

无线传感器网络中基于压缩感知的动态目标定位算法

孙保明 郭艳* 李宁 钱鹏
(解放军理工大学通信工程学院 南京 210007)

摘要: 传统的动态目标定位算法需要采集、存储和处理大量数据,并不适用于能量受限的无线传感器网络。针对该缺陷,该文提出一种基于压缩感知的动态目标定位算法。该算法利用目标的运动规律设计稀疏表示基,从而将动态目标定位问题转化为稀疏信号恢复问题。针对传统观测矩阵难以实现的缺陷,该算法设计可实现且与稀疏表示基相关性低的稀疏观测矩阵,从而保证了算法的重构性能。该算法的特点是可利用较少的数据采集实现动态目标定位,从而大大延长无线传感器网络的寿命。仿真结果表明,该文所提出的基于压缩感知的动态目标定位算法具有较好的定位性能。

关键词: 无线传感器网络; 动态目标定位; 压缩感知; 稀疏表示基; 观测矩阵

中图分类号: TP393; TN911.7

文献标识码: A

文章编号: 1009-5896(2016)08-1858-07

DOI: 10.11999/JEIT151203

Mobile Target Localization Algorithm Using Compressive Sensing in Wireless Sensor Networks

SUN Baoming GUO Yan LI Ning QIAN Peng

(Institute of Communications Engineering, PLA University of Science and Technology, Nanjing 210007, China)

Abstract: Traditional mobile target localization algorithms are not suitable for wireless sensor networks as they need to collect, store, and process a mass of data. To address this issue, a mobile target localization algorithm based on compressive sensing is proposed. Two sparse representation bases are designed by exploiting the movement characteristics of mobile targets, therefore the mobile target localization issue is transferred into a sparse signal recovery issue. To avoid the unpractical limitation of traditional measurement matrices, two sparse measurement matrices are proposed that are practical and lowly coherent with the designed representation bases. The characteristic of this algorithm is that mobile target localization can be achieved by collecting a little data, thus prolonging the lifetime of wireless sensor networks. Simulation results indicate that the proposed localization algorithm based on compressive sensing is highly efficient.

Key words: Wireless sensor networks; Mobile target localization; Compressive sensing; Sparse representation basis; Measurement matrix

1 引言

无线传感器网络是由大量廉价的具有感知、通信和计算能力的微型传感器形成的多跳自组织网络。其目的是感知、采集和处理网络覆盖区域中各种感知对象的信息,例如温度、压力、湿度、噪声、光强度等物理信号。与传统的信息获取方式相比,无线传感器网络具有自组织、廉价、可扩展性强以及能在恶劣环境下正常工作等优点,在国防军事、

城市管理、生物医疗、环境监测和反恐救灾等众多领域具有极为广阔的应用前景^[1]。

在无线传感器网络的各种应用中,隐藏着一个共同的必备信息——位置信息。位置信息至关重要,传感器感知的数据只有在获得位置信息后才具有更高的使用价值^[2]。在实际生活中,人们不仅关心某一监测事件的发生,而且关心该事件发生的位置,只有知道位置信息后才能采取相应的应对措施。例如森林火灾报警必须获取火灾的具体位置,入侵者监测必须实时掌握入侵者的运动轨迹,毒气泄漏时必须知道有害气体的漫延范围等。复杂多变的应用环境导致传感器网络拓扑具有高度的动态性,若要实现动态目标实时定位,必须频繁地感知和处理大量信息,这对信号采样速率和数据处理速度提出了较

收稿日期: 2015-10-29; 改回日期: 2016-03-29; 网络出版: 2016-05-09

*通信作者: 郭艳 guoyan_2000@sina.com

基金项目: 国家自然科学基金(61571463, 61371124, 61272487, 61472445, 61201217)

Foundation Items: The National Natural Science Foundation of China (61571463, 61371124, 61272487, 61472445, 61201217)

