

DOI: 10.19650/j.cnki.cjsi.J2513841

动态辐射条件下的双源感知室内位置测算方法*

吴 岩, 秦宁宁, 宋书林, 王 艳

(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:在地下车库复杂的室内环境中,传统基于信号强度指示(RSSI)的指纹定位技术因辐射条件波动、多径效应及信号干扰等因素,存在指纹特征失真与定位结果偏移现象。针对此问题,提出一种动态辐射条件下的双源感知室内位置测算方法,通过融合环境辐射条件感知与信号特征分析,有效提升定位系统的鲁棒性。指纹离线采集阶段,构建双向融合时序感知模型(BGLA),创新结合双向长短期记忆网络(BiLSTM)与双向门控循环单元(BiGRU),分别捕捉辐射条件对RSSI的长、短期影响特征,并利用多头自注意力机制对特征进行深度融合,进而构建适应不同辐射条件的自适应指纹库;指纹在线匹配阶段,采用指数幂归一化方法,通过调节归一化参数,实现不同设备RSSI信号向统一量程的映射,以缓解硬件RSSI量程差异带来的干扰;此外,提出信源感知聚类算法,基于接入点(AP)质量筛选参考点(RP),并融合感知密度估计,抑制AP信号质量波动引发的RP在线匹配偏差。地下车库场景的实验结果显示,所提方案综合性能较优,在已知辐射条件下,平均定位精度较对比算法提升11.05%~25.38%;在未知辐射条件下,通过BGLA模型构建对应辐射条件的指纹库,从而平均定位精度优于对比算法27.55%~35.71%。

关键词:室内定位;指纹库扩充;辐射条件;指纹点优选

中图分类号:TN96 TH89 文献标识码:A 国家标准学科分类代码:510.40

Dual-source perception indoor localization algorithm under dynamic radiation conditions

Wu Yan, Qin Ningning, Song Shulin, Wang Yan

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

Abstract: In underground garage environments, traditional RSSI-based fingerprint positioning is affected by fluctuating radiation, multipath effects, and interference, resulting in feature distortion and positioning errors. This paper proposes a dual-source sensing indoor positioning method that integrates environmental radiation perception with signal analysis to enhance system robustness. In the offline phase, a bidirectional fusion model combining BiLSTM and BiGRU is employed to capture both long-term and short-term radiation effects on RSSI. By leveraging multi-head self-attention, the model constructs an adaptive fingerprint database that accommodates varying radiation conditions. During the online matching phase, an exponential power normalization technique is used to map RSSI signals to a unified scale, mitigating hardware-related interference. An AP-aware clustering algorithm is introduced to select RPs based on AP signal quality and suppress matching deviations through density estimation. Experimental results in underground garages demonstrate the method's strong performance. Under known radiation conditions, it achieves an average positioning accuracy improvement of 11.05%~25.38% over baseline methods. Under unknown radiation conditions, the BGLA-constructed fingerprint database enables it to outperform comparative approaches by 27.55%~35.71% in average positioning accuracy.

Keywords: indoor localization; fingerprint database expansion; radiation conditions; RP optimization

收稿日期:2025-03-19 Received Date: 2025-03-19

* 基金项目:长三角科技创新共同体联合攻关项目(2023CSJGG1700)资助

0 引言

近年来,随着无线通信技术与智能终端应用高速发展,室内定位服务(indoor position service, IPS)在地下车库、商场导航、仓储物流以及工业监控等领域的应用需求不断增加。在无线网络广泛普及的背景下,室内场景能探测到多个接入点(access point, AP)并测量其接收信号强度指示(received signal strength indicator, RSSI),使基于RSSI的指纹定位技术被广泛应用于室内定位系统^[1]。在指纹定位中,以离线阶段测量多个参考点(reference point, RP)上各个AP的RSSI建立信号指纹库^[2];在线阶段,将待测点(test point, TP)处信号与指纹库中的数据进行匹配,从而推断出TP的位置信息。该方法依赖场景位置特征,在一定程度上回避场景变化对信号测距的干扰^[3-4]。

在相关研究中,文献[5]试图以线性回归算法(linear regression, LR)消除不同硬件设备引起的RSSI波动,但欠缺对环境因素影响信号波动的考量。除克服终端干扰外,环境场景的格局变化对指纹库信号的影响也被研究者所关注,文献[6]通过深度随机神经网络与改进自适应无迹卡尔曼滤波有效抑制环境对RSSI的影响。文献[7]采用信道状态信息(channel state information, CSI)模拟电磁波在空间传播的多径效应,在定时和抗干扰方面表现出优于RSSI的特征。然而CSI的应用受商用设备的布置成本约束,大面积的室内定位场景使用RSSI居多。Guidara等^[8]虽然创新性分析辐射条件与RSSI的相关性,却未进一步考虑辐射条件下的定位方法。在研究辐射条件对RSSI影响尺度与程度的长期数据统计与分析中,Fan等^[9]发现相对湿度(relative humidity, RH)与RSSI的高相关性,并利用部分最小二乘(partial least squares, PLS)构建适应不同辐射条件的指纹库。但PLS难以捕捉RSSI与RH间的非线性关系,指纹库的可信度较低。

可见,抑制辐射条件、设备差异以及信号波动对RSSI的不确定扰动是提高定位精度的关键因素,为此提出辐射、射频双源感知(radiation-RF dual-source aware, RR-DSA)指纹定位方法。为抑制以湿度主导的辐射条件对定位精度的负向影响,采用多头自注意力机制结合双向LSTM与双向GRU构建BGLA模型,以准确捕捉辐射条件与RSSI之间的非线性关系,构建适应多种辐射条件的动态指纹库。为缓解不同设备信号波动范围差异引起的匹配误差,以EPDN归一化将RSSI映射至相同量程。设计信源感知聚类与感知密度位置估计方法,以信源信号质量为尺度进行优质RP筛选,实现在线指纹与AP高维相似度精确匹配,从而克服信号质量波动导致匹配偏差的问题。

