

基于 Bayes 滤波的移动机器人定位方法

赵增顺^{1,3} 沈继毕¹ 王继贞¹ 侯增广² 谭民²

(山东科技大学信息与电气工程学院 青岛 266510)¹ (中国科学院自动化研究所 北京 100080)²
(山东省机器人与智能技术重点实验室 青岛 266510)³

摘要 对基于贝叶斯滤波原理的机器人定位方法提出了一个通用框架,进行了贝叶斯滤波方法的推导,理顺了贝叶斯总体框架以及卡尔曼滤波定位、多假设定位、马尔可夫定位、蒙特卡罗定位方法之间的内在逻辑关系。回顾了基于概率推理框架的各种机器人定位方法的发展过程、目前发展水平,并针对各自的利弊进行了比较。基于采样的蒙特卡罗定位算法能够描述多峰分布,可近似大范围的概率分布,能够有效解决定位过程中出现的歧义情况以及绑架情况等,因此重点对蒙特卡罗定位算法的实现过程以及存在的问题进行了详细的阐述,同时对研究难点和未来的发展趋势做了展望。

关键词 贝叶斯滤波,机器人定位,蒙特卡罗定位,马尔可夫定位

中图分类号 TP242.2 **文献标识码** A

Research on Self-localization Methods for Mobile Robots Based on Bayes Filter

ZHAO Zeng-shun^{1,3} SHEN Ji-bi¹ WANG Ji-zhen¹ HOU Zeng-guang² TAN Min²

(School of Electric Engineering, Shandong University of Science and Technology, Qingdao 266510, China)¹

(Institute of Automation, Chinese Academy of Sciences, Beijing 100080, China)²

(Shandong Key Laboratory of Robotics & Intelligent Technology, Qingdao 266510, China)³

Abstract This article presented a survey of the most common probabilistic models for self localization algorithm of mobile robot. We proposed a general Bayesian inference framework which is deduced in detail through a combination of Markov assumption with Bayesian rule. Under such general framework, we gave a review of the main probabilistic models such as Kalman Filtering Series, Multi-hypothesis Localization, Markov Model Localizations and Monte Carlo localization, etc., all of which can be captured under this single formalism. This will provide readers a global view of this literature. We emphasized the implementation and drawbacks of Monte Carlo Localization, which is considered as one of the most promising method.

Keywords Bayesian filtering, Robot localization, Monte carlo localization, Markov localization

机器人在感知环境、执行动作的过程中,总是存在非常大的不确定性,机器人的观测也必然是不完整的、含有噪声的。如何描述机器人运动控制以及观测信息的不确定性问题,如何依据不可靠信息做出决策? 概率推理就能够有效解决对象自身以及对象之间的不确定性关系。目前,基于 Bayes 滤波模型和多传感器融合的移动机器人定位已取得了丰硕的研究成果^[1-6,11-14]。

基于 Bayes 滤波定位算法的基本思想是将机器人定位问题转化为状态空间中机器人的状态估计问题,即位姿概率分布的计算和更新。基于贝叶斯滤波框架下的概率推理定位算法的代表性方法主要有:卡尔曼滤波^[5](KF)、多假设定位^[3](MHL)、马尔可夫^[4](Markov)模型(我们把部分可观测马尔

可夫模型决策过程^[1](POMDP)划分在基于拓扑的马尔可夫模型定位中)以及蒙特卡罗定位^[2](MCL),其内在逻辑关系如图 1 所示。

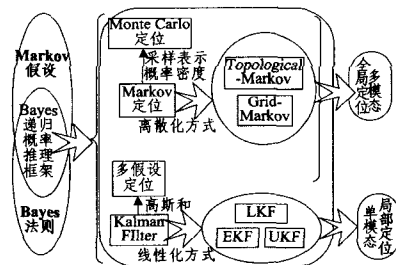


图 1 基于贝叶斯滤波统一框架的机器人定位方法逻辑关系图

到稿日期:2010-03-21 返修日期:2010-06-23 本文受 863 项目(2006AA04Z219),国家自然科学基金(60805028,60903146,60775043),山东省自然科学基金(ZR2010FM027)资助。

