

基于条件后验克拉美-罗下界的目标跟踪传感器管理

杨小军^{1†}, 马祥¹, 宋青松¹, 邢科义²

(1. 长安大学信息工程学院, 陕西西安 710064; 2. 西安交通大学系统工程研究所, 陕西西安 710049)

摘要: 对传感器网络下的目标跟踪问题, 基于条件后验克拉美-罗下界(CPCRLB)提出一种传感器网络节点管理方法. 传感器节点的观测数据是目标信号强度(RSS), 基于RSS量测推导了目标状态估计均方误差的CPCRLB. 以CPCRLB作为传感器管理的准则, 选择激活一组最优传感器节点参与目标跟踪. 利用粒子滤波器逼近目标状态, 并估计CPCRLB, 实现传感器节点在线选择. 对基于CPCRLB、无条件后验克拉美-罗下界(PCRLB)和互信息理论的传感器选择方法进行对比仿真, 结果表明CPCRLB传感器管理的有效性和优越性.

关键词: 传感器网络; 传感器管理; 目标跟踪; 克拉美-罗下界; 粒子滤波器

中图分类号: TP273 **文献标识码:** A

Sensor management for target tracking based on conditional posterior Cramér-Rao lower bounds

YANG Xiao-jun^{1†}, MA Xiang¹, SONG Qing-song¹, XING Ke-yi²

(1. School of Information Engineering, Chang'an University, Xi'an Shaanxi 710064, China;
2. Institute of System Engineering, Xi'an Jiaotong University, Xi'an Shaanxi 710049, China)

Abstract: For target tracking in the sensor networks, a sensor management scheme is proposed based on conditional posterior Cramér-Rao lower bounds (CPCRLB). The measurement in the sensor is the received signal strength (RSS) from the target. The CPCRLB on the mean-squared error of target state estimate is derived based on RSS measurements. The CPCRLB is used as the criterion for activating a set of optimal sensors to involve in the target tracking. The particle filtering is employed to estimate the target state and CPCRLB approximately. The online sensor selection is achieved by particle filtering. The sensor selection schemes based on CPCRLB, unconditional posterior Cramér-Rao lower bounds (PCRLB) and mutual information are compared by simulations. The simulation results demonstrate the efficiency and superiority of the CPCRLB-based sensor management.

Key words: sensor networks; sensor management; target tracking; Cramér-Rao lower bounds; particle filtering

1 引言(Introduction)

目标跟踪是无线传感器网络的一个重要任务, 但是对能量和带宽受限的无线传感器网络, 系统不允许所有的传感器节点参与任务. 传感器管理通过选择一组最优的传感器节点, 在有效完成任务的同时, 又降低网络在能量、通信、计算等方面的消耗^[1-5]. 对目标跟踪问题, 传感器管理的目标是选择激活能够提供有关目标状态估计最多信息的传感器节点. Kreucher等^[6-7]以目标状态先验分布和后验分布之间的Rényi距离作为传感器选择的目标, Hoffmann等^[8]以传感器量测和目标状态之间的互信息最大为传感器管理的准则, Williams等^[9]以条件熵作为目标函数, 利用近似动态规划方法实现传感器管理.

后验克拉美-罗下界(posterior Cramér-Rao lower

bounds, PCRLB)给出了目标状态估计误差的理论上的边界, Tichavsky等^[10]给出了一种计算有效的迭代的PCRLB计算方法. 由于PCRLB代表滤波器的最优性能, 文献[11-12]提出基于PCRLB的传感器部署方法, 文献[13]提出基于PCRLB的目标定位传感器选择方法, 并且文献[13]表明对传感器量化数据, PCRLB方法相对于信息论方法具有较低的计算复杂性. 但是PCRLB没有利用实际的量测信息, 完全由系统动态模型、量测模型和初始时刻状态的先验分布确定, 因此对具体的目标航迹实现, PCRLB不能完全反映传感器的性能. 最近, 文献[14-15]提出了条件PCRLB(CPCRLB), CPCRLB以当前时刻的所有真实量测为条件, 给出了目标状态估计的实际均方误差下界. 由于CPCRLB是传感器真实量测的函数,

包含了当前目标真实航迹信息,因此适合于无线传感器网络下的传感器资源管理。

本文基于传感器接收到的目标信号强度(received signal strength, RSS)量测数据,推导了目标状态估计均方误差的CPCRLB性能边界,并且将CPCRLB作为无线传感器网络下目标跟踪的传感器管理准则,基于粒子滤波器对目标跟踪的同时,利用粒子滤波器对CPCRLB进行逼近计算,实现传感器的在线选择。

