

# 动态贝叶斯网络一种自适应的 局部抽样粒子滤波算法\*

戚 围, 王 浩, 姚宏亮

(合肥工业大学 计算机与信息学院, 合肥 230009)

**摘 要:** 针对传统自适应粒子滤波(APF)对于动态贝叶斯网络推理中高维的问题,提出动态贝叶斯网络一种自适应的局部抽样粒子滤波算法(LSAPF)。LSAPF 算法将 BK 算法分团的思想引入到粒子抽样中,利用策略相关性和局部模型的弱交互性为指导对动态贝叶斯网络进行分割,以降低抽样规模和抽样的状态空间;进而对局部模型用自适应粒子滤波算法进行近似推理,并以粒子的因式积形式近似系统的状态信度。实验结果表明,该算法能很好地兼顾推理精度和推理时间,其性能优于普通 PF 算法;与 APF 算法相比,在不增加推理误差的情况下推理时间也有较大的提高。

**关键词:** 动态贝叶斯网络;局部抽样方法;自适应粒子滤波;粒子滤波;BK 算法

中图分类号: TP18; TP301.6

文献标志码: A

文章编号: 1001-3695(2010)04-1304-04

doi:10.3969/j.issn.1001-3695.2010.04.027

## Adaptive particle filtering for dynamic Bayesian networks inference based on local sample method

QI Wei, WANG Hao, YAO Hong-liang

(School of Computer Science & Technology, Hefei University of Technology, Hefei 230009, China)

**Abstract:** This paper proposed a local sample adaptive particle filtering (LSAPF) to resolve the high dimension problem of traditional adaptive particle filter for dynamic Bayesian networks inference. Based on particle sampling method, introduced the LSAPF algorithm the clusters idea of BK algorithm to. Aparated dynamic Bayesian networks under the guidance of strategic relevance and weak interaction of local model, so reduced the sampling model scale and state-space of sampling. Then used the APF algorithm to execute approximate inference for local model, represented the reliable state as a factor plot of particles. The experiment result shows that the LSAPF algorithm can make good choice between inference precision and inference time, and performs better than traditional particle filter algorithms. Especially compared with APF algorithm, the algorithm has greatly improved on inference efficiency without increasing inference error.

**Key words:** dynamic Bayesian networks(DBNs); local sample method; adaptive particle filtering; particle filter; BK algorithm

### 0 引言

动态贝叶斯网(dynamic Bayesian networks, DBNs)<sup>[1,2]</sup>是对认知科学和人工智能领域中动态不确定性问题进行表示和处理的一种重要工具,被广泛用于非线性、实时以及不确定性系统领域。在利用 DBNs 处理动态不确定性问题的过程中,随着网络规模的不断增大,精确推理的时间是难以预测的,因此常求助于近似推理方法<sup>[3]</sup>。近似推理算法分为有参推理算法和无参推理算法两类。Boyen-Kollen(BK)算法<sup>[4,5]</sup>是一种有参的近似推理算法,利用参数方法对系统信度状态进行近似。它可以很好地处理中等规模问题,但是有时生成的团(cluster)本身节点数较多时,推理在计算上也是一个高维问题。Hutter 等人<sup>[6]</sup>通过将 TJTF(thin junction tree filter)与 BK 这两种算法结合,提出条件 BK 算法,获得了一个优于 TJTF 的算法效率。粒

子滤波(particle filtering, PF)推理算法<sup>[7-13]</sup>是一种无参的近似推理算法,是一种常用的 Monte Carlo 抽样方法,它利用样本或粒子来近似状态变量的概率分布,已广泛应用于机动目标跟踪和定位、监控结构不断变化的不确定性系统、图像处理,以及信号传输与压缩等方面<sup>[4]</sup>。

