

基于自适应粒子群优化的代价评估 Marginalized 粒子滤波

胡振涛 魏丹 金勇 胡玉梅

(河南大学计算机与信息工程学院 开封 475004) (河南大学图像处理与模式识别研究所 开封 475004)

摘要 针对量测受扰动情况下粒子重要性权重的精确度量和粒子的有效采样问题,提出了一种基于自适应粒子群优化的代价评估 Marginalized 粒子滤波。首先,在 Marginalized 粒子滤波框架下,通过引入代价函数和风险函数,实现了粒子重要性权重评价过程中对最新量测信息的合理利用,以降低传统的依据重要性权重度量方式中对于噪声先验信息的依赖。其次,通过对粒子分布特征信息的提取和利用,构建了粒子极限速度设定的自适应选取策略,给出了一种自适应粒子群优化方法。在此基础上,结合粒子群优化中群体优化机理来提升采样粒子对被估计状态的逼近程度,进而改善重采样后粒子的多样性。理论分析和仿真实验证了算法的有效性。

关键词 非线性滤波,代价评估粒子滤波,粒子群优化,量测不确定

中图法分类号 TP391.4 文献标识码 A

Cost Reference Marginalized Particle Filter Based on Adaptive Particle Swarm Optimization

HU Zhen-tao WEI Dan JIN Yong HU Yu-mei

(College of Computer and Information Engineering, Henan University, Kaifeng 475004, China)

(Institute of Image Processing and Pattern Recognition, Henan University, Kaifeng 475004, China)

Abstract Aiming at the precise measures of important weights and the effective sampling of particle in measurement uncertainty, a novel cost reference marginalized particle filter based on adaptive particle swarm optimization was proposed. In the new algorithm, cost function and risk function are firstly introduced to complete reasonable utilization of the latest observation, and the dependency on priori information of observation noise in classical measuring method of important weights is improved. Secondly, through the extraction and utilization of particle distribution features information, the adaptive selection strategy of the limit velocity is obtained and a new adaptive particle swarm optimization method is given. Finally, combining with the mechanism of colony optimization in particle swarm optimization, the approximation effectiveness of sampling particles relative to estimated state is enhanced, and the diversity of particle after re-sampling is improved. The theoretical analysis and experimental results show the efficiency of the proposed algorithm.

Keywords Nonlinear filter, Marginalized particle filter, Particle swarm optimization, Measurement uncertainty

1 引言

滤波器设计和优化是实现系统辨识、估计和控制的关键技术。当被估计系统满足线性且噪声为高斯独立分布时,基于递推贝叶斯估计原理的 Kalman 滤波(KF)给出了基于线性最小方差最优准则的典型实现^[1,2],此外就是状态空间离散且状态数有限时所采用的栅格法(网格滤波)^[3]。然而,对于非线性动态系统,上述方法最优解通常并不解析,并且随着时间的推移将趋于无穷维,由于“维数灾难”以及运算量和存储量的急剧膨胀而使得最优解在物理上不可实现^[4,5]。为此,

结合被估计系统的特点,在 KF 框架下通过引入局部线性化^[6]、UT 变换^[7]、Stirling 插值技术^[8]、三阶容积积分法则^[9]等方法,学者们相继提出了扩展 Kalman 滤波(EKF)、不敏感 Kalman 滤波(UKF)、差分 Kalman 滤波(DKF)、容积 Kalman 滤波(CKF)等改进算法。近年来,伴随着计算机性能的不断提升,基于序贯重要性采样技术和递推贝叶斯理论的粒子滤波给出了一种处理非线性非高斯问题的有效解决方法。粒子滤波(PF)的基本思想是通过一组附带权重的随机采样粒子逼近后验概率分布,理论上可以取得被估计对象的最小方差估计并且不受系统非线性程度和噪声类型的约束,因而在信

到稿日期:2013-08-23 返修日期:2013-11-12 本文受国家自然科学基金项目(61300214, U1204611),河南省高校科技创新团队支持计划(13IRTSTHN021),河南省基础与前沿技术研究计划(132300410148, 132300410278),河南省教育厅科学技术研究重点项目(13A413066),河南省青年骨干教师资助计划(2010GGJS-041),河南大学教学改革重点项目(HDXJJG2013-07),河南省博士后基金(2013029),中国博士后基金(2014M551999)资助。

胡振涛(1979—),男,博士,副教授,主要研究方向为复杂系统建模与估计、多源信息融合、非线性滤波, E-mail: hzt@henu.edu.cn; 魏丹(1980—),女,讲师,主要研究方向为非线性滤波、智能优化; 金勇(1972—),男,博士,副教授,主要研究方向为阵列信号处理、方位估计; 胡玉梅(1972—),女,硕士生,主要研究方向为信息融合、非线性滤波。

