

引用格式: 谢晓娟, 王耀力. 基于 CVaR 子模效益模型的传感器布局优化[J]. 微电子学与计算机, 2020, 37(1): 14-19. [XIE X J, WANG Y L. Sensor deployment optimization based on CVaR submodular utility maximization model[J]. Microelectronics & Computer, 2020, 37(1): 14-19.]

基于 CVaR 子模效益模型的传感器布局优化

谢晓娟, 王耀力

(太原理工大学 信息与计算机学院, 山西 晋中 030600)

摘 要: 针对在不确定情况下如何保证传感器布局取得最优效果问题, 本文在初始部署节点时考虑节点存在的不确定性, 采用基于 CVaR 的子模效益模型来最小化这种不确定性对传感器网络布局效果的影响, 为了快速有效获得该模型下的最优传感器布局, 对传统贪婪算法进行改进, 根据模型中存在的参数 τ 对全局最优解进行有序搜索, 同时引入 lazy evaluation 减少算法的时间复杂度. 仿真实验表明, 在不确定情况下对传感器进行布局时, CVaR 模型可以有效提高网络布局的鲁棒性, 与改进的贪婪算法相结合, 可以快速获得保证较高信息增益下的布局点集.

关键词: 传感器布局; CVaR; 子模函数; 有序搜索; lazy evaluation

中图分类号: TP393

文献标识码: A

文章编号: 1000-7180(2020)01-0014-06

Sensor deployment optimization based on CVaR submodular utility maximization model

XIE Xiao-juan, WANG Yao-li

(College of Information and Computer, Taiyuan University of Technology, Jinzhong 030600, China)

Abstract: In order to ensure the optimal effect of sensor layout under uncertain conditions, this paper considers the uncertainty of nodes in the initial deployment of nodes, and adopts CVaR submodular utility maximization model to minimize the uncertainty of sensor network layout. In order to quickly and effectively obtain the optimal sensor layout under the model, the traditional greedy algorithm is improved, and the global optimal solution is searched according to the parameter τ existing in the model. At the same time, the lazy evaluation is introduced to decrease time complexity. Simulation experiments show that the CVaR model can effectively improve the robustness of the sensor deployment network when the sensor is laid out under uncertainty. Combined with the improved greedy algorithm, the layout point set can be quickly obtained with high information gain.

Key words: sensor deployment; CVaR; submodular function; ordered search; lazy evaluation

1 引言

传感器网络的布局方式影响获取信息的准确性以及资金的耗费程度等, 所以优化传感器网络的布局一直是无线传感器网络的一个研究热点. 目前传感器网络中大都采用无线传感器, 无线传感器节点电量有限, 一旦电量耗尽, 则节点就会失效; 再者, 在

实际部署传感器节点时, 由于地形险峻等不适宜人员进行部署的情况存在, 会采用无人机投递的方法进行布局, 那么实际部署位置与仿真实验得出的预期位置间可能存在偏差. 这些不确定情况的存在可能会严重影响传感器网络的布局效果并造成较大的经济损失, 故节点存在不确定性的传感器网络布局优化问题得到了广泛的关注^[1].

2012 年, Krause^[2]将传感器布局问题转化为最优子集选择问题,采用离散子模效益最大化模型进行传感器布局,以信息增益作为衡量布局效益的目标函数,采用贪婪算法,从备选点中选择使信息增益最大的子集作为部署的集合进行布局. 这种布局模型未考虑传感器节点的不确定性,鲁棒性较差^[3]. 且采用贪婪算法来解决这个 NP-hard^[2]问题,存在计算效率过低、解集效果不佳的问题.

为了更好解决节点存在不确定性情况下的最优子集选择问题,2010 年, Xiong 等人^[4]提出将其转化为风险规避问题,寻求获得的效益与存在的风险之间的平衡. 对此,为规避风险,2012 年, Gonzalez^[5]采用经济学中的均值-方差模型,用均值表示预期收益,方差表示实际收益与预期收益的差;在均值一定的情况寻找最小的方差来减小节点的不确定性对布局效果的影响. 在风险管理中, VaR (Value at risk) 可以表示一定条件下的最大损失,对风险的描述更具体. 故 Ning 等人^[6]提出基于 VaR 的子集选择模型. Rockafellar^[7]证明 CVaR (Conditional Value at Risk) 比 VaR 具有更好的性质:可以表示潜在损失,且具有次可加性和凸性,在风险管理中应用广泛. 2015 年, Maehara^[8]提出了基于 CVaR 的子模效益模型,目前,这种基于 CVaR 的子模效益模型已经在社会影响最大化问题^[9]、零和博弈^[10]中得到了很好的应用.

