

压缩感知多目标无源定位中的字典适配方法

余东平 郭艳* 李宁 杨思星 宋晓祥

(陆军工程大学通信工程学院 南京 210007)

摘要: 该文针对压缩感知多目标无源定位在无线定位环境中的字典失配问题, 提出基于变分期望最大化算法的字典适配方法。该方法首先根据鞍面模型建立无源字典, 并将与定位环境相关的字典参数作为可调参数。然后, 为目标位置向量建立两层的混合高斯先验模型以诱导其稀疏性。最后, 利用变分期望最大化算法估计隐藏变量的后验分布以及优化字典环境参数, 实现多目标位置估计和字典适配。仿真结果表明, 相较于传统的压缩感知多目标无源定位方法, 在变化的无线定位环境下, 所提定位方法的性能优势尤为明显。

关键词: 无源定位; 压缩感知; 字典适配; 变分期望最大化

中图分类号: TN911.7

文献标识码: A

文章编号: 1009-5896(2019)04-0865-07

DOI: 10.11999/JEIT180531

Dictionary Refinement Method for Compressive Sensing Based Multi-target Device-free Localization

YU Dongping GUO Yan LI Ning YANG Sixing SONG Xiaoxiang

(College of Communications Engineering, Army Engineering University of PLA, Nanjing 210007, China)

Abstract: In order to solve the dictionary mismatch problem of Compressive Sensing (CS) based multi-target Device-Free Localization (DFL) under the wireless localization environments, a Variational Expectation Maximization (VEM) based dictionary refinement method is proposed. Firstly, this method builds the dictionary based on the saddle surface model, and models the environment-related dictionary parameters as tunable parameters. Then, a two-layer hierarchical Gaussian prior model is imposed on the location vector to induce its sparsity. Finally, the VEM algorithm is adopted to estimate the posteriors of hidden variables and optimize the environment-related dictionary parameter, thus the estimation of target locations and dictionary refinement can be realized jointly. Compared with the conventional CS based multi-target DFL schemes, the simulation results demonstrate that the performance of the proposed algorithm is especially excellent in changing wireless localization environments.

Key words: Device-Free Localization (DFL); Compressive Sensing (CS); Dictionary refinement; Variational Expectation Maximization (VEM)

1 引言

无源定位(Device-Free Localization, DFL)技术^[1-3]对于实现基于位置的服务具有十分重要的作用和意义, 是入侵者检测、灾难救援、智能交通以及智慧城市等应用的关键, 也是当前目标定位研究中不可或缺的组成部分。近年来, 大量文献研究了无线传感器网络(Wireless Sensor Network, WSN)

中基于压缩感知(Compressive Sensing, CS)的多目标无源定位技术^[4-6]。基于压缩感知理论利用目标位置的空间稀疏性, 能够有效减少所需采集的测量数据, 从而大大降低无线传感器节点的部署数量。

按照对无线信号处理方式的不同, 可将现有的多目标无源定位技术分为如下4类^[6]: (1)基于空间关系的无源定位技术^[3,7]; (2)基于指纹法的无源定位技术^[8,9]; (3)基于无线层析成像(Radio Tomographic Imaging, RTI)的无源定位技术^[10,11]; (4)基于压缩感知的无源定位技术^[6,12]。基于空间关系的无源定位技术根据被遮挡链路和目标的空间关系实现位置估计。该方法需事先获取传感器节点的位置信息且定位精度较低。为提高定位性能, 提出了基于指纹法的无源定位技术。该方法通过匹配离线指

收稿日期: 2018-05-30; 改回日期: 2018-11-06; 网络出版: 2018-11-16

*通信作者: 郭艳 guoyan_1029@sina.com

基金项目: 国家自然科学基金(61871400, 61571463), 江苏省自然科学基金(BK20171401)

Foundation Items: The National Natural Science Foundation of China (61871400, 61571463), The Natural Science Foundation of Jiangsu Province (BK20171401)

纹信息与在线测量数据估计目标的当前位置。但是,采集指纹信息并建立指纹库需耗费大量的人力与时间资源。基于无线层析成像的无源定位技术根据计算机断层扫描的原理实现位置估计,能取得较好的定位性能。但是,该方法需建立大量的无线链路以实现定位区域的充分覆盖,对硬件资源的要求较高。基于压缩感知的无源定位技术根据目标在定位区域中的空间稀疏性,将目标位置信息视为稀疏信号,并利用稀疏恢复算法估计目标位置。

在压缩感知多目标无源定位中,首先通过非相关观测采集测量数据,然后利用稀疏恢复算法以高概率重构目标位置向量,只需少量的测量数据即可获得较好的定位性能。LCS方法^[13]首次将压缩感知理论应用于多目标无源定位,该方法利用贪婪匹配追踪(Greedy Matching Pursuit, GMP)算法恢复目标位置向量,并证明了所建立的无源字典满足有限等距性质(Restricted Isometry Property, RIP)^[14]。E-HIPA方法^[6]基于正交匹配追踪(Orthogonal Matching Pursuit, OMP)算法恢复目标位置向量,可在目标数未知的情况下实现位置估计。