PF 算法的优点在于它易于实现,对各种模型有很强的适应性,可以被用于混合模型、变状态空间模型,甚至变结构模型等。但 PF 在 DBNs 推理过程中抽样的粒子数目一般是固定的,要想获得好的推理精度就必须使用较多的样本数,这样 PF 的计算复杂性是粒子规模的指数问题,对于中等规模的问题,在计算上已变得不再可行。自适应粒子滤波算法(adaptive particle filtering, APF)<sup>[14,15]</sup>在推理过程中可以随着状态空间的变化而动态地改变粒子数目来提高推理效率,如果状态空间不确定性较低,该算法使用较少的粒子数;如果状态空间有很大的不确定性,该算法将使用较多粒子数目以提高推理性能。但

收稿日期: 2009-07-10; 修回日期: 2009-09-09 基金项目: 安徽省自然科学基金资助项目(070412064);合肥工业大学科学研究发展基金资助项目(070504F)

作者简介:戚围(1984-),男,安徽宿州人,硕士研究生,主要研究方向为人工智能(qiwei\_0828@163.com);王浩(1962-),男,教授,硕导,博士,主要研究方向为人工智能、数据挖掘、软件工程等;姚宏亮(1972-),男,副教授,硕导,博士,主要研究方向为人工智能、数据挖掘。

对于较大规模或较大的联合状态空间,该算法的推理精度还不是很很好。

本文提出了动态贝叶斯网络一种自适应的局部抽样粒子滤波算法(local sample adaptive particle filtering, LSA PF)。该算法引入 BK 算法分团的思想,利用策略相关性和局部模型的弱交互性为指导对动态贝叶斯网络进行分割,以降低抽样模型规模和抽样的状态空间;然后对不同内部相关性的局部模型用自适应粒子滤波算法来进行近似推理,并以粒子的因式积形式近似表示系统的状态信度;最后对 DBNs 的整个状态空间进行重采样和更新。虽然在分团过程中会产生误差,但当这种误差足够小时,该算法可以很好地提高推理精度。实验结果表明,该算法能很好地兼顾推理精度和推理时间,其性能与普通 PF 算法相比有较显著的提高,与 APF 算法相比,在不提高推理误差的情况下推理时间也有较大的提高。

### 1 动态贝叶斯网络

动态贝叶斯网络是贝叶斯网络在时间上的扩展,是表示复杂随机过程的有向图模型。设  $X, Y$  表示随机变量; $x, y$  表示随机变量的某个取值; $X, Y$  表示随机变量的集合。假定  $X = \{X_1, \dots, X_N\}$  是时态过程中发生变化的属性集, $X[t]$  表示属性集  $X$  在  $t$  时间片对应的随机变量集, $X_i[t]$  表示在  $t$  时间片对应的第  $i$  个随机变量。

一个 DBNs 由初始网  $B_0$  和转换网  $B \rightarrow$  组成:

1) 初始网  $B_0$  指定时态过程初始状态  $X[0]$  的概率分布  $p(X[0])$ 。

2) 转换网  $B \rightarrow$  对所有时间片  $0, 1, \dots, t$  指定  $t-1$  时刻到  $t$  时刻变量集状态的转移概率  $p(X[t+1]|X[t])$ 。

给定 DBNs  $B = (B_0, B \rightarrow)$ , 在  $X[0], X[1], \dots, X[T]$  上的联合概率分布可以简化为

$$P_B(X[0], X[1], \dots, X[T]) = P_{B_0}(X[0]) \prod_{t=0}^{T-1} P_{B \rightarrow}(X[t+1]|X[t]) \quad (1)$$

图 1(a) 是一个定义了三个状态变量  $A, B, C$  和三个观察证据  $y^A, y^B, y^C$  的动态贝叶斯网络的初始网和两个时间片转换网;(b) 是六个状态变量的 DBNs 展开三个时间片的相应贝叶斯网。




