

doi: 10.3969/j.issn.0490-6756.2018.01.002

无线传感器网络中假设检验的传感器选择问题

钱博, 马婷, 宋恩彬

(四川大学数学学院, 成都 610064)

摘要: 无线传感器网络通常具有带宽限制和能量约束,这就涉及到传感器的选择问题,即如何在 n 个传感器中选取 p 个,使得仅由这 p 个传感器的观测进行假设检验时虚警率达到最小.这类问题已被证明是NP难的.本文将该问题松弛成一个易处理的新问题,并提出了一个可以达到新问题KKT点的高效算法.通过与已有的算法比较复杂度,本文提出的算法效率更高.同时仿真结果也表明,大多数情况下我们提出的算法均可达到全局最优解.

关键词: 无线传感器网络; 传感器选择; 虚警率; KKT点

中图分类号: O29 **文献标识码:** A **文章编号:** 0490-6756(2018)01-0007-06

Sensor selection for hypothesis testing in wireless sensor networks

QIAN Bo, MA Ting, SONG En-Bin

(College of Mathematics, Sichuan University, Chengdu 610064, China)

Abstract: The well-known sensor selection issue is of great significance in wireless sensor network. We aim at selecting a subset of p out of n sensors to conduct the corresponding hypothesis test based on their observations such that the false alarm rate attains the minimum, which has been proved to be NP hard. In this paper, we relax the original problem to a tractable one and propose a new algorithm, which can achieve the KKT point. Moreover, compared with the existing algorithm, our algorithm is more efficient since it has lower computation complexity. Simulations also illustrate that the global optimum can be reached in most cases.

Keywords: Wireless sensor network; Sensor selection; False alarm; KKT point

1 引言

在无线传感器网络 WSN (Wireless Sensor Network) 中,能量是制约传感器使用寿命的关键^[1-2]. 为了保证长期无人值守,所部署的传感器需要节约能源使用,因此需要最小化传感、计算和通信来最大化使用寿命. 此外由于带宽和计算的限制,搜集所有传感器的数据进行计算在大多数情况下是不可行的. 因此在传感器网络中有限的激活具有重要意义,即如何选取最优的传感器子集群

使得基于其观测作估计或决策时达到性能最优. 在实际应用中,常常涉及到针对事件检测的传感器选择问题,如自然灾害发生、固定通信网络被破坏等^[3]. 不同于分布式检测,只有部分传感器被激活用来传输观测到融合节点进行判决. 此时传感器选择问题即寻找最优的传感器子集,在满足功率约束的同时,根据它们的观测做判决,使得检测性能最大化也即虚警率(第一类犯错误概率)最小化.

近年来,传感器选择问题已经引起了学者们的广泛关注^[4-6]. 其中,文献[4]给出了一个高效选择

收稿日期: 2017-05-25

基金项目: 国家自然科学基金(61473197)

作者简介: 钱博(1993-),男,湖北黄石人,硕士研究生,主要研究方向为概率论与数理统计. E-mail: chuandaqianbo@163.com

通信作者: 宋恩彬. E-mail: e. b. song@163.com

最优传感器子集的启发式算法,文献[5]考虑了 Kalman 滤波动态系统中的最优传感器选取问题,文献[6]介绍了不同框架下的传感器选择问题,包括路径跟踪及合理分配等,文献[7]中提出了一种选取最优传感器子集的问题框架,并给出了相应的贪婪算法进行求解.虽然能得到次优解,但大多数情况下得不到全局最优解,文献[8]已证明在该框架下传感器选择问题是 NP 难的,故寻找高效方法求解此类问题具有重要意义.

本文基于文献[7]提出的传感器选择问题的框架,运用新的梯度算法来进行求解,从理论上说明了我们提出的算法计算复杂度低于文献[7]中的贪婪算法,且证明梯度算法可以收敛到松弛之后的新问题的 KKT 点.仿真例子显示我们的算法总是可以获得比贪婪算法更高质量的解,特别地,当问题规模较小时,可以用穷举法获得全局最优解,与我们的算法获得的结果一致.因此我们提出的算法更具有实际应用意义.