高要求,使得传统的信号采样和数据处理方法“力不从心”。

压缩感知(Compressive Sensing, CS)技术^[3,4]的出现为解决上述问题提供了新思路。作为信号处理领域的新兴技术,压缩感知基于信号的稀疏性,它通过低维空间的非相关观测实现对高维信号的感知。压缩感知理论表明,只要信号在某个变换基下是稀疏的,就可以用一个与变换基不相关的观测矩阵对信号进行少量采样,而这些少量的采样值却包含了重构该信号的足够信息,通过求解一个优化问题就可以从这些采样值中以高概率重构原信号。在压缩感知理论中,信号的采样与压缩同时以低速率进行,对能量和计算能力的要求较低;而信号恢复是一个优化计算的过程,对能量和计算能力的要求较高。无独有偶,在无线传感器网络动态目标定位中,负责信息采集的传感器由于靠电池供电,能量及计算能力均受限,而负责信息处理的融合中心则没有能量及计算能力的限制。因此,压缩感知理论的这种天然特点仿佛是为无线传感器网络中动态目标定位问题“量身定制”的。

文献[5]将目标所在的区域离散化为一个网格,通过探讨目标位置与接收信号强度(Received Signal Strength, RSS)向量之间的关系,将定位问题转化为RSS向量在某字典下的稀疏逼近问题,奠定了压缩感知定位技术的基础。但是该方法需要为每个传感器构建一个稀疏字典,定位开销较大。文献[6]通过离散物理空间将每个目标的位置转化为稀疏度为1的向量,从而将多目标定位问题转化为多稀疏向量恢复问题,并利用压缩感知技术进行定位。但该方法数据压缩不充分,且需要事先知道目标的个数。文献[7]研究了在目标数目未知情况下的多目标定位问题,将多个目标的位置转化为一个稀疏向量,并设计了基于贪婪匹配追踪的恢复算法。文献[8]采用残差最优匹配和多分辨率分析的方法对压缩感知重构算法进行了改进,提高了定位精度,但是增加了恢复算法的计算复杂度。文献[9,10]对感知矩阵分别进行LU分解和奇异值分解,得到的新感知矩阵有效地满足了约束等距性条件,且该预处理方法不影响原信号的稀疏性,保证了算法的定位性能,但增加了算法复杂度和定位开销。文献[11]提出一种基于字典学习的压缩感知室内定位方法。该方法首先利用K-SVD将无线电地图(Radio Map, RM)分解为一个稀疏字典和一个稀疏表示矩阵的乘积,该稀疏表示矩阵的每一列对应着一个参考点。在线阶段测得的RSS向量在稀疏字典中的表示系数与稀疏表示矩阵的每一列向量的相关性最小,该列对应的参考节

点的位置即为目标的位置。文献[12]提出一种压缩感知与多边测量技术相结合的无线传感器网络定位算法。该方法克服了目标只能在网格中心的局限性,但是增加了计算复杂度。文献[13]设计一种基于梯度投影的两步字典学习算法,利用该算法学习真实稀疏字典,从而消除环境变化造成的定位误差。文献[14,15]提出了一种非基于测距的压缩感知定位方法。该方法通过测量传感器感知范围内目标的数量来实现定位,算法实现简单,但定位精度很难得到保证。

以上的定位方法只考虑了静态目标,而忽略了动态目标。基于此,本文提出了一种基于压缩感知的动态目标定位算法。该算法通过时间离散化建立压缩感知模型,利用目标的运动规律设计稀疏表示基,将动态目标定位问题转化为稀疏信号恢复问题,利用较少信号采集实现动态目标精确定位,从而大大延长无线传感器网络寿命。

2 压缩感知

压缩感知理论表明,如果信号 $\mathbf{x} \in \mathbb{R}^N$ 稀疏,即 $\|\mathbf{x}\|_0 = K, (K \ll N)$,就能够按照观测矩阵 $\Phi \in \mathbb{R}^{M \times N}$,以低于奈奎斯特定律的速率对其采样,并通过观测值 $\mathbf{y} = \Phi \mathbf{x}$ 以高概率恢复出原始信号。然而,实际中的很多信号本身不是稀疏的,但是能在某个稀疏表示基 Ψ 下稀疏表示,即 $\mathbf{x} = \Psi \mathbf{r}, \|\mathbf{r}\|_0 \ll N$,同样可以按照观测矩阵 Φ 对其进行欠采样,并通过观测值 $\mathbf{y} = \Phi \Psi \mathbf{r}$ 以高概率恢复出原始信号,其模型如图1所示。




