

基于压缩感知的被动式移动目标轨迹测绘

王 举 陈晓江 常俪琼 房鼎益 邢天璋 聂卫科

(西北大学信息科学与技术学院 西安 710127)

摘 要 被动式目标轨迹测绘以其无需目标携带任何设备的优点吸引着许多应用,如野生动物监测、入侵安全监测等.针对现有基于被动式目标轨迹测绘方法,因频繁定位而导致计算开销大和大量观测数据导致通信能耗高的问题,文中提出基于压缩感知的被动式目标轨迹测绘(Compressive Sensing Based Device-Free Target Trajectory Depiction, CSTD)算法,仅用少量观测数据一次性精确测绘出目标轨迹,减少了计算和通信开销,降低了能耗.文中的关键性发现及 CSTD 优点是:(1) 轨迹上不同的位置及其估算具有时间独立性和空间统一性,可将不同位置映射到统一的物理空间一次性测绘出目标轨迹,避免传统方法频繁定位计算开销的问题;(2) 目标轨迹与监测区域的空间位置相比具有稀疏性,利用压缩感知原理通过少量观测数据就能精确测绘出目标轨迹,降低了数据量和能耗.为适应实际应用中的大规模场景需求,该文给出了可扩展的 CSTD 算法模型,并提出了目标轨迹稀疏度未知(目标经过的位置数未知)下的稀疏恢复算法.部署了 48 个节点的 $8\text{m}\times 8\text{m}$ 真实实验,结果表明在降低观测数据量的同时, CSTD 较现有经典算法至少提高了 63% 的轨迹测绘精度.

关键词 被动式跟踪(定位);压缩感知;数据量;物联网

中图法分类号 TP393 **DOI 号** 10.11897/SP.J.1016.2015.02361

Compressive Sensing Based Device-Free Moving Target Trajectory Depiction

WANG Ju CHEN Xiao-Jiang CHANG Li-Qiong FANG Ding-Yi XING Tian-Zhang NIE Wei-Ke

(School of Information Science and Technology, Northwest University, Xi'an 710127)

Abstract Without relying on devices carried by the target, device-free trajectory depiction is attractive to many applications, such as wildlife monitoring and asset protection in industrial facilities. To deal with the challenges, such as repeatedly positioning calculation, high data volume and the energy consumption, existed in most of current device-free trajectory depiction methods, this paper introduces a novel compressive sensing based device-free target trajectory depiction (CSTD) method. The key observation is that: (1) the location estimation has the time-independence and spatial-uniformity. Different locations can be mapped into a unified physical space and depict target trajectory one time, thus, avoid the repeatedly positioning calculation; (2) the target trajectory has the sparse property, which can apply the compressive sensing to track the target accurately even with just a few measurements, thus, we can reduce the data volume and the energy consumption. More importantly, CSTD can be easily scaled to work in large areas. We also design a sparse recovery algorithm which can recovery the signal without requiring the sparse level. Results from the real-world deployment of 48 nodes in an $8\text{m}\times 8\text{m}$ area demonstrate that CSTD can provide an improvement of 63% accuracy.

Keywords device-free localization (tracking); compressive sensing; data volume; Internet of Things

收稿日期:2014-06-18;在线出版日期:2014-10-22. 本课题得到国家科技支撑计划项目基金(2013BAK01B02)、国家自然科学基金(61170218, 61272461, 61373177)、西北大学研究生创新教育项目(YZZ13104, YZZ14002)资助. 王 举,男,1989 年生,博士研究生,中国计算机学会(CCF)会员,主要研究方向为物联网. E-mail: wangju@nwu.edu.cn. 陈晓江(通信作者),男,1973 年生,博士,教授,中国计算机学会(CCF)会员,主要研究领域为物联网、网络安全. E-mail: xjchen@nwu.edu.cn. 常俪琼,女,1989 年生,博士研究生,中国计算机学会(CCF)会员,主要研究方向为物联网. 房鼎益,男,1959 年生,博士,教授,中国计算机学会(CCF)会员,主要研究领域为物联网、网络安全. 邢天璋,男,1981 年生,博士研究生,讲师,中国计算机学会(CCF)会员,主要研究方向为物联网. 聂卫科,男,1978 年生,博士,讲师,主要研究方向为物联网.

1 引 言

移动目标轨迹测绘是人们感知客观世界的重要工具,已经成为人类生活的重要组成部分.在军事领域,通过跟踪测绘敌方炮弹轨迹来获取炮弹参数,能提高我军的防御能力;在体育领域,通过测绘竞争对手的发球轨迹,乒乓球机器人能做出合理的判断和回球策略,实现机器与人类的体育竞技对抗;在野生动物的监测和保护领域,通过测绘野生动物的运动轨迹,动物保护专家能发掘出野生动物种群的迁徙规律,给野生动物保护提供可靠决策支撑.当今流行的轨迹测绘方法,均需要给待跟踪(定位)目标配戴特定设备(例如 RFID 标签、GPS 模块),才能完成轨迹测绘^[1],然而,当被跟踪(定位)目标无法携带这些特定设备时,上述的主流目标轨迹测绘方法便存在极大的局限性.例如,在野生动物保护中,给每个野生动物佩戴电子设备具有代价高、可行性差的缺点;在入侵检测、安全监控中,入侵者不可能佩戴设备主动暴露其入侵的轨迹信息,使得传统的安全检测方法存在极大的挑战.因此针对这些应用,被动式目标轨迹跟踪(定位)、测绘,以其让被监测目标“无意识协作感知”,让被监测目标在不佩戴任何设备情况下完成轨迹测绘的优点,有效地解决了当前基于设备(如 RFID 标签、GPS 模块)的目标轨迹测绘方法的局限性,成为最新研究热点^[2-14].

目前主流的被动式目标跟踪(定位)算法是基于目标对无线通信链路造成的信号强度(Received Signal Strength, RSS)扰动分析和建模实现对目标的跟踪(定位),即当目标出现在监测区域的不同位置时,目标会对无线通信链路造成不同的 RSS 衰减,其核心思想就是利用这种与位置相关的 RSS 衰减值来完成被动式定位^[5-14].被动式目标跟踪(定位)算法,根据其对于 RSS 的处理方式可分为基于估计计算的被动式目标跟踪(定位)算法和基于学习的被动式目标跟踪(定位)算法.“基于估计计算的被动式目标跟踪(定位)”算法,其核心思想是基于“目标就位于被干扰链路附近”的理念,来进行目标的被动式跟踪(定位),这类算法具有计算复杂度低、易于实现的优点.如 Liu 等人^[5]、Zhang 等人^[6],利用被干扰链路的位置物理几何关系及被干扰区域的重叠交集来推算目标的轨迹和位置;Sigg 等人^[7]进行了关于射频通道对单个个体活动特性识别的调查,利用目标对射频信道特性的扰动来估算目标的轨迹和位

置.然而,此类算法只是进行目标轨迹和位置的大致估计,存在定位精度差的问题,其次,由于实际应用中的信号多径、障碍物遮挡等复杂环境^[2],使得此类方法存在鲁棒性差、误检率高的问题.为解决这些问题, Youssef 等人^[8]提出了“基于学习的被动式目标跟踪(定位)”算法,其核心策略分为两阶段.第一阶段,在跟踪(定位)前,即预部署阶段,让单个目标遍历监测区域的所有位置,标记(学习)不同位置、环境下目标对链路造成的 RSS 扰动的先验知识库;第二阶段,即在跟踪(定位)阶段,将在线观测的 RSS 扰动测量值与先验知识库匹配得到目标的轨迹(位置).该类算法具有跟踪(定位)精度高、适应复杂环境能力强的优点.如经典的 Wilson 等人^[9]提出的 RTI(Radio Tomographic Imaging)系统,该系统通过在监测区域部署密集的无线通信链路,以收集目标在该区域出现时造成的大量 RSS 扰动值,建立目标在不同位置的 RSS 扰动测量值先验知识库,并将该先验知识库的数据用灰度图像的形势影射到监测区域中,形成随着位置变化而变化的层析图像库,最终达到能够高精度的跟踪(定位)多个目标的目的.如 Zhang 等人^[10]提出的 RASS(Real-time, Accurate, and Scalable System)跟踪系统,该系统将监测区域划分成多个不同的三角形区域,每个三角形的定点顶点部署一个无线收发设备,形成无缝拼接的蜂窝式部署.在每个三角形区域利用 SVR(Support Vector Regression)对目标造成的 RSS 扰动建立回归模型,拟合出目标在不同位置时的 RSS 扰动变化与目标位置之间的关系,从而实现大规模下易于扩展的被动式目标跟踪(定位).但是,这类方法需要大量 RSS 扰动测量值来建立先验知识库,所以面临数据量大导致能耗高的问题,而高能耗问题一直是无线通信领域的一个挑战.此外,现有被动式目标跟踪(定位)方法对目标的轨迹测绘^[5-14],均是先定位再将不同时间点目标的估算位置,通过几何关系进行拼接来完成轨迹测绘,因此需要在每个时间点进行定位计算,存在频繁定位导致计算开销大的问题.

针对上述传统被动式跟踪(定位)算法在目标轨迹测绘方面存在的问题,本文提出基于压缩感知的被动式目标轨迹测绘(Compressive Sensing Based Device-Free Target Trajectory Depiction, CSTD)算法,通过少量观测数据就能一次性精确测绘出目标轨迹,减少了计算开销,降低了通信能耗. CSTD 的工作原理与传统基于学习的被动式跟踪(定位)方法类似,在跟踪(定位)前的预部署阶段,让目标遍历

监测区域的所有位置, 每条链路采集并记录目标在不同位置时的 RSS 扰动测量值, 然后将这些 RSS 扰动测量值按照一定的方式进行编排构建感知矩阵; 在跟踪(定位)阶段, 根据压缩感知理论, 将少量 RSS 扰动观测值和感知矩阵作为压缩感知稀疏恢复算法的输入, 重建出表示目标轨迹的稀疏向量, 根据该稀疏向量的定义即可测绘出目标的轨迹. 较传统被动式跟踪(定位)方法相比, 本文的核心发现及 CSTD 的优点是: (1) 独立性发现. 目标轨迹上不同的位置及其估算, 在时间上具有独立性, 空间上具有统一性, 可将不同时刻目标的位置影射到同一个监测空间区域, 将所有时刻的观测数据进行并行处理, 从而一次性测绘出目标轨迹, 避免多次频繁重复定位导致计算开销大的问题; (2) 轨迹稀疏性发现. 一般性况下目标轨迹经过的 K 个位置与监测区域的所有 N 个位置相比具有 K -稀疏性, 即 $K < N$. 因此可将目标轨迹测绘的问题转化为稀疏求解的问题, 利用压缩感知理论在稀疏信号恢复方面的优点, 可在不降低测绘精度的条件下, 减少测绘轨迹所需的数据量并降低能耗. 同时由于 CSTD 将目标的轨迹看作稀疏向量对待, 且仅做一次稀疏恢复求解计算, 因此较传统方法其具有计算复杂度低、测绘效率高的优点. 其次, CSTD 对特定场景利用先验知识库建立感知矩阵, 故较基于估算的被动式跟踪(定位)方法具有精度高的优点.