2 CPCRLB及其迭代算法(CPCRLB and its iterative calculation)

设目标状态 \mathbf{x}_k 是维数为 n_x 的不可观的一阶Markov过程,其动态方程为

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

其中: $f_k: \mathbb{R}^{n_x} \times \mathbb{R}^{n_u}$, \mathbf{u}_k 是维数为 n_u 的独立同分布(i.i.d)的噪声过程. 传感器量测方程为

$$\mathbf{z}_k = h_k(\mathbf{x}_k, \mathbf{v}_k), \quad (2)$$

其中: $h_k: \mathbb{R}^{n_x} \times \mathbb{R}^{n_v}$, \mathbf{v}_k 是 n_v 维 i.i.d 量测噪声, 量测 \mathbf{z}_k 的维数为 n_z , 设 \mathbf{v}_k 独立于 \mathbf{u}_k 和初始状态 \mathbf{x}_0 . 传统的无条件PCRLB给出了目标状态 \mathbf{x}_k 的任一估计值的均方误差(MSE)的下界:

$$\mathbb{E}\{[\hat{\mathbf{x}}_k(\mathbf{z}_{1:k}) - \mathbf{x}_k][\hat{\mathbf{x}}_k(\mathbf{z}_{1:k}) - \mathbf{x}_k]^T\} \geq L^{-1}(\mathbf{x}_k). \quad (3)$$

$L^{-1}(\mathbf{x}_k) = \mathbb{E}\{-\Delta_{\mathbf{x}_k}^{\mathbf{x}_k} \log p(\mathbf{x}_{0:k}, \mathbf{z}_{1:k})\}$ 称为Fisher信息矩阵(FIM), 其中的数学期望是关于联合概率密度 $p(\mathbf{x}_{0:k}, \mathbf{z}_{1:k})$. 在传统的无条件PCRLB中, 状态变量 $\mathbf{x}_{0:k}$ 和量测 $\mathbf{z}_{1:k}$ 都是随机变量, 并且边界是通过对所有量测 $\mathbf{z}_{1:k}$ 和状态 $\mathbf{x}_{0:k}$ 取平均值. 而在实际中, 在 $k+1$ 时刻, 除了目标状态方程和量测方程之外, 还可能知道量测信息 $\mathbf{z}_{1:k}$. 在已知过去所有量测值 $\mathbf{z}_{1:k}$ 的条件下, 当新的量测 \mathbf{z}_{k+1} 到达时, 估计目标状态 \mathbf{x}_{k+1} 的条件MSE的下界满足

$$\mathbb{E}\{[\hat{\mathbf{x}}_{k+1} - \mathbf{x}_{k+1}][\hat{\mathbf{x}}_{k+1} - \mathbf{x}_{k+1}]^T | \mathbf{z}_{1:k}\} \geq L^{-1}(\mathbf{x}_{k+1} | \mathbf{z}_{1:k}), \quad (4)$$

其中: $L(\mathbf{x}_{k+1} | \mathbf{z}_{1:k})$ 为目标状态估计值 $\hat{\mathbf{x}}_{k+1}$ 的条件FIM, $L^{-1}(\mathbf{x}_{k+1} | \mathbf{z}_{1:k})$ 为CPCRLB. 这里的量测 $\mathbf{z}_{1:k}$ 是实际获得的真实量测而不是随机向量, CPCRLB给出了利用 k 时刻的目标状态估计值向前一步预测 $k+1$ 时刻的估计值的性能下界. 根据文献[14], 在已知量测 $\mathbf{z}_{1:k}$ 的条件下, 目标状态向量 \mathbf{x}_{k+1} 的均方误差的条件FIM能够计算如下:

$$L(\mathbf{x}_{k+1} | \mathbf{z}_{1:k}) = B_k^{22} - B_k^{21}[L_A(\mathbf{x}_k | \mathbf{z}_{1:k}) + B_k^{11}]^{-1}B_k^{12}, \quad (5)$$

其中:

$$B_k^{11} = \mathbb{E}_{p_{\hat{\mathbf{x}}_k}^c} \{-\Delta_{\mathbf{x}_k}^{\mathbf{x}_k} \log p(\mathbf{x}_{k+1} | \mathbf{x}_k)\}, \quad (6)$$

$$B_k^{12} = \mathbb{E}_{p_{\hat{\mathbf{x}}_k}^c} \{-\Delta_{\mathbf{x}_k}^{\mathbf{x}_{k+1}} \log p(\mathbf{x}_{k+1} | \mathbf{x}_k)\} = (B_k^{21})^T, \quad (7)$$

$$B_k^{22} = \mathbb{E}_{p_{\hat{\mathbf{x}}_k}^c} \{-\Delta_{\mathbf{x}_{k+1}}^{\mathbf{x}_{k+1}} \log p(\mathbf{x}_{k+1} | \mathbf{x}_k)\} + \mathbb{E}_{p_{\hat{\mathbf{x}}_k}^c} \{-\Delta_{\mathbf{x}_{k+1}}^{\mathbf{x}_{k+1}} \log p(\mathbf{z}_{k+1} | \mathbf{x}_{k+1})\}. \quad (8)$$

数学期望是关于联合条件概率密度

$$p_{\hat{\mathbf{x}}_k}^c = p(\mathbf{x}_{0:k+1}, \mathbf{z}_{k+1} | \mathbf{z}_{1:k}),$$

其中 $L_A(\mathbf{x}_k | \mathbf{z}_{1:k})$ 称为辅助FIM. 为了降低计算复杂性, 文献[14]中给出了 $L_A(\mathbf{x}_k | \mathbf{z}_{1:k})$ 的一个近似迭代计算公式:

$$L_A(\mathbf{x}_{k+1} | \mathbf{z}_{1:k}) \approx S_k^{22} - S_k^{21}[L_A(\mathbf{x}_k | \mathbf{z}_{1:k-1}) + S_k^{11}]^{-1}S_k^{12}, \quad (9)$$

