

文章编号: 1001-0920(2008)12-1333-05

基于粒子滤波的模型自适应机动目标跟踪算法

胡振涛, 潘 泉, 梁 彦, 程咏梅

(西北工业大学 自动化学院, 西安 710072)

摘 要: 针对当前机动目标跟踪领域中多模型算法存在的问题, 提出一种基于粒子滤波的模型自适应机动目标跟踪算法. 首先, 依据前一时刻每个粒子采用的模型状态和模型间的状态转移概率, 实现对当前时刻模型的采样; 然后, 将采样模型用于对当前粒子的预测, 并根据当前时刻得到的量测数据实现对预测粒子权值的度量; 最后, 通过重采样策略和概率最大化原则完成对模型的合理选择和状态的有效估计. 仿真实验验证了该算法的有效性.

关键词: 机动目标跟踪; 粒子滤波; 交互式多模型; 模型自适应

中图分类号: TP391

文献标识码: A

Model adaptive maneuvering target tracking algorithm based on particle filtering

HU Zhen-*tao*, PAN Quan, LIANG Yan, CHENG Yong-*mei*

(College of Automation, Northwestern Polytechnical University, Xi'an 710072, China. Correspondent: HU Zhen-*tao*, E-mail: guchenshou@yahoo.com.cn)

Abstract: Aiming at the existing problems of current multi-model algorithm for maneuvering target tracking, the paper proposes a model adaptive maneuvering target tracking algorithm based on particle filtering. Firstly, the algorithm achieves the sampling for current moment model according to the previous moment particle model information and the model transfer probability. Then, the prediction for current particle is accomplished by combining the model sampling result with state transfer equation, and the weight of prediction particle is measured based on current moment measurement. Finally, the re-sampling step and the principle of probability maximization are utilized to realize reasonable selection for model and effective estimation for state. Simulation results show the effectiveness of the algorithm.

Key words: Maneuvering target tracking; Particle filtering; Interacting multiple model (IMM); Model adaptive

1 引 言

在机动目标跟踪问题中, 针对目标机动形式的多样性和环境的复杂性, 建立能包含各种情况和各种类型机动的全局统计模型是不现实的, 因此一般采用多模型算法. 在此类方法中, 交互式多模型算法 (IMM)^[1,2] 较为优越. 然而, 采用模型“软切换”机制使该算法易在模型切换时刻造成较大的估计误差. 尤其对于非线性系统的估计, 采用标准 IMM 算法中次优滤波器 (EKF) 会进一步降低模型匹配和状态估计的精度^[3,4], 并且 EKF 不适用于非高斯噪声环境下的滤波估计. 但在对机动目标跟踪系统的建模中, 非线性非高斯情况是不可避免的. 文献[5]针

对 IMM 算法给出了一种改进方法, 即利用 UKF 滤波器替换标准 IMM 中的 EKF 滤波器. UKF 相对于 EKF 有更高的估计精度, 在一定程度上发展了 IMM 算法, 但 UKF 滤波器同样具有不适用于非高斯噪声环境的缺陷.

对于非线性系统的有效估计问题, 近几年兴起的粒子滤波给出了有效的解决办法. 理论上, 使用该算法可获得被估计对象的最小方差估计, 并且算法不受模型线性、高斯假设约束, 适用于任意非线性非高斯动态系统^[6,7], 因而得到了国内外专家学者的广泛关注. 文献[8]提出了将 IMM 算法与粒子滤波相结合的思想, 但这种简单的结合使粒子数成倍增

收稿日期: 2007-09-19; 修回日期: 2007-12-06.

基金项目: 国家自然科学基金重点项目 (60634030); 国家自然科学基金项目 (60702066); 中国航空工业第一集团公司航空基金项目 (2007ZC53037); 中国航天科技集团公司航天科技创新基金项目 (CASC0214).

作者简介: 胡振涛 (1979—), 男, 河南永城人, 博士生, 从事多源信息融合、非线性滤波的研究; 潘泉 (1961—), 男, 上海人, 教授, 博士生导师, 从事动态系统建模、多目标跟踪与识别等研究.

加,导致了计算量的骤增.文献[9]提出在粒子中同时融合状态信息与模型信息,进而提高状态估计的精度,但没有明确给出对于系统模型的辨识方法.

