



# 计算机科学

COMPUTER SCIENCE

## 传感器唤醒机制下的智能干扰源定位方法

杨思星, 李宁, 郭艳, 杨延宇

引用本文

杨思星, 李宁, 郭艳, 杨延宇. 传感器唤醒机制下的智能干扰源定位方法[J]. 计算机科学, 2022, 49(11A): 211000165-6.

YANG Si-xing, LI Ning, GUO Yan, YANG Yan-yu. [Intelligent Jammers Localization Scheme Under Sensor Sleep-Wakeup Mechanism](#) [J]. Computer Science, 2022, 49(11A): 211000165-6.

---

## 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

### [改进的粒子群蒙特卡洛WSN节点定位算法](#)

Improved Particle Swarm Monte Carlo WSN Node Location Algorithm

计算机科学, 2022, 49(11A): 210900156-5. <https://doi.org/10.11896/jsjcx.210900156>

### [基于深度神经网络的块压缩感知图像重构](#)

Block-based Compressed Sensing of Image Reconstruction Based on Deep Neural Network

计算机科学, 2022, 49(11A): 210900118-9. <https://doi.org/10.11896/jsjcx.210900118>

### [基于行为树调度的多无人机未知室内空间探索方法](#)

Multi-UAV Cooperative Exploring for Large Unknown Indoor Environment Based on Behavior Tree

计算机科学, 2022, 49(11A): 210900083-11. <https://doi.org/10.11896/jsjcx.210900083>

### [高分辨率斜视聚束SAR回波仿真加速算法研究](#)

Study on Acceleration Algorithm for Raw Data Simulation of High Resolution Squint Spotlight SAR

计算机科学, 2022, 49(8): 178-183. <https://doi.org/10.11896/jsjcx.210600066>

### [基于数据增广和模型集成策略的图神经网络在抑郁症识别上的应用](#)

Application of Graph Neural Network Based on Data Augmentation and Model Ensemble in

Depression Recognition

计算机科学, 2022, 49(7): 57-63. <https://doi.org/10.11896/jsjcx.210800070>

# 传感器唤醒机制下的智能干扰源定位方法

杨思星<sup>1,2</sup> 李宁<sup>1</sup> 郭艳<sup>1</sup> 杨延宇<sup>2</sup>

1 陆军工程大学通信工程学院 南京 210000

2 94701 部队 安徽 安庆 246000

(yangsixing01@sina.com)

**摘要** 随着人工智能技术的发展,智能干扰源可通过改变自身发射功率来提高干扰效果,导致传统基于接收信号强度的定位技术失效。为此,引入传感器唤醒机制,研究基于块压缩感知的多干扰源定位方法。首先,周期性地唤醒传感器节点,同时提高传感器节点利用有效性和定位信息采集精确性;其次,考虑到在干扰源发射功率未知且变化的情况下无法确定距离与接收信号强度之间的关系,引入参考功率对智能变化的干扰源功率进行处理;然后,基于压缩感知理论,将定位问题建模为块稀疏向量重构问题;最后,通过探索功率变化规律设计出一种基于变分贝叶斯均值-期望的 Wake-VBEM 重构算法,精确重构目标位置向量。仿真证明,所提方法在干扰源功率未知且变化时,可同时实现多干扰源位置估计并有效提高网络使用寿命。

**关键词:** 干扰源定位;无线传感器网络;传感器唤醒;块压缩感知;变分贝叶斯均值-期望

**中图分类号** TN919

## Intelligent Jammers Localization Scheme Under Sensor Sleep-Wakeup Mechanism

YANG Si-xing<sup>1,2</sup>, LI Ning<sup>1</sup>, GUO Yan<sup>1</sup> and YANG Yan-yu<sup>2</sup>

1 Institute of Communication Engineering, Army Engineering University of PLA, Nanjing 210000, China

2 The PLA Unit 94701, Anqing, Anhui 246000, China

**Abstract** Intelligent jammer can change its transmitting power to improve the jamming effect adaptively with the developing artificial intelligence(AI) technique, making the traditional localization scheme out of work. Therefore, this paper investigates the block compressive sensing(BCS) based multi-jammer localization scheme under sensor wake-up mechanism. Firstly, the sensor nodes are periodically awakened to prolong the lifetime of the network and to collect more accurate localization information. Secondly, this paper introduces the reference power to avoid the issue that the relationship between the distance and the varying power are unknown. Thirdly, we utilize the compressive sensing(CS) theory to build the localization issue as a BCS recovery problem. Finally, a novel Wake-VBEM algorithm under the variational Bayesian mean-expect is proposed by exploring the power variation law. Simulations show that the proposed method can simultaneously estimate the location of multi-jammers and prolong the lifetime of the network even the power of the jammer is unknown and varying.

**Keywords** Jammer localization, Wireless sensor networks, Sensor wakeup, Block compressive sensing, Variational Bayesian meanexpect

## 1 引言

无线传感器网络(Wireless Sensor Networks, WSN)由低成本、低功耗的传感器节点组成,被广泛应用于日常生产、生活以及国防军事等领域<sup>[1]</sup>。WSN 具有天然的开放特性,攻击者常通过部署干扰机来影响无线信号的传输,从而破坏 WSN 中信息交互的安全性和可靠性。

现有的频谱抗干扰措施通过提升技术方案来确保通信质量,如直接序列扩频、跳频技术和智能抗干扰技术等<sup>[2-3]</sup>。然而,这类方法实现复杂度高,需占用大量的带宽和存储资源,且无法从根本上消除恶意干扰问题。干扰源定位不仅可以为抗干扰技术提供技术保障,如干扰定向消除等,而且可以帮助

实现干扰源精确打击<sup>[4]</sup>,从根本上消除恶意干扰源。

基于接收信号强度(Received Signal Strength, RSS)的干扰源定位技术通过采集干扰源的 RSS 来定位,不需要传感器节点发送任何信号,具有操作简单、安全性高以及应用广泛等优点<sup>[5]</sup>。该方法可在隐藏自身的情况下实现对干扰源的定位<sup>[6]</sup>,因此成为了对干扰源进行定位的一种有效措施。文献[7]提出了一种分布式的基于 RSS 的干扰源定位算法,其根据梯度思想沿着 RSS 上升方向逼近干扰源,但该算法仅能够实现单一干扰源定位。文献[8]研究短距通信下干扰源定位方法,根据是否受到干扰源影响,采用聚类方法实现定位,定位精度较低。随着恶意干扰源智能化水平不断提高,干扰源可改变自身发射功率来增强干扰效果<sup>[9]</sup>。而基于 RSS 的定

基金项目:国家自然科学基金(61871400);江苏省自然科学基金(BK20211227)

This work was supported by the National Natural Science Foundation of China(61871400)and Natural Science Foundation of Jiangsu Province, China(BK20211227).