号处理、目标跟踪、故障诊断与图象处理等领域得到了广泛应用^[10,11]。然而,PF中随机性采样策略和重采样过程的采用将不可避免地导致递推实现过程中粒子退化和粒子多样性溃退现象的出现。粒子退化意味着大量的计算用来更新对逼近后验概率分布的贡献非常小的粒子;粒子溃退是指由于重采样中粒子复制和删除策略导致的粒子多样性衰减^[12]。如何克服以上制约粒子滤波精度提升的两类问题一直是相关领域专家学者关注的热点,目前对于粒子退化的主要解决方式是引入次优滤波器以实现提议分布的优选^[13];而对于粒子溃退重用的处理方式主要包括优化重采样结构^[14]以及与智能进化算法^[15,16]相结合等,如引入进化策略、蚁群算法等。此外,针对被估计状态能够建模为非线性状态和线性状态演化的一类特殊非线性系统,Schon提出了一种边际化粒子滤波算法(MPF)^[17],算法实现中针对线性状态部分利用KF进行估计,对于非线性状态通过PF方法来估计,其滤波精度和计算量均明显优于标准PF^[18]。

PF及以上改进算法取得较好滤波效果的前提在于已知噪声分布的统计信息,即对于系统运动状态建模非常准确,能够精确获取传感器的量测精度,而此时一般不考虑量测环境中的随机扰动。但在实际工程环境中,由于各种条件的限制,人们对实际现象的认识、各种检测或估计设备等总是存在一定的不足和偏差,从而使得建模噪声和实际噪声的统计特性具有较大偏差,并且这种偏差直接影响着滤波器估计精度。因此,研究粒子滤波在量测受扰动情况下的设计与优化具有重要的现实意义。针对噪声统计信息未知情况下粒子权重的有效评价问题,Djuric等提出了一种代价评估粒子滤波器(CRPF)^[19],通过代价函数和风险函数的构建和遗忘因子的引入,利用当前时刻量测完成对低信扰比下粒子权重的合理评价,改善PF利用量测似然度评价粒子权重过程中对量测噪声统计信息的依赖,提升了粒子权重量的可靠性^[20]。

基于以上分析,通过MPF、代价评估策略以及自适应粒子群算法的动态综合,本文提出一种基于自适应粒子群优化的代价评估 Marginalized 粒子滤波算法(APSO-CRMPF)。仿真实验结果表明,在量测受扰动情况下,APSO-CRMPF 的滤波估计精度明显优于EKF、UKF、MPF 和 CRMPF。

2 代价评估 Marginalized 粒子滤波

2.1 Marginalized 粒子滤波

考虑下面量测受扰动条件下且状态可分的一类非线性系统:

$$\mathbf{x}_{k+1}^n = \mathbf{A}_k^n \mathbf{x}_k^n + \mathbf{B}_k^n \mathbf{u}_k^n \quad (1)$$

$$\mathbf{x}_{k+1}^l = \mathbf{B}_k^l \mathbf{x}_k^l + \mathbf{u}_k^l \quad (2)$$

$$\mathbf{z}_k = h(\mathbf{x}_k^n) + \mathbf{v}_k + \mathbf{e}_k \quad (3)$$

式中, \mathbf{x}_k^n 和 \mathbf{x}_k^l 分别为非线性状态分量和线性状态分量, $\mathbf{x}_k = [\mathbf{x}_k^n \mathbf{x}_k^l]^T$ 为系统状态向量。 \mathbf{A}_k^n 、 \mathbf{A}_k^l 、 \mathbf{B}_k^n 和 \mathbf{B}_k^l 分别表示 \mathbf{x}_k^n 和 \mathbf{x}_k^l 的状态转移函数。状态噪声为 $\mathbf{u}_k = [\mathbf{u}_k^n \mathbf{u}_k^l]^T$, 且 $\mathbf{u}_k^n \sim \mathcal{N}(0, \sigma_{u_k^n}^2)$, $\mathbf{u}_k^l \sim \mathcal{N}(0, \sigma_{u_k^l}^2)$ 。 \mathbf{z}_k 为量测向量, $h(\cdot)$ 为量测函数, 表征状态空间到量测空间的映射关系, $\mathbf{z}_{1:k} = (\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_k)$ 表示直到 k 量测序列; 量测噪声 $\mathbf{v}_k \sim \mathcal{N}(0, \sigma_{v_k}^2)$; \mathbf{e}_k 表示量测在 k 时刻受到的扰动量。对于式(1)做进一步变换得

$$\bar{\mathbf{z}}_k = \mathbf{x}_{k+1}^n - \mathbf{A}_k^n \mathbf{x}_k^n = \mathbf{A}_k^n \mathbf{x}_k^l + \mathbf{u}_k^n \quad (4)$$

将 $\bar{\mathbf{z}}_k$ 看作虚拟量测值, 则式(2)和式(4)中所描述系统为线性高斯的, 可以利用 Kalman 滤波(KF)对 \mathbf{x}_k^l 进行估计。对

于式(1)和式(3)描述的非线性系统则可以利用 PF 实现 \mathbf{x}_k^n 的估计, 以上即 MPF 滤波的实现机理^[13,14]。相对于 KF, MPF 具有处理非线性问题的特性; 相对于 PF, 其由于子区间的维数比整个状态向量的维数小, 因此有效简化了计算量。另外, MPF 实现中本身具有线性滤波结果到非线性滤波结果的反馈回路, 并且线性分量估计中采用基于线性最小方差准则的最优估计器, 其结果通过反馈机制来改善对非线性分量的估计效果, 因而相对标准 PF 进一步提升了系统状态的估计精度。