然而, 利用压缩感知理论实现被动式目标轨迹测绘还存在以下两个挑战: (1) 利用 RSS 扰动测量值编排、建立的感知矩阵是否满足约束等距性质 (Restricted Isometry Property, RIP), 这直接影响着压缩感知理论的运用是否正确; (2) 现有多数稀疏恢复算法均要求已知待恢复信号的稀疏度 (即目标轨迹经过的位置个数 K), 而稀疏度 K 在本文的测绘应用中是未知量, 使得现有稀疏恢复算法失效. 针对挑战 (1), 本文将观测数据和感知矩阵进行正交化预处理, 使得处理后的感知矩阵满足 RIP; 针对挑战 (2), 本文提出了自适应匹配追踪稀疏恢复算法 (Adaptive Matching Pursuit, AMP), 通过搜索迭代的方式, 在稀疏度未知情况下精确恢复出稀疏信号, 符合被动式目标轨迹测绘的需求.

此外, CSTD 的重要特性是该算法模型易于扩展到任意大规模区域. 与现有的多数小规模被动式跟踪(定位)方法相比^[5-12], CSTD 的可扩展性在许多应用场景很受欢迎. 如野生动物监测保护领域, 斑马、老虎等野生动物具有活动范围广的特点, 因此需

要大规模监测区域的被动式目标轨迹测绘方法, 本文的 CSTD 可以满足该需求.

本文第 2 节介绍本文相关工作和 CSTD 区别于现有方法的创新点; 第 3 节描述本文提出 CSTD 的动机和核心思想; 第 4 节详细介绍本文提出的 CSTD 方法; 第 5 节通过真实实验及大规模仿真实验, 验证本文提出的 CSTD 方法的有效性; 最后一节总结全文.

2 相关工作

在本节将介绍与本文相关的现有工作和本文提出的 CSTD 方法区别于现有方法的创新点. 由于本文的贡献不仅在被动式目标跟踪(定位)方面, 还在稀疏信号恢复方面也有贡献, 因此本节从这两方面分别总结现有的相关工作.

(1) 被动式目标跟踪(定位). 自 2007 年起, 国内外以 Liu 等人^[5]、Zhang 等人^[6]和 Youssef 等人^[8]为代表提出了被动式跟踪(定位)方法, 其特点是被动跟踪(定位)目标无需携带任何设备 (如 RFID 标签、GPS 模块), 被监测目标“无意识协作感知”下, 即可完成对目标的跟踪(定位). 被动式跟踪(定位)有效地解决了当前基于设备 (如 RFID 标签、GPS 模块) 的目标轨迹测绘方法, 在一些特殊应用领域 (如野生动物监测、入侵检测等领域中目标无法携带电子设备) 所存在的局限性, 而成为最新研究热点^[2-14]. 目前主流的被动式目标跟踪(定位)算法是通过目标对无线链路信号强度 (Received Signal Strength, RSS) 扰动的分析和建模实现对目标的跟踪(定位), 即当目标出现在监测区域的不同位置时, 目标会对无线通信链路造成不同的 RSS 衰减, 其核心思想是利用这种与位置相关的 RSS 衰减值来完成被动式目标跟踪(定位)^[5-14]. 这种基于无线链路信号强度 RSS 的被动式跟踪(定位)方法, 较基于红外^[3]、视频^[4]的方法, 其优点是: (1) 基于无线信号 RSS 分析的被动式跟踪(定位)不仅可以在视距范围内工作还能在非视距、有遮挡物的环境下工作, 而基于红外、视频的方法仅能在视距、无遮挡情况下工作; (2) 获取目标对无线链路的 RSS 扰动测量值时无需增加额外硬件设备 (如摄像头、红外传感器), 降低了功耗和成本; (3) 绝大多数无线设备在底层已经提供了 RSS 读数^[2], 因此 RSS 扰动测量值获取简单.

根据对 RSS 的处理方式可分为基于估计计算的被动式目标跟踪(定位)和基于学习的被动式目标

跟踪(定位). Liu 等人^[5]、Zhang 等人^[6]和 Sigg 等人^[7]最先提出了基于估计计算的被动式目标跟踪(定位)算法. 这类方法的核心思想是基于“目标就位于被干扰链路附近”的理念, 获取被干扰链路的几何位置坐标及被干扰区域的重叠交集的几何位置坐标, 通过将坐标加权处理来推算目标的轨迹和位置; 如 Liu 等人^[5]使用一组固定的射频标签来完成大范围的被动式目标的活动监控. 通过目标在不同时刻将会干扰影响不同的通线链路这一发现, 作者对目标轨迹测绘建立了数据挖掘模型, 通过多链路的关联性分析较为准确的完成对目标的被动式跟踪; Zhang 等人^[6]除了关注目标对无线链路的干扰外, 还考虑无线设备间的距离和发送功率, 使得在单个目标定位的情况下, 概率覆盖算法提供较为精准的位置信息. 同时, 作者还提出了一个分布式动态聚类方法来完成对目标的被动式跟踪; Sigg 等人^[7]等进行了关于射频通道对单个个体活动特性识别的调查, 利用目标对射频信道特性的扰动来估算目标的轨迹和位置. 然而这两类基于估算的方法, 其本身的跟踪(定位)精度差; 其次, 实际场景中环境复杂多变, 如信号的多径效应、障碍物遮挡等, 使得上述这两类基于估算的方法存在鲁棒性差、误检率高的问题. 为解决这些问题, 许多学者提出了“基于学习的被动式目标跟踪(定位)”算法, 其核心思想是在预部署阶段学习不同位置、环境下目标对 RSS 扰动的先验知识, 在跟踪(定位)阶段将观测的 RSS 扰动与先验知识库匹配得到目标轨迹(位置). 如 Zhang 等人^[10]提出 RASS(Real-time, Accurate, and Scalable System)跟踪系统, 该系统将监测区域划分成多个不同的三角形区域, 每个三角形的定点顶点部署一个无线收发设备, 形成无缝拼接的蜂窝式部署. 在每个三角形区域利用 SVR(Support Vector Regression)对目标造成的 RSS 扰动建立回归模型, 拟合出目标在不同位置时的 RSS 扰动变化与目标位置之间的关系, 从而实现大规模下易于扩展的被动式目标跟踪(定位); Wilson 等人^[8]提出了 RTI 系统, 其通过密集通信收集大量数据, 建立目标在不同位置的 RSS 变化层析图像库, 能够跟踪多个目标. 但是, 这类方法需要大量 RSS 扰动测量值来建立先验知识库, 面临数据量大导致能耗高的问题, 而且高能耗问题一直是无线通信领域的一个挑战. Adib 等人^[11]提出 Wi-Vi 系统, 该系统即使在复杂环境下也能准确检测出移动目标, 然而该系统未能实现对目标的定位和跟踪. Adib 等人^[12]提出的 Wi-Track 系统,

能够在复杂场景下对目标进行三维被动式定位和跟踪, 然而该系统仅限于工作在视距范围内. Wang 等人^[13-14]提出基于压缩感知的被动式定位方法, 然而据我们所知, 利用压缩感知针对目标轨迹测绘的研究还未发现. 此外, 上述方法对目标被动式跟踪(定位)^[5-14], 均是先定位再将不同时间点目标的估算位置连起来完成轨迹测绘, 需要在每个时间点上进行定位计算, 存在频繁定位导致计算开销大的问题. 本文提出基于压缩感知的被动式目标轨迹测绘方法, 通过少量观测数据就能一次性精确测绘出目标轨迹, 降低了数据量和能耗.

(2) 稀疏信号恢复. 压缩感知(Compressed Sensing, CS)^[15]理论给信号采样方法带来一次新的革命和采样理论, 它能够以远低于 Nyquist 采样速率的速度采样信号, 同时以高概率精确恢复原始信号, 具有节省带宽、降低能耗的优点. 由于压缩感知用欠采样的方式采样信号, 因此如何从低维度观测数据准确恢复出高维度原始数据是这个领域的研究重点和热点. 众所周知, 在感知矩阵满足 RIP(Restricted Isometry Property)的前提条件下, 通过 l_0 -minimization 范数求解能精确恢复稀疏信号. 然而, 求解 l_0 -minimization 范数最优化是一个 NP(Non-deterministic Polynomial)难问题, 因为需要穷举原始 N 维 K 稀疏信号中的所有非零项的 C_N^K 种可能组合, 因而无法求解^[16].