传统的压缩感知多目标无源定位方法假设定位环境是理想的,即定位过程不受环境变化的影响。然而在实际的定位过程中,无线信号的强度不仅与目标位置相关,而且还受到定位环境中多种因素的影响。定位区域中其他物体的移动、温度、湿度的变化以及无线信号的多径、衰落等效应都将导致在线测量数据与字典信息不匹配,即字典失配问题。由环境的动态变化所导致的字典失配问题将对稀疏恢复过程造成严重干扰,进而影响无源定位的性能。为有效解决字典失配问题,本文提出针对压缩感知多目标无源定位的字典适配方法。该方法首先基于鞍面模型^[15]建立参数化的字典,将字典中的环境参数作为可调参数。然后,建立两层的混合高斯先验模型以诱导目标位置向量的稀疏性。最后,利用变分期望最大化(Variational Expectation Maximization, VEM)算法估计目标位置向量以及优化字典环境参数。

2 系统模型和问题描述

压缩感知多目标无源定位的基本场景如图1所示。多个传感器节点部署在目标定位区域的周围,由 M 条链路组成的无线传感器网络实现对定位区域的覆盖。 K 个目标随机地分布于定位区域中,并对无线链路造成遮挡或阴影。图中椭圆形的区域为被遮挡链路的目标影响区域,当目标位于该区域时将会对无线链路造成影响。无源定位技术主要通过测量和分析无源目标对无线链路的影响实现位置估




图1 压缩感知多目标无源定位基本场景

计。本文利用接收信号强度(Received Signal Strength, RSS)的变化评估目标对无线链路的遮挡和阴影效应。在定位区域中,目标的位置信息是连续信号,而压缩感知理论则主要针对离散信号。为了将压缩感知理论应用于多目标无源定位,需对定位区域离散化,将目标位置信息转化为离散信号。为此,我们将定位区域均匀地划分为 N 个格点,并假设目标的位置即为其所处格点的中心点坐标。在此情况下,多个目标的位置信息可表示为

$$\boldsymbol{\theta} = [\theta_1, \theta_2, \dots, \theta_n, \dots, \theta_N]^T \quad (1)$$

其中, $\boldsymbol{\theta} \in \mathbb{R}^{N \times 1}$ 为目标位置向量,其元素 $\theta_n \in \{0, 1\}$ 。当格点 n 内存在目标时, $\theta_n = 1$;否则 $\theta_n = 0$ 。由于 $K \ll N$,则 $\boldsymbol{\theta}$ 为 K 稀疏向量。在 X - Y 坐标系下,第 n 个格点内目标的位置可表示为 (x_n, y_n) 。因此, K 个目标的坐标为 $\{(x_n, y_n) | \theta_n = 1, n \in 1, 2, \dots, N\}$,目标数为 $K = \|\boldsymbol{\theta}\|_0$ 。

在压缩感知多目标无源定位中,目标位置估计问题被转化为目标位置向量的稀疏恢复问题。如前所述,本文将 M 条链路上RSS的变化值作为测量信息。根据信号衰减模型,第 m 条链路上的RSS为

$$R_m = G_m + H_m - L_m - 10\rho_m \lg d_m - S_m + \varepsilon_m \quad (2)$$

其中, $G_m, H_m, L_m, \rho_m, d_m, S_m$ 和 ε_m 分别为第 m 条链路上的接收增益、发射功率、信号传播衰减、路径损耗率、链路长度、目标遮挡导致的信号衰减以及测量噪声。当目标分别处在和不在定位区域中时,RSS的变化值为

$$\Delta R_m = R_m - R_m^0 = -S_m + \Delta \varepsilon_m \quad (3)$$

其中, R_m 表示第 m 条链路上当前的接收信号强度, R_m^0 表示定位区域为空时该链路上的接收信号强度, $\Delta \varepsilon_m$ 表示测量噪声的变化。当目标位置满足稀疏条件时,由目标遮挡和阴影效应所导致的信号衰减 S_m 可由多个格点内的目标所造成的信号衰减线性叠加表示^[6],即

$$S_m = \sum_{n=1}^N \theta_n \phi_{m,n} \quad (4)$$

其中, $\phi_{m,n}$ 表示由格点 n 内的目标所引起的第 m 条链路上RSS的变化。通过评估 N 个格点对 M 条链路的影响, 可建立无源字典 $\Phi \in \mathbb{R}^{M \times N}$, $\phi_{m,n}$ 为其第 (m, n) 个元素。为构建可适配的无源字典, 本文根据鞍面模型计算 $\phi_{m,n}$ 的值:

$$\left. \begin{aligned} \phi_{m,n} &= \gamma_m \left(\frac{1 - \rho_m}{\lambda_1^2} U_{m,n}^2 + \rho_m \left(1 - \frac{V_{m,n}^2}{\lambda_2^2} \right) \right) \\ \text{s.t.} \quad \frac{U_{m,n}^2}{\lambda_1^2} + \frac{V_{m,n}^2}{\lambda_2^2} &\leq 1 \end{aligned} \right\} (5)$$

