

一种鲁棒闭环的增量式 Graph SLAM 算法

张国良，姚二亮，岳亚南，孙一杰

(第二炮兵工程大学, 西安 710025)

摘要：针对常规增量式 Graph SLAM 算法的后端优化无法高效排除错误闭环影响的问题, 基于 iSAM 算法和 SC 算法, 提出一种鲁棒闭环的增量式 Graph SLAM 算法 R-iSAM。R-iSAM 在增量式过程中对当前时刻引入的闭环约束的转换变量进行初步近似计算, 得到合理的机器人节点位姿。在离线式过程中对当前时期的所有闭环约束转换变量进行精确计算, 判断当前时期闭环的正确性, 并作为以后优化节点的基础。对公开的数据集进行的算法实验表明, 在添加不同类型、不同数量的错误闭环条件下, 所提算法对不同数据集具有良好适应性, 且收敛速度满足增量式 SLAM 实时性要求, 证明了算法的有效性。

关键词：同步定位与地图构建；图优化；鲁棒闭环；增量式

中图分类号：TP242 文献标志码：A 文章编号：1671-637X(2015)07-0028-06

A Robust Close-Loop Incremental Graph SLAM Algorithm

ZHANG Guo-liang, YAO Er-liang, YUE Ya-nan, SUN Yi-jie

(The Second Artillery Engineering University, Xi'an 710025, China)

Abstract: In view of the problem that the back-end optimaziation for conventional incremental Graph SLAM alrgorithm cannot efficiently remove the influence of false close-loop, R-iSAM, a robust close-loop incremental Graph SLAM algorithm is put forward based on iSAM algorithm and SC algorithm. In the incremental process, R-iSAM makes a preliminary approximate calculation of the close-loop constrained conversion variables introduced at the current time, obtaining reasonable node positions of robot. In the off-line process, it makes a refined calculation of all close-loop constrained conversion variables in the current period, to judge the correctness of current-period close-loop, and lay a foundation for node optimization later on. The algorithm experiment of public data set (DS) show that under the condition of adding different types and numbers of fault close-loops, the proposed algorithm is well adaptive to different DS, and the convergence rate satisfies the real-time requirement of incremental SLAM, proving the validity of this algorithm.

Key words: simultaneous localization and map construction; graph optimization; robust close-loop; incremental

0 引言

在未知环境中, 机器人需要根据自定位与创建的环境地图来执行其他任务。然而不可避免地, 自身位姿感知器(如里程计)和环境感知器(如激光、视觉摄像头)存在一定的误差, 影响机器人环境创建与自定位的结果。定位与建图(Simultaneous Localization and Mapping, SLAM)是指移动机器人在未知环境中运动时

逐步构建环境地图, 同时利用该地图计算机器人位姿的过程。近几年来, 由于其重要的理论和应用价值, 被很多学者认为是实现真正全自主移动机器人的关键。多年来基于滤波的 SLAM 方法得到很大发展, 常用的包括扩展卡尔曼滤波(EKF)方法^[1]、扩展信息滤波(EIF)方法^[2]以及粒子滤波(PF)方法^[3]等。然而, 基于滤波器的方法存在线性化及更新效率等问题, 这使得它难以应用于大规模环境的地图创建^[4]。

文献[5]首先提出基于图优化的 SLAM 方法, 然而受限于计算方法, 无法满足算法实时性要求。随着高效求解方法的出现, Graph SLAM 方法成为当前 SLAM 研究的热点^[6-9], 近年来涌现了优秀的 Graph SLAM 算

法,如 TreeMap^[6],TORO^[7],HOG_MAN^[8]以及 g²o^[9]。然而离线式的 Graph SLAM 算法不能很好地应用于实际系统,为此,文献[10]提出了一种增量式的平滑建图方法 iSAM (Incremental Smoothing and Mapping)。iSAM 在计算非线性优化问题时,对信息矩阵进行 QR 分解,当新的量测信息到来时,算法应用上一步的矩阵信息增量地对信息矩阵进行更新,避免对所有的相关元素重新进行计算,从而提高算法效率;另外,iSAM 仍需要定期地对信息矩阵进行重新线性化计算以及重排序,以减小由于线性化产生的累计误差,并保持信息矩阵的稀疏性,保证算法计算效率。然而,尽管 iSAM 可以有效地处理在线 SLAM 问题,但对于位姿图 SLAM 问题,其往往假设数据关联正确,并未考虑其中的错误闭环给建图和定位带来的负面影响,可能导致算法收敛到错误结果。

