

DOI: 10.19650/j.cnki.cjsi.J2312274

基于半张量积压缩感知的室内定位算法*

蒲巧林, 周龙璨, 周牧, 蒋逢怡, 李云海

(重庆邮电大学通信与信息工程学院 重庆 400065)

摘要:为应对大场景环境下利用压缩感知(CS)技术实现无线局域网(WLAN)的室内定位时,所面临的定位精度降低和计算复杂度提升的两大挑战,首先引入了改进的聚类算法进行粗定位,以此有效缩减搜索范围。针对无线信号的奇异值问题,创新性地提出了自适应直觉模糊C有序均值聚类算法。其次,为克服高维观测矩阵带来的巨大存储压力,提出了一种半张量积压缩感知(STP-CS)技术对观测矩阵降维。相比传统CS方法,该方法能在维持相同维度的基础上,容纳更多数量的接入点。实验结果表明,所提的算法在保证定位精度的前提下,成倍降低观测矩阵所需的存储空间,显著降低计算开销,在大场景应用中更具优势。

关键词:室内定位;半张量积压缩感知;聚类;接入点;观测矩阵

中图分类号: TN91 TH89 文献标识码: A 国家标准学科分类代码: 510.50

Indoor localization based on semi-tensor product compression sensing

Pu Qiaolin, Zhou Longcan, Zhou Mu, Jiang Fengyi, Li Yunhai

(School of Communication and Information Engineering, Chongqing University of Posts and
Telecommunications, Chongqing 400065, China)

Abstract: When using the compression sensing (CS) localization algorithm for large scene environments based on the wireless local area network (WLAN), two challenges arise: reduced positioning accuracy and increased computational complexity. To address these issues, this paper introduces an improved clustering algorithm for coarse localization to reduce the search range. Specifically, for the singular value problem of wireless signals, we innovatively propose the adaptive intuitionistic fuzzy c-ordered mean clustering algorithm. Secondly, to overcome the high storage pressure brought by the high-dimensional observation matrix, a semi-tensor product compression sensing (STP-CS) technique is proposed. Compared with the traditional CS method, this method can accommodate more access points while maintaining the same dimensionality. Experimental results show that the proposed algorithm significantly reduces the storage space required by the observation matrix and decreases the computational overhead under the premise of ensuring positioning accuracy. These advantages make it particularly well-suited for large-scale applications.

Keywords: indoor localization; semi-tensor product compression sensing; clustering; access points; measurement matrix

0 引言

随着物联网技术的发展,基于位置的服务(location-based service, LBS)^[1]已被应用于日常生活的各个领域。在室外环境中,应用最广泛的是全球定位系统(global positioning system, GPS)^[2],它具有较高的定位精度,但

GPS定位需要卫星和用户之间的直接视距(line of sight, LOS),这在室内环境中并不适用。因此,基于射频识别(radio frequency identification, RFID)^[3]、超宽带^[4]、惯性系统^[5]和无线局域网(wireless local area network, WLAN)^[6]的定位技术已被相继提出。其中,基于WLAN的室内定位技术不需要部署额外的设备,具有普遍性,因此,这种技术已成为最常见的室内定位技术之一。

收稿日期: 2023-12-14 Received Date: 2023-12-14

* 基金项目: 国家自然科学基金项目(62201110)、重庆市教委科学技术研究中心项目(KJQN202200648)、重庆市科委项目(CSTB2022NSCQ-MSX1385)资助

在基于 WLAN 的定位系统中,存在两种数据源:一种是接收信号强度(received signal strength, RSS);一种是信道状态信息(channel state information, CSI)。由于 RSS 数据更容易获得,数据处理更为容易,因此在大多数定位系统中选择使用 RSS 数据。而基于 RSS 的定位方法可以分为两类,一类是基于模型的方法,如信号传播模型^[7]和深度学习模型^[8]。信号传播模型根据三边定位算法获得位置估计,而深度学习模型多具有较高的内存和计算要求,这使得在资源受限的系统上部署是一项挑战。另一种基于非模型的方法,它通过建立指纹数据库来进行定位。其优点是不需要建立传播模型,并且定位精度相对较高,所以现如今的定位系统多采用指纹的方法进行定位。

基于 RSS 指纹定位系统存在两种定位方法:一种是基于信号空间相似度的定位方法;一种是基于稀疏恢复技术的室内定位方法,其经典代表为压缩感知(compression sensing, CS)^[9]的定位方法。在基于信号空间相似度的定位方法中,最简单的定位算法是 K 近邻算法(K nearest neighbor, KNN)^[10],它通过计算离线与在线 RSS 测量值的最小欧氏距离的 K 个最近邻质心来估计用户的位置。虽然这样的系统很容易实现,但是高度依赖相似性度量方法的选择。而基于稀疏恢复的室内定位方法主要是从传统回归算法改进而来的,其优点是它不依赖于相似性度量,并且可以定量地给出在线测量和全局所有参考点(reference point, RP)之间的相关性,可以提高定位精度和系统稳定性。因此,稀疏恢复方法成为研究热点。

CS 是稀疏恢复方法中最经典的方法,被广泛用于室内定位系统中^[11-12]。当然,这种方法也存在待解决的问题。当目标环境属于大场景范畴时,即 RP 和接入点(access point, AP)数量较多,定位区域面积较广,稀疏向量维度过高,稀疏恢复精度大打折扣。因此,一方面需要粗定位阶段进行聚类来降低稀疏向量维度,但现有的聚类算法,大多是针对聚类结果进行优化,没有考虑无线信号具有多径效应造成异常值的情况,从而针对异常值处理进行设计。另一方面,当 AP 数量较多时,观测矩阵维度较大,占用较大存储空间且计算开销增大。传统处理方法是进行 AP 约简,然而,AP 数量减少将降低系统定位精度,而且选择合适的 AP 数量也是一个挑战。因此,针对上述粗定位和精定位阶段存在的问题,本文首先提出了自适应直觉模糊 C 有序均值(adaptive intuitionistic fuzzy C-ordered mean, AIFCOM)聚类算法来处理具有异常值的离线数据库。其次,提出半张量压缩感知(semi-tensor product compression sensing, STP-CS)模型来构造低阶的观测矩阵。该模型与传统 CS 模型相比,当观测矩阵具有同样维度时,该模型包含了 t 倍数量的 AP,

更佳适用大环境下的定位,可以降低存储空间节约运行时间,同时提高定位精度。主要的研究工作如下。

1) 提出一种 AIFCOM 聚类方法。该方法与传统的聚类方法相比,考虑了异常值,并可以消除初始值带来的影响,更适合多变的 WLAN 环境。

2) 提出一种 STP-CS 方法。通过构造低阶的观测矩阵,从而减少存储空间。与传统的 CS 模型相比,该模型保留了 AP 的数量,更佳适用大环境下 AP 的定位。

