

具有间歇性观测的无线传感器网络分布式容错目标跟踪

杨小军^a, 单博炜^a, 梁中华^a, 徐先峰^b

(长安大学 a. 信息工程学院, b. 电子与控制工程学院, 西安 710064)

摘要: 针对具有随机间歇性观测的无线传感器网络, 基于多模型估计方法和一致性信息滤波器, 提出一种对观测节点故障容错的自适应分布式目标跟踪方法. 将传感器节点随机间歇性观测丢失和到达过程建模为马尔科夫切换系统, 在容积信息滤波器框架下, 估计传感器节点的观测丢失和到达的后验概率. 通过观测状态概率组合计算每个局部传感器节点的信息贡献, 基于自适应多模型估计方法, 实现对间歇性观测的容错性. 仿真结果表明了所提出算法的有效性和对间歇性观测的自适应容错性.

关键词: 目标跟踪; 多模型估计; 分布式估计; 容积卡尔曼滤波器

中图分类号: TP273

文献标志码: A

Fault tolerant distributed target tracking with intermittent observations in wireless sensor networks

YANG Xiao-jun^a, SHAN Bo-wei^a, LIANG Zhong-hua^a, XU Xian-feng^b

(a. School of Information Engineering, b. School of Electrical and Control Engineering, Chang'an University, Xi'an 710064, China. Correspondent: YANG Xiao-jun, E-mail: xjyang@chd.edu.cn)

Abstract: This paper presents an adaptive fault tolerant distributed target tracking algorithm for wireless sensor networks with intermittent observation based on the multi-model method and consensus information filtering. The loss and arrival of the observation are modeled as a Markov process. The posterior probabilities of intermittent observation loss and arrival are estimated in the framework of Cubature information filtering. The information contributions of each local sensor are calculated via the combination of measurement model probability. The fault tolerance to intermittent observations is obtained based on multi-model estimation. Simulation results show the effectiveness and fault tolerance of the proposed algorithm.

Keywords: target tracking; multi-model estimation; distributed estimation; cubature Kalman filter

0 引言

近年来, 分布式无线传感器网络 (WSN) 广泛应用于目标跟踪、战场监视、远程医疗、环境监控等领域^[1-2]. 对 WSN 下的目标跟踪, Kalman 滤波器 (KF) 以及扩展 Kalman 滤波器 (EKF) 是一个重要工具, 信息滤波器 (IF) 是 KF 的逆协方差矩阵形式. 针对非线性滤波和多传感器融合问题, 文献 [3] 将 Unscented 卡尔曼滤波器 (UKF)^[4] 嵌入 IF 结构内, 提出 UT 变换的信息滤波器 (UIF). Olfati-Saber 等^[5-6] 利用平均一致性策略, 提出一种分布式滤波器, 称为卡尔曼一致性滤波器, 文献 [7-8] 基于一致性算法提出了分布式粒子滤波器. 在一致性滤波器中, 每个节点只与邻居节点通讯, 而且没有融合中心, 因而具有灵活的网络拓扑结构和较低的通讯负担. 对于机动目标跟踪问题, 交互

式多模型 (IMM) 算法^[9] 是一种计算有效的滤波器, 文献 [10] 对多个机动目标跟踪问题, 在 IMM 框架内结合一致性算法提出一种分布式多模型 UKF 跟踪算法. 对于不可靠的传感器数据, 文献 [11] 考虑了具有间歇性观测的 Kalman 滤波问题, 将观测数据到达建模为一个独立同分布的随机过程, 并利用代数 Riccati 方程分析了滤波器的收敛性. 对于传感器的量测故障, 文献 [12] 基于 IMM 方法提出一种故障容错的估计算法.