图1 动态贝叶斯网络

### 2 粒子滤波算法

#### 2.1 粒子滤波算法

PF 是一种常用的 Monte Carlo 方法,其基本思想是通过利用一组带权粒子或样本来近似状态的后验概率分布状态以对动态系统推理<sup>[9,10]</sup>。设  $\{x_i^t, i=1, \dots, N\}$  表示  $t$  时的粒子集,其对应重要性权值为  $\{w_i^t, i=1, \dots, N\}$ , 归一化权值  $\sum_i w_i^t = 1$ , 则  $t$  时刻的后验概率密度可离散加权近似为<sup>[7-12]</sup>

$$p(x_{0:t} | y_{1:t}) \approx \sum_{i=1}^N w_i^t \delta(x_t - x_i^t) \quad (2)$$

其中; $\delta$  为 Dirac delta 函数。粒子的生成和重要性权值  $w_i^t$  的计算重要性抽样原则为:在一般情况下很难对后验概率分布函数  $p(x)$  进行直接抽样,但可以借助一个易抽样的分布函数  $q(x)$ , 通常称  $q(x)$  为重要性密度函数或建议分布,因此,粒子的权值可以近似地表示为

$$w_i^t \propto \frac{p(y_{1:t} | x_{0:t}^i) p(x_{0:t}^i)}{q(x_{0:t}^i | y_{1:t})} \quad (3)$$

根据贝叶斯法则递推,计算  $q(x_{0:t} | y_{1:t})$ , 即

$$q(x_{0:t} | y_{1:t}) = q(x_{0:t-1} | y_{1:t-1}) q(x_t | x_{0:t-1}, y_{1:t}) \quad (4)$$

假设所有状态都符合马尔科夫过程,观察值条件独立于给定的状态,则有

$$w_i^t \propto \frac{p(y_{1:t} | x_{0:t}^i) p(x_{0:t}^i)}{q(x_{0:t}^i | y_{1:t}) q(x_t^i | x_{0:t-1}^i, y_{1:t})} = w_{i-1}^t \frac{p(y_t | x_t^i) p(x_t^i | x_{t-1}^i)}{q(x_t^i | x_{t-1}^i, y_{1:t})} \quad (5)$$

#### 2.2 自适应粒子滤波算法

自适应粒子滤波算法可有效解决粒子滤波的计算量问题,其基本思想是在估计过程中采样粒子数不再保持固定值,而是根据滤波性能动态改变<sup>[14,15]</sup>。下面说明如何决定样本数,使抽样的极大似然估计(maximum likelihood estimate, MLE)和真实后验不超出预先给定的界限  $\epsilon$ 。

本文在抽样中使用 KLD-抽样算法,MLE 与真实分布间的距离用 Kullback-Leibler(KL) 距离度量。KL-距离描述粒子滤波的近似误差,是用于表示不同概率分布  $p$  和  $q$  的差异,即

$$K(p, q) = \sum_x p(x) \log \frac{p(x)}{q(x)} \quad (6)$$

KL-距离是非负的,当且仅当两个分布相同时才会为零。

假设  $n$  个样本从一个有  $k$  个不同状态的离散分布中抽取,向量  $X = (X_1, \dots, X_k)$  指代从每个状态所抽取的样本数。 $X$  服从多项式分布,即  $X \sim \text{Multinomial}_k(n, p)$ 。其中  $p = p_1 \dots p_k$  指代每个状态的真实概率。在  $n$  个样本下, $p$  的极大似然估计可以通过  $\hat{p} = n^{-1} X$  得到。而且, $p$  的似然比统计量  $\lambda_n$  有如下关系:

$$\log \lambda_n = \sum_{i=1}^k X_i \log \left( \frac{\hat{p}_i}{p_i} \right) \quad (7)$$

因为  $X_i$  等同于  $n \hat{p}_i$ , 可得到

$$\log \lambda_n = n \sum_{i=1}^k \hat{p}_i \log \left( \frac{\hat{p}_i}{p_i} \right) \quad (8)$$

