



研究与开发

非理想信道下的传感器网络一比特最大似然算法

王娜娜, 刘兆霆, 姚英彪

(杭州电子科技大学通信工程学院, 浙江 杭州 310018)

摘要: 无线传感器网络通常由分布在一定空间范围内的无线传感器节点构成。一般情况下, 节点的能量存储、计算和通信能力都极为有限。直接传输各个节点的采样信号到融合中心将导致较多的能量消耗与较大的网络通信负载。若将每个传感器节点的采样信号值压缩为一比特测量值后再传输, 则可以在很大程度上降低能量消耗和减轻通信负载。研究了在乘性噪声环境下, 基于传感器网络一比特测量的参数估计问题。考虑节点和融合中心之间是存在干扰的非理想二值信道, 提出了基于最大似然的参数估计算法, 分析了参数估计的克拉美罗下界, 并通过一系列仿真实验, 验证了算法的有效性。

关键词: 传感器网络; 非理想信道; 参数估计; 一比特量化; 最大似然算法

中图分类号: TP393

文献标识码: A

doi: 10.11959/j.issn.1000-0801.2020041

One-bit maximum likelihood algorithm for sensor networks in non-ideal channels

WANG Nana, LIU Zhaoting, YAO Yingbiao

School of Communication Engineering, Hangzhou Dianzi University, Hangzhou 310018, China

Abstract: Wireless sensor networks typically consist of wireless sensor nodes that are distributed in a certain spatial range. In general, the energy storage, computing and communication capabilities of nodes are extremely limited. Direct transmission of the sampled signals of the various nodes to the fusion center will result in more energy consumption and greater network communication load. If the sampled signal value of each sensor node is compressed into a one-bit measurement value and then transmitted, the energy consumption and the communication load can be greatly reduced. The parameter estimation problem based on one-bit measurement of sensor networks in multiplicative noise environment was studied. Considering the non-ideal binary channel with interference between the node and the fusion center, a parameter estimation algorithm based on maximum likelihood was proposed, Cramér-Rao lower bound of the parameter estimation was analyzed, and the effectiveness of the algorithm was verified through a series of simulation experiments.

Key words: sensor network, non-ideal channel, parameter estimation, one-bit quantization, maximum likelihood algorithm

收稿日期: 2019-05-16; 修回日期: 2020-02-10

通信作者: 刘兆霆, liuzhaoting@163.com

基金项目: 国家自然科学基金资助项目 (No.61671192); 浙江省自然科学基金资助项目 (No.LY16F010012)

Foundation Items: The National Natural Science Foundation of China (No. 61671192), Zhejiang Provincial Natural Science Foundation of China (No. LY16F010012)



1 引言

近几年来,随着物联网的快速发展,无线传感器网络引起了广泛的关注^[1]。无线传感器网络由大量小型、低成本的传感器节点组成,具有综合的传感、处理和通信能力,在诸如环境和战场监测、目标定位和跟踪^[2]、结构健康管理^[3]等方面有着重要的应用。通常情况下,无线传感器网络与融合中心之间的通信带宽是有限的,且每个传感器节点由电池供电,其能量存储、感知信息和通信能力^[4-6]有限。若某一节点能量耗尽,意味着这个节点在网络中所起的功能消失,从而影响网络整体性能。在基于传感器网络的参数估计中,各个传感器获得的采样信号需要量化为一定长度的数据比特,然后发送给融合中心,融合中心根据这些数据并采用一定的算法获得参数估计。比特长度越大,信息损失越少,对参数估计越有利;然而,这也导致了网络的通信负载、节点能量消耗的增加。

传感器节点消耗能量的模块主要包括传感器模块、处理器模块和无线通信模块。随着集成电路工艺的进步,传感器模块和处理器模块的功耗变得很低,绝大部分能量消耗在无线通信模块上。无线通信模块存在发送、接收、空闲和睡眠 4 种状态,其中无线通信模块在发送状态时能量消耗最大^[7]。因此节点能量消耗可以用单位时间内发送的比特长度来衡量,而网络的通信负载也可以用其来衡量。单位时间内发送的比特长度越短,则节点能量消耗和网络通信负载越小。

为了降低节点能量消耗和减轻通信负载,国内外研究者已经提出了将每个传感器节点的采样信号压缩为一比特测量值后再传输给融合中心,并提出了一些基于一比特测量数据的参数估计算法。例如,参考文献[8-9]提出一种一比特压缩感知算法来估计矢量参数。参考文献[10]提出两个估计方案:两阶段估计和均值估计。两阶段估计首

