

DOI: 10.13382/j.jemi.B2307039

信号指纹测量下双度量协同的室内定位方法*

汪杰 宋书林 秦宁宁

(江南大学物联网技术应用教育部工程研究中心 无锡 214122)

摘要:针对室内 WiFi 定位中指纹信息冗余、空间边界划分困难和 RP 集获取精准度缺失的问题,提出一种信号指纹测量下双度量协同的室内定位方法。通过 S 度量和欧氏度量下指纹矩阵融合,精简形成低维指纹信息,考量指纹间“点-类”关联度和“类-类”相似度,兼顾子区域边界新增指纹数目的可控性,确立子区域边界模糊深度调整机制,形成边界模糊泛化能力,以区域稀疏度判定插值方法完成指纹库扩充,以构建高密度离线指纹库。在优选子区域中,结合信号空间和位置空间,对比两类度量的差异度,实现对高价值指纹点的定向筛选,削弱在线指纹匹配集合的误差影响。在全局实验场景中,分区结果规整有序,较为符合实际空间构造。指纹库构建效果较其他方案至少提升 11%,定位精度相对同类型算法提升了 12% 以上,论文所提方案定位精度优势显著,在具备高扰动特点下的复杂室内环境中,具有较好的场景适应性。

关键词:室内定位;指纹定位;双度量协同;模糊聚类;指纹点优选

中图分类号: TN92; TN96

文献标识码: A

国家标准学科分类代码: 510.40

Indoor localization method based on dual-metric coordination of signal fingerprint measurement

Wang Jie Song Shulin Qin Ningning

(Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China)

Abstract: To address the problems of fingerprint information redundancy, difficulty in spatial boundary division, and lack of accuracy in acquiring RP sets in indoor WiFi localization, we propose an indoor localization method based on dual-metric coordination of signal fingerprint measurement. The low-dimensional fingerprint information is simplified and formed through the fusion of fingerprint matrix under S-metric and European-metric. The correlation degree between fingerprints is considered through the “point-class” correlation degree and “class-class” similarity, taking into account the controllability of the number of new fingerprints on the subregion boundary, and the adjustment mechanism of the fuzzy depth of the subregion boundary is established to form the boundary ambiguity generalization ability. Expansion of the fingerprint database is accomplished by the interpolation method of regional sparsity determination, so as to construct a high-density offline fingerprint database. In the preferred subregion, combining the signal space and the location space, the difference degree of the two kinds of measurements is compared to realize the targeted screening of high-value fingerprint points, and reduce the error influence of online fingerprint matching set. In the global experimental scene, the partition results are regular and orderly, which accords with the actual space structure. The construction effect of fingerprint database is improved by at least 11% compared with other schemes, and the positioning accuracy is improved by more than 12% compared with the same type of algorithm. The proposed scheme has significant positioning accuracy advantages, and has better scene adaptability in complex indoor environments with high disturbance characteristics.

Keywords: indoor localization; fingerprint localization; dual-metric coordination; fuzzy clustering; RP optimization

0 引言

在“万物互联”的智能化时代,物联网技术和导航定位技术等的发展和运用,使得人们在“衣食住行”方面享受极大便利。然而在复杂室内场景中,受限于大区域、多遮蔽、多信源的交叉影响,简单复用已有的卫星导航系统,无法达到室外同等精度定位效果。利用室内 WiFi 信源接入点(access point, AP)部署广泛且易获取的便利,基于不同信源在同一位置空间下接收来自 AP 的信号强度(received signal strength, RSS)具有的相异性,以特定位置下 RSS 的特征信息作为指纹信息,使得以 RSS 信息为基准的指纹定位技术,成为室内场景中,不依赖特殊设备下的常用定位方法之一^[1]。该技术通过将待定位点,又称目标点(target point, TP)与目标区域参考点(reference point, RP)的指纹信息进行匹配,估算出目标 TP 的空间位置^[2]。因此,根据各 RP 接收的指纹信息及其物理位置,预先构建离线指纹库^[3-4],是指纹定位技术的应用基础与保障。

各运营商为满足通信稳定的需求,通常在室内区域铺设大量 AP 或网络热点,使得在室内定位检测时,可测 AP 数目远超所需,且其可靠性水平不一。若直接采集关于 RSS 的指纹信息离线建库,造成指纹信息维度过高的同时,使得高维指纹信息间存在大量数据特征冗余,导致在线匹配负担沉重、定位精度提升困难。因此,突出数据主要特征与减少计算负担不失为一种高效方法。基于此, Khoo 等^[5]采用主成分分析法(principle component analysis, PCA)或截断奇异值分解(truncated singular value decomposition, TSVD)从高维指纹信息中提取关键特征,并对其进行重构,但忽略了信号与空间距离之间的非线性关系^[6]。此外,利用高质量 AP 筛选也可去除数据冗余的优势, Yang 等^[7]以 AP 信息增益比衡量指纹信息特征模糊权重,从而获取高位置分辨率 AP 集合,然而在多复杂、高扰动场景中,这种 AP 的优化效果不够明显。为降低匹配负担,可以对大规模指纹库进行聚类划分。Bi 等^[8]基于仿射传播聚类(affinity propagation cluster, APC)算法对指纹库进行簇类化精简,虽将位置空间纳入聚类相似度考量中,但在邻接子区域边界指纹点处,由于过度依赖固定距离半径形成过渡区域,使得普适性较低。Sharma 等^[9]引入一种自适应融合距离概念,利用融合距离改进 K-means 聚类算法,但该方法对小数据样本的聚类效果差强人意。

除受离线指纹库质量因素影响外,在线优质 RP 集合的筛选对实现高精度定位同等重要。通常的在线匹配定位,为简化考虑,会采用单纯的线性欧氏度量将 TP 指纹信息与指纹库匹配,以寻找高相似度 RP 集合。文

献[10]综合考虑信号空间和位置空间下双重距离,提出基于 DBSCAN 算法和多度量融合方法获取可靠 RP 集合,但由于算法复杂度较高,实时定位效果较差。文献[11]在目标空间分区的基础上,以相邻时刻位置空间下约束关系筛选候选指纹点,但对前一时刻的位置精度要求较高,容易因误差累积造成较大的定位偏差。