赵增顺(1975—),男,博士,副教授,主要研究方向为智能机器人、视觉语音信号处理等,E-mail:zhaozhengshun@163.com;沈继毕(1986—),男,硕士生,主要研究方向为智能机器人和 Zigbee 无线网络等;王继贞(1985—),男,硕士生,主要研究方向为目标跟踪和智能算法等;侯增广(1969—),男,研究员,博士生导师,主要研究方向为移动机器人控制、智能优化、多传感器融合等;谭民(1963—),男,研究员,博士生导师,主要研究方向为先进机器人控制、多机器人协调。

1 贝叶斯滤波框架

对于状态估计问题可给出如下描述:根据当前时刻 k 之前的状态序列 $x_{0:k-1} = (x_0, \dots, x_{k-1})$ 和当前所有观测序列 $z_{0:k} = (z_0, \dots, z_k)$ 来估计当前 k 时刻的状态 x_k , 即希望得到概率密度函数 $p(x_k | z_{0:k})$ 。这个问题理论上的最优解法就是迭代 Bayes^[10]方法。Bayes 滤波原理的实质用系统模型预测状态的先验概率密度,再使用最近的观测值进行修正,得到后验概率密度。递归贝叶斯滤波为定位问题提供了一个通用的概率框架。

假设动态系统符合一阶马尔可夫假设,即(1)Markov 记忆性假设:当前时刻的观测量和控制量只与前一时刻的观测量和控制量相关。那么有:

$$p(x_k | x_{0:k-1}) = p(x_k | x_{k-1}) \quad (1)$$

(2)Markov 观测假设:当前观测仅仅依赖于当前状态,即当前观测量相对于其他测量条件独立。

$$p(z_{0,k} | x_k) = p(z_k | x_k) p(z_{0,k-1} | x_k) \quad (2)$$

在一阶马尔可夫假设的前提下,在贝叶斯法则的基础上可以得到系统状态随时间演变的递归状态预测方程,这个由观测时间序列获得状态序列的过程称之为贝叶斯滤波。逻辑关系如图 1 所示。

假设已得到信度 $Bel(x_{k-1}) = p(x_{k-1} | z_{0:k-1})$ 的表达式,那么要预测的是当前时刻的 $Bel(x_k)$:

$$Bel(x_k) = \frac{p(z_k | x_k, z_{0:k-1}) p(x_k | z_{0:k-1})}{p(z_{0,k})} \quad (3)$$

令 $\eta = p(z_{0,k})$,利用事件分解、全概率公式、两个 Markov 假设及信度的定义,可得:

$$Bel(x_k) = \eta p(z_k | x_k) \int p(x_k | x_{k-1}) Bel(x_{k-1}) dx_{k-1} \quad (4)$$

式(4)就是贝叶斯滤波应用于系统动态模型和感知模型的结果。其中 $p(z_k | x_k)$ 是系统感知模型; $p(x_k | x_{k-1})$ 是系统动态模型。递归贝叶斯滤波估计系统状态通常分解为状态预测和感知更新两个过程,如式(5)和式(6)所示。

$$Bel^-(x_k) = \int p(x_k | x_{k-1}) Bel(x_{k-1}) dx_{k-1} \quad (5)$$

$$Bel(x_k) = \eta p(z_k | x_k) Bel^-(x_k) \quad (6)$$

2 卡尔曼滤波系列

卡尔曼滤波器^[5,10]用高斯分布来描述机器人的当前位姿。在基于贝叶斯推理框架下,同样是运动预测到感知更新的递推过程。常规卡尔曼滤波是线性卡尔曼滤波 LKF(Linear Kalman Filters),是一种简单有效的线性最优递推估计算法。当卡尔曼滤波应用于非线性系统状态估计时,根据对非线性系统处理方式的不同,又可以分为 EKF 和 UKF。

扩展卡尔曼滤波方法 EKF^[5](Extended KF)用泰勒级数展开的一阶项来近似非线性系统,然后运用线性卡尔曼滤波 LKF 对系统状态进行递归估计。如 Curran^[5]融合了航位推算、超声和红外传感器数据信息,提出了基于扩展卡尔曼滤波器的定位和运动控制算法。Unscented KF 运用 Unscented 变换来代替非线性系统方程,从而实现了对系统状态的递归估计,它避开了 EKF 中雅克比矩阵的计算。