本文针对具有间歇性观测的 WSN, 假设观测丢失和到达过程服从随机马尔科夫链, 基于多模型估计和平均一致性算法, 提出一种自适应故障容错的分布式目标跟踪方法. 本文创新点在于利用自适应多模型方法建立无线传感网络节点间歇性观测的模型, 在容积卡尔曼信息滤波器框架内, 基于多模型估计方法分

收稿日期: 2015-06-08; 修回日期: 2015-09-13.

基金项目: 国家自然科学基金项目(61473047, 61271262, 61201407); 陕西省科技计划项目(2015JM6356, 2014k-025).

作者简介: 杨小军(1971—), 男, 教授, 从事多源信息融合、统计信号处理等研究; 单博炜(1978—), 男, 讲师, 从事信息融合、目标跟踪等研究.

别对每个节点的观测丢失和到达的概率进行在线估计, 对间歇性观测具有容错性, 并且利用一致性算法对所有节点估计值进行分布式融合.

1 问题描述

设目标运动方程为离散时间状态空间模型, 即

$$x_k = F_k x_{k-1} + \epsilon_k. \quad (1)$$

其中: $x_k = [x_{1,k}, x_{2,k}, \dot{x}_{1,k}, \dot{x}_{2,k}]^T \in R^4$ 为 k 时刻未知的目标状态向量, 包括目标位置坐标 $(x_{1,k}, x_{2,k})$ 和目标速度 $(\dot{x}_{1,k}, \dot{x}_{2,k})$;

$$F_k = \begin{bmatrix} 1 & 0 & T & 0 \\ 0 & 1 & 0 & T \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad (2)$$

T 为采样时间间隔; ϵ_k 为零均值高斯白噪声. 设 q 为噪声强度, 协方差矩阵为

$$Q_k = \begin{bmatrix} \frac{T^3}{3} & 0 & \frac{T^2}{2} & 0 \\ 0 & \frac{T^3}{3} & 0 & \frac{T^2}{2} \\ \frac{T^2}{2} & 0 & \frac{T^2}{2} & 0 \\ 0 & \frac{T^2}{2} & 0 & T \end{bmatrix}. \quad (3)$$

在无线传感器网络环境下, 为了描述间歇到达的节点观测值, 引入离散随机变量 $r_k^i \in \{0, 1\}$ 代表传感器节点 i 的观测丢失和到达状态. $r_k^i = 0$ 表示传感器节点的观测丢失, 称为丢失状态; $r_k^i = 1$ 表示传感器正常接收到观测, 称为到达状态. 设 r_k^i 为一个离散时间、齐次、两状态的一阶 Markov 链, 转移概率矩阵为

$$\pi^i = \begin{bmatrix} 1 - q^i & q^i \\ p^i & 1 - p^i \end{bmatrix},$$

其中 p^i 和 q^i 分别称为传感器节点的故障率和修复率. 无线传感器节点的观测方程可以用一个离散时间 Markov 跳跃系统来描述, 即

$$z_k^i = h_k^i(x_k, r_k^i) + n_k^i(r_k^i), \quad i = 1, 2, \dots, N. \quad (4)$$

其中: z_k^i 为来自传感器节点 i 的观测, N 为 WSN 传感器节点个数. 设观测噪声 $n_k^i(r_k^i)$ 是与过程噪声 ϵ_k 互不相关的零均值白高斯过程, 与观测丢失和到达状态有关, 协方差矩阵为 $R_k^i(r_k^i)$, 设各传感器节点的观测噪声互不相关. $h_k^i(\cdot)$ 为传感器节点 i 的观测函数, 与状态 r_k^i 有关, 当 $r_k^i = 0$ 时, $h_k^i = 0$, 此时传感器节点观测只包含噪声.

