

多传感器量测下权重优化粒子滤波算法

胡振涛¹ 刘宇¹ 杨树军²

(河南大学图像处理与模式识别研究所 开封 475004)¹ (江南计算技术研究所 无锡 240083)²

摘要 针对粒子滤波在多传感器量测系统状态估计问题中的有效实现,提出一种多传感器量测下的权重优化粒子滤波算法。首先,依据提议分布的具体形式设计用于度量当前时刻粒子的权重的量测似然函数,并利用单个滤波周期内的全部量测分别计算每个粒子权重;其次,考虑到不同传感器精度存在的差异性,结合传感器精度等先验信息,通过加权融合处理方式实现对单个粒子在多传感器量测下权重度量结果的优化;进而在减小粒子权重方差的基础上改善滤波的精度。理论分析和仿真实验结果验证了算法的可行性和有效性。

关键词 多源信息融合,多传感器量测,粒子滤波,权重优化

中图分类号 TP391.4 **文献标识码** A

Weights Optimization Particle Filter Algorithm in Multi-sensor Measurement

HU Zhen-tao¹ LIU Yu¹ YANG Shu-jun²

(Institute of Image Processing & Pattern Recognition, Henan University, Kaifeng 475004, China)¹

(Jiangnan Institute of Computing Technology, Wuxi 240083, China)²

Abstract Aiming at the effective realization of particle filter in multi-sensor measurement system state estimation, a novel particle filter algorithm based on weights optimization in multi-sensor measurement was proposed in this paper. In the new algorithm, the measurements likelihood function is firstly constructed on the basis of the concrete form of proposal distribution, and all measurement in single filter period are used to calculate the every particle weights, respectively. Secondly, given the otherness of different sensors precision, combining with priori information of sensors precision, the weighting fusion method is used to optimize every particle weights in multi-sensor measurement. Finally, the filter precision is improved by decreasing the variance of particle weights. The theoretical analysis and experimental results show the feasibility and efficiency of the proposed algorithm.

Keywords Multi-information fusion, Multi-sensor measurement, Particle filter, Weights optimization

1 引言

伴随着对感知对象认识的不断深入以及估计和控制任务要求的日益提高,人们在多传感器融合系统估计过程中越来越不能回避非线性、非高斯以及分布式等问题^[1]。考虑到近似非线性函数的概率密度分布比近似非线性函数更容易以及计算机性能的不提升,使用采样方法近似非线性分布来解决非线性问题的途径日趋受到相关研究领域学者的重视。随机性采样滤波的典型实现方法即粒子滤波(PF),它利用状态空间中一组附带权重的随机样本(粒子)来逼近状态变量的后验概率分布,每个样本代表系统的一个可能状态^[2]。相对于其它现有的非线性滤波器,其具有不受模型线性和高斯假设约束,适用于任意非线性非高斯动态系统的优点。近年来,针对 PF 中存在的提议分布有效选取、粒子退化和重采样后粒子多样性枯竭问题,一些学者通过引入次优滤波器^[3,4]、智能

优化技术^[5,6]、马尔可夫蒙特卡洛移动方法^[7]等相继提出一些改进方法,取得了较好的滤波结果。然而,以上成果主要集中于单传感器量测系统状态估计领域,即滤波器自身性能的进一步优化,而结合多传感器融合系统自身特点实现采样型非线性滤波器设计和应用的报道相对较少。此类研究在国内外还都处于起步阶段。

多传感器量测问题的处理上,Hlinomaz 和 Hong 等基于小波理论提出量测在不同速率和分辨率下的多尺度建模和估计方法,并在多尺度建模框架下给出了 PF 的具体实现步骤^[8]。但多尺度建模实质是将量测空间中的多量测多速率问题转化为状态空间中的系统状态演化建模问题,而系统建模本身就是估计理论中的一个难点问题。Armesto 等则结合插值技术提出了插值粒子滤波,并将其运用到机器人定位和地图创建过程中,但算法构建过程中缺乏对传感器量测相关问题的考虑^[9]。Tehrani 等针对自主车辆导航中异质多传

到稿日期:2013-02-01 返修日期:2013-04-28 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),河南省教育厅科学技术研究重点项目(13A413066),河南大学教学改革重点项目(HDXJG2013-07)的资助。

胡振涛(1979-),男,博士,副教授,主要研究方向为多源信息融合、最优估计, E-mail: hzt@henu.edu.cn; 刘宇(1980-),女,讲师,主要研究方向为最优估计、无线传感器网络。

