

基于多维测量信息的压缩感知多目标无源被动定位算法

余东平^① 郭艳^{*①} 李宁^① 刘杰^② 杨思星^①

^①(陆军工程大学通信工程学院 南京 210007)

^②(武警部队 北京 100089)

摘要: 无源被动定位是入侵者检测、环境监测以及智能交通等应用的关键问题之一。现有的无源被动定位方法可通过信道状态信息获取多个维度上的测量信息,但是现有方案未能充分挖掘多个信道上的频率分集以提高定位性能。该文提出一种基于多维测量信息的压缩感知多目标无源被动定位算法,在压缩感知框架下利用多维测量信息的频率分集提高定位精度和鲁棒性。根据鞍面模型建立无源字典,将多目标无源被动定位问题建模成多测量向量联合稀疏恢复问题,并利用多维稀疏贝叶斯学习算法估计目标位置向量。仿真结果表明,该算法能有效利用多维测量信息提高定位性能。

关键词: 无源被动定位; 压缩感知; 多测量向量; 稀疏贝叶斯学习

中图分类号: TN911.7

文献标识码: A

文章编号: 1009-5896(2019)02-0440-07

DOI: 10.11999/JEIT180333

Compressive Sensing Based Multi-target Device-free Passive Localization Algorithm Using Multidimensional Measurement Information

YU Dongping^① GUO Yan^① LI Ning^① LIU Jie^② YANG Sixing^①

^①(College of Communications Engineering, Army Engineering University of PLA, Nanjing 210007, China)

^②(The Chinese Armed Police Force, Beijing 100089, China)

Abstract: Device-free passive localization is a key issue of the intruder detection, environmental monitoring, and intelligent transportation. The existing device-free passive localization method can obtain the multidimensional measurement information by channel state information, but the existing scheme can not fully exploit the frequency diversity on multiple channels to improve the localization performance. This paper proposes a Compressive Sensing (CS) based multi-target device-free passive localization algorithm using multidimensional measurement information. It takes advantage of the frequency diversity of multidimensional measurement information to improve the accuracy and robustness of localization results under the CS framework. The dictionary is built according to the saddle surface model, and the multi-target device-free passive localization problem is modeled as a joint sparse recovery problem based on multiple measurement vectors. The target location vector is estimated based on the multiple sparse Bayesian learning algorithm. Simulation results indicate that the proposed algorithm can make full use of the multidimensional measurement information to improve the localization performance.

Key words: Device-free passive localization; Compressive Sensing (CS); Multiple measurement vectors; Sparse Bayesian Learning (SBL)

收稿日期: 2018-04-11; 改回日期: 2018-11-01; 网络出版: 2018-11-09

*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)

1 引言

近年来,随着物联网、泛在通信以及移动计算等技术的兴起和发展,用户对位置信息的需求日益增长。目标位置信息对实现基于位置的服务(Location-Based Service, LBS)至关重要,同时目标定位问题也受到了学术界越来越多的关注和研究^[1-3]。目前,已有多种成熟的目标定位系统被广泛应用于国防军事、资源管理以及交通运输等众多领域,如全球定位系统(Global Positioning System, GPS)以及基于移动蜂窝网的定位系统。这些定位系统能够满足用户在众多应用场景下的定位需求,同时也为目标定位技术的进一步发展奠定了必要基础。

在定位目标无法携带无线收发设备或是目标本身并不希望被监测或跟踪的场景中,传统的卫星定位以及有源定位技术将不再适用。针对此类场景,研究者们提出了不依赖于目标发射无线信号的无源被动定位(Device-Free passive Localization, DFL)技术^[4-6]。无源被动定位免除了目标需携带无线收发设备的需求,在定位过程中无需目标辐射电磁信号即可实现位置估计。与有源定位技术相比,无源被动定位技术具有更强的适用性以及更好的安全性,可应用在入侵者检测、紧急救援、智能交通以及智慧城市等应用中,对于实现基于位置的服务有着不可或缺的作用,是当前目标定位技术研究中很重要的一个方面。

无源被动定位技术利用目标在无线网络中的遮挡和阴影效应估计目标位置。根据对无线信号处理方式的不同,现有的无源被动定位技术主要可分为如下4类^[7]: (1)基于空间关系的无源被动定位技术^[8]; (2)基于指纹法的无源被动定位技术^[9]; (3)基于无线层析成像的无源被动定位技术^[10]; (4)基于压缩感知的无源被动定位技术^[7]。基于空间关系的无源被动定位技术根据无线信号强度的变化估计被遮挡链路和目标的空间关系。该方法需事先获取无线节点的位置信息且定位精度较低。为提高定位性能,指纹法被应用于无源被动定位中。基于指纹法的无源被动定位技术需耗费大量的人力与时间资源建立和更新指纹库,以保持指纹与位置信息的匹配。基于无线层析成像的无源被动定位根据计算机断层扫描技术估计目标位置信息,能取得较好的定位精度。但是,该方法需部署大量的无线链路以充分覆盖定位区域,对硬件资源的要求较高。

