

## 基于粒子群优化和 M-H 抽样粒子滤波的传感器网络目标跟踪方法

蒋鹏<sup>1</sup>, 宋华华<sup>1</sup>, 林广<sup>2</sup>

(1. 杭州电子科技大学 信息与控制研究所, 浙江 杭州 310018; 2. 浙江省环境监测中心, 浙江 杭州 310012)

**摘要:** 针对实际应用条件下传感器节点的观测数据与目标动态参数间呈现为非线性关系的特性, 提出了一种基于粒子群优化和 M-H 抽样粒子滤波的传感器网络目标跟踪方法。该方法采用分布式结构, 在动态网络拓扑结构下, 由粒子群优化和 M-H 抽样技术实现滤波中的重抽样过程, 抑制粒子退化现象, 并通过粒子间共享历史信息, 降低单个粒子历史状态间的相关性使各粒子能快速收敛至最优分布, 从而实现高精度的目标跟踪效果。仿真结果表明, 相比现有的基于信息粒子滤波和并行粒子滤波技术的传感器网络目标跟踪方法, 所提出的方法能降低网络总能耗, 同时保证目标跟踪的精度。

**关键词:** 粒子群优化; metropolis-hasting 抽样; 粒子滤波; 目标跟踪

中图分类号: TP393

文献标识码: A

文章编号: 1000-436X(2013)11-0008-10

## Target tracking algorithm for wireless sensor networks based on particle swarm optimization and metropolis-hasting sampling particle filter

JIANG Peng<sup>1</sup>, SONG Hua-hua<sup>1</sup>, LIN Guang<sup>2</sup>

(1. Institute of Information and Control, Hangzhou Dianzi University, Hangzhou 310018, China;

2. Zhejiang Province Environmental Monitoring, Hangzhou na)

**Abstract:** For the characteristic of the nonlinear relationship between the observation information of sensor nodes and the target dynamic parameters under the real application conditions, a target tracking algorithm for wireless sensor networks based on particle swarm optimization and Metropolis-Hasting sampling particle filter was proposed. Distributed architecture is adopted in this target tracking scheme. And under the dynamic network topology, particle swarm optimization and Metropolis-Hasting sampling are introduced into the resampling period to reduce sample degeneracy. In order to achieve the goal of high-precision tracking performance, the history information is shared among the particles to reduce the correlation between the history states of a single particle, so that the particles can rapidly converge to an optimal distribution. The simulations corroborate that compared with currently existing target tracking schemes based on the technology of information particle filter and parallel particle filter, the proposed scheme can reduce the total energy consumption, while ensuring the accuracy of target tracking.

**Key words:** particle swarm optimization; metropolis-hasting sampling; particle filter; target tracking

收稿日期: 2013-04-13; 修回日期: 2013-07-11

基金项目: 国家自然科学基金资助项目(61273072); 浙江省自然科学基金资助项目(Y1100054, Y1111220); 浙江省环保科技计划基金资助项目(2013A034); 浙江省安全生产科技计划基金资助项目(2013A1006); 杭州市科技局科技计划基金资助项目(20120433B40)

**Foundation Items:** The National Natural Science Foundation of China(61273072); The Natural Science Foundation of Zhejiang Province(Y1100054, Y1111220); The Environmental Protection Plan of Zhejiang Province(2013A034); The Safety Science and Technology Plan of Zhejiang Province(2013A1006); The Science and Technology Program of Science and Technology Department of Hangzhou (20120433B40)

## 1 引言

在传感器网络目标跟踪方法的发展历程中, 初期多利用现成的定位方法实现对目标的定位, 如 TOA(time of arrival)、TDOA(time difference of arrival)、AOA(angle of arrival)、MPS(multi-path signature)、RSSI(received signal strength indication)等, 这些方法原理简单, 易于实现但精度较低, 且在进行目标跟踪时, 仅能实现对目标位置的粗略估计, 而无法对目标的速度或加速度做精确的估计<sup>[1,2]</sup>。在跟踪精度要求较高或需要对目标状态作全面估计的场合, 卡尔曼滤波(KF, Kalman filter)、扩展卡尔曼滤波(EKF, extended Kalman filter)、无迹卡尔曼滤波(UKF, unscented Kalman filter)、粒子滤波(PF, particle filter)等方法被引入传感器网络目标跟踪系统中, 以节点的观测值作为滤波方法的输入量, 把所求目标的状态作为输出, 根据状态方程和量测方程计算和校正目标的状态估计<sup>[3,4]</sup>。UKF 是一种应用较为广泛的非线性系统滤波方法, ANAND 等人<sup>[5]</sup>提出了一种以 UKF 算法为核心的传感器网络目标跟踪方法, 利用 BP(back propagation)神经网络校正机动目标建模中的误差, 其输出为 UKF 处理所得的目标状态估计与目标真实值之间偏差的估计值, 该偏差值将反馈至 UKF 以提高目标跟踪的精度。上述方法所适用的系统均须具备高斯或弱非线性条件, 在非线性非高斯条件下的表现则差强人意, 目前针对这一难题常用的方法是采用粒子滤波方法。近年来, 学者以粒子滤波方法为核心进行了一系列的研究和改进工作, 改进后的方法如辅助粒子滤波(APF, auxiliary particle filter)<sup>[6]</sup>、正规粒子滤波(RPF, regularized particle filter)<sup>[7]</sup>、RB 粒子滤波(RBPF, rao-blackwellized particle filter)<sup>[8]</sup>等。邹冈等人<sup>[9]</sup>对粒子滤波方法进行了改进, 使其能适用于传感器网络目标跟踪系统, 在采用动态分簇结构的传感器网络中分别利用信息粒子滤波(IPF, information particle filter)和并行粒子滤波(PPF, parallel particle filter)方法实现分布式估计。IPF 与标准粒子滤波的标志性区别是将扩展卡尔曼滤波引入粒子滤波, 该方法中粒子滤波的建议密度由 EKF 生成, 并采用了分簇结构, 在簇头内执行后融合得到簇内目标状态的本地估计。PPF 则是由簇首节点将粒子均匀分配至簇内的成员节点, 通过降低单个节点处理的粒子数和分布式处理的方法降低节点能耗。这 2 种方法