为降低冗余指纹信息、区域划分效果和 RP 筛选对位置估计的影响,论文提出了 DMCF 算法。在信号空间下,以压缩指纹信息间冗余信息的双度量矩阵形式,描述 RP 之间的信号关系,提取关键指纹特征。进一步综合位置空间特征、低维指纹信息相似度矩阵的非对称特性,建立场景模糊区域,降低低敏感 TP 错误分区的概率。以双度量结合指纹信息距离与位置空间距离,重新定义 RP 权重衡量标准,实现对指纹信息和位置特征属性表现度高的最优 RP 集合的选取,实现基于信号与位置要素下,从自适应 RP 选取标准和权重配置方式,对定位精度进行连贯化优化。

1 系统模型

假设在待定位区域内,部署 M 个无线接入点 $AP_1, AP_2, \dots, AP_m, \dots, AP_M$ 和 N 个参考点 $RP_1, RP_2, \dots, RP_n, \dots, RP_N$ 。其中,参考点由 N_1 个已采样参考点(sample reference point, SRP) $SRP_1, SRP_2, \dots, SRP_{N_1}$ 和 N_2 个待插值参考点(interpolated reference point, IRP) $IRP_1, IRP_2, \dots, IRP_{N_2}$ 共同构成($N = N_1 + N_2$)。论文所需系统参数描述如下:

1) 在位于 (x_n, y_n) 的指纹参考点 RP_n 处, $\mathbf{R}_n = [r_{n1}, r_{n2}, \dots, r_{nm}, \dots, r_{nM}]$ 表示接收到来自 M 个 AP 的 RSS 向量。 $\mathbf{r}_{nm} = [r_{nm}^1, r_{nm}^2, \dots, r_{nm}^q, \dots, r_{nm}^Q]$ 表示 RP_n 处接收到来自 AP_m 的 Q 次 RSS 向量。

2) $\Omega = \{\Omega_1^{n1}, \Omega_2^{n2}, \dots, \Omega_p^{np}\}$ 为目标场景被划分为 P 个子区域,子区域 $\Omega_p^{np} = \{SRP_{1(p)}, SRP_{2(p)}, \dots, SRP_{np(p)}\}$ ($p = 1, 2, \dots, P$, 简记为 Ω_p) 中共有 np 个已采样指纹点。子区域各聚类中心表示为 $c = \{c_1, c_2, \dots, c_p\}$ 。

3) 位于 (x', y') 的待定位点 TP 处,接收到来自 M 个 AP 的 RSS 向量 $\mathbf{R}' = [r'_1, r'_2, \dots, r'_M]$ 。

2 样本异常值标识更正

在复杂多变的室内环境中,信号传播极易受到行人走动、建筑物遮蔽、多径效应等交叉干扰。在给定单位时间 T 内,同一设备在特定位置采集到的充分数量 RSS 样本值,其频数分布近似符合正态分布^[12]。但也会存在个

别样本离群情况,使得样本值整体波动较大。

常用的 3σ 准则以固定概率值为界限,“切除”区间外概率较小的样本值,以保留高概率样本值。该方法虽简单快速,但固定概率值的选取,显然不能灵活判断其周边样本值的重要程度,使得小概率样本值的剔除效果不够理想。不同于简单考虑样本概率分布的 3σ 准则,格拉布斯准则可以以较低的样本容量,在综合样本的个体差异和聚集程度的基础上,发现处于临界值之外的异常样本值^[13]。

在格拉布斯准则中,对于给定位置 RP_n 处接收到来自 AP_m 的 Q 次样本值,以样本标准差为单位,观察单次样本值与样本均值 r_{nm} 间的相对标准距离,并与准则中临界值 $G_0(Q, \alpha)$ 进行比较。对超出临界值的样本值 r_{nm}^q ,以所处向量中最小 RSS 值进行赋值,即 $r_{nm}^q = \min(r_{nm})$,以此降低环境和设备的影响。其中,临界值 $G_0(Q, \alpha)$ 可根据测量次数 Q 和经验性显著性水平 α 得出。

3 离线指纹库构建

3.1 双度量协同降维

为提高离线阶段数据处理的效率和准确性,采用多维缩放(multiple dimensional scaling, MDS),对原始高维信号空间下距离矩阵进行重构,从中提取关键特征,将原始高维属性空间精简为低维子空间,从而将指纹库中存在的 M 维特征减少至 $L(L \ll M)$ 维。

精简高维属性前,需依据指纹信息构建信号空间下的距离矩阵。经典的欧氏度量,以指纹点 RP_i 和 RP_j 之间的指纹信息差异度,衡量彼此的相似性。虽能较快构建矩阵,但指纹信息与空间距离不是简单的线性关系,以类似计算位置之间物理距离的方式得出指纹信息差异,难以保证矩阵构建的精确程度。不同于常用的欧氏度量, S 度量来源于厄米正定矩阵锥上的类距离函数——S 散度,可表达出任意两个指纹点间的非线性距离下的函数关系^[14-15]。给定已采样指纹点 SRP_i 和 SRP_j 的 S 度量表达式,如式(1)所示:

$$d_{sig}^S(R_i, R_j) = \sqrt{\sum_{m=1}^M \left(\log \left| \frac{1}{2}(r_{im} + r_{jm}) \right| - \frac{1}{2}(\log |r_{im}| + \log |r_{jm}|) \right)^2} \quad (1)$$

由式(1)可知, S 度量采用对数运算方式,将两指纹点之间的信息差异作平滑处理,以约束物理位置对指纹信息相关性的影响。

配置合适的距离函数是构建距离矩阵提取数据特征的关键环节^[16]。基于欧氏度量和 S 度量,分别建立 $N \times M$ 维的指纹点的距离矩阵 D_E 和 D_S ,融合得到兼顾指纹

信息突出和物理位置约束双重尺度的融合矩阵:

$$D_{fusion} = \lambda_E D_E + \lambda_S D_S \quad (2)$$

其中,权重 λ_E 与 λ_S 调节矩阵相对比重,以具有方案稳定性和评估可靠性的评估函数 GL 2 确定 λ_E 与 λ_S ,且 $\lambda_E + \lambda_S = 1$ 。将融合矩阵 D_{fusion} 作为 MDS 算法的输入,在 M 维高维特征中保留 L 维关键特征,得到重构且精简后的低维指纹信息矩阵 $\widehat{D}_{N \times L}$ 。以 \widehat{D} 中指纹点 SRP_i 的低维指纹信息 \widehat{D}_i 及其物理位置形成临时指纹库,用于后续模糊聚类研究。