1 辐射条件波动下的系统建模

在待定位区域内,构建场景参考坐标系并配置AP信源 $\theta = \{\theta_n | n \in [1, N]\}$ 与TP点 $\phi = \{\phi_m | m \in [1, M]\}$ 。 θ_n 与 ϕ_m 分别表示第 n 个AP与第 m 个RP及其二维坐标 (x_m, y_m) 。

1.1 辐射参数

$H = \{h_x | x \in [1, X]\}$ 表示代表性辐射条件集合。其中, $h_x = [temp_x, humi_x]$ 表示第 x 个代表性辐射条件,并且 $temp_x$ 、 $humi_x$ 分别表示其温度与湿度。鉴于已有研究结果^[9],可忽略 $temp_x$ 对RSSI的微弱影响,仅考虑具有较大影响能力的相对湿度 $humi_x$ 作为辐射条件且依旧记为 h_x 。

1.2 指纹参数

1) $RSSI_m^{h_x} = \{RSSI_{mn}^{h_x} | m \in [1, M]\}$ 表示在 h_x 辐射条件下,在 ϕ 位置上采集的信号强度构成指纹数据集合。其中, $RSSI_m^{h_x} = \{RSSI_{mn}^{h_x} | n \in [1, N]\}$ 表示 h_x 时 ϕ_m 上接收到来自 θ 的信号组成的信号指纹集合, $RSSI_{mn}^{h_x}$ 表示 $RSSI_m^{h_x}$ 中接收到 θ_n 处的RSSI。

2) $RSSI_{(mn,q)}^{h_x}$ 表示 h_x 时 ϕ_m 处接收到 θ_n 处发出的第 q 次RSSI信号,且 $q \in [1, Q]$ 。

3) $RSSI_n^{h_{TP}} = \{RSSI_{nn}^{h_{TP}} | n \in [1, N]\}$ 表示在线定位时,在线辐射条件 h_{TP} 下TP处采集到来自于 θ_n 的RSSI信号 $RSSI_n^{h_{TP}}$ 集合。

2 辐射指纹库构建阶段

2.1 信源分布指纹清洗

由于室内环境中RSSI波动明显,瞬时采集的RSSI往往无法准确反映位置特征。尽管信号的整体分布能够全面表示RP的位置特征,但若将所有指纹数据纳入指纹库用于匹配,不同位置上RP的RSSI数值区间的重叠将导致这些RP难以区分。受文献[10-11]启发,将信号分布压缩为单一值,以信号分布作为RSSI信号位置特征。

已有研究成果表明,RSSI的环境噪声可近似认定为0均值高斯分布^[12],在此可将 $RSSI_{mn}^{h_x}$ 信号拟合为高斯分布函数以剔除环境噪声。并计算其概率密度函数(probability density function, PDF)与RSSI的乘积得到RP的分布期望作为指纹。通过此方式,将原本数值波动、但具有相同信号特征的RSSI的 Q 个分布离线数据,整合为包含RP位置信号分布特征的独立数值指纹表达,如式(1)所示。

$$\overline{RSSI}_{mn}^{h_x} = \sum_{q=1}^Q p_{mn}^{h_x} (RSSI_{(mn,q)}^{h_x}) \times RSSI_{(mn,q)}^{h_x} \quad (1)$$

$$p_m^{h_x} = \{p_{mn}^{h_x} | n = 1, 2, \dots, N\} \quad (2)$$

其中, $\overline{RSSI}_{mn}^{h_x}$ 即数据清洗后辐射条件 h_x 下, 在 ϕ_m 接收来自 θ_n 的 RSSI。 $p_{mn}^{h_x}$ 为辐射条件 h_x 下 ϕ_m 处指纹在 θ_n 分量上的 PDF。下文以原符号代表清洗后的数据。

2.2 辐射指纹库结构

经典指纹库的构建忽视辐射条件波动对 RSSI 变化的影响, 导致指纹匹配偏差而降低定位精度。为此, 论文增加辐射条件作为指纹库的新维度以适应辐射条件变化, 称新构建的指纹库为辐射指纹库并记作 D 。辐射指纹库 D 由多个辐射条件下的子指纹库组成, 如式 (3) 所示。为降低辐射指纹库的采集成本投入, 离线阶段仅需采集代表性辐射条件 H 下的子指纹库。在 h_x 下的指纹库记作子指纹库 D_{h_x} , 以式 (4) 表示。

$$D = [D_{h_1} \ D_{h_2} \ \dots \ D_{h_x}]^T \quad (3)$$

$$D_{h_x} = \begin{bmatrix} \phi_1 & RSSI_{1N}^{h_x} & h_x \\ \phi_2 & RSSI_{2N}^{h_x} & h_x \\ \vdots & \vdots & \vdots \\ \phi_M & RSSI_{MN}^{h_x} & h_x \end{bmatrix} \quad (4)$$

2.3 指纹库扩充模型

顾及定位场景中辐射条件连续变化, 论文构建双向融合时序感知模型 (BiGRU-BiLSTM-attention, BGLA) 并基于 D 扩充未知辐射条件下的指纹库。BGLA 采用双通道架构, 分别使用双向长短期记忆网络 (Bi-directional long short term memory, BiLSTM) 和双向门控循环单元 (Bi-directional gated recurrent unit, BiGRU) 并行处理输入, 以提取辐射条件对 RSSI 的长、短期影响特征。BiLSTM 凭借输入门、输出门、遗忘门, 能够关注到多个辐射条件下的指纹数据。而 BiGRU 的更新门与重置门则聚焦于短期依赖性, 从子指纹库中提取单一辐射条件与位置特征间的影响机理。

