

一种改进的粒子滤波算法及其性能分析

曹洁, 李伟

CAO Jie, LI Wei

兰州理工大学 计算机与通信学院, 兰州 730050

College of Computer and Communication, Lanzhou University of Technology, Lanzhou 730050, China

CAO Jie, LI Wei. Improved PF algorithm and performance analysis. *Computer Engineering and Applications*, 2012, 48(8): 144-147.

Abstract: A new particle filter is proposed for the on-line estimation problem of non-Gauss nonlinear systems. In order to weaken the effect of historical information and enhance the effect of up-to-date measurement, it introduces attenuation memory factor for generating the important density function based on the Unscented Kalman filter(UKF) for a better performance in inhibiting the particle degradation problems in the new algorithm. As a result, the theoretical analysis and experimental results show that the new particle filter outperforms obviously superior to the standard particle filter and Unscented particle filter.

Key words: state estimation; particle filter; attenuation memory factor; important density function

摘要: 针对非线性、非高斯系统状态的在线估计问题, 提出了一种改进的粒子滤波算法。该算法采用 Unscented 卡尔曼滤波器(UKF)产生系统的状态估计, 并在量测更新过程中加入衰减记忆因子, 削弱滤波器对历史信息的依赖, 增强当前量测信息对滤波器的修正作用, 从而产生一个优选的建议分布函数, 较好地抑制了粒子退化问题。理论分析和实验表明: 引入记忆衰减因子的粒子滤波, 即衰减记忆无味粒子滤波(MAUPF)的性能明显优于标准的粒子滤波以及 Unscented 粒子滤波。

关键词: 状态估计; 粒子滤波器; 记忆衰减因子; 重要性概率密度函数

DOI: 10.3778/j.issn.1002-8331.2012.08.041 文章编号: 1002-8331(2012)08-0144-04 文献标识码: A 中图分类号: TP391

1 引言

非线性、非高斯随机系统的状态估计在现代信号处理、图像处理、计算机视觉以及自动控制等领域有着广泛的应用^[1-3]。长期以来, 针对非线性非高斯系统的估计问题, 各个领域的学者对此进行了广泛的研究。众所周知, 解决非线性滤波问题最为普遍的方法是扩展卡尔曼滤波器(Extended Kalman Filter, EKF), 但是该方法只适用于弱非线性的系统, 对于强非线性系统, 很容易导致滤波发散。由于近似非线性函数的概率密度分布比近似非线性函数容易得多, 使用采样方法近似非线性分布来解决非线性问题的途径在最近几年得到研究人员的广泛关注。在此基础上, 研究人员提出一种新的用于解决非线性滤波问题的滤波器, 称为 Unscented 卡尔曼滤波器(UKF)^[4-6]。实验证明 UKF 给出的估计结果比 EKF 更准确, 尤其是它能给出更精确的系统状态方差估计。但是, UKF 的使用具有一定的限制, 它不适用于一般的非高斯分布的模型。

粒子滤波(Particle Filter, PF)是一类随机模拟滤波器, 其理论基础是基于序贯重要性采样(Swquential Importance Sampling, SIS)的蒙特卡洛仿真^[7]。由于 PF 算法对系统和噪声的性质(线性/非线性、高斯/非高斯)没有过多的限制, 因此, 较之 EKF、UKF 算法具有更好的滤波性质^[8-9], 并越来越受到广大研究人员的关注。但是, 传统的 PF 算法是以转换先验密度函数作为重要性概率密度函数进行采样, 这种做法虽然计算量小、易于实现, 却忽视了观测值对状态估计的修正作用, 很容易引发 SIS 法则的快速退化并最终导致滤波发散。为克服传统 PF 算法的缺陷, 文献[10]提出了 UPF 算法, 该算法以 UKF 方法生成新的重要性概率密度函数并从中采样, 从而能够较好地利用观测值提供的信息, 有效提高滤波算法的性能。但是,