虽然一些学者对前端的闭环产生和闭环确认提出了改进方法^[11-13],但仍然会不同程度地出现错误闭环,这些错误闭环使 iSAM 失败。为此,对于离线式 Graph SLAM 算法,文献[14]提出了利用闭环集群内部以及外部的一致性检验来排除错误闭环的 RRR 算法,但耗费时间较长;文献[15]采用一种多模态的高斯模型作为鲁棒的代价函数,为每个闭环添加一个无效假设,在优化过程中判定闭环是否有效,但在大量错误闭环环境下算法召回率较低;文献[16]提出给每个闭环约束添加一个转换变量,控制闭环约束对整个图的影响,通过在优化过程中调整机器人位姿和转换变量,使鲁棒的代价函数最小,这种算法称为 SC(Switchable Constraints)算法,然而此方法不能完全排除错误闭环的影响。

针对以上问题,在 Niko 闭环调整以及 iSAM 算法框架的基础上,本文提出一种能够适应大范围环境并且排除错误闭环影响的增量式 Graph SLAM 算法 R-iSAM。当闭环约束来临时,R-iSAM 在增量式优化过程中动态调整闭环对节点位姿配置的影响,使节点位姿处于合理状态,并在离线式优化过程中最终确定当前时期所有闭环的转换变量,从而精确判定闭环是否存在,排除错误闭环影响。与离线式鲁棒闭环算法每次迭代时计算所有闭环转换变量不同的是,本文提出的算法最多只对一个时期的若干闭环的转换变量进行计算,因而可以保证算法的快速性,满足在线 SLAM 算法的实时性需求。

1 增量式 Graph SLAM 算法

在 Graph SLAM 算法中,机器人位姿作为图 1 中的节点,里程计约束以及闭环约束作为图中的边约束。令 $\mathbf{X} = (\mathbf{x}_1, \dots, \mathbf{x}_n)^T$ 为机器人位姿矩阵, \mathbf{x}_i 为机器人在时刻

i 的位姿, $\mathbf{U} = \{\mathbf{u}_{i,i+1}, \mathbf{u}_{ij}\} = \{\mathbf{u}_{mn}\}$ 为约束边,其中, $\mathbf{u}_{i,i+1}$ 为第 i 个节点到第 $i+1$ 个节点的里程计约束, \mathbf{u}_{ij} 为第 i 个节点到第 j 个节点的闭环约束, 图结构见图 1。

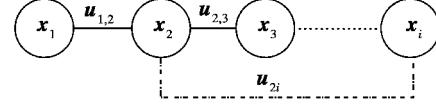


图 1 图结构

Fig. 1 Graph structure

常规 Graph SLAM 算法由前端(front-end)和后端(back-end)组成,前端根据外部传感器输入的原始数据来确定图结构的节点位姿和边约束,后端则根据前端得到的节点和边信息,利用非线性最小二乘等方法对图结构进行优化,得到满足约束的最优节点位姿。

令 γ_{mn} 和 Σ_{mn} 分别为从节点 m 到节点 n 的约束边 \mathbf{u}_{mn} 观测均值向量以及协方差阵。在给定节点状态 \mathbf{x} 和边约束 \mathbf{u}_{mn} 下计算约束边引入的剩余误差 \mathbf{e}_{mn} 为

$$\mathbf{e}_{mn}(\mathbf{x}) = \gamma_{mn} - \mathbf{f}_{mn}(\mathbf{x}_m, \mathbf{x}_n) \quad (1)$$

式中, $\mathbf{f}_{mn}(\mathbf{x})$ 为利用节点位姿得到从节点 m 到节点 n 的转移向量。

所以每个约束的引入误差为

$$d_{mn}(\mathbf{x})^2 = \mathbf{e}_{mn}(\mathbf{x})^T \Sigma_{mn}^{-1} \mathbf{e}_{mn}(\mathbf{x}) \quad (2)$$

假定所有约束是独立的,得到所有边的引入误差为

$$D^2(\mathbf{x}) = \sum d_{mn}(\mathbf{x})^2 = \sum \mathbf{e}_{mn}(\mathbf{x})^T \Sigma_{mn}^{-1} \mathbf{e}_{mn}(\mathbf{x}) \quad (3)$$

对 Graph SLAM 问题描述为

$$\mathbf{X}^* = \operatorname{argmin}_{\mathbf{x}} \sum \mathbf{e}_{mn}(\mathbf{x})^T \Sigma_{mn}^{-1} \mathbf{e}_{mn}(\mathbf{x}) \quad (4)$$

