

无线传感器网络中基于多比特量化的极大似然分布式估计方法

郭黎利, 高 飞, 孙志国

(哈尔滨工程大学信息与通信工程学院, 黑龙江哈尔滨 150001)

摘 要: 在无线传感器网络背景下的分布式估计中, 由于传输网络对发送功率和传输带宽的限制, 压缩信源冗余、降低通信数据量便成为一个重要的课题. 为此, 本文提出了一种基于多比特量化观测的分布式估计方法(MQS), 利用渐进性能作为优化准则构造量化阈值优化问题, 运用粒子群算法对其进行求解得到最优量化阈值, 给出了克拉美罗下界的解析表达式, 并与均匀量化方法(UQS)和未量化方法(NQS)进行对比. 理论分析和仿真实验表明, MQS的性能优于UQS. 当量化深度增大到3时, MQS的估计性能十分接近NQS的估计性能.

关键词: 无线传感器网络; 多比特量化; 分布式估计; 粒子群算法

中图分类号: TN911.23

文献标识码: A

文章编号: 0372-2112 (2016)11-2773-07

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2016.11.029

Multi-level Quantization Scheme for Distributed Maximum Likelihood Estimation in Wireless Sensor Networks

GUO Li-li, GAO Fei, SUN Zhi-guo

(College of Information and Communication Engineering, Harbin Engineering University, Harbin, Heilongjiang 150001, China)

Abstract: In the context of distributed estimation in wireless sensor networks (WSN), due to transmission power/bandwidth constrains, it is significant to reduce size of transmitted data. In this paper, a distributed estimation scheme, namely, multi-level quantization scheme (MQS) is proposed. The quantization threshold optimization problem is formulated by using asymptotic performance as an optimality criterion. The optimum quantization thresholds are obtained by resorting to particle swarm optimization algorithm. The explicit expression of the Cramér-Rao lower bound is derived. The proposed method is compared with uniform quantization scheme (UQS) and no quantization scheme (NQS). Theoretical analysis and simulation results demonstrate that the MQS scheme outperforms the UQS. Moreover, with 3-bit quantization, the MQS can provide estimation performance very close to that of the NQS.

Key words: wireless sensor networks; multi-level quantization; distributed estimation; particle swarm optimization algorithm

1 引言

与集中式融合估计相比, 分布式融合估计在降低传输带宽、提高系统可靠性等方面具有明显优势, 近年来越来越受到关注, 得到了广泛深入的研究^[1~3]. 无线传感器网络(Wireless Sensor Networks, WSN)存在固有的功率/带宽限制, 针对这个问题, Ribeiro提出了基于最大似然的分布式一比特量化估计方法^[4]. 每个传感器节点对本地原始观测数据进行量化或者压缩, 避免

了在网络中传输过多的信息. Song设计了一比特量化的最大似然估计器^[5], 使融合中心(Fusion Center, FC)输出接近最佳线性无偏估计器的均方误差下界. 上述方法的量化阈值依赖未知参数的先验信息, 但实际中往往很难获取. Fang提出了一比特自适应分布式估计方法^[6], 结果表明在未知参数先验信息无法获取的情况下, 系统性能可渐进地达到最优. 上述局部一比特量化是对本地观测信息最大限度的压缩, 系统性能损失显然很大. 针对这个问题, 增加局部传感器节点的量

化位数成为提高融合系统性能的有效途径之一. 关小杰等提出了一种基于量化观测的粒子滤波状态估计算法^[7], 有效地提高了系统跟踪精度. Cabral Farias 研究了基于量化观测的标量信号估计^[8], 提出了费舍尔信息渐进逼近法, 得到了较好的系统性能, 但没有考虑传感器节点与 FC 之间的差错信道对系统性能的影响. Aziz 提出了一种易于实现的多比特量化方法^[9], 有效地提高了系统性能. 但文中假设传感器节点处为均匀量化 (Uniform Quantization Scheme, UQS), 并不是局部最优量化方法. 文献[10]在研究 WSN 的目标跟踪问题中考虑量化的局部传感器观测数据, 提出了一种传感器选择算法, 有效地节约了网络能量和传输带宽. 但文中并未考虑量化阈值的选取问题.

为了解决一比特量化所导致信息损失较大的问题, 本文在文献[9]和[10]的多比特量化器结构的基础上, 将文献[11]和[12]中系统渐进性能的思想引入量化阈值优化的过程中, 提出了一种基于多比特量化 (Multi-level Quantization Scheme, MQS) 的最大似然估计方法. 本文的创新之处在于考虑了多比特量化阈值的最优化, 推导了基于多比特量化数据下目标估计均方误差的性能下界. 由于对传感器节点观测数据进行多比特量化, 带来了非线性优化问题, 本文利用粒子群算法对其进行求解, 得到最优量化阈值. 最后通过仿真验证了本文方法的有效性.

