

基于性能边界和量化数据的 WSN 目标跟踪 传感器选择算法

杨小军

(长安大学信息工程学院, 陕西西安 710064)

摘要: 对能量和带宽受限的无线传感器网络下的目标跟踪问题, 基于量化的观测数据和条件后验克拉美-罗下界提出一种传感器选择方法. 为了节约网络能量和带宽, 对传感器接收到的观测数据进行量化压缩, 推导了传感器量化数据下目标状态估计的条件后验克拉美-罗下界, 将其作为传感器选择和优化的准则, 并且利用粒子滤波器给出一种条件后验克拉美-罗下界的近似计算方法. 与基于无条件后验克拉美-罗下界和互信息的传感器选择方法进行了对比仿真, 结果表明了条件后验克拉美-罗下界作为传感器选择准则的有效性以及对跟踪性能的改进.

关键词: 传感器网络; 后验克拉美-罗下界; 传感器选择; 粒子滤波; 量化

中图分类号: TP273 **文献标识码:** A **文章编号:** 0372-2112 (2014)06-1081-05

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2014.06.007

Sensor Selection for Target Tracking in Wireless Sensor Networks Based on Performance Bounds and Quantized Data

YANG Xiao-jun

(School of Information Engineering, Chang'an University, Xi'an, Shaanxi 710064, China)

Abstract: For target tracking in the energy and bandwidth-constrained wireless sensor networks, a sensor selection scheme is proposed based on quantized data and conditional posterior Cramér-Rao lower bounds (CPCRLB). The received measurements are quantized and compressed to save the energy and bandwidth. The CPCRLB with quantized data is derived and used as the criterion for sensor selection to optimize the performance of tracking. Moreover, the particle filtering is employed to compute the CPCRLB approximately. The CPCRLB based sensor selection scheme is compared with the mutual information and the unconditional posterior Cramér-Rao lower bounds based sensor selection schemes by simulation. The results show that the CPCRLB is more efficient and the improved performance is achieved.

Key words: sensor networks; posterior Cramér-Rao lower bounds; sensor selection; particle filtering; quantization.

1 引言

无线传感器网络 (Wireless Sensor Networks, WSN) 综合了现代传感器技术、微电子技术、通讯技术等多个学科, 实现了信息采集、传输和处理的统一^[1]. 但是对能量、带宽等资源受限的 WSN, 为了充分发挥 WSN 的功能, 必须在条件允许下, 选择激活一组最优的传感器节点参与任务, 从而降低 WSN 能量、带宽等资源消耗, 同时获得精确的目标状态估计, 有效的传感器选择已成为 WSN 分布式目标跟踪理论的一个重要组成部分^[2].

信息论方法最早被用作传感器选择的准则, Zhao 等^[3]基于对熵和相对熵等方法, 提出了信息驱动的传感器选择策略. Hoffmann 等^[4]以目标状态和观测之间的互

信息作为传感器选择的目标函数, 国内研究者也提出了多种基于信息增量的传感器资源分配方法^[5,6], 但是当传感器节点数目很大时, 信息论方法面临很高的计算复杂性. 后验克拉美-罗下界 (Posterior Cramér-Rao Lower Bounds, PCRLB) 给出了目标状态估计均方误差理论上的性能下界, 近年来, 许多研究者提出了控制目标状态估计的 PCRLB 的传感器资源管理方法^[7]. 但是 PCRLB 没有利用实际的观测信息, 对具体的目标航迹实现, 不能完全反映传感器的性能. 最近, 文献^[8]提出了条件 PCRLB (Conditional Posterior Cramér-Rao Lower Bounds, CPCRLB), CPCRLB 以当前时刻的所有真实观测为条件, 给出了目标状态估计的实际均方误差下界. 由于 CPCRLB 是传感器真实观测的函数, 包含了当前目标真

实航迹信息,特别适合于无线传感器网络下的传感器资源管理^[9].对资源受限的WSN,文献[10,11]提出了基于量化数据的目标跟踪和定位方法,对观测数据进行量化压缩,只传递有限位量化信号到融合中心.但是在实际目标跟踪中,经常面对非线性系统,特别是量化数据下的目标跟踪,CPCRLB的迭代计算及传感器选择是实现分布式WSN目标跟踪需要解决的关键问题.