本文在粒子滤波的基本框架下,依据其特殊的预测和更新机制,给出了一种基于粒子滤波的模型自适应机动目标跟踪算法,并依据重采样策略和概率最大化原则完成对模型的合理选择.仿真实验结果表明,该算法能实现对模型的准确辨识和对机动目标状态的有效估计.

2 具有模型切换的离散时间非线性动态系统模型

考虑如下系统模型:

$$x_k = f(x_{k-1}, r_{k-1}) + (w_{k-1}, r_{k-1}), \quad (1)$$

$$y_k = h(x_k, r_k) + v_k. \quad (2)$$

其中: k 表示采样时刻; x_k 和 w_k 分别为系统的 n 维状态向量和过程噪声向量; y_k 和 v_k 分别为 m 维量测向量和量测噪声向量;初始状态 $x_0 \sim p(x_0)$, w_k 和 v_k 相互独立且与系统状态无关; r_k 为未知的模型状态,且满足离散时间、齐次、有限状态的一阶 Markov 链, $r_k \in \{R_1, R_2, \dots, R_M\}$, $R_s (s = 1, 2, \dots, M)$ 表示模型集中的模型, s 表示模型标号.模型间状态转移概率为 $p_{st} = Pr\{r_{t+1} = R_s / r_t = R_t\}$, $s, t = 1, 2, \dots, M$, $\sum_{s=1}^M p_{st} = 1$;初始概率分布 $U_s = P(r_0 = R_s)$; f, h 和 Σ 分别表示系统的状态演化函数、量测演化函数和过程噪声矩阵.

3 粒子滤波

状态估计的最终目标是根据状态的后验概率分布 $p(x_k / y_{1:k})$ 计算 x_k 的数学期望,其数学描述为

$$E[x_k] = \int x_k p(x_k / y_{1:k}) dx_k, \quad (3)$$

其中 $y_{1:k}$ 表示从初始采样时刻到当前采样时刻的量测序列.蒙特卡罗仿真原理提供了一种有效的离散化计算方法,即通过下式将式(3)的积分问题变化为离散点求和问题:

$$\bar{E}[x_k] = \frac{1}{N} \sum_{i=1}^N x_k^{(i)}. \quad (4)$$

根据大数定理,当 $N \rightarrow \infty$ 时, $\bar{E}[x_k]$ 将绝对收敛于 $E[x_k]$.然而,通常很难从 $p(x_k / y_{1:k})$ 中直接采样.一种解决办法是,从一个已知的易采样且接近后验概率分布的重要性概率分布 $q(x_k / y_{1:k})$ 中采样,并通过采样粒子进行加权来近似 $p(x_k / y_{1:k})$,有

$$p(x_k / y_{1:k}) = \frac{1}{Z} \sum_{i=1}^N \omega^{(i)}(x_k - x_k^{(i)}). \quad (5)$$

引入 $q(x_k / y_{1:k})$ 后,式(3)变为

$$E[x_k] = \int x_k p(x_k / y_{1:k}) q(x_k / y_{1:k}) dx_k.$$

$$\int x_k p(x_k / y_{1:k}) q(x_k / y_{1:k}) dx_k = \int x_k p(x_k / y_{1:k}) dx_k. \quad (6)$$

结合贝叶斯公式

$$p(x_k / y_{1:k}) = p(y_{1:k} / x_k) p(x_k) / p(y_{1:k}),$$

对式(6)进一步化简得

$$E[x_k] = \int x_k q(x_k / y_{1:k}) dx_k / \int q(x_k / y_{1:k}) dx_k, \quad (7)$$

其中 $\tilde{w}_k = p(y_{1:k} / x_k) p(x_k) / q(x_k / y_{1:k})$.