先利用二进制传感器的量化数据估计其输出,然后估计源信号。均值估计通过对融合中心接收到的噪声数据取平均来进行参数估计。这两种估计方案可以有效降低最优极大似然估计器的复杂性。参考文献[11]提出自适应量化的观点,通过传感器自动调整阈值来估计未知的确定性参数。参考文献[12]提出一种基于期望最大和递归最小二乘的自适应参数估计算法,该算法具有较好的收敛性和稳健性。参考文献[13]着重通过最大似然估计来提高标量参数估计的性能。参考文献[14-15]在输入信号噪声已知的前提下,提出非参数化方法。

这些现有的参数估计算法虽然有各自的优点,但它们都依赖于某些假设,如测量环境不存在乘性噪声^[16-19]、无线传感器网络与融合中心之间的信道是理想二值信道等。然而,在许多实际情况下,乘性噪声是经常出现的,并且无线传感器网络和融合中心之间的信道往往存在二值信道干扰^[12,20],导致某些比特值出现反向。针对目前方法的缺点,本文研究了在乘性噪声环境下,基于传感器网络一比特测量的参数估计问题。考虑节点和融合中心之间是存在干扰的非理想二值信道,提出了基于最大似然估计(maximum likelihood estimation, MLE)的参数估计算法,分析了参数估计的克拉美罗下界(Cramér-Rao lower bound, CRLB),并通过一系列仿真实验,验证了算法的有效性。

2 传感器网络和信号参数估计模型

基于二值信道的传感器网络一比特量化观测的参数估计模型如图 1 所示,传感器网络模型由 N 个独立的传感器节点、 N 个与传感器节点对应的量化器、 N 个独立的二值信道以及一个融合中心组成。该传感器网络的目的是将每个传感器节点独立测量的采样信号值,发送到量化器进行量化处理,获得一比特量化数据,最后将一比特量




图 1 基于二值信道的传感器网络 1 比特量化观测的参数估计模型

化数据通过二值信道发送到融合中心，融合中心根据接收到的数据获得未知参数的估计值 $\tilde{\theta}_y$ 。

假设第 n 个传感器节点接收的采样信号值 x_n 可表示为：

$$x_n = h_n \theta + v_n, n=1, 2, 3, \dots, N \quad (1)$$

其中， θ 是待估计的未知参数， v_n 是均值为 0、方差为 σ_v^2 的高斯加性白噪声，且独立同分布。 h_n 表示均值为 1、方差为 σ_e^2 、独立同分布的高斯随机变量，且与 v_n 独立。因此，式 (1) 可以改写为 $x_n = (1 + e_n)\theta + v_n$ ，其中， e_n 是均值为 0、方差为 σ_e^2 的随机高斯分布乘性噪声。定义 $z_n = e_n \theta + v_n$ ，则有：

$$x_n = \theta + z_n \quad (2)$$

其中， z_n 作为等效噪声，可看作加性噪声和乘性噪声的总和。由于加性噪声 v_n 独立于 e_n ，因此 $z_n \sim N(0, \delta z^2)$ ，其中 $\sigma_z^2 = \sigma_e^2 \theta^2 + \sigma_v^2$ 。正如引言所述，为了降低节点能量消耗和减轻通信负载，本文考虑将每个传感器节点接收的采样信号值 x_n 与一个门限值 τ 进行比较，若接收信号大于该门限值，用 1 表示；反之，用 -1 表示。如式 (3) 所示：

$$y_n = \text{sign}(x_n - \tau) = \begin{cases} 1, & x_n > \tau \\ -1, & x_n \leq \tau \end{cases}, n=1, 2, 3, \dots, N \quad (3)$$

然后每个传感器节点将一比特量化值 $\{y_n\}_{n=1}^N$ 发送到融合中心，融合中心根据这些数据来估计未知参数 θ 。

假设融合中心接收到各个节点的一比特量化观测值为 $\{\tilde{y}_n\}_{n=1}^N$ 。在理想情况下， $\tilde{y}_n = y_n$ ， $n=1$,

$2, \dots, N$ 。然而，在许多实际情况下，传感器和融合中心之间的二值信道同样容易受到随机噪声的干扰，导致某些比特值可能出现反相。在这种情况下，融合中心接收一比特量化观测值可以表示为：

$$\tilde{y}_n = y_n \varepsilon_n = \begin{cases} y_n, & \varepsilon_n = 1 \\ -y_n, & \varepsilon_n = -1 \end{cases} \quad (4)$$

其中， $\varepsilon_n \in \{1, -1\}$ 表示二值干扰噪声，并且 $\varepsilon_n = -1$ （存在干扰）的概率假设为 μ ，即 $P(\varepsilon_n = -1) = \mu$ 。