传感器布局优化问题可转化为最优子集选择问题,本文将基于 CVaR 的子模效益模型应用于具有不确定性的传感器布局优化问题,保证在风险情况下取得最大的布局效益,同时提高传感器网络的鲁棒性. 为了更好地寻找到约束条件下的布局最优解,采用改进的贪婪算法,在减少算法时间复杂度的同时进行全局有序搜索,完成对传感器网络的优化布局.

2 基于 CVaR 的子模效益模型

2.1 离散子模效益最大化模型

假设目标区域需部署 k 个传感器,那可在目标区域先确定大量可部署传感器的位置,用集合 X 来表示这 $n (n > k)$ 个可部署位置的总和,则传感器优化布局即可转化为最佳子集选择问题:选择一个最佳的子集 $S (S \in M)$ 使部署的传感器网络达到的效果最佳. 用拟阵 I 表示子集 S 的约束条件,用函数 $f(S)$ 衡量布局效果.

定义 1: 对函数 $f: 2^x \rightarrow R$, 若任意 $S \subseteq T$ 存在

$f(S \cup T) + f(S \cap T) \leq f(S) + f(T)$, 那么函数 f 具有子模性质.

显然,衡量布局效果的效益函数满足子模性质,即随着解集中传感器节点的不断增加,新加入的节点对整个网络的布局效果的影响力逐渐减小. 本文采用满足子模性质的信息增益^[11] 衡量布局效果,那么最优解集为令信息增益最大的那组解,则离散子模效益最大化模型可表示为:

$$\max_{S \in X, S \in M} f(S) \quad (1)$$

2.2 Conditional Value at Risk (CVaR)

Conditional value at risk (CVaR) 是在 Value at risk (VaR) 的基础上发展起来的, VaR 指在一定的置信水平 α 下,某一组合价值在特定时间 t 内的最大可能损失^[12]. 令置信水平 $\alpha \in (0, 1)$, P 为损失函数 $f(X, \omega)$ 的分布函数,那么 VaR 可表示为:

$$\text{VaR}_\alpha(X) = \max \{t: P(f(X, \omega) \geq t) \geq \alpha\} \quad (2)$$

CVaR 表示在既定置信水平 α 下,损失超过 VaR 的那部分的平均值,故为:

$$\text{CVaR} = E(f(X, \omega) | f(X, \omega) \geq \text{VaR}_\alpha(X)) \quad (3)$$

CVaR 值不仅可以充分反映损失的尾部信息,且满足次可加性和凸性,是较好的风险度量指标. 在传感器布局效益函数中采用 CVaR 衡量最坏情况下的平均效益,确保其能达到最大,那么传感器在面临节点损失、部署不到预期位置等情况时,造成的损失也会相应减少,可达到规避风险的目的.

2.3 基于 CVaR 的子模效益模型

在实际部署中,由于地形的限制以及传感器节点易损坏的特性,实际获得的布局效益存在小于预期效益的可能性. 即在衡量布局效果的效益函数中存在一个独立于最优子集 S 的变量 y , 对传感器网络获取的布局效果也有影响,则包含不确定性的传感器布局模型可表示为:

$$\max_{S \in I, S \in X} f(S, y) \quad (4)$$

在节点的不确定性的影响下,采用 CVaR 可表示出最差情况下取得的布局效果的平均值,基于 CVaR 的子模效益模型以最大化 CVaR 为目标,将出现最坏情况下的布局效果达到最大,减少这种不确定性对布局效益的影响,则基于 CVaR 的子模效益模型为:

$$\max_{S \in I, S \in X} \text{CVaR}_\alpha(S) \quad (5)$$

在优化 $\text{CVaR}_\alpha(S)$ 时,通常采用辅助函数 $H(S, \tau)$ ^[13]. 那么优化 $\text{CVaR}_\alpha(S)$ 就可以转化为化 S

和 τ 上的辅助函数 $H(S, \tau)$, 那么可将基于 CVaR 的子模效益模型表示为如下表达式:

$$\max_{x \in I, \tau \in [0, \Gamma]} \tau - \frac{1}{\alpha} E[(\tau - F(S, y))_+] \quad (6)$$