传感器量测的有效利用问题,采用加权最大似然估计方法构建不可观测状态与传感器量测之间的联合概率量测模型,进而综合传感器物理特性、精度以及可靠性实现粒子数目在系统状态估计中的自适应分配,同时采用次优滤波器弥补多传感器量测速率、采样粒子状态维数和数目差异对滤波实现实时性的影响^[10]。针对分布式结构下多传感器量测随机缺失下的系统状态估计问题,Achutegui 等结合非比例分配重采样技术设计了独立节点量测下的分布式采样策略,并通过其它节点的量测拟合信息缺失节点的量测数据,以上方法在降低节点数据通讯负担和改善滤波精度的实现上具有一定借鉴价值^[11]。但由于缺失量测的估计精度严重依赖于量测系统中的传感器数目,因此,算法取得较好性能的前提在于量测系统中传感器数量足够多。考虑对量测不确定和多速率问题的综合处理,François 等提出一种基于量测马尔可夫模型切换多传感器融合粒子滤波的算法。根据算法实现原理可知,其滤波效果依赖于量测模型先验概率和状态转移概率的精确选取,同时要求状态转移模型能够匹配不同量测速率的传感器,而这些假设条件在实际应用中因为过于苛刻而一般难以达到^[12]。

针对以上问题,本文从粒子滤波实现原理入手,在构建多传感器量测似然函数和传感器精度等先验信息的利用基础上,实现对多传感器量测数据中冗余和互补信息的有效提取和利用,进而在减小粒子权重的方差条件下改善粒子权重度量结果的稳定性和可靠性,提出了一种多传感器量测下权重优化粒子滤波算法(WOPF)。对上述算法进行了仿真实验,并在仿真结果分析的基础上给出了相关结论。

2 粒子滤波

考虑下面非线性状态空间模型:

$$\mathbf{x}_k = f(\mathbf{x}_{k-1}) + \mathbf{u}_k \quad (1)$$

$$\mathbf{z}_{k,j} = h(\mathbf{x}_k) + \mathbf{v}_{k,j}, j = 1, 2, \dots, M \quad (2)$$

式中, \mathbf{x}_k 和 $\mathbf{z}_{k,j}$ 分别表示 k 时刻系统状态变量和第 j 个传感器的量测值。 $f(\cdot)$ 和 $h(\cdot)$ 分别表示系统状态和量测的非线性演化函数。 \mathbf{u}_k 和 $\mathbf{v}_{k,j}$ 分别表示具有独立同分布特性的系统过程噪声和量测噪声序列,其噪声方差分别为 $\sigma_{\mathbf{u},k}^2$ 和 $\sigma_{\mathbf{v},k,j}^2$ 。基于第 j 个传感器量测序列的状态估计问题描述,可归结为利用所有可能得到的量测递推地估计出当前时刻系统状态 \mathbf{x}_k 的后验概率分布 $p(\mathbf{x}_k | \mathbf{z}_{1:k,j})$,由于 $p(\mathbf{x}_k | \mathbf{z}_{1:k,j})$ 包括序贯估计的完全信息,因此可得到系统状态估计所需的参数如均值、方差等信息。具体在粒子滤波中是利用采样粒子完成对 $p(\mathbf{x}_k | \mathbf{z}_{1:k,j})$ 的逼近,即

$$p(\mathbf{x}_k | \mathbf{z}_{1:k,j}) \approx \sum_{i=1}^N \delta(\mathbf{x}_k - \mathbf{x}_k^i) / N \quad (3)$$

式中, $\delta(\cdot)$ 是 Kronecker 函数; $\{\mathbf{x}_k^i\}_{i=1}^N$ 表示系统中的采样粒子集,且粒子数目 $N \rightarrow \infty$,通过直接从后验概率分布中独立抽样得到。但由于实际上 $p(\mathbf{x}_k | \mathbf{z}_{1:k,j})$ 是未知的,上述过程一般很难实现。为克服以上困难,通过引入一个容易采样且接近后验概率分布的提议分布 $q(\mathbf{x}_k | \mathbf{z}_{1:k,j})$,并从中抽取一组带权子样 $\{\mathbf{x}_k^i, \omega_{k,j}^i\}_{i=1}^N$,来近似后验概率分布,该过程被称为重要性采样。此时,采样粒子权重的数学表达式为

$$\omega_{k,j}^i \propto p(\mathbf{x}_k^i | \mathbf{z}_{1:k,j}) / q(\mathbf{x}_k^i | \mathbf{z}_{1:k,j}) \quad (4)$$