3) 实验结果表明,本文的定位系统降低了存储空间,提升了定位精度和效率。与传统的聚类算法和 CS 定位技术相比,提出的方法可以去除异常值的影响,并保留更多数量的 AP。

1 研究现状

1.1 基于聚类算法的粗定位

当使用稀疏恢复算法进行精定位时,建议引入粗定位步骤,其一是为了减轻 RSS 在线测量数据与离线测量数据偏差较大对精度的影响,需先进行粗定位;其二是稀疏恢复算法的计算复杂度随着目标区域的增大而增加,因此需要粗定位步骤来缩减搜索区域。这样的粗定位大多采用聚类的方式,将离线数据库划分为多个子数据库,以减少目标区域的大小。Lee 等^[13]提出了一种指纹数据库生成算法,使用 K-means 聚类算法寻找最优的聚类数量。Li 等^[14]提出了一种基于主成分分析的自适应分层聚类算法辅助室内定位,通过聚集 RP 和利用 PCA 特征提取方法可以提高定位精度。在文献[15-16]中,由于引入了基于模糊集的聚类算法,聚类效果得到改善。Yang 等^[17]提出了一种用于室内定位的鲁棒稀疏重叠群套索算法,该方法首先利用离线 RP 和在线测试点(test point, TP)的相似性,通过模糊 C 均值(fuzzy C-mean, FCM)聚类获得重叠组,然后使用鲁棒稀疏重叠群套索算法重建 TP 的指纹。然而,基于 FCM 的聚类方法在处理有异常值的数据集时,聚类算法的性能会降低。

综上所述,现有的基于聚类的定位方法仅仅针对聚类算法本身来进行改进,大多没有考虑面对大目标环境和数据中的异常值对聚类结果和定位精度带来的影响。因此提出了 AIFCOM 聚类算法,在划分子数据库的同时处理原数据库存在的异常值,旨在得到更完善的离线数据库,为后续的精定位打好基础。

1.2 基于稀疏恢复的精定位

基于 CS 模型的定位方法旨在使用稀疏恢复算法从少量的在线测量中获得准确的位置估计。该方法不依赖于指纹之间的相似性,而是通过将定位问题表述为空间的稀疏恢复问题来实现位置的精确估计。因此,该方

法在定位系统中得到了广泛的应用。Feng 等^[18]首次提出了基于 CS 的定位方法,使用亲和传播进行粗定位,再使用 CS 进行精定位。Yan 等^[19]设计了一种优化测量矩阵来增强受限等距特性(restricted isometric property, RIP)和最大化信噪比的 CS 定位方法。文献[20]提出了一种使用增强型稀疏恢复算法的室内 WLAN 定位方法,该方法首先应用图的聚类方法进行粗定位,然后使用改进的 CS 方法进行精定位。Khan 等^[21]提出了一种使用贝叶斯压缩感知估计目标节点位置的方法。Zhao 等^[22]提出了一种离线指纹数据库构建方法,通过结合贝叶斯压缩感知理论和 RP 指纹的相似性来实现指纹数据库的更新。文献[23]提出了一种基于 RSS 指纹的超高频局部放电的定位算法。该方法首先使用训练好的 BP 神经网络实现了粗定位,然后使用 CS 算法获得了更准确的位置估计。在大场景环境下,一般采用筛选 AP 的方法对观测矩阵进行降维。陈鹏等^[24]提出一种基于信号丢失率的 AP 选取算法,选取高质量的 AP 实现高精度定位。吴伟等^[25]提出了一种基于 WiFi 信号的整体区间重叠度的 AP 选取方法,通过增强 AP 对 RP 的识别能力达到提高定位精度的效果。

传统 AP 选择算法一般都是以裁撤 AP 的数量来对观测矩阵降维,所提的方法从矩阵乘法的原理出发,旨在保留 AP 数量的同时构造与之等价的低阶矩阵,从而避免误删了可用信息而导致精度下降的问题。

2 传统 CS 模型

假设一个基于 CS 的定位系统,其由 L 个 AP 和 N 个 RP 组成。因此,在离线阶段,在已知位置的 RP 处收集 RSS 测量值的时间样本。在第 j 个 RP 收集到的第 i 个 AP 的原始 RSS 时间样本被表示为:

$$\{\psi_{i,j}(\tau), \tau = 1, \dots, Q, Q > 1\} \quad (1)$$

式中: Q 表示在每个 RP 处收集的 RSS 测量值的次数。RSS 测量值的平均值存储在数据库中,表示为:

$$\Psi = \begin{pmatrix} \bar{\psi}_{1,1} & \bar{\psi}_{1,2} & \cdots & \bar{\psi}_{1,N} \\ \bar{\psi}_{2,1} & \bar{\psi}_{2,2} & \cdots & \bar{\psi}_{2,N} \\ \vdots & \vdots & \ddots & \vdots \\ \bar{\psi}_{L,1} & \bar{\psi}_{L,2} & \cdots & \bar{\psi}_{L,N} \end{pmatrix} \quad (2)$$

式中: L 是 AP 的总数; N 是 RP 的总数; $\bar{\psi}_{i,j}$ 是第 j 个 RP 在第 i 个 AP 处的平均 RSS 测量值。

在线阶段,测量得到的 RSS 测量值可以表示为 y , 那么可以构造 CS 模型为:

$$\mathbf{y}_{M \times 1} = \Phi_{M \times L} \Psi_{L \times N} \boldsymbol{\theta}_{N \times 1} + \boldsymbol{\omega} \quad (3)$$

式中: $\Phi_{M \times L}$ 是观测矩阵;在定位系统中, Φ 表示 AP 选择矩阵; Ψ 是指纹数据库; $\boldsymbol{\omega}$ 表示噪声,并满足 $\boldsymbol{\omega} \sim N(0, \sigma^2 \mathbf{I})$;

M 是 AP 子集的数量,也是在线测量的 AP 数量; $\boldsymbol{\theta}$ 是表示目标位置的稀疏向量,表示为:

$$\boldsymbol{\theta} = [0, \dots, 0, 1, 0, \dots, 0]^T \quad (4)$$

式中: $\theta(\iota) = 1$ 表示目标在第 ι 个 RP 处,其余元素均为零。因此,目标的位置估计是使用稀疏恢复算法精确地恢复稀疏向量,例如 ℓ_1 范数最小化^[26]。

$$\begin{cases} \hat{\boldsymbol{\theta}} = \underset{\boldsymbol{\theta} \in \mathbb{R}^N}{\operatorname{argmin}} \|\boldsymbol{\theta}\|_1 \\ \text{s. t. } \mathbf{y}_{M \times 1} = \Phi_{M \times L} \Psi_{L \times N} \boldsymbol{\theta}_{N \times 1} + \boldsymbol{\omega} \end{cases} \quad (5)$$