2 自适应容错的分布式信息滤波器

2.1 容积信息滤波器 (CIF)

对于单个传感器, 设其观测方程为

$$z_k = h_k(x_k) + n_k, \quad (5)$$

定义 Fisher 信息矩阵和信息状态向量分别为

$$Y_{k|k} = (P_{k|k})^{-1},$$

$$\hat{y}_{k|k} = (P_{k|k})^{-1} \hat{x}_{k|k} = Y_{k|k} \hat{x}_{k|k}. \quad (6)$$

扩展信息滤波器 (EIF) 的信息矩阵和信息状态的更新方程为

$$Y_{k|k} = (P_{k|k})^{-1} + H_k^T R_k^{-1} H_k = Y_{k|k-1} + I_k,$$

$$\hat{y}_{k|k} = \hat{y}_{k|k-1} + H_k^T R_k^{-1} (v_k + H_k \hat{x}_{k|k-1}) = \hat{y}_{k|k-1} + i_k.$$

其中: i_k 为信息状态贡献, I_k 为其关联信息矩阵, 有

$$i_k = H_k^T R_k^{-1} (v_k + H_k \hat{x}_{k|k-1}),$$

$$I_k = H_k^T R_k^{-1} H_k. \quad (7)$$

并且 H_k 是非线性观测方程 $h_k(\cdot)$ 的一阶偏导, $\hat{x}_{k|k}$ 为状态估计值, $P_{k|k}$ 为状态估计值 $\hat{x}_{k|k}$ 的协方差矩阵, $v_k = z_k - h(\hat{x}_{k|k-1})$ 为新息向量. 信息状态向量和信息矩阵的预测方程为

$$\hat{y}_{k|k-1} = (P_{k|k-1})^{-1} \hat{x}_{k|k-1},$$

$$Y_{k|k-1} = (P_{k|k-1})^{-1} = (F_k P_{k-1|k-1} F_k^T + Q_k)^{-1}. \quad (8)$$

将容积卡尔曼滤波器 (CKF)^[13] 嵌入 EIF 框架, 可以得到容积信息滤波器 (CIF). CKF 利用球面径向准则选择 $2n$ (n 为状态向量 x_k 的维数) 个具有相同权值的 cubature 点

$$\chi_{k-1|k-1}^s = \sqrt{P_{k-1|k-1} \xi_s + \hat{x}_{k-1|k-1}},$$

$$s = 1, 2, \dots, 2n. \quad (9)$$

其中: $\xi_s = \sqrt{n}[1]_s$, $[1]_s$ 表示集合 $[1]$ 的第 s 列, 且

$$[1] = \left\{ \begin{bmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix}, \begin{bmatrix} 0 \\ 1 \\ \vdots \\ 0 \end{bmatrix}, \dots, \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 1 \end{bmatrix}, \begin{bmatrix} -1 \\ 0 \\ \vdots \\ 0 \end{bmatrix}, \begin{bmatrix} 0 \\ -1 \\ \vdots \\ 0 \end{bmatrix}, \dots, \begin{bmatrix} 0 \\ 0 \\ \vdots \\ -1 \end{bmatrix} \right\}.$$

EIF 的信息更新公式是基于线性化的观测方程, 但是 CKF 得不到观测方程的线性化雅可比矩阵 H_k . 文献 [3] 利用统计线性误差传播方法, 得到一个伪观测矩阵

$$(H_k)^T = [P_{k|k-1}]^{-1} P_{k|k-1}^{X,Z}. \quad (10)$$

其中: $P_{k|k-1}^{X,Z}$ 为状态和观测向量的互协方差矩阵, 由 CKF 的量测更新过程得到, 即

$$P_{k|k-1}^{X,Z} = E[(x_k - \hat{x}_{k|k-1})(z_k - \hat{z}_{k|k-1})^T] =$$

$$\frac{1}{2n} \sum_{s=1}^{2n} \chi_{k|k-1}^s [Z_{k|k-1}^s]^T - \hat{x}_{k|k-1} [\hat{z}_{k|k-1}^s]^T; \quad (11)$$

$$\chi_{k|k-1}^s = \sqrt{P_{k|k-1} \xi_s + \hat{x}_{k|k-1}},$$

$$Z_{k|k-1}^s = h_k(\chi_{k|k-1}^s), \quad \hat{z}_{k|k-1}^s = \frac{1}{2n} \sum_{s=1}^{2n} Z_{k|k-1}^s.$$

将伪观测矩阵 H_k 代入式 (7) 可以得到信息状态贡献向量 i_k 和信息矩阵 I_k , 由 EIF 的信息状态和信息

矩阵的预测更新方程可以得到 CIF 的预测更新迭代方程.