3 基于 MLE 算法的量化估计

3.1 基于采样信号值 $\{x_n\}_{n=1}^N$ 的 MLE 算法

根据信号模型 (2)，未知参数 θ 关于 $\{x_n\}_{n=1}^N$ 的最大似然估计为：

$$\theta_{\text{ML}} = \arg \max_{\theta} \{\ln P(\mathbf{x}; \theta)\} = \arg \max_{\theta} \left\{ \ln \prod_{n=1}^N P(x_n; \theta) \right\} \quad (5)$$

$$\text{其中, } P(x_n; \theta) = \frac{1}{\sqrt{2\pi(\sigma_e^2 \theta^2 + \sigma_v^2)}} \exp \left\{ -\frac{(x_n - \theta)^2}{2(\sigma_e^2 \theta^2 + \sigma_v^2)} \right\},$$

表示 θ 关于采样信号值 $\{x_n\}_{n=1}^N$ 的概率密度函数。

$P(\mathbf{x}; \theta)$ 表示 θ 关于采样信号值 $\{x_n\}_{n=1}^N$ 的似然函数。对式 (5) 中对数似然函数求导并令其为零，得到式 (6)：

$$N\sigma_e^4 \theta^3 + \sigma_e^2 s \theta^2 + (N\sigma_v^2 - \sigma_e^2 t + N\sigma_e^2 \sigma_v^2) \theta - \sigma_v^2 s = 0 \quad (6)$$

其中， $s = \sum_{n=1}^N x_n$ ， $t = \sum_{n=1}^N x_n^2$ 。通过计算，可以获得

式 (6) 的 3 个根，其中满足式 (5) 的根即最大



似然估计值 θ_{ML} 。

3.2 基于一比特量化观测值 $\{y_n\}_{n=1}^N$ (理想二值信道) 的 MLE 算法

假设 $\theta \in (-\Delta, \Delta)$, 且 Δ 是已知的。从式 (3) 可以看出, $\{y_n\}_{n=1}^N$ 可以划分成集合 I_+ 和 I_- , 分别表示为 $I_+ = \{n | y_n = 1, n = 1, 2, 3, \dots, N\}$ 和 $I_- = \{n | y_n = -1, n = 1, 2, 3, \dots, N\}$ 。此时, 根据式 (2), 似然函数可以表示为:

$$P(y; \theta) = \prod_{n \in I_+} P(\theta + z_n - \tau > 0) \cdot \prod_{n \in I_-} P(\theta + z_n - \tau \leq 0) = \prod_{n=1}^N \Phi\left(y_n \frac{\theta - \tau}{\sigma_z}\right) \quad (7)$$

其中, $\Phi(u) = (1/\sqrt{2\pi}) \int_{-\infty}^u e^{-x^2/2} dx$, 表示标准高斯分布的累积分布函数, σ_z 为等效噪声 z_n 的标准差。因此, 相应的对数似然函数为:

$$l(y; \theta) = \ln \prod_{n=1}^N \Phi\left(y_n \frac{\theta - \tau}{\sigma_z}\right) \quad (8)$$

然后采用 MLE 算法获得参数估计, 即 $\hat{\theta}_{ML} = \arg \max_{\theta} l(y; \theta)$ 。

3.2.1 参数可识别性

本节推导并确定了模型 (3) 基于参数可识别性的阈值范围。参数可识别性是从分布策略中得来的。在数学领域中, 它表示映射 $\theta \rightarrow l(y; \theta)$, 即对于所有的 y 都是单射的。这表明, 当观测数据数量足够大^[21]时, 未知参数 θ 可以被准确地估计。

为了计算方便, 引入一个新的变量 $\omega(\theta, \tau)$, $\omega(\theta, \tau)$ 定义如下:

$$\omega(\theta, \tau) = (\theta - \tau) / \sqrt{\sigma_e^2 \theta^2 + \sigma_v^2} \quad (9)$$

此时式 (8) 可以简化为 $l(y; \theta) = \ln \prod_{n=1}^N \Phi(y_n \omega(\theta, \tau))$ 。由于函数 $\ln \Phi(\cdot)$ 是单调递增的函数, 因此, 为了满足未知参数 θ 的可识别性, 式 (10) 必须被满足:

$$\theta_1 \neq \theta_2 \Rightarrow \omega(\theta_1, \tau) \neq \omega(\theta_2, \tau) \quad (10)$$