由于 UKF 滤波本身的增长记忆性, 随着观测时间的延长和系统复杂度的增加, 其计算量也在大幅增加, 同时, 最新量测信息的作用也在不断地减弱。

本文在 UPF 算法的基础上, 提出了一种新型粒子滤波算法, 称之为衰减记忆无味粒子滤波器(Memory Attenuation Unscented Particle Filter, MAUPF)。它在 UKF 的状态更新过程中引入记忆衰减因子, 增强对当前测量数据的利用, 以减少历史数据对滤波性能的影响。通过引入记忆衰减因子, 将非线性系统的最新量测信息加入更新过程, 产生更加真实的重要性概率密度函数, 从而有效克服重采样过程导致的粒子多样性丧失的缺陷。

2 问题提出与粒子滤波

2.1 问题提出

非线性、非高斯随机状态空间模型如下:

$$\begin{cases} x_t = f(x_{t-1}) + v_{t-1} \\ y_t = h(x_t) + w_t \end{cases} \quad (1)$$

其中 $x_t \in R^n$ 为系统在 t 时刻的状态, $y_t \in R^m$ 为系统状态 x_t 的量测; $v_{t-1} \in R^n$, $w_t \in R^m$ 分别为过程噪声和量测噪声; $f: R^n \rightarrow R^n$, $h: R^n \rightarrow R^m$ 为有界的非线性映射; m 和 n 分别为量测和状态的维数。

滤波的目的是在量测数据序列的基础上能够递推地估计出状态的后验概率分布 $p(x_t | y_{1:t})$, 特别是滤波概率分布 $p(x_t | y_{1:t})$, 其中 $x_{1:t} = \{x_1, x_2, \dots, x_t\}$, $y_{1:t} = \{y_1, y_2, \dots, y_t\}$ 。在滤波分布的基础上, 就可以实现系统状态的优化估计。

2.2 粒子滤波

粒子滤波算法(Particle Filter, PF)最先由 Gordon 在文献[7]

基金项目: 甘肃省自然科学基金(No.1010RJZA046); 甘肃省教育厅硕士基金项目(No.0914ZTB003); 甘肃省财政厅项目(No.0914ZTB148)。

作者简介: 曹洁(1966—), 女, 教授, 主要研究方向为智能交通系统、多传感器信息融合; 李伟(1982—), 男, 工程师。E-mail: lwyz815@163.com

收稿日期: 2010-09-27; **修回日期:** 2010-12-15; **CNKI 出版:** 2011-03-15; <http://www.cnki.net/kcms/detail/11.2127.TP.20110315.1622.003.html>

中提出,它为离散时间的递归滤波问题提供了一种近似的贝叶斯解决方法。粒子滤波采用重要性抽样(Importance Sampling)的方法,通过引入易于采样的重要性采样函数 $q(x_k|y_{1:k})$ 来逼近滤波概率密度 $p(x_k|y_{1:k})$ 。用 $\{x_k^i, w_k^i\}_{i=1}^N$ 表示从 $q(x_k|y_{1:k})$ 中抽取的支撑点集,则滤波概率密度 $p(x_k|y_{1:k})$ 可以表示为:

$$p(x_k|y_{1:k}) \approx \sum_{i=1}^N \omega_k^i \delta(x_k - x_k^i) \quad (2)$$

其中 $\omega_k^i \propto p(x_k^i|y_{1:k})/q(x_k^i|y_{1:k})$ 。粒子滤波采用序贯分析与重要性采样相结合的序贯重要性抽样算法,从重要性采样函数 $q(x_k|y_{1:k})$ 中获取支撑点集,并随着量测值的依次到来序贯计算粒子的权值,即:

$$\omega_k^i \propto \omega_{k-1}^i \frac{p(y_k|x_k)p(x_k|x_{k-1}^i)}{q(x_k|x_{k-1}^i, y_k)} \quad (3)$$