其中:

$$S_k^{11} = \mathbb{E}_{p(\mathbf{x}_{0:k} | \mathbf{z}_{1:k})} \{-\Delta_{\mathbf{x}_{k-1}}^{\mathbf{x}_{k-1}} \log p(\mathbf{x}_k | \mathbf{x}_{k-1})\}, \quad (10)$$

$$S_k^{12} = \mathbb{E}_{p(\mathbf{x}_{0:k} | \mathbf{z}_{1:k})} \{-\Delta_{\mathbf{x}_{k-1}}^{\mathbf{x}_{0:k}} \log p(\mathbf{x}_k | \mathbf{x}_{k-1})\} = (S_k^{21})^T, \quad (11)$$

$$S_k^{22} = \mathbb{E}_{p(\mathbf{x}_{0:k} | \mathbf{z}_{1:k})} \{-\Delta_{\mathbf{x}_k}^{\mathbf{x}_k} \log p(\mathbf{x}_{k+1} | \mathbf{x}_k)\} + \mathbb{E}_{p(\mathbf{x}_{0:k} | \mathbf{z}_{1:k})} \{-\Delta_{\mathbf{x}_k}^{\mathbf{x}_k} \log p(\mathbf{z}_k | \mathbf{x}_k)\}. \quad (12)$$

可以看出, 为了迭代计算条件FIM, 需要迭代计算辅助FIM $L_A(\mathbf{x}_k | \mathbf{z}_{1:k})$, 使得计算过程复杂化. 为了简化计算, 文献[16]给出了一个直接的CPCRLB近似迭代公式:

$$L(\mathbf{x}_{k+1} | \mathbf{z}_{1:k}) \approx B_k^{22} - B_k^{21}[L(\mathbf{x}_k | \mathbf{z}_{1:k-1}) + B_k^{11}]^{-1}B_k^{12}, \quad (13)$$

其中: B_k^{11} , B_k^{12} , B_k^{21} , B_k^{22} 由式(6)–(8)给出. 很显然, 迭代计算式(13)比式(5)更加紧凑, 不需要计算辅助FIM $L_A(\mathbf{x}_k | \mathbf{z}_{1:k})$, 因此, 简化了CPCRLB的计算过程, 节约了计算时间, 而且仿真结果表明两种近似算法之间几乎没有太大差别.

3 基于RSS观测的CPCRLB(CPCRLB based on RSS measurements)

在无线传感器网络下, 考虑一个目标在二维 X - Y 平面上运动, 目标状态向量为 $\tilde{\mathbf{x}}_k = (x_{1,k}, x_{2,k}, \dot{x}_{1,k}, \dot{x}_{2,k})^T$, 包括目标位置坐标 $(x_{1,k}, x_{2,k})$ 和速度 $(\dot{x}_{1,k}, \dot{x}_{2,k})$, 目标的运动模型为白噪声加速度模型:

$$\tilde{\mathbf{x}}_k = \tilde{F}_k \tilde{\mathbf{x}}_{k-1} + \tilde{\mathbf{u}}_k, \quad (14)$$

$$\text{其中: } \tilde{F}_k = \begin{bmatrix} 1 & 0 & T & 0 \\ 0 & 1 & 0 & T \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \tilde{\mathbf{u}}_k \text{ 是零均值高斯白噪声,}$$

协方差矩阵为

$$\tilde{Q} = q \begin{bmatrix} \frac{T^3}{3} & 0 & \frac{T^2}{2} & 0 \\ 0 & \frac{T^3}{3} & 0 & \frac{T^2}{2} \\ \frac{T^2}{2} & 0 & T & 0 \\ 0 & \frac{T^2}{2} & 0 & T \end{bmatrix}.$$

本文采用一个各向同性的信号强度衰减模型, 在 k 时刻, 传感器 n 接收到的目标信号强度(RSS)为

$$a_{n,k}^2 = \frac{G_n \bar{\phi}_k}{\left(\frac{d_{n,k}}{d_0}\right)^\alpha}, \quad (15)$$

其中: G_n 是传感器 n 的增益, $\bar{\phi}_k$ 表示在 k 时刻在参考距离 d_0 处, 目标辐射的信号强度; α 为信号衰减指数; $d_{n,k} = \sqrt{(\xi_{1,n} - x_{1,k})^2 + (\xi_{2,n} - x_{2,k})^2}$ 为目标和传感器节点 n 之间的距离, 其中: $(\xi_{1,n}, \xi_{2,n})$ 为传感器节点 n 的坐标, $(x_{1,k}, x_{2,k})$ 为 k 时刻目标位置坐标. 为简单起见, 假设对所有传感器节点 n , $G_n = G$, 记 $\phi_k = G_n \bar{\phi}_k$, 并且假设 $d_0 = 1$ m, 则式(15)简化为