实际应用中 $q(\mathbf{x}_k | \mathbf{z}_{1:k,j})$ 选取为状态转移概率密度形式,即

$$q(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i, \mathbf{z}_{1:k,j}) = p(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i) \quad (5)$$

此时,粒子权重度量可通过计算每个粒子自身的量测似然度函数实现。

$$\omega_{k,j}^i = \omega_{k-1,j}^i p(\mathbf{z}_{k,j} | \mathbf{x}_k^i) \quad (6)$$

对 $\omega_{k,j}^i$ 进行归一化处理得到归一化权重 $\bar{\omega}_{k,j}^i$,进而依据 $\bar{\omega}_{k,j}^i$ 实现重采样过程。所谓重采样即在评估粒子权值后,维持粒子总数不变的条件下,删减权值低的粒子,复制权值高的粒子,重采样后得到一组新的粒子集 $\{\mathbf{x}_k^i, \bar{\omega}_{k,j}^i\}_{i=1}^N$ 。依据蒙特卡罗仿真技术,最终状态估计结果可通过求解重采样后粒子算术平均值获得。

3 多传感器量测下权重优化粒子滤波算法

在 PF 中,粒子的有效采样和粒子权重的合理度量是其获得较好估计精度的两个重要方面。其中,粒子有效采样直接取决于提议分布对真实后验概率分布的逼近程度;而粒子权重计算是否精确,不仅取决于提议分布的选取形式,而且受到随机量测噪声的影响。考虑到多传感器的采用使得单个滤波周期存在多个量测数据,客观上提供了融合多个量测信息改善随机量测噪声影响的必要条件。本文从随机采样型滤波器的实现原理入手,通过多传感器量测似然函数的构建和传感器精度等先验信息的合理利用,在减小粒子权重方差的基础上改善了滤波精度,进而提出了一种多传感器量测下权重优化粒子滤波算法。下面着重分析利用多传感器量测实现粒子权重优化的原理和步骤。

3.1 多传感器量测下粒子权重优化策略

首先,依据式(5)给出提议分布的形式,利用第 k 个采样周期内传感器 j 量测计算粒子权重 $\omega_{k,j}^i$ 。

$$\begin{aligned} \omega_{k,j}^i &= \omega_{k-1,j}^i \frac{1}{\sqrt{2\pi\sigma_{\mathbf{v},k,j}^2}} \exp\{-[\mathbf{z}_{k,j} - h(\mathbf{x}_k^i)]^2 / 2\sigma_{\mathbf{v},k,j}^2\} \\ &= \omega_{k-1,j}^i \frac{1}{\sqrt{2\pi\sigma_{\mathbf{v},k,j}^2}} \exp\{-[h(\mathbf{x}_{k,j}) + \mathbf{v}_{k,j} - h(\mathbf{x}_k^i)]^2 / 2\sigma_{\mathbf{v},k,j}^2\} \end{aligned} \quad (7)$$

由式(7)可知, $\omega_{k,j}^i$ 与 $\mathbf{z}_{k,j}$ 之间呈指数函数关系。 $\mathbf{z}_{k,j}$ 服从均值为 $h(\mathbf{x}_k^i)$ 、方差为 $\sigma_{\mathbf{v},k,j}^2$ 的高斯分布。则 $\omega_{k,j}^i$ 服从均值为 $\exp(h(\mathbf{x}_k^i) + \sigma_{\mathbf{v},k,j}^2/2)$ 、方差为 $((\exp(\sigma_{\mathbf{v},k,j}^2) - 1) \exp(2h(\mathbf{x}_k^i) + \sigma_{\mathbf{v},k,j}^2))^2$ 的高斯分布^[13]。其次,计算第 k 个采样周期内采用 $\lambda_{k,j}$ 为权系数融合后粒子 i 的权重 $\hat{\omega}_k^i$,同时考虑到在一些实时性要求较高的估计系统中滤波采样周期较小而系统状态未发生转移,即 $\mathbf{x}_{k,j} \approx \mathbf{x}_k$,式(7)可进一步简化为

$$\hat{\omega}_k^i = \omega_{k-1,j}^i \sum_{j=1}^M \lambda_{k,j} \frac{1}{\sqrt{2\pi\sigma_{\mathbf{v},k,j}^2}} \exp\{-[h(\mathbf{x}_k) + \mathbf{v}_{k,j} - h(\mathbf{x}_k^i)]^2 / 2\sigma_{\mathbf{v},k,j}^2\} \quad (8)$$