本文基于量化数据和CPCRLB解决WSN下分布式目标跟踪的传感器选择问题,本文的创新之处在于考虑了量化的传感器观测数据,推导了传感器量化数据下目标状态估计均方误差的CPCRLB性能边界.由于传感器量化观测带来的非线性问题,我们基于粒子滤波器对目标进行跟踪,同时利用粒子滤波器提出一种CPCRLB迭代逼近算法,实现传感器在线选择.

2 问题描述

对平面运动目标,设目标状态向量为 $\mathbf{x}_k = [x_{1,k}, x_{2,k}, \dot{x}_{1,k}, \dot{x}_{2,k}]^T$,包括目标位置 $(x_{1,k}, x_{2,k})$ 和速度 $(\dot{x}_{1,k}, \dot{x}_{2,k})$,目标运动模型为白噪声加速度模型:

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

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

方差矩阵 $\mathbf{Q} = q \begin{bmatrix} \frac{T^3}{3} & 0 & \frac{T^2}{2} & 0 \\ 0 & \frac{T^3}{3} & 0 & \frac{T^2}{2} \\ \frac{T^2}{2} & 0 & T & 0 \\ 0 & \frac{T^2}{2} & 0 & T \end{bmatrix}$, q 为信号强度, T

为采样间隔.设在 k 时刻,传感器 n 接收到的来自目标的信号强度为^[9,10]:

$$a_{n,k} = \sqrt{\varphi \left(\frac{d_0}{d_{n,k}} \right)^\alpha} \quad (2)$$

其中: φ 表示在参考距离 d_0 处目标辐射的信号能量,不失一般性,设 $d_0 = 1$. 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 n 之间的距离,其中: $(\xi_{1,n}, \xi_{2,n})$ 为传感器 n 的坐标, $(x_{1,k}, x_{2,k})$ 为 k 时刻目标坐标.传感器 n 实际接收到的被噪声污染的观测为:

$$y_{n,k} = a_{n,k} + v_{n,k} \quad (3)$$

其中:观测噪声为独立同分布的零均值高斯白噪声,即 $v_{n,k} \sim N(0, \sigma_v^2)$.

由于网络资源限制,为了减少通讯进而减少网络

能量消耗和带宽,各传感器节点对其原始观测 $y_{n,k}$ 进行量化压缩: $z_{n,k} = Q(y_{n,k})$.其中: $Q(\cdot)$ 是 $M = \log_2^L$ 位量化器,量化后的观测为:

$$z_{n,k} = \begin{cases} 0, & \eta_{n,0} < y_{n,k} < \eta_{n,1} \\ 1, & \eta_{n,1} < y_{n,k} < \eta_{n,2} \\ \vdots \\ L-1, & \eta_{n,L-1} < y_{n,k} < \eta_{n,L} \end{cases} \quad (4)$$

其中: $\eta_{n,0}, \eta_{n,1}, \dots, \eta_{n,L}$ 是预先指定的量化阈值, $\eta_{n,0} = -\infty, \eta_{n,L} = \infty$.

由于高斯噪声假设,量化观测的似然度函数为:

$$p_{n,k}(l, \mathbf{x}_k) = p(z_{n,k} = l | \mathbf{x}_k) = Q\left(\frac{\eta_{n,l} - a_{n,k}}{\sigma_v}\right) - Q\left(\frac{\eta_{n,l+1} - a_{n,k}}{\sigma_v}\right) \quad (5)$$

其中 $Q(x) = \int_x^\infty \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} dt$ 是标准高斯分布的补分布函数.设在给定的时刻 k ,融合中心接受到来自 N 个激活的传感器节点的观测集合为: $\mathbf{z}_k = [z_{1,k}, \dots, z_{N,k}]^T$.