考虑一般情况下未知参数估计的可识别性, 即假设乘性噪声和加性噪声的方差 σ_e^2 、 σ_v^2 都不为零。满足式 (10) 的一个充分条件是: 当 θ 位于 $(-\Delta, \Delta)$ 内时, $\omega(\theta, \tau)$ 是关于 θ 的严格单调函数。对式 (9) 求导并令其为 $\eta(\theta, \tau)$, 可以得到:

$$\eta(\theta, \tau) = \frac{\partial \omega(\theta, \tau)}{\partial \theta} = (\sigma_e^2 \theta \tau + \sigma_v^2) / (\sigma_e^2 \theta^2 + \sigma_v^2)^{\frac{3}{2}} \quad (11)$$

由于 $\theta \in (-\Delta, \Delta)$ 且 $\eta(0, \tau) > 0$, 当且仅当满足:

$$-\sigma_v^2 / (\Delta \sigma_e^2) \leq \tau \leq \sigma_v^2 / (\Delta \sigma_e^2) \quad (12)$$

时, $\omega(\theta, \tau)$ 是关于 θ 的单调递增函数。因此, 当阈值取值在式 (12) 范围内时, 参数估计问题是可识别的。

3.2.2 最大似然估计

本节采用间接法来获得 θ 的最大似然估计值, 即首先优化式 (9) 中的变量 $\omega(\theta, \tau)$, 然后获得 θ 的最大似然估计, 相当于式 (13) 的优化问题:

$$\hat{\theta}_{ML} = \arg \max_{\theta \in [-\Delta, \Delta]} \left\{ \ln \prod_{n=1}^N \Phi(y_n \omega(\theta, \tau)) \right\} \quad (13)$$

假设 $\{y_n\}_{n=1}^N$ 中有 k 个 1, $\omega(\theta, \tau)$ 的最大似然估计可以简化为:

$$\hat{\omega}_{\tau} = \arg \max_{\omega(\theta, \tau)} \{k \ln \Phi(\omega(\theta, \tau)) + (N - k) \ln \Phi(-\omega(\theta, \tau))\} \quad (14)$$

对式 (14) 中对数似然函数求关于 $\omega(\theta, \tau)$ 的一阶偏导数方程, 并令其偏导数方程为 0, 可以得到:

$$\hat{\omega}_{\tau} = \Phi^{-1}\left(\frac{k}{N}\right) \quad (15)$$

其中, $\Phi^{-1}(\cdot)$ 表示 $\Phi(\cdot)$ 的反函数, 考虑 $\theta \in (-\Delta, \Delta)$ 且 τ 满足式 (12), 则 $\omega(\theta, \tau)$ 需要满足式 (16):

$$\Omega_1 \triangleq \omega(-\Delta, \tau) \leq \omega(\theta, \tau) \leq \omega(\Delta, \tau) \triangleq \Omega_2 \quad (16)$$

结合式 (15) 和式 (16), $\omega(\theta, \tau)$ 的最大似然估计为 $\hat{\omega}_{ML} = I_{\Omega}(\hat{\omega}_{\tau})$, $I_{\Omega}(\hat{\omega}_{\tau})$ 表达式如下:

$$I_{\Omega}(\hat{\omega}_{\tau}) = \begin{cases} x, \Omega_1 \leq x \leq \Omega_2 \\ \Omega_1, x < \Omega_1 \\ \Omega_2, \text{其他} \end{cases} \quad (17)$$

根据式 (9) 和定义: $\xi^2 = 1 + \frac{\sigma_v^2}{\sigma_e^2 \tau^2} (1 - \hat{\omega}_{ML}^2 \sigma_e^2)$ ($\xi > 0$), 可以得到关于 θ 的 4 个解, 分别为 $\theta_1 = \frac{1 + \hat{\omega}_{ML} \sigma_e \xi}{1 - \hat{\omega}_{ML}^2 \sigma_e^2} \tau$ 、 $\theta_2 = \frac{1 - \hat{\omega}_{ML} \sigma_e \xi}{1 - \hat{\omega}_{ML}^2 \sigma_e^2} \tau$ 、 $\theta_3 = \frac{\sigma_v}{\sqrt{1 - \hat{\omega}_{ML}^2 \sigma_e^2}} \hat{\omega}_{ML}$ 、 $\theta_4 = \left(1 - \frac{\sigma_v^2}{\sigma_e^2 \tau^2}\right) \frac{\tau}{2}$ 。表 1 显示了最大似然估计 $\hat{\theta}_{ML}$ 与阈值 τ 的关系, 其中 $\times$ 表示 θ 在这种情况下无解。

表 1 最大似然估计 $\hat{\theta}_{ML}$ 与阈值 τ 的关系 ($\theta \in (-\Delta, \Delta)$)