能一定程度地节约通信能耗, 起到平衡网络中节点能耗的效果, 但是由于在粒子滤波中需要频繁地进行重抽样, 剔除权重值较小的粒子, 因而无法避免该过程中的粒子退化现象, 这将严重影响目标跟踪的精度, 甚至导致系统丢失目标。针对传感器网络目标跟踪系统中存在的上述问题, 本文提出了一种基于粒子群优化和 M-H 抽样粒子滤波(PSO-MHPF, particle swarm optimization and metropolis-hasting sampling particle filter)的传感器网络目标跟踪方法。该方法采用动态分簇结构和分布式算法, 将粒子群优化(PSO, particle swarm optimization)和 metropolis-hasting(M-H)抽样方法引入到粒子的生成和抽样中, 使各粒子在传播时需综合考虑该粒子以及相邻粒子的历史最优值, 进而动态地调整粒子演进的速度和分布, 使其收敛至最优分布, 通过粒子间的这种信息共享, 也可降低单个粒子各历史状态间的相关性, 从而加快粒子分布的收敛速度。PSO-MHPF 方法主要在粒子滤波的重抽样阶段进行了创新, 在该阶段不再轻易地剔除权值较小的粒子, 而是通过调整粒子分布使每个粒子都能得到优化并发挥出作用, 可有效避免粒子退化现象, 同时获得非线性非高斯条件下较为精确的目标跟踪效果。

## 2 系统模型

首先将建模过程中的一些假设和定义描述如下。

1) 总数为  $N$  的传感器节点布设在  $m \times n$  的监测区域后, 网络内各节点将节点坐标视作已知数据, 节点的坐标以直角坐标的方式表示成  $(x_i, y_i)$ ,  $i \in \{1, L, N\}$ 。

2) 传感器网络中的节点随机地布设在监测区域内, 实现对监测区域的完全覆盖, 即当目标处于该区域内任一位置时, 至少有一个节点能监测到该目标的信息。

3) 所采用的节点具备类似 MAC 地址的身份识别标签, 便于节点通信时明确源节点或目的节点的编号, 同时节点配备能量监测传感器, 可实时感知节点的剩余能量。

4) 各节点具有相同的感知半径  $R_s$  和通信半径  $R_c$ , 在节点所带电池的能量消耗完毕前, 节点的感知半径和通信半径始均为常量。

### 2.1 目标模型

将  $k$  时刻机动目标的真实状态表示为  $x_k$ , 当其处

于二维空间时, 取其状态向量为  $x_k = [p_x \quad v_x \quad p_y \quad v_y]^T$ , 其中,  $p_x$ 、 $p_y$  是  $x$  和  $y$  方向上的位置分量,  $v_x$ 、 $v_y$  则为速度分量。则状态方程可表示为

$$x_{k+1} = A(x_k)x_k + Gw_k \quad (1)$$

其中,  $A(x)$  为状态转移矩阵,  $G$  为噪声转移矩阵,  $w_k$  表示过程噪声。

本文设置一种做直线运动的机动目标模型, 用以考查所提出的 PSO-MHPF 方法在跟踪该类目标时的性能。在考查目标跟踪方法的能耗时要求目标在监测区域内运动足够长的时间, 所以设计目标的状态方程时, 需利用特定的状态转移矩阵  $A(x)$  将目标运动限制在边长为  $l$  的矩形区域内。

目标做直线运动时, 状态转移矩阵  $A(x)$  定义为<sup>[10]</sup>

$$A(x) = M(x) \otimes F_1 + (I_2 - M(x)) \otimes F_2 \quad (2)$$

$$\text{其中, } F_1 = \begin{bmatrix} 1 & T \\ 0 & 1 \end{bmatrix}, F_2 = \begin{bmatrix} 1 & T \\ -Tc_1 & 1 - Tc_2 \end{bmatrix}, M(x) = \begin{bmatrix} m(x_1) & 0 \\ 0 & m(x_3) \end{bmatrix}。$$

矩阵  $F_1$  和  $F_2$  的作用在于决定目标在限制区域内外时不同的动态特性,  $T$  为步长,  $c_1$ 、 $c_2$  为大于 0 的控制参数,  $I_2$  为二阶单位阵,  $\otimes$  表示两矩阵做克罗内克积。矩阵  $M(x)$  中函数  $m(x)$  的参数  $x_1$  和  $x_3$  分别表示状态矩阵的第 1 项和第 3 项元素, 即目标状态的位置分量, 该函数将根据输入值的不同返回 0 或 1, 其定义为

$$m(x) = \frac{s(a+x) + s(a-x)}{2}, s(z) = \begin{cases} 1, & z \geq 0 \\ -1, & z < 0 \end{cases} \quad (3)$$

