

无线传感器网络下的粒子滤波分布式目标跟踪算法

李善仓, 张德运, 杨振宇, 杨鹏宏

(西安交通大学电子与信息工程学院, 710049, 西安)

摘要: 针对无线传感器网络环境下的机动目标跟踪问题, 提出了一种描述目标机动加速度的目标状态空间模型, 以此模型为基础开发出基于粒子滤波的单目标和多目标跟踪算法. 基本思想是: 在状态空间中通过寻找一组传播的随机样本来获得近似后验概率分布, 并以样本均值代替积分运算, 从而求得最小状态方差估计. 仿真结果表明, 所提算法可以较好地解决无线传感器网络环境下的机动目标跟踪问题, 速度跟踪精度、机动加速度跟踪精度均较经典分布式粒子滤波算法分别提高20%、27%.

关键词: 传感器网络; 目标跟踪; 粒子滤波算法

中图分类号: TP393.17 **文献标识码:** A **文章编号:** 0253-987X(2007)08-0912-05

Distributed Target Tracking Algorithm Based on Particle Filtering in Wireless Sensor Networks

Li Shancang, Zhang Deyun, Yang Zhenyu, Yang Penghong

(School of Electronics and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: Focusing on the maneuvering target tracking problem in wireless sensor networks, a state space model for describing the maneuvering target acceleration is proposed. On the basis of the model, single and multiple target tracking algorithms based on particle filtering are developed, in which the approximate posterior probability distribution is acquired through searching a set of transmitted random samples in the state space, and the integral operation is replaced by sample's average value so as to obtain the minimum variance estimation. Simulation results show that in wireless sensor network environment, the maneuvering target tracking problem can be solved better by the proposed algorithm. The precision of velocity tracking and maneuvering tracking acceleration is increased by about 27% and 20% respectively compared to the traditional particle filtering algorithms.

Keywords: sensor network; target tracing; particle filter algorithm

目标跟踪是无线传感器网络(WSN)的一项重要应用. WSN节点体积小、价格低廉,同时还具有无线通信、网络随机部署等功能,其自组织、鲁棒和隐蔽等特点也非常适用于机动目标的跟踪和定位^[1],但它易受节点能耗的干扰,拓扑结构也是动态变化的.

目前已开发出的 WSN 目标跟踪系统有多种,包括 MIT 的 Cricket 系统和 Rine-Grained 方法,它

们利用了到达时间差定位(TDOA)技术,可将定位相对误差降低至 10%^[2],但其受超声波传播方向性的限制,所以也不能实现任意两点间的测距和定位,同时还存在计算复杂度高、实时性差、效率低等缺点. 威斯康星的 SenIT 定位系统^[3]尝试着将粒子滤波算法应用于目标跟踪,以避免定位算法对参数过于敏感的缺点. 目前,大多数算法仅仅是针对位置序列采样的,却不适用于非高斯、非线性环境下的机动

目标跟踪问题。

本文建立了基于非线性、非高斯状态的空间模型,并基于此提出了粒子滤波的分布式目标跟踪算法,其中包括分布式单目标跟踪算法和分布式多目标跟踪算法,利用该算法通过2步滤波计算可以估计目标的状态信息,从而解决非线性环境下的机动目标跟踪问题。

1 目标跟踪基本模型与方法

基于无线传感器网络的目标跟踪通常包括3个阶段^[3]:检测、定位和通告。

(1)检测阶段.在此阶段,节点将周期性地进行检测,如果发现检测范围内出现目标,首先计算其与目标之间的距离,同时向网络广播目标进入检测范围的消息,消息包括节点ID、节点自身位置和节点与目标之间的距离等,而邻居节点接收并保存该消息,同时加上时间戳。

(2)定位阶段.为了节能,节点只对近距离目标的位置进行估计,并根据自身的检测结果或其他节点的通告结果,再应用三角测量法计算目标的位置。

(3)通告阶段.当计算出目标运动轨迹之后,WSN需要激活并实时通知轨迹附近的节点,使其加入跟踪行列.通告消息中包含了发送者的位置信息、发送者预测目标的运动参数,节点根据这些通告消息可以计算自己与目标的距离,并估计目标的运动参数和轨迹。