通信作者:李宁(lining\_friend@sina.com)

位方法依靠信号衰减估计其位置,但干扰源发射功率变化后功率衰减很难计算,因此无法完成定位。此外,为提高定位精度,通常需要部署数目巨大的传感器节点,但传感器节点为电池供电,其能量有限,大量应用会严重阻碍传感器网络的发展<sup>[10]</sup>。

基于此,本文研究针对多智能干扰源的节能定位方法,在传感器唤醒机制下设计了基于变分贝叶斯期望-均值(Variational Bayesian Expect-Mean, VBEM)<sup>[11]</sup>的 Wake-VBEM 算法。该方法通过周期性地唤醒传感器节点来提高网络的使用寿命并获取更多的定位数据,同时引入参考功率来解决干扰源功率变化导致的无法定位问题,其主要创新点如下:

(1)设计传感器休眠-唤醒机制,通过周期性地唤醒传感器以采集更多的定位信息并延长传感器节点使用寿命。

(2)引入参考功率,解决干扰源功率变化导致感知字典无法获得的问题,进而采用块压缩感知(Block Compressive Sensing, BCS)原理<sup>[12]</sup>,将定位问题建模为块稀疏向量重构问题。

(3)基于 VBEM 算法设计相关矩阵来探索干扰源功率变化规律,设计基于干扰源功率变化的相关矩阵实现精确的位置向量重构。

## 2 模型建立

为解决干扰源功率智能变化下的定位问题,采用传感器唤醒机制采集数据并引入压缩感知理论建立定位模型。为重构出位置向量,在基于 VBEM 的框架下设计重构算法,具体的操作流程如图 1 所示。

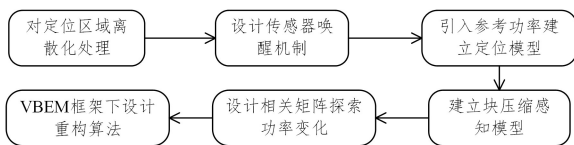


图 1 传感器唤醒机制下的智能干扰源定位流程图

Fig. 1 Flow diagram of intelligent jammers localization scheme under sleep-wakeup mechanism

### 2.1 压缩感知定位模型

压缩感知理论<sup>[13]</sup>针对离散的稀疏信号进行重构,将其引入定位中需要将定位区域进行离散化处理。如图 2 所示,将定位区域划分为  $N$  个网格并依次编号(这里以正方形区域为例,其他任意形状的定位区域按此办法处理)。

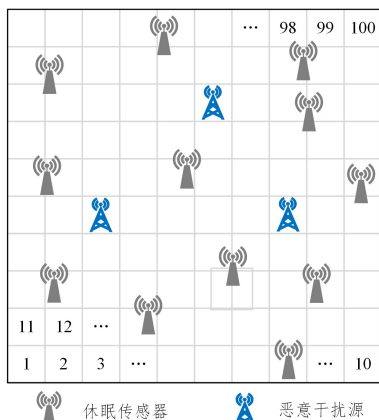


图 2 压缩感知定位场景图

Fig. 2 CS-based localization scheme

干扰源位置不确定,可随机分布在任意网格中,用一个稀疏向量  $\mathbf{s}$  描述其位置:

$$\mathbf{s} = [0, 1, 0, \dots, 0, 1, 0, \dots, 0] \quad (1)$$

若  $s_i = 1$ ,则代表第  $i$  个网格中存在一个干扰源;否则不存在。若定位区域中存在  $Q$  个传感器节点采集定位信息,则定位方程如下:

$$\mathbf{y}_Q = \mathbf{\Psi}_Q \times \mathbf{s}_N + \mathbf{n}_Q \quad (2)$$

其中,  $\mathbf{y}_Q$  表示第  $Q$  个传感器节点采集的所有干扰源的 RSS 之和;  $\mathbf{\Psi}$  为感知字典,用来刻画干扰源位置与 RSS 之间的关系,  $\mathbf{\Psi}_m$  表示干扰源处于第  $q$  个网格时第  $n$  个传感器节点的 RSS<sup>[14]</sup>,其表达式如下:

$$\mathbf{\Psi}_m = P_n f(S_q, J_n) \quad (3)$$

其中,  $P_n$  为位于第  $n$  个网格中干扰源的发射功率;  $S_q$  和  $J_n$  分别为第  $q$  个传感器节点和第  $n$  个干扰源的坐标;  $f$  表示干扰源与传感器节点的关系。显然,  $\mathbf{\Psi}_m$  受干扰源发射功率和其与传感器节点距离的影响。此时,一旦获得了位置向量  $\mathbf{s}$ ,即可对应干扰源坐标。

### 2.2 传感器唤醒机制设计

在 CS 框架下引入传感器唤醒机制具有以下优势:1)周期性地唤醒传感器节点,可节约能量并延长网络使用寿命;2)唤醒不同的传感器节点,可采集更多且更有效的定位信息;3)在 CS 框架下实现定位,可使每次唤醒的无线链路数目尽可能少。

此时,唤醒策略的设计可建模为观测矩阵的建造,令  $l = 1, 2, \dots, L$  为采样时刻,则:

$$\mathbf{y}_M^{(l)} = \mathbf{\Phi}_M^{(l)} \mathbf{\Phi}_Q^{(l)} \mathbf{s}_N + \mathbf{n}_M^{(l)} = \mathbf{A}_M^{(l)} \mathbf{s}_N + \mathbf{n}_M^{(l)} \quad (4)$$