2 问题描述

2.1 高斯假设检验

令 $x = (x_1, x_2, \dots, x_n)^T \in \mathbf{R}^n$ 表示所有传感器的观测,其中 x_i 代表第 i 个传感器的观测.假设真实数据 $x \in \mathbf{R}^n$ 由两个已知的高斯分布产生.因此我们考虑的假设检验问题为:

$$H_0: x \sim N(m_0, S_0),$$

$$H_1: x \sim N(m_1, S_1),$$

其中 $N(m_i, S_i)$ 代表均值为 m_i 方差阵为 S_i 的高斯分布,假设 $H_1(H_0)$ 代表该事件发生(未发生).

但在实际应用中,由于传输的功率限制,仅允许其中 p 个传感器的观测传输到融合节点上,并在该低维空间上做假设检验.由此产生了传感器选择问题,即找到一个元素全为 0/1 的选择矩阵 $E \in \mathbf{R}^{n \times p}$,使得 $y = E^T x \in \mathbf{R}^p$,再在 y 的低维空间上进行假设检验.显然,选择矩阵 E 的转置 E^T 满足:每一行有且只有一个 1(即 y 的每一个分量恰为 x 的某个分量),每列最多有一个 1(每个传感器至多被选取一次),其余元素均为 0.

基于以上分析,若固定选择矩阵 E ,低维空间 \mathbf{R}^p 中的 y 可看作高维空间 \mathbf{R}^n 中数据 x 的投影,具体表现形式即: $x \rightarrow y = E^T x$.从而原假设检验问题转化为低维空间 \mathbf{R}^p 上的假设检验问题:

$$\bar{H}_0: y \sim N(E^T m_0, E^T S_0 E),$$

$$\bar{H}_1: y \sim N(E^T m_1, E^T S_1 E).$$

基于上述表达式,传感器选择问题即为如何最优地设计选择矩阵 E ,使得对上述假设检验问题做判决时犯错误概率最小.

2.2 问题转化

直观上两个分布差别越大,判决的虚警率就会越低,而 KL 散度恰好是两个概率分布差别的度量.下面的引理具体给出了虚警率 P_{FA} 与 KL 散度的关系.

引理 2.1 (Stein's 引理^[9]) 在 Neyman-Pearson(NP)框架^[10]下判决 $H_0: x \sim p_0$ 和 $H_1: x \sim p_1$ 时,随着独立同分布的样本数据增大,虚警率呈指数衰减至零,那么有如下关系式:

$$\lim_{k \rightarrow \infty} \frac{\log P_{FA}(k)}{k} = -D_{KL}(p_1 \parallel p_0),$$

其中 k 表示样本量, P_{FA} 表示虚警率(第一类犯错误概率)即 H_0 发生的情况下判决为 H_1 的概率, $D_{KL}(p_1 \parallel p_0) = \int p_1(x) \log \frac{p_1(x)}{p_0(x)} dx$ 表示分布 p_0 和 p_1 之间的 Kullback-Leibler (KL)散度(又称相对熵).

类似于文献[7],由引理 2.1,最小化虚警率可以转化为极大化两个分布的 KL 散度.因此我们希望寻找一个最优的选择矩阵 E ,使得在低维空间上做假设检验时,两个分布的 KL 散度可以达到最大,从而得到下述优化问题:

$$\max F(E) \text{ s. t. } E_{ij} \in \{0, 1\} E^T E = I_p \quad (1)$$

其中 I_p 表示 $p \times p$ 的单位阵,目标函数 $F(E) := D_{KL}(N(E^T m_1, E^T S_1 E), N(E^T m_0, E^T S_0 E))$. 根据 KL 散度的定义,

$$\begin{aligned} F(E) = & \frac{1}{2} \{ \text{tr}((E^T S_0 E)^{-1} (E^T S_1 E)) + \\ & (m_1 - m_0)^T E (E^T S_0 E)^{-1} E^T (m_1 - m_0) - \\ & \log \frac{\det(E^T S_1 E)}{\det(E^T S_0 E)} - p \}. \end{aligned}$$

3 传感器选择算法

显然问题(1)是一个组合问题,可以直接穷举所有的 C_n^p 种组合方式来进行求解.但当 n 较大时,计算复杂度过高,穷举法很难实现(实际问题中 n 往往很大).文献[7]中提出的贪婪算法是对选择矩阵的每一列进行优化,复杂度较高.本文提出的梯度算法直接整体优化选择矩阵,在得到次优解的同时降低了计算复杂度,仿真结果也表明大多数情况下我们的算法可以得到更高质量的解.

