

引入分割团的BK推理算法及其在Robocup中的应用

张润梅^{1,2} 姚宏亮¹

(合肥工业大学计算机与信息学院 合肥 230009)¹ (安徽建筑工业学院电子与信息学院 合肥 230022)²

摘要 BK算法是动态贝叶斯网络(DBNs)的一种主要近似推理方法,但对网络的人工分割会引入较大误差。首先通过将决策结点转换成随机结点,给出基于DBNs的Robocup协作问题的一种建模方法;然后,给出一种引入分割团的新BK算法,以减小网络分割产生的误差,并对Robocup中的两个球员配合射门问题进行推理。引入分割团的BK算法和1.5片联合树推理算法的比较实验结果表明,引入分割团使BK算法在精度损失较小的情况下,时间性能有显著提高。

关键词 动态贝叶斯网络,近似推理,BK算法,1.5片联合树

中图分类号 TP181 **文献标识码** A

Separators Introduced BK Inference Algorithm and its Application in Robocup

ZHANG Run-mei^{1,2} YAO Hong-liang¹

(Department of Computer Science and Technology, Hefei University of Technology, Hefei 230009, China)¹

(School of Electronics and Information Engineering, Anhui University of Architecture, Hefei 230022, China)²

Abstract Boyen-Koller(BK) algorithm is the primary algorithm of approximate inference for DBNs, however, more error is introduced by the artificial division of the network. A new modeling means of cooperation problem in Robocup was given in this paper based on DBNs by converting the decision-making node into random node. Then a new BK algorithm introducing conditionally independent separators was presented for decreasing the error of inference, and was used to solve the problem of two Agent coordination shooting in Robocup. The results of inference experiment implemented on BK algorithm introducing separators and 1.5-slice junction tree algorithm show that time performance has improved significantly in the case that the accuracy loss is relatively low by introducing conditionally independent separators in BK algorithm.

Keywords Dynamic Bayesian networks, Approximate inference, BK algorithm, 1.5-slice junction tree

动态贝叶斯网络(Dynamic Bayesian Networks, DBNs)是传统的静态贝叶斯网络在时间演化过程上的扩展,以隐含马尔可夫模型(Hidden Markov Models, HMMs)和静态贝叶斯网络为基础^[1],是表示和处理具有随机过程性质的概率模型的一种有力的和灵活的方法。DBNs已在语音识别、手写体识别、人体姿势识别和交通工具的实时监控中获得了成功的应用。

动态贝叶斯网络推理是在给定一组证据变量的情况下,计算用户所关心的变量或变量集的概率分布^[2]。1.5时间片联合树算法是DBNs的一种精确推理算法,通过将联合概率分布表示成联合树中团结点的概率分布的乘积,可以有效地提高推理效率^[3],但由于算法将接口中的所有结点当成一个团,如果接口的规模太大,推理在计算上将变得难以处理。

Boyen-Koller(BK)算法是DBNs的一种主要近似推理方法^[4],利用参数方法来对系统状态变量的概率分布进行近似。BK算法人工地将系统划分成相对独立的子系统,整个系统

状态变量的概率分布表示成因式的形式,每个因式是关于每个子系统局部化的概率分布。因此BK算法可以较好地处理中等规模的动态问题,但由于BK算法是基于变量之间的弱相关性来生成相对独立的团(cluster),会引入较大的误差。

训练和制造机器人进行足球比赛,是当前人工智能和机器人领域的研究热点之一。创立机器人世界杯足球赛(Robocup)的目的就是为了通过足球这个具有普遍意义的平台,来评价各种理论、算法,从而促进相关领域的研究。Robocup已成为复杂动态环境中多Agent决策问题的一个理想的研究平台^[5]。本文首先通过将决策结点转换成随机结点,给出基于DBNs的Robocup协作问题的一种建模方法;然后,给出一种引入分割团的新BK算法,以减小网络分割产生的误差,并对Robocup中的两个球员配合射门问题进行推理。

1 动态贝叶斯网络(DBNs)

一个动态贝叶斯网络的模型由两部分确定:(1)一个先验

到稿日期:2008-11-14 返修日期:2009-02-16 本文受国家自然科学基金(60705015),安徽省自然科学基金(070412064),安徽省教育厅自然科学基金重点项目(KJ2009A020Z)资助。