ℓ_1 范数不是严格凸的,因此更容易获得稀疏解。利用 CS 模型还存在两个前提条件:稀疏性和非相干性。此外,由式(3)和(4)可知,当面对多 AP 和多 RP 的大型环境时,稀疏向量的维度很大。由经验可知这种方法会导致定位精度的降低和计算复杂度的增加。因此,需要使用稀疏恢复进行精定位之前添加粗定位步骤。在多 AP 环境下,构建观测矩阵是一个耗时和增加存储成本的问题。因此,可使用 AP 选择来选择预定数量的 AP。

3 系统模型

3.1 系统整体框架

为解决大目标环境下采用稀疏恢复算法进行位置估计会增加稀疏向量维数,导致定位精度下降,计算复杂度增加的问题,本文提出了 AIFCOM 聚类方法和 STP-CS 方法进行定位。其定位方法包括两个阶段:离线阶段,在 RP 位置处采集 RSS 样本值,然后利用 AIFCOM 聚类方法对离线阶段采集的 RSS 样本值进行聚类;在线阶段细分为两个阶段:粗定位阶段,通过聚类匹配缩小定位区域的范围。精定位阶段,利用 STP-CS 方法实现位置估计。所提出的定位系统流程图如图 1 所示。

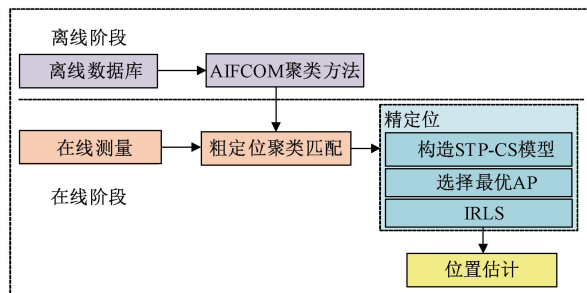


图 1 定位系统流程

Fig. 1 Localization system flowchart

3.2 基于 AIFCOM 聚类算法的粗定位

尽管 WLAN 信号在室内环境的普遍性和可用性为室内定位技术带来了极大便利,但是也面临了一些问题。由于环境因素的改变,在采集 RSS 读数时会出现

随机波动,且由于门、墙壁等障碍物存在非视线传播,复杂的室内环境呈现出多路径 RSS 轮廓。此外,在距离 APs 较近的地方, RSS 曲线显示出更高的差异。 WLAN 是动态的系统,它经历快速变化不仅是由于 AP 软件,而且由于基础设施的变化,如 AP 的移除、故障、干扰、AP 的间歇性关闭,在这种情况下,某些不正常的读数被称为异常值。

AIFCOM 可以通过计算识别异常值并对其赋予较低的权重,同时能够自适应地选择最优聚类数量,使聚类中心受异常值的影响较小,其位置不会因为异常值的存在而发生显著变化,也不会产生较大的位置偏移。其原理及实现过程如下:

首先引入一种广义模糊集,即 Atanassov 直觉模糊集 (Atanassov intuitionistic fuzzy set, AIFS), 定义为:

$$A = \{ \langle x_i, \mu_A(x_i), v_A(x_i) \rangle, i = 1, 2, \dots, N \} \quad (6)$$

式中: $\mu_A(x_i)$ 是成员值; $v_A(x_i)$ 是非成员值,且满足 $0 \leq \mu_A(x_i) + v_A(x_i) \leq 1$; N 是数据项的总数; x_i 是 AIFS 数据集中第 i 个数据项。此外,直觉模糊集中还包含直觉模糊指数,也称为犹豫度 $\pi_A(x_i)$, 表示为 $\pi_A(x_i) = 1 - \mu_A(x_i) - v_A(x_i)$ 。

x_i 通过成员值、非成员值和犹豫度表示为 $x_i = (\mu_{il}, v_{il}, \pi_{il})_{l=1}^L$, 通过对下式进行分析即可获得:

$$\begin{cases} \mu_{il} = (\bar{\omega}_{il})^s, & s > 0 \\ v_{il} = (1 - (\bar{\omega}_{il})^\alpha)^{\frac{1}{\alpha}}, & 0 < \alpha \leq 1 \\ \pi_{il} = 1 - \mu_{il} - v_{il} \end{cases} \quad (7)$$

式中: $\bar{\omega}$ 是归一化的函数,通过一个正值的参数 s 谐调 $\bar{\omega}$ 。根据 $\bar{\omega}$ 生成 AIFS 时需要满足 $x_i \rightarrow [0, 1]$ 的条件。

由上可知, AIFS 可对模糊数据集的不确定性进行估计。此外,有序加权平均 (ordered weighted averaging, OWA) 函数^[27]可对数据进行加权,为各数据分配最优权重。因此,本文将 AIFS 理论、OWA 函数与模糊 C 均值方法相结合,提出了 AIFCOM 聚类方法来提升处理异常值数据时的聚类效果,该聚类方法的准则函数定义如下:

$$J = \min \sum_{j=1}^c \sum_{i=1}^N \beta_{ji} u_{ji}^m \sum_{l=1}^L \tilde{\Gamma}(\tilde{x}_{il} - \tilde{v}_{jl}) \quad (8)$$

式中: β_{ji} 是局部典型性值; u_{ji} 是第 i 个数据点在第 j 个聚类中的成员值; m 是模糊性指数; c 代表聚类的数量, L 是数据的维度。每个数据点 x_i 都包含有 L 个维度的值。例如, $(\tilde{x}_{il})_{l=1}^L$ 是一个有 L 个维度的特征向量,其中 $\tilde{x}_{il}$ 为第 l 个特征值。在定位系统中, L 也表示 AP 的数量。此外, $\tilde{\Gamma}$ 是损失函数,表示为 $\tilde{\Gamma}(\tilde{x}_{il} - \tilde{v}_{jl}) = h(e_{jil}) [(\mu_{il} - \bar{\mu}_{jl})^2 + (v_{il} - \bar{v}_{jl})^2 + (\pi_{il} - \bar{\pi}_{jl})^2]$ 。在该损失函数中的函数 h 被定义为映射 h , 使得:

$$h(e_{jil}) = \begin{cases} 0, & e_{jil} = 0 \\ \frac{1}{|e_{jil}|}, & e_{jil} \neq 0 \end{cases} \quad (9)$$

其中,就第 l 个维度而言,第 i 个数据项在第 j 个聚类中的残留量用 $e_{jil} = (\tilde{x}_{il} - v_{jl})$ 计算, v_{jl} 表示第 j 个聚类区域中的聚类中心点的非成员值。

为了求解目标函数,该问题还需要满足约束条件:

$$\begin{cases} u_{ji} \geq 0, & 1 \leq j \leq c, 1 \leq i \leq N \\ 0 \leq \sum_{i=1}^N u_{ji} \leq N, & 1 \leq j \leq c \\ \sum_{j=1}^c \beta_{ji} u_{ji} = f_i, & 1 \leq i \leq N \end{cases} \quad (10)$$