其中,  $a$  为常量, 该值即为限定目标运动区域边界的阈值。此外, 噪声转移矩阵  $G$  以及过程噪声  $w_k$  的方差矩阵  $Q$  定义如式(4)所示, 其中,  $s_0^2$  为零均值高斯白噪声的方差, 控制常量  $q$  使目标运动的轨迹具有不确定性。

$$G = I_2 \otimes \begin{bmatrix} Ts_0^2/2 \\ Ts_0 \end{bmatrix}, Q = \begin{bmatrix} \frac{T^3 q}{2} & \frac{T^2 q}{2} & 0 & 0 \\ \frac{T^2 q}{2} & Tq & 0 & 0 \\ 0 & 0 & \frac{T^3 q}{2} & \frac{T^2 q}{2} \\ 0 & 0 & \frac{T^2 q}{2} & Tq \end{bmatrix} \quad (4)$$

## 2.2 感知模型

在系统运行的各时刻, 节点通过传感器感知目标信息, 以恒定而快速的频率采集 1 000 个样本后取其均值作为节点对目标的量测值。假设由节点的传感器采集的样本值服从高斯分布, 其值为  $s^2 + gI_k d_{k,i}^{-x}$ 。其中,  $s^2$  为传感器量测噪声的方差, 包含节点内部噪声和背景噪声两部分,  $gI_k d_{k,i}^{-x}$  表示由节点感知到的目标信号,  $g$  为节点的增益因子,  $I_k$  是  $k$  时刻目标发出的恒功率信号的强度,  $x$  为信号衰减因子,  $d_{k,i}$  则表示  $k$  时刻节点  $i$  与目标之间的欧氏距离为

$$d_{k,i} = \sqrt{(p_x - x)^2 + (p_y - y)^2} \quad (5)$$

对所有采集到的样本信号处理后, 将所得感知信号的均值和方差分别表示为<sup>[11]</sup>

$$m_i(x_k) = s_i^2 + g_i I_k d_{k,i}^{-x} \quad (6)$$

$$R_i(x_k) = \frac{2}{N_{\text{sam}}} c [s_i^2 + g_i I_k d_{k,i}^{-x}]^2 \quad (7)$$

式(7)中, 参量  $c$  用于模拟系统的非线性,  $N_{\text{sam}}$  表示传感器一次抽样的样本数目。

综上, 可将节点的感知模型整合为

$$z_{k,i} = \begin{cases} m_i(x_k) + v_i(x_k), & \text{若 } E_{k,i} = 1 \\ v_i^*, & \text{其他} \end{cases} \quad (8)$$

其中,  $v_i(x_k)$  是零均值的高斯白噪声, 其方差为  $R_i(x_k)$ ,  $E_{k,i}$  是一个默认值为 0 的标志位, 在节点  $i$  感知到目标信号时置位为 1,  $v_i^*$  则是方差为  $(2/N_{\text{sam}})cs_i^4$ , 且均值为零的高斯白噪声。

## 2.3 动态拓扑结构

本文中的传感器网络平台采用一种可随目标运动而实时建立和切换的动态分簇结构。节点布设后设置为休眠状态, 在该状态下, 节点仅将传感器和无线通信接收器置于工作状态, 而将处理器等其它设备置于关闭状态, 目的是利用观测事件的发生激活传感器网络的初次建簇。以观测事件激活节点的其他设备, 再建立用于跟踪目标的分簇结构的方法可以最大限度地降低节点的能量消耗, 延长传感器网络的寿命。失去感知信号后, 节点将返回休眠状态。

下面将这种动态分簇结构的原理简述如下。

1) 监测区域内各节点在部署后处于默认的休眠状态, 当目标出现在监测区域内时, 网络中部分

节点因感知到该目标的信号而激活。

2) 以式(6)中节点感知的信号强度为依据, 结合节点的剩余能量  $E_{i, res}$  选拔簇首节点。考查当前  $N_{act}$  个活跃节点, 由剩余能量大于阈值的节点中感知信号最强的节点作为本次选拔的簇首。

3) 簇首节点广播信号至通信半径  $R_c$  内的其他节点, 由于各节点均有唯一的身份识别标签, 因此被唤醒的节点很容易就能获取信号源的身份, 在此基础上便可与簇首节点建立通信, 从而以该信号源节点为簇首, 成为簇中的成员节点。

4) 因目标具有机动能力, 为了实时跟踪目标, 需要在一定时刻建立新的分簇, 并实现簇间的切换和数据交割。簇间切换的临界条件设置为  $(N_{act} < 3) \parallel$

$\left( \frac{N_{act}}{N_{cluster}} - \frac{1}{4} \right)$ , 其中,  $N_{act}$  表示当前活跃的节点数,  $N_{cluster}$  则为当前簇内节点总数。当临界条件满足时, 簇内活跃的节点数过少将导致跟踪精度过低, 甚至丢失目标, 此时需及时切换并构建新簇。

5) 节点切换时, 由簇首节点根据下一时刻目标状态的预测值, 激活离该位置最近的节点, 并按步骤 2)至步骤 3)的原则建立新的分簇。在当前簇首节点将目标状态估计等信息发送至下一簇首后, 当前簇内所有节点将重回休眠状态。

### 2.4 能耗模型

节点能量的消耗直接影响到传感器网络的寿命, 因此设计低功耗的传感器网络目标跟踪系统具有实际意义。本节旨在设计符合实际的节点能耗模型用以考查所提出的目标跟踪方法在能耗上的表现。

