

利用先验点图模型的 SLAM 后端优化算法

吕瑞¹ 陈龙² 翁雪³ 何金城³

1 武汉大学测绘遥感信息工程国家重点实验室,湖北 武汉, 430072

2 中山大学移动信息工程学院,广东 珠海, 519000

3 武汉大学计算机学院,湖北 武汉, 430072

摘要:目前基于因子图的后端优化算法具有优越性。在因子图中,节点代表姿态,节点之间的边代表里程信息和封闭循环约束。由于因子图并未描述每个节点精度的差异,导致整体定位精度仍有提高的空间。针对这个问题,提出了一种基于先验点图模型的后端优化算法,依据前端提供节点精度的差异,在因子图中引入高精度点,然后采用改进的 Levenberg 算法进行全局优化,从而实现在结合原有概率约束的基础上,利用少量高精度点牵引其他点向真实值靠近,完成更为精准的自身定位。并在公开数据集上进行了实验,结果证明,本文提出的算法增强了前后端的关联,提高了定位精度。

关键词:图优化;机器人;同时定位与地图构建;后端优化算法

中图法分类号:P237.3

文献标志码:A

目前,同时定位与地图构建^[1](simultaneous localization and mapping, SLAM)是移动和自主机器人领域最热门的问题之一。从20世纪90年代起,美国 Berkeley 大学、卡内基梅隆大学、哥伦比亚大学等都开展了相应的研究工作。国内的清华大学、国防大学、武汉大学^[2]、同济大学、中国测绘科学研究院、吉林大学、中科院深圳先进技术研究院等也开展了相应的关于多传感器集成车辆的研究,并研制了相应的系统。1997年, Lu 和 Millois^[3]首次提出基于因子图优化来解决全局 SLAM 问题的方法。最近,在同时定位与地图构建领域,因为它提供了有效解决潜在优化问题的方法,所以变得越来越受欢迎。Graphs of Olson^[4]、TreeMap^[5]、TORO^[6]、iSAM^[7]、iSAM2^[8]和 g2o^[9]等流行算法都是基于图优化方法。在常规硬件上,采用图优化算法可以在几秒钟优化包含1万个变量的大范围 SLAM 问题,而且得到比较高的定位精度。

然而,当前基于因子图的算法并没有充分利用前端提供的信息,难以实现高精度的地图构建。在真实场景中,有些特征十分明显,如角落、路标、目标物体等。前端传感器进行提取时,可以得到

精度更高的位置坐标。此外,在测绘领域,可以事先测量的控制点^[10]也是一种先验高精度点。Montemerlo 和 Thrun^[11]提出一种用 GPS 获取先验信息的方法,从而辅助定位。Rainer 的团队^[12]利用航空影像作为先验信息,扩展了 MCL 算法,实现了实时的图优化。然而,以上算法并没令先验信息得到充分的利用。

针对上述问题,本文在现有图优化算法的基础上提出了一种基于先验点图模型的后端优化算法,依据前端提供姿态点精度的差异,为每个姿态赋予权值,然后采用改进的 Levenberg 算法^[13]进行全局优化,提升地图(本文中均指由机器人的位置坐标构成的 2D 地图)的定位精度。

1 系统概述

SLAM 系统可以分为前端预处理和后端优化两个部分,如图 1 所示。目前常用的传感器包括激光雷达、相机、GPS、IMU 等,前端预处理通过对各种传感器数据进行目标分割、特征提取、数据融合等方式,提供初始估计地图和里程、封闭循环等概率约束。后端优化是利用图模型描述初始

收稿日期:2014-01-15

项目来源:中央高校基本科研业务费专项资金资助项目(2013460003161001);空间信息智能感知与服务深圳市重点实验室开放基金资助项目(2013460004299001)。

第一作者:吕瑞,硕士生。主要研究方向为智能车、计算机视觉。E-mail:lvru@whu.edu.cn

通讯作者:陈龙,博士,讲师。E-mail:chenl46@mail.sysu.edu.cn

估计和概率约束,然后运用高效的稀疏矩阵优化和概率约束来进行进一步优化,实现更高精度的定位。本文是在前端提供先验精度的基础上,提出了先验点图模型和一种基于改进 Levenberg 的后端优化算法,依据前端提供节点精度的差异,在

因子图中引入高精度点,然后采用改进的 Levenberg 算法进行全局优化,从而实现在结合原有概率约束的基础上,利用少量高精度点牵引其他点向真实值靠近,完成更为精准的自身定位,有利于机器人进行自主导航。