对于式(4),由于 \mathbf{e}_{mn} 为非线性函数,常规的 Graph SLAM 算法通常采用 Gauss-Newton 或 Levenberg-Marquadt 等非线性最小二乘方法,找到使所有约束边引入误差最小的节点 \mathbf{X}^* 的增量,从而得到最终问题的求解,即

$$\hat{\Delta X} \approx \operatorname{argmin}_{\Delta X} \sum_{\mathbf{u}_{mn} \in U} \left\| \mathbf{e}_{mn} - \mathbf{H}_{mn} \Delta X \right\|_{\Sigma_{mn}}^2 = \operatorname{argmin}_{\Delta X} \left\| \mathbf{J} \Delta X - \mathbf{e} \right\|^2 \quad (5)$$

$$\text{式中: } \mathbf{e} = \begin{pmatrix} \Sigma_{12}^{-1/2} \mathbf{e}_{12} \\ \vdots \\ \Sigma_{mn}^{-1/2} \mathbf{e}_{mn} \\ \vdots \end{pmatrix}; \mathbf{J} = \begin{pmatrix} \Sigma_{12}^{-1/2} \mathbf{H}_{12} \\ \vdots \\ \Sigma_{mn}^{-1/2} \mathbf{H}_{mn} \\ \vdots \end{pmatrix}; \mathbf{H} = \frac{\partial f(\mathbf{x}_m, \mathbf{x}_n)}{\partial X} \Big|_{X=\hat{\mathbf{x}}}.$$

在 iSAM 算法中,对式(5)中的 \mathbf{J} 进行 QR 分解,式(5)变换为

$$\begin{aligned} \left\| \mathbf{J} \Delta X - \mathbf{e} \right\|^2 &= \left\| \mathbf{Q} \begin{pmatrix} \mathbf{R} \\ \mathbf{0} \end{pmatrix} \Delta X - \mathbf{e} \right\|^2 = \left\| \begin{pmatrix} \mathbf{R} \\ \mathbf{0} \end{pmatrix} \Delta X - \mathbf{Q}^T \mathbf{e} \right\|^2 = \\ \left\| \begin{pmatrix} \mathbf{R} \\ \mathbf{0} \end{pmatrix} \Delta X - \begin{pmatrix} \mathbf{d} \\ \mathbf{b} \end{pmatrix} \right\|^2 &= \left\| \mathbf{R} \Delta X - \mathbf{d} \right\|^2 + \left\| \mathbf{b} \right\|^2 \end{aligned} \quad (6)$$

式中, $\mathbf{Q}^T \mathbf{e} = (\mathbf{d}, \mathbf{b})^T$ 。

所以式(5)转化为求解 $\Delta \hat{\mathbf{X}}$, 使

$$\mathbf{R} \Delta \hat{\mathbf{X}} = \mathbf{d} \quad (7)$$

对于式(7), iSAM 可以采用非线性最小二乘法得到新的节点配置为

$$\hat{\mathbf{X}} = \mathbf{X} + \Delta \hat{\mathbf{X}} \quad (8)$$

当新的节点约束到来, 通常需要计算所有之前和现在节点的相关 Jacobian 矩阵, 然而这种方法在大环境下算法复杂度高。为节约计算量, iSAM 使用之前的 Jacobian 矩阵信息, 增量地更新 QR 分解。

对 Jacobian 矩阵 \mathbf{J} 进行 QR 分解, 得到

$$\mathbf{J} = \mathbf{Q} \begin{pmatrix} \mathbf{R} \\ \mathbf{0} \end{pmatrix} = (\mathbf{Q}_1 \quad \mathbf{Q}_2) \begin{pmatrix} \mathbf{R} \\ \mathbf{0} \end{pmatrix} = \mathbf{Q}_1 \mathbf{R} \quad (9)$$

用之前的测量 Jacobian 矩阵信息更新得到当前 Jacobian 矩阵 \mathbf{J}_{new} , 即

$$\mathbf{J}_{\text{new}} = \begin{pmatrix} \mathbf{J} \\ \mathbf{W}_{\text{new}}^{-1/2} \mathbf{H}_{\text{new}} \end{pmatrix} = \begin{pmatrix} \mathbf{Q}_1 & \mathbf{0} \\ \mathbf{0} & 1 \end{pmatrix} \begin{pmatrix} \mathbf{R} \\ \mathbf{W}_{\text{new}}^{-1/2} \mathbf{H}_{\text{new}} \end{pmatrix} \quad (10)$$

同时对新的 \mathbf{d} 矩阵 \mathbf{d}_{new} 的更新为

$$\mathbf{d}_{\text{new}} = \begin{pmatrix} \mathbf{d} \\ \mathbf{W}_{\text{new}}^{-1/2} \mathbf{e}_{\text{new}} \end{pmatrix} \quad (11)$$