于是,任意函数 $g(x_k)$ 的最小均方误差(MMSE)估计可以用下式来逼近,即:

$$\hat{x}_k = E[g(x_k)|y_{1:k}] = \int g(x_k)p(x_k|y_{1:k})dx_k = \sum_{i=1}^N g(x_k^i)\omega_k^i \quad (4)$$

在粒子滤波算法中,序贯重要性采样步骤采用有限的离散粒子逼近连续的概率分布,粒子权值的方差随着时间递增,经过若干次迭代以后,除了极少数粒子外,其余的粒子归一化权值可以忽略不计,使得粒子集无法正确地描述后验概率分布,产生权值退化现象,影响了粒子滤波的性能。粒子滤波算法的退化程度可以通过有效粒子数 N_{eff} 来衡量:

$$N_{\text{eff}}(k) = \frac{N}{1 + \text{var}(\omega_k^*)} = \frac{N}{E(\omega_k^*)^2} \quad (5)$$

其中 $\omega_k^* = p(x_k^i|y_{1:k})/q(x_k^i|x_{k-1}^i, y_k)$ 。有效粒子数越小,表明权值退化现象越严重。克服退化现象最直接的方法就是增加粒子数,但是过多的粒子会降低粒子滤波算法运行效率,影响算法的实时性。选择合理的重要性函数是一种缓解退化现象的有效办法。

3 改进算法思路分析

3.1 UKF 算法

UKF是在U变换的基础上结合卡尔曼滤波算法对非线性非高斯状态进行估计。具体算法^[11]如下:

(1)初始化

$$\hat{x}_0 = E[x_0]$$

$$P_0 = E[(x_0 - \hat{x}_0)(x_0 - \hat{x}_0)^T]$$

(2)计算权值

$$W_0^{(m)} = \lambda/(n + \lambda)$$

$$W_0^{(c)} = W_0^{(m)} + (1 - \alpha^2 - \beta)$$

$$W_i^{(m)} = W_i^{(c)} = 1/2(n + \lambda)$$

(3)计算sigma点

$$\hat{x}_{0,k-1} = \hat{x}_{k-1}, k \in \{1, 2, \dots, +\infty\}$$

$$\hat{x}_{i,k-1} = \hat{x}_{k-1} + (\sqrt{(L + \lambda)P_{k-1}})_i, i = 1, 2, \dots, L$$

$$\hat{x}_{i,k-1} = \hat{x}_{k-1} + (\sqrt{(L + \lambda)P_{k-1}})_{i-L}, i = L + 1, L + 2, \dots, 2L$$

式中, $(\sqrt{(L + \lambda)P_{k-1}})_i$ 为矩阵 $\sqrt{(L + \lambda)P_{k-1}}$ 的第 i 行(或列)。

(4)时间更新

$$X_{k|k-1}^* = f[X_{k-1}, v_k]$$

$$\hat{x}_k = \sum_{i=0}^{2L} W_i^{(m)} X_{i,k|k-1}^*$$

$$P_k = \sum_{i=0}^{2L} W_i^{(c)} [X_{i,k|k-1}^* - \hat{x}_k][X_{i,k|k-1}^* - \hat{x}_k]^T + Q(k)$$

$$y_{k|k-1} = h[X_{k|k-1}]$$

$$\hat{y}_k = \sum_{i=0}^{2L} W_i^{(m)} y_{i,k|k-1}$$

(5)量测更新

$$P_{y_k y_k} = \sum_{i=0}^{2L} W_i^{(c)} [y_{i,k|k-1} - \hat{y}_k][y_{i,k|k-1} - \hat{y}_k]^T + R(k)$$

$$P_{x_k y_k} = \sum_{i=0}^{2L} W_i^{(c)} [x_{i,k|k-1} - \hat{x}_k][y_{i,k|k-1} - \hat{y}_k]^T$$