我们提出的算法具体实施过程主要分为下面

三个过程: 松弛约束、投影和局部优化, 本文将该传感器选择算法简称为梯度算法。

3.1 松弛约束

首先将约束 $E_{ij} \in \{0, 1\}$ 松弛掉并令 $f(E) = -F(E)$, 得到新的优化问题:

$$\min f(E) \text{ s. t. } E^T E = I_p \quad (2)$$

由于该问题满足列正交约束, 并且目标函数可导, 故我们考虑利用文献[11]中约束保持的梯度下降法求解问题(2), 具体执行步骤如下。

算法 1. 约束保持的梯度下降算法

- 1: 随机输入初始的选择矩阵 E_0 ;
- 2: 初始化: 令 $k = 0, \varepsilon \geq 0, 0 < \rho_1 < \rho_2 < 1$;
- 3: 当终止条件 $\|\nabla f(x_k)\| \leq \varepsilon$ 不满足时, 执行 4~7 步;
- 4: 令 $H_k \leftarrow E_k (\nabla f(x_k))^T - \nabla f(x_k) E_k^T$;
- 5: 根据 Armijo-Wolfe 准则选取步长 τ_k ;
- 6: 令 $E_{k+1} \leftarrow Y(\tau_k) = (I + \frac{\tau}{2} H_k)^{-1} (I - \frac{\tau}{2} H_k) E_k$;
- 7: $k \leftarrow k + 1$.

在上述算法中, Armijo-Wolfe 准则^[12]是常用的优化算法准则, 可以保证每步迭代中目标函数有足够的下降量, 即以满足下列两个不等式的 τ_k 为步长:

$$\begin{aligned} f(Y_k(\tau_k)) &\leq f(Y_k(0)) + \rho_1 \tau_k f'_\tau(Y_k(0)), \\ f'_\tau(Y_k(\tau_k)) &\geq \rho_2 f'_\tau(Y_k(0)). \end{aligned}$$

由文献[13]可知, 当 $0 < \rho_1 < \rho_2 < 1, f'_\tau(Y_k(0)) < 0$ 时, 存在满足上述 Armijo-Wolfe 不等式的区间步长的选取。

下面的定理 3.1 证明了算法 1 的单调下降性和约束保持性, 即每次迭代点在保持正交约束的同时使得目标函数单调下降。尽管文献[11]中的引理 3 已经包含了定理 3.1 的结论, 但为了完整性和清晰性, 我们仍然将其列出并给出证明。

定理 3.1 如果矩阵 $H \in \mathbf{R}^{n \times n}$ 满足 $H^T = -H$, 那么

- (1) $I + H$ 为非奇异矩阵;
- (2) $Y = (I + H)^{-1} (I - H) E$ 满足 $Y^T Y = E^T E$;
- (3) 令 $G \triangleq \nabla f(E), A = GE^T - EG^T$, 则 $Y(\tau) = (I + \frac{\tau}{2} H)^{-1} (I - \frac{\tau}{2} H) E$ 为使得目标函数下降

的方向, 即 $f'_\tau(Y(0)) = -\frac{1}{2} \|A\|_F^2 < 0$, 其中 τ 为迭代步长。

证明 (1) 对于所有非零向量 $x \in \mathbf{R}^n$, 我们有

$$\begin{aligned} x^T H x &= x^T H^T x = \\ &= -x^T H^T x \Rightarrow x^T (I + H) x = x^T x > 0. \end{aligned}$$

因此 $I + H$ 为可逆矩阵, 否则存在非零向量 $x \in \mathbf{R}^n$ 使得 $(I + H)x = 0$ 与之矛盾。

$$(2)$$

$$Y^T Y =$$

$$\begin{aligned} E^T (I - H)^T (I + H)^{-T} (I + H)^{-1} (I - H) E &= \\ E^T (I + H) (I - H)^{-1} (I + H)^{-1} (I - H) E &= \\ E^T (I + H) (I + H)^{-1} (I - H)^{-1} (I - H) E &= \\ E^T E. \end{aligned}$$