根据高斯分布的性质,则

$$\hat{\omega}_k^i \sim \mathcal{N}\left[\sum_{j=1}^M \lambda_{k,j} \exp(h(\mathbf{x}_k^i) + \sigma_{\mathbf{v},k,j}^2/2), \sum_{j=1}^M (\lambda_{k,j} (\exp(\sigma_{\mathbf{v},k,j}^2) - 1) \exp(2h(\mathbf{x}_k^i) + \sigma_{\mathbf{v},k,j}^2))^2\right] \quad (9)$$

式(9)表明经过融合后所得输出 $\hat{\omega}_k^i$ 的期望为各传感器期望的加权平均值,且精度为

$$\sigma_{\hat{\omega}_k^i}^2 = \sqrt{\sum_{j=1}^M (\lambda_{k,j} (\exp(\sigma_{\mathbf{v},k,j}^2) - 1) \exp(2h(\mathbf{x}_k^i) + \sigma_{\mathbf{v},k,j}^2))^2} \quad (10)$$

$\sigma_{\omega_k}^{\Delta}$ 值越小,表明融合后输出的精度越高,显然,在 $\sigma_{k,j}$ 一定的条件下,式(10)的值与权 $\lambda_{k,j}$ 的分配密切相关。为了使融合后精度达到最高, $\sigma_{\omega_k}^{\Delta}$ 应该达到最小,结合信息守恒原理, $\sigma_{\omega_k}^{\Delta}$ 计算进一步归结为条件求极值的问题。即已知 $\sigma_{k,j}$ 和 $\sum_{j=1}^M \lambda_{k,j} = 1$, 且 $\lambda_{k,j} \geq 0, j=1, 2, \dots, M$, 求 $\lambda_{k,j}$ 在满足什么条件时, $\Psi(\lambda_{k,1}, \lambda_{k,2}, \dots, \lambda_{k,M})$ 的值最小。

$$\Psi = \sum_{j=1}^M (\lambda_{k,j} (\exp(\sigma_{k,j}^2) - 1) \exp(2h(x_k^i) + \sigma_{k,j}^2))^2 \quad (11)$$

考虑到以上是一个约束条件下等式的多变量条件极值问题,具体可采用拉格朗日乘数法进行求解。对 $\lambda_{k,j}$ 的计算和证明如下:

令 $\xi_{k,j} = (\exp(\sigma_{k,j}^2) - 1) \exp(2h(x_k^i) + \sigma_{k,j}^2)$, 引进修正函数 $\vartheta(\sum_{j=1}^M \lambda_{k,j} - 1)$ 后得到 Ψ 的函数表达式。

$$\Psi = \sum_{j=1}^M (\lambda_{k,j} \xi_{k,j})^2 + \vartheta(\sum_{j=1}^M \lambda_{k,j} - 1) \quad (12)$$

对该函数两边分别求 $\lambda_{k,j}$ 偏导数 $\partial\Psi/\partial\lambda_{k,j}, j=1, 2, \dots, M$, 当且仅当 $\partial\Psi/\partial\lambda_{k,j} = 0$ 时, Ψ 取最小值。进而得到 $\lambda_{k,j}$ 的表达式。

$$\lambda_{k,j} = -\vartheta/(2\xi_{k,j}) \quad (13)$$

结合 $\sum_{j=1}^M \lambda_{k,j} = 1$, 则

$$\vartheta = -2/(\sum_{j=1}^M 1/\xi_{k,j}) \quad (14)$$

将式(14)代入式(13)得

$$\lambda_{k,j} = 1/(\xi_{k,j} \sum_{j=1}^M 1/\xi_{k,j}) \quad (15)$$

在获得 $\lambda_{k,j}$ 基础上,利用式(10)可最终获得融合后 $\sigma_{\omega_k}^{\Delta}$ 的精度。

$$\sigma_{\omega_k}^{\Delta} = 1/\sqrt{\sum_{j=1}^M 1/\xi_{k,j}} \quad (16)$$

由式(16)可知:当多传感器量测系统中各传感器精度相同且为 $\sigma_{k,v}$ 时

$$\sigma_{\omega_k}^{\Delta} = \xi_{k,v}/\sqrt{M} \quad (17)$$

表明 M 个精度相同的传感器量测获得的粒子权重度量结果融合后,粒子权重方差相对于单个传感器获得的权重方差提高了 \sqrt{M} 倍。若各传感器精度不同,且设最高精度和最低精度分别为 $\sigma_{k,\max}^2$ 和 $\sigma_{k,\min}^2$, 则

$$\sigma_{\omega_k}^{\Delta} \leq 1/(\xi_{k,\min} + \sqrt{\sum_{j=1}^{M-2} 1/\xi_{k,j}}) \quad (18)$$