3.2 指纹模糊聚类

1) 区域初划分

在大面积、多复杂的定位场景下,将空间划分为若干紧凑子空间后,以子空间 Ω_p 为候选空间,显然可以缩小最优 RP 集合的搜寻范围,降低定位开销。因此,利用 APC 聚类^[17]具有的将所有指纹点平等视为潜在聚类中心认同,结合场景的实际地理构造,对全场景中指纹点 SRP_i 和 SRP_j 的相似度定义如式(3),作为区域小空间划分的依据。

$$s(i, j) = -Nor(d_{pos}(i, j)) \sqrt{\sum_{l=1}^L (\widehat{D}_i^l - \widehat{D}_j^l)^2} \quad (3)$$

其中, $d_{pos}(i, j)$ 为 SRP_i 和 SRP_j 的位置空间欧氏距离, Nor 为最大最小值归一化方法表达式。

2) 模糊边界构建

在完成区域初划分后, P 个子区域的边界棱角分明。当 TP 位于子区域邻接处,由于邻接处的指纹点间指纹信息差异度较小,在线匹配只能简单将其判定为某单一子区域或除邻接子区域外的第 3 个子区域内,而忽略对相邻子区域中的 RP 集合的信息价值,且这种归属错误难以在后续匹配过程中得到有力纠正。

因此,在原来“唯一”划分的基础上,提出一种基于低维指纹信息的模糊边界方法,以“点-类”关联度和“类-类”相似度衡量指纹点与子区域、子区域间的相关程度,并通过空间最优模糊参数 γ_1 配置,进而主动将边界指纹点进行模糊处理,以降低边界指纹点异常归属的风险。

(1) 点-类关联度 $Rel_{i(p1), (p2)}$

定义 $Rel_{i(p1), (p2)}$ 为子区域 Ω_{p1} 中的第 i 个指纹点 $SRP_{i(p1)}$ 与子区域 Ω_{p2} 的聚类中心 $c_{(p2)}$ 低维指纹信息距离,以表征 $SRP_{i(p1)}$ 与邻接子区域 Ω_{p2} 间的关联度。

$$Rel_{i(p1), (p2)} = \sqrt{\sum_{l=1}^L (\widehat{D}_{i(p1)}^l - c_{(p2)}^l)^2} \quad (4)$$

其中, $p1, p2 \in \{1, 2, \dots, P\}$, $p1 \neq p2$, $\widehat{D}_{i(p1)}^l, c_{(p2)}^l$ 分别表示指纹点 $SRP_{i(p1)}$ 和聚类中心 $c_{(p2)}$ 的第 l 维低维指纹信息。 $Rel_{i(p1), (p2)}$ 越小,指纹点 $SRP_{i(p1)}$ 与周围邻接子区域间指纹信息重合度越高, $SRP_{i(p1)}$ 错误划分入 Ω_{p2} 的风险越高。

(2) 类-类相似度 $Sim_{(\rho_1),(\rho_2)}$

以邻接子区域间聚类中心 c_p 低维指纹信息密切程度衡量类间相似度,将 $Sim_{(\rho_1),(\rho_2)}$ 表示为第 p_1 与第 p_2 子区域的聚类中心距离,即:

$$Sim_{(\rho_1),(\rho_2)} = \sqrt{\sum_{l=1}^L (c_{(\rho_1)}^l - c_{(\rho_2)}^l)^2} \quad (5)$$

其中, $Sim_{(\rho_1),(\rho_2)}$ 越小,表明 Ω_{p_1} 与 Ω_{p_2} 的区域相似度越高,边界指纹点越容易受另一侧子区域诱导而误入其中。

综合“点-类”和“类-类”双重密切度,描述子区域边界模糊区间,从而协调边界点对域外区域的归属。综上,可对指纹点 SRP_i 建立如式(6)所示边界指纹点归属模型:

$$SRP_{i(p_1)} \in \begin{cases} \Omega_{p_1} \cup \Omega_{p_2}, & \frac{Rel_{i(p_1),(\rho_2)}}{Sim_{(\rho_1),(\rho_2)}} \leq \gamma_1 \\ \Omega_{p_1}, & \frac{Rel_{i(p_1),(\rho_2)}}{Sim_{(\rho_1),(\rho_2)}} > \gamma_1 \end{cases} \quad (6)$$

其中,以模糊参数 γ_1 调节边界模糊的深度。 γ_1 越小,模糊区域仅存在于“零星”边界点处,区域模糊效应不明显; γ_1 越大,则模糊界限的可分离度交叉,也会降低算法本身形成的各子区域的辨识能力,增加定位开销的同时,降低后续位置估计精度。因此,在离线阶段应适配 γ_1 取值处于合理区间内,实现在线位置估计的时效性和精度。

模糊边界构建完成后,以子区域 Ω_p 中 np 个已采样指纹点的指纹信息,即 RSS 向量,同其物理位置共同构成第 p 个子指纹库。

3.3 指纹库扩充

1) 区域稀疏度

经模糊聚类后,在独立的子区域 Ω_p^{np} 内,所包含的 np 个指纹点在信号空间的离散程度和强度稳度不尽相同。指纹点的离散程度较大,表明该点附近的指纹信息波动较明显。以指纹点 $SRP_{i(p)}$ 处来自所有 AP 的指纹信息均值与标准差比值,反映该指纹点的离散程度^[18]。由于熵值可以衡量指纹信息的不确定性,以评估指纹点处指纹信息的稳定性,因此,在 Ω_p^{np} 中,以所有指纹点 $SRP_{i(p)}$ 接收到 M 个 AP 的 RSS 向量的均值、标准差和熵值,定义子区域 Ω_p^{np} 的区域稀疏度 rs_p :

$$rs_p = \frac{1}{np} \sum_{i=1}^{np} \left(S_i / \bar{r}_i \times \sum_{m=1}^M (-P(r_{im}) \log_2(P(r_{im}))) \right) \quad (7)$$