在WSN中,还可采用动态区域跟踪方法^[4]来提高跟踪效率.动态区域的变化根据节点对目标的预测而定,区域划分应依据地理位置事先划分成近似、相邻、部分重叠的矩形区域,划分方法主要参考数据精确聚合与近似方法^[3],以此最大限度地节省能量,提高监测效率.在每个周期中只有目标所在区域处于激活状态,区域通过投票选举出一个头节点,选择方法取决于节点的剩余能量对连通度的影响和域内的通信代价,选择算法为同情K近邻(TP-KNN)算法^[3].目标跟踪系统采用分域跟踪机制,即在 t 时刻,只有目标所处域中的节点在工作,其他域的节点处于休眠状态。

2 粒子滤波目标跟踪算法

2.1 粒子滤波

粒子滤波(PF)是近几年提出的一种非线性滤波算法,是一种基于Monte Carlo仿真的最优回归贝叶斯滤波算法.该算法将所关心的状态矢量表示

为一组带有相关权值的随机样本,并基于这些样本和权值计算状态.与其他非线性滤波算法,如Kalman不敏感滤波等算法相比,这种算法不受线性化误差或高斯噪声假定的限制,适用于任何环境、任何状态下的转换或量测模型.对于WSN这类不可能得到后验概率分布函数解析解的非线性高斯模型,可以考虑采用粒子滤波方法来近似求解。

2.2 目标跟踪的数学模型

目标运动的状态方程和观测方程为

$$x_{k+1} = f_k(x_k, u_k) + w_k \quad (1)$$

$$z_k = h_k(x_k) + v_k \quad (2)$$

式中: x_k 为目标状态; z_k 为观测状态; u_k 为控制输入; w_k 、 v_k 为测量噪声序列.系统的混合模型为

$$x_{k+1} = F_k x_k + E_k u_k + G_k w_k \quad (3)$$

$$\dot{x}(t) = A(t)x(t) + E(t)u(t) + B(t)w(t);$$

$$x(t_0) = x_0 \quad (4)$$

$$z_k = H_k(x_k) + v_k \quad (5)$$

$$z(t) = C(t)x(t) + v(t) \quad (6)$$

如果没有机动目标, a_t 为随机加速度,通常视为状态噪声.当存在未知机动目标时, a'_t 为机动加速度,即

$$a'_t = a_t + \Delta a_t \quad (7)$$

式中: Δa_t 表示 $(t-1)$ 时刻到 t 时刻的变化量,即

$$\Delta a_t = u_t + \varepsilon_t \quad (8)$$

其中 u_t 是均值为0的离散随机变量, ε_t 是均值为0的连续随机变量,二者在不同的应用中取值不同.比如,在连续的时间段内的加速度变化不大,可以用 $\varepsilon_t \sim N(0, 0.1I_2)$ 分布来表示,此时

$$u_t \in \Omega \equiv \{(0,0)^T, (1,0)^T, (1,1)^T,$$

$$(0,1)^T, (-1,1)^T, (-1,0)^T,$$

$$(-1,-1)^T, (0,-1)^T, (1,-1)^T\} \quad (9)$$

u_t 的分布需由前验信息来确定.由式(9)可以推导机动目标的运动方程

$$\begin{bmatrix} s_t \\ v_t \end{bmatrix} = \begin{bmatrix} I_2 & \Delta t I_2 \\ \mathbf{0} & I_2 \end{bmatrix} \begin{bmatrix} s_{t-1} \\ v_{t-1} \end{bmatrix} + \begin{bmatrix} \frac{\Delta t^2}{2} I_2 \\ \Delta t I_2 \end{bmatrix} a_t \quad (10)$$