(3) 由链式法则有 $f'_\tau(Y(\tau)) = [\nabla f(Y(\tau)), Y'(\tau)] = \text{tr}(\nabla f(Y(\tau))^T Y'(\tau))$, 而在 $\tau = 0$ 处有 $\nabla f(Y(0)) = \nabla f(E) = G, Y'(0) = -(HE^T - EH^T)E$. 因此目标函数在 $\tau = 0$ 处, $f'_\tau(Y(0)) = -\text{tr}(G^T (GE^T - EG^T)E) = -\frac{1}{2} \|A\|_F^2 < 0$ 得证。

为了刻画算法 1 的收敛性, 我们引入文献[14]中关于矩阵运算的优化算法的收敛性结论, 即当 $f'_\tau(Y(0)) \leq -\sigma \|A\|_F^2$ 成立时, 其中 $\sigma > 0$ 为常数, 则由算法 1 生成的迭代序列 $\{E_k\}$ 满足

$$\lim_{k \rightarrow \infty} \|\nabla f(E_k)\|_F = 0.$$

取 $\sigma = \frac{1}{2}$, 由定理 3.1 (3) 知算法 1 满足条件, 故其得到的 \hat{E} 满足 $\nabla f(\hat{E}) = 0$.

下面将证明算法 1 的迭代序列可以收敛到问题(2)的 KKT 点。这里先引入问题(2)的 KKT 点的具体定义。

定义 3.2 $E \in \mathbf{R}^{n \times p}$ 为松弛后的优化问题(2)的 KKT 点^[15] 当且仅当存在拉格朗日乘子 $\Lambda \in \mathbf{R}^{p \times p}$ 使得 KKT 条件成立:

$$\begin{cases} \nabla_E L(E, \Lambda) = \nabla f(E) + 2E\Lambda = 0, \\ E^T E = I_p, \end{cases}$$

其中 $L(E, \Lambda) = f(E) + [\Lambda, E^T E - I_p]$ 为问题(2)的拉格朗日函数。

下面的定理保证了算法 1 可以收敛到上述定义的 KKT 点。

定理 3.3 随机产生初始的选择矩阵 E_0 后, 由算法 1 产生的序列 $\{E_k\}$ 收敛到问题(2)的 KKT 点。

证明 记算法 1 得到的解为 \hat{E} . 由之前的分析知 $\nabla f(\hat{E}) = 0$. 通过取拉格朗日乘子 $\Lambda^* = 0, E$ 在每步迭代中均满足 $E^T E = I_p$, 则 (\hat{E}, Λ^*) 满足上述 KKT 条件, 从而 \hat{E} 为问题(2)的 KKT 点。

3.2 投影

通常情况下,由算法 1 得到的解 \hat{E} 并不是一个选择矩阵,即元素不为 0/1. 因此我们需要将 \hat{E} 投射到问题(1)的可行集中,将 \hat{E} 中的元素投影到 0 或 1. 一种直观的取整方式是:对 \hat{E} 每一列的元素,将最靠近 1 的令为 1,其余的令为 0,在保证每列只有一个 1、每行最多一个 1 的情况下可以得到一个满足条件的选择矩阵.

然而这种方式并没有充分利用到目标函数的信息. 注意到,对于每个列正交矩阵 $E \in \mathbf{R}^{n \times p}$ 和正交阵 $Q \in \mathbf{R}^{p \times p}$,问题(1)中的目标函数满足: $F(E) = F(EQ)$. 因此 $F(E)$ 仅依赖于 E 的列空间,而不是元素的取值.

为了推导如何由 \hat{E} 得到最靠近 \hat{E} 的列空间的选择矩阵 \tilde{E} ,我们首先给出下面的引理.

引理 3.4 EE^T 是 Stiefel 矩阵^[16] $E \in \mathbf{R}^{n \times p}$ 的列空间的正交投影算子.