利用区域稀疏度 rs_p 标识 Ω_p^{np} 中所有指纹点的指纹信息离散程度和稳定性, rs_p 越小表明 Ω_p^{np} 中指纹信息分布越平滑。

2) 插值平稳性优化

根据插值方法可拟合待插值指纹点 IRP 的指纹信

息,在各子区域中,适当扩充少量指纹点可为 TP 提供更多指纹点选择。需要注意的是,所用插值方法的拟合精度至关重要。克里金插值算法^[19]的插值结果虽具有较高的平滑性,但在不同场景下,由于该算法对于变异函数的拟合忽略了不同 AP 信号传播的差异性,因此在其高斯变异函数 $\varphi(h)$ 式(8)中,引入类惩罚因子函数 $\lambda(h)$,如式(9)所示,对 $\varphi(h)$ 进行修正。

$$\varphi(h) = e^{-\left(\lambda(h) + \frac{h^2}{2\theta^2}\right)} \quad (8)$$

$$\lambda(h) = \frac{\eta}{h^t + \eta} \quad (9)$$

其中, θ 为高斯变异函数的空间范围参数,影响插值的平滑程度。可调参数 η 反映插值结果的整体均值, t 可调节高斯变异函数钟形曲线的陡峭程度,以合理分配距离插值点远近不同的指纹点的权重。通过上述参数的合理搭配取值,在保留高斯函数 $\varphi(h)$ 平滑性质的基础上,可提升插值结果的平稳性。

3) IRP 指纹预测

在指纹库扩充的过程中,若忽略各子区域的实际稀疏度 rs_p ,采取“单一”插值方法,导致插值点指纹信息不够精确。为此,引入区域稀疏阈值 γ_2 ,作为子区域扩充所需插值方法选择标准。

在子区域 Ω_p 中,当 $rs_p > \gamma_2$,表明该子区域中指纹点的离散程度较高且稳定性不好,因此采用插值精度较高的改进克里金插值算法。反之,选用对区域指纹信息稳定性要求不高的双线性插值方法。在完成对所有子区域的扩充后,将 IRP 的指纹信息与其物理位置结合,填充至对应子指纹库中。至此,完成离线指纹库的构建。

4 高适应度在线定位

4.1 子区域优选

指纹信息高维属性精简后,以关键特征构成的低维指纹信息为基础的模糊聚类,极大降低了子区域归属门槛,且在少量指定位置扩充指纹库,为 TP 提供更多的候选指纹点选择。在指纹点聚类和分类特征相统一的基础上,在线优选子区域时,为兼顾区域判别时效性与精度,仅需将 TP 与所有聚类中心指纹信息相匹配,选择差异最小的子区域 Ω_p^{np} 作为 TP 的最优候选空间,用于后续位置计算。

4.2 基于差异度的 TP 位置计算

1) 双空间下双度量差异度集合获取

传统定位算法以欧氏度量,将 TP 指纹信息与指纹库匹配,选取低指纹差距 RP 集合。但在信号波动与环境扰动因素加持下,仅采用单一度量标准,指纹信息差异小但位置距离远的离群点的混入难以避免。尤其在确定的

RP 集数目时,由于不能自适应调整 RP 准入,单个离群点将引起较大定位扰动。基于此,为突出物理位置距离作用,以 S 度量为例,将待定位点 TP 和指纹点 RP_i 的指纹信息与位置空间信息结合,计算 TP 和 RP_i 间差异度:

$$d^{Si}(TP, i) = \xi \text{Nor}(d_{sig}^S(TP, i)) + (1 - \xi) \text{Nor}(d_{pos}^S(TP, i)) \quad (10)$$

其中, ξ 为表征指纹信息相对权重的距离因子。

在候选空间 Ω_p^m 中,对信号空间与位置空间下的 TP 与 RP_i 的 S 度量进行加权取和,以获得关于 RP_i 的 n_p 个差异度序列,取差异最小的前 K 个 RP,获得包含差异度 d^{Si} 与物理坐标的集合 Φ_S 。同理可得欧氏度量下的差异度 d^{Ei} 和集合 Φ_E 。

2) 最优 RP 集筛选

在 Φ_E 和 Φ_S 中,必然存在 k 个坐标相同的 RP ($k = |\Phi_E \cap \Phi_S|$, 且 $k \leq K$, $|\cdot|$ 表示个数的选取)。若 k 值较小,此时的小容量 RP 集不足以支撑位置计算的准确度。为此,为平衡 k 值可靠性与集合扩充代价,引入可信阈值 γ_3 ,在候选空间中适当拓宽最优 RP 集范围,以寻求高质量 RP 集带来位置精准度的提升。

(1) $\frac{k}{K} \leq \gamma_3$,表明集合 Φ_E 和 Φ_S 中相同指纹点较少,欧氏度量与 S 度量标准搜索到的两集合差异过大,仅采用其中一组指纹点集合而忽略另一组集合价值,显然不能精确估算 TP 位置。因此,将 Φ_E 和 Φ_S 中的所有指纹点均作为最优 RP 集成员, $K = |\Phi_E \cup \Phi_S|$ 。并根据各 RP 与集合质心之间位置空间距离关系,由式(11)、(12)调整欧氏度量和 S 度量在位置计算中所占权重。

$$\beta_E = \frac{\nu_E}{\nu_E + \nu_S}, \beta_S = \frac{\nu_S}{\nu_E + \nu_S} \quad (11)$$

$$\begin{cases} \nu_E = \sqrt{\sum_{k=1}^K ((x_k - \bar{x}_E)^2 + (y_k - \bar{y}_E)^2)} \\ \nu_S = \sqrt{\sum_{k=1}^K ((x_k - \bar{x}_S)^2 + (y_k - \bar{y}_S)^2)} \end{cases} \quad (12)$$

其中, (\bar{x}_E, \bar{y}_E) 和 (\bar{x}_S, \bar{y}_S) 分别为集合 Φ_E 和 Φ_S 中 K 个 RP 的质心坐标。

(2) $\frac{k}{K} > \gamma_3$,表明欧氏度量和 S 度量下估算的位置,均具有较高的可信度,且以 $K = k$ 个指纹点构成的最优 RP 集,即统筹集合的数量支撑与质量保证,以双重要求确定 TP。对于欧氏度量与 S 度量的位置权重进行等价配置 $\beta_E = \beta_S = 0.5$ 。

3) 位置计算

以最优 RP 集中 K 个高可靠指纹点,平衡信号空间和位置空间的影响,估计待定位点 TP 空间位置 (x', y') :

$$(x', y') = \frac{\sum_{k=1}^K \omega_k (x_k, y_k)}{\sum_{k=1}^K \omega_k} \quad (13)$$