图1 压缩感知模型

从 \mathbf{y} 中恢复 \mathbf{x} 是一个解线性方程组的问题,需要求解如式(1)所示的优化问题:

$$\min_{\mathbf{r}} \|\mathbf{r}\|_0, \text{ s.t. } \mathbf{y} = \Phi \Psi \mathbf{r} \quad (1)$$

显然,这是一个NP难问题。然而,当矩阵 $\Phi \Psi$ 满足有限等距性质(Restricted Isometry Property, RIP)^[16]时,上述问题可以松弛为 ℓ_1 范数最小优化问题:

$$\min_{\mathbf{r}} \|\mathbf{r}\|_1, \text{ s.t. } \mathbf{y} = \Phi \Psi \mathbf{r} \quad (2)$$

为了精确重构 \mathbf{r} ,观测次数 M 需满足 $M \geq C \mu^2(\Phi, \Psi) K \lg N$,其中 C 为某一固定常数, $\mu(\Phi, \Psi)$ 表示测量矩阵 Φ 和稀疏表示基 Ψ 的相关性。对于给定的

N 维空间中的一组正交基 (Φ, Ψ) ，它们的相关性可表示为

$$\mu(\Phi, \Psi) = \sqrt{N} \max_{1 \leq i, j \leq N} |\langle \varphi_i^r, \psi_j \rangle| \in [1, \sqrt{N}] \quad (3)$$

其中 φ_i^r 和 ψ_j 分别表示 Φ 和 Ψ 的行向量和列向量。

因此，对于给定的信号 x ，应该选择合适的稀疏表示基 Ψ 和观测矩阵 Φ ；在保证信号 x 在 Ψ 中的表示向量稀疏的同时，使 Ψ 和 Φ 之间的相关性足够小。

3 系统模型

为简单起见，我们只考虑 1 维空间中的一个动态目标，相同的方法可以应用到多维空间中的多个目标。动态目标的位置在时域中是随机且连续的，为了将其离散化，将时间划分为 T 个时刻。一个动态目标在 T 个时刻的位置可表示为 $x = [x_1 \ x_2 \ \dots \ x_T]^T$ ，其中 x_i 表示目标在第 i 个时刻的位置。传统的动态定位方法假设目标在每个时刻内是静止的，然后在每个时刻内用静态方法实现定位。这种方法的精度取决于时间分辨率的大小，若要实现精确定位，需要频繁地执行静态定位算法，定位开销较大。

实际上，目标的运动往往呈现某种规律，即目标的运动轨迹与运动速度在时域中均具有平滑性。这些规律为利用压缩感知技术进行动态目标定位提供了契机。压缩感知的两大要素就是稀疏表示基和观测矩阵。若存在一个稀疏表示基 Ψ ，使得位置向量 x 稀疏，那么可以通过一个测量矩阵 Φ 对 x 进行欠采样，并通过少量的采样值恢复出位置向量 x 。值得说明的是，这里的采样是指在抽样时刻对目标进行静态定位，采样值为目标在若干个抽样时刻的位置。因此，本文的目标就是设计合理的稀疏表示基和观测矩阵，建立压缩感知模型，利用少量时刻内的目标位置恢复所有时刻内的目标位置，如图 2 所示。

4 矩阵设计

4.1 稀疏表示基设计

实际中，我们注意到目标的运动轨迹在时域内




图2 动态目标定位模型

具有平滑性，即目标位置只有在少数时刻发生较大改变。因此，我们考虑如式(4)所示矩阵：

$$M_T = \begin{bmatrix} 1 & -1 & 0 & \dots \\ 0 & 1 & -1 & \dots \\ 0 & 0 & 1 & \dots \\ \vdots & \vdots & \vdots & \ddots \end{bmatrix} \quad (4)$$