其中, f_i 是全局典型性值。局部典型性 β_{ji} 是指对数据进行加权后的值,并利用 OWA 函数进行加权。因此,第 i 个数据项在第 j 个聚类中的局部典型性 β_{ji} , 由式 (11) 表示:

$$\begin{cases} \beta_{ji} = \prod_{l=1}^L \hat{\beta}_{jil} \\ \hat{\beta}_{jil} = \{ [(p_c N - \tau) / (2p_j N) + 0.5] \wedge 1 \} \vee 0 \end{cases} \quad (11)$$

式中: $\wedge$ 和 $\vee$ 分别表示最小和最大操作。 $\tau \in [p_c N - p_j N, p_c N + p_j N]$ 从 1 到 0 线性递减,第 i 个数据项在第 j 个聚类的第 l 个维度上使用函数 τ 进行排序。对最接近第 l 个聚类的数据项被赋予等级 1,对最远的数据项被赋予等级 N 。

全局典型性 f_i 分析了第 i 个数据项在 c 个聚类中的整体行为。因此,第 i 个数据项的全局典型性 f_i 是通过找到第 i 个数据项在 c 个聚类区域中最大的局部典型性来估计的,如下:

$$f_i = \max \{ \beta_{1i}, \beta_{2i}, \dots, \beta_{ci} \} \quad (12)$$

为了求解目标函数,利用拉格朗日函数得到成员值和聚类中心的迭代表达式。借助拉格朗日乘数 λ_i ($1 \leq i \leq n$), 得到拉格朗日函数 $G(M, V)$ 如下:

$$G(M, V) = \sum_{i=1}^N \left(\sum_{j=1}^c \beta_{ji} u_{ji}^m \sum_{l=1}^L h(e_{jil}) ((\mu_{il} - \bar{\mu}_{jl})^2 + (v_{il} - \bar{v}_{jl})^2 + (\pi_{il} - \bar{\pi}_{jl})^2) - \sum_{i=1}^N \lambda_i \left[\sum_{j=1}^c \beta_{ji} u_{ji} - f_i \right] \right) \quad (13)$$

通过得到的拉格朗日函数对成员值 u_{ji} 进行迭代更新,首先利用拉格朗日函数对成员值 u_{ji} 求导。

$$\frac{\partial G(M, V)}{\partial u_{ji}} = \beta_{ji} m u_{ji}^{m-1} \sum_{l=1}^L h(e_{jil}) ((\mu_{il} - \bar{\mu}_{jl})^2 + (v_{il} - \bar{v}_{jl})^2 + (\pi_{il} - \bar{\pi}_{jl})^2) - \lambda_i \beta_{ji} = 0 \quad (14)$$

通过求解式 (14) 可得:

$$u_{ji} = \left(\frac{\lambda_i}{m} \right)^{\frac{1}{m-1}} \sum_{l=1}^L h(e_{jil}) ((\mu_{il} - \bar{\mu}_{jl})^2 + (v_{il} - \bar{v}_{jl})^2 + (\pi_{il} - \bar{\pi}_{jl})^2)^{\frac{1}{m-1}} \quad (15)$$

其次,结合式 (14) 和 (15), 可得:

$$\left\{ \begin{aligned} & \sum_{j=1}^c \beta_{ji} \left(\frac{\lambda_i}{m} \right)^{\frac{1}{m-1}} \left(\sum_{l=1}^L h(e_{jil}) ((\mu_{il} - \bar{\mu}_{jl})^2 + \right. \\ & \quad \left. (v_{il} - \bar{v}_{jl})^2 + (\pi_{il} - \bar{\pi}_{jl})^2) \right)^{\frac{1}{m-1}} = f_i \\ & \left(\frac{\lambda_i}{m} \right)^{\frac{1}{m-1}} \sum_{j=1}^c \beta_{ji} \left(\sum_{l=1}^L h(e_{jil}) ((\mu_{il} - \bar{\mu}_{jl})^2 + \right. \\ & \quad \left. (v_{il} - \bar{v}_{jl})^2 + (\pi_{il} - \bar{\pi}_{jl})^2) \right)^{\frac{1}{m-1}} = f_i \end{aligned} \right. \quad (16)$$

最后,将式(15)除以式(16)可得成员值 u_{ji} 的迭代表达式:

$$u_{ji} = \frac{\left\{ f_i \sum_{l=1}^L h(e_{jil}) ((\mu_{il} - \bar{\mu}_{jl})^2 + (v_{il} - \bar{v}_{jl})^2 + (\pi_{il} - \bar{\pi}_{jl})^2)^{\frac{1}{m-1}} \right\}}{\left\{ \sum_{j=1}^c \beta_{ji} \left(\sum_{l=1}^L h(e_{jil}) ((\mu_{il} - \bar{\mu}_{jl})^2 + (v_{il} - \bar{v}_{jl})^2 + (\pi_{il} - \bar{\pi}_{jl})^2) \right)^{\frac{1}{m-1}} \right\}} \quad (17)$$

此外,聚类中心点矩阵 $\mathbf{V} = [\tilde{v}_1, \tilde{v}_2, \dots, \tilde{v}_c]^T$, 需要迭代更新。在 AIFS 中, $\tilde{v}_j = (\mu_{jl}, v_{jl}, \pi_{jl})_{l=1}^L$ 代表在第 j 个聚类区域中的聚类中心点。根据式(13)推导的拉格朗日函数,可以迭代更新 AIFS 中的成员值 $\bar{\mu}_{jl}$ 、非成员值 $\bar{v}_{jl}$ 和犹豫值 $\bar{\pi}_{jl}$, 求解方法同成员值 u_{ji} 的求解方法, 先进行求导, 再化简可得:

$$\left\{ \begin{aligned} \bar{\mu}_{jl} &= \frac{\sum_{i=1}^N \beta_{ji} u_{ji}^m h(e_{jil}) \mu_{il}}{\sum_{i=1}^N \beta_{ji} u_{ji}^m h(e_{jil})} \\ \bar{v}_{jl} &= \frac{\sum_{i=1}^N \beta_{ji} u_{ji}^m h(e_{jil}) v_{il}}{\sum_{i=1}^N \beta_{ji} u_{ji}^m h(e_{jil})} \\ \bar{\pi}_{jl} &= \frac{\sum_{i=1}^N \beta_{ji} u_{ji}^m h(e_{jil}) \pi_{il}}{\sum_{i=1}^N \beta_{ji} u_{ji}^m h(e_{jil})} \end{aligned} \right. \quad (18)$$

通过上述步骤的迭代更新之后,聚类算法需要实现收敛才能得到在预设聚类数量下的最优解。所以,该算法收敛需要满足条件为:

$$\sum_{j=1}^c \frac{d_2(\tilde{v}_j(t), \tilde{v}_j(t+1))}{c} < \varepsilon \quad (19)$$