其中, ω_k 为第 k 个指纹点权重,公式如下:

$$\omega_k = (\beta_E d^{Ek} + \beta_S d^{Sk})^{-1} \quad (14)$$

5 实验场景与结果分析

5.1 测试场景与数据分析

为了验证 DMCF 定位算法的性能,在某大学物联网工程学院某楼层中,选取人员走动随机、拐角处存在木门或玻璃门遮挡特点的环形室内走廊作为实验场景,场景大小为 60 m×42 m。在走廊中以相邻参考点间隔 1 m 的网格化形式,均匀部署 $N_1 = 368$ 个 SRP 和 $N_2 = 185$ 个 IRP;在整体实验场景中,先后收集到 $M = 98$ 个 AP 的信号,为统一 RSS 向量维度,未接收到信号强度值以 -100 dBm 补齐。在各个参考点处以 2.3 s 采样间隔,采集 $Q = 50$ 次指纹数据。在走廊中间位置以 1 m 间隔采集 184 个位置处信号作为在线测试点数据。

为避免设备异质性对实验性能的影响,在线和离线阶段均使用同一设备采集数据。所有数据均基于 MATLAB 2021a 进行处理。论文参考选取显著性水平 $\alpha = 0.05$,则格拉布斯准则中临界值 $G_0(50, 0.05) = 2.956$,空间范围参数 $\theta = 5$,可调参数 η 和 t ,分别取 $\eta = 0.5$, $t = 2$,距离因子 $\xi = 0.7$ 。低维度个数 $L = 5$,区域稀疏阈值 $\gamma_2 = -0.016$ 。

5.2 实验参数配置

为弱化环境对分区效果束缚,在所提边界指纹点归属模型中引入模糊参数 γ_1 用以构建区域模糊边界。鉴于子区域规模不一,单一固定参数取值并不能充分发挥模型的模糊作用。为此,依据场景变化以 γ_1 不同取值对模糊参考点平均关联度和累计量的影响衡量边界模糊性能和边界参考点划分效果,对模糊参数 γ_1 进行空间最优配置,以实现自动调整边界模糊深度的功能。

在定位效益追求中,通过双度量融合方式选取高定位价值 RP。然而初始 RP 个数 K 与可信阈值 γ_3 在确定取值条件下会限制高贡献 RP 进入最优集合,从而破坏算法在定位性能上的优异表现。因此,在不同子区中,以平均定位误差为评估基准,借助 K 和 γ_3 的最优参数组合配置,促使算法依据区域范畴自适应调整 RP 集规模,以保证定位精度提升。

1) 模糊参数 γ_1

场景中各区域间边界划分质量关乎系统的定位性能,为有效平衡因边界 RP 归属带来的匹配量增加而造成的系统定位压力,保证分区效果中质的有效提升和量的合理增长。实验对比了不同 γ_1 情况下,归入模糊边界

中 RP 的平均关联度与累计个数变化关系,以配置最佳模糊参数 γ_1 。

如图 1 所示,随着 γ_1 值的增大,达到归属门槛的 RP 数量越来越多,RP 平均关联度和累计量不断增加,其增长趋势符合边界归属规则。当 γ_1 在 $[0.5, 0.7]$ 范围中以 0.01 的小量程增加,平均关联度陡然升高,表明参数的配置迅速起到构建模糊边界的作用,且此时 RP 个数增长较为缓慢,各子区域中仅增加有限 RP 个数,后续定位局部匹配压力相对可控。

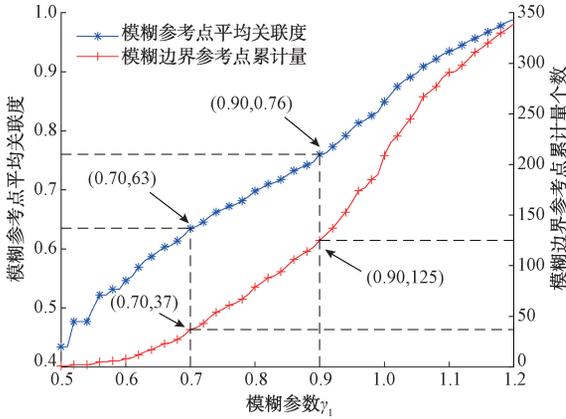


图 1 模糊参数 γ_1 对性能的影响

Fig. 1 The influence of fuzzy parameters γ_1 on performance

但当 $\gamma_1 > 0.7$ 时,RP 平均关联度增长趋势虽偶有减缓,但 RP 累计量呈现多量程倍增形势,对系统定位压力较大,且平均关联度间接反映 RP 归属后边界规整情况,平均关联度越大,构建的边界区域越大,区域较容易出现个别归属离群点,与边界划分初衷相悖。当 $\gamma_1 = 0.7$ 时,累计 RP 个数为 37,较区域初划分于各子区域中仅平均新增 6 个 RP,且各子区域模糊边界构建效果较好,详见图 2 效果图。因此,在确保边界划分完整的前提下,即至少边界最外层 RP 归入相邻子区域中,综合考量匹配数量与边界规整程度,配置论文场景的模糊参数 $\gamma_1 = 0.70$ 。

为进一步验证本文提出的全场景模糊聚类中,关键指纹特征对聚类的支撑作用和边界指纹点归属模型的有效性。以子区域模糊边界构建效果衡量聚类质量,聚类效果如图 2 所示。

在图 2 的环形走廊中,经模糊聚类形成 $P = 6$ 个独立子区和对应 6 个模糊边界。以关键指纹特征 \hat{D} 为支撑,可以避免指纹信息中冗余特征对聚类的扰动。且得益于边界模糊深度可根据场景特点和“点-类”、“类-类”双重密切度调整边界 RP 二次归属,在具有人员走动频繁特征的拐角处和两条东西走廊中部,形成了 $\Omega_1\Omega_2$ 、 $\Omega_1\Omega_3$ 、

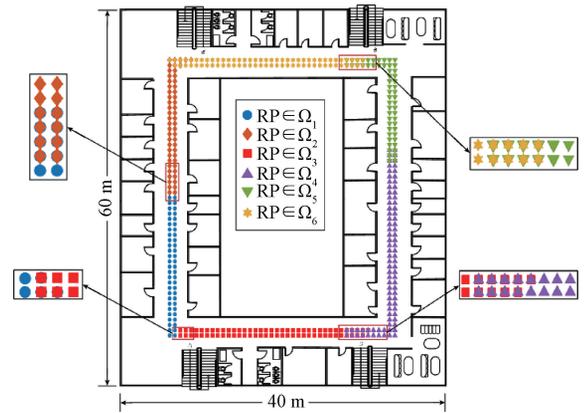


图 2 模糊边界构建效果图

Fig. 2 Fuzzy boundary building results

$\Omega_3\Omega_4$ 、 $\Omega_4\Omega_5$ 、 $\Omega_5\Omega_6$ 、 $\Omega_2\Omega_6$ 相交的 6 个过渡区域。在关键指纹特征和模糊边界判别的协同下,使得各独立子区 RP 集中且规范。