至此, iSAM 算法通过利用之前的 Jacobian 矩阵计算新节点或约束到来时的新 Jacobian 矩阵, 有效地解决了大范围环境下机器人 SLAM 的计算效率问题。但由于 iSAM 算法对所有闭环约束的信任度相同, 数据关联错误得到的错误闭环对 iSAM 算法会产生毁灭性影响, 导致算法收敛到错误的结果。因此可以看出, iSAM 对不可避免的错误闭环鲁棒性较差, 无法得到满意的 SLAM 结果。

2 鲁棒闭环增量式 Graph SLAM 算法

虽然正确的闭环对机器人位姿节点的优化有相当大的作用, 但错误的闭环也必定会使算法收敛到错误结果, 可见, 里程计约束和闭环约束在图优化中的作用和性质不尽相同, 因此将两种约束分开考虑, 即

$$\begin{aligned} \mathbf{X}^* = \arg \min_{\mathbf{X}} & \left[\underbrace{\sum_i \|f(\mathbf{x}_i, \mathbf{u}_i) - \mathbf{x}_{i+1}\|_{\Theta_i}^2}_{\text{里程计约束}} + \right. \\ & \left. \underbrace{\sum_{ij} \|f(\mathbf{x}_i, \mathbf{u}_{ij}) - \mathbf{x}_j\|_{A_{ij}}^2}_{\text{闭环约束}} \right] \quad (12) \end{aligned}$$

对于闭环约束, SC 算法提出为每个闭环约束添加一个转换变量, 在优化过程中同时优化机器人位姿节点和与闭环约束相关的转换变量 $s_{ij} \in [0, 1]$, 调整错误闭环对节点位姿的影响。另外, 添加附加项 $w \|1 - s_{ij}\|^2$ 以

避免闭环约束误差项被完全消除, 无法利用正确闭环修正机器人位姿

$$\begin{aligned} \mathbf{X}^*, \mathbf{S}^* = \arg \min_{\mathbf{X}, \mathbf{S}} & \left[\sum_i \|f(\mathbf{x}_i, \mathbf{u}_i) - \mathbf{x}_{i+1}\|_{\Theta_i}^2 + \right. \\ & \left. \sum_{ij} \|s_{ij}(f(\mathbf{x}_i, \mathbf{u}_{ij}) - \mathbf{x}_j)\|_{A_{ij}}^2 + \sum_{ij} w \|1 - s_{ij}\|^2 \right] \quad (13) \end{aligned}$$

由于离线式的 SLAM 算法在每步迭代中要对所有的节点和测量进行重计算, 加大了不必要的计算量。iSAM 算法认为新的测量往往只对局部节点有影响, 因此, 只用新的测量数据来增量地更新平方根信息矩阵 \mathbf{R} 以及矩阵 \mathbf{d} 。这个更新往往只对矩阵的小部分产生影响, 因此相对离线式算法更加具有时效性。另外, iSAM 需要定期执行离线算法, 对节点进行重新排序, 并重新计算关于所有节点的信息矩阵, 从而提高矩阵稀疏度并降低增量式算法产生的线性化误差。

在 iSAM 算法的基础上, 假设 R-iSAM 算法在每添加 K 个约束时执行一次离线式算法, 每 K 个约束为一个时期。R-iSAM 执行增量式过程时, 若当前时刻添加的约束为闭环约束, 考虑到当前时期内当前时刻之前的闭环约束已经对节点优化产生作用, 不再对其进行重复计算, 仅对当前时刻闭环的转换变量进行计算。

因此, R-iSAM 增量式过程描述为

$$\begin{aligned} \mathbf{X}^*, s_{ij_now}^* = \arg \min_{\mathbf{X}, s_{ij_now}} & \left[\sum_i \|f(\mathbf{x}_i, \mathbf{u}_i) - \mathbf{x}_{i+1}\|_{\Theta_i}^2 + F_{\text{pre}} + F_{\text{now}} \right] \\ (14) \end{aligned}$$

式中: F_{pre} 为之前的闭环约束引入的误差项, 表示为

$$F_{\text{pre}} = \sum_{ij_pre} \|f(\mathbf{x}_{i_pre}, \mathbf{u}_{ij_pre}) - \mathbf{x}_{j_pre}\|_{A_{ij}}^2 + \sum_{ij_pre} w \|1 - s_{ij_pre}\|^2 \quad (15)$$

式中: $\mathbf{x}_{i_pre}, \mathbf{x}_{j_pre}$ 为之前时刻被闭环的节点位姿; s_{ij_pre} 为已经计算得到的常量。

F_{now} 为当前时刻闭环引入的误差项, 表示为

$$F_{\text{now}} = \|s_{ij_now}(f(\mathbf{x}_{i_now}, \mathbf{u}_{ij_now}) - \mathbf{x}_{j_now})\|_{A_{ij}}^2 + w \|1 - s_{ij_now}\|^2 \quad (16)$$

