

基于测量矩阵优化的分布式压缩估计算法

刘 云, 陈 倩

(昆明理工大学 信息工程与自动化学院, 昆明 650500)

摘 要: 为更好地解决无线传感网分布式测量中有效数据估计问题, 提出一种新的分布式压缩估计算法。通过在一个压缩维度上完成未知参数变量的分布式估计, 并采用自适应随机梯度递归方法更新测量矩阵, 将分布式压缩估计与测量矩阵优化相结合, 实现收敛速度及估计误差精度的最优化。仿真结果表明, 与 dNLMS、DCE 算法相比, 该算法具有更快的收敛速度及更高的估计误差精度。

关键词: 无线传感测量; 分布式压缩估计; 梯度递归; 测量矩阵优化; 系统模型

中文引用格式: 刘 云, 陈 倩. 基于测量矩阵优化的分布式压缩估计算法[J]. 计算机工程, 2018, 44(3): 114-118.

英文引用格式: LIU Yun, CHEN Qian. Distributed Compression Estimation Algorithm Based on Measurement Matrix Optimization[J]. Computer Engineering, 2018, 44(3): 114-118.

Distributed Compression Estimation Algorithm Based on Measurement Matrix Optimization

LIU Yun, CHEN Qian

(Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China)

[Abstract] In order to solve the problem of effective data estimation in distributed measurement of Wireless Sensor Network (WSN), a Distributed Compression Estimation Algorithm for Measurement Matrix Optimization (MMDCE) is proposed. It performs the distributed estimation of unknown parameter variables on a compressed dimension, and updates the measurement matrix by using adaptive random gradient recursion. The DCE is combined with the measurement matrix optimization, the optimization of convergence rate and estimated error accuracy are achieved. Simulation results show that compared with dNLMS algorithm and DCE algorithm, the algorithm has better convergence speed and higher precision of estimation error.

[Key words] wireless sensor measurement; Distributed Compression Estimation (DCE); gradient recursion; measurement matrix optimization; system model

DOI: 10.3969/j.issn.1000-3428.2018.03.020

0 概述

在无线传感网的分布式测量中, 为解决高原河流污染日趋严重的问题, 有效的数据估计测量技术显得至关重要^[1]。由于高原河流具有范围广、多参数、时变的测量特性, 数据压缩估计测量如何实时响应数据变化, 减小数据传输量, 提高估计精度是传感器节点采集处理的关键问题。

文献[2-3]提出一种分布式稀疏扩散归一化最小均方算法(dNLMS), 该算法克服实时响应数据变化受限的问题, 提高了估计稳定性。当估计的数据量较大时, 基于全维度空间估计的 dNLMS 算法是受限的。为了延长网络生命周期, 文献[4-5]提出了一

种分布式压缩估计(DCE)算法, 该算法采用数据相关性, 对参数变量进行估计, 实现边采样边压缩。然而, 当采集环境时变性较强时, 该算法显然具有局限性。在 dNLMS 算法和 DCE 算法研究的基础上, 本文提出一种测量矩阵优化的分布式压缩估计算法(MMDCE)。

1 系统建模

1.1 定义

基于高原河流范围广、多参数、时变的测量特性, 将高原河流以 $100\text{ m} \times 100\text{ m}$ 的区域进行划分, 且在各区域中随机分布 N 个传感器节点。在时刻 i , 每个节点上的传感器对水体进行采集, 得到标量测量值如下:

基金项目: 国家自然科学基金(61262040)。

作者简介: 刘 云(1973—), 男, 副教授, 主研方向为无线通信系统; 陈 倩, 硕士研究生。

收稿日期: 2016-12-26 **修回日期:** 2017-03-13 **E-mail:** liuyun@kmust.edu.cn

在如图 4 所示的合并阶段中,在每个时刻 $i = 1, 2, \dots, I$,各节点将自身和相邻节点的局部压缩估计值进行合并。其中, $\{\psi_l(i)\}_{l \in N_k}$ 表示 k 节点的各邻居节点在时刻 i 的局部压缩估计值, $\{c_{k,l}\}$ 表示 k 节点与各邻居节点的组合系数。计算出时刻 $i+1$ 的更新的压缩估计值如下:

$$\bar{\omega}_k(i+1) = \sum_{l \in N_k} c_{kl} \bar{\psi}_l(i) \quad (8)$$




图 4 合并阶段

经过 I 次迭代之后,每个节点将采用正交匹配追踪算法(OMP)^[13-15]产生解压缩的估计值 $\omega_k(I)$ 。在 MMDCE 算法中,仅需要传输局部压缩估计值 $\bar{\psi}_k(i)$,即大大减小了所需传输的参数数量。

通过伪代码对 MMDCE 算法描述如下:

```

Initialize:  $\bar{\omega}_k(1) = 0$ 
For each time instant  $i = 1, 2, \dots, I-1$ 
  For each node  $k = 1, 2, \dots, N$ 
    execute the formula A
    execute the formula B
  end
  For each node  $k = 1, 2, \dots, N$ 
    execute the formula C
  end
end
After the final iteration  $I$ 
For each node  $k = 1, 2, \dots, N$ 
  execute the formula D
A:  $\bar{\psi}_k(i) = \bar{\omega}_k(i) + \mu_k(i) e_k^*(i) \bar{x}_k(i)$ 
B:  $e_k(i) = d_k(i) - \bar{\omega}_k^H(i) \bar{x}_k(i)$ ,
 $d_k(i) = \bar{\omega}_0^H \bar{x}_k(i) + n_k(i) = (\Phi_k \omega_0)^H \bar{x}_k(i) + n_k(i)$ 
C:  $\bar{\omega}_k(i+1) = \sum_{l \in N_k} c_{kl} \bar{\psi}_l(i)$ 
D:  $\omega_k(I) = f_{OMP} \{ \bar{\omega}_k(I) \}$ 

```

由以上伪代码可知:首先初始化 $\bar{\omega}_k(1) = 0$,在时刻 $i(i = 1, 2, \dots, I-1)$ 时,对各节点 $k(k = 1, 2, \dots, N)$ 的局部压缩估计值进行求解得到 $\bar{\psi}_k(i)$,将 k 节点与其邻居节点的局部压缩估计值相合并,计算出 $i+1$ 时的压缩估计值 $\bar{\omega}_k(i+1)$ 。通过 I 次迭代后得到 $\bar{\omega}_k(I)$,最后采用正交匹配追踪算法(OMP)产生解压缩的估计值 $\omega_k(I)$ 。

2.2 测量矩阵优化

为了进一步提高算法的收敛速度、估计误差精度,需要对测量矩阵 $\Phi_k(i)$ 进行优化,其中测量矩阵具有时变性,且采用分布式和自适应的优化方式。考虑成本函数如下:

$$J = E \{ |e_k(i)|^2 \} = E \{ |d_k(i) - y_k(i)|^2 \} = E \{ |d_k(i)|^2 \} - E \{ d_k^*(i) y_k(i) \} - E \{ d_k(i) y_k^*(i) \} + E \{ |y_k(i)|^2 \} \quad (9)$$

其中, $y_k(i) = \bar{\omega}_k^H(i) \bar{x}_k(i)$ 。为了使成本函数达到最小,需要计算相对于 $\Phi_k^*(i)$ 的梯度,并将其等同于空向量,即 $\nabla J_{\Phi_k^*(i)} = 0$ 。此时,仅需考虑式(9)中的前 3 项:

$$\begin{aligned} & E \{ |d_k(i)|^2 \} - E \{ d_k^*(i) y_k(i) \} - E \{ d_k(i) y_k^*(i) \} = \\ & E \{ | \omega_0^H \Phi_k^H(i) \bar{x}_k(i) + n_k(i) |^2 \} - \\ & E \{ (\omega_0^H \Phi_k^H(i) \bar{x}_k(i) + n_k(i))^* y_k(i) \} - \\ & E \{ (\omega_0^H \Phi_k^H(i) \bar{x}_k(i) + n_k(i)) y_k^*(i) \} = \\ & E \{ | \omega_0^H \Phi_k^H(i) \bar{x}_k(i) |^2 \} + \\ & E \{ (\omega_0^H \Phi_k^H(i) \bar{x}_k(i))^* n_k(i) \} + \\ & E \{ (\omega_0^H \Phi_k^H(i) \bar{x}_k(i)) n_k^*(i) \} + E \{ |n_k(i)|^2 \} - \\ & E \{ (\omega_0^H \Phi_k^H(i) \bar{x}_k(i))^* y_k(i) \} - \\ & E \{ n_k^*(i) y_k(i) \} - E \{ (\omega_0^H \Phi_k^H(i) \bar{x}_k(i)) y_k^*(i) \} - \\ & E \{ n_k(i) y_k^*(i) \} \end{aligned} \quad (10)$$

由于随机变量 $n_k(i)$ 统计独立于其他参数,且均值为 0。则对式(10)进行简化得到:

$$\begin{aligned} & E \{ |d_k(i)|^2 \} - E \{ d_k^*(i) y_k(i) \} - \\ & E \{ d_k(i) y_k^*(i) \} = E \{ | \omega_0^H \Phi_k^H(i) \bar{x}_k(i) |^2 \} + \\ & \sigma_{n,k}^2 - E \{ (\omega_0^H \Phi_k^H(i) \bar{x}_k(i))^* y_k(i) \} - \\ & E \{ (\omega_0^H \Phi_k^H(i) \bar{x}_k(i)) y_k^*(i) \} \end{aligned} \quad (11)$$

进一步得到:

$$\nabla J_{\Phi_k^*(i)} = R_k(i) \Phi_k(i) R_{\omega_0} - P_k(i) \quad (12)$$

其中, $R_k(i) = E \{ \bar{x}_k(i) \bar{x}_k^H(i) \}$, $R_{\omega_0} = E \{ \omega_0 \omega_0^H \}$, 以及 $P_k(i) = E \{ y_k^*(i) \bar{x}_k(i) \omega_0^H \}$ 。根据 $\nabla J_{\Phi_k^*(i)} = 0$, 计算式(12)得到:

$$R_k(i) \Phi_k(i) R_{\omega_0} - P_k(i) = 0 \quad (13)$$

$$\Phi_k(i) = R_k^{-1}(i) P_k(i) R_{\omega_0}^{-1} \quad (14)$$

由于 ω_0 是一个未知参数,不能用闭合方式求解式(14),需要用估计值 $\bar{\omega}_k(i)$ 替代 ω_0 。然后采用初始预测来对式(14)进行迭代来获得解。针对式(14),用瞬时值来替换期望值,用瞬时估计进行计算得到:

$$\hat{R}_k(i) = \bar{x}_k(i) \bar{x}_k^H(i) \quad (15)$$

$$\hat{R}_{\omega_0} = \omega_0 \omega_0^H \quad (16)$$

$$\hat{P}_k(i) = y_k^*(i) \bar{x}_k(i) \omega_0^H \quad (17)$$

根据最速下降法^[16-17],使用简单递归关系,计算 $i+1$ 的测量矩阵 $\Phi_k(i)$ 的更新值如下:

$$\begin{aligned} \Phi_k(i+1) &= \Phi_k(i) + \eta [- \nabla J_{\Phi_k^*(i)}] = \\ & \Phi_k(i) + \eta [\hat{P}_k(i) - \hat{R}_k(i) \Phi_k(i) \hat{R}_{\omega_0}] = \\ & \Phi_k(i) + \eta [y_k^*(i) \bar{x}_k(i) \omega_0^H] - \\ & \eta [\bar{x}_k(i) \bar{x}_k^H(i) \Phi_k(i) \omega_0 \omega_0^H] \end{aligned} \quad (18)$$