从式(6)~(8)可以看到,似然比统计量是 MLE 与真实分布间的 KL-距离的  $n$  倍。

$$\log \lambda_n = nK(\hat{p}, p) \quad (9)$$

可以得到似然比收敛于一个服从自由度为  $k-1$  的  $\chi^2$  分布:

$$2 \log \lambda_n \xrightarrow{n \rightarrow \infty} \chi_{k-1}^2 \quad (10)$$

用  $p_{\epsilon}(K(\hat{p}, p) \leq \epsilon)$  表示真实分布与基于抽样的 MLE 间的 KL-距离不超过  $\epsilon$  的概率(假设  $p$  是真实的分布)。这个概率与抽样样本数之间的关系可以从下面得到:

$$p_{\epsilon}(K(\hat{p}, p) \leq \epsilon) = p_{\epsilon}(2nK(\hat{p}, p) \leq 2n\epsilon) = p_{\epsilon}(2 \log \lambda_n \leq 2n\epsilon) \approx P(\chi_{k-1}^2 \leq 2n\epsilon) \quad (11)$$

式(11)遵循式(9)和(10)的收敛结果。 $\chi^2$  分布的分位数可由式(12)给出:

$$P(\chi_{k-1}^2 \leq \chi_{k-1, 1-\delta}^2) = 1 - \delta \quad (12)$$

选择适当的  $n$  使  $2n\epsilon$  等于  $\chi_{k-1, 1-\delta}^2$ , 可以组合式(11)和

(12)得到

$$p_p(K(\hat{p}, p) \leq \varepsilon) \approx 1 - \delta \quad (13)$$

现在就可以清楚得到样本数与结果近似精度之间的一个关系。概括而言,如果选择样本数  $n$  为

$$n = \frac{1}{2\varepsilon} \chi_{k-1, 1-\delta}^2 \quad (14)$$

就可以确保在给定的概率为  $1 - \delta$  下,MLE 与真实分布间的 KL-距离小于  $\varepsilon$ ,如式(13)所示。为了根据式(14)决定出  $n$ ,需要计算  $\chi^2$  分布的分位数。通过 Wilson-Hilferty 变换可以得到一个较好的近似:

$$n = \frac{1}{2\varepsilon} \chi_{k-1, 1-\delta}^2 \approx \frac{k-1}{2\varepsilon} \left\{ 1 - \frac{2}{9(k-1)} + \sqrt{\frac{2}{9(k-1)} z_{1-\delta}} \right\}^3 \quad (15)$$

其中:  $z_{1-\delta}$  是标准正态分布的上  $1 - \delta$  分位数。典型  $\delta$  的  $z_{1-\delta}$  值可以从标准的统计表中获得。

通常真实分布是难以获得的,从式(15)可以看出,事先并无需知道真实分布,在给定的  $\varepsilon$  和  $\delta$  后,只需确定抽样中状态数目  $k$ ,就可以得到当前所需的样本数  $n$ 。

### 3 自适应的局部抽样粒子滤波算法

PF 算法的计算量与粒子数成正比,且描述后验概率密度所需的粒子数随状态空间的增大而指数增加<sup>[16]</sup>,减少粒子采样空间的维数是提高算法效率的有效办法。APF 在推理过程中可以随着状态空间的变化而动态地改变粒子数目来提高推理效率。如果状态空间不确定性较低,该算法使用较少的粒子数;如果状态空间有很大的不确定性,该算法将使用较多粒子数目以提高推理性能。但对于较大规模或较大的联合状态空间,该算法的推理精度不是很高。通过引入 BK 算法分团的思想,对较大规模或较大的联合状态空间进行分割,可以在一定程度上提高推理精度。

LSAPF 算法的基本思想是将 BK 算法分团的思想引入到粒子抽样中,利用策略相关性和局部模型的弱交互性为指导对动态贝叶斯网络进行分割,以降低抽样规模和抽样的状态空间,进而对局部模型用自适应粒子滤波算法进行近似推理,并以粒子的因式积形式近似系统的状态信度;然后对 DBNs 的整个状态空间进行重采样和更新,从而算法的时间复杂度为 APF 在每个团上计算时间的线性问题,达到提高推理效率的目的。然而分团会引入一定的误差,这种误差已被证明在时间上是受限制的<sup>[4]</sup>。