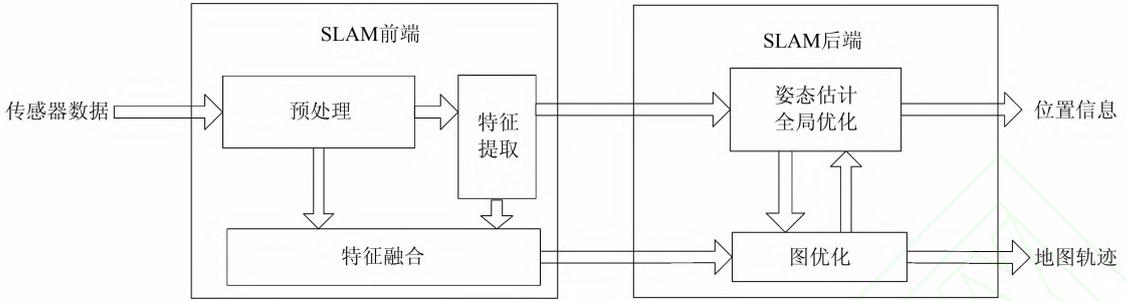


图1 图1系统框架

Fig.1 System Framework

2 图优化

经典的SLAM图模型^[7-8]公式在每个连续的姿态 x_i 和 x_j 之间提供了一系列的里程信息约束。它们的关系如式(1)所示。此外,前端传感器可以检测两个不连续姿态 x_i 和 x_j 之间的封闭循环。封闭循环约束可以表示为式(2)。

$$x_{i+1} = f(x_i, u_i) + \omega_i \tag{1}$$

$$x_j = f(x_i, u_{ij}) + \lambda_{ij} \tag{2}$$

式(1)和式(2)中, f 是一个用来表示机器人运动模型的非线性函数; x_i 和 x_j 是未知的机器人姿态; ω_i 和 λ_{ij} 是协方差分别为 Σ_i 和 Λ_{ij} 的高斯误差。

本文用因子图^[8]对SLAM图模型问题进行建模,图2对其进行了阐述。图2中大节点代表未知的机器人姿态,小节点代表概率约束。所有变量(机器人姿态) $X = \{x_i\}$ 和约束 $U = \{u_i \cup u_{ij}\}$ 的条件概率关系表示如下:

$$P(X | U) \propto \prod_i P(x_{i+1} | x_i, u_i) \prod_{ij} P(x_j | x_i, u_{ij}) \tag{3}$$

SLAM图模型的关键就是计算概率分布 $P(X|U)$ 。 $P(X|U)$ 与机器人姿态的最大后验优化结果 X^* 相关,即概率分布有最大值时, X^* 为所求点。在假设所有条件概率满足高斯分布的情况下^[14],最优的 X^* 在联合概率最大时取得,公式如下:

$$X^* = \arg \max_X P(X | U) = \arg \min_X - \log P(X | U) = \arg \min_X \sum_i \| f(x_i, u_i) -$$

$$x_{i+1} \|_{\Sigma_i}^2 + \sum_{ij} \| f(x_i, u_{ij}) - x_j \|_{\Lambda_{ij}}^2 \tag{4}$$

这是一个非线性最小二乘问题。在本文中,马氏距离的平方被定义为 $\| a - b \|_{\Sigma}^2 = (a - b)^T \Sigma^{-1} (a - b)$ 。

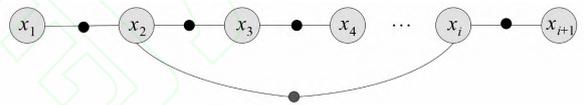


图2 因子图

Fig.2 Pose Graph

3 高精度后端优化

3.1 先验点图模型

本文在因子图模型的基础上进一步挖掘模型的隐藏信息,通过标识节点来区别节点坐标之间的精度差异。本文提出的先验点图模型如图3所示。图3中实心节点代表高精度节点,空心节点代表低精度节点。本文提出的算法只需少量高精度节点即可达到提升全局地图精度的效果,后文将进一步阐述。