但是应用卡尔曼滤波器有严格的条件:(1)采样间隔必须足够小;(2)系统假定为线性系统或者可以接受将非线性系统进行线性化近似;(3)该方法要求系统状态、运动模型和观测模型都是高斯分布的情况;(4)不能解决多峰问题。

3 多假设定位

多假设定位^[3,6]把系统状态分布的概率密度函数用多个假设表示,每一假设由一个独立的高斯分布表示。多假设定位能做出多个确定的状态假设,利用卡尔曼滤波来跟踪每一个假设,其可以看作是卡尔曼滤波器群。这种方法具有多模性,因此可解决全局定位问题,同时在每一个位姿假设上进行局部位姿跟踪。I. J. Cox 提出了基于高斯混合模型多重假设 Kalma 滤波方法^[3]来消除定位歧义。然而该方法继承了卡尔曼滤波算法中的高斯噪声假设,并需要复杂的启发式信息来解决数据相关问题及假设的添加或删除。

4 Markov 定位算法

我们可以从隐马尔可夫滤波方法的角度来考虑定位问题,即目标状态 x_k 是不可见的,只知道状态变化满足马尔可夫过程,只能从已知的观测数据中来推测状态的变化规律。对应于贝叶斯滤波统一框架中的系统动态方程,机器人运动模型是 $p(x_k | x_{k-1}, a_{k-1}, u_{k-1})$,其中 a_{k-1} 是机器人动作数据, u_{k-1} 是运动噪声。 $p(z_k | x_k, v_k)$ 是机器人的观测似然, v_k 是观测噪声。

根据对位姿空间离散化形式的不同,Markov 定位主要分为基于拓扑离散的 Markov 定位(图 1 中用 topological_Markov 表示)^[1,7]和基于栅格离散的 Markov 定位^[4,8,9](图 1 中用 grid_Markov 表示)。基于拓扑离散的 Markov 定位是对位姿空间的低分辨率离散,由一组离散的明显区分的位置构成位姿空间,并组成环境的图结构形式,其已成功应用到办公室环境的导航机器人 Derish^[7]。基于拓扑的建模方法允许机器人在难以获得精确定位信息的情形下,利用状态部分可观测马尔可夫决策过程模型(POMDP)^[1],依靠传感器信息与环境特征信息的匹配来确定机器人的方位。1996 年 Burgard^[4]等提出了 Markov 定位思想和占据栅格法结合的一种方法,称为概率栅格法。其把机器人位于所有可能的位姿空间的概率表示为一段的常数函数,从而表示了复杂的多峰函数。Burgard^[8]和 Thrun^[9]将这个方应用博物馆导航机器人上。

Markov 定位是用概率密度分布来描述机器人在整个状态空间的可能位置,并用传感器信息和里程计信息不断更新概率密度分布,使得密度分布最大值所在的位置不断地逼近机器人所在的真实位置,鲁棒性好,但是因为要维持整个状态空间的概率密度分布,所以需要消耗很大的内存和计算资源。

5 Monte-Carlo 定位算法

蒙特卡罗是近几年开始在机器人学研究中得到应用的新方法^[2],有的称为粒子滤波^[10]或者 condensation 算法。Dellaert^[2]最早提出了基于蒙特卡罗采样的定位算法。蒙特卡罗方法作为贝叶斯滤波统一框架下的一种实现形式,同样是通过传感信息递归估计位姿状态空间的概率分布来实现的,不过概率分布是以加权采样的形式来描述的。可以认为基于采样的概率表示形式的 Markov 定位就是蒙特卡罗定位,可以用于全局定位以及局部位姿跟踪。

蒙特卡罗方法的重要组成部分就是因子采样法。机器人 $k-1$ 时刻以前的状态先验概率密度 $p(x_k)$ 一般是非高斯的,需要复杂的高维函数积分估计,难以得到解析解,也很难直接从中采样。为了获取位姿空间概率密度分布的采样集,采用重要性采样性方法^[13]求取近似解。这种方法通过引入 N 个