位置向量 x 在矩阵 M_T 下的投影向量为

$$r_T = \begin{bmatrix} 1 & -1 & 0 & \dots \\ 0 & 1 & -1 & \dots \\ 0 & 0 & 1 & \dots \\ \vdots & \vdots & \vdots & \ddots \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} = \begin{bmatrix} x_1 - x_2 \\ x_2 - x_3 \\ \vdots \\ x_n - x_1 \end{bmatrix} \quad (5)$$

r_T 中的元素 $(x_{i+1} - x_i)$ 表示目标在两个相邻时刻的位置之差。因此， r_T 中只有少量元素较大，其他大部分元素可以忽略。令 $\Psi_T = M_T^{-1}$ ，位置向量 x 可稀疏表示为 $x = \Psi_T r_T$ 。

另外，我们还发现动态目标的速度在整个时域内也具有平滑性，即目标的速度只有在少量时刻发生显著变化。因此，我们考虑如式(6)所示矩阵：

$$M_S = \begin{bmatrix} 2 & -1 & 0 & 0 & \dots \\ -1 & 2 & -1 & 0 & \dots \\ 0 & -1 & 2 & -1 & \dots \\ \vdots & \vdots & \vdots & \vdots & \ddots \end{bmatrix} \quad (6)$$

位置向量 x 在矩阵 M_S 下的投影向量为

$$r_S = \begin{bmatrix} 2 & -1 & 0 & 0 & \dots \\ -1 & 2 & -1 & 0 & \dots \\ 0 & -1 & 2 & -1 & \dots \\ \vdots & \vdots & \vdots & \vdots & \ddots \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} = \begin{bmatrix} 2x_1 - x_2 \\ 2x_2 - x_1 - x_3 \\ \vdots \\ 2x_n - x_{n-1} \end{bmatrix} \quad (7)$$

r_S 中的元素 $(x_i - x_{i-1}) - (x_{i+1} - x_i)$ 近似为目标在两个相邻时刻的速度之差。因此， r_S 中只有少量元素较大，其他大部分元素可以忽略。令 $\Psi_S = M_S^{-1}$ ，位置向量 x 可稀疏表示为 $x = \Psi_S r_S$ 。

4.2 观测矩阵设计

目前，压缩感知理论大多采用随机矩阵(例如高斯随机矩阵)作为观测矩阵。这类矩阵能够保证以较大概率与稀疏表示基不相关，然而这类矩阵是非稀疏矩阵，不能应用于本文的定位场景。在本文的动态目标定位中，一次观测相当于在某个抽样时刻执行一次静态定位算法，利用目标在若干时刻的位置恢复所有时刻的位置。显然，一次观测只能在一个时刻内进行；另外假设观测值是精确的，每个抽样时刻只需观测一次^[17]。因此，观测矩阵是稀疏矩阵，即它的每行只有一个“1”，每列至多有一个“1”，其它元素全部为“0”。若它的元素 $\varphi_{m,n} = 1$ ，表明在第 n 个时刻进行第 m 次观测。基于此，我们考虑

如下两种观测矩阵:

(1)随机稀疏观测矩阵: 随机选择若干个时刻进行观测, 记做 Φ_R 。

(2)均匀稀疏观测矩阵: 均匀选择若干个时刻进行观测, 记做 Φ_U 。

5 性能分析

在压缩感知中, 实现信号重构需要满足以下两个条件: (1)信号在稀疏表示基下的表示向量足够稀疏; (2)稀疏表示基与观测矩阵不相关。本节将从这两个角度分析所设计的稀疏表示基和观测矩阵的性能。

5.1 稀疏表示基的稀疏信号能力

实际中, 信号 x 在稀疏表示基 Ψ 下的表示系数 r 并非完全稀疏的, 而是可压缩的, 即它的大部分元素接近于零。本文设计一种指标来衡量稀疏表示基的稀疏信号能力, 即 $(\sum_{i=1}^K r_i^2) / (\sum_{i=1}^N r_i^2)$, 其中 r_i 表示向量 r 中的第 i 大元素; $\sum_{i=1}^K s_i^2$ 表示向量 s 中的 K 个最大元素的能量; $\sum_{i=1}^N s_i^2$ 表示向量 s 的总能量。对于给定的参数 K , 该指标越大, 稀疏表示基的稀疏信号能力越强。