张润梅(1971-),女,博士研究生,副教授,研究方向为人工智能和知识工程, E-mail: zhangrong@aiai.edu.cn;姚宏亮(1972-),男,博士,副教授,研究方向为人工智能和知识工程。

网络,就是一个已学习过的静态贝叶斯网络;(2)一个转移网络,它由两个时间片之间的转移连接和下一时间片中的贝叶斯网络两部分组成。对于初始时间片 $t=0$ 时,结点之间的边以及局部概率函数和先验网络相同。在时间片 $t-1$ 和时间片 t 之间的边由转移网络具体确定。与静态贝叶斯网络一样,动态贝叶斯网络的联合概率分布是建立在变量的条件独立性假设的基础之上^[6]。

设 $X = \{X^1, X^2, \dots, X^n\}$ 是 DBNs 的随机变量集, X_i^t 表示变量 X^i 在 t 时对应的随机变量。一个 DBN 由一个初始网 B_0 和一个转换网 B_{-} , 初始网 B_0 给出系统初始状态的网络结构和联合概率分布:

$$P(X_0) = \prod_{i=1}^n P(X_0^i | Pa(X_0^i))$$

转换网 B_{-} 表示 $t-1$ 时到 t 时状态变量集的转移概率 $P(X_t | X_{t-1})$ 。DBNs 在 $X = \{X^1, X^2, \dots, X^n\}$ 上的联合概率分布可以表示为:

$$P_B(X^1, \dots, X^n) = P_{B_0}(X_0) \prod_{i=0}^{T-1} P_{B_{-}}(X_t | X_{t-1})$$

2 球员配合射门问题建模

本文以禁区内两个球员配合射门为例构建动态贝叶斯网络。设有两个球员 Agent A 和 B 相互配合完成射门,其中 A 为控球队员, C 为守门 Agent, 这里将 C 看成环境变量, 其模型如图 1 所示。

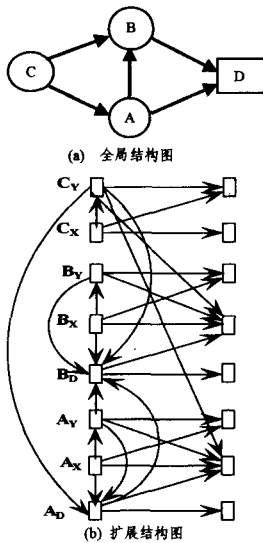


图 1

2.1 结构模型

初始全局动态贝叶斯网络结构如图 1(a) 所示, 其中: A, B 和 C 结点分别对应一个 Agent, D 为 A 和 B 的联合决策结点; 每个 Agent 都由多个变量组成, A 有状态、观察和决策变量, 分别用 A_x, A_y, A_d 表示; B 有状态、观察和决策变量, 分别用 B_x, B_y, B_d 表示; 由于设定 C 采取固定策略, 则 C 有状态变量和观察变量, 分别用 C_x, C_y 表示。

图 1(a) 中 A, B, C 之间的边表示决策依赖关系, 如 A 和 C 的状态直接影响到 B 的决策, 因而 A 和 C 都有指 B 的边; 另外, 图 1(a) 中的边不是表示单个变量之间的关系, 而是多个变量之间的关系, 如图 1(b) 中左侧结点之间的边。

DBNs 在 1.5 个时间片上的扩展结构如图 1(b) 所示, 其中左侧和右侧结点之间的边组成 DBNs 的转移网络, 左侧结

点之间的边对应图 1(a) 中去掉 D 结点后的内部结构; 右侧结点为左侧结点在时间上进行的一步扩展 (如左侧为 t 时 DBNs, 则右侧为 $t+1$ 时 DBNs), 其中右侧结点之间的结构和左侧相同, 为了清晰地表示 DBNs, 没有给出右侧结点之间的边, 只给出了 DBNs 在下一时间片中的接口结点, 因而图 1(b) 表示的是 1.5 个时间片的 DBNs。

2.2 概率模型

给定决策规则 d_i^t , 下面的式 (1) 是将决策变量 D_i^t 转换成随机变量的一种方法, 并表示了 D_i^t 的条件概率:

$$P_{d_i^t}(D_i^t | Pa(D_i^t)) = \begin{cases} 1 & \text{当 } d_i^t(Pa(D_i^t)) = d_i^t \\ 0 & \text{否则} \end{cases} \quad (1)$$