为融合这两种不同尺度的特征表示, 模型引入多头自注意力机制 (multi-head self-attention, MHSA)。在注意力模块中, 将辐射条件通过线性层映射为查询向量 Query, 而 BiLSTM、BiGRU 的输出 s 与 τ 分别作为注意力机制中的键 Key 和值 Value 输入。注意力模块通过辐射条件与 BiLSTM 输出的交互以计算注意力权重, 并对 BiGRU 的输出进行加权融合。该机制使模型能依据辐射条件自适应调整特征贡献比例, 从而预测其他辐射条件下的 RSSI 指纹库。

在获得注意力输出后, 模型取融合序列的最后一个时间步输出作为全局特征表示, 并通过多层感知器

(multi-layer perceptron, MLP) 进行非线性映射, 最终生成包含多个 AP 的 RSSI 值构成的子指纹库。

BGLA 的输入为指纹坐标位置 RP 与 h_{TP} , 输出为 h_{TP} 下的子指纹库。结构功能图如图 1 所示, 其中 Query、Key 和 Value 为 MHSA 的输入, Dot 为向量乘积。




图 1 BGLA 模型结构

Fig. 1 Structure of BGLA model

最终模型表达式如式 (5) 所示。

$$D_{TP} = FC \left(\text{softmax} \left(\frac{H_{TP} \times s}{\sqrt{d_k}} \right) \tau \right) \quad (5)$$

其中, D_{TP} 表示 BGLA 在 h_{TP} 下扩充的子指纹库; softmax 为激活函数; FC 为 MLP 层, 用于将模型的输出根据注意力权重转换为指纹; d_k 为 Key 的维度, 用于防止梯度消失或爆炸; H_{TP} 为 h_{TP} 构成的向量。

2.4 辐射指纹库动态扩充

BGLA 模型能够根据环境动态变化构建相应辐射条件子指纹库, 并将该子指纹库添加进辐射指纹库。在线定位时, 选取辐射条件与在线辐射条件一致的子指纹库作为离线指纹库用于定位, 如图 2 所示。




图 2 自适应辐射指纹库定位示意图

Fig. 2 Schematic diagram of adaptive radiation fingerprint database localization

3 指纹匹配阶段

3.1 设备差异归一化消除

相同型号设备由于硬件灵敏度差异及 RSSI 与距离的非线性关系,在等距间隔下仍存在 RSSI 偏差,进而影响相似度计算的准确性。而归一化方法能够快速地将不同量纲的 RSSI 调整至统一尺度而受研究者们关注。在文献[13]方法基础上提出指数幂归一化(exponential power-based data normalization, EPDN)方法,如式(6)所示,该方法根据场景中的信号衰减特性调节两个关键参数 α 和 β ,参数 α 通过改变指数项分母调整相同 RSSI 衰落对应归一化值衰落,以调控 RSSI 与归一化值的相对变化率;而参数 β 控制归一化值对应 RSSI 的整体衰减速率,使归一化值与距离的关系趋近线性。

$$RSSI_{normal} = \left(\frac{e^{\frac{|RSSI_{nature} - RSSI_{min}|}{\alpha}}}{e^{\frac{|RSSI_{min}|}{\alpha}}} \right)^{\beta} \quad (6)$$

$$RSSI_{min} = \min(RSSI^h, RSSI_{TP}) \quad (7)$$

其中, $RSSI_{normal}$ 表示归一化值, $RSSI_{nature}$ 为原始 RSSI 数据, $RSSI_{min}$ 为指纹库中 RSSI 的最小值。为便于下文描述,归一化后的变量以原符号表示。

3.2 信源感知匹配

1) 感知偏差率评估

基于数值的指纹匹配方法着眼于指纹间整体相似度,忽视在线指纹与离线指纹在各 AP 分量上的匹配情况。而 TP 接收的瞬时 RSSI 难以反映当前位置特征,即使在线指纹与指纹库中指纹存在较大的数值偏差,RP 与 TP 仍可能具有较高的整体相似度。此现象导致与 TP 整体相似度较高的 RP 被误判为不相似 RP。

为解决此问题,定义感知偏差率 λ 作为指纹在 AP 分量上相似度的评估指标。经 EPDN 处理后, RSSI 值被统一到相同尺度,故能够直接进行数值上的比较。于是通过比较 RSSI 偏差比例与噪声阈值 γ 判断相似度。 λ 为 $RSSI_n^{h_{TP}}$ 与 $RSSI_{mn}^h$ 在 θ_n 上的相似度,如式(8)所示。

$$\lambda(RSSI_{mn}^h, RSSI_n^{h_{TP}}) = \left| \frac{RSSI_n^{h_{TP}} - RSSI_{mn}^h}{RSSI_{mn}^h} \right| \quad (8)$$

则 TP 与 ϕ_m 在 θ_n 上相似判定函数 f 可表示为式(9),其中数值 1 表示相似,0 表示不相似,便于在下文的信源感知聚类中,评估 RP 与 TP 间相似度。

$$f(m, n) = \begin{cases} 1, & \lambda(RSSI_{mn}^h, RSSI_n^{h_{TP}}) < \gamma \\ 0, & \lambda(RSSI_{mn}^h, RSSI_n^{h_{TP}}) > \gamma \end{cases} \quad (9)$$