当目标处在链路 m 的椭圆形目标影响区域时, 将对该链路上的RSS造成影响。 λ_1 和 λ_2 分别为椭圆形影响区域的长半轴及短半轴。 $(U_{m,n}, V_{m,n})$ 表示格点 n 相对于链路 m 的坐标。 γ_m 为链路 m 上接收信号强度的最大衰减, ρ_m 表示该链路上最小的信号衰减与 γ_m 的比值。根据式(3)和式(4), M 条链路上RSS的变化值可表示为

$$\mathbf{y} = \Phi \boldsymbol{\theta} + \boldsymbol{\varepsilon} \quad (6)$$

其中, $\mathbf{y} \in \mathbb{R}^{M \times 1}$ 为测量向量, 其第 m 个元素 $y_m = \Delta R_m$ 。 $\boldsymbol{\varepsilon} \in \mathbb{R}^{M \times 1}$ 为测量噪声向量, 其第 m 个元素为 $\Delta \varepsilon_m$ 。在此情形下, 可将多目标位置估计问题建模成稀疏向量的恢复问题。同时, 为了减轻由字典失配问题造成的影响, 需根据定位环境的变化实时调整字典元素的值以实现字典适配。

3 先验模型建立

本文利用变分期望最大化算法实现稀疏恢复以及字典适配。首先, 为了诱导 $\boldsymbol{\theta}$ 的稀疏性建立如图2所示的两层混合高斯先验模型。图中圆形节点表示随机变量, 方形节点代表确定性参数, 箭头则表明了各节点间的从属关系。 \mathbf{y} 为测量值, 其值依赖于随机变量 $\boldsymbol{\theta}$ 和 $\boldsymbol{\varepsilon}$ 。 $\boldsymbol{\theta}$ 为目标位置向量, 其值依赖于随机变量 $\boldsymbol{\alpha}$ 。 $\boldsymbol{\varepsilon}$ 为测量噪声向量, 其值依赖于随机变量 β 。由于测量噪声为加性高斯白噪声, 则测量噪声向量 $\boldsymbol{\varepsilon}$ 服从多维高斯分布。因此, 似然函数可表示为

$$p(\mathbf{y}|\boldsymbol{\theta}, \beta) = \left(2\pi\beta^{-1} \right)^{-\frac{M}{2}} \exp \left(-\frac{\beta}{2} \|\mathbf{y} - \Phi \boldsymbol{\theta}\|_2^2 \right) \quad (7)$$

其中, β^{-1} 表示测量噪声的方差。由于测量噪声向




图2 两层混合高斯先验模型

量服从多维高斯分布, 其共轭先验为伽马分布。因此, 将 β 视为随机变量并假设其服从伽马先验分布

$$p(\beta; a, b) = \text{Gamma}(\beta; a, b) = \frac{1}{\Gamma(a)} b^a \beta^{a-1} e^{-b\beta} \quad (8)$$

其中, a 和 b 为该先验分布函数的确定性参数。在先验模型的第1层, 将 $\boldsymbol{\theta}$ 视为随机变量, 并假设其服从多维高斯先验分布

$$\begin{aligned} p(\boldsymbol{\theta}|\boldsymbol{\alpha}) &= \prod_{n=1}^N \mathcal{N}(\theta_n | 0, \alpha_n^{-1}) \\ &= (2\pi)^{-\frac{N}{2}} |\boldsymbol{\Lambda}|^{\frac{1}{2}} \exp \left(-\frac{1}{2} \boldsymbol{\theta}^T \boldsymbol{\Lambda} \boldsymbol{\theta} \right) \end{aligned} \quad (9)$$

其中, α_n^{-1} 表示 θ_n 的方差, 且 $\boldsymbol{\alpha} = [\alpha_1, \alpha_2, \dots, \alpha_N]^T$, $\boldsymbol{\Lambda} = \text{diag}(\boldsymbol{\alpha})$ 。在先验模型的第2层, 将 $\boldsymbol{\alpha}$ 视为随机变量, 并假设其服从多维伽马先验分布

$$\begin{aligned} p(\boldsymbol{\alpha}; c, \mathbf{d}) &= \prod_{n=1}^N \text{Gamma}(\alpha_n; c, d_n) \\ &= \prod_{n=1}^N \frac{1}{\Gamma(c)} d_n^c \alpha_n^{c-1} \exp(-d_n \alpha_n) \end{aligned} \quad (10)$$