本文分别采用模拟数据和实测数据来衡量稀疏表示基的稀疏信号能力, 其中模拟数据通过随机游走模型(Random Waypoint Model, RWM)获得, 实测数据^[18]通过对不同地区若干志愿者的运动轨迹采集获得, 如表 1 所示。测试结果表明稀疏表示基 Ψ_S 的稀疏信号能力强于稀疏表示基 Ψ_T , 如图 3 所示。当采用稀疏表示基 Ψ_S 时, 最大的 20 个元素占据了所有信号中 62.5%~91.4%的能量, 这些信号的能量都集中在少量的大系数中。由此可见, 稀疏表示基 Ψ_S 具有较强的稀疏信号能力。

5.2 相关性

式(3)只能用来计算两个正交基之间的相关性, 而不能直接用来计算本文所设计的稀疏表示基和观测矩阵之间的相关性。因此, 这里采用非相关性^[17]来间接反映稀疏表示基和观测矩阵相关性的大小。对于给定的一组稀疏表示基和观测矩阵 (Ψ, Φ) , 它

们之间的非相关性 $I(\Psi, \Phi)$ 定义为

$$I(\Psi, \Phi) = \min_{1 \leq i \leq M} \|\theta_i\|_0 \quad (8)$$

其中 θ_i 表示观测矩阵 Φ 的第 i 个行向量在由稀疏表示基 Ψ 各列张成的空间中的投影向量, 即

$$\theta_i = (\Psi^T \Psi)^{-1} \Psi^T \varphi_i^r \quad (9)$$

其中 φ_i^r 表示观测矩阵 Φ 的第 i 个行向量。 $I(\Psi, \Phi)$ 越大, 稀疏表示基 Ψ 和观测矩阵 Φ 之间的非相关性越大, 相关性越小。

表 2 分别显示了不同稀疏表示基和观测矩阵组合之间的非相关性。由表可知, 本文所设计的稀疏表示基和观测矩阵的非相关性较大, 即相关性较小。当观测矩阵 Φ 固定时, Ψ_S 与 Φ 之间的非相关性大于 Ψ_T 与 Φ 之间的非相关性。当稀疏表示基 Ψ 固定时, Φ_U 和 Ψ 之间的非相关性几乎等于 Φ_R 与 Ψ 之间的非相关性。然而, 相对于 Φ_R, Φ_U 的观测点更加均匀, 能够携带更多信息。而相对于 Φ_U, Φ_R 中的观测点可以随机选取, 实际中不需要人为控制抽样时刻, 操作更加简单。

表 2 稀疏表示基与观测矩阵的非相关性

N	$I(\Psi_T, \Phi_U)$	$I(\Psi_S, \Phi_U)$	$I(\Psi_T, \Phi_R)$	$I(\Psi_S, \Phi_R)$
200	188	199	184	199
400	386	399	385	400
600	555	599	561	600
800	764	800	765	800
1000	973	999	979	1000

6 仿真结果与分析

6.1 仿真场景

我们采用前文所述的模拟数据和实测数据来验证本文所提定位算法的性能。模拟数据由在 100 m×100 m 的区域中的 20 个目标随机游走产生, 时间间隔为 1 s, 最大速度为 10 m/s, 最小速度为 2 m/s, 暂停时间为 10 s。为了方便与模拟数据进行比较, 我们对实测数据中目标的运动范围进行相应比例的缩放, 使它的大小也为 100 m×100 m。本文采用的性能指标为所有目标在所有时刻内的平均误差, 即

$$\text{AvgError} = \frac{1}{TK} \sum_{k=1}^K \sum_{t=1}^T \sqrt{(x_{kt} - \hat{x}_{kt})^2 + (y_{kt} - \hat{y}_{kt})^2} \quad (10)$$

其中 K 是网络中的目标个数, T 是时刻数, (x_{kt}, y_{kt}) 和 $(\hat{x}_{kt}, \hat{y}_{kt})$ 分别表示第 k 个目标在第 t 个时刻内的真实位置与估计位置。