式中: Δt 为采样周期; I_2 为 2×2 单位矩阵.观测方程为

$$y_t = h(s_t) + \eta_t \quad (11)$$

式中: η_t 为观测噪声; $h(\cdot)$ 表示不同的应用形式。

2.3 单目标跟踪算法

WSN的单目标跟踪,其动态系统可以用状态空间模型来表示,即

$$X_k = F_k(X_{k-1}, V_{k-1}) \quad (12)$$

$$Y_k = H_k(X_k, W_k) \quad (13)$$

式中: X_k 表示系统状态; Y_k 表示量测状态; V_k 、 W_k 为独立、同分布的系统噪声和观测噪声. 假定 X_k 服从一阶 Markov 过程, 给定 X_k , 量测序列 Y_k 互相独立, 则初始状态 X_0 的先验概率为 $p(X_0)$. 又设 $X_{0:k} = \{X_0, X_1, \dots, X_k\}$, $Y_{0:k} = \{Y_0, Y_1, \dots, Y_k\}$, 由 Bayes 公式可得

$$p(X_k | Y_{1:k-1}) = \int p(X_k | X_{k-1}) p(Y_{k-1} | Y_{1:k-1}) dX_{k-1} \quad (14)$$

$$p(X_k | Y_{1:k}) = \frac{p(Y_k | X_k) p(X_k | Y_{1:k-1})}{p(Y_k | Y_{1:k-1})} \quad (15)$$

式中: $p(Y_k | Y_{1:k-1}) = \int p(Y_k | X_k) p(X_k | Y_{1:k-1}) dX_k$.

在此, 假设机动加速度可以用 U_k 表示, 则

$$p(X_k | Y_{1:k-1}) = \int p(X_k | X_{k-1}, U_k) \cdot p(U_k) p(X_{k-1} | Y_{1:k-1}) dX_{k-1} dU_k \quad (16)$$

在 Markov 的结构空间模型中, U_k 与 X_k 、 $Y_{1:k-1}$ 互相独立, 假设根据前验分布 $p(X_{k-1} | Y_{1:k-1})$ 采样获得随机样本 $\{X_{k-1}^{(i)}\}_{i=1}^N$, 由分布 $p(U_k)$ 采样获得随机样本 $\{U_k^{(j)}\}_{j=1}^M$, 那么式(16)可以表示为

$$p(X_k | Y_{1:k-1}) \triangleq \frac{1}{M} \sum_{j=1}^M \sum_{i=1}^N p(X_k | X_{k-1}^{(i)}, U_k^{(j)}) W_{k-1}^{(i)} \quad (17)$$

又因 $p(X_k | Y_{1:k}) = \frac{p(Y_k | X_k) p(X_k | Y_{1:k-1})}{p(Y_k | Y_{1:k-1})}$, 而且

$p(Y_k | Y_{1:k-1}) = 1/M$, 则有

$$\hat{p}(X_k | Y_{1:k}) \propto p(Y_k | X_k) \cdot \sum_{j=1}^M \sum_{i=1}^N p(X_k | X_{k-1}^{(i)}, U_k^{(j)}) W_{k-1}^{(i)} \quad (18)$$

若添加一个辅助随机变量 t , 则由式(18)可得 $\hat{p}(X_k, t | Y_{1:k}) \propto p(Y_k | X_k) p(X_k | X_{k-1}^{(i)}, U_k^{(j)})$, 其中 $t \in (1, \dots, MN)$, 显然 $\hat{p}(X_k | Y_{1:k})$ 是 $\hat{p}(X_k, t | Y_{1:k})$ 的边界分布. 以 $p(X_k, t | Y_{1:k-1})$ 生成随机样本, 可选择下列重要性概率密度

$$q(X_k, t | Y_{1:k}) \propto p(Y_k | \mu_k^{(i)}) p(X_k | X_{k-1}^{(i)}, U_k^{(j)}) W_{k-1}^{(i)} \quad (19)$$

式中: $\mu_k^{(i)} = E\{X_k | X_{k-1}^{(i)}, U_k^{(j)}\}$. 由式(11)可知

$$q(t | Y_{1:k}) \propto p(Y_k | \mu_k^{(i)}) p(X_k | X_{k-1}^{(i)}, U_k^{(j)}) W_{k-1}^{(i)} \quad (20)$$

则可得

$$q(X_k, t | Y_{1:k}) \propto q(t | Y_{1:k}) p(X_k | X_{k-1}^{(i)}, U_k^{(j)}) \quad (21)$$

由 $q(X_k, t | Y_{1:k})$ 生成随机样本的方法描述如

下.

(1) 根据概率密度 $q(t | Y_{1:k})$ 生成 N 个随机样本 $\{t^{(j)}\}_{j=1}^N$.