其中,  $\mathbf{A}^{(l)}$ ,  $\mathbf{y}^{(l)}$  和  $\mathbf{n}^{(l)}$  分别为第  $l$  次采样时的感知矩阵、测量向量以及噪声向量,这里假定每次唤醒的无线链路数目一致;  $\mathbf{s}_N$  表示干扰源位置不变;  $\mathbf{\Phi}^{(l)}$  为第  $l$  次的采样矩阵,其每行仅有一个元素为 1,指示第  $l$  次唤醒的无线链路索引。

对无线链路唤醒策略的设计,体现在压缩感知定位模型中就是设计观测矩阵  $\mathbf{\Phi}$ ,其非 0 元素的位置代表了被唤醒的无线链路。本文设计了随机唤醒策略,即观测矩阵  $\mathbf{\Phi}_R$  中非 0 元素的位置随机产生,且每一行只有一个 1。

### 2.3 唤醒机制下的定位模型建立

智能干扰源通过改变功率影响通信,导致 CS 模型中的感知字典  $\mathbf{\Phi}^{(l)}$  无法建立。为解决该问题,引入参考功率  $P_0$ 。若干扰源在第  $l$  个采样时刻的功率为  $P_l$ ,则定位模型可表示如下:

$$\mathbf{y}^{(l)} = \mathbf{A}^{(l)} \mathbf{s}^{(l)} = \mathbf{D}^{(l)} \mathbf{w}^{(l)}, l = 1, 2, \dots, L \quad (5)$$

其中,  $\mathbf{y}^{(l)}$ ,  $\mathbf{A}^{(l)}$  和  $\mathbf{s}^{(l)}$  分别为第  $l$  次采样时的测量向量、感知矩阵和位置向量。  $\mathbf{A}^{(l)}$  的建立如式(3)所示,需要已知干扰源的功率  $P_l$ ,但在干扰源功率变化时无法实现,因此引入参考发射功率,则:

$$\begin{aligned} \mathbf{y}_m^{(l)} &= \sum_{n=1}^N P_n^{(l)} f(S_m, J_n^{(l)}) \\ &= \sum_{n=1}^N \omega_n^{(l)} P_{n_0}^{(l)} f(S_m, J_n^{(l)}) \\ &= \sum_{n=1}^N \omega_n^{(l)} \mathbf{D}_{nm}^{(l)} \end{aligned} \quad (6)$$

其中,  $P_n^{(l)}$  和  $P_{n_0}^{(l)}$  为第  $l$  个采样时刻位于第  $n$  个网格中的干扰源发射功率和参考功率。  $\mathbf{D}^{(l)}$  为对应于参考功率  $P_{n_0}^{(l)}$  的感知字典。此时位置向量  $\mathbf{w}^{(l)}$  定义如下:

$$P_n^{(l)} = \omega_n^{(l)} P_{n_0}^{(l)} \quad (7)$$

显然,  $\mathbf{w}^{(l)}$  的元素虽不是非 0 即 1 的, 但非 0 元素的索引可指示目标位置。若  $\omega_n^{(l)} \neq 0$ , 则表示第  $n$  个网格中不存在干扰源。

问题(5)涉及到多个测量向量的重构问题, 然而, 传统的多测量向量(Multiple Measurement Vectors, MMV)一般要求感知矩阵一致, 很难解决上述问题。基于此, 本文引入 BCS 理论, 通过探索干扰源功率变化规律来提高定位精度, 可解决感知矩阵和位置向量都不一致时的重构问题。

## 2.4 块压缩感知定位模型建立

要探索干扰源功率变化规律, 首先要对定位方程进行向量化操作:

$$\tilde{\mathbf{y}}_{ML \times 1} = \tilde{\mathbf{D}}_{ML \times NL} \tilde{\mathbf{w}}_{NL \times 1} + \tilde{\mathbf{n}}_{ML \times 1} \quad (8)$$

其中,  $\tilde{\mathbf{y}}$ ,  $\tilde{\mathbf{D}}$ ,  $\tilde{\mathbf{w}}$  和  $\tilde{\mathbf{n}}$  分别为向量化之后的测量向量、感知矩阵、位置向量和噪声向量, 如图 3 所示。




图 3 块压缩感知示意图

Fig. 3 Illustration of BCS

块稀疏向量  $\tilde{\mathbf{w}}$  由  $\mathbf{W} = [\mathbf{w}^{(1)}, \mathbf{w}^{(2)}, \dots, \mathbf{w}^{(L)}]$  组成且:

$$\tilde{\mathbf{w}} = \text{vec}(\mathbf{W}^T) \quad (9)$$

其中,  $\tilde{\mathbf{w}}$  由  $N$  个长度为  $L$  的块组成, 具有块稀疏性, 其第  $i$  个块包含所有  $L$  个采样时刻第  $i$  个格点的干扰源位置信息, 定义为:

$$\tilde{\mathbf{w}}_i = [\omega_i^{(1)}, \omega_i^{(2)}, \dots, \omega_i^{(L)}]^T \quad (10)$$

转化后的感知矩阵  $\tilde{\mathbf{D}}$  定义为:

$$\tilde{\mathbf{D}} = \mathbf{D} \otimes \mathbf{I}_L \quad (11)$$

其中, 符号  $\otimes$  和  $\mathbf{I}_L$  分别表示克罗内克积和  $L$  维的单位阵。令

$\tilde{\mathbf{D}} = [\tilde{\mathbf{D}}_1, \tilde{\mathbf{D}}_2, \dots, \tilde{\mathbf{D}}_N]$ , 则元素  $\tilde{\mathbf{D}}_n$  为:

$$\tilde{\mathbf{D}}_n = \begin{bmatrix} \mathbf{D}^{(1)}(:, n) & 0 & \dots & 0 \\ 0 & \mathbf{D}^{(2)}(:, n) & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \mathbf{D}^{(L)}(:, n) \end{bmatrix} \quad (12)$$

其中,  $\mathbf{D}^{(l)}(:, n)$  表示  $\mathbf{D}^{(l)}$  的第  $n$  列。此时, 转化后的测量向量  $\tilde{\mathbf{y}}$  变为:

$$\tilde{\mathbf{y}} = \text{vec}([\mathbf{y}^{(1)}, \mathbf{y}^{(2)}, \dots, \mathbf{y}^{(L)}]) \quad (13)$$