令 $x_k^{(i)}$ 表示从 $q(x_k / y_{1:k})$ 中抽取的 N 个独立同分布的粒子,由式(4)可得

$$\bar{E}[x_k] = \frac{1}{N} \sum_{i=1}^N \tilde{w}_k^{(i)} x_k^{(i)} / \sum_{i=1}^N \tilde{w}_k^{(i)} = \frac{1}{N} \sum_{i=1}^N \tilde{w}_k^{(i)} x_k^{(i)}, \quad (8)$$

其中 $\tilde{w}_k^{(i)}$ 表示归一化的权重.将上述原理以递推形式给出,成为序贯重要性采样,同时假设状态估计结果是最优的,则重要性分布只依赖于 x_{k-1} 和 y_k ,其选取形式如下:

$$q(x_k^{(i)} / y_{1:k}) = q(x_k^{(i)} / x_{k-1}^{(i)}, y_k) q(x_{k-1}^{(i)} / y_{k-1}). \quad (9)$$

此时权重的递推表达式为

$$\tilde{w}_k^{(i)} = \frac{\tilde{w}_{k-1}^{(i)} p(y_k / x_k^{(i)}) p(x_k^{(i)} / x_{k-1}^{(i)})}{q(x_k^{(i)} / x_{k-1}^{(i)}, y_k)}. \quad (10)$$

由式(10)可知,重要性分布的选取关键是如何合理选择 $q(x_k^{(i)} / x_{k-1}^{(i)}, y_k)$.对此,文献[10,11]给出了一种简单易操作的选取方式,即

$$q(x_k^{(i)} / x_{k-1}^{(i)}, y_k) = p(x_k^{(i)} / x_{k-1}^{(i)}). \quad (11)$$

获得粒子的权重后,为解决粒子退化问题需引入重采样步骤.所谓重采样即在评估粒子权值后,在维持粒子总数不变的条件下,删减权值低的粒子,复制权值高的粒子.目前,重采样方法主要有:残差重采样、系统重采样、多项式重采样等^[12].

4 基于粒子滤波的模型自适应机动目标跟踪算法

机动目标跟踪的前提是,所采用的滤波器能完成对状态进行估计的同时,有效地在线辨识系统模型.实际上,二者是一种相互依存的关系,仅在实现对模型有效辨识的条件下,才能保证对本时刻状态较好的估计,而获取较好的状态估计结果,又进一步为下一时刻模型的辨识提供了有力保障.

4.1 算法描述

对上述粒子滤波过程的分析发现,该算法首先根据状态转移模型完成对粒子的预测;然后,基于当前时刻的量测值实现对预测粒子权重的评估;最后,通过重采样步骤完成对预测的更新.这种基于蒙特卡罗仿真原理独特的预测更新方式,为实现实时模

型辨识和状态估计提供了可行性. 这里仍然以粒子滤波的基本框架为基础, 首先, 根据前一时刻每个粒子采用模型状态和模型间的状态转移概率实现对当前时刻模型的采样, 即根据先验信息完成对模型的预测; 然后, 将采样模型结合其相应的粒子, 并依据状态转移模型完成对当前时刻粒子的预测, 此时预测粒子中不仅包含状态信息, 也包含了粒子所采用的模型信息; 再后, 通过当前时刻获取的量测信息实现对预测粒子权重的度量, 最后, 利用以权值为基准的重采样过程实现对模型的在线辨识和状态的可靠估计. 基于以上思想, 式(9) 表示为

$$q(x_k^{(i) \sim s(k,i)} / y_{1:k}) = q(x_k^{(i) \sim s(k,i)} / x_{k-1}^{(i) \sim s(k-1,i)}, y_k) q(x_{k-1}^{(i) \sim s(k-1,i)} / y_{k-1}). \tag{12}$$

其中: $s(k, i)$ 表示 k 时刻第 i 个粒子所采用的模型状态的标号, 它由 $s(k-1, i)$ 和模型转移概率通过对模型集进行采样得到, 具体方法如下:

已知 $r_{k-1}^{(i)} = R_{s(k-1,i)}$, 从 $[0, 1]$ 的均匀分布中采样 u , 若满足 $\sum_{t=1}^{s(k,i)-1} r_{k-1}^{(i), t} < u \leq \sum_{t=1}^{s(k,i)} r_{k-1}^{(i), t}$, 则 $r_k^{(i)} = R_{s(k,i)}$. $x_k^{(i) \sim s(k,i)}$ 表示 k 时刻采用 $s(k, i)$ 所对应模型状态的第 i 个粒子. 将式(12) 代入粒子滤波的递推公式可得权值的表达式

$$\tilde{w}_k^{(i)} = \frac{\tilde{w}_{k-1}^{(i)} p(y_k / x_k^{(i) \sim s(k,i)}) p(x_k^{(i) \sim s(k,i)} / x_{k-1}^{(i) \sim s(k-1,i)})}{q(x_k^{(i) \sim s(k,i)} / x_{k-1}^{(i) \sim s(k-1,i)}, y_k)}. \tag{13}$$