2) 信源感知聚类

当某 AP 出现信号丢失、环境遮蔽等情况时, RSSI 扰

动将影响指纹匹配并造成 TP 与相邻 RP 在该 AP 信号上的 λ 不匹配。考虑到以上问题,当某 AP 收到干扰后,考量指纹中多数 AP 分量的相似程度以降低干扰。论文提出信源感知聚类 $\Omega = \{\Omega_m | m \in [1, M]\}$,以评估 RP 与 TP 的相似程度,其中子聚类 Ω_n 表示某 RP 与 TP 在 θ_n 分量上满足 f 相似的 RP 的集合。并定义信源感知度 $F = \{F_m | m \in [1, M]\}$ 作为相似评价尺度,其中 F_m 表示 ϕ_m 与 TP 的相似程度。构建 Ω 的具体步骤为:

1) 计算 $RSSI^{h_{TP}}$ 与 D_{TP} 中各 RP 点间的感知偏差率 λ ,并计算 f 判断指纹各 AP 分量是否相似;

2) 根据 f 对 RP 进行分类:若 ϕ_m 在 θ_n 上相似,则将 ϕ_m 加入集合 Ω_n 中,分类原理如式(10)所示。

$$\Omega_n = \{\phi_m | f(m, n) = 1\} \quad (10)$$

3) 计算 ϕ_m 的信源感知度 F_m ,其取值范围为 $[0, N]$ 。构建方法如式(11)所示。

$$F_m = \sum_{i=1}^N [\phi_m \in \Omega_n] \quad (11)$$

其中, $[\cdot]$ 为艾弗森括号,若 $\phi_m \in \Omega_n$ 为真,则 $[\phi_m \in \Omega_n] = 1$,否则为 $[\phi_m \in \Omega_n] = 0$ 。需要说明的是,RP 能够被多个子聚类包含,表明此 RP 与 TP 在多个 AP 分量上相似。

4) 信源感知度最高的 ϕ_m 作为 RP 优选结果 RP_{Select} , RP_{Select} 表达式如式(12)所示。

$$RP_{Select} = \{\phi_m | F_m = \max(F)\} \quad (12)$$

其中, $\max$ 表示集合中的最大值。

3.3 矢量相似度位置估计

在指纹定位系统通过多个 AP 的 RSSI 来估计设备的当前位置。经典指纹匹配方法中利用欧式距离衡量指纹间相似度^[14],但在随着 AP 数量的增加,指纹间的欧式距离会趋于相同,这一现象被称为维度灾难。因此欧式距离在反映 RSSI 数据间的相似度方面存在其局限性。

经实践与研究发现^[15],向量方向的一致性能够衡量指纹间的相似度。因此论文将指纹作为向量处理,通过计算指纹向量间的矢量相似度 sim ,得到 RP 优选结果 RP_{Select} 在位置估计中的权重 ω_m 。为减少低信号质量 AP 对指纹向量模长的影响,将 Ω_n 的密度作为 θ_n 信号质量的判断标准,增加高信号质量 AP 在位置估计中的占比。定位坐标估计步骤为:

1) 根据 Ω 中子聚类 Ω_n 的密度,如式(13)所示,计算指纹向量 θ_n 信号质量权重 w_n ,即:

$$w_n = \rho(\Omega_n) \quad (13)$$

其中,聚类密度计算函数 $\rho(\Omega_n) = |\Omega_n| / |\Omega_n|$ 表示 Ω_n 的基数等同于 Ω_n 中 RP 的个数。

2) 根据 w_n 调整指纹的 θ_n 分量在 sim 中的占比,以增强高质量 AP 的影响。 sim 可表示为:

$$\begin{aligned} \text{sim}(RSSI_n^{h_{TP}}, RSSI_m^h) = & \frac{\sum_{n=1}^N w_n (RSSI_n^{h_{TP}} \cdot RSSI_m^h)}{\sum_{n=1}^N w_n \|RSSI_n^{h_{TP}}\|_2 \|RSSI_m^h\|_2} \end{aligned} \quad (14)$$

其中, $\|p\|_2$ 表示向量 p 的二范数。

3) 基于式(15), 计算 RP_{Select}^i 的权重 ω_i , 并构建 RP_{Select} 的权重集合 ω , 即:

$$\omega_i = \frac{1}{1 - \text{sim}(RSSI_n^{h_{TP}}, RSSI_i^h)} \quad (15)$$

$$\omega = \{\omega_i \mid i \in [1, K]\} \quad (16)$$

4) 对 RP_{Select} 加权求和得到最终定位结果:

$$TP_{pred} = \sum_i^K \omega_i \cdot RP_{Select}^i \quad (17)$$

3.4 RR-DSA 定位算法流程

在指纹定位中, 定位精度受辐射条件变化、设备差异、信号质量波动与高维指纹匹配误差等条件制约。针对辐射条件的动态变化引发指纹库中 RSSI 偏移现象, 以 BGLA 模型对未知辐射条件下的指纹库进行扩充, 克服辐射条件改变对定位精度的影响。此外, 为消除设备差异对 RSSI 的影响, 利用 EPDN 将 RSSI 统一到相同尺度。面对信号质量波动对 RP 匹配环节的干扰, 论文使用 f 筛选与 TP 相似的 RP。最终定位结果由高维 RSSI 指纹间的相似度经过处理后作为权重, 并与 RP_{Select} 加权求和得到。算法流程如算法 1 所示。

算法 1: RR-DSA 算法流程

输入: 在线指纹 $RSSI^{h_{TP}}$

输出: 在线定位结果 TP_{pred}

通过式归一化处理 D_{TP} 与 $RSSI^{h_{TP}}$;

for ϕ_m do

for θ_n do

通过式(8)判断 ϕ_m 与 TP 在 θ_n 上的相似度;