3 改进的贪婪算法

3.1 算法流程

贪婪算法的基本思路^[14]就是将问题简化为规模更小的子问题, 对每一个子问题, 求出它们的局部最优解, 然后将这一系列的局部最优解组成的解集作为最终得到的解集. 传感器布局的目标是在 n 个备选点中选择 k 个元素组成的子集使效益函数 $f(S)$ 达到最大, 那么根据贪婪算法的思想, 每次加入一个令边际效益 $f(S \cup i) - f(S)$ 最大的节点, 那么加入 k 个后即可认为达到了最优解. 不难发现, 将传统贪婪算法应用于求解式(6)的最优解时, 若 α 以及 τ 设置不当, 很容易陷入局部最优解. 故在算法中在指定 α 下对 τ 以一定的步长进行有序搜索, 寻找最佳解集对 (S^G, τ) , 然后对比不同 α 下求得的 $H(S_i^G, \tau_i)$, 根据确定 α 的值.

传统贪婪算法的运行效率较低, 每次加入新元素的时候都需计算可加入点的效益然后进行排序选择出最大的那个节点加入到最终解集中, 这样算法的时间复杂度会大大增加. 为了减小算法的时间复杂度, 采用 Lazy evaluation 的思想对算法进行简化. 具体如下:

每次加入使子模效益最大的那个点, 在第一个节点 A 加入到解集后, 在第二轮加入新节点的时候, 先将比其子模效益次小的节点 B 再次计算下子模效益, 如果 B 产生的子模效益大于或等于上一轮比 B 次小的 C 节点子模效益, 那么 B 直接可看作是第二轮的解, 不需要再与其他节点产生的边际效益再去排序比较. 若结点 B 的影响力不大于或等于上一轮又比自己次小的节点 C 的上一轮边际影响力, 就依次逐个算出各个节点边际影响力, 排序选择最大的作为种子节点, 放入种子集. 采用 lazy evaluation 优化后的贪婪算法在每次加入新元素的时候可以减少很多步骤, 所以算法的效率大大提高.

改进后的贪婪算法的步骤如下:

Step 1: 定义一个集合 M 来存储指定置信水平 α 下求得的最优解 (S^G, τ^*) , S^G 用于存储部署点的集合, τ^* 表示搜索到的最优参数, 初始化其为空集.

Step 2: 设置 τ 的搜索上界 Γ 以及搜索间隔 Δ

Step 3: 对 $\tau \in [0, \Gamma]$ 以步长 Δ 采用贪婪算法求位置集合 S^G , 采用 lazy evaluation 减少算法时间复杂度

Step 4: 对比不同 τ 下求得的位置集合 S^G 的 $H(S^G, \tau)$, 选择令 $H(S^G, \tau)$ 最大的那组 τ 和 S^G 作为最终解 (S^G, τ^G) .

改进贪婪算法的伪代码如下:

基于子模函数的贪婪算法

Input: Ground set V and matroid I

Risk level set in advance $\alpha \in (0, 1)$

Parameter $\tau \in (0, \Gamma)$ and search step Δ

Output: (S^G, τ^G)

1: $M = \varphi$

2: for $i = \{0, 1, \dots, \lceil \frac{\Gamma}{\Delta} \rceil\}$

3: $\tau_i = i \Delta$

4: $S_i^G = \varphi$

5: while $S_i^G \in I$ do

6: $s = \operatorname{argmax}_{s \in v \setminus S_i^G} S_i^G \cup \{s\} \in I H(S_i^G \cup \{s\}, \tau_i) - H(S_i^G, \tau_i)$ (加入 lazy evaluation)

7: $S_i^G = S_i^G \cup \{s\}$

8: end while

9: $M = M \cup (S_i^G, \tau_i)$

10: end for

11: $(S^G, \tau^G) = \operatorname{argmax}_{(S_i^G, \tau_i) \in M} H(S_i^G, \tau_i)$

3.2 算法性能分析

令 K_f 为效用函数的曲率, 根据贪婪算法求得的解集 S_i^G 下的子模效用函数 $f(S_i^G)$ 与最优解 OPT 的解集 S^* 下的子模效用函数 $f(S^*)$ 存在以下关系:

$$\frac{f(S_i^G)}{f(S^*)} \gg \frac{1}{1 + K_f} \quad (7)$$

本文采用的是非标准化单调子模函数 $H(S, \tau)$, 对这个进行归一化处理后代入式(7), 可得:

$$\frac{H(S_i^G, \tau_i) - H(\varphi, \tau_i)}{H(S_i^{G*}, \tau_i) - H(\varphi, \tau_i)} \gg \frac{1}{1 + K_f} \quad (8)$$