3 量化数据的CPCRLB及其迭代计算

CPCRLB给出了在已知过去所有观测值 $\mathbf{z}_{1:k}$ 的条件下,当获得新的观测 \mathbf{z}_{k+1} 时,估计目标状态 \mathbf{x}_{k+1} 的均方误差(Mean Square Error, MSE)下界满足:

$$E\{[\hat{\mathbf{x}}_{k+1} - \mathbf{x}_{k+1}][\hat{\mathbf{x}}_{k+1} - \mathbf{x}_{k+1}]^T | \mathbf{z}_{1:k}\} \geq \mathbf{L}^{-1}(\mathbf{x}_{k+1} | \mathbf{z}_{1:k}) \quad (6)$$

其中: $\mathbf{L}(\mathbf{x}_{k+1} | \mathbf{z}_{1:k})$ 表示目标状态估计值 $\hat{\mathbf{x}}_{k+1}$ 的条件Fisher信息矩阵(Fisher Information Matrix, FIM).文献[10]给出了条件FIM的一个迭代计算方法,但是该方法需要计算一个辅助FIM,带来了额外的矩阵求逆,消耗了大量计算时间,为了简化CPCRLB的迭代计算,文献[12]给出了一个新的直接的CPCRLB近似迭代公式:

$$\mathbf{L}(\mathbf{x}_{k+1} | \mathbf{z}_{1:k}) \approx \mathbf{B}_k^{22} - \mathbf{B}_k^{21} [\mathbf{B}_k^{11} + \mathbf{L}(\mathbf{x}_k | \mathbf{z}_{1:k-1})]^{-1} \mathbf{B}_k^{12} \quad (7)$$

其中:

$$\begin{aligned} \mathbf{B}_k^{11} &= E_{p_{k+1}^c} \{ -\Delta_{\mathbf{x}_k}^{\mathbf{x}_{k+1}} \ln p(\mathbf{x}_{k+1} | \mathbf{x}_k) \} \\ \mathbf{B}_k^{12} &= E_{p_{k+1}^c} \{ -\Delta_{\mathbf{x}_k}^{\mathbf{x}_{k+1}} \ln p(\mathbf{x}_{k+1} | \mathbf{x}_k) \} = (\mathbf{B}_k^{21})^T \\ \mathbf{B}_k^{22} &= E_{p_{k+1}^c} \{ -\Delta_{\mathbf{x}_k}^{\mathbf{x}_{k+1}} [\ln p(\mathbf{x}_{k+1} | \mathbf{x}_k) + \ln p(\mathbf{z}_{k+1} | \mathbf{x}_{k+1})] \} \end{aligned} \quad (8)$$

数学期望是关于联合概率密度 $p_{k+1}^c = p(\mathbf{x}_{0:k+1}, \mathbf{z}_{k+1} | \mathbf{z}_{1:k})$,初始迭代为: $\mathbf{L}(\mathbf{x}_0 | \mathbf{z}_{-1}) = E\{ -\Delta_{\mathbf{x}_0}^{\mathbf{x}_0} \ln p(\mathbf{x}_0) \}$.

对线性目标运动模型式(1)和非线性量化观测模型式(4),式(8)中的各项变为:

$$\mathbf{B}_k^{11} = \mathbf{F}^T \mathbf{Q}^{-1} \mathbf{F}, \mathbf{B}_k^{12} = -\mathbf{F}^T \mathbf{Q}^{-1}, \mathbf{B}_k^{22} = \mathbf{Q}^{-1} + \mathbf{B}_k^{22,b} \quad (9)$$

其中: $\mathbf{B}_k^{22,b} = \mathbb{E}_{p_{k+1}^c} \left\{ -\Delta \mathbf{x}_{k+1}^{(i)} \ln p(\mathbf{z}_{k+1} | \mathbf{x}_{k+1}) \right\}$.