**定义 1** 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  $\phi$  表示。

**定义 2** 团(cluster)是一个最大无向完备图。其中最大完备图是指图中每个节点与图中的其他节点都是相连的。对于团  $C$ ,团中的变量集为  $V_C$ ,团  $C$  的概率函数的势  $\phi_C$  为

$$\phi_C = \prod_{x \in V_C} P(X|pa(X)) \quad (16)$$

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 算法将状态空间分划成子集,  $W = \{W_1, \dots, W_k\}$ 。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<sup>[4,5]</sup>

$$P(X_t | Y_{0:t}, D_{0:t}) \approx \prod_W P(X_t^W | Y_{0:t}, D_{0:t}) \quad (17)$$

按照 BK 算法,利用策略相关性和局部模型的弱交互性为指导对动态贝叶斯网络进行分割,以降低抽样模型规模和抽样的状态空间。可以充分考虑分团引入的误差,选取合适的团个数和大小,保证人工分割的合理性。从形式上,DBNs 被分为一个团的集合  $C = \{C_1, C_2, \dots, C_k\}$ ,对每个团  $C_i$ ,节点集为  $\{X_1, X_2, \dots, X_m\}$ ,对应一个因式粒子的集合  $\{x_{t,c_i}^{(1)}, x_{t,c_i}^{(2)}, \dots, x_{t,c_i}^{(N_{c_i})}\}$ 。其中  $N_{c_i}$  是团  $C_i$  的粒子数目。每个时刻  $t$ ,对团  $C_i$  运用 APF 算法对其进行推理运算求出权值,并归一化其值。

下面是每个团运用的算法简单描述步骤:

- (1) Inputs: last time slice posterior belief  $S_{t-1} = \{ \langle x_{t-1}^{(i)}, \omega_{t-1}^{(i)} \rangle \mid i = 1, \dots, n \}$ , bounds  $\varepsilon$  and  $\delta$ , state size  $\Delta$
- (2)  $S_t := \emptyset$ ,  $n = 0$ ,  $k = 0$ , determine state and let b empty
- (3) do
- (4) Sample an index  $j$  from the discrete distribution given by the weights in  $S_{t-1}$
- (5) Sample  $x_t^{(n)}$  from formula (6) conditioned on  $x_{t-1}^{(j)}$  and  $y_t$
- (6) Use formula (7) to compute importance weight  $\omega_t^{(n)}$
- (7)  $S_t := S_t \cup \{ \langle x_t^{(n)}, \omega_t^{(n)} \rangle \}$
- (8) if  $(x_t^{(n)})$  falls into empty state in b) then
- (9)  $k := k + 1$
- (10) b := non - empty
- (11)  $n := n + 1$
- (12) while  $(n < (1/2\varepsilon) * \chi_{k-1, 1-\delta}^2)$
- (13) for  $i := 1, \dots, n$  do
- (14)  $\omega_t^{(i)} := \omega_t^{(i)} / \sum_j \omega_t^{(j)}$
- (15) return  $S_t$

再根据 BK 算法,系统状态信度用局部状态信度因式积表示,对每个团的后验概率近似分布执行求积操作,得到整个 DBNs 的后验概率近似分布。

## 4 实验结果与分析

### 4.1 实验环境

实验中选择的基本粒子滤波软件包是 Nando de Freitas 的 Rao-Blackwellised Particle Filtering for Dynamic Bayesian Networks matlab 软件包<sup>[13]</sup>,选用的 DBNs 如图 1 所示,实验环境是 Windows XP Professional, MATLAB 7.0, Celeron<sup>®</sup> CPU 2.66, 512 MB。