传感器网络的总能耗主要由数据通信的能耗(包括发送数据的能耗  $E_{Tx}$  和接收数据的能耗  $E_{Rx}$ ) 和运行跟踪算法的能耗  $E_{Rf}$  组成。节点间的无线通信以单跳或多跳的方式实现, 本文中, 假设节点间的无线通信是对称的, 即发送等量数据时, 由节点 A 发送数据至节点 B 时消耗的能量与节点 B 发送数据至节点 A 时消耗的能量相等。数据通信时取节点的发送器和接收器的能耗为  $E_{elec} = 50 \text{ nJ/bit}$ , 发送

放大器的功耗为  $E_{amp} = 100 \text{ pJ/bit/m}^2$ 。间距为  $d$  的 A、B 2 节点在数据通信时, 由 A 发送  $k \text{ bit}$  数据消耗的能量为<sup>[12]</sup>

$$E_{Tx}(k, d) = E_{Tx-elec}(k) + E_{Tx-amp}(k, d) = E_{elec} \times k + E_{amp} \times k \times d^2 \quad (9)$$

同样, 节点 B 接收由 A 发送的这些数据应消耗的能量可表示为

$$E_{Rx}(k) = E_{Rx-elec}(k) = E_{elec} \times k \quad (10)$$

节点执行程序时的能耗为

$$E_{Rf} = N_c \times C \times V_{dd}^2 \quad (11)$$

其中,  $N_c$  表示节点执行指令的时钟周期数,  $C$  为切换电容均值,  $V_{dd}$  则是电源电压。节点间的无线通信特征和通信模型分别如表 1 和图 1 所示。

表 1 无线通信特征

操作	能量消耗
发送电路 $E_{Tx-elec}$	50 nJ / bit
接收电路 $E_{Rx-elec}$	
$E_{Tx-elec} = E_{Rx-elec} = E_{elec}$	
发送放大器 $E_{amp}$	100 pJ/bit/m <sup>2</sup>
程序执行器 $E_{Rf}$	$N_c \times C \times V_{dd}^2$

### 3 粒子群优化和 M-H 抽样粒子滤波

粒子滤波是一种蒙特卡洛类的非线性滤波算法, 适用于解决非线性模型和非高斯噪声条件下的信号处理问题, 目前已有学者将其引入无线传感器网络目标跟踪系统中<sup>[13,14]</sup>。该算法通过递归地构建状态变量的条件概率分布, 以随机样本对概率密度函数进行近似后, 获得状态的最小方差估计。根据标准粒子滤波的原理, 在抽样过程中, 权值小于阈值的粒子将被舍弃, 因而在几次迭代后, 可能会出现样本退化现象, 即众多粒子因权重值较小而被剔除, 最终转变为一个单一的点, 这种现象会严重影响目标跟踪系统的精度, 甚至是丢失目标。抑制样




图 1 节点间无线通信模型

本退化的方法有 2 种,即增加粒子数或重抽样,由于增加粒子数将直接增大计算量,在本文的 PSO-MHPF 方法中,由簇首节点完成粒子初始化、粒子分配和融合目标状态全局估计等工作,减少单个成员节点处理的粒子数量,从而降低成员节点的负担。成员节点则负责调整粒子分布和计算目标状态的局部估计。在粒子调整过程中,本文创新性地将粒子群优化技术和 Metropolis-Hasting 抽样方法相结合进行重抽样来抑制样本退化现象,提高了目标跟踪的精度和滤波的收敛速度。

本文所提出的 PSO-MHPF 方法在初始化各粒子后,采用结合粒子群优化技术<sup>[15]</sup>的 Metropolis-Hasting 抽样方法<sup>[16]</sup>实现重抽样,目的是加速滤波的收敛速度,抑制滤波过程中因频繁重抽样而出现的样本退化现象,从而起到提高滤波精度的作用,在实现重抽样的过程中,马尔可夫链的构建由 M-H 方法实现。基于粒子群优化和 M-H 抽样粒子滤波方法的原理表述如下。

1) 初始化。根据预设的先验分布  $p(x_0)$ , 抽取粒子  $x_0^i$ , 将各粒子的权重值设置为  $w_0^i$ , 其中,  $i=1,2,L,N_p$ ,  $N_p$  为粒子总数。

2) 一步预测。在  $k$  时刻,根据系统模型,对各粒子作一步预测,得到各粒子的预测值为

$$\hat{x}_k^i = f(x_{k-1}^i, v_{k-1}^i) \quad (12)$$

其中,  $f(\cdot)$  表示目标的状态转移函数,  $x_{k-1}^i$  为粒子  $i$  在上一次迭代中所得的结果,  $v_{k-1}^i$  则表示对应的过程噪声。

3) 权值更新。在获取当前时刻目标的量测信息  $z_k$  后,按式(13)对粒子的权值进行更新,再由式(14)做归一化处理

$$\mathcal{W}_k^i = w_{k-1}^i p(z_k | \hat{x}_k^i) \quad (13)$$

$$w_k^i = \frac{\mathcal{W}_k^i}{\sum_{i=1}^{N_p} \mathcal{W}_k^i} \quad (14)$$

步骤 2)和步骤 3)主要是对粒子及其对应权重值进行处理,构建了一个  $k$  时刻的离散分布,在该分布中,各项元素  $\{\hat{x}_k^i : i=1,2,L,N_p\}$  对应的权值为  $\{w_k^i : i=1,2,L,N_p\}$ ,则目标状态的后验分布可近似地表示为

$$\hat{p}(x_k | z_{1:k}) = \sum_{i=1}^{N_p} w_k^i d(x - \hat{x}_k^i) \quad (15)$$