其中, c 和 d_n 为该先验分布函数的确定性参数。 $\Gamma(c) = \int_0^\infty w^{c-1} e^{-w} dw$ 表示伽马函数。基于所建立的两层混合高斯先验模型, $\boldsymbol{\theta}$ 的先验分布可表示为

$$\begin{aligned} p(\boldsymbol{\theta}; c, \mathbf{d}) &= \int p(\boldsymbol{\theta}|\boldsymbol{\alpha}) p(\boldsymbol{\alpha}; c, \mathbf{d}) d\boldsymbol{\alpha} \\ &= \prod_{n=1}^N \mathcal{N}(\theta_n | 0, \alpha_n^{-1}) \text{Gamma}(\alpha_n; c, d_n) \\ &= \prod_{n=1}^N \text{St}(\theta_n | \lambda_n, v) \end{aligned} \quad (11)$$

其中, $\text{St}(\cdot)$ 表示Student-t分布, 且 $\lambda_n = c/d_n$, $v = 2c$ 。当 v 较小时, 能够诱导 $\boldsymbol{\theta}$ 的稀疏性。将先验模型中的确定性参数 (a, b, c, d_n) 均设置为较小的值(10^{-6}), 以使得 $\boldsymbol{\theta}$ 中各分量的先验信息相同。

4 稀疏恢复和字典适配

4.1 后验分布估计

在两层混合高斯先验模型中, 隐藏变量为 $\mathbf{z} \triangleq \{\boldsymbol{\theta}, \beta, \boldsymbol{\alpha}\}$, 确定性参数为 $\Omega \triangleq \{a, b, c, \mathbf{d}\}$ 。为恢复目标位置向量 $\boldsymbol{\theta}$, 需求隐藏变量 \mathbf{z} 的后验分布。另一方面, 随着环境的变化, 字典环境参数 ρ_m 也将随之改变。为实现字典适配, 需实时地对字典环境参数 ρ_m 进行优化。本文利用变分期望最大化(VEM)算法估计隐藏变量的后验分布以及优化字典环境参数。在变分期望最大化算法的每一步迭

代中,首先在变分E步更新 \mathbf{z} 的后验分布,然后在变分M步利用牛顿法优化 ρ_m 。

由于无法求得各隐藏变量后验分布的解析表达式,本文采用变分逼近的方法估计其后验分布。分别用 $q(\boldsymbol{\theta})$, $q(\beta)$ 和 $q(\boldsymbol{\alpha})$ 逼近各隐藏变量的后验分布,且其联合后验分布 $q(\mathbf{z}) = q(\boldsymbol{\theta})q(\beta)q(\boldsymbol{\alpha})$ 。根据变分贝叶斯推理技术^[16],各隐藏变量的后验分布可通过式(12)–式(14)的方式进行逼近

$$\ln q^*(\boldsymbol{\theta}) \propto \langle \ln p(\mathbf{y}, \boldsymbol{\theta}, \beta, \boldsymbol{\alpha}; \Omega) \rangle_{q(\beta)q(\boldsymbol{\alpha})} \quad (12)$$

$$\ln q^*(\beta) \propto \langle \ln p(\mathbf{y}, \boldsymbol{\theta}, \beta, \boldsymbol{\alpha}; \Omega) \rangle_{q(\boldsymbol{\theta})q(\boldsymbol{\alpha})} \quad (13)$$

$$\ln q^*(\boldsymbol{\alpha}) \propto \langle \ln p(\mathbf{y}, \boldsymbol{\theta}, \beta, \boldsymbol{\alpha}; \Omega) \rangle_{q(\boldsymbol{\theta})q(\beta)} \quad (14)$$

其中, $p(\mathbf{y}, \boldsymbol{\theta}, \beta, \boldsymbol{\alpha}; \Omega)$ 为联合先验分布函数。根据链式法则, $p(\mathbf{y}, \boldsymbol{\theta}, \beta, \boldsymbol{\alpha}; \Omega)$ 可表示为

$$p(\mathbf{y}, \boldsymbol{\theta}, \beta, \boldsymbol{\alpha}; \Omega) = p(\mathbf{y}|\boldsymbol{\theta}, \beta)p(\boldsymbol{\theta}|\boldsymbol{\alpha}) \cdot p(\beta; a, b)p(\boldsymbol{\alpha}; c, \mathbf{d}) \quad (15)$$

根据式(12)和式(15), $\boldsymbol{\theta}$ 的后验分布可表示为

$$\begin{aligned} \ln q^*(\boldsymbol{\theta}) &= \ln (\mathcal{N}(\boldsymbol{\theta}|\boldsymbol{\mu}, \boldsymbol{\Sigma})) \\ &\propto -\frac{1}{2} \boldsymbol{\theta}^T (\langle \beta \rangle \boldsymbol{\Phi}^T \boldsymbol{\Phi} + \langle \boldsymbol{\Lambda} \rangle) \boldsymbol{\theta} \\ &\quad + \langle \beta \rangle \boldsymbol{\theta}^T \boldsymbol{\Phi}^T \end{aligned} \quad (16)$$