由于不同采样时刻的噪声一般相互独立且为高斯分布。因此, 转化之后  $\tilde{\mathbf{n}}$  也为高斯白噪声。

至此, 将传感器唤醒模式下基于压缩感知的干扰源定位问题建模为块稀疏重构问题, 定位的目的就是在已知  $\tilde{\mathbf{D}}$  和  $\tilde{\mathbf{y}}$  的条件下, 重构出位置向量  $\tilde{\mathbf{w}}$ 。

## 3 重构算法设计

### 3.1 贝叶斯框架下的参数分析

为解决问题, 设计出一种 VBEM 框架下的算法 Wake-

VBEM。首先在贝叶斯框架<sup>[15]</sup>下分析模型中的参数, 如图 4 所示。




图 4 定位参数之间的关系示意图

Fig. 4 Relation of parameters of localization model

$\tilde{\mathbf{w}}$  由  $L$  个具有稀疏性的位置向量  $\mathbf{w}^{(l)}$  构成, 其与  $\mathbf{W}$  具有相同的支撑集。为了探索  $\tilde{\mathbf{w}}$  的块稀疏特性, 可从  $\mathbf{w}$  出发假定其服从二层的高斯分布且第一层高斯分布如下:

$$\begin{aligned} p(\mathbf{w} | \boldsymbol{\alpha}) &= \prod_{i=1}^N N(\mathbf{w}_i | 0, \alpha_i^{-1}) \\ &= \frac{1}{(2\pi)^{N/2} |\mathbf{B}|^{-1/2}} \exp\left(-\frac{1}{2} \mathbf{w}^T \mathbf{B} \mathbf{w}\right) \end{aligned} \quad (14)$$

其中,  $\alpha_i^{-1}$  为参数  $\omega_i$  的方差。  $\mathbf{w}$  的协方差矩阵可定义为  $\mathbf{B} = \text{diag}(\alpha_1^{-1}, \alpha_2^{-1}, \dots, \alpha_N^{-1})$ 。令:

$$\boldsymbol{\alpha} = [\alpha_1, \alpha_2, \dots, \alpha_N] \quad (15)$$

在第二层  $\boldsymbol{\alpha}$  服从参数为  $a$  和  $b$  的 Gamma 分布:

$$p(\boldsymbol{\alpha}; a, b) = \prod_{i=1}^N \text{Gamma}(\alpha_i | a, b) \quad (16)$$

$\tilde{\mathbf{w}}$  的第  $i$  个系数块  $\tilde{\mathbf{w}}_i$  包含了干扰源的位置和功率变化信息, 因此引入相关矩阵  $\mathbf{R}_i$  来探索干扰源功率的变化规律:

$$\begin{aligned} p(\tilde{\mathbf{w}}_i; \alpha_i, \mathbf{R}_i) &= N(\tilde{\mathbf{w}}_i | 0, \alpha_i^{-1} \mathbf{R}_i) \\ &= \frac{1}{(2\pi)^{L/2} |\alpha_i^{-1} \mathbf{R}_i|^{1/2}} \exp\left(-\frac{1}{2} \tilde{\mathbf{w}}_i^T \alpha_i \mathbf{R}_i^{-1} \tilde{\mathbf{w}}_i\right) \end{aligned} \quad (17)$$

其中,  $\mathbf{R}_i$  是  $L \times L$  的正定矩阵, 则块稀疏向量  $\tilde{\mathbf{w}}$  的先验概率分布为高斯分布:

$$p(\tilde{\mathbf{w}}; \{\alpha_i, \mathbf{R}_i\}_i^N) = N(\tilde{\mathbf{w}} | 0, \tilde{\boldsymbol{\Sigma}}) \quad (18)$$

其中,  $\tilde{\boldsymbol{\Sigma}}$  为  $\tilde{\mathbf{w}}$  的协方差矩阵:

$$\tilde{\boldsymbol{\Sigma}} = \begin{bmatrix} \alpha_1^{-1} \mathbf{R}_1 & 0 & \dots & 0 \\ 0 & \alpha_2^{-1} \mathbf{R}_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \alpha_N^{-1} \mathbf{R}_N \end{bmatrix} \quad (19)$$

实际中的噪声  $\mathbf{n}^{(l)}$  为高斯噪声, 其均值为 0 且方差为  $\beta$ 。考虑到各个采样时刻的噪声向量  $\mathbf{n}^{(l)}$  相互独立, 因此:

$$p(\tilde{\mathbf{n}} | \beta) = N(\tilde{\mathbf{n}} | 0, \beta \mathbf{I}) \quad (20)$$

其中,  $\mathbf{I}$  是大小为  $LM$  的单位矩阵。为适应多变的环境, 令  $\beta$  服从参数为  $c$  和  $d$  的 Gamma 分布:

$$p(\beta; c, d) = \text{Gamma}(\beta | c, d) \quad (21)$$

根据式(8)和式(20)可得条件概率  $p(\tilde{\mathbf{y}} | \tilde{\mathbf{w}}, \beta)$  为:

$$p(\tilde{\mathbf{y}} | \tilde{\mathbf{w}}, \beta) = (2\pi\beta^{-1})^{-\frac{ML}{2}} \exp\left(-\frac{\beta}{2} \|\tilde{\mathbf{y}} - \tilde{\mathbf{A}}\tilde{\mathbf{w}}\|_2^2\right) \quad (22)$$

此时, 依据全概率公式, 计算后验概率  $p(\tilde{\mathbf{w}}, \boldsymbol{\alpha}, \beta | \tilde{\mathbf{y}})$  如下:

$$\begin{aligned} p(\tilde{\mathbf{w}}, \boldsymbol{\alpha}, \beta | \tilde{\mathbf{y}}) &= \\ &= \frac{p(\tilde{\mathbf{y}} | \tilde{\mathbf{w}}, \beta) p(\tilde{\mathbf{w}}; \{\alpha_i, \mathbf{R}_i\}_{i=1}^N) p(\boldsymbol{\alpha}) p(\beta)}{p(\tilde{\mathbf{y}})} \end{aligned} \quad (23)$$