式中: ε 是阈值常数。

最后,根据预先设定的聚类数量的搜索范围,生成不同数量的聚类结果,并选择有效性指数最小的聚类结果,以实现自适应确定最优聚类数的聚类结果,如

$$J_{\text{best}} = \min_{c=1}^{\text{cmax}} (J) \quad (20)$$

通过得到的聚类结果,比较在线测量的 RSS 值与每个聚类中心的距离,找到与在线 RSS 测量值距离最近的聚类区域。由此,确定粗定位的区域。

3.3 基于 STP-CS 的精定位

通过粗定位缩小定位区域之后,本节采用 STP-CS 模型进行精定位。由于 STP-CS 模型只改变了观测矩阵的大小,其他特征保持不变,所以 STP-CS 的定位过程与 CS 的定位过程相似。因此,在本节中首先对 STP 理论进行分析;其次,给出 STP-CS 定位模型;最后,通过稀疏恢复算法实现对用户位置的估计。

1) STP 理论

对于大量的数据,传统的矩阵乘法运算需要建立一个较大的矩阵,而 STP 乘法^[28]通过建立一个低阶的观测矩阵就可以达到同样的效果。这种方法可以大大减少观测矩阵的存储空间,降低数据的计算复杂性,因此可以在稀疏恢复中得到应用。

STP 是一种新型的矩阵乘法。它是介于传统矩阵乘法和张量乘法之间的一种新操作。当两个矩阵 Φ 和 Ψ 满足 Φ 的列数和 Ψ 的行数之间的多重关系时,它们之间可以进行 STP 乘法。

定义 1: 设 Φ 是一个 np 维的行向量, Ψ 是一个 p 维的列向量。 Φ 分成等长的 p 块, $\Phi^1, \Phi^2, \dots, \Phi^p$, 其中每一块都是 n 维的行向量, 那么 STP 定义为:

$$\Phi \triangleright \Psi = \sum_{i=1}^p \Phi^i \psi_i \in \mathbf{R}^n \quad (21)$$

式中: $\psi_i (i=1, 2, \dots, p)$ 是列向量 Ψ 中的一个元素; $\triangleright$ 是 STP 的符号。展开式(21), 得到:

$$\Phi \triangleright \Psi = \Phi^1 \psi_1 + \Phi^2 \psi_2 + \dots + \Phi^p \psi_p \quad (22)$$

式中: $\Phi^i \psi_i$ 是一个长度为 n 的行向量; $\Phi \triangleright \Psi$ 也是一个 n 维的行向量。因此,两个不等长向量的乘积得以实现。

定义 2: 设 $\Phi \in \mathbf{R}^{(M/t) \times (L/t)}$, $\Psi \in \mathbf{R}^{L \times N}$ 。如果 (L/t) 是 L 的一个因子, 那么:

$$\mathbf{O}' = \Phi \triangleright \Psi \quad (23)$$

其中, $\mathbf{O}'$ 是 Φ 和 Ψ 的 STP。

设 $a_{ij} \in \Phi$, $b_{ij} \in \Psi$, 然后展开式(23), 得到:

$$\mathbf{O}' = \begin{bmatrix} a_{11} & \cdots & a_{1(L/t)} \\ \vdots & & \vdots \\ a_{(M/t)1} & \cdots & a_{(M/t)(L/t)} \end{bmatrix} \triangleright \begin{bmatrix} b_{11} & \cdots & b_{1N} \\ \vdots & & \vdots \\ b_{L1} & \cdots & b_{LN} \end{bmatrix} = \begin{bmatrix} a_{11} & \cdots & a_{1(L/t)} \\ \vdots & & \vdots \\ a_{(M/t)1} & \cdots & a_{(M/t)(L/t)} \end{bmatrix} \triangleright \begin{bmatrix} B^{11} & \cdots & B^{1N} \\ \vdots & & \vdots \\ B^{(L/t)1} & \cdots & B^{(M/t)N} \end{bmatrix} \quad (24)$$

其中, $B^i (i=1, 2, \dots, (L/t), j=1, 2, \dots, N)$ 代表矩阵列中的第 i 个被分成 (L/t) 块, B^i 是一个长度为 t 的列向量。

因此,利用定义 1,式(24)有以下形式:

$$\mathbf{O}' = \begin{bmatrix} \sum_{i=1}^{(L/t)} a_{li} \mathbf{B}^{i1} & \cdots & \sum_{i=1}^{(L/t)} a_{li} \mathbf{B}^{iN} \\ \vdots & & \vdots \\ \sum_{i=1}^{(L/t)} a_{Mi} \mathbf{B}^{i1} & \cdots & \sum_{i=1}^{(L/t)} a_{Mi} \mathbf{B}^{iN} \end{bmatrix} \quad (25)$$

由此可知其特性,即当 $t=1$, $\Phi \triangleright \Psi = \Phi \Psi$ 时,STP 是传统的矩阵乘法,且满足乘法分配律和结合律。

2) STP-CS 模型应用

STP-CS^[29]方法使用低阶观测矩阵对用户位置进行稀疏恢复,既可以指数地减少观测矩阵的存储空间,又可以在保证定位精度的同时大大提高定位的实时性。该方法还能满足传统 CS 模型的要求,即 CS 理论的 RIP 和互不相干特性。该模型只改变观测矩阵的大小,但不改变矩阵的任何特性。

从式(3)中可以看出,当目标环境较大,存在多 AP 情况时,稀疏向量的维数会增加。由以往的经验可知,稀疏向量维数的增加会导致计算复杂度的增加。因此,本文基于 STP 改进的 CS 定位模型可以定义为:

$$\mathbf{y}_{M \times 1} = \Phi_{(M/t) \times (L/t)} \triangleright \Psi_{L \times N'} \triangleright \theta_{N' \times 1} + \omega \quad (26)$$

其中, $\mathbf{y}$ 代表在线测量的 RSS 测量值, $\Phi_{(M/t) \times (L/t)}$ 是低阶观测矩阵,即低阶 AP 选择矩阵, $\Psi_{L \times N'}$ 是粗定位缩小后的定位区域, $\theta_{N' \times 1}$ 是用户位置向量, N' 是粗定位后的 RP 数量, M 表示定位模型中在线测量的 AP 个数。

低阶观测矩阵的构造方法,主要通过对该聚类区域中的 AP 进行排序,用到的方法是最强 AP 选择。该方法把 AP 根据 RSS 平均值进行降序排序;最后根据排序顺序选择具有较高 RSS 平均值的 AP 集,从而构造最佳的 AP 选择矩阵。此外,AP 个数的选择跟 t 值有关,设定 t 值,即可得到一个 $(M/t) \times (L/t)$ 维度的观测矩阵。其中, (L/t) 表示 AP 子集,也是选择的得分最高的前 (L/t) 个 AP, (M/t) 表示 AP 子集中得分最高的前 (M/t) 个 AP。因此,在 STP-CS 模型中只需满足 $t|M$ 和 $t|L$ 的关系,观测矩阵所需的存储空间就减少到只有传统观测矩阵 $1/t^2$ 的存储空间。在保证重构用户位置准确性的同时,观测矩阵所需的存储空间成倍的减少,这使得 STP-CS 方法具有重要意义。