通过式(10)将 ϕ_m 添加到集合 Ω_n 中;

end

end

for ϕ_m do

通过式(12)得到 RP 优选结果 RP_{Select} ;

end

for Ω_n do

通过(13)计算 θ_n 的信号质量权重 w_n ;

end

for RP_{Select}^i do

通过式(15)计算 RP_{Select}^i 的权重 ω_i ;

end

通过式(17)预测在线定位结果。

4 实验结果分析

4.1 实验场景设置

1) 数据采集

为验证 RR-DSA 算法的定位精度, 以江南大学先进技术研究院地下车库作为实验地点, 车库西侧矩形区域设置为主实验区域, 车库入口处矩形区域为泛化实验区域, 两个实验区域的场景布置相同。下文若不作特殊说明, 实验区域均为主实验区域。二维坐标系中, 在 13 m×7 m 矩形区域内均匀设置 $M=91$ 个 RP 点, 相邻参考点间隔 1 m。布置 $N=6$ 个 nRF52832 模块作为 AP 基站, 模块距离地面高度为 1.8 m。离线指纹库构建阶段, 指纹采样间隔设置为 2 s, 共采集 $Q=60$ 次 RSSI 并进行数据清洗后构成指纹。辐射条件使用位于定位场景内部的湿度传感器获得, 受非视距误差 (non line of sight, NLOS) 等条件影响, 为保证指纹库的完整度, 指纹中缺失的 RSSI 值记为 -99 dbm。离线采集代表性辐射条件 H 下的指纹库共 $X=6$ 组, 对应指纹库 $D = [D_{h_1}, D_{h_2}, \dots, D_{h_6}]^T$ 。 ϕ 与 H 具体布设见表 1。鉴于辐射条件受到季节、天气等因素显著影响, 实验的离线数据采集工作在 9 月至 12 月即夏末至冬初时段完成。并按照辐射条件 5% 的变化间隔在晴、多云、阴等不同天气状况下进行系统性的数据采集。


表 1 基站坐标与辐射条件信息

Table 1 Coordinates of base stations and radiation condition information


基站坐标/m	H	$RH/\%$
$\theta_1(0,0)$	h_1	30
$\theta_2(0,6)$	h_2	35
$\theta_3(12,6)$	h_3	40
$\theta_4(12,0)$	h_4	45
$\theta_5(6,6)$	h_5	50
$\theta_6(6,0)$	h_6	55

在线数据采集阶段, 设置 nRF52832 模块作为 RSSI 测量设备, 在实验区域内沿两条矩形路线移动采集 H 与 $h_{TP} = 37$ 下 77 个 TP 点处的测试指纹 $\mu = \{\mu_{h_x} \mid h_x \in \{H, h_{TP}\}\}$, 其中 μ_{h_x} 为 h_x 处的在线指纹。场景内部布置如图 3(a) 所示, 采集设备移动路线如图 3(b) 中轨迹所示。

使用 h_{TP} 作为测试辐射条件, 并且 h_{TP} 下扩充后的指纹库为 D_{TP} 。根据多次实验结果, 合适的归一化参数取值范围为 $\alpha, \beta \in [1, 20]$, 于是计算 H 下每组归一化参数的平均均方根误差 (root mean square error, RMSE) 得到最佳的归一化参数为 $\alpha = 11, \beta = 3$ 。归一化参数优化结果如图 4 所示。



(a) 实验场景实景图
(a) Actual image of the experimental scene



(b) 实验区域与布置图
(b) Experimental area and layout diagram

图 3 实验场景

Fig. 3 Experimental scene diagram




图 4 归一化参数优化结果

Fig. 4 Optimization results of normalization parameters

2) 模型参数

BGLA 模型使用的环境为 Pytorch2. 1. 2+cu118,GPU 使用 1 块 NVIDIA RTX4060,操作系统为 Windows10,CPU 为 Intel Core i5-12490F。实验中模型参数具体如表 2 所示。

4.2 归一化方法对 RR-DSA 定位结果的影响

为评估论文所提 EPDN 方法在 RR-DSA 算法中的有效性,将算法中的归一化算法更换为无归一化、线性

表 2 模型相关参数

Table 2 Model-related parameters

参数名称	参数值
BiLSTM 隐藏层尺寸	64
BiGRU 隐藏层尺寸	64
注意力头数	4
批尺寸	32
训练轮次	200
验证集拆分比例	0. 2
损失函数	MSE
优化函数	Adam
学习率	0. 001

(Linear)归一化、Z-score 归一化并将 D 与 D_{TP} 作为指纹库进行对比实验。将 D 与 D_{TP} 在 RR-DSA 算法下定位结果的 RMSE、最大值 (MAX) 与最小值 (MIN) 取均值作为定位误差。

表 3 给出 4 种归一化方法的实验结果,可见未归一化的 RSSI 处理策略在各项误差指标上均表现最差,这是由于实际环境中不同 AP 的取值范围与分布特性差异较大,未经尺度调整的 RSSI 会使 RR-DSA 算法在匹配中无法准确判断 TP 与 RP 相似性。线性归一化方法通过将数据映射 $[0, 1]$ 区间,相较于无归一化在 RMSE、MAX 以及 MIN 上分别提升 1. 7%、1. 1% 和 33. 5%。虽缓解了尺度差异带来的问题,但 RSSI 分布在最值异常时缺乏区分度,最终影响定位结果。Z-score 基于数据的均值和标准差进行处理在对比算法中表现最佳,但缺乏对于 RSSI 信号衰减的考量。EPDN 在这些方法的基础上增加 α 与 β 参数,根据 RSSI 物理特征调节归一化效果,因而在误差指标上最佳优化分别达到 4. 91%、4. 26% 和 38. 4%。