2.2 粒子重要性权重量的代价评估策略

在标准 PF 实现中, 通过计算量测似然度的方式计算粒子的重要性权重 ω_k^i , 即

$$\omega_k^i = \exp\{-[\mathbf{z}_k - h(\mathbf{x}_k^{n,i})][\mathbf{z}_k - h(\mathbf{x}_k^{n,i})]^T / 2\sigma_{v_k}^2\} / \sqrt{2\pi}\sigma_{v_k} \quad (5)$$

由式(5)可知, ω_k^i 的优劣直接受到 σ_{v_k} 的影响, 当量测建模中 σ_{v_k} 不精确时, ω_k^i 无法有效表征粒子的有效性。针对以上问题, 文献[19]通过代价函数、风险函数的构建及遗忘因子的引入, 并依据代价最小化原则给出了一种量测噪声统计特性未知条件下粒子重要性权重代价评价策略。在 MPF 的非线性分量估计环节, 我们利用重要性权重代价评价策略替换标准 PF 中量测似然度的方式, 在保持 MPF 能够获取较高估计精度的优势的同时, 综合代价评价策略中能较好处理扰动信息的能力, 在此基础上构建了代价评估 Marginalized 粒子滤波(CRMPF)。代价函数定义为如下递推形式:

$$C(\mathbf{x}_k^{n,i} | \mathbf{z}_{1:k}) = \kappa C(\mathbf{x}_{k-1}^{n,i} | \mathbf{z}_{1:k-1}) + \Delta C(\mathbf{x}_k^{n,i} | \mathbf{z}_k) \quad (6)$$

其中, κ 是遗忘因子, 且 $0 \leq \kappa \leq 1$; $\Delta C(\mathbf{x}_k^{n,i} | \mathbf{z}_{1:k})$ 为一个代价增量, 取值大小与当前时刻采样粒子及量测信息有关。为有效评价 \mathbf{z}_k 给定条件下 $\mathbf{x}_k^{n,i}$ 对真实状态的逼近程度, 进一步定义一种风险函数 $R(\mathbf{x}_k^{n,i} | \mathbf{z}_k)$ 。 $R(\mathbf{x}_k^{n,i} | \mathbf{z}_k)$ 取值越大, 则表明选用该粒子对真实状态逼近中存在的风险就越大, 即代价就越大。因此, $R(\mathbf{x}_k^{n,i} | \mathbf{z}_k)$ 可以被认为是对代价增量的预测, 实际应用中一般直接采用代价增量的形式:

$$R(\mathbf{x}_k^{n,i} | \mathbf{z}_k) = \Delta C(f(\mathbf{x}_{k-1}^{n,i}) | \mathbf{z}_k) \quad (7)$$

结合式(5)和式(6), 代价函数的定义形式被修正为:

$$C(\mathbf{x}_k^{n,i} | \mathbf{z}_{1:k}) = \kappa C(\mathbf{x}_{k-1}^{n,i} | \mathbf{z}_{1:k-1}) + R(\mathbf{x}_k^{n,i} | \mathbf{z}_k) \quad (8)$$

基于最小化代价原则, 粒子权重的表达式为:

$$\hat{\omega}_k^i \propto \eta(C(\mathbf{x}_k^{n,i} | \mathbf{z}_{1:k})) \quad (9)$$

其中, $\eta(\cdot)$ 一般设计为粒子代价的单调减函数^[20]。对比以上 ω_k^i 和 $\hat{\omega}_k^i$ 的实现过程可知, 基于代价评估的粒子权重评价方式, 主要通过最新量测信息和以往量测信息的综合来实现粒子重要性权重评估, 改善了量测似然度评价方法对量测噪声先验统计信息的依赖。外界扰动影响越显著, 滤波精度的优势就体现得越明显。因为外界扰动对于量测信息影响越大, 则意味着系统建模中量测噪声的统计特性和真实环境下量测噪声的统计特性之间的偏差越大。

3 基于粒子群优化的代价评估 Marginalized 粒子滤波

考虑到 PF 中重采样环节的采用极易导致算法递推实现过程中粒子多样性的衰减, 进而使得采样粒子集无法有效表征状态的后验概率分布, 本节通过在重采样前引入具有种群优化特性的粒子群优化(PSO)方法改善单个粒子采样的有效性, 从而提升重采样后粒子集的多样性; 同时针对标准 PSO