τ	$\hat{\omega}_{ML}$			
	$(-\infty, -1/\sigma_e)$	$(\pm 1/\sigma_e)$	$(-1/\sigma_e, 1/\sigma_e)$	$(1/\sigma_e, \infty)$
$\tau < 0$	$\times$	θ_4	θ_2	θ_2
$\tau = 0$	$\times$	$\times$	θ_3	$\times$
$\tau > 0$	θ_1	θ_4	θ_1	$\times$

3.3 基于一比特量化观测值 $\{\tilde{y}_n\}_{n=1}^N$ (非理想二值信道) 的 MLE 算法

3.3.1 最大似然估计

在非理想二值信道的情况下, 融合中心所获得的一比特观测值为 $\{\tilde{y}_n\}_{n=1}^N$, 而不是传感器节点经量化后发送的实际比特 $\{y_n\}_{n=1}^N$ 。假设 $\theta \in (-\Delta, \Delta)$, 且 Δ 是已知的。将 $\{\tilde{y}_n\}_{n=1}^N$ 划分成集合 $\tilde{I}_+$ 和 $\tilde{I}_-$, 分别表示为 $\tilde{I}_+ = \{n | \tilde{y}_n = 1, n = 1, 2, 3, \dots, N\}$ 和 $\tilde{I}_- = \{n | \tilde{y}_n = -1, n = 1, 2, 3, \dots, N\}$ 。此时, 似然函数表示为:

$$P(\tilde{\mathbf{y}}; \theta) = \prod_{n \in \tilde{I}_+} P(\tilde{y}_n = 1; \theta) \prod_{n \in \tilde{I}_-} P(\tilde{y}_n = -1; \theta) \quad (18)$$

根据式 (4) 给出的 $\{\tilde{y}_n\}_{n=1}^N$ 与 $\{y_n\}_{n=1}^N$ 的关系, 可以获得:

$$\begin{aligned} P(\tilde{y}_n = 1; \theta) &= P(\tilde{y}_n = 1 | y_n = 1; \theta) P(y_n = 1; \theta) + \\ &P(\tilde{y}_n = 1 | y_n = -1; \theta) P(y_n = -1; \theta) \\ &= P(\varepsilon_n = 1; \theta) P(y_n = 1; \theta) + \\ &P(\varepsilon_n = -1; \theta) P(y_n = -1; \theta) \\ &= (1 - \mu) P(y_n = 1; \theta) + \mu P(y_n = -1; \theta) \\ &= (1 - \mu) P(y_n = 1; \theta) + \mu (1 - P(y_n = 1; \theta)) \\ &= \mu + (1 - 2\mu) P(y_n = 1; \theta) \end{aligned} \quad (19)$$

同理, 有 $P(\tilde{y}_n = -1; \theta) = \mu + (1 - 2\mu) P(y_n = -1; \theta)$, 且 $P(y_n; \theta) = \Phi\left(y_n \frac{\theta - \tau}{\sigma_e}\right) = \Phi(y_n \omega(\theta, \tau))$, 代入式 (18)

可以得到似然函数为 $P(\tilde{\mathbf{y}}; \theta) = \prod_{n=1}^N (\mu + (1 - 2\mu) \Phi(y_n \omega(\theta, \tau)))$, 相应的对数似然函数为:

$$l(\tilde{\mathbf{y}}; \theta) = \ln \prod_{n=1}^N (\mu + (1 - 2\mu) \Phi(y_n \omega(\theta, \tau))) \quad (20)$$

θ 的最大似然估计相当于下面的优化问题:

$$\tilde{\theta}_{ML} = \arg \max_{\theta \in [-\Delta, \Delta]} \left\{ \ln \prod_{n=1}^N (\mu + (1 - 2\mu) \Phi(y_n \omega(\theta, \tau))) \right\} \quad (21)$$

类似地, 通过先优化变量 $\omega(\theta, \tau)$, 得到 θ 的最大似然估计。假设 $\{\tilde{y}_n\}$ 中有 k 个 1, $\omega(\theta, \tau)$ 的最大似然估计可以简化为:

$$\begin{aligned} \tilde{\omega}_\tau &= \arg \max_{\omega(\theta, \tau)} \{k \ln(\mu + (1 - 2\mu) \Phi(\omega(\theta, \tau))) + \\ &(N - k) \ln(\mu + (1 - 2\mu) \Phi(-\omega(\theta, \tau)))\} \end{aligned} \quad (22)$$

对式 (22) 中对数似然函数求关于 $\omega(\theta, \tau)$ 的一阶偏导数方程, 并令其偏导数方程为 0, 可以得到:

$$\tilde{\omega}_\tau = \Phi^{-1} \left(\frac{k - \mu N}{(1 - 2\mu)N} \right) \quad (23)$$