表 3 4 种归一化方法实验结果比较

Table 3 Comparison of experimental results for four normalization methods (m)

误差指标	EPDN	无归一化	Linear	Z-score
RMSE	1. 278	1. 344	1. 321	1. 292
MAX	2. 607	2. 723	2. 692	2. 641
MIN	0. 101	0. 164	0. 109	0. 120

4.3 扩充指纹库算法性能对比

为探究 BGLA 模型扩充指纹库的性能,实验选取 RNN、LSTM、GRU、BiLSTM、BiGRU、Transformer 这 6 种具有代表性的时序学习模型作为对比模型,扩充辐射条件 h_{TP} 下的指纹库 D_{TP} 。为确保实验对比的公平性,对比模型的训练轮次统一设置为 200 轮,并使用 RR-DSA 算法

进行定位,以排除训练轮次差异与算法差异对结果的影响。

由图 5 可知,GRU 与 BiLSTM 扩充后的指纹库在进行定位时出现了离群点,表明 GRU 与 BiLSTM 生成指纹库在部分测试点上表现较差,这是因为模型对训练数据中的噪声与异常特征过度学习,导致模型无法准确拟合真实的信号指纹。相比其他对比模型,BGLA 模型在中位数方面最佳优化 26.31%,并在上四分位数指标方面优于其他模型,仅在下四分位数指标方面 BiGRU 领先 BGLA 5.08%。由实验结果可知,BGLA 通过双向网络与自注意力机制,能够学习 RSSI 中的辐射条件影响与空间位置特征,扩充后指纹库的整体质量优于对比模型。




图 5 7 种模型下指纹库扩充性能箱型图

Fig. 5 Box plot of fingerprint database expansion performance across seven models

4.4 辐射指纹库定位性能对比

为评估 BGLA 模型扩充指纹库相对于未扩充指纹库的定位性能,实验将 D_{tp} 与 D 共 7 组指纹库分别作为离线指纹库、 μ 作为在线指纹在 RR-DSA 下得到 7 组定位结果,通过比较 D_{tp} 与 D 作为离线指纹库时的累计误差概率分布与定位误差以验证 D 的有效性。

由图 6 可知, D_{tp} 作为离线指纹库时的累计误差概率曲线较为陡峭,表明整体定位误差相较于 D 作为离线指纹库有了明显改善。虽在极少 TP 上,相同误差概率时的定位偏差大于 D_1 与 D_2 ,但最大定位误差仅 0.076 m。这是由于指纹采集时存在信号噪声,对 BGLA 学习辐射条件对 RSSI 产生了干扰,因此 D_{tp} 在极少数 TP 上的定位结果略低于 D ,而整体定位性能更加理想。实验结果表明, D_{tp} 相比 D 在场景辐射条件变化时具有显著优势。

4.5 多种辐射条件下定位性能比较

1) 已知辐射条件下定位性能

为验证 RR-DSA 算法在 H 上的定位性能,论文选取




图 6 7 组子指纹库误差分析

Fig. 6 Error analysis of seven sub-fingerprint databases

随机森林 (random forest, RF)、极限梯度提升 (extreme gradient boosting, XGBoost) 和马氏距离加权 K 近邻 (modified weighted K-nearest neighbor, MWKNN)^[16] 定位算法作为对比算法,RF 对数据的适应性强能够对 RP 分类、XGBoost 可通过梯度提升树灵活调优,而 MWKNN 通过距离匹配推断 TP 位置。为保证对比的公平性,RF、XGBoost 和 MWKNN 算法均选取本实验场景下的中最佳参数进行实验, μ 作为测试指纹在 D 上进行定位得到 6 组定位结果。

从表 4 可知,RR-DSA 算法在所有辐射条件下的 RMSE 均优于其他算法,表明该算法在辐射条件变化场景下具有较强的适应性。RF 算法在 h_3 时相比 RR-DSA 算法在 RMSE 方面差距最大为 14.9%,在 h_5 时与 RR-DSA 相近;而在最大误差方面,RR-DSA 在 h_6 时相较 RF 算法提升最多,为 35.7%;在 h_2 时提升最小,为 10.7%。MWKNN 和 XGBoost 的表现虽较为接近,但在各评估指标下均低于 RR-DSA。综合实验结果表明,RR-DSA 在 H 上的定位表现全面优于对比算法。这源于信源感知聚类在离线阶段根据 AP 分量的相似度进行 RP 筛选,而其他对比算法无法剔除 AP 质量波动引起的扰动故在实验场景中表现不佳。

表 4 4 种算法在 6 个辐射条件下的 RMSE 对比

Table 4 RMSE comparison of four algorithms under six radiation conditions

定位方法	h_1	h_2	h_3	h_4	h_5	h_6
RR-DSA	1.214	1.260	1.272	1.265	1.368	1.321
RF	1.535	1.550	1.537	1.549	1.538	1.676
XGBoost	1.604	1.579	1.617	1.595	1.697	1.768
MWKNN	1.627	1.542	1.653	1.610	1.694	1.621

2) 未知辐射条件下定位性能

为验证 RR-DSA 在 h_{TP} 下的定位性能,再次选取 MWKNN、RF 和 XGBoost 算法作为对比算法、 $\mu_{h_{TP}}$ 作为测试指纹在离线指纹库 D_{TP} 上进行定位得到定位结果。为保证对比的公平性,MWKNN、RF 和 XGBoost 算法均选取本实验场景下的中最佳参数进行实验。