2) 初始 RP 个数 K 与可信阈值 γ_3

为发挥双度量融合的最大定位性能优化作用,选取高定位表现 RP 集,对 5.2 节中的初始 RP 个数 K 和可信阈值 γ_3 进行配置。在固定 RP 集数目经验取值范围 $[3, 6]$ 的基础上,适当扩大范围上限,即 $K \in [3, 15]$ 。为保证最优 RP 集对位置确定的点数支撑,仅观察 $\gamma_3 \in [0.5, 1]$ 取值对定位性能的影响。

为有效评估初始 RP 数目 $K \in \{3, 4, \dots, 14, 15\}$ 和可信阈值 $\gamma_3 \in \{0.5, 0.55, \dots, 0.95, 1\}$ 的不同参数组合方案对系统定位性能的影响,将给定场景 6 个子区域 $\Omega = \{\Omega_1, \Omega_2, \dots, \Omega_6\}$ 分别作为候选空间,以各子区的最小平均定位误差作为最优参数组合的评定标准,从而保证待定位点对最优 RP 集的最佳选取效果。限于篇幅,图 3 随机选取了具有代表性的子区域 $\Omega_1, \Omega_2, \Omega_6$,在不同参数组合下的定位效果图。其中,右侧色标表明平均定位误差大小。

不难发现,不同的参数组合 (K, γ_3) 下,子区域中的定位性能也有所不同。表 1 给出了上述子区域在各自最优参数配置下,随机指定待定位点 TP 位置及生成的最优 RP 集个数 K ,其数目差异进一步验证算法随场景变化自适应调节 RP 集的能力表现优异。

5.3 指纹库构建质量对定位性能的影响

针对常见指纹库构建算法对区域聚类处理较为简单,论文利用经降维处理后的低维指纹信息对给定场景进行模糊聚类,在此基础上适当扩充各子区域指纹点数量。为有效评估指纹库构建质量对待定位点位置估算精度的影响,论文以同一在线匹配方法为前提,通过控制不同建库方法执行,在“原始指纹库”、“仅区域模糊聚类”、“降维协同聚类”、“聚类协同子区域扩充”和本文中降

维、聚类、子区域扩充协同下的“全新指纹库”5 种角度 所示。
下,重复 10 次试验,进行定位性能比较分析,如表 2

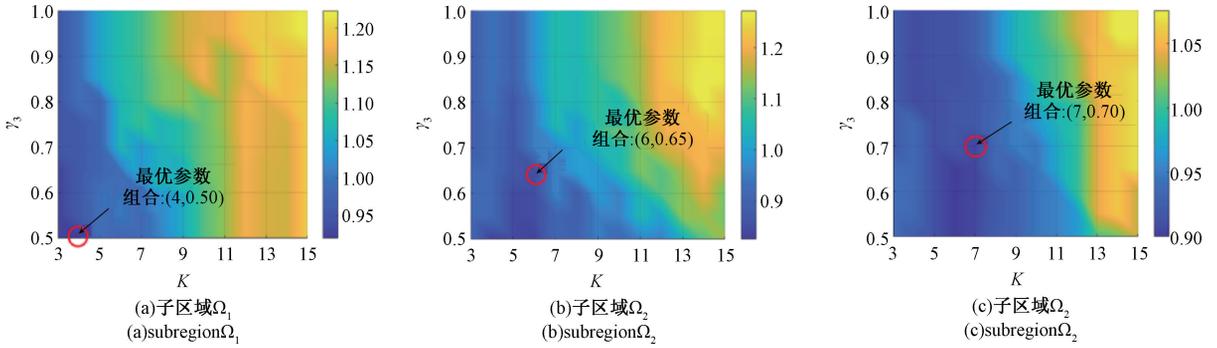


图 3 不同参数 (K, γ_3) 组合在子区域 $\Omega_1, \Omega_2, \Omega_6$ 中的定位误差 (m)

Fig. 3 Positioning error (m) of different parameter (K, γ_3) combinations in subregions $\Omega_1, \Omega_2, \Omega_6$

表 1 代表子区域内最优参数

Table 1 Optimal parameters within representative subregions

子区域 Ω_p	初始 RP 个数 K	可信阈值 γ_3	平均定位误差/m	随机 2 个待定位点 TP	最优 RP 集个数 K
Ω_1	4	0.50	0.920	(3.5, 1.5)	4
				(1.5, 4.5)	7
Ω_2	6	0.65	0.826	(2.5, 52.5)	7
				(1.5, 44.5)	8
Ω_6	7	0.70	0.900	(9.5, 52.5)	5
				(4.5, 52.5)	6

表 2 指纹库构建方法对定位误差的影响

Table 2 The influence of fingerprint database construction method on positioning error

降维/聚类/子区域扩充	平均值/m	最小值/m	最大值/m	方差值/m	运行时间/s
无/无/无	1.299	0.160	12.767	1.584	0.870
无/有/无	1.253	0.066	4.324	0.529	1.008
有/有/无	1.111	0.042	3.996	0.499	2.036
无/有/有	1.136	0.006	10.541	1.379	3.917
有/有/有	0.931	0.006	4.250	0.481	4.057

从实验结果不难发现,相较于原始指纹库,仅区域模糊聚类、降维协同聚类和聚类协同子区域扩充下指纹库的定位误差有所下降,表明所提降维、模糊聚类、子区域扩充 3 种优化方式的合理搭配对定位性能起到优化作用,但优化效果未达最优。使用本文提出的包含降维、聚类和子区域扩充的“全新指纹库”构建方法,平均定位误差仅为 0.931 m,较“原始指纹库”的 1.299 m 性能优化了 28.3%。以其他条件一致为前提,在上述 3 种优化方式的分别作用下,虽然算法运行时间提高了 0.140、0.138、2.021 s,但平均定位误差降低了 0.205、0.046、0.180 m,验证 3 种优化方式搭配下的定位算法,以有限定位开销换取定位精度的提升。