对上式进行处理, 可得:

$$H(S_i^G, \tau_i) \gg \frac{1}{1 + K_f} H(S_i^{G*}, \tau_i) + \frac{K_f}{1 + K_f} H(\varphi, \tau_i) \quad (9)$$

将 $H(\varphi, \tau_i) = -\Gamma(\frac{1}{\alpha} - 1)$ 代入上式, 则:

$$H(S_i^G, \tau_i) \geq \frac{1}{1 + K_f} H(S_i^{G*}, \tau_i) - \frac{K_f}{1 + K_f} \Gamma(\frac{1}{\alpha} - 1) \quad (10)$$

根据式(9),每个 τ_i 下的最佳解集 S^*_i 满足:

$$H(S^*_i, \tau_i) \geq \frac{1}{1+K_f} H(S^G_i, \tau_i) - \frac{K_f}{1+K_f} \Gamma \left(\frac{1}{\alpha} - 1 \right) \quad (11)$$

令上界:

$$H(S^G_i, \tau_i)^b = (1+K_f)H(S^G_i, \tau_i) + K_f \Gamma \left(\frac{1}{\alpha} - 1 \right) \quad (12)$$

在设定的 $\tau = \tau_i$ 下按照搜索间隔 Δ 进行求解,那么求得的解与最优解集对 $H(S^*_i, \tau^*)$ 存在以下关系:

$$\max_{i=\{0,1,\dots,\lceil \frac{\Gamma}{\Delta} \rceil\}} H(S^*_i, \tau_i) \gg H(S^*_i, \tau^*) - \Delta \quad (13)$$

故:

$$\max_{i=\{0,1,\dots,\lceil \frac{\Gamma}{\Delta} \rceil\}} H(S^G_i, \tau_i)^b \gg H(S^*_i, \tau^*) - \Delta \quad (14)$$

将式(13)代入可得:

$$(1+K_f)H(S^G_i, \tau_i) + K_f \Gamma \left(\frac{1}{\alpha} - 1 \right) \gg H(S^*_i, \tau^*) - \Delta \quad (15)$$

对上式进行整理,则基于子模的贪婪算法求取的解集对 (S^G, τ^G) 与最优解 (S^*, τ^*) 存在以下关系:

$$H(S^G, \tau^G) \gg \frac{1}{1+K_f} (H(S^*, \tau^*) - \Delta) - \frac{K_f}{1+K_f} \Gamma \left(\frac{1}{\alpha} - 1 \right) \quad (16)$$

4 仿真实验与分析

4.1 实验步骤

本文讨论的是考虑不确定风险情况下传感器优化布局的问题,故本文优化布局有两个目标:达到较好的布局效果并减小所部署传感器网络因为不确定风险引起的损失。其中,布局效果通过信息增益来衡量,传感器网络因不确定情况导致的风险以损失量来衡量。通过对比实验来说明本文模型及算法的有效性。具体的实验步骤如下:

(1)根据参考文献[15]所提供的数据从80个备选点选择40个进行传感器部署。


(2)利用 Matlab 工具并采用上述数据对本文所提模型进行传感器布局仿真实验,分析参数 τ 以及置信水平 α 对最优解的影响,确定所需设置的数值。

(3)将本文所提算法与传统贪婪算法以及随机部署方法进行对比,分析采用三种算法在相同情况下获得的信息增益、不确定情况下的损失以及时间复杂度上的差异。


4.2 参数 τ 和 α 对解集的影响

如图1(a)可知,对于任意给定的置信水平 α ,对 τ 设定搜索上界 Γ ,采用本文提出的算法以步长1从0到上界 Γ 之间进行有序搜索,总能得到一个局部最优解。而且, Γ 设置地越大,所找到的局部最优解就越接近全局最优解,故 Γ 要设置地要尽可能大。本文信息增益来衡量布局效果,由图1(a)可知,当 τ 的搜索上界 Γ 置为50时对于不同的置信水平均可保证搜索到全局最优解。