其中 d_i^t 是 Agent i 行为集中的一个行为。

由于式 (1) 给出了决策变量的概率分布, 则决策结点成为概率模型的组成部分。因而给定 σ_t , 随机变量集、观察变量集和决策变量集在 t 时的联合概率分布为:

$$P_{\sigma_t}(X_t, Y_t, D_t) = \prod_{x_i^t \in X_t} P(X_i^t | Y_{0:t}, D_{0:t}) \prod_{y_i^t \in Y_t} P(Y_i^t | Pa(Y_i^t)) \prod_{d_i^t \in D_t} P_{d_i^t}(D_i^t | Pa(D_i^t)) \quad (2)$$

其中 D_i^t 是第 i 个 Agent 的决策变量, 下标 $0:t$ 表示从时间 0 到时间 t 。式 (2) 所表示的概率模型是动态贝叶斯网络的一种扩展形式, 即将决策结点引入到动态贝叶斯网络中。

3 联合树

首先给出图的可分解性的相关定义:

定义 1 带弦图 G 是一个无向图, 图中任意一条长度大于 3 的环都是带弦的。环有弦是指在环中不相邻的两个结点, 它们在图 G 中相邻。

定义 2 (团, cluster) 团是一个最大无向完备图, 其中最大完备图是指图中每个结点和图中的其它结点都相连。带弦图中的每个不再被其他完备子图包含的完备子图对应一个团。

定义 3 (图 G 的正规化, moral) 在有共同子结点的两个结点之间添加一条无向边, 然后去掉所有边的方向的操作。

定义 4 (正规化图的三角化) 是指通过对正规化图进行结点消除生成一个带弦图的操作。包含长度大于 3 的带弦环的图, 将被三角化。

定义 5 联合树可定义为一个二元组 $T = (\Gamma, \Delta)$, 其中 Γ 是团的集合, Γ 中的两个团是通过 Δ 中团相连。对任意一对相邻团 C_i 和 $C_j, C_i \in \Gamma, C_j \in \Gamma, S_k \in \Delta, S_k$ 为 C_i 和 C_j 之间的一个分割团, 则有 $V_{S_k} = V_{C_i} \cap V_{C_j}$ 。

联合树生成过程^[7] (CJT) 可表示如下:

- (1) 对图 G 进行正规化 (moral) 化操作, 生成正规化图;
- (2) 对正规化图进行三角化操作, 得到一个三角化的图;
- (3) 将三角化的图变成联合树, 在直接相连的两团之间, 生成一个分割团, 通过所生成的分割团将它们相连。

定义 6 (势, potential) 是一个非负实函数 (可简称函数), 将变量或变量集的每个实例映射到一个非负的实数值上, 用 ϕ 表示。设 C 为联合树中的任意一个团, C 的概率函数的势 ϕ_C :

$$\phi_C = \prod_{x \in V_C} P(X | pa(X))$$

4 引入分割团的 BK 推理算法

BK 算法的基本思想是: 利用不同系统部分之间的弱交

互性,来人工地在弱交互的子系统之间强加独立性。BK算法将状态空间划分成子集, $W = \{W_1, W_2, \dots, W_k\}$, 其中 W_i 对应于一个子系统。整个系统的状态信度表示成因式的形式,每个因式是关于每个子系统局部化的信度。在 t 时刻信度状态的联合概率分布为:

$$P(X_t | Y_{0:t}, D_{0:t}) \approx \prod_w P(X_t^w | Y_{0:t}, D_{0:t})$$

其中 X_t^w 是 X_t 的一个子集。

4.1 BK算法中分割团的引入

由于传统的BK算法是根据DBNs结点之间弱相关性人工地对网络中的结点进行分割,会引入较大的误差,且通常这种人工划分的合理性常不能得到保证^[8]。因而,将相邻团结点之间的分割团引入到BK算法的推理过程中可以减小误差。