融合中心接受到的来自 N 个激活的传感器节点的观测似然度为:

$$p(\mathbf{z}_{k+1} | \mathbf{x}_{k+1}) = \prod_{n=1}^N \prod_{l=0}^{L-1} p_{n,k+1}(l, \mathbf{x}_{k+1})^{\delta(z_{n,k+1} - l)} \quad (10)$$

对数似然度为:

$$\begin{aligned} & \ln p(\mathbf{z}_{k+1} | \mathbf{x}_{k+1}) \\ &= \sum_{n=1}^N \sum_{l=0}^{L-1} \delta(z_{n,k+1} - l) \ln p_{n,k+1}(l, \mathbf{x}_{k+1}), \end{aligned}$$

其中: $\delta(x) = \begin{cases} 1, & x = 0 \\ 0, & x \neq 0 \end{cases}$.

对称矩阵 $\mathbf{B}_k^{22,b}$ 通常没有解析表达式, 类似文献 [9] 方法, 借助于粒子滤波器和 Monte Carlo 方法, 在 k 时刻, 给定一组 S 个加权粒子 $\{\mathbf{x}_{0:k}^{(i)}, \omega_{0:k}^{(i)}\}_{i=1}^S$ 逼近目标状态的后验概率密度: $p(\mathbf{x}_{0:k} | \mathbf{z}_{1:k}) \approx \frac{1}{S} \sum_{i=1}^S \delta(\mathbf{x}_{0:k} - \mathbf{x}_{0:k}^{(i)})$, 并且有 $p_{k+1}^c \approx \frac{1}{S} \sum_{i=1}^S \delta(\mathbf{x}_{0:k+1} - \mathbf{x}_{0:k+1}^{(i)}) p(\mathbf{z}_{k+1} | \mathbf{x}_{k+1}^{(i)})$. 首先, 推导矩阵元素 $\mathbf{B}_k^{22,b}(1,1)$:

$$\begin{aligned} & \frac{\partial^2 \ln p(\mathbf{z}_{k+1} | \mathbf{x}_{k+1})}{\partial x_{1,k+1}^2} \\ &= \sum_{n=1}^N \sum_{l=0}^{L-1} -\frac{\delta(z_{n,k+1} - l)}{p_{n,k+1}^2(l, \mathbf{x}_{k+1})} \left[\frac{\partial p_{n,k+1}(l, \mathbf{x}_{k+1})}{\partial x_{1,k+1}} \right]^2 \\ &+ \frac{\delta(z_{n,k+1} - l)}{p_{n,k+1}(l, \mathbf{x}_{k+1})} \left[\frac{\partial^2 p_{n,k+1}(l, \mathbf{x}_{k+1})}{\partial x_{1,k+1}^2} \right] \quad (11) \end{aligned}$$

注意到: $\mathbb{E}_{p(\mathbf{z}_{k+1} | \mathbf{x}_{k+1}^{(i)})} [\delta(z_{n,k+1} - l)] = p_{n,k+1}(l, \mathbf{x}_{k+1}^{(i)})$, 则有

$$\begin{aligned} & \mathbb{E}_{p_{k+1}^c} \left\{ \frac{\partial^2 \ln p(\mathbf{z}_{k+1} | \mathbf{x}_{k+1})}{\partial x_{1,k+1}^2} \right\} \\ &= \mathbb{E}_{p_{k+1}^c} \left\{ \sum_{n=1}^N \sum_{l=0}^{L-1} -\frac{\delta(z_{n,k+1} - l)}{p_{n,k+1}^2(l, \mathbf{x}_{k+1})} \left[\frac{\partial p_{n,k+1}(l, \mathbf{x}_{k+1})}{\partial x_{1,k+1}} \right]^2 \right\} \\ &\approx \frac{1}{S} \sum_{i=1}^S \sum_{n=1}^N \sum_{l=0}^{L-1} \frac{-1}{p_{n,k+1}^2(l, \mathbf{x}_{k+1}^{(i)})} \left[\frac{\partial p_{n,k+1}(l, \mathbf{x}_{k+1})}{\partial x_{1,k+1}} \right]^2 \Bigg|_{\mathbf{x}_{k+1} = \mathbf{x}_{k+1}^{(i)}} \quad (12) \end{aligned}$$