中粒子极限速度对专家知识的依赖问题,结合采样粒子的分布特点,我们首先给出了一种极限速度自适应粒子群算法。

3.1 自适应粒子群优化

粒子群优化(PSO)是一种基于群体智能的进化计算技术,由 Kennedy 和 Eberhart 等学者提出,其思想来源于对鸟群、鱼群等群集行为的模拟。PSO 首先初始化为一群随机粒子,然后通过迭代搜寻最优解。在每一次迭代中粒子通过跟踪两个极值来更新自己的速度和位置(速度-位移模型):一个是粒子本身所找到的最好解,即个体历史极值 p_k^i ;另一个是整个种群目前所找到的最好解,称为全局最优值 p_k^g 。在得到 p_k^i 和 p_k^g 后,每个粒子根据以下公式来更新其速度和位置^[21]:

$$\begin{cases} \mathbf{V}_{k,m+1}^i = \xi * \mathbf{V}_{k,m}^i + \lambda_1 * rand * (p_k^i - \mathbf{x}_{k,m}^i) + \\ \lambda_2 * rand * (p_k^g - \mathbf{x}_{k,m}^i), & \mathbf{V}_{k,\min} < \mathbf{V}_{k,m+1}^i < \mathbf{V}_{k,\max} \\ \mathbf{V}_{k,\min}, & \mathbf{V}_{k,m+1}^i \leq \mathbf{V}_{k,\min} \\ \mathbf{V}_{k,\max}, & \mathbf{V}_{k,\max} \leq \mathbf{V}_{k,m+1}^i \end{cases} \quad (10)$$

$$\mathbf{x}_{k,m+1}^{n,i} = \mathbf{x}_{k,m}^{n,i} + \mathbf{V}_{k,m+1}^i \quad (11)$$

其中, $\mathbf{x}_{k,m}^{n,i}$ 和 $\mathbf{V}_{k,m}^i$ 分别表示 k 时刻第 m 次循环中第 i 个粒子的状态和速度, $m=1, 2, \dots, M$; ξ 称为惯性系数; λ_1 和 λ_2 通常称为学习因子,一般 $\lambda_1=\lambda_2=2$; $rand$ 表示介于 $(0, 1)$ 区间的随机数; $\mathbf{V}_{k,\min}$ 和 $\mathbf{V}_{k,\max}$ 分别表示 k 时刻粒子最小速度和最大速度,它们的合理选择能够避免粒子过度发散。粒子群优化不同于传统遗传算法中的个体优化策略,本身属于群优化方式。它通过式(10)和式(11)实现粒子向当前时刻全局最优值 p_k^g 靠近,同时使得整个粒子群向真实状态逼近。对于 $\mathbf{V}_{k,\min}$ 和 $\mathbf{V}_{k,\max}$,通常依据系统状态演化的专家知识预先设定,这在一定程度上限制了算法的应用范围。通过对粒子分布特征信息的提取和利用,以下构建了粒子极限速度设定的自适应选取策略^[22]。对 $\mathbf{V}_{k,\min}$ 和 $\mathbf{V}_{k,\max}$ 做如下定义:

$$\mathbf{V}_{k,\max} = [\mathbf{x}_{k,\omega_{k,\max}^i}^{n,i} - \mathbf{x}_{k,\omega_{k,\min}^i}^{n,i}] [\mathbf{x}_{k,\omega_{k,\max}^i}^{n,i} - \mathbf{x}_{k,\omega_{k,\min}^i}^{n,i}]^T / (2\sigma_{\omega_k}^2) \quad (12)$$

$$\mathbf{V}_{k,\min} = -\mathbf{V}_{k,\max} \quad (13)$$

其中, $\mathbf{x}_{k,\omega_{k,\max}^i}^{n,i}$ 和 $\mathbf{x}_{k,\omega_{k,\min}^i}^{n,i}$ 分别表示 ω_k^i 取最大值和最小值时对应的粒子。由式(12)和式(13)的表达形式可知, $\mathbf{V}_{k,\max}$ 实际表示 k 时刻粒子集中差别最大两个粒子之间的距离,并且这个极限距离来源于先验状态建模信息,可以认为是利用状态方程实现采样粒子分布区域的极限范围。

3.2 APSO-CRMPF 算法实现

考虑到粒子群优化具有种群优化的功能,通过 MPF 与 PSO 的有机结合,利用 APSO 实现采样粒子集向权重高粒子区域移动,APSO-CRMPF 算法构建原理和步骤分析如下。

首先,依据系统状态演化方程实现 k 时刻非线性分量粒子 $\mathbf{x}_k^{n,i}$ 的采样以及量测预测值 $\mathbf{z}_{k/k-1}^i$ 的计算。

$$\mathbf{x}_{k+1}^{n,i} = f(\mathbf{x}_k^{n,i}) + \mathbf{F}_k^i \mathbf{x}_k^i + \mathbf{G}_k^i \mathbf{u}_k^i \quad (14)$$

$$\mathbf{z}_{k/k-1}^i = h(\mathbf{x}_k^{n,i}), i=1, 2, \dots, N \quad (15)$$

其次,利用式(5)求解粒子的重要性权重 $\hat{\omega}_k^i$,并结合代价评估策略实现重要性权重 $\hat{\omega}_k^i$ 的计算。为改善采样粒子对于真实状态逼近的有效性,在此引入自适应粒子群方法。综合考虑算法实时性和滤波精度的要求,设定粒子群优化的最大迭代次数 M 和阈值 δ 。为保证采样粒子集以粒子权重为基准沿着权重大粒子区域移动,将粒子群优化中的适应度函数定义为与 CRPF 中的粒子度量函数相同的形式,即