表 1 本文所采用的实测数据

轨迹名称	描述	时间间隔(s)
KAIST	KAIST 大学 20 个学生的移动轨迹	10
NCSU	NCSU 大学 32 个学生的移动轨迹	10
NewYork	纽约市 12 个志愿者的移动轨迹	10
Orlando	奥兰多市 8 个志愿者的移动轨迹	10

6.2 恢复算法的影响

本节首先研究不同的恢复算法对定位性能的影响。本文考虑的恢复算法包括基追踪(Basis Pursuit, BP), 正交匹配追踪(Orthogonal Matching Pursuit, OMP)和迭代加权最小二乘(Iterative Re-Weighted Least Squares, IRWLS)。在该实验中, 稀疏表示基 Ψ 采用 Ψ_S , 观测矩阵 Φ 采取 Φ_U , 观测次数 $M = 200$, 仿真结果如图 4 所示。由图可见, BP 恢复算法优于 OMP 和 IRWLS 算法。这是因为 BP 运用线性规划求解一个优化问题, 而 OMP 和 IRWLS 都是通过贪婪迭代的方法获得最优解, 3 种算法的计算复杂度将于 6.5 节进行讨论。另外, 在所有的实测数据中, NewYork 轨迹的定位误差最小; 这是因为 NewYork 轨迹的稀疏性最好, 如图 3 所示。

6.3 矩阵选择的影响

图 5 给出了不同的矩阵(稀疏表示基和观测矩阵)选择对定位性能的影响。从图中可以看出, 首先当观测矩阵固定时, 稀疏表示基 Ψ_S 优于稀疏表示基 Ψ_T , 这是因为 Ψ_S 的稀疏信号能力强于 Ψ_T , 如图 3 所示。其次当稀疏表示基 Ψ 固定时, 均匀稀疏观测矩阵 Φ_U 优于随机稀疏观测矩阵 Φ_R , 该现象与表 2 中的结论并不相符。这是因为恢复性能不仅与 $I(\Phi, \Psi)$ 有关, 还与观测点的分布有关。观测点分布越均匀, 恢复性能越好, 反之越差。在 Φ_U 中, 观测点均匀选取, 观测值能够涵盖信号在较多时间段的信息; 而在 Φ_R 中, 观测点随机选取, 观测值只能涵盖信号在较少时间段的信息。

6.4 测量噪声的影响

在实际测量中, 传感器不可避免地会受到周围噪声的影响。为了检验定位算法的鲁棒性, 我们在每个测量值中添加一个均值为 0, 方差为 σ 的高斯白噪声 $N(0, \sigma^2)$, 定义信噪比为 $SNR = 10 \lg(\|x\|_2^2 / (M\sigma^2))$ 。在该实验中, 稀疏表示基 Ψ 采用 Ψ_S , 观

测矩阵采取 Φ_R 。图 6 显示了在无噪声, $SNR=30$ dB 和 $SNR=20$ dB 情况下两种数据的定位结果。

由图 6 可见, 对于所有的参数设置, 定位误差随着测量次数的增加而降低, 这是因为测量次数越大, 信号恢复就越精确。另外, 定位误差随着信噪比的降低而增大, 这是因为噪声越大, 测量值就越不准确, 信号恢复误差就越大。在 NewYork 轨迹中, 当信噪比 $SNR=20$ dB, 测量次数 $M = 100$ 时, 定位误差小于 0.4 m。由此可见本文提出的定位算法具有较强的鲁棒性。

6.5 与插值方法比较

为了检验本文所提定位算法的性能, 我们仿真比较了该算法与传统的基于样条插值 (Spline Interpolation, SI) 算法的定位效果, 结果如图 7 所示。由图 7 可见, 基于 CS 和 SI 的定位算法的误差都随着测量次数的增加而减少, 这是因为观测次数越多, 获得的原信号的信息也就越多。另外, 基于 CS 的定位算法明显优于基于 SI 的算法, 这是因为基于 SI 的算法只是对信号进行简单的插值, 而基于 CS 的算法充分利用了信号的稀疏特性。

为了进一步检验本文所提定位算法的性能, 我们仿真比较了, 在某个定位精度指标约束下, 基于 CS 和 SI 的定位算法所需要最小测量次数。这里考虑 0.1 m 和 0.2 m 两种精度指标, 仿真结果如图 8 所示。