利用 $\frac{\partial Q\left(\frac{\eta_{n,l} - a_{n,k+1}}{\sigma_v}\right)}{\partial x_{1,k+1}} = \frac{\alpha a_{n,k+1} d_{n,k+1}^{-2} (\xi_{1,n} - x_{1,k+1})}{2\sqrt{2\pi}\sigma_v} \cdot e^{-\frac{(\eta_{n,l} - a_{n,k+1})^2}{2\sigma_v^2}}$, 可以得到如下近似:

$$\begin{aligned} & \mathbf{B}_k^{22,b}(1,1) = \mathbb{E}_{p_{k+1}^c} \left\{ -\frac{\partial^2 \ln p(\mathbf{z}_{k+1} | \mathbf{x}_{k+1})}{\partial x_{1,k+1}^2} \right\} \\ &\approx \frac{1}{S} \sum_{i=1}^S \sum_{n=1}^N \alpha^2 \kappa_n a_{n,k+1}^2 d_{n,k+1}^{-4} (\xi_{1,n} - x_{1,k+1}^{(i)})^2 \Bigg|_{\mathbf{x}_{k+1} = \mathbf{x}_{k+1}^{(i)}} \quad (13) \end{aligned}$$

其中: $\kappa_n = \frac{1}{8\pi\sigma_v^2} \sum_{l=0}^{L-1} \frac{\gamma_{n,l}}{p_{n,k+1}(l, \mathbf{x}_{k+1})}$,

$$\gamma_{n,l} = \left(e^{-\frac{(\eta_{n,l} - a_{n,k+1})}{2\sigma_v^2}} - e^{-\frac{(\eta_{n,l+1} - a_{n,k+1})}{2\sigma_v^2}} \right)^2.$$

同理可得:

$$\begin{aligned} & \mathbf{B}_k^{22,b}(1,2) \approx \frac{1}{S} \sum_{i=1}^S \sum_{n=1}^N \alpha^2 \kappa_n a_{n,k+1}^2 d_{n,k+1}^{-4} (\xi_{1,n} \\ & - x_{1,k+1}^{(i)}) (\xi_{2,n} - x_{2,k+1}^{(i)}), \mathbf{B}_k^{22,b}(1,3) = 0, \mathbf{B}_k^{22,b}(1,4) = 0 \quad (14) \end{aligned}$$

$$\begin{aligned} & \mathbf{B}_k^{22,b}(2,2) \approx \frac{1}{S} \sum_{i=1}^S \sum_{n=1}^N \alpha^2 \kappa_n a_{n,k+1}^2 d_{n,k+1}^{-4} (\xi_{2,n} \\ & - x_{2,k+1}^{(i)})^2, \mathbf{B}_k^{22,b}(2,3) = 0, \mathbf{B}_k^{22,b}(2,4) = 0 \quad (15) \end{aligned}$$

$$\mathbf{B}_k^{22,b}(3,3) = 0, \mathbf{B}_k^{22,b}(3,4) = 0, \mathbf{B}_k^{22,b}(4,4) = 0 \quad (16)$$

综上所述, 对跟踪系统式(1)和式(4), 基于量化数据的条件 FIM 可以迭代计算如下:

$$\mathbf{L}(\mathbf{x}_{k+1} | \mathbf{z}_{1:k}) \approx (\mathbf{Q} + \mathbf{F} \cdot \mathbf{L}^{-1}(\mathbf{x}_k | \mathbf{z}_{1:k-1}) \cdot \mathbf{F}^T)^{-1} + \mathbf{B}_k^{22,b} \quad (17)$$