$$a_{n,k}^2 = \frac{\phi_k}{(d_{n,k})^\alpha}. \quad (16)$$

在实际中, 由于噪声和建模误差影响, 传感器节点 n 实际接收到的被噪声污染了的RSS量测为

$$z_{n,k} = a_{n,k} + v_{n,k}, \quad (17)$$

其中: 观测噪声为零均值i.i.d加性高斯白噪声, 即 $v_{n,k} \sim N(0, \sigma_v^2)$. 当目标辐射的信号能量 ϕ_k 未知, 并且随时间随机波动时, 将 ϕ_k 建模为一个动态过程:

$$\phi_k = \phi_{k-1} + \beta_k, \quad (18)$$

其中 $\beta_k \sim N(0, \sigma_\beta^2)$. 将式(14)中的原始状态向量 $\tilde{\mathbf{x}}_k$ 扩张得到新的状态向量 $\mathbf{x}_k = (\phi_k, \tilde{\mathbf{x}}_k^T)^T$, 则扩张状态的动态模型为

$$\mathbf{x}_k = F_k \mathbf{x}_{k-1} + \mathbf{u}_k, \quad (19)$$

其中: $\mathbf{u}_k \sim N(0, Q)$, 并且

$$F = \begin{bmatrix} 1 & 0 \\ 0 & \tilde{F} \end{bmatrix}, \quad Q = \begin{bmatrix} \sigma_\beta^2 & 0 \\ 0 & \tilde{Q} \end{bmatrix}.$$

在给定的时刻 $k+1$, 设融合中心接受到来自其中 A 个节点的量测集合为 $\mathbf{z}_{k+1} = (z_{1,k+1}, \dots, z_{A,k+1})^T$. 基于加性高斯量测噪声假设, 融合中心量测数据的对数似然度为

$$\log p(\mathbf{z}_{k+1} | \mathbf{x}_{k+1}) = \sum_{n=1}^A \left[-\frac{(z_{n,k+1} - a_{n,k+1})^2}{2\sigma_v^2} - \log \sqrt{2\pi} \sigma_v \right]. \quad (20)$$

CPCRLB迭代的初始条件为

$$L(\mathbf{x}_0 | \mathbf{z}_{-1}) = E\{-\Delta_{\mathbf{x}_0} \log p(\mathbf{x}_0)\},$$

其中 $p(\mathbf{x}_0)$ 为目标初始状态概率密度函数(probability density function, PDF).

对本文的线性目标运动模型(19)和量测模型(17), 计算CPCRLB所需的式(6)–(8)中的数学期望为

$$\begin{aligned} B_k^{11} &= F^T Q^{-1} F, \\ B_k^{12} &= -F^T Q^{-1} = (B_k^{21})^T, \\ B_k^{22} &= Q^{-1} + B_k^{22,b}, \end{aligned}$$

其中:

$$B_k^{22,b} = E_{p_{k+1}^c} [-\Delta_{\mathbf{x}_{k+1}} \log p(\mathbf{z}_{k+1} | \mathbf{x}_{k+1})], \quad (21)$$

$B_k^{22,b}$ 是 5×5 维对称矩阵, 对非线性量测模型, 通常 $B_k^{22,b}$ 中的数学期望没有解析表达式.

在假设目标状态服从一阶Markov过程, 并且量测条件相互独立, 有

$$\begin{aligned} p_{k+1}^c &= p(\mathbf{x}_{0:k+1}, \mathbf{z}_{k+1} | \mathbf{z}_{1:k}) = \\ & p(\mathbf{z}_{k+1} | \mathbf{x}_{k+1}) p(\mathbf{x}_{k+1} | \mathbf{x}_k) p(\mathbf{x}_{0:k} | \mathbf{z}_{1:k}). \quad (22) \end{aligned}$$

对于具有RSS量测的目标跟踪问题, 由于量测方程的非线性, 本文借助于粒子滤波器对目标状态进行估计. 不失一般性, 利用通常的采样重要性重采样(sampling importance re-sampling, SIR)粒子滤波器, 在 $k+1$ 时刻, 从目标状态转移先验分布中采样: $\mathbf{x}_{k+1}^{(i)} \sim p(\mathbf{x}_{k+1} | \mathbf{x}_k^{(i)})$, 则粒子的权值简化为似然度, 即 $\omega_{k+1}^{(i)} \propto p(\mathbf{z}_{k+1} | \mathbf{x}_{k+1}^{(i)})$. 在 k 时刻, 给定一组 S 个加权粒子 $\{\mathbf{x}_{0:k}^{(i)}, \omega_{0:k}^{(i)}\}$, 经过重采样后, 每个粒子具有同样的权值 $1/S$, 目标状态的PDF可以逼近为

$$p(\mathbf{x}_{0:k} | \mathbf{z}_{1:k}) \approx \frac{1}{S} \sum_{i=1}^S \delta(\mathbf{x}_{0:k} - \mathbf{x}_{0:k}^{(i)}). \quad (23)$$

由式(22)–(23), 可以得到(证明见文献[14]附录A)

$$p_{k+1}^c \approx \frac{1}{S} \sum_{i=1}^S \delta(\mathbf{x}_{0:k+1} - \mathbf{x}_{0:k+1}^{(i)}) p(\mathbf{z}_{k+1} | \mathbf{x}_{k+1}^{(i)}), \quad (24)$$

其中: $\mathbf{x}_{k+1}^{(i)}$ 是利用目标状态模型从粒子集 $\{\mathbf{x}_{0:k}^{(i)}, \omega_{0:k}^{(i)}\}$ 得到的预测粒子. 借助于粒子滤波器, 式(21)中的数学期望能够用一组加权粒子逼近.