从图 7 可以看出,RR-DSA 在测试条件下的定位精度最优,1 m 内误差累计概率达到 56.41%;2 m 内误差累计概率达到 97.44%,最佳优化为 12.82%。原因在于 MWKNN 在线搜索量大,对优质 RP 区分能力不足;RF 决策过程依赖于学习 RSSI 的位置特征,而包含信号噪声的在线指纹导致位置特征不准确,难以评估 TP 与 RP 处指纹的相似性;XGBoost 虽然处理非线性问题上有一定优势,但无法准确捕捉信号与位置间的复杂关系。而 RR-DSA 充分考虑了基站质量、信号波动与辐射条件的影响,因而提升了定位效果。




图 7 4 种算法在不同指纹库下的累计误差分析

Fig. 7 Cumulative error analysis of four algorithms under different fingerprint databases

4.6 算法对 AP 信号敏感性分析

为验证 RR-DSA 算法应对 AP 数量变化时的抗干扰性,分别对 D 中指纹的 θ_0 分量、 θ_5 和 θ_6 分量增加高斯噪声生成受干扰指纹库 D_5 与 $D_{5,6}$,以模拟 1 到 2 个 AP 信号被干扰时的定位场景。RF、XGBoost 与 MWKNN 作为对比算法在全局辐射条件 H 下使用 3 个指纹库 $D_{5,6}$ 、 D_5 与 D ,将 μ 作为测试指纹进行位置估计,将 RMSE 作为抗干扰性能的评价指标。

从表 5 中能够看出, D_5 与 D 作为指纹库时 RR-DSA 算法的 RMSE 显著优于其他算法;而在指纹库为 $D_{5,6}$ 的情况下,仅在辐射条件为 h_2 与 h_4 时,RF 算法略微领先 RR-DSA 算法 1.6 ~ 2.2%。实验结果表明,随着被干扰 AP 数量的增加,所有定位算法的定位精度均显著降低。然而与其他对比算法相比,RR-DSA 算法在不同指纹库

下定位精度均保持领先。这一优势得益于信源感知聚类方法能够提高信号质量较强的 AP 在定位中的作用,抑制被干扰 AP 带来的精度损失。

表 5 各算法 AP 信号敏感性

Table 5 AP signal sensitivity of each algorithm

辐射条件		h_1	h_2	h_3	h_4	h_5	h_6
$D_{5,6}$	RR-DSA	1.639	1.748	1.734	1.747	1.697	1.841
	RF	1.714	1.720	1.800	1.708	1.931	1.888
	XGBoost	1.873	1.811	1.909	1.777	2.104	1.924
	MWKNN	2.083	2.196	2.029	1.968	2.195	2.164
D_5	RR-DSA	1.407	1.489	1.520	1.480	1.532	1.627
	RF	1.423	1.563	1.714	1.573	1.877	1.832
	XGBoost	1.540	1.628	1.755	1.544	1.966	1.657
	MWKNN	1.884	1.776	1.777	1.893	1.634	1.78
D	RR-DSA	1.214	1.260	1.272	1.265	1.368	1.321
	RF	1.535	1.550	1.537	1.549	1.538	1.676
	XGBoost	1.604	1.579	1.617	1.595	1.697	1.768
	MWKNN	1.627	1.542	1.653	1.610	1.694	1.621

4.7 算法区域泛化能力

在实际的大规模定位场景中,受建筑结构与通风设备位置影响,不同位置的辐射条件呈现出差异性。通过将车库按照实验面积拆分为若干个子区域,利用基站的媒体存取控制位址(media access control, MAC)地址识别所在子区域^[17]并运行 RR-DSA 算法以避免辐射条件差异对辐射条件的影响并拓展定位范围。为测试算法在大规模定位场景的泛化能力,实验场地设置在泛化实验区域,泛化实验区域位置与布置如图 3(b)所示,在线指纹的辐射条件为 $h_{TP2} = 48$ 。

表 6 为 RR-DSA 与上文所提 3 种对比算法在当前实验区域内的定位精度。在 h_{TP2} 下,整体定位精度较对比算法提升了 13.7% ~ 19.2%,最大误差降低幅度达 32.32% ~ 44.7%。

表 6 各算法区域泛化能力对比

Table 6 Comparison of the generalization ability of each algorithm region (m)

误差指标	RR-DSA	MWKNN	RF	XGBoost
RMSE	1.144	1.415	1.325	1.379
MAX	2.102	3.801	3.106	3.363
MIN	0.127	0.248	0.190	0.062

如图 8 所示,RR-DSA 仅在最小误差上大于 XGBoost,在其他测试点上的定位精度均领先其他对比算

法。这是因为 RR-DSA 在每个子区域内的运行机制一致,使算法能够在辐射条件变化较大的环境中保持良好的定位性能。实验结果表明,RR-DSA 算法在其他区域的定位精度领先对比算法,能够满足大面积场景的定位需求。




图 8 算法区域泛化性能误差分析

Fig. 8 Error analysis of the generalization performance of algorithm regions

5 结 论

针对地下车库场景下,基于 RSSI 的指纹定位技术因辐射条件波动、信号干扰等因素,导致定位结果出现偏移的问题,提出一种基于辐射条件扩充指纹库的室内定位算法—RR-DSA。该算法在离线阶段构建 BGLA 模型,提取辐射条件对 RSSI 的影响,构建出能够适应不同辐射条件的动态指纹库。在线匹配阶段,RR-DSA 通过 EPDN 归一化方法还原 RSSI 与物理距离之间的关系,并借助信源感知聚类方法改善 RP 点质量,最终结合感知密度估计定位结果。实验结果表明,在不同辐射条件下,RR-DSA 的定位精度领先其他定位算法。该研究侧重于辐射条件对室内定位的影响分析,因此实验暂不考虑可能存在的非视距干扰因素如车辆移动、人员密度等。

参考文献

[1] CHEN P, ZHANG SH P. DeepMetricFi: Improving Wi-Fi fingerprinting localization by deep metric learning[J]. IEEE Internet of Things Journal, 2024, 11(4): 6961-6971.