CPCRLB 给出了目标状态估计均方误差的下界, 给出了目标状态的精确的在线预测性能边界, 因此适合于作为传感器选择的准则. 对目标跟踪问题, 通常更关心的是目标位置, 因此我们选择位置坐标分量的边界之和作为传感器选择的目标函数.

$$\mathcal{C}_{k+1} = \mathbf{L}_{k+1}^{-1}(1,1) + \mathbf{L}_{k+1}^{-1}(2,2) \quad (18)$$

其中: $\mathbf{L}_{k+1} = \mathbf{L}(\mathbf{x}_{k+1} | \mathbf{z}_{1:k})$, $\mathbf{L}_{k+1}^{-1}(1,1)$ 和 $\mathbf{L}_{k+1}^{-1}(2,2)$ 是运动目标位置分量 $x_{1,k+1}$ 和 $x_{2,k+1}$ 的均方误差下界. 假定在时刻 $k+1$, 从所有候选传感器中选择激活包含 N 个节点的传感器子集, 则最优传感器子集 $S^*(k+1)$ 由下式给出:

$$S^*(k+1) = \arg \min_{S(k+1) \subseteq \bar{S}} \mathcal{C}_{k+1}(S(k+1)) \quad (19)$$

其中 \bar{S} 为所有候选传感器节点, $\mathcal{C}_{k+1}(S(k+1))$ 表示选择传感器子集 $S(k+1)$ 获得的性能边界目标函数.

4 仿真结果

本节利用传感器量化数据, 对传感器网络下传感器选择和目标跟踪问题进行计算机仿真. 传感器网络包含 36 个节点, 以方格形式均匀部署在 250m × 250m 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 $\varphi = 25000$. 假定所有传感器节点的观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 $T = 1\text{s}$. 目标状态的先验分布为高斯分布, 均值为 $\mathbf{x}_0 = [30, 30, 10, 10]^T$, 协方差矩阵为 $\text{diag}\{20, 20, 5, 5\}$. 每个传感器使用 $M = 4$ bit 量化位率, 为简单起见, 假设每个传感器使用了均匀量化策略和相同的量化阈值, 粒子滤波器粒子个数取 $S = 3000$. 在仿真中, 在每个时刻利用穷举搜索方法从所有传感器节点中选择 $N = 3$ 个节点参与目标跟踪任务.

首先我们对 CPCRLB 和无条件 PCRLB 传感器选择方法进行了对比仿真. 在仿真中, 我们基于观测 $\mathbf{z}_{1:k}$ 的

实现计算了目标状态的 CPCRLB 和均方根误差 (Root Mean Square Error, RMSE), 无条件 PCRLB 是通过关于所有观测 $z_{1:k}$ 和状态 $x_{0:k}$ 取平均值得到, 我们采用 Monte Carlo 方法对 PCRLB 中的数学期望值进行了逼近计算. 图 1 给出了一次 Monte Carlo 仿真实验中真实目标轨迹, 以及分别基于 CPCRLB 和 PCRLB 传感器选择获得的目标轨迹的估计值. 图 2 和图 3 分别给出了目标位置坐标分量 $x_{1,k}$ 和 $x_{2,k}$ 估计值的 RMSE, 图中也给出了相应于 $x_{1,k}$ 和 $x_{2,k}$ 的 CPCRLB 的均方根和 PCRLB 的均方根, 其中 RMSE、CPCRLB 和 PCRLB 分别由 100 次 Monte Carlo 仿真取平均. 在每次仿真中, 对固定的目标轨迹, 由粒子滤波器和传感器选择算法得到目标状态估计的 RMSE, 并利用所选择激活的传感器得到 CPCRLB 和 PCRLB. 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 RMSE, 而且相对于 PCRLB, CPCRLB 给出了状态估计 RMSE 的更紧密的下界. 因为 CPCRLB 利用了传感器已经获得的真实观测信息和实际的目标航迹信息, 因此能够选择更好的传感器节点, 从而获得更精确的目标状态估计.