压缩感知(Compressive Sensing, CS)技术^[11]的出现为实现多目标无源被动定位提供了新的思路。压缩感知基于信号的稀疏性,通过在低维空间的非相关观测实现对高维信号的感知。在多目标无源被

动定位中,目标位置向量是稀疏的,因此通过非相关观测只需采集少量的测量信息,就能以高概率重构目标位置向量。基于压缩感知技术实现多目标无源被动定位,只需部署少量的无线链路即可获得较好的性能。LCS方法^[12]首先将压缩感知技术应用到无源被动定位中,并严格证明所建立的无源字典满足有限等距性质(Restricted Isometry Property, RIP)。E-HIPA方法^[7]基于正交匹配追踪(Orthogonal Matching Pursuit, OMP)算法恢复目标位置向量,该方法无需事先获取目标位置向量的稀疏度,可在目标数未知的情况下实现多目标无源被动定位。在无线定位环境中,环境的变化可对定位性能造成严重影响^[13]。为应对环境变化导致的字典失配问题,DR-DFL方法^[14]基于变分期望最大化(Variational Expectation-Maximization, VEM)算法实现字典适配和位置估计。

现有的无源被动定位技术大多利用接收信号强度(Received Signal Strength, RSS)的变化估计目标对无线链路的影响。在实际的定位环境中,无线链路上的接收信号强度易受到多径、衰落以及环境变化等因素的干扰。与接收信号强度相比,信道状态信息(Channel State Information, CSI)具有更好的稳定性^[15]。此外,信道状态信息包含多个子信道上的幅度和相位响应,能够为目标定位提供丰富的频率分集信息。目前,基于信道状态信息的有源和无源被动定位受到了学术界越来越多的关注和研究^[16,17]。但是,现有的基于信道状态信息的无源被动定位技术主要是对单个目标进行定位。并且,现有方案未能充分挖掘多个信道上的频率分集信息以提高定位性能。基于此,本文在压缩感知框架下基于信道状态信息实现多目标无源被动定位,将压缩感知技术与信道状态信息相结合,提出了基于多维测量信息的压缩感知多目标无源被动定位算法。该算法根据鞍面(Saddle Surface, SaS)模型^[18]设计无源字典,通过信道状态信息获取多个子信道上的定位信息,将多目标无源被动定位问题建模为基于多测量向量的联合稀疏恢复问题,并利用多维稀疏贝叶斯学习(Multiple Sparse Bayesian Learning, MSBL)算法^[19]实现联合稀疏恢复。

2 系统模型

基于压缩感知的多目标无源被动定位基本场景如图1所示。无线网络节点均匀地分布在目标监测区域周围,由无线网络节点所建立的 M 条无线链路实现对目标监测区域的覆盖。 K 个目标处在目标监测区域内,且因遮挡和阴影效应对多条链路上的无




图1 基于压缩感知的多目标无源被动定位基本场景

线信号造成影响。由于目标在监测区域中的位置是连续且随机的,为了稀疏表示其位置信息,将目标监测区域离散化。假设目标监测区域被均匀地划分为 N 个格点,且每个格点内至多包含一个目标,则多个目标的位置信息可用一个 N 维的稀疏向量表示

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

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, θ_n 取非零值。由于 $K \ll N$, 因此 $\boldsymbol{\theta}$ 为 K 稀疏的向量。

由于目标对无线信号的遮挡和阴影效应,被遮挡链路上的信道状态信息将会产生相应的变化。假设每条链路都能从 F 个子信道上采集信道状态信息,则链路 m 上的信道状态信息可表示为

$$H_m(f) = |H_m(f)| e^{j \sin\{\angle H_m\}} \quad (2)$$

其中, $H_m(f)$ 为对应于第 m 条链路的子信道 f 上的信道状态信息,且 $f \in \{1, 2, \dots, F\}$ 。 $|H_m(f)|$ 和 $\angle H_m$ 分别为该子信道上的幅度和相位响应。为了获取信号功率的衰减大小,可将 $|H_m(f)|$ 进行如式(3)变化。

$$P_m(f) = 20 \lg(|H_m(f)|/1000) \quad (3)$$

其中, $P_m(f)$ (dBm)为第 m 条链路在子信道 f 上的信号功率衰减值。为了估计目标对无线信号的影响,分别测量当目标处在和不在监测区域内时的信号功率衰减值。子信道 f 上的信号功率衰减变化量为

$$\begin{aligned} \Delta P_m(f) &= P_m(f) - P_m^0(f) \\ &\approx S_m(f) + \Delta \varepsilon_m(f) \end{aligned} \quad (4)$$