$$\kappa_k = P_{x_k y_k} P_{y_k y_k}^{-1}$$

$$\hat{x}_k = \hat{x}_k + \kappa_k (y_k - \hat{y}_k)$$

$$P_k = P_k - \kappa_k P_{y_k y_k} \kappa_k^T$$

式中, L 为状态向量维数, $Q(k)$ 是过程噪声的方差, $R(k)$ 是量测噪声的方差。因为UKF不需要计算线性化过程中的雅克比矩阵,不要求所处理的非线性函数可微,因此其处理非线性系统的能力很强,但是,它要求系统服从高斯分布,当系统不能满足这个条件的时候,UKF便不能应用,而粒子滤波可以解决这一问题,因此,很多学者研究将UKF和粒子滤波结合起来处理非线性非高斯系统。

3.2 UPF 算法

序贯重要性采样理论要求从后验概率密度函数中进行采样,这在实际的应用中是很难实现的。工程实践中,通常是从一个已知的、易于采样的重要性概率密度函数中采样。Doucet在文献[12]中已经证明, $p(x_i|x_{1:i}, y_i)$ 就是最优重要性概率密度函数。在实际情况中,得到最优的重要性概率密度函数的困难程度与直接从目标的概率分布中抽取样本的困难程度等同,但是从最优的重要性概率密度函数的表达式来看,产生一个预测样本依赖于已有的样本和最新的观测数据,这对于选择重要性概率密度函数有一定的指导意义。

为有效利用观测信息,文献[10-11]尝试由UKF方法产生重要性概率密度函数 $q_N(x_i^0|y_{1:i}) = N(x_i; \hat{x}_i^0, P_i^0)$ 并从中采样,这种改进的滤波算法被称为UPF,该滤波算法对粒子均值和方差的估计精度更高^[10]。但是在采样过程中,由于UKF自身对历史信息的增长记忆性,通过UKF产生的重要性分布最终将会导致滤波性能的降低,基于此,本文就如何降低UKF算法在生成采样粒子过程中对历史数据的依赖,提出了改进的UPF算法。

3.3 MAUPF 算法

由于UKF是增长记忆性滤波^[11],在系统的动态模型变化规律精确已知,且无需考虑计算误差的情况下,UKF能够给出一个随着量测信息的积累,精度不断提高的估计结果。但是在实际的动态系统中,模型的变化信息是很难完全掌握的。因此,随着系统的变化,必然导致相应参数的变化,而UKF在估计中还是按照没有变化的参数进行计算,直接导致了估计误差协方差的范数随着时间的增长不断减小,削弱了最新量测信息对状态估计的修正作用。而动态系统的最新量测包含了较为丰富的系统变化信息,因此,要增强滤波的稳定性和鲁棒性,必须增强最新量测信息对状态估计误差的修正作用,降

低历史信息对估计的影响程度。基于此,本文在生成重要性概率密度函数的步骤里面引入衰减因子 S ,生成优选的建议分布函数,构成衰减记忆UPF算法,也称作衰减记忆无味粒子滤波(MAUPF)。

例如,考虑采用 t_k 时刻的观测噪声协方差矩阵来表示 t_n 时刻的观测噪声协方差矩阵:

$$R_{n|k} = E(V_k V_k^T | t = t_n) = S^{n-k} R(k), n > k \quad (6)$$

这里, V_k 是 t_k 时刻的观测噪声, $R(k)$ 是 V_k 的协方差阵, S 是一个经验值,且 $S \geq 1$ 。上式表示,处于现在时刻的 t_n 把过去时刻 t_k 的观测噪声协方差阵 $R(k)$ 中的每个元素都放大了 S^{n-k} 倍。也就是说,使过去时刻的观测噪声协方差随着背离时间的增加,以数 S^{n-k} 倍增大,这就相当于随着观测时间的增加,逐渐放弃过去的量测信息,降低了滤波器对历史信息的依赖,更加准确地逼近系统状态的后验概率分布。该方法反映在具体的算法上就是在UKF算法的量测更新过程中引入衰减记忆因子 S ,即:

$$P_{y_k y_k} = S^{n-k} \sum_{i=0}^{2l} W_i^{(c)} [y_{i,k|k-1} - \hat{y}_{\bar{k}}] [y_{i,k|k-1} - \hat{y}_{\bar{k}}]^T + R(k) \quad (7)$$