式中: $\mathbf{x}_{i_now}, \mathbf{x}_{j_now}$ 为当前时刻中被闭环的节点; s_{ij_now} 为在此增量式过程中需要计算的闭环转换变量。

在 iSAM 离线式过程中重新计算 Jacobian 矩阵和矩阵重排序以减小线性化误差以及提高稀疏度的基础上, R-iSAM 在离线式过程中对当前时期的闭环 $\mathbf{U}' = \{\mathbf{u}'_{ij}\}$ 重新计算转换变量值 $\mathbf{S}' = \{s'_{ij}\}$, 并将其作为最终固定值, 在以后的优化中不再对其进行计算。

因此, R-iSAM 离线式过程描述为

$$\mathbf{X}^*, s_{ij}^{t*} = \arg \min_{\mathbf{X}, s_{ij}^t} \left[\sum_i \|f(\mathbf{x}_i, \mathbf{u}_i) - \mathbf{x}_{i+1}\|_{\Theta_i}^2 + \right.$$

$$F^{1:t-1}(\mathbf{x}_i^{1:t-1}, \mathbf{x}_j^{1:t-1}, \mathbf{u}_{ij}^{1:t-1}) + F^t(\mathbf{x}_i^t, \mathbf{x}_j^t, \mathbf{u}_{ij}^t) \quad (17)$$

式中： $\mathbf{x}_i^{1:t-1}, \mathbf{x}_j^{1:t-1}$ 为 $1:t-1$ 时期内被闭环的节点， $\mathbf{u}_{ij}^{1:t-1}$ 为相应的约束； $\mathbf{x}_i^t, \mathbf{x}_j^t$ 为第 t 时期中被闭环的节点位姿； \mathbf{u}_{ij}^t 为相应的闭环约束； s_{ij}^t 为当前时期若干闭环约束的转换变量； $F^{1:t-1}(\mathbf{x}_i^{1:t-1}, \mathbf{x}_j^{1:t-1}, \mathbf{u}_{ij}^{1:t-1})$ 为 $1:t-1$ 时期闭环引入的误差项，其具体表示为

$$F^{1:t-1}(\mathbf{x}_i^{1:t-1}, \mathbf{x}_j^{1:t-1}, \mathbf{u}_{ij}^{1:t-1}) = \sum_q \left\| s_{ij}^{1:t-1}(f(\mathbf{x}_i^{1:t-1}, \mathbf{u}_{ij}^{1:t-1}) - \mathbf{x}_j^{1:t-1}) \right\|_{A_{ij}}^2 + \sum_q w \left\| 1 - s_{ij}^{1:t-1} \right\|^2 \quad (18)$$

式中， $s_{ij}^{1:t-1}$ 为已经计算得到的常量。

$F^t(\mathbf{x}_i^t, \mathbf{x}_j^t, \mathbf{u}_{ij}^t)$ 为当前时期闭环引入的误差项，其具体表示为

$$F^t(\mathbf{x}_i^t, \mathbf{x}_j^t, \mathbf{u}_{ij}^t) = \sum_q \left\| s_{ij}^t(f(\mathbf{x}_i^t, \mathbf{u}_{ij}^t) - \mathbf{x}_j^t) \right\|_{A_{ij}}^2 + \sum_q w \left\| 1 - s_{ij}^t \right\|^2. \quad (19)$$

当一个时期的离线式过程结束后，若其中的闭环转换变量大于一个阈值，则认为是正确闭环，令其值为 1 且 $w=0$ ，否则在以后的优化过程将其排除，令其值为 0 且 $w=0$ 。

至此，利用 R-iSAM 的增量式过程对当前时刻引入闭环的转换变量进行计算，以初步优化节点位姿，并在离线式计算过程中优化当前时期所有闭环的转换变量，精确计算闭环对节点配置的影响程度，并作为以后时期增量式以及离线式的优化基础。

3 实验与分析

为进行算法对比，对公开的数据集 Manhattan 3500 Olson^[17]，City10000^[10]，Intel^[9] 进行仿真。3 个数据集节点与边的个数见表 1，机器人真实节点见图 2。由于 Intel 数据集是在真实环境中采集得到的，无法得到精确的真实机器人位姿，将对无错误闭环的 Intel 数据集优化计算得到的节点位姿作为其真实值。图 3 所示为原始数据中机器人节点与边。