定理 1 对目标运动模型(19)和量测模型(17), 基于RSS量测数据的条件Fisher信息矩阵式可以迭代逼近计算如下:

$$L(\mathbf{x}_{k+1} | \mathbf{z}_{1:k}) \approx [FL^{-1}(\mathbf{x}_k | \mathbf{z}_{1:k-1})F^T + Q]^{-1} + B_k^{22,b}.$$

矩阵 $B_k^{22,b}$ 的元素如下:

$$B_k^{22,b}(1, 1) \approx \sum_{i=1}^S \kappa^{(i)} \frac{(d_{n,k+1}^{(i)})^2}{\alpha \phi_{k+1}^{(i)}}, \quad (25)$$

$$B_k^{22,b}(1, 2) \approx \sum_{i=1}^S \kappa^{(i)} (x_{1,k+1}^{(i)} - \xi_{1,n}), \quad (26)$$

$$B_k^{22,b}(1, 3) \approx \sum_{i=1}^S \kappa^{(i)} (x_{2,k+1}^{(i)} - \xi_{2,n}), \quad (27)$$

$$B_k^{22,b}(1, 4) = 0, \quad B_k^{22,b}(1, 5) = 0, \quad (28)$$

$$B_k^{22,b}(2, 2) \approx \sum_{i=1}^S \kappa^{(i)} \frac{\alpha \phi_{k+1}^{(i)} (x_{1,k+1}^{(i)} - \xi_{1,n})^2}{(d_{n,k+1}^{(i)})^2}, \quad (29)$$

$$\begin{aligned} B_k^{22,b}(2, 3) &\approx \sum_{i=1}^S \kappa^{(i)} \frac{\alpha \phi_{k+1}^{(i)}}{(d_{n,k+1}^{(i)})^2} (x_{1,k+1}^{(i)} - \xi_{1,n}) \cdot \\ & (x_{2,k+1}^{(i)} - \xi_{2,n}), \quad (30) \end{aligned}$$

$$B_k^{22,b}(2, 4) = 0, \quad B_k^{22,b}(2, 5) = 0, \quad (31)$$

$$B_k^{22,b}(3,3) \approx \sum_{i=1}^S \kappa^{(i)} \frac{\alpha \phi_{k+1}^{(i)} (x_{2,k+1}^{(i)} - \xi_{2,n})^2}{(d_{n,k+1}^{(i)})^2}, \quad (32)$$

$$B_k^{22,b}(3,4) = 0, B_k^{22,b}(3,5) = 0, \quad (33)$$

$$B_k^{22,b}(4,4) = 0, B_k^{22,b}(4,5) = 0, \quad (34)$$

$$B_k^{22,b}(5,5) = 0, \quad (35)$$

其中: $\kappa^{(i)} = \frac{1}{S\sigma_v^2} \sum_{n=1}^A \frac{\alpha}{4(d_{n,k+1}^{(i)})^{\alpha+2}}$, $d_{n,k+1}^{(i)}$ 由粒子 $\mathbf{x}_{k+1}^{(i)} = (\phi_{k+1}^{(i)}, x_{1,k+1}^{(i)}, x_{2,k+1}^{(i)}, \dot{x}_{1,k+1}^{(i)}, \dot{x}_{2,k+1}^{(i)})$ 得到。

证 见附录。

4 传感器选择方法(Sensor selection method)

4.1 基于CPCRLB的传感器选择(CPCRLB based sensor selection)

CPCRLB给出了目标状态的精确的在线预测性能边界,而且CPCRLB直接与估计器的均方误差有关,具有明显的物理意义,CPCRLB矩阵的迹可以作为传感器选择的标量准则。假定在时刻 $k+1$,从 N 个候选传感器中选择一个包含 A 个节点的传感器子集,则最优传感器子集 $S^*(k+1)$ 由下述带约束条件的优化问题给出:

$$S^*(k+1) = \arg \min_{s_{n,k+1}} \text{tr}[(FL^{-1}(\mathbf{x}_k | \mathbf{z}_{1:k-1})F^T + Q)^{-1} + \sum_{n=1}^N s_{n,k+1} B_k^{22,b}(z_{n,k+1})]^{-1}. \quad (36)$$

约束条件为

$$\sum_{n=1}^N s_{n,k+1} = A, s_{n,k+1} \in \{0, 1\}, n = 1, 2, \dots, N,$$

其中 $s_{n,k+1}$ 表示传感器 n 在 $k+1$ 时刻的状态

$$s_{n,k+1} = \begin{cases} 1, & \text{如果选择传感器}n, \\ 0, & \text{否则.} \end{cases}$$