(2) 根据概率密度 $p(X_k | X_{k-1}^{(i)}, U_k^{(j)})$ 生成 $j=1, \dots, N$ 个随机样本. 如果为每个随机样本 $X_{k-1}^{(i)}$ 分配一个权重

$$W_k^{(j)} \propto \frac{p(X_k^{(j)}, t^{(j)} | Y_{1:k})}{q(X_k^{(j)}, t^{(j)} | Y_{1:k})} = \frac{p(Y_k | X_k^{(j)})}{p(Y_k | \mu_k^{(i)})} \quad (22)$$

根据概率密度函数 $p(X_k^{(j)}, t^{(j)} | Y_{1:k})$ 可以获得权值样本 $\{(X_k^{(j)}, t^{(j)}), W_k^{(j)}\}_{j=1}^N$, 根据概率密度函数 $p(X_k | Y_{1:k})$ 可获权值样本 $\{(X_k^{(j)}, W_k^{(j)})\}_{j=1}^N$.

单目标跟踪算法如图 1 所示.




图1 单目标跟踪算法

2.4 多目标跟踪模型

假设有 M 个目标的系统, $\mathbf{X}_k^m = (x_k^m, v_k^m, a_k^m)$, $m=1, \dots, M$ 为 M 个目标在 k 时刻的状态. 每个目标的状态空间设计方法为

$$x_k^m = x_{k-1}^m + \Delta t v_{k-1}^m + \frac{\Delta t^2}{2} a_k^m \quad (23)$$

$$v_k^m = v_{k-1}^m + \Delta t a_k^m \quad (24)$$

$$a_k^m = a_{k-1}^m + \Delta a_k^m \quad (25)$$

Δa_k^m 建模的方法与单目标设计法一样, $\Delta a_k^m = u_k^m + \epsilon_k^m$, 令 $\mathbf{X}_k = \{\mathbf{X}_k^1, \mathbf{X}_k^2, \dots, \mathbf{X}_k^M\}$, $\mathbf{X}_k^m = (x_k^m, v_k^m, a_k^m)^T$, $\mathbf{U}_k = (\mathbf{U}_k^1, \mathbf{U}_k^2, \dots, \mathbf{U}_k^M)$, $\mathbf{U}_k^m = \{u_k^m\}$, 那么 k 时刻的观测序列为 $\mathbf{Y}_k = (Y_k^1, Y_k^2, \dots, Y_k^M)$. 由于观测噪声会引起虚警, 一般采用数据融合方法来解决^[5].

2.4.1 状态估计 根据数据联合输出可以估计每一个目标的状态, M 个目标的跟踪后验密度

$$p(\mathbf{X}_k^m | \mathbf{Y}_{1:k}) = \frac{p(\mathbf{Y}_k | \mathbf{X}_k^m) p(\mathbf{X}_k^m | \mathbf{Y}_{1:k-1})}{p(\mathbf{Y}_k | \mathbf{Y}_{1:k-1})} \quad (26)$$

其中

$$p(\mathbf{X}_k^m | \mathbf{Y}_{1:k-1}) = \int p(\mathbf{X}_k^m | \mathbf{X}_{k-1}^m, \mathbf{U}_k^m) \cdot$$

$$p(\mathbf{X}_{k-1}^m | \mathbf{Y}_{1:k-1})p(\mathbf{U}_k^m)d\mathbf{X}_{k-1}^md\mathbf{U}_k^m$$

此处 $\mathbf{X}_k^m$ 仅与 $\mathbf{X}_{k-1}^m$ 相关, $\mathbf{U}_k^m$ 独立于其他元素.

在 $k-1$ 时刻,假设根据概率密度可以得到一组随机样本及其权值 $\{\mathbf{X}_{k-1}^{m,(i)}, \mathbf{W}_{k-1}^{m,(i)}\}_{i=1}^N$, 根据概率密度 $p(\mathbf{U}_k^m)$ 可以得到 $\{\mathbf{U}_k^{m,(j)}\}_{j=1}^R$, 则有

$$p(\mathbf{X}_k^m | \mathbf{Y}_{1:k-1}) \approx \frac{1}{R} \sum_{i=1}^N \sum_{j=1}^R p(\mathbf{X}_k^m | \mathbf{X}_{k-1}^{m,(i)}, \mathbf{U}_k^{m,(j)}) \mathbf{W}_{k-1}^{m,(i)} \quad (27)$$