为了解决该问题, 近年来提出了一系列近似求解算法. 在现有众多的重建恢复算法中, 著名的 BP(Basis Pursuit)^[17]算法, 致力于将原有的 l_0 范数最小化求解放松到利用线性规划求解 l_1 -minimization. 但该方法的计算复杂度较高, 为 $O(M^2 N^{3/2})$, 其中, N 是稀疏信号的维度, K 是稀疏信号的非零元素个数, M 是观测向量的维度, 其高计算复杂度限制了它的应用. 另一类稀疏恢复算法是基于贪婪迭代追踪的思想, 如早期提出的正交匹配追踪(Orthogonal Matching Pursuit, OMP)^[18]算法, 及其衍生算法分段正交匹配追踪 StOMP(Stagewise OMP)^[19]算法和正则正交匹配追踪 ROMP(Regularized OMP)^[20]算法. 这类基于贪婪的恢复算法具有求解速度快的优点, 重建算法复杂度约是 $O(KMN)$, 显然低于 BP 算法; 然而, 这类算法的缺点是重建精度不高. Needell 等人^[21]提出了压缩采用匹配追踪(Compressive Sampling Matching Pursuit, CoSaMP)算法, 其特点在于引入了回溯的思想, 在每次的迭代中选取 $2K$ 个候选的支配点, 按照重建误差最小均方

的准则选出最终的 K 个支撑点. CoSaMP 算法较 OMP、StOMP、ROMP 相比, 具有更高的精确重建概率, 并且对于测量噪声有更好的鲁棒性. 另外, 由于 BP、OMP、StOMP 以及 ROMP 等算法没有考虑到信号多尺度分解时稀疏系数在各个子带上的位置关系, 因此, La 等人^[22] 提出了属性匹配追踪 (Tree Matching Pursuit, TMP) 算法, 利用稀疏信号系数的树型结构, 进行搜索和剪枝, 进一步提升了贪婪匹配追踪算法的重构精度和求解速度. Dai 等人^[23] 提出子空间追踪 (Subspace Pursuit, SP) 算法, 其核心思想与 CoSaMP 类似, 主要差别在于 SP 算法在每次迭代找到 K 个支撑点后, 在下一次的迭代中同样的利用回溯的思想对上次找到的信号支撑集进行修正, 最后通过伪逆得到重构信号. 较 OMP、StOMP 和 ROMP 算法相比, SP 算法在重构概率和效率上都有改进. 较 BP 算法相比, SP 算法的重构概率与 BP 相当, 但 SP 算法的计算复杂度减少到了 $O(MN \log K)$. 然而, 上述所有稀疏恢复算法都需要先验知道待恢复信号的稀疏度 (即目标轨迹经过的位置个数), 而实际中稀疏度是无法先验获得的. 鉴于此, Do 等人^[24] 提出了稀疏度自适应匹配追踪 (Sparsity Adaptive Matching Pursuit, SAMP) 算法, 该算法在重建信号的过程中无需信号稀疏度的先验知识, 仅通过固定步长来不断逼近原始信号. 当 SAMP 的固定步长为 1 时, 其可以近似为 OMP 算法, 但需要更多的迭代步骤来重建信号; 当 SAMP 的固定步长为信号的真是稀疏度时, 其与 SP 算法等价. 因此 SAMP 的计算复杂随着固定步长的不同而不同, 在 $O(KMN)$ 和 $O(MN \log K)$ 之间. 虽然 SAMP 无需先验已知信号的稀疏度即取得了较好

的效果, 但是如何选取最优步长、如何在重构概率和计算复杂度之间折中依然是个未解的问题. 综上所有算法的优缺点, 本文提出自适应匹配追踪稀疏恢复 (Adaptive Matching Pursuit, AMP) 算法, 与 BP、OMP、SP 等算法相比, AMP 可以在稀疏度未知下依然精确恢复稀疏信号; 与 SAMP 算法相比, AMP 仅需要感知矩阵和观测数据作为输入来重建信号, 没有步长选取的难题, 具有操作更简单、实现更容易的优点.

3 核心思想及动机

假设一个二维监测区域被划分成 N 个网格, 并依次由左至右、从上而下对每个网格标记唯一的编号, 标号从 1 至 N . 目标的轨迹 (位置) 用网格标号表示, 若在给定时刻某网格上存在目标, 则将该网格标记为 1; 否则标记为 0. 在时刻 q ($1 \leq q \leq Q$), 将目标在网格上的位置标记用 N 维向量 \mathbf{S}_q 表示, 将监测系统观测的一组 RSS 值用 M 维向量 \mathbf{U}_q 表示. 经过 Q 个时刻后, 目标在监测区域移动形成图 1 中虚线所示的轨迹. 传统被动式目标轨迹测绘方法是先用观测向量 \mathbf{U}_q 估计出目标在 q 时刻的位置, 再将不同时刻的目标位置连起来即完成轨迹测绘, 需进行 Q 次定位计算, 存在频繁定位导致计算开销大 (计算开销是原来的 Q 倍) 的问题. 其次, 为了准确估算位置向量 \mathbf{S}_q , 需要 \mathbf{U}_q 的维度大于 \mathbf{S}_q 的维度^[25], 即 $M > N$. 一般情况下为取得高定位精度, 网格都很小^[5-10, 13-14], 划分后 N 很大, 而 M 的取值反应了观测值数据量的多少, 导致需要大量数据来精确定位, 使得传统方法具有能耗高的问题.

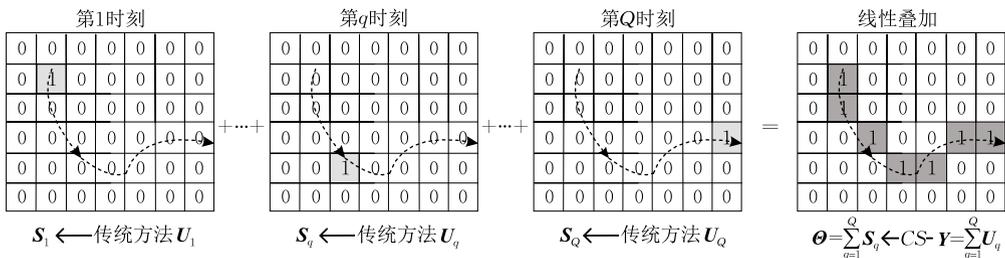


图 1 基于压缩感知的被动式目标轨迹测绘原理示意

针对上述场景, 为解决传统方法存在的问题, 本文从以下两个关键性发现出发给出解决思路:

(1) 时间独立性. 轨迹上不同的位置及其估算, 在时间上具有独立性, 空间上具有统一性. 由于用 q 时刻观测向量 \mathbf{U}_q 进行位置估算, 不会影响用 $q+1$ 时刻观测向量 \mathbf{U}_{q+1} 进行位置估算, 即上述两个“估

计事件”在不同的时间上发生, 互不影响, 因此, 根据文献^[26]的独立性原理可知, 轨迹上不同位置的估算在时间上具有独立性. 此外, 表示 q 时刻的位置向量 \mathbf{S}_q 和 $q+1$ 时刻的位置向量 \mathbf{S}_{q+1} 维度相同仅元素取值不同, 均表示给定监测空间区域的位置信息, 因此, 轨迹上不同位置的估算在空间上具有统一性.

(2) 轨迹稀疏性. 针对上述场景规则, 目标经过 Q 个时刻后的轨迹及位置如图 1 所示, 容易发现大部分标记为 0, 只有少部分标记为 1. 如当考察某一时刻目标位置向量 S_q 时, 该向量只有一个非零元素, S_q 具有 1-稀疏特性; 经过 Q 个时刻后, 假设目标轨迹覆盖了 K 个网格, 一般情况下有 $K < N$ (如在机场、商场等生活区域, 由于桌椅等其他障碍物的存在, 导致目标轨迹覆盖的网格数 K 必然小于区域中的总网格数 N), 故根据文献[15]的稀疏性定义可知, 目标轨迹向量具有 K -稀疏性.

基于“时间独立性”发现, 可将不同时刻目标位置的 1-稀疏向量 S_q 线性叠加映射到同一个监测空间区域, 构成目标在 Q 个时刻内形成的轨迹的 N 维 K -稀疏向量 $\Theta_{N \times 1}$ 表示, 即 $\Theta = \sum_{q=1}^Q S_q$; 同时将 Q 个时刻的观测值向量 U_q 线性叠加构成 M 维测量向量 $Y_{M \times 1}$, 即 $Y = \sum_{q=1}^Q U_q$, 然后从向量 Y 一次性恢复出 K -稀疏目标轨迹 Θ , 避免频繁定位计算的问题.

基于“轨迹稀疏性”发现, 即目标轨迹的 N 维向量表示 Θ 具有 K -稀疏特性, 利用压缩感知在稀疏恢复的优点, 可在不损失向量 Θ 恢复精度的同时, 仅用 $M (M < N)$ 维的观测向量 Y 精确恢复出向量 Θ , 减少轨迹测绘所需的数据量开销, 降低能耗.

本文设计的 CSTD 算法面向对实时性要求不高的场景, 如野生动物监测. 保护专家更关注于长时间段内动物迁移轨迹的统计变化规律, 而非某一个特定时刻动物的位置^[27]. 当某些应用需要进行实时跟踪时, CSTD 算法将退化成 1-稀疏 (即 $K = 1$) 向量恢复问题, 此时较现有算法 CSTD 仍具有数据量少、能耗低的优点.

4 基于压缩感知的移动目标轨迹测绘

本节中, 首先给出用于被动式目标轨迹测绘的场景部署, 然后介绍如何将轨迹测绘问题转化成压缩感知稀疏恢复问题, 最后, 给出该算法模型的扩展方法和自适应匹配追踪稀疏恢复算法.

4.1 移动目标轨迹测绘场景设置

设有一个监测区域是面积为 $a \times b$ 的矩形区域, 并将该区域划分为 N 个 $\omega \times \omega$ 的网格, 如图 2 所示. 本文在图 2 所示的部署场景中进行被动式目标轨迹测绘. 若监测区域边长 a 或 b 不能整除 ω 时, 将网格数目向上取整, 保证监测区域完全被 N 个网格所覆

盖. 将这 N 个网格按照从左到右, 从上而下的顺序依次编号为 $1, \dots, j, \dots, N$; 在位于区域一条边上的每个方格外侧边缘中点放置一个发射器, 共部署 M 个发射器, 在该边的对边上用同样的方法部署 M 个接收器. 所有无线收发器距离地面高度均为 H . 将 M 个发射器和 M 个接收器按照从上而下的顺序依次分别编号为 $T_{x_1}, \dots, T_{x_i}, \dots, T_{x_M}$ 和 $R_{x_1}, \dots, R_{x_p}, \dots, R_{x_M}$, 同时将网络路由拓扑设定为, 当且仅当 $i = p$ 时两个无线设备才收发数据构成一条链路. 显然, 较文献[5-8, 14]相比, 本文采用的部署具有稀疏性, 即减少数据采集量.