2 问题描述及分布式估计模型

2.1 分布式估计模型

考虑一个有 FC 的分布式估计并行结构, N 个传感器节点观测并估计所监测区域的未知确定性参数 $\theta \in \mathbf{R}$. 每个传感器节点的观测模型表示为

$$x_n = h_n \theta + w_n, n \in N \quad (1)$$

上式中 $n \in N \triangleq \{1, 2, \dots, N\}$, x_n 表示第 n 个传感器节点的原始观测值, $h_n \in \mathbf{R}$ 表示已知的观测系数, 描述第 n 个传感器节点的输入与输出关系, w_n 表示观测噪声, 服从均值为 0 方差为 $\sigma_{w_n}^2$ 的高斯分布. 假设各个传感器节点之间相互独立, 第 n 个传感器节点处的 q 比特量化器表示为 $Q_{n,q} (q \in \mathbf{Z}^+)$, 量化后的数据传送到 FC, FC 根据接收到的量化数据对目标的状态做出实时估计.

2.2 量化模型

考虑到实际 WSN 中存在发射功率和传输带宽的限制, 每个传感器节点需将各自观测到的原始信息通过一个 q 比特量化器对观测空间进行划分, 如图 1 所示. 假设量化深度为 q 位, $q \in \mathbf{Z}^+$. 第 n 个传感器节点处的 q




图1 传感器观测空间划分

比特量化器 $Q_{n,q}$ 有 $2^q + 1$ 个量化阈值 $\tau_{n,k}, k = 0, 1, \dots, 2^q$, 其中 $\{\tau_{n,k}\}_{k=0}^{2^q}$ 为量化阈值集, 且 $\tau_{n,0} = -\infty, \tau_{n,2^q} = +\infty$. 不同传感器节点处的量化阈值集并未约束成相同的集合. 在固定的 n 和 q 下, 实数集 \mathbf{R} 被量化阈值集 $\{\tau_{n,k}\}_{k=0}^{2^q}$ 中的元素划分为 2^q 个互不重叠的量化区间, 每一个量化区间由量化电平集合 $\Gamma = \{\gamma_i\}_{i=1}^{2^q}$ 中的元素唯一表示. 第 i 个量化电平被编码为 q 比特的二进制码字 $\mathbf{b}_{n,i} = [b_{n,i,q}, b_{n,i,q-1}, \dots, b_{n,i,1}]^T$, 其中 $b_{n,i,q} \in \{0, 1\}$.

第 n 个传感器节点处的 q 比特量化器输出数据 \mathbf{d}_n 可以表示为

$$\mathbf{d}_n = Q_{n,q}(x_n) = \mathbf{b}_{n,i}, \tau_{n,i-1} \leq x_n < \tau_{n,i} \quad (2)$$

原始观测信息 x_n 落入量化器 $Q_{n,q}$ 中第 j ($1 \leq j \leq 2^q$) 个量化区间 $(\tau_{n,j-1}, \tau_{n,j}]$ 内的概率表示为

$$\begin{aligned} P_{w_n}^{n,j}(\theta) &= P(\mathbf{d}_n = \mathbf{b}_{n,j}; \theta) \\ &= P(\tau_{n,j-1} \leq x_n < \tau_{n,j}; \theta) \\ &= F_{w_n}(\tau_{n,j-1} - h_n \theta) - F_{w_n}(\tau_{n,j} - h_n \theta) \end{aligned} \quad (3)$$

上式中 $F_{w_n}(\cdot)$ 表示高斯噪声 w_n 的互补累积分布函数 (Complementary Cumulative Distribution Function, CCDF). 量化后的 q 比特信息 $\{\mathbf{d}_n\}_{n=1}^N$ 通过信道发送至 FC.

2.3 差错信道模型

假设各传感器节点与 FC 之间的差错信道相互独立, 则每一个信道模型可建模为一个基于二元对称信道 (Binary Symmetric Channel, BSC) 的多元差错信道, 错误转移概率记为 \bar{P} , $1 - \bar{P}$ 为正确接收 0 或 1 的概率. 根据 BSC 概率转移的特点, 当差错信道输入为 $\mathbf{d}_n = \mathbf{b}_{n,j}$ 时, FC 处的接收信号 \mathbf{y}_n 可能是二进制码字集中的任意一个. 因此, q 比特信息 $\mathbf{b}_{n,j}$ 通过差错信道突变为 $\mathbf{b}_{n,i}$ 的条件概率表示为

$$\begin{aligned} P(\mathbf{y}_n = \mathbf{b}_{n,i} | \mathbf{d}_n = \mathbf{b}_{n,j}) &= \bar{P}^{D_{n,i,j}} (1 - \bar{P})^{(q - D_{n,i,j})} \\ &= G(q, \bar{P}, D_{n,i,j}) \end{aligned} \quad (4)$$

上式中 $D_{n,i,j}$ 表示 q 比特信息 $\mathbf{b}_{n,j}$ 和 $\mathbf{b}_{n,i}$ 之间的汉明距离, 其定义为

$$D_{n,i,j} \triangleq D(\mathbf{b}_{n,i}, \mathbf{b}_{n,j}) = q - \sum_{k=0}^{q-1} I(b_{n,i,q-k}, b_{n,j,q-k}) \quad (5)$$