其中, $P_m^0(f)$ 为目标不在监测区域内时的功率衰减, $S_m(f)$ 代表由遮挡和阴影效应造成的功率衰减, $\Delta \varepsilon_m(f)$ 为噪声的变化。在 M 条链路上,通过采集不同子信道上的 $\Delta P_m(f)$,可建立如式(5)的多测量向量。

$$\begin{aligned} \mathbf{Y} &= [\mathbf{y}^1 \ \mathbf{y}^2 \ \cdots \ \mathbf{y}^f \ \cdots \ \mathbf{y}^F] \\ &= \begin{bmatrix} y_{11} & y_{12} & \cdots & y_{1F} \\ y_{21} & y_{22} & \cdots & y_{2F} \\ \vdots & \vdots & \ddots & \vdots \\ y_{M1} & y_{M2} & \cdots & y_{MF} \end{bmatrix}_{M \times F} \end{aligned} \quad (5)$$

其中, $\mathbf{Y} \in \mathbb{R}^{M \times F}$ 为测量矩阵,其第 (m, f) 个元素 $y_{mf} = \Delta P_m(f)$ 。由于目标监测区域中存在多个目标,我们将 y_{mf} 视为由多个目标造成的功率衰减的叠加,即

$$y_{mf} = \sum_{n=1}^N \theta_n \cdot h_{mn}(f) + \Delta \varepsilon_m(f) \quad (6)$$

其中, $h_{mn}(f)$ 表示格点 n 内存在目标时,第 m 条链路上子信道 f 的功率衰减。根据鞍面模型, $h_{mn}(f)$ 可表示为

$$\begin{aligned} h_{mn}(f) &= \left(\frac{1-\rho}{\lambda_1^2} U_{mn}^2 + \rho \left(1 - \frac{V_{mn}^2}{\lambda_2^2} \right) \right) \cdot \omega^f \\ \text{s.t.} \quad &\left(\frac{U_{mn}^2}{\lambda_1^2} + \frac{V_{mn}^2}{\lambda_2^2} \right) \leq 1 \end{aligned} \quad (7)$$

其中, λ_1 和 λ_2 分别为链路 m 上椭圆形影响区域的长半轴和短半轴。当目标处在该椭圆形影响区域内时,将会对该链路上的无线信号造成影响并使 $h_{mn}(f)$ 取非零值。 (U_{mn}, V_{mn}) 代表格点 n 相对于链路 m 的坐标。 ρ 为模型参数, ω^f 表示对应于不同子信道的环境参数。基于式(6)和式(7),测量矩阵 $\mathbf{Y}$ 可表示为

$$\mathbf{Y} = \boldsymbol{\Phi} \mathbf{W} + \boldsymbol{\Xi} \quad (8)$$

其中, $\boldsymbol{\Phi} \in \mathbb{R}^{M \times N}$ 为公共字典,其元素 $\phi_{mn} = h_{mn}(f)/\omega^f$ 。 $\boldsymbol{\Xi} \in \mathbb{R}^{M \times F}$ 为噪声矩阵,其第 (m, f) 个元素为 $\Delta \varepsilon_m(f)$ 。 $\mathbf{W} \in \mathbb{R}^{N \times F}$ 为稀疏矩阵,其元素 $w_{nf} = \theta_n \cdot \omega^f$ 。其中, $\mathbf{W}$ 的第 f 列元素为 K 稀疏向量 ω^f ,且 ω^f 和 $\boldsymbol{\theta}$ 具有共同的支撑集。并且, $\mathbf{W}$ 满足行稀疏度 $\text{rd}(\mathbf{W}) = K$ 。行稀疏度定义为

$$\text{rd}(\mathbf{W}) \triangleq \sum_{n=1}^N \mathcal{I}[\|\mathbf{W}_n\| > 0] \quad (9)$$

其中, $\mathbf{W}_n$ 代表 $\mathbf{W}$ 的第 n 行元素。 $\mathcal{I}[\cdot]$ 为指示函数, $\|\cdot\|$ 代表任意的向量范数。基于 $\mathbf{W}$ 的稀疏性,可通过求解如式(10)的松弛优化问题估计 $\mathbf{W}$ 。

$$\widehat{\mathbf{W}} = \arg \min_{\mathbf{W}} \left(\|\mathbf{Y} - \boldsymbol{\Phi} \mathbf{W}\|_F^2 + \ell \cdot \text{rd}(\mathbf{W}) \right) \quad (10)$$

其中, $\|\cdot\|_F$ 为Frobenius范数, ℓ 为优化参数。但是,求解式(10)所示的优化问题为NP难问题,并且参数 ℓ 的值未知。

3 联合稀疏恢复

本文基于多维稀疏贝叶斯学习算法估计稀疏矩

阵 $\mathbf{W}$ 。通过 $\exp[-(\cdot)]$ 变换, 可将式(10)所示的松弛优化问题转化为如式(11)的最大后验概率估计问题^[19]

$$\begin{aligned}\widehat{\mathbf{W}} &= \arg \max_{\mathbf{W}} p(\mathbf{Y} | \mathbf{W}) p(\mathbf{W}) \\ &= \arg \max_{\mathbf{W}} \frac{p(\mathbf{Y} | \mathbf{W}) p(\mathbf{W})}{p(\mathbf{Y})} \\ &= \arg \max_{\mathbf{W}} p(\mathbf{W} | \mathbf{Y})\end{aligned}\quad (11)$$