其中, $\boldsymbol{\mu}$ 和 $\boldsymbol{\Sigma}$ 分别为 $\boldsymbol{\theta}$ 的均值向量和协方差矩阵。根据式(16), $\boldsymbol{\mu}$ 和 $\boldsymbol{\Sigma}$ 的更新规则为

$$\boldsymbol{\Sigma} = (\langle \beta \rangle \boldsymbol{\Phi}^T \boldsymbol{\Phi} + \langle \boldsymbol{\Lambda} \rangle)^{-1} \quad (17)$$

$$\boldsymbol{\mu} = \langle \beta \rangle \boldsymbol{\Sigma} \boldsymbol{\Phi}^T \mathbf{y} \quad (18)$$

根据式(13)和式(15), β 的后验分布可表示为

$$\begin{aligned} \ln q^*(\beta) &= \ln (\text{Gamma}(\beta; a^*, b^*)) \\ &\propto (0.5M + a - 1) \ln \beta \\ &\quad - \left(0.5 \left\langle \|\mathbf{y} - \boldsymbol{\Phi} \boldsymbol{\theta}\|_2^2 \right\rangle + b \right) \beta \end{aligned} \quad (19)$$

其中, a^* 和 b^* 为 β 后验分布中的参数。根据式(19), a^* 和 b^* 的更新规则为

$$a^* = 0.5M + a \quad (20)$$

$$b^* = 0.5 \left(\|\mathbf{y} - \boldsymbol{\Phi} \boldsymbol{\mu}\|_2^2 + \text{tr}(\boldsymbol{\Phi} \boldsymbol{\Sigma} \boldsymbol{\Phi}^T) \right) + b \quad (21)$$

根据式(14)和式(15), $\boldsymbol{\alpha}$ 的后验分布可表示为

$$\begin{aligned} \ln q^*(\boldsymbol{\alpha}) &= \ln \prod_{n=1}^N \text{Gamma}(\alpha_n; c^*, d_n^*) \\ &\propto (c - 0.5) \sum_{n=1}^N \ln \alpha_n \\ &\quad - \sum_{n=1}^N (d_n + 0.5 \langle \theta_n^2 \rangle) \alpha_n \end{aligned} \quad (22)$$

其中, c^* 和 d_n^* 为该后验分布中的参数。根据式(22),

c^* 和 d_n^* 的更新规则为

$$c^* = c + 0.5 \quad (23)$$

$$d_n^* = d_n + 0.5 \langle \theta_n^2 \rangle \quad (24)$$

其中, $\langle \theta_n^2 \rangle = \mu_n^2 + \Sigma_{n,n}$ 。根据上述后验分布的更新规则, 隐藏变量 β 和 α_n 的期望可分别表示为 $\langle \beta \rangle = a^*/b^*$ 和 $\langle \alpha_n \rangle = c^*/d_n^*$ 。

4.2 字典参数优化

为实现字典适配, 本节根据当前各隐藏变量的后验分布对字典环境参数 ρ_m 进行优化。新的字典环境参数可通过最大化似然函数 $p(\mathbf{y}|\boldsymbol{\theta}, \beta)$ 求得, 即

$$\rho^* = \arg \max_{\rho} \langle \ln p(\mathbf{y}|\boldsymbol{\theta}, \beta) \rangle_{q(\boldsymbol{\theta})q(\beta)q(\boldsymbol{\alpha})} \quad (25)$$

其中, $\rho = \{\rho_m\}_{m=1}^M$ 为对应于 M 条链路的字典环境参数集。将式(7)代入式(25), 通过忽略与 ρ 无关的项, 式(25)中的优化问题可转化为

$$\begin{aligned} \rho^* &= \arg \max_{\rho} \left\langle \left(2\pi\beta^{-1} \right)^{-\frac{M}{2}} \right. \\ &\quad \left. \cdot \exp \left(-\frac{\beta}{2} \|\mathbf{y} - \boldsymbol{\Phi}(\rho) \boldsymbol{\theta}\|_2^2 \right) \right\rangle_{q(\boldsymbol{\theta})q(\beta)q(\boldsymbol{\alpha})} \\ &= \arg \min_{\rho} \left\langle \|\mathbf{y} - \boldsymbol{\Phi}(\rho) \boldsymbol{\theta}\|_2^2 \right\rangle_{q(\boldsymbol{\theta})q(\beta)q(\boldsymbol{\alpha})} \\ &= \arg \min_{\rho} \left\langle \|\mathbf{y} - \boldsymbol{\Phi}(\rho) \boldsymbol{\mu}\|_2^2 \right. \\ &\quad \left. + \text{tr}(\boldsymbol{\Phi}^T(\rho) \boldsymbol{\Phi}(\rho) \boldsymbol{\Sigma}) \right\rangle_{q(\boldsymbol{\theta})q(\beta)q(\boldsymbol{\alpha})} \end{aligned} \quad (26)$$