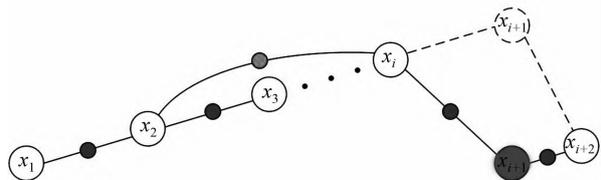


图3 先验点图模型

Fig.3 Graph Model Based Prior Point

3.2 改进的 Levenberg 算法

本文通过改进 Levenberg 方法^[13]来解算先验点图模型,在利用因子图原有的里程约束和封

闭循环约束进行优化的同时,结合少量高精度点进行全局优化,实现在不破坏高精度点自身精度的前提下,将所有低精度点向真实值进行牵引,从而完成更为精准的自身定位。首先,利用变量 ω 来标识每个节点,如果 $\omega=1$,则代表节点精度较低;如果 $\omega=0$,则代表节点精度较高。为了充分利用先验点,且不破坏原有算法的结构,本文更新了两个步骤。具体的解算方法如下。

定义一个标量值函数 $f: \mathbb{R}^n \rightarrow \mathbb{R}, n \geq 1$, \mathbb{R} 代指一个坐标空间,则式(4)可以表示为:

$$\mathbf{X}^* = \arg \min_{\mathbf{X}} \{F(\mathbf{X})\} \quad (5)$$

式中,

$$F(\mathbf{X}) = \frac{1}{2} \sum_{i=1}^m (f_i(x))^2 = \frac{1}{2} \|\mathbf{f}(x)\|^2 = \frac{1}{2} \mathbf{f}(x)^T \mathbf{f}(x) \quad (6)$$

1) 计算式(7),获得初始估计 \mathbf{X}_0 :

$$\mathbf{F}'(\mathbf{X}_0) = 0 \quad (7)$$

这里, \mathbf{X}_0 是一个 n 维矩阵。本文在此处采用矩阵 \mathbf{W} 来存储标识节点精度的变量 ω 。并通过式(8)更新初始估计:

$$\mathbf{X}_0 = \mathbf{W} \cdot (\mathbf{X}_0 - \mathbf{x}) + \mathbf{x} \quad (8)$$

2) 当 f 存在二次偏导时,得到其泰勒公式:

$$f(x+h) = f(x) + \mathbf{J}_f(x)h + O(\|h\|^2) \quad (9)$$

3) 依据式(9)计算迭代步 h_M :

$$(\mathbf{J}_f^T \mathbf{J}_f + \mu \mathbf{I})h_M = -\mathbf{g}, \mathbf{g} = \mathbf{J}_f^T \text{ and } \mu \geq 0 \quad (10)$$

这里, μ 是一个巧妙的约束参数,用于控制迭代步的大小。在每次迭代中监控误差的更新。当新的误差小于之前的误差,在下次迭代中将减小 μ ; 否则,增大 μ 。具体可参考 Marquardt 的方法^[13]。

4) 更新 $\mathbf{X}_k (k \geq 0)$, 本文为保持高精度节点的精度,在优化中不更新高精度节点的位置。公式如下:

$$\mathbf{X}_{k+1} = \mathbf{X}_k + \mathbf{W} \cdot h_M \quad (11)$$

5) 重复执行第 3)、4)步,直至系统收敛。高精度点在优化过程中同样参与计算,在每次迭代过程中和因子图没有区别。每次迭代后,本文通过式(11)保持高精度点的位置不变。在之后的迭代过程中,由于高精度点的坐标始终比较准确,也有助于其他点向真实值靠近,从而实现了对整个地图的全局调整与优化。

4 实验

4.1 实验数据

为了证明算法的正确性和鲁棒性,本文采用

两个仿真数据和一个真实数据来进行实验。实验数据的基本信息如表 1 所示。Manhattan 数据是由 Olson^[1]首次提出;Ring 数据集是 Niko^[15]制作的仿真数据;真实数据 Bicocca^[16]是在室内采集的,它提供的里程信息和封闭循环是利用 BoW 识别系^[16]得到的。以上数据都是公开的 2D 数据集,可以直接从网上获取。

表 1 实验数据和平均 RMSE_{pos} 对比

Tab. 1 Experimental Data and Comparison of Mean RMSE_{pos}

数据集	数据类型	来源	节点数 / 个	g2o 误差 / m	本文误差 / m
Manhattan	仿真	isam	3 500	1.19	0.67
Ring	仿真	novel	434	4.39	0.99
Bicocca	真实	RRR	8 358	2.26	1.32

4.2 评价方法

为了评价和衡量本文提出的算法,通过人工添加少量先验点到对应的数据进行实验,再通过与目前优化效果最佳方法的 RMSE (root-mean-square-error)^[17] 来进行对比,得出结论。对于 2D slam 问题, RMSE_{pos} 用于衡量机器人位置与真实值的偏移误差, RMSE_{ori} 用于衡量机器人方向角度与真实值的偏移量。