对无线传感器网络(wireless sensor networks, WSN)的分簇管理,以上优化问题产生的 A 个节点的传感器子集可以作为在下一时刻需要激活唤醒的簇。

4.2 基于无条件PCRLB的传感器选择(Unconditional PCRLB based sensor selection)

基于无条件PCRLB的传感器选择方法与CPCRLB方法类似,其中的性能边界为目标状态估计值 $\hat{\mathbf{x}}_{k+1}$ 的PCRLB,需要注意的是,无条件PCRLB也有类似于式(13)的严格相等的迭代公式,CPCRLB与PCRLB迭代公式的主要区别是,PCRLB迭代公式中的式(6)–(8)中的数学期望是关于联合分布 $p(\mathbf{x}_{0:k}, \mathbf{z}_{1:k+1})$,其中的量测 $\mathbf{z}_{1:k+1}$ 是随机变量而不是实际获得的量测,PCRLB边界是关于所有的量测取平均。

4.3 基于互信息的传感器选择(Mutual information based sensor selection)

目标状态变量 \mathbf{x}_k 和传感器量测 \mathbf{z}_k 之间的互信息

(mutual information, MI)定义为

$$I(\mathbf{x}_k; \mathbf{z}_k) = \iint p(\mathbf{x}_k, \mathbf{z}_k) \log \frac{p(\mathbf{x}_k, \mathbf{z}_k)}{p(\mathbf{x}_k)p(\mathbf{z}_k)} d\mathbf{x}_k d\mathbf{z}_k. \quad (37)$$

互信息代表着传感器量测带来的信息增量,在 k 时刻,选择能带来最大互信息的包含 A 个节点的最优传感器子集 $S^*(k)$ 由下式给出:

$$S^*(k) = \arg \max_{S(k) \subset S} I(\mathbf{x}_k; \mathbf{z}_k(S(k))), \quad (38)$$

其中: $S(k)$ 为所有候选传感器节点, $\mathbf{z}_k(S(k))$ 表示传感器子集 $S(k)$ 产生的量测向量。下面本文给出MI的一种逼近算法,利用公式

$$p(\mathbf{x}; \mathbf{z}) = p(\mathbf{x}|\mathbf{z})p(\mathbf{z}) = p(\mathbf{z}|\mathbf{x})p(\mathbf{x}),$$

代入式(37)得

$$I(\mathbf{x}_k; \mathbf{z}_k) = \iint p(\mathbf{x}_k)p(\mathbf{z}_k|\mathbf{x}_k) \log \frac{p(\mathbf{z}_k|\mathbf{x}_k)}{p(\mathbf{z}_k)} d\mathbf{x}_k d\mathbf{z}_k. \quad (39)$$

在 k 时刻,基于当前所有实际量测信息 $\mathbf{z}_{1:k-1}$,目标状态分布可以逼近为 $p(\mathbf{x}_k) \approx \frac{1}{S} \sum_{i=1}^S \delta(\mathbf{x}_k - \mathbf{x}_k^{(i)})$,式(39)中 \mathbf{z}_k 的积分是关于 $\mathbf{z}_k = (z_{1,k}, \dots, z_{A,k})^T$ 的 A 重积分,通过量测空间的离散化和数值积分,则互信息可以逼近为

$$I(\mathbf{x}_k; \mathbf{z}_k) \approx \sum_{j_1=1}^{N_z} \dots \sum_{j_A=1}^{N_z} \frac{1}{S} p[(z_{1,k}^{j_1}, \dots, z_{A,k}^{j_A}) | \mathbf{x}_k^{(i)}] \cdot \log \frac{p[(z_{1,k}^{j_1}, \dots, z_{A,k}^{j_A}) | \mathbf{x}_k^{(i)}]}{p(z_{1,k}^{j_1}, \dots, z_{A,k}^{j_A})}. \quad (40)$$

其中: N_z 为每个传感器观测变量离散化样本个数, $\Delta z_{i,k}$ 为离散化区间长度。

5 仿真结果(Simulation results)

本节基于无线传感器网络获得的RSS量测数据,对无线传感器网络下的传感器管理和目标跟踪问题进行计算机仿真。传感器网络包含100个传感器节点,随机部署在 $300 \text{ m} \times 350 \text{ m}$ 的区域内。目标信号衰减指数 $\alpha=2$,目标辐射的信号能量在 $d_0=1 \text{ m}$ 处 $\phi=2000$ 。假定所有传感器节点的量测噪声具有相同的方差 $\sigma_v^2=0.1$ 。目标运动过程噪声参数 $q=1$,采样周期 $T=1 \text{ s}$ 。扩展的目标状态的先验分布为高斯分布,均值为 $\mathbf{x}_0 = (2000, 30, 30, 10, 10)$,协方差矩阵为 $\text{diag}\{100, 20, 20, 5, 5\}$ 。利用粒子滤波器进行100次Monte Carlo仿真,粒子个数取 $S=2000$ 。在仿真中,利用粒子滤波器计算CPCRLB,在每个时刻利用穷举方法从100个可用的传感器中选择激活 $A=2$ 个传感器。同时,本文对基于CPCRLB方法、无条件PCRLB以及MI传感器选择方法的目标跟踪结果进行了仿真对比。

图1给出了一次Monte Carlo仿真实实现中无线传感器网络节点几何位置、真实目标轨迹、以及分别

基于CPCRLB、PCRLB和MI传感器选择方法获得的目标轨迹的估计值. 从仿真结果可以看出, CPCRLB和MI的传感器选择方法具有相似的跟踪性能, CPCRLB和MI方法相对于PCRLB方法获得了更高的目标跟踪精度. 因为在CPCRLB和MI的计算中利用了传感器已经获得的真实量测信息和实际的目标航迹信息, 因此相对于无条件PCRLB方法, CPCRLB和MI能够选择更好的传感器节点, 从而获得更精确的目标位置估计.