离散的加权随机采样集合 $\{(s^{(i)}, w^{(i)})\}$ 来近似表示分布函数, 而且每个样本的概率值与它所对应的权值 $w^{(i)}$ 成比例。那么 $k-1$ 时刻的采样 $p(s_k^{(i)} | z_{0,k-1})$ 可近似描述贝叶斯滤波中的后验概率 $p(x_k | z_k)$, 通过递归迭代得到 $p(s_k^{(i)} | z_{0,k})$ 。

在运动更新也就是预测阶段, 需要推导用采样方式得到的预测概率分布 $p(x_k | z_{0,k-1})$, 即:

$$Bel^-(x_k) \approx p(x_k | z_{0,k-1}) = \sum_{i=1}^N p(x_k | x_{k-1} = s_k^{(i)}, a_{k-1}, u_{k-1}) \quad (7)$$

得到 k 时刻样本的预测值 $s_k^{(i)}$ 。此时对权重的知识一无所知, 认为各个样本等权重。

在观测更新阶段要预测 $p(x_k | z_{0,k})$, 那么

$$w = \frac{p(x_k | z_{0,k})}{p(x_k | z_{0,k-1})} = \frac{\eta p(z_k | x_k) p(x_k | z_{0,k-1})}{p(x_k | z_{0,k-1})} = \eta p(z_k | x_k) \quad (8)$$

由式(6)可以得到:

$$\eta p(z_k | x_k) = \frac{Bel(x_k)}{Bel^-(x_k)} \quad (9)$$

可以看到, 虽然式(8)和式(9)表现形式不同, 但进行采样集合的权值更新的过程式(8)和观测更新的过程式(6)的本质是一样的。上面就是重要性系数即权重的推导过程。

对每个权值进行规范化:

$$w_i = p(z_k | s_k^{(i)}) / \sum_{j=1}^N p(z_k | s_k^{(j)}) \quad (10)$$

$p(z_k | s_k^{(i)})$ 即观测条件概率分布的 $p(x_k | z_k)$ 一个样本, 用 k 时刻的观测值 z_k 对当前时刻 k 的每个样本 $s^{(i)}$ 加以评价。其评价的原则就是: 与当前观测越接近的, 该样本的权值就越高, 在下一时刻即对后验概率采样时, 它被采样的机会就越大, 那么在新的样本集中该样本的个数会增多。在采样更新后, 利用重要性重采样使采样集中于真实的位姿附近区域, 得到采样分布 S 。经过若干次递归迭代, 可直接从加权采样集合中近似得出状态 x_k 。进行位姿估计时可采用简单平均、加权平均或者选择性加权平均方法。

MCL 的优势在于: (1) 与卡尔曼滤波定位法比较, 能够描述多峰分布, 可以近似大范围的概率分布, 可有效解决定位歧义及绑架情况; (2) 与基于栅格地图的 Markov 定位算法相比, 很大程度上减少了存储量和计算量, 能以更高频率融合测量信息, 比 Markov 定位算法具有更高的定位精度。

MCL 问题在于: (1) 采样枯竭问题。较大权值的粒子被多次选取, 采样包含了许多重复点, 从而损失了粒子的多样性; (2) 采样数目的确定。采样的数据过多会占用过多的计算资源, 但如果采样过少, 则难以保证对信度的有效描述; (3) 常规 MCL 不能解决机器人绑架问题。当机器人被绑架后, 原有的采样集合不包含新的位姿附近的采样, 则此时的重要性函数已经严重偏离当前的位姿分布, 采样集合已经不再是真实位姿分布的较好估计。

6 Bayes 滤波定位方法的新发展

有的学者为了弥补单独使用某种概率定位方法的缺陷, 将其进行了与其他方法的结合。Fox^[11] 提出了自适应采样数目的 Monte Carlo 方法, 其通过约束位姿概率分布的误差适时调整采样数目来反映位姿分布的变化。Pitt^[15] 提出了辅助粒子滤波 (APF), 引入了一个辅助变量设计建议分布。Shen^[16] 提出了 U 辅助粒子滤波 (UAPF) 算法, 其利用 UKF 近似 APF 预测似然, 在没有增加计算量的前提下提高了估计

