

# 无线传感器网络中基于字典优化的压缩感知定位方法

吴 健<sup>1</sup> 孙保明<sup>2</sup>

(苏州经贸职业技术学院 江苏 苏州 215009)<sup>1</sup> (中国人民解放军 91977 部队 北京 102249)<sup>2</sup>

**摘 要** 传统的压缩感知定位方法将物理空间离散化为一个固定网格,并假设所有目标准确地落在该网格上,从而将定位问题转化为稀疏重构问题。事实上,目标的随机性导致很难找到满足上述假设的固定网格,进而引起字典失配问题,使得定位性能急剧下降。针对该问题,文中提出一种基于字典优化的压缩感知定位方法,将稀疏字典建模为以网格为参数的参数化字典,通过动态调整网格不断优化稀疏字典,从而将定位问题转化为联合参数优化的稀疏重构问题,并在变分贝叶斯推理框架下解决该问题。仿真结果表明,与传统的压缩感知定位方法相比,所提方法具有更强的可靠性和鲁棒性。

**关键词** 无线传感器网络,压缩感知,字典优化,变分贝叶斯推理

**中图分类号** TN911.7 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2019.04.019

## Dictionary Refinement-based Localization Method Using Compressive Sensing in Wireless Sensor Networks

WU Jian<sup>1</sup> SUN Bao-ming<sup>2</sup>

(Suzhou Institute of Trade & Commerce, Suzhou, Jiangsu 215009, China)<sup>1</sup>

(No. 91977 of PLA, Beijing 102249, China)<sup>2</sup>

**Abstract** Traditional Compressive Sensing (CS)-based localization methods divide physical space into a fixed grid and assume that all targets fall on the grid precisely, therefore formulating the localization problem into a sparse reconstruction problem. In fact, it is very difficult to find such a fix grid because of the randomness of targets. As a result, there always exists mismatch between the assumed and actual sparse dictionaries, deteriorating localization performance significantly. This paper addressed this problem and proposed a novel dictionary refinement-based localization method using CS. In this method, the true sparse dictionary is modeled as a parameterized dictionary which views grids as adjustable parameters. Based on the model, the sparse dictionary is gradually refined by dynamically adjusting the grid. Consequently, the localization problem is formulated into a joint parameter estimation and sparse reconstruction problem, and this problem is solved under variational Bayesian inference framework. Simulation results show that the proposed localization method is more efficient and robust compared with traditional CS-based methods.

**Keywords** Wireless sensor networks, Compressive sensing, Dictionary refinement, Variational bayesian inference

## 1 引言

随着传感技术与微电子技术的不断革新,多功能低功耗的传感器被广泛地应用到人们的日常生活中。由大量微型传感器节点组成的无线传感器网络<sup>[1]</sup>(Wireless Sensor Networks, WSNs)通常被部署在复杂环境中,用于感知监测对象的物理信息,例如温度、湿度和压力等。位置信息<sup>[2]</sup>对无线传感器网络至关重要,在多数情况下是保证其正常运行的前提和基础。无线传感器网络中的数据只有在获得位置信息后才具有更高的使用价值。因此,如何快速获取监测目标的精确

位置信息是无线传感器网络中的关键问题。

为了实现定位,传统的定位方法通常需要部署大量的传感器以获取海量信息,此时信息的感知、传输与处理开销较大,对信号的采样速率和数据的处理速度提出了较高要求,使传统的信号采样和处理方法显得“力不从心”。压缩感知(Compressive Sensing, CS)理论<sup>[3-4]</sup>为上述问题提供了新的解决思路。压缩感知理论表明,对于某一稀疏信号,可以对其进行欠采样,并利用这些少量的采样值将其以较高的概率重构出来。目前,压缩感知技术已被用于解决目标定位问题。

文献[5]将目标所在的区域离散化为一个包含多个格点

到稿日期:2018-03-19 返修日期:2018-09-14 本文受江苏省高校自然科学研究面上项目(16KJB510047),江苏省高等学校自然科学研究项目(18KJB510042)资助。