设图 G 的联合树 $T = (\Gamma, \Delta)$, 设 C_i 和 C_j 是 T 的两个邻接结点, 设 $\Gamma = \{C_1, \dots, C_n\}$ 是 T 的拓扑有序的结点, 当 $S_k = C_i \cap C_j$ 时, 有 $X_{S_k} = X_{C_i \cap C_j}$; 则根据条件独立性, G 的联合概率分布可以表示为:

$$\begin{aligned} P(X) &= \prod_i P(X_{C_i} | X_{C_1}, \dots, X_{C_{i-1}}) = \prod_i P(X_{C_i} | X_{C_{Pa(i)} \cap C_i}) \\ &= \prod_i \frac{P(X_{C_i})}{P(X_{C_{Pa(i)} \cap C_i})} = \frac{\prod_{C_i \in \Gamma} P(X_{C_i})}{\prod_{S_k \in \Delta} P(X_{S_k})} \end{aligned}$$

其中 $C_{Pa(i)}$ 为 C_i 团的父结点团。

根据上式,在引入分割团的条件下,多Agent系统的状态变量在 t 时的联合分布为:

$$\hat{P}(X_t | Y_{0:t}, D_{0:t}) \approx \frac{\prod_{C_i \in \Gamma_t} P(C_i | Y_{0:t}, D_{0:t})}{\prod_{S_k \in \Delta_t} P(S_k | Y_{0:t}, D_{0:t})}$$

4.2 原型联合树(Proto JT, PJT)

定义7(边际化, marg) 设变量集 $R \subseteq C$, 团 C 的概率函数为 ϕ_c , 则 R 的边际化操作为:

$$m \arg(C, R, \phi) = \sum_{V_{C \setminus R}} \phi_c$$

定义8 原型联合树GT中的结点由 Γ_t, F_t 和 Γ_{t+1} 组成。

变量 x 的家庭(family) f_x 由该变量和其父结点组成 $f_x = \{x \cup pa(x)\}$, 转移网络 V_t 中所有结点的家庭集为 $F_t = \{f_x | x \in V_t\}$, f_x 的概率函数为 ϕ_{f_x} , F_t 的概率函数为: $\Phi_t = \prod_{x \in V_t} \phi_{f_x}$ 。

原型联合树的构建过程:

- (1) 对一组变量的划分 $c = \{C_1, C_2, C_3, \dots, C_n\}$ 和一个时间片的贝叶斯网, 先将 B_0 生成一个的联合树 $J_0 = \{\Gamma_0, \Delta_0\}$;
- (2) 生成一个空原型联合树 G^T , 引入团的概念: 团 = $\{V_C | C \in \Gamma_t \cup \Gamma_{t+1}\} \cup F_t$;
- (3) 将团集 Γ 中所有团和 F_t 中的所有结点合并到 G^T 中;
- (4) 对于每个 $C_0 \in \Gamma_0$, 边际化: $\phi_{C_0} = m \arg(J_0, V_{C_0}, \phi)$, 同样对于每个 $S_0 \in \Delta_0$, 边际化: $\phi_{S_0} = m \arg(J_0, V_{S_0}, \phi)$;
- (5) 原型联合树 G^T 的初始概率函数为 $\Phi_{G^T} = \Phi_t$ 。

4.3 引入分割团的BK推理算法

引入分割团的BK算法的推理过程是:首先对DBNs的初始网络进行分解生成联合树(JT),然后由JT生成原型联合树(Proto JT, PJT),最后通过PJT上结点的边际化操作进行信息传播。

- (1) 构建原型联合树 G^T ;
- (2) 信息前向传播:

①将 F_t 中的概率函数 $\Phi_t = \prod_{x \in V_t} \phi_x$ 乘到 G^T 中;

②对于推理所用的联合树 J_0, t 从0开始;

③将 G^T 复制给一个过渡的原型联合树 G ;

④对于每个 $C \in \Gamma_t$, 有 $G = \frac{\prod_{C \in \Gamma_t} \phi_C}{\prod_{S \in \Delta_t} \phi_S} \Phi_t$;

⑤将 Y_{t+1} 引入到 G 中, 执行局部信息传递, 调整 G 使其达到新的一致状态;

⑥对每个 $C \in \Gamma_{t+1}$, $\phi_{C_{t+1}} = m \arg(G, V_{C_{t+1}}, \phi)$, 对于每个 $S \in \Delta_{t+1}$, $\phi_{S_{t+1}} = m \arg(J_0, V_{S_{t+1}}, \phi)$

⑦ $t = t + 1$ 返回到③。

5 实验结果

本文的实验是在VC++6.0环境下实现的,首先可视化构建了DBNs,其次实现了引入分割团的BK推理算法,并将引入分割团的BK算法与1.5片联合树推理算法进行了性能比较。