由式(11) 可得

$$q(x_k^{(i) \sim s(k,i)} / x_{k-1}^{(i) \sim s(k-1,i)}, y_k) = p(x_k^{(i) \sim s(k,i)} / x_{k-1}^{(i) \sim s(k-1,i)}). \tag{14}$$

权值的表达式进一步简化为

$$\tilde{\alpha}_k^{(i)} = \tilde{\alpha}_{k-1}^{(i)} p(y_k / x_k^{(i) \sim s(k,i)}). \tag{15}$$

利用式(15) 得到粒子的权值后, 对其进行归一化处理, 并以归一化处理后的结果为基准实现重采样过程, 进而获得采样更新后的重采样粒子 $\bar{x}_k^{(i)}$ 和对应的模型 $\bar{s}(k, i)$. 此时, 可依据概率最大化原则实现对模型的在线辨识, 其概率计算表达式为

$$P(r_k = R_t) = \frac{\sum_{i=1}^N (t - \bar{s}(k, i))}{N}, \quad t = 1, 2, \dots, M, \tag{16}$$

其中 $P(r_k = R_t)$ 表示 k 时刻模型集中标号为 t 所对应模型为真实模型的概率, 当前时刻系统的模型即取模型集中模型概率最大的模型. 由粒子滤波器的收敛性结论, 当粒子个数趋于无穷大时, 状态的最小均方误差估计收敛于真实状态的后验均值, 因此 $\text{Max}\{P(r_k = R_t)\}$ 也将趋于 1, 从而实现对模型的准

确辨识和对状态的精确估计. 最终状态估计为

$$\hat{x}_k = \frac{1}{N} \sum_{i=1}^N \tilde{x}_k^{(i) \sim s(k,i)}. \tag{17}$$

4.2 算法步骤

Step 1: 起始.

$k = 0;$

FOR $i = 1, 2, \dots, N$

根据初始模型概率密度 $P_r(r_0)$, 通过对模型集采样获得模型样本的初始值 $R_{s(0,i)} \sim P_r(r_0)$; 基于初始状态概率密度 $p(x_0)$ 和模型样本信息获得粒子的初始值 $x_0^{(i) \sim s(0,i)} \sim p(x_0)$;

END FOR

Step 2: 递推循环.

FOR $k = 1, 2, \dots$

FOR $i = 1, 2, \dots, N$

模型抽样 $s(k, i) \sim P_r(r_k^{(i)} / r_{k-1}^{(i)})$; 附带模型信息的粒子抽样 $x_k^{(i) \sim s(k,i)} \sim q(x_k^{(i) \sim s(k,i)} / x_{k-1}^{(i) \sim s(k-1,i)}, y_k)$; 根据式(15) 计算粒子的权值 $\tilde{w}_k^{(i)}$;

END FOR

对权值进行归一化处理得到 $\tilde{w}_k^{(i)}$; 重采样后得到相应的粒子 $\bar{x}_k^{(i)}$ 和模型 $\bar{s}(k, i)$; 依据模型概率最大化原则实现对模型的辨识; 通过式(17) 实现对状态的估计;

END FOR.

5 仿真结果与分析

为验证本文算法对于多模型非线性系统状态估计的有效性, 给出单维和多维两个仿真算例. 例 1 中分别采用文献[13] 和文献[10] 给出了两种典型的单维非线性模型; 例 2 中给出单部检测概率为 0.92 的 3 坐标雷达实现机动目标的仿真实例, 目标的机动通过 CV 与 CA 模型之间的模型切换实现.