根据以上分析可知:在粒子权重优化过程中,对多传感器量测条件下获取的量测似然函数采用以上加权融合方式进行处理,即使精度再差的传感器量测也有利于减小粒子权重方差。

3.2 多传感器量测下权重优化粒子滤波步骤

多传感器量测下粒子权重优化策略是对标准粒子滤波算法中权重度量环节的改进,实现对量测似然函数权值的合理分配。在有效提取和利用多传感器量测中冗余和互补信息的基础上,由 2.1 节中结论可知,融合后的粒子权重方差将明显优于依据单个传感器量测得到的粒子权重方差。因此,利用融合后的粒子权重无疑将会增强粒子权值的稳定性和可靠性。下面采用伪代码的形式给出 WOPF 算法的具体流程。

1. 初始化: $k=0$

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

• 154 •

初始化采样粒子: $x_0^i \sim p(x_0)$;

初始化粒子权重: $\omega_0^i = 1/N$;

END

2. 序贯重要性采样:

For $k \geq 1$

依据第 k 个采样周期内的所有量测,利用式(7)分别计算粒子权重 $\omega_{k,j}^i, i=1, 2, \dots, N, j=1, 2, \dots, M$;

结合式(14)给出权重分配原则,利用加权融合方式求解当前时刻

粒子的权重 $\hat{\omega}_k^i = \sum_{j=1}^M \lambda_{k,j} \omega_{k,j}^i$;

归一化当前时刻粒子权重: $\tilde{\omega}_k^i = \hat{\omega}_k^i / (\sum_{i=1}^N \hat{\omega}_k^i)$;

3. 重采样

重采样后得到一组新的粒子集 $\{x_k^i\}_{i=1}^N$;

重置粒子权重: $\omega_k^i = 1/N$;

4. 结果输出:

$\hat{x}_k = \sum_{i=1}^N x_k^i / N$;

END

4 仿真实验与分析

为验证算法的可行性,仿真实验中给出了两组仿真算例,实验 1 中分别选用了文献[3]以及文献[6]中采用的两种典型非线性系统测试模型。实验 2 基于目标跟踪场景进一步验证 WOPF 在高维非线性系统状态估计问题中的有效性。

实验 1 模型 1

$$x_{k+1} = \alpha x_k + \sin(0.04\pi k) + 1 + u_k$$

$$z_{k,j} = \begin{cases} \beta_1 x_k^2 + v_{k,j}, & 1 \leq k \leq 15 \\ \beta_2 x_k - 2 + v_{k,j}, & 15 < k \leq 30 \end{cases}$$

模型 2

$$x_{k+1} = \xi x_k + \eta [x_k / (1 + x_k^2)] + \mu \cos(\zeta k) + u_k$$

$$z_{k,j} = \beta_3 x_k^2 + v_{k,j}$$

实验 1 两模型中系统演化参数、噪声类型的设置均遵循文献给出的数据。 $\alpha=0.5, \beta_1=0.2, \beta_2=0.5$ 。模型 1 具有噪声非高斯的分段非线性特性, u_k 服从伽玛分布,其噪声统计特性满足 $\mathcal{G}\alpha(3, 2)$; $v_{k,j}$ 服从高斯分布, $j=1, 2, 3$, 其噪声统计特性分别为 $\mathcal{N}(0, 0.005), \mathcal{N}(0, 0.0002), \mathcal{N}(0, 0.001)$ 。 $\xi=0.5, \eta=25, \mu=8, \zeta=1.2, \beta_3=0.05$; 模型 2 被称为单变量非静态增长模型,具有强非线性特性。 u_k 服从高斯分布,其噪声统计特性满足 $\mathcal{N}(0, 10)$; $v_{k,j}$ 服从高斯分布,其噪声统计特性分别为 $\mathcal{N}(0, 5), \mathcal{N}(0, 3), \mathcal{N}(0, 1)$; 采样间隔 τ 为 1, Monte Carlo 仿真次数循环次数为 50, 仿真步数分别取为 30 和 25, 采样粒子个数 N 取 300, 状态的初始值 $x_0=1$ 。仿真实验中对比了 UKF、PF、PFMC、UPF 及 WOPF 等 5 种典型非线性滤波算法,其中前 4 种算法对于多传感器量测数据的利用,采用了具有较好实时性的集中式最优加权融合方式。