5.1 实验方案

(1) 可视化地构建DBNs

图1对应的DBNs如图2所示。




图2 一个可视化的DBNs

(2) 推理方式

分别按以下3种推理方式^[9]执行BK和1.5片联合树推理。

① 滤波。给定从初始到当前的所有证据,计算当前状态的后验概率分布。如,已知证据 $E_{1:t}$, 计算系统的后验概率分布 $P(X_t | E_{1:t})$ 。滤波是Agent根据当前系统状态对系统状态可能发生变化所进行估计的过程,是为Agent下一步的行为寻找到可靠的决策依据。

② 平滑。给定从初始到当前的所有证据,计算过去某一状态的后验概率。如,对某个 k 满足 $0 \leq k < t$, 计算 $P(X_k | E_{1:t})$ 。这实质上就是反向信息传播的过程。平滑是一个Agent利用已知的证据来更新自身的知识的过程。

③ 固定步长平滑。已知从初始到当前的所有证据情况下,按照固定步长 l 计算过去某一状态的后验概率。如,对某个 l 满足 $0 \leq l < t$, 计算 $P(X_{t-l} | E_{1:t})$ 。

(3) 参数设置

①查询结点为0,加入的证据结点均为1,状态也均为1,时间片定为10。

②引入分割团的BK推理算法中分团方案为 $\{2, 7\}, \{4\}, \{0, 1, 6\}, \{3\}, \{5\}$ 。

③分别将接口结点分成:1个团 $\{0, 1, 2, 3, 4, 5, 6, 7\}$; 3个团 $\{0, 1, 2\}, \{3, 4, 5\}, \{6, 7\}$; 8个团 $\{0\}, \{1\}, \{2\}, \{3\}, \{4\},$

(下转第234页)

分类系统仍可获得较高的识别精度。

实验中还发现:原始训练样本及重组训练用测试样本越多,得到对应每种情感的最优子 HMM 的可靠性越高,重组模型也越稳定;否则,当训练样本数量不是很多但达到一定数量时,分类系统中可能用到某些情感的次优特征向量,识别效果不是最理想,但相对于单特征向量分类器来说,整体性能仍得到提高。

参考文献

[1] Murray I, Amott J L. Towards the Simulation of emotion in Synthetic Speech: A review of the Literature on Human Vocal Emotion[J]. Journal of the Acoustic Society of American, 1993, 93 (2): 1097-1108

[2] Cowie R, Douglas-Cowie E, Tsapatsoulis N, et al. Emotion Recognition in Human-Computer Interaction [J]. IEEE Signal Processing magazine, 2001, 18(1): 32-80

[3] 赵力. 语音信号处理[M]. 北京:机械工业出版社, 2003

[4] Schuller B, Rigoll G, Lang M. Hidden Markov Model - Based

Speech Emotion Recognition[C]//ICASSP'03. 2003(2): 1-4

[5] Nwe T L, Foo S W, Silva L C D. Speech Emotion Recognition Using Hidden Markov Models [J]. Speech Communication, 2003, 41(4): 603-623

[6] Nogueiras A, Moreno A, Bonafonte A, et al. Speech Emotion Recognition Using Hidden Markov Models [A]// Eurospeech 2001 [C]. Scandinavia, 2001

[7] Lee C M, Yildirim S, Bulut M, et al. Emotion Recognition Based on Phoneme Classes [A]// ICSLP 2004 [C]. 2004: 889-892

[8] 谢波, 陈岭, 陈根才, 等. 普通话语音情感识别的特征选择技术 [J]. 浙江大学学报: 工学版, 2007, 41(11): 1816-1822

[9] Mao Xia, Zhang Bing, Luo Yi. Speech emotion recognition based on a hybrid of HMM/ANN [C]// The 7th WSEAS International Conference. 2007: 181-184

[10] Ortony A, Tunen T J. What's Basic About basic Emotions [M]. Psychological Reviews, 1997, 3: 315-331

[11] Chen Guanghua, Liu Junhai, Ye Jun. An improved method of endpoints detection based on energy-frequency-value [C]// IEEE Proceedings of HDP'06. 2006: 9-11

(上接第 216 页)