$$r_k^i \propto \eta(C(x_k^i | z_{1:k})) \quad (16)$$

接下来,利用式(13)得到采样粒子为 k 时刻粒子集的初始值,并通过式(10)~式(12)利用粒子群优化策略的迭代处理完成采样粒子向权重高粒子区域的密集。最后,以 r_k^i 和 p_k^i 作为 k 时刻粒子权重和粒子实现重采样过程,重采样后得到一组新的粒子集 $\{\mathbf{x}_k^i\}_{i=1}^N$ 。对 $\hat{\omega}_k^i$ 进行归一化处理后得到权重 $\hat{\omega}_k^i$,进而依据 $\hat{\omega}_k^i$ 实现重采样过程。所谓重采样即在评估粒子权值后,维持粒子总数不变条件下,删除权值低的粒子,复制权值高的粒子,重采样后得到一组新的粒子集 $\{\mathbf{x}_k^{n,j}, \hat{\omega}_k^j\}_{j=1}^N$ 。依据蒙特卡罗仿真原理,非线性状态分量估计结果可通过求解重采样后粒子的算术平均值获得。

$$\hat{\mathbf{x}}_{k/k}^n = \sum_{j=1}^N \mathbf{x}_k^{n,j} / N \quad (17)$$

接下来,结合式(4)中虚拟量测,并通过 KF 中的状态更新和量测更新步骤实现线性状态分量 $\hat{\mathbf{x}}_{k/k}^l$ 的估计。

$$\bar{\mathbf{z}}_k = \hat{\mathbf{x}}_{k/k}^n - \mathbf{F}_k^n \hat{\mathbf{x}}_{k-1/k-1}^l \quad (18)$$

$$\mathbf{P}_{k/k-1}^l = \mathbf{B}_k^l \mathbf{P}_{k-1/k-1}^l (\mathbf{B}_k^l)^T + \mathbf{\sigma}_{u_k}^2 \quad (19)$$

$$\mathbf{K}_k = \mathbf{P}_{k/k-1}^l (\mathbf{A}_k^l)^T (\mathbf{A}_k^l \mathbf{P}_{k-1/k-1}^l (\mathbf{A}_k^l)^T + \mathbf{\sigma}_{u_k}^2)^{-1} \quad (20)$$

$$\hat{\mathbf{x}}_{k/k}^l = \hat{\mathbf{x}}_{k/k-1}^l + \mathbf{K}_k (\bar{\mathbf{z}}_k - \mathbf{A}_k^l \hat{\mathbf{x}}_{k-1/k-1}^l) \quad (21)$$

$$\mathbf{P}_{k/k}^l = \mathbf{P}_{k/k-1}^l - \mathbf{K}_k \mathbf{A}_k^l \mathbf{P}_{k-1/k-1}^l \quad (22)$$

其中, $\hat{\mathbf{x}}_{k/k-1}^l$ 和 $\hat{\mathbf{x}}_{k/k}^l$ 分别为线性状态分量的一步预测值和估计值, \mathbf{K}_k 表示滤波增益矩阵, $\mathbf{P}_{k/k-1}^l$ 和 $\mathbf{P}_{k/k}^l$ 分别为线性状态分量的一步预测值误差协方差和估计误差协方差阵。最终,通过综合非线性状态分量和线性状态分量估计结果,得到系统状态估计值 $\hat{\mathbf{x}}_{k/k}$ 。

$$\hat{\mathbf{x}}_{k/k} = [\hat{\mathbf{x}}_{k/k}^n \quad \hat{\mathbf{x}}_{k/k}^l]^T \quad (23)$$

4 仿真实验与分析

仿真实验场景设定为利用两坐标雷达的量测数据实现 X-Y 平面上运动目标的跟踪。为了有效验证算法的性能,目标运动形式分别设定为匀速运动和匀速转弯运动两种情况。

实验 1 依据运动目标所具有的动力学特性,目标状态转移方程和量测方程如下:

$$\dot{\mathbf{x}}_k^i = \mathbf{A}_k^i \mathbf{x}_k^i + \mathbf{A}_k^i \mathbf{x}_k^i + \mathbf{u}_k^i$$

$$\mathbf{x}_{k+1}^i = \mathbf{B}_k^i \mathbf{x}_k^i + \mathbf{B}_k^i \mathbf{x}_k^i + \mathbf{u}_k^i$$

$$\mathbf{z}_k = [\sqrt{(x_k)^2 + (y_k)^2} \quad \tan^{-1}(y_k/x_k)]^T + \mathbf{v}_k + \mathbf{e}_k$$