2.2 多传感器融合 CIF 滤波器

CIF 能进一步推广到多传感器估计问题. 设 N 个传感器共同观测同一个目标, 每个传感器节点的观测方程为

$$z_k^i = h_k^i(x_k) + n_k^i, \quad i = 1, 2, \dots, N.$$

设观测噪声是白高斯噪声, 并且各传感器噪声互不相关. 利用伪观测矩阵 (10), 每个传感器节点 i 的局部信息状态贡献和其关联信息矩阵可表示为

$$\begin{aligned} i_k^i &= [H_k^i]^T [R_k^i]^{-1} (v_k^i + H_k^i \hat{x}_{k|k-1}^i), \\ I_k^i &= [H_k^i]^T [R_k^i]^{-1} H_k^i, \end{aligned}$$

其中 H_k^i 为节点 i 的伪观测矩阵. 由于每个传感器的观测噪声互不相关, 多传感器融合 CIF 的更新公式中的信息状态贡献和关联信息矩阵可以表示为各局部传感器信息贡献项的线性组合, 即

$$\begin{aligned} I_k &= \sum_{i=1}^N I_k^i = \sum_{i=1}^N [H_k^i]^T [R_k^i]^{-1} H_k^i, \\ i_k &= \sum_{i=1}^N i_k^i = \sum_{i=1}^N [H_k^i]^T [R_k^i]^{-1} (v_k^i + H_k^i \hat{x}_{k|k-1}^i). \end{aligned} \quad (12)$$

将一致性算法嵌入信息滤波器, 通过邻居节点之间的信息交换, 可以将传感器节点的局部估计扩展到全局, 实现分布式滤波, 所得到的滤波器称为一致性信息滤波器. 对于每个局部传感器节点的信息状态贡献和其关联信息矩阵可以用平均一致性算法来表现^[7-8], 即

$$\alpha_c^{(i)}(t+1) = \omega_{ii}(t) \alpha_c^{(i)}(t) + \sum_{j \in N_i} \omega_{ij}(t) \alpha_c^{(j)}(t). \quad (13)$$

其中: $\alpha_c^{(i)}(t)$ 为在传感器节点 i 处的一致性变量, t 为一致性迭代变量, N_i 为传感器节点 i 的邻居节点集合, $\omega_{ii}(t)$ 为权值. 随着迭代次数的增加, 每个节点的一致性变量会收敛于初始值的平均值.

对于传感器节点 i , 取初始一致性变量为

$$\begin{aligned} \alpha_{c1}^{(i)}(0) &= I_k^i = [H_k^i]^T [R_k^i]^{-1} H_k^i, \\ \alpha_{c2}^{(i)}(0) &= i_k^i = [H_k^i]^T [R_k^i]^{-1} (v_k^i + H_k^i \hat{x}_{k|k-1}^i), \end{aligned}$$

然后用平均一致性算法 (13) 进行迭代, 一旦算法收敛达到一致, 多传感器融合 CIF 更新公式中的信息状态贡献和其关联信息矩阵可以计算为

$$I_k = N \alpha_{c1}^{(i)}(t), \quad i_k = N \alpha_{c2}^{(i)}(t). \quad (14)$$

2.3 分布式自适应容错的 CIF 滤波器

对无线传感器网络下具有间歇性观测的目标跟踪系统 (1) 和 (4), 利用多模型估计方法分别对各个节点的观测丢失和到达的概率进行在线估计, 通过观测状态模型概率组合得到每个节点的信息滤波器的信息贡献项; 然后利用 2.2 节中的一致性 CIF 算法对每

个节点估计值进行分布式融合, 提高局部节点的估计精度和对观测状态的识别概率, 从而建立具有故障容错的分布式滤波器.