实验步骤如下:

a) 对 DBNs 中节点进行分割,充分考虑了节点间的弱相关性和分团可能引入的误差,以人工方式进行分团,将图 1(a) 所示的 DBNs 分别分割为  $\{A, B\}$ 、 $\{C\}$  或  $\{A\}$ 、 $\{B, C\}$  和图 1(b) 所示的 DBNs 分割为  $\{A, B, C\}$ 、 $\{D, E, F\}$ 。

b) 确定推理的时间步数和抽样粒子数目,设定时间步长为 50 个时间片,PF 用的粒子数分别取 100、300、500、700、900、1 100、1 300、1 500、1 700、1 900 个。

c) 取 LSAPF 和 APF 的  $\varepsilon = 0.02$ ,  $\delta = 0.97$ ,分别在相同粒子数下,运行 50 个时间步 PF、APF、LSAPF 程序,得出它们的时间平均  $L_1$  误差和算法推理时间关系数据。

d) 取 LSAPF 和 APF 的  $\varepsilon = 0.03$ ,  $\delta = 0.97$ ,作步骤 c)。

### 4.2 实验结果

图 2 为图 1(a) 的 DBNs 在粒子数目为 500 和时间步长为 50 时进行 50 次独立随机实验所得的时间平均  $L_1$  误差。




图2 APF和LSAPF的时间平均 $L_1$ 误差

LSAPF 和 APF 算法在实验中的实际粒子数目与设定的精度  $\varepsilon$  和  $\delta$  有关,在给定不同的 KL-距离界限下,LSAPF 和 APF 算法会根据 DBNs 的状态不确定性变化对粒子数目进行自动调整。如果当前状态比较简单,使用较少的粒子数;如果当前状态有很大的不确定性,就使用较多的粒子数,最终确保满足给定的  $\varepsilon$  要求(由于  $\varepsilon$  和  $\delta$  相比有很大的相似性,没有专门讨论  $\delta$  对性能的影响)。

从图2可看出,LSAPF 算法随时间的增长是收敛的。尽管该算法在分团时会引入一定的误差,但分团的同时也可以减少采样过程中的变化,从而提高了推理精度,并且在时间步长固定条件下,随着问题的规模扩大,LSAPF 的精度也会明显增加。

表 1 和 2 是固定时间步长为 50 的条件下,PF、APF、LSAPF 算法的推理时间。

表 1 LSAPF 和 APF 的  $\varepsilon=0.02, \delta=0.97$

粒子数	运行时间/s					
	图 1(a)			图 1(b)		
	PF	APF	LSAPF	PF	APF	LSAPF
100	0.407	2.609	2.203	2.219	52.015	49.226
300	1.078	2.612	2.016	3.828	51.912	49.157
500	1.734	2.422	1.797	5.078	50.219	48.000
700	2.469	2.281	1.718	6.609	48.797	46.484
900	3.112	2.153	1.712	8.391	47.102	45.578
1 100	3.897	2.134	1.697	9.750	46.297	43.937
1 300	4.547	2.187	1.750	11.391	43.437	40.563
1 500	5.078	2.188	1.735	13.165	40.328	37.500
1 700	5.765	2.136	1.689	14.437	37.235	34.516
1 900	6.341	2.112	1.683	17.359	36.719	33.718

表 2 LSAPF 和 APF 的  $\varepsilon=0.03, \delta=0.97$

粒子数	运行时间/s					
	图 1(a)			图 1(b)		
	PF	APF	LSAPF	PF	APF	LSAPF
100	0.39	1.718	1.357	2.213	28.512	26.531
300	1.125	1.578	1.251	3.821	28.171	26.756
500	1.656	1.647	1.344	5.161	28.547	26.396
700	2.344	1.563	1.252	6.385	26.031	24.591
900	3.141	1.578	1.256	8.173	24.375	22.296
1 100	3.819	1.587	1.219	9.993	22.094	20.112
1 300	4.343	1.594	1.259	11.047	19.109	17.269
1 500	5.141	1.516	1.281	12.922	16.797	15.215
1 700	5.535	1.609	1.250	14.453	17.047	15.719
1 900	6.516	1.546	1.281	17.987	16.969	15.078