其中, 分子上参数的概率  $p(\tilde{\mathbf{y}} | \tilde{\mathbf{w}}, \beta)$ ,  $p(\tilde{\mathbf{w}}; \{\alpha_i, \mathbf{R}_i\}_{i=1}^N)$ ,  $p(\boldsymbol{\alpha})$  和  $p(\beta)$  可分别通过式(22)、式(17)、式(16)和式(21)获得, 而分母上的概率  $p(\tilde{\mathbf{y}})$  则需要通过积分求解, 实际中很难甚至

无法计算。由图 4 可知,块稀疏向量  $\tilde{\mathbf{w}}$ , 转化噪声信号  $\tilde{\mathbf{n}}$  及其依赖参数  $\alpha, \beta$  等相互独立。此时根据 VBEM 思想,假定后验概率相互独立,则  $p(\tilde{\mathbf{w}}, \alpha, \beta | \tilde{\mathbf{y}})$  可以近似计算为:

$$p(\tilde{\mathbf{w}}, \alpha, \beta | \tilde{\mathbf{y}}; a, b, c, d) \approx q(\tilde{\mathbf{w}})q(\alpha)q(\beta) \quad (24)$$

其中,  $q(\tilde{\mathbf{w}})$ ,  $q(\alpha)$  和  $q(\beta)$  分别为  $\tilde{\mathbf{w}}$ ,  $\alpha$  和  $\beta$  的后验分布。而作为探索  $\tilde{\mathbf{w}}$  中各个块之间关系的矩阵  $\mathbf{R}_i$ , 可进行设计。这样就避免了对复杂积分  $p(\tilde{\mathbf{y}})$  的求解。

### 3.2 VBEM 框架下的重构算法设计

在 VBEM 框架下解决该问题,主要包括两个过程,在 E-步,固定当前迭代求解的  $\mathbf{R}_i$ , 分别更新参数  $\tilde{\mathbf{w}}$ ,  $\alpha$  和  $\beta$ ; 在 M-步,固定当前迭代值  $\tilde{\mathbf{w}}$ ,  $\alpha$  和  $\beta$ , 设计有效的相关矩阵  $\mathbf{R}_i$  来探索功率变化规律。交替执行 E-步和 M-步,算法收敛时可获得最终结果。

#### 3.2.1 定位模型参数更新

首先更新块稀疏向量  $\tilde{\mathbf{w}}$  如下:

$$\begin{aligned} \ln q(\tilde{\mathbf{w}}) &= \langle \ln p(\tilde{\mathbf{y}} | \tilde{\mathbf{w}}, \alpha, \beta) \rangle_{q(\alpha)q(\beta)} + C \\ &= \langle \ln p(\tilde{\mathbf{y}} | \tilde{\mathbf{w}}, \beta) p(\tilde{\mathbf{w}}_i; \{\alpha_i, \mathbf{R}_i\}_1^N) \rangle_{q(\alpha)q(\beta)} + C \\ &= -\frac{1}{2} \tilde{\boldsymbol{\theta}}^T (\langle \beta \rangle \tilde{\mathbf{D}}^T \tilde{\mathbf{D}} + \boldsymbol{\Sigma}^{-1}) \tilde{\boldsymbol{\theta}} + \langle \beta \rangle \tilde{\boldsymbol{\theta}}^T \tilde{\mathbf{D}}^T \tilde{\mathbf{y}} + C \end{aligned} \quad (25)$$

$\tilde{\mathbf{w}}$  服从参数为  $\boldsymbol{\mu}$  和  $\boldsymbol{\Sigma}$  的高斯分布,且:

$$\boldsymbol{\mu} = \langle \beta \rangle \boldsymbol{\Sigma} \tilde{\boldsymbol{\theta}}^T \tilde{\mathbf{D}}^T \quad (26)$$

$$\boldsymbol{\Sigma} = (\langle \beta \rangle \tilde{\mathbf{D}}^T \tilde{\mathbf{D}} + \tilde{\boldsymbol{\Sigma}}^{-1})^{-1} \quad (27)$$

其中,  $\langle \beta \rangle \tilde{\mathbf{D}}^T \tilde{\mathbf{D}} + \tilde{\boldsymbol{\Sigma}}^{-1}$  为  $LN \times LN$  ( $M \ll N$ ) 的方阵,该矩阵尺寸大,求逆运算复杂度高。因此采用如下的方式来简化  $\boldsymbol{\Sigma}$  求解:

$$\boldsymbol{\Sigma} = \tilde{\boldsymbol{\Sigma}}^{-1} - \tilde{\boldsymbol{\Sigma}}^{-1} \tilde{\mathbf{D}}^T \mathbf{E}^{-1} \tilde{\mathbf{D}} \tilde{\boldsymbol{\Sigma}}^{-1} \quad (28)$$

其中,  $\tilde{\boldsymbol{\Sigma}}$  为  $\tilde{\mathbf{w}}$  的协方差矩阵,其逆矩阵很容易计算,而矩阵  $\mathbf{E}$  定义为:

$$\mathbf{E} = \langle \beta \rangle^{-1} \mathbf{I} + \tilde{\mathbf{D}} \tilde{\boldsymbol{\Sigma}}^{-1} \tilde{\mathbf{D}}^T \quad (29)$$

其中,  $\mathbf{E}$  是一个  $LM \times LM$  的矩阵,其逆运算比  $\langle \beta \rangle \tilde{\mathbf{D}}^T \tilde{\mathbf{D}} + \tilde{\boldsymbol{\Sigma}}^{-1}$  简单得多。该优化可以将逆运算复杂度由  $O(L^3 N^3)$  降低到  $O(L^3 M^3)$ , 极大地提高了算法运算效率。

然后,用同样的方法更新参数  $\alpha$ :

$$\begin{aligned} \ln q(\alpha) &= \langle \ln p(\tilde{\mathbf{y}} | \tilde{\mathbf{w}}, \alpha, \beta) \rangle_{q(\alpha)q(\tilde{\boldsymbol{\theta}})} + C \\ &= \langle \ln p(\tilde{\mathbf{w}}; \{\alpha_i, \mathbf{R}_i\}_1^N) p(\alpha) \rangle_{q(\tilde{\boldsymbol{\theta}})} + C \end{aligned} \quad (30)$$