表 1 数据集中节点与边个数

Table 1 The numbers of nodes and edges in datasets

数据集	节点数	边个数
Intel	943	1838
Manhattan3500	3500	5598
City10000	10000	20687

为了检验算法对 Graph SLAM 前端产生的不同类型错误闭环的适应性，采用文献[16]的方法对每个数据分别添加 4 种类型的异常闭环，即随机闭环(Random, R)，局部闭环(Local, L)，随机组闭环(Random Grouped, RG) 以及局部组闭环(Local Grouped, LG)。随机闭环在图中

随机选取 2 个节点添加约束边，用于模拟在全局相似环境中由闭环算法得到的错误闭环。局部闭环随机在局部区域添加闭环，模拟局部相似环境中闭环算法得到的错误闭环，组闭环则是添加具有一致性的若干闭环约束，使用 Vertigo 包^[18]提供的添加异常闭环工具。

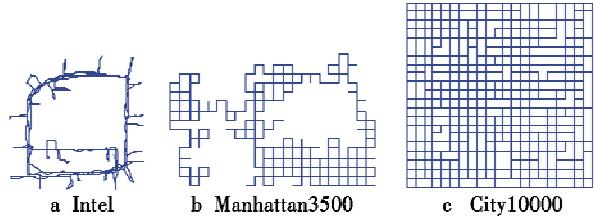


图 2 数据集节点真实位姿

Fig. 2 True node poses of datasets

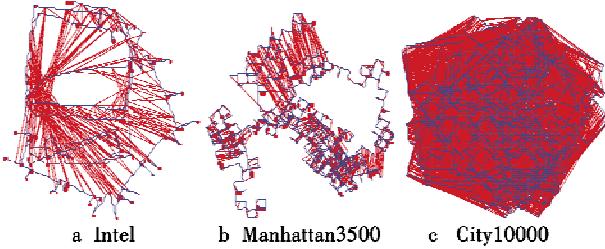


图 3 数据集原始节点(蓝)与边(红)

Fig. 3 Raw nodes (blue) and edges (red) of datasets

对数据集添加 100 个异常闭环约束后，利用 iSAM 算法对含有异常闭环的数据集进行运算，得到与真实情况差距巨大的节点图（见图 4）。可见 iSAM 算法对闭环依赖性高，虽然正确闭环可以较好地纠正里程计误差，但是一旦闭环错误就会导致灾难性后果，使 SLAM 过程失败。因此有必要应用鲁棒闭环的增量式 Graph SLAM 算法，排除错误闭环影响。

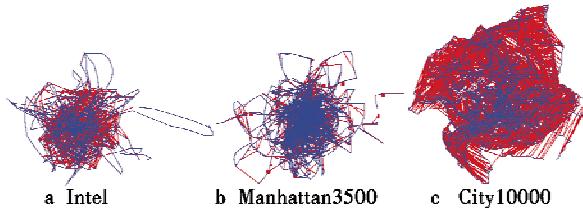


图 4 异常闭环节点配置结果

Fig. 4 Results of nodes with wrong loops

本文对数据集分别添加 4 种不同类型(R, L, RG, LG)、不同数量的异常闭环，采用 R-iSAM 算法和 SC 算法对含有错误闭环的数据集进行计算，R-iSAM 算法中设置每 100 个节点为一个时期。由此得到 R-iSAM 算法单步节点平均收敛时间，以及 SC 算法的收敛时间，见表 2。由于离线式鲁棒闭环的 SC 算法在迭代优化过程中需要考虑数据集内所有闭环约束的影响，即每次迭代计算都需要计算所有闭环的转换变量，因此耗时长，无法在增量式 SLAM 中得以应用。而 R-iSAM 最多只需要在离线式过程中对一个时期内的若

于一个闭环转换变量进行计算,大大减少了计算量,因此R-iSAM算法可以很好地满足增量式SLAM的实时性要求。另外,观察表2可以发现,两种算法在处理随机

性闭环(R, RG)时需要的计算时间更长。这主要是因为随机性闭环对整个图结构产生较大负面影响,所需要的迭代次数更多。

表2 不同数量、不同类型错误闭环下算法平均收敛时间

Table 2 Average convergence time of algorithm with different numbers and types wrong loops

数据集_算法(单位)	闭环添加数量															
	500				1000				1500				2000			
	R	L	RG	LG	R	L	RG	LG	R	L	RG	LG	R	L	RG	LG
Intel_SC/s	0.32	0.18	0.38	0.20	0.59	0.39	0.68	0.32	1.24	0.61	1.13	0.52	1.60	0.94	1.58	0.91
Intel_R-iSAM/ms	9	6	8	7	13	8	12	8	15	10	16	9	18	13	20	14
Manhattan_SC/s	2.2	1.2	2.8	1.5	3.8	1.7	3.5	1.6	5.4	2.8	5.2	2.1	7.6	2.6	4.5	2.8
Manhattan_R-iSAM/ms	13	9	15	10	19	13	21	14	26	18	28	19	38	25	37	28
City10000_SC/s	32.4	21.5	38.1	19.5	40.5	32.4	50.4	25.2	78.5	35.3	71.2	32.1	95.6	33.8	84.1	31.4
City10000_R-iSAM/ms	41	27	39	24	67	39	59	42	84	53	76	59	112	71	104	82