其中, η 是步长, ω_0 是需估计的未知参数矢量。采用参数向量 $\bar{\omega}_k(i)$ 来重构向量 ω_0 的估计值如下:

$$\omega_{rek}(i) = f_{OMP} \{ \bar{\omega}_k(i) \} \quad (19)$$

其中,运算符 $f_{OMP} \{ \cdot \}$ 表示 OMP 重建算法。通过用 $\omega_{rek}(i)$ 替换 ω_0 ,可以得到用于更新测量矩阵的表达式如下:

$$\begin{aligned} \Phi_k(i+1) &= \Phi_k(i) + \eta [y_k^*(i) \bar{x}_k(i) \omega_{rek}^H(i)] - \\ & \eta [\bar{x}_k(i) \bar{x}_k^H(i) \Phi_k(i) \omega_{rek}(i) \omega_{rek}^H(i)] \end{aligned} \quad (20)$$

在时变性较强的环境中,根据式(20)对测量矩阵进行更新,可以克服无法实时响应数据变化的局限性。针对MMDCE算法,其计算复杂度为 $O(NDI + ND^3I)$,其中, N 表示网络中节点数目, I 表示时刻的数目。而dNLMS算法的计算复杂度为 $O(NMI)$,DCE算法的计算复杂度为 $O(NMI + ND^3I)$ 。根据 $D \ll M$ 可知,相比DCE算法和dNLMS算法,MMDCE算法的计算复杂度达到最小。

3 仿真结果与分析

基于范围广、多参数、时变的测量特性,考虑采集节点 $N=20$,原始数据维度 $M=50$,压缩后维度 $D=10$,即采样比率为 $M/D=5$ 。 $M \times 1$ 的参数向量 ω_0 的稀疏度 $S=3$ 。输入信号为 $\mathbf{x}_k(i) = [x_k(i) x_k(i-1) \cdots x_k(i-M+1)]^T$ 以及 $\mathbf{x}_k(i) = u_k(i) + \alpha_k x_k(i-1)$,其中, α_k 是一个相关系数, $\mathbf{x}_k(i)$ 的方差为1, $u_k(i)$ 是方差 $\sigma_{u,k}^2 = 1 - |\alpha_k|^2$ 的白噪声。通过 $\bar{\mathbf{x}}_k(i) = \Phi_k \mathbf{x}_k(i)$ 可以获得压缩后的输入信号,其中测量矩阵 Φ_k 是独立同分布的高斯随机矩阵,其复高斯噪声的方差 $\sigma_{u,k}^2 = 0.001$,且参数 η 设置为 $0.08^{[4-5]}$,dNLMS的步长 $\mu_0 = 0.45^{[2-3]}$ 。为了对测量值的精确程度作出评定,采用中误差 $\hat{\sigma}$ 来表示,中误差是衡量观测精度的一种数字标准,亦称“标准差”或“均方根差”。已知中误差越小,精度越高,反之成立,假设各测量值与真值之差为 $\Delta_1, \Delta_2, \cdots, \Delta_n$,则中误差可以表示为: $\hat{\sigma} = \sqrt{\frac{(\Delta_1^2 + \Delta_2^2 + \cdots + \Delta_n^2)}{n}}$ 。

如图5所示,随着时间的增加,dNLMS算法、DCE算法与MMDCE算法的均方误差逐渐降低。当时间为100 ms时,dNLMS算法、DCE算法和MMDCE算法的均方误差分别为-4 dB、-15 dB、-26 dB,即MMDCE算法具有较快的收敛行为。当时间大于700 ms时,dNLMS算法、DCE算法与MMDCE算法的均方误差逐渐趋于平缓。对比dNLMS算法和DCE算法,MMDCE算法实现了较快的收敛速度。