式(26)中的优化目标函数为

$$H(\rho) = \|\mathbf{y} - \boldsymbol{\Phi}(\rho) \boldsymbol{\mu}\|_2^2 + \text{tr}(\boldsymbol{\Phi}^T(\rho) \boldsymbol{\Phi}(\rho) \boldsymbol{\Sigma}) \quad (27)$$

本文通过牛顿法求解上述优化问题。令 $f(\rho) = \|\mathbf{y} - \boldsymbol{\Phi}(\rho) \boldsymbol{\mu}\|_2^2$, $g(\rho) = \text{tr}(\boldsymbol{\Phi}^T(\rho) \boldsymbol{\Phi}(\rho) \boldsymbol{\Sigma})$, 则目标函数的梯度与海森阵可分别表示为

$$\nabla H(\rho) = \nabla f(\rho) + \nabla g(\rho) \quad (28)$$

$$\nabla^2 H(\rho) = \nabla^2 f(\rho) + \nabla^2 g(\rho) \quad (29)$$

其中, $\nabla f(\rho)$ 和 $\nabla^2 f(\rho)$ 分别表示 $f(\rho)$ 的梯度和海森阵, $\nabla g(\rho)$ 和 $\nabla^2 g(\rho)$ 分别表示 $g(\rho)$ 的梯度和海森阵。字典环境参数 ρ 可通过式(30)的方式迭代更新

$$\rho^{(\tau+1)} = \rho^{(\tau)} - \left(\nabla^2 H(\rho^{(\tau)}) \right)^{-1} \cdot \nabla H(\rho^{(\tau)}) \quad (30)$$

其中, τ 表示牛顿迭代次数。为减小计算复杂度, 最大迭代次数设为 $\tau_{\max} = 2$ 。

4.3 目标位置向量恢复

根据上述后验分布估计以及字典参数优化方法, 可实现目标位置向量恢复以及字典适配。目标位置估计算法如表1所示。本节根据 $\boldsymbol{\theta}$ 的均值 $\boldsymbol{\mu}$ 估计

表1 目标位置估计算法

(1)	令 $\gamma_{\text{th}} = 10^{-3}$, $r_{\text{max}} = 10^3$, $\eta_{\text{th}} = -10$ dB, $\gamma = \tau = 0$.
(2)	while ($\gamma \geq \gamma_{\text{th}}$ 或 $r \leq r_{\text{max}}$) do
(3)	根据式(17)和式(18), 计算 Σ 和 μ ;
(4)	根据式(20)和式(21), 更新参数 a^* 和 b^* ;
(5)	根据式(23)和式(24), 更新参数 c^* 和 d_n^* ;
(6)	while ($\tau \leq \tau_{\text{max}}$) do
(7)	根据式(30)更新 ρ ;
(8)	end while
(9)	令 $\gamma \leftarrow \ \mathbf{y} - \Phi(\rho^*)\mu\ _2^2$, $r \leftarrow r + 1$;
(10)	end while
(11)	$\forall n \in \{1, 2, \dots, N\}$, 若 $20 \lg(\mu_n / \max_i \mu_i) < \eta_{\text{th}}$, 则 $\mu_n = 0$;
(12)	令恢复的位置向量 $\hat{\theta} = \mu$, 目标个数 $\hat{K} = \hat{\theta} $.

目标位置, 并利用稀疏阈值 μ_{th} 滤除 μ 中可忽略的非零分量。所估计的目标位置向量为 $\hat{\theta}$, 其非零分量所对应的格点中心坐标即为目标位置的估计值。

5 仿真实验

本节利用 Matlab 仿真工具对所提定位方法的性能进行仿真评估。本仿真考虑在一个 $6.5 \text{ m} \times 6.5 \text{ m}$ 的区域对 $K = 4$ 个目标进行无源定位。定位区域被划分为 $N = 169$ 个大小相同的格点, 且部署 $M = 26$ 条链路。每条链路上都存在测量噪声, 且信噪比 $\text{SNR}(\text{dB}) \triangleq 10 \lg(\|\Phi\theta\|_2^2 \beta / M)$ 。仿真中将信噪比设为 $\text{SNR} = 20$ dB。本仿真利用平均定位误差 (E_A) 评价多目标无源定位的性能, E_A 定义为多次仿真中目标位置估计值与真实值间的平均欧氏距离。蒙特卡洛仿真次数 $P = 200$, 且第 p 次仿真的定位误差 (E_p) 为

$$E_p = \sum_{k=1}^{\hat{K}} \sqrt{(x^k - \tilde{x}^k)^2 + (y^k - \tilde{y}^k)^2} / \hat{K} \quad (31)$$

其中, \hat{K} 表示第 p 次仿真中目标个数的估计值。 (x^k, y^k) 代表第 k 个目标的真实坐标, $(\tilde{x}^k, \tilde{y}^k)$ 为第 k 个目标的估计坐标。根据式(31), 第 p 次仿真中的定位误差为 \hat{K} 个目标位置估计值与真实值间的平均