其中, $p(\mathbf{W}) \propto \exp[-\text{rd}(\mathbf{W})]$ 。为求解该问题, 将 $\mathbf{Y}$ 和 $\mathbf{W}$ 视为随机变量, 并为其分配先验概率以诱导 $\mathbf{w}^f$ 的稀疏性。假设 $\varepsilon_m(f)$ 为加性高斯白噪声, 则似然函数为

$$p(\mathbf{y}^f | \mathbf{w}^f, \sigma) = (2\pi\sigma^2)^{-\frac{N}{2}} \cdot \exp\left(-\frac{1}{2\sigma^2} \|\mathbf{y}^f - \Phi \mathbf{w}^f\|_2^2\right) \quad (12)$$

其中, σ^2 为噪声方差。为了诱导 $\mathbf{w}^f$ 的稀疏性, 假设 $\mathbf{W}$ 的行向量 W_n 服从 N 维的高斯分布

$$p(W_n; \alpha_n) = \mathcal{N}(0, \alpha_n \mathbf{I}_F) \quad (13)$$

其中, α_n 为 W_n 中元素的公共方差。这里, 用 $\{\alpha_1, \alpha_2, \dots, \alpha_N\}$ 诱导 $\{\mathbf{w}^1, \mathbf{w}^2, \dots, \mathbf{w}^F\}$ 的联合稀疏性。基于式(13), $\mathbf{W}$ 的先验分布可表示为

$$p(\mathbf{W}; \alpha) = \prod_{n=1}^N p(W_n; \alpha_n) \quad (14)$$

其中, $\alpha = [\alpha_1 \ \alpha_2 \ \dots \ \alpha_N]^T$ 。基于似然函数和上述先验分布, $\mathbf{w}^f$ 的后验分布可表示为

$$\begin{aligned}p(\mathbf{w}^f | \mathbf{y}^f; \alpha_n) &= \frac{p(\mathbf{w}^f, \mathbf{y}^f; \alpha)}{\int p(\mathbf{w}^f, \mathbf{y}^f; \alpha) d\mathbf{w}^f} \\ &= \mathcal{N}(\boldsymbol{\mu}_f, \boldsymbol{\Sigma})\end{aligned}\quad (15)$$

其中, $\boldsymbol{\Sigma}$ 为协方差矩阵, 其计算公式为

$$\boldsymbol{\Sigma} = \text{Cov}[\mathbf{w}^f | \mathbf{y}^f; \alpha] = \boldsymbol{\Gamma} - \boldsymbol{\Gamma} \Phi^T \boldsymbol{\Theta}^{-1} \Phi \boldsymbol{\Gamma} \quad (16)$$

其中, $\boldsymbol{\Gamma} = \text{diag}(\alpha)$, $\boldsymbol{\Theta} = \sigma^2 \mathbf{I} + \Phi \boldsymbol{\Gamma} \Phi^T$ 。设 $\boldsymbol{\mu}_f$ 为 $\mathbf{w}^f$ 的均值, 则 $\mathbf{W}$ 的均值可表示为

$$\boldsymbol{\Pi} = [\boldsymbol{\mu}_1 \ \boldsymbol{\mu}_2 \ \dots \ \boldsymbol{\mu}_F] = \mathbb{E}[\mathbf{W} | \mathbf{Y}; \alpha] = \boldsymbol{\Gamma} \Phi^T \boldsymbol{\Theta}^{-1} \mathbf{Y} \quad (17)$$

通过最大化 α 的边缘似然函数求解 α 的最优值, 其代价函数为

$$\begin{aligned}\mathcal{L}(\alpha) &= -2 \lg \int p(\mathbf{Y}, \mathbf{W}; \alpha) p(\mathbf{W}; \alpha) d\mathbf{W} \\ &= -2 \lg p(\mathbf{Y}; \alpha) \\ &= F \cdot \lg |\boldsymbol{\Theta}| + \sum_{f=1}^F (\mathbf{y}^f)^T \boldsymbol{\Theta}^{-1} \mathbf{y}^f\end{aligned}\quad (18)$$

本文采用循环迭代的方法寻找 α 的最优值。根据代

价函数 $\mathcal{L}(\alpha)$, α_n 和 σ^2 的更新规则可表示为

$$\alpha_n^* = \frac{1}{F} \|\boldsymbol{\Pi}_n\|_2^2 + \Sigma_{nn}, \forall n = 1, 2, \dots, N \quad (19)$$

$$(\sigma^2)^* = \frac{(1/F) \cdot \|\mathbf{Y} - \Phi \boldsymbol{\Pi}\|_{\mathcal{F}}^2}{M - N + \sum_{n=1}^N (\Sigma_{nn}/\alpha_n)} \quad (20)$$