由图 8 可以看出, 对于所有数据和方法, 0.2 m 约束下的最小测量次数都要小于 0.1 m 约束下的测量次数。另外, 当约束和数据固定时, 基于 CS 的定位算法所需的最小测量次数明显小于基于 SI 的定位算法。因此, 本文算法能够利用较少的数据采集实现动态目标定位, 从而大大延长无线传感器网络的寿命。

为了分析不同算法的计算复杂度, 我们重复执

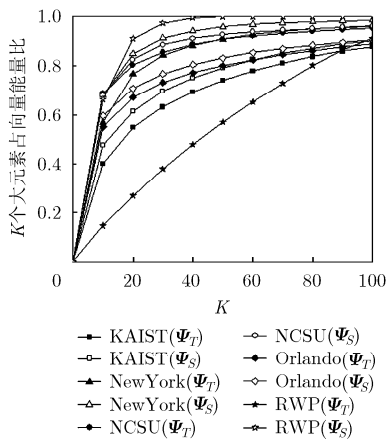


图 3 稀疏表示基的稀疏信号能力




图 4 恢复算法对定位结果的影响

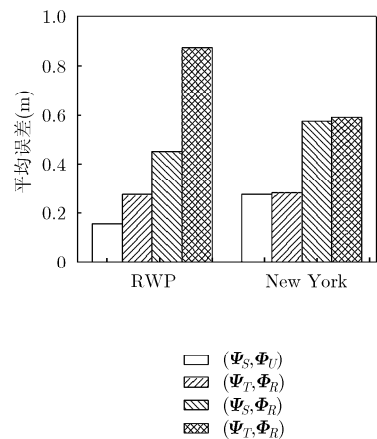


图 5 矩阵选择对定位结果的影响




图 6 测量噪声对定位结果的影响

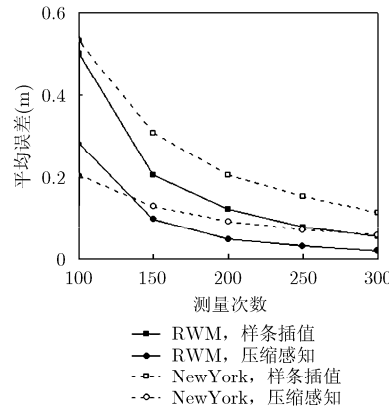


图 7 基于 CS 和 SI 算法的定位效果对比




图 8 不同精度指标约束下定位算法所需要的最小测量次数

行100次定位过程，计算其平均运行时间。这里考虑的算法包括基于CS的算法(BP, OMP和IRWLS)以及非基于CS的算法(SI)，结果如表3所示。

表 3 不同定位方法计算复杂度分析

算法	平均运行时间(s)
SI	0.021
BP	0.068
OMP	0.036
IRWLS	0.039

如表3所示，在基于CS的算法中，BP算法虽然定位误差最小(见图4)，但计算复杂度也最高。另外，相比于基于CS的算法，SI算法的计算复杂度明显较低。因此在实时性要求高的应用场景，SI算法较为适用；相反，在定位精度要求高的应用场景，本文算法更为适用。

7 结束语

本文提出一种基于压缩感知的动态目标定位算法。该算法充分利用动态目标的运动规律设计合适的稀疏表示基，并设计与该稀疏表示基低相关的易实现的稀疏观测矩阵，建立压缩感知模型，从而用较少的信息采集实现动态目标精确定位，从而大大减少了定位开销。仿真结果表明，本文所提出的定位算法具有较好的性能。

参考文献

[1] AKYILDIZ I F, SU W, SANKARASUBRAMANIAM Y, et al. Wireless sensor networks: a survey[J]. *Computer Networks*, 2002, 38(4): 393-422.

[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] CANDÈ E J. Compressive sampling[C]. International Congress of Mathematicians, Madrid, Spain, 2006: 1433-1452.

[5] CEVHER V, DUARTE M, and BARANIUK R G. Distributed target localization via spatial sparsity[C]. Proceedings of the European Signal Processing Conference (EUSIPCO), Lausanne, Switzerland, 2008: 25-29.