图 1 和图 2 中分别给出了 50 次独立实验条件下,基于以上 5 种滤波算法得到的状态估计的均方根误差比较,表 1 中数据定量给出了各滤波算法均方根误差的均值和方差及平均运行时间。由图 1 和表 1 给出的仿真结果可知:在弱非线性、非高斯噪声情况下(模型 1),基于随机采样 PF 及其改进方法的滤波精度明显优于 UKF 算法;而 WOPF 由于改善了粒子权重度量的可靠性,相对于 PF、PFMC 以及 UPF 则能够进一步降低系统状态的估计误差,即使在状态线性演化阶段仍然

保持着较好的性能。同样,由图 2 和表 2 可清晰发现:在强非线性、高斯噪声情况下(模型 2),WOPF 的滤波精度明显优于其他 4 种算法;但 UPF 不仅没有提升 PF 改进后的滤波精度,反而导致滤波精度下降,主要原因就在于 UPF 引入次优滤波器 UKF 来优化提议分布,而 UKF 本身缺乏对强非线性的有效处理能力,这种缺陷清晰地体现在表征 UKF 滤波精度的数据中,进而导致修正后提议分布相对于真实后验分布偏差的进一步扩大。此外,在算法实时性上,与 PFMC 及 UPF 等 PF 的改进方法相比,WOPF 相对于 PF 仅有有限增加。




图 1 基于模型 1 的 RMSE 比较 图 2 基于模型 2 的 RMSE 比较

表 1 基于 50 次独立仿真条件下 RMSE 均值、方差和平均运行时间

算法	模型 1		
	RMSE(mean)	RMSE(Var)	Time(s)
UKF	0.19154	0.04406	—
PF	0.10297	0.05539	0.7689
PFMC	0.04562	0.01307	1.6529
UPF	0.03523	0.00370	5.7376
WOPF	0.02331	0.00038	0.9360

表 2 基于 50 次独立仿真条件下 RMSE 均值、方差和平均运行时间

算法	模型 2		
	RMSE(mean)	RMSE(Var)	Time(s)
UKF	10.263	15.783	—
PF	5.1824	7.9656	0.3984
PFMC	4.8527	6.9710	0.8390
UPF	9.2352	19.854	3.0475
WOPF	4.1866	5.4923	0.5088

实验 2 利用 3 部两坐标雷达传感器的量测数据实现对 X-Y 平面上运动目标的跟踪,目标运动和量测方程如下:

$$\mathbf{x}_k = \mathbf{F}\mathbf{x}_{k-1} + \mathbf{\Gamma}\mathbf{u}_k$$

$$\mathbf{z}_{k,j} = [\gamma_k \quad \theta_k]^T + \mathbf{v}_{k,j}, j=1,2,3$$

式中, $\mathbf{x}_k = [x_k, \dot{x}_k, y_k, \dot{y}_k]^T$, 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; $\mathbf{z}_{k,j}$ 表示第 j 部雷达传感器获取运动目标的径向距 γ_k 和方位角 θ_k 量测数据。 $\gamma_k = \sqrt{x_k^2 + y_k^2}$, $\theta_k = \tan^{-1}(y_k/x_k)$; $\mathbf{F} = \begin{bmatrix} f_1 & 0 \\ 0 & f_1 \end{bmatrix}$ 为系

统状态转移矩阵,且 $f_1 = \begin{bmatrix} 1 & \tau \\ 0 & 1 \end{bmatrix}$, $\mathbf{o} = \begin{bmatrix} 0 & 0 \\ 0 & 0 \end{bmatrix}$; 系统噪声 \mathbf{u}_k

采用均值为 0、标准差为 $0.2\mathbf{I}$ 的高斯白噪声; γ_k 采用均值为 0、标准差分别为 0.2km、0.1km 和 0.25km 的高斯白噪声; θ_k 采用均值为 0、标准差分别为 0.15° 、 0.12° 和 0.15° 的高斯白噪声; 仿真采样间隔 τ 为 1, 系统过程噪声矩阵 $\mathbf{\Gamma} = \begin{bmatrix} 0 & 0 & \tau/2 & \tau \\ \tau/2 & \tau & 0 & 0 \end{bmatrix}$; Monte Carlo 仿真循环次数为 50, 仿真步数为 25, 采样粒子个数 N 取 1000, 目标状态的初值 $\mathbf{x}_0 = [5, 0, 3, 10, 0, 5]^T$ 。仿真实验软硬件平台与实验 1 相同。