MAUPF的具体算法实现步骤如下:

(1)初始化($k=0$)

$$x_0^i \sim p(x_0), \text{ 并令 } \omega_0^i = 1/N, i = 1, 2, \dots, N。$$

(2)重要性采样

对每一个采样点 x_{k-1}^i ,应用UKF算法得到 \hat{x}_k^i, P_k^i ,并在 P_k^i 的计算中引入衰减记忆因子 S 。

权值更新:

$$\omega_k^i = \omega_{k-1}^i \frac{p(z_k/x_k^i) p(x_k^i/x_{k-1}^i)}{q(x_k^i/x_{k-1}^i, z_{1:k})}$$

所得的重要性函数 $q(x_k^i/x_{k-1}^i, z_{1:k}) \sim N(\hat{x}_k^i, P_k^i(s))$,充分利用了最新的观察值,因而很好地改进了粒子采样的精度。

(3)重采样

对 $\{\hat{x}_k^i, i = 1, 2, \dots, N\}$ 进行重新采样,产生集合 $\{\hat{x}_k^i, i = 1, 2, \dots, N\}$,使得对于任意的 i ,都有 $P\{x_k^i = \hat{x}_k^i\} = \omega_k^i$,重新设定 $\omega_k^i = 1/N$ 。

(4)状态更新

$$x(k/k) = \sum_{i=1}^N x_k^i \omega_k^i$$

4 实验与分析

4.1 实验仿真

考虑到系统的非线性、非高斯性,本文采用了如下系统模型^[11]对PF、UPF和MAUPF三种滤波器的性能进行了比较分析。

$$\begin{cases} x_t = 1 + \sin(0.4\pi t) + 0.5x_{t-1} + v_{t-1} \\ y_t = \begin{cases} 0.2x_t^2 + n_t, & t \leq 30 \\ 0.5x_t - 2 + n_t, & t > 30 \end{cases} \end{cases} \quad (8)$$

其中,过程噪声 $v_{t-1} \sim \text{Gamma}(3, 2)$,量测噪声 $n_t \sim N(0, 0.00001)$,采用两个不同阶次观测模型对系统状态进行观测,观测时间为 $T=60$ 。实验中,系统状态的估计采用均值估计器,即:

$$\hat{x}_t = \frac{1}{N} \sum_{j=1}^N x_t^j \quad (9)$$

一次独立实验的均方误差定义为:

$$MSE = \left(\frac{1}{T} \sum_{t=1}^T (\hat{x}_t - x_t)^2 \right)^{1/2} \quad (10)$$

仿真实验1:为了检验衰减因子 S 的不同取值对滤波性能的影响,实验中,首先固定采样粒子数为 $N=100$, S 取不同的值,观察滤波的均方根误差,实验中UPF算法的 $RMSE=0.01175$,实验结果见表1。

表1 S 取不同值对 $RMSE$ 的影响表

S	1.05	1.1	1.2	2	2.5	3
$RMSE$	0.01080	0.00988	0.00869	0.00827	0.01061	0.01201

仿真实验2:取衰减因子为固定值 $S=2$,采样粒子数为 $N=100$,分别采用PF、UPF和MAUPF对系统的状态进行跟踪,仿真结果如图1所示;在相同条件下,用三种滤波进行50次独立仿真,所得的均方误差根曲线如图2所示,各滤波器均方误差的均值和方差如表2。