{5}, {6}, {7}。

(4) 数据处理

首先分别按 3 种推理方式对 DBNs 模型分别执行 BK 推理算法和 1.5 片联合树算法(JT)12 次,记录下各自的运行时间;去掉运行时间的最大值及最小值,将剩下的 10 组数据取其平均值,如表 1 所列。由表 1 可知, BK 算法在滤波、平滑和固定步长平滑的推理中的时间性能要明显好于 1.5 片联合树算法。由图 3 可知, 1.5 片联合树算法可以看成是 BK 算法的特殊情况,即当 BK 算法中将所有接口结点分为一个团时即成为 1.5 片联合树算法;且随着分团个数增加,误差逐步增加。

表 1 BK 算法与 1.5 片联合树算法时间性能比较表(时间单位:秒)

时间片	10	20	30	40	50	60	70	80	90	100	
过滤	JT	0.187	0.397	0.591	0.803	0.952	1.196	1.398	1.547	1.908	1.962
	BK	0.129	0.250	0.382	0.528	0.645	0.788	0.924	1.063	1.211	1.289
平滑	JT	0.156	0.329	0.496	0.664	0.822	1.008	1.146	1.336	1.510	1.695
	BK	0.122	0.240	0.350	0.474	0.586	0.710	0.841	0.965	1.077	1.218
固定步	JT	0.215	0.469	0.685	0.963	1.183	1.426	1.659	1.908	2.156	2.373
长平滑	BK	0.170	0.363	0.557	0.736	0.940	1.134	1.317	1.519	1.707	1.914




图 3 BK 算法精度分析

时间性能分析:

① 1.5 片联合树算法的时间复杂度 $O(M^I T)$ 。其中, M 表示状态变量最多能取到的值的个数, I 表示接口中所含的结点的个数, T 表示时间步骤。

② 引入分割团的 BK 推理算法的时间复杂度最少为 $O(T(M)^{\max(S(C_i)) + \max(F_{C_i}) + 1})$ 。其中, M 表示状态变量最多能取到的值的个数, F_{C_i} 是团 C_i 中变量的父结点数, $S(C_i)$ 表示 C_i

中所含结点数, T 表示时间步骤。

结束语 由于 DBNs 的推理是一个 NP 问题^[10], 因而近似推理是主要的推理方式, BK 算法是 DBNs 的一种主要近似推理算法。BK 算法人工地在弱交互的子系统之间强加独立性, 生成相对独立的团, 并将其转换成联合树, 进而通过联合树上结点之间的信息传播进行推理。为了减小 BK 算法的推理误差, 本文给出一种引入分割团的新 BK 算法, 并针对 Robocup 中的两个球员配合射门问题构建 DBNs, 分别利用引入分割团的 BK 算法和 1.5 片联合树算法对 DBNs 进行推理, 结果表明引入分割团使 BK 算法在精度损失较小的情况下, 时间性能有显著提高。

参考文献

[1] Murphy K. Dynamic Bayesian networks: representation, inference and learning [D]. University of California, Berkeley, 2002

[2] Jensen F V, Jensen F. Optimal junction trees [C]// Proc. of UAI-94. 1994: 360-366

[3] 周本达, 王浩, 姚宏亮. 1.5 片联合树算法在动态贝叶斯网精确推理中的应用 [J]. 计算机工程与应用, 2005, 41(14): 81-84

[4] Boyen X, Koller D. Tractable inference for complex stochastic processes [C]// Proc. of UAI-98. San Francisco: Morgan Kaufmann, 1998: 33-42

[5] 张润梅, 王浩, 姚宏亮. 一种基于影响图的决策方法及在 RoboCup 中的应用 [J]. 系统仿真学报, 2005, 17(1): 134-137

[6] Dechter R. Bucket elimination: A unifying framework for probabilistic inference [C]// Proc. of UAI-96. San Francisco: Morgan Kaufmann, 1996: 75-104

[7] Draper D. Clustering without (thinking about) triangulation [C]// Proc. of UAI-95. San Francisco: Morgan Kaufmann, 1995: 125-133

[8] Kjaerulff U. Reduction of computational complexity in Bayesian networks through removal of weak dependences [C]// Proc. of UAI-94. 1994: 374-382

[9] Paskin M A. Thin junction tree filters frontier for simultaneous localization and mapping [C]// Proc. of IJCAI-03. 2003: 1157-1164

[10] Dagum P, Luby M. Approximating probabilistic inference using Bayesian networks is NP-hard [J]. Artificial Intelligence, 1993, 60(1): 141-151