其中,  $d(\cdot)$  表示狄拉克函数,从而可计算得目标状态的估计值为

$$\hat{x}_k = \sum_{i=1}^{N_p} w_k^i \hat{x}_k^i \quad (16)$$

4) 重抽样。若抽样有效尺度小于阈值,则需进行重抽样,这里采用结合粒子群优化技术的 M-H 抽样方法实现粒子滤波的重抽样过程,步骤如下。

(a) 初始化,令

$$t = 0, x_{k,0}^i = \hat{x}_k^i, V_{k,0}^i = 0, x_{k,0}^i = w_k^i \quad (17)$$

其中,  $t$  表示第  $t$  次迭代。

(b) 搜寻  $\{x_{k,t}^i : i=1,2,L,N_p\}$  中的最大权重值,将其对应的粒子标记为  $gB_{k,t}$ ,即 PSO 中粒子的历史最优值。再找出粒子  $i$  自身的历史权重  $\{x_{k,j}^i : j=1,2,L,t\}$  中的最优值,标记为  $pB_{k,t}$ 。

(c) 采用 PSO 对粒子  $x_{k,t}^i$  的演进速度和位置进行调整:

$$V_{k,t+1}^i = V_{k,t}^i + j_1(pB_{k,t} - x_{k,t}^i) + j_2(gB_{k,t} - x_{k,t}^i) \quad (18)$$

$$\hat{x}_{k,t+1}^i = x_{k,t}^i + V_{k,t+1}^i \Delta t \quad (19)$$

(d) 计算接受概率为

$$r = \frac{\hat{p}(\hat{x}_{k,t+1}^i | z_{1:k}) Q(x_{k,t}^i | \hat{x}_{k,t+1}^i)}{\hat{p}(x_{k,t}^i | z_{1:k}) Q(\hat{x}_{k,t+1}^i | x_{k,t}^i)} \quad (20)$$

(e) 抽取随机数  $u : U(0,1)$ ,若  $u < \min(r,1)$ ,那么

$$x_{k,t+1}^i = \hat{x}_{k,t+1}^i \quad (21)$$

否则

$$x_{k,t+1}^i = x_{k,t}^i \quad (22)$$

(f) 计算各粒子的权重值为

$$x_{k,t+1}^i = p(z_k | x_{k,t+1}^i) \quad (23)$$

(g) 若  $t < B + J$ ,则将  $x_{k,t+1}^i$  和  $x_{k,t+1}^i$  代入步骤(b)进行下一次迭代;否则,若  $t = B + J$ ,则迭代结束。经过  $B + J$  次迭代后,得到粒子

$$x_k^i = x_{k,B+J}^i, i=1,2,L,N_p \quad (24)$$

并将权重值归一化为  $w_k^i = \frac{1}{N_p}$  后,转入步骤 2)

进行下一轮操作。

## 4 基于 PSO-MHPF 的传感器网络目标跟踪方法

PSO-MHPF 方法应用于传感器网络目标跟踪系统中时,将其与网络动态分簇的拓扑结构相结合,以分布式的方式搭建目标跟踪方法的架构,采

用结合了粒子群优化技术的 M-H 抽样方法构建马尔可夫链,用以完成粒子滤波中的重抽样过程,以抑制粒子滤波中常见的样本退化现象,提高目标跟踪的精度,同时,PSO 的引入有助于各粒子在演进速率和位置方面的优化,加快滤波的收敛速度。基于 PSO-MHPF 的传感器网络目标跟踪方法实现步骤描述如下。

1) 传感器节点布设在监测区域后,处于休眠状态,即将节点设备中的传感器和无线通信接收器置于工作状态。当监测事件发生时,网络中部分节点因接收到目标的信号而激活,节点切换至工作状态。

2) 激活的节点若剩余能量大于能量阈值(能量阈值指执行一次发送、接收和处理数据的能量总和,由式(9)~式(11)决定,即能量阈值 =  $E_{Tx} + E_{Rx} + E_{Rf}$ ),则向邻节点广播其接收到目标信号的强度,然后搜寻出接收到信号为最强的节点,将其标记为簇首。与簇首节点间具有通信能力的节点根据其身份标签,加入分簇成为其中的成员节点。在进行目标跟踪时,簇首节点负责完成簇内数据的融合,并在分簇切换时将数据传送到下一簇首节点。

3) 在初次跟踪时簇首节点需完成滤波的初始化工作,主要是粒子的生成和对应的权重值的计算。

4) 在生成粒子和权重值后,簇首节点(CH, cluster head)便根据当前时刻活跃簇内成员(CM, cluster member)节点总数  $N_{act}$ ,将总数为  $N_p$  的粒子按式(25)分配至各成员节点,使分布式的 PSO-MHPF 方法得以在簇内节点间实现。簇中第  $i$  个活跃节点应分配的粒子数为

$$N_{p,i} = \left\lfloor \frac{N_p - \sum_{j=0}^{i-1} N_{p,j}}{N_{act} - (i-1)} \right\rfloor \quad (25)$$

其中,  $\lfloor \cdot \rfloor$  为取整运算,  $N_{p,i}$  表示簇中第  $i$  个节点应分得的粒子数,且  $N_{p,0} = 0$ 。在式(25)的右式中,分子的计算结果为剩余粒子的总数,分母则为尚未分配粒子的节点数。