吴 健(1984-),男,硕士,工程师,主要研究方向为传感器网络定位,E-mail:abroad80@126.com(通信作者);孙保明(1989-),男,博士,工程师,主要研究方向为信号处理。

的网格,通过探讨目标位置与接收信号强度之间的关系,将定位问题转化为接收信号强度在某稀疏表示字典下的稀疏逼近问题。文献[6]通过区域离散化将多目标位置建模为一个稀疏度未知的稀疏向量,从而将定位问题转化为稀疏重构问题,并提出一种贪婪匹配追踪(Greedy Matching Pursuit, GMP)算法来解决该问题,同时实现目标计数与定位。文献[7]利用残差最优匹配思想优化压缩重构算法,大大减少了网络通信的数据量,从而延长网络寿命,其代价是增加了融合中心的算法复杂度。文献[8]对文献[6]中的感知矩阵进行奇异值分解,得到新的满足约束等距性条件的感知矩阵。该预处理方法不影响原信号的稀疏性,从而有效地保证了算法的重构性能。文献[9]提出了一种基于压缩感知的多目标在线定位方法,该方法实时地记录RSS值,在获得有限的RSS值后立即进行定位,实时性较好。文献[10]提出了一种基于联合稀疏性的压缩感知定位方法。该方法的定位精度较高,但需要多个测量向量,数据采集量较大,不适合大规模应用。文献[11]提出了一种基于压缩感知的动态目标空时二维定位方法,该方法充分利用信号在空域和时域的稀疏性,大大减少了动态目标定位所需的信息采集量。文献[12]首次提出采用稀疏贝叶斯学习实现多目标定位,该方法充分利用了模型参数的后验概率分布,极大地提高了定位性能。

上述定位方法虽然实现了目标定位,但仍存在一个共同的缺陷:假设所有目标准确地落在一个固定网格上。基于该假设,传感器接收到的目标信号可以在一个由该网格形成的稀疏字典中稀疏表示,且表示系数包含目标的位置信息,因此定位问题转化为稀疏重构问题。然而,在一般情况下,由于目标位置未知,很难事先找到满足该假设的固定网格。当目标偏离所采用的固定网格时,该网格所对应的稀疏字典与真实稀疏字典之间存在失配,称为字典失配问题。相关研究<sup>[13]</sup>表明字典失配会极大地降低压缩感知重构性能,从而导致上述方法的定位性能急剧下降。

针对该问题,本文摒弃传统的固定网格,提出一种基于字典优化的压缩感知定位方法。该方法将真实稀疏字典建模为一个以网格为参数的参数化的字典,在稀疏重构的过程中通过动态调整网格来不断优化所采用的稀疏字典,从而减轻甚至消除字典失配问题,提高定位精度。

## 2 问题描述

假设在一个方形的感知区域内,随机分布着 $K$ 个位置未知的目标和 $M$ 个位置已知的传感器。传感器对每个目标进行感知,然后分别将各自接收到的信号强度发送给数据融合中心,最后融合中心利用定位算法进行目标定位。假设目标和传感器的位置分别为 $\Gamma = \{\tau_k\}_{k=1}^K$ 和 $\{t_m\}_{m=1}^M$ ,其中 $\tau_k$ 和 $t_m$ 分别表示第 $k$ 个目标和第 $m$ 个传感器的位置。因此,第 $m$ 个传感器的接收信号强度为:

$$z_m = \sum_{k=1}^K \alpha_k f(t_m, \tau_k) + \varepsilon_m \quad (1)$$

其中, $\alpha_k$ 、 $\varepsilon_m$ 和 $f(t, \tau)$ 分别表示目标发射功率、测量噪声和信号传播模型。为方便起见,这里假设所有目标的功率已知且

相等。我们的目标就是从 $M$ 个测量值 $z = [z_1, z_2, \dots, z_M]^T$ 中恢复目标个数 $K$ 以及位置 $\Gamma = \{\tau_k\}_{k=1}^K$ 。