本文给出3个数据集在1000个R型异常闭环下的R-iSAM增量式节点配置结果,分别见图5、图6和图7。

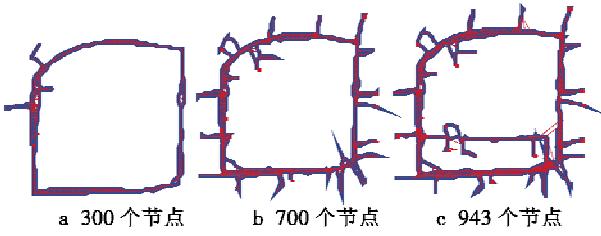


图5 Intel数据集的R-iSAM增量式过程

Fig. 5 R-iSAM process of Intel datasets

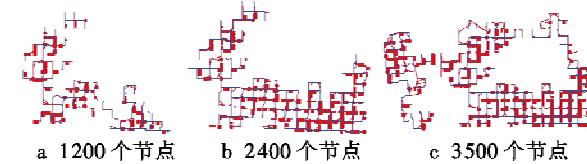


图6 Manhattan数据集的R-iSAM增量式过程

Fig. 6 R-iSAM process of Manhattan datasets

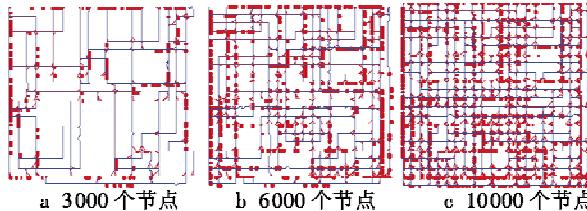


图7 City10000数据集的R-iSAM增量式过程

Fig. 7 R-iSAM process of City10000 datasets

对比图2与图5、图7可以发现,对于Intel数据集和City10000数据集,R-iSAM可以很好地恢复正确的节点配置,整个节点图的拓扑一致性较好。而对于Manhattan数据集,可以观察到R-iSAM得到的节点拓扑存在一定的倾斜现象,这与iSAM算法结果类似。主要是由于原始数据集中缺少针对部分误差较大节点的足够正确闭环,从而导致节点偏差未能得到有效修正。

由于一个节点的位姿误差会对接下来的所有节点

的位姿都产生影响,采用RMSE(Root Mean Square Error)值在评价节点图时不能有效评价其局部一致性,因此本文使用RPE(Relative Pose Error)值衡量算法结果与真实数据的差距。其计算方法为

$$K_{\text{RPE}} = \frac{1}{n} \sum_{i,i+1} \left(\delta_{i,i+1} - \hat{\delta}_{i,i+1} \right)^2 \quad (20)$$

式中: $\delta_{i,i+1}$ 为计算得到的约束边两个端点 x_i 与 x_{i+1} 之间的相对转移量距离; $\hat{\delta}_{i,i+1}$ 为真实节点 \hat{x}_i 与 \hat{x}_{i+1} 之间的相对转移距离。

给出3个数据集运算后的RPE值,如图8所示。可见当前实验下,R-iSAM在4种错误闭环的RPE值基本上在 $10^{-3} \sim 10^{-4}$ m之间,节点之间的相对关系比较准确,整个机器人轨迹的拓扑与真实拓扑具有很强的一致性,体现了算法的有效性。