将式(16)和式(18)带入可得  $\alpha$  的后验概率服从 Gamma 分布:

$$p(\alpha; \tilde{a}_i, \tilde{b}_i) = \prod_{i=1}^N \text{Gamma}(\alpha_i | \tilde{a}_i, \tilde{b}_i) \quad (31)$$

且参数  $\tilde{a}_i$  和  $\tilde{b}_i$  分别为:

$$\tilde{a}_i = a + \frac{L}{2} \quad (32)$$

$$\tilde{b}_i = b_i + \frac{1}{2} \text{tr}(\mathbf{R}_i^{-1} (\boldsymbol{\Sigma}_i + \boldsymbol{\mu}_i \boldsymbol{\mu}_i^T)) \quad (33)$$

其中,  $\text{tr}(\cdot)$  为矩阵的迹。 $\boldsymbol{\mu}_i$  和  $\boldsymbol{\Sigma}_i$  分别为  $\tilde{\mathbf{w}}_i$  的均值和协方差矩阵。

最后,更新噪声向量  $\tilde{\mathbf{n}}$  的方差  $\beta$  为:

$$\begin{aligned} \ln q(\beta) &= \langle \ln p(\tilde{\mathbf{y}} | \tilde{\mathbf{w}}, \alpha, \beta) \rangle_{q(\alpha)q(\tilde{\boldsymbol{\theta}})} + C \\ &= \langle \ln p(\tilde{\mathbf{y}} | \tilde{\mathbf{w}}, \beta) p(\beta) \rangle_{q(\alpha)q(\tilde{\boldsymbol{\theta}})} + C \end{aligned} \quad (34)$$

显然,  $\beta$  的后验概率服从参数为  $\tilde{c}$  和  $\tilde{d}$  的 Gamma 分布:

$$\tilde{c} = c + \frac{ML}{2} \quad (35)$$

$$\tilde{d} = d + \frac{1}{2} (\|\tilde{\mathbf{y}} - \tilde{\mathbf{A}}\boldsymbol{\mu}\|_2^2) + \text{tr}(\tilde{\mathbf{A}}\boldsymbol{\Sigma}\tilde{\mathbf{A}}^T) \quad (36)$$

至此,我们在 E-步分别完成了基于相关矩阵  $\mathbf{R}_i$  的参数  $\tilde{\mathbf{w}}$ ,  $\alpha$  以及  $\beta$  的估计。接下来,在 M-步设计相关矩阵  $\mathbf{R}_i$ 。

#### 3.2.2 相关矩阵的设计

$\tilde{\mathbf{w}}$  由  $N$  个长度为  $L$  的块组成,要对每一个干扰源的功率变化进行精确描述,需要设计  $N$  个相关矩阵  $\{\mathbf{R}_i\}_{i=1}^N$ 。然而,若  $\mathbf{R}_i$  数目远大于  $M$ ,会导致过拟合问题。为解决该问题,用固定矩阵  $\mathbf{R}$  描述所有稀疏块之间的关系。此时,根据 M-步的计算方法,最大化函数  $Q(\mathbf{R}, \mathbf{R}^{\text{old}})$  来更新  $\mathbf{R}$ :

$$\begin{aligned} \tilde{\mathbf{R}} &= \arg \max_{\mathbf{R}} Q(\mathbf{R}, \mathbf{R}^{\text{old}}) \\ &= \arg \max_{\mathbf{R}} \langle \ln p(\tilde{\mathbf{y}} | \tilde{\mathbf{w}}, \alpha, \beta; \mathbf{R}) \rangle_{q(\alpha)q(\tilde{\boldsymbol{\theta}})q(\beta)} \\ &= \arg \max_{\mathbf{R}} \langle \ln p(\tilde{\mathbf{w}} | \alpha; \mathbf{R}) \rangle_{q(\alpha)} \end{aligned} \quad (37)$$

其中,  $\mathbf{R}^{\text{old}}$  和  $\tilde{\mathbf{R}}$  分别为  $\mathbf{R}$  的上次迭代和当前迭代估计值。由式(18)和式(19)可得:

$$p(\tilde{\mathbf{w}} | \alpha; \mathbf{R}) = N(0, \mathbf{B}^{-1} \otimes \mathbf{R}) \quad (38)$$

则问题(37)可等价于:

$$\begin{aligned} \tilde{\mathbf{R}} &= \arg \min_{\mathbf{R}} \{N \ln |\mathbf{R}| + \langle \tilde{\boldsymbol{\theta}}^T (\mathbf{B}^{-1} \otimes \mathbf{R}) \tilde{\boldsymbol{\theta}} \rangle_{q(\alpha)}\} \\ &= \arg \min_{\mathbf{R}} \{N \ln |\mathbf{R}| + \text{tr}[(\mathbf{B}^{-1} \otimes \mathbf{R}) \tilde{\boldsymbol{\Sigma}} + \tilde{\boldsymbol{\mu}} \tilde{\boldsymbol{\mu}}^T]\} \end{aligned} \quad (39)$$

采用函数求导方法解决该极值问题,定义以  $\mathbf{R}$  为变量的函数  $f(\mathbf{R})$ :

$$f(\mathbf{R}) = N \ln |\mathbf{R}| + \text{tr}[(\mathbf{B}^{-1} \otimes \mathbf{R}) \tilde{\boldsymbol{\Sigma}} + \tilde{\boldsymbol{\mu}} \tilde{\boldsymbol{\mu}}^T] \quad (40)$$

其一阶导数为:

$$\frac{\partial f(\mathbf{R})}{\partial \mathbf{R}} = N \mathbf{R}^{-1} - \sum_{i=1}^N \alpha_i \mathbf{R}^{-1} (\tilde{\boldsymbol{\Sigma}}_i + \tilde{\boldsymbol{\mu}}_i \tilde{\boldsymbol{\mu}}_i^T) \mathbf{R}^{-1} \quad (41)$$

实际问题中,依据导数性质,函数极小值一般为整个函数的最小值。令一阶导数值为 0,可更新感知矩阵  $\mathbf{R}$  为:

$$\mathbf{R} = \frac{1}{N} \sum_{i=1}^N \alpha_i (\tilde{\boldsymbol{\Sigma}}_i + \tilde{\boldsymbol{\mu}}_i \tilde{\boldsymbol{\mu}}_i^T) \quad (42)$$