类似地, $\omega(\theta, \tau)$ 、 $I_\Omega(\tilde{\omega}_\tau)$ 分别满足式 (16) 和式 (17)。最大似然估计值 $\tilde{\theta}_{ML}$ 与阈值 τ 的关系和第 3.2.2 节的算法推导是相同的, 具体见表 1。

3.3.2 克拉美罗下界

按照 CRLB 定义 $\text{CRLB}(\theta) = -\frac{1}{E[\nabla_\theta^2 \ell(\tilde{\mathbf{y}}; \theta)]}$ 对

式 (19) 求一阶及二阶偏导数, 得到:

$$\begin{aligned} \nabla_\theta \ell(\tilde{\mathbf{y}}; \theta) &= \sum_{n=1}^N \frac{(1 - 2\mu) \phi(\omega(\theta, \tau)) y_n \eta(\theta, \tau)}{\mu + (1 - 2\mu) \Phi(y_n \omega(\theta, \tau))} \\ \nabla_\theta^2 \ell(\tilde{\mathbf{y}}; \theta) &= -\sum_{n=1}^N \frac{(1 - 2\mu)^2 \phi^2(\omega(\theta, \tau)) \eta^2(\theta, \tau)}{[\mu + (1 - 2\mu) \Phi(y_n \omega(\theta, \tau))]^2} + \\ &\sum_{n=1}^N \frac{(1 - 2\mu) \nabla_\theta [\phi(\omega(\theta, \tau)) y_n \eta(\theta, \tau)] [\mu + (1 - 2\mu) \Phi(y_n \omega(\theta, \tau))]}{[\mu + (1 - 2\mu) \Phi(y_n \omega(\theta, \tau))]^2} \end{aligned} \quad (24)$$

因为 $E_y[\nabla_\theta \ell(\tilde{\mathbf{y}}; \theta)] = 0$ [8], 所以 $E_y[\nabla_\theta^2 \ell(\tilde{\mathbf{y}}; \theta)] = -E_y \left\{ \sum_{n=1}^N \frac{(1 - 2\mu)^2 \phi^2(\omega(\theta, \tau)) \eta^2(\theta, \tau)}{[\mu + (1 - 2\mu) \Phi(y_n \omega(\theta, \tau))]^2} \right\}$ 。因此 CRLB



可以表示为:

$$\text{CRLB} = \frac{1}{Nq(\theta, \tau)\eta^2(\theta, \tau)} \quad (25)$$

其中,

$$q(\theta, \tau) = \frac{(1-2\mu)^2 \phi^2(\alpha(\theta, \tau))}{[\mu + (1-2\mu)\Phi(\alpha(\theta, \tau))][\mu + (1-2\mu)\Phi(-\alpha(\theta, \tau))]},$$

$\phi(\cdot)$ 为标准正态分布的概率密度函数。

3.3.3 算法复杂度分析

本节以实数乘法次数和加法次数来衡量上述 3 种算法的复杂度。对于基于采样信号值 $\{x_n\}_{n=1}^N$ 的 MLE 算法, 该算法复杂度主要在于式 (5) 的求解, 其只需要 N 次实数乘法; 对于基于一比特量化观测值 $\{y_n\}_{n=1}^N$ (理想二值信道) 的 MLE 算法, 该算法复杂度主要在于式 (13) 的求解, 其只需要 N 次实数乘法; 本文提出的基于一比特量化观测值 $\{\tilde{y}_n\}_{n=1}^N$ (非理想二值信道) 的 MLE 算法复杂度主要在于式 (20) 的求解, 其需要 N 次实数乘法和 N 次实数加法。因此, 本文提出的算法计算复杂度和前两种算法接近。

4 性能仿真分析

为了验证 MLE 算法的估计性能, 本节考虑一个由 N 个节点和 1 个融合中心构成的传感器网络, 给出一系列 MATLAB 仿真实验结果。由于本文提出的算法是基于集中式处理的, 与网络的拓扑结构没有直接关系, 因此无需考虑传感器网络节点的分布问题。仿真实验参数设置为: 未知参数的真实值 $\theta=1$, $\Delta=3$, 乘性噪声方差 $\sigma_e^2=0.5$, 加性噪声方差 $\sigma_v^2=0.5$, 量化阈值 $\tau=1.5$ 。估计的性能指标采用均方误差 (mean square error, MSE), 定义为 $\text{MSE} \triangleq E[(\tilde{\theta} - \theta)^2]$ 。以下所有的仿真结果均通过 1 000 次试验平均得到。

图 2 分别对比了两种情况下 MLE 的均方误差和相对应的 CRLB。这两种情况分别是 $\mu=0$ 、 $\mu=0.1$ 与 $\mu=1$ 、 $\mu=0.9$ 。从图 2 可以得到结论, MLE 的均方误差和 CRLB 取决于传感器数量 N 和