5.4 不同度量方式下多误差分析

为验证论文所提 DMCF 算法中双度量融合 (ED-SD) 方法对定位精度提升的有效性,在算法整体逻辑一致的前提下,ED-SD 分别与 SD、曼哈顿距离 (MD)、ED、余弦距离 (CD) 中一种或多种度量融合下误差较小的 5 种方式 SD、MD、ED-MD、ED-MD-SD、ED-MD-CD 进行定位效果对比。根据待定位点的平均绝对误差、均方根误差和标准差 3 种指标衡量算法的定位效果。

从图 4 可知,SD 和 MD 的定位表现良好,但由于单度量往往忽略部分指纹信息价值,定位性能有待提升。相较于单度量,难以以合理分配各度量权重,两种三度量融合方式 ED-MD-SD 和 ED-MD-CD 的定位效果并不理

想,表明并不是简单的度量堆叠就可以提升定位性能。而文中 ED-SD 在综合信号空间和位置空间信息的同时,保证了 RP 集的高质量选取,有效提升了算法的定位精度。DMCF 算法的 3 种指标值均优于其他方式,在平均

绝对误差、均方根误差和标准差分别达到了 0.864、0.965 和 0.693 m,相较于误差相近的 ED-MD 度量,分别提升了 22.5%、11.0% 和 13.2%。结果验证了所提融合方法对定位效果的提升行之有效。

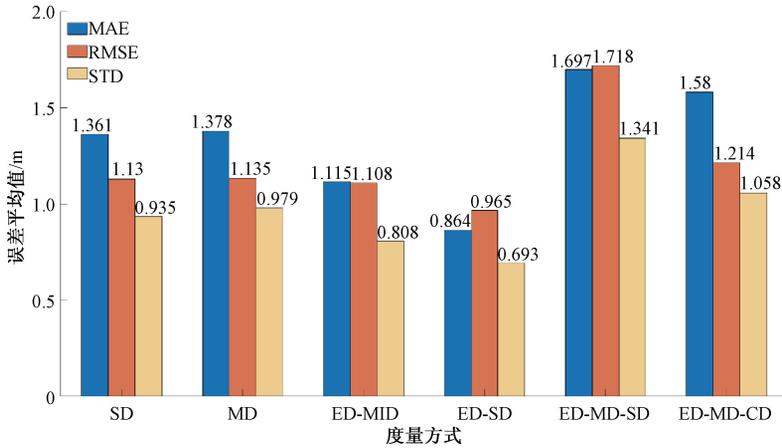


图 4 6 种度量方式在 3 种误差下的比较
Fig. 4 Comparison of 6 metrics under three errors

5.5 整体定位性能对比

为验证 DMCF 算法的整体性能,分别 WKNN^[20]、AAS^[21]、MDRC^[5]和 DTIA^[10]4 种算法进行比较与分析。为保证实验对比的公平性,各算法参数均为最优配置,WKNN、AAS、MDRC 算法中 RP 集个数 $K=5$,MDRC 算法中低维个数 $L=6$,DTIA 算法根据自身寻优结果确定 K 。

图 5 给出了 5 种算法定位误差累积分布,所有算法的误差累积概率随定位误差的增加均呈现增长趋势。在定位性能比较中,论文所提算法均优于其他定位算法,2 m 内误差累积概率可达 93.5%,性能优化 12.4%~36.3%。原因在于,WKNN 在线搜索量大,对优质 RP 识别区分能力不足;AAS 仅采用指纹信息差异排序的方式选取 RP 集,缺乏对空间位置距离的考虑,筛选条件单一;MDRC 则缺少对模糊边界划分的考虑;DTIA 忽视了对各度量权重的合理分配,且在线定位 K 值的设定限制了优质 RP 集的选取。而论文所提指纹库构建和 RP 集筛选方法,以关键指纹特征支撑模糊聚类,适当扩充指纹点以丰富候选匹配空间,并精选高可靠 RP 集,以此提升定位质量。

表 3 总结了 5 种算法的定位性能。实验结果表明,在相同测试场景中,论文算法的平均误差、最小误差、最大误差和方差误差均优于其他定位算法,分别达到了 0.931、0.006、4.250 和 0.481 m。较 WKNN、AAS、MDRC 和 DTIA 4 种算法的平均误差分别降低了 0.359、0.806、0.296、0.544 m。综合实验结果表明,论文算法在具有人

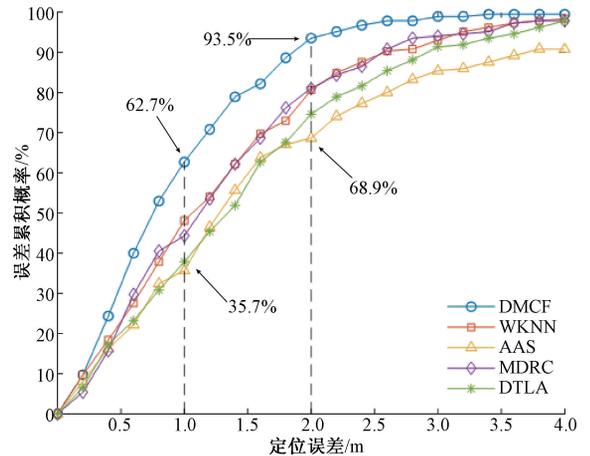


图 5 5 种定位算法误差累积比较
Fig. 5 Comparison of cumulative error for 5 localization algorithms

员走动、障碍遮挡特点下的复杂室内环境中,对定位性能提升较为显著。

表 3 5 种定位算法性能比较
Table 3 Performance comparison of 5 localization algorithms (m)

定位算法	平均误差	最小误差	最大误差	误差方差
DMCF	0.931	0.006	4.250	0.481
WKNN	1.290	0.031	5.375	0.998
AAS	1.737	0.014	10.012	2.824
MDRC	1.227	0.007	9.229	1.071
DTIA	1.475	0.031	5.216	1.118

6 结 论

论文针对复杂室内环境定位需求,提出一种新的指纹库构建方法与 RP 集优选策略,以解决指纹信息高维度冗余、全场景匹配任务繁重和 RP 集可靠度不一影响定位性能的问题,实现 TP 的有效位置估计。本算法以信号空间下的双度量协同提取关键指纹特征,以此为支撑对给定场景进行模糊聚类,完成边界稳定处理,并适当扩充子区域指纹点数,从而提高指纹库构建质量;基于信号空间和位置空间结合下的双度量差异度比对,筛选出可靠 RP 集,保证定位效果。实验验证,所提算法以高质量指纹库为基础,以高可靠 RP 集为保证,以有限的定位开销换取了定位效益的较大提升。