图1 系统状态估计

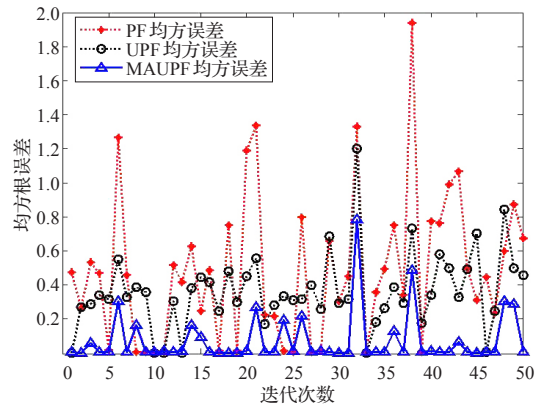


图2 均方根误差曲线

表2 均方误差的均值和方差

算法	均方误差	
	均值	方差
PF	0.428550	0.056933
UPF	0.069959	0.005880
MAUPF	0.031844	0.002551

4.2 实验结果分析

由表1中可以看出,引入衰减记忆因子以后,滤波器的性能有了明显改善,在 $S=2$ 时,改善的性能在实验中达到最佳状态,此时MAUPF的 $RMSE=0.00827$,远小于UPF的 $RMSE=0.01175$;由表2中可以看出,UPF、MAUPF的估计精度明显高于PF,主要是因为当观测模型的精度较高时,UPF与MAUPF在产生预测粒子时都不同程度地利用了系统的最新量测数据,而PF忽略了最新量测对系统状态的影响,因此,UPF和MAUPF对状态的估计精度明显高于标准的粒子滤波器的估

计精度,如图2所示。同样,由图2中可以看出,MAUPF的性能明显好于UPF,这主要是因为MAUPF引入衰减记忆因子有效降低了对过去信息的依赖,在产生预测粒子的过程中,增强了最新量测信息的作用;图1为三种粒子滤波器对系统状态进行一次独立实验结果,从图中可以看到:标准粒子滤波器的状态估计有时会严重偏离真实状态,而UPF与MAUPF所估计的状态能够较好地吻合真实轨迹,本文给出的粒子滤波器的估计效果要好于UPF和PF的估计效果。

5 结论

粒子滤波器在解决非线性非高斯滤波问题中已经取得了非常好的效果,但是粒子权值退化问题仍然是一个尚待解决的难题。综合以上论述与实验结果分析,本文提出的新型粒子滤波器——MAUPF,在采用UKF产生建议分布的同时,引入了衰减记忆因子,有效地削弱了滤波器对历史信息的依赖,增强了最新量测在滤波更新中的作用,得到了一种更加接近真实分布的近似表达,较好地克服了权值退化问题。实验结果表明,新算法明显优于标准粒子滤波算法和UPF算法。MAUPF算法的提出为非线性滤波问题提供了一种新的解决方法,在下一步的工作中,将用MAUPF算法解决说话人跟踪问题。

参考文献:

- [1] Kitagawa G. Monte Carlo filter and smoother for non Gaussian nonlinear state space models[J]. Journal of Computational and Graphical Statistics, 1996, 5: 1-25.
- [2] Avitzour D. A stochastic simulation Bayesian approach to multi-target tracking[J]. IEE Proc Radar, Sonar and Navigation, 1995.
- [3] Isard M, Blake A. Contour tracking by stochastic propagation of conditional density[C]//European Conference on Computer Vision, 1996: 343-356.