以上研究了传感器唤醒条件下的多干扰源定位方法。算法以 VBEM 为框架,交替执行 E-步和 M-步至收敛,估计  $\tilde{\mathbf{w}}$ 。

#### 算法 1 Wake-VBEM 算法流程图

输入:  $\tilde{\mathbf{y}}, \tilde{\mathbf{D}}, \tau_{\max}, \delta_{\min}$

输出: 根据式(44)输出估计位置向量  $\tilde{\mathbf{w}}$

初始化:

1. 初始化迭代次数  $\tau = 0$ ;
2. 初始化相关矩阵  $\mathbf{R} = \mathbf{I}_L$ ;
3. 初始化参数  $a = b = c = d = 10^{-6}$ ;
4. 根据式(16)、式(21)和式(18)初始化  $\alpha^{(0)}$ ,  $\beta^{(0)}$  和  $\tilde{\mathbf{w}}^{(0)}$  的先验分布;

- 迭代:
1. 更新迭代次数  $\tau = \tau + 1$ ;
2. 根据式(31)一式(33)更新  $q(\alpha^{(\tau)})$ ;
3. 根据式(35)和式(36)更新  $q(\beta^{(\tau)})$  的后验概率;
4. 根据式(26)、式(28)和式(29)更新  $q(\tilde{\mathbf{w}}^{(\tau)})$  的后验概率;
5. 根据式(42)更新相关矩阵  $\mathbf{R}$ ;
6. 根据式(43)计算相对误差  $\delta$ ;
7. 若  $\tau < \tau_{\max}$  且  $\delta > \delta_{\min}$ , 转步骤 1; 否则转步骤 8;
8. 根据式(26)将当前  $\boldsymbol{\mu}$  作为  $\tilde{\mathbf{w}}$  的最终估计值。

参数  $a, b, c, d$  数值较小时几乎不会为模型提供先验信息,故令  $a = b = c = d = 10^{-6}$  以避免提供错误的先验概率。

此外,干扰源功率变化无规律且无法预先知道,故设定  $\mathbf{R}=\mathbf{I}_L$  为初始值。设计参数  $\alpha$  的相对误差值  $\delta$  来控制收敛结果:

$$\delta = \frac{\|\alpha^{(\tau)} - \alpha^{(\tau-1)}\|_2}{\|\alpha^{(\tau)}\|_2} \quad (43)$$

当  $\delta$  达到门限  $\delta_{\min}$  或者迭代次数  $\tau$  达到最大值  $\tau_{\max}$  时,迭代结束。此时,获得估计的块稀疏信号  $\tilde{\mathbf{w}} = \boldsymbol{\mu}$ 。根据式(5),  $\mathbf{w}^{(l)}$  中最大  $K$  个元素索引代表相同干扰源位置信息,故干扰源位置向量  $\bar{\mathbf{w}}$  计算为:

$$\bar{w}_i = \frac{1}{L} \sum_{l=1}^L \mu_i^{(l)} \quad (44)$$

其中,  $\mu_i^{(l)}$  表示  $\tilde{\mathbf{w}}$  的第  $i$  个稀疏块  $\tilde{\mathbf{w}}_i$  的第  $l$  个元素的估计值。

## 4 仿真实验

在 Matlab 中对本文提出的智能干扰源定位算法 Wake-VBEM 进行验证。将  $12\text{m} \times 12\text{m}$  的正方形区域划分为  $N=144$  个网格且部署  $Q=144$  个传感器节点。 $K$  个智能干扰源随机分布且每次唤醒的传感器节点数为  $M$ 。用信噪比(Signal-to-Noise Ratio, SNR)来描述噪声。

为衡量算法定位性能,定义平均定位误差  $ErrL$  为:

$$ErrL = \frac{1}{K \cdot S} \sum_{k=1}^K \sum_{s=1}^S \sqrt{(x_k^s - \hat{x}_k^s)^2 + (y_k^s - \hat{y}_k^s)^2} \quad (45)$$

其中,  $(x_k^s, y_k^s)$  和  $(\hat{x}_k^s, \hat{y}_k^s)$  分别为第  $s$  次仿真时第  $k$  个干扰源的实际和估计坐标。 $S$  和  $K$  分别为总仿真次数和目标数目。

干扰源功率变化可视为高斯过程,第  $l$  个采样时刻第  $k$  个目标功率  $P_k^{(l)}$  变化如下<sup>[16]</sup>:

$$P_k^{(l)} = rP_k^{(l-1)} + (1-r)P_0^k + v^{(l)} \quad (46)$$

其中,  $P_k^{(l)} \sim \mathcal{N}(P_0^k, \sigma_p^k)$  且  $\sigma_p^k$  为第  $k$  个干扰源功率波动的方差,参数  $v^{(l)} \sim \mathcal{N}(0, (1-r^2)\sigma_p^k)$ 。 $r$  用来描述不同时刻功率变化的关系。当采样间隔非常小时,  $r$  接近于 1,且随采样时刻的增加而减小。该模型可设置不同干扰源之间的功率变化相互独立,符合实际情况。假定 4 个干扰源的参考功率分别为 100w, 800w, 900w 和 1100w,当相关性为  $r=0.5$  时不同干扰源的功率变化如图 5 所示。不同采样时刻干扰源功率变化不一致,并且同一时刻不同干扰源的功率变化也不一致。可见,所提出的干扰源变化模型能有效模拟实际中的功率变化情况。因此,基于该模型验证算法性能。




图 5 不同干扰源功率变化示意图

Fig. 5 Illustration of power varying of different jammers

首先,检验不同采样长度  $L$  下算法的定位性能。假定每次唤醒的传感器节点数目为  $M=14$  且  $\text{SNR}=30\text{dB}$ ,当干扰源数目  $K=3$  时不同采样长度下算法的  $ErrL$  如图 6 所示。SVM-VBEM 和 MMV-VBEM 分别为单测量向量和不考虑功率变化规律的 VBEM 算法,用来和所提 Wake-VBEM 算法进行对比。随着采样长度  $L$  的增加,MMV-VBEM 和 Wake-VBEM 算法的  $ErrL$  都降低,这是因为  $L$  增加可提供更多的