证明 E 为 Stiefel 矩阵即满足: $EE^T = I_p$. 设全空间 $C^n = R(E) \oplus R^\perp(E)$, 则对任意的 $x \in C^n$, 可唯一地分解为 $x = y + z, y \in R(E), z \in R^\perp(E)$, 其中根据定义 $R(E) = \{y \in \mathbf{R}^n \mid \exists \xi \in \mathbf{R}^p, E\xi = y\}$, $R^\perp(E) = N(E^T) \Rightarrow E^T z = 0$ 成立. 因此利用 $EE^T = I_p$ 有 $EE^T x = EE^T(y + z) = EE^T E\xi + EE^T z = E\xi + 0 = y$. 根据定义, EE^T 为 $R(E)$ 的正交投影算子.

由引理 3.4, EE^T 是 Stiefel 矩阵 E 的列空间的正交投影算子,故最靠近 $\hat{E}E^T$ 的选择矩阵 \tilde{E} 即为最靠近 \hat{E} 的列空间的选择矩阵,从而求解 \tilde{E} 就转化为下面的优化问题:

$$\begin{aligned} \min_E & \|EE^T - \hat{E}\hat{E}^T\|_F, \\ \text{s. t. } & E_{ij} \in \{0, 1\}, E^T E = I_p \end{aligned} \quad (3)$$

其中 $\|\cdot\|_F$ 为矩阵的 Frobenius 范数. 下面的引理 3.5 及其证明过程给出了问题(3)的解的形式.

引理 3.5 优化问题(3)具有解析解.

证明 令 $E = (e_1, \dots, e_p)$. 由 $E_{ij} \in \{0, 1\}$, $E^T E = I_p$ 可知 $e_i e_i^T$ 是一个对角元为 1,其余元素均为 0 的对角阵,故 $EE^T = e_1 e_1^T + \dots + e_p e_p^T$ 为对角元含有 p 个 1,其余元素均为 0 的对角阵. 记对角线上前 p 个最大的元素所对应的角标为 (j_1, \dots, j_p) , 则问题(3)的解为 $\tilde{E} = (i_{j_1}, \dots, i_{j_p})$, 其中 i_j 为单位阵 I_n 的第 j 列.

3.3 局部优化

对投影后得到的矩阵 \tilde{E} 进行局部优化,即对第 i 列中元素为 1 的位置进行遍历,从中选出使得目标函数最优的位置固定住,再对第 $i + 1$ 列中元

素为 1 的位置进行相同的遍历,直到所有的 p 列均得到优化. 容易看出,局部优化的计算量仅为 $(n - p)p$ 次目标函数的计算. 显然当 $p = 1$ 时,经过一次局部优化得到的必是全局最优解.

在时间允许的情况下可以精炼多次至目标函数不变(仿真结果表明最多两次就可以达到最优),最终得到最优的选择矩阵 E^* .

整体分析我们提出的梯度算法,梯度算法的复杂度为 $O(np^2)$ (文献[11]已证明),而文献[7]中的贪婪算法复杂度为 $O(n^3 p)$,故梯度算法的效率比贪婪算法更高.

4 仿真结果

为了衡量我们提出的梯度算法的性能,我们将梯度算法、穷举法(当可以执行时)和贪婪算法三者的输出结果进行了比较.

首先考虑问题规模不大的情况,此时可以利用穷举法求出全局最优解. 分别取 $n = 10, 20, 30, 40, 50$, 随机产生两组高斯分布 $N(m_0, S_0)$ 和 $N(m_1, S_1)$, 其中均值 $m_0 \in \mathbf{R}^n$ 的每个元素在 $(0, 0.5)$ 内均匀产生,而 m_1 的每个元素在 $(0, 0.8)$ 中均匀产生, $S_i = P_i \Lambda_i P_i^T$, 其中 P_i 为每个元素服从 $(0, 1)$ 上均匀分布的 $n \times n$ 矩阵的正交基, Λ_i 为对角元在 $(0, 1)$ 内均匀产生的对角阵, $i = 0, 1$. 对 $p = 2, 3, 4, 5$, 利用这三种算法计算各自输出的最优 KL 散度值,结果如表 1.

