电大学副教授,主要研究方向为集群导航与感知、协同多源融合、组合导航算法。

解相朋,2010 年于东北大学获得博士学位,现为南京邮电大学先进技术研究院教授,主要研究方向为模糊建模与控制,状态估计,工业过程优化和智能优化算法。

E-mail:xiexp@njupt.edu.cn

熊智,2004 年于南京航空航天大学获得博士学位,现为南京航空航天大学教授,主要研究方向为惯性导航、组合导航系统。

E-mail:jzh0903@csu.edu.cn

庄园,2015 年于卡尔加里大学获得博士学位,现为武汉大学教授,主要研究方向为多传感器融合,实时定位系统,物联网定位等。

E-mail:yuan.zhuang@whu.edu.cn