根据参考文献[3]可得

$$\hat{p}(\mathbf{X}_k^m | \mathbf{Y}_{1:k-1}) \triangleq \frac{1}{R} \sum_{i=1}^{NR} p(\mathbf{X}_k^m | \mathbf{X}_{k-1}^{m,(i)}, \mathbf{U}_k^{m,(j)}) \omega_{k-1}^{m,(i)}$$

本文根据概率分布 $p(\mathbf{X}_k^m | \mathbf{Y}_{1:k-1})$, $m=1, \dots, M$ 可以生成权重随机样本 $\{\mathbf{X}_k^{m,(i)}, \mathbf{W}_k^{m,(i)}\}_{i=1}^N$, 这种多目标跟踪算法如图2所示.

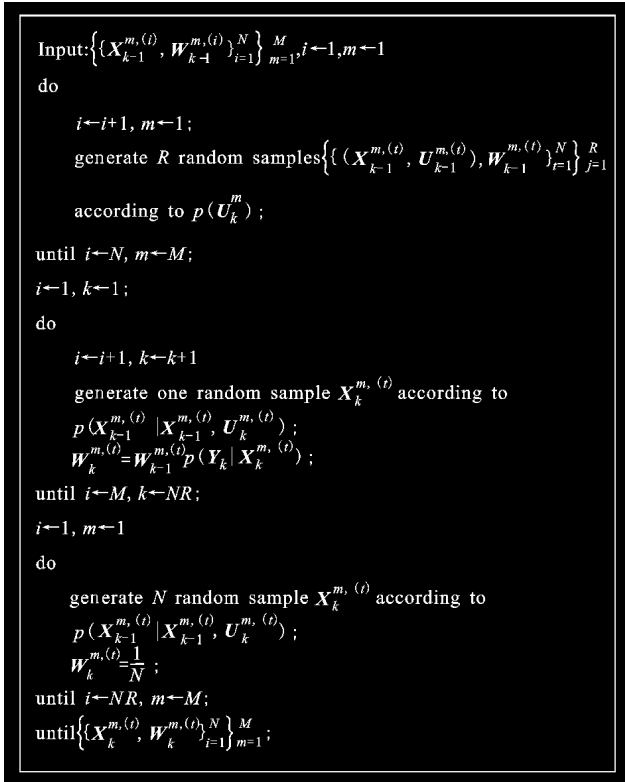


图2 多目标跟踪算法

计算式(26)需要考虑数据融合问题. 根据全概率公式 $p(\mathbf{A}_k^n = m)$, $n=1, \dots, N_k$, 则有

$$p(\mathbf{Y}_k | \mathbf{X}_k^m) = \sum_{n=1}^{N_k} p(\mathbf{Y}_k | \mathbf{X}_k^m, \mathbf{A}_k^n = m) p(\mathbf{A}_k^n = m) = \sum_{n=1}^{N_k} p(\mathbf{Y}_k^n | \mathbf{X}_k^n, \mathbf{A}_k^n = m) \beta_k^{mn} \quad (28)$$

2.4.2 多目标辨识 当2个或者多个目标过于接近时,其周围的节点会把 t 时刻跟踪的目标与 $t-1$ 时刻跟踪的目标混淆起来,从而导致失跟现象. 本文应用 Shin 等人提出的方法^[2]来解决失跟问题.

3 仿真

在 NS2 环境下对本文算法进行了仿真. 系统在 $300 \text{ m} \times 300 \text{ m}$ 的区域内部署节点,节点数为100并随机放置. 仿真的主要内容包括:预测轨迹与实际轨迹之间的误差,在 X, Y 方向上实际速度与估计速度,在 X, Y 方向的实际加速度与估计加速度. 由于粒子数与计算复杂性呈线性关系,所以粒子数不宜过大,在此取200. 实验模型参见文献[3],参数如表1所示,实验数据均为200次模拟实验的平均抽样结果.