上式中 $I(\cdot)$ 表示指示函数, 当 $A = B$ 时, $I(A, B) = 1$, 否则 $I(A, B) = 0$. 汉明距离 $D_{n,i,j}$ 这里表示传输码字 $\mathbf{b}_{n,i}$ 与接收码字 $\mathbf{b}_{n,j}$ 之间的错误接收比特数. 在备选假设 H_1 下, 通过差错信道后到达 FC 处的接收信息 \mathbf{y}_n 的概率质量函数 (Probability Mass Function, PMF) 为

$$\begin{aligned} P(\mathbf{y}_n; \theta) &= \sum_{i=1}^{2^q} \sum_{j=1}^{2^q} P(\mathbf{y}_n = \mathbf{b}_{n,i} | \mathbf{d}_n = \mathbf{b}_{n,j}) P(\mathbf{d}_n = \mathbf{b}_{n,j}) \\ &= \prod_{i=1}^{2^q} \left\{ \sum_{j=1}^{2^q} G(q, \bar{P}, D_{n,i,j}) P_{w_n}^{n,j}(\theta) \right\}^{I(\mathbf{y}_n, \mathbf{b}_{n,i})} \end{aligned} \quad (6)$$

上式中 $P_{w_n}^{n,j}(\theta)$ 已在式(3)中推导.

2.4 融合准则

广义似然比检验 (Generalized Likelihood Ratio Test,

GLRT)利用未知参数的最大似然估计(Maximum Likelihood Estimation, MLE)来代替未知参数,其中最大似然估计器对于未知参数估计的准确程度将直接影响到 GLRT 的性能.因此,本文采用 GLRT 作为 FC 处的融合准则,研究多比特量化观测对最大似然估计性能的影响.未知参数 θ 的 MLE 可以表示为

$$\hat{\theta} = \underset{\theta}{\operatorname{argmax}} L_q(\theta) \quad (7)$$

上式中 $\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N]$ 表示 FC 的输入矩阵, $L_q(\theta)$ 表示 $P(\mathbf{Y}; \theta, H_1)$ 的自然对数.由于各传感器观测的量化值 $\{d_n\}$ 相互独立,则在备选假 H_1 下, \mathbf{Y} 的 PMF 可以表示为

$$P(\mathbf{Y}; \theta, H_1) = \prod_{n=1}^N P(\mathbf{y}_n; \theta) = \prod_{n=1}^N \prod_{i=1}^{2^q} \left\{ \sum_{j=1}^{2^q} G(q, \bar{P}, D_{n,i,j}) P_{w_n}^{n,j}(\theta) \right\}^{I(\mathbf{y}_n, b_{n,i})} \quad (8)$$

在大多数问题中, θ 的 MLE 很难得到一个闭合表达式.然而,当 w_n 为高斯噪声时,不难看出 $P(\mathbf{Y}; \theta, H_1)$ 是一个凸函数.

定理 1 最大似然估计问题(式(7)和式(8))是一个关于参数 θ 的凸优化问题.

证明 因为当观测噪声服从高斯分布时,噪声的概率密度函数 $p_{w_n}(\cdot)$ 和互补累积分布函数 $F_{w_n}(\cdot)$ 都是对数性凸函数^[13].根据 2.2 节中的假设,观测空间为一个实数集 \mathbf{R} ,被量化阈值集 $\{\tau_{n,k}\}_{k=0}^{2^q}$ 中的元素划分为 2^q 个互不重叠的量化区间,即 $\mathbf{R} = \mathbf{R}_{n,1} \cup \dots \cup \mathbf{R}_{n,j} \cup \dots \cup \mathbf{R}_{n,2^q} = (-\infty, \tau_{n,1}] \cup \dots \cup \dots \cup (\tau_{n,j-1}, \tau_{n,j}] \cup \dots \cup (\tau_{n,2^q-1}, +\infty)$, 且这些集合均为凸集;又 $P(\mathbf{Y}; \theta, H_1)$ 是凸函数 $P_{w_n}^{n,j}(\theta)$ ($1 \leq j \leq 2^q$) 这些凸集上的线性组合,因此 $P(\mathbf{Y}; \theta, H_1)$ 与其自然对数 $L_q(\theta)$ 均为对数性凸函数.

由定理 1 可知,求解 θ 的 MLE 是一个可以解决的数值分析问题.随机地设置一个初始估计值,通过数值搜索的方法求得全局最大值.从式(7)和式(8)中可以看出,整个系统的估计性能与量化阈值 $\tau_{n,k}$ ($n \in \mathbf{N}, k = 0, 1, \dots, 2^q$) 相关.因此,要使系统估计性能最优,需要求解最优的量化阈值.

3 量化阈值的优化准则

根据文献[14]知,在大数据记录或者渐进($N \rightarrow \infty$)的情况下,修正的 GLRT 检验 $2 \ln T_q(\mathbf{Y})$ 近似地服从

$$2 \ln T_q(\mathbf{Y}) \overset{a}{\sim} \begin{cases} \chi_1^2, & H_0 \\ \chi_1^2(\lambda_q), & H_1 \end{cases} \quad (9)$$

上式中 $T_q(\mathbf{Y})$ 表示 q 比特量化方法下的 GLRT 检验,“ a ”表示表示渐进分布, χ_1^2 表示自由度为 1 的中心化 chi 分布, $\chi_1^2(\lambda_q)$ 表示自由度为 1、非中心化参数为 λ_q 的非

中心化 chi 分布.非中心化参数 λ_q 表示为

$$\lambda_q = (\theta_1 - \theta_0)^T \mathcal{F}_q(\theta_0) (\theta_1 - \theta_0) \quad (10)$$