根据参数更新规则以及 $\mathbf{w}^f$ 的后验分布, 可通过表1中所示的联合稀疏恢复算法估计 $\boldsymbol{\theta}$ 。在该算法中, 首先利用多维稀疏贝叶斯学习算法估计 $\mathbf{W}$ 后验分布, 从而得到 $\mathbf{W}$ 的均值 $\boldsymbol{\Pi}$ 和协方差阵 $\boldsymbol{\Sigma}$ 。由于 $\mathbf{W}$ 和 $\boldsymbol{\theta}$ 的支撑集相同, 可根据 $\boldsymbol{\Pi}$ 估计 $\boldsymbol{\theta}$ 。为减小估计误差, 该算法选取使得残差 $\|\mathbf{y}^f - \Phi \boldsymbol{\Pi}_{\cdot f}\|$ 最小的信道 $\hat{f}$, 并根据 $\boldsymbol{\Pi}_{\cdot \hat{f}}$ 求位置向量的估计值 $\hat{\boldsymbol{\theta}}$ 。由于噪声等因素的影响, $\boldsymbol{\Pi}_{\cdot \hat{f}}$ 并不是严格稀疏的, 并可能包含大量可忽略的非零分量。因此, 该算法在步骤(8)中利用阈值 η_{th} 滤除 $\boldsymbol{\Pi}_{\cdot \hat{f}}$ 中可忽略的非零分量。下面分析该联合稀疏恢复算法的计算复杂度。该算法的最大迭代次数为 τ_{max} , 每次迭代的计算复杂度分析如下:

表1 联合稀疏恢复算法

- (1) 令 $\gamma_{\text{th}} = 10^{-3}$, $\tau_{\text{max}} = 10^3$, $\eta_{\text{th}} = -10$ dB, $\gamma = \tau = 0$ 。
- (2) **while** ($\gamma \geq \gamma_{\text{th}}$ 或 $\tau \leq \tau_{\text{max}}$) **do**
- (3) 根据式(16)和式(17), 计算 $\boldsymbol{\Sigma}$ 和 $\boldsymbol{\Pi}$ 。
- (4) 根据式(19)和式(20), 更新参数 α_n 和 σ^2 。
- (5) 令 $\gamma \leftarrow \|\mathbf{Y} - \Phi \boldsymbol{\Pi}\|$, $\tau \leftarrow \tau + 1$ 。
- (6) **end while**
- (7) 选择使 $\|\mathbf{y}^f - \Phi \boldsymbol{\Pi}_{\cdot f}\|$ 取得最小值的子信道 $\hat{f}$ 。
- (8) $\forall n \in \{1, 2, \dots, N\}$, 若 $20 \lg(\boldsymbol{\Pi}_{n\hat{f}} / \max_i |\boldsymbol{\Pi}_{i\hat{f}}|) < \eta_{\text{th}}$, 则 $\boldsymbol{\Pi}_{n\hat{f}} = 0$ 。
- (9) 令恢复的位置向量 $\hat{\boldsymbol{\theta}} = \boldsymbol{\Pi}_{\cdot \hat{f}}$, 目标个数 $\hat{K} = |\hat{\boldsymbol{\theta}}|$ 。

步骤(3)需对 $\boldsymbol{\Theta}$ 求逆, 由于 $\boldsymbol{\Theta}$ 为 M 阶矩阵, 则 $\boldsymbol{\Theta}^{-1}$ 的计算复杂度为 $\mathcal{O}(M^3)$ 。式(16)和式(17)中均需进行矩阵乘法操作, 其计算复杂度为 $\mathcal{O}(N^2 M)$ 。由于 $M \ll N$, 则该步骤的计算复杂度为 $\mathcal{O}(N^2 M)$ 。

步骤(4)更新 $\{\alpha_n^*\}_{n=1}^N$ 的计算复杂度为 $\mathcal{O}(NF)$, 更新 $(\sigma^2)^*$ 的计算复杂度为 $\mathcal{O}(MNF)$ 。因此, 该步骤的计算复杂度为 $\mathcal{O}(MNF)$ 。