图1 目标真实轨迹和估计值




图2 目标位置坐标 $x_{1,k}$ 的RMSE、CPCRLB和PCRLB

其次我们对基于 CPCRLB 和基于互信息 (Mutual Information, MI) 的传感器选择方法进行了对比仿真. MI 选择的最优传感器子集为: $S^*(k+1) = \arg \max_{S(k+1) \subset S} I(\mathbf{x}_{k+1}; \mathbf{z}_{k+1}[S(k+1)])$, 其中: $I(\mathbf{x}_{k+1}; \mathbf{z}_{k+1}[S(k+1)])$ 是目标状态和选择激活的传感器子集 $S(k+1)$ 产生的观测之间的互信息 (互信息的数值计算参见文献 [9, 11]). 图 4 和图 5 分别给出了 CPCRLB 和 MI 两种传感器选择方法

的 $x_{1,k}$ 和 $x_{2,k}$ 的 RMSE. 作为性能比较, 我们也给出了基于最近邻 (Nearest Neighbor, NN) 传感器选择的 RMSE 性能, 在最近邻方法中, 每次都选择最靠近目标预测位置的 N 个节点. 仿真结果表明基于 CPCRLB 和 MI 的传感器选择方法具有相似的跟踪性能, 并且两者性能都超过了 NN. 在 MI 方法中, 状态 x_k 为 k 时刻目标状态基于所有实际观测 $z_{1:k-1}$ 的一步预测值, 由于 CPCRLB 和 MI 均利用了当前实际获得的所有观测信息 $z_{1:k-1}$ 以及相同粒子滤波器生成的粒子逼近, 因此产生了类似的性能.




图3 目标位置坐标 $x_{2,k}$ 的RMSE、CPCRLB和PCRLB




图4 CPCRLB、MI和NN方法对目标位置坐标 $x_{1,k}$ 估计的RMSE




图5 CPCRLB、MI和NN方法对目标位置坐标 $x_{2,k}$ 估计的RMSE

在计算复杂性方面, 文献 [9, 11] 表明, 互信息函数的计算需要 $S \times L^N + N \times L \times S$ 次求和运算, 而由式 (12) 可以看到本文的 CPCRLB 方法中 FIM 需要 $N \times L \times S$ 次求和运算, 因此, CPCRLB 方法在在计算复杂性上更具有优越性, MI 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. 在 MATLAB R2010a, 2.1GHz CPU 平台下通过 100 次仿真运行求平均, 表 1 给出了两种算法传感器选择函数的平均计算时间.


表 1 互信息和 CPCRLB 算法的平均 CPU 时间(s)

	CPCRLB	MI
$N=1$	0.27	0.18
$N=2$	0.61	10.01
$N=3$	0.80	372.65
$N=4$	1.20	15546.00

最后,我们以目标位置估计的 RMSE 对时间的平均值:

$$\sqrt{\frac{1}{M_c K} \sum_{m=1}^{M_c} \sum_{k=1}^K (\hat{x}_{1,k}(m) - x_{1,k})^2 + (\hat{x}_{2,k}(m) - x_{2,k})^2}$$

作为性能指标,其中: $\hat{x}_{1,k}(m)$ 和 $\hat{x}_{2,k}(m)$ 分别是第 m 次 Monte Carlo 仿真中 k 时刻目标位置估计值, M_c 是仿真次数, K 是终止时刻.图 6 给出了目标位置估计的平均 RMSE 性能指标与选择激活的传感器个数(N)以及量化位率(M)之间的关系.从图中可以看出,随着量化位率和激活的传感器个数的增加,目标位置估计的平均 RMSE 在减小,目标跟踪性能在改善.