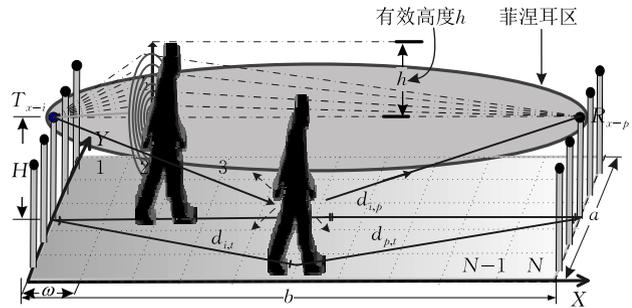


图 2 场景部署设置示意

当无线设备互相通信时, 部署有这些设备的监测区域将会被无线信号所覆盖. 位于该监测区域的目标 (如人或动物) 将会对无线通信链路的信号造成吸收、反射、绕射等干扰影响^[2, 28]. 由于无线信号的独特传播特性, 无线链路观测到的 RSS 扰动值, 将会随着目标位置的变化而改变, 使得基于 RSS 的被动式目标定位、跟踪、轨迹测绘成为可能^[5-14]. 根据无线通信原理^[28], 当目标位于第 $j (1 \leq j \leq N)$ 个网格时, 第 i 个链路观测到的 RSS 值 $R_{i,j}$ (以 dB 为单位) 表示为

$$R_{i,j} = P_i - L_i - D_{ij} - Q_i \quad (1)$$

其中, P_i 是第 i 条链路的发射功率; L_i 是第 i 条链路的传播损耗, 该损耗由于距离衰减, 天线增益等而造成; D_{ij} 是第 i 条链路的绕射衰减, 该损耗由于目标位于第 j 个网格时遮挡了部分无线通信链路而造成, 这种遮挡会减少接收端接收到的功率, 因此会降低 $R_{i,j}$ 的值; Q_i 是链路 i 的其他损耗, 如多径损耗、反射传播等.

设当目标出现在第 j 个位置和当目标不在该监测区域时, 第 i 条链路观测到的 RSS 值分别是 $R_{i,j}$ 和 F_i . 在给定的环境中, P_i , L_i 和 Q_i 是不变量^[29]. 因此, 我们能够得到由于目标出现在第 j 个网格后, 第 i 条链路观测到的 RSS 扰动值 (以 dB 为单位) 为

$$\Delta R_{i,j} = R_{i,j} - F_i = -D_{ij} \quad (2)$$

在本文中,用扰动值 $\Delta R_{i,j}$ 来量化目标对第 i 条链路造成的干扰,并将 $\Delta R_{i,j}$ 用于定位模型的建立.

4.2 问题定义及模型建立

由于监测区域被划分为 N 个网格,让目标轨迹经过的 K 个网格用向量 Θ 表示,

$$\Theta_{N \times 1} = [\theta_1, \dots, \theta_j, \dots, \theta_N]^T \quad (3)$$

其中, $\theta_j \in \{0, 1\}$, 当目标经过第 j 个网格时, $\theta_j = 1$, 否则, $\theta_j = 0$. 如无特殊说明,当提到目标在第 j 个网格时,指在第 j 个网格的中心,此时根据几何关系可得到 θ_j 所表示的唯一二维坐标 (x_j, y_j) .

本文的目标就是通过 M 维观测值(即 M 条链路的 RSS 值)来精确得到表示目标轨迹的 N 维向量 Θ , 然而,在本文给定的部署场景中有 $M < N$, 即求解向量 Θ 是个欠定求解的问题,有无数个解^[25].

注意到目标经过的网格数 $K = \sum_{j=1}^N \theta_j$, 通常情况下, K 远小于监测区域内总的网格数 N , 即 $K \ll N$. 例如,对于一间 $10\text{ m} \times 10\text{ m}$ 的房间,可以将其划分出 $N = 400$ 个大小为 $0.5\text{ m} \times 0.5\text{ m}$ 的网格(位置),而该房间内的目标数 K (如人的个数)一般不会大于 400. 因此,向量 Θ 中仅有 K 个非零元素,即向量 Θ 具有 K 稀疏性. 根据压缩感知理论,不用直接去测量 N 维 K 稀疏向量 Θ , 仅通过 M 维的观测向量 $\mathbf{Y}_{M \times 1}$, 就能以压倒性概率精确恢复出目标的轨迹向量 Θ . 因此,采用压缩感知理论的优点是在不损测绘精度的同时,减少观测数据量并降低了能耗. 根据压缩感知理论有

$$\mathbf{Y}_{M \times 1} = \mathbf{A}_{M \times N} \cdot \Theta_{N \times 1} + \mathbf{n} \quad (4)$$

其中, $\mathbf{Y}_{M \times 1} = [y_1, \dots, y_i, \dots, y_M]^T$, y_i 是在轨迹测绘阶段第 i 条链路在所有 Q 个时刻测量到的 RSS 扰动值线性叠加之和(设在轨迹测绘阶段共进行了 Q 个时刻的观测), $\mathbf{A}_{M \times N}$ 是在预部署阶段建立的感知矩阵, \mathbf{n} 是测量噪声. 在矩阵 $\mathbf{A}_{M \times N}$ 下, 观测向量 $\mathbf{Y}_{M \times 1}$ 有稀疏系数向量 Θ . $\mathbf{A}_{M \times N}$ 的定义如下:

$$\mathbf{A}_{M \times N} = \begin{bmatrix} \Delta R_{1,1} & \Delta R_{1,2} & \dots & \Delta R_{1,N} \\ \Delta R_{2,1} & \Delta R_{2,2} & \dots & \vdots \\ \vdots & \vdots & \Delta R_{i,j} & \vdots \\ \Delta R_{M,1} & \dots & \dots & \Delta R_{M,N} \end{bmatrix} \quad (5)$$

其中, $\Delta R_{i,j}$ 如式(2)中所示,代表在跟踪(定位)前的预部署阶段目标位于第 j 个网格时,第 i 条链路测量到的目标造成的 RSS 干扰值.

根据压缩感知原理,稀疏向量 Θ 可以被精确恢复的充分条件是感知矩阵 \mathbf{A} 满足 RIP 性质^[15], 即感

知矩阵的列向量应近似于正交. 然而,通常情况下不同链路的观测数据具有空间相关性,使得式(5)所示矩阵的列向量不满足近似正交性,即感知矩阵 \mathbf{A} 不满足 RIP 性质. 为解决该问题,本文在恢复稀疏向量 Θ 前先对感知矩阵及观测向量进行正交化处理. 对于观测向量 \mathbf{Y} 进行如下处理:

$$\mathbf{Z} = \mathbf{\Omega} \cdot \mathbf{Y} \quad (6)$$

其中, $\mathbf{\Omega} = \mathbf{\Phi} \mathbf{A}^{-1}$, $\mathbf{\Phi} = \text{orth}(\mathbf{A}^T)^T$. $\text{orth}(\mathbf{A})$ 代表矩阵 \mathbf{A} 的正交化, \mathbf{A}^{-1} 和 \mathbf{A}^T 分别代表 \mathbf{A} 的伪逆矩阵和 \mathbf{A} 的转置矩阵. 将式(6)代入式(4)有

$$\mathbf{Z} = \mathbf{\Omega}(\mathbf{A}\Theta + \mathbf{n}) = \mathbf{\Phi} \mathbf{A}^{-1} \mathbf{A}\Theta + \mathbf{n} = \mathbf{\Phi}\Theta + \mathbf{n} \quad (7)$$

因为 $\mathbf{\Phi}$ 是正交矩阵,因此对于 N 维 K -稀疏向量 Θ , 根据压缩感知理论,当观测向量 \mathbf{Z} (或 \mathbf{Y}) 的维度 M 满足 $M = O[K \log(N/K)]$ 时^[15], 向量 Θ 可以通过 l_1 -minimization 范数求最优化重建恢复,即

$$\min \|\Theta\|_{l_1} \text{ s.t. } \|\mathbf{\Phi}\Theta - \mathbf{Z}\|_{l_2} < \epsilon \quad (8)$$

其中, ϵ 约束测量噪声的大小. Needell 等人^[20] 已经给出理论证明指出,由式(8)恢复重建出的向量 Θ , 其重建误差将不大于 $c_0 \epsilon_0 + c_1 \epsilon$, 其中, c_0 和 c_1 是两个较小的常数, ϵ_0 是当观测向量 \mathbf{Z} 不含噪声时,通过 l_1 -minimization 恢复出向量 Θ 的重建误差.

4.3 适用于大规模下的目标跟踪轨迹测绘模型

上述的跟踪测绘算法是针对由无线收发设备构成的通信链路而设计的,然而,无线收发设备的传输链路长度有限,使得该算法无法覆盖大规模区域. 为了克服该问题,本文给出上述算法的几何模型化扩展方法,其核心思想是将大规模区域划分成若干个子区域,每个子区域均能被无线链路覆盖,在每个子区域内采用上述轨迹测绘方法.

假设大规模区域被 T 个相同的子区域所覆盖,每个子区域拥有独属于自己的感知矩阵. 让 M 乘 N 维矩阵 \mathbf{A}_t ($t = 1, 2, \dots, T$) 表示第 t 个子区域的感知矩阵,则大规模区域的感知矩阵 $\mathbf{A}_{\text{total}}$ 为

$$\mathbf{A}_{\text{total}} = \begin{bmatrix} \mathbf{A}_1 & 0 & \dots & 0 \\ 0 & \mathbf{A}_2 & \dots & \vdots \\ \vdots & \vdots & \mathbf{A}_t & \vdots \\ 0 & \dots & \dots & \mathbf{A}_T \end{bmatrix}_{MT \times NT} \quad (9)$$

假设目标在大规模区域经过了 K 个网格,则表示该目标轨迹的 NT 维未知向量 Θ_{total} 为

$$\Theta_{\text{total}} = [\Theta_1^T, \Theta_2^T, \dots, \Theta_t^T, \dots, \Theta_T^T]^T \quad (10)$$

其中, Θ_t 是 N 维向量,表示目标在第 t 个区域内的轨迹, $(\cdot)^T$ 是矩阵的转置函数. 不失一般性,让 M 维向量 \mathbf{Y}_t 表示轨迹测绘阶段第 t 个子区域在所有 Q 个时刻测量到的 RSS 观测向量线性叠加之和,则整个

大规模区域在所有 Q 个时刻测量到的 RSS 观测向量为

$$\mathbf{Y}_{\text{total}} = [\mathbf{Y}_1^T, \mathbf{Y}_2^T, \dots, \mathbf{Y}_t^T, \dots, \mathbf{Y}_T^T]^T \quad (11)$$

根据压缩感知原理, 类比于式(4)所示的小规模目标轨迹测绘模型有, $\mathbf{Y}_{\text{total}} = \mathbf{A}_{\text{total}} \cdot \boldsymbol{\Theta}_{\text{total}}$. 通过前述正交化预处理方法后, 利用稀疏恢复算法即可得到目标在大规模区域内的轨迹向量 $\boldsymbol{\Theta}_{\text{total}}$ 表示.