单目标的运动轨迹如图3所示,最终结果取200次迭代的平均值. 对200次 Monte Carlo 的位置均方根误差(RMSE)进行了仿真实验,获得最大误差为15 m,最小误差为0.8 m,均方根误差为2.4 m,从而得知在5~20 m之间的误差是合理的^[6]. 稳定以后的位置误差在0.5 m以内,比经典分布式粒子滤波(DPE)算法提高20%. 在跟踪过程中,由于本文子域的更新策略与DPF相同,即采用分域跟踪机制实现域间的实时跟踪,域内的实时性能与采样周期相关,所以本文仿真的采样周期为1 s,显然实时性比较好. 采样周期越短,实时性越好,但WSN的通信负载则越大.

表1 仿真实验环境参数配置(ns-allinone-2.29)

网络尺寸	300 m×300 m
节点数	100
节点分布形式	随机
感知范围	10 m
Sink 节点坐标	(0,0)
节点收发电路能耗	50 nJ/b
节点初始能量	2 J/b
单目标位置	(300,0)
目标数	3
多目标位置	(300,0), (50,0), (0,0)
采样周期	1 s
粒子数	200
传播范围	25 m




图3 单目标跟踪时的实际位置与估计位置

X、Y方向上的实际速度与估计速度的比较如图4所示。通过仿真发现:当目标速度低于15 m/s时,本文算法精度很高;当目标速度超过20 m/s时,需要减小采样周期,这将增加通信负载,所以跟踪效果不尽人意,实时性同时也降低。




图4 X、Y方向上的实际速度与估计速度

X、Y方向上的实际加速度与估计加速度的比较如图5所示。当速度小于15 m/s时,本文算法对加速度的平均估计误差为0.2 m/s²,比DPT^[3]算法的精度提高约27%;当速度大于15 m/s时,对加速度的估计误差剧增。

由于X、Y方向的衰减模型是一致的,所以目标在X、Y方向上的速度和加速度误差也是一致的。速度的均方根误差约为0.25 m/s,加速度的均方根误差约为0.12 m/s²。当3个目标分别从位置(300, 0) m、(50, 0) m、(0, 0) m并以速度1:4 m/s、2:8 m/s、3:12 m/s运行时,多目标跟踪算法的跟踪轨迹如图6所示。图中有2处目标交汇,交汇时采用了2.4.2节所述的识别方法。可以看出,在WSN环境下本文算法可实现机动目标跟踪。




图5 X、Y方向上的实际加速度与估计加速度

4 结 论

在建立无线传感器网络环境下的目标运动模型




图6 3个目标跟踪时的实际位置与估计位置

的基础上,提出了单目标和多目标跟踪算法,二者均适用于非线性、非高斯环境。从整体上看,利用本文算法可提高传感器网络的位置跟踪精度,这是因为它总是采用局部相关的节点进行目标跟踪,而不相关节点处于休眠状态,所以能有效降低传感器网络通信负载,降低能耗,延长WSN的生命期。

参考文献:

- [1] Coates M. Distributed particle filters for sensor networks[C]//3rd International Conference on Information Processing in Sensor Networks. Palo Alto, USA: Springer Press, 2004:99-107.
- [2] Shin J, Guibas L, Feng Zhao. A distributed algorithm for managing multi-target identities in wireless ad-hoc sensor networks[C]//Proceedings of 2nd Workshop on Information Processing in Sensor Networks. Palo Alto, USA: Springer Press, 2003:223-238.
- [3] Sheng Xiaohong, Yu Henhu. Sequential acoustic energy based source localization using particle filter in a distributed sensor network[C]//IEEE International Conference on Acoustics, Speech, and Signal Processing. Piscataway, USA: IEEE, 2004:961-972.
- [4] Kim W Y, Mechtov K. On target tracking with binary proximity sensors [C]//4th International Conference on Information Processing Sensor Networks. Piscataway, USA: IEEE, 2005:125-129.
- [5] Mechtov K, Sundresh S, Kwon Y, et al. Cooperative tracking with binary-detection sensor networks [C]//Proceedings of the 1st International Conference on Embedded Networked Sensor Systems. New York: ACM Press, 2003:332-333.
- [6] Chen Weipeng, Hou J C, Liu Sha. Dynamic clustering for acoustic target tracking in wireless sensor networks [C]//Proceedings of IEEE International Conference on Network Protocols. Piscataway, USA: IEEE, 2003:284-294.

(编辑 苗凌)