图5 均方误差随时间的变化

如图6所示,随着时间的增加,dNLMS算法、DCE算法与MMDCE算法的中误差逐渐降低。当时间为100 ms时,MMDCE算法的中误差比DCE算法降低44.9%,比dNLMS算法降低58.7%。且MMDCE算法总是具有最低的中误差,而dNLMS算法的中误差最大。对比dNLMS算法和DCE算法,MMDCE算法实现了较高的估计误差精度。




图6 中误差随时间的变化

如图7所示,随着稀疏度 S 的增加,DCE算法与MMDCE算法的均方误差逐渐升高,而dNLMS算法的均方误差不变。且当参数向量 ω_0 的每系数传输比特从6 bit增加到10 bit时,dNLMS算法、DCE算法和MMDCE算法的均方误差都减小。对于dNLMS算法,传输比特总数是每个系数传输比特的 M 倍,而对于DCE算法和MMDCE算法,是每个系数传输比特的 D 倍($D \ll M$)。对比dNLMS算法和DCE算法,当稀疏度 S 增加时,MMDCE算法能实现较好的均方误差性能。




图7 每系数传输不同比特数时均方误差随稀疏度的变化

4 结束语

为更好实现无线传感网的分布式测量中有效数据估计,本文提出一种测量矩阵优化的分布式压缩估计算法(MMDCE)。该算法通过在一个压缩维度上完成未知参数变量的估计,并采用自适应随机梯度递归来更新测量矩阵,将分布式压缩估计与测量

矩阵优化相结合,实现收敛速度及估计误差精度的最优化。仿真结果表明,对比 dNLMS 算法和 DCE 算法,在范围较大的多重时变数据监测测量中,MMDCE 算法可以实现更快的收敛速度及更高的估计误差精度。

参考文献

- [1] 朱 杰. 无线传感器网络事件监测与环境感知算法研究[D]. 合肥:中国科学技术大学,2014.
- [2] SANG M J, SEO J H, PARK P G. A Variable Step-size Diffusion Normalized Least-mean-square Algorithm with a Combination Method Based on Mean-square Deviation[J]. Circuits, Systems, and Signal Processing, 2015, 34(10): 3291-3304.
- [3] SANG M J, SEO J H, PARK P G. Efficient Variable Step-size Diffusion Normalised Least-mean-square Algorithm[J]. Electronics Letters, 2015, 51(5): 395-397.
- [4] XU S, de Lamare R C, POOR H V. Distributed Compressed Estimation Based on Compressive Sensing[J]. IEEE Signal Processing Letters, 2015, 22(9): 1.
- [5] BAI H, XU S, LI S, et al. Adaptive Distributed Compressed Estimation Based on Recursive Least Squares with Sensing Matrix Design[C]//Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing. Washington D. C., USA: IEEE Press, 2016: 3691-3695.
- [6] 柴继贵. WSN 中一种基于压缩感知的目标定位算法[J]. 计算机工程, 2013, 39(3): 77-81.
- [7] 祁 锐, 李宏伟, 张玉洁. 基于改进光滑 l_0 范数的块稀疏信号重构算法[J]. 计算机工程, 2015, 41(11): 294-298.
- [8] HUANG S, LI C. Distributed Sparse Total Least-squares over Networks[J]. IEEE Transactions on Signal Processing, 2015, 63(11): 2986-2998.
- [9] 马兰申. 自适应网络的分布式估计研究[D]. 苏州: 苏州大学, 2014.
- [10] XU S, LAMARE R C D, POOR H V. Adaptive Link Selection Strategies for Distributed Estimation in Wireless Sensor Networks[C]//Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing. Washington D. C., USA: IEEE Press, 2014: 5402-5405.
- [11] LORENZO P D, SAYED A H. Sparse Distributed Learning Based on Diffusion Adaptation[J]. IEEE Transactions on Signal Processing, 2013, 61(6): 1419-1433.
- [12] SAYIN M O, KOZAT S S. Compressive Diffusion Strategies over Distributed Networks for Reduced Communication Load[J]. IEEE Transactions on Signal Processing, 2014, 62(20): 5308-5323.
- [13] 陈善雄, 何中市, 熊海灵, 等. 一种基于压缩感知的无线传感信号重构算法[J]. 计算机学报, 2015, 38(3): 614-624.
- [14] 马硕骛. 稀疏时变信号压缩感知重构算法的研究[D]. 南京: 南京理工大学, 2014.
- [15] 唐朝伟, 王雪锋, 杜永光. 一种稀疏度自适应分段正交匹配追踪算法[J]. 中南大学学报(自然科学版), 2016, 47(3): 784-792.
- [16] ARABLOUEI R, WERNER S, DOGANCAI K. Analysis of the Gradient-descent Total Least-squares Adaptive Filtering Algorithm[J]. IEEE Transactions on Signal Processing, 2014, 62(5): 1256-1264.
- [17] 徐 健, 常志国, 赵小强, 等. 基于自适应梯度最速下降的分类字典训练算法[J]. 计算机工程, 2013, 39(5): 225-229.