4.4 自适应匹配追踪稀疏恢复算法

4.2 节给出了被动式目标轨迹测绘的问题描述和建模, 指出目标轨迹向量 $\boldsymbol{\Theta}$ 可以通过 l_1 -minimization 最优化解. 但是, l_1 -minimization 算法要求知道待恢复向量 $\boldsymbol{\Theta}$ 的稀疏度 K , 即需要知道目标经过了多少个网格. 然而, 实际应用中预先获取 K 值是不现实的; 其次, 当 N 增大时, l_1 -minimization 的计算复杂度将急剧上升. 为解决该问题, 本文提出自适应匹配追踪 (AMP) 稀疏恢复算法. AMP 的核心思想是先找到对向量 $\boldsymbol{\Theta}$ 贡献最大的一个非零元素, 然后将该元素加入到待恢复向量 $\boldsymbol{\Theta}$, 并保持在后续迭代中不变. 接着以上一步更新的向量 $\boldsymbol{\Theta}$ 为基础, 寻找对 $\boldsymbol{\Theta}$ 贡献次大的一个非零元素, 将该元素加入到待恢复向量 $\boldsymbol{\Theta}$, 并保持在后续迭代中不变, 以此重复, 直至达到终止条件. 算法的伪代码如下.

算法 1. 自适应匹配追踪稀疏恢复算法.

输入: M 维观测向量 \mathbf{Y} , $M \times N$ 维感知矩阵 \mathbf{A}

输出: N 维重构向量 $\hat{\boldsymbol{\Theta}}_{N \times 1}$

1. $\boldsymbol{\Theta} = \mathbf{0}, \boldsymbol{\Gamma} = \emptyset, \mathbf{I}_{\text{set}} = \{1, \dots, N\}, \mathbf{r} = \mathbf{Y}$; /* 初始化 */
2. WHILE ($\|\mathbf{r} - \mathbf{A}\hat{\boldsymbol{\Theta}}\|_2 > \epsilon$ AND $\mathbf{I}_{\text{set}} \neq \emptyset$)
/* ϵ 是噪声界限或可容忍误差大小 */
3. FOR $i = 1: |\mathbf{I}_{\text{set}}|$ /* i 取值从 1 到 $|\mathbf{I}_{\text{set}}|$, $|\mathbf{I}_{\text{set}}|$ 是集合 \mathbf{I}_{set} 的大小 */
4. $\alpha = \mathbf{I}_{\text{set}}(i)$; /* 将 \mathbf{I}_{set} 的第 i 个元素赋值给变量 α */
5. $\{(\xi_\alpha, \theta_\alpha)\} \leftarrow \arg \min_{\theta_\alpha \in \{0, 1, 2, \dots, Q\}} \|\mathbf{r} - \mathbf{A}\hat{\boldsymbol{\Theta}}\|_2$;
/* 将向量 $\hat{\boldsymbol{\Theta}}$ 下标为 α 的元素 θ_α 取值由 0 遍历至 Q , 寻找使得 $\xi_\alpha = \|\mathbf{r} - \mathbf{A}\hat{\boldsymbol{\Theta}}\|_2$ 最小的 θ_α 的取值 */
6. $\boldsymbol{\Gamma} = \boldsymbol{\Gamma} \cup \{(\xi_\alpha, \theta_\alpha)\}$;
7. END
8. $\{(\xi_\alpha, \theta_\alpha)\} \leftarrow \arg \min_{\xi_\alpha} \{\boldsymbol{\Gamma}\}$; /* 在集合 $\boldsymbol{\Gamma}$ 中寻找 ξ_α 最小的组合 $(\xi_\alpha, \theta_\alpha)$ */
9. $\hat{\boldsymbol{\Theta}} = \text{update}(\hat{\boldsymbol{\Theta}}, \alpha, \theta_\alpha)$; /* 更新向量 $\hat{\boldsymbol{\Theta}}$ 的取值, 其中函数 $d = \text{update}(\mathbf{a}, j, c)$ 是将向量 \mathbf{a} 中的第 j 个元素替换成 c 后赋值给 d */;
10. $\boldsymbol{\Gamma} = \emptyset$; /* 清空候选集合 */
11. $\mathbf{r} = \mathbf{r} - \mathbf{A}\hat{\boldsymbol{\Theta}}$ s. t. $\xi_\alpha = \|\mathbf{r} - \mathbf{A}\hat{\boldsymbol{\Theta}}\|_2$ /* 更新残差取值 */
12. $\mathbf{I}_{\text{set}} \leftarrow \mathbf{I}_{\text{set}} / \{\alpha\}$; /* 裁剪搜索集合 */
13. END

然而实际中由于噪声等的影响, 使得目标在第 j 个网格时, 恢复向量 $\hat{\boldsymbol{\Theta}}$ 的元素 $\hat{\theta}_j$ 取值并非 0 或 1, 还可能存在 0 和 1 之间的数. 因此, 当 $\hat{\theta}_j$ 大于阈值 σ 时, 本文将 $\hat{\theta}_j$ 置 1, 否则置 0. 其次, 当目标多次经过第 j 个网格时, $\hat{\theta}_j$ 的取值将大于 1, 但此时并不影响轨迹的测绘, 故此时依然用上述的阈值判别法将 $\hat{\theta}_j$ 置 1. 在本文仿真及实验中取 $\sigma = 0.5$. 注意, 当目标多次经过第 j 个网格时, 按照本文规则得到的向量 $\hat{\boldsymbol{\Theta}}$, 其取值并不满足式(4), 但 $\hat{\boldsymbol{\Theta}}$ 的取值依然能够精确表示目标经过的轨迹. 实际上, 当 $\hat{\theta}_j$ 的取值大于 1 时, 其值的大小反应了目标经过第 j 个网格的次数多少, 若 $\hat{\theta}_j$ 越大, 则表明目标经过第 j 个网格的次数越多.

本文提出的自适应匹配追踪 (AMP) 稀疏恢复算法是在匹配追踪 (MP) 算法的基础上设计的, 因此 AMP 的时间复杂度同 MP 类似, 主要由“算法 1”的第 3~8 步决定. 不同之处在于, AMP 算法为了能够在稀疏度 K 未知下依然精确恢复目标的轨迹向量, 较匹配追踪算法, AMP 需付出更多的搜索代价. AMP 需要遍历待恢复向量元素的可能取值, 即 AMP 算法较 MP 算法增加了“算法 1”中第 5 步的计算. 根据文献[18], MP 算法(或 OMP)算法的时间复杂度为 $O(KMN)$, 其中 K 为待恢复信号的稀疏度(针对 MP 或 OMP 算法需要先验已知), M 是观测向量的维度, N 是待恢复向量的维度. 故本文提出的 AMP 算法的复杂度为 $O(QK_s MN)$, 其中 Q 是进行轨迹测绘时目标经历的时数, K_s 是达到终止条件时的迭代次数, 根据文献[20], 一般有 $K_s \geq K$. 由此可知, AMP 算法的复杂度比 MP(或 OMP)算法至少增加了 Q 倍, 但付出此代价带来的优点是: (1) 无需知道待恢复向量的稀疏度; (2) 提供了比 MP(或 OMP)算法更高的恢复精度, 如本文 5.3 节实验结果分析所示.

5 实验及性能评价

在本节将分别展开大规模仿真实验和小规模真实实验, 其目的在于回答以下 3 个问题: (1) 提出的 AMP 稀疏恢复算法是否优于现有的算法, 是否能提供更高重建精度? (2) 提出的 CSTD 算法涉及的相关参数对目标轨迹测绘的精度有什么影响? (3) 提出的 CSTD 算法在真实场景中是否可行、有效?

5.1 评价指标及比较对象

本文用真实轨迹与测绘轨迹之间的点对点距离

与网格大小的比值来衡量轨迹测绘误差。假设目标的真实轨迹经过了 K 个位置 $(x_1, y_1), (x_2, y_2), \dots, (x_K, y_K)$, 计算出的目标测绘轨迹由 \hat{K} 个位置 $(\hat{x}_1, \hat{y}_1), (\hat{x}_2, \hat{y}_2), \dots, (\hat{x}_{\hat{K}}, \hat{y}_{\hat{K}})$ 构成。首先, 计算所有 (x_i, y_i) 和 (\hat{x}_i, \hat{y}_i) 两两之间的欧式距离, 然后将所有距离按照非递增的形式排列成表。根据该表中距离计算值所对应的真实坐标 (x_i, y_i) 和估算坐标 (\hat{x}_i, \hat{y}_i) , 可计算目标轨迹测绘误差 (Trajectory Error, TE) 如下:

$$TE = \frac{\sum_{i=1}^{\min\{K, \hat{K}\}} \sqrt{(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2}}{\omega \min\{K, \hat{K}\}} \quad (12)$$

其中, ω 是划分区域的网格边长大小。

为检验本文提出的 AMP 稀疏恢复算法是否优于现有稀疏恢复算法, 是否能提供更高的重建精度, 本文将 AMP 与著名的正交匹配追踪算法 OMP^[18] 和 l_1 -magic 算法^[30] 相比较。注意, OMP 算法需要知道待恢复向量的稀疏度 K , 因此本文将原来的终止条件“迭代 K 次”, 改为“迭代直至残差小于阈值 ($<10^{-6}$)”。

为验证本文提出的 CSTD 在被动式轨迹测绘方面的优越性, 本文将 CSTD 与现有的两种经典被动式定位算法相比较, 即基于学习的 RASS 算法^[10] 和基于层析成像的 RTI 算法^[9]。注意: (1) RASS 算法按照传统的先定位再测绘目标轨迹的方式进行; (2) RTI 算法用一片区域来估计目标的位置而非一个精确坐标, 因此本文将 RTI 估计区域的质心位置坐标作为 RTI 对目标位置的估计。