传统的压缩感知定位方法通常将定位区域离散化为一个包含 $N$ 个格点的固定网格 $\Theta = \{\theta_i\}_{i=1}^N$ ,并假设所有目标准确落在该网格上。基于该假设,RSS测量值可以稀疏表示为:

$$z = D(\Theta)w + \varepsilon \quad (2)$$

其中, $D(\Theta) = [d(\theta_1), \dots, d(\theta_N)]$ 称为稀疏字典,它的行向量 $d(\theta) = [f(t_1, \theta), \dots, f(t_M, \theta)]^T$ 称为字典原子; $w = [\omega_1, \dots, \omega_N]^T$ 称为稀疏表示系数,且 $w$ 中的元素满足:

$$\omega_i = \begin{cases} \alpha_k, & \theta_i = \tau_k \\ 0, & \text{其他} \end{cases} \quad (3)$$

若 $\omega_i \neq 0$ ,则表明在第 $i$ 个格点上存在目标;否则表明不存在目标。因为目标数 $K$ 远远小于格点数目 $N$ ,所以 $w$ 是一个稀疏向量。因此,定位问题就被转化为稀疏重构问题。

然而,由于事先无法获得一个固定网格,使得所有目标均落在该网格上,当目标偏离所采用的网格时,该网格所对应的字典 $D(\Theta)$ 与真实的稀疏字典 $D(\Gamma)$ 之间存在失配,称为字典失配问题,此时表示系数 $w$ 不再是稀疏向量,定位性能急剧下降。为解决该问题,本文提出基于字典优化的压缩感知定位方法。该方法的基本思路是:将 $\Theta$ 看作字典的可变参数,从而通过不断更新字典参数 $\Theta$ 来动态优化稀疏字典 $D(\Theta)$ ,其目标是同时优化字典参数 $\Theta$ 和稀疏表示系数 $w$ 。因此,定位问题被转化为联合参数优化的稀疏重构问题,本文考虑在变分贝叶斯推理<sup>[14]</sup>框架下解决该问题。

## 3 基于字典优化的压缩感知定位方法

本文提出的基于字典优化的定位模型如图1所示。在该模型中,根据变分贝叶斯推理,首先将稀疏表示系数 $w$ 和字典参数 $\Theta$ 分别视为隐含变量和未知的确定性参数,并为 $w$ 分配一个分层高斯先验以诱导其稀疏性;然后迭代地更新稀疏表示系数 $w$ 和字典参数 $\Theta$ 。若要实现稀疏重构,需要解决以下两个子问题:1)给定字典参数 $\Theta$ ,如何更新稀疏表示系数 $w$ ;2)给定稀疏表示系数 $w$ ,如何更新字典参数 $\Theta$ 。下面,将详细介绍解决以上两个子问题的方法。




图1 变分贝叶斯推理框架下基于字典优化的定位模型

Fig. 1 Dictionary refinement-based localization model in variational Bayesian inference framework

### 3.1 更新稀疏表示系数

为更新稀疏表示系数 $w$ ,根据变分贝叶斯推理,假设其服从分层高斯先验分布,即:

$$p(w | \alpha) = \frac{1}{(2\pi)^{N/2} |\mathbf{A}|^{-1/2}} \exp\left(-\frac{1}{2} w^T \mathbf{A} w\right) \quad (4)$$

$$p(\alpha; a, b) = \prod_{i=1}^N \text{Gamma}(\alpha_i | a, b) \quad (5)$$

其中,  $\boldsymbol{\alpha} = [\alpha_1, \dots, \alpha_N]^T$ ,  $\mathbf{A} = \text{diag}\{\alpha_1, \dots, \alpha_N\}$ ,  $\alpha_i^{-1}$  表示  $w_i$  的先验方差。类似地, 假设  $\boldsymbol{\varepsilon}$  服从如下的分层高斯先验分布:

$$p(\boldsymbol{\varepsilon} | \beta) = (2\pi\beta^{-1})^{-M/2} \exp(-\frac{\beta}{2} \|\boldsymbol{\varepsilon}\|_2^2) \quad (6)$$

$$p(\beta; c, d) = \text{Gamma}(\beta | c, d) \quad (7)$$

其中,  $\beta^{-1}$  表示  $\boldsymbol{\varepsilon}$  中所有元素的方差。根据式(2)和式(4), 似然函数可表示为:

$$p(\mathbf{z} | \mathbf{w}, \beta) = (2\pi\beta^{-1})^{-M/2} \exp(-\frac{\beta}{2} \|\mathbf{z} - \mathbf{D}(\boldsymbol{\Theta})\mathbf{w}\|_2^2) \quad (8)$$

根据变分贝叶斯推理,  $\mathbf{w}$ ,  $\boldsymbol{\alpha}$  和  $\beta$  的后验概率密度可分别更新为:

$$\ln q(\mathbf{w}) = \langle \ln p(\mathbf{z}, \mathbf{w}, \boldsymbol{\alpha}, \beta) \rangle_{q(\boldsymbol{\alpha})q(\beta)} + \text{const} \quad (9)$$

$$\ln q(\boldsymbol{\alpha}) = \langle \ln p(\mathbf{z}, \mathbf{w}, \boldsymbol{\alpha}, \beta) \rangle_{q(\mathbf{w})q(\beta)} + \text{const} \quad (10)$$

$$\ln q(\beta) = \langle \ln p(\mathbf{z}, \mathbf{w}, \boldsymbol{\alpha}, \beta) \rangle_{q(\mathbf{w})q(\boldsymbol{\alpha})} + \text{const} \quad (11)$$

经过整理, 可得  $\mathbf{w}$ ,  $\boldsymbol{\alpha}$  和  $\beta$  的后验概率密度为:

$$q(\mathbf{w}) = N(\mathbf{w} | \boldsymbol{\mu}, \boldsymbol{\Sigma}) \quad (12)$$

$$q(\boldsymbol{\alpha}) = \prod_{n=1}^N \text{Gamma}(\alpha_n | \tilde{a}, \tilde{b}_i) \quad (13)$$

$$q(\beta) = \text{Gamma}(\beta | \tilde{c}, \tilde{d}) \quad (14)$$

其中:

$$\boldsymbol{\mu} = \langle \beta \rangle \boldsymbol{\Sigma} \mathbf{D}^T(\boldsymbol{\Theta}) \mathbf{z} \quad (15)$$

$$\boldsymbol{\Sigma} = (\langle \beta \rangle \mathbf{D}^T(\boldsymbol{\Theta}) \mathbf{D}(\boldsymbol{\Theta}) + \langle \mathbf{A} \rangle)^{-1} \quad (16)$$

$$\tilde{a} = a + \frac{1}{2} \quad (17)$$

$$\tilde{b}_i = b + \frac{1}{2} \langle w_i^2 \rangle = b + \frac{1}{2} \text{var}(w_i) + \frac{1}{2} \langle w_i \rangle^2 \quad (18)$$

$$\tilde{c} = c + \frac{M}{2} \quad (19)$$

$$\tilde{d} = d + \frac{1}{2} \|\mathbf{z} - \mathbf{D}(\boldsymbol{\Theta})\boldsymbol{\mu}\|_2^2 + \frac{1}{2} \text{tr}(\mathbf{D}^T(\boldsymbol{\Theta}) \mathbf{D}(\boldsymbol{\Theta}) \boldsymbol{\Sigma}) \quad (20)$$

其中,  $\boldsymbol{\mu}$  表示  $\mathbf{w}$  当前的均值矢量。值得注意的是, 在上述更新过程中, 参数  $a, b, c$  和  $d$  均被设置为较小的常数, 例如  $a = b = c = d = 10^{-6}$ , 这相当于假设  $\boldsymbol{\alpha}$  和  $\beta$  服从无信息的先验分布。