如图1(b)所示,不同的置信水平 α 下求得的最大效益也不同。在参数 τ 一定时,将不同置信水平 α 下求得的效益 $H(S^G, \tau^G)$ 进行比较,可知,随着置信水平 α 的不断增大,最优解产生的布局效益 $H(S^G, \tau^G)$ 也在不断增大。为了令部署的传感器网络获取到最大的效益,算法所求得的最优解为置信水平 $\alpha=0.9$ 下的部署集合 S^G 。



(a) 参数 τ 和 α 对 $H(S^G, \tau)$ 的影响



(b) 参数 α 对 $H(S^G, \tau)$ 的影响

图1 参数 τ 和 α 对 $H(S^G, \tau)$ 的影响

4.3 不同算法下信息增益的对比

本文对传统贪婪算法进行改进,根据模型中存在的参数 τ 对全局最优解进行有序搜索,将 Γ 作为搜索的上界,以设定的步长在0到 Γ 之间进行有序搜索,避免算法陷入局部最优解,保证本文所提算法所求解更接近于最优解。为了验证本文算法的有效性,对比随机部署、传统贪婪算法以及本文所提算法在部署相同传感器节点个数下的部署情况以及取得的布局效益。

本文以信息增益衡量传感器网络的布局效果. 由图 2(a)可知,随机部署传感器节点时,位置呈现出无序性,中间部分几乎没有部署节点,导致布局效果不是很好.传统贪婪算法可实现对整个目标区域的均匀分布,但是在目标区域的边缘位置部署的节点较多,会造成资源的浪费,相应的布局效益也会受到影响.从图 2(c)可以看出,本文提出的算法部署的节点在目标区域均匀分布,且减少了节点部署在边缘地带的情况,使得布局效益进一步提高.




图 2 不同算法下传感器网络的布局情况

由图 3 可知,随着传感器节点的不断增加,传感器网络的布局效益不断增加,当目标区域完成 40 个传感器节点的部署后,本文所提算法、传统贪婪算法以及随机部署方法所达到的信息分别为 32、28 和 19,本文所提算法在部署传感器后获取到的信息增益比随机部署方法提高了 68.4%,比传统贪婪算法提高了 14.2%,证明了本文算法可获得更好的布局效果.




图 3 不同算法下传感器网络获得的信息增益

4.4 不同模型下损失的对比

由于本文探讨的是节点存在不确定风险情况下

的传感器优化布局,获取较好的布局效益只是目标之一,规避风险也是优化的一个重要目标.规避风险,也就是说降低传感器网络在风险条件下的损失.本文模拟了传感器可能遇到的不确定风险情况,比如节点未部署到预期位置,网络中有节点不能使用等,以信息增益为衡量布局效果的目标函数,令损失为这些不确定情况下传感器网络获得的信息增益与预期部署情况下获得的信息增益之间的差值,分析不同风险情况下传统布局模型以及本文所提模型的损失.

表 1 两种模型下损失对比

不确定情况	传统布局模型的损失	本文布局模型的损失
5 个节点不能使用	2.53	1.27
5 个节点偏离预期位置	0.78	0.43
10 个节点不能使用	3.18	2.85
10 个节点偏离预期位置	1.46	1.06
15 个节点不能使用	4.82	4.21
15 个节点偏离预期位置	2.45	1.95
20 个节点偏离预期位置	2.96	2.31

由表 1 可知,当部署的传感器网络面临不确定风险情况时,本文所提出的基于 CVaR 的布局模型获得的信息增益的损失量比传统布局模型的损失量小,这就说明了当节点出现问题时,本文提出的模型能够更大程度保证较好的布局效果,证明了本文所提布局模型具有良好的鲁棒性.

4.5 不同算法时间复杂度的对比

本文提出的算法在传统贪婪算法中引入 lazy evaluation 来提高算法的效率,通过分析两者在传感器网络需要部署节点个数不同的情况下时间复杂度的差异性来验证本文所提算法的有效性.

时间复杂度描述算法的运行时间.根据上文分析可得,每次加入一个传感器节点,算法需要比较加入所有可选点产生的效益,然后将产生最大效益那个点加入到最优解集中.此过程会耗费大量的运算时间,所以主要比较这部分时间复杂度的不同.在此过程中引入参数 k 来累加所需的比较步骤.由于网络中所需部署传感器节点的总个数对参数 k 有一定的分析,本组对比实验设置为在目标区域部署 5 个、10 个、15 个、20 个、25 个、30 个、35 个、40 个传感器节点的情况下,以信息增益衡量布局效果时,本文所提算法与传统算法在参数 k 上的差异对比.