5.2 仿真及真实实验设置

(1) 仿真实验设置。仿真以 Matlab 为平台, 仿真中所需的数据均通过自由传播模型^[28] 和绕射模型^[28] 计算获取, 设无线信号的波长为 λ ; 发射端 Tx_i 和接收端 Rx_p 间的欧式距离为 $d_{i,p}$; Tx_i (或 Rx_p) 与目标间的欧式距离为 $d_{i,t}$ (或 $d_{p,t}$)。上述模型所需的相关参数取值如表 1 所示。根据绕射模型^[28], 当且仅当目标位于无线通信链路的第一菲涅耳区时才会干扰该链路, 因此当目标位于监测区域的第 j 个网格时, 第 i 条链路的路径损耗 $R_{i,j}$ 计算如下:

$$R_{i,j} = \begin{cases} P_i - L_i - D_{i,j} + n, & \text{若 } d_{i,t} + d_{p,t} \leq \sqrt{r_1^2 + d_{i,p}^2} \\ P_i - L_i + n, & \text{若 } d_{i,t} + d_{p,t} > \sqrt{r_1^2 + d_{i,p}^2} \end{cases} \quad (13)$$

其中, $r_1 = \sqrt{\lambda d_{i,t} d_{p,t} / (d_{i,t} + d_{p,t})}$ 是第一菲涅耳区的

半径大小, 如图 2 中所示。 $L_i = 10 \log[\lambda^2 / (16\pi^2 d_{i,p}^2)]$ 是第 i 条链路的路径损耗, P_i 是 Tx_i 的发射功率, n 是噪声, 仿真中用信噪比 SNR 来量化表示噪声大小 ($w=0$ 表示无噪声), $D_{i,j}$ 是由于目标出现在第 j 个网格时对第 i 条链路造成的 RSS 衰减, 定义如下:

$$D_{i,j} = 20 \log \left[\frac{\sqrt{2}}{2} \left| \int_v^{\infty} \exp\left(-\frac{img}{2} \pi t^2\right) dt \right| \right] \quad (14)$$

其中, $v = h \sqrt{2(d_{i,t} + d_{p,t}) / (\lambda d_{i,t} d_{p,t})}$, h 为有效高度, 其值为目标高度减去链路距地面的高度, 如图 2。

表 1 仿真模型相关参数及取值

参数名	取值
有效高度 (h)	1.75 - 0.95 = 0.8 m, 根据真实实验设置
发射功率 (P_i)	0 dB, 根据 MICAZ 节点
信号波长 (λ)	0.125 m, 根据 MICAZ 节点
噪声大小 (n)	2 dB, 根据经验知识

仿真实验中, 通过调节以下参数来评价 CSTD 算法的性能: ① K 为目标经过的网格数, 即轨迹向量 Θ 的稀疏度; ② M 为链路个数, 即观测向量 Y 的维度; ③ ω 为划分区域的网格大小; ④ AS 为区域的面积大小。如无说明, 这些参数的默认值见表 2。

表 2 仿真实验参数及默认取值

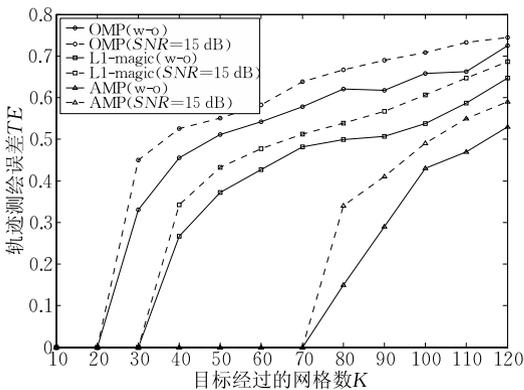
参数名	默认取值
网格个数 (N)	4×10^4 ($\omega = 0.5$ m)
稀疏度 (K)	60
链路个数 (M)	200
网格大小 (ω)	0.5 m
区域面积 (AS)	100 m \times 100 m

(2) 真实实验设置。为验证 CSTD 在真实环境中的可行性和有效性, 本文在 8 m \times 8 m 的开阔监测区域进行目标轨迹测绘实验, 并与 RASS 和 RTI 算法相比较, 实验场景在 5.5 节给出。监测区域被划分为 4 个 4 m \times 4 m 的子区域, 每个子区域被划分为 64 个 0.5 m \times 0.5 m 的网格。一个身高为 1.75 m 的人作为目标。48 个 MICAZ[®] 节点按照如图 2 所示的配置进行部署, 发射节点每秒发射一个数据包。根据我们的经验, 当节点距离地面高 $H = 0.95$ m 时具有较好的信号传播特性。实验中为避免偶然因素, 在目标经过的每一个网格上采集 30 个相对稳定的 RSS 值。

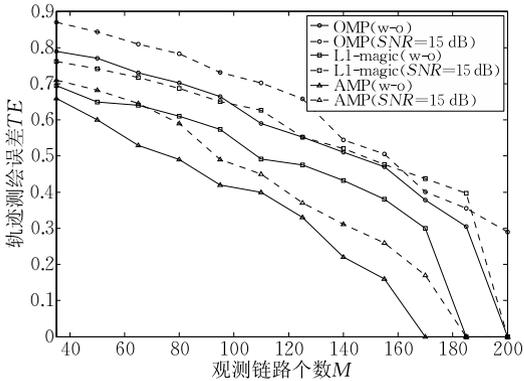
5.3 稀疏恢复算法性能比较

为验证本文提出的 AMP 算法在稀疏度未知下的稀疏恢复优越性, 本文将 AMP 与著名的正交匹配追踪算法 OMP^[18] 和 l_1 -magic 算法^[30] 相比较。图 3 展示了 AMP 算法的轨迹测绘误差低于 OMP

和 l_1 -magic 算法. 如在图 3(a)中当 $M=200, K>20$ (或 30)时, OMP(或 l_1 -magic)算法开始出现测绘误差, 即 $TE>0$, 而 AMP 算法在 $K<70$ 时, 始终可以精确测绘出目标轨迹, 即一直保持 $TE=0$. 图 3(b)再次证明了 AMP 算法优于 OMP 和 l_1 -magic 算法. 如在不加噪声环境(w-o), 当 $K=60$ 时, AMP 算法至少需要 175 个观测值来精确测绘目标轨迹, 而 l_1 -magic 和 OMP 算法则分别至少需要 185 个和 200 个观测值来精确测绘目标轨迹, 分别比 AMP 额外多需要 10 个和 25 个观测数据. 综上所述, AMP 算法较上述两种经典稀疏恢复算法能提供更高的重建精度, 且用了更少的观测数据量, 降低了能耗, 因此 AMP 较上述两种算法有一定优越性.



(a) 在 $M=200$, 改变不同稀疏度下的测绘误差比较



(b) 在 $K=60$, 改变不同观测链路数下的测绘误差比较

图 3 当 $N=4 \times 10^4$, 噪声 $SNR=15$ dB 时, 比较 AMP 与 2 种稀疏恢复算法的轨迹测绘误差

5.4 CSTD 相关参数对测绘误差的影响

本文提出的 CSTD 算法涉及多个参数, 在这里讨论相关参数的取值对轨迹测绘误差的影响. 在第 1 个仿真中, 讨论 CSTD 算法能精确测绘的目标轨迹长度(即 K 的大小). 将 K 以 10 为间隔由 10 增加到 120(即不断增加目标轨迹的测绘长度), 而保持其他参数如表 2 所示不变. 从图 4 可看出 CSTD 能精确测绘的最大轨迹长度 K 是受限的. 如当 $K \geq 80$

时, CSTD 的测绘误差 TE 急剧增加. 原因在于根据压缩感知原理, 当 $K=80$ 时, 精确测绘目标轨迹所需的最少观测链路数为 $K \log(N/K) \approx 216$ 条, 大于表 2 中的默认值(即 200 条). RTI 算法表现不如 CSTD 的原因在于, RTI 需要更密集的部署和更多的观测值(即链路数)来精确定位目标位置, 其次, RTI 仅估计目标出现的区域而非具体位置. 而 CSTD 利用压缩感知原理, 即使在少量观测值下也能精确恢复出目标轨迹, 且 CSTD 算法给出了目标的具体位置. 由图 4 还能看出一个有趣的现象, RASS 算法的测绘误差较大, 且基本不变, 这是因为 RASS 采用传统的先定位再测绘轨迹的方法. RASS 的轨迹测绘结果实际上是对目标进行 K 次独立、重复的定位结果, 因此测绘误差与 K 值无关, 不会因为 K 值而改变. 图 4 还展示了当 CSTD 的参数满足压缩感知原理时, 即满足 $M > K \log(N/K)$ 时, CSTD 的测绘精度将远高于 RASS.

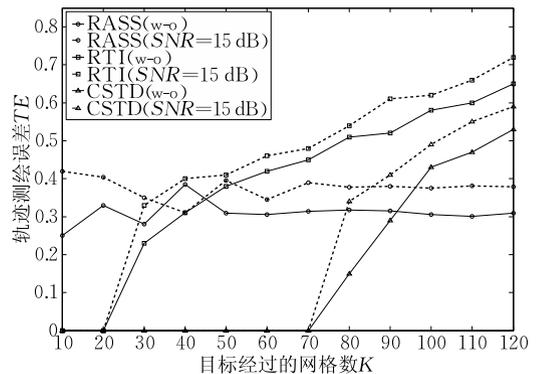


图 4 目标轨迹长度 K 对于测绘误差的影响

在第 2 个仿真中, 讨论 CSTD 的轨迹测绘误差与部署链路数(即 M 的取值)的关系. 将 M 以 15 为间隔由 200 减少到 35(即不断移除部署的链路), 而保持其他参数如表 2 所示不变. 由图 5 可以看出, 与默认部署的链路数相比, CSTD 算法可以在更为稀疏的部署下精确测绘出目标轨迹, 例如对于 CSTD

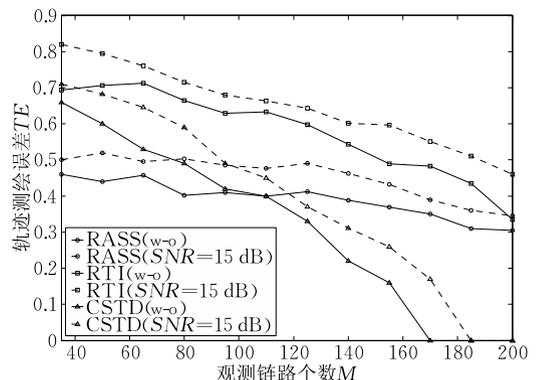


图 5 部署链路数 M 对测绘误差的影响

(w-o), 当 M 由 200 减少到 175 的过程中轨迹测绘误差 TE 始终为 0, 而 RTI 和 RASS 算法的测绘误差 TE 则呈现增长的趋势. 该现象的原因在于当 $M=175 > K \log(N/K) \approx 169$ 时, CSTD 的参数取值依然满足压缩感知原理, 因此 CSTD 算法可以在比默认部署更稀疏的情况下精确测绘出目标的轨迹. CSTD 算法优于 RTI 和 RASS 算法的原因如第一个仿真中所述, 在这里不再赘述.