### 3.2 更新字典参数

假设  $\mathbf{w}$ ,  $\boldsymbol{\alpha}$  和  $\beta$  当前的后验概率密度分别为  $q(\mathbf{w}; \boldsymbol{\Theta})$ ,  $q(\boldsymbol{\alpha}; \boldsymbol{\Theta})$  和  $q(\beta; \boldsymbol{\Theta})$ , 根据变分贝叶斯推理, 字典参数可利用式(2)进行更新:

$$\boldsymbol{\Theta}^{\text{NEW}} = \arg \max_{\boldsymbol{\Theta}} \langle \ln p(\mathbf{z}, \mathbf{w}, \boldsymbol{\alpha}, \beta; \boldsymbol{\Theta}) \rangle_{q(\mathbf{w}; \boldsymbol{\Theta})q(\boldsymbol{\alpha}; \boldsymbol{\Theta})q(\beta; \boldsymbol{\Theta})} \quad (21)$$

经过整理, 可以得到:

$$\boldsymbol{\Theta}^{\text{NEW}} = \arg \max_{\boldsymbol{\Theta}} \langle p(\mathbf{z} | \mathbf{w}, \beta; \boldsymbol{\Theta}) \rangle_{q(\mathbf{w}; \boldsymbol{\Theta}^{\text{OLD}})q(\boldsymbol{\alpha}; \boldsymbol{\Theta}^{\text{OLD}})q(\beta; \boldsymbol{\Theta}^{\text{OLD}})} \quad (22)$$

根据式(8), 式(22)可重新表示为:

$$\boldsymbol{\Theta}^{\text{NEW}} = \arg \min_{\boldsymbol{\Theta}} (\|\mathbf{z} - \mathbf{D}(\boldsymbol{\Theta})\mathbf{w}\|_2^2)_{q(\mathbf{w}; \boldsymbol{\Theta}^{\text{OLD}})} \quad (23)$$

经过推导、简化和整理, 式(23)可重新表示为:

$$\boldsymbol{\Theta}^{\text{NEW}} = \arg \min_{\boldsymbol{\Theta}} \{ \|\mathbf{z} - \mathbf{D}(\boldsymbol{\Theta})\boldsymbol{\mu}\|_2^2 + \text{tr}(\mathbf{D}^T(\boldsymbol{\Theta}) \mathbf{D}(\boldsymbol{\Theta}) \boldsymbol{\Sigma}) \} \quad (24)$$

其中,  $\boldsymbol{\mu}$  和  $\boldsymbol{\Sigma}$  分别表示  $\mathbf{w}$  当前的均值矢量与协方差矩阵。显然, 式(24)是一个带惩罚项的非线性最小二乘问题, 这里采用信赖域子空间方法<sup>[15]</sup>求解。

### 3.3 算法实现

根据 3.1 节和 3.2 节的结果, 字典参数的估计和稀疏系

数的重构可通过迭代地执行下述步骤实现: 在第  $i$  次迭代中, 首先利用当前的网格参数  $\boldsymbol{\Theta}^{(i)}$  和  $\mathbf{w}$  后验分布  $q(\mathbf{w}^{(i)})$ , 依次更新  $\mathbf{w}$ ,  $\boldsymbol{\alpha}$  和  $\beta$  的后验分布; 然后, 利用更新后的  $\mathbf{w}$  的后验分布  $q(\mathbf{w}^{(i+1)})$  来更新字典参数  $\boldsymbol{\Theta}^{(i+1)}$ 。每次迭代完成之后计算当前的拟合残差:

$$r^{(i+1)} = \|\mathbf{z} - \mathbf{D}(\boldsymbol{\Theta}^{(i+1)})\boldsymbol{\mu}^{(i+1)}\|_2^2 \quad (25)$$