上式中 $\theta_0 = 0$ 和 $\theta_1 = \theta$ 分别表示假设 H_0 和 H_1 假设下的待估计信号, $\mathcal{F}_q(\cdot)$ 表示费舍尔信息(Fisher Information, FI),可以通过对 Y 的似然函数求二阶导数得到

$$\mathcal{F}_q(\theta) = \sum_{n=1}^N h_n^2 \sum_{i=1}^{2^q} \frac{\left\{ \sum_{j=1}^{2^q} G(q, \bar{P}, D_{n,i,j}) P_{w_n}^{n,j}(\theta) \right\}^2}{\sum_{j=1}^{2^q} G(q, \bar{P}, D_{n,i,j}) P_{w_n}^{n,j}(\theta)} \quad (11)$$

上式中

$$\rho_{w_n}^{n,j}(\theta) = p_{w_n}(\tau_{n,j-1} - h_n \theta) - p_{w_n}(\tau_{n,j} - h_n \theta) \quad (12)$$

$p_{w_n}(\cdot)$ 表示观测噪声 w_n 概率密度函数(Probability Density Function, PDF).从式(11)的表述形式可以看出, FI 呈现独立求和的形式.随着传感器节点感知的数据越来越多, FI 随之增大,表明 FC 得到关于 θ 的信息越来越多.根据文献[14]可知,对于足够多的数据记录,未知参数 θ 的 MLE 是无偏估计,可达到克拉美罗下界(Cramér-Rao Lower Bounds, CRLB),并且 θ 的 MLE 渐进服从 $\hat{\theta} \sim \mathcal{N}(\theta, \mathcal{F}_q^{-1}(\theta))$.由于各传感器观测值是独立同分布(i. i. d.),上式可变换为 $\sqrt{n}(\hat{\theta} - \theta) \sim \mathcal{N}(0, f_q^{-1}(\theta))$, 其中 $f_q(\theta)$ 表示 FC 接收到一个观测值时的 FI,即 $f_q(\theta) = \mathcal{F}_q(\theta)/N$. FI 表征了对未知参数 θ 估计的准确度, FI 越大, θ 的 MLE 方差越小,估计的准确度就越高.因此, θ 的 CRLB 为

$$\text{CRLB}_\theta = \frac{1}{\mathcal{F}_q(\theta)} \quad (13)$$

由式(10)和式(11)可知,非中心化参数 λ_q 是量化阈值 $\{\tau_n\}_{n=1}^N$ 的函数.根据式(9)性质可知,非中心化参数 λ_q 越大, GLRT 的性能越好,且 MLE 是无偏估计器,估计性能可渐进达到 CRLB.因此,最优的局部量化准则是一组能够使非中心化参数 λ_q 最大的量化阈值,可以通过对优化问题求解得到.为了便于数值计算,对噪声 w_n 进行归一化处理 $w_n \sim \mathcal{N}(0, \sigma_{w_n}^2)$ 变为 $\tilde{w}_n \sim \mathcal{N}(0, 1)$, 则上述的优化问题可以归纳为

$$\begin{aligned} & \arg \max_{\boldsymbol{\tau}} g(\boldsymbol{\tau}), \\ & \text{s. t. } \boldsymbol{\tau} = [\tau_1, \tau_2, \dots, \tau_{2^q-1}]^T, -\infty < \tau_1 < \tau_2 < \dots < \tau_{2^q-1} < +\infty \\ & g(\boldsymbol{\tau}) = \sum_{i=1}^{2^q} \frac{\left\{ \sum_{j=1}^{2^q} G(q, \bar{P}, D_{n,i,j}) \rho_{\tilde{w}_n}^{n,j}(\theta) \right\}^2}{\sum_{j=1}^{2^q} G(q, \bar{P}, D_{n,i,j}) P_{\tilde{w}_n}^{n,j}(\theta)} \end{aligned} \quad (14)$$

上式中

$$\rho_{\tilde{w}_n}^{n,j}(\theta) = p_{\tilde{w}_n} \left(\frac{\tau_{n,j-1} - h_n \theta}{\sigma_{\tilde{w}_n}} \right) - p_{\tilde{w}_n} \left(\frac{\tau_{n,j} - h_n \theta}{\sigma_{\tilde{w}_n}} \right) \quad (15)$$

$$P_{\tilde{w}_n}^{n,j}(\theta) = F_{\tilde{w}_n} \left(\frac{\tau_{n,j-1} - h_n \theta}{\sigma_{\tilde{w}_n}} \right) - F_{\tilde{w}_n} \left(\frac{\tau_{n,j} - h_n \theta}{\sigma_{\tilde{w}_n}} \right) \quad (16)$$

上式中 $p_{\tilde{w}_n}^{n,j}(\cdot)$ 和 $F_{\tilde{w}_n}^{n,j}(\cdot)$ 分别表示归一化噪声 \tilde{w}_n 的 PDF 和 CCDF.

4 最优量化阈值的求解

本节将求解式(14)中的优化问题,得到局部最优量化阈值. 传统的优化算法(如梯度搜索法等)在处理具有良好特性的代价函数时(凹凸性,单调性等),能够表现出较好的性能. 而式(14)中的代价函数呈现非线性、非凸性质,因此传统的优化方法不适用于式(14). 粒子群优化(Particle Swarm Optimization, PSO)算法^[15]具有实现简单,可调参数少,易于实现等优点,尤其在求解大量非线性、不可微和多峰值的复杂问题时有良好的性能.