设传感器节点 i 在 $k-1$ 时刻的目标状态估计值为 $\hat{x}_{k-1|k-1}^i$, 协方差矩阵为 $P_{k-1|k-1}^i$, 观测丢失和到达模型概率为 $\mu_{k-1}^i(r)$, $r \in \{0, 1\}$. 自适应多模型一致性 CIF 在下一时刻 k 的循环中, 传感器节点 i 的基本滤波步骤如下.

Step 1 信息矩阵和信息状态预测. 有

$$\begin{aligned} \hat{y}_{k|k-1}^i &= (P_{k|k-1}^i)^{-1} \hat{x}_{k|k-1}^i, \\ Y_{k|k-1}^i &= (P_{k|k-1}^i)^{-1} = (F_k P_{k-1|k-1}^i F_k^T + Q_k)^{-1}. \end{aligned} \quad (15)$$

Step 2 CKF 预测. 生成 $2n$ 个容积分

$$\chi_{k|k-1}^{i,s} = \sqrt{P_{k|k-1}^i \xi_i + \hat{x}_{k|k-1}^i}, \quad s = 1, 2, \dots, 2n. \quad (16)$$

对每个观测状态 $r \in \{0, 1\}$, 计算观测预测值容积分、均值、协方差矩阵和伪观测矩阵, 有

$$\begin{aligned} Z_{k|k-1}^{i,s}(r) &= h_k^i(\chi_{k|k-1}^{i,s}, r), \quad i = 1, 2, \dots, 2n, \\ \hat{z}_{k|k-1}^i(r) &= \frac{1}{2n} \sum_{s=1}^{2n} Z_{k|k-1}^{i,s}(r); \end{aligned} \quad (17)$$

$$P_{k|k-1}^{i,Z,Z}(r) =$$

$$\begin{aligned} E\{[z_k^i(r) - \hat{z}_{k|k-1}^i(r)][z_k^i(r) - \hat{z}_{k|k-1}^i(r)]^T\} = \\ \frac{1}{2n} \sum_{s=1}^{2n} Z_{k|k-1}^{i,s}(r) [Z_{k|k-1}^{i,s}(r)]^T - \end{aligned}$$

$$\hat{z}_{k|k-1}^i(r) [\hat{z}_{k|k-1}^i(r)]^T + R_k^i(r),$$

$$P_{k|k-1}^{i,\chi,Z}(r) =$$

$$E\{[x_k^i(r) - \hat{x}_{k|k-1}^i(r)][z_k^i(r) - \hat{z}_{k|k-1}^i(r)]^T\} =$$

$$\frac{1}{2n} \sum_{s=1}^{2n} \chi_{k|k-1}^{i,s}(r) [Z_{k|k-1}^{i,s}(r)]^T - \hat{x}_{k|k-1}^i(r) [\hat{z}_{k|k-1}^i(r)]^T,$$

$$(H_k^i(r))^T = [P_{k|k-1}^i]^{-1} P_{k|k-1}^{i,\chi,Z}(r). \quad (18)$$

Step 3 预测模型概率量测更新. 对每个观测模型 $r \in \{0, 1\}$, 计算传感器节点观测数据 z_k^i 的似然函数

$$A_k^i(r) = N(v_k^i(r); 0, \Psi_k^i(r)). \quad (19)$$

其中

$$v_k^i(r) = z_k^i - \hat{z}_{k|k-1}^i(r), \quad \Psi_k^i(r) = P_{k|k-1}^{i,z,z}(r).$$

观测模型 r 的概率为

$$\mu_k^i(r) = \frac{1}{c} A_k^i(r) \sum_{m=0}^1 \pi_{mr}^i \mu_{k-1}^i(m). \quad (20)$$

其中: $c = \sum_{r=0}^1 A_k^i(r) \sum_{m=0}^1 \pi_{mr}^i \mu_{k-1}^i(m)$ 为归一化常数, π_{mr}^i 为模型转移概率.