干扰概率 μ 。两者都随着传感器数量 N 的增大而减小。当 N 足够大时, MLE 的均方误差将无限接近 CRLB。另外, 对于干扰概率 $\mu=0$ 与 $\mu=1$, 或者 $\mu=0.1$ 与 $\mu=0.9$, CRLB 几乎是相同的。从统计意义上讲, MLE 的均方误差也有相同的对称特性。图 3 显示了采样信号值直接估计和 $\mu=0.1$ 时 MLE 的均方误差和 CRLB。可以看出, θ_{ML} 的均方误差很快接近它对应的 $\text{CRLB}(\theta_{\text{ML}})$ 。当 $N>110$ 时, $\tilde{\theta}_{\text{ML}}$ 的均方误差与 $\text{CRLB}(\tilde{\theta}_{\text{ML}})$ 几乎相同。





图 2 MLE 的均方误差和相对应的 CRLB 的对比

图 4 给出了在 $\mu=0$ 、0.1、0.2、0.3、0.4 的情况下, MLE 的均方误差随传感器数量 N 的变化情况。从图 4 中可以看出, 随着传感器数量 N 逐渐增大, 在不同干扰概率的情况下, MLE 的均方误差迅速减小。




图3 θ_{ML} 与 $\bar{\theta}_{ML}$ ($\mu=0.1$) 的均方误差与相对应的 CRLB 的对比




图4 不同干扰概率 μ 的情况下, MLE 的均方误差随传感器数量 N 的变化情况

图5给出了4种不同干扰概率 μ 下 CRLB 随阈值 τ 的变化情况。从图5中可以观察到, 当阈值 τ 固定时, 随着干扰概率 μ 的增加, CRLB 不断增大; 当干扰概率 μ 一定时, 随着阈值 τ 由0.5增加到2.5, CRLB 先不断减小后不断增加, 这表明存在一个最优阈值, 使得 CRLB 达到最小值。另外, 随着干扰概率 μ 的不断增大, 最优阈值逐渐减小。

图6给出了当干扰概率 μ 由0增加到1的过程中, CRLB 与信道容量的仿真性能曲线。从第3.3.2节的分析可知, CRLB 是 $\Phi(\omega(\theta, \tau))$ 和干扰概率 μ 的函数。对于给定的 $\Phi(\omega(\theta, \tau))$, 当干扰概率 μ 在0.4和0.6之间变化时, CRLB 会发生显著变化。图6也表明, 当信道容量达到最小值时,




图5 不同干扰概率 μ 下 CRLB 随阈值 τ 的变化情况 ($N=100$)




图6 CRLB 和信道容量与干扰概率的关系 ($N=100$)

CRLB 达到最大值。这也直观地反映了 CRLB 随信道容量减小而增大的特性。此外, 在干扰概率 μ 为1或者0的情况下, 当信道容量接近1 bit 时, CRLB 达到其最小值。当 $\mu=0$ 时, 信道为理想信道, 相对应的 CRLB 满足参考文献[22]中的结果; 当 $\mu=1$ 时, 信道也可看作理想信道, 相对应的 CRLB 同样满足参考文献[22]中的结果。

5 结束语

本文研究了在乘性噪声环境下, 基于传感器网络一比特测量的参数估计问题。考虑节点和融合中心之间是存在干扰的非理想二值信道, 提出了基于最大似然的参数估计算法, 并且推导了参数估计的克拉美罗下界 (CRLB)。仿真实验表明, 虽然只采用一比特量化值进行估计, 本文提出的最大似然估计算法仍具有良好的收敛性和较小的




估计误差。另外, 本文是基于噪声方差已知所做的仿真和研究, 对于噪声方差未知的情况有待进一步研究。

参考文献:

- [1] LIN W, MATSUMOTO T. Performance analysis of distortion-acceptable cooperative communications in wireless sensor networks for internet of things[J]. IEEE Sensors Journal, 2019, 19(5): 1979-1989.
- [2] FANG J, LI H. Distributed adaptive quantization for wireless sensor networks: from delta modulation to maximum likelihood[J]. IEEE Transactions on Signal Processing, 2008, 56(10): 5246-5257.
- [3] WU T, CHENG Q. Distributed estimation over fading channels using one-bit quantization[J]. IEEE Transactions on Wireless Communications, 2009, 8(12): 5779-5784.
- [4] 李敏, 徐小天, 高冉馨. 基于安全功能要求的无线传感器网络安全分析[J]. 电信科学, 2017, 33(Z1): 96-101.
LI M, XU X T, GAO R X. Wireless sensor network security analysis over security function requirements[J]. Telecommunications Science, 2017, 33(Z1): 96-101.
- [5] WILLIAMS J L, FISHER J W, WILLISKY A S. Approximate dynamic programming for communication-constrained sensor network management[J]. IEEE Transactions on Signal Processing, 2007, 57(8): 4300-4311.
- [6] PREDD J B, KULKARNI S R, POOR H V. Distributed learning in wireless sensor networks[J]. Signal Processing Magazine IEEE, 2005, 23(4): 56-69.
- [7] 孙利民, 李建中, 陈渝, 等. 无线传感器网络[M]. 北京: 清华大学出版社, 2005.
SUN L M, LI J Z, CHEN Y, et al. Wireless sensor network[M]. Beijing: Tsinghua University Press, 2005.
- [8] KNUDSON K, SAAB R, WARD R. One-bit compressive sensing with norm estimation[J]. IEEE Transactions on Information Theory, 2016, 62(5): 2748-2758.
- [9] BARANIUK R G, FOUCART S, NEEDELL D, et al. Exponential decay of reconstruction error from binary measurements of sparse signals[J]. IEEE Transactions on Information Theory, 2017, 63(6): 3368-3385.
- [10] AYSAL T C, BARNER K E. Constrained decentralized estimation over noisy channels for sensor networks[J]. IEEE Transactions on Signal Processing, 2008, 56(4): 1398-1410.
- [11] FANG J, LI H. Adaptive distributed estimation of signal power from one-bit quantized data[J]. IEEE Transactions on Aerospace and Electronic Systems, 2010, 46(4): 1893-1905.
- [12] 彭秋燕, 刘兆霆, 姚英彪. 基于传感器网络的一比特 RLS 算法[J]. 传感技术学报, 2018, 31(12): 1889-1893.
PENG Q Y, LIU Z T, YAO Y B. One-bit recursive least-square algorithm over sensor networks[J]. Journal of Sensing Technology, 2018, 31(12): 1889-1893.
- [13] LIU G, XU B, ZENG M, et al. Distributed estimation over binary symmetric channels in wireless sensor networks[J]. IET Wireless Sensor Systems, 2011, 1(2): 105-109.
- [14] CHEN H, VARSHNEY P K. Nonparametric one-bit quantizers for distributed estimation[J]. IEEE Transactions on Signal Processing, 2010, 58(7): 3777-3787.
- [15] ZHAO W, CHEN H, TEMPO R, et al. Recursive nonparametric identification of nonlinear systems with adaptive binary sensors[J]. IEEE Transactions on Automatic Control, 2017, 62(8): 3959-3971.
- [16] ZHU J, LIN X, BLUM R S, et al. Parameter estimation from quantized observations in multiplicative noise environments[J]. IEEE Transactions on Signal Processing, 2015, 63(15): 1.
- [17] ZHU J, WANG X, LIN X, et al. Maximum likelihood estimation from sign measurements with sensing matrix perturbation[J]. IEEE Transactions on Signal Processing, 2014, 62(15): 3741-3753.
- [18] COLINET E, JUILLARD J. A weighted least-squares approach to parameter estimation problems based on binary measurements[J]. IEEE Transactions on Automatic Control, 2010, 55(1): 148-152.
- [19] RIBEIR O, GIANNAKIS G B. Bandwidth-constrained distributed estimation for wireless sensor networks-part II: unknown probability density function[J]. IEEE Transactions on Signal Processing, 2006, 54(7): 2784-2796.
- [20] CHEN C, WU J. Amplitude-aided one-bit compressive sensing over noisy wireless sensor networks[J]. IEEE Wireless Communications Letters, 2015, 4(5): 473-476.
- [21] TSAKONAS E, JALDÉN J, SIDIROPOULOS N D, et al. Sparse conjoint analysis through maximum likelihood estimation[J]. IEEE Transactions on Signal Processing, 2013, 61(22): 5704-5715.
- [22] RIBEIR O, GIANNAKIS G B. Bandwidth-constrained distributed estimation for wireless sensor networks-part I: Gaussian case[J]. IEEE Transactions on Signal Processing, 2006, 54(3): 1131-1143.

[作者简介]



王娜娜(1995—), 女, 杭州电子科技大学通信工程学院硕士生, 主要研究方向为分布式自适应信号处理。

刘兆霆(1975—), 男, 博士, 杭州电子科技大学通信工程学院副教授、硕士生导师, 主要研究方向为传感器网络信号处理、自适应信号处理、机器学习。

姚英彪(1976—), 男, 博士, 杭州电子科技大学通信工程学院教授、硕士生导师, 主要研究方向为媒体信号处理、无线传感器网络、固态存储。