其中,  $\boldsymbol{\mu}^{(i+1)}$  表示第  $i$  次迭代之后  $\mathbf{w}$  的后验均值向量。

当迭代次数超过最大允许次数  $k_{\text{max}}$ , 或者拟合残差的变化量小于预设门限  $\eta$ , 即  $|r^{(i+1)} - r^{(i)}| < \eta$  时, 迭代终止。该算法的具体流程如算法 1 所示。

#### 算法 1 联合参数优化的稀疏重构流程

输入: 初始网格  $\tilde{\boldsymbol{\Theta}}$ , 测量值  $\mathbf{z}$ , 迭代次数  $i=0$ , 最大迭代次数  $k_{\text{max}}$ , 预设门限  $\eta$

输出:  $\tilde{\mathbf{w}} = \boldsymbol{\mu}^{(i)}$ ,  $\tilde{\boldsymbol{\Theta}} = \boldsymbol{\Theta}^{(i)}$

1. 利用当前的字典参数, 更新稀疏表示系数的后验概率;
2. 利用当前的稀疏表示系数的后验概率, 更新字典参数;
3. 计算当前的拟合残差  $r^{(i+1)}$ ;
4. 令  $i=i+1$ ;
5. 如果终止条件满足, 输出结果; 否则转到步骤 1。

算法中, 参数  $\boldsymbol{\alpha}$  和  $\beta$  的后验概率密度分别初始化为相应的先验分布, 稀疏系数  $\mathbf{w}$  的初始后验概率密度可通过式(15)和式(16)获得。根据变分贝叶斯推理, 在迭代的过程中对数似然函数不断增大, 因此算法 1 是收敛的。

### 3.4 定位

一般情况下, 算法 1 的输出  $\tilde{\mathbf{w}}$  是可压缩信号, 即它只有少量的较大元素, 其余的大部分元素接近于零。为了实现定位, 本文用一个稀疏向量  $\hat{\mathbf{w}}$  来近似表示  $\tilde{\mathbf{w}}$ , 即:

$$\hat{w}_i = \begin{cases} 0, & 20 \log_{10} \left( \frac{\tilde{w}_i}{\max |\tilde{\mathbf{w}}|} \right) < \delta \\ \tilde{w}_i, & \text{其他} \end{cases} \quad (26)$$

其中,  $\delta$  称为稀疏门限。获得稀疏向量  $\hat{\mathbf{w}}$  后, 可以分别估计目标的个数和位置:

$$\hat{K} = \|\hat{\mathbf{w}}\|_0 \quad (27)$$

$$\hat{\boldsymbol{\Theta}} = \{ \boldsymbol{\theta}_k \in \tilde{\boldsymbol{\Theta}} | \hat{w}_k \neq 0 \} \quad (28)$$

## 4 仿真结果与分析

### 4.1 仿真场景设置

本文采用 MATLAB 作为仿真平台。在一个边长为 9 m 的方形区域内随机产生  $K$  个目标和  $M$  个传感器, 将感知区域均匀地划分为一个包含  $10 \times 10$  个格点的网格。为了检验本文字典优化 (Dictionary Refinement, DicRef) 算法的优越性, 将其与现有的基追踪 (Basic Pursuit, BP)<sup>[16]</sup> 算法、正交匹配追踪 (Orthogonal Matching Pursuit, OMP)<sup>[17]</sup> 算法、贪婪匹配追踪 (Greedy Matching Pursuit, GMP)<sup>[6]</sup> 算法和稀疏贝叶斯学习 (Sparse Bayesian Learning, SBL)<sup>[12]</sup> 算法进行对比。仿真中用到的参数取值为  $k_{\text{max}} = 1000$ ,  $\eta = 10^{-6}$ ,  $\delta = -3$  dB。

4.2 计数及定位结果

为了检验所提算法的定位性能,在区域中随机部署  $K=3$  个目标和  $M=25$  个传感器,不同算法的定位结果如图 2 所示。可以看到,OMP 和 SBL 都存在漏检目标;BP 和 GMP 虽然能够正确计数,但是只能将目标定位到初始网格中距离目标较近的相邻格点上,定位误差较大。显然,这是字典失配造成的影响。与之相对应,本文所提的字典优化算法 DicRef 能够自适应地调整网格划分,使得所有目标位于调整后的网格上,从而实现准确计数及定位。