编辑 索书志

(上接第 113 页)

- [4] RANJAN R, WANG M, PERERA C, et al. City Data Fusion: Sensor Data Fusion in the Internet of Things[J]. International Journal of Distributed Systems & Technologies, 2016, 7(1): 15-36.
- [5] COLLOTTA M, PAU G, SCATA G. A Fuzzy System to Reduce Power Consumption in Wireless Sensor Networks: A Comparison Between Wireless HART and IEEE 802.15.4[C]//Proceedings of IEEE International Energy Conference. Washington D. C., IEEE Press, 2014: 766-771.
- [6] COLLOTTA M, MESSINEO A, NICOLOSI G, et al. A Dynamic Fuzzy Controller to Meet Thermal Comfort by Using Neural Network Forecasted Parameters as the Input[J]. Energies, 2014, 7(8): 4727-4756.
- [7] KAYRAKOWSKY U. Fundamentals of the Dempster-shafer Theory and its Applications to Reliability Modeling[J]. International Journal of Reliability Quality & Safety Engineering, 2007, 14(6): 579-601.
- [8] BIGLARBEIGIAN M, MELEK W, MENDEL J. On the Robustness of Type-1 and Interval Type-2 Fuzzy Logic Systems in Modeling[J]. Information Sciences, 2011, 181(7): 1325-1347.
- [9] WANG Q, LIAO H, WANG K, et al. A Variable Weight Based Fuzzy Data Fusion Algorithm for WSN[M]. Germany, Berlin: Springer, 2011.
- [10] IZADI D, ABAWAJY J H, GHANAVATI S, et al. A Data Fusion Method in Wireless Sensor Networks[J]. Sensors, 2015, 15(2): 2964-2979.
- [11] ZOVIDAVIANPOOR M, GHARIBI A. Applications of Type-2 Fuzzy Logic System: Handling the Uncertainty Associated with Candidate-well Selection for Hydraulic Fracturing[J]. Neural Computing & Applications, 2015, 51(4): 1-21.
- [12] BIGLARBEIGIAN M, MELEK W, MENDEL J. On the Robustness of Type-1 and Interval Type-2 Fuzzy Logic Systems in Modeling[J]. Information Sciences, 2011, 181(7): 1325-1347.
- [13] 曾振东, 陈 霄, 孙 波, 等. 基于占空比控制和时延保证的传感器网络队列管理算法[J]. 计算机应用, 2015, 35(5): 1242-1245.
- [14] DE Ying, LI Beijing. Survey on Energy Efficiency in Wireless Sensor Networks[J]. Computer Science, 2008, 135(111): 8-12.
- [15] 陈慧杰, 韩江洪, 刘 磊. 无线传感器网络中自然能收集分簇路由算法研究[J]. 计算机工程, 2016, 42(3): 143-147.

编辑 索书志