优化算法所用到的参数: M 表示搜索粒子的个数, q 表示量化深度, $r_{i,1}^k$ 和 $r_{i,2}^k$ 表示第 k 次迭代中在区间 $[0, 1]$ 内均匀选取的随机数, K 表示压缩参数,其数学表达式为 $K = 2 / |2 - \varphi - \sqrt{\varphi^2 - 4\varphi}|$, $\varphi = c_1 + c_2$ 且 $\varphi > 4$. 常数 c_1 和 c_2 通常设定为 2.05^[15]. ν_{tol} 表示迭代终止时的最小速度,第 k 次迭代中粒子 i 的位置矢量表示为 $\tau_i^k = [\tau_{i,1}^k, \tau_{i,2}^k, \dots, \tau_{i,2^q-1}^k]$,第 k 次迭代中粒子 i 的速度矢量表示为 $\nu_i^k = [\nu_{i,1}^k, \nu_{i,2}^k, \dots, \nu_{i,2^q-1}^k]$, τ_{max} 表示搜索空间最大限制距离, pbest_i^k 表示第 k 次迭代中第 i 个粒子的最优位置, gbest^k 表示第 k 次迭代中的全局最优位置. 为了便于理解本文所运用的粒子群算法,下面给出搜索过程的简要说明:(1)对粒子群体的位置 τ_i^k 和速度 ν_i^k 进行随机初始化;(2)将每个粒子初始化的位置 τ_i^k 代入代价函数 $g(\tau)$ 计算适应度,然后将其作为该粒子所获得的局部最优解 pbest_i^k ,再将所有粒子中适应度最大的位置矢量作为初始全局最优解 gbest^k ;(3)利用公式更新粒子的位置和速度;(4)判断粒子在更新后是否满足式(14)中的约束条件并且是否还处在搜索区间内,如果不在,则进行调整使其重回搜索区间并满足约束条件;(5)计算并更新各粒子在新位置下的适应度,如果获得的新适应度比原来的 pbest_i^k 大,则令 $\text{pbest}_i^{k+1} = \tau_i^{k+1}$,否则 $\text{pbest}_i^{k+1} = \text{pbest}_i^k$;如果新的适应度比 gbest^k 大,则还需要更新全局最优解;(6)根据 PSO 算法的特点,当粒子群接近全局最优时,速度变化不断减小,因此设定最小值 ν_{tol} ,当速度变化达到 ν_{tol} 时,迭代终止,从而获得全局最优解. 算法 1 给出了 PSO 算法求解式(14)的流程:

算法 1 PSO 算法(求解式(14))

输入: $\tau_{\text{max}}, \nu_{\text{tol}}, c_1, c_2, K, M, \bar{P}, q, \text{iter}_{\text{max}}$

输出: 在差错概率 \bar{P} 下的最优量化阈值 τ^*

初始化: $k = 0$

(1) $m = -\tau_{\text{max}} \cdot E_{M \times (2^q-1)}, n = \tau_{\text{max}} \cdot E_{M \times (2^q-1)}$; $E_{M \times (2^q-1)}$ 表示

M 行 $(2^q - 1)$ 列的矩阵,其中所有元素均为 1

(2) $\tau^0 = m + (n - m) \cdot \Phi_{M \times (2^q-1)}$; $\Phi_{M \times (2^q-1)}$ 表示 M 行 $(2^q - 1)$ 列的矩阵,其中所有元素为 $[0, 1]$ 之间的随机数

(3) $\nu^0 = \frac{1}{2} \cdot (n - m) \cdot \Phi_{M \times (2^q-1)}$; $\Phi_{M \times (2^q-1)}$ 表示 M 行 $(2^q - 1)$ 列的矩阵,其中所有元素为 $[0, 1]$ 之间的随机数

(4) for $i = 1$ to M

(5) for $j = 1$ to $2^q - 1$

(6) if $\tau_{i,j-1}^k > \tau_{i,j}^k$, then

(7) $\tau_{i,j-1}^k = \tau_{i,j}^k - \varepsilon$; ε 为使各粒子的坐标之间满足式(14)的关系

(8) end if

(9) end

(10) for $i = 1$ to M

(11) for $j = 1$ to $2^q - 1$

(12) if $\tau_{i,j}^k > \tau_{\text{max}}$, $\tau_{i,j}^k = \tau_{\text{max}}$; $\tau_{i,j}^k < -\tau_{\text{max}}$, $\tau_{i,j}^k = -\tau_{\text{max}}$; $\tau_{i,j}^k$ 确保各粒子的坐标在搜索区间内

(13) else if $\tau_{i,j}^k < -\tau_{\text{max}}$, $\tau_{i,j}^k = -\tau_{\text{max}}$; $\tau_{i,j}^k$ 确保各粒子的坐标在搜索区间内

(14) else

(15) continue;

(16) end

(17) 计算 $g(\tau_i^k)$;

(18) end

(19) 令 $\text{pbest}_i^k = \tau_i^k$; τ_i^k 初始局部最优坐标

(20) $\text{gbest}^k = \arg \max_{\tau_i^k} \{g(\tau_1^k), g(\tau_2^k), \dots, g(\tau_M^k)\}$; τ_i^k 初始全局最优坐标