[2] LENG Y H, HUANG F HU, TAN W J. A Wi-Fi fingerprint positioning method based on RLWKNN[J]. IEEE Sensors Journal, 2024, 25(1): 1706-1715.

[3] WU ZH, HU P, LIU SH Y, et al. Attention mechanism and LSTM network for fingerprint-based indoor location system[J]. Sensors, 2024, 24(5): 1398-1417.

[4] 陈潇,秦宁宇,宋书林. 双源信号下多元尺度融合室内

位置测算方法[J]. 仪器仪表学报, 2024, 44(1): 311-320.

CHEN X, QIN N N, SONG SH L, et al. Indoor position estimation method with multi-scale fusion under dual-source signals[J]. Chinese Journal of Scientific Instrument, 2024, 44(1): 311-320.

[5] ZHANG L Y, MA L, XU Y B, et al. Linear regression algorithm against device diversity for indoor WLAN localization system[C]. 2017 IEEE Global Communications Conference, 2017: 3349-3354.

[6] TILWARI V, PACK S, MADURANGA M W P, et al. An improved Wi-Fi RSSI-based indoor localization approach using deep randomized neural network[J]. IEEE Transactions on Vehicular Technology, 2024, 73(12): 18593-18604.

[7] CAI X, LI X H, YUAN R Y, et al. Identification and mitigation of NLOS based on channel state information for indoor WiFi localization[C]. 2015 International Conference on Wireless Communications & Signal Processing, 2015: 1055-1059.

[8] GUIDARA A, FERSI G, DERBEL F, et al. Impacts of temperature and humidity variations on RSSI in indoor wireless sensor networks[J]. Procedia Computer Science, 2018, 126: 1072-1081.

[9] FAN Y F, SUN H T. Environmental causality calibration: Advancing WLAN RF fingerprinting for precise indoor localization[J]. Plos One, 2024, 19(2): 0297108.

[10] 汪杰,宋书林,秦宁宇. 信号指纹测量下双度量协同的室内定位方法[J]. 电子测量与仪器学报, 2024, 38(3): 133-142.

WANG J, SONG SH L, QIN N N. Indoor localization method based on dual-metric coordination of signal fingerprint measurement[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(3): 133-142.

[11] VENKATESH R, MITTAL V, TAMMANA H. Indoor localization in BLE using mean and median filtered RSSI values[C]. 2021 5th International Conference on Trends in Electronics and Informatics, 2021: 227-234.

[12] CHEN B H, MA J, ZHANG L F, et al. Research progress of wireless positioning methods based on RSSI[J]. Electronics, 2024, 13(2): 360-379.

[13] SACCOMANNO N, BRUNELLO A, MONTANARI A. What you sense is not where you are: On the relationships between fingerprints and spatial knowledge in indoor positioning[J]. IEEE Sensors Journal, 2021, 22(6): 4951-4961.

[14] 王开亮,谢亚琴,宦海,等. 基于投票机制的室内 WiFi 指纹定位算法[J]. 电子测量技术,2023,46(12): 61-68.
WANG K L, XIE Y Q, HUAN H, et al. Indoor WiFi fingerprinting algorithm based on voting mechanism[J]. Electronic Measurement Technology, 2023, 46(12): 61-68.

[15] YARO A S, MALY F, MALY K, et al. Impact of varying distance-based fingerprint similarity metrics on affinity propagation clustering performance in received signal strength-based fingerprint databases[J]. IEEE Open Journal of Signal Processing, 2024, 5: 1005-1014.

[16] 周宁,雷少刚,赵东升,等. 基于 MWKNN-PF 的两阶段室内蓝牙定位方法[J/OL]. 吉林大学学报(工学版),1-8[2025-03-19].
ZHOU N, LEI SH G, ZHAO D SH, et al. A two-stage indoor bluetooth localization methodbased on MWKNN-PF[J/OL]. Journal of Jilin University (Engineering and Technology Edition), 1-8[2025-03-19].

[17] 郑安琪,秦宁宁. 空间指纹测量特征双精简下的室内定位算法[J]. 仪器仪表学报, 2023,44(10):80-89.
ZHENG AN Q, QIN N N. Indoor localization algorithm with dual refinement of spatial fingerprint measurement features[J]. Chinese Journal of Scientific Instrument, 2023,44(10):80-89.

作者简介



吴岩,2023 年于南昌大学获得学士学位,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短距通信辨析。
E-mail:wu0114@foxmail.com

Wu Yan received his B.Sc. degree from NanChang University in 2023. He is currently a master student at Jiangnan University. His main research interests include indoor positioning technology and analysis of

short-range communication.

 **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.

 **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.

 **王艳**,2000 年于南京理工大学获得学士学位,2003 年于南京理工大学获得硕士学位,2006 年于南京理工大学获得博士学位,现为江南大学教授,主要研究方向为工业互联网的智能制造与系统优化。
E-mail: wangyan@jiangnan.edu.cn

Wang Yan received her B.Sc. degree, M.Sc. degree and Ph.D. degree all from Nanjing University of Science and Technology in 2000, 2003 and 2006, respectively. She is currently a professor at Jiangnan University, Her main research interests include intelligent manufacturing and system optimization for industrial internet.