5) 各节点在分配得粒子后,便可结合该节点对目标的量测值  $z_{1,k}$ ,对粒子进行处理,以获得目标状态的后验分布。在这一过程中,首先需对粒子做一步预测和权值更新。

6) 利用 PSO-MHPF 方法实现马尔可夫链蒙特卡洛过程,对粒子进行重抽样。首先经 PSO 结合粒子自身的历史最优值和所有粒子的历史最优值,动

态地调整粒子的演进速率,结合接受概率对粒子分布做调整,目的是使粒子分布收敛至最优。

7) 在调整粒子分布的过程中,根据前文所述 PSO-MHPF 方法的原理,该调整过程总共需迭代  $B+J$  次,最终,粒子  $x_k^i$  被调整至  $x_{k,B+J}^i$ ,经归一化后,其权值调整为  $1/N_p$ 。

8) 步骤 7) 所得粒子及对应的权重值后,便可近似地表示目标状态的后验分布  $\hat{p}(x_k | z_{1:k})$ ,从而各成员节点可根据该分部计算得到目标状态的局部估计  $\%_{k,i}$ 。局部估计将被上传至簇首节点进行融合后得到当前时刻目标状态的全局估计  $\%_k$ 。

9) 因目标具备机动能力,一定时间后当前分簇必定不再具备监测能力,需根据簇间切换的临界条件,判断下一时刻是继续在当前分簇内进行跟踪,还是需另行建立分簇。若临界条件满足,当前簇首需根据全局估计  $\%_k$  中的位置和速度分量,结合步长  $T$  计算下一时刻目标状态的预测值,然后将  $\%_k$ 、 $x_k^i$ 、 $w_k^i$  等必要信息打包发送至离该预测值最近的节点  $b$ ,由节点  $b$  接手簇首的工作并根据建簇原理建立分簇,以便在下一时刻实时跟踪目标。

## 5 仿真算例

以上已对本文所提出的 PSO-MHPF 方法的原理和实现步骤做了详细的叙述,并对传感器网络的目标模型、感知模型、拓扑结构和能耗模型等做了阐述,本节将结合这些内容,考查 PSO-MHPF 方法在动态网络拓扑结构下跟踪机动目标时的性能表现。为了直观地展现该方法的性能,将 IPF 和 PPF 作为对比方法,在相同仿真环境下通过具体的仿真实验,对比分析 PSO-MHPF 方法的网络总能耗、目标跟踪精度等性能指标。仿真中,假设各节点均配置声波传感器,以预定的时间间隔采集周边环境中的声音信号。目标的运动模型、节点的感知模型、网络的拓扑结构以及网络的能耗模型已在前文中做了说明,仿真时涉及的参数设置如表 2 所示。

因本文提出的基于粒子群优化和 M-H 抽样粒子滤波的传感器网络目标跟踪方法是在动态网络拓扑结构下实现的,网络中节点初次感知到目标信号时,需及时完成分簇的建立,从而使 PSO-MHPF 得以在簇内执行。根据前文中构建动态网络拓扑结构的原理,当机动目标以初始状态  $[-45 \ -20 \ -50 \ -35]^T$  出现在监测区域时,传感器网络首次构建的拓扑结构如图 2 所示。

表 2 仿真参数设置

参数名称	符号	取值	参数名称	符号	取值
监测区域	$m \times n$	400 m × 400 m	方差	$s_0^2$	1
节点数目	$N$	256	增益因子	$g$	±30%
感知半径	$R_s$	60 m	衰减因子	$\alpha$	2.2
通信半径	$R_c$	75 m	传感器抽样次数	$N_{sam}$	1 000
初始状态	$x_0$	[- 45 - 20 - 50 - 35] <sup>T</sup>	非线性常量	$c$	1.5
参数	$a$	180	粒子总数	$N_p$	400
步长	$T$	0.04	系统参数	$j_1$	2
控制参数	$c_1$	0.75	系统参数	$j_2$	2
控制参数	$c_2$	1	Burn-in period	$B$	20
控制常量	$q$	0.002	MCMC 迭代次数	$J$	50




图 2 初次建簇示意

其中“?”表示布设在监测区域内的节点,在被激活前,各节点均处于休眠状态,“+”则表示机动目标在当前时刻的真实位置,因标记为“?”的节点感知到的信号最强,因此在本次建簇过程中,该节点被选为簇首,标记有“+”的节点由于既可感知到目标信号,又具有与簇首节点间的通信能力,因此这些节点在该次建簇中成为簇内的成员节点。图 2 中较大圆形的圆心为簇首节点,其半径等于  $R_c$ , 较小圆形的圆心为目标所处的位置,其半径等于  $R_s$ , 处于两圆交集区域内的节点在该时刻下均处于工作状态,执行 PSO-MHPF 方法时 簇首负责的工作包括 PSO-MHPF 的初始化、粒子分配、计算目标状态的全局估计等,各成员节点则并行地执行 PSO-MHPF 方法,对分配至该节点的粒子进行处理,主要包括各粒子的一步预测、权值更新、分布调整、计算目标状态的局部估计

以及上传数据等。该簇工作一段时间后,因目标运动而需要切换分簇时,簇首节点需预测下一时刻目标的位置,将距离该位置最近的节点作为候选簇首,并将当前目标状态的估计值、带有权重的粒子集合等必要信息打包发送至下一簇首。