[6] CHEN F, VALAEE S, and TAN Z. Multiple target localization using compressive sensing[C]. IEEE Global Telecommunications Conference (GLOBECOM), Honolulu, HI, USA, 2009: 1-6.

[7] 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.

[8] 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. doi: 10.3724/SP.J.1146. 2011.00405.

HE Fenghang, YU Zhijun, and LIU Haitao. Multiple target localization via compressed sensing in wireless sensor networks[J]. *Journal of Electronics & Information Technology*, 2012, 34(3): 716-721. doi: 10.3724/SP.J.1146. 2011.00405.

[9] 赵春晖, 许云龙, 黄辉. 基于LU分解的稀疏目标定位算法[J]. *电子与信息学报*, 2013, 35(9): 2234-2239. doi: 10.3724/SP.J.1146. 2012.01527.

ZHAO Chunhui, XU Yunlong, and HUANG Hui. Localization algorithm of sparse targets based on LU-decomposition[J]. *Journal of Electronics & Information Technology*, 2013, 35(9): 2234-2239. doi: 10.3724/SP.J.1146.

- 2012.01527.
- [10] 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(自然科学版), 2014, 45(5): 1516-1521.
LI Yibing, HUANG Hui, YE Fang, *et al.* Target localization via compressed sensing based on SVD[J]. *Journal of Central South University (Natural Science)*, 2014, 45(5): 1516-1521.
- [11] GUYEN G K, VAN NGUYEN T, and SHIN H. Learning dictionary and compressive sensing for WLAN localization[C]. IEEE Wireless Communications and Networking Conference (WCNC), Istanbul, Turkey, 2014: 2910-2915.
- [12] 陈伟, 颜俊, 朱卫平. 利用压缩感知与多边测量技术的无线传感器网络定位算法[J]. 信号处理, 2014, 30(6): 728-735.
CHEN Wei, YAN Jun, and ZHU Weiping. Wireless sensor network location algorithm using compressive sensing and multilateral measurements[J]. *Journal of Signal Processing*, 2014, 30(6): 728-735.
- [13] 王婷婷, 柯炜, 孙超. 自适应环境变化的RSS室内定位方法[J]. 通信学报, 2014, 35(10): 210-217.
WANG Tingting, KE Wei, and SUN Chao. Environmental-adaptive RSS-based indoor localization[J]. *Journal on Communications*, 2014, 35(10): 210-217.
- [14] LIU L, CUI T, and LÜ W. A range-free multiple target localization algorithm using compressive sensing theory in wireless sensor networks[C]. IEEE 11th International Conference on Mobile Ad Hoc and Sensor Systems (MASS), Philadelphia, PA, USA, 2014: 690-695.
- [15] 吕伟杰, 崔婷婷, 刘超, 等. 一种新的基于压缩感知的 WSN 多目标定位方法[J]. 系统仿真技术, 2015, 11(1): 6-13.
LÜ Weijie, CUI Tingting, LIU Chao, *et al.* A new multiple target localization based on compressed sensing theory in WSN[J]. *System Simulation Technology*, 2015, 11(1): 6-13.
- [16] SONG C and XIA S. Sparse signal recovery by minimization under restricted isometry property[J]. *IEEE Signal Processing Letters*, 2014, 21(9): 1154-1158.
- [17] WU X and LIU M. In-situ soil moisture sensing: Measurement scheduling and estimation using compressive sensing[C]. Proceedings of the 11th ACM International Conference on Information Processing in Sensor Networks, Beijing, China, 2012: 1-12.
- [18] RHEE I, SHIN M, HONG S, *et al.* Mobility traces[OL]. <http://crawdad.org/ncsu/mobilitymodels/>, 2009.
- 孙保明: 男, 1989年生, 博士生, 研究方向为压缩感知、无线传感器网络定位.
- 郭艳: 女, 1971年生, 教授, 研究方向为信号处理、压缩感知、波束形成.
- 李宁: 男, 1967年生, 副教授, 研究方向为信号处理、认知无线电.
- 钱鹏: 男, 1991年生, 硕士生, 研究方向为压缩感知、无源目标定位.