Step 4 组合的信息贡献. 传感器节点 i 的信息滤波器的信息状态贡献和其关联信息矩阵分别为

$$\begin{aligned}
\hat{x}_k^i &= \sum_{r=0}^1 \mu_k^i(r) [H_k^i(r)]^T [R_k^i(r)]^{-1} (v_k^i(r) + \\
&\quad H_k^i(r) \hat{x}_{k|k-1}^i), \\
I_k^i &= \sum_{r=0}^1 \mu_k^i(r) [H_k^i(r)]^T [R_k^i(r)]^{-1} H_k^i(r). \quad (21)
\end{aligned}$$

Step 5 一致性CIF融合估计. 取初始一致性变量为 $\alpha_{c1}^{(i)}(0) = I_k^i$, $\alpha_{c2}^{(i)}(0) = v_k^i$, 一致性迭代循环分别为

$$\begin{aligned}
\alpha_{c1}^{(i)}(t) &= \\
\omega_{ii}(t-1) \alpha_{c1}^{(i)}(t-1) &+ \sum_{j \in N_i} \omega_{ij}(t-1) \alpha_{c1}^{(j)}(t-1), \\
\alpha_{c2}^{(i)}(t) &= \\
\omega_{ii}(t-1) \alpha_{c2}^{(i)}(t-1) &+ \sum_{j \in N_i} \omega_{ij}(t-1) \alpha_{c2}^{(j)}(t-1);
\end{aligned}$$

信息矩阵和信息状态量测分别更新为

$$\begin{aligned}
Y_{k|k}^i &= Y_{k|k-1}^i + N \alpha_{c1}^{(i)}(T) = (P_{k|k-1}^i)^{-1} + N \alpha_{c1}^{(i)}(T), \\
\hat{y}_{k|k}^i &= \\
\hat{y}_{k|k-1}^i + N \alpha_{c2}^{(i)}(T) &= (P_{k|k-1}^i)^{-1} \hat{x}_{k|k-1}^i + N \alpha_{c2}^{(i)}(T);
\end{aligned}$$

目标状态估计值和协方差矩阵分别为

$$P_{k|k}^i = (Y_{k|k}^i)^{-1}, \quad \hat{x}_{k|k}^i = P_{k|k}^i \hat{y}_{k|k}^i.$$

3 仿真分析

设无线传感器网络包含 $N = 50$ 个传感器节点, 随机部署在一个 $350 \text{ m} \times 400 \text{ m}$ 的区域内. 目标运动模型为式(1), 其中过程噪声参数 $q = 1$, 采样间隔 $T = 1 \text{ s}$, 目标运动持续时间为 50 s . 设目标初始状态服从高斯分布, 均值为 $x_0 = [50, 50, 10, 10]^T$, 协方差矩阵为 $\text{diag}([10^2, 10^2, 3^2, 3^2])$. 设传感器节点 i 的坐标为 (ξ_1^i, ξ_2^i) , 观测方程为

$$z_k^i = \begin{bmatrix} \sqrt{(x_{1,k} - \xi_1^i)^2 + (x_{2,k} - \xi_2^i)^2} \\ \arctan\left(\frac{x_{2,k} - \xi_2^i}{x_{1,k} - \xi_1^i}\right) \end{bmatrix} + \begin{bmatrix} n_k^{i,1} \\ n_k^{i,2} \end{bmatrix}, \quad i = 1, 2, \dots, N.$$