根据表 2 可知,随着传感器网络规模的不断扩大,本文所提改进算法的 k 明显小于传统贪婪算法,

节省的效率也在不断提高. 说明本文所提算法可大大减少时间复杂度,尤其应用在大规模传感器布局问题时,本文算法更具优越性.

表 2 两种算法下时间复杂度对比

传感器网络规模	传统贪婪算法下的 k	本文所提算法的 k	节省的效率/%
5	420	140	66.67
10	814	231	71.65
15	1185	283	76.12
20	1530	318	79.22
25	1 850	352	80.97
30	2 145	374	82.56
35	2 415	409	83.06

5 结束语

本文讨论节点存在不确定性下的传感器网络的优化布局,采用 CVaR 的子模效益模型来让布局效果以及不确定性情况的损失达到一个动态平衡,并改进贪婪算法,减少算法的时间复杂度并借助参数有序搜索,更快更好求出模型下的部署最优解. 根据实验证明,在本文模型下采用改进贪婪算法对传感器网络进行布局,布局效果有所提高,且在不确定情况下损失也有所减少.

参考文献:

[1] WEI B G, KONG Y Y. Application status of wireless sensor networks in various fields [J]. Electronic Technology and Software Engineering, 2018(7):25.

[2] SRINIVAS N, KRAUSE A, KAKADE S M, et al. Information-theoretic regret bounds for gaussian process optimization in the bandit setting [J]. IEEE Transactions on Information Theory, 2012, 58(5): 3250-3265.

[3] PARK H, HUTCHINSON S. Robust optimal deployment in mobile sensor networks with peer-to-peer communication [C]// IEEE International Conference on Robotics & Automation. Hong Kong, China, IEEE, 2014.

[4] XIONG H, XIE J, DENG X. Risk-averse decision making in overbooking problem [J]. Journal of the Operational Research Society, 2011(62): 1655-1665. DOI: 10.1057/jors.2010.130.

[5] GONZALEZ-LONGATT F, RUEDA J L, DOGDANOV D. Mean variance mapping optimization for the identification of gaussian mixture model; test case [C]// Efficacité énergétique - sources d'énergies renouvelables protection de l'environnement COFRET '12.

IEEE, 2012.

[6] NING Y, WANG X, PAND. VaR for Loan Portfolio in Uncertain Environment [C]// Seventh International Joint Conference on Computational Sciences & Optimization. Beijing, China, IEEE Computer Society, 2014.

[7] ROCKAFELLAR R T. Conditional value-at-risk for general loss distributions [J]. Journal of Banking & Finance, 2002, 26(7):1443-1471.

[8] TAKANORI MAEHARA. Risk averse submodular utility maximization [J]. Operations Research Letters, 2015, 43(5):526-529.

[9] TONG G, WU W, TANG S, et al. Adaptive influence maximization in dynamic social networks [J]. IEEE/ACM Transactions on Networking, 2015, 25(1):112-125.

[10] LOU Y, HONG Y, XIE L, et al. Nash equilibrium computation in subnetwork Zero-Sum games with switching communication [J]. IEEE Transactions on Automatic Control, 2016, 61(10):1-15.

[11] AKRAUSE, CGUESTRIN. Submodularity and its applications in optimized information gathering [J]. ACM Transactions on Intelligent Systems and Technology, 2011, 2(4): 32.

[12] WU W L. Application of VaR in risk management [J]. Modern Commerce, 2008(35):85-86.

[13] TYRRELL ROCKAFELLAR R, STANISLAV UR-YASEV. Optimization of conditional value-at-risk [J]. Journal of risk, 2000(2):21-42.

[14] PIRSIIVASH H, RAMANAN D, FOWLKES C C. Globally-optimal greedy algorithms for tracking a variable number of objects [C]//Proceedings / CVPR, IEEE Computer Society Conference on Computer Vision and Pattern Recognition. IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2011.

[15] KRAUSE A, RAJAGOPAL R, GUPTA A, et al. Simultaneous optimization of sensor placements and balanced schedules [J]. IEEE Transactions on Automatic Control, 2011, 56(10):2390-2405.

作者简介:

谢晓娟 女, (1995-), 硕士研究生. 研究方向为传感器布局优化、子模函数、智能算法.

王耀力(通信作者) 男, (1965-), 博士, 副教授. 研究方向为计算机视觉、机器人、神经网络、智能感知.

E-mail: 1042949978@qq.com.