图1 真实目标轨迹和估计值

Fig. 1 A realization of target trajectory and its estimates

图2和图3分别给出了3种传感器选择方法对应的目标位置坐标 $x_{1,k}$ 和 $x_{2,k}$ 估计值的均方误差(MSE), 图中也给出了相应坐标分量的CPCRLB. 图4给出了3种传感器选择方法对应的目标辐射的信号能量 ϕ_k 的MSE, 及相应的CPCRLB, 其中MSE, CPCRLB分别由100次不同的Monte Carlo仿真结果的平均值给出. 在每次仿真中, 首先随机生成传感器节点的几何位置和目标轨迹, 然后由粒子滤波器和传感器选择算法得到目标状态估计值和MSE, 并利用所选择的传感器得到CPCRLB. 从仿真结果可以看出, 基于CPCRLB的传感器选择方法不但具有较小的MSE, 而且CPCRLB给出了状态估计MSE的一个紧密的下界.




图2 目标位置坐标 $x_{1,k}$ 的MSE和CPCRLB

Fig. 2 MSE and CPCRLB of $x_{1,k}$




图3 目标位置坐标 $x_{2,k}$ 的MSE和CPCRLB

Fig. 3 MSE and CPCRLB of $x_{2,k}$

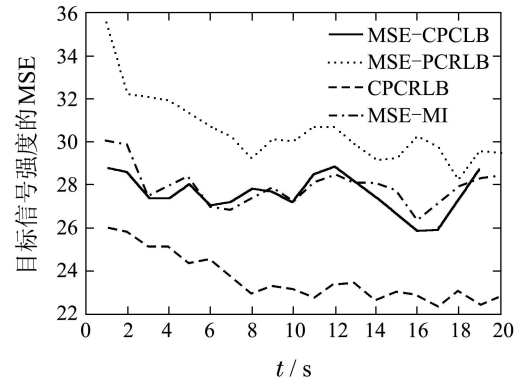


图4 目标辐射信号能量 ϕ_k 的MSE和CPCRLB

Fig. 4 MSE and CPCRLB of target signal power

注意到MI的计算公式(40)需要 $S \times N_z^A$ 次求和运算, N_z 为每个传感器观测变量离散化样本个数, A 为每次激活的传感器个数, 而CPCRLB方法中FIM需要 $S \times A$ 次求和运算, 因此在计算复杂性方面, CPCRLB方法比MI更具有优越性, MI方法的计算复杂性随每次激活的传感器个数指数增加, 而CPCRLB的计算复杂性随每次激活的传感器个数线性增加.

6 结论(Conclusions)

本文对无线传感器网络下的目标跟踪问题, 基于CPCRLB和传感器接收到的信号强度观测数据, 提出一种传感器选择算法. 利用传感器接收到的信号强度量测数据推导了目标跟踪均方误差的CPCRLB, 并且基于粒子滤波器对目标进行跟踪, 同时利用粒子滤波器给出CPCRLB的一种逼近计算方法. 后续的研究工作包括在量测来源不确定性下的传感器选择算法, 以及量化数据下的CPCRLB和传感器网络的分簇管理方法.

参考文献(References):

[1] HERO A O, COCHRAN D. Sensor management: past, present, and future [J]. *IEEE Sensors Journal*, 2011, 11(12): 3064–3075.
 [2] ZHAO F, SHIN J, REICH J. Information-driven dynamic sensor collaboration for tracking applications [J]. *IEEE Signal Processing Magazine*, 2002, 19(1): 68–77.