在 PSO-MHPF 方法中,粒子总数的选择至关重要,因为粒子总数除了影响滤波结果的精度之外,还直接影响到算法的计算量和收敛速度。为了恰当地设置粒子总数  $N_p$ ,在较少的粒子总数下获得满意的滤波精度和模型收敛速度,本文以图 2 中的分簇结构作为执行 PSO-MHPF 方法的平台进行了多次仿真,仿真时设置了不同的粒子总数和迭代次数,考查在不同条件下均方根误差的大小,所得结果如图 3 所示。均方根误差的计算方法为




图 3 粒子数与均方根误差的关系

$$RMSE = \sqrt{\frac{\sum_{i=1}^n err_i^2}{n}} \quad (26)$$

其中,  $n$  为仿真总次数,  $err_i$  则表示第  $i$  次仿真所得目标状态估计值与真实值之间的位置误差, 本次仿真中将仿真总次数设置为 100。观察图 3 可知, 每次滤波时, 当迭代次数一定时, 均方根误差随着粒子数的增大而减小, 而在粒子数一定的条件下, 均方根误差随着迭代次数的增长而逐渐降低, 迭代足够多次后, 各曲线中的均方根误差的取值变化幅度减小, 最终趋于稳定。从该图中也可以发现, 在只迭代一次的情况下, 各曲线中均方根误差之间的差异较大, 如粒子总数分别设置为 1 600 和 100 时, 它们之间的均方根误差几乎相差了一个数量级。迭代 2 次后, 各曲线之间的差异减小, 特别是粒子数为 400、800 和 1 600 时所得的结果较为接近, 且此时的误差十分接近稳定值, 因此, 为了以较少的计算量获得较高的精度, 后面的仿真中将粒子总数设置为 400, 每次滤波时迭代 2 次。

前文中已对目标的运动模型做了介绍, 当仿真参数按表 2 中设置时, 得到簇间切换的路径如图 4 所示。该图中, 实心正方形表示簇首节点, 黑色实线为簇首切换的路径, 标记有“+”的节点则是不同时刻下的成员节点, 需要说明的是, 各节点激活与否与目标的位置有直接关系, 某些节点在不同时刻下属于不同的分簇。簇首切换路径与目标运动轨迹之间的关系如图 5 所示, 该图中的虚线表示目标运动的轨迹, 实线则为簇首切换路径。目标跟踪系统运行时, 根据前文介绍的能耗模型, 得到各时刻网络的瞬时能耗如图 6 所示, 图中的瞬时能耗曲线与簇间切换的次序相对应, 由 16 段首尾连接的水平线段构成, 其中, 第 8、9 两段因瞬时能耗接近而几乎处于同一水平面上, 最大瞬时能耗为  $3.378 \times 10^{-3}$  J, 最小值为  $2.364 \times 10^{-3}$  J。

为对比说明 PSO-MHPF 方法在跟踪机动目标时的性能, 本文将其与 IPF 和 PPF 方法做了仿真对比, 仿真时这 3 种方法均采用前文所述的目标模型和感知模型, 当参数设置如表 2 所示时, 得到跟踪机动目标的效果如图 7 所示, 该图中 PSO-MHPF、PPF 和 IPF 方法得到的估计轨迹均接近于目标的真实运动轨迹, 说明这 3 种方法均能实现对该机动目标的跟踪, 但由于各方法的实现方式不同, 相同条件下

跟踪同一目标时的能耗有较大差别, 当节点间通信时每次发送的数据分组大小相等, 为 12 byte, 其余参数按表 2 中设置时, 能耗曲线如图 8 所示。该图中, PPF 的能耗曲线位于最上方, 其网络总能耗最大, 在仿真结束时刻, 其网络总能耗达到了 2.45 J, IPF 的能耗曲线与 PPF 的较为接近, 但由于其平均




图 4 簇首切换路径




图 5 簇首切换路径与目标运动轨迹示意




图 6 网络瞬时能耗




图 7 目标跟踪效果




图 8 网络总能耗

通信量小于 PPF，因而其网络总能耗为 2.33 J，略小于 PPF 方法，这是因为这 2 种方法采用了相同的拓扑结构，仅在实现滤波时略有不同，而 PPF 方法因其在成员节点更新和融合阶段时通信量较大而能耗略高。相比于这 2 种方法，PSO-MHPF 方法的网络总能耗更低，仿真结束时其值仅为 1.82 J。影响网络总能耗的主要原因是 PSO-MHPF 方法采用了分布式结构，节点的计算量较少，算法的执行效率更高，此外，PSO 的引入也使得滤波的收敛速度加快。粒子群优化技术和 M-H 方法的引入不仅影响了滤波的收敛速率，并且通过抑制粒子退化现象提高了滤波结果的精度，如图 9 所示。该图中显示了跟踪同一目标时 3 种方法的均方根误差曲线，统计图中各曲线数据后，得到 PSO-MHPF 方法的 RMSE 均值约为 2.534 7 m，而 IPF 和 PPF 方法的 RMSE 均值分别为 3.371 0 m 和 4.551 9 m，说明粒子群优化技术和 Metropolis-Hasting 抽样方法的引入对于调整粒子的分布、提高滤波精度有着积极的作用。