其中, $\mathbf{x}_k^i = [x_k \quad y_k]^T$, $\dot{\mathbf{x}}_k^i = [\dot{x}_k \quad \dot{y}_k]^T$, x_k, \dot{x}_k, y_k 和 \dot{y}_k 分别表示目标状态在 X 轴和 Y 轴方向上的位置分量和速度分量。匀速运动时 $\mathbf{A}_k^i = \mathbf{I}$, $\mathbf{A}_k^i = \begin{bmatrix} \tau & 0 \\ 0 & \tau \end{bmatrix}$, $\mathbf{B}_k^i = \begin{bmatrix} 0 & 0 \\ 0 & 0 \end{bmatrix}$, $\mathbf{B}_k^i = \mathbf{I}$, $\mathbf{I} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$ 。采样间隔 $\tau=1$,系统噪声 \mathbf{u}_k^i 和 \mathbf{u}_k^i 采用均值为零、方差为 $0.2\mathbf{I}$ 的高斯白噪声。量测噪声向量 \mathbf{v}_k 为满足均值为零、标准差为 $\begin{bmatrix} R_r & 0 \\ 0 & R_\theta \end{bmatrix}$ 的高斯白噪声,其中径向距分量的噪声标准差 R_r 为 0.1km ,方位角分量的噪声标准差 R_θ 为 0.1° 。外界扰动 \mathbf{e}_k 的噪声统计特性在径向距分量和方位角分量上分别体现为均值为零、均方根误差为 0.25km 和 0.2° 。目标状态的初值 $\mathbf{x}_0 = [8\text{km}, 0.3\text{km/s}, 5\text{km}, 0.4\text{km/s}]^T$ 。采样粒子个数 N 为 500, $M=5, \delta=0.6$ 。采用文献[19]中所用的 $\eta(\cdot)$ 形式,即 $\eta(C(x_k^i | z_{1:k})) = 1/(C(x_k^i | z_{1:k}) - \min(C(x_k^i | z_{1:k}))$

$z_{1:k} + 1/\mu$), 其中 $\mu = 2$ 。Monte Carlo 仿真次数循环数为 100; 在每次 Monte Carlo 循环中仿真步数 T 为 25。

图 1 和图 2 分别给出了 100 次独立实验条件下, 采用 EKF、UKF、MPF、CRMPF 及 APSO-CRMPF 算法得到的目标在水平方向和垂直方向上位置分量状态估计的均方根误差 (RMSE) 比较。表 1 则针对滤波精度的差异, 利用均方根误差均值形式给出了滤波精度的定量分析。由以上结果可以清晰地看到: 在量测受扰动情况下高维非线性系统的状态估计实现中, 传统的次优滤波器 EKF 和 UKF 缺乏对外界扰动和强非线性问题的解决能力, 滤波精度明显低于基于随机性采样策略的 MPF、CRMPF 和 APSO-CRMPF。相比于 MPF 算法完全依赖于量测噪声统计信息实现粒子权重评估方式, CRMPF 通过代价评估方式减弱了扰动对度量粒子权重的不利影响, 从而在一定程度上提升了滤波精度。但 CRMPF 本身缺乏对粒子集的优化过程, APSO-CRMPF 通过自适应粒子群优化策略方式的引入, 使得采样粒子集能够更好地逼近后验概率分布, 从而改善了滤波估计精度。

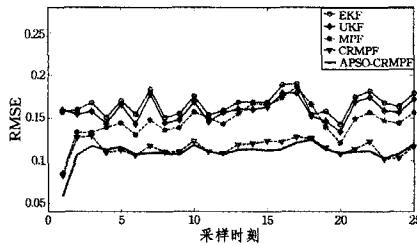


图 1 水平方向(X 轴)位置估计的 RMSE 比较

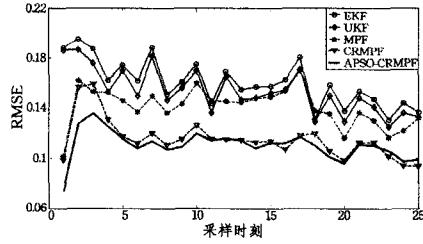


图 2 坚直方向(Y 轴)位置估计的 RMSE 比较

表 1 基于 100 次独立仿真条件下 RMSE 的均值比较

算法	EKF	UKF	MPF	CRMPF	APSO-CRMPF
X 轴方向	0.1603	0.1536	0.1409	0.1154	0.1015
Y 轴方向	0.1657	0.1587	0.1465	0.1147	0.1029

实验 2 为进一步说明算法的可行性和有效性, 考虑目标以匀速转弯形式运动, 针对以上 5 种算法, 给出算法滤波性能的比较。相对于实验 1 中参数的设定, $A_k^t = I$, $A_k^l = \begin{bmatrix} \sin(\bar{\omega}\tau)/\bar{\omega} & -(1-\cos(\bar{\omega}\tau))/\bar{\omega} \\ (1-\cos(\bar{\omega}\tau))/\bar{\omega} & \sin(\bar{\omega}\tau)/\bar{\omega} \end{bmatrix}$, $B_k^t = \begin{bmatrix} 0 & \cos(\bar{\omega}\tau) \\ 0 & \sin(\bar{\omega}\tau) \end{bmatrix}$, $B_k^l = \begin{bmatrix} 0 & -\sin(\bar{\omega}\tau) \\ 0 & \cos(\bar{\omega}\tau) \end{bmatrix}$, 转弯角速度 $\bar{\omega} = 0.02 \text{ rad/s}$ 。其他参数的设定与实验 1 相同。