其中 $n_k^i = [n_k^{i,1}, n_k^{i,2}]^T$ 为观测噪声. 设所有传感器节点的观测噪声协方差矩阵为 $R_k = \text{diag}([0.1^2, 0.5^2])$, 在观测丢失状态 $r_k^i = 0$ 下, 观测只包含噪声项 $z_k^i = n_k^i$. 设所有节点观测丢失和到达的切换概率为 $p = 0.05$ 和 $q = 0.4$, 并且初始时刻节点处于观测到达状态的概率为 0.8 , 处于观测丢失状态的概率为 0.2 . 设每个传感器节点的通讯半径为 50 m , 节点 i 的邻居节点是所有位于其通讯半径内的节点.

在仿真中, 首先对本文提出的包含观测丢失模型的自适应多模型一致性CIF和不包含丢失模型的单模型一致性CIF的性能进行对比, 在不包含丢失模型的单模型一致性CIF中, 假设所有观测都来自节点的观测到达模型; 然后采用2.2节给出的一致性信息滤波器算法, 通过50次Monte Carlo仿真求平均值. 在

存在节点间歇性观测情况下, 图1给出了目标真实轨迹(true trajectory)和经过一致性估计融合后, 传感器节点1(三角形)对目标轨迹的跟踪结果. 从仿真结果可以看出, 不包含观测丢失模型的单模型一致性CIF滤波器(track without loss mode)存在严重的性能退化, 然而包含丢失模型的多模型一致性CIF滤波器(track with loss mode)获得了较为精确的跟踪性能. 因为后者能对每个节点的观测到达和丢失状态进行在线估计, 所以在目标状态估计中考虑了节点观测丢失带来的影响, 而单模型滤波器观测值和模型之间存在失配, 因此多模型一致性CIF滤波器对观测丢失具有一定的自适应容错性.

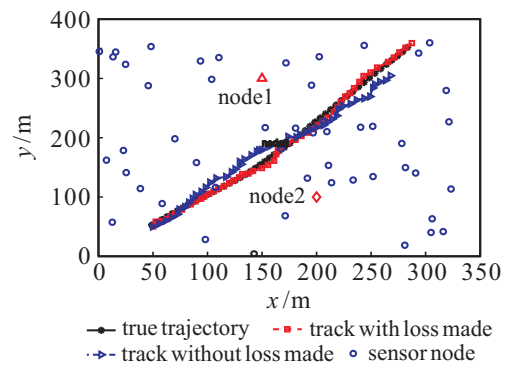


图1 真实目标轨迹、传感器节点分布和估计的目标轨迹

其次, 将本文提出的带有多传感器分布式融合的多模型一致性CIF与不带有融合的单传感器多模型CIF滤波器(即假设在多模型一致性信息滤波器算法中, 传感器节点的邻居只有自己, 节点之间不交换信息)的性能进行了对比仿真. 图2和图3分别给出了传感器节点1和节点2对目标位置估计的均方根误差(RMSE). 从RMSE曲线可看出, 在没有一致性融合的单传感器(track without consensus)情况下, 各个节点的估计精度不相同, 估计误差较大, 但是经过多传感器一致性融合(track with consensus)后, 各节点的估计精度得到较大提高, 说明采用多传感器分布式融合的跟踪效果明显优于单传感器的跟踪效果. 图2和图3中也给出了采用集中式多传感器融合的多模型CIF滤波器的跟踪结果(centralized fusion), 与一致性算法不同之处在于其中的融合算法使用了2.2节给出的集中式多传感器融合方法. 由图2和图3可以看出, 在不同节点处, 多模型一致性信息滤波器的RMSE曲线和集中式融合估计的RMSE几乎相同, 说明经过一致性估计融合后, 局部传感器节点1和节点2对目标状态的估计值达到了近似平均一致, 并且与集中式融合算法几乎等效.