定位信息,而 SVM-VBEM 仅处理单个测量向量,无法提高定位精度。此外,MMV-VBEM 算法不考虑干扰源功率变化规律,其定位误差较大且  $ErrL$  随  $L$  的变化较小。而 Wake-VBEM 算法的  $ErrL$  随  $L$  的增加迅速减小,显示出其优越的定位性能。为均衡定位精度和算法复杂度,在接下来的仿真中令  $L=2$ 。




图 6 采样长度对定位性能的影响

Fig. 6 Influence of sampling length on localization performance

其次,检验不同干扰源数目对所提 Wake-VBEM 算法的影响。令  $M=14$  且  $\text{SNR}=30\text{dB}$ ,当  $L=2$  时不同算法的平均定位误差如图 7 所示。可以看出,目标数目的增加导致向量稀疏度降低,影响了重构精度,因而所有算法的  $ErrL$  都逐渐增加。所提 Wake-VBEM 算法考虑了干扰源的功率变化规律,其定位误差最小。




图 7 目标数目对定位性能的影响

Fig. 7 Influence of target number on localization performance

然后,检验不同传感器唤醒数目下算法的定位性能。令  $K=3$ ,  $\text{SNR}=25\text{dB}$  且  $L=2$ ,不同算法的  $ErrL$  随  $M$  的变化如图 8 所示。 $M$  的增加可获得更多的定位信息,有助于提高定位精度。可以看出,3种算法的  $ErrL$  都随着唤醒传感器数目的增加而降低,而所提 Wake-VBEM 算法的  $ErrL$  最低。




图 8 唤醒的传感器节点数目对定位性能的影响

Fig. 8 The localization performance via the number of waked sensors

最后,检验算法的抗噪声性能。令  $M=14$ ,  $K=3$  且  $L=2$ ,  $ErrL$  随噪声的变化如图 9 所示。随着  $\text{SNR}$  逐渐增加,所有算法的  $ErrL$  都逐渐降低。然而不论  $\text{SNR}$  如何变化,所提 Wake-VBEM 算法的  $ErrL$  总是最低。此外,当  $\text{SNR}=30\text{dB}$  时,所提算法的  $ErrL$  逐渐开始收敛,体现了算法良好的抗噪声性能。




图9 噪声对定位性能的影响

Fig. 9 Influence of noise on localization performance

**结束语** 为解决智能干扰源功率变化导致的定位失效问题,提出了一种传感器唤醒机制下的节能算法 Wake-VBEM。首先,在 CS 框架下将随机唤醒策略建模为观测矩阵的设计。接着,引入参考功率和 BCS 理论,将定位问题建模为块稀疏重构问题。最后,在 VBEM 框架下设计重构算法,通过探索干扰源的功率变化规律提高重构精度。仿真证明,所提 Wake-VBEM 算法能够在干扰源功率未知且变化的条件下实现多干扰源定位,同时可提高对网络的有效利用。

### 参考文献

- [1] AKYILDIZ I F, SU W, SANKARASUBRAMANIAM Y, et al. A Survey on Sensor Networks[J]. IEEE Communications Magazine, 2002, 40(8): 102-114.
- [2] MPITZIOPOULOS A, GAVALAS D, KONSTANTOPOULOS C, et al. A survey on jamming attacks and countermeasures in WSNs[J]. IEEE Communications Surveys & Tutorials, 2009, 11(4): 42-56.
- [3] YAO F Q. Communication anti-jamming engineering and practice[M]. Beijing: Publishing House of Electronics Industry, 2012.
- [4] SUN Y, WANG X, ZHOU X. Jammer Localization for Wireless Sensor Networks[J]. International Journal of Sensor Networks, 2006, 1(3/4): 169-178.
- [5] SUN Y Q, WANG X D, ZHOU X M. Jamming attacks in wireless network[J]. Journal of Software, 2012, 23(5): 1207-1221.
- [6] MORAVEK P, DAN K, SIMEK M, et al. Energy Analysis of Received Signal Strength Localization in Wireless Sensor Networks[J]. Radioengineering, 2011, 20(4): 937-945.
- [7] WANG Q P, WEI X L, FAN J H, et al. Jammer localization based on received jamming signal strength[J]. Journal of Military Communications Technology, 2016, 37(2): 28-32.

- [8] TANG L, ZHAO J X. Precise location of interference sources in ultra low power and short distance wireless communication[J]. Computer Simulation, 2021, 38(2): 124-127.
- [9] GARNAEV A, LIU Y, TRAPPE W. Anti-jamming Strategy Versus a Low-Power Jamming Attack When Intelligence of Adversary's Attack Type is Unknown[J]. IEEE Transactions on Signal and Information Processing over Networks, 2016, 2(1): 49-56.
- [10] RAULT T, BOUABDALLAH A, CHALLAL Y. Energy Efficiency in Wireless Sensor Networks: a top-down survey[J]. Computer Networks, 2014, 67: 104-122.
- [11] FOX C W, ROBERTS S J. A Tutorial on Variational Bayesian Inference[J]. Artificial Intelligence Review, 2012, 38(2): 85-95.
- [12] BARANIUK R G, CEVHER V, DUARTE M F, et al. Model-Based Compressive Sensing[J]. IEEE Transactions on Information Theory, 2010, 56(4): 1982-2001.
- [13] BARANIUK R G. Compressive Sensing[J]. IEEE Signal Processing Magazine, 2007, 24(4): 118-121.
- [14] SHENG X, HU Y H. Maximum likelihood multiple-source localization using acoustic energy measurements with wireless sensor networks [J]. IEEE Transactions on Signal Processing, 2005, 53(1): 44-53.
- [15] JI S, XUE Y, CARIN L. Bayesian Compressive Sensing[J]. IEEE Transactions on Signal Processing, 2008, 56(6): 2346-2356.
- [16] TONISSEN S M, LOGOTHETIS A. Estimation of multiple target trajectories with time varying amplitudes [C]// IEEE Proceedings of 8th Workshop on Statistical Signal and Array Processing, 1996: 32-35.



**YANG Si-xing**, born in 1992, Ph.D. Her main research interests include Internet of things, wireless networks, and device-free target localization.



**LI Ning**, born in 1965, master, associate professor. His main research interests include Ad hoc networks, digital beamforming and machine learning.