步骤(5)计算迭代残差的计算复杂度为 $\mathcal{O}(MNF)$ 。

由于 $N \gg F$, 则每次迭代的计算复杂度为 $\mathcal{O}(N^2 M)$ 。

4 仿真结果及分析

本节通过仿真实验验证所提定位算法的性能。在仿真中, 目标监测区域为 $14 \text{ m} \times 14 \text{ m}$ 的方形区

域, 本文将其分为 $N = 784$ 个大小相同的格点, 且覆盖该区域的链路数量 $M = 56$ 。假定 $\Delta\epsilon_m(f)$ 为加性高斯白噪声, 且定义信噪比 $\text{SNR}(\text{dB}) \triangleq 10 \lg (\|\Phi \mathbf{w}^f\|_2^2 / M\sigma^2)$ 。为了评价多目标无源被动定位的性能, 分别定义平均定位误差 (E_A)、定位均方根误差 (E_R) 以及正确计数概率 (P_C)。蒙特卡洛仿真次数为 $T = 200$ 次。 E_A 为目标位置的估计值与真实值间的平均欧氏距离。 E_R 定义为 $E_R = \sqrt{\sum E_t^2 / T}$, 其中 E_t 表示第 t 次仿真的定位误差。 P_C 则为能正确估计目标个数的概率。假设定位目标的真实位置坐标为 $\mathbf{x} = [x_1, x_2]^T$, 估计坐标为 $\hat{\mathbf{x}} = [\hat{x}_1, \hat{x}_2]^T$, 则有

$$\text{Cov}(\mathbf{x}) = \text{E}[(\hat{\mathbf{x}} - \mathbf{x})(\hat{\mathbf{x}} - \mathbf{x})^T] \geq \mathbf{F}^{-1}(\mathbf{x}) \quad (21)$$

其中, $\mathbf{F}(\mathbf{x}) \in \mathbb{R}^{2 \times 2}$ 为费雪信息矩阵 (Fisher Information Matrix, FIM)^[20]。根据 $\mathbf{F}(\mathbf{x})$ 计算 E_R 的克拉美罗限

$$E_R = \sqrt{\text{E}[\|\hat{\mathbf{x}} - \mathbf{x}\|^2]} \geq \sqrt{\text{tr}[\mathbf{F}^{-1}(\mathbf{x})]} \quad (22)$$

$\mathbf{F}(\mathbf{x})$ 的主对角元素可分别表示为

$$F_{1,1} = \frac{1}{\sigma^2(\mathbf{x})} \sum_{m=1}^M \left[\left(\frac{\partial h_m(\mathbf{x})}{\partial x_1} \right)^2 + 2 \left(\frac{\partial \sigma(\mathbf{x})}{\partial x_1} \right)^2 \right] \quad (23)$$

$$F_{2,2} = \frac{1}{\sigma^2(\mathbf{x})} \sum_{m=1}^M \left[\left(\frac{\partial h_m(\mathbf{x})}{\partial x_2} \right)^2 + 2 \left(\frac{\partial \sigma(\mathbf{x})}{\partial x_2} \right)^2 \right] \quad (24)$$

次对角元素可表示为

$$F_{1,2} = F_{2,1} = \frac{1}{\sigma^2(\mathbf{x})} \sum_{m=1}^M \left(\frac{\partial h_m(\mathbf{x})}{\partial x_1} \cdot \frac{\partial h_m(\mathbf{x})}{\partial x_2} + 2 \frac{\partial \sigma(\mathbf{x})}{\partial x_1} \cdot \frac{\partial \sigma(\mathbf{x})}{\partial x_2} \right) \quad (25)$$

其中, $\sigma^2(\mathbf{x})$ 表示链路噪声的方差, 可表示为

$$\sigma^2(\mathbf{x}) = \frac{\sum_{m=1}^M h_m^2(\mathbf{x})}{M \cdot \exp(\text{SNR}/10)} \quad (26)$$

$h_m(\mathbf{x})$ 表示当目标位于 $\mathbf{x}$ 时, 链路 m 上的信号强度。可表示为

$$h_m(\mathbf{x}) = h_m(\emptyset) - \Delta h_m(\mathbf{x}) \quad (27)$$

其中, $h_m(\emptyset)$ 表示当定位区域中不存在目标时, 链路 m 上的信号强度。 $\Delta h_m(\mathbf{x})$ 则表示当定位区域中存在目标时, 链路 m 上信号强度的变化量, 我们根据鞍面模型计算 $\Delta h_m(\mathbf{x})$ 。

本文将所提算法与现有的多种基于压缩感知的多目标无源被动定位算法进行性能比较, 这些算法所利用的稀疏恢复算法分别为: 正交匹配追踪 (OMP) 算法^[7]、基追踪算法 (Basis Pursuit, BP)^[11]、

贪婪匹配追踪 (Greedy Matching Pursuit, GMP) 算法^[12]、贝叶斯压缩感知 (Bayesian Compressive Sensing, BCS)^[21] 以及变分期望最大化算法 (VEM)^[14]。