图4和图5分别给出了在带有多传感器分布式融合的多模型一致性CIF滤波器与不带有融合的单传感器多模型CIF滤波器算法下, 传感器节点1和节点2对观测到达状态模型概率的估计值, 图4




图2 传感器节点1对目标位置估计的RMSE




图3 传感器节点2对目标位置估计的RMSE

和图5中也给出了真实模型概率(true probability). 由仿真结果可以看出, 不带有一致性融合的单传感器节点(probability without consensus)不能正确识别节点观测到达的状态, 但是经过多传感器一致性融合(probability with consensus)后, 能够准确识别出观测到达的真实状态, 从而提高节点的目标状态估计精度.




图4 传感器节点1对观测到达模型概率估计




图5 传感器节点2对观测到达模型概率估计

4 结论

本文基于多模型方法和平均一致性算法提出了一种新颖的针对WSN间歇性观测的分布式自适应容错的目标跟踪算法. 利用多模型方法建立传感器节点的间歇性观测模型, 在容积信息滤波器框架下分别估计每个节点观测到达和丢失状态的概率, 通过模

型概率组合得到每个传感器节点观测的信息贡献, 自适应应对传感器网络间歇性观测丢失. 基于一致性算法, 实现网络节点局部估计值的分布式融合. 后续的研究将包括一致性容积信息滤波器的收敛性和加快收敛的方法.

参考文献(References)

- [1] Freris N M, Kowshik H, Kumar P R. Fundamentals of large sensor networks: Connectivity, capacity, clocks, and computation[J]. Proc of the IEEE, 2010, 98(11): 1828-1846.
- [2] Yao K. Sensor networking: Concepts, applications and challenges[J]. Acta Automatica Sinica, 2006, 32(6): 839-845.
- [3] Lee D J. Nonlinear estimation and multiple sensor fusion using unscented information filtering[J]. IEEE Signal Processing Letters, 2008, 15(1): 861-864.
- [4] Julier S J, Uhlmann J K, Durrant-Whyte H F. A new method for the nonlinear transformation of means and covariances in filters and estimators[J]. IEEE Trans on Automatic Control, 2000, 45(3): 477-482.
- [5] Olfati-Saber R. Distributed Kalman filtering for sensor networks[C]. Proc of the 46th IEEE Conf on Decision and Control. New Orleans, 2007: 5492-5498.
- [6] Olfati-Saber R. Kalman-consensus filter: Optimality, stability and performance[C]. Proc of IEEE Conf on Decision and Control. Shanghai, 2009: 7036-7042.
- [7] Mohammadi A, Asif A. Distributed particle filter implementation with intermittent/irregular consensus convergence[J]. IEEE Trans on Signal Processing, 2013, 61(10): 2572-2587.
- [8] Hlinka O, Hlawatsch F, Djuric P M. Consensus-based distributed particle filtering with distributed proposal adaptation[J]. IEEE Trans on Signal Processing, 2014, 62(12): 3029-3041.
- [9] Blom H, Bar-Shalom Y. The interacting multiple model algorithm for systems with Markovian switching coefficients[J]. IEEE Trans on Automatic Control, 1988, 33(8): 780-783.
- [10] Li W, Jia Y. Consensus-based distributed multiple model UKF for jump Markov nonlinear systems[J]. IEEE Trans on Automatic Control, 2012, 57(1): 227-233.
- [11] Sinopoli B, Schenato L, Franceschetti M, et al. Kalman filtering with intermittent observations[J]. IEEE Trans on Automatic Control, 2004, 49(9): 1453-1464.
- [12] Rapoport I, Oshman Y. Efficient fault tolerant estimation using the IMM methodology[J]. IEEE Trans on Aerospace and Electronic Systems, 2007, 43(2): 492-508.
- [13] Arasaratnam I, Haykin S. Cubature Kalman filter[J]. IEEE Trans on Automatic Control, 2009, 54(6): 1254-1269.

(责任编辑: 孙艺红)