图 3 和图 4 中分别给出了 50 次独立实验条件下,采用 EKF、UKF、PF、EPF、UPF 及 WOPF 等 6 种算法在 X 轴方向

和 Y 轴方向上位置分量状态估计的均方根误差比较;表 3 中数据定量给出了各滤波算法均方根误差的均值及平均运行时间的对比结果。从以上仿真结果可以清晰地看出:针对高维非线性系统的状态估计,WOPF 在滤波精度方面明显优于其他 5 种典型非线性滤波算法。此外,我们发现 EPF 和 UPF 不仅在计算量上明显多于 PF,并且滤波精度上也次于 PF,其原因与导致模型 2 中状态估计精度下降的原因相同,这里不再累述。在算法实现的耗时上,WOPF 相对于 PF 增加了 39.4%,EPF 和 UPF 则分别增加了 78.5%和 291.9%。




图 3 X 轴方向 RMSE 比较 图 4 Y 轴方向 RMSE 比较

表 3 基于 50 次独立仿真条件下位置分量 RMSE 均值及平均运行时间

算法	平均运行时间		
	X 轴方向(km)	Y 轴方向(km)	Time(s)
EKF	0.0641	0.1093	—
UKF	0.0615	0.1053	—
PF	0.1326	0.0815	2.6797
EPF	0.0593	0.0970	4.7827
UPF	0.0579	0.0925	10.5031
WOPF	0.0391	0.0646	3.7359

结束语 针对多传感器融合系统自身特点实现粒子滤波器的合理设计,将有效地拓展算法的应用领域,利用多传感器量测信息对粒子权重的直接优化的思想,本文提出了一种多传感器量测下的权重优化粒子滤波算法。相对现有的处理方法,新算法具有以下优点:首先,以 PF 为 WOPF 算法的构建基础,使得算法具有解决非线性特性。其次,由于粒子权重度量仅和当前时刻采集到的数据的传感器精度有关,而与传感器数目以及采样速率无关,避免了单步采样中传感器量测缺失和错序问题对权重度量结果的不利影响。另外,根据算法构建过程可知,WOPF 通过降低随机噪声对粒子度量结果可靠性的影响实现粒子权重的优化,并没有增加重采样步骤的计算复杂度,而重采样过程是 PF 实现过程中计算量的主要负担部分,因此相对于 PF 算法,WOPF 在有效改进滤波精度的同时计算量增加有限。

参考文献

- [1] 潘泉,梁彦,杨峰,等.现代目标跟踪与信息融合[M].北京:国防工业出版社,2009
- [2] 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
- [3] Li L Q, Ji H B, Luo J H. The iterated extended Kalman particle filter[C]// IEEE International Symposium on Communications and Information Technology. 2005: 1213-1216
- [4] 祝继华,郑南宁,袁泽剑,等.基于中心差分粒子滤波的 SLAM 算法布[J].自动化学报,2010,36(2): 249-257

先级时隙内的业务,其媒质访问时间有所增加。修改多优先级混合时隙包含的时隙数可以有效实现不同 QoS 需求的业务的媒质访问延迟的调节。

图 6 和图 7 给出了网络非饱和条件下,随着站点的增加总吞吐量和各业务吞吐量的变化情况。网络处于非饱和条件下,业务之间的碰撞概率低。因此,混合时隙传输方法与 ED-CA 机制传输方法的总吞吐量和各业务吞吐量均增加且增加趋于平缓。当整个网络发送量较少时,高优先级业务的吞吐量占了整个网络吞吐量的大部分。采用多优先级混合时隙对高优先级的吞吐量有很大的提升。




图 6 非饱和条件下总吞吐量




图 7 非饱和条件下各业务吞吐量

结束语 本文提出了一种新的基于 IEEE 802.11e ED-CA 机制的多优先级混合时隙传输方法,将各业务根据其 QoS 需求组合分配到不同优先级的时隙中进行传输。分别针对网络饱和和非饱和条件,建立了相应的多优先级混合时隙传输方法模型。通过理论分析及仿真研究表明:与传统区分服务机制相比,多优先级混合时隙传输方法有效提高了特定传输 QoS 需求业务的传输质量。