表 1 三种算法获得的最优 KL 散度
Tab. 1 The optimal KL divergences of three algorithms

KL 散度	$p = 2$	$p = 3$	$p = 4$	$p = 5$
穷举法 n				
10	1.8394	2.1647	2.4392	4.5893
20	1.5585	1.8853	2.0568	3.6449
30	1.0647	1.491	3.2979	3.4179
40	1.3659	1.9953	2.6463	4.28
50	1.3218	1.5624	2.1914	2.9365
贪婪算法 n				
10	0.8631	1.6378	1.8221	4.2213
20	1.4935	1.6341	1.8063	3.3406
30	0.8596	1.1988	2.8853	3.3576
40	1.126	1.6941	2.4984	3.8162
50	1.0971	1.4276	1.7509	2.823
梯度算法 n				
10	1.8394	2.1647	2.4392	4.5893
20	1.5585	1.8853	2.0568	3.6449
30	1.0647	1.491	3.2979	3.4179
40	1.3659	1.9953	2.6463	4.28
50	1.3218	1.5624	2.1914	2.9365

由表 1 可以看出, 梯度算法的输出结果与穷举法得到的目标函数值相同, 这说明我们的算法可以达到穷举法所得到的全局最优解, 明显优于文献 [7] 中的贪婪算法.

当 n 和 p 取值较大时, 穷举法由于计算量的原因无法实现, 故我们仅比较梯度算法与贪婪算法的最优 KL 散度输出结果, 这里的参数与表 1 一样随机产生, 输出结果见表 2.

表 2 两种算法获得的最优 KL 散度

Tab. 2 The optimal KL divergences of two algorithms

KL 散度	$p = 10$	$p = 11$	$p = 12$	$p = 13$	$p = 14$	$p = 15$
梯度算法 n						
100	4.8070	5.4418	5.9714	5.8569	5.4669	5.6056
150	6.1371	6.2913	5.1602	6.1189	7.4014	6.4287
200	4.7017	5.5424	6.4018	7.8681	6.0012	8.2157
250	4.9767	5.8966	5.5271	6.4414	7.1814	7.4111
300	5.8701	6.1051	6.3167	6.8414	7.4998	8.0478
贪婪算法 n						
100	4.2644	5.0223	5.5306	5.6009	5.2412	5.2103
150	5.8420	6.3328	4.7882	5.5871	6.9056	6.0322
200	4.4599	5.3036	6.1533	7.6348	5.9112	8.1134
250	4.6727	5.579	5.4834	6.3612	7.0902	7.3144
300	5.4277	5.9924	6.0468	6.7486	7.3391	7.9319

从表 2 可明显看出, 在所有情况下梯度算法得到的目标函数值更大, 故其可以得到更高质量的解.

另一方面, 对于假设检验问题而言, ROC (Receiver Operating Characteristic) 曲线是衡量检测性能的一个重要工具: ROC 曲线越高, 表明虚警率相同的情况下检测概率越大, 性能越好. 因此, 我们也给出了三种算法对应的 ROC 曲线.

当 $n = 40, p = 3$ 时, 穷举法和梯度算法得到的最优 KL 散度均为 1.9953, 而贪婪算法得到的 KL 散度为 1.6941 明显欠佳. 针对这三个算法得到的选择矩阵 E , 由之前 H_0, H_1 中的两个高斯分布分别随机产生 10^5 个样本进行极大似然比检验^[17], 即

$$P_{FA} = \left(t = \frac{p(y|\bar{H}_1)}{p(y|H_0)} > \gamma | H_0 \right),$$

$$P_{Det} = \left(t = \frac{p(y|\bar{H}_1)}{p(y|H_0)} > \gamma | H_1 \right),$$

其中 γ 为阈值, 对虚警率和检测概率进行近似, 最终得到三种算法的 ROC 曲线如图 1.

由图 1 易知, 梯度算法与穷举法的 ROC 曲线重合, 明显位于贪婪算法的 ROC 曲线的上方. 故在相同虚警率情况下, 梯度算法得到的检测概率更高.




图 1 三种算法的 ROC 曲线

Fig. 1 The ROC curves of three algorithms

当 $n = 300, p = 10$ 时, 问题规模较大, 穷举法无法实现, 故仅比较梯度算法和贪婪算法. 此时梯度法得到的最优 KL 散度为 5.8701, 优于贪婪算法得到的 5.4277. 对这两种算法得到的最优选择矩阵, 同样地由之前的两个高斯分布分别随机产生 10^5 个样本近似虚警率和检测概率, 得到 ROC 曲线如下.