4.1 算法迭代次数对定位性能的影响

目标位置向量的估计精度与联合稀疏恢复算法的循环迭代次数密切相关, 因此本节首先考察算法迭代次数 τ 对定位性能的影响。在仿真中, 目标数 $K = 5$, 且信噪比 $\text{SNR} = 25 \text{ dB}$ 。仿真结果如图2所示, 当 τ 逐渐增大时, E_A 逐渐降低, 且 P_C 逐渐增大。可以看到, 随着 τ 的增大, E_A 的下降率以及 P_C 的增长率逐渐降低。并且, τ 越大, 算法的计算复杂度越高, 实现目标位置估计所需要的时间也将随之增加。因此, 为了平衡定位性能与计算复杂度, 本文设置联合稀疏恢复算法的迭代阈值 $\tau_{\max} = 1000$ 。




图2 算法迭代次数对定位性能的影响

4.2 子信道数对定位性能的影响

本文所提算法利用信道状态信息所包含的频率分集信息提升定位性能, 本小节主要考察子信道数 F 对定位性能的影响。仿真中, 目标数 $K = 5$, 且信噪比 $\text{SNR} = 25 \text{ dB}$ 。仿真结果如图3所示, 随着 F 的增加, E_A 逐渐降低, 且 P_C 逐渐增加。仿真结果验证了自有算法能够有效地利用多维测量信息提升定位性能。当 $F > 20$ 时, 增加子信道数所带来的性能提升非常有限。这是因为子信道越多, 联合稀疏恢复所需的计算复杂度将随之增加, 从而阻碍了恢复精度的进一步提升。当 F 较大时, 由多个子信道引入的测量噪声对估计精度造成的负面影响也将




图3 子信道数对定位性能的影响

会随之增加。基于此，在后续的仿真中设置子信道的默认条数 $F = 20$ 。

4.3 目标个数与平均定位误差的关系

本小节对比多种压缩感知多目标无源被动定位算法的定位精度，主要考察目标个数 K 与 E_A 的关系。仿真中，信噪比 $\text{SNR} = 25 \text{ dB}$ 。仿真结果如图4所示，随着 K 的增加，多种无源被动定位算法的 E_A 均逐渐增大。这是因为 K 增大导致 θ 的稀疏度降低，压缩感知恢复算法的恢复精度也随之降低。图中“自有算法”表示本文所提出的基于多维测量信息的压缩感知多目标无源被动定位算法，CRLB表示克拉美罗限。可以看到，与其他的无源被动定位算法相比，自有算法的 E_A 最小。并且，当子信道数 F 越大时，自有算法的 E_A 越小。此外，当 θ 的稀疏度较低(K 较大)时，通过增加子信道所带来的性能提升更显著。




图4 目标个数与平均定位误差的关系

4.4 信噪比与平均定位误差的关系

本小节主要考察不同信噪比条件下多种压缩感知多目标无源被动定位算法的定位精度。仿真中，目标数 $K = 5$ 。仿真结果如图5所示，当 SNR 增加时，多种无源被动定位算法的 E_A 逐渐降低，CRLB表示克拉美罗限。当 $\text{SNR} > 25 \text{ dB}$ 时，随着 SNR 的增加自有算法的性能提升较小。由此可知，此时噪声已不再是限制自有算法定位性能的主要因素。此外，当 SNR 较小时，增加 F 对于提升定位性能具有较强的促进作用。这是因为当 F 增加时，联合稀疏恢复算法能获得更多的频率分集信息降低噪声的影响，提升定位性能。




图5 信噪比与平均定位误差的关系

4.5 平均定位误差与定位均方根误差的比较

本小节对比多种压缩感知多目标无源被动定位算法的平均定位误差 E_A 与定位均方根误差 E_R 。仿真中， $K = 5$ ， $\text{SNR} = 25 \text{ dB}$ 。仿真结果如表2所示，可以看到自有算法能获得最小的 E_A 以及 E_R 。与其他算法相比，自有算法能够充分利用多个子信道上的测量信息提高定位精度。并且还可以看到，随着 F 的增加， E_A 和 E_R 随之减小。这说明该算法在频率分集信息增加的情况下，能有效提升定位性能。分别比较当 F 为10和20的情况，虽然 E_A 下降较少，但是 E_R 下降较多，这说明定位结果的稳定性得到了较大的提升。

5 结束语

本文设计并实现了基于多维测量信息的多目标无源被动定位算法。该算法首先利用鞍面模型建立无源字典，并将字典环境参数与目标位置向量相结合，构成稀疏矩阵。然后，基于多维稀疏贝叶斯学习算法实现联合稀疏恢复。最后，根据恢复的稀疏矩阵估计目标位置向量。仿真结果表明，本文所提算法能有效利用信道状态信息所包含的频率分集信息提高定位性能。鉴于当前多目标无源被动定位技术存在的挑战以及其对基于位置服务的重要性，下一步研究工作包括：(1)研究基于动态目标的多目标无源被动定位算法，充分挖掘动态目标位置信息在时间上的相关性以提升无源被动定位性能；(2)研究目标个数未知时的多维稀疏贝叶斯算法中矩阵奇异导致的算法不收敛问题，探索相应的解决方法；(3)探索未知目标个数条件下稀疏恢复以及多维稀疏贝叶斯方法的性能。