(上接121页)

效率。这是由于CBNS在收到新的协商请求时,会向CBR发送不同类型的信息以期得到CBR的控制和指导,CBR基于存储在案例库中的相似案例对协商过程进行控制和最大限度的规划,从而减少了网络数据传输的轮数和持续时间。

其他实验案例如驾驶执照案例(如图3),均表明CBNS协商机制相对于改进前提高了效率,验证了CBNS协商机制的高效性。

5 结论

CBNS提出了基于CBR的协商过程控制和计划机制。有效表达协商案例相关信息,即协商案例的表示、检索方法、案例的相似度及案例的联网查询功能等方面的内容还需要更多的研究工作。另外,协商模块和CBR推理模块间的主动通信时机以及如何运用CBR对协商过程的控制信息有待于更多的研究讨论。

参考文献:

- [1] Winsborough W H, Seamons K E, Jones V E. Automated trust

- [4] van der Merwe R, Doucet A, de Freitas N, et al. The unscented particle filter, CUED/F-INFENG/TR 380[R]. Engineering Department, Cambridge University, 2000.
- [5] Julier S J, Uhlmann J K. Unscented filtering and nonlinear estimation[J]. Proceedings of the IEEE, 2004, 92(3): 401-422.
- [6] Wan E A, Merwe R. The unscented Kalman filter for nonlinear estimation[C]//Proceedings of International Symposium on Adaptive Systems for Signal Processing, Communications and Control, Alberta, Canada, 2000: 153-158.
- [7] Gordon N J, Salmond D J, Smith A F M. Novel approach to nonlinear/non-Gaussian Bayesian state estimation[J]. IEE Proceedings on Radar and Signal Processing, 1993, 140(2): 107-113.
- [8] Gustafsson F. Particle filters for positioning, navigation, and tracking[J]. IEEE Transactions on Signal Processing, 2002, 50(2): 425-437.
- [9] Vo B N, Vo B T, Singh S. Sequential Monte Carlo methods for static parameter estimation in random set models[C]//SSNIP, 2004: 313-318.
- [10] Julier S J, Uhlmann J K. A new method for the nonlinear transformation of means and covariances in filters and estimators[J]. IEEE Trans on Automatic Control, 2000, 45(3): 477-482.
- [11] van der Merwe R, Doucet A. The unscented particle filter[M]//Advance in neural information processing systems. [S.l.]: MIT Press, 2000.
- [12] Julier S J, Uhlmann J K. A new approach for filtering nonlinear systems[C]//Proceedings of the 1995 American Control Conference, Seattle, WA, 1995: 1628-1632.
- [13] Doucet A, Godsill S J, Adrieu C. On sequential Monte Carlo sampling methods for Bayesian filtering[J]. Statistics and Computing, 2000, 10(3): 197-208.
- [14] Tam T, Zarbosky J. A practical non-driving filter[J]. AIAA Journal, 1970, 8(6): 1127-1133.

negotiation[C]//DARPA Information Survivability Conf and Exposition. New York: IEEE Press, 2000: 88-102.

- [2] 李建欣, 怀进鹏, 李先贤. 自动信任协商研究[J]. 软件学报, 2007: 124-133.
- [3] Lu H, Liu B. DFANS: a highly efficient strategy for automated trust negotiation[J]. Comput Secur, 2009, 28(7): 1-9.
- [4] He Yan, Zhi Miao. Liang. A complete and efficient strategy based on Petri net in automated trust negotiation[C]//InfoScale'07, Suzhou, China, 2007: 34-40.
- [5] 姚慧, 高承实, 戴青, 等. 一种基于树建模的自动信任协商策略[J]. 计算机工程与应用, 2008, 44(15): 127-130.
- [6] 孙天昊, 朱庆生, 李双庆, 等. 一种优化的基于增强学习协商策略[J]. 计算机工程与应用, 2008, 44(30): 24-25.
- [7] 曹东君. CBR系统和工具的研制开发[D]. 吉林: 吉林大学, 2001.
- [8] 李晓辉, 刘妍秀. 基于案例推理机制综述[J]. 长春大学学报, 2006, 16(4): 68-70.
- [9] 房文娟, 李绍稳, 袁媛, 等. 基于案例推理技术的研究与应用[J]. 农业网络信息, 2005(1): 13-17.
- [10] 孙锋. CBR中的相似算法[J]. 重庆工学院学报: 自然科学, 2008, 22(4): 67-72.