3) 稀疏恢复算法求解用户位置

在建立的 STP-CS 模型之上,通过式(26),使用 IRLS 算法对用户的位置进行稀疏重构,从而获得准确的位置估计。

重构后的数据 $\hat{\theta}$ 是 l_p 范数的最小值,且 $0 < p < 1$,并受限于:

$$\min \|\theta\|_p^p \text{ subject to } \Phi \triangleright \Psi \triangleright \theta = \mathbf{y} \quad (27)$$

该算法需进行迭代,下一次迭代计算方法如下:

$$\hat{\theta}^{(n)} = D_n \mathbf{O}'^T (\mathbf{O}' D_n \mathbf{O}'^T)^{-1} \mathbf{y} \quad (28)$$

其中, $D_n = 1/w_i$ 。 w_i 是第 i 次迭代权重,定义为:

$$w_i = ((\hat{\theta}_i^{(n-1)})^2 + v)^{\frac{p-2}{2}} \quad (29)$$

其中, $v > 0$ 。当满足设定的迭代终止条件时,算法

将完成迭代,得到重构的用户位置 $\hat{\theta} \in \mathbf{R}^{N' \times 1}$ 。但由于重构的用户位置向量不是理想情况下的稀疏向量,因此需要设置阈值,此时的 $\hat{\theta}$ 需要高于这个阈值 κ :

$$\mathfrak{R} = \{i | \hat{\theta}(i) > \kappa\} \quad (30)$$

在向量 θ 中取高于阈值的值的权重 η_i , 并得到用户的位置估计

$$(\hat{x}, \hat{y}) = \sum_{i \in \mathfrak{R}} \eta_i (x_i, y_i) = \sum_{i \in \mathfrak{R}} \frac{\hat{\theta}(i)}{\sum_{i \in \mathfrak{R}} \hat{\theta}(i)} (x_i, y_i) \quad (31)$$

4 实验结果分析

实验采用在本校三教 5 楼采集的数据。该实验环境共有 5 个区域,包括教室和走廊。在该实验环境中部署 20 个 AP,312 个 RP 和 115 个 TP,间距均为 1.2 m,具体实验环境设置如图 2 所示。离线阶段,通过实验室已有的设备采集每一个 RP 处接收到来自不同 AP 的 WLAN 信号的 RSS 值。对于 TP,则通过手机进行在线采集,采集的数据不需要全采样,只需在每个 TP 处采集 10 个 AP 的 RSS 值即可。采样间隔均为 1 s 一个样本,在每个 RP 和 TP 处均采集 150 个 RSS 数据。真实数据采集照片如图 3 所示。在实验中,参数的设置参照文献[30-31]。因此,设聚类算法中的模糊索引值 $m=2$, $\alpha=0.5$, $\varepsilon=10^{-5}$ 以及迭代次数为 100,同时,算法随机初始化 50 次以求得最优 $\bar{\omega}$ 。在精定位阶段,为使位置估计更为准确,需要设置不同的阈值,即阈值需满足的条件为 $\kappa \in [0.65\max(\theta), 0.85\max(\theta)]$ 。




图 2 实验环境设置

Fig. 2 Experimental environment setting

4.1 粗定位结果分析

由于聚类的性能直接影响定位的性能,所以本文对比了 AIFCOM、FCM 和 K-means3 种聚类算法下的定位性能。实验中先利用这 3 种聚类算法实现区域划分,然后根据粗定位缩小定位区域,再使用相同的 STP-CS 模型进



图 3 真实数据采集照片
Fig. 3 Real data capture photos

行精定位。由于离线阶段采集 RSS 信号时受到的干扰不同,得到的信号分布存在差异,这将导致聚类效果存在

差异。而本文提出的方法可以对异常值分配较低的权重,在信号分布较差的环境中,聚类中心受到的异常值的干扰较小,能保持稳定,由此得到的定位误差也不会偏差太大。

为了验证聚类算法的有效性,分析了不同定位区域的定位误差累积分布函数 (cumulative distribution function, CDF),如图 4 所示。实验结果表明,在不同区域中采用 AIFCOM 聚类算法进行粗定位的定位精度均高于采用 K-means 聚类方法进行定位的定位精度。在区域 1 中,AIFCOM 与 FCM 聚类算法的定位误差 CDF 有重合,这是由于区域 1 受环境干扰较小,环境中存在的异常值较少,因此得到的聚类中心能保持相对稳定,得到相似的定位误差 CDF。但在其余区域 AIFCOM 的定位误差均小于 FCM 的定位误差。




图 4 不同聚类方法的定位误差 CDF
Fig. 4 Localization error CDF of different clustering methods

为了验证聚类算法的稳定性,本文对数据采集时实验环境差距最大的 3 个区域,区域 1、3、5 进行比较。这 3 个区域根据实验得到最优的聚类数分别为 4、3、2, $t = 5$, 由此得到的平均定位误差如表 1 所示。FCM 聚类算法在不同环境中的定位误差相差较大,K-means 聚类算法得到的定位误差也较大,而 AIFCOM 聚类算法在 3 个区域的定位误差均较小且相对稳定。

表 1 不同聚类算法在不同区域的平均定位误差

Table 1 The average localization errors of different clustering algorithms in different regions (m)

聚类算法	区域 1	区域 3	区域 5
AIFCOM	2. 839 6	3. 088 1	2. 521 7
FCM	2. 839 6	4. 189 9	4. 431 1
K-means	2. 999 9	4. 214 4	3. 912 1

最后,通过箱线图分析 3 种聚类算法。如图 5 所示,FCM 和 K-means 算法最大的定位误差分别为 10. 217 6 m 和 11. 415 8 m,而本文提出的 AIFCOM 算法得到的最大定位误差为 6. 072 4 m。此外,AIFCOM、FCM 和 K-means 聚类算法得到的平均定位误差分别为 2. 836 2、3. 567 1 和 3. 672 5 m,中值误差分别为 2. 860 9、3. 059 6、3. 498 6 m。综上所述,本文提出的 AIFCOM 聚类方法优于传统的聚类方法。




图 5 不同聚类方法的定位误差

Fig. 5 Boxplots of localization errors using different clustering methods

4. 2 精定位结果分析

1) 与观测矩阵构造有关

在精定位研究方面,本文提出了 STP-CS 的定位方法。在该方法中观测矩阵的构造尤为重要,其 AP 的可靠性直接影响了定位的精度。在线定位阶段选择的 10 个 AP 中,每个 AP 对定位性能都具有不同的贡献度,若随机选择其中的几个 AP 来构建观测矩阵,则有多种组合方法。但随机选择的 AP 可能会导致定位精度的下