精度, 跟踪性能超过 PF 和 APF。H. Kose 提出了一种逆蒙特卡罗方法进行定位^[17]。Thrun 提出的混合蒙特卡罗定位 (Mixture. MCL)^[12] 算法对解决全局定位及机器人绑架提供了一种新思路, 但要求传感器具有快速的采样能力。由于卡尔曼滤波和 Markov 方法是在 Bayes 推理的统一框架下, Markov-EKF 方法^[14] 将二者组合起来。由 Markov 方法维护整个位姿空间的概率分布, 实现多模态的全局定位, 而卡尔曼滤波则跟踪位姿假设以提高位姿估计的精度。洪炳镛等将蒙特卡罗方法与遗传算法相结合^[13], 确保了采样粒子的多样性, 同时相对减少了粒子的数目。

概率推理有效地解决了机器人感知、控制、建模中的数据不完整以及不确定性问题, 这种方法将在机器人研究中得到越来越深入、广泛的应用。

参考文献

- [1] Simmons R, Koenig S. Probabilistic Robot Navigation in Partially Observable Environments[C]//Proc. Int'l Joint Conf. Artificial Intelligence. 1995:1080-1087
- [2] Dellaert F, Fox D, Burgard W, et al. Monte Carlo Localization for Mobile Robots[C]//Proc. Int'l Conf. Robotics and Automation. 1999:1322-1328
- [3] Cox I J. Modeling a Dynamic Environment Using a Bayesian Multiple Hypothesis Approach[J]. Artificial Intelligence, 1994, 66(2):311-344
- [4] Burgard W, Fox D, Hennig D, et al. Estimating the absolute position of a mobile robot using position probability grids[C]//Proc. 14th National Conference on Artificial Intelligence. 1996:896-901
- [5] Currant A, Kyriakopoulos K J. Sensor-based self localization for wheeled mobile robots[J]. Journal of Robotic Systems, 1995, 12(3):163-176
- [6] Jensfelt P, Kristensen S. Active global localization for a mobile robot using multiple hypothesis tracking[J]. IEEE Trans. on Robotics and Automation, 2001, 17(5):748-760
- [7] Nourbakhsh I, Powers R, Birchfield S. DERVISH an officenavigating robot[J]. AI Magazine, 1995, 16(2):53-60
- [8] Burgard W, Cremers A, Fox D, et al. The Interactive Museum Tour-Guide Robot[C]//Proc. AAAI-98. 1998:11-18
- [9] Thrun S, Bennewitz M, Burgard W, et al. Minerva: A second-generation museum tour-guide robot [C]//Proc. IEEE Int'l Conf. Robotics and Automation. 1999:1999-2005
- [10] Doucet A. On sequential simulation-based methods for Bayesian filtering[R]. Department of Engineering, University of Cambridge, 1998
- [11] Fox D. Adapting the Sample Size in Particle Filters through KLD-Sampling[J]. Int'l J. Robotics Research, 2003, 22(12):985-1003
- [12] Thn S, Fox D, Burgard W. Monte carlo localization with mixture proposal distribution[C]//Proc. National Conference on Artificial Intelligence(AAAI). 2000:859-865
- [13] 洪炳镛, 罗荣华. 一种鲁棒移动机器人自主定位方法[J]. 哈尔滨工业大学学报, 2003, 35(9):1047-1049
- [14] Gutmann J S. Markov-kalman localization for mobile robots[C]//Proc. Int'l Conf. Pattern Recognition(ICPR02). Canada. 2002:601-604
- [15] Pitt M, Shephard N. Filtering via simulation: auxiliary particle filters[J]. Journal of the American statistical association, 1999, 94(446):590-599
- [16] Shen C H, van den H A, Dick A, et al. Enhanced importance sampling: unscented auxiliary particle filtering for visual tracking[C]//Proc. Australian Conference on Artificial Intelligence. Cairns, Australia, 2004:180-191
- [17] Kose H, Akin H L. The Reverse Monte Carlo localization algorithm[J]. Robotics and Autonomous Systems, 2007, 55(6):480-489