在第 3 个仿真中, 讨论 CSTD 算法的轨迹测绘误差与网格划分大小(即 ω 取值)之间的关系. 将网格大小 ω 以 0.2m 为间隔由 0.1m 增加到 2.4m, 然后比较 $K=20, 40, 60, 80$ 下的轨迹测绘误差. 注意: 当网格大小 ω 改变时, 链路数 M 及网格数 N 也会变化, 根据本文在 4.1 节介绍的部署, 易知 $M=a/\omega$, $N=ab/\omega^2$. 图 6 展示了不同网格大小 ω 及轨迹大小 K 值下的测绘误差, 可发现两个规律: (1) 在给定轨迹大小 K 值下, 当网格大小 ω 超过某临界值时, 将会出现测绘误差, 且误差呈非线性增长; (2) 轨迹大小 K 值越大, 出现测绘误差的网格大小 ω 的临界值越小. 出现两个规律的原因: 根据压缩感知原理, 文献[13]指出 ω 需要满足 $\omega > \sqrt{ab/K} 10^{-0.5\sqrt{a/(bk)}}$, 即精确测绘目标轨迹需要满足一定的下界, 且该界限是关于区域大小(如图 2 中所示矩形监测区域的边长 a 和 b)和测绘轨迹大小(K)的非线性函数, 此验证了规律(1); 该界限与 K 值成反比, 验证了规律(2).

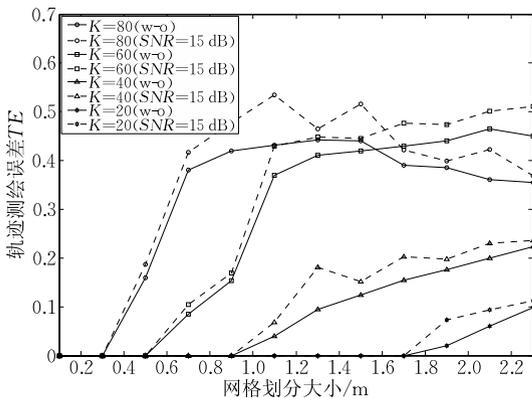


图 6 网格划分大小对测绘误差的影响

第 4 个仿真中, 讨论 CSTD 在大规模场景下的测绘误差. 将轨迹大小 K 由 60 增加到 6600, 将区域面积 AS 由 10^4m^2 增加到 $11 \times 10^4 \text{m}^2$. 由于监测区域的面积大小已超出链路通信范围, 故在该仿真中, 采用 4.3 节介绍的方法用一系列子区域将大监测区域覆盖. 简单期间, 设每个子区域的大小仍为 $100 \text{m} \times 100 \text{m}$. 仿真结果图 7 表明, CSTD 能否精确测绘目标轨迹的区域大小取决于目标经过的最大网格数,

即最大轨迹长度 K . 根据压缩感知原理及第 1 个仿真结果可知, 每个子区域能精确测绘目标经过的网格数为 70, 因此若有 T 个子区域, 那么最大能精确测绘的目标经过网格数 K 为 $70T$. 如果目标经过的网格数, 即轨迹长度 $K < 70T$, 则 CSTD 能精确进行目标的轨迹测绘, 如图 7 中 $TE=0$ 的部分. 否则, 测绘误差 TE 服从下面两个规律: (1) 当监测区域面积 AS 固定时, 轨迹长度 K 越大, 测绘误差 TE 越大; (2) 当轨迹长度 K 固定时, 监测区域面积 AS 越大, 测绘误差 TE 越小.

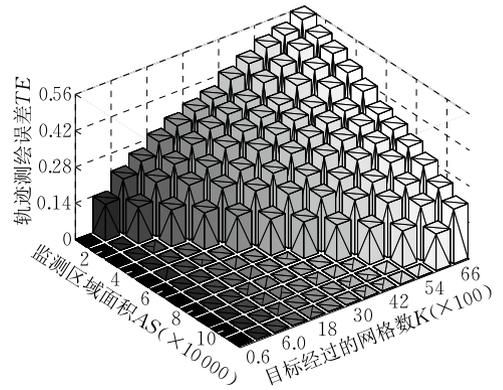


图 7 大规模场景下测绘误差变化规律

5.5 真实场景下目标轨迹测绘误差及能耗比较

图 8 展示了真实实验的场景图. 图 9 展示了真实场景下的目标轨迹测绘结果, CSTD 算法的测绘结果最大程度地逼近了真实轨迹, 测绘误差最小 $TE=0.17$, 而 RTI 和 RASS 的测绘误差 TE 分别为 0.46 和 0.49. 在减少观测数据量的同时, CSTD 较 RTI 和 RASS 至少提高了 $(0.46-0.17)/0.46=63\%$ 的轨迹测绘精度, 其原因如 5.4 节中的仿真分析所述.

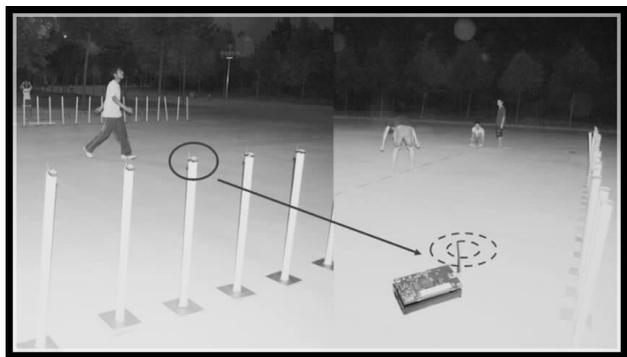


图 8 真实场景

观察图 9, 针对 CSTD 发现, 在子区域 1 和子区域 2 中其测绘误差为 0, 而在子区域 3 和子区域 4 中有较大的误差. 这是因为每个子区域的观测数 M 和网格数 N 均有限, 均为 $M=8, N=64$, 而目标在

每个子区域经过的网格数,即轨迹长度 K 大小不一,当 $M > K \log(N/K)$ 时, CSTD 能无误的测绘出目标轨迹,否则将出现误差. 如当目标在子区域 1 中时, $K=7$, 精确测绘目标的轨迹所需的最少观测链路数为 $K \log(N/K)=6.7 < 8$, 因此 $TE=0$; 而当目标在子区域 3 中时, $K=12$, 精确测绘所需的最少链路数为 $K \log(N/K)=8.7 > 8$, 因此 $TE > 0$. 由图 9 还发现 RTI 和 CSTD 算法的轨迹测绘结果都有“漏掉”的轨迹, 而 RASS 却没有. 这是因为 RTI 和 CSTD 是通过“一次”计算来测绘出目标轨迹, 而 RASS 是通过给定轨迹长度 K 值下的 K 次重复定位完成, 因此不存在“漏掉”目标轨迹的问题. 另外 RASS 的 K 次定位之间相互独立, 因此, RASS 算法的定位误差随机波动.

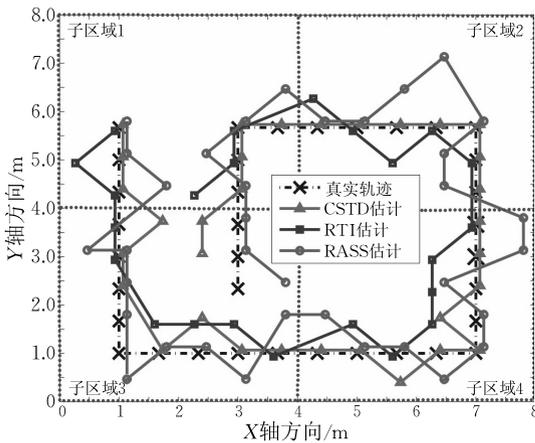


图 9 真实场景下目标轨迹测绘比较

为验证 CSTD 算法较传统算法具有低能耗开销的优势, 本文在给定轨迹测绘精度需求下, 比较 CSTD 算法与 RASS、RTI 算法的能量消耗. 对于每一种算法, 不断增加部署在监测区域的观测链路数 (注意, 链路数越多, 能耗越大), 直到目标轨迹测绘结果满足给定的精度需求, 然后计算该算法的能量消耗. 根据一介无线通信模型^[31], 每条链路的能量消耗可计算为 $E_{\text{radio}} = e_l B b^2 + 2BE_{\text{elec}}$, 其中 B 是以比特为单位的数据包大小, b 是链路长度 (如图 2 所示), $e_l = 100 \text{ pJ}/(\text{bit}/\text{m}^2)$, $E_{\text{elec}} = 50 \text{ nJ}/\text{bit}$. 在本文实验中, 每个子区域的部署及拓扑设置均相同, 均为 $B=320 \text{ bits}$, $b=4 \text{ m}$, 每个监测时刻发送 30 个数据包. 由于所有 3 种算法均是在同一个大监测区域进行轨迹测绘, 简单期间在此仅考虑它们在某一个子区域内的能量消耗比较. 针对给定算法, 当子区域由 M 条链路覆盖时, 其能耗为 $E_{\text{radio}} = M \times 0.96 \text{ mJ}$. 图 10 展示了在不同的平均轨迹测绘误差下, CSTD 算法与 RASS、RTI 算法的能量消耗对比, 可以看出

为达到给定的精度需求, CSTD 算法消耗的能耗最小, 其原因在于 CSTD 算法利用压缩感知原理, 仅通过少量观测数据就能精确恢复出目标的轨迹, 而 RASS 和 RTI 算法需要更多的观测数据来精确测绘目标的轨迹. 图 10 还表明无论是哪种算法, 随着轨迹测绘误差的降低, 其能量消耗均在增加. 这个现象的原因在于, 当用更多的观测链路覆盖监测区域时, 一定程度上可以降低轨迹测绘的误差^[10, 13-14] (如图 6 中展示的结果所示), 即轨迹测绘误差的降低, 是以能耗的增加为代价, 实际应用中, 可以根据需求, 在精度和能耗之间折中.