为了进一步提高多优先级混合时隙传输方法的性能,在接下来的工作中将继续研究在多媒体网络中根据传输 QoS 需求,自适应地调整混合时隙中的时隙数,调整不同的接入参数,从而提高特定 QoS 需求业务的传输性能。

参考文献

- [1] 董超,陈贵海,王海. 无线网状网的 QoS 研究[J]. 软件学报, 2009,20(6):1539-1552
 - [2] 李文新,李宇光,胡延苏,等. 嵌入式无线局域网中 H.264 视频传输的 QoS 研究[J]. 计算机科学,2011,38(5):83-85
 - [3] IEEE 802.11e. Wireless LAN Media Control(MAC) and physical layer(PHY) specifications[S]. 2005
 - [4] Chen Yeong-sheng, Lee Yuan-wei, Hyuk P J. Enhanced HCCA mechanism for multimedia traffics with QoS support in IEEE802.11e networks[J]. Journal of Network and Computer Application,2011,34(5):1566-1571
 - [5] 葛永明,朱艺华,龙胜春,等. IEEE802.11 移动自组织网络节点竞争窗口长度的概率分布[J]. 电子学报,2010,38(8):1841-1844
 - [6] 陈晨,高新波,张素兵,等. 无线局域网中 TXOP 动态分配方法[J]. 计算机工程,2010,37(7):11-13
 - [7] Hu Jia, Min Ge-yong, Jia Wei-jia, et al. Comprehensive QoS analysis of enhanced distributed channel access Comprehensive QoS analysis of enhanced distributed channel access in wireless local area networks[J]. Information Sciences, 2012,214(10):20-34
 - [8] 康凯,胡海波,林孝康. 一种新的用于 IEEE 802.11e EDCA 中提供 QoS 的方法[J]. 电子与信息学报,2007,29(12):2991-2995
 - [9] Yao Xin-wei, Wang Wan-liang, Yang Shuang-hua, et al. PABM-EDCF: parameter adaptive bi-directional mapping mechanism for video transmission over WSNs[J]. Multimedia Tools and Applications, 2011,9(4):378-387
 - [10] 杜建超,吴嵩,吴成柯. 一种基于 EDCA 的视频数据包动态映射算法[J]. 电子与信息学报,2012,34(1):46-50
 - [11] Bianchi G. Performance analysis of the IEEE 802.11 distributed coordination function [J]. Selected Areas in Communications, 2000,18(3):535-547
 - [12] 张勇,谭小彬,崔孝林,等. 基于 Markov 博弈模型的网络安全态势感知方法[J]. 软件学报,2011,22(3):495-508
 - [13] 张伟. IEEE 802.11e 的网络性能、容量评估与资源分配策略研究[D]. 上海:上海交通大学,2008
-
- (上接第 155 页)
- [5] Seongkeun P, Jae P H, Euntai K, et al. A new evolutionary particle filter for the prevention of sample impoverishment [J]. IEEE Transactions on Evolutionary Computation, 2009,13(4):801-809
 - [6] 刘先省,胡振涛,金勇,等. 基于粒子优化的多模型粒子滤波算法[J]. 电子学报,2010,38(2):301-306
 - [7] Zhai Y, Yeary M. Implementing particle filters with metropolis-hastings algorithms[C]// Region 5 Conference: Annual Technical and Leadership Workshop. 2004:149-152
 - [8] Hlinomaz P, Hong L. A multi-rate multiple model track-before-detect particle filter[J]. Mathematical and Computer Modelling, 2009,49(1):146-162
 - [9] Armesto L, Ippoliti G, Longhi S, et al. Probabilistic self-localization and mapping-An asynchronous multi-rate approach [J]. IEEE Robotics & Automation Magazine, 2008,15(2):77-88
 - [10] Tehrani N H, Seiichi M, Han L. Multi-Sensor data fusion for autonomous vehicle navigation through adaptive particle filter[C]// IEEE Intelligent Vehicles Symposium. 2010:752-759
 - [11] Achutegui K, Míguez J. A parallel resampling scheme and its application to distributed particle filtering in wireless networks[C]// The fourth IEEE International Workshop on Computational Advances in Multi-Sensor Adaptive Processing. 2011:81-84
 - [12] François C, Davy M, Duflos E, et al. Particle filtering for multi-sensor data fusion with switching observation models: application to land vehicle positioning[J]. IEEE Transactions on Signal Processing, 2007,55(6):2703-2719
 - [13] 菲诗松,王静龙,濮晓龙. 高等数理统计[M]. 北京:高等教育出版社,2006