降。因此,对于最优 AP 集的选择采用前文提到的最强 AP 选择方法,根据 RSS 平均值进行降序排序,从中选择具有较高 RSS 平均值的 AP 构造最优 AP 集。此外,低阶观测矩阵的构建也与 t 值有关, t 值的大小决定了观测矩阵的大小。当 $t = 5$ 时,存在 $C_4^2 = 6$ 种不同的 AP 选择,不同 AP 选择情况下的定位误差 CDF 如图 6 所示。最优 AP 采用最强 AP 选择方法,其余的随机 AP 均采用随机的方式生成。当 AP 不是最优选择时定位误差较大,且定位精度远小于 STP-CS 定位方法。当选择最优的几个 AP 来构造观测矩阵时,定位精度得到明显提升。因此,由实验结果可知,只有找到 AP 贡献度最大的几个 AP 构造观测矩阵,才能得到较小的定位误差。




图 6 不同 AP 选择的定位误差 CDF

Fig. 6 Localization error CDF of different AP selection

2) 与 t 值有关

为了进一步对比分析精定位阶段的 STP-CS 与传统 CS 方法,在该实验中保持粗定位阶段的聚类方法不变,只改变精定位阶段使用的方法。离线阶段收集 20 个 AP 的 RSS 值,在线阶段收集 10 个 AP 的值,所以当具有相同 AP 数量时,传统 CS 方法与 STP-CS 方法观测矩阵的维数会存在差异。在 STP-CS 方法中观测矩阵的维数与 t 值有关, t 值的不同导致观测矩阵的维数也不相同。从 t 的取值可以发现, t 值越大观测矩阵维数越小,观测矩阵的维数就减少到只有传统 CS 方法中观测矩阵 $1/t^2$ 的大小,但定位误差却是相似的,具体如表 2 所示。其平均定位误差均在 2. 836 2 m 左右。 t 的取值分别为 2、5、10 时,观测矩阵大小分别为 5×10 、 2×4 和 1×2 ,观测矩阵的维数在大大降低。实验结果表明,采用低阶观测矩阵可以在保证定位精度的前提下,既成倍降低观测矩阵所需的存储空间,又大幅提升定位的效率。

3) STP-CS 与传统 CS 计算开销与存储空间对比

以 STP-CS 观测矩阵维度为参考,将 CS 观测矩阵的维数降低,根据 t 的 3 种取值,可得到关于 CS 方法的 3 种

表 2 不同维数观测矩阵和平均定位误差比较

Table 2 Comparison of measurement matrices with different dimensions and average localization errors

方法	观测矩阵维数	平均定位误差
CS	10×20	2.836 2
t=2 STP-CS	5×10	2.836 2
t=5 STP-CS	2×4	2.836 2
t=10 STP-CS	1×2	2.836 2

维度的观测矩阵 5×10、2×4 和 1×2,并在此基础上进行定位性能分析。在传统 CS 定位方法中,AP 的数量会影响观测矩阵的维数。当 CS 测量矩阵与 STP-CS 观测矩阵同维时,离线和在线阶段的 AP 数量发生变化,从而改变了粗定位阶段。当 $t=2$ 时,观测矩阵维数为 5×10,此时采用 CS 方法离线阶段所需 AP 数为 10,在线阶段所需 AP 数为 5。因此,从观测矩阵确定的 AP 中收集 RSS,并使用这些 RSS 值进行位置估计。这 3 种观测矩阵维数 5×10、2×4 和 1×2 下的 CS 定位方法分别用 CS1、CS2、CS3 表示。根据实验设置,分析不同定位方法在不同区域的平均定位误差,如图 7 所示。实验结果表明,当以 STP-CS 观测矩阵维度为参考时,随着 t 值的增加,CS 的定位性能逐渐降低,但 STP-CS 的定位性能并没有受到太大影响。因此,STP-CS 方法保留了环境中 t 倍的 AP 数量,只需较少的 AP 就可以得到精确的位置估计,更适合大环境下的定位。




图 7 不同区域平均定位误差比较

Fig. 7 Comparison of average localization errors in different regions

5 结 论

本文提出了一个大目标环境下的 STP-CS 室内定位系统。针对大目标环境下的定位,首先利用 AIFCOM 聚

类算法,处理含有异常值的指纹数据库。其次,通过得到的聚类结果进行聚类匹配的粗定位,缩小定位的区域。最后,利用 STP-CS 方法构造低阶观测矩阵,进行精定位。实验结果表明,该方法具有较好的处理异常值的能力,并优化了观测矩阵,同时减少了存储空间有效缩小了占用内存,大大节约了运行时间,使所提算法能够实现实时定位。提高了定位精度和效率。

参考文献

[1] YADAV V K, ANDOLA N, VERMA S, et al. P2LBS: Privacy provisioning in location-based services[J]. IEEE Transactions on Services Computing, 2021, 16(1):466-477.

[2] HE M F, LIU J CH, GU P F, et al. Leveraging map retrieval and alignment for robust UAV visual geolocalization[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 1-13.

[3] 谢良波, 夏晨晖, 张钰坤, 等. 基于双频点载波相位的 RFID 室内定位算法[J]. 仪器仪表学报, 2023, 44(5): 267-277.

XIE L B, XIA CH H, ZHANG Y K. RFID indoor localization algorithm based on dual-frequency carrier phase[J]. Chinese Journal of Scientific Instrument, 2023, 44(5): 267-277.

[4] 周伯宇, 孙洁, 史元良. 基于 IKF 与 FA-PF 的井下超宽带定位算法[J]. 国外电子测量技术, 2022, 41(8): 39-45.

ZHOU B Y, SUN J, SHI Y L. Underground ultra-wideband localization algorithm based on IKF and FA-PF[J]. Foreign Electronic Measurement Technology, 2022, 41(8): 39-45.

[5] 廖亚桢, 刘昱, 张立强, 等. 面向 PDR 定位系统的多层感知机 IMU 阵列数据融合方法[J]. 电子测量与仪器学报, 2022, 36(8): 35-42.

LIAO Y ZH, LIU Y, ZHANG L Q, et al. Multi-layer sensor IMU array data fusion method for PDR positioning system[J]. Journal of Electronic Measurement and Instrumentation 2022, 36(8): 35-42.

[6] 刘伟, 王智豪, 李卓, 等. 基于 cGAN-SAE 的室内定位指纹生成方法[J]. 电子测量技术, 2024, 47(14): 57-63.

LIU W, WANG ZH H, LI ZH, et al. Indoor positioning fingerprint generation method based on cGAN-SAE[J]. Electronic Measurement Technology, 2024, 47(14): 57-63.