欧氏距离。平均定位误差 E_A 定义为 E_p 的均值, 即

$$E_A = \sum_{p=1}^P E_p / P \quad (32)$$

为验证所提定位方法的性能, 本文将所提方法与多种压缩感知多目标无源定位方案进行性能比较, 这些方案所利用的稀疏恢复算法分别为: 正交匹配追踪算法 OMP^[6]、基追踪算法 (Basis Pursuit, BP)^[17]、贪婪匹配追踪算法 GMP^[13] 以及贝叶斯压缩感知算法 (Bayesian Compressive Sensing, BCS)^[18]。本文方法则利用变分期望最大化 (VEM) 算法实现稀疏恢复。

为考察字典失配问题对多种压缩感知多目标无源定位方案的影响, 首先建立变化的无线定位环境。通过为字典环境参数加噪, 模拟无线定位环境中字典环境参数的动态变化。假设环境参数的变化次数为 t , 则字典环境参数可表示为


$$\rho_m^t = \rho_m^0 + \sum_{i=1}^t v_m^i \quad (33)$$

其中, ρ_m^0 为字典环境参数的初始值, 且 $\rho_m^0 = 0.3562$ 。 v_m^i 为加性高斯白噪声, 用来模拟字典环境参数随环境的动态变化。在此情况下, 测量向量可表示为

$$\mathbf{y} = \Phi(\rho^t)\theta + \varepsilon \quad (34)$$

图3为不同时刻, 字典原子 $[\Phi]_{10}$ 和 $[\Phi]_{20}$ 的值。由图3可知, 由于字典环境参数的变化, 不同时刻字典元素的值差异较大。如果基于固定字典 $\Phi(\rho^0)$ 并利用稀疏恢复算法估计目标位置向量, 将会产生字典失配, 并导致定位性能下降。

图4表示多种压缩感知多目标无源定位方案的定位性能与环境变化次数 t 的关系。由图4可知, 随着环境的变化, 采用固定字典的4种方案的定位性能逐渐恶化, 而本文所提的具有字典适配功能的定位方法受到环境变化的影响较小。这是因为字典适配方法能够实时地优化字典环境参数, 通过自适应地调整字典元素以避免字典失配对定位性能造成的

图3 不同时刻($t=1, 5, 10$)字典原子




图4 定位性能与环境变化的关系

不利影响。

图5所示是各无源定位方案的平均定位误差的累积分布函数。由图5可以看到本文所提的定位方法能以较大的概率取得较小的定位误差。图6表示平均定位误差与目标个数的关系。由图6可知，随着目标个数的增加，5种无源定位算法的平均定位误差逐渐增大。这是因为当目标个数增加时，目标位置向量 θ 的稀疏度随之降低。因此，通过压缩感知恢复算法所估计的目标位置向量的精度也随之降低。此外，与其他的无源定位方案相比，本文方法的平均定位误差最小。




图5 平均定位误差的累积分布函数




图6 平均定位误差与目标个数的关系

6 结束语

针对多目标无源定位中的字典失配问题，本文设计并实现压缩感知多目标无源定位的字典适配。该方法首先利用鞍面模型建立无源字典，并将字典环境参数设置为可调参数。然后，建立两层的混合高斯先验模型以诱导目标位置向量的稀疏性。最后，利用变分期望最大化算法估计目标位置向量以及优化字典环境参数实现字典适配。仿真结果表明，本文方法具有较好的定位性能，能有效应对无线定位环境的变化，解决多目标无源定位中的字典失配问题。

参考文献

- [1] WANG Jie, GAO Qinhua, PAN Miao, *et al.* Device-free wireless sensing: Challenges, opportunities, and applications[J]. *IEEE Network*, 2018, 32(2): 132–137. doi: [10.1109/MNET.2017.1700133](https://doi.org/10.1109/MNET.2017.1700133).
- [2] YOUSSEF M, MAH M, and AGRAWALA A. Challenges: Device-free passive localization for wireless environments[C]. *Proceedings of the ACM MobiCom'07*, Montreal, 2007: 222–229. doi: [10.1145/1287853.1287880](https://doi.org/10.1145/1287853.1287880).
- [3] ZHANG Dian, MA Jian, CHEN Quanbin, *et al.* An RF-based system for tracking transceiver-free objects[C]. *Proceeding of the 5th IEEE International Conference on Pervasive Computing and Communications (PerCom'07)*, White Plains, 2007: 135–144. doi: [10.1109/percom.2007.8](https://doi.org/10.1109/percom.2007.8).
- [4] WANG Ju, CHEN Xiaojiang, FANG Dingyi, *et al.* Transferring compressive-sensing-based device-free localization across target diversity[J]. *IEEE Transactions on Industrial Electronics*, 2015, 62(4): 2397–2409. doi: [10.1109/TIE.2014.2360140](https://doi.org/10.1109/TIE.2014.2360140).
- [5] KE Wei, WANG Tingting, and SHAO Jianhua. CS-based device-free localization in the presence of model errors[C]. *Proceedings of the 2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Shanghai, 2016: 4443–4447. doi: [10.1109/ICASSP.2016.7472517](https://doi.org/10.1109/ICASSP.2016.7472517).
- [6] WANG Ju, FANG Dingyi, and YANG Zhe. E-HIPA: An energy-efficient framework for high-precision multi-target adaptive device-free localization[J]. *IEEE Transactions on Mobile Computing*, 2017, 16(3): 716–729. doi: [10.1109/TMC.2016.2567396](https://doi.org/10.1109/TMC.2016.2567396).
- [7] TALAMPAS M and LOW K. A geometric filter algorithm for robust device-free localization in wireless networks[J]. *IEEE Transactions on Industrial Informatics*, 2016, 12(5): 1670–1678. doi: [10.1109/TII.2015.2433211](https://doi.org/10.1109/TII.2015.2433211).
- [8] LEI Qian, ZHANG Haijian, SUN Hong, *et al.* Fingerprint-based device-free localization in changing environments using enhanced channel selection and logistic regression[J].