图 2 不同算法的计数及定位结果

Fig. 2 Counting and localization results of different algorithms

4.3 测量次数的影响

图 3 描述了在无噪声条件下测量次数对不同算法计数性能的影响,测量次数的变化范围是 $[16, 25]$ 。结果显示,随着测量次数的增加,所提的字典优化算法 DicRef 的平均估计目标数逐渐逼近真实目标数,其成功计数概率逐渐增加,且在在整个测量次数范围内,DicRef 的成功计数概率均高于其他算法。由此可见,在字典失配条件下,所提算法的计数性能明显优于传统的稀疏重构算法。

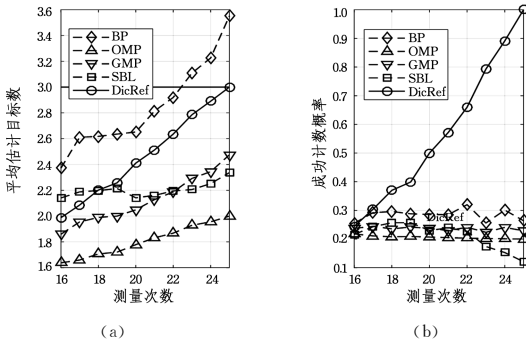


图 3 不同测量次数条件下不同算法的平均估计目标数和成功计数概率

Fig. 3 Average estimated target number and successful counting probability of different algorithms with different measurement numbers

图 4 比较了不同测量次数条件下不同算法的平均定位误差。由图 4 可见,传统稀疏重构算法的平均定位误差随着测量次数的增加而不断减小,但当测量次数增加到一定水平后,平均定位误差基本保持不变。而在整个测量次数范围内,本文提出的字典优化算法 DicRef 的平均定位误差明显低于其他算法。由此可见,在字典失配条件下,所提算法的定位性能明显优于传统的稀疏重构算法。




图 4 不同测量次数条件下不同算法的平均定位误差

Fig. 4 Average localization error of different algorithms with different measurement numbers

4.4 测量噪声的影响

图 5 描述了在测量次数  $M=25$ ,且信噪比在 $[0, 30]$ dB 内变化时,不同算法的平均估计目标数和成功计数概率。从图 5 可以看出:当信噪比大于 5 dB 时,所提字典优化算法 DicRef 的平均估计目标数和成功计数概率均优于传统的重构算法;特别地,当  $SNR=10$  dB 时,DicRef 的平均估计目标数和成功计数概率分别为 2.88 和 82%。由此可见,本文所提算法能够在较低信噪比的条件下实现准确计数。




图 5 不同信噪比条件下不同算法的平均估计目标数和成功计数概率

Fig. 5 Average estimated target number and successful counting probability of different algorithms with different SNRs

图 6 比较了不同信噪比条件下不同算法的平均定位误差。由图 6 可见,在整个信噪比区间,所有算法的平均定位误差均随着信噪比的增加而不断减小,且所提算法 DicRef 的定位性能明显优于传统的稀疏重构算法。特别地,当  $SNR=10$  dB 时,DicRef 的平均定位误差为 0.57 m。该结果进一步表明,即使在字典失配的条件下所提算法仍具有较强的鲁棒性。




图 6 不同信噪比条件下不同算法的平均定位误差

Fig. 6 Average localization error of different algorithms with different SNRs

**结束语** 针对传统压缩感知定位方法中的字典失配问题,本文提出了基于字典优化的压缩感知定位方法。该方法将真实稀疏字典建模为一个参数化的字典,字典参数为空间网格,从而将定位问题建模为一个联合参数优化的稀疏重构问题。为解决该问题,本文提出一种能够交替进行参数优化和稀疏重构的迭代算法。仿真结果表明,所提定位方法能够有效解决字典失配问题且具有较强的鲁棒性。