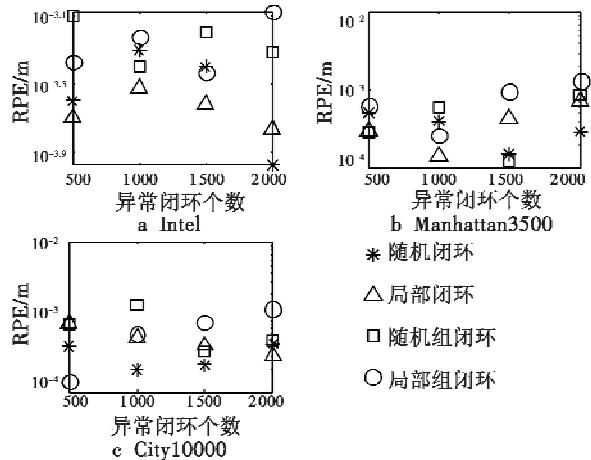


图8 R-iSAM算法在4种错误闭环下的RPE值

Fig. 8 RPE of R-iSAM with four kinds of wrong loops

4 总结

本文在iSAM算法的基础上,利用SC算法思想,提出一种能够有效消除错误闭环影响的增量式Graph SLAM算法R-iSAM。利用算法的增量式过程逐步评价

当前时刻闭环的有效性，并在离线式过程确定当前时期引入闭环的存在性，从而在鲁棒闭环的同时能够兼顾算法的实时性。实验证明，R-iSAM 能够排除错误闭环干扰，恢复机器人定位结果，且收敛速度较快，满足了增量式 SLAM 的要求。

参 考 文 献

- [1] BAILEY T, DURRANT-WHYTE H. Simultaneous Localization and Mapping (SLAM): part I [J]. *Robotics & Automation Magazine*, 2006, 13(3):108-117.
- [2] SMITH R C, CHEESEMAN P. On the representation and estimation of spatial uncertainty [J]. *The International Journal of Robotics Research*, 1986, 5(4):56-68.
- [3] 祝继华, 郑南宁, 袁泽剑, 等. 基于中心差分粒子滤波的 SLAM 算法 [J], *自动化学报*, 2010, 36(2):249-257.
(ZHU J H, ZHENG N N, YUAN Z J, et al. A SLAM algorithm based on central difference particle filter [J]. *Acta Automatica Sinica*, 2010, 36(2):249-257.)
- [4] HUANG S, DISSANAYAKE G. Convergence and consistency analysis for extended Kalman filter based SLAM [J]. *IEEE Transactions on Robotics*, 2007, 23(5):1036-1049.
- [5] LU F, MILIOS E. Globally consistent range scan alignment for environment mapping [J]. *Autonomous Robots*, 1997, 4(4):333-349.
- [6] FRESE U, SCHRODER L. Closing a million-landmarks loop [C]//IEEE/RSJ International Conference on Intelligent Robots and Systems, Beijing: IEEE, 2006:5032-5039.
- [7] GRISETTI G, STACHNISS C, BURGARD W. Nonlinear constraint network optimization for efficient map learning [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2009, 10(3):428-439.
- [8] GRISETTI G, KUMMERLE R, STACHNISS C, et al. Hierarchical optimization on manifolds for online 2D and 3D mapping [C]//IEEE International Conference on Robotics and Automation (ICRA), Anchorage: IEEE, 2010:273-278.
- [9] KUMMERLE R, GRISETTI G, STRASDATH, et al. G² o : a general framework for graph optimization [C]//IEEE International Conference on Robotics and Automation (ICRA), Shanghai: IEEE, 2011:3607-3613.
- [10] KAESZ M, RANGANATHAN A, DELLAERT F. iSAM: fast incremental smoothing and mapping with efficient data association [C]//IEEE International Conference on Robotics and Automation, Roma: IEEE, 2007:1670-1677.
- [11] TIPALDI G D, BRAUN M, ARRAS K O. FLIRT: interest regions for 2D range data with applications to robot navigation [C]//The 12th International Symposium on Experimental Robotics, Experimental Robotics, Berlin: Springer Berlin Heidelberg, 2014:695-710.
- [12] OLSON E. Recognizing places using spectrally clustered local matches [J]. *Robotics and Autonomous Systems*, 2009, 57(12):1157-1172.
- [13] CUMMINS M, NEWMAN P. FAB-MAP: probabilistic localization and mapping in the space of appearance [J]. *The International Journal of Robotics Research*, 2008, 27(6):647-665.
- [14] LATIF Y, CADENA C, NEIRA J. Robust loop closing over time [C]//Robotics: Science and Systems Conference, Sydney, 2012:233-236.
- [15] OLSON E, AGARWAL P. Inference on networks of mixtures for robust robot mapping [J]. *The International Journal of Robotics Research*, 2013, 32(7):826-840.
- [16] SUNDERHAUF N, PROTZEL P. Switchable constraints for robust pose graph slam [C]//IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), Vilamoura: IEEE, 2012:1879-1884.
- [17] OLSON E, LEONARD J, TELLER S. Fast iterative alignment of pose graphs with poor initial estimates [C]//Proceedings IEEE International Conference on Robotics and Automation, Orlando: IEEE, 2006:2262-2269.
- [18] KAESZ M, RANGANATHAN A, DELLAERT F. iSAM: fast incremental smoothing and mapping with efficient data association [C]//IEEE International Conference on Robotics and Automation, Roma: IEEE, 2007:1670-1677.

欢迎订阅期刊

欢迎刊登广告