图 2 显示梯度算法的 ROC 曲线明显高于贪婪算法, 故在问题规模较大时, 梯度算法的检测性能仍然优于贪婪算法.

结合之前对这两种算法复杂度的分析可知, 在

实际应用中,不管是在计算复杂度上还是检测性能上,梯度算法在求解传感器选择问题时更有优势.




图 2 两种算法的 ROC 曲线

Fig. 2 The ROC curves of two algorithms

5 结束语

本文针对无线传感器网络中的传感器选择问题提出了一种新的梯度算法,较已有的贪婪算法而言,复杂度更低,并证明了梯度算法可以达到松弛之后的新问题的 KKT 点. 另外,仿真例子也表明在大多数情况下梯度算法都可以达到全局最优解,特别是在问题规模较小时,梯度算法的性能与穷举法完全一致. 这说明我们提出的算法在实际应用中具有更大的应用价值.

本文考虑的假设检验问题中均值向量和协方差矩阵都是事先给定的,然而在实际应用中当均值向量或协方差矩阵设定有误时,这就牵涉到了稳健假设检验问题,即给定一个误差界之后,假设检验判决在误差容忍范围内达到最坏情况最优. 由于本文是沿用文献[7]的框架,在其基础上提出的一种更高效性能更优的算法,故暂不考虑稳健假设检验问题,但这可以作为一个未来的考虑方向.

参考文献:

[1] 张春琴. 基于人工蜂群的无线传感器网络分簇规划方法[J]. 四川大学学报:自然科学版, 2014, 51: 282.
 [2] 罗娅, 陈文. 一种安全的无线传感器网络分布式决策融合方法[J]. 四川大学学报:自然科学版, 2015, 52: 499.

[3] 马祖长, 孙怡宁, 梅涛. 无线传感器网络综述[J]. 通信学报, 2004, 25: 114.
 [4] Joshi S, Boyd S. Sensor Selection via Convex Optimization [J]. IEEE T Signal Proces, 2009, 57: 451.
 [5] Weimer J E, Sinopoli B, Krogh B H. A relaxation approach to dynamic sensor selection in large-scale wireless networks [C]// International Conference on Distributed Computing Systems Workshops, 2008.
 [6] Rowaihy H, Verma D, Brown T, et al. A survey of sensor selection schemes in wireless sensor networks [J]. Defence Security Symp, 2007, 6562: 35.
 [7] Bajovic D, Sinopoli B, Xavier J. Sensor selection for hypothesis testing in wireless sensor networks: a Kullback-Leibler based approach[C]// Proceedings of the IEEE Conference on Decision and Control, 2009.
 [8] Bajovic D, Sinopoli B, Xavier J. Sensor selection for event detection in wireless sensor networks [J]. IEEE T Signal Proces, 2011, 59: 4938.
 [9] Cover T M, Thomas J A. Elements of information Theory [M]. Beijing: Tsinghua University Press, 1991.
 [10] Lehmann E L. Testing statistical hypothesis[M]. New York: Wiley, 2011.
 [11] Wen Z, Yin W. A feasible method for optimization with orthogonality constraints [J]. Math Program, 2013, 142: 397.
 [12] Sun W, Yuan Y X. Optimization theory and methods [M]. New York: Springer, 2006.
 [13] Nocedal J, Wright S. Numerical optimization[M]. New York: Springer, 2006.
 [14] Absil P A, Mahony R, Sepulchre R. Optimization algorithms on matrix manifolds [M]. Princeton: Princeton University Press, 2009.
 [15] Bian W, Chen X, Ye Y. Complexity analysis of interior point algorithms for non-Lipschitz and non-convex minimization [J]. Math Program, 2015, 149: 301.
 [16] Hatcher A. Algebraic topology[M]. Cambridge: Cambridge University Press, 2002.
 [17] Suleiman R F R, Mary D, Ferrari A. Dimension reduction for hypothesis testing in worst-case scenarios [J]. IEEE T Signal Proces, 2014, 62: 5973.