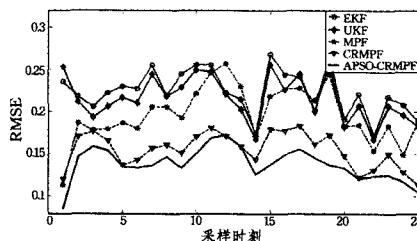


图 3 水平方向(X 轴)位置估计的 RMSE 比较

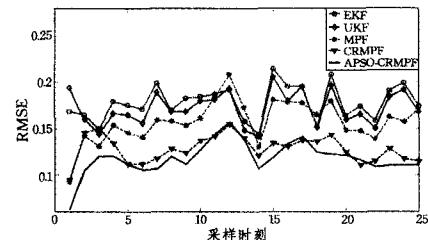


图 4 坚直方向(Y 轴)位置估计的 RMSE 比较

由图 3 和图 4 可知, APSO-CRMPF 滤波精度同样优于 CRMPF、MPF、UKF、EKF, 结果表明 APSO-CRMPF 算法在系统状态估计实现中具有较好的稳定性。表 2 定量给出了 5 种滤波算法 RMSE 均值的结果比较。以上结果为实际工程应用中依据估计精度指标选择合适的滤波器提供了参考。

表 2 基于 100 次独立仿真条件下 RMSE 的均值比较

算法	EKF	UKF	MPF	CRMPF	APSO-CRMPF
X 轴方向	0.2154	0.2236	0.1969	0.1548	0.1382
Y 轴方向	0.1783	0.1724	0.1576	0.1279	0.1181

结束语 本文提出了一种基于自适应粒子群优化的代价评估 Marginalized 粒子滤波算法。与现有的处理方法相比, 该算法具有以下优势: 首先, 以 MPF 机理为 APSO-CRMPF 的构建基础, 使得算法具有能够较好解决非线性非高斯问题的优点, 而粒子权重的代价评估策略有效改善了粒子权重度量中扰动信息带来的不利影响; 其次, 通过粒子群优化策略的引入, 能够改善当前时刻采样粒子对后验概率分布的逼近程度, 优化当前时刻采样粒子集; 另外, 依据采样粒子间蕴含的冗余和互补信息实现了粒子群优化策略中极限速度的设定, 避免了对专家知识的依赖, 提升了算法的可操作性。

参 考 文 献

- [1] Simon D. Kalman filtering with state constraints: A survey of linear and nonlinear algorithms[J]. IET Control Theory & Applications, 2010, 4(8): 1303-1318
- [2] Grewal M S, Kain J. Kalman filter implementation with improved numerical properties[J]. IEEE Transactions on Automatic Control, 2010, 55(9): 2058-2068
- [3] Jia B, Xin M. Vision-based spacecraft relative navigation using sparse-grid quadrature filter[J]. IEEE Transactions on Control Systems Technology, 2013, 21(5): 1595-1606
- [4] Novara C, Ruiz F, Milanese M. Direct filtering: A new approach to optimal filter design for nonlinear systems[J]. IEEE Transactions on Automatic Control, 2013, 58(1): 86-99
- [5] Arulampalam M S, Maskell S, Gordon N, et al. A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking[J]. IEEE Transactions on Signal Processing, 2002, 50(2): 174-188
- [6] Chunbo L, McClean S I, Parr G, et al. UAV Position estimation and collision avoidance using the extended Kalman filter[J]. IEEE Transactions on Vehicular Technology, 2013, 62(6): 2749-2762
- [7] Jafarzadeh S, Lascu C, Fadali M S. State Estimation of induction motor drives using the unscented Kalman filter[J]. IEEE Transactions on Industrial Electronics, 2012, 59(11): 4207-4216
- [8] Xu J L, Wang H J, Zhang A H. Underwater target bearing only

- tracking based on first order divided difference filter[C]//25th Chinese Control and Decision Conference, 2013, 351-356
- [9] Leong P H, Arulampalam S, Larnahewa T A, et al. A Gaussian-sum based cubature Kalman filter for bearings-only tracking[J]. IEEE Transactions on Aerospace and Electronic Systems, 2013, 49(2):1161-1176
- [10] Cappe O, Godsill S J, Moulines E. An overview of existing methods and recent advances in sequential Monte Carlo[J]. Proceedings of the IEEE, 2007, 95(5):899-924
- [11] Gustafsson F. Particle filter theory and practice with positioning applications[J]. IEEE Aerospace and Electronic Systems Magazine, 2010, 25(7):53-82
- [12] Karlsson R. Particle filter for positioning and tracking applications[D]. Linkoping: Linkoping University, 2005
- [13] Qi C, Bondon P. An efficient two-stage sampling method in particle filter[J]. IEEE Transactions on Aerospace and Electronic Systems, 2012, 48(3):2666-2672
- [14] Fu X Y, Jia Y M. An improvement on re-sampling algorithm of particle filters[J]. IEEE Transactions on Signal Processing, 2010, 58(10):5414-5420
- [15] Li H W, Wang J, Su H T. Improved particle filter based on differential evolution[J]. Electronics Letters, 2011, 47(19):1078-1079
- [16] Zhong J, Fung Y F. Case study and proofs of ant colony optimi-
- sation improved particle filter algorithm[J]. IET Control Theory & Applications, 2012, 6(5):689-697
- [17] Schon T, Gustafsson F, Nordlund P J. Marginalized particle filters for mixed linear/nonlinear state-space models[J]. IEEE Transactions on Signal Processing, 2005, 50(7):2279-2289
- [18] Karlsson R, Schon T, Gustafsson F. Complexity analysis of the marginalized particle filter[J]. IEEE Transactions on Signal Processing, 2005, 53(11):4408-4411
- [19] Djuric P M, Bugallo M F. Cost-reference particle filtering for dynamic systems with nonlinear and conditionally linear states[C]// IEEE Nonlinear Statistical Signal Processing Workshop. 2006: 183-188
- [20] Jaechan L, Hong D. Cost Reference Particle Filtering Approach to High-Bandwidth Tilt Estimation[J]. IEEE Transactions on Industrial Electronics, 2010, 57(11):3830-3839
- [21] Li C H, Yang S X, Nguyen T T. A self-learning particle swarm optimizer for global optimization problems[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics, 2012, 42(3):627-646
- [22] Hu Z T, Liu X X, Jin Y. Cost Reference Particle Filter Based on Adaptive Particle Swarm Optimization in Observation Uncertainty [C]// Proceedings of the 30th Chinese Control Conference. 2011: 769-800