例 1 模型(1) 的系统状态方程和量测方程为

$$\begin{aligned} x_{k+1} &= 0.5x_k + \sin(0.04k) + 1 + w_{1,k}, \\ y_k &= x_k^2/5 + v_k; \end{aligned}$$

模型(2) 的系统状态方程和量测方程为

$$\begin{aligned} x_{k+1} &= 0.5x_k + 25[x_k/(1+x_k^2)] + 8\cos(1.2k) + w_{2,k}, \\ y_k &= x_k^2/20 + v_k. \end{aligned}$$

其中: $w_{1,k} \sim \text{Gamma}(3, 2)$; $w_{2,k} \sim N(0, 0.5)$; $v_k \sim N(0, 1)$. 模型初始概率 $u_1 = 0.5, u_2 = 0.5$, 模型转

移概率 $P = \begin{bmatrix} 0.9 & 0.1 \\ 0.1 & 0.9 \end{bmatrix}$, 粒子数取 100, 仿真时间为

50 拍, 采样周期 $T = 1$, 模型切换设置为: 1 ~ 20 拍模型(1) 作用, 21 ~ 40 拍模型(2) 作用, 40 ~ 50 拍模型(1) 作用. 仿真结果如图 1 所示.

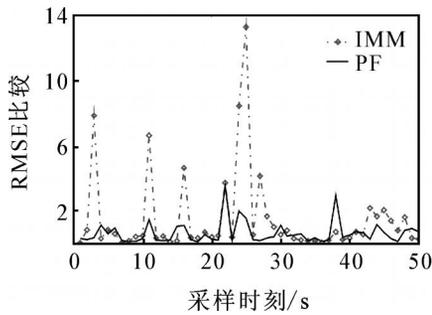


图 1 RMSE 比较

图 1 给出了利用 IMM 算法和基于 PF 的模型自适应算法在 50 次 Monte Carlo 仿真环境下得到的均方根误差 (RMSE) 比较. 可以看到, 由于模型 (1) 中系统过程噪声采用非标准高斯噪声以及模型 (2) 的强非线性, 而标准 IMM 中 EKF 算法要求系统满足弱非线性且噪声为高斯型假设条件, 从而无法有效地处理这两种情况的滤波问题, 使得 IMM 算法的滤波精度明显不如本文算法.

例 2 系统的状态方程和量测方程为

$$X_k = \begin{cases} F_1 * X_{k-1} + w_{1,k-1}, & k < 40; \\ F_2 * X_{k-1} + w_{2,k-1}, & 40 \leq k < 60; \\ F_1 * X_{k-1} + w_{1,k-1}, & 60 \leq k \leq 100; \end{cases}$$

$$Z_k = \begin{bmatrix} \sqrt{x_k^2 + y_k^2 + z_k^2} & \text{tg}^{-1} \frac{y_k}{x_k} & \text{tg}^{-1} \frac{z_k}{\sqrt{x_k^2 + y_k^2}} \end{bmatrix}^T + v_k.$$

其中: $F_n = \begin{bmatrix} f_n & 0 & 0 \\ 0 & f_n & 0 \\ 0 & 0 & f \end{bmatrix}$, $n = 1, 2$. 这里

$$f_1 = \begin{bmatrix} 1 & t & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}, f_2 = \begin{bmatrix} 1 & t & t^2/2 \\ 0 & 1 & t \\ 0 & 0 & 1 \end{bmatrix},$$

$$f = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}.$$

采样周期 $t = 1$ s, 目标的匀加速运动时加速度为 8 m/s^2 , 模型初始概率 $u_1 = 0.5, u_2 = 0.5$, 模型转移概率 $P = \begin{bmatrix} 0.9 & 0.1 \\ 0.1 & 0.9 \end{bmatrix}$. 粒子数取 1000, 系统过程噪声方差 $Q_1 = \text{diag}([0.01 \ 0.01 \ 0.01])$, $Q_2 = \text{diag}([100 \ 100 \ 100])$, 量测噪声方差 $R = \text{diag}([100 \ 0.8 \ 0.8])$. 在基于 50 次 Monte Carlo 仿真的环境下, 分别对 IMM, IMMPF 及本文算法进行仿真结果比较.