4.3 处理方法

首先,为证明本文算法的有效性,对三个数据分别进行了 20 组实验,每组实验随机标识 10 个先验高精度点,然后采用高精度后端算法进行优化,计算平均 RMSE。Rainer^[9]通过对比实验证明 g2o^[9] 离线优化效果优于 isam、isam2、TORO 等诸多算法。本文与其优化结果进行了对比,数据对比如表 1 所示。真实数据 Bicocca 的实验效果如图 4 所示。

其次,为了探索不动点个数以及布局对优化结果的影响,本文采用 3 种策略来标识不同数量的高精度节点:① 全局随机策略:在整个地图随机地标识高精度点,所有高精度点都彼此保持一定距离。② 全局角点策略:在真实场景中,角落更容易被前端识别,因此,本策略采用在整个地图标识角点的方式。③ 全局随机分组策略:在整个地图随机标识 n 组高精度点,每组点有 3 个高精度点。

4.4 实验结果与分析

表 1 统计了本文算法与 g2o 算法在三种公开数据集上的定位误差。结果表明,在测试的数据集上,本文算法平均将 2D 位置地图的误差 RMSE_{pos} 降低了 54.2%,进而提升了地图的全局定位

精度。

在 Manhattan 数据上,采用三种策略进行自身对比实验的结果如图 5 所示。图 5 的横坐标代表高精度点的比例,纵坐标代表误差值。实验结果表明:① 在测试数据上,采用本文算法进行优化后一定能提升定位精度,且当高精度点的个数为 0.2%~0.33%时,三种策略均可得到自身方法下最小的定位误差;② 采用全局随机分组策略标识高精度点时,优化结果稳定,定位误差保持在 0.67 m 左右;③ 采用全局角点策略标识高精度点时,可以得到最精确的优化效果,最低误差为 0.62 m。

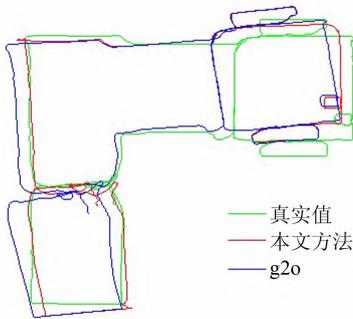


图 4 Bicocca 地图效果

Fig. 4 Result of Bicocca Map

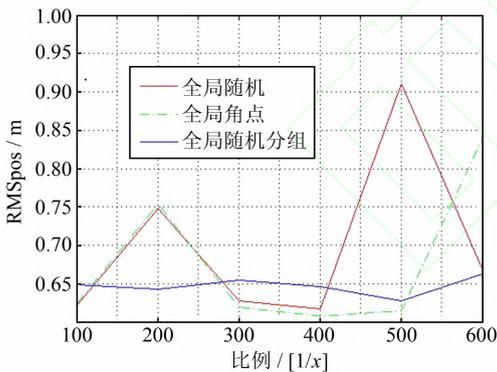


图 5 高精度点的影响

Fig. 5 Influence of Precise Points

5 结 语

本文提出的基于先验点图模型的后端优化算法,利用先验高精度点充分挖掘图模型的潜在属性,并通过改进的 Levenberg 算法进行优化,最终提升了地图的整体定位精度。然而,本文算法需要人工标识高精度点,缺乏自适应性。下一步将进一步挖掘图模型的潜在属性,实现高低精度点的自动区分,完成更加智能和精确的全局优化。