(21) for $k = 1$ to iter_{max} ; iter_{max} 确定循环的最大次数

(22) for $i = 1$ to M

(23) $\nu_i^{k+1} = K[\nu_i^k + c_1 r_{i,1}^k (\text{pbest}_i^k - \tau_i^k) + \nu_i^k + c_2 r_{i,2}^k (\text{gbest}^k - \tau_i^k)]$; ν_i^k 速度更新

(24) $\tau_i^{k+1} = \tau_i^k + \nu_i^{k+1}$; τ_i^k 坐标更新

(25) if $\|\nu_i^k\| \leq \nu_{\text{tol}}$, then $\tau^* = \text{gbest}^k$; break; τ^* 满足条件,输出结果并终止迭代

(26) else

(27) τ_i^k

(28) 第 5 步至第 8 步;

(29) 第 11 步至第 17 步;

(30) if $g(\tau_i^{k+1}) \leq g(\text{pbest}_i^k)$; τ_i^{k+1} 本次迭代局部最优坐标

(31) $\text{pbest}_i^{k+1} = \tau_i^{k+1}$;

(32) else

(33) $\text{pbest}_i^{k+1} = \text{pbest}_i^k$;

(34) $\text{gbest}^{k+1} = \arg \max_{\tau_i^{k+1}} \{g(\text{pbest}_1^{k+1}), \dots, g(\text{pbest}_M^{k+1})\}$; τ_i^{k+1} 本次迭代的全局最优坐标

(35) τ_i^k

(36) end

(37) end

图 2 给出了 PSO 和梯度搜索法的收敛性能对比实验结果. PSO 的参数设定: $M = 100, q = 2, \bar{P} = 0, \tau_{\text{max}} = 5$. 从图中可以看出, PSO 和梯度搜索法都能快速收敛. 但是梯度搜索法依赖随机初始点的位置,容易“陷入”局部最优解而无法搜索到全局最优. 相比之下, PSO 遵循个体和群体协调一致的机理,具有信息共享机制. 分别

通过个体和群体对适应度的比对来更新局部最优和全局最优,从而增强群体寻优能力,在不同的随机初始值下能始终收敛到全局最优解. PSO 收敛轨迹所表示的寻优过程和搜索结果直观地说明了 PSO 优化算法在求解式(14)的有效性.




图2 PSO与梯度搜索的收敛性对比实验

改变 \bar{P} 值,产生不同的优化问题. 运用 PSO 优化算法对其逐一求解后,得到二比特、三比特最优局部量化阈值如表 1 所示. 一比特局部最优量化阈值在文献[11]中已给出, $\tau_0^* = -\infty$, $\tau_1^* = 0$, $\tau_2^* = +\infty$. 从表 1 可以看出,每一组最优量化阈值都是关于中间阈值 $\tau = 0$ 中心对称. 产生这一现象的原因可以简要地解释为以下两点:第一,本文以零均值的高斯噪声为背景噪声,其 PDF 是中心对称的;第二,从 PDF 的形状来看,零均值高斯噪声的 PDF 是单峰的,峰值位置位于原点处. 然而,文献[16]指出,当背景噪声的 PDF 服从广义高斯分布时,局部一比特量化的最优量化阈值位置不在零点处. 因此,第二点解释并不能始终保证量化阈值关于 $\tau = 0$ 中心对称,那么产生这种现象的深层机理有待进一步的研究.

表 1 不同量化方法下的最优局部量化阈值

量化阈值	量化方法			
	2-bit($\bar{P}=0$)	2-bit($\bar{P}=0.2$)	3-bit($\bar{P}=0$)	3-bit($\bar{P}=0.2$)
τ_0^*	$-\infty$	$-\infty$	$-\infty$	$-\infty$
τ_1^*	-0.9816	-0.2384	-1.7479	-4.9999
τ_2^*	0	0	-1.0500	-4.9991
τ_3^*	0.9816	0.2384	-0.5005	-0.3152
τ_4^*	$+\infty$	$+\infty$	0	0
τ_5^*	—	—	0.5005	0.3152
τ_6^*	—	—	1.0500	4.9991
τ_7^*	—	—	1.7479	4.9999
τ_8^*	—	—	$+\infty$	$+\infty$

5 仿真实验以及结果分析

假设对所有 $n, h_n = 1, \sigma_w^2 = 1, \bar{P} = 0.2, M = 100, T_{\max}$

以及 $v_{\text{tol}} = 10^{-6}$. 为了对比本文提出的 MQS 与文献[9, 14]中算法的性能,从信息损失 (Information Loss, IL) 和估计性能上进行说明. 文献[17]定义了 IL 为提出方法 CRLB 与未量化方法 (No Quantization Scheme, NQS) CRLB 的比率,即

$$IL \triangleq 10 \log_{10} \frac{\text{CRLB}_{\text{Q-based}}(\sigma)}{\text{CRLB}_{\text{NQS}}(\sigma)} \quad (17)$$