- IEEE Access*, 2018, 6: 2569–2577. doi: [10.1109/ACCESS.2017.2784387](https://doi.org/10.1109/ACCESS.2017.2784387).
- [9] CHEN Xi, MA Chen, ALLEGUE M, *et al.* Taming the inconsistency of Wi-Fi fingerprints for device-free passive indoor localization[C]. Proceeding of the IEEE INFOCOM 2017, Atlanta, 2017: 1–9. doi: [10.1109/INFOCOM.2017.8057185](https://doi.org/10.1109/INFOCOM.2017.8057185).
- [10] WILSON J and PATWARI N. Ratio tomographic imaging with wireless networks[J]. *IEEE Transactions on Mobile Computing*, 2010, 9(5): 621–632. doi: [10.1109/TMC.2009.174](https://doi.org/10.1109/TMC.2009.174).
- [11] WANG Qinghua, YIGITLER H, JANTTI R, *et al.* Localizing multiple objects using radio tomographic imaging technology[J]. *IEEE Transactions on Vehicular Technology*, 2016, 65(5): 3641–3656. doi: [10.1109/TVT.2015.2432038](https://doi.org/10.1109/TVT.2015.2432038).
- [12] DONOHO D. Compressed sensing[J]. *IEEE Transactions on Information Theory*, 2006, 52(4): 1289–1306. doi: [10.1109/TIT.2006.871582](https://doi.org/10.1109/TIT.2006.871582).
- [13] WANG Ju, FANG Dingyi, CHEN Xiaojing, *et al.* LCS: Compressive sensing based device-free localization for multiple targets in sensor networks[C]. Proceeding of the IEEE INFOCOM 2013, Turin, 2013: 14–19. doi: [10.1109/INFOCOM.2013.6566752](https://doi.org/10.1109/INFOCOM.2013.6566752).
- [14] SONG Chaobing and XIA Shutao. Sparse signal recovery by minimization under restricted isometry property[J]. *IEEE Signal Processing Letters*, 2014, 21(9): 1154–1158. doi: [10.1109/LSP.2014.2323238](https://doi.org/10.1109/LSP.2014.2323238).
- [15] WANG Jie, GAO Qinhu, PAN Miao, *et al.* Towards accurate device-free wireless localization with a saddle surface model[J]. *IEEE Transactions on Vehicular Technology*, 2016, 65(8): 6665–6677. doi: [10.1109/TVT.2015.2476495](https://doi.org/10.1109/TVT.2015.2476495).
- [16] SEEGER M and WIPF D. Variational Bayesian inference techniques[J]. *IEEE Signal Processing Magazine*, 2010, 27(6): 81–91. doi: [10.1109/MSP.2010.938082](https://doi.org/10.1109/MSP.2010.938082).
- [17] CANDÈS E and WAKIN M. An introduction to compressive sampling[J]. *IEEE Signal Processing Magazine*, 2008, 25(2): 21–30. doi: [10.1109/MSP.2007.914731](https://doi.org/10.1109/MSP.2007.914731).
- [18] JI Shihao, XUE Ya, and CARIN L. Bayesian compressive sensing[J]. *IEEE Transactions on Signal Processing*, 2008, 56(6): 2346–2356. doi: [10.1109/TSP.2007.914345](https://doi.org/10.1109/TSP.2007.914345).
- 余东平：男，1989年生，博士生，研究方向为信号处理、无线传感器网络定位。
- 郭艳：女，1971年生，教授，博士生导师，研究方向为信号处理、压缩感知以及波束形成。
- 李宁：男，1967年生，副教授，研究方向为认知无线电、自组织网。
- 杨思星：女，1992年生，博士生，研究方向为信号处理、无源目标定位。