从表 1 和 2 可以看出,PF 算法推理时间随着粒子数目的增加而线性地增加,而 APF 和 LSAPF 算法在  $\varepsilon$  和  $\delta$  值不同的情况下,其推理时间仍呈现稳定的趋势,不会随着粒子数目增加而变化很快,可以保持推理时间的稳定;而 LSAPF 算法在相同的情况下,与 APF 算法相比显著提高了计算效率,且推理精度也有一定的提高。由此可见,通过对 DBNs 的合理分割,从每个新生成的团中抽取粒子,有效减少了总体采样的规模和计算量,从而可以显著提高推理效率。

## 5 结束语

针对传统自适应粒子滤波(APF)对于动态贝叶斯网络推理中计算量太大的问题,本文提出动态贝叶斯网络一种自适应的局部抽样粒子滤波算法(LSAPF)。它基于粒子抽样方法的基本思想,引入 BK 算法分团的思想,利用策略相关性和局部模型的弱交互性为指导对动态贝叶斯网络进行分割,以降低抽样模型规模和抽样的状态空间,从而提高了推理的性能。实验结果表明,该算法能很好地兼顾推理精度和推理时间,其性能与 APF 算法相比,在保持推理误差的情况下,推理时间有较大的提高。

### 参考文献:

- [1] KUENZER A, SCHLIC C, OHMANN F, *et al.* An empirical study of dynamic Bayesian networks for user modeling[C]//Proc of UM2001 Workshop on Machine Learning for User Modeling, 2001:1-10.
- [2] MIHAJLOVIC V, PETKOVIC M. Dynamic Bayesian networks: a state of the art[R]. [S. l.]: University of Twente Document Repository, 2001.
- [3] MURPHY K. A brief introduction to graphical models and Bayesian networks[EB/OL]. (1998). <http://www.cs.ubc.ca/~murphyk/Bayes/bnintro.html>.
- [4] BOYEN X, KOLLER D. Tractable inference for complex stochastic processes[C]//Proc of the 14th Annual Conference on Uncertainty in Artificial Intelligence. Morgan Kaufman; [s. n.], 1998:33-42.
- [5] MURPHY K. Dynamic Bayesian networks: representation inference and learning[D]. Berkeley: Doctor of Philosophy Dissertation, University of California, 2002.
- [6] HUTTER F, BRENDA N G, DEARDEN R. Incremental thin junction trees for dynamic Bayesian networks[R]. [S. l.]: Intellectics Group, Darmstadt University of Technology, 2004.
- [7] SANJEEV M, MASKELL S. A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking [J]. *IEEE Trans on Signal Processing*, 2002, 50(2):174-188.
- [8] MURPHY K P, MIAN S. Modeling gene expression data using dynamic Bayesian networks[R]. Berkeley: Computer Science Division, University of California, 1999.
- [9] DOUCET A, GODSILL S, ANDRIEU C. On sequential monte carlo sampling methods for Bayesian filtering[J]. *Statistics and Computing*, 2000, 10(3):197-208.
- [10] 胡士强, 敬忠良. 粒子滤波算法综述[J]. *控制与决策*, 2005, 20(4):361-371.
- [11] 范典华. 粒子滤波[J]. *中山大学研究生学刊*, 2005, 26(2):22-32.
- [12] GORDON N J, SALMOND D J, SMITH A F M. Novel approach to nonlinear and non-Gaussian Bayesian state estimation[J]. *IEEE Proceedings on Radar and Signal Processing*, 1993, 140(2):107-113.
- [13] DOUCET A, De FREITAS N, MURPHY K P, *et al.* Rao-Blackwellised particle filtering for dynamic Bayesian networks[C]//Proc of the 16th Conference on Uncertainty in Artificial Intelligence. 2000:176-183.
- [14] FOX D. KLD-sampling: adaptive particle filters[C]//Proc of Advances in Neural Information Processing Systems 14(NIPS). 2001.
- [15] FOX D. Adapting the sample size in particle filters through KLD-sampling[J]. *The International Journal of Robotics Research*, 2003, 22(12):985-1003.
- [16] MACCORMICK J, ISARD M. Partitioned sampling, articulated object, and interface-quality hand tracking[C]//Proc of European Conference on Computer Vision. Dublin: [s. n.], 2000.