上式中下标 Q-based 表示任意量化方法. 文献[14]中给出了 NQS,即在传感器节点处对数据不进行量化或者压缩处理. NQS 不损失任何有用信息,因此是一种渐进最优的估计方法,提供了估计差错性能的下界. 在 NQS 下, θ 的 CRLB 可以表示为 $\text{CRLB}_{\text{NQS}}(\theta) = \sigma^2/N$. 文献[10]假设在每个传感器节点处采用 UQS,即 q 比特 UQS 结构为对接收信号动态范围进行 2^q 等分. 图 3 所示的是在不同量化深度下, MQS 与 UQS 在信息损失角度上的对比. 从图 3 中可以看出, IL 与传感器个数相互独立,估计方法一旦确定,信息损失也随之确定. 在不同的量化深度 q 下,文中提出的 MQS 均比文献[9]中的 UQS 信息损失小. 将 $q = 1, 2, 3$ 时的最优门限代入式(17)可知, $q = 3$ 时的信息损失与 $q = 1$ 时相比降低 2dB,说明 MQS 可有效地解决一比特方法损失信息过多的问题. 在估计性能分析中,均方误差 (Mean Square Estimation, MSE) 是一个较为重要的衡量指标,定义为 $E\{(\theta - \hat{\theta})^2\}$.




图3 不同量化深度下MQS与UQS的信息损失

图 4 给出了 MQS 方法在量化深度 $q = 2$ 和 $q = 3$ 时,不同信道下 ($\bar{P} = 0, 0.1, 0.2$) 的 FI 仿真性能曲线. 从第 3 节的分析可知, FI 从信息积累的角度表征了对未知参数 θ 的估计性能. 从图中可以看出,传感器个数越多, FI 越大,这也直观地反映了 FI (式(11)) 具有可加性的特点. 在理想信道 ($\bar{P} = 0$) 和差错信道下, MQS 的估计性能随着错误转移概率 \bar{P} 的增大而恶化. 当量化深度 q 增加时, FI 随之增加,估计性能得到提升. 由此可见,本文提出的 MQS 方法适用于不同 \bar{P} 值下的信道.

图 5(a) 和图 5(b) 分别是理想信道和差错信道下,


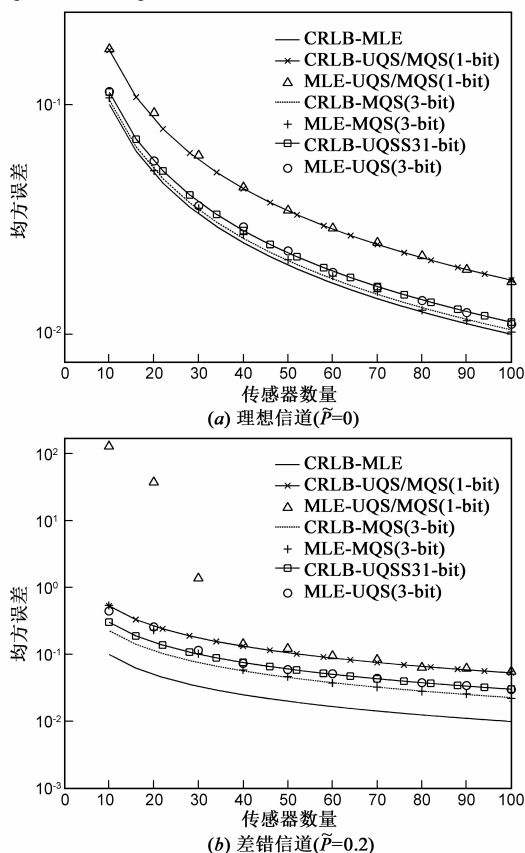


图4 不同信道下的性能对比

不同量化深度($q=1,3$)的估计性能对比. 图中 MLE 的 MSE 是通过 10^5 次独立的 Monte-Carlo 实验所获得. 从图中可以看出,随着传感器数量增大, MSE 减小,理论和仿真实验结果渐进一致. 在理想信道下($\bar{P}=0$),各量化方法的 MSE 可达到对应的 CRLB. 随着量化深度 q 增大,对 θ 的估计越准确. 当量化深度 $q=3$ 时,提出的 MQS 的 CRLB 与 NQS 的 CRLB 十分接近. 在差错信道下($\bar{P}=0.2$),随着传感器个数的增大, MSE 逐渐趋近于对应的 CRLB. 在理想信道和差错信道下,与文献[9]中的 UQS 相比, MQS 信息损失和均方误差更小,估计性能

图5 基于 q 比特量化/均匀量化方法的CRLB以及MSE

更优;与 NQS 相比, MQS 可渐进达到这个下界,因此估计量是渐进有效的. 文中提出的分布式估计方法在提高系统估计性能的同时也增加了本地传感器的计算复杂度. 但随着处理器集成度的增高和运算速度的加快,适当地提高本地传感器节点的复杂程度是可以实现的.

6 结论

本文以降低通信数据量,提高系统性能为目标,对 WSN 中受限分布式估计问题进行研究,提出了一种基于多比特量化的分布式估计方法—MQS. 利用渐进性能作为优化准则构建优化问题,运用粒子群算法求解得到最优量化阈值,推导了克拉美罗下界的解析表达式. 实验结果表明:首先,随着传感器个数的增加,所推导的闭合表达式其理论值与仿真值比较吻合;其次,本文方法以适当地增加本地传感器节点处的复杂度为代价,有效地减小通信传输所需的数据量和获得更好的估计性能. 从表 1 所示的最优量化阈值可知,在高斯噪声背景下, MQS 呈现与原点中心对称的特点,产生这种现象的深层机理以及在非高斯噪声下的估计方法有待进一步的研究.