- [7] 蒲巧林, 陈有坤, 周牧, 等. 基于改进对比学习和并行融合神经网络的室内 WiFi 定位算法[J]. 仪器仪表学报, 2024, 45(1): 101-110.
- PU Q L, CHEN Y K, ZHOU M, et al. Indoor WiFi localization algorithm based on the improved contrastive learning and parallel fusion neural network[J]. Chinese Journal of Scientific Instrument, 2024, 45(1): 101-110.
- [8] ZHOU CH Y, LIU J Y, SHENG M, et al. Exploiting fingerprint correlation for fingerprint-based indoor localization: A deep learning based approach[J]. IEEE Transactions on Vehicular Technology, 2021, 70(6): 5762-5774.
- [9] GONG X D, LIU J B, YANG SH, et al. A usability-enhanced smartphone indoor positioning solution using compressive sensing[J]. IEEE Sensors Journal, 2022, 22(3): 2823-2834.
- [10] ZHANG H, WANG ZH K, NI Y Y, et al. Improved KNN algorithm with historical information fusion for indoor positioning [C]. 2021 IEEE 4th International Conference on Electronics and Communication Engineering (ICECE), 2021: 184-188.
- [11] LI H X, YU D, HU Y, et al. Compressed sensing based two-phase multiple target localization algorithm for wireless sensor network [C]. 2020 12th International Conference on Communication Software and Networks (ICCSN), 2020: 144-148.
- [12] JIANG X H, LI N, GUO Y, et al. Sensing matrix optimization for multi-target localization using compressed sensing in wireless sensor network[J]. China Communications, 2022, 19(3): 230-244.
- [13] LEE S G, LEE C. Developing an Improved fingerprint positioning radio map using the k-means clustering algorithm[C]. 2020 International Conference on Information Networking (ICOIN), 2020: 761-765.
- [14] LI ANG, FU J Q, SHEN H M, et al. A cluster-principal-component-analysis-based indoor positioning algorithm[J]. IEEE Internet of Things Journal, 2020, 8(1): 187-196.
- [15] WANG C, PEDRYCZ W, LI ZH W, et al. Residual-driven fuzzy C-means clustering for image segmentation[J]. IEEE/CAA Journal of Automatica Sinica, 2021, 8(4): 876-889.
- [16] WANG C, PEDRYCZ W, LI ZH W, et al. G-image segmentation: Similarity-preserving fuzzy C-means with spatial information constraint in wavelet space[J]. IEEE Transactions on Fuzzy Systems, 2021, 29(12): 3887-3898.
- [17] YANG G, YE X Q. Robust sparse overlapping group lasso for indoor localization[C]. 2018 Ubiquitous Positioning, Indoor Navigation and Location-Based Services (UPINLBS), 2018: 1-5.
- [18] FENG CH, AU WS A, VALAEE S, et al. Received-signal-strength-based indoor positioning using compressive sensing[J]. IEEE Transactions on Mobile Computing, 2011, 11(12): 1983-1993.
- [19] YAN K, WU H C, XIAO H L, et al. Novel measurement matrix optimization for source localization based on compressive sensing[C]. 2014 IEEE Global Communications Conference, 2014: 341-345.
- [20] KHALAJMEHRABADI A, GATSIS N, PACK J, et al. A joint indoor WLAN localization and outlier detection scheme using LASSO and elastic-net optimization techniques[J]. IEEE Transactions on Mobile Computing, 2017, 16(8): 2079-2092.
- [21] KHAN M S, KIM J, LEE E H, et al. A received signal strength based localization approach for multiple target nodes via Bayesian compressive sensing[C]. 2019 22nd International Multitopic Conference (INMIC), 2019: 1-6.
- [22] ZHAO M, QIN D Y, GUO R L, et al. Research on crowdsourcing network indoor localization based on co-forest and bayesian compressed sensing [J]. Ad Hoc Networks, 2020, 105: 102176.
- [23] LI ZH, LUO L G, LIU Y D, et al. UHF partial discharge localization algorithm based on compressed sensing [J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2018, 25(1): 21-29.
- [24] 陈鹏, 花向红, 张伟. 基于信号丢失率的 AP 选取算法分析[J]. 测绘地理信息, 2021, 46(4): 36-39.
- CHEN P, HUA X H, ZHANG W. Analysis of AP selection algorithm based on signal loss rate[J]. Journal of Geomatics, 2021, 46(4): 36-39.
- [25] 吴伟, 花向红, 吴帮, 等. 基于 WiFi 信号的整体区间重叠度的 AP 选取算法[J]. 测绘地理信息, 2021, 46(2): 67-70, 122.

- WU W, HUA X H, WU B, et al. AP selection algorithm based on overall interval overlap of WiFi signal [J]. *Journal of Geomatics*, 2021, 46(2):67-70,122.
- [26] WANG ZH, LIU F L, YIN Y W, et al. Weighted l1-norm for one-bit compressed sensing based on approximated observation[C]. 2020 IEEE MTT-S International Wireless Symposium (IWS), 2020: 1-3.
- [27] YAGER R. On ordered weighted averaging aggregation operators in multicriteria decision making [J]. *IEEE Transactions on Systems, Man, and Cybernetics*, 1988, 18(1): 183-190.
- [28] YAN Y Y, YUE J M, CHEN Z Q, et al. Algebraic expression and construction of control sets of graphs using semi-tensor product of matrices [J]. *IEEE Access*, 2019, 7: 113440-113451.
- [29] XU B, XIE ZH L, ZHANG ZH, et al. Joint compression and encryption of distributed sources based on wavelet transform and semi-tensor product compressed sensing[J]. *IEEE Sensors Journal*, 2022, 22(16): 16451-16463.
- [30] PAL N R, BEZDEK J C. On cluster validity for the fuzzy c-means model[J]. *IEEE Transactions on Fuzzy Systems*, 1995, 3(3): 370-379.
- [31] KAUSHAL M, LOHANI Q M D. Generalized intuitionistic fuzzy c-means clustering algorithm using an adaptive intuitionistic fuzzification technique[J]. *Granular Computing*, 2022, 7(1): 183-195.

作者简介



蒲巧林(通信作者), 分别在 2011 和 2016 年于重庆邮电大学获得学士学位和硕士学位, 2022 年于香港浸会大学获得博士学位, 现为重庆邮电大学副教授, 主要研究方向为无线定位与感知、普适计算与机器学习等。

E-mail: puql@cqupt.edu.cn

Pu Qiaolin (Corresponding author) received her B. Sc. degree and M. Sc. degree from Chongqing University of Posts and Telecommunications in 2011 and 2016, and her Ph. D. degree from Hong Kong Baptist University in 2022, respectively. She is currently an associate professor at Chongqing University of Posts and Telecommunications. Her research interests include indoor localization, signal processing, and ubiquitous pervasive computing.