图 6 平均 RMSE 与激活的传感器个数 N 以及量化位率 M 的关系

5 结论

CPCRLB 给出了目标状态估计的一步预测均方误差下界,本文对传感器网络下的目标跟踪问题,基于 CPCRLB 和传感器量化观测数据提出一种传感器选择算法.本文推导了量化观测数据下目标跟踪均方误差的 CPCRLB,并且基于粒子滤波器给出了一种 CPCRLB 的逼近计算方法.对资源受限的 WSN,通过观测数据的量化和传感器选择,激活最优传感器节点参与跟踪任务,节约了网络能量和通讯带宽,实现了网络资源的有效管理.后续的研究工作包括将本文的方法推广到面向多目标跟踪的传感器选择和无线传感器网络的分布式选择方法.

参考文献

- [1] A Sayeed, D Estrin, G Pottie, K Ramchandran. Special issue on self-organizing distributed collaborative sensor networks [J]. IEEE Journal of Selected Areas on Communication, 2005, 23(4): 689 - 872.
- [2] 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. (in

Chinese)

- [3] F Zhao, J Liu, L Guibas, J Reich. Collaborative signal and information processing: an information-directed approach [J]. Proceedings of the IEEE, 2003, 91(8): 1199 - 1209.
- [4] G M Hoffmann, C J Tomlin. Mobile sensor network control using mutual information methods and particle filters [J]. IEEE Transactions on Automatic Control, 2010, 55(1): 32 - 47.
- [5] 刘先省,周林,杜晓玉.基于 RIMMKF 的一种传感器管理算法 [J].电子学报, 2007, 35(12): 2247 - 2251.
Liu Xianxing, Zhou Lin, Du Xiaoyu. An algorithm of sensor management based on RIMMKF [J]. Acta Electronica Sinica, 2007, 35(12): 2247 - 2251. (in Chinese)
- [6] 刘先省,周林,杜晓玉.基于目标权重和信息增量的传感器管理方法 [J].电子学报, 2005, 33(9): 1683 - 1687.
Liu Xianxing, Zhou Lin, Du Xiaoyu. A method of sensor management based on target priority and information gain [J]. Acta Electronica Sinica, 2005, 33(9): 1683 - 1687. (in Chinese)
- [7] K Punithakumar, T Kirubarajan, M L Hernandez. Multisensor deployment using PCRLBs, incorporating sensor deployment and motion uncertainties [J]. IEEE Transactions on Aerospace and Electronic Systems, 2006, 42(4): 1474 - 1485.
- [8] L Zuo, R Niu, P K Varshney. Conditional posterior Cramer-Rao lower bounds for nonlinear sequential Bayesian estimation [J]. IEEE Transactions on Signal Processing, 2011, 59(1): 1 - 14.
- [9] 杨小军,马祥,宋青松,邢科义.基于条件后验克拉美-罗下界的目标跟踪传感器管理 [J].控制理论与应用, 2013, 30(5): 543 - 548.
Yang Xiaojun, Ma Xiang, Song Qingsong, Xing Keyi. Sensor management for target tracking based on conditional PCRLB [J]. Control Theory & Applications, 2013, 30(5): 543 - 548. (in Chinese)
- [10] R Niu, P K Varshney. Target location estimation in sensor networks with quantized data [J]. IEEE Transactions on Signal Processing, 2006, 54(12): 4519 - 4528.
- [11] E Masazade, R Niu, P K Varshney. Energy aware iterative source localization for wireless sensor networks [J]. IEEE Transactions on Signal Processing, 2010, 58(9): 4824 - 4835.
- [12] Y Zheng, O Ozdemir, R Niu, P K Varshney. New conditional posterior Cramer-Rao lower bounds for nonlinear sequential Bayesian estimation [J]. IEEE Transactions on Signal Processing, 2012, 60(10): 5549 - 5556.

作者简介

杨小军 男, 1971 年 6 月出生, 陕西扶风人. 博士, 副教授. 1995 年、2002 年和 2006 年分别在四川大学、西安电子科技大学和西北工业大学获学士、硕士和博士学位. 主要从事自适应控制, 统计信号处理, 估计理论, 多目标跟踪, 目标检测与识别, 传感器管理, 无线传感器网络和多源信息融合等方面的研究工作.

E-mail: xjyang@chd.edu.cn