参考文献

- [1] Li J, AlRegib G. Distributed estimation in energy-constrained wireless sensor networks[J]. IEEE Transaction on Signal Processing, 2009, 57(10): 3746–3758.
- [2] 乔向东, 李涛, 杨全, 等. 多传感器混合多模型估计的误差相关性及其融合算法研究[J]. 电子学报, 2010, 38(4): 804–810.
Qiao Xiang-dong, Li Tao, Yang Tong, et al. On error cross-correlation and fusion algorithm for multi-sensor hybrid multiple model estimation[J]. Acta Electronica Sinica, 2010, 38(4): 804–810. (in Chinese).
- [3] 李劲, 岳昆, 刘惟一. 基于融合的无线传感器网络 k -集覆盖的分布式算法[J]. 电子学报, 2013, 41(4): 659–665.
LI Jin, YUE Kun, LIU Wei-yi. Distributed set k -cover algorithms for fusion-based coverage in wireless sensor networks[J]. Acta Electronica Sinica, 2013, 41(4): 659–665. (in Chinese).
- [4] Riebeiro A, Giannakis G B. Bandwidth-constrained distributed estimation for wireless sensor networks-Part I: Gaussian case[J]. IEEE Transaction on Signal Processing, 2006, 54(3): 1131–1143.
- [5] Song E B, Zhu Y M, Zhou J, et al. Minimum variance in biased estimation with singular fisher information matrix[J]. IEEE Transactions on signal processing, 2009, 57(1): 376–381.
- [6] Fang J, Li H B. Adaptive distributed estimation of signal power from one-bit quantized data[J]. IEEE Transactions

- on Aerospace and Electronic System, 2010, 46(4): 1893 – 1905.
- [7] 关小杰, 陈军勇. 无线传感器网络中基于量化观测的粒子滤波状态估计[J]. 传感技术学报, 2009, 22(9): 1337 – 1341.
Guan Xiao-jie, Chen Jun-yong. Particle filter state estimation based on quantized observations in wireless sensor networks[J]. Journal of Sensors and Actuators, 2009, 22(9): 1337 – 1341. (in Chinese)
- [8] Cabral Farias R, Brossier J-M. Scalar quantization for estimation; from an asymptotic design to a practical solution [J]. IEEE Transactions on Signal Processing, 2014, 62(11): 2860 – 2870.
- [9] Aziz A M. A simple and efficient suboptimal multilevel quantization approach in geographically distributed sensor systems[J]. Signal Processing, 2008, 88(7): 1698 – 1714.
- [10] 杨小军. 基于性能边界和量化数据的 WSN 目标跟踪传感器选择算法[J]. 电子学报, 2014, 42(6): 1081 – 1085.
Yang Xiao-jun. Sensor selection for target tracking in wireless sensor networks based on performance bounds and quantized data[J]. Acta Electronica Sinica, 2014, 42(6): 1081 – 1085. (in Chinese)
- [11] Fang J, Liu Y M, Li H B, et al. One-bit quantizer design for multi-sensor GLRT fusion[J]. IEEE Signal Processing Letters, 2013, 20(3): 257 – 260.
- [12] 王平波, 蔡志明. 有色非高斯背景下微弱信号的 Rao 有效检验[J]. 电子学报, 2007, 35(3): 534 – 538.
Wang Ping-bo, Cai Zhi-ming. The Rao efficient scores test of weak signals in colored non-Gaussian background[J]. Acta Electronica Sinica, 2007, 35(3): 534 – 538. (in Chinese)
- [13] Boyd S, Vandenberghe. Convex Optimization[M]. Cambridge, U. K.: Cambridge Univ. Press, 2004.
- [14] Kay S M. Fundamentals of Statistical Signal Processing: Estimation Theory[M]. NJ: Prentice Hall, 1993.
- [15] Clerc M. Particle Swarm Optimization[M]. London, U. K.: Wiley-ISTE, 2006.
- [16] Farias R C, Moisan E, Brossier J M. Optimal asymmetric binary quantization for estimation under symmetrically distributed noise[J]. IEEE Signal Processing Letters, 2014, 21(5): 523 – 526.
- [17] Papadopoulos H C, Wornell G W, Oppenheim A V. Sequential signal encoding from noisy measurements using quantizers with dynamic bias control[J]. IEEE Transactions on Information Theory, 2001, 47(3): 978 – 1002.

作者简介



郭黎利 男, 1955 年 4 月生于黑龙江哈尔滨. 现为哈尔滨工程大学信息与通信工程学院教授. 从事现代通信系统理论与技术、通信信号处理技术方面的研究.



高 飞(通信作者) 男, 1983 年 12 月生于湖南长沙. 现为哈尔滨工程大学信息与通信工程学院博士研究生. 研究方向为分布式信号检测与估计、凸优化理论.
E-mail: gaofei85@hrbeu.edu.cn



孙志国 男, 1977 年 8 月生于黑龙江哈尔滨. 现为哈尔滨工程大学信息与通信工程学院副教授. 从事数字通信、宽带信号检测方面的研究.