### 参考文献

- [1] LIU Y, HE Y, LI M, et al. Does wireless sensor network scale? A measurement study on GreenOrbs [J]. *IEEE Transactions on Parallel and Distributed Systems*, 2013, 24(10): 1983-1993.
- [2] LIU Y, YANG Z, WANG X, et al. Location, localization, and localizability [J]. *Journal of Computer Science and Technology*, 2010, 25(2): 274-297.
- [3] DONOHO D L. Compressed sensing [J]. *IEEE Transactions on Information Theory*, 2006, 52(4): 1289-1306.
- [4] CANDE J. Compressive sampling [C] // *International Congress of Mathematicians*, Madrid, Spain, 2006: 1433-1452.
- [5] CEVHER V, DUARTE M, BARANIUK R G. Distributed target localization via spatial sparsity [C] // *Proceedings of the European Signal Processing Conference (EUSIPCO)*, Lausanne, Switzerland, 2008: 25-29.
- [6] ZHANG B, CHEN X, ZHANG N, et al. Sparse target counting and localization in sensor networks based on compressive Sensing [C] // *IEEE International Conference on Computer Communications (INFOCOM)*, Shanghai, China, 2011: 2255-2263.
- [7] HE F H, YU Z J, LIU H T. Multiple target localization via compressed sensing in wireless sensor networks [J]. *Journal of Electronics & Information Technology*, 2012, 34(3): 716-721. (in Chinese)  
何风行, 余志军, 刘海涛. 基于压缩感知的无线传感器网络多目标定位算法 [J]. *电子与信息学报*, 2012, 34(3): 716-721.
- [8] LI Y B, HUANG H, YE F, et al. Target localization via compressed sensing based on SVD [J]. *Journal of Central South University (Natural Science)*, 2014, 45(5): 1516-1521. (in Chinese)  
李一兵, 黄辉, 叶方, 等. 基于奇异值分解的压缩感知定位算法 [J]. *中南大学学报*, 2014, 45(5): 1516-1521.
- [9] WU D, ARKHIPOV D I, ZHANG Y, et al. Online war driving by compressive sensing [J]. *IEEE Transactions on Mobile Computing*, 2015, 14(11): 2349-2362.
- [10] LAGUNAS E, SHARMA S K, CHATZINOTAS S. Compressive sensing based target counting and localization exploiting joint sparsity [C] // *2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2016: 3231-3235.
- [11] SUN B, GUO Y, LI N, et al. TDL: two-dimensional localization for mobile targets using compressive sensing in wireless sensor networks [J]. *Computer Communications*, 2016, 78: 45-55.
- [12] XUE B, ZHANG L, YU Y. Multi-target localization based on sparse Bayesian learning in wireless sensor networks [J]. *IEICE Transactions on Communications*, 2016, 99(5): 1093-1100.
- [13] CHI Y, SCHARF L, PEZESHKI A, et al. Sensitivity to basis mismatch in compressed sensing [J]. *IEEE Transactions on Signal Processing*, 2011, 59(5): 2182-2195.
- [14] TZIKAS D, LIKAS A, GALATSANOS P. The variational approximation for Bayesian inference [J]. *IEEE Signal Processing Magazine*, 2008, 25(6): 131-146.
- [15] BRANCH M, COLEMAN T, LI Y. A subspace, interior, and conjugate gradient method for large-scale bound-constrained minimization problems [J]. *SIAM Journal on Scientific Computing*, 1999, 21(8): 1-23.
- [16] CHEN S, DONOHO D, SAUNDERS M. Atomic decomposition by basis pursuit [J]. *SIAM Journal on Scientific Computing*, 1998, 20(1): 33-61.
- [17] TROPP J, GILBERT A. Signal recovery from random measurements via orthogonal matching pursuit [J]. *IEEE Transactions on Information Theory*, 2007, 53(12): 4655-4666.