图 2 ~ 图 5 分别表示基于 IMM, IMMPF 以及本文的基于 PF 的模型自适应算法得到在 X 和 Y 轴方向上位置和速度分量的 RMSE 结果比较; 另外, 3 种算法单次仿真条件下的耗时分别为 0.078 s,

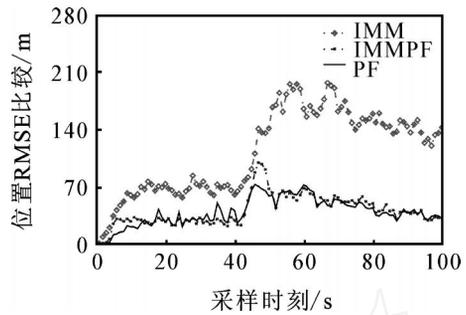


图 2 X 轴方向位置 RMSE 比较

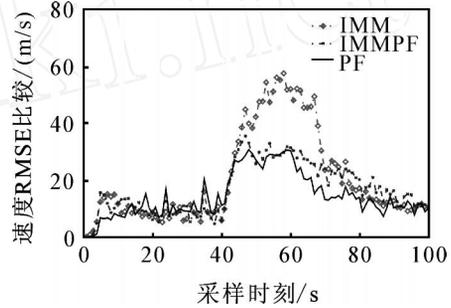


图 3 X 轴方向速度 RMSE 比较

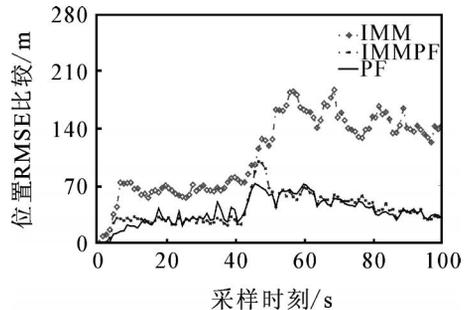


图 4 Y 轴方向位置 RMSE 比较

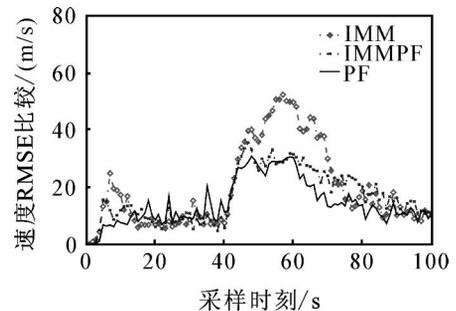


图 5 Y 轴方向速度 RMSE 比较

24.250 s 和 59.5150 s. 由仿真结果可知, IMM 算法虽有较好的实时性, 但次优滤波器使用过程中产生的误差累计效应造成了模型匹配偏差的递增, 最终导致滤波发散, 出现严重的目标失跟现象. 而本文算法实现了对目标的有效跟踪, 并且对于量测噪声的压缩效果达到了 60%, 另外, 在实时性和滤波精度方面优于 IMMPF 算法. 这主要因为本文算法中采样粒子不仅包含了状态信息, 而且也包含模型状态信息, 相对于 IMMPF 算法, 这种处理方式并未带来粒子数目的增加; 并且, 粒子蕴含信息的多样性也在很大程度上缓解了重采样引起的粒子多样性减弱造成的粒子溃退现象, 进一步增强了粒子的稳定性和

状态估计的精度.

6 结 论

本文提出了一种基于粒子滤波的模型自适应机动目标跟踪算法.在粒子滤波算法框架下,将模型信息引入到粒子的采样中,实现了对模型的准确辨识,进而提高了状态估计的精度.同时,该算法不受模型非线性条件的限制,可有效解决一些 IMM 算法失效的情况:高度非线性运动模型,高度非线性测量模型及各种机动目标的跟踪.另外,在实时性和精度方面本文算法也优于 IMMPF 算法.