(上接第 165 页)

验显示 LO-DLDA 对围巾遮挡要劣于墨镜遮挡, 主要原因可能是围巾遮挡破坏了脸部轮廓。如何解决 LO-DLDA 对围巾遮挡比较敏感的问题, 将是我们下一步研究工作的重点。

参 考 文 献

- [1] Turk M, Pentland A. Eigenfaces for recognition[J]. Journal of Cognitive Neuroscience, 1991, 3(1):71-86
- [2] He X F, Yan S C, Hu Y X, et al. Face recognition using Laplacianfaces[J]. IEEE Trans. on Pattern Analysis and Machine Intelligence, 2005, 27(3):328-340
- [3] He X F, Cai D, Yan SC , et al. Neighborhood preserving embedding[C] // Proc. of the IEEE Int'l Conf. on Computer Vision (ICCV). Beijing, 2005: 1208-1213
- [4] Belhumeur P N, Hespanha J P, Kriegman D J. Eigenfaces vs. Fisherfaces: Recognition using class specific linear projection [J]. IEEE Trans. on Pattern Analysis and Machine Intelligence, 1997, 19(7):711-720
- [5] Xu D, Yan S, Tao D, et al. Marginal Fisher analysis and its variants for human gait recognition and content-based image retrieval[J]. IEEE Trans. Image Process, 2007, 16 (11):2811-2821
- [6] Cai Deng, He Xiao-fei, Zhou Kun, et al. Locality Sensitive Discriminant Analysis[C] // Proceedings of the 20th International Joint Conference on Artificial Intelligence(IJCAI). Hyderabad, 2007: 708-713
- [7] Chen Xiao-hong, Chen Song-can, Xue Hui. A unified dimensionality reduction framework for semi-paired and semi-supervised multi-view data[J]. Pattern Recognition, 2012, 45(4):2005-2018
- [8] Cai D, He X, Han J. Semi-supervised discriminant analysis[C] // Proceedings of IEEE 11th International Conference on Computer Vision (ICCV). Rio de Janeiro, 2007: 1-7
- [9] Balasubramanian M, Schwartz E L, Tenenbaum J B, et al. The Isomap Algorithm and Topological Stability[J]. Science, 2002, 295(5552):7
- [10] Roweis S, Saul L. Nonlinear dimensionality reduction by locally linear embedding[J]. Science, 2000, 290(5500):2323-2326
- [11] Belkin M, Niyogi P. Laplacian Eigenmaps for dimensionality reduction and data representation[J]. Neural Computation, 2003, 15(6):1373-1396
- [12] Schölkopf B, Smola A, Müller K R. Nonlinear Component Analysis as a Kernel Eigenvalue Problem[J]. Neural Computation, 1998, 10(5):1299-1319
- [13] Baudat G, Anouar F. Generalized Discriminant Analysis Using a Kernel Approach[J]. Neural Computation, 2000, 12 (10): 2385-2404
- [14] Di You, Hamsici O C, Martinez A M. Kernel Optimization in Discriminant Analysis[J]. IEEE Trans. Pattern Analysis and Machine Intelligence, 2011, 33(3):631-638
- [15] Yang J, Frangi A F, Yang J Y, et al. KPCA plus LDA: A complete kernel fisher discriminant framework for feature extraction and recognition[J]. IEEE Trans. on Pattern Analysis and Machine Intelligence, 2005, 27(2):230-244
- [16] Cai Deng, He Xiao-fei, Han Jia-wei. Speed up kernel discriminant analysis[J]. The VLDB Journal, 2011, 20(1):21-33
- [17] Martinez A M, Kak A C. PCA versus LDA[J]. IEEE Trans. Pattern Analysis and Machine Intelligence, 2001, 23(2):228-233
- [18] Lee K, Ho J, Kriegman D. Acquiring linear subspaces for face recognition under variable lighting [J]. IEEE Trans. Pattern Analysis and Machine Intelligence, 2005, 27(5):684-698