图 9 均方根误差曲线

### 6 结束语

本文对非线性非高斯条件下传感器网络的目标跟踪问题进行了研究，在构建的动态网络拓扑结构中，利用本文提出的 PSO-MHPF 方法实现了对机动目标的跟踪。PSO-MHPF 方法采用了分布式结构，簇首对粒子及其权值进行初始化后将其均匀分配给簇内处于活跃状态的成员节点，各成员节点则以感知的量测值为依据，实现粒子分布的调整并计算目标状态的局部估计，最终将局部估计发送至簇首融合成目标状态的全局估计。在该过程中，引入了粒子群优化和 Metropolis-Hasting 抽样技术，对粒子滤波的重抽样阶段进行了创新，改变了重抽样阶段粒子分布的调整方式，利用粒子群优化调整粒子的分布使得各粒子之间可以利用彼此的历史信息，从而降低了单个粒子各历史状态间的相关性，加快了滤波的收敛速度，Metropolis-Hasting 抽样方法的引入则是利用了该方法能构建马尔可夫链抑制粒子退化现象的特点，通过加强粒子的样本有效性的途径，提高了滤波的精度。相比于 IPF 和 PPF 方法，采用本文提出的 PSO-MHPF 方法实现传感器网络目标跟踪时取得了更低的网络总能耗和更高的目标跟踪精度。

### 参考文献：

[1] MUSICKI D, KAUNE R, KOCH W. Mobile emitter geolocation and tracking using TDOA and FDOA measurements[J]. IEEE Transactions on Signal Processing, 2010, 58(3):1863-1874.  
 [2] CHEN J, SALIM M B, MATSUMOTO M. A single mobile target tracking in voronoi-based clustered wireless sensor network[J]. Jour-

- nal of Information Processing Systems, 2011,7(1):17-28.
- [3] SCHMID J, BEUTLER F, NOACK B, *et al.* An Experimental Evaluation of Position Estimation Methods for Person Localization in Wireless Sensor Networks[M]. Bonn: Springer Berlin Heidelberg, 2011.
- [4] KUMAR S, PRAKASH J, KANAGASABAPATHY P. A Critical Evaluation and Experimental Verification of Extended Kalman Filter, Unscented Kalman Filter and Neural State Filter for State Estimation of Three Phase Induction Motor[J]. Applied Soft Computing, 2011, 11(3): 3199-3208.
- [5] OKA A, LAMPE L. Distributed target tracking using signal strength measurements by a wireless sensor network[J]. IEEE Journal on Selected Areas in Communications, 2010, 28(7):1006-1015.
- [6] USTEBAY D, COATES M, RABBAT M. Distributed auxiliary particle filters using selective gossip[A]. IEEE International Conference on Acoustics, Speech and Signal Processing[C]. Prague, Czech Republic, 2011. 3296-3299.
- [7] MURANGIRA A, MUSSO C, DAHIA K, *et al.* Robust regularized particle filter for terrain navigation[A]. The 14th International Conference on Information Fusion[C]. Chicago, USA, 2011. 1-8.
- [8] CARLONE L, NG M K, DU J, *et al.* Simultaneous localization and mapping using rao-blackwellized particle filters in multi-robot systems[J]. Journal of Intelligent & Robotic Systems, 2011,63(2):283-307.
- [9] 邹冈, 石章松, 刘忠. 传感器网络中的分布式粒子滤波被动跟踪算法比较研究[J]. 传感技术学报, 2007, 20(6):1344-1348.  
ZOU G, SHI Z S, LIU Z. Comparison of decentralized particle filter algorithms in sensor networks for passive tracking[J]. Chinese Journal of Sensors and Actuators, 2007, 20(6):1344-1348.
- [10] OLFATI-SABER R, SANDELL N F. Distributed tracking in sensor networks with limited sensing range[A]. American Control Conference[C]. Washington, USA, 2008. 3157-3162.
- [11] AHMED N, RUTTEN M, BESSELL T, *et al.* Detection and tracking using particle-filter-based wireless sensor networks[J]. IEEE Transactions on Mobile Computing, 2010,9(9):1332-1345.
- [12] JIANG P, LI S Q. A data compression algorithm for wireless sensor networks based on an optimal order estimation model and distributed coding[J]. Sensors, 2010, 10(10):9065-9083.
- [13] CABALLERO F, MERINO L, MAZA I, *et al.* A particle filtering method for wireless sensor network localization with an aerial robot beacon[A]. IEEE International Conference on Robotics and Automation[C]. Pasadena, USA, 2008. 596-601.
- [14] OZDEMIR O, NIU R, VARSHNEY P K. Tracking in wireless sensor networks using particle filtering: physical layer constraints[J]. IEEE Transactions on Signal Processing, 2009, 57(5):1987-1999.
- [15] ALRASHIDI M R, EI-HAWARY M E. A survey of particle swarm optimization applications in electric power systems[J]. IEEE Transactions on Evolutionary Computation, 2009, 13(4):913-918.
- [16] HOLDEN L, HAUGE R, HOLDEN M. Adaptive independent metropolis-hastings[J]. The Annals of Applied Probability, 2009, 19(1): 395-413.

#### 作者简介：



蒋鹏[通信作者] (1975-), 男, 浙江衢州人, 博士, 杭州电子科技大学教授、博士生导师, 主要研究方向为无线传感器网络、物联网技术及其应用、嵌入式系统及其应用、智能仪表。E-mail: pjiang@hdu.edu.cn。



宋华华 (1986-), 男, 浙江湖州人, 杭州电子科技大学硕士生, 主要研究方向为无线传感器网络。



林广 (1975-), 男, 浙江温州人, 硕士, 浙江省环境监测中心高级工程师, 主要研究方向为环境监测、环境质量评价。