参考文献

- [1] SHANG S, WANG L. Overview of WiFi fingerprinting - based indoor positioning [J]. IET Communications, 2022, 16(7) : 725-733.
- [2] DBNA B, JING H A, VTT A, et al. An effective random statistical method for indoor positioning system using WiFi fingerprinting [J]. Future Generation Computer Systems, 2020, 109:238-248.
- [3] LUO J, ZHANG Z, WANG C, et al. Indoor multifloor localization method based on WiFi fingerprints and LDA[J]. IEEE Transactions on Industrial Informatics, 2019, 15(9) : 5225-5234.
- [4] 唐恒亮, 米源, 刘涛, 等. 基于空间位置约束的稀疏指纹室内定位方法[J]. 电子测量与仪器学报, 2020, 34(6) : 79-85.
TANG H L, MI Y, LIU T, et al. Sparse fingerprint indoor localization based on spatial position constraint[J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(6) : 79-85.
- [5] KHOO H W, NG Y H, TAN C K. Enhanced radio map interpolation methods based on dimensionality reduction and clustering [J]. Electronics, 2022, 11 (16) : 2581-2581.
- [6] WANG B, LIU X, YU B, et al. An improved WiFi positioning method based on fingerprint clustering and signal weighted Euclidean distance[J]. Sensors, 2019, 19(10) : 2300-2300.
- [7] YANG X, LIU Z, NIE W, et al. AP optimization for Wi-Fi indoor positioning-based on RSS feature fuzzy mapping and clustering [J]. IEEE Access, 2020, 8: 153599-153609.
- [8] BI J, HUANG L, CAO H, et al. Improved indoor fingerprinting localization method using clustering algorithm and dynamic compensation [J]. ISPRS International Journal of Geo-Information, 2021, 10(9) : 613-613.
- [9] SHARMA K K, SEAL A. Clustering analysis using an adaptive fused distance[J]. Engineering Applications of Artificial Intelligence, 2020, 96: 103928-103928.
- [10] BI J, CAO H, WANG Y, et al. DBSCAN and TD integrated Wi-Fi positioning algorithm [J]. Remote Sensing, 2022, 14(2) : 297-297.
- [11] 杨海峰, 张勇波, 黄裕梁, 等. 基于空间特征分区和前点约束的 WKNN 室内定位方法[J]. 软件学报, 2019, 30(11) : 3427-3439.
YANG H F, ZHANG Y B, HUANG Y L, et al. WKNN indoor positioning algorithm based on spatial characteristics partition and former location restriction [J]. Journal of Software, 2019, 30(11) : 3427-3439.
- [12] 秦宁宁, 吴忆松, 孙顺远. 一种双信标机制下的指纹库构建方法[J]. 西安电子科技大学学报, 2022, 49(3) : 111-119.
QIN N N, WU Y S, SUN SH Y. Algorithm for fingerprint database construction under the dual beacon mechanism [J]. Journal of Xidian University, 2022, 49(3) : 111-119.
- [13] YUAN Y, LIU X, LIU Z, et al. Indoor localization with wireless heterogeneous devices by composite fingerprint sets and hybrid classification [J]. IEEE Transactions on Vehicular Technology, 2022, 71(11) : 12117-12127.
- [14] KARLEKAR A, SEAL A, KREJCAR O, et al. Fuzzy K-means using non-linear s-distance [J]. IEEE Access, 2019, 7: 55121-55131.
- [15] SRA S. Positive definite matrices and the S-divergence [J]. Proceedings of the American Mathematical Society, 2016, 144(7) : 2787-2797.
- [16] WANG D, HUANG C, ZHANG H, et al. Dynamic clustering and resource allocation using deep reinforcement learning for smart-duplex networks [J]. IEEE Internet of Things Journal, 2022, 10(1) : 42-56.
- [17] KAREGAR P A. Wireless fingerprinting indoor positioning using affinity propagation clustering methods [J]. Wireless Networks, 2018, 24: 2825-2833.
- [18] 田洪亮, 钱志鸿, 梁潇, 等. 离散度 WKNN 位置指纹 Wi-Fi 定位算法 [J]. 哈尔滨工业大学学报, 2017, 49(5) : 94-99.
TIAN H L, QIAN ZH H, LIANG X, et al. Discrete degree WKNN location fingerprinting algorithm based on Wi-Fi [J]. Journal of Harbin Institute of Technology, 2017, 49(5) : 94-99.
- [19] JAN S S, YEH S J, LIU Y W. Received signal strength

database interpolation by Kriging for a Wi-Fi indoor positioning system [J]. *Sensors*, 2015, 15 (9): 21377-21393.

- [20] YANG H, ZHANG Y, HUANG Y, et al. WKNN indoor location algorithm based on zone partition by spatial features and restriction of former location[J]. *Pervasive and Mobile Computing*, 2019, 60(10): 1-14.
- [21] TAO Y, ZHAO L. Fingerprint localization with adaptive area search[J]. *IEEE Communications Letters*, 2020, 24(7): 1446-1450.

作者简介



汪杰, 2021 年于山西农业大学获得学士学位, 现为江南大学硕士研究生, 主要研究方向为室内定位技术和无线传感器网络。

E-mail: 18434764935@163.com

Wang Jie received his B. Sc. degree from Shanxi Agricultural University in 2021. He is currently a M. Sc. candidate at Jiangnan University. His main research interests include indoor positioning technology and wireless sensor networks.



宋书林, 2002 年于江南大学获得学士学位, 2005 年于江南大学获得硕士学位, 现为江南大学讲师, 主要研究方向为软件无线电和无线网络定位。

E-mail: songshulin@jiangnan.edu.cn

Song Shulin received his B. Sc. degree and M. Sc. degree from Jiangnan University in 2002 and 2005, respectively. He is currently a lecturer at Jiangnan University. His main research interests include software defined radio and wireless network positioning.



秦宁宁 (通信作者), 2002 年于江南大学获得学士学位, 2008 年于江南大学获得博士学位, 现为江南大学教授, 主要研究方向为智能网络组建和信道数据的网络化应用。

E-mail: ningning801108@163.com

Qin Ningning (Corresponding author) received her B. Sc. degree and Ph. D. degree both from Jiangnan University in 2002 and 2008, respectively. She is currently a professor at Jiangnan University. Her main research interests include intelligent network formation and networked applications of channel data.