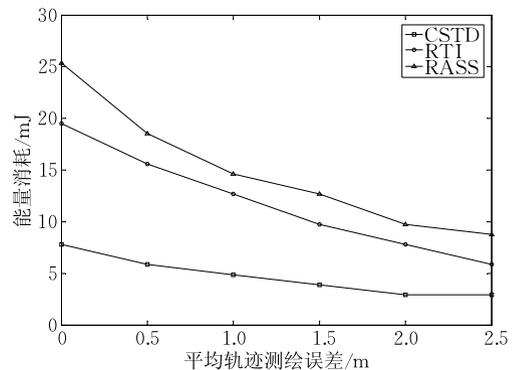


图 10 能量消耗比较

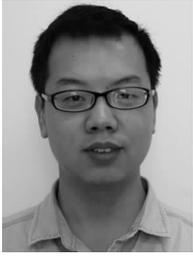
6 总 结

本文提出了一种基于压缩感知的被动式目标轨迹测绘 CSTD 方法, 其优点是利用压缩感知原理在稀疏恢复方面的优势, 仅用少量观测数据就能精确测绘出目标的轨迹, 同时, CSTD 仅通过一次计算完成测绘, 避免了现有算法频繁定位导致计算开销大的问题. 其次, 为适应大规模被动式轨迹测绘的应用需求, 本文给出了一种可扩展的 CSTD 算法模型, 使得 CSTD 算法很容易扩展到任何规模场景. 针对在目标轨迹经过的网格数 K 未知的情况下, 现有经典稀疏恢复算法无法重建的问题, 本文提出了自适应稀疏恢复算法 AMP, 放宽了目标轨迹向量恢复的约束条件. 仿真实验和真实实验均验证了本文提出的 CSTD 和 AMP 方法的有效性和可行性.

参 考 文 献

- [1] Garg R, Mittal A. A survey on techniques of vertebrae localization//Proceedings of the Recent Advances in Engineering and Computational Sciences (Raecs 2014). Chandigarh, India, 2014: 1-4

- [2] Patwari N, Wilson J. RF sensor networks for device-free localization; Measurements, models, and algorithms. *Proceedings of the IEEE*, 2010, 98(11): 1961-1973
- [3] Hauschildt D, Kirchhof N. Advances in thermal infrared localization: Challenges and solutions//*Proceedings of the Indoor Positioning and Indoor Navigation (Ipin 2010)*. Zurich, Switzerland, 2010; 1-8
- [4] Salih Y, Sebastian P, Vooi Voon Yap. Video localization using array of microphones//*Proceedings of the International Conference on Intelligent and Advanced Systems (ICIAS 2010)*. Kuala Lumpur, Malaysia, 2010; 1-4
- [5] Liu Yunhao, Chen Lei, Pei Jian, et al. Mining frequent trajectory patterns for activity monitoring using radio frequency tag arrays//*Proceedings of the Pervasive Computing and Communications (Percom 2007)*. White Plains NY, USA, 2007; 37-46
- [6] Zhang Dian, Ma Jian, Chen Quanbin, et al. An RF-based system for tracking transceiver-free objects//*Proceedings of the Pervasive Computing and Communications (Percom 2007)*. White Plains NY, USA, 2007; 135-144
- [7] Sigg S, Schol M, et al. RF-sensing of activities from non-cooperative subjects in device-free recognition systems using ambient and local signals. *IEEE Transactions on Mobile Computing*, 2014, 13(4): 907-920
- [8] Youssef M, Mah M, Agrawala A. Challenges: Device-free passive localization for wireless environments//*Proceedings of the International Conference on Mobile Computing and Networking (Mobicom 2007)*. Montréal, Canada, 2007; 222-229
- [9] Wilson J, Patwari N. See-through walls: Motion tracking using variance-based radio tomography networks. *IEEE Transactions on Mobile Computing*, 2011, 10(5): 612-621
- [10] Zhang D, Liu Y, Guo X, et al. RASS: A real-time, accurate, and scalable system for tracking transceiver-free objects. *IEEE Transactions on Parallel and Distributed Systems*, 2013, 24(5): 996-1008
- [11] Adib F, Katabi D. See through walls with Wi-Fi//*Proceedings of the Special Interest Group on Data Communication (SIGCOMM 2013)*. Hong Kong, China, 2013; 75-86
- [12] Adib F, Kabelac Z, Katabi D, Miller R C. 3D tracking via body radio reflections//*Proceedings of the Symposium on Networked System Design and Implementation (NSDI 2014)*. Seattle, USA, 2014; 317-329
- [13] Wang J, Fang D Y, Chen X J, et al. LCS: Compressive sensing based device-free localization for multiple targets in sensor networks//*Proceedings of the International Conference on Computer Communications (INFOCOM 2013)*. Turin, Italian, 2013; 145-149
- [14] Wang J, Gao Q, Zhang X, Wang H. Device-free localization with wireless networks based on compressive sensing. *IET Communications*, 2012, 6(15): 2395-2403
- [15] Eldar Y C, Kutyniok G. *Compressed Sensing: Theory and Applications*. Oxford, UK; Cambridge University Press, 2012
- [16] Donoho D L. For most large underdetermined systems of linear equations, the minimal l_1 -norm solution is also the sparsest solution. *Communications on Pure and Applied Mathematics*, 2006, 59(6): 797-829
- [17] Van D B E, Friedlander M P. Probing the Pareto frontier for basis pursuit solutions. *SIAM Journal on Scientific Computing*, 2008, 31(2): 890-912
- [18] Tropp J A, Gilbert A C. Signal recovery from random measurements via orthogonal matching pursuit. *IEEE Transactions on Information Theory*, 2007, 53(12): 4655-4666
- [19] Donoho D L, Tsaig Y, Drori I, et al. Sparse solution of underdetermined systems of linear equations by stage wise orthogonal matching pursuit. *IEEE Transactions on Information Theory*, 2012, 58(2): 1094-1121
- [20] Needell D, Vershynin R. Signal recovery from incomplete and inaccurate measurements via regularized orthogonal matching pursuit. *IEEE Journal of Selected Topics in Signal Processing*, 2010, 4(2): 310-316
- [21] Needell D, Tropp J A. Cosamp: Iterative signal recovery from incomplete and inaccurate samples. *Applied and Computational Harmonic Analysis*, 2009, 26(3): 301-321
- [22] La C, Minh N D. Tree-based orthogonal matching pursuit algorithm for signal reconstruction//*Proceedings of the International Conference on Image Processing*. Atlanta, GA, 2006; 1277-1280
- [23] Dai W, Milenkovic O. Subspace pursuit for compressive sensing signal reconstruction. *IEEE Transactions on Information Theory*, 2009, 55(5): 2230-2249
- [24] Do T T, Gan L, Nguyen N, Tran T D. Sparsity adaptive matching pursuit algorithm for practical compressed sensing//*Proceedings of the Asilomar Conference on Signals, Systems and Computers*. Pacific Grove, USA, 2008; 581-587
- [25] Zhang F. *Matrix Theory: Basic Results and Techniques*. Germany: Springer Verlag, 2011
- [26] Mendenhall W, Beaver R, Beaver B. *Introduction to Probability and Statistics*. USA: Cengage Learning, 2012
- [27] Millsaugh J, Frank R, Thompson E. *Models for Planning Wildlife Conservation in Large Landscapes*. Academic Press, 2011
- [28] Rappaport T S. *Wireless Communications: Principles and Practice*. New Jersey, USA: Prentice Hall PTR, 2002
- [29] Jackson J D, Fox R F. *Classical electrodynamics*. *American Journal of Physics*, 1999, 67(9): 841-842
- [30] Candes E J, Romberg J. ℓ_1 -MAGIC: Recovery of sparse signals via convex programming. URL: www.acm.caltech.edu/l1magic/downloads/l1magic.pdf, 2010
- [31] Heinzelman W R, Chandrakasan A, Balakrishnan H. Energy-efficient communication protocol for wireless microsensor networks//*Proceedings of the International Conference on System Sciences*. Hawaii, USA, 2000; 10-20



WANG Ju, born in 1989, Ph. D.

His current research interest is Internet of Things.

security.

CHANG Li-Qiong, born in 1989, Ph. D. Her current research interest is Internet of Things.

FANG Ding-Yi, born in 1959, Ph. D. , professor. His current research interests include network security and IoT.

XING Tian-Zhang, born in 1981, Ph. D. , lecturer. His current research interest is Internet of Things.

NIE Wei-Ke, born in 1978, Ph. D. , lecturer. His current research interest is Internet of Things.

CHEN Xiao-Jiang, born in 1973, Ph. D. , professor.

His current research interests include IoT and network

Background

Localization has long been playing one of the key roles in our daily life such as finding the lost object, route navigation applications. There are many Radio-Frequency based localization devices/systems, for example, RADAR, Horus, EZ and etc. Current localization systems typically can locate the target when it carries devices. These systems may not be applicable in some scenarios. For instance, in case of the intrusion detection, it is impossible to pre-install the tracking devices on the intruders. Similarly, in the wild animal monitoring, it is hard to attach any device to the animal body and zoologists do not favor to do that either. Given these limitations, it has been of a great interest in both the academia and industry to enable RF based Device-Free Localization (DFL) to perform more pervasively for wild animal monitoring, intrusion detection privacy-enhanced monitoring, and personal security when stepping into dark alleys.

The concept of received signal strength (RSS)-based DFL was born of the seminal work by Youssef et al. who conducted the localization by explicating the RSS changes distorted by target and modeled the DFL as a fingerprint matching (location matched with the RSS changes) problem.

Compared with the similar techniques, such as video based DFL and infrared based DFL, one main advantage of using RSS for DFL is that the RSS readings are readily available in existing wireless infrastructures and without requiring additional devices (such as camera and infrared sensor).

Most of current device-free localization and trajectory depiction method suffer from the problems such as repeatedly positioning calculation, high data volume and the energy consumption. To deal with the challenges, this paper introduces a novel compressive sensing based device-free target trajectory depiction (CSTD) method, which apply the compressive sensing to track the target accurately even with just a few measurements and depict the trajectory at one calculation. Thus, reduce the energy consumption and avoid the repeatedly positioning calculation.

This work was supported by Project National Natural Science Foundation of China (61170218, 61272461, 61373177), Project National Key Technology R&D Program (2013BAK01-B02), and Graduate Innovative Education Project of Northwest University (YZZ13104, YZZ14002).