表2 平均定位误差与定位均方根误差的比较

定位算法	OMP	BP	GMP	BCS	VEM	自有算法($F = 5$)	自有算法($F = 10$)	自有算法($F = 20$)
平均定位误差	3.2028	1.3028	2.1795	0.8955	0.6196	0.4631	0.2744	0.2584
定位均方根误差	3.3801	1.5735	2.4543	1.5838	1.0036	0.8392	0.6720	0.4738

参考文献

- [1] LIU Dawei, SHENG Bin, HOU Fen, *et al.* From wireless positioning to mobile positioning: An overview of recent advances[J]. *IEEE Systems Journal*, 2014, 8(4): 1249–1259. doi: [10.1109/JSYST.2013.2295136](https://doi.org/10.1109/JSYST.2013.2295136).
- [2] 冯奇, 曲长文, 周强. 多运动站异步观测条件下的直接定位算法[J]. 电子与信息学报, 2017, 39(2): 417–422. doi: [10.11999/JEIT160314](https://doi.org/10.11999/JEIT160314).
FENG Qi, QU Changwen, and ZHOU Qiang. Direct position determination using asynchronous observations of multiple moving sensors[J]. *Journal of Electronics & Information Technology*, 2017, 39(2): 417–422. doi: [10.11999/JEIT160314](https://doi.org/10.11999/JEIT160314).
- [3] 孙保明, 郭艳, 李宁, 等. 无线传感器网络中基于压缩感知的动态目标定位算法[J]. 电子与信息学报, 2016, 38(8): 1858–1864. doi: [10.11999/JEIT151203](https://doi.org/10.11999/JEIT151203).
SUN Baoming, GUO Yan, LI Ning, *et al.* Mobile target localization algorithm using compressive sensing in wireless sensor networks[J]. *Journal of Electronics & Information Technology*, 2016, 38(8): 1858–1864. doi: [10.11999/JEIT151203](https://doi.org/10.11999/JEIT151203).
- [4] 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).
- [5] ZHANG Dian, MA Jian, CHEN Quanbin, *et al.* An RF-based system for tracking transceiver-free objects[C]. Proceedings 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).
- [6] 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).
- [7] 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).
- [8] TALAMPAS M C R and LOW K S. 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).
- [9] KHALAJMEHRABADI A, GATSIS N, and AKOPIAN D. Modern WLAN fingerprinting indoor positioning methods and deployment challenges[J]. *IEEE Communications Surveys & Tutorials*, 2017, 19(3): 1974–2002. doi: [10.1109/COMST.2017.2671454](https://doi.org/10.1109/COMST.2017.2671454).
- [10] 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).
- [11] CANDES E J and WAKIN M B. 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).
- [12] 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/INFCOM.2013.6566752](https://doi.org/10.1109/INFCOM.2013.6566752).
- [13] MAGER B, LUNDRIGAN P, and PATWARI N. Fingerprint-based device-free localization performance in changing environments[J]. *IEEE Journal on Selected Areas in Communications*, 2015, 33(11): 2429–2438. doi: [10.1109/JSAC.2015.2430515](https://doi.org/10.1109/JSAC.2015.2430515).
- [14] YU Dongping, GUO Yan, LI Ning, *et al.* Dictionary refinement for compressive sensing based device-free localization via the variational EM algorithm[J]. *IEEE Access*, 2016, 4: 9743–9757. doi: [10.1109/ACCESS.2017.2649540](https://doi.org/10.1109/ACCESS.2017.2649540).
- [15] YANG Zheng, ZHOU Zimu, and LIU Yunhao. From RSSI to CSI: Indoor localization via channel response[J]. *ACM Computing Surveys*, 2013, 46(2): 1–32. doi: [10.1145/2543581.2543592](https://doi.org/10.1145/2543581.2543592).
- [16] GAO Qinhua, WANG Jie, MA Xiaorui, *et al.* CSI-based device-free wireless localization and activity recognition using radio image features[J]. *IEEE Transactions on Vehicular Technology*, 2017, 66(11): 10346–10356. doi: [10.1109/TVT.2017.2737553](https://doi.org/10.1109/TVT.2017.2737553).
- [17] 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).
- [18] WANG Jie, GAO Qinhua, 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).
- [19] WIPF D P and RAO B D. An empirical Bayesian strategy for solving the simultaneous sparse approximation problem[J]. *IEEE Transactions on Signal Processing*, 2007, 55(7): 3704–3716. doi: [10.1109/TSP.2007.894265](https://doi.org/10.1109/TSP.2007.894265).
- [20] SAVAZZI S, NICOLI M, CARMINATI F, *et al.* A Bayesian approach to device-free localization: Modeling and experimental assessment[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2014, 8(1): 16–29. doi: [10.1109/JSTSP.2013.2286772](https://doi.org/10.1109/JSTSP.2013.2286772).
- [21] 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。