参 考 文 献

- [1] Dissanayake M W M G, Newman P, Clark S, et al. A Solution to the Simultaneous Localization and Map Building (SLAM) Problem[J]. *IEEE Transactions on Robotics and Automation*, 2001, 17(3): 229-241
- [2] Li Deren, Guo Sheng, Hu Qingwu. LD2000 Series Mobile Road Measurement System and Its Application Based on 3S Integration Technology[J]. *Journal of Surveying and Mapping*, 2008, 37(3): 273-276(李德仁,郭晟,胡庆武.基于 3S 集成技术的 LD2000 系列移动道路测量系统及其应用[J].测绘学报,2008, 37(3):273-276)
- [3] Lu F, Milios E. Globally Consistent Range Scan Alignment for Environment Mapping[J]. *Autonomous Robots*, 1997, 4(4):333-349
- [4] Olson E, Leonard J, Teller S. Fast Iterative Optimization of Pose Graphs with Poor Initial Estimates [C]. 2006 IEEE International Conference on Robotics and Automation, Orlando, Florida, USA, 2006
- [5] Frese U, Schroder L. Closing a Million-Landmarks Loop[C]. 2006 IEEE/RSJ International Conference on Intelligent Robots and Systems, Beijing, China, 2006
- [6] Grisetti G, Stachniss C, Burgard W. Non-linear Constraint Network Optimization for Efficient Map Learning [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2009, 10(3):428-439
- [7] Kaess M, Ranganathan A, Dellaert F. iSAM: Incremental Smoothing and Mapping [J]. *IEEE Transactions on Robotics*, 2008, 24(6): 1 365-1 378
- [8] Kaess M, Johannsson H, Roberts R, et al. iSAM2: Incremental Smoothing and Mapping Using the Bayes Tree[J]. *The International Journal of Robotics Research*, 2012, 31(2): 216-235
- [9] Kummerle R, Grisetti G, Strasdat H, et al. g2o: A General Framework for Graph Optimization [C]. IEEE International Conference on Robotics and Automation, Shanghai, China, 2011
- [10] Heikkila J. Geometric Camera Calibration Using Circular Control Points[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2000, 22(10): 1 066-1 077
- [11] Montemerlo M, Thrun S. Large-scale Robotic 3D Mapping of Urban Structures [M]. *Experimental Robotics*, 2006, 9: 141-150
- [12] Kummerle R, Steder B, Dornhege C, et al. Large Scale Graph-based SLAM Using Aerial Images as Prior Information [J]. *Autonomous Robots*, 2011,

- 30(1):25-39
- [13] Hertzberg C. A Framework for Sparse, Non-linear Least Squares Problems on Manifolds[D]. Bremen: University Bremen, 2008
- [14] Kschischang F R, Frey B J, Loeliger H A. Factor-Graphs and the Sum-product Algorithm[J]. *IEEE Transactions on Information Theory*, 2001, 47(2): 498-519
- [15] Sunderhauf N, Protzel P. Switchable Constraints for Robust Pose Graph Slam[C]. 2012 IEEE/RSJ International Conference on Intelligent Robots and Systems, Vilamoura, Algarve, Portugal, 2012
- [16] Ceriani S, Fontana G, Giusti A, et al. Rawseeds Ground Truth Collection Systems for Indoor Self-localization and Mapping [J]. *Autonomous Robots*, 2009, 27(4): 353-371
- [17] Kümmerle R, Steder B, Dornhege C. On Measuring the Accuracy of SLAM Algorithms[J]. *Autonomous Robots*, 2009, 27(4): 387-407

A Back-End Optimization Algorithm of SLAM Based on Graph Model with Prior Points

LV Rui¹ CHEN Long² WENG Xue³ HE Jincheng³

- 1 State Key Laboratory of Information Engineering in Surveying, Mapping and Remote Sensing, Wuhan University, Wuhan 430079, China
- 2 School of Mobile Information Engineering, Sun Yat-sen University, Zhuhai 519000, China
- 3 School of Computer, Wuhan University, Wuhan 430072, China

Abstract: Simultaneous localization and mapping (SLAM) is a hot issue in the field of robotics, the problem consists of two parts, front-end perception and back-end optimization. At present, the back-end optimization algorithm based on factor graph works well. In the factor graph, nodes represent poses, the edges between nodes represents the range information and closed loop constraint. Since the accuracy differences of nodes are not described in factor graph, the global positioning accuracy can be improved no further. To solve this problem, we propose a back-end optimization algorithm based on graph model with prior points which are introduced from the front-end that updates the graph model by fixing high-precision poses during optimization. The back-end can thereby use these fixed high-precision poses to drag low-precision poses closer to the ground truth and increase overall accuracy. We demonstrate the approach and present results on public datasets. The experimental results show that the maps acquired with our method show increased global precision.

Key words: graph optimization; robot; SLAM; back-end optimization algorithm

First author: LV Rui, postgraduate. His research interests include smart car and computer vision. E-mail: lvru@whu.edu.cn

Corresponding author: CHEN Long, PhD, lecturer. E-mail: chenl46@mail.sysu.edu.cn

Foundation support: The Fundamental Research Funds for the Central Universities, No. 2013460003161001; the Open Fund of Spatial Information Intelligent Perception and Service Shenzhen Key Laboratory, No. 2013460004299001.