- [3] 罗开平, 姜维, 李一军. 传感器管理述评 [J]. 电子学报, 2010, 38(8): 1900 – 1907.
(LUO Kaiping, JIANG Wei, LI Yijun. Review of sensor management [J]. *Acta Electronica Sinica*, 2010, 38(8): 1900 – 1907.)
- [4] 赵忠华, 皇甫伟, 孙利民, 等. 无线传感器网络管理技术 [J]. 计算机科学, 2011, 38(1): 8 – 14.
(ZHAO Zhonghua, HUANG Fuwei, SUN Limin, et al. Wireless sensor network management technology [J]. *Computer Science*, 2011, 38(1): 8 – 14.)
- [5] 陈延军, 潘泉, 梁彦, 等. 基于信息量的分布式协同自组织算法 [J]. 控制理论与应用, 2011, 28(10): 1391 – 1398.
(CHEN Yanjun, PAN Quan, LIANG Yan, et al. Decentralized collaborative self-organization algorithm based on information content [J]. *Control Theory & Applications*, 2011, 28(10): 1391 – 1398.)
- [6] KREUCHER C M, KASTELLA K D, HERO A O. Sensor management using active sensing approach [J]. *Signal Processing*, 2005, 85(3): 607 – 624.
- [7] KREUCHER C M, HERO A O, KASTELLA K D, et al. An information-based approach to sensor management in large dynamic networks [J]. *Proceedings of the IEEE*, 2007, 95(5): 978 – 999.
- [8] HOFFMANN G M, TOMLIN C J. Mobile sensor network control using mutual information methods and particle filters [J]. *IEEE Transactions on Automatic Control*, 2010, 55(1): 32 – 47.
- [9] WILLIAMS J L, FISHER J W, WILLSKY A S. Approximate dynamic programming for communication-constrained sensor network management [J]. *IEEE Transactions on Signal Processing*, 2007, 55(8): 4300 – 4311.
- [10] TICHAVSKY P, MURAVCHIK C H, NEHORAI A. Posterior Cramér-Rao bounds for discrete-time nonlinear filtering [J]. *IEEE Transactions on Signal Processing*, 1998, 46(2): 1386 – 1395.
- [11] HERNANDEZ M L, KIRUBARAJAN T, BAR-SHALOM Y. Multisensor resource deployment using Cramér-Rao lower bounds [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2004, 40(2): 399 – 416.
- [12] PUNITHAKUMAR K, KIRUBARAJAN T, HERNANDEZ M L. Multisensor deployment using PCRLBs, incorporating sensor deployment and motion uncertainties [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2006, 42(4): 1474 – 1485.
- [13] MASAZADE E, NIU R, VARSHNEY P K. Energy aware iterative source localization for wireless sensor networks [J]. *IEEE Transactions on Signal Processing*, 2010, 58(9): 4824 – 4835.
- [14] ZUO L, NIU R, VARSHNEY P K. Conditional posterior Cramer-Rao lower bounds for nonlinear sequential Bayesian estimation [J]. *IEEE Transactions on Signal Processing*, 2011, 59(1): 1 – 14.
- [15] ZUO L. *Conditional posterior Cramér-Rao lower bound and distributed target tracking in sensor networks* [D]. Syracuse, NY: Syracuse University, 2010.

- [16] ZHENG Y, OZDEMIR O, NIU R, et al. New Conditional Posterior Cramér-Rao lower bounds for nonlinear sequential bayesian estimation [J]. *IEEE Transactions on Signal Processing*, 2012, 60(10): 5549 – 5556.

附录 定理1证明(Appendix Proof of Theorem

1)

首先笔者推导矩阵 $B_k^{22,b}$ 的(1,1)元素:

$$\frac{\partial^2 \log p(\mathbf{z}_{k+1} | \mathbf{x}_{k+1})}{\partial \phi_{k+1}^2} = \frac{1}{\sigma_v^2} \sum_{n=1}^A [(z_{n,k+1} - a_{n,k+1}) \frac{\partial^2 a_{n,k+1}}{\partial \phi_{k+1}^2} - (\frac{\partial a_{n,k+1}}{\partial \phi_{k+1}})^2]. \quad (A1)$$

注意到 $E_{p(z_{k+1} | \mathbf{x}_{k+1}^{(i)})}(z_{n,k+1}) = a_{n,k+1}(\mathbf{x}_{k+1}^{(i)})$, 有

$$E_{p_{k+1}^c} \left[- \frac{\partial^2 \log p(\mathbf{z}_{k+1} | \mathbf{x}_{k+1})}{\partial \phi_{k+1}^2} \right] = E_{p_{k+1}^c} \left[\frac{1}{\sigma_v^2} \sum_{n=1}^A - \left(\frac{\partial a_{n,k+1}}{\partial \phi_{k+1}} \right)^2 \right]. \quad (A2)$$

利用 $\frac{\partial a_{n,k+1}}{\partial \phi_{k+1}} = \frac{1}{2\sqrt{\phi_{k+1} d_{n,k+1}^\alpha}}$, 以及粒子逼近式(23), 可得

$$B_k^{22,b}(1,1) \approx \sum_{i=1}^S \kappa^{(i)} \frac{(d_{n,k+1}^{(i)})^2}{\alpha \phi_{k+1}^{(i)}}. \quad (A3)$$

同理可得矩阵 $B_k^{22,b}$ 的其他元素, 由于篇幅所限, 本文省略了推导过程.

作者简介:

杨小军 (1971-), 男, 博士, 副教授, 目前研究方向为统计信号处理及应用、目标检测与跟踪、无线传感器网络和多源信息融合, E-mail: xjyang@chd.edu.cn;

马祥 (1978-), 男, 博士, 讲师, 目前研究方向为信号与信息处理, E-mail: maxiang@chd.edu.cn;

宋青松 (1980-), 男, 博士, 讲师, 目前研究方向为智能计算与自主移动机器人, E-mail: qssong@chd.edu.cn;

邢科义 (1957-), 男, 教授, 博士生导师, 目前研究方向为离散事件动态系统, E-mail: kyxing@sei.xjtu.edu.cn.