参考文献(References)

- [1] Johnston L A, Krishnamurthy V. An improvement to the interacting multiple model (IMM) algorithm [J]. IEEE Trans on Signal Processing, 2001, 49(12): 2909-2923.
- [2] Derbez E, Remillard B, Jouan A. A comparison of fixed gain IMM against two other filters[C]. Proc of 2000 Int Conf on Information Fusion. Paris, 2000: 10-13.
- [3] 梁彦,程咏梅,贾宇岗,等.交互式多模型算法性能分析[J].控制理论与应用,2001,18(4):487-492.
(Liang Y, Chen Y M, Jia Y G, et al. Analysis on the performance and properties of interacting multiple models algorithm[J]. Control Theory and Applications, 2001, 18(4): 487-492.)
- [4] Kirubarajan T, Bar-Shalom Y. Kalman filter versus IMM estimator: When do we need the latter[J]. IEEE Trans on Aerospace and Electronic Systems, 2003, 39(4): 1452-1457.
- [5] Lenon C, Rodney W. Sensor fault detection for UAVs using a nonlinear dynamic model and the IMM-UKF algorithm[C]. 2007 Information, Decision and Control. Adelaide, 2007: 1-6.
- [6] Doucet A, Godsill S J, Andrieu C. On sequential Monte Carlo sampling methods for Bayesian filtering [J]. Statistics and Computing, 2000, 10(3): 197-208.
- [7] Andrieu C, De Freitas N, Doucet A, et al. An introduction to MCMC for machine learning [J]. Machine Learning, 2003, 50(1/2): 5-43.
- [8] Boers Y, Driessen J N. Interacting multiple model particle filter[J]. IEE Proc of Radar Sonar Navigation, 2003, 150(5): 334-349.
- [9] Doucet A, Gordon N J, Vikram K. Particle filters for state estimation of jump Markov linear systems [J]. IEEE Trans on Signal Processing, 2001, 49(3): 613-624.
- [10] Gordon N J, Salmond D J, Smith A F M. Novel approach to nonlinear/non Gaussian Bayesian state estimation[J]. IEE Proc of Radar Signal Process, 1993, 140(2): 107-113.
- [11] Gordon N J. A hybrid bootstrap filter for target tracking in clutter[J]. IEEE Trans on Aerospace and Electronic Systems, 1997, 33(3): 353-358.
- [12] Liu J S, Chen R. Sequential Monte Carlo methods for dynamic systems [J]. J of the American Statistical Association, 1998, 93(443): 1032-1044.
- [13] Doucet A, Godsill S. On sequential Monte Carlo sampling methods for Bayesian filtering [R]. Cambridge: Department of Engineering University of Cambridge, 1998.

(上接第 1332 页)

- [4] Zou Q Y, Jiang C S, Wu D. Evolutionary fuzzy guidance law with self-adaptive region[J]. Transactions of Nanjing University of Aeronautics & Astronautics, 2004, 21(3): 234-240.
- [5] Mukherjee V, Ghoshal S P. Intelligent particle swarm optimized fuzzy PID controller for AVR system [J]. Electric Power System Research, 2007, 77(12): 1689-1698.
- [6] Kao C C, Chuang C W, Fung R F. The self-tuning PID control in a slider-crank mechanism system by applying particle swarm optimization approach[J]. Mechatronics, 2006, 16(8): 513-522.
- [7] 郝万君,强文义,柴庆宣,等.基于粒子群优化的一类模糊控制器设计[J].控制与决策,2007,22(5):585-588.
(Hao W J, Qiang W Y, Chai Q X, et al. Design of fuzzy controller based on particle swarm optimization [J]. Control and Decision, 2007, 22(5): 585-588.)
- [8] Van den Bergh F, Engelbrech A P. A cooperative approach to particle swarm optimization [J]. IEEE Trans on Evolutionary Computation, 2004, 8(3): 225-239.
- [9] 曾建潮,崔志华.一种保证全局收敛的 PSO 算法[J].计算机研究与发展,2004,41(8):1333-1338.
(Zeng J C, Cui Z H. A guaranteed global convergence particle swarm optimizer [J]. J of Computer Research and Development, 2004, 41(8): 1333-1338.)
- [10] Solis F, Wets R. Minimization by random search techniques[J]. Mathematics of Operations Research, 1981, 6(1): 19-30.
- [11] 胡德文,王正志,王耀南,等.神经网络自适应控制[M].长沙:国防科技大学出版社,2006.
(Hu D W, Wang Z Z, Wang Y N, et al. Neural networks for adaptive control[M]. Changsha: National University of Defence Technology Press, 2006.)